



Sosyal Bilimler
Enstitüsü

T.C.

MARMARA ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ
EKONOMETRİ ANABİLİM DALI
EKONOMETRİ BİLİM DALI

KARMA FREKANSLI ZAMAN SERİLERİNİN MODELLENMESİ:

BÜYÜK VERİ ÖRNEĞİ

Doktora Tezi

GÖZDE BOZKURT

İSTANBUL, 2022

T.C.

MARMARA ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ
EKONOMETRİ ANABİLİM DALI
EKONOMETRİ BİLİM DALI

KARMA FREKANSLI ZAMAN SERİLERİNİN MODELLENMESİ:

BÜYÜK VERİ ÖRNEĞİ

Doktora Tezi

GÖZDE BOZKURT

Danışman: Prof. Dr. ŞEVKET İŞİL AKGÜL

İSTANBUL, 2022

ÖZET

KARMA FREKANSLI ZAMAN SERİLERİNİN MODELLENMESİ: BÜYÜK VERİ ÖRNEĞİ

Yatırımcıların yeterince bilgi sahibi olmadan sadece farkında oldukları hisse senetlerine yatırım yaptıklarının varsayıldığı Yatırımcı Tanınmışlık Hipotezi'nin sınanmasında, yatırımcı ilgisi doğrudan ölçülebilen bir kavram olmadığı için aktif yatırımcı ilgisinin ölçümünde arama motoru ve sosyal medya verilerinden yararlanılabilmektedir. Finansal hizmetler alanının teknolojiyle buluşması sonucu, bu alanın durağanlık özelliğinin değişmesine, paranın yapısını ve dolayısıyla da tanımını değiştirecek yeni bir olguyu ve soruyu gündeme getiren kripto para ekonomisi hayatımıza girmiştir. Bu yenilikçi ve henüz dinamiklerinin araştırıldığı piyasada doğru değerlendirilmesi için büyük veri ve analitiğinin kripto para birimi endüstrisine getirebileceği değerlerin ortaya çıkarılması önemlidir. Endüstri 4.0 ile birlikte üretim süreçlerinde yer alan tüm birimler arası iletişimin sağlanmasında büyük verilere gerçek zamanlı erişim hedeflenmektedir. İletişim ağlarının yaratmış olduğu organik veriler doğası gereği düzensiz bir yaratma sürecine sahiptir. Kripto para fiyatları üzerinde tanınmışlığın etkisinin incelenmesinde piyasaya ait göstergeler ise düzenli frekanslarda elde edilmektedir. Bu problemin interpolasyon, boyut indirgeme, toplulaştırma gibi tekniklerle giderilmesi sonucu uygulanan klasik tahmin yaklaşımları bilgi kaybına neden olabilmektedir. Aynı zamanda bu veri yaratma sürecindeki hızlı teknoloji nedeniyle oluşan büyük verinin geleneksel ekonometrik yöntemlere uyarlanması oldukça zordur. Bu doğrultuda tez çalışmasında; büyük kripto ekonomisinin dinamiklerinin anlaşılmasında en uygun tahmin yönteminin belirlenmesi ve tahmin sonuçlarıyla ekonomik ve ekonometrik karşılaştırma yapmak için kullanılması hedeflenmiştir. İlişkilerin belirlenmesinde Transfer Entropi'ye dayalı Doğrusal Olmayan Granger Nedensellik analizi kullanılmış olup, kripto para fiyat tahmininde XGBoost algoritmasının en yüksek performansa sahip olduğu belirlenmiştir. Ancak karma frekans durumunun incelemesinin bu algoritmayla sağlanamaması nedeniyle MIDAS regresyon tahminleri gerçekleştirilmiştir. Elde edilen bulgular doğrultusunda, karma frekanslı verilerin modellenmesinde MIDAS regresyon ve makine öğrenmesi algoritmasını birleştiren hibrit model önerisinde bulunulmuştur.

Anahtar Kelimeler: Büyük Kripto Ekonomisi, Duygu Analizi, Karma Frekans, Doğrusal Olmayan MIDAS Regresyon, Makine Öğrenmesi Algoritmaları

ABSTRACT

MODELING OF MIXED FREQUENCY TIME SERIES: BIG DATA EXAMPLE

Since investor interest is not a directly measurable concept, search engine and social media data can be used to measure active investor interest in testing the Investor Reputation Hypothesis, which assumes that investors only invest in stocks of which they are aware without adequate knowledge. As a result of the meeting of the financial services field with technology, the crypto-money economy has entered our lives, which brings a new phenomenon and question that will change the stagnation feature of this field and change the structure of money and, therefore, its definition. It is essential to reveal the values that big data and analytics can bring to the cryptocurrency industry to correctly evaluate this innovative yet dynamic market. With Industry 4.0, real-time access to big data ensures communication between all units in the production processes. Organic data created by communication networks has an irregular creation process by nature. Market indicators are obtained at regular frequencies in examining the effect of reputation on cryptocurrency prices. Classical estimation approaches applied to eliminate this problem with techniques such as interpolation, dimension reduction, and aggregation may cause a loss of information. At the same time, it is not easy to adapt big data, which is formed due to the rapid technology in this data creation process, to traditional econometric methods. In this direction, the thesis study aims to determine the most appropriate forecasting method to understand the dynamics of the big crypto economy and to use it to make economic and econometric comparisons with the forecast results. Nonlinear Granger Causality analysis based on Transfer Entropy was used to determine the relationships, and it was determined that the XGBoost algorithm had the highest performance in cryptocurrency price prediction. However, MIDAS regression estimations were made because the analysis of the mixed frequency situation could not be achieved with this algorithm. In line with the findings, a hybrid model was proposed that combines MIDAS regression and machine learning algorithms in modeling mixed-frequency data.

Keywords: Big Crypto Economics, Sentiment Analysis, Mixed Frequency, Non-Linear MIDAS Regression, Machine Learning Algorithms

ÖNSÖZ

Her zaman farklı bakış açılarıyla doğru noktaya bakmamı sağlayan, her zorlukta güven veren, destek olan, bilgi ve tecrübesini sürekli paylaşan, hatalarımda büyük bir sabırla doğruyu gösterip yol gösterici olan saygıdeğer tez danışmanım Prof. Dr. Işıl AKGÜL'e teşekkür ve minnetimi sunarım. Doktora tez sürecinde değerli katkıları ve sabırla gösterdikleri yol için Prof. Dr. Melike BİLDİRİCİ ve Doç. Dr. Selin Devrim ÖZDEMİR YAZGAN'a çok teşekkür eder, saygılarımı sunarım. Hiçbir zaman desteğini esirgemeyen, deneyimlerini aktararak yardımcı olan ve her zaman disiplinli çalışmayı öğreten Prof. Dr. Volkan ÖNGEL'e teşekkürü borç bilirim. Ayrıca çalışma amacına uygun olarak veri desteği sağlayan Angelabs İnternet Yazılım ve Danışmanlık Hizmetleri Ticaret A.Ş'ye teşekkür ederim.

Benden maddi ve manevi desteğini hiç esirgemeyen başta dedem ve babaannem olmak üzere tüm aileme, her zorlukta karşılık beklemeden yanımda olan yol arkadaşım Niyazi Ateş'e teşekkürü borç bilirim.

Gözde BOZKURT

İstanbul, 2022

İÇİNDEKİLER

KISALTMALAR.....	ix
TABLolar LİSTESİ	x
ŞEKİLLER LİSTESİ	xiii
1.PARANIN DİJİTALE EVRİMİ	20
1.1. Para Kavramı ve Dönüşüm Süreci	20
1.1.1. Paranın Dijitalleşmesi	22
1.2. Kripto Para ve Blokzincir Teknolojisi.....	23
1.2.1. Kripto Para ve Kriptografi.....	23
1.2.2. Blokzincir Teknolojisi.....	25
1.2.3. Başlıca Kripto Paralar	29
1.2.3.1. Bitcoin.....	31
1.2.3.2. Ethereum.....	34
1.2.3.3. Litecoin	36
1.2.3.4. Ripple.....	38
1.3. Kripto Para ve Finansal Piyasalar	42
1.3.1. Alanyazın Taraması	42
2. BÜYÜK VERİ VE KRİPTO PARA	71
2.1. Büyük Veri.....	71
2.1.1. Büyük Veri Bileşenleri.....	72
2.1.2. Büyük Veri Analitiği.....	74
2.2. Büyük Veri ve Kripto Para Piyasası Teknolojisi.....	78
2.2.1. Büyük Veri ve Kripto Para	89
2.2.1.1.Alanyazın Taraması.....	90
2.3. Veri Madenciliği	95
2.3.1. Metin Madenciliği.....	96

2.3.2. Web Madenciliği.....	99
2.4. Duygu Analizi	101
2.4.1. Duygu Analizi Yöntemleri	104
2.4.1.1. Sözlük Temelli Yaklaşımlar.....	106
2.4.1.2. Makine Öğrenmesi Temelli Yaklaşımlar	106
2.4.2. Modelleme ve Sınıflandırma Teknikleri	107
2.4.2.1. Naive Bayes	108
2.4.2.2. Lojistik Regresyon.....	108
2.4.2.3. Yapay Sinir Ağları.....	109
3. KURAMSAL VE EKONOMETRİK ÇERÇEVE	110
3.1. Gündem Belirleme Kuramı.....	110
3.2. Yatırımcı Tanınmışlık Hipotezi	114
3.3. Veri Zarflama Analizi.....	115
3.4. Doğrusal Olmayan Granger Nedensellik Analizi.....	118
3.5. Markov Rejim Değişim Modeli	123
3.6. Markov Rejim Değişimli Vektör Otoregresif Model (MS-VAR)	126
3.7. Organik Veri	129
3.8. Düzensiz Zaman Serileri.....	130
3.9. Karma Frekans	132
3.9.1. MIDAS Regresyon.....	133
3.9.2. MIDAS Regresyon Polinom Spesifikasyonları	134
3.9.2.1. Sonlu Polinomlar: Üstel Almon ve Beta.....	135
3.9.2.2. Sonsuz Polinomlar.....	138
3.9.2.3. Genelleştirilmiş Tek Değişkenli Doğrusal MIDAS Regresyon Modeli.....	138
3.9.2.4. Doğrusal Olmayan MIDAS Regresyon Modeli.....	139

3.9.2.5. Çok Değişkenli MIDAS Regresyon Modeli.....	139
3.9.2.6. GARCH-MIDAS Regresyon Modeli.....	140
3.10. Otoreresif (AR) Model	142
3.11. AR-MIDAS Regresyon Modeli	142
3.12. MS-MIDAS Regresyon Modeli	142
3.13. MS-GARCH MIDAS Modeli	143
3.14. Diebold-Mariano Test.....	145
3.15. Makine Öğrenmesi Algoritmaları	146
3.15.1. Rastsal Orman (Random Forest) Regresyonu.....	147
3.15.2. Ekstrem Gradyan (XGBoost) Regresyon	149
3.15.3. Hafif Grandyan Artırma (LightGBM).....	151
3.15.4. K-en Yakın Komşuluk (KNN).....	152
4. KARMA FREKANSLI ZAMAN SERİLERİNİN MODELLENMESİ: BÜYÜK VERİ ÖRNEĞİ.....	148
4.1. Veri Toplama Tekniği	148
4.2. Anakütle ve Örneklem.....	148
4.3. Araştırma Kısıtları.....	149
4.4. Ön-Test Çalışması	149
4.5. Duygu Analizi	191
4.5.1. Veri Ön İşleme Sürecinden Geçirilmesi.....	192
4.5.2. Metin Verisinin Vektör Uzayında Gösterilmesi (Öznitelik Seçimi)	194
4.5.3. Sınıflandırma Teknikleri	195
4.6. Karma Frekanslı Zaman Serilerinin Modellenmesi.....	211
4.6.1. Doğrusal Olmayan MIDAS Regresyon Tahminleri.....	211
4.6.2. Hibrit Model Denemesi	220
SONUÇ VE DEĞERLENDİRME	226

KAYNAKÇA	231
EKLER	257



KISALTMALAR

AIC	Akaike Bilgi Kriteri
BIC	Bayesyen Bilgi Kriteri
BCC	Banker, Charnes, Cooper Modeli
BTC	Bitcoin
CCR	Charnes Cooper Rhodes Modeli
CSV	Virgüle Ayrılmış Değerler (Comma Separated Values)
DVR	Destek Vektör Regresyon
ETH	Ethereum
FOMO	Fırsatları Kaçırma Korkusu (Fear of Missing Out)
GT	Google Trend
IDC	Uluslararası Veri Şirketi (International Data Corporation)
LTC	Litecoin
MIDAS	Karma Frekanslı Veri Örnekleme Regresyon Modelleri (Mixed Frequency Data Sampling Regression Models)
MS	Markov Geçiş Modeli (Markov Switching Regression)
QR	Karekod (Quick Response)
USD	Amerika Doları (United States Dollar)
UTAUT	Birleştirilmiş Teknoloji Kabul Modeli (Unified Theory of Acceptance and Use of Technology)
VARNN	Vektör Otoregresif Sinir Ağı (Vector Auto-Regressive Neural Network)
VZA	Veri Zarflama Analizi
XRP	Ripple
YSA	Yapay Sinir Ağları

TABLolar LİSTESİ

Tablo 1. 2021 Mayıs Ayı İtibari ile İlk 10 Kripto Para Birimi	29
Tablo 2. Kripto Para Birimlerine Ait Korelasyon Durumu	40
Tablo 3. Kripto Para ve Finansal Piyasalar Çalışmaları.....	43
Tablo 4. Değişkenlerin Tanımlayıcı İstatistikleri (Logaritmik, Günlük Frekans)	48
Tablo 5. Korelasyon Analizi.....	49
Tablo 6. BDS Testi Sonuçları (Logaritmik Seriler)	51
Tablo 7. KSS Doğrusal Olmayan Birim Kök Testi Sonuçları.....	53
Tablo 8. BDS Testi Sonuçları (Logaritmik Fark Serileri)	54
Tablo 9. Kripto Para Piyasasının Markov Rejim Değişim Modelleriyle İncelendiği Çalışmalar.....	55
Tablo 10. Litecoin Arama Hacmi için Markov Rejim Değişim Modeli Tahmin Sonuçları: MSIAH(2)-AR(1)-X	57
Tablo 11. Geçiş Olasılıkları Gösterimi – Litecoin Google Arama Hacmi	58
Tablo 12. Rejimde Geçirilen Süre Gösterimi – Litecoin Google Arama Hacmi	58
Tablo 13. Litecoin Fiyatları için Markov Rejim Değişim Modeli Tahmin Sonuçları: MSIH(2)-AR(1)-X	58
Tablo 14. Geçiş Olasılıkları Gösterimi – Litecoin Fiyatları İçin	59
Tablo 15. Rejimde Geçirilen Süre Gösterimi – Litecoin Fiyatları İçin	59
Tablo 16. Bitcoin Google Arama Hacmi İçin Markov Rejim Değişim Modeli Tahmin Sonuçları: MSIH(2)-ARMA(1,1)-X	60
Tablo 17. Geçiş Olasılıkları Gösterimi – Bitcoin Google Arama Hacmi.....	61
Tablo 18. Rejimde Geçirilen Süre Gösterimi – Bitcoin Google Arama Hacmi	61
Tablo 19. Bitcoin Fiyatı için Markov Rejim Değişim Modeli Tahmin Sonuçları: MSIH(2)-ARMA(1,1)-X	61
Tablo 20. Geçiş Olasılıkları Gösterimi – Bitcoin Fiyatları İçin.....	62
Tablo 21. Rejimde Geçirilen Süre Gösterimi – Bitcoin Fiyatları İçin	62
Tablo 22. Ripple Google Arama Hacmi için Markov Rejim Değişim Modeli Tahmin Sonuçları: MSH(2)-AR(1)-X	63
Tablo 23. Geçiş Olasılıkları Gösterimi – Ripple Google Arama Hacmi.....	63
Tablo 24. Rejimde Geçirilen Süre Gösterimi – Ripple Google Arama Hacmi	64
Tablo 25. Ripple Fiyatı için Markov Rejim Değişim Modeli Tahmin Sonuçları: Dinamik MS(2)	64
Tablo 26. Geçiş Olasılıkları Gösterimi – Ripple Fiyatları İçin.....	65

Tablo 27. Rejimde Geçirilen Süre Gösterimi – Ripple Fiyatları İçin	65
Tablo 28. Ethereum Markov Rejim Değişim Modeli Tahmin Sonuçları: MSH(2)-AR(1)-X	66
Tablo 29. Geçiş Olasılıkları Gösterimi - Ethereum	66
Tablo 30. Rejimde Geçirilen Süre Gösterimi- Ethereum	66
Tablo 31. Ethereum Markov Rejim Değişim Modeli Tahmin Sonuçları: MSIH(2)-ARMA(1,1)-X	67
Tablo 32. Geçiş Olasılıkları Gösterimi- Ethereum	67
Tablo 33. Rejimde Geçirilen Süre Gösterimi - Ethereum	68
Tablo 34. Büyük Veri Kaynak, Tür ve Etkilediği Sektörler	68
Tablo 35. UTAUT Modelinin Yapısı ve Araştırma Hipotezleri	77
Tablo 36. Kripto Para Teknolojisi Kabul Modeli Alanyazın Araştırması.....	81
Tablo 37. Bileşik Güvenilirlik ve Yakınsak Geçerliliği	82
Tablo 38. Diskriminant Geçerliliği (Fornell-Larcker Test).....	86
Tablo 39. UTAUT Modeline İlişkin YEM Sonuçları	86
Tablo 40. Dolaylı Etkiler	87
Tablo 41. Büyük Veri ve Kripto Para Birimi İle İlgili Uygulamaların Özet Tablosu	87
Tablo 42. Kripto Para ve Büyük Veri Analitiği Çalışmaları	92
Tablo 43. MS-VAR Modelleri.....	127
Tablo 44. MS-MIDAS Modellerinin Sınıflandırılması	143
Tablo 45. Örneklem Bilgisi	154
Tablo 46. Tanımlayıcı İstatistikler (Düzye Kripto Para-Haftalık Frekans).....	154
Tablo 47. Tanımlayıcı İstatistikler (Logaritmik Kripto Para-Haftalık Frekans).....	155
Tablo 48. Tanımlayıcı İstatistikler (Düzye Twitter Hacimleri-Haftalık Frekans)	158
Tablo 49. Tanımlayıcı İstatistikler (Logaritmik Twitter Hacimleri-Haftalık Frekans)	158
Tablo 50. BCC Çıktı Odaklı Değişken VZA Sonuç Tablosu (2020).....	162
Tablo 51. BCC Girdi Odaklı Değişken VZA Sonuç Tablosu (2020)	163
Tablo 52. BCC Çıktı Odaklı Değişken VZA Sonuç Tablosu (2021).....	164
Tablo 53. BCC Girdi Odaklı Değişken VZA Sonuç Tablosu (2021)	165
Tablo 54. Tanımlayıcı İstatistikler (Düzye Kripto Para-Günlük Frekans).....	167
Tablo 55. Tanımlayıcı İstatistikler (Logaritmik Kripto Para-Günlük Frekans).....	167
Tablo 56. Tanımlayıcı İstatistikler (Düzye Twitter Hacim-Günlük Frekans)	170
Tablo 57. Tanımlayıcı İstatistikler (Logaritmik Kripto Para Fiyatı-Günlük Frekans).....	171
Tablo 58. BDS Testi Sonuçları (Logaritmik Kripto Para – Günlük Frekans)	174
Tablo 59. BDS Testi Sonuçları (Logaritmik Fark Kripto Para – Günlük Frekans)	176

Tablo 60. BDS Testi Sonuçları (Logaritmik Twitter Hacimleri – Günlük Frekans)	178
Tablo 61. BDS Testi Sonuçları (Logaritmik Fark Twitter Hacimleri – Günlük Frekans).....	180
Tablo 62. KSS Doğrusal Olmayan Birim Kök Testi Sonuçları (Kripto Para).....	182
Tablo 63. KSS Doğrusal Olmayan Birim Kök Testi Sonuçları (Twitter Hacim)	182
Tablo 64. Doğrusal Olmayan Granger Nedensellik Analizi (2020).....	184
Tablo 65. Doğrusal Olmayan Granger Nedensellik Analizi (2021).....	184
Tablo 66. MSIH-VAR(2) Model Tahmin Sonuçları.....	186
Tablo 67. MSIH-VAR(1) Model Tahmin Sonuçları.....	187
Tablo 68. MSIH-VAR(2) Model Tahmin Sonuçları.....	188
Tablo 69. MSIH-VAR(1) Model Tahmin Sonuçları.....	190
Tablo 70. MSIH-VAR(2) Model Tahmin Sonuçları.....	191
Tablo 71. MSIH-VAR(1) Model Tahmin Sonuçları.....	192
Tablo 72. MSIH-VAR(2) Model Tahmin Sonuçları.....	193
Tablo 73. MSIH-VAR(1) Model Tahmin Sonuçları.....	195
Tablo 74. Tanımlayıcı İstatistikler (Düzy Euro ve Dolar – Günlük Frekans)	205
Tablo 75. Tanımlayıcı İstatistikler (Logaritmik Euro ve Dolar – Günlük Frekans)	205
Tablo 76. BDS Testi Sonuçları (Logaritmik Euro ve Dolar – Günlük Frekans)	206
Tablo 77. BDS Testi Sonuçları (Logaritmik Fark Euro ve Dolar – Günlük Frekans)	207
Tablo 78. KSS Doğrusal Olmayan Birim Kök Test Sonuçları (Euro-Dolar–Günlük Frekans) .	208
Tablo 79. Tanımlayıcı İstatistikler (Logaritmik Fark Euro ve Dolar – Günlük Frekans)	208
Tablo 80. Algoritma Tahminlerinde Kullanılan Değişkenler	210
Tablo 81. Algoritma Fiyat Tahmin Performansları (ΔLXR)	210
Tablo 82. Algoritma Fiyat Tahmin Performansları (ΔLE)	210
Tablo 83. Algoritma Fiyat Tahmin Performansları (ΔLL).....	210
Tablo 84. Algoritma Fiyat Tahmin Performansları (ΔLB)	211
Tablo 85. MIDAS Regresyon Modelleri Performans Karşılaştırması	218
Tablo 86. Beta Polinomlu MIDAS Regresyon Modeli (ETH-2020)	219
Tablo 87. Beta Polinomlu MIDAS Regresyon Modeli (ETH-2021)	220
Tablo 88. Üstel Almon Polinomlu MIDAS Regresyon Modeli (LTC-2020).....	221
Tablo 89. Beta Polinomlu MIDAS Regresyon Modeli (LTC-2021)	222
Tablo 90. GARCH-MIDAS Regresyon Model (BTC)	225
Tablo 91. GARCH-MIDAS Regresyon Model (XRP)	225
Tablo 92. Klasik ve Hibrit Model Tahmin Performanslarının Karşılaştırılması	231
Tablo 93. MS-GARCH-MIDAS Regresyon Model (BTC).....	234

ŞEKİLLER LİSTESİ

Şekil 1: Merkezi ve Ademi Merkeziyetçi Dağıtılmış Ağ Örnekleri	25
Şekil 2: Blokzincir Çalışma Yapısı.....	26
Şekil 3: Gartner Hype Döngüsü.....	28
Şekil 4: 2021 Mayıs Ayı İtibari ile Kripto Para Piyasasında Yer Alan Para Birimleri	30
Şekil 5: Yıllara Göre Bitcoin Fiyat Değişimi (\$ Bazlı).....	31
Şekil 6: Yıllara Göre Google Aramalarda “Bitcoin”	32
Şekil 7: Yıllara Göre Dünya Geneli Bitcoin’e Gösterilen İlgi.....	32
Şekil 8: Yıllara Göre Ethereum Fiyat Değişimi (\$ Bazlı)	35
Şekil 9: Yıllara Göre Google Aramalarda “Ethereum”	35
Şekil 10: Yıllara Göre Dünya Geneli Ethereum’a Gösterilen İlgi	35
Şekil 11: Yıllara Göre Litecoin Fiyat Değişimi (\$ Bazlı)	36
Şekil 12: Yıllara Göre Google Aramalarda “Litecoin”	37
Şekil 13: Yıllara Göre Dünya Geneli Litecoin’e Gösterilen İlgi	37
Şekil 14: Yıllara Göre Litecoin Fiyat Değişimi (\$ Bazlı)	39
Şekil 15: Yıllara Göre Google Aramalarda “Litecoin”	39
Şekil 16: Yıllara Göre Dünya Geneli Litecoin’e Gösterilen İlgi	39
Şekil 17: Kripto Para Birimleri Logaritmik Fiyat Grafikleri.....	49
Şekil 18: Kripto Para Birimleri Logaritmik Google Trend Arama Hacimleri Grafikleri.....	49
Şekil 19: Litecoin Arama Hacmi -Markov Geçiş Rejim Olasılıkları – MSIAH(2)-AR(1)-X	58
Şekil 20: Litecoin Fiyatları için Markov Geçiş Rejim Olasılıkları – MSIH(2)-AR(1)-X	59
Şekil 21: Bitcoin Google arama hacmi Markov Geçiş Rejim Olasılıkları – MSIH(2)-ARMA(1,1)-X	61
Şekil 22: Markov Geçiş Rejim Olasılıkları – MSIH(2)-ARMA(1)-X	62
Şekil 23: Markov Geçiş Rejim Olasılıkları – MSH(2)-AR(1)-X.....	64
Şekil 24: Markov Geçiş Rejim Olasılıkları – MSH(2)-X.....	65
Şekil 25: Markov Geçiş Rejim Olasılıkları – MSH(2)-AR(1)-X.....	67
Şekil 26: Markov Geçiş Rejim Olasılıkları – MSIH(2)-ARMA(1,1)-X	68
Şekil 27: Küresel Veri Merkezine Ait Yıllık Büyüklük.....	72
Şekil 28: Büyük Veri Analitiği Zinciri.....	75
Şekil 29: Birleştirilmiş Teknoloji Kabul Modeli	81
Şekil 30: Önerilen Modele Ait Sonuçlar	88
Şekil 31: Kripto Para Birimleri Tweet Hacimleri (2019-2022).....	94
Şekil 32: Veri Madenciliği Model Türleri.....	96

Şekil 33: Madencilik Süreçleri Arası İlişki	97
Şekil 34: Metin Madenciliği ile İlişkili Alanlar	98
Şekil 35: Web Madencilik Türleri	100
Şekil36: ‘Cryptocurrency’ Etiketleri ile Paylaşılan Anlık Tweetlerin Duygularının Görselleştirilmesi (18.06.2022)	102
Şekil 37: ‘Cryptocurrency’ Etiketleri ile Paylaşılan Anlık Tweetlerin En Çok Birlikte Kullanıldıkları Kelime Setleri (18.06.2022)	103
Şekil 38: Duygu Analizi Yaklaşımı	103
Şekil 39: Duygu Analizi Görevlerinin Taksonomisi.....	105
Şekil 40: Tek Katmanlı Yapay Sinir Ağı	109
Şekil 41: CCR ve BCC Modellerinde Etkinlik Sınır Görüntüsü	116
Şekil 42: Granger Nedensellik için YSA Model Gösterimi	121
Şekil 43: Düzensiz Çok Değişkenli Zaman Serisi	126
Şekil 44: Düzensiz Zaman Serisi - Twitter.....	131
Şekil 45: Tahmin-Zaman Çizelgesi	134
Şekil 46: Almon Polinomiyal MIDAS Ağırlıkları.....	136
Şekil 47: Beta Polinomiyal MIDAS Ağırlıkları	137
Şekil 48: Rastsal Orman Regresyon Algoritma Yapısı.....	148
Şekil 49: XGBoost Model Gelişimi.....	149
Şekil 50: Düzey Kripto Para Zaman Grafikleri (2020-Haftalık Frekans)	156
Şekil 51: Logaritmik Kripto Para Zaman Grafikleri (2020-Haftalık Frekans).....	156
Şekil 52: Düzey Kripto Para Zaman Grafikleri (2021-Haftalık Frekans)	157
Şekil 53: Logaritmik Kripto Para Zaman Grafikleri (2021-Haftalık Frekans).....	157
Şekil 54: Düzey Twitter Hacimleri Zaman Grafikleri (2020-Haftalık Frekans)	159
Şekil 55: Logaritmik Twitter Hacimleri Zaman Grafikleri (2020-Haftalık Frekans)	159
Şekil 56: Düzey Twitter Hacimleri Zaman Grafikleri (2021-Haftalık Frekans)	160
Şekil 57: Logaritmik Twitter Hacimleri Zaman Grafikleri (2021-Haftalık Frekans)	160
Şekil 58: Düzey Kripto Para Zaman Grafikleri (2020-Günlük Frekans)	168
Şekil 59: Logaritmik Kripto Para Zaman Grafikleri (2020-Günlük Frekans)	169
Şekil 60: Düzey Kripto Para Zaman Grafikleri (2021-Günlük Frekans)	169
Şekil 61: Logaritmik Kripto Para Zaman Grafikleri (2021-Günlük Frekans)	170
Şekil 62: Düzey Twitter Hacim Zaman Grafikleri (2020-Günlük Frekans).....	172
Şekil 63: Logaritmik Twitter Hacim Zaman Grafikleri (2020-Günlük Frekans)	172
Şekil 64: Düzey Twitter Hacim Zaman Grafikleri (2021-Günlük Frekans).....	173

Şekil 65: Logaritmik Twitter Hacim Zaman Grafikleri (2021-Günlük Frekans)	173
Şekil 66: Etki-Tepki Fonksiyon Grafiği (Ethereum-2020).....	187
Şekil 67: Etki-Tepki Fonksiyon Grafiği (Ripple-2020)	188
Şekil 68: Etki-Tepki Fonksiyon Grafiği (Bitcoin-2020)	189
Şekil 69: Etki-Tepki Fonksiyon Grafiği (Bitcoin-2020)	190
Şekil 70: Etki-Tepki Fonksiyon Grafiği (Ethereum-2021).....	192
Şekil 71: Etki-Tepki Fonksiyon Grafiği (Ripple-2021)	193
Şekil 72: Etki-Tepki Fonksiyon Grafiği (Bitcoin-2021)	194
Şekil 73: Etki-Tepki Fonksiyon Grafiği (Bitcoin-2021)	195
Şekil 74: Önerilen Metodoloji Çerçevesi	197
Şekil 75: İşlenmemiş Veri Görüntüsü	198
Şekil 76: Normalizasyon İşlemi Uygulanmış Veri Görüntüsü	198
Şekil 77: TF-IDF.....	199
Şekil 78: <i>Train_test_split()</i>	200
Şekil 79: Duygu Analizi Model Skorları (2020)	202
Şekil 80: Duygu Analizi Model Skorları (2021)	202
Şekil 81: CSV Formatında Kodlama Görüntüsü	203
Şekil 82: Düzey Euro-Dolar Zaman Grafikleri (Günlük Frekans).....	206
Şekil 83: Logaritmik Euro-Dolar Zaman Grafikleri (Günlük Frekans)	206
Şekil 84: Logaritmik Fark Euro-Dolar Zaman Grafikleri (Günlük Frekans)	209
Şekil 85: Ethereum XGBoost Algoritması Fiyat Tahmin Grafiği (2020)	212
Şekil 86: Litecoin Rastsal Orman Algoritması Fiyat Tahmin Grafiği (2020)	212
Şekil 87: Bitcoin XGBoost Algoritması Fiyat Tahmin Grafiği (2020).....	213
Şekil 88: Ripple Karar Ağacı Algoritması Fiyat Tahmin Grafiği (2020).....	213
Şekil 89: Ethereum XGBoost Algoritması Fiyat Tahmin Grafiği (2021)	214
Şekil 90: Litecoin Rastsal Orman Algoritması Fiyat Tahmin Grafiği (2021)	214
Şekil 91: Bitcoin XGBoost Algoritması Fiyat Tahmin Grafiği (2021).....	215
Şekil 92: Ripple Karar Ağacı Algoritması Fiyat Tahmin Grafiği (2021).....	215
Şekil 93: Kombinasyon-MIDAS-XGBoost Model Akış Şeması.....	223
Şekil 94: Tahmin Kriter Değerleri Karşılaştırması	225

GİRİŞ

Çalışmanın birinci bölümünde paranın dijital dönüşümü, blokzincir teknolojisi, kripto para birimleri ve finansal piyasalar ile ilişkisi üzerinde durularak davranışsal iktisat bağlamında değerlendirilmiştir. Öncelikle kripto para piyasası hakkında gerçekleştirilen çalışmalar için alanyazın incelendiğinde sıklıkla kripto paraların finansal varlıklarla karşılaştırıldığı görülmüştür. Alanyazında, araştırmacıların sıklıkla kripto para birimlerinin yatırım aracı olarak yüksek getiri sağladığını ancak henüz güvenilir olmadığı görüşünde oldukları görülmüştür. Bu yatırım araçlarının spekülatif kullanıma açık olduğu görüşü iddia edilmektedir. Bu nedenle son yıllarda kripto paraların birbirleriyle olan ilişkilerinin incelendiği çalışmaların sayısında artış görülmektedir. Kripto para piyasasında yatırımcı ilgisinin ölçülerek değerlendirilmesi için Google Trend arama hacimleri ile piyasaya değer olarak hakim dört kripto para fiyatı (bitcoin, ethereum, litecoin, ripple) arasındaki ilişki incelenmiştir. Grafik analizleri ve yapılan testler sonucunda serilerin doğrusal olmadıkları belirlenmiş ve bu noktadan hareketle ilk olarak tüm veri seri için uygun Markov Rejim Değişim modelleri tahmin edilmiştir. Cari dönemdeki rejimin ve rejimde kalma olasılıklarının belirlenebilmesi, yatırımcılar açısından önemli bilgiler sağlayacaktır. Bu aşamada elde edilen bulgulardan hareketle, ilgili kripto paraların sürekli olarak rejim değişimlerinin takip edilmesi halinde yatırımcıların portföy kararlarını şekillendirmesi mümkün görünmektedir. Aynı zamanda kripto paralarla ilgili alanyazında sıklıkla ifade edilen yüksek oynaklık, spekülasyon vb. sorunlara karşı Markov rejim değişim modellerinden elde edilen bulgular doğrultusunda, cari rejiminin bilinmesi durumunda sonraki dönemlerin öngörülebilirliğinin arttığı ifade edilebilir. Ayrıca kripto paraların yalnızca fiyatlarının değil, aranma sıklıklarının dolayısıyla da popüleritesinin izlenmesi ile bir sonraki dönemin rejiminin de öngörülebilecek olmasından bahsedilebilir. Genel olarak değerlendirildiğine, rejimlerin cari dönemde kalıcılık eğiliminin olduğu ve çok sık değişim yaşanmadığı belirlenmiştir.

Çalışmanın ikinci bölümünde büyük veri, büyük veri ve kripto para piyasası ilişkisi ile büyük kripto ekonomisi üzerinde durulmaktadır. Kripto para teknolojisinin yeni bir teknoloji olması ve klasik finansal sistemden farklı dinamiklere sahip olması, beraberinde klasik finans mekanizmalarının hıza ayak uydurmakta zorlanmasına da neden olmaktadır. Dünya genelinde kullanıcılar ve makinelerce sentezlenen sanal ve dijital verilerin miktar ile çeşitliliğinde büyük bir artış yaşanmaktadır. Finans sektörü çalışanları da sürekli olarak farklı piyasaların geleceğini araştırmakta ve tahminlerde bulunmaktadır. Özellikle gelecek tahminlerinin yani ileriye yönelik öngörülerinin daha etkin şekilde yapılabilmesi için etkili modellere olan gereksinim giderek artmaktadır. Finans sektöründe kripto para birimleri ve büyük veri muazzam bir

teknolojik gücü bir araya getirmektedir. Küresel ölçekte milyarlardan trilyonlarca dolara kadar değişim gösteren yatırımlar dikkat çekmektedir. Çünkü kripto para piyasası tüm hızıyla ilerleme gösteren blokzincir teknolojisini kullanmaktadır. Bu nedenle hem blokzincir hem de büyük verinin birbirini tamamlayan teknolojiler olabileceği söylenebilir. Ancak yeni bir teknolojik altyapıyı kullanan yeni finansal araçlar üzerinde inceleme yapmadan önce, mevcut yeniliğin bireyler tarafından nasıl algılandığının incelenmesi uygun olacaktır. Teknolojinin daha detaylı değerlendirilebilmesi için öncelikle bireyler tarafından bu teknolojinin dinamiklerinin ne kadar önemli olduğunun belirlenmesi gerekmektedir. Bu amaçla davranışsal iktisat bağlamında gerçekleştirilen bir anket çalışmasıyla Teknoloji Kabul Modeli oluşturulmuştur. Elde edilen bulgulara göre bir kripto para birimi tarafından sunulan katma değer ne kadar fazlaysa, kullanılma olasılığının o kadar arttığı ifade edilebilir. Bu bulgudan hareketle performans kullanışlılığına odaklanmak, kripto para piyasasında önerilen bir strateji olabilir. Bu bağlamda performans beklentisi değişkeninin, yeniliğin kişinin performansına etkisi olarak almak yerine, yenilikten beklenen performansı ifade edecek kapsamda şekillendirilmesi gerekmektedir. Kripto para piyasasının davranışsal iktisat bağlamında değerlendirildiği alanyazına bakıldığında ise daha çok teknolojinin yaratmış olduğu büyük veriyle güvenlik ve ağ yapısı gibi araştırmaların sıklıkla yapıldığı görülmüştür. Sosyal bilimci alan yazında ise sıklıkla kripto para ve pay piyasalarının birlikte ele alındığı çalışmalar yapıldığı görülmüştür. Bu kapsamda düşünüldüğünde, sosyal bilimci araştırmacıların, kripto para piyasasının yarattığı büyük verinin doğru/uygun tekniklerle analiz edilmesi ve bulguların yorumlanması halinde stratejik karar almada ve risk yönetiminde inovasyon (yenilik) yapılmasına olanak verebilecektir. Bu nedenle kripto para piyasası, büyük veri analitiği için iyi bir kaynak görevi görmekle birlikte, kripto para birimlerinin devrimi ve gelişiminde de önemli noktadır. Tüm yukarıda bahsedilenleri kapsayan, büyük veri analitiği ile kripto para piyasasını birleştiren ve davranışsal iktisat bağlamında değerlendirme yapılmasını sağlayacak tekniklere bu bölümde yer verilmiştir.

Çalışmanın üçüncü bölümünde kuramsal çerçeve kapsamında Gündem Belirleme Kuramı ve Yatırımcı Tanınmışlık Hipotezi üzerinde durulmaktadır. Ayrıca karma frekanslı verilerin analizi için geliştirilen MIDAS regresyon ve makine öğrenmesi regresyon algoritmalarına teorik olarak yer verilmiştir. Çalışmanın ilk iki bölümünde yapılan araştırmalardan elde edilen bulgular doğrultusunda, medya ile kamu gündemi arasındaki yüksek korelasyonun belirlenmesinin ardından nedensel bağlantılar ve zaman dizisinin gösterilmesi gerekliliği doğmuştur. Dolayısıyla kamu gündemi ile medya içerikleri arasındaki bu yüksek korelasyonlu ilişkide belirleyicilerin hangileri olduğu ve yönünün ne olduğu Gündem Belirleme Kuramı bağlamında temel önerme niteliği taşımaktadır. Bu doğrultuda tez çalışmasında, bilgi toplumlarına dijital para birimleri

hakkında yeni olarak nitelendirilebilecek bu finansal sistemle olan ilişkinin belirlenmesi gündem belirleme kuramı bağlamında ele alınmıştır. Büyük ekonomik belirsizliğin olduğu kripto para piyasasında yatırımcıların belirsizlik durumunda dahi kripto para birimlerine yatırım yapmaya eğilimli olduğu araştırmalarla desteklenmiştir. Bu doğrultuda tez çalışmasında, elde edilen bulguların Yatırımcı Tanınmışlık Hipotezini destekleme durumu incelenmiştir. Yine bu bölümde kripto para piyasasında yatırımcı davranışının etkisinin incelenmesinde kullanılan Veri Zarflama Analizi ve Yapay Sinir Ağı tabanlı Doğrusal Olmayan Granger Nedensellik Analizi'nin teorisine yer verilmiştir. Ancak kripto para piyasasının Gündem Belirleme Kuramı bağlamında incelenebilmesi için sosyal medya platformu olan Twitter'dan elde edilen içeriklerin büyük veri olması nedeniyle işlenmesi zorluğu ortaya çıkmaktadır. Anlık etkileşime açık olan bu platformlar aracılığı ile gerçek zamanlı ve etkileşimli büyük veri yığınları oluşmaktadır. Ancak kripto piyasasının göstergelerine ait verilerin aynı sıklıkta elde edilmesi olanaklı değildir. Alanyazına bakıldığında araştırmacıların sıklıkla her iki gösterge için de toplulaştırma işlemi yaparak geleneksel metotları kullandıkları görülmektedir. Ancak yeni teknolojiye sahip bu piyasanın dinamiklerinin anlaşılmasında verinin yaratma sürecinin gözardı edilmesi sonucu yaşanacak olan bilgi kaybının önüne geçilmesi gerekmektedir. Bu kapsamda yapılan Doğrusal Olmayan Nedensellik Analizi sonucunda, alanyazında incelenen çalışmalardan farklı sonuçlar elde edilmiştir. Buradan hareketle, verilerin frekansını değiştirmeden modellenmesine olanak veren doğrusal olmayan MIDAS regresyon ve makine öğrenmesi regresyon algoritmalarına teorik olarak yer verilmiştir.

Çalışmanın dördüncü bölümünde birinci ve ikinci bölümlerde ön araştırması yapılan kripto para teknolojisi, üçüncü bölümde verilen kuramsal çerçeve bağlamında karma frekanslı büyük veri analiz edilerek sonuçlar Yatırımcı Tanınmışlık Hipotezi bağlamında değerlendirilmiştir. Araştırma doğrultusunda kripto para piyasasında yüksek işlem hacmiyle yer alan “Bitcoin”, “Ethereum”, “Litecoin” ve “Ripple” için sosyal medya platformlarından olan Twitter üzerinden yapılan paylaşımlar “13.05.2020 – 30.09.2020” ve “13.05.2021 – 30.09.2021” dönemleri için elde edilmiştir. Aynı zamanda fiyat ve getiri serileri ile küresel para piyasasının da etkisinin incelenmesi adına Dolar ve Euro serileri de toplanmıştır. İlgilenilen kripto paraların piyasa etkinliğinin incelenmesinde Veri Zarflama Analizi kullanılmış olup, haftalara göre değişkenlik gösteren sonuçlarla birlikte kripto paraların etkinlik sınırına çok yakın oldukları belirlenmiştir. Ardından yine bir ön araştırma özelliğinde olan, finansal piyasalar hakkındaki bilgilerin medya kanalları aracılığı ile bireylere aktarılmasının kitle alım-satım kararlarında ve dolayısıyla fiyatlar üzerinde etkileyici olduğu varsayımının desteklenmesi adına ilişkilerin yönünün incelenmesinde, diğer bir kişisel araştırma olarak Transfer Entropi (transfer entropy-TE) temeline dayanan

doğrusal olmayan Granger nedensellik testi gerçekleştirilmiştir. Farklı gecikmelerde ve dönemlere göre değişmekle birlikte, incelenen kripto paraların fiyatlarının Twitter paylaşımları ile ilişkili olduğu ve bu ilişkilerin yönü gerçekleştirilen keşifsel ön-testler aracılığı ile belirlenmiştir. Dolayısıyla yatırımcıların yeterince bilgi sahibi olunmaması bile sadece farkında oldukları kripto paralara yatırım yaptıklarını söylemek mümkün olmakla birlikte “Yatırımcı Tanınmışlık Hipotezi”nin de desteklediği belirlenmiştir. Ancak daha detaylı araştırma yapılması adına Twitter aracılığı ile elde edilen verilerle doküman tabanlı duygu analizinin yarı denetimli makine öğrenmesi algoritmalarıyla uygulanmasıyla gerçekleştirilmiştir. İlgili kripto paraların fiyat tahminlerinin yapılmasında performansı en yüksek makine öğrenmesi algoritmaları belirlenmiştir. Ancak bu algoritmalarda ele alınan değişkenlerin aynı frekansa sahip olması gerekliliği ve sosyal medya platformlarından elde edilen büyük verilerin frekansının piyasa değişkenleriyle uyumsuz olduğu bilinmektedir. Büyük veride gerçekleştirilen toplulaştırma işleminin bilgi kaybına neden olacağı görüşünden hareketle, karma frekansa sahip değişkenler arasındaki ilişki, doğrusal olmayan MIDAS regresyon yöntemleriyle araştırılmıştır. Tahmin edilen modellerin öngörü performansına göre karşılaştırılması sonucu kripto paralara ait en iyi tahmin modelleri belirlenmiştir. Modellerden elde edilen tüm bulgular bir arada değerlendirildiğinde ilgili kripto paralar kapsamında Yatırımcı Tanınmışlık Hipotezi’nin doğrulandığı görülmüştür. Ancak kripto para piyasası ve sosyal medya yapılandırılmamış verilerinin dinamik yapısı gereği tahmin performansının artırılmasına yönelik hibrit model önerisinde bulunulmuştur. Hibrit modeller makine öğrenmesi algoritmalarında en yüksek başarıyı yakalayan XGBoost algoritmasının MIDAS regresyon ile birleştirilmesiyle elde edilmiştir. Tüm bu analizler sonucunda tahmin edilen modellere ait performansların karşılaştırılması ile kripto para piyasasında kullanılacak yaklaşımlardan bahsedilmiştir.

BÖLÜM 1

PARANIN DİJİTALE EVRİMİ

Tezin birinci bölümünde paranın dijital dönüşümü, blokzincir teknolojisi, kripto para birimleri ve finansal piyasalar ile ilişkisi üzerinde durulmaktadır.

1.1. Para Kavramı ve Dönüşüm Süreci

Mal ve hizmet takası anlamında kullanılan para kelimesi dilimize Farsça “pare” kelimesinden “küçük parça” ifadesiyle gelmiştir (Sarp Nebil, 2018:3). Paranın en bilinen tanımı Galbraith tarafından “*insanların para olarak kullanmak üzere kabul edeceği her şey*” şeklinde yapılmıştır (Galbraith, 1990:30). Mal ve hizmet ödemesinde kullanılacak bir aracın para olarak nitelendirilebilmesi için her şeyden önce genel kabul görmesi gerekmektedir. Paranın niteliği, içeriğinin ne olduğunun bilinmesi ve insanlar tarafından kabul edilebilirliği ölçüsünde belirlenmektedir. Bu durumda paranın belirlenmesinde insan davranışlarının ön plana çıktığını ve hatta aslında şart olduğunu söylemek mümkündür (Mishkin, 2003:51). Paranın tarihi incelendiğinde, çeşitli zamanlarda ve yerlerde çeşitli roller edindiği görülmektedir. Para ve kimlik araştırmalarıyla bilinen ve “*Before Babylon, Beyond Bitcoin*” kitabıyla tanınan Birch, son beş bin yıllık para tarihini üç döneme ayırmaktadır. Paranın ortaya çıkışı kabul edilen M.S. 806 yılından 1871 yılına kadar olan dönem; değerli taşlar, para, kâğıt, tohumlar gibi fiziksel ortamlarda bulunuşu *Para 1.0* dönemi olarak ifade edilirken 1871 yılında Western Union’ın telgraf ağı üzerinden resmi olarak ilk elektronik fon transferini yapışı ve kredi kartı gibi unsurların başlaması sonucu fiziksel formunu kaybeden paranın 1971 yılına kadar olan bu durumu da *Para 2.0* dönemi olarak ifade edilmektedir. 1971 yılında ABD başkanı Nixon, Bretton Woods anlaşmasını yok sayarak doların altına olan konvertibilitesini kaldırması sonucunda paranın fiziksel karşılığı olmaması, bütünüyle kavramsal kabule dönüşmesini ifade eden ve hala daha içerisinde bulunduğumuz dönem *Para 3.0* olarak tanımlanmaktadır. Amerikan hükûmeti 1972-73 yıllarında Suudi kraliyet ailesiyle, petrolü yalnız dolarla satmaları hususunda bir anlaşma gerçekleştirmiştir. Diğer Petrol İhraç Eden Ülkeler Teşkilatı (OPEC) ülkelerinin de bunu takip etmesi sonucu petrol karşılığı olarak sadece dolar kabul edilir hale gelmiştir. Petrolün dolar cinsinden fiyatlanması ve dolara yönelik uluslararası talebin ortaya çıkması ile Petro-dolar sistemi başlamış olup günümüzde de sürmektedir. Birch, insanlığın içerisinde bulunduğu bu dönemin olgunlaşma

sürecinde olduğunu ancak kısa zaman içerisinde de son bulacağını ifade etmiştir (Birch, 2017:14-20). Çünkü “21. Yüzyılın petrolü bilgidir” (Aksu, 2015:1).

Paranın tarihi incelendiğinde, farklı dönemlerde şekil değiştirerek farklı işlevler kazandığı görülmektedir. İnsanlık tarihinde her dönem için borç ödenmesinde nihai kabul görülen araç niteliğinde olduğu kabul edilirken paranın evrim süreci incelendiğinde ekonomik veya fiziksel özelliğinden çok davranışsal ve psikolojik açıdan değerlendirilen bir niteliğe sahip olduğu görülmektedir. Bu nedenle para niteliği taşıyacak aracın fiziksel formundan çok toplum tarafından genel kabul görmüş olması önemli bir noktadır. Bu nedenle tüketicilerin para niteliğindeki araca olan güvenleri, ihtiyaçları doğrultusunda belirlenmesi ve psikolojik düşünceleri paranın evrilmesindeki temel motivasyonu oluşturmaktadır. Bu durumda da, toplumun subjektif değerleri, para olarak nitelendirilecek aracın görevlerini belirlemektedir (Özyurt, 2012:8). Bilişim teknolojilerinin 20. yüzyılın son çeyreğinden sonra hızlı gelişiminin paraya yansımaları da yine toplumsal ihtiyaçların değişmesinde görülmektedir. Teknolojinin hızla ilerlemesi, toplumların fiziki olarak bulunmasını gerektirmeyen ödeme alternatiflerinin gelişmesine yardımcı olmuştur. Para yerine sanal para, kredi kartı gibi araçların kullanımının etkisinin ödeme sistemlerinde hissedilmesi sonucu teknolojinin para üzerindeki önemi artmıştır. Teknolojik gelişmeler sonucu formu yeni bir değişime uğrayan para, henüz tam olarak geleneksel işlevleri karşılamasa da para olgusunun gelişiminin son halkası olarak gelecek vaat etmektedir (IMF, 2018:52). Bu önemli değişimle birlikte akla gelmesi ve üzerinde durulması gereken dönem, yakın gelecekte yaşanacak olan *Para 4.0* dönemidir.

Para 3.0 döneminde gelişen teknolojiyle birlikte, denge sağlanması hedefli arz kontrol mekanizması ve dolandırıcılık, sahte işlem gibi güvenlik sorunları nedeniyle yeni yaklaşımlara gereksinim duyulmaktadır. Dijitalleşen dünyayla birlikte paranın temel niteliklerine uygun sayısal formunun üretilmesi çabası da gündeme gelmektedir (Usta ve Doğanekin, 2018: 44). Günümüzde paranın nakit formda tutulmasından çok elektronik ortamda kullanımının tercih edilmesi, *kaydi para* niteliğini doğurmuş olup günümüz finans dünyasına da etkileri yansımaktadır. Ticari işlemlerin ve para transferlerinin yoğunlukla dijital ortamlarda yapılabilir nitelikte altyapının oluşturulması, hızlı ve güvenilir ödeme sistemini de beraberinde getirmiştir. *Para 3.0* döneminde gerçekleşen bu yeniliklerle birlikte toplumların dijital deneyimleri yaşaması sonucunda teknoloji, ödeme aracı olan paranın üzerinde önemli bir ayrıştırıcı unsur haline gelmektedir. Toplumların daha rahat ve hızlı deneyim yaşaması, kurumların zaman ve maliyet tasarrufu sağlaması sonucu teknoloji ile değer zinciri organizasyonlarının kolektif bir bütünü olan

Para 4.0 dönemi, yakın gelecek için varlığını hissettirmektedir. Bu döneme hakim olacağı düşünülen katma değerlerden birisi olan *dijital para* ve/veya *kripto para* ödeme araçları *Para 3.0* döneminde kendini göstermiştir. Günümüzde gelişmiş ülkelerde itibari para kullanımı gün geçtikçe azalmaktadır. Ödemeler sisteminde büyük ölçüde dijital platformlar altyapısının kullanıldığı görülmektedir. Bu da, yakın gelecekte yaşanacak olan *Para 4.0* döneminin belli bir otoriteye bağlı olmayan kripto para birimlerinin hakimiyetinde olacağının sinyalini vermektedir. Gelecekte yapay zekâ ve kripto para birimlerinin de altyapısını oluşturan blokzincir hibriti ürünlerin öne çıkacağı bir dönem öngörülmektedir (Claian vd., 2016:1813). *Para 4.0* sürecine geçişle birlikte kripto paralar ve blokzincir teknolojisinin ekonomideki rolünün ciddi boyutlara geleceği düşünülmektedir (Birch, 2017:14-19).

1.1.1. Paranın Dijitalleşmesi

Klasik para anlayışından farklı bir yapıda ortaya çıkan dijital para, son yıllarda dünya genelinde yaygınlaşan bir alternatif değişim aracı niteliğindedir. İtibari paranın temsili olan dijital paralar, elektronik ortamda saklanarak transfer edilebilir özelliktedir. Altın, altına dayalı kâğıt para ve sonrasında dijital paraya geçiş, bilgi ve iletişim teknolojilerinde yaşanan gelişmeler sayesinde yaygınlaşmaktadır. Tarihi boyunca fiziksel açıdan değişik şekillere bürünen paranın bugününe baktığımızda sanallaşma görülmektedir. Teknolojinin gelişmesiyle birlikte oluşan dijitalleşme, paranın sanallaşmasını da devam ettirmektedir. Dijital para fikri ilk olarak 1980'lerin sonunda Hollanda'da ortaya çıkmıştır. Ülkede benzin istasyonu sahipleri ve kamyonculara yönelik hırsızlığın engellenebilmesi adına akıllı kart sistemi geliştirilmiştir. Bu sistem aracılığıyla yakıt alınabilmesi sağlanmıştır. Aynı dönemde Avrupa'da ise müşterilerin banka hesaplarından doğrudan ödeme yapabilmesi için satış noktaları terminali (POS cihazları) kullanılmaya başlanmıştır. İlk e-para uygulaması ise 1990'larda Asya ve Avrupa'da elektronik cüzdan formunda olan kart tabanlı ürünler çıkartılmıştır (Altay, 2017: 36). Paranın dijital ortama girmesi sonucu kredi kartı, e-cüzdan, PayPal gibi farklı ödeme yöntemleri de ortaya çıkmıştır. Dolayısıyla para giderek fiziksel mahiyetini kaybetmeye başlamıştır. Wriston tarafından bu durum, "*modern kablolu bir ekonomi oluşturmak*" olarak ifade edilmektedir. Bu ifade, paranın kendini bitlere ve baytlara dönüştürmesi anlamına gelmektedir (Wriston, 1996).

Dijital paranın artan kullanımı, hem ülkelerin hem de kurumların önceliği haline gelmektedir. Avrupa Merkez Bankası Başkanı Christine Lagarde, başkan sıfatıyla gerçekleştirdiği ilk konuşmasında "*bankanın özel görev komitesinin dijital paralara yönlendirme planı*" olduğunu

ifade etmiştir. Legarde aynı zamanda geleneksel bankacılık sistemlerinin önüne geçebilecek yeni teknolojilerin kullanımında Avrupa Merkez Bankası'nın öncü rol oynaması gerekliliğini de vurgulamıştır. Türkiye için bakıldığında, Cumhurbaşkanlığı Hükümet Sistemi'nin 2019-2023 dönemini kapsayan ilk kalkınma planı olan ve 23 Temmuz 2019 tarihli Resmi Gazete'de yayınlanarak yürürlüğe giren 11.Kalkınma Planı'nda da "Blokzincir Tabanlı Dijital Merkez Bankası Parası" kararının yer aldığı görülmektedir (TC. Strateji ve Bütçe Başkanlığı, 2019). Güney Kaliforniya Üniversitesi'nde sosyolog Manuel Castells "*Büyük teknolojik değişimin bütün anlarında insanlar, şirketler ve kurumlar değişimin derinliğini hisseder, ama çoğu zaman, tamamen onun etkileri konusunda cehaletleri yüzünden, değişimin altında kalırlar*" ifadesiyle, değişen paranın oluşturduğu yeni ekosistemin incelenmesi gerekliliği üzerinde durmaktadır (Schwab, 2016:102).

Bu ve benzeri gelişme ve ihtiyaçlar, insanların para üzerinde yeniliğe gitme ve oluşturma arayışına itilmesine neden olmuştur. Böylece ilk olarak sanal para birimleri oluşturulmuştur. Ancak sanal para birimlerinde, aynı dijital varlığın aynı anda birden fazla kez transfer edilmesi girişimi işlemi olan çifte harcama (double spending) yapma gibi aksaklıklar nedeniyle başarısız olunmuştur. Teknolojinin gelişmeye devam etmesiyle birlikte kriptoloji gibi teknolojiler kullanılarak çifte harcama ve harcamayı yapanın kontrolü olanaklı hale getirilmiştir. Getirilen bu çözümün temelinde blokzincir altyapısı yer almaktadır. Blokzincir teknolojisi sayesinde çifte harcamanın olanaklı olmadığı, merkezi otoriteye bağlı olmayan ve tamamen şeffaf, kontrol edilebilir kripto para birimleri meydana gelmiştir. Bu teknoloji, geçmişten bugüne dijital varlıkları içeren her çevrimiçi işlemin her zaman doğrulanabileceği, dağıtılmış bir uzlaşmayı sağlayarak, dijital dünyada devrim yapma potansiyeline sahiptir (Crosby, 2016:8).

1.2.Kripto Para ve Blokzincir Teknolojisi

Son on yılda finansal hizmetler alanının teknolojiyle buluşması sonucu, bu alanın durağanlık özelliği değişmiştir. Finansal hizmetlerde yer alan aktörlerin zamanla birbirine dönüşebilir olması, teknolojinin getirdiği bir yenilik ve değişim sürecidir. Dijital bilgi teknolojileriyle birlikte iletişimde yaşanan reformda etkili olan kripto paraları ve bu paraların alt yapısı olan blokzincir teknolojisidir (Polat ve Akbıyık, 2019:445).

1.2.1. Kripto Para ve Kriptografi

Kripto para, "*bir blokzincirindeki birimlerin oluşumunu ve dağıtımını düzenlemek için kriptografik tekniklerin kullanıldığı dijital hesap birimleri*" olarak tanımlanmaktadır (Nagaraj


vd., 2018:2). Keynes'e göre devlet parasının alabileceği "mal, itibari, idari" olmak üzere üç biçim vardır (Keynes, 1935:115). Kripto para topluluğu için Keynes'in tanımladığı bu üç biçiminde hepsini kapsar nitelikte olduğu söylemleri mevcuttur. Ancak paranın temel özellikleri bakımından incelendiğinde, bazılarını karşılayamadığını söylemek mümkündür. Taklit edilememeleri, türdeşliği, bozulmaması, elverişli taşınması ve bölünebilirliği paranın özelliklerini taşımaktadır. Ancak yüksek oynaklık kaynaklı değerini tam anlamıyla koruma özelliğine sahip değillerdir. Günümüzde her ne kadar ABD, Japonya, Hollanda, Kanada gibi az sayıda ülkede kabul edilip kullanılabilir olsa da dünya genelinde henüz resmi kabuliyetleri yoktur. Çünkü değişim aracı olarak kullanılabilmesi için istikrarlı bir değerinin olması beklenmektedir (Parasız, 2012:7). Ancak işlem süresi ve maliyet azaltma, finansal katılımı artırma, güvenli ve hızlı finansal kayıt gibi özellikleri nedeniyle finansal alanda dijital reform yaratma potansiyeline sahiptirler. Kripto paraların para olarak kabul görmesi konusunda henüz ortak bir kanı olmamakla birlikte, kullanılan altyapının finansal teknolojideki yeri önemli olduğundan incelenmesi gereken bir alan olduğu da ifade edilebilir.

Kripto paralar; sayıca sınırlı olan (sınırlandırılmış üretimi olanların daha değerli kabul edilmesi nedeniyle), üçüncü taraf gözetimi olmayan, dijital alışveriş olanağı sağlayan, girdiye özel biricik çıktı sağlaması nedeniyle benzersiz olan ve bilgisayar ağlarında şifreleme algoritmasıyla kullanıcılara fiziksel para birimi hissiyatıyla karma alışveriş yapma olanağı sunan değer birimleri niteliğindedir (DeVries, 2016:1-2). Böylece kriptografik varlıkların alt kümesi olan kripto para birimleri, alım-satım ve depolama işlemleri için kriptografik kod kümeleri ile tüm katılımcılarla paylaşılan ve bu mekanizma ile güvence altına alınan dijital ortamdaki bir değeri ifade etmektedir. Kriptografi, Yunanca "granhien" sözcüğünden türetilmiş, güvensiz şartlarda bile verilerin şifrenmesiyle güvenli iletimin sağlanması anlamına gelmektedir (Coron, 2006:70). Bütünlük, gizlilik, kimlik denetimi gibi kavramlar için oluşturulan matematiksel yöntemler bütünü olan Kriptografi, bilginin çeşitli tekniklerle istenmeyen taraflarca okunmasını engellemektedir. Bu şifreleme işlemi, kripto para birimlerinin bir merkezden diğerine transferinin sağlanmasını güvenli bir şekilde olanaklı kılmaktadır (Usta ve Doğanekin, 2018:21). Ayrıca kişinin başkasıymış gibi algılanmasını engelleyerek, kimlik doğrulama sonucu güvenli bir sistem özelliği barındırmaktadır. Bu sistem için kullanılan matematiksel yöntemler şifreleme bilimi olarak ifade edilen Kriptoloji alanından gelmektedir. Kriptoloji alanında, mesajın şifrenmesini Kriptografi, şifrenin anlaşılır hale gelmesini ise kripto analizi sağlamaktadır. Veri transferinin gerçekleşmesinde dağıtık bir veri tabanı özelliğinde olan blokzincir teknolojisi kullanılmaktadır.

Bu veri tabanı, merkezi bir sunucu ya da otoritenin kaldırılmasını sağlayarak, internet ortamında merkezi güvenin dağıtılmasını sağlamaktadır (Yaktıyol, 2018:2).

1.2.2. Blokzincir Teknolojisi

Türkçeye *bireyden bireye elektronik nakit sistemi* olarak çevrilen blokzinciri ilk olarak 2008 yılında merkezi sistemlerde yaşanan sıkıntılardan dolayı, Satoshi Nakamoto takma isimli kişi tarafından önerilmiştir (Nakamoto, 2018:1-9). Son yıllarda merkezi ağlarda yaşanan teknik problemler ve güvenlik aksaklıkları blokzincir teknolojisiyle çözüm bulmaktadır. Nakamoto “Bitcoin: A Peer-to-Peer Electronic Cash System” isimli makalesinde, kriptografik kanıtlara dayalı, eşten eşe çalışma olanağı sağlayan, üçüncü güvenilir kişiye gerek kalmayan, doğrudan işlem yapılabilen bir sistem olduğunu ifade etmiştir. Makalenin çerçevesine göre kripto paraların en büyük özelliği, para basma gücüne sahip otoriteye karşı güven duymak yerine matematiksel kurallar ve bilgisayar algoritmalarıyla temellendirilen sisteme güvendir. Geleneksel para transfer işlemlerinde ise üçüncü bir kurum ya da kuruluş mevcuttur. A ile B kişisi arasındaki para transfer işleminde aracı olan C kurumu bu işlemi gerçekleştirmektedir. İşlemin güvenilirliğinden ve doğruluğundan sorumlu olan C kurumu, blokzincir teknolojisinde mevcut olmadığından güven gereksiz bir durumdur. Çünkü artık blokzincir sistemi güven mekanizması görevi üstlenmektedir. Bahsedilen bu durumlar sonucunda kripto paralar, merkezi olmayan bir yapıya sahiptir ve yapının kontrolü de blokzincir veri tabanı ile gerçekleştirilmektedir. Kuruluş aşamasında; *ne zaman, hangi şekilde, ne kadar arz ve miktar?* sorularının belirlendiği kripto paralara ait ağ yapısı **Şekil 1**’de verilmiştir.



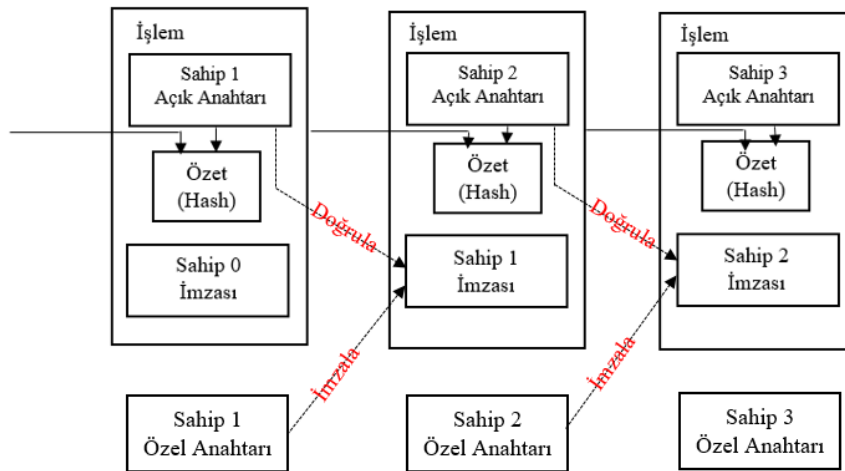
Şekil 1: Merkezi Ağ ve Merkezi Olmayan Dağıtılmış Ağ Örnekleri

Kaynak: Nordgren, A. ve Weckström, E. (2019). Blockchain in the Fields of Finance and Accounting: A Disruptive Technology or an Overhyped Phenomenon?. *ACRN Journal of Finance and Risk Perspectives 8 Special Issue Digital Accounting*, 47-58.

Şekil 1 “a”, geleneksel para transfer işlemi gerçekleştiren kurumların yıldız benzeyen ağ yapısının merkezi yapı olduğunu göstermektedir. Blokzincir sistemi ise “b” gösteriminde olduğu gibi merkezi yapıda olmayan, kontrol noktası veya merkezi sunucusu yer almayan, uçtan uca

bağlı bir ağ yapısı özelliğindedir. Merkezi sistemde A ve B kişileriyle verilen para transfer işlemi örneğinde yer alan C kurumu, blokzincir sisteminde bilgi işlem kaynağını sağlayan madencilerdir. Gerçekleştirilen işlemler herkes tarafından görülebileceği gibi, ağ içerisinde yer alan pek çok bilgisayarda saklanmaktadır. İşlem kayıtları, “b” gösteriminde yer alan düğümlerle ifade edilmektedir. Herhangi bir üçüncü aracı olmadan gerçekleştirilen bu işlemler, madenciler tarafından doğrulanmaktadır. Merkezi özellikteki ağlarda herhangi bir sunucunun arızalanması durumunda sistemin tamamı büyük bir riskle karşılaşmaktadır. Aynı zamanda güvenlik kaynaklarının tamamının tek bir merkez niteliğinde olan kurum/kuruluşa teslim edilmesi, hileli işlem yapılması veya iflas edilmesi durumunda kullanıcılar zorlu bir süreç yaşamaktadır. Dağıtık yapıya sahip olan blokzincir sisteminde aracı kurum olmaması nedeniyle işlem maliyetleri azalmakta ve geri dönüşümsüz işlemler sayesinde dolandırıcılık riski hemen hemen ortadan kalkmaktadır. Ayrıca sistemde dijital para kullanılmasından dolayı mekân ve zaman kısıtlaması yoktur.

Blokzincir sisteminde imza zinciri, kripto para olarak tanımlanmaktadır. Önce ve sonra gerçekleşecek işlem kripto para kullanıcı tarafından kontrol edilebilmektedir. Sonraki işleme sahip olacak kullanıcı için önceki kullanıcı tarafından imza verilmiştir. Böylece her bir veri bloğu kendinden öncekine bağlanarak, ilk bloktan son bloğa kadar oluşan bir zincir yapısına dönüşmektedir. Zincirde yer alan verilere dışarıdan bir müdahale geldiğinde içerisinde veri kayıtlı olan blok, diğer tüm bloklarla bağlantılı olduğundan yapılan müdahale her bir blok üzerinde değişikliği tetikleyecektir. Ancak dağıtık düğüm ağındaki veriler binlerce cihazda saklandığından, saldırılara ve teknik problemlere karşı korunaklı özellik sağlanmaktadır (Pisa ve Juden, 2017:9). Bahsedilen işlem sonucu oluşan ve dijital olayların halka açık defter şeklinde sunulduğu zincir yapısı **Şekil 2**'de verilmiştir.

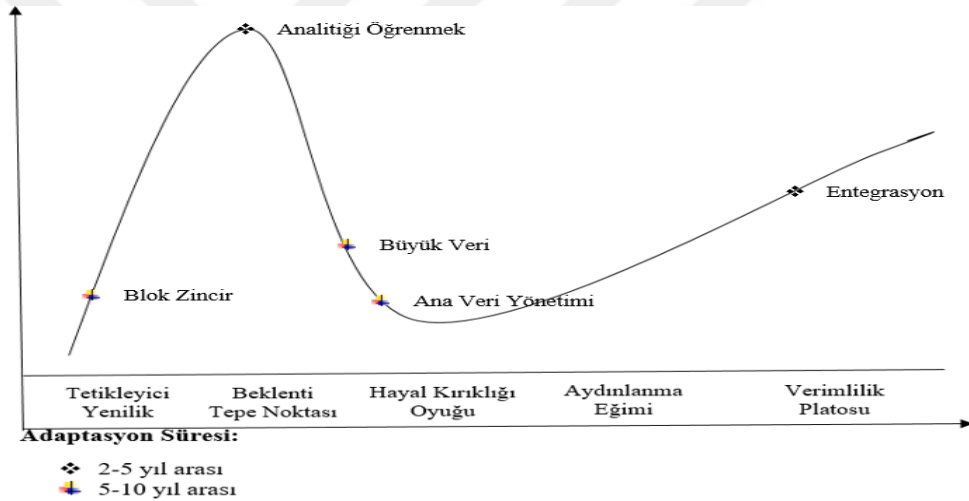


Şekil 2: Blokzincir Çalışma Yapısı

Bir kısmı **Şekil 2**'de verilen ağ, birçok düğümün ortak çalışması sonucu oluşmaktadır. Kripto para transferi işlemi için gönderenin gizli ve alıcının da açık anahtarı gerekmektedir. Kripto paranın her sahibi kendinden bir sonraki işlemi gönderme esnasında, kendi imzasıyla bir önceki işleme ait özeti ve bir sonraki sahibin açık anahtarını imzalamaktadır. Bu işlemlerin tekrara düşmesi durumu sorununun giderilmesi için tüm işlemlere ait bilgiler ilan edilmekte ve sırası da bilinmektedir. Gönderici ile alıcı arasındaki bu anahtar QR kod veya e-posta aracılığı ile edinilebilmektedir. Kripto para madencilerine gönderilen kripto para işlemi için öncelikle gönderici hesabındaki bakiye durumunun yeterliliği kontrol edilmektedir. Benzer transfer işlemleri, *blok* ismindeki yapıda birleştirilmektedir. Hazırlanan bloğun özet bilgisi madenciler tarafından hesaplanmaya başlanmaktadır. İlk hesaplayan madenci bulduğu sonucu diğerleriyle paylaşmaktadır. Diğer madencilerinde ilgili sonucu kontrol etmesinin ardından blok, blokzincirine eklenmektedir. Kripto para transferinin sonuçlanmasının ardından alıcı, göndericinin ilettiği paraya hesabında erişim sağlayabilmektedir (Grewal-Carr ve Marshall, 2016: 4-5). İşlemler sonucunda, zincirdeki her blok kendinden önceki bloğun algoritmasından geçirilen içeriğe sahip olmakta ve tüm kullanıcı hesaplarından eş zamanlı olarak kopyalanarak paylaşılmaktadır. Günümüzde blokzincir teknolojisinin gündeme gelmesinde en önemli potansiyel, bahsedilen bu işlemlerin kaydedilmesinde kullanılan teknolojiye kaynaklanmaktadır. Halka açık defter özelliği sayesinde gerçekleştirilen her işlem, sistemde yer alan katılımcıların oy birliği sonucu doğrulanmaktadır. Sistemde yer alan hiçbir bilgi silinemez ve birbirine bağlanan yapısı nedeniyle değiştirilemez bloklar halindedir. Bir blok dolduğunda sonraki bloğun üretilmesi, bilgilerin değiştirilemez ve silinemez özellikte olmasını sağlamaktadır. Bir blok'un silinmesi ya da değiştirilmesi durumunda, tüm blokların değiştirilmesi gerekmektedir (Crosby vd., 2016: 8). Özetle, sistemde yer alan her bir kullanıcı bir düğümü temsil etmektedir. Sisteme katılacak olan her düğüm, kendi başına bir veritabanına yani bir blokzincir kayıt defterine sahip olmaktadır. İlgili defter uçtan uca protokolü kullanılarak diğer düğümlerle senkronize edilmektedir. Böylece işlemler esnasında aracı ortadan kaldırılarak merkezi bir otorite zorunluluğu da oluşmamaktadır. Bir düğümün başarısız olması ya da işlevi kalmaması durumunda, geriye kalan düğümler gerçekleştirilen tüm işlemlerin ayrıntılarını korumaya devam etmektedir. Bu sistem sayesinde gerçek zamanlı veri sağlanabilmekte ve başarısızlık oranı veya hatalı işlem olasılığı azaltılmaktadır (Nair ve Sebastian, 2017:2824-2825).

Blokzincir teknolojisi genel olarak internet teknolojisine benzetilmektedir. Her iki teknolojiye reform yönünden tetikleyici olması nedeniyle vurgulanmaktadır. İnternet alt yapısında farklı protokollere göre hizmet veren pek çok internet sitesi, blokzincir teknolojisinde de tekil bir alt yapı ile üzerinde internet sitesi gibi uygulamalar bulunmaktadır. Oysa blokzincir teknolojisi,

soyut güvenlik protokolüne benzemekle birlikte pek çok farklı platformda birbirinden farklı yaklaşımların ve uygulamaların kullanılabileceği bir teknolojik yaklaşım özelliğindedir (Usta ve Dođantekin, 2018:24). Blokzincir teknolojisinin kullanımı yalnızca kripto para alanıyla sınırlı değildir. Getirdiđi avantajlar ile birçok uygulama alanı bulmuştur. Kriptografi teknikleri sayesinde sözleşmeler, belgeler vb. değerli bilgilerin saklanma ve korunması sağlanarak, emlak, sigortacılık, otomotiv, sağlık, bulut bilişim, güvenli bulut depolama gibi alanlarda kullanımı başlamıştır. Sadece paranın dijitalleşmesi sonucu hayatımıza daha yoğun şekilde girmiştir (Dilek, 2018:8). Devletler ve şirketler için ucuz hizmet, verimlilik artışı, kullanılışlılık, yeniliklere açık olma gibi imkânlar sonucu yalnızca finans sektörüyle sınırlı kalmayan blokzincir teknolojisi, farklı sektörlerin sorunlarında da çözüm önerisi olarak sunulmaktadır. Tüm bu yönleriyle tsunami gibi yavaş yavaş geldiđi, *Para 4.0* ve *Endüstri 4.0* devrimlerinin merkezinde yer aldığı öne sürülmektedir (Mougar, 2016:5).



Şekil 3: Gartner Hype Döngüsü

Kaynak: Gartner Inc (2016) Gartner's 2016 Hype Cycle for Emerging Technologies Identifies Three Key Trends That Organizations Must Track to Gain Competitive Advantage. Retrieved from <https://gtr.it/3vORMxq> (14.04.2021).











Şekil 3'te yalnızca; Hype Döngüsü'nde yer alan blokzincir teknolojisi ve ilgili olan kavramlara yer verilmiştir. Yeni teknolojilerin takip edilmesinde kullanılan en önemli araçlar arasında yer bulan Hype Cycle metodolojisine göre, blokzincir teknolojisi şu anda inovasyonu tetikleyici bölgededir. Metodolojinin geliştiricisi Gartner firmasına göre blokzincir teknolojisi 5 ile 10 yıllık bir süreçte olgunlaşarak, yaygın olarak kullanılacaktır (Gartner, 2016). 2016 yılından sonra blokzinciri “*beklentilerin tepe noktası*” aşamasını geçmiş, “*hayal kırıklığı çukuru*” aşamasına düşme noktasındadır. Bu noktada araştırmacılar tarafından sorulan soru; “*acaba verimlilik platosu aşamasına doğru ilerleyecek mi?*” şeklindedir. Satoshi Nakamoto'nun makalesinde Bitcoin isimli kripto para ile tanıdığımız blokzincir teknolojisinde bu modele dayalı olarak ortaya

çıkan pek çok *alt coin (para)* olarak adlandırılan kripto paralar günümüz ekonomik sisteminde giderek önem kazanmaktadır.

1.2.3. Başlıca Kripto Paralar

Blokzincirde yer alan Bitcoin kripto paranın üretiminin ardından alternatif olarak *Altcoin* olarak adlandırılan yeni kripto para birimleri üretilmiştir (Nguyen vd., 2019:420). Altcoinler, Bitcoin yapısını kullanan ancak Bitcoin'in mantığını geliştirmeyi amaçlayan, yeni eklentiler yapılarak yepyeni dijital para birimi gibi tanıtılan kripto paralardır (Rawat ve Tiku, 2017:2493). *Coin* olarak ifade edilen kripto paralar kendisine ait bir blokzincir içerisinde, *token (jeton)* olarak ifade edilen kripto paralar ise hazır bir blokzincir içerisinde yer almaktadırlar (Siswanto vd., 2020:8). Örneğin, Bitcoin üretiminin ardından Ethereum kripto para üretilmiştir. Ethereum blokzincirinde akıllı kontratlar özelliği eklenmesi sonucu bu kontratların oluşturulabildiği bir blokzincir kullanılmıştır. Bitcoin ve Ethereum kodlarının kullanıldığı kripto paralar olduğu gibi, kendi blokzincirlerini oluşturan kripto paralar da mevcuttur. Litecoin kripto para birimi Bitcoin kodlarının kullanılması sonucu kendi blokzincirini oluştururken, Tron, Tether gibi kripto para birimleri ise Ethereum blokzincirine bağlı olarak kayıt oluşturan token (jeton) özelliğindedirler (Burnie, 2018:6-9). Kripto para sisteminde en yüksek paya sahip olan Bitcoin, ilk üretilen kripto para olması nedeniyle en yüksek işlem hacmi ve piyasa değerine sahiptir. Bitcoin'den sonra üretilen ve 2021 yılı Mayıs ayı itibarıyla sistemde faaliyet gösteren 9649 adet kripto para bulunmaktadır. 2021 Mayıs itibarı ile piyasa değeri en yüksek olan ilk 10 kripto para birimine ait bilgiler **Tablo 1**'de verilmiştir.


Tablo 1. 2021 Mayıs Ayı İtibarı ile İlk 10 Kripto Para Birimi

Sıra	Kripto Para	Piyasa Değeri	Fiyat	Dolaşan Arz	Hacim (24 Saat)
1	 Bitcoin (BTC)	\$1,093,401,384,760	\$58,459.27	18.703.643	\$64.217.272.355
2	 Ethereum (ETH)	\$424,421,417,740	\$3,665.44	115.790.135	\$41.290.968.318
3	 Binance Coin (BNB)	\$99,753,514,236	\$650.14	153.432.897	\$3.779.796.007
4	 Dogecoin (DOGE)	\$86,493,010,668	\$0.6687	129.517.138.099	\$26.824.656.709
5	 Tether (USDT)	\$55,263,239,485	\$1	55.265.994.298	\$155.864.799.658
6	 Ripple (XRP)	\$55,138,159,272	\$1.57	35.108.326.973	\$6.819.757.916
7	 Cardano (ADA)	\$50,641,518,653	\$1.59	31.948.309.441	\$4.467.530.235
8	 Polkadot (DOT)	\$36,894,531,657	\$39.41	936.141.914	\$2.189.024.816
9	 Bitcoin Cash (BCH)	\$25,357,351,327	\$1,353.75	18.731.213	\$7.499.227.425
10	 Litecoin(LTC)	\$22,624,779,158	\$338.94	66.752.415	\$7.231.601.253

Kaynak: CoinMarket, <https://coinmarketcap.com/tr/coins/> (01.05.2021).

Her geçen gün sisteme yeni kripto paralar eklenmekte olup, belirtilen tarihte \$2,433,576,897,395 ile toplam piyasa değerine sahiptir. Kripto para birimlerinin anlık fiyat bilgileri, piyasa değerleri

gibi pek çok bilgiye erişim sağlanmasında yoğun olarak *coinmarketcap.com* adresi kullanılmaktadır. Türkiye’de 2016 yılından itibaren Bitcoin kullanımında artış meydana gelmiştir. Sonradan kaldırılmış olsa da, İstanbul Atatürk Havalimanı’nda ilk Bitcoin ATM’si kurulmuştur. Sonraki yıllarda, Türk Lirası ile işlem yapılan BtcTürk ve BinanceTR borsaları faaliyete geçmiştir. Bu uygulamalar sayesinde kullanıcılar arasında kripto para farkındalığı artış göstermiştir. Kripto para piyasası verilerini paylaşan bu platformlara göre alım-satım işlemlerinin yapıldığı uygulamalar arasında yer alan BtcTurk-Pro, *coinmarketcap.com* verilerine göre en çok işlem hacmine sahip borsalar arasında yer almaktadır. Kripto para piyasasında en çok kullanılan para birimlerine ait bilgiler **Şekil 4**’te verilmiştir.




Şekil 4: 2021 Mayıs Ayı İtibari ile Kripto Para Piyasasında Yer Alan Para Birimleri

Kaynak: CoinHills, <https://www.coinhills.com/market/currency/> (01.05.2021).

Şekil 4’te görüldüğü üzere, kripto para piyasalarında dünya genelinde en sık kullanılan beşinci para birimi Türk Lirası’dır. Hem kullanılan uygulama hem de para birimi açısından değerlendirildiğinde, Türk kullanıcıların kripto para piyasasındaki kullanımının önem arz ettiği görülmektedir. Sadece kullanıcılar açısından değil, Türkiye’de kabul etmesi sonucu şirketler tarafından da farkındalığın arttığı gözlemlenmektedir. Türkiye özelinde değerlendirilen bu rakamların, dünya genelinde ele alındığında kripto para piyasasının gün geçtikçe önem kazandığını söylemek mümkündür. Yatırımcılara yeni bir yatırım aracı alternatifi olması nedeniyle piyasada işlem gören tüm kripto paraların ve hareketlerinin incelenmesi önemli bilgiler edinilmesi açısından gereklidir. Bitcoin’den sonra akıllı sözleşmeler yeniliği ile Ethereum, bankalar arası işlemler yeniliği ile Ripple ve hızlandırılmış transferler yeniliği ile Litecoin kripto para birimi üretilmiştir. Her üretilen kripto para biriminin dijital teknolojinin kaynaklarını kullanarak yenilik getirmesi nedeniyle incelenmesi ve takip edilmesi yatırımcılar açısından önem arz etmektedir.

1.2.3.1.Bitcoin

22 Mayıs 2010 tarihinde Laszlo takma isimli bir kullanıcının pizza satın alma işlemiyle birlikte ilk Bitcoin kullanımı gerçekleşmiştir. Bu işlem tarihe kripto para biriminin ilk defa takas aracı olarak kullanılması şeklinde geçmiştir (Çarkacıoğlu, 2016:17). Küresel pazarlamada ödeme aracı olarak kullanılan ilk başarılı kripto para birimi olması nedeniyle “1.nesil blokzincir” olarak isimlendirilmiştir (Dizkızırcı ve Gökgöz, 2018:93). BTC olarak kısaltılan Bitcoin, bilgisayar ondalık sayı üretme mekanizmasına göre tasarlanmıştır. Algoritmasında sekiz basamağa kadar bölünebilirlik özelliği vardır. 100 milyonda birlik birime, ilk kuran kişinin isminden gelen “Satoshi” adı verilmektedir. Böylece $1\text{ BTC}=100\text{ Milyon Satoshi}$ şeklindedir. 2140 yılında bu sayının tamamlanacağı öngörülmekte olup, herhangi bir merkezi kuruluş tarafından dışarıdan Bitcoin para arzı yapılamamaktadır. Tüm bu nedenlerden ötürü enflasyonist etki oluşmamaktadır. Bitcoin’in değeri yalnızca talebe bağlı olarak değişim göstermektedir. Sadece bu belirlenşte, yatırımcıların zihnindeki güven algısının etkili olmaktadır (Kethineni ve Cao, 2020:1-3). Ancak üretilen Bitcoin sayısı 21 milyon ile sınırlıdır. Bu sınırlılık, aşırı yükseliş ve arz-talep dengesizliği düşüncesinin yaygınlaşmasına neden olmaktadır. Altcoinlerin miktarının artması, ana akım varlıklara alternatif yaratmasına ve çeşitlilik getirmesine neden olduğundan, Bitcoin’in iyi bir yatırım aracı olacağı da beklenmektedir (Lee vd., 2018:21). Kullanımı başladığı tarihten itibaren Bitcoin fiyat değişim hareketi **Şekil 5**’te verilmiştir.




Şekil 5: Yıllara Göre Bitcoin Fiyat Değişimi (\$ Bazlı)

Kaynak: CoinMarket, <https://coinmarketcap.com/currencies/bitcoin/> (01.05.2021).

Bitcoin pazar değerinin günümüzde her geçen gün logaritmik olarak artış göstermesi sonucu, kamuoyu, finansal piyasalar, medya, pazarlama ve akademi gibi çeşitli alanlarda ilgi odağı haline gelmiştir (Pirinçi, 2018: 51). **Şekil 5**’te görüldüğü üzere, 2020 yılının ortalarından itibaren Bitcoin piyasasında ciddi yükseliş meydana gelmiştir. Son yıllarda yaşanan bu hareketliliği Aralık 2019’da ortaya çıkan koronavirüs (Covid-19) pandemisinin piyasalara olan yansımalarıyla açıklamak mümkündür. Pandemi nedeniyle piyasalarda olduğu kadar yatırım araçlarında da

olağan dışı dalgalanmalar meydana gelmiştir. Yaşanan bu ani düşüş ve yükselişler yatırımcılar açısından panik ortamı yaratmıştır. Hükümetler, mali teşvik paketleri açıklayarak parasal genişlemeye gitmişlerdir. Ancak bu dönemde borçlanmalarda dünya genelinde rekor düzeyde artış meydana gelmiştir. Merkez bankaları düşük faiz ortamı yaratıp, ekonomiyi destekleyici tekniklere başvursa da, kâğıt para değer kaybına uğramıştır. Tüm bu hareketlilikler yaşanırken, dijital teknolojinin getirmiş olduğu yenilikler yatırımcılar açısından yeni bir alternatif yaratmıştır. Herhangi bir merkezi otoriteye bağlı olmayan kripto para piyasası güvenilir liman olarak görülerek ilgi hızla artmıştır.



Şekil 6: Yıllara Göre Google Aramalarda “Bitcoin”

Kaynak: Google Trends, <https://trends.google.com/trends/?geo=TR> (01.05.2021).

Şekil 6’da, üretim tarihinden itibaren Google Trends aracılığı ile arama motorunda “*Bitcoin*” için yapılmış aramaların akışı verilmiştir. Fiyat hareketleri ile yine bağlantılı olarak, gösterilen ilginin de aynı tarihlerde yükselişe geçtiği görülmektedir. Ancak 2017 yılının son aylarında gösterilen ilgi en yüksek seviyededir. Bu durumun nedeni, ilgili tarihte Bitcoin fiyatlarında ciddi yükseliş yaşanmış olmasıdır. 2017 yılının son birkaç ayında farkındalığın ve kabulün yükselmesi sonucu fiyat artışları meydana gelmiştir. Pek çok işletme bu dönemde Bitcoin’i ödeme aracı olarak kabul etmiştir. Birçok piyasa analisti bu konu hakkında, yasal düzenlemelerde kaydedilen ilerlemenin fiyatlarda etkili olduğu görüşünü savunmuştur. Özellikle bu dönemde Japonya’nın bu kripto parayı yasallaştırması ve Chicago Opsiyon Borsası (CBOE) ile dünyanın en büyük finansal türev borsası olan CME’nin Bitcoin için vadeli işlem başlatmaları piyasa ortamını canlandırmıştır.



Şekil 7: Yıllara Göre Dünya Geneli Bitcoin’e Gösterilen İlgi


Kaynak: Google Trends, <https://trends.google.com/trends/?geo=TR> (01.05.2021).

Şekil 7'de, üretim tarihinden itibaren Google Trends aracılığı ile arama motorunda “*Bitcoin*” için yapılmış aramaların ülkeler temelinde görseli verilmiştir. En büyük iki Sahra altı Afrika ekonomisine sahip olan Nijerya ve Güney Afrika'da ilginin en yüksek seviyelerde olduğu görülmektedir. 2017 Ocak ayında Nijerya Merkez Bankası bankalara Bitcoin kullanımının yasak olduğuna dair sirküler yayımlamıştır. Ancak Merkez Bankası Genel Müdür Yardımcısı'nın sanal para kullanımının yasaklanması yetkisinin olmadığını belirtmesi üzerine işlem gerçekleşmemiştir (Chohan, 2017:8). Bitcoin'in üretim tarihinden günümüze olan dünya geneli ilgi genel olarak değerlendirildiğinde ilginin az gelişmiş ve gelişmekte olan ülkelere, gelişmiş ülkelere kıyasla daha yoğun olduğu belirlenmiştir.

Bitcoin, geleneksel ödeme ağlarına kıyasla daha ucuz ve hızlı olma özelliği sayesinde düşük işlem maliyeti avantajı sağlamaktadır (Brito ve Castillo, 2013: 10). Örneğin, geleneksel para kullanımıyla dünya çapında havale gönderim işlemi birkaç günde ödeme yapan kişi için küçük bir yüzde ile ücrete tabii şekilde gerçekleşmektedir. Oysa Bitcoin transferinde herhangi bir masraf olmadan dünyanın her yerine saniyeler içerisinde transfer işlemi gerçekleştirilebilir. Buna ek olarak, arz sınırı belli olduğundan paranın ne şekilde oluşturulacağı ve nasıl değerlendirileceği belli olduğundan enflasyon kontrol altında kalmaktadır. Bu avantajları belirtirken, paranın kullanılabilirliği ölçüde değerli olduğu da önemli bir noktadır. Kabul eksikliği yaşayan Bitcoin, her geçen günde daha fazla kullanıcı, şirket ve işletme tarafından kabul edilmektedir (Douma, 2016: 15-26). Ancak Bitcoin piyasa değerindeki hareketler incelendiğinde yüksek oynaklık olduğu görülmektedir. Bu durumda Bitcoin'in spekülasyon yatırım aracı olarak görülmesine ve istikrarlı bir ödeme aracı olarak kabul görmesini zorlaştırmaktadır. Ama genel olarak blokzincir teknolojisine bakıldığında, üç evreden meydana gelen bir gelişim sürecinde olduğu ve tümevarım yaklaşımı içerisinde olduğu söylenebilmektedir. Blokzincir 1.0 evresinde daha çok finansal piyasaların araçlarına odak söz konusuysen, blokzincir 2.0 evresinde daha genel bir yaklaşım gösterilerek finansal piyasaların tamamı âdemi merkezî bir anlayışla hedef alınmıştır. Blokzincir 2.0 evresinin en önemli gelişmesi ise 2013 yılında Ethereum'un tanıtılması olmuştur. Bu gelişmenin önemli olma nedeni, Ethereum ile birlikte gelen akıllı sözleşmeler olmuştur. Ardından blokzincir 3.0 evresiyle birlikte artık finansal faaliyetlerin yanında devlet işleri, kültür ve sanat, eğitim gibi pek çok alanda kullanılabilirlik başlamıştır (Srivastava vd., 2018:3-4).

1.2.3.2.Ethereum


2011 yılında bir programcı olan Vitalik Buterin tarafından geliştirilen Ethereum, Bitcoin içerisine kod yazılabilme imkânı sunmaktadır. Bu platformda üretimi yapılan *ETH* simgesiyle ifade edilen *Ether* kripto para, Bitcoin'den sonra piyasa değeri en yüksek kripto paradır (Buterin, 2013:22). Ethereum platformunda yapılan işlemlerin çalıştırılmasında Ether kullanılmaktadır. Bu kullanım tarzı, “bir motorun çalışmasında benzin gerekliliği” metaforu ile ilişkilendirilmektedir. Kullanım şekli sayesinde, platformun çalışmasında yapılabilecek herhangi kötü niyetli kullanımın ya da hata durumunun etkisi sınırlandırılmaktadır (Usta ve Doğantekin, 2018:69). Değeri astronomik boyutlara ulaşan Bitcoin “*dijital altın*”, Ethereum ise “*dijital para birimi*” olarak görülmektedir. İki kripto parayı birbirinden ayıran en temel özellik, Ethereum’un programlanabilir olmasıdır. Bitcoin’in yazılımsal veri tabanı herhangi bir değişikliğin uygulanmasında Ethereum’a göre çok yavaş kalmaktadır. Hazır senaryolar garicinde merkezi olmayan uygulamalarında geliştirilmesi sonucu yenilikçi bir blokzincir platformu olan Ethereum böylece “*2. Nesil Blokzincir*” olarak tanımlanmıştır. Bu platformla kripto para dünyasına akıllı sözleşmeler girmiştir. *Akıllı sözleşme, iki veya daha fazla taraf arasında gerçekleştirilip, doğru şekilde yürütülmesi sağlanarak blokzinciri tarafından güvence altına alınan anlaşmadır* (Wattenhofer, 2016:87). Bir başka tanımla, *blokzinciri defterinde veri olarak yer alan ve dağıtılan, yürütülmesi yine blokzincirde gerçekleştirilen sözleşmelerdir*. Bu sözleşmelerle yönetilen sayısal varlıklar devredilebilir, blokzincirde yer alan diğer sözleşmeleri çağırabilir, dağıtımı olduktan sonra kodu değiştirilemez ve ilgili kod sözleşmeyi belirleyici özellik taşımaktadır (Xu X. vd., 2019: 7). Bitcoin tarafından desteklenemeyen karmaşık işlemlerin çözülmesini sağlayan bu kodlar için programlama dili olarak Solidity kullanılmaktadır. Ethereum merkezi yapısı olmaya özerk organizasyonların kurulmasında, akıllı sözleşme teknolojilerinin büyük kısmına oranla popüler bir platform olmuştur (Lee ve Low, 2018:141). Çünkü verdiği vaat; “*sadece akıllı sözleşmelerin kullanımıyla, yazılımsal ekonomik sistemlerin kurulması konusunda geliştiricilere kendini eğitebilme imkânını vermesi*” şeklindedir. Bu platformda gerçekleştirilen tüm işlemler blokzincir üzerinde depolanmaktadır. Akıllı sözleşmenin imzalanmasının ardından ücretin ödenmesiyle birlikte veriler zincire eklenmektedir. Zincirde yer alan herhangi bir düğüm, ilgili sözleşmeyi sorgulayabilmektedir. Genel olarak değerlendirildiğinde, Bitcoin ve Ethereum gibi sistemlerin güvenli olmasının nedeni, ele geçirilemez teknolojilerinin olmasından ziyade dayanak noktalarının güçlü finansal teşvikler olmasıdır (Dannen, 2017: 7-12). Kullanımı başladığı tarihten itibaren Ethereum fiyat değişim hareketi **Şekil 8**'de verilmiştir.



Şekil 8: Yıllara Göre Ethereum Fiyat Değişimi (\$ Bazlı)

Kaynak: CoinMarket, <https://coinmarketcap.com/currencies/ethereum/> (01.05.2021).

Şekil 8'de görüldüğü üzere, 2020 yılının sonlarından itibaren Ethereum piyasasında ciddi yükseliş meydana gelmiştir. Bunun yanı sıra 2017 yılının son aylarından başlayıp 2019 yılına kadar fiyatlarda önemli değişim olduğu da görülmektedir. 2015 yılında piyasada yer alan Ethereum, 2016 yılında 8,62\$ iken 2017 yılında 736,77\$ olmuştur. 2017 yılı Mart ayında çeşitli büyük firmalar ve blokzincir kuruluşları Enterprise Ethereum Alliance (EEA) kar amacı gütmeyen kuruluşu desteklediğini açıklamıştır. Microsoft, Intel, Toyota Araştırma Enstitüsü, Deloitte, ING, Kanada Ulusal Bankası da içerisinde olmak üzere toplamda 116 üyeye ulaşmıştır. 2017 yılının Temmuz ayından itibaren de MasterCard, Scotiabank gibi yeni şirketlerle toplamda 150 üzerinde üyeye ulaşmıştır. Bu nedenle ilgili dönem aralığında Ethereum'a olan ilgi de artış göstermiştir.



Şekil 9: Yıllara Göre Google Aramalarda “Ethereum”

Kaynak: Google Trends, <https://trends.google.com/trends/?geo=TR> (01.05.2021).

Şekil 9'da, üretim tarihinden itibaren Google Trends aracılığı ile arama motorunda “Ethereum” için yapılmış aramaların akışı verilmiştir. **Şekil 8**'de verilen fiyat hareketleri ile yine bağlantılı olarak, gösterilen ilginin de aynı tarihlerde yükselişe geçtiği görülmektedir.




Şekil 10: Yıllara Göre Dünya Geneli Ethereum'a Gösterilen İlgi

Kaynak: Google Trends, <https://trends.google.com/trends/?geo=TR> (01.05.2021).

Şekil 10'da, üretim tarihinden itibaren Google Trends aracılığı ile arama motorunda “*Ethereum*” için yapılmış aramaların ülkeler temelinde görseli verilmiştir. İlk sıralarda Balkan ülkelerinin yer aldığı görülmektedir. Blokzincir sistemlerinde, işlemlerin kaydedildiği blokların büyümesi sonucunda performans sorunu yaşanmaması adına yüksek elektrik harcamaları gerçekleştirilmektedir. Kripto para madenciliği yüksek enerji tüketen bilgi işlem süreciyle gerçekleştirildiğinden, sistem sürekli elektrik kaynağına bağlı olarak çalışmak zorundadır. Bu nedenle de uzun vadede madenciliğin karlılığı, elektrik maliyeti yükseldikçe azalış tehlikesi yaşamaktadır (O'dawyer, Malone, 2014:1-6). Kripto para madenciliği (mining) yapan şirketler bu nedenle maliyetlerin ucuz olduğu ülkelere yönelmektedir. Bu nedenle 2018 yılında ucuz elektrik bolluğu olan Kosova, Kuzey Makedonya gibi ülkelere eğilim gösterilmiştir. Günümüzde blokzincir ağına yeni blokların eklenmesinde madenciler tarafından harcanan işlem gücünün tükettiği elektriğin azaltılmasına yönelik çalışmalar devam etmektedir. Ancak diğer alt kripto para birimleri için de durum benzerlik göstermektedir.

1.2.3.3.Litecoin


13 Ekim 2011 tarihinde eski Google çalışanı Charlie Lee tarafından oluşturulan Litecoin, alt kripto paralar arasında “*Gümüş Bitcoin*” olarak değerlendirilmektedir. Bitcoin'den farklı bir algoritma kullanarak, bir bloğun oluşturulma süresi 2,5 dakikadır. Bu süre Bitcoin'de 10 dakikadır. Ortaya çıkış amacı para transferlerinin çok daha düşük maliyetlerle yapılmasını sağlamaktır (Franco, 2015:172). Bu blokzincir farklılığı nedeniyle Litecoin'de işlemler daha hızlı şekilde gerçekleştirilmektedir. Depolama olanağı diğer kripto para birimlerine göre daha fazla ve hızlı olan Litecoin, algoritmasından kaynaklı üretim açısından da daha maliyetlidir. Ancak her iki kripto para da sınırlı arz söz konusu olup, arz miktarı değişim göstermeyecektir (Singh, 2018:48). Ayrıca *Swiftcoin* olarak bilinen Litecoin, borç senedi işlemlerinin takas edilmesi işlemlerinin yapılmasını olanaklı kılmıştır. Bu özelliği nedeniyle Amerika Patent ve Marka Ofisi'nden ilk patent alma işlemini gerçekleştiren kripto para olma özelliğindedir. Kullanımı başladığı tarihten itibaren Litecoin fiyat değişim hareketi **Şekil 11**'de verilmiştir.



Şekil 11: Yıllara Göre Litecoin Fiyat Değişimi (\$ Bazlı)

Kaynak: CoinMarket, <https://coinmarketcap.com/currencies/litecoin/> (01.05.2021).

Şekil 11'de görüldüğü üzere, 2020 yılının sonlarından itibaren Litecoin piyasasında ciddi yükseliş meydana gelmiştir. Bunun yanı sıra 2013 yılının sonundan başlayarak 2014 yılını da kapsayacak şekilde fiyat artışı görülmektedir. Litecoin geliştirici ekibi tarafından 2013 Aralık ayında yeni işlem sürümü tanıtılmıştır. Yeni sürümle birlikte işlem ücretlerinde azalma ve ağ içerisinde güvenlik ile performans artışı sağlanmıştır. Sonrasında 2014 yılı Nisan ayında yeni bir sürüm daha tanıtılmıştır. Bu sürümle de güvenlik hatalarıyla ilgili önemli düzeltmeler gerçekleştirilerek, Litecoin'e olan ilgi arttırılmıştır. Ayrıca 2017 yılının son aylarından başlayıp 2019 yılına kadar fiyatlarda önemli değişim olduğu da görülmektedir. 2017 yılının son aylarından itibaren yüzde 4 bin 934 oranında artış göstermiştir. Bu dönemde kurucu Litecoin hisselerinin tamamını satmıştır. Hemen ardından Litecoin'in banka kartları aracılığı ile çevrimiçi alışverişte kullanılabileceği açıklanmıştır. Ayrıca en büyük kripto para borsalarından olan ve 48 ABD eyaletinde geniş kullanıcıya sahip olan Gemini kripto para borsası da yine aynı dönemde Litecoin'i işlem listelerine ekleme planını açıklamıştır. Gemini Borsası'nda o tarihe kadar yalnızca Bitcoin ve Ether alım satım işlemi gerçekleştirilmiştir.



Şekil 12: Yıllara Göre Google Aramalarda “Litecoin”

Kaynak: Google Trends, <https://trends.google.com/trends/?geo=TR> (01.05.2021).

Şekil 12'de, üretim tarihinden itibaren Google Trends aracılığı ile arama motorunda “Litecoin” için yapılmış aramaların akışı verilmiştir. **Şekil 11**'de verilen fiyat hareketleri ile yine bağlantılı olarak, gösterilen ilginin de aynı tarihlerde yükselişe geçtiği görülmektedir.



Şekil 13: Yıllara Göre Dünya Geneli Litecoin'e Gösterilen İlgi

Kaynak: Google Trends, <https://trends.google.com/trends/?geo=TR> (01.05.2021).

Şekil 13'te, üretim tarihinden itibaren Google Trends aracılığı ile arama motorunda “Litecoin” için yapılmış aramaların ülkeler temelinde görseli verilmiştir. İlk sıralarda diğer kripto para

birimlerinde de olduğu gibi Nijerya'nın olduğu görülmektedir. Ayrıca ilk sırada Hollanda yer almaktadır. Bu durumun Hollanda Parlamentosu'nun Kara Para Aklamayı Önleme (AML) politikasından kaynaklandığı düşünülmektedir. Ülkede faaliyet gösteren kripto para borsalarının faaliyetlerine devam edebilmesi için Hollanda Merkez Bankası (De Nederlandsche Bank (DNB))'na kayıt işlemi yapması yasal düzenlemesi getirilmiştir. Bununla birlikte BLOX, AMDAX ve Anycoin Direct gibi kripto para borsaları Merkez Bankası'ndan işletme lisansları almışlardır. Ayrıca diğer bir kripto para borsası olan BL3P şirketi de Litecoin'i piyasasından kaldırma kararını açıklamıştır.

1.2.3.4. Ripple

Chris Larsen ve Jed McCaleb tarafından 2012 yılında laboratuvar ortamında üretilen Ripple, 50 milyon \$'ı bankacılık kurumlarından olmak üzere toplamda 90 milyon \$ finansman elde etmiştir (Armknicht vd., 2015:163). Bitcoin'den farkı blokzincir teknolojisine dayanmamasıdır. Yine merkezi bir yapı özelliği olmasa da, dağıtımı Ripple laboratuvarları tarafından gerçekleştirilmektedir. Toplamda 100 milyar adet olan kripto paranın yüzde 20'lik bölümü kurucularına, yüzde 25'lik bölümü de laboratuvarlara aittir. Geri kalan yüzde 50'lik kısım sistemin büyütülmesi adına dağıtım amaçlı ayrılmıştır. Ripple özellikle parasal hizmet sağlayan kurum ve kuruluşlar ile büyük bankalar tarafından kullanılmaktadır. Bu durum, işlemlerin az sürede yapılması ve ödemelerin de çok yüksek hızda gerçekleşmesinden kaynaklanmaktadır (Armknicht vd., 2015:166). Bitcoin'de tüm kullanıcıların senkronize şekilde iletişimde olması gerektiğinden işlem süreleri uzamaktadır. Ancak Ripple'da güvenilir alt ağlardan meydana gelen bir algoritma kullanıldığından bu süre kısalmaktadır (Britto vd., 2014:3). Örneğin, Kanada ve Almanya'da olan iki banka arasında gerçekleştirilen Ripple testinde, normalde dört gün süren transfer işleminin sekiz saniye içerisinde tamamlandığı gözlemlenmiştir. Kullandığı teknoloji nedeniyle kurumsal firmalar tarafından kullanılmaktadır. Türkiye'de faaliyeti olan Akbank'ın Almanya şirketi Akbank AG'de dâhil olan bankalar arasındadır. Bu nedenle Ripple finansal kurumları hedefleyerek, Ripple Connect isimli bir ürün aracılığı ile kurum sistemlerinde değişiklik yapılmadan kendi teknolojisi arasında entegrasyon işlemi sağlamaktadır (Usta ve Doğantekin, 2018:73). Kullanımı başladığı tarihten itibaren Ripple fiyat değişim hareketi **Şekil 14**'te verilmiştir.



Şekil 14: Yıllara Göre Litecoin Fiyat Değişimi (\$ Bazlı)

Kaynak: CoinMarket, <https://coinmarketcap.com/currencies/ripple/> (01.05.2021).

Şekil 14’te görüldüğü üzere, 2020 yılının sonlarından itibaren Ripple piyasasında ciddi yükseliş meydana gelmiştir. Bunun yanı sıra, 2017 yılının son aylarından itibaren 2018 yılında ciddi yükseliş olduğu görülmektedir. 1\$ seviyesini ilk kez Aralık 2017’de geçen Ripple, bu dönemde Bank of America, UniCredit, Axis Bank gibi kuruluşların olduğu 75’in üzerinde finansal kuruluş ile ticari yolarak altyapısını entegre ederek kullanmaya başlamıştır. Bir şirketin kontrolü altında olmasından kaynaklı diğer kripto para birimlerine göre merkezinin olması ve bankalar gibi finansal kurum ve kuruluşlar tarafından kullanılabilir olması, yatırımcılar açısından daha güvenilir görülmesine neden olmuştur.



Şekil 15: Yıllara Göre Google Aramalarda “Litecoin”

Kaynak: Google Trends, <https://trends.google.com/trends/?geo=TR> (01.05.2021).

Şekil 15’te, üretim tarihinden itibaren Google Trends aracılığı ile arama motorunda “Ripple” için yapılmış aramaların akışı verilmiştir. Şekil 14’te verilen fiyat hareketleri ile yine bağlantılı olarak, gösterilen ilginin de aynı tarihlerde yükselişe geçtiği görülmektedir.




Şekil 16: Yıllara Göre Dünya Geneli Litecoin’ e Gösterilen İlgi

Kaynak: Google Trends, <https://trends.google.com/trends/?geo=TR> (01.05.2021).


Şekil 16'da, üretim tarihinden itibaren Google Trends aracılığı ile arama motorunda “Ripple” için yapılmış aramaların ülkeler temelinde görseli verilmiştir. İlk sırada gelişmiş ülkeler arasında yer alan Hollanda'nın olduğu görülmektedir. 2018 yılında Hollanda Merkez Bankası, ödeme sistemlerinin verimliliğinin artırılmasında Ripple ödeme sisteminin somut yenilikler getirdiğini açıklamıştır. Gerçek zamanlı ödeme altyapısını, sistemsel hızını, kolaylığını ve maliyet tasarrufu sağladığı ifade edilmiştir. Ancak ABD Menkul Kıymetler ve Borsa Komisyonu (SEC) tarafından 6 Nisan 2021 tarihinde Ripple'a, yatırımcılara kayıt dışı satım ve fon toplama amacı gerekçesiyle dava açılmıştır. Aynı dönem bir kripto para alım satım platformu olan ve İngiltere ile Slovenya'da ofisleri olan Gatehub, Ripple'ı kaldırmayacağını duyurmuştur. İkinci sırada yer alan Slovenya'da bu kripto paranın da kabul edildiği pek çok işletme ve mağaza yer almaktadır.

Genel olarak değerlendirildiğinde, ilgili kripto paraların popülerliğinin dönemsel olarak arttığını ancak yıllardır bir şekilde varlığını sürdürdüğü görülmektedir. Grafikler incelendiğinde özellikle pandemi döneminde Merkez Bankaları aracılığı ile basılan paralara alternatif olarak yeniden gündeme gelmiştir. Kripto paralar her ne kadar itibari para birimlerine alternatif olsa da kendi aralarında da alternatif durumları mevcuttur. Her ne kadar farklı çözümler için farklı teknolojilerle üretilseler de birbirine benzer çözümler sunma durumları da mevcuttur. Bu nedenle bahsedilen kripto paralar arasındaki ilişkinin incelenmesi amacıyla korelasyon durumu **Tablo 2**'de verilmiştir.

Tablo 2. Kripto Para Birimlerine Ait Korelasyon Durumu



Kaynak: CryptoWatch, <https://cryptowat.ch/tr-tr/correlations> (01.05.2021).

Portföy oluşturularak yapılan yatırımlarda korelasyon incelemesi önemli teknikler arasında yer almaktadır. Örneğin ikili alım-satım (pair trade) işlemlerinde, korelasyonu yüksek iki finansal varlık arasında ilişki bozulduğunda bir varlığın fiyatının düşüp, diğerinin yükseleceği varsayılmaktadır. **Tablo 2**'de incelenen kripto para birimlerinin son bir yıla ait korelasyon katsayıları verilmiştir. Kesikli çizginin üzerinde kalan sütunlar istatistiksel olarak anlamlı pozitif korelasyonu ifade etmektedir (). İncelenen dört kripto para biriminin de aralarındaki

korelasyonun istatistiksel olarak anlamlı olduđu belirlenmiştir. Son bir yılda en yüksek korelasyon Ethereum ve Litecoin, en düşük korelasyon ise Ethereum ve Ripple arasında gerçekleşmiştir. Ancak genel olarak değerlendirildiğinde, incelenen kripto para birimleri arasında pozitif yönlü korelasyon olduđu görülmektedir. Aynı zamanda çalışmanın bundan sonraki bölümlerinde Ripple “XRP”, Litecoin “LTC”, Ethereum “ETH” ve Bitcoin “BTC” olarak kısaltılarak ifade edilecektir.

İlk dijital para birimi olarak geliştirilen Bitcoin, kendinden sonra üretilen diđer kripto para birimlerinin ana yönlendiricisi niteliğindedir. Zaman içerisinde farklı borsalarda, pazarlarda çeşitli fiyatlar ile işlem görmesi ve tüketici ilgisini arttırması nedeniyle fiyat artışı pazar değerinin yükselmesine neden olmuştur. Dünya genelinde uluslararası uygulamaların ve sözleşmelerin olması, sözleşmeler ile hukuki metinlerin oluşturulmaya çalışması sonucu kripto para birimlerinin gelişim sürecinde proaktif katkı sağlamaktadır (Erarslan, 2020:26). Ancak Bitcoin ve diđer kripto para birimlerinin kabul görme sürecinin tamamlanabilmesi için sahip olması gereken özellik değeri depolayabilmesidir. Çünkü ilgili para biriminin stabil olma özelliği ve satın alma gücü güvenilir olmasını sağlamaktadır. En eski olan Bitcoin de dahil olmak üzere henüz kripto para birimleri bu koşulu sağlayamamaktadır. Kripto para piyasasında fiyatlar sürekli olarak azalış ya da artış eğilimi göstermektedir. Bu durum kullanıcılar açısından risk yaratmaktadır. Ancak aynı zamanda da spekülörler açısından da ilgi çekici bir piyasa özelliğindedir. Örneğin, yüksek getiri amacıyla piyasa girildikten sonra herhangi bir panik anında aniden piyasadan çıkış yapan pek çok spekülör vardır. Bu gibi işlemler sonucunda da piyasa oynaklığı belirgin şekilde değişmektedir. 2017 yılında Bitcoin fiyatlarına bakıldığında, yaşanan %2000’lik artışın arkasında herhangi bir ekonomik neden olmadığı görülmektedir. Bunun yanı sıra, Bitcoin’in 2019 yılı sonuna kadar bir daha bu seviyeye erişememesi, Ripple ve Ethereum’da da 2018 yılının başından itibaren yaşanan fiyat düşüşleri kripto para fiyatlarında balon olma durumunu sorgulattırıştır. Yaşanan bu rasyonel olmayan gelişmeler, kripto para piyasasında manipülasyon ve spekülatif davranışların incelenmesini zorunlu hale getirmiştir. Bu noktada sorulması gereken, “*Kripto para piyasasının zaman içerisinde stabil olma potansiyeli var mıdır? Yoksa spekülasyona açık bir piyasa olma özelliğini mi devam ettirecektir?*” sorusudur.

Dünya genelinde kamuoyu tarafından Bitcoin’in dikkatleri cezbetmesini, *kısa zamanda çok getiri sağlamak* düşüncesi ve fırsatları kaçırma korkusunu ifade eden “*FOMO (Fear of Missing Out)*” etkisiyle de çıkarım yapmak olanaklı gözükmektedir. 2017 yılının son aylarında Bitcoin piyasasında sürekli yükseliş yaşanan bir trendin yakalanması sonucu meydana gelen boğa piyasası yatırımcılarda FOMO etkisi yarattığı düşünülmektedir. Pek çok yatırımcının bu dönemde tepe fiyattan alış yapması ve ardından gelen düşüş sonucu büyük kayıplar yaşanmıştır. Ancak

yatırımcıların bu ve benzer düşüncelere sürüklenip rasyonel olmayan kararlar vermesinin engellenebilmesi adına somut bilgilere erişim sağlanması gerekmektedir. Bu da blokzincir teknolojisi ve modellerini incelemekten mümkün gözükmemektedir. Çünkü teknolojiye hâkim olmadan sistem içerisinde yer alan yatırımcıların geleneksel piyasa davranışlarına göre karar vermesi hem yatırımcı hem de piyasa açısından olumsuz etkiler yaratmaktadır. Bu nedenle kripto para sisteminin işleyişini anlayarak gelecek dinamikleri öngörmek oldukça önemli bir noktadır. *Kripto para birimlerini oluşturan bu sistemin altyapıları nasıl çalışmaktadır?*

1.3. Kripto Para ve Finansal Piyasalar

Geleneksel para birimlerinden farklı bir yapıya sahip olan kripto para birimleri, madenciler olarak bilinen bir grup üretici tarafından oluşturulmaktadır. Geleneksel para birimleri Merkez Bankası tarafından üretilmekte olup, denetim ve kontrol altındadır. Enflasyon, ekonomik krizler, politikalar gibi pek çok ekonomik koşula bağlı olan geleneksel para birimleri, bu özellikleriyle kesin olarak hesaplanabilmektedir. Ancak bağımsız özellikte olması nedeniyle kripto para birimlerinde fiyat ve fiyat dalgalanmalarının belirlenmesi oldukça zordur. İki para biriminin tek temel noktası, fiyatlarının belirlenmesinde arz ve talep faktörlerine bağlı olmasıdır (Andrianto ve Diputra, 2017:229). Diğer bir farklılık ise geleneksel para birimleriyle yapılan işlemlerde üçüncü kişilerin bilgi erişiminin sınırlandırılarak gizliliğin sağlanmasıdır. Bu gizlilik durumu, kripto para birimi teknolojisinde yer alan genel anahtarların isimsiz olarak tutulmasıyla sağlanmaktadır. Kripto para birimi camiası, şifreli para ile taşınabilirlik, bölünebilirlik, değiştirilebilirlik ve bölünebilirlik gibi paranın temel özelliklerinde farklılaştığını ve geleneksel para birimlerinden üstün tutulduğunu ifade etmektedir (Nakamoto, 2008:6). Kripto para birimlerinin para olarak değerlendirilebilmesi için hiçbir engel olmadığı ifade edilmektedir. Oynaklığındaki anlık ve sürekli dalgalanmaların engellenmesi durumunda herkes tarafından para olarak değerlendirilebileceği savunulmaktadır. Günümüzde blokzincir teknolojisi genel/izinsiz ve özel/izinli olarak kullanılabilir. En büyük örneği Bitcoin olan genel/izinsiz ağda herkesin özgürce ağa erişim, işlem yapma ve takip etme yetkisi bulunmaktadır. Özel/izinli kullanımda ise ağa yalnızca izin verilen kişi veya kurum/kuruluşlar ağa erişebilmektedir. Bu ağ tipi özelliği bankalar, çeşitli sektörler ve devletlerinde araştırma alanına dâhil olmuştur (Yavuz, 2019:18). İçerisinde bulunduğumuz mevcut durumda, bahsedilen tüm bu durumlar nedeniyle alanyazın iki farklı gruba ayrılmış durumdadır.

1.3.1. Alanyazın Taraması

Alanyazında kripto para birimlerinin fiyatlarının diğer finansal veya ekonomik göstergelerle olan kısa ve uzun vadeli ilişkilerinin incelendiği farklı yöntemlerle incelendiği çeşitli çalışmalar

mevcuttur. Yermack, kripto para birimlerini genel olarak değerlendirdiği çalışmasında piyasanın iktisatçılar tarafından tanımlanan kriterlere uygun hareket etmediğini ifade etmiştir. Euro, ABD Doları, Yen, İngiliz Sterlini ve İsviçre Frangı gibi para birimleriyle Bitcoin arasında neredeyse sıfır korelasyon olduğunu ve bu durumda kripto para birimlerinin para olma önündeki en büyük engel olduğunu ifade etmiştir (Yermack, 2013:2-3). Alanyazında yer alan farklı teknikler kullanılarak finansal ve ekonomik göstergeler ile kripto para birimleri arasındaki ilişkinin incelendiği çalışmalara ait bilgiler **Tablo 3**'te verilmiştir.

Tablo 3: Kripto Para ve Finansal Piyasalar Çalışmaları

Yazar/lar & Yıl	Amaç	Yöntem	Sonuç
Wijk (2013)	Seçili pariteler, endeksler ve ham petrol fiyatları ile Bitcoin arasındaki ilişkinin incelenmesi	VECM modeli	Bitcoin fiyatları üzerinde Dow Jones endeksinin, kısa ve uzun vadede anlamlı etkisi olduğu belirlenmiştir. WTI petrol kurunun ve Euro/Dolar'ın kısa vadede anlamlı etkisi olduğu belirlenmiştir. Ancak Dolar/Yen ve Nikkei 225 hareketlerinin etkisi olmadığı ifade edilmiştir.
Vockathaler (2015)	16 farklı göstergenin Bitcoin fiyatları üzerindeki etkisinin incelenmesi	GARCH modeli	Bitcoin fiyatlarında meydana gelen dalgalanmaların çoğunun nedeninin, bilinmeyen şoklar ve içsel bir süreç tarafından modellenen yapı olduğu belirlenmiştir.
Atik vd. (2015)	Çapraz döviz kurları ile Bitcoin arasındaki ilişkinin incelenmesi	Nedensellik analizi	Japon Yen'i ile Bitcoin arasında tek yönlü nedensellik ilişkisi ve gecikmeli etki olduğu belirlenmiştir.
Szetela vd. (2016)	Seçilmiş global para birimleri ile Bitcoin arasındaki ilişkinin incelenmesi	ARMA ve GARCH modelleri	Seçilmiş global para birimleri ile Bitcoin arasında eştümleşme belirlenmemiştir.
Koçoğlu vd. (2016)	8 farklı borsa ile Bitcoin fiyatlarının incelenmesi	Eştümleşme ve Nedensellik analizi	Yüksek getiri sağlayan Bitcoin'in oynaklığının çok yüksek olduğu belirlenmiştir. Ayrıca spekülatif kullanıma açık olduğu ifade edilmiştir.
Song (2016)	Dolar, Bitcoin ve Borsa Endeksleri arasındaki ilişkinin incelenmesi	Eştümleşme Analizi, VECM ve Doğrusal Regresyon	Uzun dönemde Bitcoin fiyatları ile döviz kurları arasında eştümleşme ilişkisi belirlenmiştir. Ayrıca, Bitcoin fiyatları ile borsa endeksleri arasında da pozitif ilişki olduğu ifade edilmiştir.
Bhattacharjee (2016)	Dolar, Euro, Ruble'nin Bitcoin fiyat oynaklığına etkisinin incelenmesi	GARCH modeli	Bitcoin değerinin çalışmada incelenen para birimleri ile herhangi bir ilişki içerisinde olmadığı belirtilmiştir.
Zhu vd. (2017)	Bitcoin fiyatlarını etkileyebilecek ekonomik faktörlerin analiz edilmesi	VECM modeli	Bitcoin fiyatları üzerinde altın fiyatlarının uzun vadede etkili olmadığı, Amerikan Doları ve Dow Jones Endeksi ile Tüketici Fiyat Endeksinin uzun vadede negatif etkili olduğu belirlenmiştir.
Dirican ve Canöz (2017)	Bitcoin fiyatları ve başlıca dünya hisse senedi	ARDL Sınır Testi	ABD ve Çin borsa endeksleri ile Bitcoin arasında eştümleşme ilişkisi belirlenmiştir. Bunun yanı sıra,

	endeksleri arasındaki ilişkinin incelenmesi		FTSE100, NIKKEI225 ve BIST-100 endeksleriyle herhangi bir ilişki olmadığı ifade edilmiştir.
İçellioglu ve Öztürk (2018)	Seçili döviz kurları ile Bitcoin arasındaki ilişkinin incelenmesi	Eştümleşme ve Nedensellik analizi	Altın haricinde Bitcoin'in başka bir yatırım aracı ile uzun vadeli ilişkisinin olmadığı belirlenmiştir.
Chuen, Guo ve Wang (2018)	Kripto para birimleri ile geleneksel yatırımlar arasındaki ilişkinin incelenmesi	Statik korelasyon	Kripto para birimleri ile geleneksel yatırımlar arasında düşük korelasyon olduğu belirlenmiştir.
Güleç vd. (2018)	Bitcoin ile finansal göstergeler arasındaki ilişkinin incelenmesi	Eştümleşme ve Nedensellik analizi	Faiz ile Bitcoin fiyatları arasında nedensellik ilişkisi belirlenmiştir.
Kanat ve Öget (2018)	G7 ülkeleri ve Türkiye borsaları ile Bitcoin fiyatı arasındaki ilişkinin incelenmesi	Nedensellik Analizi	Diğer ülke borsaları ile Bitcoin arasında uzun dönemde ilişki olmadığı, kısa dönemde ise İngiltere borsasının Bitcoin'in nedeni olduğu belirlenmiştir. Ayrıca, Bitcoin'in de Kanada Borsasının ve S&P 500'ün nedeni olduğu ifade edilmiştir.
Yıldırım (2018)	Günlük Bitcoin ile Altın fiyatları arasındaki ilişkinin analizi	Eştümleşme Analizi	Altın fiyatlarındaki değişimin Bitcoin fiyatlarını etkilediği, Bitcoin fiyatlarındaki değişimin ise altın fiyatlarını etkilemediği belirlenmiştir.
Baur, vd. (2018)	Ons Altın, Dolar ve Bitcoin arasındaki oynaklık hareketlerinin incelenmesi	GARCH	Ons Altın, Dolar ve Bitcoin arasında herhangi bir ilişki belirlenmemiştir.
Çütçü ve Kılıç (2018)	Bitcoin ve Dolar kuru arasındaki ilişkinin incelenmesi	Eştümleşme Analizi, Hacker-Hatemi-J Bootstrap Nedensellik	Bitcoin ile Dolar kuru arasında orta ve uzun dönemde eştümleşme ilişkisi belirlenmiştir. Ayrıca dolar kurundan Bitcoin'e tek yönlü nedensellik olduğu ifade edilmiştir.
Ağan ve Aydın (2018)	6 farklı para birimi ile Bitcoin arasındaki ilişkinin incelenmesi	Hatemi-J nedensellik analizi	Euro ve İngiliz Sterlini arasında nedensellik ilişkisi olmadığı belirlenmiştir. Ayrıca Yen, Yuan, Kanada Doları, Amerikan Doları ile Bitcoin arasında tek yönlü şokların etkisi olduğu ifade edilmiştir.
Alicemani (2018)	Dolar, Euro, İngiliz Sterlini, Altın, Ham Petrol, Doğalgaz, Gümüş, Bakır, Çin Yuanı, Japon Yeni ile Bitcoin arasındaki ilişkinin incelenmesi	Nedensellik Analizi	Emtia fiyatları ve döviz kurları ile Bitcoin arasında nedensellik ilişkisi belirlenmemiştir.
		Gregory-Hansen	

Topaloğlu (2019)	8 farklı para birimi ile Bitcoin arasındaki ilişkinin incelenmesi	eştleşme analizi ve nedensellik analizi	Döviz kurları ile Bitcoin arasında eştleşme ilişkisi belirlenmiştir. Ayrıca Çin Yuanı'ndan Bitcoin'e doğru tek yönlü nedensellik olduğu ifade edilmiştir.
Çolak ve Sandalcılar (2019)	Cumhuriyet Altını, Dolar, Euro, Pound, SDR, BIST-100, M1 ve M2 para arzları ile Bitcoin arasındaki ilişkinin incelenmesi	Eştleşme ve Nedensellik analizi	Euro ve BIST 100 değişkenlerinde Bitcoin'e doğru %10 anlamlılık seviyesinde, SDR ve Dolar'dan Bitcoin'e doğru %5 anlamlılık düzeyinde nedensellik ilişkisi olduğu belirlenmiştir.
Panagiotidis vd. (2019)	Döviz kuru, borsa getirisi, altın ve petrol getirisinin Bitcoin üzerindeki etkilerinin incelenmesi	VAR modeli	Geleneksel borsalar ve Bitcoin arasında anlamlı ilişki belirlenmiştir.
Aslan (2019)	Bitcoin'in oynaklık sıçramasının BIST-100'e olan etkisinin incelenmesi	GARCH ve Nedensellik analizi	Bitcoin ve BIST100 arasında anlamlı bir ilişki belirlenememekle birlikte, çok değişkenli GARCH analizi sonuçlarına göre BIST-100 ve Bitcoin arasında çapraz ve karşılıklı olarak anlamlı ilişki belirlenmemiştir.
Topalloğlu (2019)	Döviz kurları ile Bitcoin arasındaki ilişkinin incelenmesi	Yapısal kırılmalı eştleşme ve nedensellik analizi	Bitcoin ile Euro ve Dolar arasında herhangi bir ilişki olmadığı belirlenmiştir.
Kuzucu (2019)	Dolar ve Bitcoin arasındaki ilişkinin incelenmesi	Nedensellik Analizi	Dolar ve Bitcoin arasında kısa ve uzun dönemli pozitif yönlü ilişki belirlenmiştir.
Gil-Alana vd. (2020)	6 borsa endeksi ile 6 kripto para arasındaki ilişkinin incelenmesi	Regresyon modeli	Kripto paraların hem borsa ile hem de kendi içlerinde eştleşik olmadıkları belirlenmiştir.
Gül (2020)	Kripto paralar ile portföy çeşitlendirmesinin incelenmesi	Portföy Analizi	Kripto paralar ile diğer varlıklar arasında ters yönlü korelasyon olduğu belirlenmiştir.
Deniz (2020)	Kripto para fiyatlarını etkileyen faktörlerin incelenmesi	VAR modeli ve nedensellik analizi	Yalnızca Bitcoin'in Altın'ın nedeni olduğu belirlenmiştir.
Sivrikaya, İren ve Umay (2021)	Bitcoin ve ABD hisse senedi getirileri arasındaki oynaklığın incelenmesi	Çok değişkenli GARCH	İki getiri arasında sürdürülebilir ilişki olmadığı belirlenmiştir.
Yin, Nie ve Han (2021)	Petrol risklerinin kripto para birimlerinin uzun vadeli oynaklığı üzerindeki etkilerinin incelenmesi	GARCH modeli	Petrol tedarik şoklarının kripto para birimlerinin oynaklığı üzerinde uzun vadede olumlu etkisi olduğu belirlenmiştir.
Demirel ve Hazar (2021)	Bitcoin, Ethereum ve Ripple'in BIST-100 endeksiyle ilişkisinin incelenmesi	Destek Vektör Makineleri	BIST-100 endeksinin hareket yönleri %52 oranında başarıyla tahmin edilmiştir.

Tablo 3'e bakıldığında, kripto paraları finansal varlıklarla karşılaştırmak veya incelemenin tam anlamıyla somut sonuçlar çıkarmadığı görülmektedir. İlgili alanyazındaki çalışmaların sonuçları incelendiğinde, araştırmacıların sıklıkla kripto para birimlerinin yatırım aracı olarak yüksek getiri sağladığı ancak henüz güvenilir olmadığı görüşüne ulaşılmıştır. Oynaklığı çok yüksek olan bu yatırım aracının spekülatif kullanıma açık olduğu görüşü iddia edilmektedir. Bu nedenle son yıllarda kripto paraların birbirleriyle olan ilişkilerinin incelendiği çalışmalara olan eğilimin artış olduğu gözlemlenmiştir. Belirlenen bu bulgulardan hareketle, pay piyasaları getirisi ve işlem hacminin yatırımcı ilgisiyle olan ilişkisini araştırmaya yönelik çalışmaların alanyazına girdiği görülmektedir. Yatırımcı ilgisinin doğrudan ölçülememesi nedeniyle alanyazında bu alanda yapılan ilk çalışmalarda anket ve haber analizleri kullanıldığı bilinmektedir. Daha sonra yapılan çalışmalarda ise aktif yatırımcılara ait ilginin ölçülmesinde sosyal medya platformları ve arama motorlarına ait verilerin kullanımı başlamıştır. 2004 yılından itibaren Google firması tarafından arama motorunda taranan verilerin sıklığına Google trend aramaları aracılığıyla erişim sağlanmaktadır.

Da vd. (2011), Google trend aramaları verilerini kullanarak yatırımcı ilgisini ölçen ilk çalışma niteliğindedir. Çalışmada ABD sermaye piyasasında işlem gören firmalar anahtar kelime olarak belirlenmiş olup, yatırımcı ilgisi ile işlem hacmi ve reklam harcamaları arasındaki ilişki belirlenmiştir. Dzielinski (2012) tarafından Google trend arama verilerinin kullanımının iki önemli avantajı olduğu belirtilmiştir. Birincisi, anket verilerine göre daha yüksek frekanslı veri elde etme olanağıdır. İkincisi ise finansal piyasalardaki gelişmelerden bağımsız bir şekilde kendiliğinden (spontane) ortaya çıkması ile ilgilidir. Bu durum ekonometrik analizlerde yer alan tahmin konusunda en büyük soruna yol açan içsellik sorununu ortadan kaldırmaktadır. Bununla birlikte, anket verileri ile karşılaştırıldığında, yakın bir gelecek için neredeyse anlık veriler türetmekte ve bu durum özellikle geleceği öngörmek için büyük bir önem arz etmektedir. Alanyazındaki bir dizi çalışmada hisse senedi değişkenleri (getiri, hacim ve oynaklık) ile ilgili Google aramaları arasında önemli bir korelasyon olduğu görülmektedir. Google arama verileri, gelecekteki hisse senedi fiyatlarını tahmin etmek için kullanılmaktadır (Bijl vd., 2016; Kim vd., 2019; Preis vd., 2010). Bu tahmin işleminde doğrusal olmayan Granger nedensellik testleri başka bir alternatif olarak gözükmektedir (Hiemstra ve Jones, 1994; Diks ve Panchenko, 2006; Tank vd., 2021). Ancak önceki çalışmaların çoğunun doğrusal modellerin uygulamalarıyla sınırlı olduğunu belirtmekte fayda vardır. Bu durum zaman serilerinde olası yapı değişikliklerinin dikkate alınmadığı olasılığını düşündürmektedir. Baek ve Brock (1992), doğrusal olmama sorunuyla başa çıkmak için doğrusal olmayan bir eştümleme testi önermiştir. Monte Carlo simülasyonunu kullanarak, doğrusal olmayan durumun varlığında doğrusal modellerin tahmin

performansının düştüğünü belirlemişlerdir. Doğrusal olmayan modellerin tahmin performansının doğrusal modellerden daha iyi olduğunu göstermişlerdir. Bu nedenle test, makroekonomi ve finans gibi birçok alanda yaygın olarak kullanılmaktadır (Hiemstra ve Jones, 1994). Keynes (1936)'in ardından Kaldor (1940) ve Hicks (1950) doğrusal-olmayan matematiksel modeller kurmuşlardır. Ancak bu modellerin işaret ettiği tarzda bir doğrusal-olmayanlığın zaman serisi bağlamında sınanması için epey uzun bir süre geçmiştir. Çünkü zaman serisi analizinde doğrusallık varsayımı uzun süre hakim olmuştur (Franses, Van Dijk, 2000). Değişkenlerin izlediği veri yaratma süreçlerinin ya da değişkenler arasındaki ilişkinin doğrusal olmadığı kuramsal olarak kabul edildiği durumlarda bile uygulama aşamasında genellikle doğrusal zaman serisi modelleri kullanılmıştır. Tahmin aşamasındaki zorlukların azalmasıyla 1990'ların başından itibaren doğrusal-olmayan zaman serisi alanında özellikle uygulamaya dönük çalışmalarda artış meydana gelmiştir.

Google arama hacmi verileri, müşterilere, yatırımcılara ve politika yapıcılara daha iyi kararlar verme konusunda yardımcı olma potansiyeline sahiptir. Yatırım kararları almak için bilgi ararken, yatırımcılar fiyatlardaki değişikliklerle ilgili haberler sağladıkları için Google trendlerini dikkate almaktadırlar (Salisu vd., 2021). Pay piyasaları işlem hacmiyle yatırımcı ilgisini inceleyen çalışmalarda nedensellik analizi, portföy analizi, panel veri analizi, korelasyon analizi ve vektör otoregresyon modelleri tekniklerinin sıklıkla kullanıldığı görülmektedir (Mao vd., 2011; Joseph vd., 2011; Bank vd., 2011; Beer vd., 2012; Vlastakis ve Markellos, 2012; Dzielinski, 2012; Liu vd., 2012; Latoeiro vd., 2013; Harnish ve Loughlin, 2013; Zhang vd., 2013; Yu vd., 2013). Gözlenemeyen ve heterojen davranışlar nedeniyle yatırımcı duyarlılığını ölçmek kolay bir işlem değildir (Gao vd., 2020; Baker ve Wurgler, 2007; Bandopadhyaya ve Jones, 2005). Özellikle son yıllarda veri mevcudiyeti nedeniyle, Google arama hacmi popüler bir yatırımcı duyarlılığı endeksi haline gelmiştir (Bijl vd., 2016; Kim vd., 2019; Preis vd., 2013; Bollen vd., 2011).

Türkiye'de yatırımcı ilgisi ve pay piyasaları arasındaki ilişkiyi endeksler üzerinden araştıran Akgün (2016), Bilgiç (2017), Korkmaz vd (2017) ile Erten ve Korkmaz (2018) tarafından yapılan çalışmalar mevcuttur. Ancak pay senedi getirisi ve işlem hacmi ile yatırımcı ilgisi arasındaki ilişkinin ölçüldüğü çalışma sınırlıdır. Hâlbuki bulguların etkin piyasa hipotezi ya da davranışsal finans teorisinden hangisini destekler nitelikte olduğunun ortaya konulması gerekmektedir. Bu bağlamda bireysel yatırımcıların piyasaya yeni bir bilgi gelmemesi durumunda bile pay piyasasına ilişkin Google üzerinden araştırma yaparak bilgiyi ortaya çıkarmalarının işlem hacmi üzerindeki etkisi araştırılacaktır. Yatırımcı ilgisinin doğrudan ölçülememesi nedeniyle alanyazında bu alanda yapılan ilk çalışmalarda anket ve haber analizleri kullanıldığı bilinmektedir. Daha sonra yapılan çalışmalarda ise aktif yatırımcılara ait ilginin ölçülmesinde

sosyal medya platformları ve arama motorlarına ait verilerin kullanımı başlamıştır. 2004 yılından itibaren Google firması tarafından arama motorunda taranan verilerin sıklığına Google trend aramaları aracılığıyla erişim sağlanmaktadır. Verilerin karşılaştırılmasının kolaylaştırılması adına normalleştirme işlemi yapılmaktadır. Verilerin normalize edilmesinde ayın en yüksek hacmine göre endekslenen haftanın gününün hacim endeksi (RWW), bu endeksin toplamı (RDV), trendlerden alınan haftanın hacim endeksi (WV) ve veri tarihindeki en yüksek hafta arama hacmine göre endekslenmiş hacim kullanılmaktadır.

$$RWW_w = \sum_{i=7}^7 RDV_{wi} \quad \{i = 1,2,3,4,5,6,7\} \quad (1.1)$$

$$DV_t = \frac{WV_w}{DV_t} \times RDV_{wi} \quad (1.2)$$

Normalleştirme işlemi herhangi bir kelimenin toplam aranma ve güncel aranma sayılarına göre yapılmaktadır. Normalleştirme işlemi yapılan arama sayıları en yüksek çevrimiçi arama seviyesine göre yeniden ölçeklendirilmektedir. Ölçeklendirme sonucu aranan kelime 0 ile 100 aralığında değişmektedir. Aynı zamanda bu platform aracılığıyla herhangi bir kelimenin hangi sıklıkta arandığına dair haftalık istatistiklerin de elde edilmesi mümkündür.

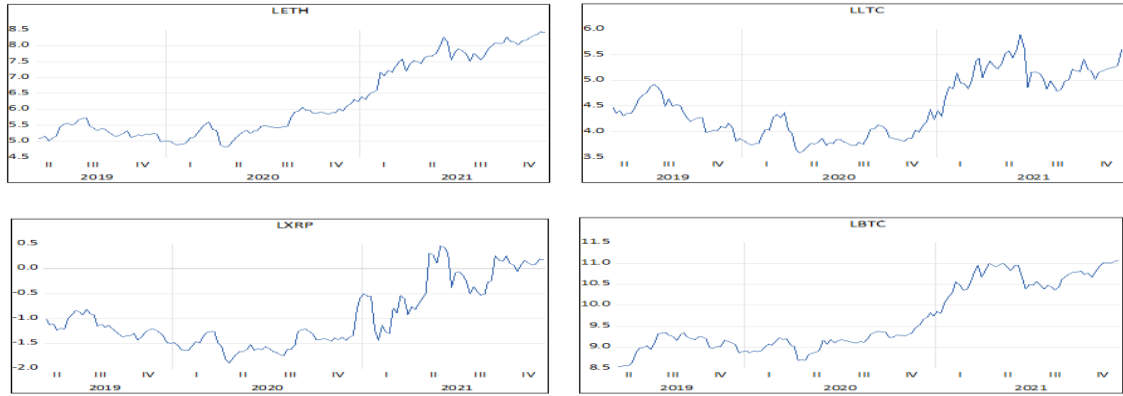
Ön-test niteliği taşıyan bu araştırma için 05.04.2019 – 12.11.2021 dönemi kapsamında Bitcoin, Ethereum, Litecoin, Ripple kripto para birim fiyatları Thomson Reuters veritabanından elde edilmiştir. Bu kripto para birimlerine ait Google Trend arama hacimleri ise Google Trend web sitesinden aynı dönem için temin edilmiştir. Analizler Ox programı aracılığıyla gerçekleştirilmiş olup, logaritmik dönüşüm yapılan değişkenlere ait tanımlayıcı istatistikler Tablo 4'te verilmiştir. Çalışmada Bitcoin fiyatları “BTC”, ethereum “ETH”, Litecoin “LTC”, Ripple “XRP”, Bitcoin Google Trend arama hacimleri “GT_BTC”, Ethereum için “GT_ETH”, Litecoin için “GT_LTC” ve Ripple için “GT_XRP” olarak kısaltılarak verilmiştir. Değişkenlerin varyansta durağan olmadıkları görülmektedir. Ayrıca eğrisellikleri vardır. Bu nedenle serilere logaritmik dönüşüm yapılmıştır. Tablo 4'de değişkenlerin önüne eklenmiş olan L, logaritmik dönüşümü göstermektedir.

Tablo 4: Değişkenlerin Tanımlayıcı İstatistikleri (Logaritmik, Günlük Frekans)

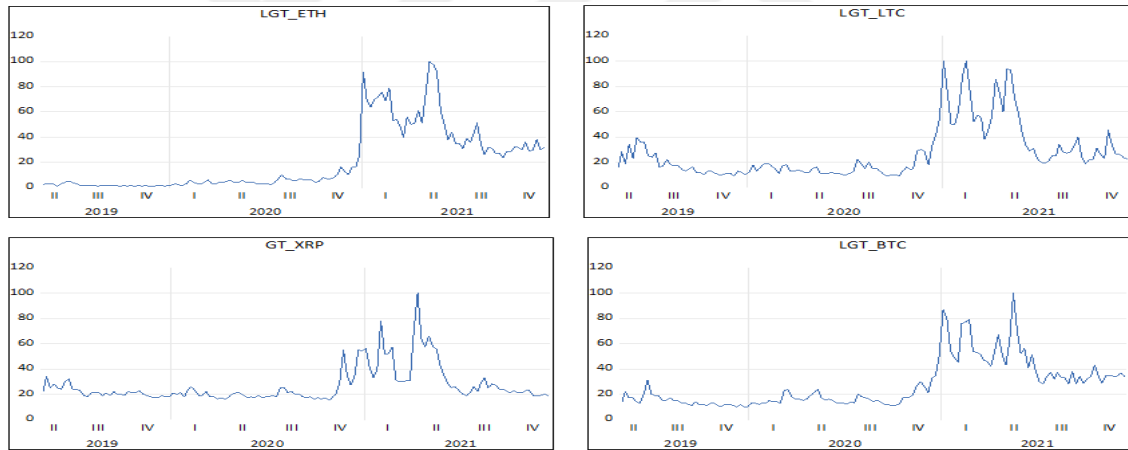
Değişken	LGT_ETH	LGT_LTC	LGT_XRP	LGT_BTC	LLTC	LXRP	LBTC	LETH
Ortalama	0.9433	1.3393	1.3897	1.3558	1.9431	-0.4229	4.2046	2.7086
Medyan	0.7782	1.2788	1.3222	1.2788	1.8906	-0.5336	4.0372	2.4923
Maksimum	2.0000	2.0000	2.0000	2.0000	2.5585	0.1979	4.8077	3.6640
Minimum	0.0000	0.9542	1.1761	1.0000	1.5525	-0.8210	3.7083	2.0944
Standart Sapma	0.6005	0.2720	0.1675	0.2574	0.2580	0.2709	0.3437	0.5062

Jarque-Bera	11.47445	11.99052	68.12678	10.8204	10.4335	16.09377	16.1238	17.05098
<i>p-değeri</i>	0.003224	0.002491	1.61E-15	0.004471	0.005425	0.00032	0.000315	0.000198

Logaritmik dönüşüm yapılmış serilerin normal dağılım özelliği göstermediği görülmektedir. Ancak finansal veriler oldukları için normal dağılıma sahip olmamaları, beklenen durumdur. Değişkenlere ait zaman grafikleri Şekil 17 ve Şekil 18’de verilmiştir.



Şekil 17: Kripto Para Birimleri Logaritmik Fiyat Grafikleri



Şekil 18: Kripto Para Birimleri Logaritmik Google Trend Arama Hacimleri Grafikleri

Analize alınan değişkenler arasındaki korelasyon analizi sonuçları Tablo 5’te verilmiştir.

Tablo 5: Korelasyon Analizi

<i>Fiyat</i>	LXRП	LLTC	LBTC	LETH
<i>Google Trend</i>				
LGT_XRP	0.286284	0.468378	0.483503	0.384043
LGT_BTC	0.661336	0.734427	0.806870	0.774815
LGT_LTC	0.533364	0.672777	0.665562	0.604932
LGT_ETH	0.679781	0.704416	0.873764	0.861505

Değişkenler arasında pozitif yönlü korelasyon olmakla birlikte genel olarak değerlendirildiğinde, ilgili kripto para birimlerinin hem kendi aramaları ve fiyatları arasında hem de birbirlerinin arama ve fiyatları arasında ilişki olduğu görülmektedir ($p < 0.05$).

Grafiklerine bakıldığında doğrusal olmadığı görülen değişkenlerin doğrusal olup olmadıklarını belirlemek amacı ile BDS testi uygulanmıştır. Broock, Dechert ve Scheinkman (1987) tarafından tanıtılan, ardından Broock, Hsieh ve LeBaron (1991) tarafından geliştirilen parametrik olmayan testtir. BDS testi, zaman serilerinde seri bağımlılığı belirlemek için güçlü bir araçtır. Tanımlanmamış bir alternatife karşı bağımsız ve özdeş olarak dağılmış (I.I.D.) sıfır hipotezini test eder. Başka bir ifade ile, doğrusallığa karşı doğrusal olmama test edilmektedir. Testin hipotezi aşağıdaki gibidir:

H_0 : Veriler bağımsız ve özdeş olarak dağılır (I.I.D.)

H_a : Veriler I.I.D. değildir.

Test, hipotezlerinden da anlaşılacağı üzere, sadece doğrusal olmamayı belirler, bağımlılığın tipi/türünü hakkında bir bilgi vermez. BDS testi, kaos teorisinden mekansal korelasyon kavramını kullanır ve korelasyon integrali yardımı ile hesaplanır.

Kaotik bir süreç, deterministik bir süreç tarafından meydana getirilen ancak stokastik bir süreç görünümünde olan ve bu sürece benzer otokorelasyon özellikleri sergileyen bir süreç olarak tanımlanmaktadır (Granger ve Teräsvirta, 1993: 90). Ancak doğrusal olmama, kaosun göstergelerinden biri olduğundan, böyle bir göstergelyi belirlemek için BDS testinin kullanılmasının uygun olacağı kabul edilmektedir. Test istatistiğinin hesaplanması için gömme boyutu olarak adlandırılan bir m değeri seçilir. Ardından serideki her m -ardışık noktayı alarak zaman serisini m -boyutlu vektörler oluşturulur;

$$\begin{aligned}x_1^m &= (x_1, x_2, \dots, x_m) \\x_2^m &= (x_2, x_3, \dots, x_{m+1}) \\&\vdots \\x_{N-m}^m &= (x_{N-m}, x_{N-m+1}, \dots, x_N)\end{aligned}$$

$C_m(l)$ m adet gömme boyutuna karşılık gelen korelasyon integralini, l uzaklığı ifade etmek üzere

$$W_m(l) = \frac{\sqrt{T}[C_m(l) - (C_l(l))^m]}{\sigma_m(l)}$$
 formülü ile hesaplanır (Jirasakuldech ve Emekter, 2011: 15).

BDS testi iki uçlu (two-tailed) bir testtir ve test istatistiği kritik değerlerden büyük veya küçükse sıfır hipotezini reddetmemiz gerekir (örn. $\alpha=0.05$ ise, kritik değer = ± 1.96) (Broock vd., 1996:203-205). Serinin doğrusal olduğunu ifade eden H_0 hipotezinin reddedilmemesi durumunda serinin doğrusallığına, H_0 hipotezi reddedildiğinde doğrusal olmadığına karar verilir. Ancak yukarıda da değinildiği üzere, alternatif hipotez, doğrusal olmamanın formu ile ilgili bilgi vermez.

Tablo 6. BDS Testi Sonuçları (Logaritmik Seriler)

	Boyut	BDS Test İstatistiği	Std. Hata	Z-İstatistiği	p-değeri
LBTC	2	0.180996	0.004647	38.94584	0.0000
	3	0.304730	0.007343	41.49967	0.0000
	4	0.387158	0.008689	44.55477	0.0000
	5	0.443694	0.008999	49.30608	0.0000
	6	0.481941	0.008622	55.89990	0.0000
		Boyut	BDS Test İstatistiği	Std. Hata	Z-İstatistiği
LETH	2	0.183733	0.004614	39.81770	0.0000
	3	0.312516	0.007298	42.82114	0.0000
	4	0.400958	0.008645	46.37929	0.0000
	5	0.461658	0.008962	51.51347	0.0000
	6	0.503289	0.008595	58.55765	0.0000
		Boyut	BDS Test İstatistiği	Std. Hata	Z-İstatistiği
LXRP	2	0.165832	0.005727	28.95817	0.0000
	3	0.277922	0.009134	30.42568	0.0000
	4	0.350935	0.010915	32.15281	0.0000
	5	0.397539	0.011414	34.82960	0.0000
	6	0.427017	0.011043	38.66852	0.0000
		Boyut	BDS Test İstatistiği	Std. Hata	Z-İstatistiği
LLTC	2	0.163206	0.003798	42.97091	0.0000
	3	0.277855	0.006028	46.09035	0.0000
	4	0.352868	0.007165	49.24577	0.0000
	5	0.400963	0.007453	53.80075	0.0000
	6	0.430977	0.007171	60.09963	0.0000
		Boyut	BDS Test İstatistiği	Std. Hata	Z-İstatistiği
LGT_BTC	2	0.148122	0.004255	34.80974	0.0000
	3	0.252835	0.006765	37.37555	0.0000
	4	0.323293	0.008054	40.14111	0.0000
	5	0.368660	0.008391	43.93508	0.0000
	6	0.394500	0.008088	48.77781	0.0000
		Boyut	BDS Test İstatistiği	Std. Hata	Z-İstatistiği
LGT_ETH	2	0.172440	0.003739	46.11789	0.0000
	3	0.295107	0.005920	49.84710	0.0000
	4	0.378738	0.007019	53.95611	0.0000
	5	0.435793	0.007283	59.83943	0.0000
	6	0.474675	0.006990	67.90736	0.0000
		Boyut	BDS Test İstatistiği	Std. Hata	Z-İstatistiği
LGT_XRP	2	0.139613	0.005518	25.30198	0.0000
	3	0.236229	0.008693	27.17403	0.0000
	4	0.295236	0.010259	28.77715	0.0000
	5	0.328918	0.010596	31.04050	0.0000
	6	0.343456	0.010126	33.91902	0.0000
		Boyut	BDS Test İstatistiği	Std. Hata	Z-İstatistiği
LGT_LTC	2	0.137515	0.009293	14.79752	0.0000
	3	0.235920	0.014814	15.92556	0.0000
	4	0.299150	0.017702	16.89954	0.0000
	5	0.340541	0.018518	18.38972	0.0000
		Boyut	BDS Test İstatistiği	Std. Hata	Z-İstatistiği

6	0.363519	0.017927	20.27788	0.0000
---	----------	----------	----------	--------

Tablo 6a ve Tablo 6b’de verilen BDS testi sonuçları, düzey ve logaritmik dönüştürülmüş değişkenler için doğrusallığı ifade eden sıfır hipotezinin tüm boyutlar için reddedildiğini göstermektedir. Bu da değişkenlerin tüm boyutlarda doğrusal olmadığını ortaya koymaktadır. Logaritmik serilerin doğrusal olmadığı belirlendikten sonra doğrusal olmayan seriler için uygun olan testlerden KSS testi ile serilerin durağan olup olmadıkları test edilmiş ve test sonuçları Tablo 7’de verilmiştir.

Kapetanios, Shin ve Snell (2003), tarafından geliştirilen doğrusal olmayan ve kısaca KSS diye adlandırılan birim kök testinde, Taylor yaklaşımından yararlanılmaktadır. Kapetanios vd. (2003), durağan olmayan doğrusal süreci durağan ancak doğrusal olmayan süreçten ayırmayı sağlayacak bir yaklaşım önermiştir. Bu test, doğrusal olmayan Üstel Yumuşak Geçişli Otoregresif (ESTAR) sürecinin birim köklü sıfır hipotezini ifade ederken alternatif hipotez durağanlığı temsil etmektedir.

$$\Delta Y_t = \gamma Y_{t-1} [1 - \exp(-\theta Y_{t-1}^2)] + \varepsilon_t \quad (\theta \geq 0) \quad (1.3)$$

Doğrusal olmayan ayarlama için $[1 - \exp(-\theta Y_{t-1}^2)]$ üstel geçiş fonksiyonu uyarlanmıştır. H_0 hipotezi altında doğrusal süreç ($H_0: \theta = 0$) test edilir. Alternatif hipotez ise doğrusal olmayan ama global olarak durağan süreci ifade etmektedir. H_0 hipotezinin test edilmesi için (1.4) yardımcı regresyon denkleminde yararlanılır.

$$\Delta Y_t = \delta Y_{t-1}^3 + \varepsilon_t \quad (1.4)$$

Serisel korelasyon olması durumunda denklem

$$\Delta Y_t = \sum_{j=1}^p p_j \Delta Y_{t-j} + \delta Y_{t-1}^3 + \varepsilon_t \quad (1.5)$$

olacak şekilde genişletilmektedir. Hesaplanan test istatistiği $(t_{NL} = \frac{\hat{\delta}}{se(\hat{\rho})})$ üzerinden t_{NL} asimptotik kritik değerler benzeşim yolu ile elde edilmektedir (Kapetonis vd., 2003; 363-364).

Tablo 7: KSS Doğrusal Olmayan Birim Kök Testi Sonuçları

<i>Model</i>	Ham Model			Trendden Arındırılmış Model		
	%1	%5	%10	%1	%5	%10
<i>Test İstatistiği</i>	-2.82	-2.23	-1.94	-3.91	-3.38	-3.13
<i>LXRP</i>		-1.356			-1.999	
<i>ΔLXRP</i>		-3.147*			-3.420*	
<i>LGT_XRP</i>		-1.263			-1.388	
<i>ΔLGT_XRP</i>		-2.341*			-3.412*	
<i>LLTC</i>		-1.787			-1.973	
<i>ΔLLTC</i>		-2.508*			-3.849*	
<i>LGT_LTC</i>		-1.873			-1.898	
<i>ΔLGT_LTC</i>		-3.168*			-3.490*	
<i>LBTC</i>		-1.394			-1.540	
<i>ΔLBTC</i>		-2.681*			-3.511*	
<i>LGT_BTC</i>		-1.215			-1.527	
<i>ΔLGT_BTC</i>		-3.487*			-3.699*	
<i>LETH</i>		-1.486			-1.929	
<i>ΔLETH</i>		-2.866*			-4.634*	
<i>LGT_ETH</i>		-1.668			-1.967	
<i>ΔLGT_ETH</i>		-2.520*			-4.491*	

Not: KSS(2003) Tablo 3b'den büyük örneklem için alınmıştır. (*) Ho red, seriler durağan.

Doğrusal olmayan yapıyı dikkate alan KSS testi sonuçlarına göre serilerin düzey haliyle değil, birinci farkının durağan olduğu belirlenmiştir. Bunun yanı sıra Şekil 17 ve Şekil 18'de verildiği üzere serilerin özellikle 2020 yılının son çeyreğinde farklı eğilim gösterdikleri görülmektedir.

Tablo 8. BDS Testi Sonuçları (Logaritmik Fark Serileri)

	Boyut	BDS Test İstatistiği	Std. Hata	Z-İstatistiği	<i>p</i> -değeri
Δ LBTC	2	0.018314	0.007775	2.355317	0.0185
	3	0.031863	0.012419	2.565791	0.0103
	4	0.037048	0.014863	2.492614	0.0127
	5	0.036773	0.015572	2.361532	0.0182
	6	0.031076	0.015095	2.058727	0.0395
		Boyut	BDS Test İstatistiği	Std. Hata	Z-İstatistiği
Δ ETH	2	0.017407	0.008164	2.132156	0.0330
	3	0.026734	0.013037	2.050675	0.0403
	4	0.030955	0.015602	1.984025	0.0473
	5	0.037684	0.016345	2.305581	0.0211
	6	0.039052	0.015844	2.464756	0.0137
		Boyut	BDS Test İstatistiği	Std. Hata	Z-İstatistiği
Δ LXRP	2	0.018689	0.010728	1.742045	0.0815
	3	0.046613	0.017159	2.716477	0.0066
	4	0.073595	0.020578	3.576323	0.0003
	5	0.088575	0.021608	4.099134	0.0000
	6	0.093640	0.020999	4.459266	0.0000
		Boyut	BDS Test İstatistiği	Std. Hata	Z-İstatistiği
Δ LTC	2	0.017142	0.008250	2.077801	0.0377
	3	0.034323	0.013164	2.607395	0.0091
	4	0.042061	0.015742	2.671948	0.0075
	5	0.050012	0.016478	3.035045	0.0024
	6	0.052252	0.015961	3.273705	0.0011
		Boyut	BDS Test İstatistiği	Std. Hata	Z-İstatistiği
Δ LG_TBTC	2	0.020790	0.007141	2.911421	0.0036
	3	0.036007	0.011367	3.167549	0.0015
	4	0.048362	0.013559	3.566777	0.0004
	5	0.051747	0.014156	3.655489	0.0003
	6	0.047098	0.013675	3.444106	0.0006
		Boyut	BDS Test İstatistiği	Std. Hata	Z-İstatistiği
Δ LG_ETH	2	0.043829	0.007382	5.937091	0.0000
	3	0.070768	0.011794	6.000375	0.0000
	4	0.083266	0.014119	5.897447	0.0000
	5	0.085309	0.014795	5.766243	0.0000
	6	0.084474	0.014344	5.889027	0.0000
		Boyut	BDS Test İstatistiği	Std. Hata	Z-İstatistiği
Δ LG_XRP	2	0.050265	0.009027	5.568267	0.0000
	3	0.077692	0.014412	5.390773	0.0000
	4	0.103087	0.017247	5.977094	0.0000
	5	0.111713	0.018069	6.182649	0.0000
	6	0.116505	0.017517	6.651008	0.0000
		Boyut	BDS Test İstatistiği	Std. Hata	Z-İstatistiği
Δ L_TTC	2	0.013089	0.006199	2.111619	0.0347

3	0.025768	0.009905	2.601545	0.0093
4	0.038369	0.011856	3.236144	0.0012
5	0.041444	0.012422	3.336391	0.0008
6	0.035673	0.012041	2.962722	0.0030

Doğrusal olmayan yapıyı dikkate alan KSS testi sonuçları, logaritmik düzey serilerin durağan olmadığını, ancak logaritmik ilk farkının durağan olduğunu göstermektedir. Bunun üzerine logaritmik ilk fark serileri içinde BDS testi yapılmış ve sonuçları Tablo 8’de verilmiştir. Tablolarda günlük fiyat ve tweet hacmi serilerinin logaritmik farkları için hesaplanan test istatistiklerinin Ho hipotezinin farklı boyutlarda reddedildiği görülmektedir. Bu da logaritmik fark serilerinin doğrusal olmama özelliğini ortaya koymaktadır.

Yukarıda logaritmik fark serilerinin durağan olduğu ancak doğrusal olmadığı yapılan testlerle ortaya kondu. Serilerin grafiklerinde de (Şekil 17 ve Şekil 18), özellikle 2020 yılının son çeyreğinde farklı eğilimler/davranışlar sergiledikleri gözlenmektedir. Bu özelliklerin geçerliliğini ortaya çıkarmak amacı ile başka bir ifade ile doğrusal olmayan değişimin modellenmesi için Markov rejim değişim (Markov Regime Switching: MRS) veya Markov değişim (MS) modellerinden yararlanılmaya karar verilmiştir. MS modelleri, Hamilton’un (1989) çalışmasıyla tanıtılmış ve ardından sıklıkla kullanılmaya başlanmıştır (Akgül vd. 2007: 9). Markov rejim prosedürünün kripto para piyasasına uygulandığı öncü çalışmalar incelendiğinde, Moln’ar ve Theis (2018)’in yedi rejimli ve Chappell (2018)’in beş rejimli Markov rejim modelleri önerdikleri görülmüştür. Alanyazında yer alan diğer çalışmalara dair bilgiler Tablo 9’da verilmiştir.

Tablo 9. Kripto Para Piyasasının Markov Rejim Değişim Modelleriyle İncelendiği Çalışmalar

Yazar/lar & Yıl	Amaç	Yöntem	Sonuç
Maupin (2019)	Bitcoin, Ethereum, Ripple ve Litecoin kripto para birimlerinin fiyat tahmininde en yüksek performansa sahip modelin belirlenmesi	AR VAR MS-AR MS-VAR	İncelenen kripto para birimleri için Markov rejim değişim modellerinin daha verimli sonuçlar verdiği tespit edilmiştir.
Ardia vd. (2019)	Bitcoin oynaklık dinamiklerinin belirlenmesi	MS-GARCH	İki rejimli MSGARCH modelinin en iyi performansa sahip olduğu tespit edilmiştir.
Söylemez ve Yılmaz Türkmen (2019)	Bitcoin getirilerinde oynaklık dinamiklerinin belirlenmesi	MS-GARCH	Bitcoin getirilerinin üç farklı rejimde geçişken olduğu tespit edilmiştir.
Caporale ve Zekokh (2019)	Dört kripto para biriminin oynaklık dinamiklerinin incelenmesi	GARCH MS-GARCH	İki rejimli MSGARCH modellerinin, BTC, ETH, XRP ve LTC için tek rejimli GARCH modellerinden daha başarılı oynaklık tahmini yaptığı tespit edilmiştir.
Mba ve Mwambi (2020)	Kripto para portföy seçiminde uygun modelin belirlenmesi	COGARCH MS-COGARCH	MS-COGARCH’in tek rejimli COGARCH’tan daha iyi performans gösterdiği tespit edilmiştir.

Ma vd. (2020)	Bitcoin'in gerçekleşen varyansının model tahmin gücünü artırma durumunun incelenmesi	MRS-MIDAS	MRS-MIDAS modelinin, Bitcoin'in gerçekleşen varyansının tahmin edilmesinde 2 haftalık ve 1 aylık tahminlerde önemli gelişmeler gösterdiği tespit edilmiştir.
Koki vd. (2020)	, Bitcoin, Ethereum ve Ripple getirilerinin rejim değişikliğinin incelenmesi	Saklı Markov modelleri	İncelenen kripto para getirilerinde dört rejimli homojen olmayan Saklı Markov (NHHM) modelinin en yüksek performansa sahip olduğu tespit edilmiştir.
Rojas ve Coronado (2020)	Bitcoin getirilerinin oynaklık dinamiklerinin incelenmesi	MS-GARCH	Toplamda 28 alt dönemde yüksek oynaklık olduğu ve en yüksek dönemin 2013 yılında olduğu tespit edilmiştir.
Samırkaş (2021)	Bitcoin getirilerinin oynaklık dinamiklerinin incelenmesi	Markov Rejim Değişim Modeli	Bitcoin getirilerinde rejim kalıcılığının yüksek olduğu tespit edilmiştir.
Maciel (2021)	Kripto para oynaklık tahmininde model karşılaştırmasının yapılması	GARCH MS-GARCH	MSGARCH modelinin oynaklığın belirlenmesinde GARCH modeline göre daha yüksek performans gösterdiği tespit edilmiştir.
Tan vd. (2021)	Bitcoin getiri serisinin oynaklık dinamiklerinin incelenmesi	GARCH TV-MS-GARCH	TV-MS-GARCH modelinin en yüksek tahmin performansına sahip olduğu tespit edilmiştir.
Chkili (2021)	Bitcoin oynaklık dinamiklerinin incelenmesi	MS-GARCH FIGARCH	Bitcoin fiyatlarının oynaklığının modellenmesinde FIGARCH modelinin daha iyi performansa sahip olduğu tespit edilmiştir.
Panagiotidis vd. (2022)	292 kripto paranın oynaklık dinamiklerinin incelenmesi	GARCH EGARCH MS-GARCH	MS-GARCH modelinin diğer modellere kıyasla performansının daha yüksek olduğu tespit edilmiştir.

Alanyazına bakıldığında, kripto para piyasasının Markov rejim değişim modelleri aracılığıyla incelendiği sınırlı sayıda çalışma olduğu görülmüştür. Ancak çalışma bulguları karşılaştırmalı olarak değerlendirildiğinde, kripto para piyasasının dinamiklerinin incelenmesinde Markov rejim değişim modellerinin yüksek performans sağladığı görülmektedir.

MS-AR(p) modeli, p mertebesinde AR sürecini gösteren Markov değişim Otoregresif modelini ifade etmektedir.

$$y_t = \begin{cases} c_1 + \alpha_{11}y_{t-1} + \dots + \alpha_{p1}y_{t-p} + \varepsilon_t & s_t = 0 \\ c_2 + \alpha_{12}y_{t-1} + \dots + \alpha_{p2}y_{t-p} + \varepsilon_t & s_t = 1 \end{cases}$$

Otoregresif kısım ve sabit terim t-zamanındaki rejime bağlıdır. 0 ve 1, 2 rejimli bir modelde rejimleri göstermektedir. Modeller arasında seçimlerde; parametrelerin istatistiksel anlamlılığını, hata terimleri için gerekli varsayımların sağlanması, en küçük AIC değerine ve en büyük log-olabilirlik değerine sahip olabirliklerine dikkat edilmiştir.

Model tanımlaması; I, MS kesim (intercept) terimini; A, MS otoregresif parametreleri; H, MS değişen varyansı (heteroskedasticity) gösteriminin yer verilmesi ile MSI-AR, MSA-AR, MSH-AR, MSIH-AR veya MSIAH-AR olacak şekilde yapılmaktadır (Krolzig, 1998:6). Aşağıda modeller bu özellikleri dikkate alacak şekilde kısaltmalarla tanımlanmıştır.

Tablo 9’da Litecoin kripto para birimine (LTC) ait Google arama haciminin (T_LTC) bağımlı değişken olduğu artıkları normal, otokorelasyonsuz ve sabit varyansla dağılan MS(2)-AR(1)-X modelinin sonuçları verilmiştir. Tüm modellerde başlangıç geçiş olasılıklarının hesaplanması aşamasında özyinelemeyi (recursion) başlatmak için ergodik olasılıklardan yararlanılmış ve güçlü yakınsamanın olduğu modeller tercih edilmiştir.

Tablo 10: Litecoin Arama Hacmi için Markov Rejim Değişim Modeli Tahmin Sonuçları:

MSIAH(2)-AR(1)-X				
Değişkenler (Bağımlı: ΔGT_LLTC)	Katsayı	Standart Hata	t-istatistik	Olasılık
AR-1(0)	-0.224666	0.07551	-2.98	0.004*
AR-1(1)	0.879016	0.2681	3.28	0.001*
$\Delta LLTC(t)$	-0.334060	0.05669	-5.89	0.000*
Sabit(0)	0.0517577	0.03274	1.58	0.117
Sabit(1)	-0.119271	0.04065	-2.93	0.004*
$\sigma(0)$	0.268885	0.07829		
$\sigma(1)$	0.024760	0.01603		
$p_{\{0 0\}}$	0.802699	0.1198		
$p_{\{0 1\}}$	0.613484	0.1340		
Log-olabilirlik: 9.16358103			AIC: -0.00261729652	
SC: 0.201021293			Normallik Testi $X^2(2)=0.048060[0.9763]$	
ARCH 1-2 test: $F(2,112)=0.27133 [0.7629]$			Portmanteau Test $X^2(124)=105.40 [0.8855]$	

Not: Model çözümlenmelerinde özyinelemeyi başlatmak için ergodik olasılıklar kullanılmıştır. Standart hatalar sayısal Hessian matrisine dayalı hesaplanmış ve güçlü yakınsama sağlanmıştır.

Litecoin Google arama hacmi için en uygun olduğu belirlenen MSIAH(2)-AR(1)-X modeli artıklarının varsayımları sağlayıp sağlamadığını görmek için ARCH, normallik ve Portmanteo testleri yapılmış ve modelin temel varsayımları sağladığı görülmüştür. Ayrıca LR olabilirlik oranına göre serinin doğrusal olduğunu ileri süren sıfır hipotezi %5 anlamlılık düzeyinde reddedilmiştir. Böylece MS’in doğrusal modele göre üstünlük sağladığı belirlenmiştir. Tahmin edilen modelde değişen varyansı gösteren H kısaltması, rejimler arasında standart sapmanın (sigma) değiştiğini göstermektedir. Sigma değerlerinden yararlanarak rejimlerin yüksek/düşük oynaklık, yüksek/düşük risk rejimleri olarak isimlendirilmesi olanaklı hale gelmektedir.

Tablo 11: Geçiş Olasılıkları Gösterimi – Litecoin Google Arama Hacmi


Geçiş Olasılıkları	Rejim 0,t	Rejim 1,t
Rejim 0,t+1	0.80	0.39
Rejim 1,t+1	0.20	0.61

Tablo 11’de verilen rejimler arası geçiş olasılıkları matrisi incelendiğinde, t-zamanında Rejim(0)’da iken Rejim(0)’da kalma olasılığının %80, Rejim(1)’e geçme olasılığının %20 olduğu görülmektedir. Ayrıca t-zamanında Rejim(1)’de iken Rejim(1)’de kalma olasılığı %61, Rejim(1) de iken Rejim(0)’a geçme olasılığı %39 dur. Bu da Rejim(0) da iken aynı rejimde kalıcılığının daha yüksek olduğunu ve ani geçiş özelliğinin daha az olduğunu göstermektedir.

Tablo 12: Rejimde Geçirilen Süre Gösterimi – Litecoin Google Arama Hacmi

Rejimler	Gözlem	Süre	Yüzde
Rejim 0,t	83	7.55	%66.40
Rejim 1,t	42	3.82	%33.60

Tablo 12’de verilmiş olan rejimlerin geçiş süreleri de yukarıdaki bulguları desteklemekte ve Rejim(0) da ortalama kalma süresinin 7.5 gün, Rejim(1)’de ortalama kalma süresinin yaklaşık 4 gün olduğunu göstermektedir.

**Şekil 19:** Litecoin Arama Hacmi -Markov Geçiş Rejim Olasılıkları – MSIAH(2)-AR(1)-X

Şekil 19’da Litecoin Arama Hacmi değişkeni için tahmin edilmiş olan MSIAH(2)-AR(1)-X modeline ait düzgünleştirilmiş rejim olasılıkları görülmektedir. Grafiklerde Litecoin için analiz döneminde Rejim (0)’ın evrelerin daha uzun süreli ve daha sık gözlemlendiğini ifade etmektedir. Yine grafiklerde, Rejim (1)’in evre sayısının ve sürelerinin daha az olduğu görülmektedir.

Tablo 13’te Litecoin kripto para fiyatlarının (LTC) bağımlı değişken olduğu MS(2)-AR(1)-X modelinin sonuçları verilmiştir. Bu model tüm varsayımları sağlayan, en küçük AIC, en yüksek LR değerine sahip modeldir.

Tablo 13: Litecoin Fiyatları için Markov Rejim Değişim Modeli Tahmin Sonuçları:

MSIH(2)-AR(1)-X				
Değişkenler (Bağımlı: $\Delta LLTC$)	Katsayı	Standart Hata	t-istatistik	Olasılık
AR-1(0)	-0.313899	0.09233	-3.40	0.001*
$\Delta GT_{LLTC}(t)$	-0.0597231	0.03470	-1.72	0.088

$\Delta GT_LLTC(t-3)$	0.141010	0.04258	3.31	0.001*
$\Delta GT_LLTC(t-4)$	0.106186	0.03728	2.85	0.005*
$\Delta GT_LLTC(t-5)$	0.283863	0.03871	7.33	0.000*
$\Delta GT_LLTC(t-8)$	0.122657	0.03720	3.30	0.001*
Sabit(0)	0.0158963	0.007715	2.06	0.042*
Sabit(1)	-0.0143742	0.02967	-0.484	0.629
$\sigma(0)$	0.0737254	0.008939		
$\sigma(1)$	0.216188	0.03287		
$p_{\{0 0\}}$	0.902390	0.05788		
$p_{\{0 1\}}$	0.753236	0.1215		
Log-olabilirlilik: 91.9018711			AIC: -1.27842994	
SC: -1.00691182			Normallik Testi $X^2(2)=2.2443[0.3256]$	
ARCH 1-2 test: $F(2,109)=1.3098[0.2741]$			Portmanteau Test $X^2(124)=121.19[0.5547]$	

Litecoin fiyatı için en uygun olduğu belirlenen MSIH(2)-AR(1)-X modelinin seçilmesinde kullanılan tüm test sonuçları verilmiştir. Bu modelde LR'a göre serinin doğrusal olduğunu ileri süren sıfır hipotezi %5 anlamlılık düzeyinde reddedilmiş ve MS'in doğrusal modele göre üstünlük sağladığı belirlenmiştir. H, rejimlerde standart sapmanın farklılığını gösterir ve fiyat serisi için oluşturulan bir model olduğu için rejimler yüksek ve düşük oynaklık rejimleri olarak isimlendirilmiştir. Rejim(0), düşük oynaklık rejimini; Rejim(1), yüksek oynaklık rejimini ifade etmektedir.

Tablo 14: Geçiş Olasılıkları Gösterimi – Litecoin Fiyatları İçin


Geçiş Olasılıkları	Rejim 0,t	Rejim 1,t
Rejim 0,t+1	0.90	0.25
Rejim 1,t+1	0.10	0.75

Tablo 14'te rejimler arası geçiş olasılıkları matrisi verilmiştir. Tablo incelendiğinde, Rejim(0) da yani düşük oynaklık rejiminde iken aynı rejimde kalma olasılığı %90, Rejim(1)'e yani yüksek oynaklık rejimine geçme olasılığı %10'dur. Rejim(1)'de yani yüksek oynaklık rejiminde iken aynı rejimde kalma olasılığı %75 iken Rejim(0)'a yani düşük oynaklık rejimine geçme olasılığı %25'tür. Bu da serinin düşük oynaklık rejiminde bulunduğu aynı rejimde kalıcılığının yüksek olduğunu ve ani geçiş özelliğinin az olduğunu göstermektedir.

Tablo 15: Rejimde Geçirilen Süre Gösterimi – Litecoin Fiyatları İçin

Rejimler	Gözlem	Süre	Yüzde
Rejim 0,t	96	13.71	%76.80
Rejim 1,t	29	4.83	%23.20

Tablo 15'te düşük oynaklık rejiminde (Rejim(0)) ortalama kalma süresi yaklaşık 14 hafta iken yüksek oynaklık rejiminde (Rejim(1)) ortalama kalma süresi yaklaşık 5 hafta olduğu görülmektedir.



Şekil 20: Litecoin Fiyatları için Markov Geçiş Rejim Olasılıkları – MSIH(2)-AR(1)-X

Şekil 20’de Litecoin fiyat değişkeni için tahmin edilmiş olan MSIH(2)-AR(1)-X modeline ait düzgünleştirilmiş rejim olasılıkları görülmektedir. Grafiklerde Litecoin fiyatı için analiz döneminde düşük oynaklık rejimi (Rejim (0))’ın evrelerin daha uzun süreli ve daha sık gözlenirken yüksek oynaklık rejiminin (Rejim (1)) evre sayısının ve sürelerinin daha az olduğu görülmektedir.

Tablo 16’da Bitcoin kripto para birimine (BTC) ait Google arama hacminin (T_BTC) bağımlı değişken olduğu MS(2)-ARMA(1,1)-X modelinin sonuçları verilmiştir. Bu model de yukarıda bahsedildiği üzere, tüm varsayımları sağlayan, en küçük AIC, en yüksek LR değerine sahip modeldir.

Tablo 16: Bitcoin Google Arama Hacmi İçin Markov Rejim Değişim Modeli Tahmin

Sonuçları: MSIH(2)-ARMA(1,1)-X

Değişkenler (Bağımlı: ΔGT_LBTC)	Katsayı	Standart Hata	t-istatistik	Olasılık
AR-1(0)	0.553488	0.1243	4.45	0.000*
MA-1(0)	-0.798608	0.07911	-10.1	0.000*
$\Delta LBTC(t)$	0.210822	0.1190	1.77	0.079
Sabit(0)	0.181506	0.07346	2.47	0.015*
Sabit(1)	-0.0476881	0.03110	-1.53	0.128
$\sigma(0)$	0.239106	0.03115		
$\sigma(1)$	0.101380	0.01680		
$p_{\{0 0\}}$	0.731359	0.1066		
$p_{\{0 1\}}$	0.846286	0.07995		
Log-olabilirlik: 42.5231346		AIC: -0.536370153		
SC: -0.332731564		Normallik Testi $X^2(2)= 0.42111[0.8101]$		
ARCH 1-2 test: $F(2,112)= 0.065973[0.9362]$		Portmanteau Test $X^2(124)= 105.11[0.8895]$		

Bitcoin Google arama hacmi için için en uygun olduğu belirlenen MSIH(2)-ARMA(1,1)-X modelinin temel varsayımları sağladığı görülmüştür. Tahmin edilen modelde değişen varyansı gösteren H kısaltması, rejimler arasında standart sapmanın (sigma) değiştiğini göstermektedir.

Tablo 17: Geçiş Olasılıkları Gösterimi – Bitcoin Google Arama Hacmi


Geçiş Olasılıkları	Rejim 0,t	Rejim 1,t
Rejim 0,t+1	0.73	0.15
Rejim 1,t+1	0.27	0.85

Tablo 17’de rejimler arası geçiş olasılıkları matrisi verilmiştir. Tablo incelendiğinde, Rejim(0) da iken aynı rejimde kalma olasılığı %73, Rejim(1)’e geçme olasılığı %27’dir. Rejim(1)’de yani iken aynı rejimde kalma olasılığı %85 iken Rejim(0)’a yani düşük oynaklık rejimine geçme olasılığı %15’dir. Bu da Bitcoin Google arama hacmi serisinin Rejim(1) de iken bulunduğu rejimde kalıcılığının daha yüksek olduğu ve ani geçiş özelliğinin daha az olduğunu göstermektedir

Tablo 18: Rejimde Geçirilen Süre Gösterimi – Bitcoin Google Arama Hacmi

Rejimler	Gözlem	Süre	Yüzde
Rejim 0,t	38	3.17	%30.40
Rejim 1,t	87	6.69	%69.60

Tablo 18’de Rejim(0)’da ortalama kalma süresi 3 hafta, Rejim(1)’de ortalama kalma süresi yaklaşık 7 haftadır.

**Şekil 21:** Bitcoin Google arama hacmi Markov Geçiş Rejim Olasılıkları – MSIH(2)-ARMA(1,1)-X

Şekil 21’de Bitcoin Google arama hacmi için tahmin edilmiş olan MSIH(2)-AR(1)-X modeline ait düzgünleştirilmiş rejim olasılıkları görülmektedir. Grafiklerde Bitcoin arama hacmi için analiz döneminde Rejim (0)’ın evrelerin daha kısa süreli ve daha seyrek olduğu gözlenirken Rejim (1)’de evre sayısının ve sürelerinin daha çok olduğu görülmektedir.

Tablo 19’da Bitcoin fiyatı (BTC) için uygun olan MS(2)-ARMA(1,1)-X modelinin sonuçları verilmiştir. Bu model de yukarıda bahsedildiği üzere, tüm varsayımları sağlayan, en küçük AIC, en yüksek LR değerine sahip modeldir.

Tablo 19: Bitcoin Fiyatı için Markov Rejim Değişim Modeli Tahmin Sonuçları:

MSIH(2)-ARMA(1,1)-X

Değişkenler (Bağımlı: $\Delta LBTC$)	Katsayı	Standart Hata	t-istatistik	Olasılık
AR-1(0)	-0.593435	0.1274	-4.66	0.000*
MA-1(0)	0.524320	0.1348	3.89	0.000*

$\Delta LT_BTC(t - 1)$	-0.134874	0.03309	-4.08	0.000*
$\Delta LT_BTC(t - 2)$	0.0776885	0.03785	2.05	0.042*
$\Delta LT_BTC(t - 5)$	0.165392	0.03470	4.77	0.000*
Sabit(0)	0.0199318	0.005425	3.67	0.000*
Sabit(1)	-0.0411017	0.03705	-1.11	0.270
$\sigma(0)$	0.0667150	0.005839		
$\sigma(1)$	0.206105	0.04196		
$p_{\{0 0\}}$	0.923498	0.04366		
$p_{\{0 1\}}$	0.538969	0.1914		
Log-olabilirlilik: 123.834987		AIC: -1.8053598		
SC: -1.5564682		Normallik Testi $X^2(2)= 1.6998[0.4275]$		
ARCH 1-2 test: $F(2,110)= 0.080280[0.9229]$		Portmanteau Test $X^2(124)= 111.97[0.7726]$		

Bitcoin fiyatı için en uygun olduğu belirlenen MSIH(2)-ARMA(1,1)-X modelinin seçilmesinde kullanılan tüm test sonuçları verilmiştir. H, rejimlerde standart sapmanın farklılığını göstermektedir. Bu nedenle rejimler yüksek ve düşük oynaklık rejimleri olarak isimlendirilmiştir. Rejim(0), düşük oynaklık rejimini; Rejim(1), yüksek oynaklık rejimini ifade etmektedir.

Tablo 20: Geçiş Olasılıkları Gösterimi – Bitcoin Fiyatları İçin


Geçiş Olasılıkları	Rejim 0,t	Rejim 1,t
Rejim 0,t+1	0.92	0.46
Rejim 1,t+1	0.08	0.54

Tablo 20’de Bitcoin fiyatı için rejimler arası geçiş olasılıkları matrisi verilmiştir. Tablo incelendiğinde, Rejim(0) da yani düşük oynaklık rejiminde iken aynı rejimde kalma olasılığı %92, Rejim(1)’e yani yüksek oynaklık rejimine geçme olasılığı %8’dir. Rejim(1)’de yani yüksek oynaklık rejiminde iken aynı rejimde kalma olasılığı %54 iken Rejim(0)’a yani düşük oynaklık rejimine geçme olasılığı %46’dır. Bu da serinin düşük oynaklık rejiminde bulunduğu aynı rejimde kalıcılığının çok yüksek olduğunu ve ani geçiş özelliğinin az olduğunu göstermektedir.

Tablo 21: Rejimde Geçirilen Süre Gösterimi – Bitcoin Fiyatları İçin

Rejimler	Gözlem	Süre	Yüzde
Rejim 0,t	114	19	%91.20
Rejim 1,t	11	2.20	%8.80

Düşük oynaklık rejiminde (Rejim(0)) ortalama kalma süresi 19 hafta iken yüksek oynaklık rejiminde (Rejim(1)) ortalama kalma süresi 2 haftadır.



Şekil 22: Markov Geçiş Rejim Olasılıkları –MSIH(2)-ARMA(1,1)-X

Şekil 22’de Bitcoin fiyat değişkeni için tahmin edilmiş olan modele ait düzgünleştirilmiş rejim olasılıkları görülmektedir. Grafiklerde Bitcoin fiyatı için analiz döneminde düşük oynaklık rejimi (Rejim (0))’ın evrelerin daha uzun süreli ve daha sık gözlenirken yüksek oynaklık rejiminin (Rejim (1)) evre sayısının ve sürelerinin çok az olduğu görülmektedir.

Tablo 22’de Ripple kripto para birimine (XRP) ait Google arama haciminin (T_XRP) bağımlı değişken olduğu modelin tahmin sonuçları ve test istatistikleri verilmiştir. Bu model de yukarıda bahsedildiği üzere, tüm varsayımları sağlayan, en küçük AIC, en yüksek LR değerine sahip modeldir.

Tablo 22: Ripple Google Arama Hacimi için Markov Rejim Değişim Modeli Tahmin Sonuçları: MSH(2)-AR(1)-X

Değişkenler (Bağımlı: ΔLT_XRP)	Katsayı	Standart Hata	t-istatistik	Olasılık
AR-1(0)	-0.216337	0.09094	-2.38	0.019*
$\Delta LXR(t)$	-0.137386	0.06689	-2.05	0.042*
$\Delta LXR(t - 1)$	-0.143752	0.07368	-1.95	0.054
$\Delta LXR(t - 2)$	-0.127720	0.06541	-1.95	0.053
$\Delta LXR(t - 3)$	-0.133078	0.06414	-2.07	0.040*
$\Delta LXR(t - 5)$	-0.150330	0.06454	-2.33	0.022*
$\Delta LXR(t - 7)$	-0.156558	0.07079	-2.21	0.029*
Sabit(0)	0.0732965	0.05919	1.24	0.218
Sabit(1)	-0.0110850	0.008544	-1.30	0.197
$\sigma(0)$	0.359667	0.05394		
$\sigma(1)$	0.100640	0.007458		
$p_{\{0 0\}}$	0.949469	0.04486		
$p_{\{0 1\}}$	0.989853	0.01056		
Log-olabilirlik: 68.4203545		AIC: -0.90114398		
SC: -0.60392124		Normallik Testi $X^2(2) = 0.28811[0.8658]$		
ARCH 1-2 test: $F(2,106) = 0.036811[0.9639]$		Portmanteau Test $X^2(122) = 108.01[0.8130]$		

Ripple Google arama hacmi için için en uygun olduğu belirlenen MSH(2)-AR(1)-X modelinin temel varsayımları sağladığı görülmüştür. Tahmin edilen modelde değişen varyansı gösteren H kısaltması, rejimler arasında standart sapmanın (sigma) değiştiğini göstermektedir.

Tablo 23: Geçiş Olasılıkları Gösterimi – Ripple Google Arama Hacmi


Geçiş Olasılıkları	Rejim 0,t	Rejim 1,t
Rejim 0,t+1	0.95	0.01
Rejim 1,t+1	0.05	0.99

Tablo 23’te rejimler arası geçiş olasılıkları matrisi verilmiştir. Tabloda, Rejim(0) da iken aynı rejimde kalma olasılığının %95, Rejim(1)’e geçme olasılığının %5 olduğu görülmektedir. Rejim(1)’de iken aynı rejimde kalma olasılığı %99 iken Rejim(0)’a geçme olasılığı %1’dir. Bu da Ripple arama hacmi serisinin Rejim(0) da iken aynı rejimde kalma olasılığı da Rejim(1)’de iken aynı rejimde kalma olasılığının da çok yüksek olduğunu göstermektedir.

Tablo 24: Rejimde Geçirilen Süre Gösterimi – Ripple Google Arama Hacmi

Rejimler	Gözlem	Süre	Yüzde
Rejim 0,t	25	25	%20.33
Rejim 1,t	98	49	%79.67

Tablo 24’te Rejim(0)’da ortalama kalma süresinin 25 hafta, Rejim(1)’de ortalama kalma süresinin 49 hafta olduğu görülmektedir. Bu da diğer kripto paralar içinde aynı rejimde kalma süreleri arasında en yüksek olan süredir.



Şekil 23: Markov Geçiş Rejim Olasılıkları – MSH(2)-AR(1)-X

Şekil 23’de Ripple Google arama hacmi için tahmin edilmiş olan MSH(2)-AR(1)-X modeline ait düzgünleştirilmiş rejim olasılıkları görülmektedir. Grafiklerde analiz döneminde Rejim (0)’ın evre sayısı 1, Rejim (1) evre sayısının 2 ve sürelerinin daha çok olduğu görülmektedir.

Tablo 25’te Ripple fiyatı (XRP) için uygun olan MSH(2)-X modelinin sonuçları verilmiştir. Bu model de yukarıda bahsedildiği üzere, tüm varsayımları sağlayan, en küçük AIC, en yüksek LR değerine sahip modeldir. Ayrıca diğer paralar için MS-AR modelleri uygun iken tek MS modeline sahip olan paradır.

Tablo 25: Ripple Fiyatı için Markov Rejim Değişim Modeli Tahmin Sonuçları: Dinamik MS(2)

Değişkenler	Katsayı	Standart Hata	t-istatistik	Olasılık
(Bağımlı: ΔLXR_P)				
$\Delta L_T XRP(t - 1)$	0.0861470	0.05280	1.63	0.106
$\Delta L_T XRP(t - 2)$	0.0976641	0.05456	1.79	0.076
$\Delta L_T XRP(t - 4)$	0.348559	0.05629	6.19	0.000*
$\Delta L_T XRP(t - 5)$	0.315299	0.05703	5.53	0.000*
$\Delta L_T XRP(t - 6)$	0.176291	0.05963	2.96	0.004*
$\Delta L_T XRP(t - 7)$	0.200662	0.05666	3.54	0.001*
$\Delta L_T XRP(t - 10)$	-0.135901	0.06410	-2.12	0.036*
$\Delta L_T XRP(t - 12)$	0.128357	0.05803	2.21	0.029*
$\sigma(0)$	0.247907	0.03175		
$\sigma(1)$	0.0756751	0.005839		
$p_{\{0 0\}}$	0.963115	0.03187		
$p_{\{0 1\}}$	0.989293	0.01128		
Log-olabilirlik: 93.8576122			AIC: -1.3202841	
SC: -1.047354			Normallik Testi $X^2(2)= 3.7736[0.1516]$	
ARCH 1-1 test: $F(1,110)= 1.3701[0.2443]$			Portmanteau Test $X^2(123)= 136.74[0.1874]$	

Ripple fiyatı için en uygun olduğu belirlenen dinamik MSH(2)-X modelinin seçilmesinde kullanılan tüm test sonuçları verilmiştir. H, rejimlerde standart sapmanın farklılığını göstermektedir. Bu nedenle rejimler yüksek ve düşük oynaklık rejimleri olarak isimlendirilmiştir. Rejim(0), yüksek oynaklık rejimini; Rejim(1), düşük oynaklık rejimini ifade etmektedir. Modeldeki farklılık gibi, oynaklık rejimleride diğer paralardan farklı çıkmıştır. Bu para birimim için Rejim(0) yüksek oynaklık rejimini, Rejim(1) düşük oynaklık rejimini ifade etmektedir.

Tablo 26: Geçiş Olasılıkları Gösterimi – Ripple Fiyatları İçin


Geçiş Olasılıkları	Rejim 0,t	Rejim 1,t
Rejim 0,t+1	0.96	0.01
Rejim 1,t+1	0.04	0.99

Tablo 26’da rejimler arası geçiş olasılıkları matrisi verilmiştir. Tabloda, Rejim(0) da yani yüksek oynaklık rejiminde iken aynı rejimde kalma olasılığının %96, Rejim(1)’e yani düşük oynaklık rejimi’ne geçme olasılığının %4 olduğu görülmektedir. Rejim(1)’de iken aynı rejimde kalma olasılığı %99 iken Rejim(0)’a geçme olasılığı %1’dir. Bu da Ripple fiyat serisinin her iki rejimde de kalma olasılıklarının çok yüksek olduğunu göstermektedir.

Tablo 27: Rejimde Geçirilen Süre Gösterimi – Ripple Fiyatları İçin

Rejimler	Gözlem	Süre	Yüzde
Rejim 0,t	34	34	%27.42
Rejim 1,t	90	45	%72.58

Tablo 27’de Rejim(0)’da ortalama kalma süresi 34 hafta iken Rejim(1)’de ortalama kalma süresinin 45 hafta olduğu görülmektedir. Bu da bulunduğu rejimde kalma sürelerinin benzer ve uzun olduğunu göstermektedir.



Şekil 24: Markov Geçiş Rejim Olasılıkları – MSH(2)-X

Şekil 24’te Ripple fiyat değişkeni için tahmin edilmiş olan MSH(2)-X modeline ait düzgünleştirilmiş rejim olasılıkları görülmektedir. Grafiklerde Ripple fiyatı için analiz döneminde yüksek oynaklık rejimi (Rejim (0))’ın evresinin 1, düşük oynaklık rejiminin (Rejim (1)) evre sayısının 2 ve sürelerinin daha uzun görülmektedir.

Tablo 28’de Ethereum kripto para birimine (ETH) ait Google arama haciminin (T_ETH) bağımlı değişken olduğu MS(2)-AR(1)-X modelinin sonuçları verilmiştir. Bu model de yukarıda

bahsedildiği üzere, tüm varsayımları sağlayan, en küçük AIC, en yüksek LR değerine sahip modeldir.

Tablo 28: Ethereum Markov Rejim Değişim Modeli Tahmin Sonuçları: MSH(2)-AR(1)-X

Değişkenler (Bağımlı: ΔLT_{ETH})	Katsayı	Standart Hata	t-istatistik	Olasılık
AR-1(0)	-0.289104	0.08079	-3.58	0.001*
$\Delta LE_{TH}(t - 6)$	-0.245938	0.1257	-1.96	0.053
$\Delta LE_{TH}(t - 9)$	0.330866	0.1243	2.66	0.009*
$\sigma(0)$	0.403212	0.03539		
$\sigma(1)$	0.172887	0.01833		
$p_{\{0 0\}}$	0.988274	0.01738		
$p_{\{0 1\}}$	0.984932	0.02319		
Log-olabilirlik: -26.5461078		AIC: 0.5454652		
SC: 0.7055082		Normallik Testi $X^2(2) = 2.1551[0.3404]$		
ARCH 1-2 test: $F(2,112) = 0.64769[0.5252]$		Portmanteau Test $X^2(122) = 95.091[0.9660]$		

Ethereum Google arama hacmi için için en uygun olduğu belirlenen MSH(2)-AR(1)-X modelinin temel varsayımları sağladığı görülmüştür. Tahmin edilen modelde değişen varyansı gösteren H kısaltması, rejimler arasında standart sapmanın değiştiğini göstermektedir.

Tablo 29: Geçiş Olasılıkları Gösterimi - Ethereum


Geçiş Olasılıkları	0	1
Rejim 0,t+1	0.99	0.01
Rejim 1,t+1	0.01	0.99

Tablo 29'da rejimler arası geçiş olasılıkları matrisi verilmiştir. Tabloda, Rejim(0) da iken aynı rejimde kalma olasılığının %99, Rejim(1)'e geçme olasılığının %1 olduğu görülmektedir. Rejim(1)'de iken aynı rejimde kalma olasılığı %98 iken Rejim(0)'a geçme olasılığı %2'dir. Bu da arama hacmi serisinin Rejim(0) da iken aynı rejimde kalma olasılığı ile Rejim(1)'de iken aynı rejimde kalma olasılığının çok yüksek olduğunu göstermektedir.

Tablo 30: Rejimde Geçirilen Süre Gösterimi- Ethereum

Rejimler	Gözlem	Süre	Yüzde
Rejim 0,t	74	74	%60.16
Rejim 1,t	49	49	%39.84

Tablo 30'da Rejim(0)'da ortalama kalma süresinin 74 hafta, Rejim(1)'de ortalama kalma süresinin 49 hafta olduğu görülmektedir. Bu da her iki rejimde de kalma süresinin çok yüksek olduğunu ortaya koymaktadır.



Şekil 25: Markov Geçiş Rejim Olasılıkları – MSH(2)-AR(1)-X

Şekil 25’de Ethereum Google arama hacmi için tahmin edilmiş olan MSH(2)-AR(1)-X modeline ait düzgünleştirilmiş rejim olasılıkları görülmektedir. Grafiklerde analiz döneminde Rejim (0)’ın ve Rejim (1)’in evre sayısının aynı ve 1 olduğu görülmektedir.

Tablo 31’de Ethereum kripto para fiyatının (ETH) bağımlı değişken olduğu MS(2)-ARMA(1,1)-X modelinin sonuçları verilmiştir. Bu model de yukarıda bahsedildiği üzere, tüm varsayımları sağlayan, en küçük AIC, en yüksek LR değerine sahip modeldir.

Tablo 31: Ethereum Markov Rejim Değişim Modeli Tahmin Sonuçları: MSIH(2)-ARMA(1,1)-X

Değişkenler (Bağımlı: ΔLE_{TH})	Katsayı	Standart Hata	t-istatistik	Olasılık
AR-1(0)	-0.717230	0.1468	-4.89	0.000*
MA-1(0)	0.513056	0.1784	2.88	0.005*
$\Delta LT_{ETH}(t - 4)$	0.110219	0.02635	4.18	0.000*
$\Delta LT_{ETH}(t - 5)$	0.104832	0.03339	3.14	0.002*
$\Delta LT_{ETH}(t - 7)$	0.0484974	0.02280	2.13	0.036*
Sabit(0)	0.0170737	0.006210	2.75	0.007*
Sabit(1)	-0.00103007	0.02242	-0.0459	0.963
$\sigma(0)$	0.0712029	0.009569		
$\sigma(1)$	0.219386	0.03132		
$p_{\{0 0\}}$	0.912604	0.05271		
$p_{\{0 1\}}$	0.802248	0.1145		
Log-olabilirlik: 90.5089205		AIC: -1.2928279		
SC: -1.0413318		Normallik Testi $X^2(2) = 3.6134[0.1642]$		
ARCH 1-2 test: $F(2,108) = 0.63588[0.5314]$		Portmanteau Test $X^2(122) = 127.76[0.3425]$		

Ethereum fiyatı için en iyi model olarak belirlenen MSIH(2)-ARMA(1,1)-X modelinin seçilmesinde kullanılan tüm test sonuçları verilmiştir. H, rejimlerde standart sapmanın farklılığını göstermektedir. Bu nedenle rejimler yüksek ve düşük oynaklık rejimleri olarak isimlendirilmiştir. Rejim(0), düşük oynaklık rejimini; Rejim(1), yüksek oynaklık rejimini ifade etmektedir.

Tablo 32: Geçiş Olasılıkları Gösterimi- Ethereum


Geçiş Olasılıkları	Rejim 0,t	Rejim 1,t
Rejim 0,t+1	0.91	0.20
Rejim 1,t+1	0.09	0.80

Tablo 32’de rejimler arası geçiş olasılıkları matrisi verilmiştir. Tablo incelendiğinde, Rejim(0) da yani düşük oynaklık rejiminde iken aynı rejimde kalma olasılığı %91, Rejim(1)’e yani yüksek oynaklık rejimine geçme olasılığı %9’dur. Rejim(1)’de yani yüksek oynaklık rejiminde iken aynı rejimde kalma olasılığı %80 iken Rejim(0)’a yani düşük oynaklık rejimine geçme olasılığı %20’dir. Bu da serinin düşük oynaklık rejiminde bulunduğu anda aynı rejimde kalıcılığının yüksek oynaklık rejimine göre daha yüksek olduğunu ve ani geçiş özelliğinin azaldığını göstermektedir

Tablo 33: Rejimde Geçirilen Süre Gösterimi - Ethereum

Rejimler	Gözlem	Süre	Yüzde
Rejim 0,t	90	15	%73.17
Rejim 1,t	33	5.5	%26.83

Tablo 33’te düşük oynaklık rejiminde (Rejim(0)) ortalama kalma süresi yaklaşık 15 hafta iken yüksek oynaklık rejiminde (Rejim(1)) ortalama kalma süresi yaklaşık 6 hafta olduğu görülmektedir.



Şekil 26: Markov Geçiş Rejim Olasılıkları – MSIH(2)-ARMA(1,1)-X

Şekil 26’da Ethereum fiyatı için tahmin edilmiş olan MSIH(2)-ARMA(1,1)-X modeline ait düzgünleştirilmiş rejim olasılıkları görülmektedir. Grafiklerde Ethereum fiyatı için analiz döneminde düşük oynaklık rejimi (Rejim (0))’ın evrelerin daha uzun süreli ve daha sık gözlenirken yüksek oynaklık rejiminin (Rejim (1)) evre sayısının ve sürelerinin daha az olduğu görülmektedir.

Yukarıda, analize alınan kripto para fiyat ve Google arama hacimleri için cari dönemdeki rejimlerin belirlenmesi, rejim olasılıklarının ve rejimde kalma sürelerinin belirlenebilmesi için Markov Değişim veya Markov Rejim Değişimi modelleri tahmin edilmiştir. Bu bilgiler, yatırımcılar açısından önem arz etmektedir. İlgili kripto paraların sürekli olarak rejim değişimlerinin takip edilmesi halinde yatırımcıların portföy kararlarını şekillendirmesi mümkün görünmektedir. Aynı zamanda kripto paralarla ilgili alanyazında sıklıkla ifade edilen yüksek oynaklık, spekülasyon vb. sorunlara karşı Markov rejim değişim modellerinden elde edilen bulgular doğrultusunda, bugünün rejiminin bilinmesinin sonraki dönemlerin tahmin edilebilir

olduğu söylenebilir. Google arama hacimleri için tahmin edilen modeller için elde edilen bulgular rejim değişiminin dört para içinde geçerli olduğunu, ancak Litecoin ve Bitcoin arama hacimlerinde rejimler arasında geçiş olasılıklarının, Ripple ve Ethereum'a göre daha yavaş olduğunu göstermiştir. Ripple ve Ethereum'da hangi rejim olursa olsun, bir rejimde kalma olasılıklarının %98-99 olduğu belirlenmiştir. Kripto para fiyatları için oluşturulan modellerin tahmini sonrasında Ripple'ın diğerlerinden farklı bir seyir izlediği görülmüştür. Bunun yanı sıra Litecoin, Bitcoin ve Ethereum fiyatları için düşük oynaklık rejiminde olmaları durumunda aynı rejimde kalma olasılıklarının yüksek oynaklık durumunda göre daha yüksek olduğu belirlenmiştir. Ripple'ın ise hem yüksek hem düşük oynaklık rejimlerinde aynı rejimde kalma olasılıkları çok yüksektir. Bu bilgilerin, kripto paraların yalnızca fiyatları değil, aranma sıklıklarının dolayısıyla da popüleritesinin takip edilmesi halinde bir sonraki dönemin rejiminin öngörülmesine yardımcı olacağı ifade edilebilir. Genel olarak değerlendirildiğine, rejimlerin cari dönemde kalıcılık eğiliminin olduğu ve çok sık değişim yaşanmadığı belirlenmiştir. Ayrıca ortalama içeren modellerde geçiş daha keskin, sabit içeren modellerde ise geçişin daha yumuşak olacağı bilgisinden (Bildirici vd., 2010: 76) yararlanıldığında, tahmin edilen modellerin, Ripple hariç, sabit içermesi nedeni ile geçişlerin daha yumuşak olacağı söylenebilir.

Modeller ile ilgili bilgi verildikten sonra, dijital para hakkında öngörülerde bulunan Friedman'a atıf yapmak uygun olacaktır. 1999 yılında Nobel Ödülü alan Milton Friedman, dijital teknolojiyle birlikte gelen gücün hükümetlerin rolünü azaltacağını ifade etmiştir. Bu bağlamda dijital para ile ilgili öngörülerde bulunan Friedman, dünya ekonomisini etkileyecek potansiyel güçten bahsetmiştir (Andersson ve Wegdell, 2014:8). Ateşin keşfedilmesiyle başlayan ve Endüstri 4.0'ın konuşulduğu günümüzde, değişim süreçlerine neden olan icatlar ve keşifler arasında blokzincir teknolojisi de aday olarak gösterilmektedir. Küresel finans sisteminde yer alan UniCredit, HSBC, BBVA, ING gibi büyük ölçekli bankaların blokzincir teknolojisi üzerinde çalışıyor olmaları da bunu örneklemektedir. Finansal hizmetler sektöründe blokzincir ekosisteminin oluşturulmasına yönelik çalışmalar bu kurumlarca yürütülmektedir (Yavuz, 2019:26-27). Teknolojinin değişmesi ve kullanım yaygınlığının (penetrasyon) artmasıyla birlikte paranın dijitalleşme süreci farklı boyutlar kazanmaktadır. Günlük ve iş hayatında dijitalleşmenin getirdiği dönüşümün etkileri görülmektedir. Özellikle bu dönüşümün teknolojik altyapısında yer alan büyük veri sürecin önemli bir bileşeni niteliğindedir. Dolayısıyla bu dönüşümün ve blokzincir teknolojisinin anlaşılmasında ve belirlenmesinde verinin ve veritabanının ne olduğunun iyi bilinmesi ve kavramsal olarak aydınlatılması gerekmektedir (Beck, 2018:55). Endüstri 4.0 ile birlikte üretim süreçlerinde yer alan tüm birimler arası iletişimin sağlanmasında büyük verilere gerçek zamanlı

erişim hedeflenmektedir. Böylece beklentileri en üst düzeyde sağlayacak çıktılar elde edilebilecektir.

Teknolojinin zaman içerisinde ilerlemesiyle birlikte büyük veri niteliğindeki veri kümelerinin de artacağı varsayılmaktadır (McKinsey, 2011:1). Büyük verinin kaldıraç olarak kullanıldığı uygulamalarda ve sektörlerde daha hızlı ve iyi karar alma olanağı sağlanacaktır. Doğru analiz teknikleriyle yorumlandığında stratejik karar almada ve risk yönetiminde inovasyon yapılmasına imkân sağlanabilecektir (EBSO, 2018:19). Şifrelenmiş dijital para bilimi olarak kabul edilen kripto para birimleri, iyi yapılandırılmış ağ yapısı ve kapsamlı kayıtları ile büyük verinin *hacim, çeşitlilik, hız, doğruluk ve değer (5V)* özelliklerini karşılamaktadır. Bu nedenle kripto para piyasası büyük veri analitiği için iyi bir kaynak görevi görmekle birlikte, kripto para birimlerinin devrimi ve gelişiminde de anahtarları elinde tutmaktadır. Hızla büyüyen bir endüstri olarak kripto para piyasası, ayrılmak bir şekilde büyük veriye sayısız yolla bağlıdır. Kripto para birimi ağının doğası önemli ölçüde büyük veri analitiğiyle belirlenmektedir. Bu durum en başta, merkez olmayan sistemde her katılımcının tüm işlem kayıtlarına erişmesiyle ağın yoğun bir veri ortamı yaratması sonucu büyük veri analitiğinin uygulanmasında ideal kaynak oluşturmasından ileri gelmektedir. Teknoloji ve dijitalleşme çağını kucaklayan araştırmacılar, devletler, şirketler gibi katılımcılar için büyük veri, kripto para piyasasının kaynağını daha da güçlendirmektedir. Büyük veri ile kripto para birimleri arasındaki doğal etkileşimin daha iyi anlaşılması için çalışılması gelecekteki potansiyellerin keşfedilmesini sağlamaktadır. Dijital ve merkezi olmayan özellikleri nedeniyle savunmasız gözüken kripto para piyasasında büyük veri araştırmaları yoğunlukla gizlilik ve güvenlik perspektifinden ele alınmaktadır. Ancak piyasanın doğru değerlendirilmesi için büyük veri ve analitiğinin kripto para birimi endüstrisine getirebileceği değerleri araştırmakta çok önemli bir noktadır (Hassani vd., 2018:7).

BÖLÜM 2

BÜYÜK VERİ VE KRİPTO PARA

Tezin ikinci bölümünde büyük veri, büyük veri ve kripto para piyasası ilişkisi ile büyük kripto ekonomisi üzerinde durulmaktadır.


2.1. Büyük Veri

Veri, “*Tek başına anlam ifade etmeyen veya kullanılmayan, bununla birlikte enformasyona ve bilgiye temel oluşturan ilişkilendirilmeye, gruplandırılmaya, yorumlanmaya, anlamlandırılmaya ve analiz edilmeye gereksinim duyulan ham bilgi*” olarak tanımlanmaktadır (Yılmaz, 2009:98). Büyük veri ise tek bir sunucuya ve veri tabanına sığmayacak kadar büyük, yapılandırılmamış ve/veya statik bir veri ambarına sığamayacak kadar akıcı veri anlamı taşımaktadır (Davenport, 2014:2). Ancak büyük veri tanımı hakkında bugüne kadar evrensel olarak kabul görmüş herhangi bir gelişme mevcut değildir (Finlay, 2014:14).

Tarihsel olarak bakıldığında büyük veri teriminin oldukça eksik ve belirsiz tanımlandığı görülmektedir. Büyük veriyi öz tanımıyla basit şekilde işlenmeyen veya işlenemeyen veri olarak ifade etmek mümkündür (Fisher vd., 2012: 53). En genel tanımı ise; “*Geleneksel yöntemlerle işlenemeyen, kurumsal veya toplumsal problem çözmeye yönelik, çeşitli kaynaklara ve yapılara sahip büyük ölçekli verilerdir*” (Komioka ve Tapanainen, 2014:2). Alanyazında kesin tanımı olmayan büyük verinin 2000’li yıllar sonrasında yaşanan bilgi patlaması sonucunda geleneksel analiz ve depolama yöntemlerinin yetersiz kalmasına neden olduğu görülmektedir. Büyük veri kavramı olarak ilk kez Michale Cox ve David Ellsworth tarafından 1997 yılında 8. IEEE Görüntüleme Konferansı’nda (Proceedings of the 8th Conference on Visualization) ve “Application Controlled Demand Paging for Out-of-core Visualization” isimli makalede yer almıştır. Makalede “Büyük Veri Problemi” sorunu ifade edilerek, veri setlerinin çok büyük olması nedeniyle bilgisayar sistemi belleğini ve diskleri doldurduğu üzerinde durulmuştur (Cox ve Ellsworth, 1997:235). Sonrasında ise Francis X. Diebold tarafından yapılan “Big Data Dynamic Factor Models for Macroeconomic Measurement and Forecasting” isimli çalışmada büyük verinin hem fen hem de sosyal bilimlerde birçok bilim alanında karşılaşılmak zorunda kalınan ve bu nedenle de faydalanılması gereken bir “fenomen” olduğu ifade edilmiştir (Diebold, 2013:115).

IBM (2015) araştırma raporuna bakıldığında, dünyadaki verilerin %90’ının son iki yıl içerisinde üretildiği belirtilmiştir. Kısacası, son yirmi yıl içerisinde dünya genelinde yalnızca 800.000

petabayt veri üretilebildiği ve büyük veriler sonucunda 2020 yılından sonra dünya genelinde 35 zettabayt veri üretilmesi beklenmektedir (IBM, 2015:5).



Şekil 27: Küresel Veri Merkezine Ait Yıllık Büyüklük

IDC'nin "Data Age 2025" isimli araştırmasında ise Şekil 27'de görüldüğü üzere, veri boyutunun 2025 yılında 175 zettabayta çıkacağı öngörülmektedir. Kesin bir terim olmamakla birlikte, "büyük" kelimesinin rölatif olarak ele alınması gerekmektedir. "Büyük"ün ne kadar büyük ve "küçük"ün ne kadar küçük olduğu sorusunun zaman, mekân ve duruma göre değiştiği göz ardı edilmemelidir (Smith, 2013:17). Bu nedenle büyük veriyi yalnızca hacim açısından ele almak yeterli değildir.

2.1.1. Büyük Veri Bileşenleri

Büyük veri geçmiş veri kaynaklarına kıyasla hız (velocity), veri büyüklüğü (volume) ve çeşitlilik (variety) arttırdığından "3V" olarak ele alınmaktadır (Franks, 2012:5; Kuiler, 2014:311; Golov ve Rönnbäck, 2017:86). Teknoloji ürünü geliştirme, alım ve kullanım süreçlerinde karar verme aşamasında önemli rol oynayan değerlendirme kuruluşu Gartner ise 2012 yılında yaptığı araştırma raporunda ise büyük veriyi "5V" olarak tanımlamıştır (Beyer ve Laney, 2012: 3). Bu tanımlama ile "3V" olarak tanımlanan özelliklere ilave olarak doğrulama (veracity) ve değer yaratma (value) da eklenmiştir.

Hız; sürekli hareket halinde olan verinin akışının analizi veri bilimciler açısından önemli bir konudur. Üretilme hızı çok yüksek olan büyük verinin hızı her geçen gün daha da artış göstermektedir. Örneğin, Twitter üzerinden saniyede 5000 ve günde 500 milyon içerik paylaşılabilir. Bu nedenle verinin işlenmesi ve analiz edilmesinin büyük veri üretimiyle aynı hızda olması gerekmektedir (Cyganeck vd., 2016:499).

Çeşitlilik (Variety); üretilen ve kullanılan verinin çeşitliliği, formatı, içerdiği değişkenler gibi pek çok durumu kapsamaktadır. Örneğin, Facebook gönderilerinde ses, yazı, resim ve video aynı anda bulunabilmektedir (Kitchin, 2014:95). Veri türleri arasında standart bir kural bulunmayan büyük veri, herhangi bir tür ve formatta üretilebilmektedir. Yapısal, yarı yapısal ve yapısal olmayan

olmak üzere üç farklı türde meydana gelmektedir (Gahi, 2016:953). Veri kümesindeki bu çeşitlilik yapısal heterojenliği ifade etmektedir (Gandomi ve Haider, 2015:143). Büyük veri analizi ile geleneksel yöntemler arasındaki en temel fark bu veri çeşitliliğinden kaynaklanmaktadır. Günümüzde büyük verinin çoğunluğu yapısal olmayan türde olup Twitter, Facebook vb. kaynaklardan beslenmektedir. Kolaylıkla depolanabilen, işlenebilen ve iletilebilen kesin veri çeşidi yapılandırılmış olarak açıklanmaktadır (Hurwitz vd., 2013:17). Bir banka sisteminde yer alan müşterilere ait hesap numaraları, isimleri, cinsiyet ve erişim bilgilerini bu veri çeşidi için örneklendirmek mümkündür. Aynı zamanda yapılandırılmış veri geleneksel sistemler ve istatistiksel yöntemler ile incelenebilmektedir (Gürsakar, 2014:26). Yarı yapılandırılmış veri ise yapılandırılmış ve yapılandırılmamış veriler arasında kalanlardan meydana gelmektedir. Bu verilerde bir yapıya sahip olmakla birlikte formal yapılara uygun durumda değildir. E-mailleri bu veri tipine örnek olarak göstermek mümkündür (Gürsakar, 2014:55). Yapılandırılmamış veri ise dağınık, ilişkilendirilemeyen ve geleneksel veri depolama ve yönetim sistemleri aracılığıyla işlenmeye uygun olmayan verilerdir (Simon, 2013:55). Sosyal ağlardaki ileteler, bloglar, forumlar, videolar gibi farklı formlardaki verileri örnek göstermek mümkündür.

Hacim; üretilen veri büyüklüğünü ifade etmektedir (Hoy, 2014:322). Geleneksel veri analizi teknikleriyle işlenemeyen büyük veri, gün geçtikçe çok daha yüksek hacimlere ulaşmaktadır. Teknolojinin sürekli gelişimiyle birlikte üretilen cihazlar sebebiyle üretilen ve depolanan dolayısıyla iletilen verinin miktarında üstel bir artış meydana gelmektedir (Gantz ve Reinsel, 2011:10).

Değer; orijinal formda alınan veri için hacmine kıyasla ilk etapta düşüktür. Ancak bu büyük verinin analiz edilmesi sonucu yüksek bir değer elde edilebilmektedir (Gandomi ve Haider, 2015:139). Büyük verinin değeri; veri parçaları arasındaki bağlantının kurulmasıyla ulaşılabilen örüntüler sonucu elde edilmektedir (Boyd ve Crawford, 2011:2). Karar verme süreçlerinde büyük verinin anlık olarak etkide bulunması ve hemen ulaşılabılır olması doğru karar verilmesinde değer bileşeni açısından oldukça önemlidir (Narasimhan ve Bhuvaneshwari, 2014:351).

Doğrulama; yüksek çeşitlilik ve hacime sahip olan büyük verinin kalitesinin ve güvenilirliğinin sağlanmasını zorlaştırmaktadır (Chandra, Ray ve Goswami, 2017:49). Büyük verideki bu durum istatistiksel hata ve yanlış yorumlamaya neden olabileceğinden verinin gerçekliği önemlidir. Bu nedenle elde edilen verilerin onaylanması, gürültü seviyesinin (rastsal hata) indirgenmesi, ilişkilerin ortaya çıkartılması ve yanlış seviyesinin belirlenmesi gerekmektedir (Goes, 2014:v). Twitter örneği üzerinden incelenecek olursa; zaman akışı (timeline) içinde herhangi bir konu üzerine açılmış başlık etiketi (hashtag) altında yer alan içeriklerin belirlenen konuyla ilişkili olup olmadığının belirlenmesi güçtür. Çünkü elde edilecek büyük verinin kalitesi ve doğruluğu hacim

ve çeşitlilikten etkilenmektedir. Veri hacmi artış gösterdikçe verinin kalitesi ve güvenilirliği de aynı oranda düşüş göstermektedir.

Büyük veri için “Büyük resmi görmek” deyimini kullanmak yerinde olacaktır. Eksiksiz, kapsamlı ve objektif bir bakış açısıyla gerçekleştirilecek nesnel bir değerlendirme, araştırılması hedeflenen bir olayı ya da durumu anlamlandırmayı sağlamaktadır (Big Picture, 2021). Bu yaklaşım tümdengelim yöntemiyle örtüştüğünden büyük verinin analitiğiyle de benzer şekilde ilerlemektedir.


2.1.2. Büyük Veri Analitiği

Büyük veriden anlam çıkarmaya verilen isim olan büyük veri analitiği, büyük veri ve taşıdığı boyutlardan ziyade verinin elde edilişi, teknolojik altyapı, çıkarım yapılmasını sağlayan yazılımlar ve gerçekleştirilen analizi sağlayan araçları ifade etmektedir (Lamba vd., 2015:284). Alanyazında çeşitli tanımları bulunan büyük veri analitiği, kısaca büyük verinin üzerine uygulanan ileri analiz tekniklerinin ifade edilmesinde kullanılmaktadır (Russom, 2011:8). Sürekli artış ve değişim gösteren büyük hacimli yapılandırılmış, yarı yapılandırılmış ve yapılandırılmamış verilerin bütün olarak analiz edilmesini olanaklı kılmaktadır. Bu nedenle geleneksel veri analizi yöntemlerinin büyük veriyi işlemekte yetersiz kalmaktadır. Böylece büyük veriden değerli bilgilerin elde edilmesi olanaklı hale gelmekte ve karar verme aşamasında yol gösterici olmaktadır (Gahi vd., 2016: 952; Gandomi ve Haider, 2015:140). “*Büyük verinin boyut ve çeşitliliğinin artması sonucu karşılaşılabilecek sorunlar nelerdir?*”, “*verinin tamamının analiz edilmesi gerekli midir?*”, “*hangi unsurların büyük veri için gerekli olduğuna nasıl karar verilmelidir?*”, “*en iyi bilgiye ulaşmak için büyük veri nasıl kullanılmalıdır?*” sorularının cevapları büyük veri analitiği ile aranmaktadır. Fakat aynı zamanda bu sorular, büyük verinin analiz edilmesinde de büyük zorlukları beraberinde getirmektedir. Büyük veri yapısal, yarı yapısal ve yapısal olmayan veri türlerinden meydana geldiği için veri analitiği kısmında da ileri istatistiksel tekniklere gereksinim duyulmaktadır. Analiz aşamasında büyük verinin tüm unsurlarının birleştirilmesi veya büyük verinin hangi unsurunun elde edilmesi hedeflenen sonuçlarla ilişkili olduğunun belirlenmesi gerekmektedir (Katal vd., 2013: 406-407). Bu nedenle veri analitiğinin odak noktası “*veriyle nasıl fayda yaratılabileceği*” olmalıdır.

Teknolojik araçların gelişmesi sonucu büyük veri analitiğinin hesaplama gücü en üst seviyeye çıkmıştır. Bu araçların gelişmesi ile farklı türlerde içerik barındıran farklı hacimdeki verileri işlemek amacı ile geliştirilmiş analitik ve paralel tekniklerin bilinmesi zorunlu hale gelmiştir. Günümüzdeki teknolojik gelişim ve insanların teknolojiye olan bağımlılığının sürekli artış göstermesi sonucu, günlük yaşamda bile ayrıntılı dijital kayıtlar söz konusu olmaktadır. Örneğin,

Twitter paylaşımları, çevrimiçi alışveriş alışkanlıkları, web sitelerinde gerçekleştirilen aramalar, fotoğraf ve videolar gibi pek çok çeşit dijital kayıt mevcuttur. Özellikle insan davranışlarının incelendiği bilim dalları için oluşan bu veri ciddi bir kaynak oluşturmaktadır. Bu noktada devreye giren büyük veri analitiği, küçük değere sahip olan verilerin uygun metotlar aracılığıyla yüksek değere sahip verilere dönüşüm sürecini sağlamaktadır. Buradan hareketle büyük veri analitiğinin “*dijital hayatımızın küçük kesitlerinden büyük resmin görülmesi*” için olanak sağladığını söylemek mümkündür (Fisher vd., 2012: 50). Bütün bu verinin analiz edilmesinin amacı, incelenmediği durumda görünmez olabilecek bağlantıları ve ilişkileri keşfederek veri yaratma sürecinde katkısı olan kullanıcılar hakkında değerli bilgilere ulaşmaktır. Facebook, Amazon, Google, Twitter, Yahoo gibi şirketler tarafından geliştirilen teknolojilerle oldukça büyük boyutlara ulaşan ve özellikle sosyal medyada yer alan verinin temizlenmesi, düzenlenmesi gibi veri madenciliği süreçlerinde kullanılması için büyük veri analitiğinden destek alınmaktadır. Konvansiyonel araçların analizlerin yapılmasında yeterli özellikleri taşınamaması sonucu ihtiyaçtan doğan büyük veri analitiği; çok disiplinli gelişmiş bilgi ve iletişim teknolojisi, yöneylem araştırması, matematik, makine öğrenmesi ve karar bilimlerinden faydalanan bir disiplinlerarası bilim ve teknoloji özelliği taşımaktadır (Fan vd., 2015: 28).

Büyük veri analitiği, büyük verideki enformasyonun yanı sıra bilgiyi, önseziyi keşfetmek, görselleştirmek ve sorgulamak için verinin toplanması, organize ve analiz edilmesi sürecidir. Karakteristik özellikleri nedeniyle gelişime, değişime ve yeniliklere açık olan büyük veri, büyük veri analitiğiyle birlikte “bilgi çöplüğünden hazine çıkarılması” niteliği taşımaktadır. Bu işlemi kazanca dönüştürmek isteyen kurum ve kuruluşlar açısından büyük veri “veri=para” denklemine dönüşerek çağın petrolü olarak nitelendirilmektedir (Ketizmen ve Kart, 2019: 66-68). Kartopu etkisiyle çoğalan bilginin yeni metot ve süreçlerle işlenerek karmaşık yapıların anlamlandırılması sürecinde büyük veri analitiği önemlidir (Gülle, 2013: 1-2). Alanyazında büyük veri aracılığıyla karar verme süreci “büyük veri zinciri” olarak adlandırılmakta olup dört safhadan meydana gelmektedir. Bu zincirin veri toplama, hazırlama, analiz ve karar verme aşamaları verilmiştir.



Şekil 28: Büyük Veri Analitiği Zinciri

Kaynak: Jannsen, M., Voort, H., ve Wahyudi, A. (2017). Factors Influencing Big Data Decision-Making Quality. Journal of Business Research, 70, 338-345.

Chen, Mao ve Lui (2014) tarafından büyük veri analitiği zincirinde veri, hammadde olarak düşünülmektedir. İlk iki aşama veri çıkarma sürecini ifade ederken veri analizi de üretim sürecini temsil etmektedir. Rajpurohit (2013) tarafından büyük veri analitiği süreci yinelemeli ve etkileşimsel olarak tanımlanarak Şekil 28'deki süreç altı temel süreçle detaylandırılmıştır (Rajpurohit, 2013: 29-31).

1. Hedef Belirleme: Amaç ve hedefler kapsamında kilit önceliklerin belirlenmesi sürecidir.
2. Veri Seçimi: Hedeflerin belirlenmesinin ardından analiz aşamasına geçilmeden uygun veri setlerinin seçilmesi sürecidir. Analiz sürecinde meydana gelebilecek olası problemlerin minimuma indirilmesi için hedefe en uygun verilerin seçilmesi optimizasyonu sağlamak açısından önemlidir.
3. Veri Temizleme ve Dönüştürme: Verilerin güvenilirliğinin artırılması için eksik değer işleme, aykırı değerleri belirleme gibi veriyi temizleme süreçleridir. Büyük verinin farklı kaynaklardan elde edilmesi ve çeşitliliği nedeniyle kolayca işlenebilecek ortak formata getirilmesi gerekmektedir.
4. Veri Madenciliği: Büyük verinin davranışının incelenmesi için desen çıkarılması sürecidir. Hedeflere bağlı olarak, açık olmayan ilişkilerin sınıflandırılması, kümelenmesi, regresyon gibi uygun veri madenciliği algoritmalarının uygulanmasıdır.
5. Değerlendirme ve Yorumlama: İşlenmesi tamamlanan verilerin belirlenen hedefler doğrultusunda değerlendirilmesi ve yorumlanması sürecidir.
6. Görselleştirme ve Geribildirim: Elde edilen analitik çıktıların sezgisel olarak temsil edilmesi için gerekli teknolojilerin kullanılması sonucu kararların potansiyel etkisini tahmine dayalı olarak analitik şekilde anlaşılması sürecidir.

Veri kalitesinin artırılmasında veri hazırlama aktivitesinin önemi büyüktür. Ancak bu işlem zaman alıcı bir süreç olduğundan bazı yaklaşımlar sürecin kısaltasında yardımcı olabilmektedir. Çözümlerden bir tanesi “Veri Gölü” olarak tanımlanan yaklaşımdır. Bu yaklaşım ile tüm veri için tek ve geniş bir bakış açısı sunulmaktadır. Veri analizinde problem doğrultusunda doğru analiz yönteminin belirlenmesi gerekmektedir (Hamilton, 2015: 27). Günümüzde analiz çabalarının çoğu tahmine dayalı analitik yöntemlerden meydana gelmektedir. Bu noktada açıklayıcı, tahmine dayalı ve kuralcı olarak üç farklı analitik türü arasında ayrımın yapılması gerekmektedir (Emrouznejad ve Charles, 2018: 51).

Açıklayıcı analizler; “Ne oldu?” sorunun yanıtlanmasına yardımcı olmaktadır. Bu aşamada geçmişin özetlenmesi ve açıklanması yardımcı olmaktadır. Bu çıkarımlarla birlikte gelecekteki

sonuçların nasıl etkilenebileceğinin anlaşılması olanaklı kılınmaktadır. Tanımlayıcı istatistikleri bu türe örnek olarak verilebilir.

Tahmine dayalı analitikler; geçmiş verilerin istatistiksel modeller ve regresyon, makine öğrenimi gibi nicel teknikler kullanılarak incelenmesi sonucu geleceğin tahmin edilmesi sürecidir.

Normatif analitikler; gelecekteki kararların etkisinin ölçülmesi sonucu karar almadan önce olası sonuçların incelenmesi sürecidir. Optimizasyon ve simülasyon algoritmaları bu sürece örnek olarak verilir.

Büyük verinin arkasındaki gerçeğin kavranması, en doğru kararların verilmesi için veri içerisindeki gizli kalıp ve ilişkilerin keşfedilmesi, rasyonel karar alma süreçlerinin tasarlanması için önem arz etmektedir. Bu bilgi keşif süreci; ham veriden elde edildiğinden, verinin şekil ve etki alanı olarak farklı uygulamalar ve alanlardan beslenmektedir. Aynı zamanda birbirinden ayrılan pek çok alana da etki etme ve yön verme özelliğine sahiptir.

Tablo 34: Büyük Veri Kaynak, Tür ve Etkilediği Sektörler

Veri Biçimi	Veri Kaynağı	Etkilenen Sektör
Yüksek Hacim	Çevrimiçi	Finans
Yapılandırılmamış	Video	Sağlık
Sürekli Akış	Algılayıcı	İmalat
Çoklu Biçim	Genom	Ulaşım

Kaynak: Davenport, T. (2018), Big Data @Work. M. Çavdar (çev..) İstanbul: Türk Havayolları Yayınları. (Orijinal baskı tarihi 2014).

Büyük verinin etki alanı ve şekli, ihtiyaçlar doğrultusunda şekil değiştirmektedir. Özellikle günümüz teknolojisi sonucu sosyal medya kullanımı benzeri görülmeyen miktarda veri üretmektedir. Sosyal medyadan elde edilen verinin üretilme hızı ve boyutuna bağlı olarak büyük veri kabul edilmekte ve bu veri geniş, gürültülü (veri toplama esnasında oluşan sistem dışı hata), dinamik ve yapılandırılmamış veri özelliği taşımaktadır (Gundecha ve Liu, 2014: 4). Teknoloji ve dijitalleşmenin sürekli gelişimiyle birlikte oluşan bu verinin çeşitliliği, hızı ve niceliği de aynı oranda her sektör kapsamında gelişim göstererek etkili sonuçların alımında parametre rolü oynamaktadır. Belirsizlik altında para yönetme sanatı olarak ifade edilen “finans” sektöründe de büyük veri “yüksek olasılığa sahip tercihler yapılması” için kullanılmaktadır. Özellikle kurum ve kuruluşların büyük ölçekli bu veriyi toplaması ve analiz etmesindeki gereklilik ve fayda artış göstermektedir.

2.2. Büyük Veri ve Kripto Para Piyasası Teknolojisi

Teknolojinin gelişimiyle birlikte yaşanan dijital devrim sonucunda finansal ürün ve hizmetlerde sayısallaşma, hareket artışı, etkileşim boyutları ve regülasyon artışı finans alanında kendini göstermiştir. Finansal piyasalarda meydana gelen bu değişim sonucunda rekabet avantajı sağlamak isteyen kurum ve kuruluşlar, yapısal ve yapısal olmayan veriler aracılığıyla kendi iş süreçlerini ve sektörü incelemektedirler. Böylece finans sektörünü yeniden yapılandırmak için büyük veri ve veriye bağlı analitik olgulardan faydalanma zorunluluğu ortaya çıkmıştır. Büyük verinin yönetilmesi hem denetim hem de ülkelerin kalkınması açısından tutarlı ve etkili para politikalarının da uygulanması hususunda oldukça önemlidir (Faccia vd., 2019: 31). Finans alanında büyük veri analitiği borsa ve getiri tahminleri, finansal analiz sonuçlarının desteklenmesi gibi pek çok farklı amaçla ve öngörü analitiği doğrultusunda gerçekleştirilmektedir. Tetlock (2007)'un makalesi, finans alanında büyük veri uygulamasının ilk ve öncü örneği özelliği taşımaktadır. Bu makale ile Wall Street Journal'daki "Abreast of the Market" isimli gazete içeriklerinin piyasa getirilerini tahmin edip etmediği araştırılmıştır. Özellikle son yıllarda piyasalar benzeri görülmemiş bir değişime uğramıştır. Bu değişimle birlikte büyük miktarlarda ve yüksek hızlı heterojen veri üretimi gerçekleşmektedir. Amerikan hisse senedi işlemlerinin yaklaşık %70'inin yüksek frekanslı işlemler aracılığıyla üretilmesi ve makine ile işlenmesi örnek olarak gösterilebilmektedir (Zervoudakis vd., 2018: 2).

Büyük veri bileşenleri açısından ele alınacak olursa;

Hacim; finansal piyasalarda veri hacmi giderek artış göstermektedir. Son on yılda Wall Street'te ana akım haline gelen algoritmik ticaret aynı zamanda sermaye piyasalarında da büyük veri çağına giriş niteliğindedir. Sayıca çok fazla borsadan ve bankadan gelen yapılandırılmış verilerin yanı sıra sosyal medya mecralarından gelen yapılandırılmamış bu veriler de giderek artış göstermektedir.

Hız; piyasalarda yer alan aktörlerin küçük hız artışları elde etmek için kullandığı teknolojiler "milisaniyelerin milyonlar anlamı taşıması" niteliğindedir. İnsanların gündelik yaşamlarında web ve mobil cihaz kullanımlarıyla birlikte işlem hızı ve sıklığı önemli ölçüde artış göstermektedir. Bu artış, finansal kurumlar açısından hem zorluklar hem de fırsatlar yaratmaktadır. Özellikle gerçek zamanlı karar verilmesi için büyük veri teknolojisi yığınınından, istatistiksel modelleme ve tahminleme tekniklerinden verimli ve etkili yararlanma yeteneği geliştirilmesine olan gereksinim giderek artmaktadır.

Çeşitlilik; üstte de değinildiği üzere finansal veriler hem yapılandırılmış hem de yapılandırılmamış verilerden meydana gelmektedir. Yapısı ve uzunluğu sabit olan bilgiler


yapılandırılmış veri olmakla birlikte çoğu zaman serisi şeklindedir. Önceden belirlenmiş bir modele girmeyen bilgiler ise yapılandırılmamış verilerdir. Karmaşıklığına rağmen yapılandırılmamış veriler, finans sektöründe strateji belirlemede önemli rol oynamaktadır.

Eşsiz miktarlarda oluşan yapılandırılmış ve yapılandırılmamış verilerin geleneksel veri analizi teknikleriyle verimli şekilde incelenmesi olanaklı olmadığından büyük veri analitiğine duyulan ihtiyaç giderek artmaktadır (Fang ve Zhang, 2016: 393-396). Finans sektöründe anlık karar verilmesi için hızlı analizler yapılabilmesi ve bunun için de tarihsel büyük veri kullanılması gerekmektedir. Zamansız ve yavaş olarak toplanan verilerin karar verme aşamasında gecikme yaratacak olması kaçınılmazdır. Büyük veri analitiği aracılığıyla, gerçek zamanlı uygulamalar yapılarak kısa zaman dilimleri içerisinde karar vermek için anlık girdi ve çıktılar elde edilebilmektedir. Finansal piyasalarda artan faaliyetlerden ve teknolojik araçların gelişiminden kaynaklanan hızlı veri akışının yaygınlaşması aynı zamanda finansal piyasa aktörlerinin de iş modellerini önemli ölçüde değiştirmektedir. Yaşanan tüm bu gelişim ve dönüşümler finansal sektörde önemli bir dönüşümün itici gücü olmuştur. Banka hesaplarında birim olarak temsil edilen para artık dijital çağda farklı form ve sistemler ile karşımıza çıkmaktadır. Yirminci yüzyılın son çeyreğinde elektronik para sisteminin gelişmesi sonucu finans endüstrisi teknoloji ağırlıklı olmaya başlamıştır. Dünya Bankası dijital finansın *“finans yanlısı bir içerme aracı olarak onaylanarak, politika tartışmalarında dijital finansın vurgulanmaması halinde eksik olarak kabul göreceğini”* ifade etmiştir (Ozili ve Arun, 2020: 137). Finans sektöründeki bu dijital dönüşümde kripto para birimlerinin de büyük verinin olduğu kadar yadsınamaz bir önemi vardır. Son on yılda kripto para birimleri ve büyük verinin araştırmacılar tarafından büyük ilgi gördüğü gerçektir. Finansal sektörde kripto para birimleri ve büyük veri muazzam bir teknolojik gücü bir araya getirmektedir. Küresel ölçekte milyarlardan trilyonlarca dolara kadar değişim gösteren yatırımlar dikkat çekmektedir. Çünkü kripto para piyasası tüm hızıyla ilerleme gösteren blokzincir teknolojisini kullanmaktadır. Bu nedenle de hem blokzincir hem de büyük verinin birbirini tamamlayan teknolojiler olabileceklerini söylemek mümkündür. Blokzincir teknolojisi, birbirine bağlanmış işlemlerle finans piyasalarına uygulandığında sorunların hangi aşamada ve nasıl ortaya çıktığını ve/veya çıkabileceğini tahmin etmede hızlı geri bildirim sağlayan bir mekanizma özelliği taşımaktadır (Krishna vd., 2017: 180).

Finansal yenilik çalışmalarında yaşanan veri kıtlığı, güvenli liman arayışında olan potansiyel yatırımcıların en büyük engeli olmaktadır. Kripto para piyasasıyla birlikte yatırımcıların finansal yeniliğe ilgisi gittikçe artmaktadır. Ancak yatırımcı açısından bakıldığında, kripto para birimlerinin diğer yatırım araçlarına kıyasla pek çok risk taşıdığı bilinmektedir. Kripto para teknolojisinin yeni bir teknoloji olması ve klasik finansal sistemden farklı dinamiklere sahip

olması, beraberinde klasik finans mekanizmalarının hızla ayak uydurmakta zorlanmasına da neden olmaktadır. Şuan dünya genelinde kullanıcılar ve makinelerce sentezlenen sanal ve dijital verilerin miktar ile çeşitliliğinde büyük bir artış yaşanmaktadır. Araştırmacılar büyük veri ve blok zincir teknolojilerinin bu artışa karşı hayati bir rol oynayacağını ve veri düzenleme ile analizinin aktif rol oynayacağını ifade etmektedirler. Finans sektörü sürekli olarak farklı piyasaların geleceğini araştırmakta ve tahminlerde bulunmaktadır. Özellikle gelecek tahminlerinin daha etkin şekilde yapılabilmesi adına etkili modellere olan ihtiyaç giderek artmaktadır. Pazarın farklılaşması ve büyümesi sonucu büyük verinin, 2025 yılına kadar 6.70 milyar ABD dolarına ulaşacağı tahmin edilen kripto para piyasasında yerini bulduğu söylenebilmektedir. Bunu başarmak ise bu yüzyılın bir başka gelişen teknolojisi haline getirmesini sağlayacaktır (Sharma vd., 2020: 192). Sistem içerisinde yer bulan bu yeni teknolojiler, Endüstri 4.0 ile birlikte finans sektörünü teknolojiye indirgeyen bir yaklaşımla ele alınması gerekliliğini meydana getirmiştir. Ekonomik determinizmin aksine yaşanan bu teknolojik determinizm, teknolojik olanı toplumsal ve ekonomik olandan ayırarak başarıya ulaşmaktadır (Başaran, 2010: 259). Tüm bu yaşanan değişimlerin teknolojiye indirgenen bir yaklaşımla incelenmesi aynı zamanda bütünün anlaşılmasında engel de olabilmektedir. M.Ö. 600'lü yıllarda, Lidya kralı Alyattes tarafından basılan para ile modern insanın (Homo Sapiens) alış-veriş biçimi tamamen değişmiştir. Tarihi değiştiren en önemli hadiselerden birisi olan bu durum, insan yaşamıyla doğrudan bağlantılı olarak farklı evrelerde geçerek teknoloji çapına ulaşmıştır. Modernleşme sonucu küreselleşme ve önü alnamaz teknolojik gelişim sonucunda paranın geldiği yeni evreleri anlamak zorunlu hale gelmiştir. Bu noktada kripto para piyasası ve sağladığı büyük veri teknolojisini irdelemeden önce Harari (2015)'e ait basit bir soruyu incelemekte fayda vardır; *"bu kadar teknolojik evrim ve yenilikten sonra homo-sapiensler olarak mutlu muyuz?"*.

Sürekli gelişim içerisinde olan teknolojinin kabul edilmesi ve benimsenmesiyle ilgili olarak çeşitli teoriler ortaya çıkmıştır. Teknoloji Kabul Modeli (Davis vd., 1989), Yeniliklerin Yayılması Teorisi (Rogers, 1995), Birleştirilmiş Teknoloji Kabul Modeli ve Planlı Davranış Teorisi (Taylor ve Todd, 1995) alanyazında kabul gören teoriler arasındadır. Çalışmanın bu kısmında tutum ve davranışı açıklamaya yönelik geliştirilmiş ve araştırmacılar arasında sosyal psikoloji (Fishbein ve Ajzen, 1975; Ajzen, 1985; Cheng ve Lam, 2008; Ryu ve Han, 2010) alanında yaygın olarak kullanılan teorilerin başında gelen ve bahsedilen bu yeni kripto para teknolojisi Birleştirilmiş Teknoloji Kabul Modeli (Technology Acceptance Model-UTAUT) aracılığıyla incelenmiş olup, model Şekil 29'da verilmiştir.



Şekil 29: Birleştirilmiş Teknoloji Kabul Modeli

Kaynak: Venkatesh, V., Morris, M. G., Davis, G. B., & Davis, F. D. (2003). User Acceptance of Information Technology: Toward a Unified View. *Management Information Systems Quarterly*, 27(3), 425–478. doi:10.2307/30036540

UTAUT modelinde, çaba ve performans beklentisi, sosyal etki ve kolaylaştırıcı koşullar olmak üzere niyet ve kullanımın dört temel belirleyicisi yer almaktadır. Bunlar temel belirleyiciler olmalarının yanı sıra, bireylerin yeni teknolojileri kullanma davranışsal niyetini doğrudan etkileyen kilit faktörlerdir.

Tablo 35: UTAUT Modelinin Yapısı ve Araştırma Hipotezleri

Yapılar	Tanım (Goswami ve Dutta, 2016:53)	Araştırma Hipotezleri
Performans Beklentisi	Bireyin teknolojiyi kullanmasının ona yardımcı olacağı veya kolaylaştırıcı performansında kazanımlar elde edeceği inancının derecesi	H_{1a} : Kripto para teknolojisinin kullanımına ilişkin performans beklentisi, kullanım niyeti üzerinde etkilidir. H_{1b} : Kripto para teknolojisinin kullanımına ilişkin performans beklentisi, gerçekleşen yatırım davranışı üzerinde etkilidir.
Çaba Beklentisi	Teknolojinin kullanım kolaylığı ile ilgili bireylerin beklentileri	H_{2a} : Kripto para teknolojisinin kullanımına ilişkin çaba beklentisi, kullanım niyeti üzerinde etkilidir. H_{2b} : Kripto para teknolojisinin kullanımına ilişkin çaba beklentisi, gerçekleşen yatırım davranışı üzerinde etkilidir.
Sosyal Etki	Bireyin önemli gördüğü kişiler tarafından teknolojiyi kullanmaya	H_{3a} : Kripto para teknolojisinin kullanımına ilişkin sosyal etki, kullanım niyeti üzerinde etkilidir.

	başlamak ve devam etmek için inandığı derece	H_{3b} : Kripto para teknolojisinin kullanımına ilişkin sosyal etki, gerçekleşen yatırım davranışı üzerinde etkilidir.
Kolaylaştırıcı Koşullar	Teknoloji kullanımını destekleyebilecek organizasyonel ve teknik altyapının beklenen düzeyi	H_{4a} : Kripto para teknolojisinin kullanımına ilişkin kolaylaştırıcı koşullar, kullanım niyeti üzerinde etkilidir. H_{4b} : Kripto para teknolojisinin kullanımına ilişkin kolaylaştırıcı koşullar, gerçekleşen yatırım davranışı üzerinde etkilidir.
Kullanım Niyeti	Bireylerin belirli bir davranışı gerçekleştirmek için hazır olma göstergesi	H_5 : Kripto para teknolojisini kullanım niyeti, gerçekleşen yatırım davranışı üzerinde etkilidir.

UTAUT modeline göre performans ve çaba beklentisi ile sosyal etki, bir teknolojiyi kullanma niyetini belirleyen bağımsız değişkenlerdir. Davranışsal niyet ve kolaylaştırıcı koşullar değişkenleri ise teknoloji kullanım davranışını belirleyen değişkenlerdir (Tablo 35). Birleştirilmiş Teknoloji Kabul Modeli, her bir modelin birleşik açıklayıcı güç ve kilit düzenleyici etkilerini kapsayarak ancak temel yapıyı da koruyarak alanyazına katkı sağlamaktadır (Venkatesh vd., 2003: 427). Alanyazındaki çalışmalar, UTAUT modelinin önceki modelleri başarıyla entegre ettiğini, davranışsal niyet ve kullanım davranışındaki değişikliği önceki modellerden daha iyi açıkladığını ortaya çıkarmıştır. Bu çalışmada da moderatörlerle ilgilenilmediği için ihmal edilmiştir. Bu doğrultuda çalışma amacına yönelik olarak, “*bireyleri kripto para birimlerine yatırım yapmaya ikna eden ana niyetler veya motivasyon faktörleri nelerdir?*” sorusunu ele alan çalışmalar listelenmiştir. Bu çalışmalarda sadece kripto para piyasası ele almakta olup, Teknoloji Kabul Modeli temelinde incelenmiştir.

Tablo 36: Kripto Para Teknolojisi Kabul Modeli Alanyazın Araştırması

Yazar/lar	Araştırma
Thong vd. (2011)	Riskler ile algılanan kullanım kolaylığı arasında ilişki belirlenmiştir.
Baur vd. (2015)	İnsanların bitcoin kullanımının belirleyicilerinin incelendiği çalışmada, algılanan kullanılabilirliğin etkili olduğu belirlenmiştir.
Lee (2015)	Mahremiyetin, kullanıcıların verileriyle ilgili endişelerinin etkisinin ve kripto para biriminin algılanan kullanım kolaylığı tarafından belirlendiği dikkate alınmıştır. Gizlilik değişkeninin Bitcoin'in algılanan kullanılabilirliği üzerindeki etkisi belirlenmiştir.
Dauda & Lee (2015)	Güvenin, algılanan kullanım kolaylığı üzerindeki etkisi belirlenmiştir.
Junadi & Fenrianto (2015)	Bitcoin ve kripto para biriminin algılanan güvenlik ve tüketicilerin Bitcoin'i kullanma şekli ile ilişkisi belirlenmiştir.
Folkinshteyn & Lennon (2016)	Bitcoin kullanan tüketicilere sağlanan gizliliğin etkisini ve bunun algılanan kullanım kolaylığı ve dolayısıyla kabullenme üzerindeki etkisi belirlenmiştir.
Diniz vd. (2016)	Güvenin algılanan kullanılabilirlik üzerindeki etkisi araştırılmış ve bu değişkenin Bitcoin'in benimsenmesi üzerinde etkisi belirlenmiştir.
Gunawan & Novendra (2017)	Kripto para kullanım niyeti üzerinde kolaylaştırıcı koşulların olumlu etkisi olduğu belirlenmiştir.

Urquhart (2017)	Bitcoin ekonomisinin kabulünde, risklerin algılanan risklerle doğrudan bağlantılı olduğu belirlenmiştir.
Mendoza-Tello vd. (2018)	Elektronik ödemelerde kripto para birimlerinin kullanılma niyetinde algılanan kullanılabilirliğinin en etkili faktör olduğunu belirlemiştir. Bunun yanı sıra, sosyal etkinin ise kullanım niyeti üzerinde doğrudan etkisi bulunamamıştır.
Schaupp & Festa (2018)	Kripto para kullanım niyeti üzerinde sosyal etki ve algılanan davranışsal kontrol değişkeninin önemli olduğu belirlenmiştir.
Shahzad vd. (2018)	Çin'de yapılan kabul çalışmasında, hem algılanan kullanılabilirliğin hem de algılanan kullanım kolaylığının kripto para birimlerinden olan bitcoin üzerinde kullanma niyetinin önemli ölçüde etkili olduğu ifade edilmiştir.
Oliva vd. (2019)	İspanya'da temel internet bilgisine sahip üniversite eğitilmiş yetişkinlerle yaptıkları çalışmada, algılanan riskin etkili bir değişken olmadığını ifade etmişlerdir. Kripto para biriminin performans beklentisinin tüketici davranışında en etkili değişken olduğu belirlenmiştir.
Chow vd. (2019)	Kripto para kullanım niyeti üzerinde kolaylaştırıcı koşulların olumlu etkisi olduğu belirlenmiştir.
Öksüz Karademir & Kuş (2020)	Türkiye'de kripto para sahiplik eğiliminde en etkili değişkenlerin kolaylaştırıcı koşullar ve performans beklentisi olduğu belirlenmiştir. Coin-iyimserler kripto paraları hedeflerine ulaşmak bir araç olarak görmüşlerdir. Gözlemcilerin elde ettikleri bilgiler doğrultusunda hareket ettikleri ve son olarak coin-şüphecilerin de ekonomik kayıp nedeniyle kripto para sahibi olmadıkları görülmüştür.
Kabak & Çelik (2020)	Algılanan risk ve kullanım niyetinin en etkili değişkenlerin algılanan risk, güven, algılanan zevk, algılanan fayda, algılanan kullanım kolaylığı, algılanan erişim hızı ve maliyetin kripto para kullanım niyeti üzerinde etkili olduğu belirlenmiştir.
Gupta vd. (2020)	Yatırımcı niyetinin ölçeklendirildiği çalışmada, en az etkili faktörün çaba beklentisi, en çok etkili faktörün ise sosyal etki olduğu belirlenmiştir.

Tablo 36'da verilen gerçekleştirilmiş bir dizi araştırma, kripto para birimlerinin modern dijital dünyada varlık gösterdiğini ifade etmektedir. Chatterjee vd. (2020), kripto para birimleri üzerine yaptıkları çalışmada Bitcoin'in geniş çapta araştırıldığını ifade ederler. Değişim ve yatırım aracı olarak kullanılan kripto para birimlerinin hemen her yatırımcının portföyünde gelecekte bir parça oluşturacağı kabul edilmektedir (İnci ve Lagasse, 2019: 102). Nitekim NewYork Menkul Kıymetler Borsası'nda, ProShares Bitcoin Strategy ETF (BITO) isimli fon işleme açılmıştır (Marketwatch, 2021). Genel olarak değerlendirildiğinde, bireylerin davranış niyetleri herhangi bir nesne ya da fikre yönelik olumlu veya olumsuz değerlendirmeleri sonucu meydana gelmektedir. Bireylerin fikirlerinin davranışa dönüşmesinde önemli etkiye sahip bir belirleyicidir (Kotler, 2000: 136). Bu nedenle değişken doğaya sahip olan kripto para teknolojisinin bireysel yatırımcıların yatırım davranışları üzerindeki etkisini incelemek olanaklı gözükmemektedir.

Alanyazında kripto para ve büyük veri etkileşiminin araştırıldığı çalışmalar mevcuttur. Henüz tam adaptasyon, benimsenme ve arkasındaki blokzincir teknolojisinin benimsenmesine dair net bir bilgi yoktur. Ancak tüm teknik, ekonomik, sosyal ve kültürel değişim ile dönüşümlere rağmen yatırımcıların servet güdüsünün ve dolayısıyla da rekabetçi yaklaşımının evrimleşerek devam edeceği tarihe bakıldığında yorumlanabilmektedir. Kıt kaynakların sonsuz ihtiyaçları karşılamasında yol açacağı krizlere karşı yeni olanaklar sunan bu teknolojinin arkasındaki

benimsenme durumunun araştırılması gerekmektedir (Hassani vd., 2018: 10). Araştırma amacına uygun olarak incelenmesi hedeflenen, gerçekleşen yatırım davranışının belirlenmesinde Grable ve Lytton (1999) tarafından geliştirilen ölçekten yola çıkılmıştır. İlgili ölçek, bireylerin ellerinde para olması ve/veya kendilerine para hibe edilmesi durumunda nasıl yatırım davranışı gerçekleştireceklerine yönelik uyarlanmıştır. Aynı zamanda kripto para piyasası hakkında olumlu ve olumsuz haberler olması durumunda yatırımlarında kazanma ve kaybetme olasılıklarına göre de davranışları belirlenmek istenmiştir. Bu ayırımın yapılmasının temel sebebi, piyasalarda insanların verdikleri kararların rasyonel olmadığı ve kişiden kişiye değişen birçok faktörün piyasa davranışlarında etkili olmasıdır (De Bondt ve Thaler, 1995: 401). Yatırımcılar mevcudiyet hevristikinin (eldeki bilginin ve zamanın sınırlı olduğu durumlarda, çeşitli problemlerin çözümünde kullanılabilen zihinsel bir araç) etkisiyle kararlarında bazen diğer bütün istatistiki verileri göz ardı ederek çarpıcı bilgilerin etkisine kapılmaktadır. Özellikle kripto para piyasasında, zaman zaman “flash haber” başlığı altında büyük puntolarla dikkat çekici bir şekilde verilen bilgiler piyasalarda aşırı reaksiyona sebebiyet verebilmektedir. Yatırımcıların herhangi bir iyi habere karşı düşük reaksiyon göstererek, çok nadir satım işlemlerinde bulunabilmektedirler (Frazzini, 2006: 2017). Alanyazında balon fiyat oluşumundaki sıklık nedeniyle kripto para piyasasının spekülatif bir varlık olabileceğini araştıran çalışmalar mevcuttur. Bu nedenle kripto para teknolojisinde gerçekleşen yatırım davranışının ardındaki faktörlerin incelenmesinde bahsedilen olası durumlar modele eklenmiş ve ilgili sorular **Ek 1**'de verilmiştir. Alanyazında bu yeni teknolojinin bireyler tarafından nasıl değerlendirildiği, sonucunda yatırım kararlarına nasıl etki ettiği ve gerçekleşen davranışta ilgili teknolojiye ait özelliklerin dâhil edildiği herhangi bir çalışmaya rastlanmamıştır. Bu nedenle araştırma, kripto para teknolojisinden elde edilen büyük veriyle yapılacak olan araştırmalara geçmeden önce bir ön araştırma niteliği taşımaktadır.

Kripto para teknolojisini kullanmayı belirleyen ana niyetlerin belirlenmesi ve yatırımcı davranışı üzerindeki etkisini araştırmak amacıyla yapılandırılmış çevrimiçi anket tekniği kullanılmıştır. Araştırmanın evrenini 2021 yılında internet kullanıcısı olan ve en az bir kez kripto para alım-satım işlemi gerçekleştirmiş 18 yaş üstü bireysel yatırımcılar oluşturmaktadır. Çalışmanın örnekleme, Türkiye’de yaşayan 18 yaş üstü bireysel yatırımcılar, kolayda örnekleme yöntemiyle 216 kişi olarak belirlenmiştir. Çalışma için etik kurul onayı ve tüm katılımcılardan onam alınmıştır. Soruların aynı özelliği ölçebilmesi adına madde sayısının en az iki katı örnekleme ulaşma gerekliliği sağlanmıştır. Verilerin analizinde SPSS versiyon 25.0 ve SmartPLS versiyon 3 istatistik programları kullanılmıştır. Ayrıca kripto para yatırımcılarının yatırım kararlarında etkili olan değişkenleri incelemek için yapısal eşitlik modeli ile analizler %95 güven düzeyinde gerçekleştirilmiştir.

Katılımcılara cinsiyete göre bakıldığında, erkeklerin oranının (%63.4) kadınlardan (%36.6) daha fazla olduğu belirlenmiştir. Katılımcıların son mezun olduğu okul en az ilköğretim (%0.9) ve en fazla lisans (%46.3) olduğu görülmüştür. Aylık gelirleri incelendiğinde en yüksek 5000 Türk Lirası (%14.4) olduğu görülürken, yüksek gelir grubundan katılımcının daha fazla olduğu belirlenmiştir. Katılımcılar akıllı telefon, bilgisayar, tablet gibi cihazları günlük kullanım saatlerini en fazla 5 saat (%22.7) ve en az 14 saat ve üstü (%7.5) olarak belirtmişlerdir. En sık kullandıkları sosyal medya platformu Twitter (%36.6) iken, en az kullandıkları LinkedIn'dir (%0.5). Kripto paralardaki güncel gelişmeleri takip etmekte en sık kullandıkları sosyal medya platformu yine Twitter (%79.6) iken, en az kullandıkları WhatsApp'tır (%1.9). Katılımcılar herhangi bir yatırım kararı verirken en temel beklentilerini "yüksek getiri arzusu" (%50), "sermayeyi koruma arzusu" (%7.9), "devamlı gelir isteği" (%26.9) ve "portföy riskini azaltma" (%15.3) olarak belirtmişlerdir. Katılımcılar tarafından, sosyal medyada yapılan paylaşımların kripto para piyasasında etkili olduğu (%94.4) ve konuyla ilgili insanların düşüncelerini takip etmek gerektiği (%89.4) düşünülmektedir. Bunun yanı sıra, sosyal medyada kripto paralarla ilgili yapılan paylaşımlar kaçırılmak istenmemekte (%81) ve çıkan haberler/konuşmaları kaçırmakta huzursuzluk hissi yaratmaktadır (%58.3). Twitter üzerinden yapılan haberler/paylaşımlar kripto para yatırım hareketlerini etkilerken (%75.5), bu haberler/paylaşımların kripto para piyasasının ayı/boğa sürecinde olmasında da etkili olduğu düşünülmektedir (%87). Katılımcılar bugüne kadar olan performanslarını göz önüne aldığında birinci yatırım aracı olarak kripto parayı belirlerken (%74.5), ikinci olarak daha düşük olmakla birlikte yine kripto parayı belirlemişlerdir (%56). Ölçek maddeleri, UTAUT'un teoride yer alan ölçek maddeleri baz alınarak, 5'li Likert ölçeğinde hazırlanmıştır. Burada UTAUT modelini ortaya atan ilk araştırmacılar olan Venkatesh ve diğerlerinin (2003) makalesi temel alınmıştır. 216 katılımcıdan oluşan örneklemin analizinde önerilen modelin uygunluğunun incelenmesi için yapısal eşitlik modeli (YEM) kullanılmıştır. YEM önerilen teorik modelin analiz edilmesinin yanı sıra, gözlenen ve gizil değişkenler arasındaki ilişkiyi de ortaya koyan kapsamlı bir istatistiksel tahmin tekniğidir (Schumacker ve Lomax, 2004: 2). Ekonomi, davranış, sosyal bilimler ve tıp gibi pek çok alanda bu teknikten faydalanılmaktadır (Raykov ve Marcoulides, 2006: 5). YEM analizi SmartPLS 3 bilgisayar programı aracılığı ile gerçekleştirilmiştir.

Şekil 29' da verilen araştırmanın kavramsal modeli tahmin edilmiş olup, uyum indisleri sırasıyla X^2/df ; 2.12, SRMR; 0.07, NFI; 0.81 olarak elde edilmiştir. Uyum indislerinin kabul edilebilir düzeyde uyum gösterdiği belirlenmiştir (Jörg, Hubona ve Ray, 2016: 11). Ek olarak, tüm örnek için hesaplanan Standardize Edilmiş Ortalama Kare Kök (SRMR) katsayısı, özellikle PLS için uygun olan genel model uyumunun bir ölçüsüdür. Çalışmamızda bu katsayının değeri 0.07 olarak

belirlenmiş ve 0.08'den düşük seviyelerin elde edilmesi için önerilen sınırlamaya göre uyum sağlandığı gözlenmiştir. Aynı zamanda modelde R^2 değeri %76 olarak hesaplanmıştır. Analiz kapsamında modelde çoklu doğrusal bağlantı sorunu olup olmadığını incelemek için VIF değerlerine bakılmıştır. Elde edilen VIF değerleriyle çoklu bağlantı olmadığını doğrulayan sonuçlara ulaşılmıştır (VIF<5). Model geçerliliği ise yakınsak geçerliliğinin sağlanabilmesine bağlıdır. Her bir yapı için Composite Reliability (CR) ve Cronbach Alpha (CA) değerinin 0,70'den büyük olması gerekmektedir (Hair vd., 1998: 611). Aynı zamanda her bir yapı için Average Variance Extracted (AVE) değerinin 0.50'den yüksek olması gerekmektedir (Fornell ve Larcker, 1981: 40).

Tablo 37: Bileşik Güvenilirlik ve Yakınsak Geçerliliği

Faktörler	Cronbach's Alpha	Rho_A	Bileşik Güvenilirlik	Ortalama Açıklanan Varyans (AVE)
Performans Beklentisi	0.917	0.918	0.941	0.801
Çaba Beklentisi	0.925	0.925	0.947	0.816
Sosyal Etki	0.887	0.895	0.922	0.748
Kolaylaştırıcı Koşullar	0.848	0.849	0.908	0.768
Kullanım Niyeti	0.863	0.862	0.917	0.788
Kullanım Davranışı	0.916	0.920	0.941	0.800

Ölçeğe ait Cronbach Alpha katsayısı 0,96 bulunarak homojen bir yapıyı açıklamak üzere bir bütün oluşturdukları görülmüştür. Buna dayanarak bulguların, yüksek derecede güvenilir olduğu söylenebilir. CR ve CA değerlerinin ise 0,70 ve üstü değerler aldığı ve AVE değerinin 0,80'den büyük olduğu gözlenmiştir. Elde edilen değerlerin kabul edilebilir olduğu ve yapı geçerliliğinin yeterli olduğu belirlenmiştir (Fornell ve Larcker, 1981: 46). Aynı zamanda ölçüm modelinin ayırt edici geçerliliğinin her bir yapının AVE değeri karekökünün, o yapı ile diğer yapılar arasındaki korelasyonun karşılaştırılmasıyla kontrol edilmektedir.

Tablo 38: Diskriminant Geçerliliği (Fornell-Larcker Test)

	Ortalama	Standart Sapma	BI	EE	FC	PE	SI	UB
BI	4.44	0.79	0.888					
EE	4.14	0.99	0.810	0.903				
FC	3.86	0.75	0.742	0.832	0.876			
PE	4.36	0.80	0.846	0.818	0.706	0.895		
SI	4.08	0.98	0.721	0.834	0.846	0.707	0.865	
UB	4.24	0.88	0.867	0.869	0.747	0.880	0.740	0.895

Not: "BI", davranışsal niyet; "EE", çaba beklentisi; "FC", kolaylaştırıcı koşullar; "PE", performans beklentisi; "SI", sosyal etki; "UB", kullanım davranışı temsil etmektedir.

Köşegen elemanları AVE'nin kare kökünü, köşegen dışında kalan elemanlar ise gizil değişkenler arasındaki korelasyon katsayılarını göstermektedir. Bu karşılaştırmalar sonucunda AVE'nin karekök değerleri daha büyük olduğu için ayırt edici geçerliliğin sağlandığı söylenebilir.

Dolayısıyla yapısal modeli değerlendirmek için yol katsayılarının değerlerinin analiz edilebileceği belirlenmiştir.

Tablo 39: UTAUT Modeline İlişkin YEM Sonuçları

İlişki	Std Beta	t-değeri	p-değeri	Karar
BI → UB	0.867	27.855	0.000*	Desteklendi
PE → BI	0.540	6.130	0.000*	Desteklendi
UB → CN	0.370	4.648	0.000*	Desteklendi
UB → CP	-0.302	2.520	0.012*	Desteklendi
EE → BI	0.212	1.634	0.103	Desteklenmedi
FC → BI	0.166	1.721	0.086	Desteklenmedi
SI → BI	0.021	0.186	0.852	Desteklenmedi

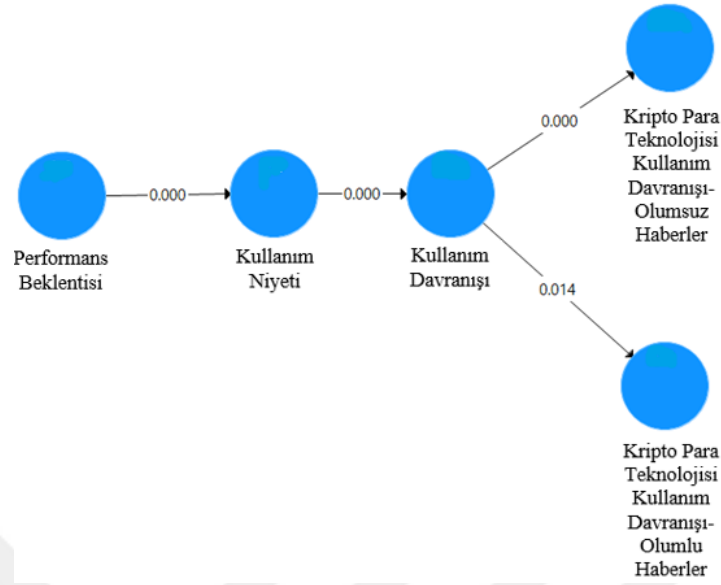
Not: *p < .5. Ayrıca “CP”, kripto para teknolojisi kullanım davranışı-olumlu haberler; “CN”, kripto para teknolojisi kullanım davranışı-olumlu haberleri temsil etmektedir.

Yol katsayıları, bağımlı ve bağımsız değişkenler arasındaki ilişkinin yoğunluğunu ifade etmektedir. Tablo 39’da desteklenen ve reddedilen hipotezler görülmektedir. Ayrıca, UTAUT modeline göre davranışsal niyetin gerçekleşen davranışın en büyük belirleyicisi olduğu varsayılmaktadır. Diğer tüm faktörler, gerçekleşen davranış tahmin etme hususunda davranışsal niyet aracılığı ile dolaylı olarak etki etmektedir (Davis vd., 1989: 320). Desteklenen hipotezler incelendiğinde, modelde yer alan faktörler arasında yalnızca performans beklentisinin etkisi olduğu görülmektedir. Modele ait istatistiksel olarak anlamlı elde edilen dolaylı etkiler Tablo 40’ta verilmiştir.

Tablo 40: Dolaylı Etkiler

İlişki	Yol Katsayıları	p-değeri
PE → BI → UB	-0.262	0.013
BI → UB → CP	-0.142	0.021
PE → BI → UB → CP	0.321	0.000
BI → UB → CN	0.174	0.001
PE → BI → UB → CN	0.468	0.000

Tablo 40’a göre, gerçekleşen kripto para yatırım davranışında, performans beklentisi etkisinin kullanım niyeti ve algılanan kullanım davranışı aracılığıyla ortaya çıktığı belirlenmiştir. Buna göre Şekil 29’da önerilen model istatistiksel olarak anlamlı değişkenlerle yeniden tahmin edilmiş ve sonuçlar Şekil 30’da verilmiştir.



Şekil 30: Önerilen Modele Ait Sonuçlar

Not: $p < .5$. (500 örnek ile çift taraflı bootstrap tekniğine dayalıdır).

Yapılan analizler sonucunda araştırma hipotezlerinden H_{1a} ve H_{1b} 'nin desteklendiği ve performans beklentisinin etkili faktör olduğu sonucuna ulaşılmıştır. Ayrıca performans beklentisinin, kripto para piyasasında olumsuz haberler olması durumunda gerçekleşen yatırım davranışı üzerinde olumlu haberlere göre daha fazla etkili olduğu belirlenmiştir. Bu ön araştırmada, yeni bir teknoloji olan kripto para piyasasında gerçekleşen davranışın arka planındaki belirleyicilerin incelenmesi ana hedef olarak belirlenmiştir. Yeni bir model geliştirilerek, yüksek bir açıklama kapasitesi sağlanmıştır. Çalışma modeli oluşturulduktan ve sonuçların analizinden sonra, gerçekleşen yatırım davranışı üzerinde en büyük etkiye sahip değişkenin performans beklentisi olduğu gözlemlenmiştir. Performans beklentisi, bireylerin belirli bir teknolojiyi kullanmasının faaliyetlerindeki performansı iyileştirmede yararlı olacağına inanma derecesi olarak tanımlanmaktadır. Çalışmanın bulguları ile beraber Venkatesh'in de bulgularına dayanarak, insanların olumlu sonuçlar alacağına inandıkları takdirde blokzincir teknolojisini benimseyecekleri ifade edilebilir. Dolayısıyla performans beklentisinin davranışsal niyet, algılanan kullanım davranışı ve sonucunda da gerçekleşen yatırım davranışı üzerinde olumlu bir etkisinin olduğu görülmektedir. Bir yeniliğin mevcuttan daha avantajlı olduğunun algılanma derecesi anlamına gelen algılanan avantajın en önemli yapıtaşı, yeniliğin adaptasyonu kapsamında performans beklentisidir (Moore ve Benbasat, 1991: 195). Çoğu araştırmacı, kullanım amacı için bir arka plan olarak performans beklentisinin önemli ve gerekli olduğu konusunda hemfikirdir (Oliva vd., 2019; Al-Amri vd., 2019; Alzahrani vd., 2019). Bir kripto para birimi tarafından sunulan katma değer ne kadar fazlaysa, kullanılma olasılığı o kadar artmaktadır.

Bu nedenle performans kullanılabilirliğe odaklanmak, kripto para piyasasında önerilen bir stratejidir. Bu bağlamda performans beklentisi değişkenini, yeniliğin kişinin performansına etkisi olarak değil, yenilikten beklenen performansı ifade edecek kapsamda şekillendirilmesi gerekmektedir. Aynı zamanda elde edilen sonuçlar doğrultusunda, son yıllarda hızla büyüyen bir endüstri olan kripto para birimleri teknolojisinin de incelenmesi gereken bir alan olduğunu söylemek mümkündür.

Kripto para teknolojisi ve büyük veri ayrılmaz şekilde bağlantılıdır. Modern dijital dünyadaki bu iki büyük kavram arasındaki etkileşimlerin araştırılması gerekmektedir (Hassani vd., 2018:6). Kripto para birimi ve büyük veri arasındaki yakınsama karşılıklıdır. Kripto para ağının doğası, büyük veri analitiğinin değerli bir kaynağı olarak önemini belirlemiştir. Örneğin temel bir blok zinciri mimarisi olan merkezi olmayan sistem, her katılımcı için tüm işlem kayıtlarını içermektedir. Veriler iyi yapılandırılmış ve doğrudur. Bu da veri yoğun bir ortam ve büyük veri analitiğini uygulamak için ideal bir kaynak haline gelmesini sağlamıştır. Alternatif bir para birimi olarak ölçülemez değeri ve arkasındaki geniş uygulanabilirlik ile blok zinciri teknolojisi göz önüne alındığında, geliştiricilerin ve yatırımcıların ilgisi, kripto para birimi ile ilgili teknolojiyi popüler hale getirmiş, kripto para biriminin büyüyen boyutu ve dijitalleşme çağını benimsemeyi seçen katılımcılarla birlikte dijitalleşmeyi daha da arttırmaktadır. Bu nedenle bu iki iç içe geçmiş alanın doğasının anlaşılması, hem politika yapıcılar hem de yatırımcılar açısından büyük önem arz etmektedir.

2.2.1. Büyük Veri ve Kripto Para

Son dönemlerde hızlanan finansal yayılım, 2030 yılı gündemi kapsamında sürdürülebilir kalkınma olarak ele alınmaktadır. Finansal yayılım Dünya Bankası (2020) tarafından *“bireylerin ve işletmelerin ödemelerinde, kredi ve tasarruf işlemlerinde ihtiyaçlara uygun olarak kullanılabilir finansal mal ve hizmetlere ulaşılması”* olarak tanımlanmaktadır. Dünya Bankası'nın Universal Financial Access 2020 Initiative isimli girişiminin temel noktası; küresel ölçekte bireylerin işlem yapabilecekleri bir hesaba sahip olmalarıdır. Böylece kredi, yatırım, ödeme ve tasarruflar gibi diğer finansal hizmetlere kapı açılması sağlanmaya çalışılmaktadır. Dünya genelinde finansal yayılım amacından söz edildiğine göre *“blokzincir teknolojisi ve kripto paraların buradaki yeri nedir?”* sorusu oluşmaktadır. Blokzincir teknolojisiyle finansal hizmetler kolayca sağlandığından finansal yayılımın kaçınılmaz ögesi haline gelmektedir. Teknoloji güdümlü günümüz dünyasında kripto para olgusunun finansal tabana yayılımda üsteleneceği rol, uygulanması hedeflenen programlar için önemli gözükmektedir.

Kripto para borsaları olarak adlandırılan piyasalarda işlem gören kripto paralar, kripto para-fiyat veya kripto para-kripto para değişimlerinin yapıldığı çevrimiçi platformlar aracılığıyla işlemleri gerçekleştirmektedir (Prypto, 2018: 22-23). Yasal düzenleme dezavantajına rağmen kripto para piyasalarının sağladığı yüksek getiri potansiyeli ve yeni altyapıları kullanan blokzincir teknolojisi sayesinde küresel olarak alternatif bir finansal piyasa haline gelmişlerdir (Huynh vd., 2020: 1). Dünya genelinde 300'ün üzerinde faaliyet gösteren kripto para borsası teknolojik ve finansal bir yenilik özelliğindedir. En fazla işlem hacmine sahip olan kripto para borsası Binance olup 01.06.2022 tarihi itibarıyla 24 saatlik toplam işlem hacmi 13.487.097.996 \$ (USD)'dir. Türkiye özelinde bakıldığında ise en yüksek işlem hacmine sahip platform olan Paribu'da 24 saatlik toplam işlem hacmi 3.262.146.776 ₺ (TL)'dir (CoinMarket, 2022). Görüldüğü üzere dijital finans piyasası ivmesinin, dijital para biriminde de büyüme potansiyeli yaratmaktadır. Örneğin, nesnelerin internetini ifade eden iletişim ağı IoT'un küresel ölçekte dijitalleşme ve popülerleşmesi sonucunda yeni teknolojilerin de benimsenmesi teşvik edilmektedir. Bu gelişimle birlikte kullandıkları teknoloji nedeniyle kripto para piyasaları daha umut verici alternatifler haline gelmektedir. Kripto paranın doğası gereği büyük veri analitiğinin değerli bir kaynağı haline gelmektedir. Ayrıca büyük veri analitiği, yatırımcılar ve teknoloji geliştiriciler açısından da daha iyi kararlar alınmasına yardımcı olmaktadır. Kripto paraların altyapı teknolojisinin ise çok çeşitli uygulanabilirlik alanları yaratması nedeniyle dijitalleşme sürecini hızlandırarak büyük veri analitiği ağını da genişletmektedir. Blokzincir teknolojisiyle büyük verinin birleşimi sonucunda hem kurum/kuruluşlar hem de yatırımcılar açısından büyüme potansiyeli yaratılmaktadır. Dolayısıyla bu potansiyel kripto para piyasasını da güçlendirmektedir. Bu nedenle finansal dijitalleşme, kripto para piyasaları ve büyük veri arasında meydana gelen bu yakınsamanın karşılıklı olarak gerçekleştiğini söylemek mümkündür.

2.2.1.1. Alanyazın Taraması

Veri analitiği ve büyük verinin kripto para endüstrisine getirebileceği değerlerin ve etkileşimin araştırılmasında alanyazında iki ana odak noktası mevcuttur. Bunlardan biri "Güvenlik ve gizlilik geliştirme" kapsamında uygulanan analiz ve tahmin teknikleridir. Bu yaklaşımda, kripto para teknolojilerinden doğan büyük miktarda verinin depolama ve paylaşım için güvenli bir ağ işlevi görmesinden yola çıkılmaktadır. Katılımcı sayısının fazla olduğu bu ağda büyük verinin analiz edilmesiyle zaten kararlı görülen mimarinin güvenliğinin daha da artırılması hedeflenmektedir. Örneğin, siber suçlu varlıkların tanımlanması ve olası saldırıların belirlenmesi amacıyla analizler gerçekleştirilebilmektedir. Diğeri ise kripto para ağının işlem verileri veya diğer büyük veri kaynakları (sosyal medya platformları) hakkında daha iyi bilginin elde edilmesine yardımcı olan

büyük veri analitiklerinin kullanılmasıdır. Her iki yaklaşım için alanyazında yer alan araştırmaların derlemesi Tablo 41’de verilmiştir.

Tablo 41: Büyük Veri ve Kripto Para Birimi İle İlgili Uygulamaların Özet Tablosu

Yaklaşım	Anahtar Teknikler	Uygulama Alanları
Güvenlik ve Gizlilik Geliştirme	Amaç Merkezli Erişim Modeli Güvenli Çok Taraflı Bilgi İşlem Ethereum Blok Zinciri Hash-Zincir	Tıbbi Kayıt Erişimi Kişisel Sağlık Verilerinin İşlenmesi ve İzlenmesi IoT Güvenliği ve Gizlilik Akıllı Ulaşım Sistemi
	Heterojen Anahtar Yönetimi Açık Anahtarlı Bitcoin Zinciri Denetimli Makine Öğrenimi Sınıflandırması Algoritmik Oyun Teorisi	Yeraltı Madenleri Güvenliği ve Verimliliği Akıllı Şehir Güvenliği Bulut Bilişim Güvenliği Bitcoin Ekosistemindeki Siber Suçlu Varlıklar Çoğunluk Saldırısını Önleme
Analizler ve Tahmin	Metin Sınıflandırma Duygu Analizi Kümeleme Sezgileri Bayesian Sinir Ağları Destek Vektör Makinesi GARCH Yapay Sinir Ağları Temel bileşenler Analizi Tekrarlayan Sinir Ağları Bayesian Regresyon ve Genelleştirilmiş Doğrusal Model/Rastsal Orman	Ticaret Stratejisi İlerlemesi Fiyat ve/veya İşlem ve/veya İade Tahmini Kripto Para Birimi Benimseme Belirleyicileri Yapay Kullanıcı Davranış Tanımlama

Kaynak: Hassani, H., Huang, X., & Silva, E. (2018). Big-Crypto: Big Data, Blockchain and Cryptocurrency. *Big Data and Cognitive Computing*. 2.4, s.8.

Büyük veri analitiği, karmaşık büyük hacimli veriler hakkında daha iyi bilgi edinilmesine yardımcı olmaktadır. Dijital olarak veri yoğun bir pazar için kripto para teknolojisi kısmen büyük veri tarafından oluşturulmaktadır. İyi yapılandırılmış ve yüksek kaliteli bu büyük veri, büyük veri analitiği için ideal kaynaklar oluşturmaktadır. Akademik araştırmalarda ortaya konulan genel tabloya bakıldığında, çalışmaların daha derinlemesine yapılması önerilmektedir. Zaman içerisinde araştırmacılara daha büyük veri seti sunacak olan kripto para ekosistemi üzerinde yapılacak olan çalışmalar kuşkusuz daha ayrıntılı ve açıklayıcı hale getirecektir. Ancak kripto para teknolojisinden doğan büyük verinin analiz edilmesinde henüz ele alınmayan ve kesinlikle keşfedilmeye değer potansiyeller için gelecek araştırmaların yapılması gerekmektedir (Hassani vd., 2018: 10).

Birçok araştırmada, kripto para piyasasının oynaklığına odaklanarak, daha iyi sonuçlar için çeşitli büyük veri analitiği teknikleri uygulanmıştır. Bu araştırmalarda temel olarak kar maksimizasyonuna yardımcı olmak ve yatırım risklerini azaltmak amaçlanmaktadır. Örneğin Colianni vd. (2015), Tablo 40’ta yer alan metin sınıflandırması tekniğini kullanarak avantajlı algoritmik ticaret stratejileri geliştirmek için kripto parayla ilgili gerçek zamanlı Twitter verileri

ile çalışmışlardır. Bu yaklaşım sonucunda kripto para piyasası hareketinde %90'ın üzerinde tahmin doğruluğu elde etmişlerdir. Jensen (2011), bu alandaki internet yöntemlerini “internetin özel bir analitik nesne olduğu ve kendi verisini kendi ürettiği” konusunu ısrarla vurgulamaktadır (Jensen, 2011: 52). Aynı zamanda internet çalışmalarında içerik çözümlemesi ve söylem çözümlemesinin yoğun kullanıldığını da belirtmiştir. Kalus Merten ise bu yöntemi “*sosyal gerçeğin belirgin (manifest) içeriklerinin özelliklerinden, içeriğin belirgin olmayan özellikleri hakkında çıkarımlar yapmak yoluyla sosyal gerçeğin araştırılması*” olarak tanımlamaktadır (Merten, 1983: 15). Yatırımcılar tarafından kripto para teknolojisinin benimsendiği, bu nedenle de daha fazla araştırılmaya değer yeni bir teknoloji olduğu önerilen ön çalışma sonucunda da belirlenmiştir. Aşağıda büyük veri ve kripto para teknolojisi için kripto para ağının, işlem verileri veya diğer büyük veri kaynakları (sosyal medya platformları) hakkında daha iyi bilginin elde edilmesine yardımcı olan büyük veri analitiklerinin kullanıldığı çalışmalar özetlenmiştir.


Tablo 42: Kripto Para ve Büyük Veri Analitiği Çalışmaları

Yazar/lar & Yıl	Amaç	Yöntem	Sonuç
Matta vd. (2015)	Google Trendler ile Bitcoin fiyatları arasındaki ilişkinin incelenmesi	Çapraz Korelasyon	Google Trendlerin Bitcoin fiyatı için bir tür tahmin edici niteliğinde olduğu belirtilmiştir.
Kaminski (2016)	Twitter paylaşımları ile Bitcoin fiyatları arasındaki ilişkinin incelenmesi Fiyat ve işlem sayısı hakkında daha iyi tahmin elde etmek için çevrimiçi topluluklarındaki kullanıcı yorum verilerinin incelenmesi	Çapraz Korelasyon	Bitcoin kapanış fiyatları ile olumsuz tweetler ile orta düzeyde korelasyon belirlenmiştir.
Kim vd. (2016)	Haber ve sosyal medya verileri kullanarak, üç kripto para birimi için fiyat dalgalanmalarının tahmin edilmesi	Duygu Analizi	Kripto para birimlerinin fiyat hareketlerindeki dalgalanmaların öngörülmesinde yararlı olduğu belirlenmiştir.
Lamon vd. (2017)	Sosyal medya içerik madenciliği ile Bitcoin'in benimsenmesinin incelenmesi	Lojistik Regresyon & Bernoulli Naive Bayes	Ethereum fiyatları için en iyi sonuca Bernoulli Naive Bayes ve Bitcoin ile Litecoin fiyatları için en iyi sonuca Lojistik Regresyon ile ulaşıldığı belirlenmiştir.
Lu (2017)	Twitter ile Bitcoin fiyat dalgalanmasının tahmin edilmesi	Duygu Analizi	Sosyal medya içeriklerinde duygu durumunun, Bitcoin'in benimsenmesi üzerinde farklı etkileri olduğu belirlenmiştir.
Stevqvist ve Lönnö (2017)	Twitter verileri ve Google Trends verileri ile Bitcoin ve Ethereum fiyatlarındaki	Duygu Analizi	Twitter paylaşımları ile Bitcoin fiyatları arasında kısa vadeli etki olduğu belirlenmiştir. Ancak daha büyük ve uzun vadeli verilerle daha iyi sonuçlar elde edilebileceği belirtilmiştir.
Abraham vd. (2018)			Tweet hacminin fiyat yönünün bir göstergesi olduğu belirlenmiştir.

	değişikliklerin tahmin edilmesi		
Jain vd. (2018)	Mevcut Tweetlerde ifade edilen duygulara dayanarak Bitcoin ve Litecoin fiyatlarının önceden tahmin edilmesi	Çoklu Doğrusal Regresyon	Bitcoin'in fiyatının, Litecoin'in fiyatına kıyasla tweet'lerin duygularından çok fazla etkilenmediği belirlenmiştir. Bitcoin fiyatındaki dalgalanmanın, madencilik maliyeti, ekonomik faktör gibi diğer faktörlere bağımlı olduğu belirtilmiştir.
Pant vd. (2018)	Twitter'da yer alan içerikler ile Bitcoin fiyat tahmini yapılması	Duygu Analizi & RNN Modeli	Zaman serileri tahminlemesinden daha çok duygu analizinin başarılı olduğu görülmüştür.
Hasan vd. (2018)	Twitter paylaşımları ile Bitcoin fiyatları arasındaki ilişkinin incelenmesi	Regresyon Makine Öğrenmesi k-En Yakın Komşu, Lojistik Regresyon,	Twitter'ın Bitcoin fiyatı üzerinde kısa vadeli etkisi olduğu saptanmıştır.
Kinderis vd. (2018)	Tweet'lerden alınan veriler ile kripto para değerleri arasındaki ilişkinin incelenmesi	Karar Ağaçları, Destek Vektör Makineleri, Gaussian Naive Bayes, Doğrusal Ayrımcılık Analizi	Bitcoin fiyatlarındaki dalgalanmaların daha doğru ve gerçek zamanlı tahmin edildiği bir model önerisi yapılmıştır.
Aste (2019)	Kripto para fiyatlarının toplu olarak nasıl davrandığını ve fiyat davranışının Twitter ile ilişkisinin incelenmesi	Çapraz Korelasyon & Nedensellik Analizi	Hem fiyatların duyarlılığın hem de duyarlılığın fiyat hareketlerinin nedeni olduğu belirlenmiştir.
Beck vd. (2019)	Kripto para borsasıyla ilgili yatırımcıların ilgisini çekebilecek kripto para haberlerinin sosyal medya platformlarında yer alan tweetlerle eşleştirilmesinin incelenmesi	Makine Öğrenimi Modeli ile birlikte Diziden Diziye Derin Öğrenme Modeli	Sektörel medya kuruluşlarının ana haber üreticisi olduğu ve popüler makalelerinin Twitter'da kullanıcıların içerik üretmesinde etkili olduğu saptanmıştır.
Dulau ve Dulau (2019)	Twitter ve Reddit'te yer alan kullanıcı gönderilerinde, kripto para fenomeni ile ilgili duyguların belirlenmesi	Duygu Analizi	Kripto para konulu iletilerde negatif duygu yoğunluğunun, nötr ve pozitif içeriklere oranla daha yüksek olduğu saptanmıştır.
Kraaijeveld ve De Smedt (2020)	Tweet duyarlılığının ve tweet hacminin fiyat getirileri ve günlük işlem hacimleriyle karşılaştırılması	Duygu Analizi & Nedensellik Analizi	Twitter'da ifade edilen duyguların, kripto para birimi fiyat değişikliklerini tahmin etmede yardımcı olabileceği sonucuna ulaşılmıştır.
Narman ve Uulu (2020)	Kripto para borsasında spekülasyon hareketlerinde kamuoyunun görüşlerinin araştırılması	Duygu Analizi	Pazardaki dalgalanmalara göre platformdaki içerik sayısının incelenen kripto paralar için yükseldiği belirlenmiştir.
Köksal vd. (2021)	Twitter Bitcoin tweetleri ile Bitcoin değer tahminlemesi yapılması	Doğrusal Regresyon Analizi & Rastsal Orman Regresyonu	Doğrusal regresyonun uygulandığı yöntemde model açıklanabilirliği %88,97, rastsal orman regresyonunun uygulandığı yöntemde ise %94,16 oran belirlenmiştir.

Aslam vd. (2022)	Kripto para biriminin piyasa fiyatlarının tahmin edilmesinde Twitter içeriklerinin kullanılması	Duygu Analizi & Derin öğrenme topluluğu modeli (LSTM-GRU)	Fiyatların tahmin edilmesinde makine öğrenimi modellerinin performansının nispeten daha iyi olduğu belirlenmiştir.
-------------------------	---	---	--

Dijital bilgi ve iletişim teknolojilerinin yatay hiyerarşisiyle birlikte sıradan bir internet kullanıcısı ile büyük yatırımcılar aynı platformda bir araya gelmiştir. Bu birleşim sonucunda uluslararası kripto para borsaları oluşmuş ve günümüzde büyük borsalarla rekabet edebilecek düzeye gelmiştir. Bu borsa hakkında bilgi edinmek isteyen büyük ve küçük yatırımcılar artık TV, gazete vb. konvansiyonel medya yerine sosyal medyayı sıklıkla tercih etmektedir. Dolayısıyla sosyal medyanın büyük ve küçük tüm yatırımcılar için kripto para gelecek değerleri tahmini ve buna bağlı olarak yatırım kararı belirlemede ciddi öneme sahip bilgi kaynağı olduğunu ifade etmek mümkündür (Polat ve Akbıyık, 2019: 445-446). Özellikle Twitter üzerine yapılan büyük veri araştırmalarında, büyük kitlelerin davranışsal açıdan incelenmesine olanak sağlanmakta ve farklı disiplinleri etkileyen sosyal olguların takip edilmesi mümkün olmaktadır (Savage, 2011: 20). Pek çok araştırmacı kripto para fiyatlarının temel ekonomik göstergelerden bağımsız şekilde piyasa katılımcıları tarafından belirlendiğini ifade etmiştir. İlgili alanyazına bakıldığında çalışmaların son yıllarda artış gösterdiği ve ağırlıklı olarak bitcoin üzerine yapıldığı görülmektedir. Yapılan araştırmalarda öncelikle “bitcoin yatırım aracı mı?” sorusu, akabinde de “fiyatı etkileyen faktörler nelerdir?” sorularına yanıt aranmıştır. Fiyatın yatırımcılar tarafından belirlendiğinin ortaya konulduğu çalışmaların sıklaşması sonucu son yıllarda ağırlıklı olarak duygu analizi üzerine odaklanılmıştır. Ancak piyasa hacmi oldukça büyük olan diğer kripto para birimleri üzerine yapılan araştırmalarda eksiklik olduğunu söylemek mümkündür. Farklı çözümler için farklı teknolojiler ile üretilen bu kripto para birimlerinin incelenmesi, kripto para piyasasının bütüncül olarak anlaşılmasında önemli bir basamak olacaktır.



Şekil 31: Kripto Para Birimleri Tweet Hacimleri (2019-2022)

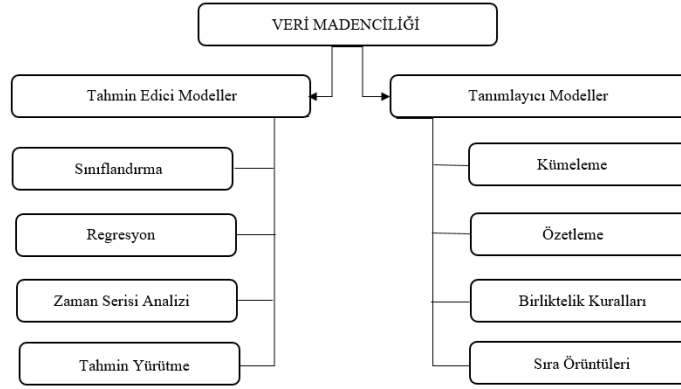
Kaynak: Bitinfocharts, <https://bitinfocharts.com/comparison/tweets-btc-eth-xrp-ltc.html#log&3y> (Erişim Tarihi: 30.05.2022).

Şekil 31’de, son üç yıl içerisinde bitcoin, ethereum, litecoin ve ripple kripto para birimleri hakkında Twitter üzerinden yapılan paylaşımların zamana göre eğilimleri verilmiştir. Bu kripto

paralar arasında önemli korelasyonlar olduğu da Tablo 2’de paylaşılmıştır. Yatırım ve tasarruf kararlarında bireyler finansal piyasaları ve dolayısıyla da tüm ekonomiyi etkileyebilecek potansiyele sahiptir. Finansal piyasalar arasındaki etkileşim sebebiyle herhangi bir piyasada meydana gelecek bir istikrarsızlık sonucu diğer piyasalarda etkilenebilecektir (Göker, 2009: 10). Bu nedenle en yüksek hacime sahip olan kripto para birimi bitcoin olsa da, diğer kripto para birimlerinin de ele alınmasının tüm sistemin anlaşılmasında katkı sağlayacağı söylenebilir. Bu noktada insanların ortak fikirlerini paylaşabildiği bir forum işlevi gören Twitter’ın, günlük olarak kullanıcıların kripto para piyasasına karşı olan duygularını yansıtmada iyi bir araç olduğu ifade edilebilir (Jain vd., 2018: 7). Aynı zamanda bireylerin duyguları da karar alma süreçlerine etki etmektedir (Paulus ve Angela, 2012: 477). Dolayısıyla tüm bu özelliklerin bireylerin yatırım kararlarının incelenmesinde önemli rolü vardır.

2.3. Veri Madenciliği

Verilerdeki yeni, geçerli, potansiyel olarak yararlı ve anlaşılabilir örüntülerin belirlenmesi süreci olan veri madenciliği, anlamlı kalıpların ortaya çıkarılmasında büyük miktarlardaki verilerin araştırılması ve analiz edilmesi için yararlı bir araçtır (Ha ve Park, 1998: 4). Veri madenciliği, verilerden çıkarım yapılması açısından benzer özellikler göstermelerine rağmen geleneksel istatistiksel modellemeye çeşitli farklılık göstermektedir (Shapoval vd., 2018: 311; Magnini vd., 2003: 95). Genellikle büyük ölçekli verilere uygulanan istatistiksel analizler ve/veya yapay zekâ analizi veri madenciliği kapsamındadır. Genellikle yönlendirilen ve belirli bir beklenen sonuç kümesinin olduğu durumlarda ise geleneksel istatistiksel analizler kapsamındadır. Geleneksel teknikler kestirimci modeller olarak bilinmekte olup temel hedef parametrelerin tahmin edilmesi ve hipotezlerin doğrulanması üzerine büyük öznel bileşenlere sahiptir (Shapoval vd., 2018: 312). Özetle veri madenciliği, karmaşık ve büyük veri kümelerinin işlenmesini sağlamaktadır (Magnini vd., 2003: 95). Büyük miktardaki verilerden elde edilen verimli özetler ve ilişkileri tanımlayarak geleceğe yönelik öngörüler oluşturulabilmektedir (Shapoval vd., 2018: 311). Veri madenciliği tanımlayıcı ve tahmin edici modeller olmak üzere ikiye ayrılmaktadır. Ancak modeller arası fark kesin sınırlarla ayrılmamaktadır.



Şekil 32: Veri Madenciliği Model Türleri

Kaynak: Yazar tarafından oluşturulmuştur.


Tahmin edici modellerin tanımlayıcı, tanımlayıcı modellerin tahmin edici olarak kullanılabilmesi anlaşılabilir olduğu ölçüde mümkündür (Rud, 2001: 4). Yöntem seçimi, verilerin yapısına ve veri madenciliği sürecinde yer alan araştırmacının beceri ve tercihlerine bağlıdır (Berry ve Linoff, 2004: 7). Veri madenciliği ile büyük verinin analiz edilmesi sonucu anlamlı ve değerli bilgileri oldukça geniş bilgi kalabalıklarından çekmek mümkündür. Dolayısıyla veriler arasındaki bütünlüğü ve ilişkiyi anlayarak, problemlerin çözümünde karar verme sürecini destekleyen bir araçtır (Davenport, 2012: 24). Veri madenciliği yöntemleri sayesinde yapısal veriler analiz edilebilmektedir. Ancak günümüz teknolojisinde verilerinin çoğunlukla yapısal olmayan formda olduğu bilinmektedir. Örneğin, e-postalar, metin dosyaları, resim dosyaları gibi veriler ham veri olarak değerlendirilmektedir. Veri madenciliği yöntemlerinin uygulanabilmesi için verilerin yapısal formda olması gerekmektedir. Ham verilerden yapısal formda veri elde edilmesinde sıklıkla metin ve web madencilikleri kullanılmaktadır.

2.3.1. Metin Madenciliği

Gelişen teknolojiyle birlikte veri kaynakları ve verinin oluşumunda çok sayıda çeşitlenme söz konusudur. Veri hacminin giderek büyümesiyle önemli bilgiler kaybolabilmektedir. Bu nedenle değerli bilgilere ulaşılmasında yarı yapısal verilerin içeriğinin belirlenmesi ve uygun sorgulama tekniklerinin kullanılmasına ihtiyaç vardır. Bu noktada önem kazanan metin madenciliği için alanyazında çeşitli tanımlar mevcuttur. Metin madenciliğini en genel tanımıyla, “*yapılandırılmamış metinlerden ilgi çekici bilgilerin elde edilmesi süreci*” olarak ifade etmek mümkündür (Chen, 2011: 5). Başka bir tanıma göre, “*metinlerden yüksek kaliteli bilgi edinme süreci*”dir (Mucherino, Papajorgji, & Pardalos, 2009: 17). Metin madenciliği ile salt metinde yer alan bilgiler arasındaki ilişkilere keşifsel olarak yaklaşılmaktadır (Babu vd., 2014: 12). Bu

keşifsel süreçte metin içerisindeki gizli kalıp ve örüntüler ortaya çıkartılmaktadır (Hansen ve Johnson, 2011: 10).

Alanyazında önemli yere sahip bir diğer tanıma göre “*metin madenciliği insanlar arasındaki iletişimin analiz edilmesi süreci*”dir (Miner vd., 2012: 1009). Metin madenciliği için kullanılan veri tabanları, kayıtlar, yazışmalar, materyaller, sosyal medya girdi ve konuşmalarına bakıldığında, ilgili tanımın süreci ifade etmekte uygun olduğu görülmektedir. Metin madenciliği ve veri madenciliği arasındaki interaktif ilişki Şekil 33’te verilmiştir.



Şekil 33: Madencilik Süreçleri Arası İlişki

Kaynak: Dolgun, M.Ö., Güzel Özdemir, T. ve Oğuz, D. (2009). Veri madenciliği’nde yapısal olmayan verinin analizi: Metin ve web madenciliği. *İstatistikçiler Dergisi*. 2,51.

Metin madenciliği sürecinde elde edilen yapısal veri, modellenerek elde edilen sonuçlarla ilgili metnin yapısı incelenmektedir. Veri madenciliği alanının bir parçası olarak görülen metin madenciliği; temel olarak yapısal olmayan metinlerin sayısallaştırılarak sonrasında veri madenciliği araç ve tekniklerinin kullanılmasıyla anlamlı ilişkiler ve örüntülerin çıkartılması sürecidir. Temel farklılık, metin madenciliğinde ortaya çıkartılan örüntülerin olay veritabanlarından ziyade doğal dil metinlerinden çıkartılması işlemidir (Nisbet ve diğerleri, 2009: 174). Örneğin, günümüzde ciddi kullanıcı sayısına sahip olan Twitter aynı zamanda ciddi bir veri kaynağı özelliğindedir. Metin madenciliği sürecini genel olarak dört aşamada açıklamak mümkündür (Netzer vd., 2012: 524).

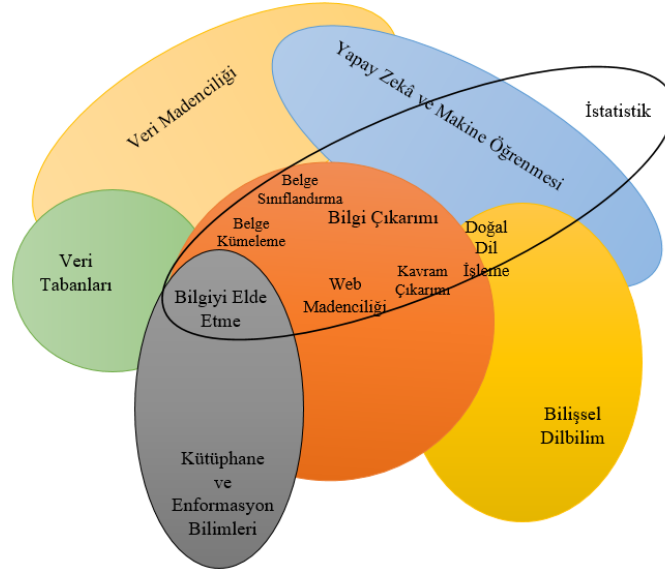
- **Metin koleksiyonunun oluşturulması;** metin madenciliği yazılımları ile Twitter gibi çevrimiçi sistemler, çevrimiçi sistemler dışındaki veritabanları ve bilgisayar üzerinde oluşturulan metinlerden içeriklerin elde edilmesidir.
- **Metin önileme;** elde edilen metinlerin yapılandırılmamış olması nedeniyle temizlenmesi, eklerinden arındırılması, en kısa biçime ve en uygun formata getirilmesi işlemidir. Bu işlemler; yazım yanlışlarının düzeltilmesi, noktalama işaretlerinin çıkartılması, büyük harflerin küçük harflere dönüştürülmesi, tek başına anlam ifade etmeyen önemsiz görülen gürültülü kelimelerin (stopwords) temizlenmesi, çalışmayla

ilişkisiz kelimelerin çıkartılması vb. sonucu verilerin yapılandırılmış formata dönüştürülmesini sağlamaktadır.

- **Veri madenciliği;** önışleme işleminin ardından yapılandırılmış forma gelen veriler ile bilginin keşfedilmesi amacıyla geleneksel veri madenciliği yönteminde kullanılan tekniklerin amaca uygun olanın seçilmesi ve uygulanması sürecidir.
- **Değerlendirme ve yorumlama;** veri madenciliği işlemi sonucunda elde edilen sonuçların değerlendirilmesi ve keşifsel sürecin açıklanmasıdır.

Metin madenciliğinin tarihine bakıldığında, ilk bulguların 1960'lara dayandığı görülmektedir. İşlenmemiş metinlerin yer aldığı ilk bilgisayar sistemlerinin geliştirilmesiyle başlayan süreç, 1980'li yılların ortasına kadar arama motorlarında yer alan "anahtar kelime ile arama" olarak kullanılabilen kullanıcı deneyimi açısından fazla gelişim göstermemiştir. Ancak 1990'lı yıllara doğru yapay zeka ailesinin üyesi olan Doğal Dil İşleme sürecinin başlamasıyla ortaya çıkmıştır. Bu süreçte geliştirilen metotlar hala metin madenciliği aracı olarak kullanılmaktadır (Bot, 2007: 3). Zohar'a (2002) göre metin madenciliği metotlarını dört grupta toplamak mümkündür.

- Bilgiye Erişim (Information Retrieval)
- Bilgi Çıkarımı (Information Extraction)
- Web Madenciliği (Web Mining)
- Kümeleme (Clustering)



Şekil 34: Metin Madenciliği ile İlişkili Alanlar

Kaynak: Miner G., Delen, D., Elder, J., Fast, A., Hill, T., Robert A. (2012). Practical Text Mining and Statistical Analysis for Non-structured Text Data Applications, Waltham USA: Elsevier

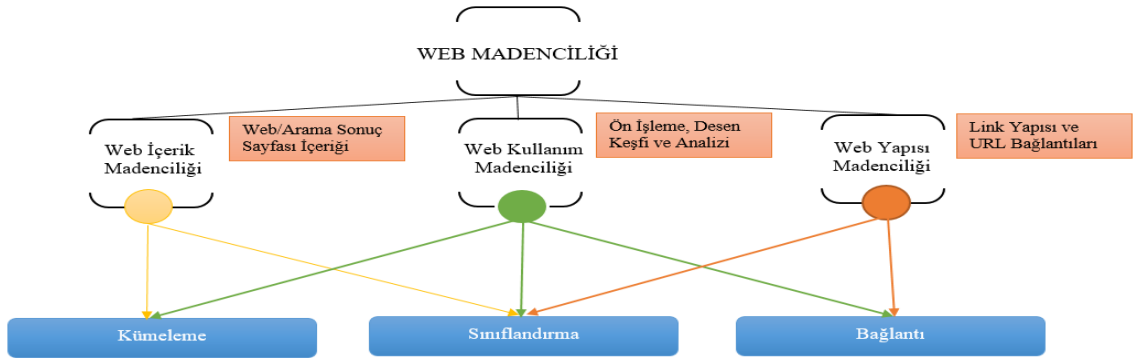
Veriden bilgi edinme işleminin sağlanması için geçirilen dönüşüm sürecinde, veri madenciliği tekniklerinin doğal dil işleme alanlarıyla birlikte optimize edilmesi sonucu web üzerinden kullanılması, web madenciliğinin de çalışma alanını oluşturmaktadır.

2.3.2. Web Madenciliği

Web madenciliği, büyük veri yığınları içerisinde anlamı sonuçların çıkartılması işlemi olması yönüyle veri madenciliğiyle benzerdir. Web servisleri ve belgelerinde veri madenciliği tekniklerinin kullanılması, elde edilen bilgilerin temizlenmesi, ortaya çıkartılması, çözümlenmesi sürecidir (Bhatia ve Kumar, 2008: 3). İnternet verileri üzerine yapılan veri madenciliği olarak tanımlanan web madenciliği terimi, alanyazındaki pek çok makaleye göre ilk kez “The World Wide Web: quagmire or gold mine?” isimli makalede ortaya atılmıştır (Etzioni, 1996). Makalede, veri madenciliği yöntemleri ile internet ortamındaki verilerin örüntülerinin bulunabileceği ortaya konulmuştur. Bu şekilde öngörülemez bilgilere ulaşmanın mümkün olduğu ifade edilmiştir. Pek çok veri madenciliği tekniğinin kullanıldığı web madenciliğinde, web verilerinin yarı yapısal, yapısal olmayan ve heterojen yapısından ötürü tamamen geleneksel veri madenciliği uygulamalarından değildir. Web madenciliğinin aşamaları genel hatlarıyla dört bölümde ele alınarak, anlamsız olan verilerden bilgi çıkarımının yapılmasında temel adımlar niteliğindedir (Kosala ve Blockeel, 2000: 2).

1. **Kaynakların bulunması:** Madencilik süreci için gerekli web servislerinin, bilgilerin, dokümanların vd. temin edilmesidir.
2. **Bilgi çıkarımı:** Elde edilen verilerden bilginin otomatik olarak çıkartılmasıdır.
3. **Genelleştirme:** Web sitelerindeki genel örüntülerin keşfedilmesidir.
4. **Analiz:** Keşfedilen örüntülerin doğruluğunun belirlenmesi ve sonucunda yorumlanmasıdır.

Web madenciliği alanyazını genel olarak web içerik ve web kullanım olmak üzere iki bölüme ayırabiliriz. Ancak günümüzde web yapı madenciliği de eklenerek üç bölüm olarak değerlendirilmektedir.



Şekil 35: Web Madencilik Türleri

Kaynak: Ateş, EC. (2021), “Siber Ansiklopedi: Siber Ortama Çok Disiplinli Bir Yaklaşım” Akdemir, N. ve Tuncer, C.O. (Ed.), *Web Madenciliği (Web Mining)*, Ankara: Pegem Akademi, 629-632.

Web içerik madenciliği: Metin, ses, resim, video vb. içeriklere sahip olan web belgeleri üzerinde bilgi çıkarma işlemidir. Örneğin, Twitter üzerinden herhangi bir kullanıcıya dair bilgilere ve paylaştığı içeriklere erişim sağlanabilmektedir. Web içeriklerinin farklı tipte olması nedeniyle analiz zorlaşmakta, metin madenciliği, makine öğrenimi, doğal dil işleme vb. tekniklerin kullanımını gerektirmektedir.

Web kullanım madenciliği: Web sitelerinde kullanıcılara ait kaynağa erişim modellerinin keşifsel analiz edilmesidir. Kullanıcıların web sitesinde kalma süreleri, hemen çıkma oranları, sayfa görüntüleme sayıları vb. kayıtlarından yola çıkarak web sitelerinin optimize edilmesi sağlanmaktadır.

Web yapısı madenciliği: Web sayfaları arasındaki bağlantıların takip edilmesi sonucu bağlantı yapılarının analiz edilmesi sağlanmaktadır. Sayfaları birbirine bağlayan ağ şeklindeki görünümünün elde edilmesini sağlayan yapı niteliğinde olduğundan özellikle arama motorlarının optimize edilmesinde kullanılabilir.

İnternet servislerinin giderek yaygınlaşması ve gelişmesi sonucu web madenciliği, atıl duruma düşen milyarlarca yapılandırılmamış veriden yapılandırılmış verilerin elde edilmesini ve istatistiksel yöntemler aracılığıyla yararlı sonuçlar elde edilmesini sağlamaktadır. Bireylerin diğer bireylerin düşüncelerini anlama eğilimleri bilgi toplama davranışının önemli bir parçasıdır. Sosyal medya, kişisel bloglar, forumlar vb. çevrimiçi paylaşım platformları bireysel kanaatler bakımından zengin olması nedeniyle bireyler tarafından başkalarının fikir ve görüşlerinin araştırılmasında yeni fırsatlar yaratmaktadır (Pang, 2008: 5). Web ve sosyal medya kullanımından önce yalnızca bireylerin kendi çevresiyle sınırlı kalan görüş belirtme, günümüzde bu platformlar sayesinde bireylerin görüşlerinin toplu olarak değerlendirilmesini sağlamaktadır. Değerlendirme sonucunda gerçekçi sonuçlara varılabilmektedir. Web madenciliği ile elde edilen verilerin analiz


edilmesi, anlaşılması ve sınıflandırılması ise zor, maliyetli ve zaman alıcı bir süreçtir. Bu noktada “hangi sistemlerin bu işlemleri hızlı şekilde gerçekleştirerek doğru sonuçlara ulaştığı?” sorusunu sormak gerekmektedir.

2.4. Duygu Analizi

Doğal dil işleme tekniği olan ve aynı zamanda fikir madenciliği (opinion mining) olarak bilinen duygu analizi (sentiment analysis) verilerin olumlu, nötr ve olumsuz olarak belirlenmesinde kullanılmaktadır (Pawar vd., 2015: 957). Metin madenciliğinin bir alt alanı olan teknikte, bireylerin belirli durum, olay, varlık vb. hakkındaki olumlu ve olumsuz görüşleri, tutumları, değerlendirmeleri ortaya çıkartılmaktadır. Bu varlık herhangi bir birey, konu, olay, ürün, hizmet, finansal varlık vb. çeşitlendirilebilmektedir. Sayıca çok fazla sosyal medya içeriği, manuel olarak işlemeyi imkânsız hale getirdiğinden duygu analizini otomatik olarak yapmayı sağlamaktadır (Sánchez-Rada ve Iglesias, 2019: 344). Duygu analizi tekniği sayesinde metinlerin içeriklerinin bilinmesinin yanı sıra metinlerin neler hissettirdiği de ortaya çıkarılabilmektedir (Liu, 2012: 4). Bunun için veride yer alan terimlerin sözlük içerisinde karşılık gelen puanları -1 ile +1 arasında değerlendirilmektedir. Cümle içerisinde yer alan kelimelere sözlük karşılığı puanlar atanarak toplanmaktadır. Toplama işlemi sonucunda elde edilen değere ise “polarite skoru” ismi verilmektedir (Bhadane vd., 2015: 812). Görüş içerikli metinler duygu analizine göre; “duygu ya da görüş hedefi (opinion target-g)”, “hedef hakkındaki duygu ya da görüş (sentiment-s)”, “görüş sahibi (opinion holder-h)” ve “görüşün ifade edildiği zaman (time-t)” olmak üzere dört bileşenden meydana gelmektedir. Ancak incelenecek içeriklerde birden fazla hedef bulunabileceğinden çalışma öncesinde belirli bir hedefin tanımlanması gerekmektedir (Fang ve Jia, 2019: 65).

Duygu analizinde metin, görüntü, ses verilerinden hareketle bilişim destekli olarak insan davranışı, duygusu ve inanışları belirlenmektedir (Poria vd., 2018: 3). Doğal dil işleme çalışmaları her ne kadar 1950’li yıllarda başlamış olsa da özellikle duygu içeren dokümanların erişiminin 2000’li yıllarda artması sonucu duygu analizine eğilim artış gösterdiği görülmektedir (Pozzi vd., 2017; Yue vd., 2019; Liu vd., 2020). Özellikle Web 2.0 aracılığıyla dinamik içerikli sayfa üretimi ve veri tabanlarının önemin artması sonucu, veri daha anlamlı ve kullanışlı hale gelmiştir. Bo Pang ve Lillian Lee tarafından 2002 yılında “*Thumbs up? Sentiment Classification using Machine Learning Techniques*” başlıklı çalışması duygu analizinin yapı taşı olarak görülmektedir. Duygu analizi; cümle, doküman ve özellik-tabanlı olmak üzere üç farklı düzeyde ele alınmaktadır. Cümle düzeyine göre gerçekleştirilen duygu analizinde, metin içerisinde yer alan tüm cümleler değerlendirilerek nesnel ya da öznel olarak tanımlanmaktadır. Duygu belirten öznel cümleler

sınıflandırılıp diğer cümleler göz ardı edilebilmektedir (Özyurt ve Akcayol, 2018: 671). Doküman düzeyli duygu analizinde, içerisinde görüş barındıran metin bir bütün olarak ele alınarak ağır basan duyguya göre sınıflandırma işlemi yapılmaktadır. Özellik tabanlı duygu analizinde ise metnin duygu eğilimin yanı sıra özellikle çıkarım işlemi sonucu hangi özellik hakkında yorum yapıldığı da belirlenmektedir (Boudad vd., 2017: 2480). İçeriklerin incelenmesi sonucu ne tür duyguların içerildiğinin anlaşılmasında kullanılan duygu analizinde veri kaynağı olarak özellikle son yıllarda sosyal medya analitiğinin ön planı çıktığı görülmektedir. Şekil 36 aracılığı ile Twitter platformunda “Cryptocurrency” etiketiyle yapılan paylaşımlara ait anlık (son bir kaç saniye içinde paylaşılan tweetler) duyguların görselleştirilmesi verilmiştir.



Şekil 36: ‘Cryptocurrency’ Etiketli Tweetlerin Duygularının Görselleştirilmesi (18.06.2022)

Kaynak: Tweet Sentiment Visualization, https://www.csc2.ncsu.edu/faculty/healey/tweet_viz/tweet_app/ (18.06.2022).

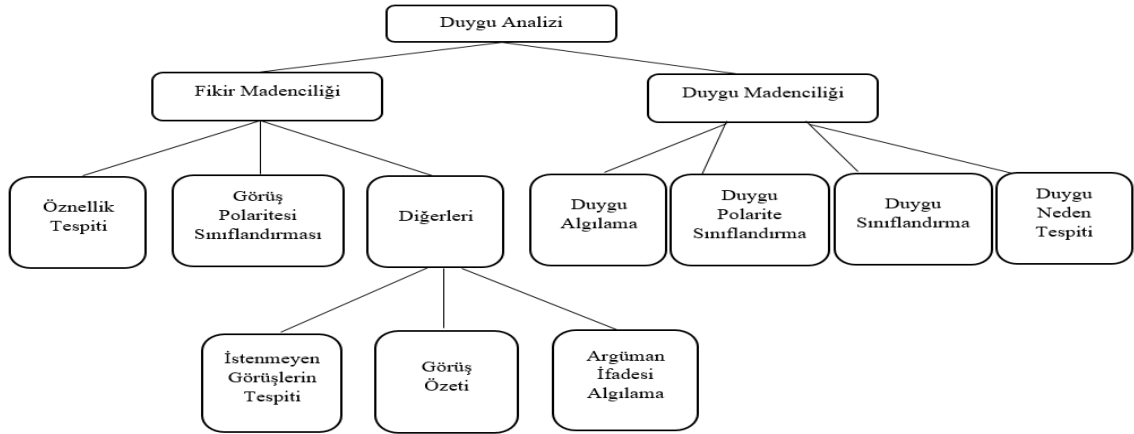
Şekil 36’da aranan anahtar sözcükle (cryptocurrency) en çok hangi sözcüklerin birlikte olduğu görülmektedir. Circumplex Model ismi verilen bu iki boyutlu modelde her bir duygunun kendine özgün yeri mevcuttur. Model aracılığıyla tweetlerin yatay ve dikey eksenlerinde duygusal bir dağılım grafiğinin neresinde yer aldığı görselleştirilmiştir. Görselde yer alan her bir nokta bir tweeti temsil ederek, noktaların renkleri de kullanıcıların memnuniyet durumunu (negatif: mavi, pozitif: yeşil) ifade ederken büyüklüğü yapılan hesaplamaların güvenilirliğini göstermektedir. Anlık olarak alınan tweetler genel olarak değerlendirildiğinde pozitif memnuniyet durumunun daha baskın olduğunu söylemek mümkündür. Aynı zamanda paylaşılan tweetlerin yoğunlukla ‘sakin’, ‘rahat’ gibi duygulara dağıldığı görülmektedir.

önemli bir araştırma alanı meydana getirmektedir. Sosyal medya platformları aracılığı ile elde edilen büyük hacimli metin verileriyle gerçekleştirilen duygu analizi sonucunda toplumun mutluluk seviyesi, görüşleri, halkın siyasi görüşleri, finansal beklentiler gibi çeşitli alanlarda kullanılacak önemli değişkenler haline getirilmektedir (Zhang v.d.,2011; Bollen v.d., 201).

2.4.1. Duygu Analizi Yöntemleri

Makine öğrenmesine dayalı, sözcük tabanlı ve hibrit olmak üzere üç ana kategoride toplanan yöntemler aracılığıyla metin içerisindeki duygu yönelimi belirlenebilmektedir (Maynard ve Funk, 2011: 89). Sözcük tabanlı yöntemlerde; doğal dil işleme araçları kullanılarak analiz edilen cümlelerde yer alan duygu terimlerinden yararlanarak sınıflandırma işlemi yapılmaktadır. Duygu ifadelerinin belirlenmesinde duygu terimleri sözlükleri kullanılmaktadır (Yousef vd., 2014: 1098). Makine öğrenmesine dayalı yöntemlerde ise karar ağaçları, sinir ağları, bayesyen ağlar vb. algoritmalar kullanılmaktadır. Algoritmaların kullanıldığı yöntemlerde denetimli, yarı denetimli ve denetimsiz olmak üzere üç farklı duygu öğrenme tekniği kullanılabilir (Özyurt ve Akcayol, 2018: 672).

Ancak duygu analizinde kullanılacak yaklaşımın belirlenmesinden önce fikir ve duygu arasındaki ayrımın yapılmasında fayda vardır. Merriam-Webster sözlüğüne göre duygu “bir duygunun harekete geçirdiği bir tutum, düşünce veya yargı” olarak tanımlanmaktadır (Merriam-Webster, 2022). Ancak güçlü korelasyona sahip olan bu iki kavramı birbirinden ayırt etmek kolay değildir. Örneğin, pek çok durumda duygu, bir kişinin yargı veya fikir oluşturması için teşvik etmektedir. Ek olarak, bir kişinin görüşü başkalarında da duygulara neden olabilir. Bununla birlikte, bir metin çelişkili görüş ve duyguları belirtebilir. Örneğin, “*ailem beni özledikleri için üzülse de eğitimimi yurtdışında sürdürmenin iyi bir karar olduğunu düşünüyor*” cümlesi aynı konuya yönelik olumlu bir düşünceyi ve olumsuz bir duyguyu ifade etmektedir (Yadollahi vd., 2017: 2). Belirtilen durumlar nedeniyle “*fikirlerin ifadesiyle ilgilenen fikir madenciliği*” ve “*duyguların ifade edilmesiyle duygu madenciliği*” olmak üzere duygu analizini iki bölüme ayırmakta fayda vardır. Şekil 39, duygu analizinin bu iki göreve ve her birinin alt görevlerine göre sınıflandırılmasını göstermektedir.



Şekil 39: Duygu Analizi Görevlerinin Taksonomisi

Fikir madenciliği metinlerde ifade edilen olumlu, olumsuz veya nötr; duygu madenciliği ise bir metin parçasına yansıyan duyguların (örneğin, mutluluk, neşe, üzüntü) incelenmesi olarak ifade edilebilir. Bu nedenle yapılacak olan araştırmalarda sağlam bir problem terminolojisine sahip olmak için belirtilen ayrıma dikkat edilmesi gerekmektedir. Ayrıca davranışsal finans özelinde karar alma sürecine bakıldığında hisler ile karar alma üzerinde durmak uygun olacaktır. Hisler nedeniyle doğan duyguların, bilişle birlikte algı, yorum, değerlendirme ve kararı etkilediği kabul edilmektedir (Blanchette ve Richards 2010; Tuckett 2011).

Duygu analizi ile gerçekleştirilmesi hedeflenen veriler, etiketli ve etiketsiz olmak üzere ikiye ayrılmaktadır. Etiketli veri seti, gözlemlerin her birinin insanlar tarafından etiketlenerek belirlenmiş şeklidir. Örneğin, öğrencilerin sınav puanları ve öğrencilere ait cinsiyet, günlük çalışma süresi, gelir gibi bilgilerin yer aldığı veri setleridir. Sınav puanları etiket bilgisi olmakla birlikte algoritmaların eğitilmesi ve test edilmesinde kullanılmaktadır. Etiketsiz veri seti ise etiket bilgisinin yer almadığı, etiketlerin tahmin edilmesi istenen veya gereken durumlarda ele alınmaktadır. Etiketleri henüz bilinmeyen gözlemler için ise durum daha karmaşıktır. Etiketsiz veriler olması durumunda, veri setinin özel olarak ayrılan bir kısmı algoritmaya öğretilerek bilinmeyen ilişkilerin öğrenilmesi hedeflenmektedir. Örneğin, bir ürünün son kullanım tarihi kullanılabilir veya kullanılmaz durumda olduğunu ifade eden bir etiket niteliğindedir. Bu ürüne ait ısı, bekleme süresi, rengi, kokusu gibi çeşitli bilgiler mevcuttur. Ürünlerin durumuyla ilgili bilgi daha önce araştırmacılar tarafından belirlenmiştir. Bu şekilde veri setinin makine öğrenmesi algoritmaları yardımıyla işlenmesinden sonra etiket bilgisi olmayan yalnızca özellikleri bilinen bir veri setinde ürünün kullanım durumunun öngörülmesi olanaklı hale gelmektedir. Ancak bu verilerin yorumlanmasını sağlayan algoritmalar genellikle karmaşık yöntemlere dayanmaktadır.

2.4.1.1. Sözlük Temelli Yaklaşımlar

Sözlük temelli yaklaşımda, amaçlar doğrultusunda geliştirilmiş ve önceden derlenen duygu terimlerinin yer aldığı duygu sözlükleri kullanılmaktadır. Bu yaklaşımda sözlükler genel olarak, istatistiksel tekniklerin kullanılması sonucu ilgili kelimelerin aratılmasıyla büyüyen bir dizi temel terimden üretilmektedir (Yadollahi vd., 2017: 26). Kelime ya da kelime grupları (ngrams) içeriğinde barındırdığı duyguya (pozitif/negatif/nötr) göre sınıflandırılarak sözlükler oluşturulmaktadır. Böylece her metin için pozitif ve negatif nötr kelimeler incelenerek sayıca yüksek olan sınıfa atanması sonucu metnin duygusu ortaya çıkartılabilmektedir. Pozitif ve negatif duygunun eşit olması durumunda veya bunların hiçbirini içermemesi durumunda nötr olarak sınıflandırılmaktadır. Sözlük kullanımı ise manuel olarak, yazılı sözlüklerden yararlanarak ya da bütüncül temelli duygu sözlüğü oluşturulması gibi yöntemler aracılığıyla sağlanmaktadır (Liu, 2010: 32).

2.4.1.2. Makine Öğrenmesi Temelli Yaklaşımlar

Makine öğrenmesi temelli yaklaşımlar denetimsiz, denetimli ve yarı denetimli olarak üç kategoriye ayrılmaktadır. Her üç yaklaşımda da başarı; temelde yatan duyguların belirlenmesinde kullanılan uygun özelliklerin belirlenmesi ve çıkarımının yapılmasına dayanmaktadır. Sınıflandırma işlemi için herhangi bir görüş kümesinin mevcut olmaması durumunda denetimsiz teknikler kullanılmaktadır. Bunun yanı sıra hem denetimli hem denetimsiz tekniklerin birleştirilmesi sonucu duygu belirleme işlemi yapılıyorsa hibrit yaklaşımı kullanılabilir. Denetimli öğrenmede makineye hem girdi hem çıktı değeri verilirken, denetimsiz öğrenmede makineye sadece girdi değeri verilerle pekiştirmeli öğrenme sağlanmaktadır. Denetimli öğrenmede temel amaç, eğitim seti ismi verilen giriş verileri ile çıkış verilerinin bir denetmen gözetiminde makineye tanıtılması sonucu bu bilgilerden anlamlı sonuçlar elde edilmesidir. Bu öğrenme metodunun kullanılabilmesi için öncelikle girdi ve çıktıların yer aldığı bir eğitim seti bulunmalı veya oluşturulmalıdır. Makineye veriler arasındaki ilişkilerin öğretilmesi sonucu, öğrenilen ilişkilere dayanarak hiç tanıtılmayan örneklem için varsayımda bulunulabilmektedir. Öğrenme sürecinde etiketlenmiş eğitim veri setinin test veri setini gözetmesinden kaynaklı yöntem denetimli olarak ifade edilmektedir (Öztemel, 2006: 25). Denetimsiz öğrenmede ise, değerlere karşılık gelen en uygun çıktının elde edilmesinde katsayılarla ait en uygun değerler bulunmaktadır (Bhonde vd., 2015: 52). Girdi değerlerine karşılık gelen çıktı değerleri bütün olarak etiketlenerek girdi ve çıktı arasındaki fonksiyonun eşlenmesi izlenmektedir. Ancak yöntemin düzgün çalışması için eğitim veri setinin yeterince büyük olması gerekmektedir (Onan ve Korukoğlu, 2016: 113). Denetimsiz öğrenmede, etiketlenmemiş veriler kullanıldığından

sistemin belli bir alanda bağı kalması engellenebilmektedir. Yarı denetimli öğrenme yaklaşımında ise elde az sayıda etiketlenmiş veri ve buna karşılık çok daha fazla sayıda etiketlenmemiş veri mevcuttur. Etiketleme bilgisi olmayan girdi değişkenleriyle çıktı değerlerini elde etmek hem zahmetli hem de maliyetlidir. Bu öğrenim yaklaşımı sayesinde yeni bir girdi için hedef çıktı bilgisinin en iyi şekilde tahmin edilmesi mümkündür. Denetimli öğrenme yaklaşımı ile arasındaki temel fark, denetimli öğrenmede etiketlenmiş veri sayısının fazla ve tahmin edilmesi istenen veri sayısı az iken yarı denetimli öğrenme yaklaşımında tam tersi durum söz konusudur. Yarı denetimli öğrenme yöntemini sınıflandırma, sıralama, regresyon gibi çeşitli tekniklerde kullanmak mümkündür (Kızılkaya ve Oğuzlar, 2018: 92). Genel hatlarıyla makine öğrenmesi temelli yaklaşımlar, incelenmesi hedeflenen veri setinde yer alan tüm kelimelerin ayrı ayrı ele alınması sonucu öznitelik olarak değerlendirilen kelime çantası (Bag of Words) tekniği vb. teknikler yardımıyla sınıflandırma algoritmalarının kullanımınıdır. Oluşturulacak model için veri setinin bir kısmının etiketlenmesi sonucu eğitim seti oluşturularak sınıflandırma algoritmalarının uygulanması sonucu metinlerde yer alan duygu durumları belirlenmektedir (Zhang, 2013: 3).

Bu tezde; duygu analizi fikir madenciliğinde yarı denetimli makine öğrenmesi yaklaşımı kullanılmıştır. Bunun nedeni, incelenmesi hedeflenen Twitter içeriklerinde etiketsiz veri olmasından kaynaklı hem denetimli hem de denetimsiz öğrenme yaklaşımlarının yetersiz kalma olasılığından kaynaklanmaktadır. Bu gibi durumlarda en ideal yöntem, az sayıda etiketlenmiş veriden hareketle etiketlenmemiş veriler için bilgi çıkarımı yaparak sınıflandırmaktır. Ayrıca bu çalışmada kripto para piyasası ele alındığından, piyasanın özellikle sosyal medya platformlar paylaşımlarının bilinen içeriklerinden farklılaşması ve büyük veriyle çalışılması nedeniyle eğitim veri setinin oluşturulabilecek kriterleri sağlaması nedeni ile bu yöntem tercih edilmiştir. Elde edilen bulgular doğrultusunda aynı alanda çalışmalar yürütmek isteyen araştırmacılara kaynak niteliğinde olması hedeflenmiştir.

2.4.2. Modelleme ve Sınıflandırma Teknikleri

Veri madenciliği alanında en sık kullanılan yöntemlerden birisi olan sınıflandırma, dağınık yapıya sahip verilerin sınıf niteliklerinin belirlenmesi sürecidir. Bu süreçte verilerin önceden belirlenen sınıflara atanması amaçlanmaktadır. Sınıfların belirlenmesi amacıyla veri tabanının bir parçası eğitim amacıyla kullanılmaktadır. Eğitim verisiyle yeni olası bir durum meydana geldiğinde nasıl karar verileceği belirlenmektedir. Bir tür öngörü modellemesi olan sınıflandırma tekniğinde etiketsiz olan verilerin etiketleri tahmin edilmektedir (Zaki ve Wong, 2003: 16). Algoritma

beraber kategorize edilebilen girdiler arasındaki benzerlikleri tanımlamaya çalıştığından *yoğunluk tahmini* olarak da adlandırılmaktadır (Marslan, 2009: 6).

2.4.2.1. Naive Bayes

Bu sınıflandırma algoritması, verilen bir öznitelik setinin ait olduğu etiketin belirlenmesinde Bayes Teoremi'ne dayanmaktadır. Bayes Teoremi aracılığıyla eğitim veri setinde yer alan her bir sınıf için olasılıklar ($X = \{f_1, f_2, \dots, f_n\}$) hesaplanmaktadır. Sınıflayıcı, en yüksek olasılığı veren sınıfı tahmin eden istatistiksel bir algoritmadır. x olarak seçilen bir örneğin i sınıfına ait olma ihtimali ($P(C_i \setminus x)$),

$$P(C_i \setminus x) = \frac{P(C_i)P(x|C_i)}{P(x)} \quad (2.1)$$

şeklinde hesaplanmaktadır. Bir n boyutlu uzayda m farklı sınıflarda bir örneğin olasılığı, x özelliklerinden bağımsız olarak dağıldığını ifade Naive varsayımı altında denklem 2.1'e göre yeniden yazılabilmektedir.

$$P(C_i \setminus x) = \frac{P(C_i)P(f_1|C_i)f_2|C_i \dots f_n|C_i)}{P(f_1, f_2, \dots, f_n)} \quad (2.2)$$

Her özelliğin koşullu olarak diğer tüm özelliklerden bağımsız olduğu varsayıldığında, tüm sınıflarda denklemde yer alan payda sabit kalacağından sadece payın kullanılması gerekmektedir. Böylece olasılığı en yüksek sınıf, sınıf etiketi olarak belirlenerek Naive Bayes olasılık modeli tahmin edilecektir (Singh, 2015: 3). Olasılık modeli, veri kümesinde yer alan farklı değişkenler arasındaki koşullu bağımsızlık varsayımına dayanmaktadır (Gov vd., 2009: 3). Stokastik makine öğrenmesi algoritması olan Naive Bayes, az sayıda ve dengesiz veri setlerinde yüksek doğruluk performansı ile yanıltıcı sonuçlar verebilmektedir.

2.4.2.2. Lojistik Regresyon


İstatistiksel bir sınıflandırma algoritması olan lojistik regresyon (LR), eğitim veri setinde yer alan örneklere dayalı bir sınıflandırma modeli oluşturmaktadır. Maksimum Entropi olarak da bilinen LR modeli sonucunda yeni örnekler, en yüksek olasılık değerine ait sınıfa atanmaktadır. Naive Bayes algoritmasından olasılık değerlerinin hesaplanması Bayes teorisine dayalıyken, lojistik regresyonda olasılık değeri direkt olarak parametreler üzerinden hesaplanmaktadır. Lojistik regresyon sınıflandırma algoritması Naive Bayes'in tersine, özellikler arasındaki ilişkiler hakkında $P(C_i \setminus x)$ tahmininin hesaplanmasında herhangi bir varsayımına dayanmamaktadır (Lee, 2004: 223).

$$P(C_i \setminus x) = \frac{1}{1 + \exp(-C_i \theta^T x)} \quad (2.3)$$

Burada, x kelime vektörünü ve C_i belirlenen sınıfa ait olup olmama durumunu, kelime vektörlerinin (θ) regresyon çarpanlarını oluşturan parametre vektörünü ifade etmektedir.

2.4.2.3. Yapay Sinir Ağları

İnsan beyin yapısının biyolojik sinir sisteminden esinlenilmesi sonucu oluşturulan bu sınıflandırıcı teknikte, örneklemin girdi değerlerinin işlenmesi sonucu sınıf etiketinin tahmin işlemi gerçekleştirilmektedir (Yıldırım Taşer, 2021: 185). YSA alanyazınında çeşitli algoritmalar olmakla birlikte bu tezde tek katmanlı algılayıcılar kullanılmıştır. Tek katmanlı YSA sınıflandırıcısı tek bir sinir ağı içererek girdi ve çıktı katmanından oluşmaktadır. YSA'da girdi katmanındaki bileşenlerin ağırlıkları belirlenerek, en uygun ağırlıkların keşfedilmesi prensibiyle modelin eğitilmesi sağlanmaktadır. Bu nedenle YSA'yı örneklerden öğrenme olarak tanımlamak mümkündür (Öztemel, 2006: 23).



Şekil 40: Tek Katmanlı Yapay Sinir Ağı

Kaynak: Hristev, R.M. (1998), The ANN Book [Elektronik Sürüm], GNU Public License, (Edition 1), Boston USA. s.:4.

Girdi ve çıktı katmanlarından oluşan ağda, her ağ bir veya daha fazla girdi ve çıktıya sahiptir. Çıktılar girdilere bağlanarak, bu bağlantılara ait ağırlık (w) mevcuttur. Ağlarda yer alan sürecin elemanlarının sıfırdan farklı olmasını önleyen eşik değerleri mevcut olup daima 1 değerini almaktadır. Ağırlıklandırılmış girdi değerlerinin eşik değeri (θ) ile toplanması sonucu aktivasyon fonksiyonundan geçmesi sonucu çıktıya ulaşmaktadır. YSA'nın diğer yöntemlerden temel farkı, bir veya daha fazla gizli katman kullanılması ve katmanda girdi değişkeninin özel bir fonksiyon yardımıyla dönüştürülmesidir. Bu gizli katman sayesinde doğrusal olmayan istatistiksel modellemede çok etkin bir çözüm sunulmaktadır (Ketrez ve Saldanlı, 2018:92).

BÖLÜM 3

KURAMSAL VE EKONOMETRİK ÇERÇEVE

Tezin üçüncü bölümünde kuramsal çerçeve kapsamında Gündem Belirleme Kuramı ve Yatırımcı Tanınmışlık Hipotezi üzerinde durulmaktadır. Ayrıca çalışmanın temelini oluşturan karma frekanslı verilerin modellenmesinde kullanılabilecek MIDAS regresyon ve makine öğrenmesi regresyon algoritmaları teorik olarak açıklanmaktadır.

3.1. Gündem Belirleme Kuramı

Bireylerin değerleri, odakları, öncelikleri ve algılarına katkıda bulunan ve etkileme potansiyeli olan kitle iletişim araçları, aynı zamanda bireylerin zihinsel gündemlerinde kendi görüşlerini oluşturması konusunda da oldukça etkilidir (Littlejohn ve Foss, 2009: 31). Bu noktada Gündem Belirleme Kuramı ile ilgili verilmesi uygun olacaktır. Kurama göre küresel olarak olup bitenler hakkında insanların bilgilendirilmesinde görev üstlenen kitle iletişim araçları aynı zamanda kamunun da fikrini belirlemesi nedeniyle merkez durumundadır. Gündem Belirleme Kuramı özünde, kamuoyunda kitle iletişim araçlarının gündem olarak belli bir konunun belirlenmesinin nasıl bir etkisinin olduğunun tartışılmasıdır. *“Kitle iletişim araçlarının, insanlığı ilgilendiren sorunlarla alakalı kamuoyunu bilgilendirmesi ve bu sorunlara dair konuların da kamu nezdinde bir önceliğinin olması fikrinin merkeze alınarak, kitle iletişim araçlarının haberleri sunuş biçimleriyle bazı konulara ağırlık verip, bazı konulara da ağırlık vermeyerek kamuoyunun gündemini belirlediği görüşüne dayanmaktadır”* (Işık, 2014: 82). Kitle iletişim araçları, kitlelerin bilgilendirilmesi ve gündemin takip edilmesinde başlıca bilgi edinim kaynaklarının başında gelmektedir (Casero-Ripolles, 2020: 1).

İlk olarak McCombs ve Shwa (1972) tarafından kullanılan Gündem Belirleme Kuramı terimi, kitle iletişim araçlarıyla öne sürülen bir konu ya da vurgunun bireyler tarafından gösterilen tepkisi ya da nitelikleri arasındaki ilişkiyi açıklamaktır (Littlejohn ve Foss, 2009: 3). “Gündem” kavramı, *“zamanın belirli bir noktasında önem derecesine göre dizilmiş konu ve olaylar listesi şeklinde görülen sıralama”* olarak tanımlanmaktadır. Bu nedenle *“dinamik etkileşim içinde olan konular bütünü”* olarak ifade edilmektedir (Yüksel 2001: 31). Bireyler açısından yalnızca öğrenmeyi değil aynı zamanda bir sorun ya da konunun önem derecesine dair çıkarımlarda bulunulması anlamına gelmektedir (Atabek, 1998: 155). Kuram en temel haliyle, *“bireylerin ne düşüneceği değil, ne hakkında düşüneceği”* üzerine kurulu olup bunu *“haberlerin sunuş biçimiyle”*

sağlamaktadır (Lilleker, 2013: 37). Bu doğrultuda; bireyler öncelikle medya haberleri, çevrelerinde gelişen olaylar, gerçekler vb. durumlar hakkında bir farkındalığa sahip olmaktadır. Akabinde farkındalığa sahip olunan durum hakkında daha fazla bilgi edinme ihtiyacı başlamaktadır. Bireylerin daha fazla bilgi edinme için kullandığı kaynaklar sonrasında edinilen bilgi doğrultusunda belirli davranışlar ya da davranış değişiklikleri ortaya çıkmaktadır (Kılıç, 2020: 94). Siyaset bilimci Bernard Cohend gündem belirlemede kitle iletişim araçlarının işlevine ilişkin fikirlerin gelişmesine önemli katkı sağlamıştır. Medyanın birey ve toplum üzerindeki etkilerini inceleyen akademisyenler için yeni bir dönem başlattığını söylemek mümkündür (Cohen, 1963: 87).

Ana akım medyanın gündem belirleme yeteneğinin doğası, yeni medyanın gelişimi sonucu değişim göstermektedir. Yeni medyanın gelişimiyle birlikte enformasyon akışını tersine çevirme potansiyeli geliştirmiştir (Sayre vd., 2010: 12-13). Yeni medya ortamı olan dijital medyanın yüksek kullanıcı potansiyeli sağlaması sonucu özellikle gündem belirleme açısından sosyal medyanın etkisi hissedilmektedir. Sosyal medyanın gündem belirleme üzerindeki etkisi ve hızı geleneksel medyanın önüne geçmektedir. Özellikle sosyal medya ağlarından olan Twitter platformunun kullanıcı görüşü ve duyarlılığı açısından benzersiz biçimde içgörü sağladığı gösterilmiştir (Pak ve Paroubek, 2010: 1321). Platform kullanıcılarının mesaj içerikleri; beğenilerini, düşüncelerini ve hoşlanmadıkları durumları ifade etmektedir. Grup halinde veya bireysel olarak derlenen duyarlılık, bu mesajların belirli teknikler yardımıyla çıkarılmasına olanak sağlamaktadır. Bu bilgilerin kullanıcı duygularının yakalanmasında, geleneksel yöntemler arasında yer alan ankette olduğu kadar tutarlı sonuçlar verdiği gösterilmiştir (Tumasjan vd., 2010). Geleneksel medya araçlarında kamu gündeminin belirlenmesi için bireyler arası etkileşime bağlı olarak belirli bir zaman geçmesi gerekmektedir. Ancak Twitter gibi anlık ve çok hızlı bir yapıya sahip platformların gündem belirlemede de çok daha hızlı olduğu görülmektedir. Bu nedenle medya gündemi ile Twitter gündeminin farklılaşması durumu ortaya çıkmaktadır. Çünkü platform ortamı bireylere izleyici olmanın yanı sıra birer üretici olma imkânı da sağlamaktadır. Anlık olarak iletişime girebilen bireyler, gündem belirleme süreci için ihtiyaç duyulan zaman miktarını da değiştirmektedir (Kılıç, 2020: 99-100). "*Çoğu insan ne hakkında konuşulacağına kararının verilmesinde en önemli, çoğu insan en fazla role sahiptir. Çoğu insan problemlerin nasıl çözüleceğine dair bu şekilde karar verir ve birbirine uyar*" (Dearing & Rogers, 1996: 2; akt. Yaşın, 2008: 6).

Medya finansal piyasalarla ilgili bilgi yayma ve baskın piyasa görüşünü belirlemede ve yansıtma medyanın güçlü bir araçtır (Davis, 2006: 605). Medya, yatırımcılar ve diğer piyasa katılımcıları açısından yorumlayıcı bir bağlam oluşturmaktadır. Böylece medya tarafından

sağlanan bilgiler, yatırımcı davranışında ortaya çıkan piyasa görüşleri ve kararlarının temeli olarak işlev görmektedir (Pollock ve Rindova, 2003: 640). Dolayısıyla finansal piyasalarda yer alan bilginin gerçekte nasıl işlendiğinin anlaşılmasında temel kaynaklardan birinin haber medyası olduğunu söylemek mümkündür. Ekonomi haber sağlayıcıları, bilginin yatırım kararına dönüşmesinde önemli rol oynamaktadır (Oberlechner ve Hocking, 2004: 409). Bu noktada medya ilgisinin alım-satım kararları üzerindeki etkisi Gündem Belirleme Kuramı ile yakından ilişkilidir. Finans piyasaları hakkındaki bilgilerin medya kanalları aracılığıyla bireylere aktarılacağı, bu durumda kitle alım-satım kararlarında etkileyici olduğu varsayılmaktadır. Son yıllarda yapılan araştırmalara bakıldığında, medyanın herhangi bir hisse senedine ölçüde ilgi gösterildiğinin yatırımcı alım-satım kararlarında etkili olduğunun öne sürüldüğü görülmektedir. Örneğin, herhangi bir hisse senedinin medya aracılığıyla gösterilen ilgisi ne kadar fazla ise fiyat hareketlerinin de aynı şekilde yüksek olduğu ifade edilmektedir (Strauss vd., 2016: 549). Gündem Belirleme Kuramı'na bakıldığında, medya aracılığı ile ele alınan konu ne kadar merkezi olursa ve gündemde tutulması sıklaşırsa, bireylerin o konuya ilişkin ilgi düzeyleri de artış eğilimindedir. Bu nedenle finansal piyasalar ve yatırım araçlarıyla ilgili medyanın önem verme düzeyinin artması, yatırımcı kararlarında etkili olma olasılığını da artırabilmektedir. Aynı zamanda haber içeriklerinin bireysel algı üzerinde olumlu ya da olumsuz şekillendirmeye neden olabileceği olasılığı söz konusudur (Strauss, 2017: 13).

Ekonomi içerikli haberlerin etki düzeylerinin araştırıldığı çalışmalara bakıldığında, olumsuz haberlerin artış gösterdiği dönemlerde bireylerin daha karamsar ekonomik algıya sahip olduğu görülmektedir. Aynı zamanda gerçek ekonomik göstergeler ile ilgili olumsuz haberler nedeniyle olumsuz algının etkisi olduğu da belirlenmiştir (Damstra ve Boukes, 2018: 5). Ancak ekonomi ve finansal piyasalarla ilgili haberlerin yatırımcı alım-satım kararlarındaki etkisinin incelenmesi sırasında haberlerin içerikleri ve özellikleri de göz ardı edilmemelidir. Çünkü bilgi alıcısının bilgiye tepkisinin karmaşık olduğu varsayılmaktadır. Alıcı tarafından algılanan bilginin önem düzeyi, alıcının tepkisiyle doğru orantılıdır. Dolayısıyla bilgiye dayalı alım-satım işlemlerinin ele alındığı davranış tahminlerinde uyarının pek çok boyutunun araştırılması gerekmektedir (Strauss vd., 2018: 1057). Davranışsal finans bağlamında bakıldığında; yatırımcıları alım-satım kararlarında rasyonel davranmadıkları, duygular, sosyal ruh halleri, sürü davranışı gibi pek çok davranıştan etkilendiği varsayılmaktadır (Strauss vd., 2017: 1058). Aynı zamanda rasyonel bireylerin de toplu olarak medya ve iletişim kaynaklarından etkilenmesi sonucu akılcı olmayan davranış gösterebilecekleri öne sürülmektedir (Davis, 2006: 621-622). Özellikle belirsizlik durumlarında bireylerin bilgi edinme ihtiyacının artması sonucu haber edinme ve tüketme şekilleri de etkilenmektedir. Örneğin pandemi döneminde, geleneksel kitle iletişim araçları ile

sosyal medya platformlarının bir arada kullanımı sonucu çoklu iletişim platformlarının bir arada kullanılması artış göstermiştir. Bu medya yakınsaması durumundan doğan geri bildirim dolaşımında da aynı derecede artış söz konusudur (Jenkins, 2004: 34). Gündem Belirleme Kuramı'na göre belirsizlik durumlarında kendini gösteren bir diğer süreç yönelim gereksinimidir. Bu gereksinim, bireylerin içerisinde buldukları durum hakkında gündemi takip etmek ve durumla ilgili bilgi alma ihtiyacının artmasına neden olmaktadır (Matthes, 2005: 432). Yatırımcı kararlarının incelenmesi amacı ile dikkate alınacak olan medya gündemi üzerine yapılacak olan araştırmalar yardımı ile piyasa/piyasaların ihtiyaç duyduğu durumların da belirlenmesi olanaklı gözükmektedir. Aynı zamanda uygulanacak ya da hâlihazırda uygulanan para politikalarında gerekli adımların atılmasında da ek veri kaynağı olarak değerlendirilebilecek kaynak sağlamaktadır.

“Küreselleşme politikalarında “yeni dünya düzeni” adıyla hedeflenen; küresel ölçekte homojen, finans alanında güçlü ve çok uluslu şirketlerin denetimiyle dünyayı tek bir pazar haline dönüştürmektir” (Gezgin, 2008: 23). Bu doğrultuda bilgi toplumu, dijital bilgi akışının hızlı ve yaygın olmasını, gecikmeleri ve coğrafi mesafeleri ortadan kaldırabilmesini sağlayacak bilgi odaklı bir ticaret ve finans sisteminin ürünü haline gelmiştir (Özçağlayan, 2008: 154). Geniş medya kapsamının sağlanması için yatırım faaliyetlerinin artması sonucu 2014 yılından bu yana para birimi değerinde de keskin artış eğilimi görülmektedir. Gündem Belirleme Kuramı bağlamına göre değerlendirildiğinde, medyanın özellikle son yıllarda kitlelere kripto para birimleri konusunu “vermiş” olduğunu ve daha fazla sonuç alınmasına neden olduğunu söylemek mümkündür (Benchlouch, 2020: 19). Gündem Belirleme Kuramı bağlamında alanyazına bakıldığında, sıklıkla kamu ve medya arasındaki ilişkilerde “konulara” yönelim olduğu dikkat çekmektedir. Yani belirlenen konuların medya içeriklerinin kamuoyu tarafından ne kadar dikkate alındığı ve yer edinmiş olduğunun yanı sıra nedensel bağlantıların zamanı ve yönüne bağlı olarak neden-etki ilişkilerini inceledikleri görülmektedir (Uscinski, 2009: 797). Medya ile kamu gündemi arasındaki yüksek korelasyonun belirlenmesinin ardından nedensel bağlantılar ve zaman dizisinin gösterilmesi gerekliliği doğmuştur. Dolayısıyla kamu gündemi ile medya içerikleri arasındaki bu yüksek korelasyonlu ilişkide belirleyicilerin hangileri olduğu ve yönünün ne olduğu Gündem Belirleme Kuramı bağlamında temel önerme niteliği taşımaktadır (Coleman vd., 2009: 148). Bu doğrultuda tez çalışmasında, bilgi toplumlarına dijital para birimleri hakkında “verilen” ve/veya toplumların kendi oluşturdukları “gündem” in, yeni olarak nitelendirilebilecek bu finansal sistemle olan ilişkisinin belirlenmesi Gündem Belirleme Kuramı bağlamında ele alınmıştır.

3.2. Yatırımcı Tanınmışlık Hipotezi

Finans ve sermaye piyasalarında bilginin elde edilmesi ve diğer ekonomik birimlere yayılması merkezi bir faaliyettir. Varlık Fiyatlama modellerine göre piyasaya gelen her türlü bilgi tüm yatırımcılar tarafından bilinmektedir. Fiyatların bilgi alındığı anda bilgi üzerinden hareket ettiği varsayılmaktadır. Bu basit bilgi yapısı ampirik varlık fiyatı davranışının tanımlanmasında yeterli olmayıp, hem bilginin niteliğine hem de zamana bağlılığı söz konusudur. Etkin piyasa hipotezinde, yatırımcıların karar alırken tüm pay senetlerinin tam geçmişine ulaşabildiği varsayılmaktadır. Ancak fiyat verilerinin erişilebilir olmaması ve analiz etmek için gerekli hesaplamaların yapılamaması gibi durumlar söz konusu olabilmektedir. Merton (1987) çalışmasında her yatırımcı için mevcut menkul kıymetlerin alt kümesini bildiği bir ortamda iki dönemlik sermaye piyasası dengesi modeli oluşturmuştur. Sınırlı bilgi durumunda denge varlık fiyatlarının yapısı üzerindeki etkileri araştırmıştır. Temel davranışsal varsayım, bir yatırımcının denge fiyatını bilmesi durumunda optimal portföyü oluşturmak için bunu kullanmasıdır. Dolayısıyla yatırımcıların yeterince bilgi sahibi olmaması durumunda, farkında oldukları pay senetlerine yatırım yaptıkları varsayımı üzerine kurulmuştur. Bu model aracılığıyla firmanın herhangi bir şey yapmadan da yatırımcı tabanını arttırmasının mümkün olduğu belirlenmiştir. Aynı zamanda kamuya açıklanan bilginin şekli yatırımcılar arasında ilgi uyandırmadıysa, bilginin açıklanış şeklinde değişikliğe gidilerek yatırımcı farkındalığı sağlamak mümkündür. Özetle modele göre rasyonel yatırımcıların hâkim olduğu piyasalarda anormal davranış gözlemlenmektedir.

Kurumsal ve bireysel yatırımcılar sadece farkında oldukları pay senetlerine yatırım yapma eğilimindedir. Yatırımcıların yeterince bilgi sahibi olmadan sadece farkında oldukları hisse senetlerine yatırım yaptıklarının varsayılması “Yatırımcı Tanınmışlık Hipotezi” olarak adlandırılmaktadır. Hipoteze göre yatırımcı, dikkatini çeken pay senedi için fiyat artışına sebep olmaktadır. Bunun sonucunda da yatırımcı ilgisinin artması yüksek işlem hacmi ve getiri yaratmaktadır (Merton, 1987:486). Etkin piyasa hipotezi varsayımı olan rasyonel yatırımcı davranışına eleştirel bakış açısı getiren davranışsal finansa göre yatırımcıların aldığı finansal kararlarda duygular önemli role sahiptir. Finansal piyasaya yeni bir bilgi gelmesi bile yatırımcı ilgisinin piyasayı etkileyeceği bu alandaki çalışmalar aracılığıyla gözlemlenmiştir. Pay senedi getirilerinin tahmin edilebilmesine yönelik gerçekleştirilen ilk araştırmalar Rastsal Yürüyüş Teorisi’ne ve Etkin Piyasalar Hipotezi’ne dayanmaktadır. Etkin Piyasalar Hipotezi’ne göre pay senedi fiyatları rastsal olarak oluşmaktadır. Bu nedenle de %50 doğruluk oranından daha yüksek bir oran ile tahmin edilememektedir (Bollen vd., 2011:1). Yatırımcı ilgisine odaklanan en eski makale “New York Stock Exchange Members” olup kamu psikolojisi üzerine yoğunlaşmıştır

(Drew vd., 1950). Bireysel yatırımcıların duyarlılığından kaynaklı yanlış fiyatlandırmadan sorumlu oldukları varsayımının, makaleyi takip eden 70 yılda tekrarlandığı ilgili alanyazında görülmektedir (Zweig, 1973; Lee vd., 1991; Nagel, 2005; Barberis ve Xiong, 2012; Da vd., 2015). Yatırımcı ilgisinin doğrudan ölçülememesi nedeniyle alanyazında bu alanda yapılan ilk çalışmalarda anket ve haber analizlerinin kullanıldığı bilinmektedir. Daha sonra yapılan çalışmalarda ise aktif yatırımcılara ait ilginin ölçülmesinde sosyal medya platformları ve arama motorlarına ait verilerin kullanımı başlamıştır.


Bir bireyin belirli bir davranışı gerçekleştirme konusundaki algılanan sosyal etkiyi ifade eden öznel norm, kripto para alanındaki kullanma niyeti üzerinde de etkilidir. Schaupp vd. (2022), kripto paralara olan özel normların değerlendirilmesinin (bireyin kendi değerlendirmesinin diğer bireyler tarafından da aynı değeri görmesinin) kripto para kullanım niyetini aynı derecede etkilediğini ifade etmişlerdir. Yatırımcıların çoğunluğunun bu davranışı gösterdiklerini gören araştırmacılar, sosyal medya aracılığıyla bireylerin etkilendiği yatırım modelini öğrenme şeklini araştırmaya başlamışlardır. Bahsedilen bu eğilim ise *sürü davranışı* olarak ele alınmaktadır. Karmaşık doğaya sahip olan kripto para birimlerinde yeni yatırımcılar, başkalarının yatırım yaptığını ve kar elde ettiğini görmediği sürece servetlerini riske atmak istememektedirler. Bouri vd. (2018), büyük ekonomik belirsizliğin olduğu kripto para piyasasında sürü davranışının yaygın olduğunu belirtmişlerdir. Alanyazına bakıldığında da, yatırımcıların etrafındakiler etkisiyle kripto para birimlerine yatırım yapmaya meyilli olduğu araştırmalarla desteklenmiştir (Veerasingam ve Teoh, 2022: 5). Bu doğrultuda tez çalışmasında, elde edilen bulguların Yatırımcı Tanınmışlık Hipotezi'ni destekleme durumu ve ilişkinin şeklinin doğru belirlenmesi sonucu yatırım kararlarına yön verme imkânları incelenecektir. Yatırımcılar bu bilgileri kullanarak yeni yatırım kararları alabilecek ve finansal piyasalarda etkinlik sağlayarak ekonomik verimliliğe katkı sağlayabilecektir.

3.3. Veri Zarflama Analizi

Fareli (1957) tarafından gerçekleştirilen üretken etkinlik çalışmasından sonra Charnes vd. (1978) tarafından gerçekleştirilen Veri Zarflama Analizi (VZA), etkinlik ölçümünde yaygın kullanıma sahip ampirik bir yöntemdir. Bu yöntem aracılığı ile her bir karar verme birimine (KVB) ait girdi/girdiler ile görel olarak en iyi performansı veren ve çıktılara dönüşümünü gözlemleyen etkinlik skorları elde edilmektedir (Hughes ve Yaisawarng, 2004: 410). Etkinlik skorlarının hesaplanma süreci "*matematiksel programlama yöntemlerini kullanan parametrik olmayan bir teknik*" özelliğindedir (Parkan ve Ming-Lu, 1999: 205). Girdi-çıkıtı arasında herhangi bir fonksiyonel bağlantı varsayımının olmaması nedeniyle VZA, parametrik olmayan yöntem

özelliği sayesinde uygulamada avantaj sağlamaktadır (Eroğlu ve Atasoy, 2006: 2). Böylece benzer türden karar birimlerine ait etkinlikler değerlendirilmektedir.

Alanyazında yaygın olarak kullanılan iki VZA modeli mevcuttur. Birincisi Charnes, Cooper ve Rhodes (1978) tarafından tanımlanan, ölçeğe göre sabit getiri varsayımı altında CCR modelidir. İkincisi Banker, Charnes ve Cooper (1984) tarafından tanımlanan, ölçeğe göre değişen getiri varsayımı altında BCC modelidir. Anlaşılacağı üzere BCC modelinin CCR modelinden temel farkı, ölçeğe göre getiriye ele alış tarzıdır. Model farklılığının yanı sıra VZA modellerinde odaklanma biçimine göre girdi (kaynakların muhafaza edilmesi) ve çıktı (çıktıların artırılması) odaklı olmak üzere farklılaşma söz konusudur (Bowlin, 1998: 8–15). CCR ve BCC modellerinde bu nedenlerden dolayı etkinlik sınır görüntüsü farklı olmaktadır. Bu şekilde 41’de görülmektedir.



Şekil 41: CCR ve BCC Modellerinde Etkinlik Sınır Görüntüsü

Kaynak: WANG Qia, CUI Jin-Chuan, (2010), “A Resource Allocation Mode Based on DEA Models and Elasticity Analysis”, The Ninth International Symposium on Operations Research and Its Applications (ISORA’10) Chengdu-Jiuzhaigou, China, August 19–23. s:170.

Etkinlik sınırı, en iyi performansı veren girdi ve çıktıların en verimli haliyle birbirine dönüştürüldüğü veri kümesinde yer alan ünitelerle oluşan sınırdır. Bu üniteler %100 verimliliğe sahiptir. Bu sınırda yer almayan her ünite %100 verimlilik altında bir verimliliğe sahiptir. Dolayısıyla etkinlik oranının (*fiili miktar/standart miktar*) 1 olması istenmektedir. Tek girdi ve tek çıktı olan bir etkinlik ölçümünde, CCR modelinin etkinlik sınır grafiği orjinden geçen bir doğrudur. Bu görüntü CCR modelinin *ölçeğe göre sabit getiri* varsayımından ileri gelmektedir. BCC modelinin etkinlik sınır grafiği ise parçalı doğrusal ve dışbükeydir. Bu görüntünün nedeni ise BCC modelinin *değişken getiri* varsayımından ileri gelmektedir. CCR modellerinde karar birimlerinin etkinlik sınırının üzerinde yer alması için hem teknik hem de ölçek etkinliğine sahip olmaları gerekmektedir (Okursoy ve Tezsürücü, 2014: 4). Banker ve Farrell (1957) tarafından CCR modelinde elde edilen teknik etkinliğin, ölçek etkinliği ile karışması nedeniyle teknik etkinliğin, ölçek ve saf teknik etkinlik olarak ikiye ayrılması gerektiğini belirlemiştir. Bu nedenle Banker, Charnes ve Cooper (1984) tarafından önerilen BCC modelinde ölçeğe göre değişen getiri varsayımı nedeniyle saf teknik etkinlik elde

edilebilmektedir. Daha esnek yapısı nedeniyle BCC modeli verimliliğin artmasını sağlamaktadır (Örkcü ve Doğan, 2015: 29). VZA modelinin oluşturulmasında çıktı ve girdilerin hangi birimler aracılığı ile belirlendiği önemlidir. Çıktılar, KVB'den elde edilen değerleri, girdiler ise çıktıların oluşumunda sahip olunan spesifik özellikleri ifade etmektedir. Dolayısıyla girdi ve çıktı seçimi amaca göre değişebilmektedir. Model kurma aşamasında ise çıktı ya da girdi odaklı olma durumu KVB'lerin etkinlik değerleri üzerinde etkilidir. Bu nedenle amaca yönelik seçim yapılması çalışma güvenilirliği açısından önem arz etmektedir. Girdi yönlü VZA modelinde, sınırlı çıktıyla en verimli üretimin sağlanması için kullanılacak en uygun girdinin belirlenmesi üzerinden hesaplama yapılırken, çıktı yönlü VZA modelinde sınırlı girdiyle en fazla ne kadar çıktı üretilebileceği üzerinden hesaplama yapılmaktadır (Özdemir ve Göktaş, 2019: 142). Model içerisinde çok fazla girdi ve çıktı olması durumunda VZA'nın ayrıştırma yeteneği düşmektedir. Her girdi ve çıktı sayısındaki artışta KVB sayısında da artış gerekmektedir. Dyson vd., (2001), girdi ve çıktı sayısı toplamının en az iki katı kadar KVB belirlenmesinin gerekliliğini vurgulamışlardır (Dyson vd., 2001: 248). Cooper vd. (2001) ise bu toplamın 3 katından daha fazla sayıda KVB olması gerektiğini ifade etmişlerdir (Cooper vd., 2001: 219). En temel haliyle, seçilen girdi sayısı m , çıktı sayısı ise n olmak üzere $m+n+1$ olması gerekmektedir (Ertuğrul ve Işık, 2008: 205). Ayrıca klasik bir VZA, negatif verilerle çalışılması sonucu çözümsüzlük (infeasibility) problemi yaratabileceğinden dikkat edilmesi gereken bir diğer husustur.

CCR ve BCC modelleri girdi ve çıktı yönlü olmak üzere uygulanabilmektedir. Çıktı yönlü CCR ve BCC modelleri, girdileri sabit tutarak çıktıların ne oranda artırılması gerektiğini incelemektedir. Girdi yönlü CCR ve BCC modelinde ise, belirli bir çıktı bileşimini üretebilmek için kullanılacak en uygun girdi bileşimini elde etmeyi amaçlamaktadır. Bu çalışmada, ölçeğe göre değişen getiri varsayımı altında saf teknik etkinliğin değerlendirilmesini olanak veren BCC modeli tercih edilmiştir (Depren, 2008: 39-44).

- *Girdi Yönlü BCC Zarflama Modeli*

Girdi yönlü BCC modeline göre girdi yönlü Zarflama Modeli formu verilmiştir. Model

$j = 1, \dots, n ; r = 1, \dots, p ; i = 1, \dots, m ; u_r \geq \varepsilon ; v_i \geq \varepsilon$ ve u_0 *kısıtsız* olmak üzere

$$E_k = \text{Max}(\sum_{r=1}^p u_r Y_{rk}) - u_0 \quad (3.1)$$

$$(\sum_{i=1}^m v_i X_{ik}) = 1 \quad (3.2)$$

$$(\sum_{r=1}^p u_r Y_{rj}) - (\sum_{i=1}^m v_i X_{ij}) - u_0 \leq 0 \quad (3.3)$$

olarak çözülür. Burada u_r , “k’inci karar birimiyle r’inci çıktıya verilen ağırlık”; v_i , “k’inci karar birimiyle i’inci girdiye verilen ağırlık”; Y_{rk} , “k’inci karar birimiyle üretilen r’inci çıktı”; X_{ik} ,

k'inci karar biriminde kullanılan i'inci girdi; Y_{rj} , "j'inci karar birimiyle üretilen r'inci çıktı"; X_{ij} , "j'inci karar biriminde kullanılan i'inci girdi"; ε , "0,00001 gibi yeterince küçük pozitif bir sayı" ve u_0 , "ölçeğe göre getirinin yönünü ifade eden değişken olarak tanımlanmaktadır. BCC modeli, CCR modelinden u_0 bulundurması açısından farklılaşmaktadır.

- *Çıktı Yönlü BCC Zarflama Modeli*

Çıktı yönlü BCC modeline göre girdi yönlü Zarflama Modeli formu verilmiştir. Model

$j = 1, \dots, n ; r = 1, \dots, p ; i = 1, \dots, m ; u_r \geq \varepsilon ; v_i \geq \varepsilon$ ve ρ_0 kısıtsız olmak üzere

$$E_k = \text{Max}(\sum_{i=1}^m v_i X_{ik}) - \rho_0 \quad (3.4)$$

$$(\sum_{r=1}^p u_r Y_{rk}) = 1 \quad (3.5)$$

$$(\sum_{r=1}^p u_r Y_{rj}) - (\sum_{i=1}^m v_i X_{ij}) + \rho_0 \leq 0 \quad (3.6)$$

olarak çözülür. Burada u_r , k'inci karar birimiyle r'inci çıktıya verilen ağırlık; v_i , k'inci karar birimiyle i'inci girdiye verilen ağırlık; Y_{rk} , k'inci karar birimiyle üretilen r'ninci çıktı; X_{ik} , k'inci karar biriminde kullanılan i'inci girdi; Y_{rj} , j'inci karar birimiyle üretilen r'ninci çıktı; X_{ij} , j'inci karar biriminde kullanılan i'inci girdi; ε , 0,00001 gibi yeterince küçük pozitif bir sayı ve ρ_0 , ölçeğe göre getirinin yönünü ifade eden değişkendir. Amaç fonksiyonunda E_k 'nin 1'e eşit olması, k karar biriminin etkin olduğu ifade etmektedir (Depren, 2008: 39-44).

Her ne kadar fonksiyonel varsayım olmasa da, aynı KVB için farklı girdi ve çıktı gruplarında etkinlik değerleri elde edilebileceği için süreçte nedensel olarak bağlı olan girdi/çıktı seçilmesi sürecin en iyi şekilde temsil edilen bileşiminin oluşturulmasında oldukça önemlidir.

3.4. Doğrusal Olmayan Granger Nedensellik Analizi

Çok değişkenli zaman serilerinin analizinde değişkenler arası bağımlılık yapısının incelenmesi önemli bir işlemdir. Tahmin modellerinde girdi olarak en önemli değişkenlerin belirlenmesinde korelasyon gibi standart ölçüler kullanılmaktadır. Ancak bu ölçüler simetrik olduğundan, zaman içerisinde bir değişkenden diğerine bilgi aktarımı hakkında yeterince veri sağlayamamaktadırlar. Bu nedenle de değişkenler arasında simetrik olmayan bağımlılıkların incelenmesi durumunda nedensellik ölçümü daha yeterli sonuçlar vermektedir. Alanyazına bakıldığında, zaman serisi alanında nedenselliğin temelini Granger nedenselliği (Granger, 1980) ve/veya Transfer entropisi (Scheiber, 2000) ölçülerine dayandığı görülmektedir. Granger nedenselliği, bir zaman serisi değişkeninin tahmin ve öngörü açısından faydalı bilgiler içermesi durumunun başka bir zaman serisi değişkenin öngörü başarısını arttırdığı ilkesine dayanmaktadır. Transfer entropisi ise bilgi

teorisine dayalı olup, koşullu Shannon entropisini kullanarak değişkenler arasındaki bilgi akışını ölçmektedir. Bu iki yaklaşım birbirinden her ne kadar farklı gözüksede Barnett vd. (2009), normal dağılıma sahip değişkenler için eşdeğer olduklarını göstermişlerdir. Aynı zamanda Transfer entropisi, değişkenler arasındaki ilişkileri istatistiksel bir model kullanarak modellemeyip, bunun yerine bilgi teorisine dayandırdığından Granger nedenselliğinin doğrusal olmayan bir alternatifi olarak kabul edilmektedir.

Doğrusal Granger nedensellik analizi, zaman serileri arasındaki nedenselliği test etmek için kullanılan klasik yöntemdir. Bir X değişkeninin başka bir Y değişkeninin nedeni olup olmadığını test etmek için; kendi gecikmelerini kullanarak Y'yi tahmin etmek ve X değişkeninin gecikmelerini kullanarak tahmin etmek ve son olarak bu iki durum arasındaki farkı değerlendirmektir. Değişkenler arasında bir sebep-sonuç ilişkisinin varlığının belirlenmesinde kullanılan ve ilişki olması durumunda bu ilişkinin yönünü belirleyen Granger nedensellik analizi değişkenler arasında doğrusal ilişki olması durumunda (3.7) ve (3.8) nolu denklemlerden yararlanılarak yapılmaktadır.

$$Model_1: Y_t = \alpha_0 + \sum_{i=1}^p \alpha_i Y_{t-i} + u_t \quad (3.7)$$

$$Model_2: Y_t = \alpha_0 + \sum_{i=1}^p \alpha_i Y_{t-i} + \sum_{i=1}^p \beta_i X_{t-i} + u_t \quad (3.8)$$

$Model_1$ 'de Y'yi tahmin (öngörmek) için Y'nin geçmiş değerlerini kullanırken, $Model_2$ 'de Y'yi tahmin etmek (öngörmek) için X ve Y'nin geçmiş değerleri kullanılmaktadır. Nedenselliğin belirlenmesi için $Model_1$ ve $Model_2$ hatalarının varyanslarının (başka bir teorik ifade ile MSE ölçütlerini) kullanılması gerekmektedir. Bu bilgiler elde edildiğinde Granger nedensellik indeksi (GCI),

$$GCI = \log \left(\frac{\sigma_1^2}{\sigma_2^2} \right) \quad (3.9)$$

şeklinde hesaplanabilir.

Uygulamada $Model_1$ hata varyansını σ_1^2 ve $Model_2$ 'de σ_2^2 ifade etmek üzere bu varyanslar arasındaki farkın istatistiksel anlamlılığının sınanması için F-test istatistiği

$$F = \frac{(RSS_1 - RSS_2)/p}{RSS_2/(n-2p-1)} \quad (3.10)$$

olarak hesaplanır. Burada RSS_1 ve $Model_2$ 'nin RSS_2 ifade etmek üzere n , gecikmeli değişkenlerin boyutudur. Testin hipotezleri

$$H_0: \forall i \in \{1, \dots, p\}, \beta_i = 0$$

$$H_1: \exists i \in \{1, \dots, p\}, \beta_i \neq 0$$

olarak ifade edilir. H_0 hipotezi, X 'in Y 'nin nedeni olmadığı ifade edilmekte olup, test istatistiği H_0 hipotezi altında serbestlik derecesi ($p, n-2p-1$) ile Fisher dağılımına sahiptir.

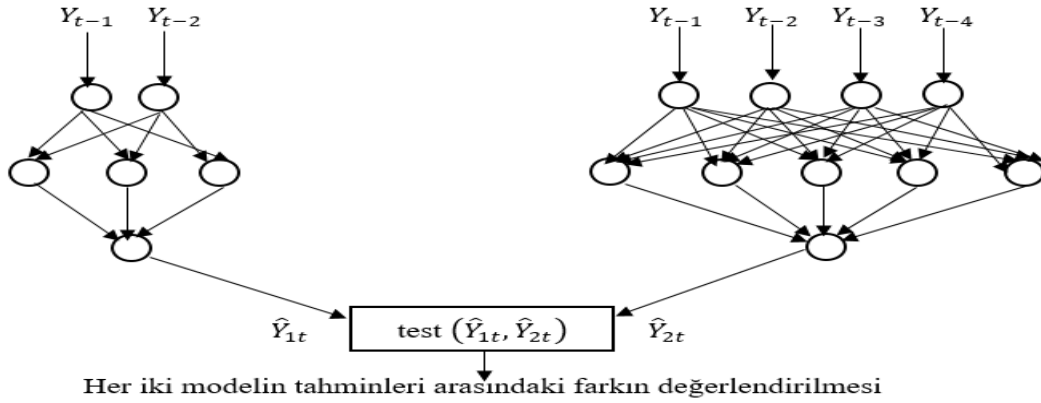
Doğrusal olmayan zaman serileri arasındaki nedensel ilişkinin araştırılmasında Yapay Sinir Ağları'ndan (YSA) yararlanılabilir. İncelenmesi hedeflenen çok sayıda zaman serisi olması durumunda ve tüm değişkenler arasındaki nedensel ilişkinin hesaplanması gerektiğinde, değişkenler arasındaki ilişkilerin zamanla değiştiği varsayımı altında klasik nedensellik ölçütlerinin temel formülleri uygulanabilir özellikte değildir. Öte yandan YSA'larda nedenselliklerin hesaplanması Granger testi ile karşılaştırıldığında yavaş olabilmekte, ancak zaman serileri, YSA'nın öğrenme özellikleri sayesinde model daha hızlı adapte olabilmektedir. Bahsedilen bu zorlukların üstesinden gelmek için, Hmamouche (2020) tarafından doğrusal olmayan nedensellik araştırmasında YSA kullanımının etkin sonuçlar verdiği ispatlanmıştır. Bu test, zaman serileri arasındaki doğrusal olmayan ilişkilerin incelenmesini ve ileri beslemeli sinir ağlarını kullanan Granger nedensellik testinin doğrusal olmayan bir uzantısını ortaya koymaktadır. Bu tezde kullanılacak olan Doğrusal olmayan Granger nedensellik testi VARNN (Vector Auto-Regressive Neural Network) modeli kullanılarak açıklanabilmektedir (Hmamouche, 2020: 22-23).

Hmamouche (2020), YSA ve VARNN modelini kullanarak Granger nedensellik testinin genişletilmiş bir uygulamasını önermektedir. Klasik Granger nedensellik testini içermekle birlikte doğrusal olmayan zaman serilerini ele almak için, yapay sinir ağı kullanılan bu testte, bilgi teorisine dayalı doğrusal olmayan bir nedensellik ölçüsü olarak da kabul edilen Transfer entropisi kullanılmaktadır. Kesikli değişkenler için klasik Shannon Transfer entropisi kullanılırken, sürekli değişkenler için k-en yakın komşular yaklaşımı kullanılmaktadır. Bilgi teorisinin babası olarak bilinen Shannon tarafından entropi, bir iletinin içerdiği bilgi miktarının ölçüsü olarak ifade edilmektedir (Shannon, 1948: 379). Bilgi iletimi konusunda gerçekleştirilen çalışmalar sonucu Shannon entropi formülünün ortaya çıkmasını sağlamıştır. 1928 yılında Ralph Hartley tarafından sorulan “Bilgi ölçülebilir mi?” sorusu sonucu $H = \log_s n$ formülü gelişmiştir. H bilgiyi; s her seçimdeki kullanılacak farklı sembol sayısını; logaritma ise bilgi miktarının sonucunu ifade etmektedir. Formül örneklendirilecek olursa; bir kişinin 0 ile 50 arasında tuttuğu bir sayının tahmin edilmesi için kaç adet “evet” ve “hayır” sorusu sorulması gerektiği düşünülebilir. “Sayı 1 mi?”, “Sayı 2 mi?”,... şeklinde sorular sorulabilecektir. Fakat bu durumda en kötü ihtimal 50. soruda cevabın bulunması olacaktır. Bu nedenle “sayı 25'ten küçük mü?” gibi bir soruyla olasılıkların yarısı indirgenebilmektedir. Buradan hareketle, sorulması gereken ortalama soru sayısının Hartley'in formülüne göre hesaplanması sonucu $\log_2 50 = 5,64$ olduğu görülmektedir. Dolayısıyla bilgi teorisinin zemininin oluşmasında Hartley'in geliştirdiği formül oldukça

önemlidir (Bahadır ve Türkmençalıkoğlu, 2021: 492). Entorpi, belli birimlerle ölçülebilen niceliksel bir büyüklüktür. Böylece bir rastsal sürecin olasılık yapısının bilinmesi durumunda o sürecin entropisinin sayısal olarak esapanması mümkündür. Bu noktada VARNN(p) modeli, bir hedef değişken olan Y'nin ve k tahmin değişkeni $\{Y_1, \dots, Y_k\}$ olmak üzere, Y'nin gelecekteki değerlerini tahmin etmek için değişkenlerin p önceki değerlerini ve hedef değişkenini (Y) hesaba katan çok katmanlı bir algılayıcı sinir ağı modelidir. İlk olarak, model, gecikme parametresine göre verileri bir denetimli öğrenme biçiminde yeniden düzenlemektedir. Ağı ağırlıklarını güncellemek için kullanılan optimizasyon algoritması, Stokastik Gradyan İniş (SGD) algoritmasına dayanmaktadır. Adam algoritması, SGD kullanırken öğrenme oranını güncellemek için de kullanılabilir.

$$Y_t = \Psi_{nn}(Y_{t-1}, \dots, Y_{t-p}, \dots, Y_{k(t-1)}, \dots, Y_{k(t-p)}) + u_t \quad (3.11)$$

Denklem 3.11'de Ψ_{nn} ağ işlevini ve u_t hata terimini ifade etmek üzere VARNN(p)'nin bütüncül fonksiyonu verilmiştir.



Şekil 42: Granger Nedensellik için YSA Model Gösterimi

X ve Y olmak üzere iki değişken olduğu varsayımı altında, Granger nedenselliğe benzer şekilde X'ten Y'ye nedenselliği test etmek için iki tahmin modeli dikkate alınmaktadır. İlki hedef zaman serisinin geçmiş değerlerini hesaba katmakta, ikincisi, hedef ve tahmin edici zaman serisinin geçmiş değerlerini almaktadır.

$$Model_1: Y_t = \Psi_{1nn}(Y_{t-1}, \dots, Y_{t-p}) + u_t \quad (3.12)$$

$$Model_2: Y_t = \Psi_{2nn}(Y_{t-1}, \dots, Y_{t-p}, X_{t-1}, \dots, X_{t-p}) + u_t \quad (3.13)$$

Ψ_{1nn} ve Ψ_{2nn} , VARNN modelini kullanan $Model_1$ ve $Model_2$ 'ye ait ağ işlevleridir. Bu iki model arasındaki fark, hata karelerinin toplamının karşılaştırılmasıyla değerlendirilmektedir. Temel hipotezi (X'in Y'nin nedeni olmadığı hipotez) incelemek için Fisher testi kullanılmaktadır.

Klasik testten farkı, iki VAR modeli yerine iki VARNN modelinin kullanılmasıdır. Bu nedenle, VARNN modellerinde VAR modelinden daha fazla parametre bulunduğundan Fisher test istatistiği,

$$F = \frac{(RSS_1 - RSS_2)/(d_2 - d_1)}{RSS_2/(n - d_2)} \quad (3.14)$$

olarak hesaplanmaktadır. Burada; d_1 ve d_2 tek değişkenli ve iki değişkenli modelin parametre sayısı olup, seçilen yapıya (katman ve nöron sayısı) bağlıdır. İki zaman arasındaki nedenselliğin yönünün belirlenmesi ve derecesinin sayısal olarak ölçülebilmesi için Schreiber (2000) tarafından yeni bir yöntem olarak transfer entropisi önerilmiştir. Ayrıca değişkenler arasındaki ilişkilerin değiştiği varsayıldığında, nedensellik ilişkisinin periyodik olarak ya da her değişimden sonra yeniden hesaplanması gerekmektedir. Bu durumda klasik nedensellik ölçütlerinin temel formülasyonları uygulanabilir nitelikte değildir. YSA ile nedensellik hesaplaması, Granger testi veya Transfer entropisi ile karşılaştırıldığında YSA'nın öğrenme özellikleri sayesinde model daha hızlı adapte olabilmektedir.

$$T_{X \rightarrow Y} = \sum_{Y_t, Y_t^q, X_t^p} P(Y_t, Y_t^q, X_t^p) \log \left(\frac{P(Y_t | Y_t^q, X_t^p)}{P(Y_t | Y_t^q)} \right) = I(Y_t; X_t^p, Y_t^q) \quad (3.15)$$

Burada $Z = X, Y, p, q$; $Z_t^l = (Z_{t-1}, \dots, Z_{t-l})$ X ve Y için zaman gecikme parametrelerini ifade etmektedir. P olasılığı ve I karşılıklı bilgiyi temsil etmekte olup, transfer entropisi, ilk olarak yalnızca Y'nin geçmiş değerlerinin kullanıldığı ve ikinci olarakta hem X hem de Y'nin dikkate alındığı iki koşullu entropi arasındaki fark olarak ifade edilebilir.

$$T_{X \rightarrow Y} = H(Y_t | (Y_{t-1}, \dots, Y_{t-q})) - H(Y_t | (Y_{t-1}, \dots, Y_{t-q}), (X_{t-1}, \dots, X_{t-q})) \quad (3.16)$$

Transfer entropisi ile elde edilen değerler normalleştirilmemiş olup, uygulamada nedenselliğinin ölçülmesi zordur. TE değerlerinin 0 ile 1 arasında normalleştirilmesi, aktarılan bilgi miktarlarının yorumlanmasını kolaylaştırmaktadır. Bir X değişkeninden bir Y değişkenine transfer entropisi, bir maksimum $H(Y_t | Y_t^m)$ değerine sahiptir. Böylece, normalleştirilmiş TE (NTE), TE'nin maksimumuna bölünerek elde edilebilmektedir.

$$NTE = \frac{H(Y_t | Y_t^m) - H(Y_t | Y_t^m, X_t^m)}{H(Y_t | Y_t^m)} \quad (3.17)$$

Alanyazına bakıldığında çalışmalarda genellikle doğrusal nedensellik analizi kullanıldığı görülmektedir. Değişkenlerin veri yaratma süreçleri ve değişkenler arası ilişkinin doğrusal olmamanın kuramsal olarak kabul edildiği durumlarda dahi genellikle doğrusal zaman serisi modellerinin kullanıldığı görülmektedir (Çinko, 2006: 24). Bunun nedeni, doğrusal olmamanın doğasının tam olarak bilinmemesi durumunda doğrusal modellerin doğrusal olmayan modellere

göre tutarlı sonuçlar ve hesaplama kolaylığı sağlamasıdır. Ancak değişkenlerin yaratma süreçlerinin ve ilişkilerin dinamiklerinin belirlenmesi ampirik sonuçları farklılaştırabilecek olması nedeni ile önem taşımaktadır. Gelişen bilgisayar ve yazılım teknolojileri sayesinde doğrusal olmayan yaklaşımların uygulanması ve geliştirilmesi mümkün olmaktadır. Bu noktada, sürekli gelişen iletişim teknolojileriyle ortaya çıkan ve belirli bir araştırma amacı ya da tasarımı olmaksızın sınırsız şekilde büyüyen organik verilerin yaratma sürecinin anlaşılması için uygun tekniklerin belirlenmesi ciddi önem taşımaktadır.

3.5. Markov Rejim Değişim Modeli

Doğrusallık kavramı ekonometride parametreler ve değişkenler açısından olmak üzere iki farklı şekilde ele alınmaktadır. Modelde yer alan parametrelerin üssünün 1 olması, diğer parametreler ile çarpılmaması ya da bölünmemesi, üs olarak yer almamaları parametreler açısından doğrusallığı ifade etmektedir. Bağımlı değişkenin koşullu beklenen değerinin bağımsız değişkenin doğrusal fonksiyonu olması ise doğrusallık kavramının değişkenler açısından ele alınışını ifade etmektedir. Değişkenlerin karesinin alınması veya birbiriyle çarpılması sonucu doğrusal olmayan ilişkiler üzerinde durulması gerekmektedir (Koç, 2008: 3).

Bir zaman serisinin davranışı, ortalaması, oynaklığı veya cari değerinin geçmiş değerlere bağlı olup olmaması açısından zamana göre değişim göstermektedir. Bu davranışın tüm zaman diliminde bir kez gerçekleşmesi “yapısal kırılma” olarak ifade edilirken, yeni bir davranışa dönüşme ve orijinal davranışına dönene dek farklılaşma yaşıyorsa “rejim değişimi” olarak tanımlanmaktadır (Brook, 2008: 451). Üstel otoregresif model (Haggan ve Ozaki, 1981), Eşik Otoregresif Model (Tsay, 1989), Markov Değişim Modeli (Hamilton, 1989) ve Yumuşak Geçişli Otoregresif Model (Teräsvirta, 1994), rejim değişim modelleri arasında en bilinenleridir (Akgül vd., 2007: 5-6). Belirtilen modellerin uygulanması için incelenen zaman serilerinin doğrusal olmayan yapı sergilemesi ve farklı doğrusal olmayan tiplerden birine uyması temel zorunluluktur (Koç, 2008: 1). Hamilton (1989, 1990) çalışmaları, Markov rejim değişim modellerinin temeli olarak kabul edilmektedir (Nikolaos-Marios, 2015: 9). Serilerin ilk farklarının doğrusal durağan süreçten ziyade doğrusal olmayan durağan süreci izlediği belirtilerek Markov Değişim ARIMA modelini ABD'nin büyüme oranları için iki mümkün durum olan daralma ve genişleme için modellenmesi denenmiştir (Hamilton, 1989: 357). Hamilton çalışmasından sonra rejim değişim modellerinin kullanımı yaygınlaşmış olup pek çok eklenti sonucu Markov Rejim Değişim modelleri geliştirilmiştir.

Stokastik süreci temsil eden markov zincirleri, gelecekteki durumun yalnızca mevcut duruma bağlı olduğunu ifade etmektedir. Dolayısıyla mevcut durumun nasıl elde edildiğine dair tam bilgi

sahibi olunamamaktadır (Nikolaos-Marios, 2015: 13). Markov Rejim Değişim modellerinde ele alınan serinin yapısındaki değişimin dikkate alınması ve olasılıksal çıkarım yapılması mümkün olmaktadır (Büyükyılmaz, 2015: 13). Hamilton (1989) tarafından geliştirilen modelde t ve $t-1$ dönemlerindeki rejimler arasındaki ilişkiler incelenmektedir.

$$Y_t = c + \phi y_{t-1} + \varepsilon_t \quad (3.18)$$

Y_t değişkeni olarak tanımlanan bir zaman serisi için birinci dereceden otoregresif model (3.18) için $\varepsilon_t \sim N(0, \sigma^2)$ ve $t = 1, 2, 3, \dots, T$ 'dir. Eğer t_0 zamanında Y_t serisinin ortalamasında anlamlı bir değişiklik olduğunun bilinmesi halinde Y_t serisini t_0 zamanında önce ve sonra olmak üzere iki ayrı denkleme ayırmak mümkündür.

$$Y_t = c_1 + \phi y_{t-1} + \varepsilon_t \quad , \quad t < t_0 \quad (3.19)$$

$$Y_t = c_2 + \phi y_{t-1} + \varepsilon_t \quad , \quad t > t_0 \quad (3.20)$$

Ancak iki ayrı denkleme ayrılması sonucu veri setinde küçülme ve modelde etkinlik kaybına neden olabilecektir (Türkmen, 2017: 112). Bu nedenle denklem 3.19 ve denklem 3.20'yi kapsayan ve veri kaybını engelleyen daha geniş bir modelin yazılması mümkündür (Hamilton, 2005: 1).

$$Y_t = c_{s_t} + \phi y_{t-1} + \varepsilon_t \quad (3.21)$$

Denklem 3.21'de yer alan ve s_t olarak ifade edilen durum veya rejim değişkeni, eğer Y_t serisi birinci rejimde bulunuyorsa $s_t = 1$ ve ikinci rejimde bulunuyorsa $s_t = 2$ değerini almaktadır. Ancak Markov Rejim Değişim modelinde s_t doğrudan gözlenememekte, yalnızca Y_t serisi gözlemlenebilmektedir (Bildirici vd., 2010: 75). Dolayısıyla Markov Rejim Değişim modelleri, markov zincirleri aracılığı ile rejimler arasındaki değişimlerin belirlenmesi ve doğrudan gözlemlenemeyen durum/rejim değişkeninin davranışının modellenmesinde kullanılmaktadır (Bildirici vd., 2010: 56). Rastsal ve tam sayı değeri alan bir değişken olarak tanımlanan s_t 'ye göre tanımlanan birinci dereceden Markov zinciri,

$$P(s_t = j | s_{t-1} = i, s_{t-2} = k, \dots, y_{t-1}, y_{t-2}, \dots) = P(s_t = j | s_{t-1} = i) = p_{ij} \quad (3.22)$$

şeklinde ifade edilmektedir. y_t serisi, c_1 ve c_2 kesim noktaları, ϕ otoregresif parametre ve p_{11} ile p_{22} iki aşamalı geçiş olasılıklarına bağlı olup, olasılık kurallarına göre açıklanabilmesi için σ^2 'nin normal dağılması gerekmektedir (Büyükyılmaz, 2015: 15).

$$Y_t = C_1 + \phi y_{t-1} + \varepsilon_t \quad (3.23)$$

$$Y_t = C_2 + \phi y_{t-1} + \varepsilon_t \quad (3.24)$$

Y_t serisinin AR(1) süreci olarak tanımlandığı denklem 3.23 üzerinden otoregresif bir modelin Markov Rejim Değişim Otoregresif modelle ilişkisi kurulabilmektedir. Zaman serisinin ortalamasını değiştirecek herhangi bir değişim olduğunda AR(1) süreci farklı bir kesim noktası ile ifade edilmelidir (3.24).

$$Y_t = \begin{cases} C_1 + \sum_{i=1}^p \phi_{1,i} Y_{t-i} + \varepsilon_{1t} & \text{eğer } s_t = 1, \\ C_2 + \sum_{i=2}^p \phi_{1,i} Y_{t-i} + \varepsilon_{2t} & \text{eğer } s_t = 2, \end{cases} \quad (3.25)$$

Denklem 3.23 ve 3.24'ten hareketle iki rejimli Y_t serisini denklem 3.25'te verildiği şekilde ifade etmek mümkündür (Tsay, 2006: 135).

$$P = \begin{bmatrix} P_{11} & P_{12} \\ P_{21} & P_{22} \end{bmatrix} \quad (3.26)$$

$$P_{11} = (S_t = 1 | S_{t-1} = 1) = p$$

$$P_{12} = (S_t = 2 | S_{t-1} = 1) = 1 - p$$

$$P_{21} = (S_t = 1 | S_{t-1} = 2) = q$$

$$P_{22} = (S_t = 2 | S_{t-1} = 2) = 1 - q$$

İki rejimli bir yapıya ait geçiş olasılıklarına göre (3.26) Y_t serisi için birinci rejimde kalma olasılığı p , ikinci rejimde kalma olasılığı $1-q$, birinci rejimden ikinci rejime geçiş olasılığı $1-p$ ve ikinci rejimden birinci rejime geçiş olasılığı q ile incelenmektedir. Toplamları bir e eşit olan ve negatif olmayan geçiş olasılıklarına göre birinci rejimde kalma süresi $\frac{1}{1-p_{11}}$ ve ikinci rejimde kalma süresi $\frac{1}{1-p_{22}}$ ise şeklinde hesaplanabilmektedir (Hamilton, 1989: 360).

$$P = \begin{bmatrix} p_{11} & \cdots & p_{N1} \\ \vdots & \ddots & \vdots \\ p_{1N} & \cdots & p_{NN} \end{bmatrix}$$

Denklem 3.22'de verilen sürecin $N \times N$ boyutlu geçiş matrisi gösteriminden hareketle, her satırda yer alan olasılıklar toplamı 1'e eşit ve $p_{ij} \geq 0$ özelliğinde olması gerekmektedir (Özdemir ve Akgül, 2015:358). Olasılık değerlerine göre elde edilen geçiş matrisini,

$$\begin{bmatrix} p_{11} & p_{12} \\ p_{21} & p_{22} \end{bmatrix}$$

şeklinde göstermek mümkündür. Matris için yukarıda ifade edilen özellikler nedeniyle $p_{i1} + p_{i2} = 1$ koşulunu sağlaması gerekmektedir.

$$Y_t = \mu_{s_t} + u_t, \quad u_t \sim iid(0, \sigma^2) \quad (3.27)$$

Markov Rejim Değişim Modelinin genel gösteriminden hareketle (3.27), rejimin sabit terime ve koşullu ortalamaya göre değişim olması durumunda model ikiye ayrılmaktadır.

$$Y_t = C_{s_t} + \phi Y_{t-1} + u_t \quad (3.28)$$

$$Y_t - \mu_{s_t} = \phi(Y_{t-1} - \mu_{s_{t-1}}) + u_t \quad (3.29)$$

Y_t 'nin sabit terimi rejimle birlikte değişim gösterdiğinde MSI modeli (3.28), ortalaması rejimle birlikte değişim gösterdiğinde ise MSM (3.29) modeli üzerinden ilerlenmektedir. Bu doğrultuda rejim “ m ” ve otoregresif süreç “ p ” olarak ifade edildiğinde MSIH(m)AR(p) modeli,

$$Y_t = C + \sum_{i=1}^p \phi_i Y_{t-i} + \varepsilon_t \quad (3.30)$$

şeklinde (Clements ve Krolzig, 1997: 14). Burada sabit terimleri ile durum vektörleri $[Y_1, Y_2, \dots, Y_t]$ şeklinde rejime bağlı olarak değişmektedir. Gözlemlenemeyen ayrı rejim değişkeni olan s_t 'ye bağlı olan $\varepsilon_t \sim NID(0, \sigma^2(s_t))$ şeklindedir. MSI ve MSM modelleri otoregresyon derecesinin sıfır olması halinde birbirine eşit olmaktadır. MSM modellerinde rejim değişimleri daha keskin, MSI modellerinde daha yumuşaktır (Bildirici vd., 2010: 76). Finansal zaman serilerinde rejim geçişleri genellikle daha yumuşak olduğundan rejimlerin birbirinden ayırt edilmesinde varyans önemli bir faktör olmaktadır. Gelecek fiyat beklentisinin kötümser seyirde olduğu bir ortamda (ayı piyasası), iyimser dönemlere göre oynaklıkta daha yüksek hareketlilik meydana gelmektedir (Koy, 2017: 77-78).

Markov Rejim Değişim modelinde yer alan parametrelerin tahmin sürecinde, log-olabilirlik fonksiyonu maksimize edilmektedir. Tahmin edilen parametreler aracılığıyla gözlenmemiş rejim değişkeni olan s_t için düzleştirilmiş ve filtrelenmiş olasılıkların bulunması amaçlanmaktadır (Özdemir ve Akgül, 2015: 370). Düzleştirilmiş olasılıkta, t zamanında rejimde bulunma olasılığının incelenmesi için tüm örneklem kullanılmaktadır. Filtrelenmiş olasılıkta ise t zamanında yalnızca t zamanına kadar olan bilgi kullanılmaktadır (Koç ve Akgül, 2013: 16).

3.6. Markov Rejim Değişimli Vektör Otoregresif Model (MS-VAR)

Markov Rejim Değişim modelleri zaman serileri için Hamilton (1988) ve Hamilton (1989) çalışmaları ile tanıtıldıktan sonra temel katkı Krolzig (1997) tarafından gerçekleştirilmiştir (Özdemir ve Akgül, 2015: 369). Krolzig (1997), çok değişkenli olarak kullanılan Markov Rejim Değişimli Vektör Otoregresif modelleri ortaya koymuştur. Kırılmaların varlığında makroekonomik dalgalanmaların karakterize edilmesinde MS-VAR modelinin geliştirilmesi sonucu alanyazına önemli katkıda bulunmuşlardır. MS-VAR modeli, VAR sürecinin parametrelerinin rejim değişikliğiyle birlikte değişmesini mümkün kılmaktadır (Krolzig, 1998:

3). Tablo 43'te MS-VAR modellerinin sınıflandırılması verilmiştir. MS-VAR modelleri, ortalama ya da sabit terimin rejime bağlı olarak değişim göstermesine göre iki ana sınıfa ayrılmaktadır.

Tablo 43: MS-VAR Modelleri

		MSM	MSI		
		μ değişir	μ sabit	c değişir	c sabit
A_j sabit	\sum sabit	MSM-VAR	Doğrusal MVAR	MSI-VAR	Doğrusal VAR
	\sum değişir	MSMH-VAR	MSH-MVAR	MSIH-VAR	MSH-VAR
A_j değişir	\sum sabit	MSMA-VAR	MSA-MVAR	MSIA-VAR	MSA-VAR
	\sum değişir	MSMAH-VAR	MSAH-MVAR	MSIAH-VAR	MSAH-VAR

Kaynak: Krolzig, H.M., (1998), "Econometric Modelling of Markov-Switching Vector Autoregressions using MSVAR for Ox", *Institute of Economics and Statistics and Nuffield College, Oxford*. December 15. s.:6.

Tablo 43'te "M" Markov değişim ortalamasını, "I" Markov değişim sabitini, "A" Markov değişim otoregresif parametresini ve "H" Markov değişim değişen varyansı ifade etmektedir. modelde hata teriminde değişen varyans problemi ya da otoregresif parametrelerin rejimlere göre değişmesi durumuna göre alt sınıflar oluşmaktadır. MS-VAR modelinin en genel gösterimi aşağıda verilmiştir.

$$y_t = c(s_t) + [A_1(s_t)y_{t-1} + \dots + A_p(s_t)y_{t-p}] + u_t \quad (3.31)$$

Rejimi belirleyen unsurun ortalama (M) olması durumunda model (denklem 3.32) MSM(M)-VAR(q) olarak ifade edilmektedir. Sabitin (v) rejimler arası değiştiği model (denklem 3.33) ise MSI(M)-VAR(q) olarak ifade edilmektedir.

$$y_t = \mu(s_t) + A_1(s_t)(y_{t-1} - \mu(s_{t-1})) + \dots + A_p(s_t)(y_{t-p} - \mu(s_{t-p})) + u_t \quad (3.32)$$

$$u_t \sim NID(0, \Sigma(s_t))$$

$$y_t = c(s_t) + A_1(s_t)y_{t-1} + \dots + A_p(s_t)y_{t-p} + u_t \quad (3.33)$$

Modellerde yer alan $\mu(s_t)$, $c(s_t)$, $A_1(s_t)$, $A_2(s_t)$, ..., $A_p(s_t)$, $\Sigma(s_t)$ gerçekleşen rejim s_t üzerine μ , v , A_1 , A_2 , ..., A_p , Σ parametrelerine bağımlılığı ifade eden parametre değişim fonksiyonlarıdır. MS-VAR modellerinde MS-AR modellerinde olduğu şekilde $\mu(s_t)$, ortalamadaki değişimin gözlemlenen zaman serisinde ani sıçramaya; $c(s_t)$, sabit terimdeki değişime karşılık u_t beyaz gürültü (white noise) değişimine olan cevap kadardır (Krolzig, 1998: 8). Rejimle birlikte tüm parametrelerin değiştiği MSIH-VAR modelinin genel formu aşağıda verilmiştir (Droumaguet, 2012: 5).

$$y_t = \begin{cases} v_{01} + \sum_{i=1}^p A_{i1}y_{t-i} + \sigma_1^2 u_t \\ \vdots \\ v_{0M} + \sum_{i=1}^p A_{iM}y_{t-i} + \sigma_M^2 u_t \end{cases}, \quad u_t \sim NID(0, I_K) \quad (3.34)$$

Modelde, rejime göre değişen sabit terim (v_{01}, \dots, v_{0M}) , değişen varyans kovaryans matrisi $(\sigma_1^2, \dots, \sigma_M^2)$ ve otoregresif katsayılar (A_{i1}, \dots, A_{iM}) şeklinde olup otoregresif parametrelerdeki değişim tarafından rejime bağlı olarak etki tepki analizinde kullanılmaktadır. MS-VAR modelinde bahsedilen bu parametrelerin sayısının fazla olması ve yorumlanma zorluğu nedeniyle etki tepki analizleri kullanılmaktadır. Ancak geleneksel VAR modelinden farklı olarak her rejim için ayrı ayrı etki tepki analizlerinin gerçekleştirilmesi gerekmektedir. Ehrmann vd., (2001, 2003), çalışmalarında MS-VAR modelinin rejime bağlı etki tepki fonksiyonu kavramını ortaya koymuşlardır. Bu fonksiyonlar, modelin rejim içerisindeki hata terimiyle endojen değişkenler arasındaki ilişkiyi ortaya koymaktadır. Farklı rejimlerdeki şoklara karşılık her bir değişkenin tepkisini ifade eden bu fonksiyonlar, hata terimlerine uygulanan bir standart sapmalı şoka karşılık elde edilmektedir (Fujiwara, 2004: 10).

$$\left. \frac{\partial E y_{t+h}}{\partial u_{k,t}} \right|_{s_t=\dots=s_{t+h}=i} = \theta_{ki,h} \quad h \geq 0 \quad (3.35)$$

Etki tepki fonksiyonunda (denklem 3.35) rejim i 'ye koşullu t zamandaki k 'inci hatanın bir standart sapmalı şoka karşılık $t+h$ zamanındaki endojen değişkenlerin tepkisi $\theta_{ki,1}, \dots, \theta_{ki,h}$ serisi aracılığıyla gösterilmektedir (Ehrmann vd., 2003: 297-298). MS-VAR modelleri için geliştirilmiş etki tepki analizi ise Krolzig ve Toro (1999) ve Krolzig (2006) tarafından geliştirilmiştir. Krolzig (2006) çalışmasında, sürecin tüm geçmiş değerler yerine yalnızca y_t ve u_t 'nin cari değerlerine bağlı olduğunu ifade etmiştir. Aynı zamanda Ehrmann vd. (2001, 2003) çalışmalarını da rejim değişim durumunda Markov özelliğinin ihlal edilmesi yönünden eleştirmiştir. Krolzig'e göre herhangi bir h periyodundaki şoka karşılık sistemin verdiği tepkiler geliştirilmiş etki tepki analiziyle aşağıda verilmiştir.

$$IR_{\nabla u}(h) = E[y_{t+h} | \xi_t, u_t + \nabla u; Y_{t-1}] - E[y_{t+h} | \xi_t, u_t; Y_{t-1}] \quad (3.36)$$

Denklem 3.36'da yer alan ∇u , t zamanında oluşan şoku ifade etmek üzere,

$$IR_{\nabla u}(h) = \frac{\partial E[y_{t+h} | \xi_t, u_t; Y_{t-1}]}{\partial u_{kt}} \quad (3.37)$$

denklem 3.37'den de görüldüğü üzere tepkiler şokun işareti ve büyüklüğüyle orantılıdır.

$$IR_{\nabla \xi}(h) = E[y_{t+h} | \xi_t + \nabla \xi, u_t; Y_{t-1}] - E[y_{t+h} | \xi_t, u_t; Y_{t-1}] \quad (3.38)$$

Rejimlerdeki değişimlere verilen tepkiler geliştirilmiş etki tepki kavramıyla ele alınmaktadır. Bunu ifade eden denklem 3.38'de yer alan $\nabla \xi$, t zamanında meydana gelen rejimdeki değişimi göstermektedir (Krolzig, 2006: 3).

3.7. Organik Veri

Bilgi iletişim teknolojilerinin, özellikle de veri analitiğinin kapasitesinin hızla artması sonucu sosyal bilim alanındaki araştırmacılar açısından veri toplamak, işlemek ve analiz etmek giderek karmaşık yöntemleri gerektirmektedir. Bunun nedeni, farklı platformlar aracılığı ile toplanabilen ayrı veri parçalarının, hiçbir orijinal veri kümesinin yapamadığı soruları yanıtlama yeteneğine sahip daha büyük veri kümeleri karşısında yetersiz kalmasıdır (Murphy vd., 2013: 16). Kullanılan araştırma yöntemlerinin karmaşıklığı göz önüne alındığında, çalışmada üretilen bulguların sağlam dayanak noktası olması gerekmektedir. Sosyal bilimler alanında genel olarak *organik veriler* kullanılan çalışmalarda verinin sürecinin dikkate alınmadığı söylenebilir. Organik veri terimi evrensel olarak kabul edilmiş olsa da kesin bir tanımı henüz bulunmamaktadır. Terimin en genel hatlarıyla içeriği; açık bir araştırma tasarımından sonra toplanmayan, ancak belgelenen verilere atıfta bulunduğu yönündedir. Teknolojik cihazlardan, mobil uygulamalardan veya çevrimiçi sosyal ağlardan gelen veriler gibi insan faaliyetlerinin doğal "*dijital ayak izlerini*" yakalayan bir veri türüdür (Xu vd., 2020: 1259-1261). Araştırmacıların organik verilerin kullanımıyla ilgili potansiyel sorunları tanıması ve öngörmesi önemlidir. Belirli organik veri biçimleri ve geleneksel olarak tasarlanmış veriler bazı boyutlarda benzer olabilir ancak yaratma süreçlerinin doğası gereği farklılık göstermektedirler. Örneğin, Türkiye Nüfus Sayım verileri, kurumsal e-posta izleri, Twitter verileri hiçbir özgün araştırma çalışması için üretilmediğinden veri oluşturma amacı boyutunda benzeşmektedir. Aynı zamanda hacimsel olarak değerlendirildiğinde de benzer özellik taşıyabilmektedirler. Farklı boyutlardaki çeşitli veri türleri arasındaki benzerlikleri ve ayrımları anlamak önemlidir. Çünkü araştırma uygulamalarını yönlendiren, veri türünden daha çok bu boyutlardır. Örneğin, girdi verilerinin anahtar sözcüklerle veya arama kalıplarıyla filtrelenmesine ilişkin araştırma uygulamaları, genellikle büyük hacimli girdi verileri tarafından meydana gelmektedir. Hangi özelliklerin hangi boyutlarda hangi araştırma uygulamalarına yön verdiğini doğru bir şekilde anlamak, ortak geçerlilik problemlerinin daha iyi tanımlanmasına yardımcı olacak ve çözümleri birden çok veri biçimine uygulanabilir hale getirecektir. Organik veriler, kullanılacağı araştırma alanındaki eğilimlerin belirlenmesi ve farkındalığın artırılmasında pragmatik bir yaklaşımdır. Geleneksel deneylerden veya anket tekniklerinden farklı yaklaşımlarla incelenen organik verilerde gözlemlenen modelin altında yatan "*doğru model*" veya veri yaratma sürecinin incelenmesinde kullanılacak olan model geleneksel çalışmalarla karşılaştırıldığında, organik veriler için veri yaratma sürecinin daha opak olduğunu söylemek mümkündür. Bunun nedeni, organik verilerin genellikle araştırmacıların yanı sıra çalışma katılımcılarının veya üçüncü tarafların davranışlarından veya kararlarından etkilenmesidir. Bu tür davranışlar ve/veya kararlar genellikle araştırmacılar tarafından bilinmemekte ve hatta gözlemlenmemektedir (Ott, Cardie ve

Hancock, 2012: 2). Veri kazıma (data scraping) sonucu elde edilebilen organik verilerin incelenmesinde duygu analizi gibi çeşitli analiz teknikleri kullanılabilir. Twitter gibi platformlardan elde edilen verilerin zaman aralıklarının düzensiz olması nedeniyle, duygu analizinde kullanılan makine öğrenimi algoritmaları, sınıflandırma işlemi açısından her ne kadar başarılı sonuçlar verebilse de, ekonometrik modelleme aşamasında araştırmacılar bir takım problemler ile karşılaşmaktadır. Organik veriler doğası gereği düzensiz bir yaratma sürecine sahiptir. Düzensiz aralıklı zaman serileri üzerine alanyazın sayısı az olup tahmin ve çıkarım yapmak için varolan yöntemler de yeterli değildir. Özellikle iletişim teknolojileri aracılığı ile elde edilen organik verilerin araştırılması hedeflenen alanda yer alan ve incelenmesi hedeflenen diğer değişkenler ile ilişkisinin incelenmesinde zaman aralıklarını görmezden gelmek ve verilere düzenliymiş gibi davranmak yaygın bir uygulamadır. Bu, yanlış tahminlere yol açan önemli bir sapmayı meydana getirebilmektedir. Organik verilerin farklı değişkenlerle ilişkisinin incelenmesinde değişkenleri aynı frekansa indirgeme yaklaşımı, özellikle yüksek frekanslı verilerde yer alan bilgilerin, toplulaştırma sonucunda kaybolmasına veya farklı bir dağılıma dönüşmesine neden olmaktadır (Marcellino, 1999: 129). Bu sorunun ortadan kaldırılması amacıyla Ghysels, Santa-Clara ve Valkanov (2004) tarafından, yüksek frekanslı serilere dönüşüm uygulanmadan kendi frekansları ile analize katılarak farklı frekanslı veriler ile bir arada kullanılmasına olanak sağlayan MIDAS yaklaşımı geliştirilmiştir.

3.8. Düzensiz Zaman Serileri

Düzensiz zaman serisi verileri, özellikle yapılandırılmamış verilerde sürekli olarak gündeme gelmekte ve giderek yaygınlaşmaktadır. İletişim ağlarının gelişimiyle birlikte sosyal ağlardan elde edilen veri hacminin yüksek ivmesi nedeniyle oluşan yapılandırılmamış verilerdeki düzensizlikte aynı oranda artış göstermektedir. Düzensiz veriler sonucu ortaya çıkan eksik değerler, verilerin sınıflandırma ve tahmin edilmesinde klasik yaklaşımları kullanışsız hatta geçersiz kılmaktadır. Çoğu zaman, bu zaman serisi verilerini işlemek için kullanılan geleneksel yöntemler, yanlılığa neden olmakta ve veri yaratma süreci ile ilgili güçlü varsayımlara gerek duyulmaktadır. Bu da zayıf model tahminlerine yol açabilmektedir.

Zaman Damgası

(Timestamps)

T (Saniye):

t_1	t_2	t_3	t_4	t_5	t_6	t_7	t_8	t_9	t_{10}
0	60	120	180	240	300	360	420	480	540

Özellik Değişkenleri

$x_j^1 f(60)$	100	105	108	112	115	110	108	101	99	95
$x_j^2 f(240)$	0.5				0.6				0.4	
$x_j^3 f(120)$	3		5		7		10		15	
\vdots										
$x_j^n f(RND)$	10		9						12	

Eksik Göstergeler

m_j^1	1	1	1	1	1	1	1	1	1	1
m_j^2	1	0	0	0	1	0	0	0	1	0
m_j^3	1	0	1	0	1	0	1	0	1	0
\vdots										
m_j^n	1	0	1	0	0	0	0	0	1	0

Zaman Aralıkları

δ_1	δ_2	δ_3	δ_4	δ_5	δ_6	δ_7	δ_8	δ_9	δ_{10}
0	60	60	60	60	60	60	60	60	60
0	60	120	180	240	60	120	180	240	60
0	60	120	60	120	60	120	60	120	60
\vdots									
0	60	120	60	120	180	240	300	360	60

Şekil 43: Düzensiz Çok Değişkenli Zaman Serisi

Kaynak: Weerakody, P.B., Wong, K.W., Wang, G. & Ela, W. (2021), “A Review of Irregular Time Series Data Handling With Gated Recurrent Neural Networks”, *Neurocomputing*, 441: 161-178.

Şekil 43, düzensiz çok değişkenli zaman serisi verilerinin bir örneğini ve bununla ilişkili zaman aralıkları ile eksik verileri göstermektedir. x_{ij} , özellikleri $i \in \{1, 2, 3, \dots, n\}$; gözlemler $j \in \{1, 2, 3, \dots, 10\}$ ve örnekleme frekansı (f). m_j^i eksik göstergeleri ifade etmek üzere, burada x_{ij} gözlemlenirse $m_j^i = 1$ ve x_{ij} eksikse $m_j^i = 0$ anlamına gelmektedir. δ_{ij} ise x_{ij} ve x_{ik} arasındaki zaman aralığına karşılık gelirken, k, j 'inci gözlemden önceki son gerçek gözlemdir.

Zaman serisi yaklaşımlarında eksik veri ile düzensiz veri sıklıkla birbiri yerine kullanılmaktadır. Ancak veri düzensizliğinin nedeni ya da nedenlerinin kesin olarak bilinmemesi durumunda eksik veriler genellikle sabit bir aralık örnek uzayına göre tanımlanmaktadır.

Yayın Tarihi
2020-05-13 13:53:13
2020-05-13 14:33:13
2020-05-13 14:48:51
2020-05-13 15:02:15
2020-05-13 16:35:29
2020-05-13 18:47:28
2020-05-13 18:48:06
2020-05-13 19:26:43
2020-05-13 19:28:23
2020-05-13 20:07:45
2020-05-13 20:31:03
2020-05-13 21:27:40
2020-05-13 21:53:47
2020-05-13 22:01:36

Şekil 44: Düzensiz Zaman Serisi - Twitter

Sosyal medya verileri örneğinden ilerlenecek olursa, düzensiz olarak örneklenen bir değişken durumunda bir beklenen örnekleme frekansı olmayabilir. Şekil 44'te görüldüğü üzere, sabit bir frekans aralığı mevcut değildir. Çalışma veri setinde daha yüksek hacimli paylaşımlar olmakla birlikte neredeyse saniyelik düzensizlik söz konusudur. Bu nedenle, beklenen bir değer ne zaman “eksik” olduğunu bilmek her zaman mümkün olmamaktadır. Finansal alım satım işlemleri gibi yüksek frekanslı veriler söz konusu olduğunda, birden fazla hisse senedine ilişkin alım

satımların nadiren aynı anda gerçekleştiği ve alım satım işlemlerinin bir saniyenin altında gerçekleştiği göz önüne alındığında, eksik verilerin yüzdesi son derece yüksek olacaktır. Büyüklükleri genellikle keyfi zaman uzunluklarına, örnekleme sıklığına veya ilgili değişkenlerin periyodikliğine göre görece uzunluklara dayalı olarak kategorize edilmektedir. Bu kategorize etme işlemi vasıtasıyla, farklı frekanslı zaman serisi verilerinin modellenmesi için MIDAS regresyon yöntemlerini kullanmak mümkündür. Ayrıca derin öğrenme ve makine öğrenmesi gibi alternatif yöntemlerin aynı zamanda verilerin doğrusal olmayan yapılarını dikkate alması nedeniyle başarılı öngörüler sağlayabileceğini söylemek mümkündür. Özellikle yüksek frekanslı doğrusal olmayan öngörülerin elde edilmesinde yapay zekâ sistemlerinin kullanımı giderek artış göstermektedir (Lahmiri ve Bekiros, 2019: 39).

3.9. Karma Frekans

Klasik zaman serisi regresyon modellerinin tanımlanması ve tahmin edilmesi için hem bağımlı hem de bağımsız değişkenlerin aynı frekansa sahip olması gerekmektedir. Gerçek hayatta özellikle ekonomik göstergeler tipik olarak aylık, çeyreklik ve finansal göstergeler ise haftalık, günlük olarak bulunmaktadır (Cont, 2010: 1782). Örneğin, incelenmesi hedeflenen bağımlı değişkenin haftalık frekansa sahip olması durumunda bağımsız değişken ya da değişkenlerinde haftalık frekansta ele alınması gerekmektedir. Ancak özellikle makroekonomik veriler farklı zaman aralıklarında farklı frekanslarda yayınlanabilmektedir. Bu durum analiz aşamasında ciddi sorunlara yol açabilmektedir. Sorunun giderilmesinde *toplulaştırma yöntemi* sıklıkla kullanılmaktadır. Uygulama aşamasında farklı frekansa sahip veriler aynı model içerisine alınmadan önce yüksek frekanslı olan verilere düşük frekanslara göre dönüştürme işlemi yapılmaktadır (Armesto ve Engemann, 2010: 521). Örneğin, standart bir yaklaşımda aylık makroekonomik bir veri inceleneceğinde günlük frekansa sahip bir finansal veri ortalama alma yöntemi aracılığı ile aylık frekansa dönüştürülmektedir. Bu dönüşüm nedeniyle elde edilen tahmin sonuçlarının etkinliği sorgulanır hale gelmektedir. Klasik En Küçük Kareler yöntemi aracılığıyla değişkenler arasındaki ilişkinin incelenmesi halinde kullanılabilir dönem aralığı en az sayıda gözleme sahip olan değişkenin örneklemeyle sınırlı olmaktadır. Granger (1988), toplulaştırılmış değişkenden tüm bilginin elde edilememesinden kaynaklı öngörü performansının kaybedileceğini ispatlamıştır. Dolayısıyla verilerdeki toplulaştırma işlemi, elde edilecek tahminlerin istatistiksel olarak sağlam ve aynı zamanda etkin olmamasına neden olabilmektedir (Ghysels ve Kourtellos, 2010: 12).

Farklı frekansların aynı frekansa indirgenmesinde toplulaştırma işleminin yanı sıra sıklıkla kullanılan diğer bir yöntem ise eksik değer atama işlemidir. Eksik verilerin bulunduğu değişkenin

etkilendiği faktörlerin belirlenmesi ve bu faktörler aracılığıyla verinin tamamlanmasında sıklıkla Dinamik Faktör Modeli Kalman Filtresi kullanılmaktadır. Kalman Filtresi aracılığı ile gerçekleştirilen bu işlemde hem yüksek hem de düşük frekanslı verilerin geçmiş değerlerine gereksinim duyulmaktadır. Dolayısıyla çok sayıda parametre, denklem, uzay dinamikleri ve hatalarına dair bilgi sahibi olunması gerekmektedir. Aynı zamanda değişkenle ilgili yeni bir bilgi olması durumunda belirlenen faktörlerde güncelleme yapılması gerekmektedir (Andreou ve Ghysels, 2010: 23). Bu noktada Ghysels vd. (2004) tarafından, bahsedilen gereksinimlerin olmadığı ve açıklayıcı değişken ya da değişkenlerin dinamik olarak izlenmesine olanak veren MIDAS regresyon yöntemi geliştirilmiştir.

3.9.1. MIDAS Regresyon


Ghysels vd. (2004) tarafından geliştirilen MIDAS (Mixed-Data Sampling – Karma Veri Örnekleme) yaklaşımında, farklı frekansta olan veriler bir arada kullanılabilir. Bu yöntem göre; modelde yer alacak bağımlı değişkenin frekansının daima bağımsız değişken ya da değişkenlerin frekansından düşük olması gerekmektedir. Bu durumun tam tersi, yani bağımlı değişkenin yüksek frekanslı ve bağımsız değişken ya da değişkenlerin ise düşük frekanslı olması durumunda yaklaşım ters MIDAS olarak adlandırılmaktadır (Andreou, Ghysels, Kourtellos, 2010: 247). Bu şekilde yüksek frekansa sahip verinin her bir gözlemi aracılığı ile maksimum bilgi kullanılması sağlanmaktadır. Örneğin; ekonomik büyüme ve işsizlik arasındaki ilişkinin araştırılması hedeflendiğinde aylık frekanstaki işsizlik verisi ile çeyreklik frekanstaki ekonomik büyüme serilerinin eşleştirilmesi için tüm serilerin çeyreklik frekansa getirilmesi gerekmektedir. Ancak MIDAS regresyon aracılığı ile değişkenlere ait orijinal frekansların analize katılması söz konusu olmaktadır. MIDAS yöntemi; eksik veriyi tamamlamak veya gelecek dönem değerini öngörmek amacıyla, düşük frekanslı değişkene ait geçmiş değerlerden yararlanarak yüksek frekanslı açıklayıcı değişkenlere belirli bir ağırlıklandırma uygulanması sonucu seri dönüşümü (sınırlandırma) sağlanmasıyla modele katılması sürecidir (Ghysels vd., 2004: 4). MIDAS regresyon, gecikmesi dağıtılmış modellerle yakından ilişkili olmakla birlikte bazı ortak özellikleri de mevcuttur.

$$y_t = \beta_0 + B(L)x_t + \varepsilon_t \quad (3.39)$$

Denklem 3.39’da verilen gecikmesi dağıtılmış modelde, $B(L)$ sonlu ya da sonsuz gecikme polinom operatörünü ifade etmektedir. Modelde bağımsız değişken olan x_t ’nin gecikmeli etkileri yer almakta olup, bağımlı değişken olan y_t ile aynı frekansta olmaları gerekmektedir. Denklem 3.39’da yer alan gecikmesi dağıtılmış modelden hareketle, Ghysels tarafından tanımlanan kapalı form MIDAS modeli

$$y_t = \beta_0 + \beta x_t + f(\{x_{t/S}^H\}, \theta, \lambda) + \varepsilon_t \quad (t = 1, 2, \dots, T) \quad (3.40)$$

olarak gösterilebilir. Burada y_t düşük frekansa sahip bağımlı değişkeni, x_t bağımsız değişken vektörünü, β, θ, λ tahmin edilecek parametreleri, f parametre tahmininde yüksek frekanslı verilerin dönüşümünü gerçekleştirecek fonksiyonu ve $x_{t/S}^H$ her bir düşük frekans olan t 'ye karşılık gelen S yüksek frekanslı bağımsız değişkeni ifade etmektedir. Fonksiyonunun uygun formu belirlendiğinde MIDAS modelindeki gecikme uzunluğu tamamen verilere bağlı olmaktadır. MIDAS modelinde tahmin edilecek parametre sayısı azaltılırken, yüksek frekanslı değişkenlerde içerilen bilgi korunmak istenmektedir (Ghysels vd., 2006: 2). Bu nedenle MIDAS polinom ağırlıklarının doğru şekilde belirlenmesi gerekmektedir. Fonksiyonunun belirlenmesi için çeşitli polinom spesifikasyonları bulunmaktadır. Dönüşümün gerçekleştirilmesinde kullanılan alternatif ağırlık fonksiyonlarına göre MIDAS modeli farklı formlar sergilemektedir. Örneğin, $x_{t/S}^H$ 'nin aylık frekansta ve y_t 'nin çeyreklik frekansta ele alındığı varsayımı altında m değeri 3 olmaktadır. Ancak frekansın sıklaşması durumunda (günlük vb.) gecikme sayısında artış yaşanmaktadır. Bu artış çok sayıda parametre tahmininin yapılması anlamına gelmektedir. Bu nedenle modelde $x_t^{(m)}$ 'ye ait gecikme sayısının belirlenmesi önemlidir.



Şekil 45: Tahmin-Zaman Çizelgesi

Kaynak: Al-Qawasmi, M. (2014), Forecasting Palestinian Gross Domestic Product Using Mixed Data Sampling. Birzeit: Birzeit Üniversitesi Sosyal Bilimler Enstitüsü.

Verilen örnek üzerinden açıklanacak olursa; bir dönem öncesi gösteren tahmin zaman çizelgesinde, $t + 1$ zamanında y_t (daire içine alınmış gözlem) tahminiyle ilgilendiği varsayalım. Standart tahmin sonuçları, t zamanına kadar mevcut olan verileri kullanarak zaman çizelgesinin kesikli bölümünde gösterilmektedir. Zaman çizelgesinin noktali bölümü, $t + 1$ döneminde kullanılabilir hale gelen bilgileri göstermektedir. Bu bilgiler y_{t+1} tahmini için uygun olabilmektedir. MIDAS yöntemlerini kullanarak, hem kesikli bölümde hem de noktali bölümde belirtilen verileri kullanarak dönem içi tahmin denemelerinin yapılması mümkündür. Bu yönüyle, MIDAS modellerinin bağımlı ve bağımsız değişkenlerde farklı frekans olması durumunda *basit*,

tutumlu ve esnek olmak üzere farklı zaman serisi modelleri olarak tanımlanması mümkündür (Ghysels vd., 2007: 54).

3.9.2. MIDAS Regresyon Polinom Spesifikasyonları

Uygun formun belirlenmesi ardından gecikme uzunluğu tamamen verilere bağlı olmaktadır. Burada amaç; yüksek frekanslı değişkenler aracılığı elde edilen bilgi korunurken parametre sayısının azaltılmasıdır. Bu nedenle MIDAS polinom ağırlıklarının, f fonksiyonunun belirlenmesinde çeşitli polinom türleri bulunmaktadır (Ghysels vd., 2006: 1-2). Ghysels vd. (2004), bağımsız değişkenlerin tüm gecikmelerini modele eklemek yerine, belirli fonksiyonlar yardımıyla ağırlıklandırma işlemi yaparak yeni değişkenlerin $(\theta_0, \theta_1, \theta_2)$ dâhil edildiği yardımcı regresyon modeli geliştirmişlerdir. Böylece gecikme sayısında artış olsa bile yardımcı modele eklenen bağımsız değişken sayısı sabit kaldığından, sınırlandırılmamış bir model sınırlı hale getirilmektedir. Alternatif ağırlık fonksiyonlarına göre MIDAS regresyon modeli farklı formlara dönüşmektedir (Ghysels vd., 2006: 4).

3.9.2.1. Sonlu Polinomlar: Üstel Almon ve Beta

f fonksiyonunun belirlenmesi için iki farklı sonlu ağırlık polinomu söz konusudur. Bunlardan bir tanesi Almon (1965) tarafından geliştirilen Almon Polinomudur. MIDAS modelinin esnekliği ağırlık fonksiyonunun istenilen bir fonksiyona uyarlanabilmesinden kaynaklanmaktadır.

$$y_t = \beta_0 + \sum_{k=0}^{kmax} (x_{t-k/S}^H) \left(\frac{e^{(\theta_1 k + \theta_2 k^2 + \dots + \theta_q k^q)}}{\sum_{j=1}^N e^{(\theta_1 j + \theta_2 j^2 + \dots + \theta_q j^q)}} \right) \lambda + \varepsilon_t \quad (3.41)$$

Burada; k optimal gecikme uzunluğunu, $x_{t-k/S}^H$ her bir düşük frekanslı t 'ye karşılık gelen S yüksek frekanslı bağımsız değişkeni ve λ esneklik katsayısını ifade etmek üzere Almon modeli ifade edilmiştir. Modeldeki gecikme sayısından kaynaklı oluşan farklı tepkiler, gecikme uzunluğunun yanı sıra modelde eş-anlı olarak tahmin edilen θ katsayılarına bağlı olmaktadır. Ghysels vd. (2007), MIDAS modelinde yer alan yüksek frekanslı değişkenin ağırlıklandırılmasında üstel Almon Polinomunu iki parametreyle kullanmayı önermişlerdir.

$$w_j(\theta_1, \theta_2) = \left(\frac{e^{(\theta_1 j + \theta_2 j^2)}}{\sum_{j=1}^m e^{(\theta_1 j + \theta_2 j^2)}} \right) \quad (3.42)$$

Gecikme polinomunun tahmin edilmesinde farklı frekanslardan kaynaklı meydana gelen çok sayıda parametre tahmini, üstel Almon Polinomu aracılığı ile ortadan kalkmakta ve yalnızca iki adet parametrenin tahmin edilmesi yeterli olmaktadır. $\theta_1, \theta_2 = 0$ olması durumunda ise yüksek frekansa sahip değişkenin gecikmeleri için eşit ağırlıklandırma vermektedir (Andreou vd., 2010: 5). Bu esnek yapısı nedeniyle uygulamada Üstel Almon gecikme polinomlarının kullanımı


yaygındır. Ancak denklem 3.41 parametrelere göre doğrusal olmadığından Üstel Almon modeli tahmininde doğrusal olmayan tahmin yöntemleri (örneğin, doğrusal olmayan EKK) kullanılmaktadır. Ghysels dv. (2007) tarafından yüksek frekanslı değişken ağırlıklandırması için üstel Almon Polinomu yanı sıra Beta dağılımı da önerilmiştir.

$$f(j, \theta_1; \theta_2) = \frac{j^{a-1}(1-j)^{b-1}\Gamma(a+b)}{\Gamma(a)\Gamma(b)} \quad (3.43)$$

$$w_j(\theta_1, \theta_2) = \left(\frac{f(j, \theta_1; \theta_2)}{\sum_{j=1}^m f(j, \theta_1; \theta_2)} \right) \quad , \quad w_j = \begin{cases} \delta & i = 0 \\ \frac{i}{k-1} & i = 1, \dots, k-2 \\ 1-\delta & i = k \end{cases} \quad (3.44)$$

$$y_t = \beta_0 + \sum_{k=0}^{kmax} (x_{t-k/S}^H) \left(\frac{w_k^{\theta_1-1}(1-w_k)^{\theta_2-1}}{\sum_{j=0}^N w_j^{\theta_1-1}(1-w_j)^{\theta_2-1}} \right) \lambda + \varepsilon_t \quad (3.45)$$

Burada; k optimal gecikme uzunluğunu, $x_{t-k/S}^H$ her bir düşük frekanslı t 'ye karşılık gelen S yüksek frekanslı bağımsız değişkeni ve λ esneklik katsayısını ifade etmek üzere Beta ağırlık modeli ifade edilmiştir. Denklem 3.43 Beta dağılımı ifade etmek üzere, Beta gecikme polinomları iki parametreyi ($\theta_1; \theta_2$) içererek bu parametrelerin farklı değerlerine göre çeşitli formlara dönüşmektedir. Ayrıca fonksiyonda yer alan ve denklem 3.44'te tanımlanan ifade edilen δ terimi çok ufak bir sayıyı ifade etmekte olup, uygulamada $2,22e^{-16}$ olarak alınmaktadır. Parametreler verilerden tahmin edildiği için f 'nin fonksiyonel formu belirlendikten sonra gecikme uzunluğu seçimi tamamen veriye dayalıdır.




Şekil 46: Almon Polinomiyal MIDAS Ağırlıkları

Kaynak: Ghysels, E., Sinko, A., & Valkanov, R. (2007), "MIDAS Regressions: Further Results and New Directions", *Econometric Reviews*, 26(1): 58. doi:10.1080/07474930600972467

Şekil 46, üstel Almon ağırlık çeşitlerini göstermektedir. Ağırlıklar ilk 252 gecikmeye (bir yıllık günlük gecikmelere karşılık gelen) göre çizilmiştir. Şekiller, parametrelerin değerleri ile

belirlenmektedir. Üst panelde, yavaş yavaş azalan ağırlıkları görülürken ($\theta_1 = 7 * 10^{-4}$ ve $\theta_2 = -1 * 10^{-4}$). Orta panel hızla azalan ağırlıkları ($\theta_1 = 6 * 10^{-3}$ ve $\theta_2 = -5 * 10^{-4}$) görülmektedir. Alt panelde ağırlıklar ($\theta_1 = 3 * 10^{-2}$ ve $\theta_2 = -7$ içerir) $* 10^{-4}$ esnekliği göstermek için seçilmiştir. Üst panel, yavaşça azalan ağırlıkları ($\theta_1 = 7 * 10^{-4}$ ve $\theta_2 = -1 * 10^{-4}$), orta panel hızla azalan ağırlıkları ($\theta_1 = 6 * 10^{-3}$ ve $\theta_2 = -5 * 10^{-4}$) ve alt panel kambur şeklinde azalan ($\theta_1 = 3 * 10^{-2}$ ve $\theta_2 = -7 * 10^{-4}$) göstermektedir.



Şekil 47: Beta Polinomial MIDAS Ağırlıkları

Kaynak: Ghysels, E., Sinko, A., & Valkanov, R. (2007), "MIDAS Regressions: Further Results and New Directions", *Econometric Reviews*, 26(1): 59. doi:10.1080/07474930600972467

Şekil 47, yavaş yavaş azalan ağırlıklar ($\theta_1 = 1$ ve $\theta_2 = 4$), orta panelde hızla azalan ağırlıklar ($\theta_1 = 1$ ve $\theta_2 = 20$) ve alt panelde kambur şeklinde azalan ($\theta_1 = 1.6$ ve $\theta_2 = 7.5$) ağırlıklar yer almaktadır (değerler sadece tanımlamanın esnekliğini göstermek için belirlenmiştir). Üstel Almon gecikmesindekine benzer şekilde burada da ağırlık fonksiyonlarının azalma oranlarına göre MIDAS regresyon gecikme sayısı belirlenmektedir. Üstel Almon ve Beta polinomlarında, oynaklık hesaplamasının pozitif tanımı gereği gerekli pozitif katsayılar elde edilebilmektedir (Ghysels ve Valkanov, 2006: 21). Özetle;

- $\theta_1 = 1$: ağırlık fonksiyonun şekli tek parametreye bağlıdır.
- $\theta_2 > 1$: ağırlık fonksiyonu yavaşça azalmaktadır.
- $\theta_2 < 1$: ağırlık fonksiyonu yavaşça artmaktadır.
- $\theta_3 = 0$: son gecikme uzunluğu sıfır ile sonlanmaktadır.
- $\theta_1 = 1$ & $\theta_3 = 0$: ağırlık fonksiyonun şekli ve son noktası belirlenmektedir.

Artan gecikme uzunluğunun parametre sayısında değişiklik yaratmaması, bu üç parametre tarafından belirlenen ağırlık fonksiyonu ile sağlanmaktadır.

3.9.2.2. Sonsuz Polinomlar

ARMA ve GARCH modellerinde iki sonlu polinomun birbirine oranlanması $B(L)/A(L)$ sonucu sonsuz bir gecikme polinomuna eşit olmaktadır. Bağımsız değişken x_t ile bağımlı değişken y_t 'nin aynı frekansa sahip olması durumunda $y_{t+1} = \beta_0 + \lambda y_t + B(L)x_t + \varepsilon_{t+1}$; gecikmesi dağıtılmış modellerin basit bir otoregresif genişlemesi sonucu sonsuz gecikmeli polinom üretilmektedir.

$$y_{t+1} = \beta_0 + \lambda y_t + \beta_1 B(L^{1/m}; \theta) x_t^{(m)} + \varepsilon_{t+1} \quad (3.46)$$

$$y_{t+1} = \beta_0 + \lambda y_{t+1-1/m} + \beta_1 B(L^{1/m}; \theta) x_t^{(m)} + \varepsilon_{t+1} \quad (3.47)$$

MIDAS modelinin otoregresif genişlemesi sonucu, denklem 3.46'da verilen $L^{1/m}$ 'den geometrik bir polinom elde edilememektedir. Denklem 3.47'de ise geometrik bir polinom elde edilebilirken $y_{t+1-1/m}^{(m)}$ teriminin modelde yer alması nedeniyle içsellik problemi meydana gelmektedir. Bu nedenle MIDAS model tahmininde araç değişken tahmincilerinin kullanılması gerekmektedir.

$$y_t = \beta_0 + \beta_1 [B_{1K}(L^{1/m})/B_{2Q}(L^{1/m})] x_t^{(m)} + \varepsilon_t \quad (3.48)$$

Ancak bahsedilen probleme rağmen, sonlu polinomların birbirine oranlanması sonsuz gecikmeli polinom spesifikasyonu olarak ele alınabilmektedir. Denklem 3.48'de pay ve paydada yer alan polinom derecelerini K ve Q temsil etmekte olup, rasyonel dağıtılmış gecikme modelinin MIDAS verisyonunu göstermektedir (Ghysels vd., 2006: 7-8).

3.9.2.3. Genelleştirilmiş Tek Değişkenli Doğrusal MIDAS Regresyon Modeli

θ vektörü tarafından belirlenen ağırlık polinomlarını $\beta_{ij}(L^{1/m_i})$ ifade etmek üzere,

$$y_{t+k} = \beta_0 + \sum_{i=1}^K \sum_{j=1}^L \beta_{ij} (L^{1/m_i}) x_t^{(m_i)} + \varepsilon_{t+1} \quad (3.49)$$

denklem 3.49'da;

- $K = 1, L = 1, m_1 = 1$: geleneksel gecikmesi dağıtılmış model,
- $K = 1, L = 1, m_1 > 1$: tek polinomlu MIDAS modeli,
- $K > 1, L = 1$: en az iki örneklem frekansını birleştiren MIDAS regresyon modeli

oluşmaktadır. Böylece gelecekteki farklı frekansların bir araya geldiği tahmin işlemi yapılmaktadır. Ayrıca $x_t^{(m_1)} = y_t^{(m_1)}$ olması durumunda ise MIDAS modeli tek bir zaman süreci diğer bir ifadeyle aynı frekansı içerdiği anlaşılmaktadır (Ghysels vd., 2006: 13).

3.9.2.4. Doğrusal Olmayan MIDAS Regresyon Modeli

Ghysels vd., (2007), denklem 3.49'un genelleştirilmesi sonucu doğrusal olmayan modeli elde etmişlerdir.

$$y_{t+k} = \beta_0 + f\left(\sum_{i=1}^K \sum_{j=1}^L \beta_{ij} (L^{1/m_i})g(x_t^{(m_i)})\right) + \varepsilon_{t+1} \quad (3.50)$$

Elde edilen denklem 3.50'de f ve g fonksiyonları, bilinen bir fonksiyon ya da parametrelere dayalı olmaktadır (Ghysels ve Valkanov, 2006: 13). Örneğin, birçok oynaklık uygulamasında log dönüşümü yapılır, yani gelecekteki log oynaklığını y_{t+k} ile tahmin etmeye çalışır. Bu nedenle $g(x) = x$ ile f, \log 'a eşit olarak almaktadır. Oynaklık bağlamında ilgilenilen g için parametrik yapı doğrusal olmayan şekilde de olabilmektedir. Aşağıdaki denklem 3.51'de yer alan g fonksiyon yapısı EGARCH modeline dayanmaktadır.

$$y_{t+k} = \beta_0 + \sum_{i=1}^K \sum_{j=1}^L \beta_{ij} (L^{1/m_i}) \left(r_t^{(m)} + \theta_L |r_t^{(m)}| \right)^2 + \varepsilon_{t+1} \quad (3.51)$$

Denklemden θ_L parametresi aracılığı ile kaldıraç etkisi incelenmektedir. Doğrusal olmayan bir MIDAS regresyon modelinde, $\theta_L = 0$ olması durumunda model doğrusal forma dönüşmektedir. θ_L parametre tahmini diğer parametreler birlikte yapılmaktadır (Ghysels, 2007: 67).

3.9.2.5. Çok Değişkenli MIDAS Regresyon Modeli

Genelleştirilmiş tek değişkenli bir MIDAS regresyon modelinin çok değişkenli forma genişletilmesi mümkündür. Bu model,

$$y_{t+k} = \beta_0 + \sum_{i=1}^K \sum_{j=1}^L \beta_{ij} (L^{1/m_i}) x_t^{(m_i)} + \varepsilon_{t+1} \quad (3.52)$$

olarak gösterilebilir. Burada; θ vektörü aracılığıyla belirlenen ağırlık polinomlarını temsil eden $\beta_{ij}(L^{1/m_i})$ 'de;

$K = 1, L = 1, m_1 > 0$ iken tek polinomlu MIDAS modeline;

$K = 1, L = 1, m_1 = 0$ iken geleneksel dağıtılmış gecikmeli modele;

$K > 1, L = 1$ iken en fazla iki örneklem frekansını birleştiren MIDAS modeline dönüşmektedir.

Denklem 3.52'nin genişletilmesiyle verilen doğrusal olmayan midas modeli

$$y_{t+1} = \beta_0 + \sum_{i=1}^K \sum_{j=1}^L \beta_{ij} (L^{1/m_i}) x_t^{(m_i)} + \varepsilon_{t+1} \quad (3.53)$$

şeklini alır. Burada ε, y ve x, n boyutlu süreci, β_0 polinom vektörünü, $\beta_{ij} n \times n$ boyutlu polinom matrisini ifade etmekte olup, bu noktada önemli olan çok değişkenle çalışılması

durumunda parametre ele alınış şeklidir. Köşegen olmayan elemanların bir polinom aracılığı ile kontrol edilmesine rağmen köşegen elemanlarının ortak bir ikinci polinoma sahip olması önerilen bir yaklaşımdır. Ancak bu öneri her zaman uygun olmamakla birlikte parametre sayısının azaltılmasında gereken kısıtlar uygulama esnasında belirlenecektir (Ghysels vd., 2007: 16).

3.9.2.6. GARCH-MIDAS Regresyon Modeli

Engle vd. (2008) tarafından geliştirilen modelde, zaman içerisindeki hisse senedi piyasa oynaklığı karma frekanstaki değişkenler ile incelenmektedir. Modelde, düşük frekanslı makroekonomik değişkenlerin oynaklık üzerindeki kısa dönemli bileşiminin değil, uzun dönemli bileşiminin etkileyeceği beklenmektedir (Girardin ve Joyeux, 2013: 62). Burada kısa dönemli bileşen oynaklıktaki geçici etkileri, uzun dönemli bileşen ise oynaklıktaki kalıcı ve yavaş hareketli etkileri ifade etmektedir (Engle vd., 2009: 3). Bir varlığı $r_{i,t}$, bilgi kümesini $\emptyset_{i-1,t}$, kısa dönemli etkiyi g_{it} ve uzun dönemli bileşenini τ_t ifade etmek üzere GARCH-MIDAS modeli aşağıda verilmiştir (Engle vd., 2009: 5-7).

$$r_{i,t} - E_{i-1,t}(r_{it}) = \sqrt{\tau_t \cdot g_{it}} \varepsilon_{it} \quad \varepsilon_{i,t} = |\emptyset_{i-1,t}| \sim N(0,1) \quad (3.54)$$

$$r_{i,t} = \mu + \sqrt{\tau_t \cdot g_{it}} \varepsilon_{it} \quad \forall i = 1, \dots, N_t \quad (3.55)$$

$$g_{it} = (1 - \alpha - \beta) + \alpha \frac{(r_{i-1,t} - \mu)^2}{\tau_t} + \beta g_{i-1,t} \quad (3.56)$$

$$\tau_t = m + \theta \sum_{k=1}^K \varphi_k(\omega_1, \omega_2) RV_t \quad \text{Gerçekleşen Oynaklık: } RV_t = \sum_{i=1}^{N_t} r_{i,t}^2 \quad (3.57)$$

$$\tau_i^{rw} = m^{rw} + \theta^{rw} \sum_{k=1}^K \varphi_k(\omega_1, \omega_2) RV_{i-k}^{rw} \quad \text{Gerçekleşen Oynaklık: } RV_i^{rw} = \sum_{j=1}^{N_i} r_{i-j}^2 \quad (3.58)$$

$E_{i-1,t}(r_{it}) = \mu$ varsayımı söz konusu olup, kısa dönemli etki bileşenine ait koşullu varyans dinamiklerinin GARCH(1,1) sürecinde olduğu kabul edilmektedir. Ayrıca τ_t için sabit zaman pencere uzunluğu (fixed window) ve değişen zaman pencere uzunluğu (rolling window) olmak üzere iki durum söz konusudur. Sabit zaman pencere uzunluğunda herhangi bir t periyodunun i zamanında değişmemesi söz konusu iken değişen zaman pencere uzunluğunda ise değişim söz konusudur. Denklem 3.57 sabit zaman uzunluğuna sahip oynaklığı, denklem 3.58 hareketli zaman pencere uzunluğuna sahip oynaklığı ifade etmektedir.

MIDAS filtrelerinin ağırlık şemasını ifade eden $\varphi_k(\omega_1, \omega_2)$ için Engle vd. (2008), Beta ve üstel ağırlıklı gecikme fonksiyonlarını önermişlerdir. Bu öneri, MIDAS filtrelerinin sadece yüksek frekanslı verilere uygulandığının düşünülmesinden kaynaklanmaktadır. Ancak GARCH-MIDAS modeliyle, modelde yer alan filtrelerin aynı tipi düşük frekanslı veriler için kullanılabilir. Bunlar

Beta ağırlıklı

$$\varphi_k(w) = w^k / (\sum_{j=1}^K w^j) \quad (3.59)$$

Üstel ağırlıklı

$$\varphi_k(w) = \frac{\left(\frac{k}{K}\right)^{w_1-1} \left(\frac{1-k}{K}\right)^{w_2-1}}{\sum_{j=1}^K \left(\frac{j}{K}\right)^{w_1-1} \left(\frac{1-j}{K}\right)^{w_2-1}} \quad (3.60)$$

olarak gösterilmektedir. GARCH-MIDAS modelinde parametrelerin Yarı-Maksimum Olabilirlik (QMLE) yöntemi tahmin edilmesi sonucu tutarlı ve asimptotik normal tahminler elde edilmektedir. Uygulamada beta ağırlıklarının daha esnek yapıda olması nedeniyle kullanımı daha yaygındır.

Özetle, Ghysels, Santa-Clara ve Valkanov (2004) tarafından geliştirilen MIDAS modellerinin en önemli özelliği, parametrelerin değerlerine bağlı olarak çeşitli şekiller alabilen bir ağırlıklandırma işlevi aracılığıyla açıklayıcı değişkenlerin dâhil edilmesinin cimri bir yolunu sunmaktadır (Guerin ve Marcellino, 2013: 45). Ancak yüksek frekanslı değişkenlerin tahmin edilmesinde örneğin piyasa koşullarında yaşanan değişimler birbirini takip eden rejimler arasında değişim gösterebilmektedir. Bu nedenle model tahmin yeteneğinin geliştirilmesi için Guerin ve Marcellino (2013) tarafından Markov rejim değişimli MIDAS (MS-MIDAS) modelleri önerilmiştir.

3.10. Otoregresif (AR) Model

y_t olarak ifade edilebilen bir zaman serisinin gözlem değerlerinin ρ gecikmesine bağlı olduğu varsayımı altında y_{t-1}, \dots, y_{t-p} 'nin doğrusal bir fonksiyonudur.

$$y_t = c + \rho_1 y_{t-1} + \rho_2 y_{t-2} + \dots + \rho_p y_{t-p} + \varepsilon_t \quad (3.61)$$

AR modeli içerdiği geçmiş dönem gözlem değerleri sayısına bağlı olarak değişmektedir. AR modelinin bir tane geçmiş dönem gözlemi içermesi durumunda “birinci dereceden”, iki tane içermesi durumunda “ikinci dereceden” ve genel olarak değerlendirildiğinde ise ρ 'inci dereceden AR modeli olarak isimlendirilmektedir. $\rho = 1$ olduğunda denklem 3.61 $y_t = \rho_1 y_{t-1} + \varepsilon_t$ formunda AR(1) modeline dönüşmektedir. Gecikmesi dağıtılmış otoregresif modeller ile MIDAS regresyon arasındaki en önemli fark, daha yüksek frekanslı değişkenin sınırlı parametre ile çeşitlendirilmesine izin veren $b(j; \theta)$ polinomudur. Ağırlıklandırma işleminde sıklıkla üstel Almon polinomu kullanılmaktadır.

3.11. AR-MIDAS Regresyon Modeli

Clements ve Galvão (2008) tarafından gecikmesi dağıtılmış modelin MIDAS formuyla birleştirilmesi sonucu otoregresif (AR) MIDAS modeli geliştirilmiştir.

$$y_t = \beta_0 + \alpha_1 y_{t-1} + \beta_1 \sum_{j=1}^q \omega_{i+j}(\theta) L^{\frac{j}{m}} x_{t-1}^{(m)} + u_t$$
$$y_t = \beta_0(1 - \alpha_1)^{-1} + \beta_1(1 - \alpha_1)^{-1} \sum_{j=1}^q \omega_{i+j}(\theta) L^{\frac{j}{m}} x_{t-1}^{(m)} + \tilde{u}_t \quad (3.62)$$

$\sum_{i=0}^p \sum_{j=0}^q \omega_{i+j}(\theta) L^{\frac{j}{m}} = 1$ varsayımıyla β_1 eğim katsayısı temsil edilerek denklemin yeniden yazılması sonucu elde edilen denklem 3.62'de; $\tilde{u}_t = (1 - \alpha_1)^{-1} u_t$, $x_{t-1}^{(m)}$ 'de yer alan $L^{\frac{j}{m}}$ polinomu ve $L, \sum \alpha_1^j L^j$ 'deki polinom çarpımıdır (Clements ve Galvão, 2008: 547).

3.12. MS-MIDAS Regresyon Modeli

Bölüm 3.5'te bahsedildiği üzere, Markov rejim değişim modellerinde ele alınan serinin yapısındaki değişimin dikkate alınması ve olasılıksal çıkarım yapılması mümkün olmaktadır. Olasılıksal çıkarım, gözlenemeyen ayrık bir S_t değişkenine bağlı olarak yapılmaktadır. Hamilton (1989) temel çalışmasından hareketle Guerin ve Marcellino (2013) tarafından önerilen temel MS-MIDAS regresyon modeli aşağıda verilmiştir.

$$y_t = \beta_0(S_t) + \beta_1(S_t) B(L^{1/m}; \theta) x_{t-h}^{(m)} + \varepsilon_t(S_t) \quad \varepsilon_t | S_t \sim NID(0, \sigma^2(S_t)) \quad (3.64)$$

Denklem 3.64'te verilen MS-MIDAS modeli, Clements ve Galvao (2008) çalışmasından hareketle otoregresif dinamikleri içerecek şekilde aşağıdaki şekilde tanımlanmaktadır.

$$y_t = \beta_0(S_t) + \lambda y_{t-d} + \beta_1(S_t) B(L^{1/m}; \theta) x_{t-h}^{(m)} + \varepsilon_t(S_t) \quad (3.65)$$

Rejim oluşma süreci, aşağıda verilen geçiş olasılıkları aracılığıyla tanımlanan sonlu sayıda tanımlanan $(S_t = \{1, \dots, M\})$ ergodik bir Markov zinciridir.

$$p_{ij} = Pr(S_{t+1} = j | S_t = i) \quad (3.66)$$

$$\sum_{j=1}^M p_{ij} = 1 \forall i, \quad j \in \{1, \dots, M\} \quad (3.67)$$

Geçiş olasılıklarının sabit olması varsayımı, başlangıçta lojistik bir fonksiyon olarak modellenen ve zamanla değişen geçiş olasılıklarını kullanan Filardo (1994) tarafından esnetilmektedir. Kim vd. (2008) ise geçiş olasılıklarını probit fonksiyonu aracılığıyla modellemiştir. Ancak modelin seyrinin izlenmesi açısından MS-MIDAS modelinde sabit geçiş olasılıkları varsayımı kullanılmıştır. Denklem 3.64'te yer alan β_1 parametresindeki değişim, yüksek frekanslı değişken

tahmininin farklı durumlarda değişmesine izin vermektedir. Ayrıca model, hata terimi varyansının hata terimi varyansının (σ^2) rejimler arasında değişim göstermesine de izin vermektedir. Böylece yalnızca finansal değişkenlerin değil aynı zamanda makroekonomik değişkenlerinde modellenmesinde faydalı olmaktadır (Guerin ve Marcellino, 2013: 47). Fakat modelde otoregresif parametre (λ) ve MIDAS parametreleri (θ) sabit tutulmaktadır. Bunun nedeni, MIDAS parametrelerindeki herhangi bir geçişin rejimler arasındaki ağırlıklandırma fonksiyonunun değişmesine yol açacağından kaynaklanmaktadır. Bu değişimle tahmin edilen parametre sayısı artış gösterecek ve ağırlıklandırma fonksiyonunun doğrusal olmayan yapısı nedeniyle tahmin işlemi zorlaşacaktır. MS-MIDAS modellerinin sınıflandırılması Tablo 44'te verilmiştir.

Tablo 44. MS-MIDAS Modellerinin Sınıflandırılması

Model	Rejim Değişiklikleri	AR Bileşeni
MSIH(M)-MIDAS	β_0 ve σ^2	Yok
MSH(M)-MIDAS	β_0, β_1 ve σ^2	Yok
MSIHAR(M)-MIDAS	β_0 ve σ^2	Var
MSHAR(M)-MIDAS	β_0, β_1 ve σ^2	Var
MSIHADL(M)-MIDAS	β_0 ve σ^2	Var
MSHADL(M)-MIDAS	β_0, β_1 ve σ^2	Var

Not: "ADL", modele bir AR bileşeni dâhil edildiğini ifade etmektedir. Denklem 3.62'de yer alan modelde S_t değişkeninin yer almadığı otoregresif-MIDAS modelini temsil etmektedir.

Kaynak: Guerin, P. ve Marcellino, M. (2013). Markov-Switching MIDAS Models. Journal of Business and Economic Statistics. 31(1): 47.

3.13. MS-GARCH MIDAS Modeli

Hisse senedi piyasalarında genellikle yapısal kırılımlar söz konusu olmaktadır. Yapısal kırılımların göz ardı edilmesi durumunda oynaklık şokları çok büyük kalıcılığına neden olabilir ve bu durum da zayıf tahmin gücüne yol açabilmektedir. Bu nedenle daha iyi tahminler elde edilmesi amacıyla GARCH-MIDAS modeli rejim değişim çerçevesine dâhil edilebilmektedir. GARCH-MIDAS modelinin yapısı, Markov rejim değişimini kısa ve uzun vadeli oynaklık açısından ayrı ayrı veya birlikte dâhil edilmesine izin vermektedir. Böylece iki bileşendeki model parametreleri, doğrudan gözlemlenemeyen iki oynaklık rejimi arasında değişebilmektedir. Kısa ve uzun vadeli bileşenlerdeki Markov geçişi, dinamik rejim değiştirme davranışını yakalayabilmektedir. Yapısal kırılımlar aynı zamanda oynaklık davranışında farklı değişimlere neden olabilmektedir. Bu davranış değişikliği hem geçici hem de konjonktür etkisiyle tekrarlayıcı görülebilmektedir. Bu noktada Pan vd. (2017), kısa vadeli bileşene bir Markov rejim sürecinin eklenmesi sonucu yeni bir GARCH-MIDAS modeli geliştirmişlerdir.

$$r_{i,t} = \sqrt{\tau_t \times h_{i,t}} \epsilon_{i,t}, \quad \forall i = 1, \dots, N_t, \quad (3.68)$$

$$\epsilon_{i,t} | F_{i-1,t} \sim N(0,1)$$

Denklem 3.68'de $F_{i-1,t}$ t döneminin $i - 1$ gününe ait mevcut bilgiyi ifade etmektedir. Kısa vadeli oynaklığı $h_{i,t}$ ve uzun vadeli oynaklığı ise τ_t tanımlanmaktadır. Engle vd. (2013) GARCH-MIDAS modelinde yer alan kısa vadeli oynaklığı Bollerslev (1986)'den hareketle denklem 3.69'daki şekilde ifade etmişlerdir (Engle vd., 2013: 776).

$$h_{i,t} = (1 - \alpha - \beta) + \alpha \frac{r_{i-1,t}^2}{\tau_t} + \beta h_{i-1,t} \quad (3.69)$$

Yapısal değişimlerin modele dâhil edilmesi için denklem 3.69'a rejim değiştirme yapısı göz önünde bulundurularak GARCH-MIDAS'a ait kısa vadeli oynaklık süreci Pan vd. (2017) tarafından değiştirilmiştir.

$$h_{i,t}^{(j)} = \omega(s_{i,t} = j) + \alpha \frac{r_{i-1,t}^2}{\tau_t} + \beta \bar{h}_{i-1,t} \quad (3.70)$$

Denklem 3.70'te $s_{i,t}$ iki rejimli gizli değişkeni ($j = \{0,1\}$) yani; $\omega(0)$ düşük oynaklık rejimini ve $\omega(1)$ ise yüksek oynaklık rejimini ifade etmektedir.

$$P = \begin{bmatrix} p_{00} & 1 - p_{11} \\ 1 - p_{00} & p_{11} \end{bmatrix}$$

Yukarıda verilen geçiş matrisiyle $s_{i,t}$ değişkeni belirlenmektedir. Burada; $p_{j_0 j_1} = Pr(s_{i,t} = j_1 | s_{i,t} = j_0)$ j_0 rejiminin j_1 rejimi tarafından takip edilme olasılığını ifade etmektedir. Ancak $h_{i,t}$ işleminde tüm parametrelerde değişikliğe izin verilmemektedir. Bu durumun ilk nedeni, iki rejim arasındaki α ve β parametrelerinin farklılaşmasının önemli olma ihtimali ve ikinci nedeni de parametre sayısındaki artıştan kaynaklı yakınsamama sorunun meydana gelmesi ihtimalidir.

$$\tau_t = \exp(\theta_0 \sum_{i=1}^K \varphi_i(\kappa) RV_{t-i}) \quad , \quad RV = \sum_{i=1}^{N_t} r_{i,t}^2 \quad (3.71)$$

Pan vd. (2017) tarafından tanımlanan τ_t bileşenine makroekonomik değişkenlerin dâhil edilme sonucu oluşan denklem 3.72'de verilmiştir.

$$\tau_t = \exp(\theta_0 \sum_{i=1}^K \varphi_i(\kappa_0) RV_{t-i} + \theta_1 \sum_{i=1}^K \varphi_i(\kappa_1) X_{t-i}) \quad (3.72)$$

Denklem 3.72'de yer alan X_{t-i} ile makroekonomik değişkenler ifade edilmektedir. Ağırlıklandırma işleminde ise esnek yapısı ve yaygın kullanımı nedeniyle tek parametrelili Beta polinomu kullanılmıştır.

$$\varphi_i(\kappa_d) = \frac{[1-i/(K+1)]^{\kappa_d-1}}{\sum_{j=1}^K [1-j/(K+1)]^{\kappa_d-1}} \quad , \quad d = 0,1 \quad (3.73)$$

Denklem 3.73'te $\varphi_i(\kappa_d)$ ağırlıkları $\{\theta_0, \theta_1, \kappa_0, \kappa_1\}$ parametreleri tanımlanacak şekilde toplamı vermektedir. Üs (exp) alma işlemi sonucunda da Engl vd. (2013) tarafından da kullanılan uzun

vadeli oynaklığın her zaman pozitif olması sağlanmaktadır. Parametrelerin tahmin edilmesinde ise geleneksel yarı maksimum olabilirlik yöntemi kullanılmaktadır.

$$\eta_{i,t} = \begin{bmatrix} f(r_{i,t}|s_{i-1,t} = 0, F_{i-1,t}; \theta) \\ f(r_{i,t}|s_{i-1,t} = 1, F_{i-1,t}; \theta) \end{bmatrix} = \begin{bmatrix} \frac{1}{\sqrt{2\pi\tau_t h_{i,t}^{(0)}}} \exp\left(-\frac{r_{i,t}^2}{2\tau_t h_{i,t}^{(0)}}\right) \\ \frac{1}{\sqrt{2\pi\tau_t h_{i,t}^{(1)}}} \exp\left(-\frac{r_{i,t}^2}{2\tau_t h_{i,t}^{(1)}}\right) \end{bmatrix} \quad (3.74)$$

Yukarıda ifade edilen matriste; $\theta = (\omega(0), \omega(1), \alpha, \beta, \bar{\tau}, \theta_0, \theta_1, \kappa_0, \kappa_1, p_{00}, p_{11})$ ifade etmekle birlikte $f(r_{i,t}|s_{i-1,t} = j, F_{i-1,t}; \theta)$ 'in, $r_{i,t}$ 'nin $s_{i-1,t} = j$ rejimi tarafından belirlenen koşullu olasılık yoğunluğu olduğu varsayımı altında log-olasılık fonksiyonu denklem 3.75'te verilmiştir.

$$\xi(\theta) = \sum_{t=1}^T \sum_{i=1}^{N_t} \log f(r_{i,t}|F_{i-1,t}; \theta) \quad (3.75)$$

$$f(r_{i,t}|F_{i-1,t}; \theta) = \mathbf{1}'(\hat{\xi}_{i,t|i-1,t} \odot \eta_{i,t}) \quad (3.76)$$

Denklem 3.76'da yer alan \mathbf{I} , elemanları bir olan 2×1 'lik vektörü ve \odot eleman çarpımıyla filtrelenmiş olasılığı ifade etmektedir.

$$\hat{\xi}_{i,t|i-1,t} = \begin{bmatrix} Pr(s_{i,t} = 0|F_{i-1,t}) \\ Pr(s_{i,t} = 1|F_{i-1,t}) \end{bmatrix} \quad (3.77)$$

Hamilton (1994)'dan hareketle 3.77'nin elde edilmesinde denklem 3.78'de yer alan denklem yinelenmektedir.

$$\hat{\xi}_{i,t|i,t} = \frac{\hat{\xi}_{i,t|i-1,t} \odot \eta_{i,t}}{\mathbf{1}'(\hat{\xi}_{i,t|i-1,t} \odot \eta_{i,t})} \quad (3.78)$$

$$\hat{\xi}_{i+1|i,t} = P \times \hat{\xi}_{i,t|i,t}$$

$$\hat{\xi}_{0|0} = \begin{bmatrix} \frac{1-p_{11}}{2-p_{00}-p_{11}} \\ \frac{1-p_{00}}{2-p_{00}-p_{11}} \end{bmatrix}$$

Denklem 3.78 için başlangıç değerini ifade eden $\hat{\xi}_{0|0}$ verilmiştir. Böylece denklem 3.75'te verilen $L(\theta)$ 'nin maksimize edilmesi sonucu θ tahmin edicisi elde edilmektedir (Pan vd., 2017: 135-139).

3.14. Diebold – Mariano Testi

Diebold ve Mariano (1995) tarafından geliştirilen testte, iki tahmin yöntemi arasındaki performansın aynı olup olmadığı incelenmektedir. Aynı zamanda ilk metodun ikinciye göre daha yüksek ya da düşük hataya sahip olduğuna dair tek yönlü hipotez testi olarak kullanmakta

mümkündür. Bu doğrultuda iki farklı yöntem arasındaki tahmin hatalarının anlamlılığı test edilmektedir. Örneğin enflasyon tahmininde S ankete dayalı ve B piyasaya dayalı tahmin olduğu varsayımı altında, $\overline{MSE}(\pi_t^S) = 1.80$ ve $\overline{MSE}(\pi_t^B) = 1.92$ ortalama hata kareler kıyaslandığında S yönteminin B yönteminden daha iyi enflasyon tahminleri sağladığı sonucuna varılmaktadır. Ancak yöntemler arası performans üstünlüğünün karşılaştırılmasında Diebold ve Mariano (DM) testi, “gerçekten üstün mü?” sorusunun yanıtlanması için uygun ekonometrik bir araç olup, araştırmacıların belirgin tahmin üstünlüğünün önemini değerlendirmesine olanak tanımaktadır. Ayrıca testin en önemli avantajı, öngörü hatalarının dağılımıyla ilgili herhangi bir varsayım gerektirmemesidir.

Testte, karşılaştırılacak olan i ve j modellerinin öngörü performanslarının eşit olduğu şekilde kurulan H_0 hipotezi sınanmaktadır. Her iki modele ait hata terimleri ile elde edilen $(e_{i,t+k} - e_{j,t+k})$ kayıp fonksiyonu d_t olarak tanımlanmaktadır. Bu durumda H_0 hipotezinin doğru olduğu varsayımı altında $E(d_t) = 0$ olacaktır. \bar{d} ; e_t^i ve e_t^j arasındaki farkların ortalamasını göstermekle birlikte $[\bar{d} = n^{-1} \sum_{t=1}^n (d_t)]$ olarak tanımlandığında \bar{d} 'ya ait asimtotik varyans $V(\bar{d}) \cong n^{-1}[\gamma_0 + 2 \sum_{k=1}^{h-1} \gamma_k]$ şeklinde hesaplanmaktadır. Burada; n toplam oynaklık öngörü sayısını ve γ_k , d_t 'nin k . otokovaryansını ifade etmektedir (Diebold, 2012: 2-8).

DM test istatistiği,

$$DM = [\hat{V}(\bar{d})]^{-1/2} \bar{d}, \quad (3.79)$$

$$\hat{V} = n^{-1} \sum_{t=k+1}^n (d_t - \bar{d})(d_{t-k} - \bar{d}) \quad (3.80)$$

yardımı ile hesaplanmaktadır.

Vektörlerin elde edilmesinde, hataların karesi ya da mutlak değeri kullanılarak iki farklı yaklaşım kullanılmaktadır. Testin temel hipotezi iki farklı tahmin yönteminin seçilen dönemde aynı performans gösterdiğini ifade ederken, küçük örneklerde daha tutarlı sonuç vermektedir. Giacomini ve White (2006), bu nedenle yuvarlanan pencere (Rolling window) ile yapılan testlerin asimptotik olarak daha uygun sonuç vereceğini ifade etmişlerdir (Giacomini ve White, 2006: 9).

3.15. Makine Öğrenmesi Algoritmaları

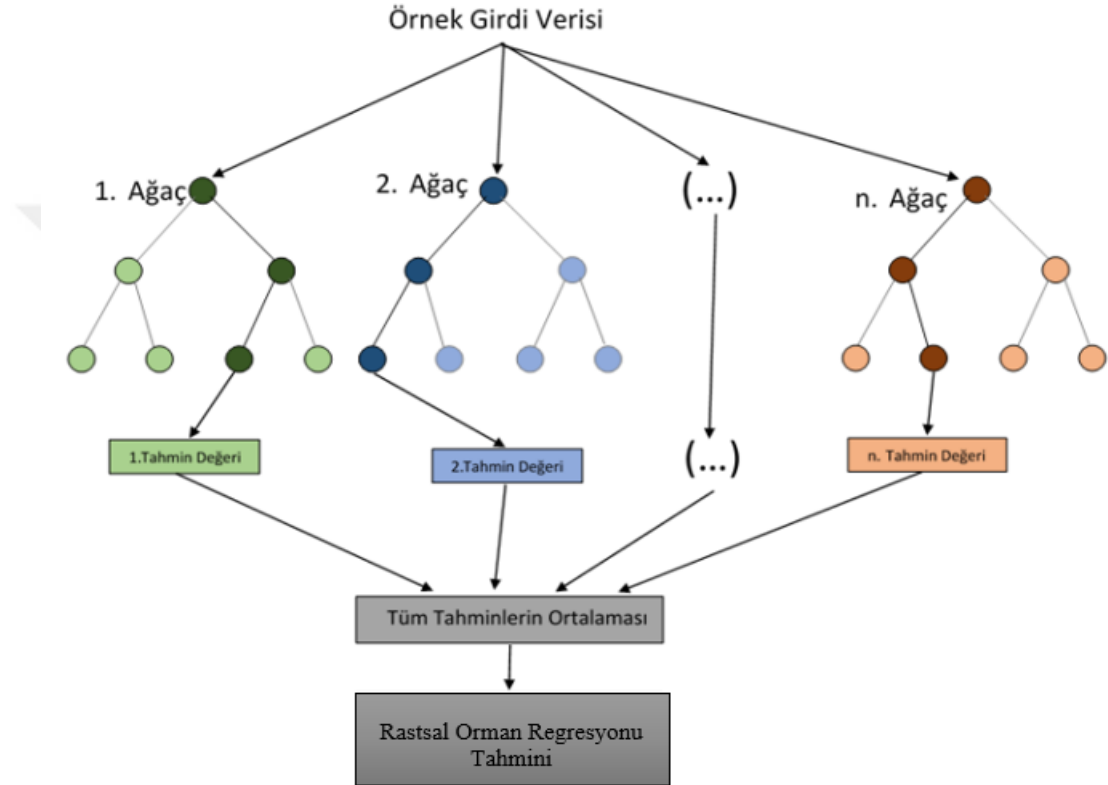
Büyük verinin ortaya çıkması sonucu ampirik makroekonomik modeller giderek daha fazla sayıda özellik ve tahmin edici içermektedir. Geleneksel tahmin yaklaşımları, özellikle örnek dışı performans açısından genellikle yüksek boyutlu modellerin tahmin edilmesinde uygun olmamaktadır. Bu nedenle doğrusal olmayan durumlara da izin verebilen makine öğrenmesi teknikleri ekonomi alanında giderek popülerlik kazanmaktadır (Diebold ve Shin, 2019; Kotchoni

vd. 2019; Medeiros vd., 2021; Borup ve Schütte, 2022). Yaygın olarak kullanılan finansal zaman serisi tahmininde, geleneksel ekonometrik modeller ve makine öğrenimi yöntemleri kullanılabilir. Her iki tahmin sürecinin de kendine has avantaj ve dezavantajları mevcuttur. Örneğin, geleneksel ekonometrik modeller doğrusal ve zamanla değişen bileşenleri yakalamada genellikle etkindir. Ancak genellikle veri kararlılığı açısından çeşitli varsayımlara ihtiyaç duyulmaktadır (Lin vd., 2011; Zhang vd., 2015). Makine öğrenmesi yöntemlerinde ise esnek doğrusal olmayan fonksiyonların kullanılması ve verilere uygulanan daha az kısıtlayıcı varsayımlar nedeniyle durağan ve doğrusal olmayan zaman serilerinin tahmin edilmesinde uygundur. Ancak tahmin performanslarının veri boyutlarından etkileneceği ihtimali göz ardı edilmemelidir (Wang vd., 2005; Psaradellis ve Sermpinis, 2016). Her iki yaklaşımında dezavantajlarından hareketle, özellikle finansal zaman serisi tahmin alanyazınında kademeli olarak hibrit modeller ortaya çıkmıştır (Zhang ve Zhang, 2018; Liv d., 2021; Xiao vd., 2021). Örneğin, Yu vd. (2008) “ayırışma-bütünleşme” hibrit modellerini önererek her zaman hibrit modellerin sonuçlarda daha iyi tahmin yeteneğine sahip olduğunu ifade etmişlerdir. Bildirici ve Ersin (2013) ise çok katmanlı algılayıcı modeli yeni Smooth Transition Autoregressive model ile GARCH modelinin birleştirilmesi sonucu hibrit yaklaşımın petrol fiyatlarının oynaklık kümelenmesinin incelenmesinde daha başarılı performans sağladığını belirtmişlerdir. İlgili alanyazına bakıldığında model kombinasyonlarının özellik yakalama kabiliyetiyle sentezlenmesi sonucu tahmin performansını iyileştirebileceğinin ifade edildiği görülmektedir (Rapach vd. 2010). Son yıllarda, büyük boyutlu değişkenlerle gerçekleştirilen ekonomik uygulamalarda sıklıkla makine öğrenimi ve cezalı regresyon tekniklerine odaklanılmaktadır (Korobilis, 2013; Gefang, 2014). Ancak alanyazına bakıldığında MIDAS regresyon aracılığıyla gerçekleştirilen hibrit model çalışmalarında nicelik açısından eksiklik olduğunu söylemek mümkündür. Halbuki doğrusal olmama (Chang, 2015; Cheng, 2013) ve küçük ve büyük örneklem boyutlarında çoklu çıktuların elde edilmesinde makine öğrenmesiyle desteklenmesinin performans açısından iyileştirici olduğu görülmektedir (Mao vd., 2014; Han, 2012; Tuia, 2011; Xiaong vd., 2014). Bu nedenle veri frekansı açısından esneklik sağlayan MIDAS regresyonun tahmin performansının iyileştirilmesinde doğrusal olmayan değişkenlerin ele alınabildiği makine öğrenmesi algoritmalarının destekleyici olacağı düşünülmüştür. Buradan hareketle doğrusal olmayan zaman serileriyle tahminlemenin makine öğrenmesi yaklaşımı ile yapılmasında sıklıkla kullanılan bazı algoritmalara bu bölümde yer verilmiştir.

3.15.1. Rastsal Orman (Random Forest) Regresyonu

Leo Breiman tarafından geliştirilen rastsal orman regresyonu (ROR), topluluk olarak meydana gelen çok sayıda karar ağacından oluşmaktadır. Algoritma içerisinde yer alan her bir ağaç bir

sınıf (kategori) tahmininde bulunarak, en fazla oy alan sınıfın belirlenmesi sonucu bu değerler modelin öngörüsü olarak kabul edilmektedir. Kısaca ROR, tahmin uygulamalarında bağımlı değişken tahmini için pek çok karar ağacı yapısının kullanıldığı bir regresyon tekniğidir. Yapısı, karar ağaçlarına ait düğümlerde karar değişkenleri ve yapraklarında tahmin değerlerinden oluşmaktadır. Karar ağaçlarının temel amacı, regresyon hata fonksiyonunun değerinin minimize edilmesidir (Sharma, 2018).



Şekil 48: Rastsal Orman Regresyon Algoritma Yapısı

Kaynak: Yavuzdoğan A., Tanır Kayıkçı, E. (2021), “Ege Denizi’nde Makine Öğrenimi Yöntemleri ile Anlık Deniz Seviyesi Değişimlerinin Tahmini”, *Jeodezi ve Jeoinformasyon Dergisi*, 8(2): 92.

Birden fazla karar ağacının oluşturulması sonucu meydana gelen ormanda, her bir ağaca ait sonuçların oylama (voting) ile elenmesi ya da ortalamasının alınması sonucu problemin çözümüne ulaşılmaktadır. Veri setinin alt kümelerine ayrılması ve tüm değişkenler arasından rastsal seçilerek oluşturulan alt küme içerisinde ağaç üzerindeki düğümlerden en iyi dallara ayrılan değişken seçilmektedir. Bu nedenle ağaç sayısı (N) ve her düğümde yer alacak değişken değeri (m) belirlenmektedir. Regresyon problemlerinde değişken değerinin belirlenmesinde toplam p değişken sayısının $p/3$ olarak alınması alanyazında sıkça önerilmektedir (Breiman, 2001). Tahmin işleminin tamamlanmasının ardından her bir ağaç için hata oranı belirlenebileceği gibi ormanın bütünüyle hata oranının belirlenmesi de mümkündür. Bu şekilde alt kümelerin veri setini


temsil etme ölçüsü belirlenebilmektedir. Rastsal orman algoritmasının aşamaları aşağıda özetlenerek verilmiştir.

- Verilerden bir bölüm seçilmektedir.
- Seçilen örneklem ile nitelikler dikkate alınarak en iyi ayırım noktası belirlenmektedir.
- Belirlenen ayırım noktasından hareketle iki yeni düğüm meydana gelmektedir.
- Hedef düğüm sayısı için ise önceki iki adım sırasıyla tekrarlanmaktadır.
- Hedef ağaç sayısı için de önceki maddeler sırasıyla tekrarlanmaktadır.

Çok fazla sayıda kayıp ve bozuk veri olması durumunda da başarılı sonuçlar veren algoritma hem kategorik hem de kategorik olmayan veri tiplerinde uygulanabilmektedir. Karar ağacı yöntemine kıyasla çok fazla sayıda değişken olması durumunda da kullanılabilir uygun bir yöntemdir. Çünkü ağaç sayısı ne kadar artsa da aşırı öğrenme problemi oluşmamaktadır. Ancak yapay sinir ağları, lojistik regresyon gibi model sonuçlarında elde edilen güven aralığının bu algorithmada elde edilememesi dezavantajını oluşturmaktadır.

3.15.2. Ekstrem Gradyan (XGBoost) Regresyon

Friedman (2001) tarafından geliştirilen XGBoost algoritması, karar ağaçları temeline dayanmaktadır. Son yıllarda tahmin başarısı ve hesaplama kolaylığı nedeni ile uygulamalarda etkin bir şekilde kullanılmaktadır (Abar, 2020: 434).



Şekil 49: XGBoost Model Gelişimi

Kaynak: Morde, V. (2019), "XGBoost Algorithm", <https://towardsdatascience.com/https-medium-comvishalmorde-xgboost-algorithm-long-she-may-reinedd9f99be63d> (Erişim Tarihi: 20.07.2022).

Makine öğrenmesi karar ağacı modelleri, torbalama (bagging) ve artırma (boosting) olarak iki topluluk öğrenme algoritmasına sahiptir. Torbalama, birbirinden bağımsız yapıların kurulması sonucu paralel çalışmakta iken, artırma sırayla birbirinin üzerine ekleme yapısına sahiptir. Rastsal orman regresyonu bu algorithmaya dayanmaktadır. Torbalama algoritması, her seferinde önceki hatalar göz önüne alındığından paralel çalışan modellere kıyasla daha hızlıdır. Artırma ise her üretilen karar ağacının sırasıyla hatalarının minimize edilmesi üzerine kuruludur. Yöntemi ifade eden karar ağacı yapısının matematiksel gösterimi aşağıda verilmiştir.

$$\hat{y}_i = \sum_{k=1}^K f_k(x_i) \quad f_k \in F \quad (3.81)$$

Topluluk öğrenme yöntemi (3.81); K toplam karar ağacı, f olasılık fonksiyonu ve F olanaklı bütün karar ağaçlarıyla ifade edilmektedir. XGBoost algoritmasının tanımlanması ise

$$\phi^{(t)} = \sum_{i=1}^n l(y_i, \hat{y}_i^{(t)}) + \sum_{t=1}^t \Omega(f_t) + \text{sabit} \quad (3.82)$$

olarak yapılabilir. Karar ağaçları ile kurulan regresyon modelinde (3.82) l fonksiyonu, tahmin değeri ile gerçek değer arasındaki farkı ifade etmekte olup, modelin karmaşık kalan kısmı için düzeltme fonksiyonu Ω kullanılmaktadır. Bu fonksiyonun değeri ne kadar küçükse karmaşıklık azalmakta ve genelleme yeteneği daha güçlü olmaktadır.

$$\Omega(f) = \gamma T + \frac{1}{2} \lambda \|w\|^2 \quad (3.83)$$

XGBoost, gradyan artırma sürecinde kayıp fonksiyonunu genişletmek için ikinci dereceden Taylor açılımını kullanılmaktadır:

$$\phi^{(t)} \cong \sum_{i=1}^n \left[g_i f_t(x_i) + \frac{1}{2} h_i f_t^2(x_i) \right] + \Omega(f_t) \quad (3.84)$$

$$= \sum_{i=1}^n \left[g_i w_{q(x_i)} + \frac{1}{2} h_i w_{q(x_i)}^2 \right] + \gamma T + \lambda \frac{1}{2} \sum_{j=1}^T w_j^2$$

$$= \sum_{j=1}^T \left[\left(\sum_{i \in I_j} g_i \right) w_j + \frac{1}{2} \left(\sum_{i \in I_j} h_i + \lambda \right) w_j^2 \right] + \gamma T$$

$$g_i = \partial_{\hat{y}^{(t-1)}} l(y_i, \hat{y}_i^{(t-1)}) \quad , \quad h_i = \partial_{\hat{y}^{(t-1)}}^2 l(y_i, \hat{y}_i^{(t-1)})$$

Burada g_i ve h_i , hata fonksiyonundaki her veri noktasının birinci dereceden türevi ve ikinci dereceden türevi olup $I_j = \{i | q(x_i) = j\}$, her bir yaprak düğümü j üzerindeki örneklerin indeks kümesidir. Verilen $q(x_i)$ için, w_j 'nin 0'a eşit türevi alınarak, j yaprak düğümüne ait en iyi

$w_j^* = -\frac{\sum_{i \in I_j} g_i}{\sum_{i \in I_j} h_i + \lambda}$ ağırlığı elde edilmektedir. XGBoost modeli, Gradyan Artırma (Gradient

Boosting) yönteminin geliştirilmiş hali olup regresyon problemlerinde artırma algoritmasına dayalı olarak kullanılabilir. Karar ağaçlarının makine öğrenmesiyle birleşmesi sonucu oluşan Gradyan Artırma modelleri,

$$F^t = \sum_{i=1}^n l(y_i, \hat{y}_i^{(t-1)}) + f_t(x_i) + \Omega(f_t) \quad (3.85)$$

şeklinde gösterilmekte olup, burada f_t hatayı minimize edene kadar eklenerek türetilen fonksiyonu temsil etmektedir.

$$\hat{y}_i^{(0)} = 0$$

$$\hat{y}_i^{(1)} = f_1(x_i) = \hat{y}_i^{(0)} + f_1(x_i)$$

$$\hat{y}_i^{(2)} = f_1(x_i) + f_2(x_i) = \hat{y}_i^{(1)} + f_2(x_i)$$

⋮

$$\hat{y}_i^{(t)} = \sum_k^t f_k(x_i) = \hat{y}_i^{(t-1)} + f_t(x_i) \quad (3.86)$$

Bu yöntemler parametrik olmadıkları için varsayım gerektirmeden kategorik ve sürekli değişkenlerle karışık olarak çok daha fazla değişkenli veri setlerinde çalışabilmektedirler. Aynı zamanda, model performansında çoklu doğrusallık problemi yokken aykırı, eksik ve gürültülü (rastsal hata) değerlerde iyi işlenebilmektedir (Zhang vd., 2021: 5-6). XGBoost algoritması, karar ağaçları ve makine öğrenmesinde sıklıkla araç olarak kullanılan bir uygulamadır. Geliştirilen bu yaklaşımla sınıflandırma, regresyon ve sıralama gibi araştırmalarda yüksek performans sağlayan önemli bir araç haline gelmiştir (Mitchell ve Frank, 2017: 127). Bu algoritmanın özünde amaç fonksiyonunun optimize edilmesi vardır (Zheng vd., 2017: 1171). XGBoost algoritmasının gradyan artırma teknikleri içerisinde performansının çok daha yüksek seviyede olmasının nedeni ağaç sınırlandırmasından kaynaklanmaktadır. Karar ağaçları kullanılan bu algoritmada aşağıya doğru uzanan ağaç dalları sınırlandırılmaktadır. Karar ağaçlarındaki dalların en başta belirlenen sınırlandırmayı geçmesi durumunda algoritma bu dalları geriye doğru kısaltmaktadır. Böylece karar ağacı çok büyüyüp karmaşık hale gelmediğinden klasik yöntemlere göre tahmin performansı daha yüksek olmaktadır.

3.15.3. Hafif Gradyan Artırma (LightGBM)

Aşağıda Gradyan Artırma regresyon modelinde uygulama adımları sırasıyla verilmiştir.

1. Regresyon ağacının oluşturulması
2. Her bir ağaç için tahmin değerleri ile gözlem değerleri arasındaki farkın (hata oranı) hesaplanması
3. Yeni gözlem verileri olarak hesaplanan hata oranlarının kullanılması
4. Hata oranlarının en aza indirilmesi için yeni ağaç oluşturulması

Algoritmada hata oranının sıfıra yaklaştırılmasına kadar belirtilen adımlar tekrarlanmaktadır. XGBoost gibi algoritmalarda en iyi performansın elde edilmesinde her değişken için tüm örneklem noktalarının taranması gerekmektedir. Bu süreç model eğitimini zorlaştırdığından LightGBM modeli önerilmiştir. Büyük verilerin işlenmesi, kategorik değişkenlerin sayısal olarak analiz edilebilmesi için gerekli “one-hot encoding” (kategorilerin sayılara dönüştürülmesi) işlemine gerek duyulmaması nedeniyle uygulama kolaylığı sağlamaktadır (Ke vd., 2017: 8).

3.15.4. K-en Yakın Komşuluk (KNN)

K-en yakın komşu (KNN) tahmin yöntemi parametrik olmayan hem sınıflandırma hem de regresyon algoritmasıdır. Yöntem, bir olayın sonucunun kendisine en yakın komşu olayların sonucuyla aynı olur fikrine dayanmaktadır. Öklid mesafesinin hesaplanması aşağıda verilmiştir.

$$d(x_i, x_k) = \sqrt{(x_{i1}, x_{k1})^2 + (x_{i2}, x_{k2})^2 + \dots + (x_{ir}, x_{kr})^2} \quad (3.87)$$

Formülde x_i ve x_k ($k=1,2,\dots,n$) arasındaki gözlemler arası Öklid mesafesi, iki boyutlu çözüm kümesinde x düzlemindeki doğrusal x_i 'ye, y kümesinde doğrusal uzaklık ise y_i 'ye bağlı olarak bulunmaktadır. Regresyon problemlerinde tahmin edilmesi hedeflenen bağımlı değişken değeri, tahminci bağımsız değişkenin optimum k sayıda komşu bağımsız değerlerin bağımlı değerlerinin aritmetik ortalamasının alınmasıyla hesaplanmaktadır (Altunkaynak vd., 2020: 1550). İteratif adımlardan oluşan algoritmada, atamalar artık değişmediğinde algoritma yakınsamaktadır. Veri setinde bulunan değişkenlerin ikiden fazla sayıda olması durumunda standardize edilmiş Öklid uzaklık fonksiyonu kullanılmaktadır. Böylece incelenen değişkenler arasındaki ölçüm farklılıkları ortadan kalkmaktadır.

BÖLÜM 4

KARMA FREKANSLI ZAMAN SERİLERİNİN MODELLENMESİ: BÜYÜK VERİ ÖRNEĞİ

Tezin dördüncü bölümünde birinci ve ikinci bölümlerde ön araştırması yapılan kripto para teknolojisi, üçüncü bölümde verilen kuramsal çerçeve bağlamında karma frekanslı büyük veri analiz edilerek sonuçlar değerlendirilmiştir.

4.1. Veri Toplama Tekniği

Çalışma amacına uygun olarak anakütleyi temsilen seçilen örneklemin yani kullanıcıların paylaşımlarının elde edilmesinde, “Angelabs İnternet Yazılım ve Danışmanlık Hizmetleri Ticaret A.Ş.” isimli şirketten temin edilen “Monitera” lisanslı program aracılığı ile veri madenciliği gerçekleştirilerek, Twitter platformundaki içerikler filtrelenerek Excel formatında elde edilmiştir. Bu doğrultuda “Bitcoin”, “Ethereum”, “Litecoin” ve “Ripple” hashtagi altında yapılan paylaşımlar “13.05.2020 – 30.09.2020” ve “13.05.2021 – 30.09.2021” tarih aralığı için iki farklı yılda aynı dönem aralığı kapsamında temin edilmiştir. Bu sayede değişen piyasa koşullarının da değerlendirilmesinin yapılması hedeflenmiştir. Belirtilen filtrelerle yapılan aramalarda, çalışma amacına uygunluğu açısından başka herhangi bir hashtagin bulunmamasına dikkat edilmiştir. Örneğin, “#spor, #haber, #ilan” vb. incelenmesi istenen durumların dışında kalabilecek paylaşımların elde edilmesi engellenmiştir.

4.2. Anakütle ve Örneklem

Çalışmanın ana kütesini, 2020 ve 2021 yıllarında sosyal medya platformlarından olan Twitter’ı kullanan bireyler oluşturmaktadır. Çalışmada anakütleyi temsilen ele alınan örneklem ise amaca uygun örneklem metodu ile bu bireyler içerisinden belirtilen tarih aralıkları ve hashtagler altında paylaşım yapanların içeriklerinden oluşmaktadır. Araştırma, hem nitel hem de nicel yaklaşım ve yöntemlerin bir arada kullanılması nedeniyle karma yöntem araştırması niteliğindedir. Bu nedenle karma araştırmanın temel ilkesi olan “araştırmacının farklı strateji, yöntem ve yaklaşımlar kullanarak çoklu veriler toplaması” işlemi gerçekleştirilmiştir. Böylece her iki yaklaşımı tek başına kullanmaya kıyasla araştırma probleminin daha iyi anlaşılması hedeflenmiştir. Veri ön işleme aşamasında konuyla ilgisiz içerikler veri seti dışında tutulmuştur.

Tablo 45: Örneklem Bilgisi

Kripto					
Para Hacim	XRP	LTC	ETH	BTC	Toplam
2020	3920	2074	23201	122320	151515
2021	31413	10740	182848	1009381	1214382
Toplam	35333	12814	206049	1131701	

Ön işleme süreci sonrasında analize dâhil edilen içeriklere hacimsel olarak bakıldığında 2020 yılı kapsamında belirtilen tarih aralığında toplamda 151515, 2021 yılında ise 1214382 içerik ele alınmıştır.

4.3. Araştırma Kısıtları

Çalışma amacına uygun olarak elde edilen veri setindeki içeriklerin yalnızca Türkçe olması ve diğer dillerin çalışma dışında tutulması nedeniyle coğrafi ve kültürel farklılaşma dikkate alınamamıştır.

4.4. Ön-Test Çalışması

Aşağıda, Twitter'dan elde edilen içerikler ile ilgili kripto paraların fiyatları arasındaki olası ilişkinin Yatırımcı Tanınmışlık hipotezi bağlamında araştırılması amacı ile bir ön-test ve duygu analizi yapılacaktır. Ancak analizlere başlamadan önce, veri setinin tanınmasını sağlayacak tanımlayıcı istatistikler ve grafiklere yer verilmektedir. Veri seti yaygın bilinen bir veri olmadığı için hem düzey hem logaritmik dönüştürülmüş halleri için bu bilgilerin paylaşılmasının uygun olacağı düşünülmüştür.

Twitter paylaşım hacimi ile kripto para fiyatları ile ilgili veriler 13.05.2020-27.09.2020 ve 13.05.2021-27.09.2021 tarihleri kapsamaktadır. Aşağıdaki bilgiler bu ayrıma dikkat ederek tablolandırılmıştır. Tablo 46'da haftalık kripto para fiyatlarının düzey hallerine ait tanımlayıcı istatistikler verilirken 2020 yılı için Şekil 50'de, 2021 yılı için zaman grafikleri Şekil 52'de verilmiştir. Tüm çalışmada değişkenlerin haftalık frekansı için "h", günlük frekansı için "g", logaritmik halleri için "L" kısaltması kullanılmıştır. Ayrıca kripto para birimlerine ait Twitter paylaşım hacimleri "T" kısaltması ile ifade edilmiştir.

Tablo 46: Tanımlayıcı İstatistikler (Düzye Kripto Para-Haftalık Frekans)

Kripto					
Para İstatistik	ETH-h	LTC-h	BTC-h	XRP-h	
2020 (Düzye)					
Ortalama	294.38	48.06	10,074.55	0.225257	
Medyan	242.51	46.50	9,739.01	0.205135	
Maksimum	430.57	61.54	11,849.00	0.298900	
Minimum	188.10	41.32	8,668.45	0.176120	


		Standart Sapma	77.28572	6.374829	986.4080	0.040825
		Jarque-Bera	2.698428	3.828987	2.03979016	2.249282
		<i>p-değeri</i>	0.259444	0.147416	0.360632776	0.324769
		Kripto				
2021 (Düzyey)	Para İstatistik	ETH-h	LTC-h	BTC-h	XRP-h	
	Ortalama	2,785.41	165.27	41,240.33	0.943226	
	Medyan	2,710.76	170.82	41,258.17	0.901420	
	Maksimum	3,922.46	224.56	57,958.91	1.531900	
	Minimum	1,816.58	119.07	31,651.52	0.586230	
	Standart Sapma	628.3367	31.32854	7060.556	0.289647	
	Jarque-Bera	1.133368	0.916295	1.195590	1.467940	
	<i>p-değeri</i>	0.567404	0.632454	0.550023	0.480000	

Değişkenlerin ait varyansda durağanlıklarının sağlanması ve eğriselliğin azaltılması için logaritmik dönüşüm gerçekleştirilmiştir. Tablo 47’de haftalık kripto para fiyatlarının logaritmik hallerine ait tanımlayıcı istatistikler verilirken, zaman grafikleri 2020 yılı için Şekil 51’de, 2021 yılı için Şekil 53’de verilmiştir.

Tablo 47: Tanımlayıcı İstatistikler (Logaritmik Kripto Para-Haftalık Frekans)


		Kripto				
2020 (Logaritmik)	Para İstatistik	LETH-h	LLTC-h	LBTC-h	LXRP-h	
	Ortalama	2.44	1.67	3.99	-0.65	
	Medyan	2.38	1.66	3.98	-0.68	
	Maksimum	2.63	1.78	4.07	-0.52	
	Minimum	2.27	1.61	3.93	-0.75	
	Standart Sapma	0.118211	0.057445	0.043447	0.075968	
	Jarque-Bera	2.235427	2.572709	1.872099	1.935939	
	<i>p-değeri</i>	0.327027	0.276276	0.392174	0.379854	
			Kripto			
	2021 (Logaritmik)	Para İstatistik	LETH-h	LLTC-h	LBTC-h	LXRP-h
Ortalama		3.43	2.21	4.00	-0.04	
Medyan		3.42	2.23	3.99	-0.04	
Maksimum		3.59	2.35	4.07	0.18	
Minimum		3.25	2.07	3.94	-0.23	
Standart Sapma		0.104905	0.085220	0.041836	0.132864	
Jarque-Bera		1.202593	0.730307	1.238017	1.410852	
<i>p-değeri</i>		0.548100	0.694090	0.538478	0.493898	

Aşağıda 13.05.2020-27.09.2020 ve 13.05.2021-27.09.2021 tarihleri arasında kripto paralara ait düzey ve logaritmik dönüşümlü verilerin zaman grafikleri Şekil 50’den - Şekil 53’e kadar sırasıyla verilmiştir.




Şekil 50: Düzey Kripto Para Zaman Grafikleri (2020-Haftalık Frekans)

2020 yılına ait (düzey) kripto fiyat grafiklerine bakıldığında, Temmuz ayı itibariyle fiyat yükselişlerinin olduğu görülmektedir.




Şekil 51: Logaritmik Kripto Para Zaman Grafikleri (2020-Haftalık Frekans)

2020 yılına ait logaritmik kripto fiyat grafiklerine bakıldığında, ölçeğin küçüldüğü ve yine Temmuz ayı itibariyle fiyat yükselişlerinin olduğu görülmektedir.



Şekil 52: Düzey Kripto Para Zaman Grafikleri (2021-Haftalık Frekans)

2021 yılına ait (düzey) kripto fiyat grafiklerine bakıldığında, Mayıs ayı itibariyle düşüş ve Temmuz ayı itibariyle fiyat yükselişlerinin olduğu görülmektedir.



Şekil 53: Logaritmik Kripto Para Zaman Grafikleri (2021-Haftalık Frekans)

2021 yılına ait logaritmik fiyat grafiklerine bakıldığında, yine Mayıs ayı itibariyle düşüş ve Temmuz ayı itibariyle fiyat yükselişlerinin olduğu görülmektedir.

Aşağıda 13.05.2020-27.09.2020 ve 13.05.2021-27.09.2021 tarihleri arasında haftalık kripto para fiyatlarıyla ilişkisi incelenecek olan Twitter paylaşımlarına ait tanımlayıcı istatistiklere yer verilmiştir. Tablo 48’de düzey, Tablo 49’da logaritmik Twitter Hacimleri verisi için tanımlayıcı istatistikleri verilirken Şekil 54 ve Şekil 55’de zaman grafikleri görülmektedir.

Tablo 48: Tanımlayıcı İstatistikler (Düzyer Twitter Hacimleri-Haftalık Frekans)

	Kripto					
	Para İstatistik	T_ETH-h	T_LTC-h	T_BTC-h	T_XRP-h	
2020 (Düzyer)	Ortalama	1115.900	142.7000	5509.500	202.6500	
	Medyan	988.0000	154.0000	5276.500	187.5000	
	Maksimum	2432.000	271.0000	7684.000	329.0000	
	Minimum	523.0000	63.00000	3989.000	122.0000	
	Standart Sapma	544.8413	47.71196	1014.888	58.75307	
	Jarque-Bera	2.576836	1.682138	1.367816	3.220267	
	<i>p-değeri</i>	0.275707	0.431249	0.504641	0.199861	
	2021 (Düzyer)	Ortalama	9333.400	16020.75	52920.60	1642.050
		Medyan	9448.500	11863.50	46424.00	1360.000
Maksimum		19213.00	26328.00	96243.00	3632.000	
Minimum		4501.000	11165.00	27184.00	549.0000	
Standart Sapma		4527.267	5584.800	20599.17	864.8840	
Jarque-Bera		1.514008	2.349869	1.703207	3.795540	
<i>p-değeri</i>		0.469070	0.308839	0.426730	0.149903	


Düzyer veri analizlerinden sonra ölçeklerin küçültülmesi ve varolan eğriselliklerin azaltılması için logaritmik dönüşüm gerçekleştirilmiştir. Aşağıda Twitter paylaşımlarının logaritmik hallerine ait tanımlayıcı istatistikler verilmiştir.

Tablo 49: Tanımlayıcı İstatistikler (Logaritmik Twitter Hacimleri-Haftalık Frekans)

	Kripto					
	Para İstatistik	LT_ETH-h	LT_LTC-h	LT_BTC-h	LT_XRP-h	
2020 (Logaritmik)	Ortalama	6.91	4.90	8.59	5.27	
	Medyan	6.89	5.03	8.57	5.23	
	Maksimum	7.79	5.60	8.94	5.79	
	Minimum	6.25	4.14	8.29	4.80	
	Standart Sapma	0.469967	0.346759	0.179558	0.270674	
	Jarque-Bera	1.217064	0.439641	0.511319	1.015171	
	<i>p-değeri</i>	0.544149	0.805663	0.774405	0.601947	
	2021 (Log)	Kripto				
		Para İstatistik	LT_ETH-h	LT_LTC-h	LT_BTC-h	LT_XRP-h


Ortalama	9.02	9.62	10.80	7.28
Medyan	9.15	9.38	10.74	7.21
Maksimum	9.86	10.17	11.47	8.19
Minimum	8.41	9.32	10.21	6.30
Standart Sapma	0.491117	0.337814	0.383564	0.504138
Jarque-Bera	1.714844	2.652837	1.220666	0.170751
<i>p-değeri</i>	0.424254	0.265426	0.543170	0.918167

Kripto paralara ait Twitter paylaşımlarının düzey ve logaritmik dönüşüm verilerine ait zaman grafikleri 2020 yılı için Şekil 54 ve Şekil 55; 2021 yılı için Şekil 56 ve Şekil 57’de görülmektedir.




Şekil 54: Düzey Twitter Hacimleri Zaman Grafikleri (2020-Haftalık Frekans)

2020 yılına ait düzey Twitter hacim grafiklerine bakıldığında, Mayıs ayı itibariyle içeriklerde düşüş, Temmuz ayı itibariyle ise yükselişler olmakla birlikte paylaşımlarda dönemsel olarak artış ve azalışların olduğunu söylemek mümkündür.




Şekil 55: Logaritmik Twitter Hacimleri Zaman Grafikleri (2020-Haftalık Frekans)

2020 yılına ait logaritmik Twitter hacim grafiklerine bakıldığında, ölçeklerin küçüldüğü ve paylaşımlarda dönemsel olarak artış ve azalışlar olduğu görülmektedir.



Şekil 56: Düzey Twitter Hacimleri Zaman Grafikleri (2021-Haftalık Frekans)



Şekil 57: Logaritmik Twitter Hacimleri Zaman Grafikleri (2021-Haftalık Frekans)

2021 yılına ait düzey (Şekil 56) ve logaritmik (Şekil 57) Twitter hacim grafiklerine bakıldığında, Temmuz ayı itibariyle paylaşımlarda yükseliş ve bütün olarak bakıldığında dönemsel dalgalanmaların olduğu görülmektedir.

Zaman grafikleri 2020 ve 2021 dönemleri kapsamında genel olarak değerlendirildiğinde, logaritmik fiyat grafikleri (Şekil 51 – Şekil 53) ile logaritmik Twitter hacim grafikleri (Şekil 55 – Şekil 57) arasında dönemsel artış ve azalışlarda paralellik olduğu görülmektedir.

Tez çalışmasının birinci bölümünde kripto para ile yatırımcı ilgisi arasındaki ilişkinin ölçüldüğü Markov rejim değişim model çalışması verilmişti. Çalışmada, kripto paraların yalnızca fiyatları değil, arama sıklıklarının dolayısıyla da popüleritesinin takip edilmesi halinde bir sonraki dönemin rejiminin de tahmin edilmesinin mümkün olduğu belirlenmiştir. Aşağıda ise birimlerin kendi girdileri ile çıktılarını ne ölçüde yaratabildiklerinin ölçülmesine dair altyapı oluşturulmuş

ve parametrik olmayan yaklaşımlardan birisi olan Veri Zarflama Analizi (VZA) gerçekleştirilerek belirli zaman dilimindeki kripto para performans değerlendirmesi yapılmıştır. Çalışmanın güvenilirliğinin yüksek olabilmesi için karar birimi sayısının doğru belirlenmesi gerekmektedir. Bu noktada genel kabul gören kısıt; analizde en az “ k ” seçilen girdi sayısını, “ p ” seçilen çıktı sayısını ifade etmek üzere “ $k+p+1$ ” adet karar biriminin ele alınması gerektiğidir (Ağ, 2019: 2662). Aynı zamanda analizin diğer kısıtı ise ele alınan tüm değişkenlerin pozitif değerli veya sıfır olması gerektiğidir (Budak, 2011: 101). Bu bağlamda çalışma kapsamında temel alınan Gündem Belirleme Kuramı ve Yatırımcı Tanınmışlık Hipotezi kapsamında kripto para fiyat hareketlerinin incelenmesinde kullanılan bu teknikte negatif değer kısıtlaması olması nedeniyle; Twitter paylaşımları girdi ve kripto para fiyatları çıktı değişkeni olarak ele alınmış olup, dört karar birimi (kripto para birimleri) açısından incelenmiştir. Yapılan analizde Banker, Charnes ve Cooper (1984) tarafından önerilen, ölçeğe göre değişen getiri varsayımı altında karar birimlerinin etkinliğinin ölçüldüğü BCC modeli tahminleri hem girdi hem de çıktı yönlü olmak üzere tahmin edilmiştir. Teknik etkinlik ile ölçek etkinliğinin CCR modelinde karışmış olduğu Banker, Farrell tarafından ispatlanmış ve bu nedenle teknik etkinliğin ölçek ve saf teknik etkinlik olarak ikiye ayrılması gerektiği ifade edilmiştir (Örkcü ve Doğan, 2015: 29). Bu nedenle ölçeğe göre değişen getiri varsayımı altında saf teknik etkinliğin değerlendirilmesini olanak veren BCC modeli tercih edilmiştir. Bu teknik sayesinde kullanılan veriye göre her karar verme birimine ait görece azami performans hesaplanabilmektedir. Böylece fonksiyonel, optimum girdi/çıktı bileşimini sağlayan “en iyi uygulama” sınırı veya diğer adıyla “veri zarfı” elde edilebilmektedir (Münyas, 2018: 119). Modelin yöneliminin belirlenmesinde; *“amaç belirli bir girdi ile maksimum çıktının üretilmesi mi, yoksa belirli çıktıyla en az girdinin üretilmesi mi?”* sorusunun sorulması gerekmektedir (Yücel, 2017: 35). Girdiler üzerinde hâkimiyet daha fazla ise girdi odaklı, çıktılar üzerinde hâkimiyet gücü daha fazla ise çıktı odaklı VZA modelinin uygulanmasının uygun olduğu kabul edilmektedir. Ancak alanyazında kripto para piyasasının Gündem Belirleme Kuramı gereği sosyal medya içerikleriyle ilişkisinin araştırıldığı herhangi bir çalışma mevcut olmadığından ve keşifsel bir süreç olduğundan tahmin edilen BCC modelleri, hem girdi hem de çıktı yönlü olarak ele alınmıştır. Böylece elde edilen sonuçlar ile karar verme ve yeni politika üretilmesine katkı sağlanması hedeflenmiştir. Veri zarflama analizi EMS (Efficiency Measurement System) 1.3 paket programı ile gerçekleştirilmiş olup sonuçları tablolararak (Tablo 50’den Tablo 53’e kadar) verilmiştir.

Tablo 50: BCC Çıktı Odaklı Değişken VZA Sonuç Tablosu (2020)

DMU		17.05.2020	24.05.2020	31.05.2020	07.06.2020	14.06.2020	21.06.2020	28.06.2020	05.07.2020	12.07.2020
Kripto Para	Dönem	-	-	-	-	-	-	-	-	-
		23.05.2020	30.05.2020	06.06.2020	13.06.2020	20.06.2020	27.06.2020	04.07.2020	11.07.2020	18.07.2020
XRP	SCORE	100%	100%	100%	100%	42.27%	36.45%	45.28%	100%	100%
	RANK	1	1	1	1	2	2	2	1	1
LTC	SCORE	100%	100%	100%	100%	100%	100%	100%	100%	100%
	RANK	1	1	1	1	1	1	1	1	1
ETH	SCORE	100%	100%	100%	100%	100%	100%	100%	100%	100%
	RANK	1	1	1	1	1	1	1	1	1
BTC	SCORE	40.28%	33.30%	23.78%	28.76%	100%	100%	100%	78.16%	56.91%
	RANK	2	2	2	2	1	1	1	2	2

DMU		19.07.2020	26.07.2020	02.08.2020	09.08.2020	16.08.2020	23.08.2020	30.08.2020	06.09.2020	13.09.2020	20.09.2020
Kripto Para	Dönem	-	-	-	-	-	-	-	-	-	-
		25.07.2020	01.08.2020	10.08.2020	15.08.2020	22.08.2020	29.08.2020	05.09.2020	12.09.2020	21.09.2020	26.09.2020
XRP	SCORE	100%	100%	100%	100%	100%	100%	100%	100%	100%	100%
	RANK	1	1	1	1	1	1	1	1	1	1
LTC	SCORE	100%	100%	100%	100%	100%	100%	33.31%	35.72%	39.11%	45.86%
	RANK	1	1	1	1	1	1	2	2	2	2
ETH	SCORE	55.55%	52.34%	100%	100%	100%	100%	100%	100%	100%	100%
	RANK	2	2	1	1	1	1	1	1	1	1
BTC	SCORE	100%	100%	49.81%	57.70%	59.23%	63.20%	100%	100%	100%	100%
	RANK	1	1	2	2	2	2	1	1	1	1

Tablo 51: BCC Girdi Odaklı Değişken VZA Sonuç Tablosu (2020)

DMU	Kripto Para	Dönem	17.05.2020	24.05.2020	31.05.2020	07.06.2020	14.06.2020	21.06.2020	28.06.2020	05.07.2020	12.07.2020
			23.05.2020	30.05.2020	06.06.2020	13.06.2020	20.06.2020	27.06.2020	04.07.2020	11.07.2020	18.07.2020
XRP	SCORE		48.15%	32.14%	15.12%	76.21%	40.15%	50.00%	100%	35.97%	100%
	RANK		4	4	4	2	4	4	1	3	1
LTC	SCORE		100%	82.23%	40.15%	40.11%	52.22%	66.21%	55.50%	15.21%	60.32%
	RANK		1	2	3	4	3	3	3	4	3
ETH	SCORE		90.15%	100%	72.92%	82.31%	100%	100%	32.36%	70.17%	62.24%
	RANK		2	1	1	1	1	1	4	2	2
BTC	SCORE		68.25%	75.10%	45.22%	55.20%	80.30%	92.26%	65.20%	100%	100%
	RANK		3	3	2	3	2	2	2	1	1

DMU	Kripto Para	Dönem	19.07.2020	26.07.2020	02.08.2020	09.08.2020	16.08.2020	23.08.2020	30.08.2020	06.09.2020	13.09.2020	20.09.2020
			25.07.2020	01.08.2020	10.08.2020	15.08.2020	22.08.2020	29.08.2020	05.09.2020	12.09.2020	21.09.2020	26.09.2020
XRP	SCORE		65.48%	100%	13.16%	60.08%	50.22%	100%	60.60%	75.70%	65.60%	75.12%
	RANK		3	1	4	4	4	1	3	1	2	2
LTC	SCORE		66.62%	100%	20.71%	65.63%	78.24%	100%	47.88%	47.42%	50.12%	40.10%
	RANK		2	1	3	3	3	1	4	3	3	4
ETH	SCORE		60.19%	100%	42.01%	92.81%	90.00%	100%	85.80%	16.21%	55.25%	55.10%
	RANK		4	1	2	2	2	1	2	4	4	3
BTC	SCORE		74.23%	90.45%	73.39%	100%	100%	100%	100%	60.50%	90.15%	100%
	RANK		1	2	1	1	1	1	1	2	1	1

Tablo 52: BCC Çıktı Odaklı Değişken VZA Sonuç Tablosu (2021)

DMU		17.05.2021	24.05.2021	31.05.2021	07.06.2021	14.06.2021	21.06.2021	28.06.2021	05.07.2021	12.07.2021
Kripto Para	Dönem	-	-	-	-	-	-	-	-	-
		23.05.2021	30.05.2021	06.06.2021	13.06.2021	20.06.2021	27.06.2021	04.07.2021	11.07.2021	18.07.2021
XRP	SCORE	55.16%	41.10%	40.12%	100%	100%	100%	100%	100%	100%
	RANK	3	2	2	1	1	1	1	1	1
LTC	SCORE	100%	100%	100%	100%	100%	100%	100%	100%	100%
	RANK	1	1	1	1	1	1	1	1	1
ETH	SCORE	100%	100%	100%	81.30%	92.20%	91.15%	72.21%	70.18%	65.25%
	RANK	1	1	1	2	2	2	2	2	2
BTC	SCORE	62.24%	33.32%	38.98%	100%	100%	100%	42.13%	40.09%	47.32%
	RANK	2	3	3	1	1	1	3	3	3

DMU		19.07.2021	26.07.2021	02.08.2021	09.08.2021	16.08.2021	23.08.2021	30.08.2021	06.09.2021	13.09.2021	20.09.2021
Kripto Para	Dönem	-	-	-	-	-	-	-	-	-	-
		25.07.2021	01.08.2021	10.08.2021	15.08.2021	22.08.2021	29.08.2021	05.09.2021	12.09.2021	21.09.2021	26.09.2021
XRP	SCORE	100%	100%	100%	100%	100%	100%	100%	100%	100%	100%
	RANK	1	1	1	1	1	1	1	1	1	1
LTC	SCORE	100%	100%	52.23%	61.14%	66.16%	100%	100%	100%	100%	100%
	RANK	1	1	2	2	2	1	1	1	1	1
ETH	SCORE	100%	100%	100%	100%	100%	66.12%	72.35%	84.43%	100%	100%
	RANK	1	1	1	1	1	2	2	2	1	1
BTC	SCORE	100%	100%	100%	100%	32.85%	42.10%	37.58%	100%	100%	100%
	RANK	1	1	1	1	3	3	3	1	1	1

Tablo 53: BCC Girdi Odaklı Değişken VZA Sonuç Tablosu (2021)

DMU		17.05.2021	24.05.2021	31.05.2021	07.06.2021	14.06.2021	21.06.2021	28.06.2021	05.07.2021	12.07.2021
Kripto Para	Dönem	-	-	-	-	-	-	-	-	-
		23.05.2021	30.05.2021	06.06.2021	13.06.2021	20.06.2021	27.06.2021	04.07.2021	11.07.2021	18.07.2021
XRP	SCORE	44.52%	28.80%	12.10%	25.25%	30.12%	50.00%	30.04%	52.83%	35.82%
	RANK	3	3	4	4	3	3	4	3	2
LTC	SCORE	100%	100%	100%	99.00%	100%	100%	100%	100%	100%
	RANK	1	1	1	1	1	1	1	1	1
ETH	SCORE	100%	100%	60.00%	80.01%	100%	100%	95.00%	70.08%	100%
	RANK	1	1	2	2	1	1	2	2	1
BTC	SCORE	62.88%	60.68%	58.53%	50.77%	90.01%	91.11%	63.31%	100%	100%
	RANK	2	2	3	3	2	2	3	1	1

DMU		19.07.2021	26.07.2021	02.08.2021	09.08.2021	16.08.2021	23.08.2021	30.08.2021	06.09.2021	13.09.2021	20.09.2021
Kripto Para	Dönem	-	-	-	-	-	-	-	-	-	-
		25.07.2021	01.08.2021	10.08.2021	15.08.2021	22.08.2021	29.08.2021	05.09.2021	12.09.2021	21.09.2021	26.09.2021
XRP	SCORE	18.32%	13.48%	19.42%	28.85%	25.20%	100%	100%	75.24%	85.10%	55.10%
	RANK	4	4	3	4	4	1	1	1	2	4
LTC	SCORE	100%	90.00%	100%	45.50%	74.44%	41.21%	75.00%	49.44%	100%	58.82%
	RANK	1	2	1	3	2	3	2	3	1	3
ETH	SCORE	90.74%	91.10%	23.06%	56.30%	63.30%	80.79%	59.80%	26.37%	100%	80.45%
	RANK	2	1	2	2	3	2	3	4	1	2
BTC	SCORE	45.45%	76.60%	100%	100%	85.57%	100%	100%	73.12%	70.52%	92.34%
	RANK	3	3	1	1	1	1	1	2	3	1

VZA sonucunda görelî etkinlik skorları hesaplanmıştır. En iyi skora sahip birimlere ait etkinlik skorları 100 olarak hesaplanmakta ve etkin olarak belirlenmektedir. Etkin olmayan birimlerin skorları ise görelî olarak 0-100 arasında olmaktadır. Bu birimlerin etkinlik skorları 100 değerine çok yakın olsa bile teknik açıdan etkin olmayan birimler olarak değerlendirilmektedir. 2020 ve 2021 yılı kapsamında tahmin edilen çıktı odaklı BCC modeline bakıldığında (Tablo 50 ve Tablo 52) ilgili kripto paraların etkinlik durumunun haftalara göre farklılaştığı görülmektedir. 2020 yılında çıktı odaklı modele bakıldığında ilgili haftalarda en etkin kripto paranın ETH olduğu görülürken, diğer kripto paraları XRP, LTC ve BTC şeklinde etkinliklerine göre sıralanmaktadır. 2021 yılında çıktı odaklı modele bakıldığında ise ilgili haftalarda en etkin kripto paraların XRP ve LTC olduğu görülürken, diğer kripto paraları ETH ve BTC şeklinde etkinliklerine göre sıralanmaktadır. Ayrıca “19.07.2021-25.07.2021”, “26.07.2021-01.08.2021”, “13.09.2021-21.09.2021” ve “20.09.2021-26.09.2021” haftalarında kripto paraların hepsinin etkin olduğu tespit edilmiştir. Buradan hareketle, kripto para fiyatlarının Twitter paylaşımlarında belirleyici olduğunu söylemek mümkündür. Girdi yönlü BCC model sonuçlarına bakıldığında (Tablo 50 ve Tablo 52), ilgili kripto para fiyat etkinliklerinin incelenen haftalara göre farklılık gösterdiğini söylemek mümkündür. 2020 yılında girdi odaklı modele bakıldığında ilgili haftalarda en etkin kripto paranın BTC olduğu görülürken, diğer kripto paraları ETH, XRP ve LTC şeklinde etkinliklerine göre sıralanmaktadır. Ayrıca “23.08.2020-29.08.2020” haftasında tüm kripto paraların etkin olduğu tespit edilmiştir. 2021 yılında girdi odaklı modele bakıldığında ise en etkin kripto paranın LTC olduğu görülürken, diğer kripto paraları BTC, ETH ve XRP şeklinde etkinliklerine göre sıralanmaktadır. Dolayısıyla Twitter paylaşımlarının ilgili kripto para fiyatlarının etkinliğinde dönemsel olarak etkisinin olduğu söylenebilir. Aynı zamanda tespit edilen dönemlerin, kripto para zaman grafikleri (Şekil 50 ve Şekil 52) ve Twitter hacim grafikleri (Şekil 54 ve Şekil 56) ile de paralellik gösterdiğini söylenebilir. Tüm bulgular değerlendirildiğinde, sosyal medya içeriklerinin ilgili kripto paralar üzerinde etkinlik sağladığı tespit edilmiştir. Bu noktada başlık 3.1’de verilen, medya ilgisinin alım-satım kararları üzerindeki etkisinin Gündem Belirleme Kuramı ile yakından ilişkili olduğu tahmin edilen modeller aracılığı ile desteklendiği şeklinde yorumlanabilir.

Aşağıda ikinci olarak, finansal piyasalar hakkındaki bilgilerin medya kanalları aracılığı ile bireylere aktarılmasının kitle alım-satım kararlarında ve dolayısıyla fiyatlar üzerinde etkileyici olduğu varsayımının geçerliliğini desteklenmesi amacı ile değişkenler arasındaki ilişkilerin yönünün belirlenebilmesi için doğrusal olmayan Granger nedensellik testi gerçekleştirilmiştir. Doğrusal olmayan Granger nedensellik testi, 13.05.2020-27.09.2020 ve 13.05.2021-27.09.2021 dönemlerinde günlük verilerle uygulanmıştır.

Doğrusal olan veya doğrusal olmayan seriler için nedensellik analizi, durağanlık varsayımına dayanmaktadır. Bu nedenle aşağıda serilerin durağan olup olmadıklarının ve doğrusal olup olmadıklarının belirlenmesi amacı ile testler yapılmıştır. Ancak ilk olarak verilerin yaygın kullanılan ve bilinen seriler olmaması nedeni ile, tanımsal istatistikleri düzey ve logaritmik halleri içinde verilmiştir. Ardından doğrusal olmadıkları ve durağan olmadıkları belirlendiği için logaritmik fark serileri olarak analizlere katılmış ve bu seriler hakkında da açıklayıcı bilgiler verilmiştir.

13.05.2020-27.09.2020 ve 13.05.2021-27.09.2021 dönemi için günlük frekanslı değişkenlerin düzey ve logaritmik hallerine ait tanımlayıcı istatistikler Tablo 54 ve Tablo 55’te verilmiştir. g-yan eki, verinin günlük olduğunu göstermektedir.

Tablo 54: Tanımlayıcı İstatistikler (Düzyen Kripto Para-Günlük Frekans)

2020 (Düzyen)	Kripto	ETH-g	LTC-g	BTC-g	XRP-g
	Para İstatistik				
	Ortalama	350.32	163.39	2,169.07	73.08
	Medyan	321.49	141.20	1,687.40	66.96
	Maksimum	502.15	235.68	3,554.70	92.10
	Minimum	283.00	120.80	1,364.90	60.42
	Standart Sapma	57.32	34.10	6,47.81	9.58
	Jarque-Bera	16.59	15.74	16.71	17.36
	<i>p-değeri</i>	0.000	0.000	0.000	0.000
2021 (Düzyen)	Kripto	ETH-g	LTC-g	BTC-g	XRP-g
	Para İstatistik				
	Ortalama	1,421.72	784.01	23,393.20	345.26
	Medyan	1,425.96	780.43	22,828.70	335.97
	Maksimum	2,757.13	1338.44	34,358.10	435.72
	Minimum	930.16	459.27	15,498.80	259.40
	Standart Sapma	3,15.01	203.30	4,748.91	48.51
	Jarque-Bera	313.39	5.33	7.59	11.91
	<i>p-değeri</i>	0.000	0.007	0.020	0.000


Değişkenlerdeki varyansda durağan olmamayı ve/veya eğriselliği ortadan kaldırmak veya azaltmak için logaritmik dönüşüm gerçekleştirilmiştir. Günlük logaritmik kripto para fiyatlarına ait tanımlayıcı istatistikler Tablo 55’te verilmiştir.

Tablo 55: Tanımlayıcı İstatistikler (Logaritmik Kripto Para-Günlük Frekans)

2020 (Logarit)	Kripto	LETH-g	LLTC-g	LBTC-g	LXRP-g
	Para İstatistik				
	Ortalama	2.539	2.204	3.317	1.860

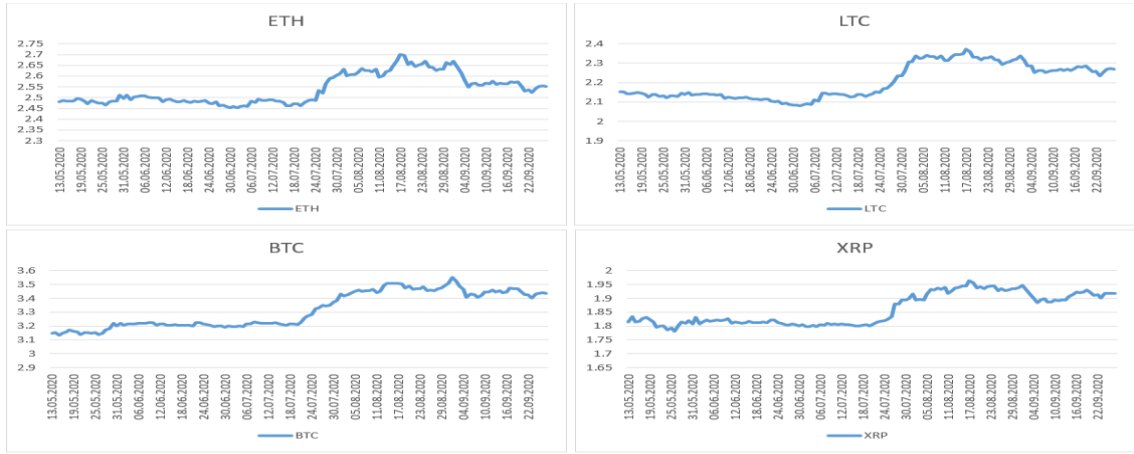
Medyan	2.507	2.150	3.227	1.826	
Maksimum	2.701	2.372	3.551	1.964	
Minimum	2.452	2.082	3.135	1.781	
Standart Sapma	0.068	0.089	0.129	0.056	
Jarque-Bera	14.481	15.753	17.325	17.752	
<i>p-değeri</i>	0.001	0.000	0.000	0.000	
2021 (Logaritmik)	Kripto Para İstatistik	LETH-g	LLTC-g	LBTC-g	LXRP-g
	Ortalama	3.144	2.880	4.360	2.534
	Medyan	3.154	2.892	4.358	2.526
	Maksimum	3.440	3.127	4.536	2.639
	Minimum	2.969	2.662	4.190	2.414
	Standart Sapma	0.085	0.114	0.089	0.061
	Jarque-Bera	54.507	6.714	7.811	11.149
	<i>p-değeri</i>	0.000	0.035	0.020	0.004

13.05.2020-27.09.2020 ve 13.05.2021-27.09.2021 dönemlerinde değişkenlere ait düzey ve logaritmik zaman grafikleri Şekil 58-Şekil 61 arasında verilmiştir.




Şekil 58: Düzey Kripto Para Zaman Grafikleri (2020-Günlük Frekans)

Şekil 58’de verilen 2020 yılına ait günlük düzey kripto fiyat grafiklerine bakıldığında, Temmuz ayından itibaren fiyat yükselişlerinin olduğu görülmektedir.




Şekil 59: Logaritmik Kripto Para Zaman Grafikleri (2020-Günlük Frekans)

2020 yılına ait logaritmik kripto fiyat grafiklerine bakıldığında, ölçeğin küçüldüğü ve yine Temmuz ayı itibariyle fiyat yükselişlerinin olduğu görülmektedir.



Şekil 60: Düzey Kripto Para Zaman Grafikleri (2021-Günlük Frekans)

Şekil 60’da verilen 2021 yılına ait düzey günlük kripto fiyat grafiklerinde, Mayıs ayından itibaren düşüş ve Temmuz ayından itibaren yükselişin olduğu görülmektedir.



Şekil 61: Logaritmik Kripto Para Zaman Grafikleri (2021-Günlük Frekans)

Şekil 61’de 2021 yılına ait logaritmik fiyat grafikleri verilmiştir. Burada da Mayıs ayı itibariyle düşüş ve Temmuz ayı itibariyle fiyat yükselişlerinin olduğu görülmektedir.

Aşağıda 13.05.2020-27.09.2020 ve 13.05.2021-27.09.2021 tarihleri arasında kripto paralarla ilgili günlük Twitter paylaşımlarına ait tanımlayıcı istatistikler, Tablo 56’da düzey, Tablo 57’de logaritmik Twitter Hacimleri verisi için verilmiştir.

Tablo 56: Tanımlayıcı İstatistikler (Düzyer Twitter Hacim-Günlük Frekans)

	Kripto				
	Para İstatistik	T_LTC-g	T_XRP-g	T_ETH-g	T_BTC-g
2020 (Düzyer)	Ortalama	29.3188	22.4493	160.4710	786.5435
	Medyan	26.0000	19.0000	111.5000	734.0000
	Maksimum	72.0000	78.0000	651.0000	2692.0000
	Minimum	10.0000	10.0000	38.0000	334.0000
	Standart Sapma	11.7691	11.8605	123.9428	292.7616
	Jarque-Bera	101.6219	457.3544	153.8335	1876.4063
	<i>p-değeri</i>	0.0000	0.0000	0.0000	0.0000
2021 (Düzyer)	Ortalama	227.7971	42.8623	1749.1377	7359.3768
	Medyan	193.0000	36.0000	1683.5000	6685.5000
	Maksimum	991.0000	160.0000	4019.0000	36672.0000
	Minimum	100.0000	14.0000	1046.0000	2968.0000


Standart Sapma	121.5649	23.1394	473.8691	4098.0110
Jarque-Bera	1099.6954	277.7926	299.0885	2511.0407
<i>p-değeri</i>	0.0000	0.0000	0.0000	0.0000

Değişkenlerin varyansda durağanlıklarının sağlanması ve eğriselliğin azaltılmasını sağlamak amacı ile logaritmik dönüşüm gerçekleştirilmiştir. Tablo 57’de günlük kripto para fiyatlarının logaritmik hallerine ait tanımlayıcı istatistikler verilmiştir.

Tablo 57: Tanımlayıcı İstatistikler (Logaritmik Kripto Para Fiyatı-Günlük Frekans)


2020 (Logaritmik)	Kripto Para İstatistik	LT_LTC-g	LT_XRP-g	LT_ETH-g	LT_BTC-g
		Ortalama	1.4379	1.3055	2.1107
	Medyan	1.4150	1.2788	2.0473	2.8657
	Maksimum	1.8573	1.8921	2.8136	3.4301
	Minimum	1.0000	1.0000	1.5798	2.5237
	Standart Sapma	0.1555	0.1920	0.2722	0.1322
	Jarque-Bera	6.1442	7.8492	10.6329	57.9554
	<i>p-değeri</i>	0.0463	0.0197	0.0049	0.0000
2021 (Logaritmik)	Kripto Para İstatistik	LT_LTC-g	LT_XRP-g	LT_ETH-g	LT_BTC-g
		Ortalama	2.3154	1.5835	3.2299
	Medyan	2.2856	1.5563	3.2262	3.8251
	Maksimum	2.9961	2.2041	3.6041	4.5643
	Minimum	2.0000	1.1461	3.0195	3.4725
	Standart Sapma	0.1801	0.1978	0.1024	0.1930
	Jarque-Bera	25.8775	7.7340	43.3391	9.7649
	<i>p-değeri</i>	0.0000	0.0209	0.0000	0.0076

13.05.2020-27.09.2020 ve 13.05.2021-27.09.2021 tarihleri arasında değişkenlere ait günlük düzey ve logaritmik zaman grafikleri, 2020 için Şekil 54 ve Şekil 55’de; 2021 için Şekil 56 ve Şekil 57’de verilmiştir.




Şekil 62: Düzey Twitter Hacim Zaman Grafikleri (2020-Günlük Frekans)

Şekil 62’de 2020 yılına ait günlük düzey Twitter hacim grafiklerine bakıldığında, Temmuz ayı itibariyle ise yükselişler olmakla birlikte paylaşımlarda dönemsel olarak artış ve azalışların olduğunu söylemek mümkündür.




Şekil 63: Logaritmik Twitter Hacim Zaman Grafikleri (2020-Günlük Frekans)

Şekil 63’de 2020 yılına ait logaritmik Twitter hacim grafikleri verilmiştir. Twitter paylaşımlarında dönemsel olarak artış ve azalışlar olduğu görülmektedir.



Şekil 64: Düzey Twitter Hacim Zaman Grafikleri (2021-Günlük Frekans)

Şekil 64’de verilmiş olan 2021 yılına ait günlük düzey Twitter hacim, grafiklerinde, bu zaman diliminde de dönemsel olarak artış ve azalışların olduğu görülmektedir.



Şekil 65: Logaritmik Twitter Hacim Zaman Grafikleri (2021-Günlük Frekans)

Şekil 65’de 2021 yılına ait günlük logaritmik Twitter hacim grafiklerine bakıldığında, bazı fiyat paylaşımlarında dönemsel olarak artış ve azalışların olduğu, bazı paylaşımların ise istikrarlı olduğu görülmektedir.

Yukarıda günlük serilerin genel özellikleri hakkında bilgiler verildi ve doğrusal olmayan Granger nedensellik analizi yapılabilmesi için serilerin durağanlık ve doğrusallık durumlarının ortaya konulması gerektiğinden bahsedildi. Aşağıda ilk olarak günlük frekanslı değişkenlerin doğrusal olup olmadıkları BDS testi aracılığıyla incelenmiştir. Burada da yukarıda izlenen yol izlenmiş ve tüm değişkenlerin bilinen seriler olmaması nedeni ile BDS testi; 2020 ve 2021 dönemleri için logaritmik ve logaritmik fark serilerine uygulanmış ve test sonuçları Tablo 58, Tablo 59, Tablo 60 ve Tablo 61’de verilmiştir.

Tablo 58: BDS Testi Sonuçları (Logaritmik Kripto Para – Günlük Frekans)

2020	Boyut	BDS Test İstatistiği	Std. Hata	Z-İstatistiği	p-değeri
LBTC-g	2	0.176559	0.003727	47.37034	0.0000
	3	0.303571	0.005906	51.40425	0.0000
	4	0.391123	0.007007	55.81960	0.0000
	5	0.448497	0.007275	61.65005	0.0000
	6	0.484994	0.006987	69.40937	0.0000
LETH-g	2	0.184460	0.005017	36.76404	0.0000
	3	0.315136	0.007982	39.48171	0.0000
	4	0.402655	0.009511	42.33704	0.0000
	5	0.457901	0.009917	46.17143	0.0000
	6	0.489881	0.009568	51.20221	0.0000
LLTC-g	2	0.190212	0.004319	44.03822	0.0000
	3	0.324220	0.006850	47.32851	0.0000
	4	0.414238	0.008137	50.90873	0.0000
	5	0.473134	0.008458	55.94112	0.0000
	6	0.510045	0.008133	62.71298	0.0000
LXRP-g	2	0.172525	0.004309	40.03672	0.0000
	3	0.293429	0.006816	43.04928	0.0000
	4	0.373194	0.008075	46.21860	0.0000
	5	0.426984	0.008370	51.01061	0.0000
	6	0.467051	0.008028	58.18031	0.0000
2021	Boyut	BDS Test İstatistiği	Std. Hata	Z-İstatistiği	p-değeri
LBT C-g	2	0.161747	0.003518	45.978886	0.0000
	3	0.274698	0.005579	49.23700	0.0000
	4	0.350514	0.006626	52.90351	0.0000

	5	0.396897	0.006885	57.64662	0.0000
	6	0.422287	0.006619	63.80176	0.0000
	Boyut	BDS Test İstatistiği	Std. Hata	Z-İstatistiği	p-değeri
LETH-g	2	0.162346	0.006966	23.30430	0.0000
	3	0.273812	0.011088	24.69480	0.0000
	4	0.345064	0.013223	26.09551	0.0000
	5	0.388182	0.013803	28.12350	0.0000
	6	0.410894	0.013331	30.82244	0.0000
	Boyut	BDS Test İstatistiği	Std. Hata	Z-İstatistiği	p-değeri
LLTC-g	2	0.166170	0.003694	44.98853	0.0000
	3	0.282792	0.005861	48.25179	0.0000
	4	0.362442	0.006964	52.04727	0.0000
	5	0.412413	0.007240	56.96018	0.0000
	6	0.442102	0.006964	63.48196	0.0000
	Boyut	BDS Test İstatistiği	Std. Hata	Z-İstatistiği	p-değeri
LXRP-g	2	0.160823	0.003511	45.80530	0.0000
	3	0.274459	0.005576	49.21789	0.0000
	4	0.348340	0.006632	52.52370	0.0000
	5	0.394879	0.006902	57.21302	0.0000
	6	0.421952	0.006645	63.50180	0.0000

Tablo 59: BDS Testi Sonuçları (Logaritmik Fark Kripto Para – Günlük Frekans)

2020	Boyut	BDS Test İstatistiği	Std. Hata	Z-İstatistiği	<i>p</i> -değeri
Δ LBTC-g	2	0.058460	0.006425	9.099361	0.0000
	3	0.086492	0.010271	8.420637	0.0000
	4	0.093806	0.012303	7.624757	0.0000
	5	0.087175	0.012897	6.759160	0.0000
	6	0.084534	0.012510	6.757537	0.0000
Δ LETH-g	2	0.021067	0.007962	2.646008	0.0081
	3	0.044323	0.012714	3.486252	0.0005
	4	0.057522	0.015214	3.780748	0.0002
	5	0.062680	0.015937	3.932893	0.0001
	6	0.068588	0.015448	4.439983	0.0000
Δ LLTC-g	2	0.056455	0.006512	8.668865	0.0000
	3	0.092608	0.010358	8.940810	0.0000
	4	0.107436	0.012343	8.704519	0.0000
	5	0.100143	0.012873	7.779532	0.0000
	6	0.095849	0.012422	7.716248	0.0000
Δ LXRP-g	2	0.027383	0.008267	3.312406	0.0009
	3	0.044751	0.013219	3.385372	0.0007
	4	0.058468	0.015842	3.690800	0.0002
	5	0.057586	0.016619	3.465147	0.0005
	6	0.057503	0.016132	3.564459	0.0004
2021	Boyut	BDS Test İstatistiği	Std. Hata	Z-İstatistiği	<i>p</i> -değeri

Δ LBTC-g	2	0.029571	0.010897	2.713770	0.0067
	3	0.032023	0.013269	2.413403	0.0158
	4	0.042380	0.013011	3.257326	0.0011
	5	0.046844	0.012597	3.445148	0.0006
	6	0.048004	0.013148	3.651115	0.0003
		Boyut	BDS Test İstatistiği	Std. Hata	Z-İstatistiği
Δ LETH-g	2	0.037571	0.012689	2.960959	0.0031
	3	0.050092	0.015198	3.296061	0.0010
	4	0.056847	0.015933	3.567796	0.0004
	5	0.058877	0.015457	3.809071	0.0001
	6	0.076721	0.014440	5.312949	0.0000
		Boyut	BDS Test İstatistiği	Std. Hata	Z-İstatistiği
Δ LLTC-g	2	0.027821	0.008700	3.198020	0.0014
	3	0.058722	0.013889	4.227932	0.0000
	4	0.073366	0.016620	4.414295	0.0000
	5	0.074914	0.017410	4.302872	0.0000
	6	0.067375	0.016877	3.992225	0.0001
		Boyut	BDS Test İstatistiği	Std. Hata	Z-İstatistiği
Δ LXRP-g	2	0.053535	0.006629	8.075453	0.0000
	3	0.083256	0.010579	7.870118	0.0000
	4	0.102260	0.012648	8.085207	0.0000
	5	0.102349	0.013235	7.733235	0.0000
	6	0.102260	0.012814	7.980424	0.0000
		Boyut	BDS Test İstatistiği	Std. Hata	Z-İstatistiği

Tablo 60: BDS Testi Sonuçları (Logaritmik Twitter Hacimleri – Günlük Frekans)

2020	Boyut	BDS Test İstatistiği	Std. Hata	Z-İstatistiği	p-değeri
LT_BTC-g	2	0.028542	0.006666	4.282003	0.0000
	3	0.047771	0.010652	4.484628	0.0000
	4	0.055558	0.012754	4.356080	0.0000
	5	0.053728	0.013366	4.019779	0.0001
	6	0.048993	0.012960	3.780336	0.0002
		Boyut	BDS Test İstatistiği	Std. Hata	Z-İstatistiği
LT_ETH-g	2	0.041566	0.005810	7.154424	0.0000
	3	0.059245	0.009250	6.405036	0.0000
	4	0.073900	0.011032	6.698944	0.0000
	5	0.085426	0.011515	7.418852	0.0000
	6	0.085856	0.011120	7.720961	0.0000
		Boyut	BDS Test İstatistiği	Std. Hata	Z-İstatistiği
LT_LTC-g	2	0.037726	0.006562	5.749114	0.0000
	3	0.074287	0.010490	7.081685	0.0000
	4	0.092958	0.012564	7.398832	0.0000
	5	0.097244	0.013170	7.383591	0.0000
	6	0.095456	0.012774	7.472763	0.0000
		Boyut	BDS Test İstatistiği	Std. Hata	Z-İstatistiği
LT_XRP-g	2	0.029585	0.005029	5.882654	0.0000
	3	0.034646	0.007944	4.361224	0.0000
	4	0.041213	0.009399	4.384821	0.0000
	5	0.044232	0.009732	4.545022	0.0000
	6	0.046853	0.009323	5.025645	0.0000

2021	Boyut	BDS Test İstatistiği	Std. Hata	Z-İstatistiği	p-değeri
LT_BTC-g	2	0.069963	0.004920	14.21906	0.0000
	3	0.118384	0.007817	15.14371	0.0000
	4	0.142909	0.009303	15.36224	0.0000
	5	0.146622	0.009688	15.13493	0.0000
	6	0.143993	0.009334	15.42731	0.0000
	Boyut				
LT_ETH-g	2	0.052543	0.008489	6.189770	0.0000
	3	0.095469	0.013576	7.031928	0.0000
	4	0.133317	0.016274	8.192027	0.0000
	5	0.159506	0.017077	9.340521	0.0000
	6	0.172802	0.016581	10.42151	0.0000
	Boyut				
LT_LTC-g	2	0.071147	0.006147	11.57358	0.0000
	3	0.116248	0.009820	11.83845	0.0000
	4	0.146942	0.011751	12.50481	0.0000
	5	0.162406	0.012307	13.19592	0.0000
	6	0.167065	0.011926	14.00843	0.0000
	Boyut				
LT_XRP-g	2	0.051507	0.005944	8.665608	0.0000
	3	0.082228	0.009457	8.694469	0.0000
	4	0.088461	0.011273	7.847056	0.0000
	5	0.084866	0.011760	7.216234	0.0000
	6	0.074700	0.011351	6.580842	0.0000
	Boyut				

Tablo 61: BDS Testi Sonuçları (Logaritmik Fark Twitter Hacimleri – Günlük Frekans)

2020	Boyut	BDS Test İstatistiği	Std. Hata	Z-İstatistiği	<i>p</i> -değeri
Δ LT_BTC-g	2	0.026659	0.006543	4.074550	0.0000
	3	0.046788	0.010426	4.487619	0.0000
	4	0.051990	0.012448	4.176695	0.0000
	5	0.045824	0.013007	3.523097	0.0004
	6	0.037676	0.012575	2.996075	0.0027
		Boyut	BDS Test İstatistiği	Std. Hata	Z-İstatistiği
Δ LT_ETH-g	2	0.015814	0.007265	2.176726	0.0295
	3	0.030121	0.011626	2.590866	0.0096
	4	0.039993	0.013941	2.868761	0.0041
	5	0.046203	0.014632	3.157685	0.0016
	6	0.041752	0.014210	2.938302	0.0033
		Boyut	BDS Test İstatistiği	Std. Hata	Z-İstatistiği
Δ LT_LTC-g	2	0.034352	0.007738	4.439614	0.0000
	3	0.051840	0.012374	4.189225	0.0000
	4	0.060479	0.014830	4.078089	0.0000
	5	0.061657	0.015557	3.963201	0.0001
	6	0.055124	0.015101	3.650274	0.0003
		Boyut	BDS Test İstatistiği	Std. Hata	Z-İstatistiği
Δ LT_XRP-g	2	0.011852	0.007502	1.579754	0.1142
	3	0.036730	0.011958	3.071646	0.0021
	4	0.054586	0.014282	3.612041	0.0003

		5	0.058509	0.014931	3.918773	0.0001
		6	0.061515	0.014443	4.259188	0.0000
2021	Boyut		BDS Test İstatistiği	Std. Hata	Z-İstatistiği	p-değeri
ΔLT_BTC-g		2	0.038447	0.008047	4.777615	0.0000
		3	0.059969	0.012880	4.655879	0.0000
		4	0.062156	0.015450	4.023191	0.0001
		5	0.065446	0.016221	4.034511	0.0001
		6	0.066370	0.015760	4.211263	0.0000
		Boyut		BDS Test İstatistiği	Std. Hata	Z-İstatistiği
ΔLT_ETH-g		2	0.050539	0.009522	5.307834	0.0000
		3	0.100986	0.015268	6.614362	0.0000
		4	0.130644	0.018352	7.118822	0.0000
		5	0.151354	0.019312	7.837205	0.0000
		6	0.154451	0.018807	8.212465	0.0000
		Boyut		BDS Test İstatistiği	Std. Hata	Z-İstatistiği
ΔLT_LTC-g		2	0.025474	0.006245	4.079185	0.0000
		3	0.038591	0.009949	3.878810	0.0001
		4	0.044895	0.011875	3.780537	0.0002
		5	0.051604	0.012405	4.159754	0.0000
		6	0.051340	0.011990	4.281797	0.0000
		Boyut		BDS Test İstatistiği	Std. Hata	Z-İstatistiği
ΔLT_XRP-g		2	0.033954	0.006328	5.365647	0.0000
		3	0.043472	0.010108	4.300531	0.0000
		4	0.045298	0.012097	3.744504	0.0002
		5	0.039352	0.012671	3.105769	0.0019
		6	0.032590	0.012279	2.654122	0.0080

Tablo 58 ve Tablo 60’da verilen BDS testi sonuçları, logaritmik değişkenler için doğrusallığı ifade eden sıfır hipotezinin tüm boyutlar için reddedildiğini göstermektedir. Bu da değişkenlerin tüm boyutlarda doğrusal olmadığını ortaya koymaktadır. Serilerin doğrusal olmadığı belirlendikten sonra doğrusal olmayan seriler için uygun olan testlerden KSS testi ile serilerin durağan olup olmadıkları test edilmiş ve test sonuçları günlük kripto paralar için Tablo 62’de, günlük Twitter hacimleri için Tablo 63’te verilmiştir.

Tablo 62: KSS Doğrusal Olmayan Birim Kök Testi Sonuçları (Kripto Para)

Dönem	Model Test İstatistiği	Ham Model			Trendden Arındırılmış Model		
		%1	%5	%10	%1	%5	%10
		-2.82	-2.23	-1.94	-3.91	-3.38	-3.13
2020	<i>LBTC-g</i>		-1.205			-2.379	
	Δ <i>LBTC-g</i>		-5.111*			-5.543*	
	<i>LLTC-g</i>		-1.759			-2.332	
	Δ <i>LLTC-g</i>		-3.468*			-3.502*	
	<i>LETH-g</i>		-1.634			-2.939	
	Δ <i>LETH-g</i>		-2.487*			-3.390*	
	<i>LXRP-g</i>		-1.126			-1.652	
	Δ <i>LXRP-g</i>		-2.893*			-4.012*	
2021	<i>LBTC-g</i>		-1.181			-1.587	
	Δ <i>LBTC-g</i>		-3.163*			-3.527*	
	<i>LLTC-g</i>		-1.655			-1.990	
	Δ <i>LLTC-g</i>		-3.632*			-3.666*	
	<i>LETH-g</i>		-0.833			-1.979	
	Δ <i>LETH-g</i>		-2.409*			-3.793*	
	<i>LXRP-g</i>		-1.370			-1.938	
	Δ <i>LXRP-g</i>		-3.133*			-3.397*	

Not: KSS(2003) Tablo 3b'den büyük örneklem için alınmıştır. (*) Ho red, seriler durağan.

Tablo 62’de verilen test sonuçları, her iki dönem içinde kripto para serilerinin logaritmik olarak durağan olmadıklarını, ilk farkı alındığında ise durağanlık söz konusu olduğunu ortaya koymuştur. Ancak kripto paralara ilgili olan Twitter hacmi serileri için bulgular farklılık göstermiştir.

Tablo 63: KSS Doğrusal Olmayan Birim Kök Testi Sonuçları (Twitter Hacim)

Dönem	Model Test İstatistiği	Ham Model			Trendden Arındırılmış Model		
		%1	%5	%10	%1	%5	%10
		-2.82	-2.23	-1.94	-3.91	-3.38	-3.13
2020	<i>LT_XRP-g</i>		-1.070			-2.872	
	Δ <i>LT_XRP-g</i>		-2.629*			-4.107*	
	<i>LT_LTC-g</i>		-3.768*			-3.801*	
	<i>LT_BTC-g</i>		-4.182*			-4.418*	
	<i>LT_ETH-g</i>		-2.101			-2.200	
	Δ <i>LT_ETH-g</i>		-3.316*			-3.795*	
2021	<i>LT_XRP-g</i>		-2.146			-2.618	
	Δ <i>LT_XRP-g</i>		-3.275*			-3.385*	
	<i>LT_LTC-g</i>		-2.500*			-3.480*	
	<i>LT_BTC-g</i>		-2.938*			-3.759*	
	<i>LT_ETH-g</i>		-1.739			-1.770	
	Δ <i>LT_ETH-g</i>		-3.081*			-4.019*	

Tablo 63'te LT_LTC ve LT_BTC serilerinin 2020 ve 2021 dönemlerinde durağan olduğu; bunlar hariç diğer değişkenlerin ise logaritmik ilk farkları alındığında durağan oldukları görülmüştür.

Bu bilgilerden hareketle logaritmik ilk fark serileri içinde BDS testi yapılmış ve sonuçları Tablo 59 ve Tablo 61'de verilmiştir. Tablolarda günlük fiyat ve tweet hacmi serilerinin logaritmik farkları için hesaplanan test istatistiklerinde H_0 hipotezinin farklı boyutlarda reddedildiği görülmektedir. Bu da hem logaritmik hem de logaritmik fark serilerinin doğrusal olmama özelliğini ortaya koymaktadır.

Aşağıda, yukarıda yapılan BDS ve KSS testlerinden elde edilen bulgulardan yararlanarak, analize alınan değişkenler arasında nedensellik ilişkisinin olup olmadığının ve nedenselliğin yönünün belirlenmesi amacı ile yapay sinir ağları ve VARNN modelini kullanarak Granger nedensellik testinin genişletilmiş bir versiyonu olan doğrusal olmayan nedensellik analizi gerçekleştirilmiştir. Analizler farklı gecikmeler ile yapılan tahminler arasında gecikmeleri istatistiksel anlamlı olan denklemler ile analize devam edilmiştir. Başlangıçta model, gecikme parametresine göre denetimli bir öğrenme formuna sahip olarak verileri yeniden düzenlemektedir. Ağ ağırlıklarının güncellenmesi için kullanılan optimizasyon algoritması, öğrenme oranı 0,1'e eşit olan stokastik gradyan iniş (SGD) algoritmasına dayanmaktadır. Bu algoritma, veri setinin tamamının hafızada tutularak optimizasyon sağlanması yerine yalnızca birkaç eğitim örneğini gördükten sonra amaca yönelik optimizasyon sağlamaktadır. Bu olasılıksal dereceli azalma yaklaşımı ile yapay sinir ağlarında büyük işlem maliyetinden kurtularak hız kazanılmaktadır. Ele alınan VARNN(p)'nin iki değişken için fonksiyonu şu şekilde ifade edilebilir:

$$y_t = \varphi_{1,nn}(y_{t-1}, \dots, y_{t-p}, \dots, y_{k(t-1)}, \dots, y_{k(t-k)}) + u_{1,t}$$

$$y_t = \varphi_{2,nn}(y_{t-1}, \dots, y_{t-p}, \dots, x_{t-1}, \dots, x_{t-p}) + u_{2,t}$$

İlk model hedef zaman serisinin gecikme değerlerini dikkate alırken, ikincisi hedef ve tahmin zaman serisinin gecikme değerlerini dikkate almaktadır. Burada, $\varphi_{1,nn}$ ve $\varphi_{2,nn}$ sırasıyla ele alınan iki modelin ağ işlevlerini ifade etmektedir. Nedensellikte, y_t 'nin gecikmeli değerleri varken, x_t serisinin gecikmeli bilgisinin y_t serisinin öngörülmesinde istatistiksel olarak anlamlı herhangi bir bilgi sunup sunmadığı araştırılmaktadır. Analizde maksimum gecikme sayısı 7 olarak belirlenmiştir. Farklı sayıda p gecikmesi göz önünde bulundurularak nedensellik analizi sonucu elde edilen test istatistiği değerleri Tablo 64 ve Tablo 65'te özetlenerek verilmiştir.

Tablo 64. Doğrusal Olmayan Granger Nedensellik Analizi (2020)

	İlişkinin Yönü	Gecikme Uzunluğu	GCI (Granger Nedensellik İndeksi)	F-istatistik	p-değeri
2020	$\Delta LXR P \rightarrow \Delta L T_XR P$	1	0.4116	6.519	0.0002
	$\Delta L B T C \rightarrow L T_B T C$	1	0.7120	9.121	0.0000
	$L T_L T C \rightarrow \Delta L L T C$	3	0.6015	15.168	0.0000
	$L T_B T C \rightarrow \Delta L B T C$	1	0.5513	12.787	0.0005
		2	0.4018	6.646	0.0018
$\Delta L T_E T H \rightarrow \Delta L E T H$	2	0.4815	4.058	0.0086	

Not: Doğrusal olmayan Granger nedensellik testinin F değerleri ve p-değerleri verilmiştir. Yalnızca gecikmesi istatistiksel olarak anlamlı olanlar paylaşılmıştır. Granger nedensellik indeksi (GCI) $\log(\sigma_1^2/\sigma_2^2)$ olarak hesaplanmaktadır.

2020 yılı kapsamında gerçekleştirilen analiz sonuçları; Ripple'ın fiyatından Twitter hacmine doğru 1.gecikmede, Bitcoin fiyatından Twitter hacmine doğru 1. gecikmede ve Twitter hacminden fiyatına doğru 1. ve 2. gecikmede, Litecoin Twitter hacminden fiyatına doğru 3. gecikmede, Ethereum Twitter hacminden fiyatına doğru 2. gecikmede nedensellik ilişkisi olduğu görülmektedir. Bu ilişkiler için aralarında nedensellik ilişkisinin olmadığını ifade eden sıfır hipotezi reddedilmiş ve tek yönlü nedensellik ilişkisinin varlığına karar verilmiştir. Bitcoin için bakıldığında ise çift yönlü nedensellik ilişkisi olduğu görülmüştür. İncelenen kripto paralar içerisinde Ripple'ın fiyat hareketinden Twitter paylaşımlarına doğru nedenselliğin, 2020 yılında Ripple ve Menkul Kıymetler ve Borsa Komisyonu (SEC) arasında meydana gelen hukuki anlaşmazlıktan kaynaklı oluşan popüleritesinden kaynaklandığı düşünülmektedir.

Tablo 65. Doğrusal Olmayan Granger Nedensellik Analizi (2021)

	İlişkinin Yönü	Gecikme Uzunluğu	GCI (Granger Nedensellik İndeksi)	F-istatistik	p-değeri
2021	$\Delta LXR P \rightarrow \Delta L T_XR P$	1	0.3339	3.213	0.0035
	$\Delta L B T C \rightarrow L T_L B T C$	1	0.4524	5.826	0.0321
	$\Delta L E T H \rightarrow \Delta L T_E T H$	1	0.4882	6.509	0.0020
		2	0.4011	4.848	0.0032
	$L T_B T C \rightarrow \Delta L B T C$	1	0.5163	7.599	0.0093
		2	0.3910	4.683	0.0177
$\Delta L T_E T H \rightarrow \Delta L E T H$	1	0.6963	9.252	0.0028	

Not: Doğrusal olmayan Granger nedensellik testinin F değerleri ve p-değerleri verilmiştir. Yalnızca gecikmesi istatistiksel olarak anlamlı olanlar paylaşılmıştır. Granger nedensellik indeksi (GCI) $\log(\sigma_1^2/\sigma_2^2)$ olarak hesaplanmaktadır.

2021 yılı kapsamında gerçekleştirilen analiz sonuçlarına bakıldığında; Ethereum Twitter hacminden fiyatına doğru 1. gecikmede ve Bitcoin Twitter hacminden fiyatına doğru 1. ve 2. gecikmede nedensellik ilişkisi olduğu görülmüştür. Ripple fiyatından Twitter hacmine 1. gecikmede, Bitcoin fiyatından Twitter hacmine 1. gecikmede ve Ethereum fiyatından Twitter hacmine 1. ve 2. gecikmede nedensellik ilişkisi olduğu görülmüştür. Bu ilişkiler için aralarında nedensellik ilişkisinin olmadığını ifade eden sıfır hipotezi reddedilmiş ve çift yönlü nedensellik

bulgusuna ulařılan Bitcoin ve Ethereum hariç 2021 dönemi için Ripple’da tek yönlü nedensellik iliřkisinin varlıđına karar verilmiřtir.

2020 ve 2021 için ortak olan nedensellik bulgusunun yönlerinin;

$$\Delta LXR P \rightarrow \Delta L T_XR P$$

$$L T_B T C \rightarrow \Delta L B T C$$

$$\Delta L B T C \rightarrow L T_B T C$$

$$\Delta L T_E T H \rightarrow \Delta L E T H$$


olduđu görülmüřtür. VARNN modeli kullanımıyla genişletilen doğrusal olmayan Granger nedensellik testi sonucunda elde edilen bulguların kıyaslanması amacıyla MS-VAR tahminleri gerçekleştirilmiřtir. MS-VAR modeli, deđişkenler arasındaki iliřkilerdeki deđişikliđin tespit edilmesine olanak tanımaktadır. VAR modelinin aksine deđişkenler arasındaki iliřkilerin ayrı rejimlerde farklı olabileceđi ihtimali göz ardı edilmemektedir. Çalışmanın birinci bölümünde gerçekleştirilen MS model tahmin sonuçlarından elde edilen bulgulardan hareketle, kazandıran ve kaybettiren rejimlerin ilgili kripto para birimleri kapsamında belirlenmesinin mümkün olduđu saptanmıřtır. Fakat bu rejim deđişimine etki eden faktörler ve bunların etki derecelerinin ne olduđu konusu çalışma dışında bırakılmıřtır. Bu nedenle sonraki arařtırmalarda bu rejimlerin deđişim nedenleri ve bu nedenlerin etki derecelerinin tespit edilmesi de olanaklı gözükmemektedir. Böylece yatırımcıların rejim deđişikliđine etki edecek faktörlere iliřkin beklentilerine göre portföy seçimlerine katkı sađlayacađı düşünölmektedir. Bu doğrultuda model seçiminin ilk aşaması olan modellerin rejim sayısının belirlenmesi amacıyla LR testi uygulanmıřtır. Test aracılıđıyla doğrusal VAR modeli iki rejimli MS-VAR ve iki rejimli MS-VAR modeli de üç rejimli MS-VAR modeline karşı sınanmıřtır. İncelenen tüm kripto paralar kapsamında gerçekleştirilen LR testi sonuçlarına göre doğrusal VAR modelinin dođru olduđunu ifade eden H_0 hipotezi reddedilmiřtir. Ardından iki rejimli MS-VAR modelleri üç rejimli MS-VAR modelleri ile karşılaştırıldıđında iki rejimli MS-VAR modellerinin dođru olduđunu ifade eden H_0 hipotezi reddedilememiřtir. Böylece ilgili kripto paralar için iki rejimin varlıđı ortaya konarak, çalışmanın birinci bölümünde gerçekleştirilen MS model tahminleriyle rejim açısından benzerlik olduđu gözlenmiřtir. Yukarıda 2020 ve 2021 dönemleri kapsamında gerçekleştirilen doğrusal olmayan Granger nedensellik analizi sonucunda elde edilen bulgular özetlenmiřti. Özet ve 2020 ile 2021 yılları kapsamında ortak olarak verilen bu iliřkilerden hareketle model tahminleri gerçekleştirilmiřtir. Tahmin edilen modellere ait sonuçlar sırasıyla verilmiřtir.

Tablo 66. MSIH-VAR(2) Model Tahmin Sonuçları

	$\Delta LE TH$	ΔLT_ETH
Sabit (Rejim 1)	0.001551* (0.99142)	-0.054914* (-2.01893)
Sabit (Rejim 2)	-0.0005787* (-1.25741)	0.332777* (4.20397)
ΔLT_ETH_{t-1}	-0.004113* (-0.79475)	-0.385329 (-4.93891)
ΔLT_ETH_{t-2}	0.003323* (0.64803)	-0.457782 (-5.60760)
$\Delta LE TH_{t-1}$	-0.032773* (-0.37969)	0.396962* (0.29995)
$\Delta LE TH_{t-2}$	0.269482 (3.20982)	-1.131760* (-0.89344)
Standart Hata (Rejim 1)	0.000179	0.000042
Standart Hata (Rejim 2)	0.000684	0.029176
Vector portmanteau	32.003271	
Vector normality	3.1225788	
Vector hetero test	26.200334	
Geçiş Olasılıkları	Rejim 1	Rejim 2
Rejim 1	0.8488	0.1511
Rejim 2	0.2284	0.7715

Not: *%5 istatistiksel anlamlılık düzeyini göstermektedir.

MSIH-VAR(2) model tahmini sonrasında gerçekleştirilen vektör portmanteo, vektör normallik ve vektör farklı yayılım testleri gerçekleştirilmiştir. Test sonuçlarından hareketle, model artıklarının normal dağılıma sahip olduğu ve otokorelasyonsuz eşit yayılıma sahip olduğu belirlenmiştir. Krolzig (1998)'e göre model katsayılarının istatistiksel anlamlılığı ve işaretlerinin yorumlanması gereksizdir (Akt; Özdemir ve Akgül, 2015: 371). Ancak katsayılara ait işaretler ilişkinin yönünü ve istatistiksel öneminin yön gösterici olacağı düşüncesinden hareketle bazı noktalara değinilmesi gerekmektedir. Model katsayıları incelendiğinde ΔLT_ETH 'deki değişmelerin $\Delta LE TH$ 'ye etkisinin 1. dönemde negatif ve 2. dönemde pozitif istatistiksel olarak anlamlı olduğu görülmektedir. Modele ait standart hatalar incelendiğinde ise rejim 1'de $\Delta LE TH$ ve rejim 2'de ΔLT_ETH 'in oynaklığının daha fazla olduğu görülmektedir. Geçiş olasılıkları incelendiğinde Rejim 1'de iken ertesi dönem aynı rejimde kalma olasılığının 0.84, rejim 2'de iken ertesi dönem aynı rejimde kalma olasılığı, 0.77, rejim 1'de iken ertesi dönem Rejim 2'ye geçme olasılığı 0.15, rejim 2'de iken ertesi dönem rejim 1'e geçme olasılığı 0.22'dir. Bulgular rejimlerde kalma olasılıklarının benzer olduğunu göstermektedir. Tahmin edilen modelin katsayıları ve geçiş olasılıkları incelendikten sonra etki tepki fonksiyonları tahmin edilmiştir.



Şekil 66: Etki-Tepki Fonksiyon Grafiği (Ethereum-2020)


1. rejimde, Twitter hacminde bir şok etkisi meydana geldiğinde $\Delta LETH$, 2. döneme kadar azalışla tepki vermiş, 3. dönemde artış meydana gelmiş, 4. dönem itibariyle azalış görülürken 5. dönemde az bir artış gerçekleşerek çok küçük dalgalanmayla tepkisini sürdürmüştür. Aynı zamanda eski düzeyine çok yakın seviyede devam ettiği görülmektedir. 2. rejimde ise Twitter hacminde bir şok etkisi meydana geldiğinde 2. Dönem itibariyle azalışla tepki vermiş, 4. dönemde artış meydana gelmiş, 5. Dönemde azalış tepkisi göstererek 6.dönemde çok az bir artış sonrasında çok küçük dalgalanmayla tepkisini sürdürmüş olup, eski düzeyine çok yakın seviyede devam ettiği tespit edilmiştir. Sonuç olarak, Twitter hacminin Ethereum fiyatları üzerinde hem arttırıcı hem de azaltıcı etkisinin olduğu söylenebilir.

Tablo 67. MSIH-VAR(1) Model Tahmin Sonuçları

	ΔLT_XRP	$\Delta LXR P$
Sabit (Rejim 1)	-0.031992* (-0.60590)	0.002689* (1.69366)
Sabit (Rejim 2)	0.160136* (2.30651)	-0.007665* (-0.97797)
ΔLT_XRP_{t-1}	-0.585900* (-8.54654)	-0.001189* (-0.38512)
$\Delta LXR P_{t-1}$	-0.779836* (-0.41284)	-0.086743* (-1.05529)
Standart Hata (Rejim 1)	0.01004	0.000342
Standart Hata (Rejim 2)	0.00232	0.000731
Vector portmanteau	19.95436	
Vector normality	3.376279	
Vector hetero test	10.35292	
Geçiş Olasılıkları	Rejim 1	Rejim 2
Rejim 1	0.8203	0.1796
Rejim 2	0.2588	0.7412

MSIH-VAR(1) model tahmini sonrasında gerçekleştirilen vektör portmanto, vektör normallik ve vektör farklı yayılım testleri gerçekleştirilmiştir. Test sonuçlarından hareketle, model artıklarının normal dağılıma sahip olduğu ve otokorelasyonsuz eşit yayılıma sahip olduğu belirlenmiştir. Model katsayıları incelendiğinde $\Delta LXR P$ 'deki değişmelerin $\Delta LTXR P$ 'ye etkisinin 1. dönemde negatif ve istatistiksel olarak anlamlı olduğu görülmektedir. Modele ait standart hatalar incelendiğinde ise hem rejim 1'de hem de rejim 2'de ΔLT_XRP 'nin

oyunaklılığının $\Delta LXR P$ 'ye göre daha fazla olduğu görülmektedir. Geçiş olasılıkları incelendiğinde Rejim 1'de iken ertesi dönem aynı rejimde kalma olasılığının 0.82, rejim 2'de iken ertesi dönem aynı rejimde kalma olasılığı, 0.74, rejim 1'de iken ertesi dönem Rejim 2'ye geçme olasılığı 0.17, rejim 2'de iken ertesi dönem rejim 1'e geçme olasılığı 0.25'tir. Bulgular rejimlerde kalma olasılıklarının benzer olduğunu göstermektedir. Tahmin edilen modelin katsayıları ve geçiş olasılıkları incelendikten sonra etki tepki fonksiyonları tahmin edilmiştir.



Şekil 67: Etki-Tepki Fonksiyon Grafiği (Ripple-2020)


1. rejimde, Ripple fiyatında bir şok etkisi meydana geldiğinde ΔLT_XRP , 2. döneme kadar azalışla tepki vermiş, 3. dönemde artış meydana gelmiş, 4. dönemde azalış ve 5. dönemde artış görülmüş olup, küçük dalgalanmalarla tepkisini sürdürdüğü gözlenmiştir. Aynı zamanda eski düzeyine çok yakın seviyede devam etmiştir. 2. rejimde ise Ripple fiyatında bir şok etkisi meydana geldiğinde ΔLT_XRP , 2. dönem itibariyle artış göstererek tepkisini 4. döneme kadar sürdürmüş, 5. dönemde azalış meydana gelmiş ve sonrasında küçük dalgalanmalarla tepkisini sürdürerek eski düzeyine çok yakın seviyede devam etmiştir. Sonuç olarak, Ripple fiyatlarının Twitter hacmi üzerinde hem azaltıcı hem de arttırıcı etkisi olduğu tespit edilmekle birlikte hareket yönünde zıtlık olduğu görülmüştür.

Tablo 68. MSIH-VAR(2) Model Tahmin Sonuçları

	$\Delta LBTC$	LT_BTC
Sabit (Rejim 1)	0.002374* (1.82597)	-0.009043* (-0.83592)
Sabit (Rejim 2)	-0.054368* (-2.87275)	0.450774* (3.53785)
$\Delta LBTC_{t-1}$	-0.041426* (-0.47087)	1.446337* (2.01662)
$\Delta LBTC_{t-2}$	0.145381 (1.66319)	0.754134* (1.05063)
LT_BTC_{t-1}	0.005709* (0.57828)	-0.217134 (-2.63573)
LT_BTC_{t-2}	0.009638* (0.99637)	-0.246353* (-3.05590)
Standart Hata (Rejim 1)	0.000213	0.000366

Standart Hata (Rejim 2)	0.000642	0.014794
Vector portmanteau	27.66027	
Vector normality	2.42896	
Vector hetero test	7.78291	
Geçiş Olasılıkları	Rejim 1	Rejim 2
Rejim 1	0.9922	0.0077
Rejim 2	0.0102	0.9898

MSIH-VAR(2) model tahmini sonrasında gerçekleştirilen vektör portmanteo, vektör normallik ve vektör farklı yayılım testleri gerçekleştirilmiştir. Test sonuçlarından hareketle, model artıklarının normal dağılıma sahip olduğu ve otokorelasyonsuz eşit yayılıma sahip olduğu belirlenmiştir. Model katsayıları incelendiğinde LT_BTC 'deki değişmelerin $\Delta LBTC$ 'ye etkisinin 1. ve 2. dönemde pozitif ve istatistiksel olarak anlamlı olduğu görülmektedir. Modele ait standart hatalar incelendiğinde ise hem rejim 1'de hem de rejim 2'de LT_BTC 'nin oynaklığının $\Delta LBTC$ 'ye göre daha fazla olduğu görülmektedir. Geçiş olasılıkları incelendiğinde Rejim 1'de iken ertesi dönem aynı rejimde kalma olasılığının 0.99, rejim 2'de iken ertesi dönem aynı rejimde kalma olasılığı, 0.98, rejim 1'de iken ertesi dönem Rejim 2'ye geçme olasılığı 0.007, rejim 2'de iken ertesi dönem rejim 1'e geçme olasılığı 0.01'dir. Bulgular rejimlerde kalma olasılıklarının benzer olduğunu göstermektedir. Tahmin edilen modelin katsayıları ve geçiş olasılıkları incelendikten sonra etki tepki fonksiyonları tahmin edilmiştir.




Şekil 68: Etki-Tepki Fonksiyon Grafiği (Bitcoin-2020)

1. rejimde, Bitcoin Twitter hacminde bir şok etkisi meydana geldiğinde $\Delta LBTC$, 2. döneme kadar azalışla tepki vermiş, 3. dönemde artış meydana gelmiş, 4. dönemde azalış ve 5. dönemde artış görülmüş olup, küçük dalgalanmalarla tepkisini sürdürdüğü gözlenmiştir. Aynı zamanda eski düzeyine çok yakın seviyede devam etmiştir. 2. rejimde ise Twitter hacminde bir şok etkisi meydana geldiğinde $\Delta LBTC$, 2. dönem itibariyle artış göstererek 3. dönemden itibaren azalan tepki ve 4. dönemde artış gösterdikten sonra azalışa geçmiş ve 6. dönem itibariyle artış gösterdikten sonrasında küçük dalgalanmalarla tepkisini sürdürerek eski düzeyine çok yakın seviyede devam etmiştir. Sonuç olarak, Bitcoin Twitter hacminin fiyat üzerinde hem azaltıcı hem de artırıcı etkisi olduğu tespit edilmiştir.

Tablo 69. MSIH-VAR(1) Model Tahmin Sonuçları

	<i>LT_BTC</i>	$\Delta LBTC$
Sabit (Rejim 1)	-0.453413* (-2.76645)	-0.000842* (-0.05524)
Sabit (Rejim 2)	-0.000798* (-0.07172)	0.002240* (-0.05524)
LT_BTC_{t-1}	-0.131670* (-1.49456)	0.010819* (1.04681)
$\Delta LBTC_{t-1}$	1.354358* (1.86449)	0.005539 (0.06173)
Standart Hata (Rejim 1)	0.01598	0.00058
Standart Hata (Rejim 2)	0.02613	0.00024
Vector portmanteau	18.46279	
Vector normality	2.49752	
Vector hetero test	4.10590	
Geçiş Olasılıkları	Rejim 1	Rejim 2
Rejim 1	0.9914	0.0085
Rejim 2	0.0779	0.9221

MSIH-VAR(1) model tahmini sonrasında gerçekleştirilen vektör portmanteo, vektör normallik ve vektör farklı yayılım testleri gerçekleştirilmiştir. Test sonuçlarından hareketle, model artıklarının normal dağılıma sahip olduğu ve otokorelasyonsuz eşit yayılıma sahip olduğu belirlenmiştir. Model katsayıları incelendiğinde $\Delta LBTC$ 'deki değişmelerin LT_BTC 'ye etkisinin 1. dönemde pozitif ve istatistiksel olarak anlamlı olduğu görülmektedir. Modele ait standart hatalar incelendiğinde ise hem rejim 1'de hem de rejim 2'de LT_BTC 'nin oynaklığının $\Delta LBTC$ 'ye göre daha fazla olduğu görülmektedir. Geçiş olasılıkları incelendiğinde Rejim 1'de iken ertesi dönem aynı rejimde kalma olasılığının 0.99, rejim 2'de iken ertesi dönem aynı rejimde kalma olasılığı, 0.98, rejim 1'de iken ertesi dönem Rejim 2'ye geçme olasılığı 0.007, rejim 2'de iken ertesi dönem rejim 1'e geçme olasılığı 0.01'dir. Bulgular rejimlerde kalma olasılıklarının benzer olduğunu göstermektedir. Tahmin edilen modelin katsayıları ve geçiş olasılıkları incelendikten sonra etki tepki fonksiyonları tahmin edilmiştir.

**Şekil 69:** Etki-Tepki Fonksiyon Grafiği (Bitcoin-2020)


1. rejimde, Bitcoin fiyatında bir şok etkisi meydana geldiğinde LT_BTC , 2. döneme kadar azalışla tepki vermiş, 3. dönemde artış meydana gelmiş ve bu artış 5. döneme kadar devam etmiş olup, 6.

dönem itibariyle azalışa geçmiştir. Sonrasında küçük dalgalanmalarla tepkisini sürdürdüğü gözlenmiş, eski düzeyine çok yakın seviyede devam ettiği tespit edilmiştir. 2. rejimde ise Bitcoin fiyatında bir şok etkisi meydana geldiğinde LT_BTC, 2. dönem itibariyle artış göstererek 3. dönemden itibaren azalan tepki ve 4. dönemde artış gösterdikten sonra azalışa geçmiş ve küçük dalgalanmalarla tepkisini sürdürerek eski düzeyine çok yakın seviyede devam etmiştir. Sonuç olarak, Bitcoin fiyatının Twitter hacmi üzerinde hem azaltıcı hem de arttırıcı etkisi olduğu tespit edilmiştir.

Tablo 70. MSIH-VAR(2) Model Tahmin Sonuçları

	ΔLEH	ΔLT_ETH
Sabit (Rejim 1)	-0.117175* (-3.90519)	0.030069* (0.34004)
Sabit (Rejim 2)	0.000452* (0.22842)	0.003127* (0.24039)
ΔLT_ETH_{t-1}	0.016088* (1.23253)	-0.481667 (-5.73632)
ΔLT_ETH_{t-2}	0.019568* (1.49211)	-0.198546* (-2.36360)
ΔLEH_{t-1}	-0.110874 (-1.62922)	0.067283* (0.15028)
ΔLEH_{t-2}	0.131077* (1.88795)	0.773727 (1.73585)
Standart Hata (Rejim 1)	0.000497	0.052146
Standart Hata (Rejim 2)	0.001296	0.021867
Vector portmanteau	25.00822	
Vector normality	3.7889	
Vector hetero test	27.70893	
Geçiş Olasılıkları	Rejim 1	Rejim 2
Rejim 1	0.9783	0.0216
Rejim 2	0.0787	0.9213

MSIH-VAR(2) model tahmini sonrasında gerçekleştirilen vektör portmanteo, vektör normallik ve vektör farklı yayılım testleri gerçekleştirilmiştir. Test sonuçlarından hareketle, model artıklarının normal dağılıma sahip olduğu ve otokorelasyonsuz eşit yayılıma sahip olduğu belirlenmiştir. Model katsayıları incelendiğinde ΔLT_ETH 'deki değişmelerin ΔLEH 'ye etkisinin 1. ve 2. dönemde pozitif ve istatistiksel olarak anlamlı olduğu görülmektedir. Modele ait standart hatalar incelendiğinde ise hem rejim 1'de hem de rejim 2'de ΔLT_ETH 'in oynaklığının ΔLEH 'ye göre daha fazla olduğu görülmektedir. Geçiş olasılıkları incelendiğinde Rejim 1'de iken ertesi dönem aynı rejimde kalma olasılığının 0.97, rejim 2'de iken ertesi dönem aynı rejimde kalma olasılığı, 0.92, rejim 1'de iken ertesi dönem Rejim 2'ye geçme olasılığı 0.02, rejim 2'de iken ertesi dönem rejim 1'e geçme olasılığı 0.07'dir. Bulgular rejimlerde kalma olasılıklarının benzer olduğunu göstermektedir. Tahmin edilen modelin katsayıları ve geçiş olasılıkları incelendikten sonra etki tepki fonksiyonları tahmin edilmiştir.



Şekil 70: Etki-Tepki Fonksiyon Grafiği (Ethereum-2021)


1. rejimde, Twitter hacminde bir şok etkisi meydana geldiğinde ΔLE_{tH} , 2. dönemde azalışla tepki vermiş, 3. dönemde artış meydana gelmiş, 4. dönem itibariyle azalış ve 5. dönem itibariyle de azalışa geçerek çok küçük dalgalanmayla tepkisini sürdürmüştür. Aynı zamanda eski düzeyine çok yakın seviyede devam ettiği görülmektedir. 2. rejimde ise Twitter hacminde bir şok etkisi meydana geldiğinde 3. döneme kadar artışla tepki vermiş, 4. dönemde azalış meydana gelmiş, 5. dönemde çok az bir artış görülmesi akabinde çok küçük dalgalanmayla tepkisini sürdürmüş olup, eski düzeyine çok yakın seviyede devam ettiği tespit edilmiştir. Sonuç olarak, Twitter hacminin Ethereum fiyatları üzerinde hem arttırıcı hem de azaltıcı etkisinin olduğu söylenebilir.

Tablo 71. MSIH-VAR(1) Model Tahmin Sonuçları

	ΔLT_XRP	$\Delta LXRP$
Sabit (Rejim 1)	0.181123* (4.96831)	-0.012872* (-3.57563)
Sabit (Rejim 2)	-0.061107* (-3.59327)	0.003811* (2.09776)
ΔLT_XRP_{t-1}	-0.313787 (-4.47547)	0.008449* (1.10103)
$\Delta LXRP_{t-1}$	1.164556* (1.40470)	-0.139003 (-1.63928)
Standart Hata (Rejim 1)	0.017308	0.000556
Standart Hata (Rejim 2)	0.023644	0.000231
Vector portmanteau	14.75911	
Vector normality	4.56703	
Vector hetero test	11.22241	
Geçiş Olasılıkları	Rejim 1	Rejim 2
Rejim 1	0.7575	0.2424
Rejim 2	0.2118	0.7882

MSIH-VAR(1) model tahmini sonrasında gerçekleştirilen vektör portmanteo, vektör normallik ve vektör farklı yayılım testleri gerçekleştirilmiştir. Test sonuçlarından hareketle, model artıklarının normal dağılıma sahip olduğu ve otokorelasyonsuz eşit yayılıma sahip olduğu belirlenmiştir. Model katsayıları incelendiğinde $\Delta LXRP$ 'deki değişmelerin ΔLT_XRP 'ye etkisinin 1. dönemde pozitif ve istatistiksel olarak anlamlı olduğu görülmektedir.

Modele ait standart hatalar incelendiğinde ise hem rejim 1’de hem de rejim 2’de ΔLT_XRP ’nin oynaklığının $\Delta LXRP$ ’ye göre daha fazla olduğu görülmektedir. Geçiş olasılıkları incelendiğinde Rejim 1’de iken ertesi dönem aynı rejimde kalma olasılığının 0.75, rejim 2’de iken ertesi dönem aynı rejimde kalma olasılığı 0.78, rejim 1’de iken ertesi dönem rejim 2’ye geçme olasılığı 0.24, rejim 2’de iken ertesi dönem rejim 1’e geçme olasılığı 0.21’dir. Bulgular rejimlerde kalma olasılıklarının benzer olduğunu göstermektedir. Tahmin edilen modelin katsayıları ve geçiş olasılıkları incelendikten sonra etki tepki fonksiyonları tahmin edilmiştir.



Şekil 71: Etki-Tepki Fonksiyon Grafiği (Ripple-2021)


1. rejimde, Ripple fiyatında bir şok etkisi meydana geldiğinde ΔLT_XRP , 2. döneme kadar azalışla tepki vermiş, 3. dönemde artış meydana gelmiş, 4. dönemde azalış ve 5. dönemde artış görülmüş olup, küçük dalgalanmalarla tepkisini sürdürdüğü gözlenmiştir. Aynı zamanda eski düzeyine çok yakın seviyede devam etmiştir. 2. rejimde ise Ripple fiyatında bir şok etkisi meydana geldiğinde ΔLT_XRP , 2. dönem itibarıyla azalış göstererek tepkisini 4. döneme kadar sürdürmüş, 5. dönemde artış meydana gelmiş ve sonrasında küçük dalgalanmalarla tepkisini sürdürerek eski düzeyine çok yakın seviyede devam etmiştir. Sonuç olarak, Ripple fiyatlarının Twitter hacmi üzerinde hem azaltıcı hem de arttırıcı etkisi olduğu tespit edilmiştir.

Tablo 72. MSIH-VAR(2) Model Tahmin Sonuçları

	$\Delta LBTC$	LT_BTC
Sabit (Rejim 1)	0.007023* (0.73636)	0.286128* (4.03538)
Sabit (Rejim 2)	-0.001064* (-0.46589)	-0.022454* (-1.66812)
$\Delta LBTC_{t-1}$	-0.095585* (-1.07325)	-0.941747* (-1.73322)
$\Delta LBTC_{t-2}$	0.108906 (1.20218)	0.675653 (1.54365)
LT_BTC_{t-1}	-0.003111* (-0.19618)	-0.425175 (-5.45598)
LT_BTC_{t-2}	-0.002431* (-0.16239)	-0.210921 (-2.90795)
Standart Hata (Rejim 1)	0.000352	0.000624

Standart Hata (Rejim 2)	0.011027	0.011845
Vector portmanteau	34.03356	
Vector normality	5.3776	
Vector hetero test	8.88472	
Geçiş Olasılıkları	Rejim 1	Rejim 2
Rejim 1	0.9233	0.0766
Rejim 2	0.0975	0.9025

MSIH-VAR(2) model tahmini sonrasında gerçekleştirilen vektör portmanteo, vektör normallik ve vektör farklı yayılım testleri gerçekleştirilmiştir. Test sonuçlarından hareketle, model artıklarının normal dağılıma sahip olduğu ve otokorelasyonsuz eşit yayılıma sahip olduğu belirlenmiştir. Model katsayıları incelendiğinde LT_BTC 'deki değişmelerin $\Delta LBTC$ 'ye etkisinin 1. ve 2. dönemde negatif ve istatistiksel olarak anlamlı olduğu görülmektedir. Modele ait standart hatalar incelendiğinde ise hem rejim 1'de hem de rejim 2'de LT_BTC 'nin oynaklığının $\Delta LBTC$ 'ye göre daha fazla olduğu görülmektedir. Geçiş olasılıkları incelendiğinde Rejim 1'de iken ertesi dönem aynı rejimde kalma olasılığının 0.92, rejim 2'de iken ertesi dönem aynı rejimde kalma olasılığı 0.90, rejim 1'de iken ertesi dönem Rejim 2'ye geçme olasılığı 0.07, rejim 2'de iken ertesi dönem rejim 1'e geçme olasılığı 0.09'dur. Bulgular rejimlerde kalma olasılıklarının benzer olduğunu göstermektedir. Tahmin edilen modelin katsayıları ve geçiş olasılıkları incelendikten sonra etki tepki fonksiyonları tahmin edilmiştir.




Şekil 72: Etki-Tepki Fonksiyon Grafiği (Bitcoin-2021)

1. rejimde, Bitcoin Twitter hacminde bir şok etkisi meydana geldiğinde $\Delta LBTC$, 2. döneme kadar azalışla tepki vermiş, 3. dönemde artış meydana gelmiş, 4. dönemde azalış, 5. dönemde artış, 6. dönemde azalış ve 7. dönemde artış görülmüş olup, küçük dalgalanmalarla tepkisini sürdürdüğü gözlenmiştir. Aynı zamanda eski düzeyine çok yakın seviyede devam etmiştir. 2. rejimde ise Twitter hacminde bir şok etkisi meydana geldiğinde $\Delta LBTC$, 2. dönem itibariyle azalış göstererek 3. dönemden itibaren artan tepki ve 4. dönem itibariyle azalış gösterdikten sonrasında küçük dalgalanmalarla tepkisini sürdürerek eski düzeyine çok yakın seviyede devam etmiştir. Sonuç olarak, Bitcoin Twitter hacminin fiyat üzerinde hem azaltıcı hem de arttırıcı etkisi olduğu tespit edilmiştir.

Tablo 73. MSIH-VAR(1) Model Tahmin Sonuçları

	<i>LT_BTC</i>	$\Delta LBTC$
Sabit (Rejim 1)	-0.005466* (-0.48739)	-0.000889* (-0.41188)
Sabit (Rejim 2)	0.599794* (3.44024)	0.034472* (1.09676)
LT_BTC_{t-1}	-0.303160* (-4.27882)	-0.004422 (-0.32358)
$\Delta LBTC_{t-1}$	-0.649785* (-1.25436)	-0.062785 (-0.64250)
Standart Hata (Rejim 1)	0.016739	0.000431
Standart Hata (Rejim 2)	0.023994	0.000624
Vector portmanteau	17.62762	
Vector normality	5.0006	
Vector hetero test	9.80858	
Geçiş Olasılıkları	Rejim 1	Rejim 2
Rejim 1	0.9921	0.0078
Rejim 2	0.0545	0.9455

MSIH-VAR(1) model tahmini sonrasında gerçekleştirilen vektör portmanteo, vektör normallik ve vektör farklı yayılım testleri gerçekleştirilmiştir. Test sonuçlarından hareketle, model artıklarının normal dağılıma sahip olduğu ve otokorelasyonsuz eşit yayılıma sahip olduğu belirlenmiştir. Model katsayıları incelendiğinde $\Delta LBTC$ 'deki değişmelerin LT_BTC 'ye etkisinin 1. dönemde negatif ve istatistiksel olarak anlamlı olduğu görülmektedir. Modele ait standart hatalar incelendiğinde ise hem rejim 1'de hem de rejim 2'de LT_BTC 'nin oynaklığının $\Delta LBTC$ 'ye göre daha fazla olduğu görülmektedir. Geçiş olasılıkları incelendiğinde Rejim 1'de iken ertesi dönem aynı rejimde kalma olasılığının 0.99, rejim 2'de iken ertesi dönem aynı rejimde kalma olasılığı, 0.94, rejim 1'de iken ertesi dönem Rejim 2'ye geçme olasılığı 0.007, rejim 2'de iken ertesi dönem rejim 1'e geçme olasılığı 0.05'tir. Bulgular rejimlerde kalma olasılıklarının benzer olduğunu göstermektedir. Tahmin edilen modelin katsayıları ve geçiş olasılıkları incelendikten sonra etki tepki fonksiyonları tahmin edilmiştir.

**Şekil 73:** Etki-Tepki Fonksiyon Grafiği (Bitcoin-2021)

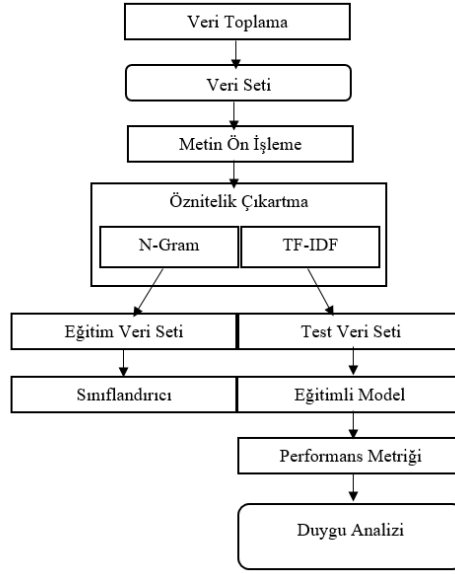
1. rejimde, Bitcoin fiyatında bir şok etkisi meydana geldiğinde LT_BTC , 2. döneme kadar azalışla tepki vermiş, 3.,4. ve 5. dönemlerde artış meydana gelmiş ve sonrasında küçük dalgalanmalarla

tepkisini sürdürdüğü gözlenmiş, eski düzeyine çok yakın seviyede devam ettiği tespit edilmiştir. 2. rejimde ise Bitcoin fiyatında bir şok etkisi meydana geldiğinde LT_BTC, 4. Döneme kadar azalış göstererek 5. Dönemde artan tepki göstermiştir. 5. dönem sonrasında azalan tepki göstererek küçük dalgalanmalarla tepkisini sürdürerek eski düzeyine çok yakın seviyede devam etmiştir. Sonuç olarak, Bitcoin fiyatının Twitter hacmi üzerinde hem azaltıcı hem de arttırıcı etkisi olduğu tespit edilmiştir.

Bulgular genel olarak değerlendirildiğinde, yatırımcıların, yeterince bilgi sahibi olunmasa bile, farkında oldukları kripto paralara yatırım yaptıklarını söylemek mümkün olabilir. Hipoteze göre yatırımcı, (Tweeter yardımı ile) dikkatini çeken kripto paralar için fiyat artışına sebep olmaktadır. Bunun sonucunda da yatırımcı ilgisinin artması yüksek işlem hacmi ve getiri yaratabilmektedir. Burada yapılan analizlerde, dönemsel farklılıkları olsa da; BTC ve ETH'nin Twitter hacminin fiyatları belirlemede etkisi olduğu görülmüştür. Aynı zamanda BTC'nin ise fiyattan hacime, hacimden fiyata nedenselliği söz konusudur. MS-VAR model tahminlerinde ise rejimlere göre farklılaşma incelenmiş olup, doğrusal olmayan Granger nedensellik testi sonucunda elde edilen bulgularla paralellik olduğu tespit edilmiştir. Bu aşamada finansal piyasalar ve yatırım araçlarıyla ilgili medyanın önem verme düzeyinin artması, yatırımcı kararlarında etkili olma olasılığında göz ardı edilmemelidir. Aynı zamanda haber içeriklerinin de bireysel algı üzerinde olumlu ya da olumsuz şekillendirmeye neden olabileceği de ifade edilmektedir (Strauss, 2017: 13). Gündem Belirleme Kuramı'nın "*çoğu insan, ne hakkında konuşulacağına kararının verilmesinde en önemli; çoğu insan, en fazla role sahiptir. Çoğu insan, problemlerin nasıl çözüleceğine dair bu şekilde karar verir ve birbirine uyar*" (Dearing ve Rogers, 1996: 2; akt. Yaşın, 2008: 6) önermesinden hareketle ve çalışmanın ikinci bölümünde bahsedilen, alanyazında sıklıkla hacimsel veriyle yapılan araştırmaların yatırımcı ilgisinin doğrudan ölçülemediğine dair getirilen eleştiriden hareketle, ilgili sosyal medya paylaşımlarının içeriklerinin ele alınması önemlidir. Aşağıda, yukarıdaki bulguları desteklemek ve ilave bilgiler sağlamak, keşifsel araştırmalarla ilişki belirlenmesinin dayanak noktasını oluşturmak amacı ile ilgili Twitter içerikleri duygu analizi yardımıyla incelenmiştir.

4.5. Duygu Analizi

Aşağıda, 13.05.2020-27.09.2020 ve 13.05.2021-27.09.2021 tarihleri arasında dört kripto para için elde edilen veri seti için doküman tabanlı duygu analizinin yarı denetimli makine öğrenmesi algoritmalarıyla uygulamasına geçilmeden önce bir takım ön işlemler yapılmıştır. İzlenecek süreç ile ilgili şematik bilgi Şekil 74'te verilmiştir.



Şekil 74: Önerilen Metodoloji Çerçevesi

Çalışmada veri ön işleme ve duygu analizi nesne yönelimli ve etkileşimi yüksek seviyeli bir programlama dili olan Phyton aracılığı ile gerçekleştirilmiştir. Phyton’da doğal dil işleme yöntemlerinin kullanılması için gerekli olan “ilişkisel” ve “etiketli” verilerle çalışmayı kolay ve sezgisel hale getirmeyi sağlayan paketler (*nlk*, *re*, *pandas* ve *numpy*) yüklenmiştir.

- *Zemberek*, açık kaynak kodlu Türkçe doğal dil işleme metodunun uygulanması için kullanılmıştır.
- *Jpype*, phyton içerisinde java dilinin kullanılmasını sağladığından ve zemberek kütüphanesinin çağrılması için kullanılmıştır.
- *Numpy*, çalışma içerisinde belirlenen eğitim ve test verilerinin tutulmasını sağlamak için kullanılmıştır.
- *Pandas*, veri ön işleme ve analiz aşamalarının kolaylaştırılması adına kullanılmıştır. “Csv” formatındaki dosyaların tutularak işlenip analiz edilmesini sağlamaktadır.
- *Nltk*, açık kodlu kaynak kütüphane sayesinde doğal dil işleme tekniği kullanılmıştır.
- *Sklearn*, makine öğrenmesi modellerinin oluşturulması için kullanılmıştır.
- *Seaborn*, Matplotlib Kütüphanesi tabanlı olup istatistiksel bir Python veri görselleştirmesi için kullanılmıştır.

4.5.1. Verinin Ön İşleme Sürecinden Geçirilmesi

Twitter verileri yapısal olmayan özelliğe sahip olduğundan kullanılabilirliği için metin madenciliği yöntemleri yardımıyla yapısal forma dönüştürülmesi gerekmektedir.

- Aynı içeriğe (aynı kelime dizimi vb.) sahip paylaşımların temizlenmesiyle benzersiz paylaşımların veri setine katılması
- İçeriklerde yer alan bağlantılar (link), etiketler (hashtag), RT ifadeleri (retweet), bahsetmeler (mention), simgeler (emoji), noktalama işaretleri ve numerik karakterlerin temizlenmesiyle ham metnin elde edilmesi
- Büyük harflerin küçük harflere çevrilmesiyle ham veride standardizasyon işleminin yapılması
- Sosyal medya içeriklerinde kelimelerin farklı yazılışı nedeniyle (örneğin kelime içerisinde harf tekrarı yapılması) ikiden fazla harf tekrarının yapılmamasının ve ayrıca üç harften küçük kelimelerin kaldırılmasının kontrolü
- Cümleden çıkartıldığında anlam açısından önemli değişikliğe neden olmayan, içeriklerde yer alan etkisiz sözcüklerin (stop words) kaldırılmasıyla sapmaların azatılmasının sağlanması için simgeleştirme (tokenization) işleminin gerçekleştirilmesi
- Kelimelerin anlamları göz önüne alınarak gövdeye indirgenmesi (morfolojik kökün elde edilmesi) için kök çözümleme/sözbirimleştirme (lemmatization) ve/veya sıkılama/gövdeleme (stemming) işleminin yapılması (örneğin, satıyorum->sat vb.)
- Cümlelerin başında, sonunda ve içerisindeki fazladan boşlukların temizlenmesi ve yanlış yazılan kelimelerin düzeltilmesi için normalizasyon işleminin yapılması

Ön işleme sürecinin önemli bir aşaması olan normalizasyon ve kök çözümleme işlemleri zemberek kütüphanesinin metin normalizasyonu aracılığı ile gerçekleştirilmiştir. Veri setini ön işleme sürecine tabii tutmadan önceki ve sonraki tweet içerikleri paylaşılmıştır.

```

Tweets
0 RT @CryptoYtrmTR: ripple hakkında çıkan iddala...
1 Bu coinin (xrp) ath yaptığı zirve yaptığında s...
2 Bitcoin balina sayısı 2020 seviyesine geriledi...
3 Ethereum yorum analiz, (ETH) mayı ethd yeni AT...
4 Fiyatın beklediim bölgeye gelmesi halinde böl...

```

Şekil 75: İşlenmemiş Veri Görüntüsü

```

Tweets
0 ripple hakkında çıkan iddialara bakılacak olu ...
1 bu coinin ath yaptığı zirve yaptığında sessizl...
2 bitcoin balina sayısı seviyesin geriledi anlam...
3 ethereum yorum analiz mayı ethd yeni ath trend...
4 fiyatın beklediğim bölgeye gelmesi halinde böl...

```

Şekil 76: Normalizasyon İşlemi Uygulanmış Veri Görüntüsü

Java dilinde yazılmış olması nedeniyle Zemberek kütüphanesinin kullanılabilmesi için *jpype* paketi kullanılmıştır. Zemberek kütüphanesinde anlamsız kelimelerin kökü yer almadığından bu gibi durumlarda sonuç döndürülememektedir. Bu nedenle anlamsız kelimelerin vektör uzayını gereksiz doldurmaması adına kökü olmayan kelimeler çıkartılmıştır. Eğitim setlerinin elde

edilmesinde el ile etiketleme aşamasında, bir tweet içerisinde birden fazla duygunun yer alması halinde tweette ifade edilen güçlü olan duygu etiketlenmiştir. Bu işlemler sonucunda kalan bütün kök kelimeler terim ağırlıklandırmasına hazır hale getirilmiştir.

4.5.2. Metin Verisinin Vektör Uzayında Gösterilmesi (Öznitelik Seçimi)

Ön işleme sürecinin tamamlanmasının ardından metin madenciliği çalışmalarında performansın artırılması ve bir terimin ilgili doküman içerisinde ne kadar önemli olduğunun belirtilebilmesi amacıyla terimlere ağırlık atama işlemi gerçekleştirilmiştir. Bu sayede “metin verileri → özniteliklere” (yapısal formata), “öznitelikler → vektörlere” çevrilmektedir. Makine öğrenmesi yöntemiyle yapılan duygu analizinde, duygu sınıfı belirlenecek olan metinlerin bir şekilde bilgisayar tarafından anlaşılabilir şekle yani sayısal hale dönüştürülmesi gerekmektedir. Bu ağırlıklandırma işlemi için Terim Frekans- Ters Doküman Frekansı (TF-IDF-Term Frequency Inverse Document Frequency) yöntemi kullanılmıştır. TF-IDF, bir terimin ilgili doküman içerisinde önemini temsil eden ağırlık faktörü olmakla birlikte, “TF” terim sıklığını yani doküman içerisinde terimin kaç kez geçtiğini ve “IDF” ters doküman sıklığını ifade etmek üzere metinlerin kaçında terimin geçtiğini temsil etmektedir. Bu ağırlıklandırma tekniğinde terimlerin sınıf bilgileri kullanılmadığından gözetimsiz (unsupervised) bir ağırlıklandırma yöntemidir.

$$w_{i,j} = tf_{i,j} \times \log \frac{N}{df_i} \quad (4.1)$$

$tf_{i,j}$, i kelimesinin j belgesinde bulunma sıklığını, N toplam doküman sayısını ve df_i i kelimesini içeren doküman sayısını ifade etmek üzere, terimin geçtiği doküman sayısının toplam doküman sayısına bölünüp logaritmasının alınmasıyla bulunmaktadır. TF-IDF değeri, ters doküman sıklığı değerleri ile terim sıklığının çarpılması sonucu elde edilmektedir. Çalışmada tweetlerde geçen kelimeler terim ve tweetlerde doküman olarak kullanılmıştır. TF-IDF değerinin hesaplanmasında sklearn kütüphanesinin `TfidfVectorizer` sınıfı kullanılmıştır.

```
def ozellik_secimi(df,max_features):\n",\n    print("\nTF-IDF yöntemi seçildi")\n",\n    vectorizer = TfidfVectorizer(lowercase=False,ngram_range=(1,2),dtype=np.byte,max_features=max_features)\n",\n    x = vectorizer.fit_transform(df['Tweets'].tolist())\n",\n    return x,vectorizer"
```

Şekil 77: TF-IDF

TF-IDF yönteminde metindeki kelimelerin n-gramı (1,2) olarak denenmiştir. N-gram, bir karakter dizininin n adet karakter dilimidir. N-gram tabanlı sınıflandırma yöntemiyle doküman içerisinde yer alan karakter tabanlı n-gram'ların kullanım sıklığına dayalı işlem gerçekleştirilmektedir. Duygu sınıf ayrımlarının yapılması için tweetlerin sayısal vektör olarak gösterilmesi gerekmektedir. Öznitelik vektörü oluşturma aşaması, tweetleri uygun vektör formuna dönüştürmek için kullanılmaktadır. Çalışmada öznitelik vektörlerinin oluşturulmasında n-gram ayırıştırma tekniği kullanılmıştır. Metinlerde genişliği n olan kayan pencereler yardımıyla yine

aynı metin içerisinde yer alan bütün n-gramlar elde edilmiştir. Elde edilen bu n-gramlar sayesinde tekrar edilenler sayılarak her bir n-gramın kaç tane yer aldığı belirlenebilmektedir. Belirlenen bu n-gramlar *n-gram profili* ismi verilen bir vektörde tutulmaktadır. Çalışmada farklı n-gram temsil modelleri arasında en başarılı olan 2-gram temsil yöntemi olduğu belirlenmiştir. Sonrasında metinlerde yer alan kelimelerin vektör uzayları alınarak modeller için eğitim (%75) ve test (%25) olmak üzere iki ayrı veri seti oluşturulmuştur. Eğitim ve test veri setleri için n-gram profilinin en uygun şekilde elde edilmesi sağlanmıştır. Model başarısının ölçülmesinde bir sınıma kümesi olarak test verisi kullanılmıştır. Bu veri eğitimi esnasında ise sınıflandırıcı tarafından görülmemesi sağlanarak taraflı değerlendirilmenin önüne geçilmesi sağlanmıştır.

```
"from sklearn.model_selection import train_test_split"  
"X_train,X_test,y_train,y_test = train_test_split(X,df['yapay_tahmin'],random_state=1,test_size=0.25)"
```

Şekil 78: *Train_test_split()*

Başlangıç noktasında ne kadar verinin tutulacağı belirlenmesinde ise *Train_test_split()* kullanılmıştır. Böylece veriler bir eğitim ve bir test verisi olmak üzere iki ayrı sete bölünmüştür. Sınıflandırma aşamasında ise eğitim veri setinde modeller yapılarak eğitim hatası ve test hatası incelenmiştir.

4.5.3. Sınıflandırma Teknikleri

Sınıflandırma işlemine geçmeden önce Twitter’da yapılan paylaşımların her biri eğitim veri seti aracılığıyla sisteme girdi olarak gösterilmiştir. Akabinde her girdiye ait amaçlanan çıktı yani sınıflandırılacağı konu sisteme tanıtılmıştır. Büyük eğitim setiyle sistem, girdiler ve çıktılar arasındaki bağlantıyı öğrenerek sınıflandırma işlemine hazır hale getirilmiştir. Bu işlem, metnin anlamlı sayılar olarak göstermenin bir yoludur. Çalışmada Twitter verilerinin duygu kutuplarının belirlenmesinde üç farklı sınıflandırma algoritması kullanılmıştır. Uygulamada TF-IDF yaklaşımıyla çıkarılan özniteliklere göre Naive Bayes, Lojistik Regresyon ve Tek Katmanlı Yapay Sinir Ağları (Perseptron) algoritmaları ile tahminler gerçekleştirilmiştir. TF-IDF vektörüyle uyumlu olduğu için tercih edilen bu sınıflandırma tekniklerine ait sonuçlarının görülmesi için *Sklearn* kütüphanesi kullanılmıştır. Bu noktada eğitilmiş modelin başarısının sağlanması için modele verilen eğitim verisi örneklerinin doğru etiketlenmesi gerekmektedir. Bu nedenle de örnek kategorilerinin önceden bilinmemesi halinde yüksek sınıflandırma başarısının sağlanması adına ön tanımlı sözlükler ve semantik işlemlere ihtiyaç duyulan doğrusal sınıflandırıcılar kullanılmaktadır. Çalışma kapsamındaki veri setinin etiketsiz olması nedeniyle verideki bilinmeyen ilişkilerin ortaya konulması ve sınıflandırılması oluşturulan eğitim veri seti aracılığıyla sağlanmıştır. Sınıflandırma tekniklerinin temelinde ise bu ilişkilerin ortaya çıkmasını sağlayan kural tabanlı yaklaşım üzerinden ilerlenmiştir.

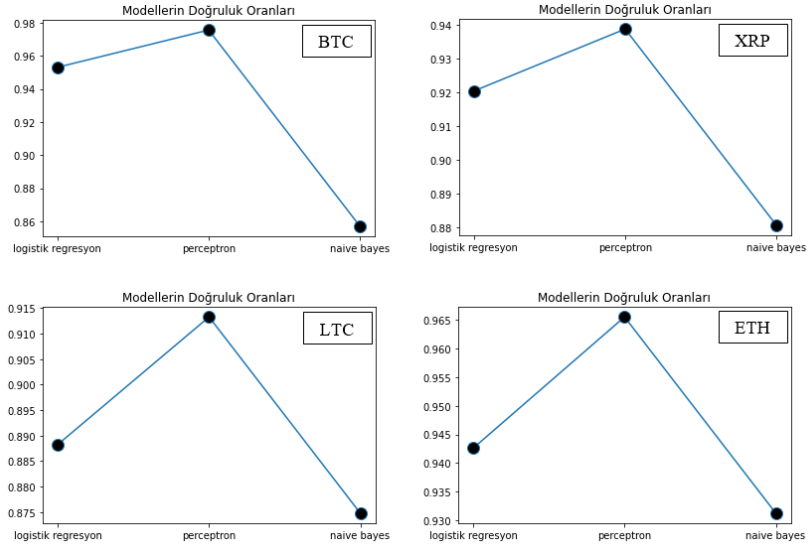
%75 eğitim ve %25 test olarak ayrılan veriler, sınıflandırma algoritmalarına gönderilmiştir. Algoritmaların kullanılması ve sınıflandırma sonuçlarının gösterilmesi işlemi *Sklearn* kütüphanesi ile gerçekleştirilmiştir. Her bir kelime için pozitif, negatif ve nötr olmak üzere üç farklı polarite skoru hesaplanmıştır. Cümle içerisindeki kelimelere sözlükte karşılık gelen puanlar atanarak toplanır ve bu toplama işlemi sonucunda çıkan değere polarite skoru denilmektedir. Verilere makine öğrenmede sınıflandırma algoritmalarının uygulanarak her bir model için karışıklık (confusion) matrisi ve doğruluk (accuracy) skorları hesaplanmıştır. Sınıflandırma tekniklerinin performanslarının karşılaştırılmasında *Doğruluk* metriği kullanılmıştır. Sınıflandırma işleminde en çok kullanılan ölçüm olmakla birlikte doğru olarak sınıflandırılmış örneklerin toplam örnek sayısına oranlanmasıyla elde edilmektedir.

- TN (True Negative Rate): Gerçekte negatif ve sınıflandırıcı tarafından da negatif olarak belirlenen içeriklerin sayısını,
- FN (False Negative Rate): Gerçekte negatif olan ancak sınıflandırıcı tarafından negatif belirlenmeyen içeriklerin sayısını,
- TP (True Positive Rate): Gerçekte pozitif olan ve sınıflandırıcı tarafından da pozitif belirlenen içeriklerin sayısını,
- FP (False Positive Rate): Gerçekte pozitif olan ancak sınıflandırıcı tarafından pozitif belirlenmeyen içeriklerin sayısını ifade etmek üzere,

$$\text{Doğruluk (Accuracy)} = \frac{TP+TN}{TP+TN+FP+FN} \quad (4.2)$$

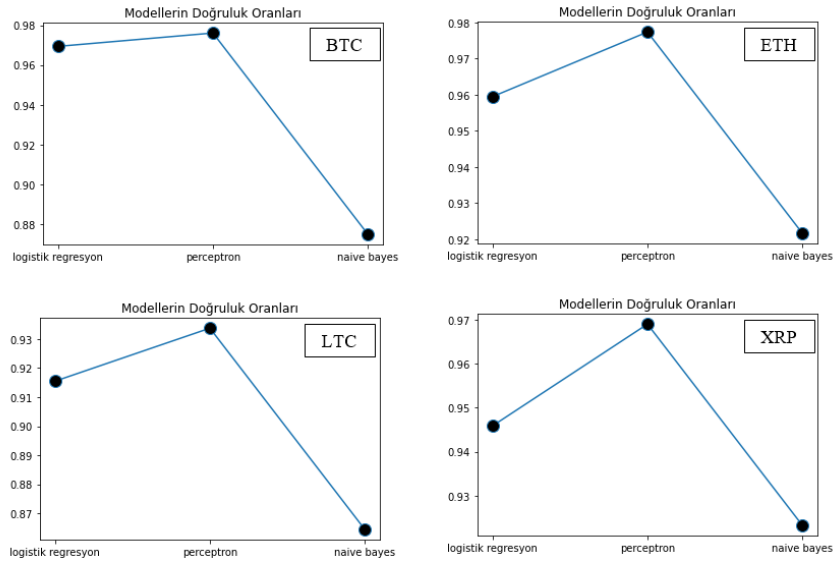
$$\text{Hata Oranı (Error Rate)} = \frac{FP+FN}{TP+FP+FN+TN} \quad (4.3)$$

Kısaca doğruluk, tüm doğru cevapların tüm cevaplara oranı olarak ifade edilmektedir. Bu değer 1'e tamlayanı ise hata oranını ifade etmektedir. Bu şekilde sınıflandırma için kullanılan algoritmalar arasında, etiketlenmiş veri setinden algoritmanın eğitimi için ayrılmış olan eğitim verisi ile algoritmanın öğrendiği kuralları test edebildiği test verisi karşılaştırılabilmektedir. Test verisinde yer alan gerçek etiketlerin silinmesiyle algoritmaya veri tahmin ettirilerek, elde edilen tahminlerle gerçek etiketler karşılaştırılması sonucu algoritmanın doğruluğu ölçülmektedir. Belirlenen sınıflandırıcı algoritmalarının eğitim verisinin etiketlenmiş veriler ile eğitilmesinin ardından etiketsiz verilere uygulanması sonucu elde edilen doğruluk oranları sırasıyla verilmiştir. Tüm tweet'lerin girdisi olarak sistem pozitif duygu için 1, negatif duygu için -1 ve nötr için 0 değeri verilmiştir. Bir içerik çok pozitif terim içeriyorsa pozitif duygu, çok negatif terim içeriyorsa negatif duygu ve ikisi de eşit ya da hiçbirini içermiyorsa nötr olarak sınıflandırılmaktadır. Veriler elde edilirken kaydedilmeden önce, her tweet elde edildiği anda, daha sonra ikinci bir işlem olarak yapılmaması ve sınıflandırmadan sonraki doğruluk skorlarında kullanılmak üzere polariteler hesaplanmıştır.



Şekil 79: Duygu Analizi Model Skorları (2020)

13.05.2020-27.09.2020 tarih aralığında dört kripto para birimi hakkında Twitter üzerinden yapılan paylaşımlara uygulanan duygu analizinde Naive Bayes, Lojistik Regresyon ve Tek Katmanlı Yapay Sinir Ağları sınıflandırma algoritmaları uygulanmıştır. Uygulama sonucunda sınıflandırma başarısının en yüksek oranla Tek Katmanlı Yapay Sinir Ağları algoritmasıyla elde edildiği Şekil 79 aracılığıyla belirlenmiştir.



Şekil 80: Duygu Analizi Model Skorları (2021)

13.05.2021-27.09.2021 tarih aralığında dört kripto para birimi hakkında Twitter üzerinden yapılan paylaşımlara uygulanan duygu analizinde Naive Bayes, Lojistik Regresyon ve Tek Katmanlı Yapay Sinir Ağları sınıflandırma algoritmaları uygulanmıştır. Uygulama sonucunda sınıflandırma başarısının en yüksek oranla Tek Katmanlı Yapay Sinir Ağları algoritmasıyla elde

edildiği belirlenmiştir. Tahmin edilen modeller sonrasında CSV formatına alınan kodlama görüntüsü verilmiştir.

Tweets	Bağlantı	Kaynak	logistik_tahmin	yapay_tahmin	bayes_tahmin	logistik_tahmin_yuzdesi	yapay_tahmin_yuzdesi	bayes_tahmin_yuzdesi
rippl blockchain tabanlı işletim k	https://tw	Twitter	2	2	2	0.920489297	0.93883792	0.880733945
rippl yeni ürününü girişimini tanı	https://tw	Twitter	2	2	2	0.920489297	0.93883792	0.880733945
işt nokta atışı bitcoin rippl tahm	https://tw	Twitter	0	0	0	0.920489297	0.93883792	0.880733945
rippl davasında sıcak gelişim fed	https://tw	Twitter	0	0	2	0.920489297	0.93883792	0.880733945
swiss bank incor dijital belirlenmi	https://tw	Twitter	1	1	1	0.920489297	0.93883792	0.880733945

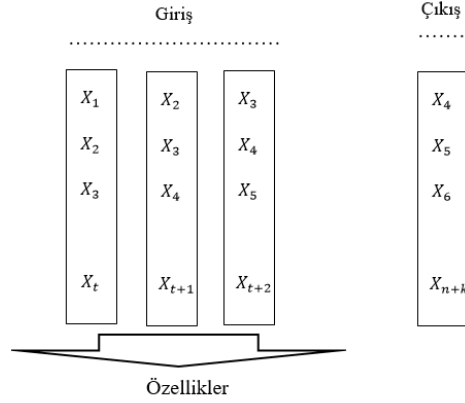
Şekil 81: CSV Formatında Kodlama Görüntüsü

2020 ve 2021 yılı kapsamında beklendiği üzere daha basit birer sınıflayıcı oldukları ifade edilen Lojistik Regresyon ve Naive Bayes sınıflayıcısı, Yapay Sinir Ağları sınıflayıcısına oranla daha düşük bir başarı göstermişlerdir. Sınıflandırma oranlarına ait görüntüler **Ek 2'** de paylaşılmıştır. Sistem modelleri içerisinde sınıflayıcı algoritması olarak kullanılan YSA, modellerde yer alan kısıtlayıcı varsayımları hafifletebilmektedir (Moradi vd., 2012: 39). Bu nedenle YSA, süreklilik değerlendirmesinde önemli potansiyele sahiptir. Özellikle de gözlemlenen süreç verilerinde herhangi bir istatistiksel dağılıma ihtiyaç duymamakla birlikte normal olmayan verilerin işlenmesinde başarılı sonuçlar vermektedir (Koh ve Tan, 2012: 212).

Çeşitli makine öğrenmesi algoritmaları ile gerçekleştirilen sınıflandır işlemi sonucunda en iyi tahmin performansının YSA'ya ait olduğunun belirlenmesi ve zamana göre değişimi verilen fiyat değişkenlerinin doğrusal olmayan veri yaratma sürecinde olması nedeniyle, aradaki ilişkinin incelenmesinde doğrusal olmayan MIDAS regresyon tahmin yöntemi kullanılmıştır. Ancak tahmin aşamasına geçilmeden önce duygu analizi sonucu polariteleri belirlenen içeriklerin (pozitif, negatif veya nötr) duygu skorları elde edilmiştir.

Tahmin işlemleri öncesi eğitim setinin makineye öğretilmesi sonucu, öğrenilen ilişkilere dayanarak hiç tanıtılmayan örneklem için çıkarımda bulunulabilmesi için elle veri üzerinde incelemeler yapılmış ve bu incelemelerle duygu kütüphanesi düzenlenmiştir. Böylece her kelimenin duygu skorunun hesaplanması sağlanmıştır. Sonrasında duygu skorlarının elde edilmesinde Twitter'da saatlik karşılaştırma sırasında duygu skorlarındaki yüzdesel değişimin izlenmesinde ağırlıklandırılmış duygu skorunun saatlik değişimi hesaplanmıştır. Saatlik duygu skoru yüzdesel değişimi, önceki saatte duygu skoru değeri ve mevcut saatteki duygu skor değeri arasında fark alınması sonucu, önceki saatte yer alan duygu skoru değerine bölünerek hesaplanmıştır ($dp = \frac{\text{saatlik duygu değeri}_{i+1} + \text{saatlik duygu değeri}_i}{\text{saatlik duygu değeri}_i}$). Polarite skoru, doğal eşik değer olan sıfırdan büyükse pozitif, sıfır ise nötr ve sıfırdan küçükse negatif olarak değerlendirilmiştir. Zaman serisi algoritmaları, örneklerinin arasında sıra ilişkisinin olduğu veri kümelerine uygulanmaktadır. Algoritmalar, t anındaki değer $t - 1$ ile $t - k$ aralığındaki değerlerini bulmaktadır. Makine öğrenmesi algoritmalarının tez çalışmasındaki veri setlerine uygulanmasında örneklere ait özellikler geçmiş zamana ait değerler aracılığıyla tanımlanmış olup,

bu işlem aşağıdaki görsel aracılığıyla ifade edilmiştir. Zaman serisi probleminin makineye tanımlanmasında tarih değişkeni için günlük kırılım yapılmıştır.



Ayrıştırma oranı olarak ise, alanyazındaki çalışmalardan yararlanarak zaman serisi değerleri yaklaşık olarak %75 eğitim ve %25 test olarak iki gruba ayrılmıştır. Kullanılan algoritmaların tahmin performanslarının karşılaştırılmasında verinin içeriğinden dolayı hata oranını değil miktarını dikkate alan Ortalama Hata Kare Kökü (Root Mean Square Error) ölçütü kullanılmıştır.

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - t_i)^2} \quad (4.4)$$

y_i : gerçek değer

t_i : tahmin değeri

Değişkenlerin doğrusal olmaması ve temel bileşenlerine ait öncül bilgilerin elde edilmesinin ardından Rastsal Orman, LGBM, XGBoost, K-en yakın komşu, Karar ağaçları ve Torbalama Regresyon algoritmalarıyla tahmin işlemleri gerçekleştirilmiştir. Algoritmaların eğitimi ve test edilmesi aşamasında Pedregosa vd. (2011) tarafından geliştirilen *SciKit-Learn* kütüphanesi kullanılmıştır. Eğitilmiş modellerin kullanılmasıyla eğitim, test ve tüm kripto paralar için tahmin yapılmıştır. Yapılan tahmin değerlerinin gerçek değerlerle karşılaştırılmasıyla modellerin eğitim, test ve tüm veri seti için tahminlerinin doğruluk performansları değerlendirilmiştir. Tahmin modellerinde bağımlı değişken olarak Bitcoin, Ethereum, Litecoin ve Ripple fiyatları, bağımsız değişken olarak duygu analizi sonucu elde edilen polarite skorları ve Dolar ve Euro serileri (TL bazında) günlük frekansta ($n = 138$) alınmıştır. Daha önce kripto para serilerine ait durağanlık ve doğrusallık sınamaları verilmişti. Aşağıda ise Euro ve Dolar için düzey ve logaritmik dönüşümlü veri setleri için tanımlayıcı istatistikler Tablo 74 ve Tablo 75'te, grafikleri ise Şekil 82 ve 83'te verilmiştir.

Tablo 74: Tanımlayıcı İstatistikler (Düzyen Euro ve Dolar – Günlük Frekans)


	Kripto Para		
	İstatistik		
2020 (Düzyen)	Ortalama	EURO-g	DOLAR-g
	Ortalama	8.484	7.322
	Medyan	8.652	7.334
	Maksimum	10.012	8.520
	Minimum	7.384	6.713
	Standart Sapma	0.736475	0.49184
	Jarque-Bera	9.557802	10.38925
	<i>p-deęeri</i>	0.008405	0.005546
	Kripto Para		
	İstatistik		
2021 (Düzyen)	Ortalama	EURO-g	DOLAR-g
	Ortalama	10.402	8.558
	Medyan	10.266	8.547
	Maksimum	12.783	9.175
	Minimum	9.805	8.273
	Standart Sapma	0.547472	0.185524
	Jarque-Bera	248.9408	14.6145
	<i>p-deęeri</i>	8.77E-55	0.000671

Serilerdeki varyansda duraęan olmama ve/veya eęrisellięi düzeltmek amacı ile logaritmik dönüřüm yapılmıř ve Tablo 75'te logaritmik dönüřüm serilerin tanımlayıcı istatistikleri verilmiřtir.


Tablo 75: Tanımlayıcı İstatistikler (Logaritmik Euro ve Dolar – Günlük Frekans)

	Kripto Para		
	İstatistik		
2020 (Logaritmik)	Ortalama	LEURO-g	LDOLAR-g
	Ortalama	0.927	0.864
	Medyan	0.937	0.865
	Maksimum	1.001	0.930
	Minimum	0.868	0.827
	Standart Sapma	0.037728	0.028754
	Jarque-Bera	10.5634	10.1705
	<i>p-deęeri</i>	0.005084	0.006187
	Kripto Para		
	İstatistik		
2021 (Logaritmik)	Ortalama	LEURO-g	LDOLAR-g
	Ortalama	1.017	0.932
	Medyan	1.011	0.932
	Maksimum	1.107	0.963
	Minimum	0.991	0.918
	Standart Sapma	0.021799	0.009343
	Jarque-Bera	175.173	12.24237
	<i>p-deęeri</i>	0.0000	0.0021

řekil 82 ve 83'te ise deęişkenlere ait düzyen ve logaritmik hallerinin zaman grafikleri verilmiřtir.



Şekil 82: Düzey Euro-Dolar Zaman Grafikleri (Günlük Frekans)



Şekil 83: Logaritmik Euro-Dolar Zaman Grafikleri (Günlük Frekans)

İkinci olarak günlük frekanslı değişkenlerin doğrusal olup olmadıklarını belirlemek için BDS testinden yararlanılmıştır. Test sonuçları Tablo 76'da verilmiştir.

Tablo 76: BDS Testi Sonuçları (Logaritmik Euro ve Dolar – Günlük Frekans)

2020	Boyut	BDS Test İstatistiği	Std. Hata	Z-İstatistiği	p-değeri
LDOLAR- _g	2	0.189166	0.004377	43.21789	0.0000
	3	0.328552	0.006974	47.10885	0.0000
	4	0.420753	0.008323	50.55531	0.0000
	5	0.483397	0.008691	55.62015	0.0000
	6	0.525894	0.008396	62.63404	0.0000
	LEURO- _g	2	0.193523	0.003553	54.46481
3		0.331927	0.005652	58.72723	0.0000
4		0.428146	0.006732	63.59598	0.0000
5		0.495317	0.007017	70.58865	0.0000
6		0.542639	0.006766	80.20244	0.0000
2021		Boyut	BDS Test İstatistiği	Std. Hata	Z-İstatistiği
LDOLAR- _c	2	0.136284	0.005688	23.95821	0.0000
	3	0.221495	0.009067	24.42871	0.0000

	4	0.272981	0.010826	25.21487	0.0000
	5	0.300567	0.011313	26.56781	0.0000
	6	0.311715	0.010938	28.49902	0.0000
	Boyut	BDS Test İstatistiği	Std. Hata	Z-İstatistiği	p-değeri
LEURO-g	2	0.181783	0.009956	18.25912	0.0000
	3	0.303604	0.015952	19.03254	0.0000
	4	0.385249	0.019162	20.10501	0.0000
	5	0.440509	0.020152	21.85903	0.0000
	6	0.479511	0.019614	24.44776	0.0000

Hem 2020 hem de 2021 dönemi için yapılan BDS test sonuçları, tüm boyutlarda her iki serisinde güçlü doğrusal olmama özelliği sergilediğini göstermektedir.

Serilerin doğrusal olmadığı bulgusunun ardından serilerin durağanlığının test edilmesi için doğrusal olmayan seriler için uygun olan KSS testi yapılmış ve Tablo 78’de test sonuçları verilmiştir. Sonuçta, LDolar ve LEuro değişkenlerinin I(1) olduğu, yani logaritmik ilk farklarının durağan olduğuna karar verilmiştir.

Bunun üzerine fark serilerinin doğrusal olup olmadığına karar vermek amacı ile BDS testi uygulanmış ve sonuçları Tablo 77’de verilmiştir.

Tablo 77: BDS Testi Sonuçları (Logaritmik Fark Euro ve Dolar – Günlük Frekans)

2020	Boyut	BDS Test İstatistiği	Std. Hata	Z-İstatistiği	p-değeri
ΔLDOLA R-g	2	0.026210	0.010201	2.569249	0.0102
	3	0.039425	0.016380	2.406919	0.0161
	4	0.055705	0.019718	2.825042	0.0047
	5	0.059862	0.020782	2.880428	0.0040
	6	0.077058	0.020271	3.801395	0.0001
	Boyut	BDS Test İstatistiği	Std. Hata	Z-İstatistiği	p-değeri
ΔLEURO-g	2	0.019527	0.009286	2.102943	0.0355
	3	0.029686	0.014861	1.997567	0.0458
	4	0.052814	0.017829	2.962271	0.0031
	5	0.062923	0.018725	3.360346	0.0008
	6	0.076269	0.018199	4.190793	0.0000
2021	Boyut	BDS Test İstatistiği	Std. Hata	Z-İstatistiği	p-değeri
ΔLDOLA R-g	2	0.038413	0.006618	5.804555	0.0000
	3	0.065366	0.010551	6.195475	0.0000
	4	0.075628	0.012602	6.001115	0.0000
	5	0.074079	0.013175	5.622598	0.0000
	6	0.069219	0.012744	5.431274	0.0000
	Boyut	BDS Test İstatistiği	Std. Hata	Z-İstatistiği	p-değeri
ΔLEURO-g	2	0.030044	0.008543	3.516968	0.0004
	3	0.049061	0.013673	3.588261	0.0003
	4	0.051575	0.016401	3.144583	0.0017
	5	0.046232	0.017223	2.684393	0.0073
	6	0.041925	0.016735	2.505180	0.0122

Logaritmik ve logaritmik fark serilerine uygulanan BDS testi sonuçlarına göre değişkenlerin tüm boyutlarda doğrusal olmadığı görülmüştür. Başka bir deyişle doğrusallığı ifade eden sıfır hipotezi

tüm boyutlar için reddedilmiştir. Hangi boyutlarda en güçlü reddedildiği bu çalışmanın devamında önemli olmadığı için sadece en güçlü reddedildiği boyutlar, tablolarda (*) ile işaretlenmiştir.

Yukarıda da bahsedildiği üzere, doğrusal olmadığı belirlenen değişkenler için yapılan KSS testi sonuçları Tablo 78’de verilmiştir.

Tablo 78: KSS Doğrusal Olmayan Birim Kök Test Sonuçları (Euro ve Dolar – Günlük Frekans)


Dönem	Model Test İstatistiği	Ham Model			Trendden Arındırılmış Model		
		%1	%5	%10	%1	%5	%10
		-2.82	-2.23	-1.94	-3.91	-3.38	-3.13
2020	LEURO-g	-1.019			-2.689		
	ΔLEURO-g	-3.036			-5.385		
	LDOLAR-g	-1.587			-2.750		
	ΔLDOLAR-g	-2.678			-4.360		
2021	LEURO-g	-1.034			-1.945		
	ΔLEURO-g	-2.244			-4.033		
	LDOLAR-g	-1.372			-1.643		
	ΔLDOLAR-g	-2.325			-3.419		

Günlük frekanslı serilere uygulanan KSS testi sonucunda, LDolar ve LEuro değişkenlerinin I(1) olduğu, yani logaritmik ilk farklarının durağan olduğuna karar verilmiştir.

Aşağıda ise KSS testi sonuçlarına göre durağan olduğuna, BDS testi ile doğrusal olmadıklarına karar verilen serilere ait tanımlayıcı istatistikler Tablo 79’da, zaman grafikleri de 84’te verilmiştir.

Tablo 79: Tanımlayıcı İstatistikler (Logaritmik Fark Euro ve Dolar – Günlük Frekans)

Dönem (Durağan)	Kripto Para	ΔLEURO-g	ΔLDOLAR-g
	İstatistik		
2020 (Durağan)	Ortalama	0.000854	0.000492
	Medyan	0.000722	0.000440
	Maksimum	0.012214	0.009159
	Minimum	-0.008122	-0.008729
	Standart Sapma	0.003171	0.002837
	Jarque-Bera	29.26480	19.97939
	p-değeri	0.000000	0.000046
	2021 (Durağan)	Kripto Para	ΔLEURO-g
İstatistik			
Ortalama		0.000660	0.000352
Medyan		0.000372	0.000097
Maksimum		0.012658	0.005944
Minimum		-0.008331	-0.008011
Standart Sapma		0.003328	0.002858
Jarque-Bera		41.98539	0.134711
p-değeri	0.000000	0.934863	



Şekil 84: Logaritmik Fark Euro-Dolar Zaman Grafikleri (Günlük Frekans)

Temel prensip, alanyazındaki çalışmalar doğrultusunda piyasa aktörlerinin de kripto para piyasasındaki fiyat oluşumundaki etkisinin eklenmesiyle uygun modelleme tekniğinin belirlenmesidir. Kripto paraların her birine ait iki dönem için belirtilen algoritmalarla 1000'in üzerinde model denenmiş olup, toplamda 12 model ile son tahminler gerçekleştirilmiştir. Dört kripto paranın ele alınması nedeniyle toplamda 48 model tahmini yapılmıştır. Model tahminleri Python dili çalışma arayüzü Jupyter aracılığıyla gerçekleştirilmiştir. Tahmin performanslarının değerlendirilmesi aşamasında kullanılmasının uygun olduğu önerilen ölçüt RMSE olduğu için (Tayman ve Swanson, 1999: 300; Hyndman ve Koehler, 2006: 682) tablolarda RMSE değerlerine yer verilmiştir. Tez kapsamında ele alınan makine öğrenmesi algoritmaları zaman serilerini genel olarak bağımsız ve özdeş dağılmış varsayımı (*i.i.d.*) ile ele almaktadır. Bu varsayım, her gözlemin diğerlerinden bağımsız olduğunu ve gözlemlerin hepsinin aynı dağılımdan geldiğini belirtmektedir. Ancak zaman serisi gözlemleri tipik olarak geçmiş gözlemlere bağlıdır. Sonuç olarak, *i.i.d.* varsayımına sahip verilerin olmaması durumunda yapılacak tahminlerde yanıltıcı sonuçlar elde edilebilecektir. Bu nedenle makine öğrenmesi algoritmalarına alınan zaman serileri durağan halleriyle ele alınarak gerçekleştirilen tahmin sonuçları sırasıyla paylaşılmıştır. Her bir zaman serisi için farklı tahmin modelleri kombinasyonuna dayalı optimize edilmiş bir yaklaşım izlenerek tahminler gerçekleştirilmiştir. Algoritma tahminlerinde bağımlı değişken olan fiyatın tahminlenmesinde en iyi performansın sağlanması adına ele alınan değişkenler Tablo 80'de verilmiştir.

Tablo 80. Algoritma Tahminlerinde Kullanılan Değişkenler

Değişken		$\Delta LFiyat$	$\Delta LFiyat(-1)$	Duygu Skoru	Duygu Skoru (-1)	$\Delta LEuro$	$\Delta LEuro(-1)$	$\Delta LDolar$	$\Delta LDolar(-1)$
Kripto Para	2020	√		√	√	√	√	√	
		√	√	√		√		√	√
		√		√	√			√	
		√	√	√		√	√	√	√
2021	2021	√		√	√	√		√	
		√	√	√		√		√	
		√		√	√			√	
		√	√	√		√	√	√	√

Tablo 80’de belirtilen değişkenlerle gerçekleştirilen fiyat tahmin sonuçları kripto para bazında sırasıyla verilmiştir.

Tablo 81. Algoritma Fiyat Tahmin Performansları ($\Delta LXR P$)

Algoritma	Ölçüt	Rastсал Orman	LGBM	XGBoost	K-En Yakın Komşu	Karar Ağacı	Torbalama
2020	R^2	0.2838	0.1896	0.4983	0.1985	0.5296	0.1687
	RMSE	0.000165	0.000339	0.000142	0.000324	0.000129	0.000343
2021	R^2	0.3546	0.2257	0.4808	0.3377	0.5191	0.1039
	RMSE	0.000375	0.000415	0.000343	0.000385	0.000311	0.000516

Ripple fiyat tahmin değerleri ile gerçek gözlem değerleri arasındaki farkın en düşük olduğu tahmin algoritmasının performans kriterlerine göre değerlendirilmesi sonucu *karar ağacı* olduğu belirlenmiştir.

Tablo 82. Algoritma Fiyat Tahmin Performansları ($\Delta LETH$)

Algoritma	Ölçüt	Rastсал Orman	LGBM	XGBoost	K-En Yakın Komşu	Karar Ağacı	Torbalama
2020	R^2	0.2757	0.3004	0.4006	0.2054	0.1574	0.1044
	RMSE	0.000297	0.000236	0.000204	0.000352	0.000414	0.000553
2021	R^2	0.4254	0.4727	0.5533	0.3577	0.2934	0.1002
	RMSE	0.000961	0.000867	0.000855	0.001162	0.001641	0.002658

Ethereum fiyat tahmin değerleri ile gerçek gözlem değerleri arasındaki farkın en düşük olduğu tahmin algoritmasının performans kriterlerine göre *XGBoost* olduğuna karar verilmiştir.

Tablo 83. Algoritma Fiyat Tahmin Performansları ($\Delta LLTC$)

Algoritma	Ölçüt	Rastсал Orman	LGBM	XGBoost	K-En Yakın Komşu	Karar Ağacı	Torbalama
2020	R^2	0.5019	0.2791	0.2735	0.2524	0.1593	0.1559
	RMSE	0.000016	0.000182	0.000201	0.000211	0.000237	0.000311
2021	R^2	0.5518	0.4504	0.4401	0.385	0.2496	0.2283
	RMSE	0.001126	0.001204	0.001341	0.001385	0.001591	0.002829


Litecoin fiyat tahmin değerleri ile gerçek gözlem değerleri arasındaki farkın en düşük olduğu tahmin algoritmasının, performans kriterlerine göre *rastsal orman algoritması* olduğu görülmüştür.

Tablo 84. Algoritma Fiyat Tahmin Performansları (Δ LBTC)


Algoritma		Rastsal Orman	LGBM	XGBoost	K-En Yakın Komşu	Karar Ağacı	Torbalama
Ölçüt							
2020	R^2	0.1512	0.2299	0.4252	0.1416	0.1392	0.1267
	RMSE	0.000285	0.000276	0.000272	0.000307	0.000324	0.000457
2021	R^2	0.3478	0.4084	0.5797	0.327	0.2243	0.1133
	RMSE	0.000794	0.000708	0.000667	0.000861	0.000967	0.001188

Bitcoin fiyat tahmin değerleri ile gerçek gözlem değerleri arasındaki farkın en düşük olduğu tahmin algoritmasının, performans kriterlerine göre *XGBoost* algoritması olduğu belirlenmiştir.


Aşağıda ilk olarak 2020 dönemi için; Ethereum fiyat tahmininde en yüksek performansa sahip algoritmaların belirlendiği Tablo 82'den yararlanılarak yapılan tahmin grafiği Şekil 85'de, Ripple için Tablo 81'den yararlanılarak yapılan tahmin grafiği Şekil 86'da, Litecoin için Tablo 83'ten yararlanılarak yapılan tahmin grafiği Şekil 78'de ve Bitcoin için Tablo 43'ten yararlanılarak yapılan tahmin grafiği Şekil 87'de verilmiştir. Daha sonra 2021 dönemi için tahmin grafikleri sırası ile Ethereum için Şekil 89'da, Litecoin için Şekil 90'da, Bircoin için Şekil 91'de ve Ripple için Şekil 92'de verilmiştir.




Şekil 85: Ethereum XGBoost Algoritması Fiyat Tahmin Grafığı (2020)




Şekil 86: Litecoin Rastal Orman Algoritması Fiyat Tahmin Grafığı (2020)




Şekil 87: Bitcoin XGBoost Algoritması Fiyat Tahmin Grafiği (2020)




Şekil 88: Ripple Karar Ağacı Algoritması Fiyat Tahmin Grafiği (2020)




Şekil 89: Ethereum XGBoost Algoritması Fiyat Tahmin Grafiği (2021)



Şekil 90: Litecoin Rastal Orman Algoritması Fiyat Tahmin Grafiği (2021)



Şekil 91: Bitcoin XGBoost Algoritması Fiyat Tahmin Grafiği (2021)



Şekil 92: Ripple Karar Ağacı Algoritması Fiyat Tahmin Grafiği (2021)

Performans karşılaştırmasının yapıldığı analiz döneminde ele alınan kripto paralar için XGBoost Gradyan Artırma algoritmasının diğer algoritmalara kıyasla kripto para fiyat tahmininde daha başarılı sonuçlar elde edildiği söylenebilir. Burada çözülen algoritmalarda tüm değişkenler günlük frekansta dâhil edilmiştir. Ancak makine öğrenmesi algoritmalarında *i.i.d.* varsayımının mevcut olması ve gerçek veri kümelerinde bunun genellikle sağlanamaması nedeniyle uygulamada zorluklarla karşılaşabilmektedir. Burada uygulanan tüm algoritmalarda serilere *i.i.d.* olacakları şekilde yer verilmiştir. Bu algoritmaların en yararlı olduğu nokta, doğrusal olmayan veri yapılarında da kullanımlarının mümkün olmasıdır. Makine öğrenmesi yöntemleri gürlüğü içeren kompleks zaman serilerine çok iyi uyum sağlayabilmektedir (Abar, 2020: 429). Karar ağacı tabanlı algoritmalarda normalleştirme işlemi gerekmediğinden ve sadece kayıp fonksiyonun yakınsamasını (tahmin hatası) hızlandırması nedeniyle *i.i.d.* varsayımına karşı toleransı daha yüksektir. Bu nedenle karar ağacı tabanlı geliştirilen algoritmaların fiyat tahmininde daha başarılı performans gösterdiğini söylemek mümkündür. Topluluk öğrenme yaklaşımını kullanan bu algoritmalar her ne kadar tahminlerde başarı sağlasa da, farklı frekanstaki değişkenlerin bir arada incelenmesi ve değerlendirilmesine olanak sağlamamaktadır. Bu noktada doğrusal olmayan yapıyı dikkate alan ve karma frekanslı değişkenlerin bir arada incelendiği ekonometrik tekniklerin kullanılması gerekmektedir.

4.6. Karma Frekanslı Zaman Serilerinin Modellenmesi

Kripto para piyasası ve yatırımcı davranışının izlendiği ve analiz edildiği çalışmalarda, piyasaya ait değişkenlerin kısıtlı frekanslarda elde edilmesi nedeniyle sıklıkla verilerde toplulaştırma işlemi uygulanmaktadır. Toplulaştırmanın yol açtığı problemlerden bölüm 3.6'da bahsedilmiştir. Bu çalışmada ise sözü edilen problemleri ortadan kaldırmak amacı ile MIDAS regresyon modelinden yararlanılmıştır. Alanyazında kripto para piyasası fiyat hareketlerinin incelendiği çalışmalar tarandığında MIDAS regresyon model kullanımının yatırımcı davranışı temelinde incelendiği herhangi bir çalışmaya rastlanmamıştır. Ayrıca büyük veri kapsamında doğrusal olmayan MIDAS regresyonu ile ilgili herhangi bir çalışmada bulunamamıştır. Kripto para fiyat tahmininde bağımlı ve bağımsız değişkenler arasındaki frekans uyumsuzluğunun fazla olması durumunda modelde parametre sayısı olağanüstü bir biçimde arttığı için Üstel Almon gibi gecikmesi dağıtılmış polinomlardan faydalanılmaktadır. Ancak bu tarz gecikmesi dağıtılmış polinomların doğrusal olmamaları nedeniyle, MIDAS regresyonları Doğrusal Olmayan En Küçük Kareler (NLS) yöntemi ile tahmin edilmektedirler. Çalışmada, Üstel Almon Polinomlu MIDAS, Beta Polinomlu MIDAS ile Doğrusal Olmayan MIDAS Regresyon modellerinden olan GARCH-MIDAS modeli ve MS-GARCH-MIDAS modelleri tahmin edilerek her kripto para için uygun modelin belirlenmesi hedeflenmiştir. Uygulamada tahmin edilen modellerin karşılaştırmasında kullanılan

ölçütlerin hesaplanmasında RStudio programı ve GitHub'ta yer alan *metrics* paketinden faydalanılmıştır.

4.6.1. Doğrusal Olmayan MIDAS Regresyon Tahminleri

Üstel Almon Polinomlu MIDAS Regresyon ve Beta Polinomlu MIDAS Regresyon modellerinin tahmininde Doğrusal Olmayan Optimizasyon tekniği uygulanmıştır. Beta Polinomlu MIDAS regresyonlarında yer alan yüksek frekansa sahip değişkenlerde beta dağılımına uyan azalma fonksiyonu kullanılmaktadır. Oluşturulan modellerin tahmininde Doğrusal Olmayan En Küçük Kareler (NLS) yöntemi kullanılmıştır. En uygun modelin tanımlanması aşamasında, optimal gecikme uzunlukları Al-Qawasmi (2014) tarafından belirtilen ve gereksiz parametre artırımının önlenmesi amacıyla önerilen haftalık frekansın 5 kabul edilmesi yaklaşımı izlenmiş ve AIC ve BIC bilgi kriterlerine göre tahmin edilen modeller arasında nihai kararlar verilmiştir. GARCH-MIDAS modellerinde ise MIDAS ağırlıklarının gecikme uzunluğu frekans baz alınarak 12 olarak belirlenmiştir. Kripto para fiyatlarının durağan olmayan yapısı nedeniyle alanyazında sıklıkla yuvarlanan pencere (Rolling window) yaklaşımı kullanılmaktadır. Bölüm 3'te yer verildiği üzere, Giacomini ve White (2006) yuvarlanan pencere ile yapılan testlerin de asimptotik olarak daha uygun sonuç vereceğini ifade etmişlerdir (Giacomini ve White, 2006: 9). Modeller arası performans karşılaştırmasında her modele ait öngörü başarı ölçütü olarak RMSE'nin yanı sıra destekleyici bilgi sağlaması amacı ile MAE ölçütleri de hesaplanmıştır. Üstel Almon ve Beta MIDAS regresyon modellerinde bağımlı değişkenlerin bir gecikmesi bağımsız değişken olarak modele dâhil edilmiştir. Bağımsız değişkenlerin gecikmeleri ise tahmin edilen tüm modellerde Akaike ve Schwarz bilgi kriterlerine göre seçilen modellerin performansı karşılaştırılmıştır. Beta Polinomlu MIDAS Regresyon modelini Üstel Polinomlu MIDAS regresyon modelinden ayıran özellik, yüksek frekansa sahip değişkenlere ait gecikmelerde ağırlıklandırma işlemi yapılırken üstel bir azalma fonksiyonu yerine, beta dağılımına uyan azalma fonksiyonu kullanılmaktadır. Tablo 85'te tahmin edilen modeller için performans karşılaştırma ölçütleri bir arada verilmiştir.

Tablo 85. MIDAS Regresyon Modelleri Performans Karşılaştırması

Model	(Gecikmeler)	Ölçüt	RMSE	MAE
Beta Polinom	(1,2)	ΔLBTC	0.21205687	0.17454563
Üstel Almon	(1,3)		0.32465521	0.28812465
GARCH-MIDAS			0.10245685	0.00865852
Beta Polinom	(2,1)	ΔLETH	0.00436987	0.00206381
Üstel Almon	(2,2)		0.01023654	0.00854269
GARCH-MIDAS			0.02135467	0.01854795
Beta Polinom	(1,4)	ΔLLTC	0.12224682	0.10023421
Üstel Almon	(1,3)		0.09116578	0.06012265
GARCH-MIDAS			0.21002478	0.18552463
Beta Polinom	(2,1)	ΔLXRP	0.11652224	0.09430136
Üstel Almon	(2,5)		0.21349962	0.16148254

GARCH-MIDAS			0.00952166	0.00751896
Beta Polinom	(2,2)		0.22181723	0.18756322
Üstel Almon	(2,3)	ΔLBTC	0.18051236	0.15422366
GARCH-MIDAS			0.10364122	0.08863241
Beta Polinom	(1,2)		0.00407263	0.00299526
Üstel Almon	(2,2)	ΔLETH	0.00831192	0.00701378
GARCH-MIDAS			0.01250565	0.00977527
Beta Polinom	(2,4)		0.00945785	0.00645872
Üstel Almon	(2,3)	ΔLLTC	0.01645821	0.01350214
GARCH-MIDAS			0.02425168	0.02154712
Beta Polinom	(1,3)		0.01265312	0.01044326
Üstel Almon	(2,3)	ΔLXRP	0.01987423	0.01622468
GARCH-MIDAS			0.00845720	0.00589672

$$RMSE = \sqrt{\frac{1}{138} \sum_{t=13.05}^{23.9} (\Delta LKriptoFiyat_t - \Delta LKripto\widehat{Fiyat}_t)^2}$$

$$MAE = \frac{1}{138} \sum_{t=13.05}^{23.9} |\Delta LKriptoFiyat_t - \Delta LKripto\widehat{Fiyat}_t|$$

Tablo 85'te yer verilen sonuçlar doğrultusunda, tahmin edilen MIDAS modelleri arasında 2020 yılı kapsamında XRP, ETH için Beta Polinomlu MIDAS, LTC için Üstel Almon MIDAS ve BTC için GARCH-MIDAS; 2021 yılı kapsamında yine BTC ve XRP için GARCH-MIDAS, ETH ve LTC için Beta Polinomlu MIDAS regresyon tahminlerinin daha başarılı öngörü gerçekleştirdiği belirlenmiştir. Üstel Almon Polinomlu MIDAS regresyonun analiz için ele alınan iki dönemde de LTC hariç kripto para fiyat tahmininde diğer modellere kıyasla başarısız olduğu görülmektedir. Beta polinomlu regresyonunun kripto para piyasasını açıklamada başarılı olduğu belirlenmiştir. Bu durumun yüksek frekanslı verilerin gecikmeli değerlerinin belirli ağırlık fonksiyonlarıyla açıklayıcı değişken olarak alan MIDAS modellerinde, ağırlık katsayılarının gecikme uzunluğu ve fonksiyona göre değişiklik göstermesinden kaynaklandığı ifade edilebilir. Ghysels vd. (2006) de, bu bulguyu destekler şekilde, $B(k, \emptyset)$ ağırlık fonksiyonunda yer alan ağırlıkların negatif olmama kısıtından kaynaklı oynaklık tahminlerinde beta polinom fonksiyonlarının kullanımının uygun olduğunu ifade etmişlerdir. Aşağıda, analiz edilen kripto fiyat getirileri için Tablo 81'deki bulgulara göre, uygun olduğu belirlenen modellerin tahminlerine ait bilgiler tablolarak paylaşılmıştır. Haftalık Ethereum fiyatları için uygun olduğu belirlenen Beta Polinomlu Midas Regresyon modelleri 13.05.2020-27.09.2020 dönemi tahmin sonuçları Tablo 86'da, 13.05.2021-27.09.2021 dönemi tahmin sonuçları Tablo 87'de verilmiştir.

Tablo 86. Beta Polinomlu MIDAS Regresyon Modeli (ETH-2020)

Değişken	Katsayı (Standart Hata)	t-istatistik	p-değeri
Sabit Terim	0.301804 (0.274413)	1.099816	0.3000
ΔLETH(-1)	0.022534 (0.009284)	2.427141	0.0283

<i>Duygu Skoru</i>			
λ	0.6044598 (0.252406)	2.395343	0.0338
θ_1	0.7822634 (0.261248)	2.994332	0.0411
θ_2	-0.483917 (0.166818)	-2.900875	0.0144
<i>$\Delta LEuro$</i>			
λ	-0.161497 (0.068319)	-2.363885	0.0457
θ_1	0.869978 (0.280798)	3.194393	0.0495
θ_2	-0.940426 (0.342907)	-2.742513	0.0207
$R^2 = 0.5530$			

13.05.2020-27.09.2020 dönemi haftalık Ethereum fiyatları için gerçekleştirilen tahmin sonuçlarına bakıldığında, modelde kullanılan bir dönem öncesine ait ETH fiyat değişkeni pozitif ve istatistiksel olarak anlamlıdır. Bu durum geçmiş dönem ETH fiyat artışının bugünün piyasasında etkili olduğunu göstermektedir. Fiyat üzerinde duygu skorunun etkisi incelendiğinde ise istatistiksel olarak anlamlı ve pozitif etkisi olduğu belirlenmiştir. Bu bulgu doğrultusunda Ethereum kapsamında Yatırımcı Tanınmışlık hipotezinin 2020 yılı için desteklendiğini söylemek mümkündür. Kripto para piyasasındaki işlem hacminde ikinci sırada yer alan Ethereum fiyatı üzerinde yatırımcı ilgisinin yanı sıra Euro'nun negatif ve istatistiksel anlamlı etkisi varken, yapılan tahminlerde Dolar değişkeni istatistiksel olarak anlamlı elde edilmediğinden nihai model tahmininde yer verilmemiştir. Ayrıca ağırlıklandırma fonksiyonunda yer alan parametrelerin (θ_1, θ_2) farklı olması fiyat ile duygu skoru ve euro arasındaki gecikmelere bağlı olarak, asimetrik bir yapının olabileceği konusunda fikir vermektedir. Modele ait gecikmelerin eğilim çizgisi incelendiğinde iç bükey eğri görünümü asimetrik yapıyı ifade etmektedir. Kripto paraların Dolar ve Euro gibi küresel paralarla tedavüldeki miktarları kıyaslandığında, gelecekte bu para birimlerine alternatif olma olasılığı pek çok araştırmacı tarafından ileri sürülmektedir. Laboure (2021), Deutch Bank için hazırlamış olduğu raporda 2021 Mart ayı itibarıyla Dolar ve Euro'dan sonra Bitcoin ile Ethereum'un küresel para sıralamasında yer aldığını ifade etmiştir. Aynı raporda 2019 yılı sonunda dolaşımdaki kripto para miktarının %100'ün üzerinde arttığı ifade edilmiştir. Ancak Euro'nun başlıca rezerv paralardan olması ve kripto para piyasasındaki etkisinin tespit edilmesi nedeniyle yatırımcıların uluslararası piyasaları takip etmelerinin yararlı olacağı, beklenmedik piyasa değişimlerine karşı yatırımcı kar marjının düşmesinin engellenmesinde faydalı olacağı ifade edilebilir.

Tablo 87. Beta Polinomlu MIDAS Regresyon Modeli (ETH-2021)

Değişken	Katsayı (Standart Hata)	t-istatistik	p-değeri
Sabit Terim	1.721944	2.644050	0.0458

	(0.651252)		
$\Delta LE_{ETH}(-1)$	-2.632476 (1.056862)	-2.490842	0.0344
<i>Duygu Skoru</i>			
λ	0.795353 (0.201738)	3.942503	0.0169
θ_1	0.789070 (0.339009)	2.327575	0.0483
θ_2	1.073333 (0.314195)	3.416138	0.0058
<i>$\Delta LEuro$</i>			
λ	-0.342852 (0.073424)	-4.669501	0.0005
θ_1	0.761790 (0.182900)	4.165060	0.0013
θ_2	0.914371 (0.154871)	5.904068	0.0001
$R^2 = 0.5020$			

13.05.2021-27.09.2021 dönemi haftalık Ethereum fiyatları için gerçekleştirilen tahmin sonuçlarına bakıldığında, modelde kullanılan bir dönem öncesine ait ETH fiyat değişkeni negatif ve istatistiksel olarak anlamlıdır. Bu durum geçmiş dönem ETH fiyat artışının bugünün piyasasında etkili olduğunu göstermektedir. Fiyat üzerinde duygu skorunun etkisi incelendiğinde ise istatistiksel olarak anlamlı ve pozitif etkisi olduğu belirlenmiştir. Bu bulgu doğrultusunda Ethereum kapsamında Yatırımcı Tanınmışlık hipotezinin 2021 yılı için desteklendiğini söylemek mümkündür. Kripto para piyasasındaki işlem hacminde ikinci sırada yer alan Ethereum fiyatı üzerinde yatırımcı ilgisinin yanı sıra Euro'nun negatif ve istatistiksel anlamlı etkisi varken, yapılan tahminlerde Dolar değişkeni istatistiksel olarak anlamlı elde edilmediğinden nihai model tahmininde yer verilmemiştir. Ayrıca ağırlıklandırma fonksiyonunda yer alan parametrelerin (θ_1, θ_2) farklı olması fiyat ile duygu skoru ve euro arasındaki gecikmelere bağlı olarak, asimetrik bir yapının olabileceği konusunda fikir vermektedir. Modele ait gecikmelerin eğilim çizgisi incelendiğinde iç bükey eğri görünümü asimetrik yapıyı ifade etmektedir. Haftalık Litecoin fiyatları için uygun olduğu belirlenen Üstel Almon ve Beta Polinomlu Midas Regresyon modellerinin 13.05.2020-27.09.2020 dönemi tahmin sonuçları Tablo 88'de, 13.05.2021-27.09.2021 dönemi tahmin sonuçları Tablo 89'da verilmiştir.

Tablo 88. Üstel Almon Polinomlu MIDAS Regresyon Modeli (LTC-2020)

Değişken	Katsayı (Standart Hata)	t-istatistik	p-değeri
Sabit Terim	-0.008309 (0.004540)	-1.830369	0.0971
$\Delta LLTC(-1)$	-3.585525 (1.466173)	-2.445499	0.0444
<i>Duygu Skoru</i>			
λ	4.445536 (1.481980)	2.999728	0.0121

θ_1	5.045187 (2.107784)	2.393597	0.0356
θ_2	5.736617 (2.025735)	2.831869	0.0221
<i>ΔLDolar</i>			
λ	5.017425 (1.292781)	3.881110	0.0031
θ_1	7.439596 (3.228403)	2.304419	0.0467
θ_2	8.467134 (3.612872)	2.343602	0.0438
$R^2 = 0.6210$			

13.05.2020-27.09.2020 dönemi haftalık Litecoin fiyatları için gerçekleştirilen tahmin sonuçlarına bakıldığında, modelde kullanılan bir dönem öncesine ait LTC fiyat değişkeni negatif ve istatistiksel olarak anlamlıdır. Bu durum geçmiş dönem LTC fiyat artışının bugünün piyasasında etkili olduğunu göstermektedir. Fiyat üzerinde duygu skorunun etkisi incelendiğinde ise istatistiksel olarak anlamlı ve pozitif etkisi olduğu belirlenmiştir. Bu bulgu doğrultusunda Litecoin kapsamında Yatırımcı Tanınmışlık hipotezinin 2020 yılı için desteklendiğini söylemek mümkündür. Bitcoin’de olduğu gibi Litecoin için de toplam arzın sınırı bulunduğundan 2020 yılının Nisan ayı itibarıyla 84 milyon ile sınırlı olan Litecoin’in %77’lik kısmı üretilmiştir. Bu durumun yatırımcı açısından pozitif algılandığı Litecoin işlem hacminin ilgili dönemlerde yükselmesiyle desteklenmektedir. Aynı zamanda yatırımcı ilgisi ve Dolar haricinde yapılan tahminlerde Euro değişkeni istatistiksel olarak anlamlı elde edilmediğinden nihai model tahmininde yer verilmemiştir. Ayrıca ağırlıklandırma fonksiyonunda yer alan parametrelerin (θ_1, θ_2) benzer olması fiyat ile duygu skoru ve dolar arasındaki gecikmelere bağlı olarak, simetrik bir yapının olabileceği konusunda fikir vermektedir.

Tablo 89. Beta Polinomlu MIDAS Regresyon Modeli (LTC-2021)

Değişken	Katsayı (Standart Hata)	t-istatistik	p-değeri
Sabit Terim	-0.002043 (0.010760)	-0.189863	0.8529
$\Delta LLTC(-1)$	-0.331098 (0.108995)	-3.037734	0.0113
<i>Duygu Skoru</i>			
λ	-0.522515 (0.216280)	-2.415924	0.0343
θ_1	-0.517476 (0.247736)	-2.088817	0.0555
θ_2	-0.532820 (0.246016)	-2.165790	0.0481
<i>$\Delta LEuro$</i>			
λ	0.855017 (0.187838)	4.551896	0.0007
θ_1	-0.333696 (0.071395)	-4.673921	0.0012

θ_2	-3.885839 (1.329688)	-2.922369	0.0119
$R^2 = 0.4518$			

13.05.2021-27.09.2021 dönemi haftalık Litecoin fiyatları için gerçekleştirilen tahmin sonuçlarına bakıldığında, modelde kullanılan bir dönem öncesine ait LTC fiyat değişkeni negatif ve istatistiksel olarak anlamlıdır. Bu durum geçmiş dönem LTC fiyat artışının bugünün piyasasında etkili olduğunu göstermektedir. Fiyat üzerinde duygu skorunun etkisinin negatif ve istatistiksel anlamlı olduğu görülmektedir. Bu bulgu doğrultusunda Litecoin kapsamında yatırımcı tanınırlık hipotezinin 2021 yılı için desteklendiğini söylemek mümkündür. Aynı zamanda yatırımcı ilgisi ve Euro haricinde yapılan tahminlerde Dolar değişkeni istatistiksel olarak anlamlı elde edilmediğinden nihai model tahmininde yer verilmemiştir. Ayrıca ağırlıklandırma fonksiyonunda yer alan parametrelerin (θ_1, θ_2) farklı olması fiyat ile duygu skoru ve euro arasındaki gecikmelere bağlı olarak, asimetrik bir yapının olabileceği konusunda fikir vermektedir. Modele ait gecikmelerin eğilim çizgisi incelendiğinde iç bükey eğri görünümü asimetrik yapıyı ifade etmektedir.

Beta polinomlu MIDAS regresyon tahminleri farklı formlarda şekil alabilen ve son derece esnek olan beta fonksiyonunun ağırlıklandırmasında üç parametre tarafından kısıtlandığından bahsedilmiştir. Bu sayede artan gecikme uzunluğuna karşılık parametre sayısında değişikliğine neden olmaması garanti altına alınmaktadır. Böylece artan gecikme sayısının doğrusal olmayan optimizasyon işleminde karmaşıklık yaratmasının önüne geçilmektedir. Bölüm 2’de verilen alanyazın taramasında kripto paraların finansal varlıklarla karşılaştırıldığı çalışmalarda tam anlamıyla somut sonuçlar çıkarılmadığı belirlenmişti. Ancak kripto para piyasasının dinamiklerinin incelenmesinde karma frekanslı yaklaşımların daha detaylı sonuçlar verebileceği elde edilen bulgularla desteklenmiştir. Aynı zamanda Ethereum ve Litecoin özelinde sonuçlar değerlendirildiğinde Etkin Piyasa Hipotezi’nin desteklenmediğini söylemek mümkündür. GARCH-MIDAS model tahminlerine geçildiğinde, oynaklık uzun dönemli bileşeninin (τ_T) , değişen ve sabit zaman uzunluğuna sahip olduğu tanımlamalar denenmiştir. Tahminler sonucu elde edilen modeller incelendiğinde tahmin performansı yüksek olan modellerin değişen zaman uzunluğuna sahip olduğu belirlenmiştir. Aynı zamanda MIDAS ağırlıklarının gecikme uzunluğu AIC ve BIC ’i en küçük yapan değerlere göre belirlenmiştir.

$$\log(\tau_t) = m + \theta \sum_{k=1}^K \varphi_k(\omega_1, \omega_2) X_{t-k} \quad (4.5)$$

$$\log(\tau_t) = m + \sum_{j=1}^J \theta_j \sum_{k=1}^K \varphi_k(\omega_{j,1}, \omega_{j,2}) X_{j,t-k} \quad (4.6)$$

Tek değişkenli GARCH-MIDAS modelinin (4.5) değişkenlerle genişletilmesi sonucu çok değişkenli GARCH-MIDAS modeli (4.6) elde edilmektedir. GARCH-MIDAS Regresyon Modeli tahmin sonuçları Bitcoin için Tablo 90 ve Ripple için Tablo 91’de verilmiştir.

Tablo 90. GARCH-MIDAS Regresyon Model (BTC)

Parametre Model	μ	α	β	γ	θ_{duygu}	ω_1	ω_2	$\theta_{\Delta Idolar}$	ω_1	ω_2	m
2020	0.04806 (0.12226)	0.23307 (0.02148)	0.18310 (0.04734)	0.11170 (0.01677)	0.65361 (0.04138)	2.67717 (0.00721)	3.45332 (1.47882)	0.01642 (0.02733)	1.26555 (0.78442)	4.74899 (2.40682)	1.60168 (0.00203)
2021	0.04779 (0.21793)	0.16975 (0.01733)	0.16087 (0.04779)	0.13082 (0.01710)	0.68924 (0.00518)	4.38624 (1.80202)	5.65697 (0.00934)	-0.02411 (0.01523)	3.80500 (1.09222)	4.42623 (2.13002)	0.64875 (0.00756)
2020						2021					
<i>AIC</i> = -3391.6 <i>BIC</i> = -3351.5						<i>AIC</i> = -4147.23 <i>BIC</i> = -4062.33					

$$\log(\tau_t) = m + \theta_{duygu} \sum_{j=1}^{12} \varphi_k(\omega_{11}, \omega_{12}) Duygu_{t-K} + \theta_{dolar} \sum_{j=1}^{12} \varphi_k(\omega_{21}, \omega_{22}) \Delta LDolar_{t-K}$$

Tablo 91. GARCH-MIDAS Regresyon Model (XRP)

Parametre Model	μ	α	β	γ	θ_{duygu}	ω_1	ω_2	$\theta_{\Delta Idolar}$	ω_1	ω_2	m
2020	0.05327 (0.26625)	0.12237 (0.04958)	0.21576 (0.00330)	0.11455 (0.02241)	0.32009 (0.02536)	3.05774 (0.00857)	5.94336 (1.67332)	-0.80121 (0.74866)	1.04711 (0.01100)	2.67525 (1.24610)	0.87640 (0.02650)
2021	0.14618 (0.00190)	0.48488 (0.01118)	0.12146 (0.02721)	0.05674 (0.01752)	-0.93754 (0.00508)	1.00012 (0.03505)	3.81775 (2.13186)	0.03021 (0.01210)	1.01752 (0.00450)	2.80333 (0.66633)	0.54219 (0.00712)
2020						2021					
<i>AIC</i> = -2125.7 <i>BIC</i> = -2112.8						<i>AIC</i> = -3011.07 <i>BIC</i> = -2993.12					

$$\log(\tau_t) = m + \theta_{duygu} \sum_{j=1}^{12} \varphi_k(\omega_{11}, \omega_{12}) Duygu_{t-K} + \theta_{dolar} \sum_{j=1}^{12} \varphi_k(\omega_{21}, \omega_{22}) \Delta LDolar_{t-K}$$

BTC fiyatı için gerçekleştirilen GARCH-MIDAS tahmin sonuçlarına bakıldığında 2020 döneminde yer alan μ parametresi dışındaki tüm parametrelerin istatistiksel olarak anlamlı olduğu belirlenmiştir. α , β ve γ GARCH model parametrelerinin toplamının 2020 modelinde 0.52, 2021 modelinde ise 0.46 olduğu görülmektedir. Aynı zamanda $\alpha > 0$ ve $\beta < 1$, oynaklık kümelenmesini göstermekte olup, kısa vadeli oynaklık bileşeninin uzun vadede dönüş eğiliminde olduğunu ifade etmektedir. Ayrıca modellerde yer alan ω ağırlık parametrelerinde 1'den büyük, θ parametrelerinin ise fiyat oynaklığı üzerinde farklı etkileri olduğu ve m parametrelerinin de pozitif olduğu belirlenmiştir. Duygu skorunun fiyat oynaklığı üzerindeki etkisi hem 2020 hem de 2021 yılında pozitif, doların etkisinin de 2020 yılında pozitif, 2021 yılında negatif olduğu görülmüştür. GARCH-MIDAS modelinin kısa dönem kısmında, α ve β katsayılarının toplamının toplamının 1'den küçük ancak her iki analizde de düşük çıkması oynaklık kalıcılığının olmadığını düşündürmektedir. Elde edilen bulgulardan hareketle tahmin edilen GARCH-MIDAS modellerinin kararlılık koşulunu sağladığı tespit edilmiştir. Aynı zamanda bu sonuç, Ripple piyasasındaki bir şokun etkisinin uzun sürmediğini göstermektedir. Ayrıca düşük bir β tahmini de, düşük frekanslı dolar kuru ve kripto paraya ait duygu skorunun uzun vadeli oynaklık üzerinde de kalıcı bir etkiye sahip olduğunu göstermektedir. Buradan hareketle Bitcoin'in incelenen dönemler kapsamında Yatırımcı Tanınmışlık Hipotezi'ni desteklediğini söylemek mümkündür.

XRP fiyatı için gerçekleştirilen GARCH-MIDAS tahmin sonuçlarına bakıldığında yer alan tüm parametrelerin istatistiksel olarak anlamlı olduğu belirlenmiştir. α , β ve γ GARCH model parametrelerinin toplamının 2020 modelinde 0.45, 2021 modelinde ise 0.75 olduğu görülmektedir. Aynı zamanda $\alpha > 0$ ve $\beta < 1$, oynaklık kümelenmesini göstermekte olup, kısa vadeli oynaklık bileşeninin uzun vadede dönüş eğiliminde olduğunu ifade etmektedir. Ayrıca modellerde yer alan ω ağırlık parametrelerinde 1'den büyük, θ parametrelerinin ise fiyat oynaklığı üzerinde farklı etkileri olduğu ve m parametrelerinin de pozitif olduğu belirlenmiştir. Duygu skorunun fiyat oynaklığı üzerindeki etkisi 2020 yılı için pozitif, 2021 yılı için negatif tespit edilmiştir. Ayrıca doların etkisinin de 2020 yılında negatif, 2021 yılında pozitif olduğu görülmüştür. GARCH-MIDAS modelinin kısa dönem kısmında, α ve β katsayılarının toplamının toplamının 1'den küçük ancak her iki analizde de düşük çıkması oynaklık kalıcılığının olmadığını düşündürmektedir. Elde edilen bulgulardan hareketle tahmin edilen GARCH-MIDAS modellerinin kararlılık koşulunu sağladığı tespit edilmiştir. Aynı zamanda bu sonuç, Ripple piyasasındaki bir şokun etkisinin uzun sürmediğini göstermektedir. Ayrıca düşük bir β tahmini de, düşük frekanslı dolar kuru ve kripto paraya ait duygu skorunun uzun vadeli oynaklık üzerinde de kalıcı bir etkiye sahip olduğunu göstermektedir. Buradan hareketle Ripple'in incelenen dönemler kapsamında Yatırımcı Tanınmışlık Hipotezi'ni desteklediğini söylemek mümkündür.


4.6.2. Hibrit Model Denemesi

Dört kripto para tahmini için gerçekleştirilen MIDAS regresyon tahminlerinde uygun olan formdaki modeller belirlenmiştir. Modeller arası farklılaşmanın incelenen kripto paraların incelenen dönem aralığındaki davranışlarından ve/veya oynaklık hareketlerinden kaynaklı olduğu düşünülmektedir. İncelenen değişkenlerin aynı frekansta ele alındığı makine öğrenmesi regresyon algoritma sonuçlarına bakıldığında ise; karar ağacı tabanlı makine öğrenmesi algoritmalarının yüksek eğitim seti başarısından dolayı tahmin değerleri ile gerçek değerlerin oldukça yakın olduğu belirlenmiştir. Optimal parametrelere göre belirlenen tahmin modellerinde test verisiyle performans karşılaştırması yapıldığında XGBoost algoritmasının diğer algoritmalara kıyasla kripto para fiyat tahmininde daha başarılı sonuçlar verdiğini söylemek mümkündür. Diğer algoritmalarla kıyaslandığında örneğin, K-en yakın komşu tekniğinin çoğunlukla sınıflandırma problemlerinde kullanılması nedeniyle performansının düşük çıkması beklenen bir durumdur. MIDAS modelleri ise tek başına kullanımının örneklem yapısının varyasyonu ve rastsal faktörler nedeniyle tüm koşullarda optimum performansı sağlamadığı için araştırmacılar tarafından eleştirilmektedir. MIDAS yaklaşımının, doğrusal olmamayı ve küçük örneklem boyutunu doğrudan ele alamaması nedeniyle alanyazında MIDAS için hibrit model önerisi yaklaşımları mevcuttur. Zaman serileri ve pay piyasalarına ait değişkenlerin tahmininde ise sıklıkla destek vektör makineleri ve yapay sinir ağlarının kullanıldığı görülmektedir. Kripto para piyasasında hibrit yaklaşım kullanılan herhangi bir çalışmaya ise rastlanmamıştır.

Regresyon problemlerinde oldukça güçlü olan XGBoost algoritması bir topluluk öğrenme yöntemi olup, birden fazla değişkene ait tahmin gücünün birleştirilerek sistematik bir çözüm sunulmasını sağlamaktadır. Başarılı tahminler elde edilmesini sağlamasının yanı sıra hesaplama kolaylığı nedeniyle özellikle büyük veri analizinde etkin şekilde kullanılmaktadır. Çünkü algoritma hataların minimize edilmesi temeline dayanmaktadır. Örneğin, Avrupa Nükleer Araştırma Merkezi (CERN), Büyük Hadron Çarpıştırıcısı'na ait üretilen yıllık 3 petabayt verinin analizinde bu algoritmayı kullanmıştır (Sundaram, 2018). Aynı zamanda özellikle yapılandırılmamış verilerde XGBoost algoritmasının diğer algoritmalara kıyasla tahmin performansının daha yüksek olduğu araştırma bulgularıyla desteklenmiştir (Li vd., 2017). Bu çalışmada da bahsedildiği üzere, kripto para piyasası tahminlerinde farklı algoritmalarla denenmiş olup, sonuçları paylaşıldığı üzere sıklıkla XGBoost algoritmasının performansının yüksek olduğu saptanmıştır. XGboost yöntemi tahmin aşamasında esnek doğrusal olmayan tahmin sağlayabildiğinden ve MIDAS regresyon ile güçlü bağlantı kurulabilmesinden hareketle hibrit bir yaklaşımın karma frekanslı ve doğrusal olmayan ilişkiye sahip verilerde kullanılması olanaklı görülmektedir. Bu nedenle çalışmadan elde edilen bulgular doğrultusunda, kripto para piyasasının dinamiklerinin tahmin edilmesinde hibrit model tahminiyle deneysel bir çalışma

gerçekleştirilmiştir. Kripto paraların dinamik ve doğrusal olmayan yapılarının tahmin edilen MIDAS regresyonların performansı üzerindeki etkisinin karşılaştırılabilmesi adına XGBoost algoritmasıyla birleştirilmiş GARCH-MIDAS-XGBoost ve Beta Polinom-XGBoost hibrit modelleri ile tahmin performansı karşılaştırması yapılması hedeflenmiştir. Deneysel çalışma doğrultusunda ise Bitcoin ve Ethereum kripto para birimleri ele alınmıştır. Alanyazına bakıldığında, Wang ve Kang (2021) tarafından haftalık buhar kömür fiyatlarının tahmin edilmesinde XGBoost ve MIDAS regresyonun birleştirildiği hibrit model önerisi tek örnek olarak görülmektedir. Gerçekleştirilen çalışmada, XGBoost algoritmasıyla tahmin edilen MIDAS regresyonun anlamlı sonuçlar çıkarma konusunda MIDAS regresyonun daha iyi bir yeteneğe sahip olduğu kanıtlanmıştır (Wang ve Kang, 2021: 4251). Buradan hareketle, Wang ve Kang (2021) çalışması referans alınarak model denemeleri gerçekleştirilmiş olup, deney tasarımı ilişkin bilgiler verilmiştir.





Şekil 93: Kombinasyon-MIDAS-XGBoost Model Akış Şeması

Kaynak: Wang, C., Kang, W. (2021), "Forecasting China's Steam Coal Prices Using Dynamic Factors and Mixed-Frequency Data", *Pol. J. Environ. Stud.*, 30(5): 4241-4254.

Adım 1: her faktörle ayrı ayrı MIDAS modelleri oluşturularak örneklem dışı tahmin performansına göre en iyi bireysel model seçilir. Önerilecek modelin oluşturulmasında en iyi MIDAS regresyonun seçilmesi gerekmektedir. Tahmin performanslarının değerlendirilmesinde RMSE ölçütü benimsenmektedir. Bu adım çalışmada gerçekleştirilmiş olup, Ethereum ve Bitcoin özelinde en uygun modeller belirlenerek paylaşılmıştır.

Adım 2: kripto para fiyatını, karşılık gelen yüksek frekanslı faktörlerle belirlenen MIDAS modelinin artıkları ele alınmaktadır. İlgili artıklar girdi verisi olarak XGBoost algoritmasıyla tahmin edilerek artıkların tahmin değerleri tahmin hataları olarak alınmaktadır.

Adım 3: Belirlenen MIDAS modellerine ait tahmin değerlerinin düzeltilmesinde XGBoost algoritması tarafından elde edilen tahmin hataları kullanılmaktadır. Elde edilen model ile belirlenen MIDAS modeli arasında tahmin performansı karşılaştırılmaktadır.

Adım 4: Aylık kripto para fiyatı tahmini MIDAS-XGBoost kombinasyonu aracılığı ile incelenmektedir. Ağırlıklandırma işleminde Akaike bilgi kriteri $AIC = (w_{j,T} = \exp(-AIC_j) / \sum_{j=1}^N \exp(-AIC_j))$ tipi ve Bayesyen bilgi kriteri $BIC = (w_{j,T} = \exp(-BIC_j) / \sum_{j=1}^N \exp(-BIC_j))$ tipi ağırlıklar kullanılmıştır.

Buradan hareketle, öncelikle MIDAS regresyon modelleri tahmin edilmiştir. Yukarıda da değinildiği gibi, model denemesi için ele alınan kripto para Bitcoin ve Ethereum'dur. Bu tercihin nedeni, fiyat tahmininde hem 2020 hem de 2021 yılı kapsamında en iyi tahmin performansının XGBoost algoritmasıyla gerçekleştirilmiş olmasıdır. Önceki aşamada olduğu gibi ilgili dönem aralığı kapsamında %75'lik kısım eğitim verisi, %25'lik kısım örnek dışı tahminde kullanılabilme adına test verisi olarak ayrılmıştır. Eğitim verileri aracılığıyla önerilen hibrit modelin eğitilerek performansının değerlendirilmesi hedeflenmiştir. Önerilen MIDAS-XGBoost model kombinasyonunu oluşturmanın ilk adımı olarak, en iyi MIDAS modelinin seçilmesi, nihai sonucun doğruluğu için kritik bir süreçtir. Çünkü önerilen hibrit modelin temelini oluşturduğundan bu adım bir önceki bölümde gerçekleştirilmiştir. 2020 yılı kapsamında tahmin edilen MIDAS modelleriyle Hibrit MIDAS modellerinin tahmin performansı karşılaştırılmıştır. Tahmin yöntemleri arasındaki tahmin doğruluğunun karşılaştırılmasında karesel hata bazlı değiştirilmiş (modified) DM testi gerçekleştirilmiştir. Klasik DM testinden farklı olarak test

istatistikleri $DM^* = \frac{DM}{\left\{ \frac{T+1-2h+\frac{h(h-1)}{T}}{T} \right\}}$ 1 / 2 olacak şekilde hesaplanmıştır (Mariano ve Preve, 2008:

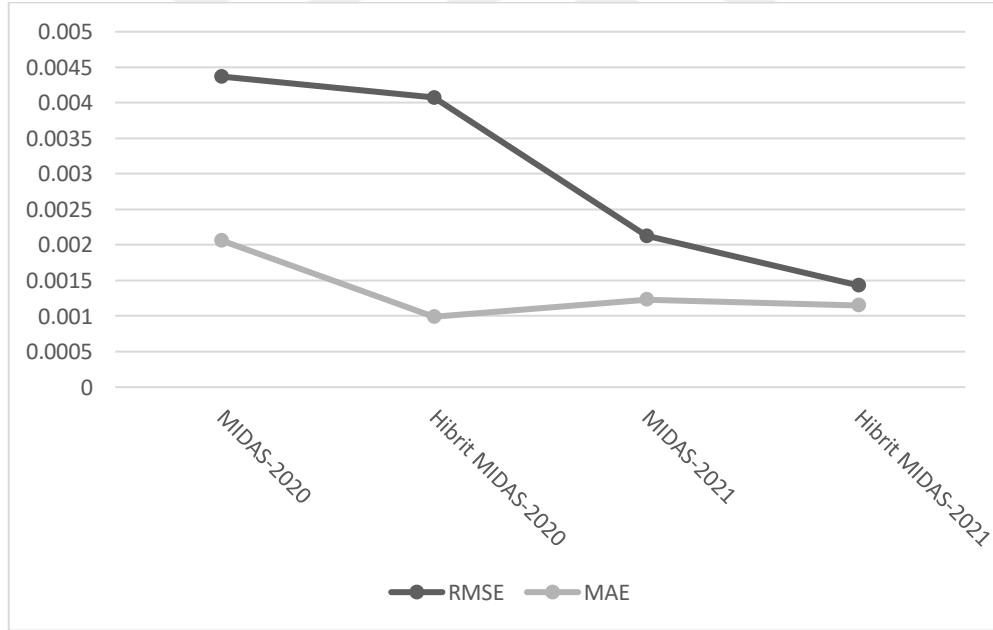
19).

Tablo 92. Klasik ve Hibrit Model Tahmin Performanslarının Karşılaştırılması

Model			Modifiye DM Test
GARCH-MIDAS	2020	ΔBTC	0.407
GARCH-MIDAS-XGBoost			(0.684)
GARCH-MIDAS	2021	ΔBTC	0.612
GARCH-MIDAS-XGBoost			(0.371)
Beta Polinom	2020	ΔETH	2.260
Beta Polinom-XGBoost			(0.024)
Beta Polinom	2021	ΔETH	2.045
Beta Polinom-XGBoost			(0.041)

Not: $|DM| > 1.96$ için %5 anlamlılık düzeyinde eşit tahmin gücünü ifade eden ($H_0: E(d_{12t}) = E[L(e_{1t}) - L(e_{2t})] = 0$) temel hipotez sınanmaktadır. İstatistiksel anlamlılıklarını ifade eden p-değerleri parantez () içerisinde verilmiştir.

Modellerin tahmin performanslarının karşılaştırılmasında kullanılan Diebold-Mariano testi sonuçları doğrultusunda incelenen dönem aralığında Ethereum için bakıldığında; test istatistiklerinin olasılık değerlerinin 0.024 ve 0.041 olması nedeniyle Beta Polinom MIDAS Beta Polinom MIDAS-XGBoost modellerinin eşit tahmin tutarlılığına sahip olduğu önsavı %5 anlamlılık düzeyinde reddedilmektedir. Bu durum, Ethereum modellemesinde Beta Polinom-XGBoost modelinin Beta Polinom MIDAS modeline göre daha iyi performans gösterdiğine işaret etmektedir.

**Şekil 94:** Tahmin Kriter Değerleri Karşılaştırması

Şekil 94'e bakıldığında, önerilen hibrit modelin Beta Polinom MIDAS regresyona göre ortalama daha iyi temsil ettiği ve gerçekleşen değerlere yakın tahminleme yaptığı görülmüştür. Esnek ve doğrusal olmayan ilişkilerin modellenmesinde başarılı olan XGBoost algoritmasının MIDAS modelle birleştirilmesi sonucu regresyon hata terimlerinde iyileştirme olduğu görülmektedir. Dolayısıyla XGBoost algoritmasının hata terimlerini en küçüklemede başarılı altyapısının MIDAS regresyon tahminlerinde alternatif olarak kullanılabilirliği düşünülmektedir.

Modellerin tahmin performanslarının karşılaştırılmasında kullanılan Diebold-Mariano testi sonuçları doğrultusunda, incelenen dönem aralığında Bitcoin için bakıldığında ise test istatistiklerinin olasılık değerlerinin 0.684 ve 0.371 olması nedeniyle GARCH-MIDAS ve GARCH-MIDAS-XGBoost modellerinin eşit tahmin tutarlılığına sahip olduğu önsavı %5 anlamlılık düzeyinde reddedilememektedir. Bu nedenle GARCH-MIDAS yönteminin düşük frekanslı ekonomik değişkenlerin modele doğrudan eklenmesine izin vermesinden kaynaklı performansının tek başına yeterli olduğunu söylemek mümkündür.

Oynaklık analizi ve tahmini, Engle (1982) ve Bollerslev (1986) tarafından GARCH modellerinin tanıtılmasından bu zamana oldukça gelişim göstermiştir. Bununla birlikte, oynaklık ile makroekonomik faktörler arasındaki bağlantı ise 1973'te Officer tarafından "*Borsa oynaklığı neden zaman içinde değişir?*" sorusunun sorulmasıyla kurulmaya başlanmıştır. Bu noktada, Ghysels vd. (2013) tarafından makroekonomik faktörlerinde dâhil edildiği MIDAS terimi alanyazına girmiştir. Ghysels vd. makroekonomik faktörlerin dâhil edilmesinin oynaklık tahminlerinin önemli ölçüde iyileşmesini sağladığını ifade etmişlerdir. Bu tezde makroekonomik faktörlerinde dâhil edildiği GARCH-MIDAS modelinin hibrit modelle karşılaştırılması sonucu eşit tahmin tutarlılığı olduğu tespit edilmişti. Ancak Ghysels vd. tarafından geliştirilen bu modelde oynaklık sürecindeki yapısal kırılmalar modele dâhil edilmemektedir. Bu nedenle model yapısal kırılmalara karşı hassas olabileceğinden kırılma tespit edilmemesi durumunda tahmin doğruluğunun azalmasına neden olabilecektir. Tezin ilk bölümünde yer verilen Markov rejim değişim modellerinden elde edilen ve tezin son bölümünde yer verilen Markov rejim değişim VAR modellerinden Bitcoin kapsamında elde edilen bulgulardan hareketle yapısal istikrarın incelenmesi ve potansiyel kırılmaların modele alınması için oynaklık rejimini de dâhil eden MS-GARCH-MIDAS modeli tahmin edilmiştir. MS-GARCH-MIDAS modeli hem basit GARCH sürecini hem de tek rejimli GARCH-MIDAS modelini barındırmaktadır. Bu nedenle de geliştirilmiş bir modelin tahmin performansı açısından daha da geliştirilmesine olanak tanıyabilmektedir. MS-GARCH-MIDAS modeli aynı dönem ve makroekonomik değişkenler üzerinden tahmin edilerek örneklem içi uyumu değerlendirilerek tek rejim modeline kıyasla iki rejimli modelin daha başarılı olduğu görülmüştür. Dolayısıyla "*bir Markov rejim değişimli GARCH-MIDAS modelinin Ghysels vd. tarafından geliştirilen GARCH-MIDAS modelinin tahmin performansını geliştirir mi?*" sorusuna yanıt aranmıştır. Aynı zamanda buna paralel olarak "*makroekonomik değişkenler, rejimdeki değişiklikleri ikinci bir rejimi önemsiz kılmak için yeterince bilgi içeriyor mu?*" sorusu da irdelenmiştir. Oynaklığın modellenmesinde sıklıkla iki rejim modelinin uygulanmasının nedeni, oynaklığın konjonktür karşısı doğasından kaynaklanmaktadır. Oynaklık, ekonomik gerileme ya da borsa üzerinden değerlendirildiğinde ayı piyasası döneminde artış eğilimi göstermektedir. Yükseliş dönemlerinde ise düşük seviyelerde

kalmaktadır. Dolayısıyla koşulsuz varyansta farklılık gösteren iki GARCH süreci oynaklık sürecini karakterize edebilmektedir. Hamilton ve Lin (1996), tek rejim yaklaşımını kullanmış olup uygunluk sırasında oynaklığın daha yüksek olduğunu tespit etmişlerdir. Bu şekilde modellemenin etkisi, özellikle kısa vade taminlerinin iyileştirilmesini sağlamaktadır.

İncelenen dönem aralığında Bitcoin için tahmin edilen GARCH-MIDAS modelinin kararlılık koşulunu sağladığı tespit edilmişti. Ancak Bitcoin için tahmin edilen MS-GARCH-MIDAS model denemelerinde kararlılık koşulunun sağlanamadığı görülmüştür. Bu durumun incelenen dönem aralığına ait frekansın düşük olmasından kaynaklandığı düşünülmektedir. Bu nedenle 13.05.2020-27.09.2020 ve 13.05.2021-27.09.2021 dönem aralıkları için Bitcoin fiyatları Kaggle üzerinden saatlik frekansta elde edilmiştir (Kaggle, 2022). 2020 yılı kapsamında 3336 ve 2021 yılı kapsamında 3312 gözlem ile Bitcoin fiyatları GARCH-MIDAS modelinde yer verilen makroekonomik değişkenlerle birlikte Pan vd. (2017) çalışmasında tanıtılan MS-GARCH-MIDAS modeliyle tahmin edilerek sonuçları Tablo 93'te verilmiştir. Bitcoin fiyat serileri için gerçekleştirilen BDS testi sonuçlarına göre doğrusallığı ifade eden sıfır hipotezinin logaritmik Bitcoin serisinde tüm boyutlar için reddedildiği tespit edilmiştir ($p = 0.000$). Bu da serilerin tüm boyutlarda doğrusal olmadığını ortaya koymaktadır. Serilerin doğrusal olmadığı belirlendikten sonra KSS testi ile serilerin durağan olup olmadıkları test edilmiş olup, hem 2020 ($KSS = -1.254$) hem de 2021 ($KSS = -1.003$) yıllarında Bitcoin fiyatının düzey haliyle durağan olmadığı görülmüştür. Saatlik frekanslı serilere uygulanan KSS testi sonucunda serilerin I(1) olduğu, yani logaritmik ilk farklarının durağan olduğuna karar verilmiştir. Ayrıca Jarque-Bera normallik testi sonuçlarına göre serilerin normal dağılım özelliği göstermediği tespit edilmiştir ($p = 0.000$).

Tablo 93. MS-GARCH-MIDAS Regresyon Model (BTC)

Parametre Model	ω_0	ω_1	α	β	θ_{duygu}	κ_1	κ_2	$\theta_{\Delta dolar}$	κ_1	κ_2	p_{11}	p_{22}	$\omega_1 - \omega_0$
2020	1.010 (0.398)	2.004 (1.773)	0.015 (0.003)	0.910 (0.046)	0.033 (0.008)	4.293 (10.230)	3.930 (2.422)	0.070 (0.036)	3.899 (6.409)	4.458 (9.614)	0.9044 (0.003)	0.9263 (0.005)	0.994
2021	1.402 (0.000)	1.913 (3.454)	0.0712 (0.0078)	0.646 (1.299)	0.016 (0.003)	5.428 (5.463)	5.673 (4.651)	0.098 (0.552)	10.344 (10.072)	10.389 (6.560)	0.9251 (0.004)	0.9703 (0.003)	0.511
2020							2021						
$AIC = -5568.8$							$AIC = -5004.42$						
$BIC = -5333.9$							$BIC = -4914.43$						

Markov tipi GARCH-MIDAS modellerinin p_{11} ve p_{22} değerlerinin tümünün 0,9'dan büyük olduğu tespit edilmiştir. Kirikos (2017) çalışmasından hareketle elde edilen bu bulgu rejim kalıcılığının yüksek olduğunu doğrulamaktadır. 2020 yılı kapsamında rejim 1 yaklaşık olarak $(1/(1 - p_{11}))$ 10 gün, rejim 2 yaklaşık olarak $(1/(1 - p_{22}))$ 14 gün ve 2021 yılı kapsamında rejim 1 yaklaşık olarak 13 gün ve rejim 2 yaklaşık olarak 34 gün sürmektedir. Bu durum Bitcoin piyasasının yüksek oynaklık süresinin düşük oynaklıktan daha uzun olduğunu ifade etmektedir. θ tahminlerine bakıldığında; duygu skoru ve doların %5 seviyesinde pozitif olmasından kaynaklı Bitcoin piyasası oynaklığını arttırıcı nitelikte oldukları görülmüştür. Bu durum fiyatlar üzerinde oynaklığı önemli ölçüde etkileyebileceğini göstermektedir. Ayrıca $\omega_1 - \omega_0$ sonuçlarının pozitif olmasından kaynaklı, rejimler arasındaki ortalama oynaklığın farklılaştığı tespit edilmiştir. Özetle Pan vd. (2017) çalışmasından hareketle, GARCH-MIDAS modelinin geliştirilerek Markov rejiminin kısa vadeli bileşende eklenmesi ve uzun vadeli makroekonomik değişkenlere kısa vadeli yapısal kırılmaların fiyat dinamiklerini yönlendirmedeki rolüne ilişkin sonuçlar tespit edilmiştir.

Model tahmin sonuçlarından özetle, Bitcoin fiyatı için kısa vadeli oynaklıkta Markov rejimine bağlı özelliklerin güçlü varlığı tespit edilmiştir. Buradan hareketle, dinamik rejim değişikliklerinin modellenmesinde kullanılan bu modelin tahmin performansının makine öğrenmesi algoritması olan XGBoost ile birleştirilerek yeniden tahmin edilmesi sonucu kıyaslanması hedeflenmiştir. Bu amaçla gerçekleştirilen Diebold-Mariano testi sonucunda eşit tahmin tutarlılığına sahip olduğu önsavı %5 anlamlılık düzeyinde ret edilememiştir ($DM\ test: 0.136, p = 0.835$). Tablo 92’de sonuçları verilen test sonuçlarından hareketle, GARCH-MIDAS modelinin de hibrit model ile eşit tahmin tutarlılığına sahip olduğu belirlenmiştir. İlgili modellerin sonuçları göz önüne alındığında, Ghysels vd. (2017) çalışmasına paralel olarak makroekonomik değişkenlerin oynaklık üzerinde önemli bir etkisi olduğu yorumu yapılabilmektedir. Ancak rejim değişimli GARCH-MIDAS modelinin de hibrit modelle eşit tahmin performansına sahip olduğu görülmüştür. Bu durum, rejim bilgisinin makroekonomik değişkenlerde yeterince yer aldığını göstermektedir. Ghysels vd. dâhil ettikleri makroekonomik değişkenlerin en yakın dönemdeki oynaklığa yaklaşık olarak %30’luk katkı yaptığını ifade etmişlerdir. Buna karşılık tüm örneklem genelinde tahmin edilen oynaklığın kabaca yarısını oluşturduğunu tespit etmişlerdir. Ayrıca makroekonomik değişken içeren modellerin içermeyenlere kıyasla, ortalama hata karelerinin sürekli olarak daha düşük elde edildiğini ifade etmişlerdir. Buradan hareketle; doğrusal olmayan ilişkilerin modellenmesinde esnek yapıyla başarılı olan XGBoost algoritmasının hata terimlerini en küçüklemede başarılı altyapısının, rejim değişimli GARCH-MIDAS regresyon modeliyle benzer olduğunu söylemek mümkündür. Aynı zamanda rejim değişimli GARCH-MIDAS ve GARCH-MIDAS modellerinde tahmin performansının, dâhil edilen makroekonomik değişkenler kaynaklı yeterli bilgiyi içerdiğini ifade edilebilir. Ma vd. (2021) tarafından Pan vd. (2017) çalışmasından hareketle geliştirilen Markov rejim değişimli GARCH-MIDAS modelinde rejim yapısının değiştirilmesiyle uzun vadeli oynaklığında modele dâhil edilebileceği gösterilmiştir. Ayrıca Wang vd. (2022) tarafından hem kısa hem de uzun vadeli oynaklığın makroekonomik değişkenlerle birlikte tahmin edilebildiği kombine edilmiş bir MS-GARCH-MIDAS modeli tanıtılmıştır. Bu nedenle sonraki araştırmalar için bahsedilen modellerin tahmin performansının incelenmesi önerilmektedir.

SONUÇ VE DEĞERLENDİRME

Karma frekanslı zaman serilerinin modellenmesi üzerine gerçekleştirilen bu tez çalışmasında büyük veri üzerine çalışılmıştır. Çalışmanın deneysel kısmında büyük veri kaynaklarından olan kripto ekonomisi ele alınmıştır. Bu tercihin nedeni, hâlihazırda dinamiklerinin anlaşılması noktasında çalışmaları devam eden bir alan için geleneksel ekonometrik yaklaşımlar yerine büyük verinin adapte edilebileceği ve neden edilmesi gerektiğinin ekonometrik açıdan açıklanabilirliğini ortaya koymaktır. Büyük kripto ekonomisi olarak isimlendirilen bu alan aynı zamanda itibari paranın dijitale evrimidir. Klasik para anlayışından farklı bir yapıda ortaya çıkan dijital para, son yıllarda dünya genelinde yaygınlaşan bir alternatif değişim aracı niteliğindedir. Evrim içerisinde olan paranın kullandığı teknolojik altyapı ise geçmişten bugüne dijital varlıkları içeren her çevrimiçi işlemin her zaman doğrulanabileceği, dağıtılmış bir uzlaşmayı sağlayarak, dijital dünyada devrim yapma potansiyeline sahiptir. Blokzincir teknolojik altyapısı sayesinde kripto piyasasıyla ilgili oluşan büyük verinin yönetilmesi hem denetim hem de ülkelerin kalkınması açısından tutarlı ve etkili para politikalarının da uygulanması hususunda oldukça önemlidir. Endüstri 4.0 döneminde gerçekleşmesi beklenen hedef, üretim, yatırım ve karar alma süreçlerinde akıllı makinelerin kullanımı üzerinedir. Ancak büyük verinin getirmiş olduğu işlem zorlukları nedeniyle adapte edilmesi oldukça zordur. Geleceğin parçası olarak görülen ancak her yönüyle araştırılmaya muhtaç bu alanda yeni yaklaşımların önerilmesinin ilgili alanyazına hem teorik hem de deneysel olarak katkı sağlayacağı düşünülmektedir. Bu doğrultuda tezin bölümleri alanyazında görülen boşlukların doldurulması üzerine kurgulanarak ampirik çalışmalarla desteklenmiştir.

Tezin birinci bölümünde amaç, kripto para piyasasındaki işlem hacmi en yüksek kripto paraların davranışsal iktisat bağlamında ele alınmasıdır. Bu doğrultuda, Bitcoin, Ethereum, Litecoin ve Ripple için finansal piyasalarla olan ilişkinin belirlenmeye çalışıldığı alanyazın incelemesi sunulmuştur. Çalışmalar hakkında yapılan genel değerlendirme sonucunda yatırımcı davranışının ilgili piyasada ele alınması gereken zorunlu bir etken olduğu görülmüştür. Ancak görüşün desteklenmesi adına doğrusal olmayan değişimlerin modellenmesinde kullanılan Markov rejim değişim modelleri ile ampirik analiz gerçekleştirilmiştir. Alanyazına bakıldığında ilişkilerin genellikle doğrusal olarak ele alındığı çalışmaların yoğunlukta olduğu görülmüştür. Oysa performans başarısı en iyi modellerin belirlenmesi sonucu kripto para piyasasındaki ilişki dinamiklerinin doğrusal olmayan formda ele alınması gerekliliği ortaya konulmuş olup, ilgili alanyazın kapsamında özgün değer taşıdığı düşünülmektedir. Belirlenen bulgular doğrultusunda, kripto para fiyatlarında yatırımcı ilgisinin etkili olduğu görülmüştür. Dolayısıyla tezin ilk bölümünde yatırımcı tanınmışlık hipotezini destekler nitelikte sonuçlar elde edilmiştir.

Tezin ikinci bölümünde amaç, kripto para piyasası ve büyük verinin birlikte oluşturduğu büyük kripto ekonomisinin dinamiklerinin hangi tekniklerle ele alınabileceğinin incelenmesidir. Tezin

ilk bölümünde yatırımcı ilgisinin belirlenmesi üzerine “*bu kadar teknolojik evrim ve yenilikten sonra homo-sapiensler olarak mutlu muyuz?*” sorusundan hareketle, bu yeni teknolojinin yatırımcı açısından önemli dinamiklerinin belirlenmesi hedeflenmiştir. Bu doğrultuda, sürekli gelişim içerisinde olan teknolojinin kabul edilmesi ve benimsenmesiyle ilgili Teknoloji Kabul Modeli aracılığıyla ampirik bir çalışma gerçekleştirilmiştir. Bölümde kripto para teknolojisinin yatırımcılar açısından araştırıldığı alanyazına yer verilmiş olup, yatırımcıların davranış niyetlerinin herhangi bir olay ya da fikre yönelik olumlu veya olumsuz değerlendirmeleri sonucu davranışta bulduklarından hareketle kripto para teknolojisinin bireysel yatırımcıların yatırım davranışları üzerindeki etkisi incelenmiştir. Bunun için Teknoloji Kabul Modeli davranışsal iktisat bağlamında adapte edilerek yeni bir model geliştirilmiş ve yüksek açıklama kapasitesi ispatlanmıştır. Ampirik analiz sonucunda, performans beklentisinin yatırımcı davranışında etkili olduğu ve kripto para piyasasında olumsuz haberler olması durumunda gerçekleşen yatırım davranışının olumlu haberlere göre daha fazla etkili olduğu belirlenmiştir. Dolayısıyla piyasa hareketlerinde yatırımcı davranışının etkisi tezin iki bölümünde de elde edilen bulgularla desteklenmiştir. Yatırımcıların bu yeni teknolojinin performansına odaklanması aynı zamanda bu piyasanın dinamiklerinin daha geniş çapta ele alınması gerekliliğini ortaya koymuştur. Blokzincir teknolojisiyle büyük verinin birleşimi sonucunda oluşan potansiyel, kripto para piyasasını da güçlendirmektedir. Bu nedenle finansal dijitalleşme, kripto para piyasaları ve büyük veri arasında meydana gelen bu yakınsamanın karşılıklı olarak gerçekleştiğini söylemek mümkündür. Zaman içerisinde araştırmacılara daha büyük veri seti sunacak olan kripto para ekosistemi üzerinde yapılacak olan çalışmalar kuşkusuz daha ayrıntılı ve açıklayıcı hale getirecektir. Ancak kripto para teknolojisinden doğan büyük verinin analiz edilmesinde henüz ele alınmayan ve kesinlikle keşfedilmeye değer potansiyeller için gelecek araştırmaların yapılması gerekmektedir.

Tezin üçüncü bölümünde amaç, tezde kullanılan teorik ve ekonometrik altyapının entegre edilebilirliğinin gösterilmesidir. Teorik kapsamda, birinci ve ikinci bölümde ele alınması nedeniyle Gündem Belirleme Kuramı ve Yatırımcı Tanınmışlık Hipotezi üzerinde durulmuştur. Teorik Çerçeve kapsamında ise medya ile kamu gündemi arasındaki yüksek korelasyonun belirlenmesinin ardından nedensel bağlantılar ve zaman dizisinin gösterilmesi gerekliliği doğmuştur. Dolayısıyla kamu gündemi ile medya içerikleri arasındaki bu yüksek korelasyonlu ilişkide belirleyicilerin hangileri olduğu ve yönünün ne olduğu gündem belirleme kuramı bağlamında temel önerme niteliği taşımaktadır. Bu doğrultuda tez çalışmasında, bilgi toplumlarına dijital para birimleri hakkında yeni olarak nitelendirilebilecek bu finansal sistemle olan ilişkinin belirlenmesi gündem belirleme kuramı bağlamında ele alınmıştır. Ancak kripto para piyasasının Gündem Belirleme Kuramı bağlamında incelenebilmesi için sosyal medya platformu olan Twitter’den elde edilen içeriklerin büyük veri olması nedeniyle işlenmesi zorluğu meydana gelmektedir. İkinci bölümde yer verilen büyük veri analitiği tekniklerinin kripto piyasasının

göstergelerine uygulanabilirliği detaylandırılarak kullanılan yöntemlere yer verilmiştir. Kripto para piyasasının pay piyasalarıyla olan etkileşiminin araştırıldığı alanyazına bakıldığında sıklıkla makine öğrenmesi algoritmalarının kullanıldığı belirlenmiştir. Ancak yatırımcı davranışının anlaşılması için ulaşılabilir veri kaynaklarından elde edilen yapılandırılmamış verinin çok yüksek frekanslara sahip olduğu bilinmektedir. Oysa pay piyasalarıyla ilgili veriler ise daha düşük ve düzenli frekansa sahiptir. Bu noktada araştırmacıların sıklıkla her iki gösterge için de toplulaştırma işlemi yaparak geleneksel metotları kullandıkları görülmektedir. Ancak yeni teknolojiye sahip bu piyasanın dinamiklerinin anlaşılmasında verinin yaratma sürecinin göz ardı edilmesi sonucu yaşanacak olan bilgi kaybının önüne geçilmesi gerekmektedir. Nitekim Doğrusal Olmayan Nedensellik Analizi sonucunda alanyazında gerçekleştirilen çalışmalardan farklı sonuçlar elde edildiği belirlenmiştir. Buradan hareketle, verilerin frekansını değiştirmeden modellenmesine imkân tanıyan doğrusal olmayan MIDAS regresyon ve makine öğrenmesi regresyon algoritmalarına teorik olarak yer verilmiştir.

Tezin dördüncü bölümü, tezin temel amacı olan karma frekanslı zaman serilerinin modellenmesinde büyük veri deneyinin gerçekleştirilmesidir. Kripto para piyasasında yatırımcı davranışının etkisinin incelenmesi için elde edilen temel verilerle Veri Zarflama Analizi ve Transfer Entropi'ye dayalı Doğrusal Olmayan Granger Nedensellik Analizi gerçekleştirilmiştir. Burada hedef; yalnızca işletme alanında etkinlik değerlendirmesi için kullanılan bir yöntemin kripto para piyasasına entegre edilmesidir. Analiz sonuçlarına bakıldığında incelenen kripto paraların piyasada yatırımcı ilgisiyle etkin oldukları belirlenmiştir. Ancak yatırımcı ilgisiyle fiyatlar arasındaki nedensel ilişkilerin ortaya çıkartılması, sonrasında kurulacak ve önerilecek olan model denemelerinin temelini oluşturmaktadır. Buradan hareketle ilişkilerin incelenmesinde Transfer Entropi'ye dayalı Doğrusal Olmayan Granger Nedensellik analizi gerçekleştirilmiştir. Çalışmanın birinci bölümündeki ampirik analizde elde edilen bulgularla örtüşmenin belirlenmesi sonucu, kripto para piyasası dinamiklerinin doğrusal olmayan formda ele alınması gerekliliği bir kez daha ispatlanmıştır. Aynı zamanda doğrusal olmayan yapı, paralel yapı özelliği gösteren MS-VAR modelleri aracılığıyla da desteklenmiştir. Transfer entropisi, değişkenler arasındaki ilişkileri istatistiksel bir model kullanarak modellemeyip, bunun yerine bilgi teorisine dayandırdığından Granger nedenselliğin doğrusal olmayan bir alternatifi olarak kabul edilmektedir. Doğrusal olmayışın doğasının tam olarak bilinmemesi durumunda doğrusal modeller, doğrusal olmayan modellere göre tutarlılık ve hesaplama kolaylığı sağlamaktadır. Ancak değişkenlerin yaratma süreçlerinin ve ilişkilerin dinamiklerinin belirlenmesi ampirik sonuçları farklılaştırabileceğinden ciddi önem taşımaktadır. Bu nedenle, Hmamouche (2020) tarafından geliştirilen doğrusal olmayan bir nedensellik araştırmasında entropi kullanımının etkin sonuçlar verdiği elde edilen bulgularla desteklenmiştir. Bu test, zaman serileri arasındaki doğrusal olmayan ilişkilerin incelenmesini ve ileri beslemeli sinir ağlarını kullanan Granger nedensellik testinin doğrusal

olmayan bir uzantısını ortaya koymaktadır. Kripto para piyasasındaki ilişkilerin ele alınmasında benzeri çalışmaya rastlanmadığından ilgili alanyazına katkı sağlayacağı düşünülmektedir.

Yatırımcı davranışının kripto para piyasası üzerindeki etkisinin çeşitli ampirik analizlerle incelenmesi ve belirlenmesine dayanarak, Twitter üzerinden ilgili kripto paralarla ilgili bireylerin paylaşımlar tezin deneysel kısmında yer alan büyük veriyi temsilen kullanılmıştır. Ancak yapılandırılmamış bu büyük veriden anlamlı sonuçların elde edilmesi gerektiğinden duygu analizi gerçekleştirilmiştir. Kripto para ile ilgili görüşlerini bildiren bireylere ait duygu skorlarının elde edilmesi sonucu fiyatlarla olan ilişkisine bakılması mümkün kılınmıştır. Büyük veri modelleme tekniklerinde sıklıkla kullanılan makine öğrenmesi regresyon algoritmalarıyla fiyatlar, pay piyasası göstergeleri ve duygu skorları arasındaki ilişkiler her bir kripto para için incelenmiştir. İncelenen dönem kapsamında fiyat tahmininde yoğunlukla gradyan arttırma tekniklerinden olan XGBoost algoritmasının oldukça yüksek tahmin performansı gösterdiği belirlenmiştir. Ancak bu algoritmalarda değişkenlerin farklı frekanslarda ele alınması olanaklı olmadığından kaybedilen bilginin varlığının belirlenmesi adına MIDAS regresyon tahminleri gerçekleştirilmiştir. Tahmin edilen modeller performansına göre karşılaştırılarak her kripto para için uygun model belirlenmiştir. Model sonuçları genel olarak değerlendirildiğinde, Etkin Piyasa Hipotezi'nin kripto para piyasasında desteklenmediği, Yatırımcı Tanınmışlık Hipotezi'nin geçerli olduğu sonucuna ulaşılmıştır. Alanyazında belirlenmeyen ilişkilerin sonuçlarla desteklenmesinden hareketle, tahmin performansının daha da iyileştirilmesi için geleneksel teknikler ile makine öğrenmesi algoritmasının birleştirilerek hibrit model önerisinde bulunulması hedeflenmiştir. Bu model, Wang ve Kang (2021) tarafından haftalık buhar kömür fiyatlarının tahmin edilmesinde XGBoost ve MIDAS regresyonun birleştirildiği hibrit modelden yola çıkılarak oluşturulmuştur. Alanyazında farklı deneme örnekleri olmakla birlikte, kripto para piyasası alanında tek örnek niteliği taşıdığından tezin özgün değerini yansıtmaktadır. Tahmin edilen modellerde dönem içi performans başarılarının incelenmesi sonucu Beta Polinomlu MIDAS modelinin hibrit modelden daha başarısız tahmin gerçekleştirdiği görülmüştür. Esnek ve doğrusal olmayan ilişkilerin modellenmesinde başarılı olan XGBoost algoritmasının MIDAS modelle birleştirilmesi sonucu tahmin performansı iyileşmektedir. Aynı zamanda GARCH-MIDAS ve MS-GARCH-MIDAS modellerinin önerilen hibrit model ile eşit tahmin tutarlılığına sahip olduğu belirlenmiştir. Bu durum incelenen dönemdeki oynaklık hareketlerinden kaynaklanabileceği gibi aynı zamanda karma frekanslı zaman serilerinin modellenmesindeki üstünlüğünü de göstermektedir. Bundan sonraki çalışmalarda araştırmacılara, GARCH-MIDAS ve MS-GARCH-MIDAS model tahminlerinin yeni bilgilerde daha hassas sonuçlar verebilen Yapay Sinir Ağları gibi algoritmalarla gerçekleştirmesi alandaki gelişimin sağlanması adına önerilmektedir. Buradan hareketle, MIDAS regresyon yönteminin farklı makine öğrenmesi algoritmalarıyla kombinasyonunun gerçekleştirilerek denenmesinin kripto para piyasası dinamiklerinin

belirlenmesinde doğru bir yaklaşım olacağı ve belirsizlik bağlamında daha istikrarlı tahmin performanslarının karşılaştırılmasını mümkün kılacaktır.

Karma frekanslı zaman serilerinin büyük veri örneğiyle modellenmesi için gerçekleştirilen tez çalışması kapsamında hem teorik hem de deneysel katkı sağlanmıştır. Ekonometri alanında büyük veri kullanımının geliştirilmesi için büyük veri kavramının sürekli gelişim içerisinde olan kripto piyasası özelinde ele alınmasıyla büyük veri kavramının ortaya konulmasında araştırmacılar için yeni bakış açılarının sağlanması hedeflenmiştir. Ancak önerilen hibrit model, alanında tek örnek olması nedeniyle sonuçların genellenebilirliğini kısıtlandırmaktadır. Ancak ekonometrik tekniklerin özellikle zaman serisi özelinde dinamikleri belirlemedeki başarısının makine öğrenmesi algoritmalarına göre üstün olduğu durumunda belirlenmesi nedeniyle her iki tekniğin araştırma alanına uygun olarak birleştirilmesi gerekli olduğu kadar hassas bir noktadır. Bu nedenle büyük veri analitiğinde disiplinlerarası çalışmaların artırılması gerektiği düşünülmektedir. Aynı zamanda finansal piyasalarda fiyat hareketlerinin işlem gördükleri platformların yapısı gereği değişik faktörlerden etkilendiği ispatlanmıştır. Bu faktörlerin ne olduğunun belirlenmesi ve fiyat hareketlerini etkileme güçlerinin belirlenmesi hem yatırımcılar özelinde hem de ekonomik politika önerilerinde daha sağlıklı çıkarımların yapılmasını sağlayacaktır. Öngörü performansı yüksek metotların geliştirilmesi ve uygulanabilirliğinin gösterilmesinin karar alma süreçlerinde daha hızlı ve çözüm odaklı politika geliştirmekte yardımcı olacağı düşünülmektedir.

KAYNAKÇA

Sürekli Yayınlar ve Diğer Yayınlar

- Abar, H. (2020), “XGBoost ve MARS Yöntemleriyle Altın Fiyatlarının Kestirimi”, *EKEV Akademi Dergisi*, 24(83): 427-446.
- Abraham, J., Higdon, D., Nelson, J., Ibarra, J. (2018), “Cryptocurrency Price Prediction Using Tweet Volumes and Sentiment Analysis”, *SMU Data Science Review*, 1/3: 1-22.
- Ağ, A. (2019), “BIST’te İşlem Gören Sigorta Şirketlerinin Veri Zarflama Analizi Yöntemi ile Finansal Performanslarının Analizi”, *Business and Management Studies An International Journal*, 7/5: 2656-2668.
- Ağan, B., Aydın, Ü. (2018), “Kripto Para Birimlerinin Küresel Etkileri: Asimetrik Nedensellik Analizi”, *Finance Symposium*, Mersin.
- Akgül, I., Koç, S., Koç Özdemir, S., (2007), “Cari İşlemler Dengesi Rejim Değişim Modelleri ile Modellenebilir mi?”, 8. *Türkiye Ekonometri ve İstatistik Kongresi*, İnönü Üniversitesi, Malatya.
- Akgül, I., Koç, S., Özdemir, S. (2007), “Cari İşlemler Dengesi Rejim Değişim Modelleri ile Modellenebilir mi?”, 8. *Türkiye Ekonometri ve İstatistik Kongresi* (24-25 Mayıs 2007), Malatya: İnönü Üniversitesi.
- Akgün, B. E. (2016), *Investor Attention and IPO Performance*, Unpublished Master Thesis, Ankara, The Graduate School of Social Sciences of Middle East Technical University.
- Aktaş, H. (2001), “İşletme Performansının Ölçülmesinde Parametrik Olmayan Bir Yaklaşım: Veri Zarflama Analizi”, *Celal Bayar Üniversitesi İİBF Dergisi*, 7/1: 163-175.
- Al-Amri, R., Zakaria, N. H., Habbal, A., Hassan, S. (2019), “Cryptocurrency Adoption: Current Stage, Opportunities, and Open Challenges”, *International Journal of Advanced Computer Research*, 9: 293–307.
- Alana, G., Alberiko, L., Abakah, E. J. H., Rojo, M. F. R. (2020), “Cryptocurrencies and Stock Market Indices. Are They Related?”, *Research in International Business and Finance*, 51.
- Alicemani, L. P. (2018), “An Analysis on the Impact of Commodity Prices and Exchange Rates on the Price of Bitcoin”, *Asian Journal of Management*, 9/1: 427-431.
- Almon, S. (1965), “The Distributed Lag Between Capital Appropriations and Expenditures”, *Econometrica: Journal of the Econometric Society*, 33(1): 178-196.
- Al-Qawasmi, M. (2014), *Forecasting Palestinian Gross Domestic Product Using Mixed Data Sampling*. Birzeit: Birzeit Üniversitesi Sosyal Bilimler Enstitüsü.
- Altay, F. (2017), “21. Yüzyılda Para Kavramı Bitcoin-Kripto Para-I”, *Yeni İpek Yolu Konya Ticaret Odası Dergisi*, 39/357: 34- 39.
- Altunkaynak, A., Başakın, E.E. & Kartal, E. (2020), “Dalgacık K-en Yakın Komşuluk Yöntemi ile Hava Kirliliği Tahmini”, *Uludağ Üniversitesi Mühendislik Fakültesi Dergisi*, 25(3): 1547-1556.

- Alzahrani, S., Daim, T. U. (2019), "Evaluation of the Cryptocurrency Adoption Decision Using Hierarchical Decision Modeling (HDM)", *Proceedings of the 2019 Portland International Conference on Management of Engineering and Technology (PICMET)*, Portland: 1-7.
- Anand, A., Suganthi, L. (2017), "Forecasting of Electricity Demand by Hybrid ANN-PSO Models", *International Journal of Energy Optimization & Engineering*, 6(4): 66e83.
- Andersson, G., Wegdell, A. (2014), "Prospects of Bitcoin An Evaluation of Its Future", *Lund University School of Economics & Management*.
- Andreou, E., Ghysels, E., ve Kourtellos, A. (2010), "Regression Models with Mixed Sampling Frequencies", *Journal of Econometrics*, 158(2): 246-261.
- Andrianto, Y., Diputra, Y. (2017), "The Effect of Cryptocurrency on Investment Portfolio Effectiveness", *Journal of Finance and Accounting*, 5/6: 229-238.
- Ardia, D., Bluteau, K., Rüede, M. (2019), "Regime Changes in Bitcoin GARCH Volatility Dynamics", *Finance Research Letter*, 29, 266-271.
- Arias-Oliva M., Pelegrin-Borondo J., Matias-Clavero G. (2019), "Variables Influencing Cryptocurrency Use: A Technology Acceptance Model in Spain", *Frontiers in Psychology*, 10: 475. doi: 10.3389/fpsyg.2019.00475.
- Armesto, M. ve Engememann, K. (2010), "Forecasting with Mixed Frequencies", *Federal Reserve Bank of St.Louis Review*, 92(3): 521-536.
- Aslam, N., Rustam, F., Lee, E., Washington, P. B., Ashraf, I. (2022), "Sentiment Analysis and Emotion Detection on Cryptocurrency Related Tweets Using Ensemble LSTM-GRU Model", *IEEE Access*. doi: 10.1109/ACCESS.2022.3165621.
- Aslan, İ. (2019), Bitcoin ve BIST Oynaklığının Yayılması: Tek ve Çok Değişkenli GARCH Modelleri, Yayınlanmamış Yüksek Lisans Tezi, Sivas: Cumhuriyet Üniversitesi SBE.
- Aste, T. (2019), "Cryptocurrency Market Structure: Connecting Emotions and Economics", *Digital Finance*, 1: 5-21.
- Atabek, N. (1998), "Gündem Belirleme Yaklaşımı", *İstanbul Üniversitesi İletişim Fakültesi Dergisi*, 7: 155-174.
- Atik, M., Köse, Y., Yılmaz, B., Sağlam, F. (2015), "Kripto Para: Bitcoin ve Döviz Kurları Üzerine Etkileri", *Bartın Üniversitesi İ.İ.B.F. Dergisi*, 6/11: 247-261.
- Babu, B. V., Nagar, A., Deep, K., Pant, M., Bansal, J. C., Ray, K., Gupta, U. (2014), *Proceedings of the Second International Conference on Soft Computing for Problem Solving (SocProS 2012), December 28-30, 2012*, Springer.
- Baek, E., Brock, W. (1992), *A General Test for Nonlinear Granger Causality: Bivariate Model [Working Paper]*, Iowa State University and University of Wisconsin, Madison.
- Bahadır, O., Türkmençalıkoğlu, H. (2021), "Bilgi Kuramında Shannon Entropisi ve Uygulamaları", *Avrupa Bilim ve Teknoloji Dergisi*, 32, 491-497.
- Baker, M., Wurgler J. (2007), "Investor Sentiment in the Stock Market", *Journal of Economic Perspective*, 21/2: 129-151.

- Bank, M., Larch, M., Peter, G. (2011), “Google Search Volume and Its Influence on Liquidity and Returns of German Stocks”, *Financial Markets and Portfolio Management*, 253: 239–264.
- Barberis, N., Xiong, W. (2012), “Realization Utility”, *Journal of Financial Economics*, 104: 251-271.
- Baur, A. W., Buhler, J., Bick, M., Bonorden, C. S. (2015), “Cryptocurrencies As A Disruption? Empirical Findings on User Adoption and Future Potential of Bitcoin and Co”, *Conference on e-Business, EServices and E-Society*, Cham: 63-80.
- Baur, D. G., Dimpel, T., Kuck, K. (2018), “Bitcoin, Gold and The US Dollar – A Replication and Extension”, *Finance Research Letters*, 25: 103-110.
- Beck, J., Huang, R., Lindner, D., Guo, T. (2019), “Sensing Social Media Signals for Cryptocurrency News”, *Companion Proceeding of the 2019 World Wide Web Conference*, 1051-1054.
- Beer, F., Hervé, F., Zouaoui, M. (2012), “Is Big Brother Watching Us? Google, Investor Sentiment and the Stock Market”, *Economic Bulletin*, 33/1: 454-466.
- Benchlouch, G. (2020), “The Relationship of Online Discourse on the Values of Bitcoin and Ethereum”. doi: 10.31235/osf.io/jwmzt
- Bhadane, C., Dalal, H., Doshi, H. (2015), “Sentiment Analysis: Measuring Opinions”, *Procedia Computer Science*, 45: 808-814.
- Bhatia, M. P. S., Kumar, A. (2008), “Information Retrieval and Machine Learning: Supporting Technologies for Web Mining Research and Practice”, *Webology*, 5: 2.
- Bhattacharjee, S. (2016), “A Statistical Analysis of Bitcoin Transactions During 2012 to 2013 in Terms of Premier Currencies: Dollar, Euro and Rubles, Vidwat”, *The Indian Journal of Management*, 1/5: 8-16.
- Bhonde, R., Bhagwat, B., Ingulkar, S., Pande, A. (2015), “Sentiment Analysis Based on Dictionary Approach”, *International Journal of Emerging Engineering Research and Technology*, 3/11: 51–55.
- Bijl, L., Kringhaug, G., Molnar, P., Sandvik, E. (2016), “Google Searches and Stock Returns”, *International Review of Financial Analysis*, 45: 150-156.
- Bildirici, M., Bozoklu, Ü. (2010), *Beklentilerin Ekonomi Üzerine Etkileri: MS-VAR Yaklaşımı [Working Paper]. TUSİAD-Koç University Economic Research Forum.*
- Bilgiç, M. E. (2017), Google Trends Search Volume Index in Estimation of Istanbul Stock Market Index (BIST), Unpublished Master Thesis, İstanbul, İstanbul Bilgi University.
- Blanchette, I., Richards, A. (2010), “The Influence of Affect on Higher Level Cognition: A Review of Research on Interpretation, Judgement, Decision-Making and Reasoning”, *Cognition and Emotion*, 24/4: 561–595.
- Boiy, E., Hens, P., Deschacht, K., Moens, M. F., (2007), “Automatic Sentiment Analysis of On-Line Text”, *Proceedings Of The 11th International Conference On Electronic Publishing*, Vienna: 349–360.

- Bollen, J., Mao, H., Zeng, X. (2011), "Twitter Mood Predicts the Stock Market", *Journal of Computational Science*, 2: 1-8.
- Borup, D., Schütte, E.C.M. (2022), In Search of A Job: Forecasting Employment Growth Using Google Trends, *Journal of Business and Economic Statistics*, 40(1): 186–200.
- Boudad, N., Faizi, R., Rachid, O. H., Chiheb, R. (2017), "Sentiment Analysis in Arabic: A Review of The Literature", *Ain Shams Engineering Journal*, 9/4: 2479-2490.
- Bowlin, W. F. (1998), "Measuring Performance: An Introduction to Data Envelopment Analysis", *The Journal of The Cost Analysis*.
- Boyd, D., Crawford, K. (2011), "Six Provocations for Big Data", *A Decade in Internet Time: Symposium on the Dynamics of the Internet and Society*, University of Oxford, 1-17.
- Breiman, L. (2001), "Random Forests." *Machine Learning*, 45(1): 5-32.
- Brock, W.A., Dechert, D., Lebaron, B., & Scheinkman, J., (1996), "A Test for Independence Based on A Correlation Dimension", *Econometric Review*, 15: 197-235.
- Budak, H. (2011), "Veri Zarflama Analizi ve Türk Bankacılık Sektöründe Uygulaması", *Marmara Üniversitesi Fen Bilimleri Dergisi*, 23/3: 95-110.
- Burnie, A. (2018), "Exploring The Interconnectedness of Cryptocurrencies Using Correlation Networks", *Cryptocurrency Reserach Conference*, Cambridge: 1-29.
- Büyükyılmaz, A., (2015), "Markov Rejim Değişimli Vektör Otoregresif Modeller ve Doğrusal Olmayan Nedensellik Analizi: OECD Ülkelerinde Yenilenebilir Enerji Tüketimi, CO2 Emisyonu ve Ekonomik Büyüme Arasındaki İlişki İçin Bir Uygulama", Akdeniz Üniversitesi Sosyal Bilimler Enstitüsü, Doktora Tezi.
- Caporale, G. M., Zekokh, T. (2019), "Modelling Volatility of Cryptocurrencies Using Markov-Switching GARCH Models", *Research in International Business and Finance*, 48: 143-155
- Chandra, S., Ray, S., Goswami, R. T. (2017, 05-07 Ocak), Big Data Security: Survey on Frameworks and Algorithms. *2017 IEEE 7th International Advance Computing Conference (IACC)*, Hyderabad: 48-54.
- Chaovalit, P., Zhou, L. (2005), "Movie Review Mining: A Comparison Between Supervised and Unsupervised Classification Approaches", *Proceedings of The 38th Hawaii International Conference on System Sciences*, Hawaii.
- Charnes, A., Cooper, W. W., Rhodes, E. (1978), "Measuring the Efficiency of Decision Making Units", *European Journal of Operational Research*, 2: 429-444.
- Cheng, S., Lam, T. (2008), "The Role of the Customer-Seller Relationship of the Intention of the Customer to Complain: A Study of Chinese Restaurateurs", *International Journal of Hospitality and Tourism Research*, 27: 552-562.
- Chkili, W. (2021), "Modeling Bitcoin Price Volatility: Long Memory vs Markov Switching", *Eurasian Econ Rev*, 11: 433–448.

- Chohan, U. (2017). Assessing the Differences in Bitcoin & Other Cryptocurrency Legality Across National Jurisdictions. <https://doi.org/10.2139/ssrn.3042248> (Accessed Date: 01.05.2021).
- Chow, Y. Y., Kalid, K. S., Sugathan, S. K., Arshadbinti, N. I. (2019), "What Determines the Acceptance of Cryptocurrency in Malaysia? An Analysis Based on UTAUT2", *Research-in-Progress. TwentyThird Pacific Asia Conference on Information Systems*.
- Chuen, D. L. K., Guo, L., Wang, Y. (2018), "Cryptocurrency: A New Investment Opportunity?", *The Journal of Alternative Investments*, 20/3: 16-40.
- Claian, P., Rajcaniova, M., Kancs, D. (2016), "The Economics of Bitcoin Price Formation", *Applied Economics*, 48/19: 1799-1815.
- Clements, M.P., Galvão, A.B. (2008), "Macroeconomic Forecasting with Mixed Frequency Data: Forecasting Output Growth in the United States", *Journal of Business & Economic Statistics*, 26(4): 546-554.
- Clements, M.P., Krolzig, H.M., (1997), "A Comparison of the Forecast Performance of Markov-switching and Threshold Autoregressive Models of US GNP." *Warwick Economic Research Papers*, 489: 1–29.
- Colianni, S., Rosales, S., Signorotti, M. (2015), "Algorithmic Trading of Cryptocurrency Based on Twitter Sentiment Analysis", *CS229 Project*, 1–5.
- Coron, J. S. (2006), "What is Cryptography?", *IEEE Security & Privacy*, 4/1: 70-73.
- Cox, M., Ellsworth, D. (1997), Application-Controlled Demand Paging for Out-of-core Visualization. *Proceedings of the 8th Conference on Visualization '97*, USA: 235-244.
- Crosby. M., Pattanayak, P., Verma, S., Kalyanaraman, V. (2016), "BlockChain Technology: Beyond Bitcoin", *Applied Innovation Review*, 2: 6-19.
- Cyganek, B., Graña, M., Krawczyk, B., Kasprzak, A., Porwik, P., Walkowiak, K., Woźniak, M. (2016), "A Survey of Big Data Issues in Electronic Health Record Analysis", *Applied Artificial Intelligence*, 30/6: 497-520.
- Çinko, M. (2006), "İMKB 100 Endeksinin Doğrusallık Testi", *İstanbul Üniversitesi İktisat Fakültesi Ekonometri ve İstatistik Dergisi*, 3: 23-31.
- Çoban, F., Demir, L. (2021), "Yapay Sinir Ağları ve Destek Vektör Regresyonu ile Talep Tahmini: Gıda İşletmesinde Bir Uygulama", *DEÜ FMD*, 23(67): 327-338.
- Çütüçü, İ., Kılıç, Y. (2018), "Bitcoin Fiyatları ile Dolar Kuru Arasındaki İlişki: Yapısal Kırılmalı Zaman Serisi Analizi", *Yönetim ve Ekonomi Araştırmaları Dergisi*, 16/4: 349-366.
- Da. Z., Engelberg, J., Gao, P. (2011), "In Search of Attention", *The Journal of Finance*, 66: 1461-99.
- Damstra, A., Boukes, M. (2018), "The Economy, The News, and The Public: A Longitudinal Study of the Impact of Economic News on Economic Evaluations and Expectations", *Communication Research*, 1-25. doi: 10.1177/0093650217750971.
- Dauda, S. Y., Lee, J. (2015), "Technology Adoption: A Conjoint Analysis of Consumers' Preference on Future Online Banking Services", *Information Systems*, 53: 1–15.

- Davenport, T., Barth, P., Bean, R. (2012), “How “Big Data” is Different”, *MIT Sloan Management Review*, 54/1: 22–24.
- Davis, A. (2006), “Media Effects and the Question of the Rational Audience: Lessons From the Financial Market”, *Media, Culture & Society*, 28: 603-625. doi: 10.1177/0163443706065035.
- Davis, F. D., Bagozzi, R. P., Warshaw, P. R. (1989), “User Acceptance of Computer Technology: A Comparison of Two Theoretical Models”, *Management Science*, 35/8: 982-1003.
- De Bondt, W. F. M., Thaler, R. H. (1995), “Financial Decision-Making in Markets and Firms: A Behavioral Perspective”, *Handbooks in Operations Research and Management Science*, Elsevier: 9/1: 385-410.
- Demirel, A., Hazar, A. (2021), “Kripto Para Değerlerine Dayanılarak BİST 100 Endeks Hareketi Tahmininde Destek Vektör Makineleri Uygulaması”, *Başkent Üniversitesi Ticari Bilimler Fakültesi Dergisi*, 5/1: 27-35.
- Deniz, E. A. (2020), Finansal Piyasalarda Kripto Para Uygulamaları: Kripto Para Fiyatlarını Etkileyen Faktörler, Yayınlanmamış Yüksek Lisans Tezi, İstanbul: Işık Üniversitesi SBE.
- Depren, Ö. (2008), Veri Zarflama Analizi ve Bir Uygulama, Yüksek Lisans Tezi, İstanbul, Yıldız Teknik Üniversitesi.
- DeVries, P. D. (2016), “An Analysis of Cryptocurrency, Bitcoin, and The Future”, *International Journal of Business Management and Commerce*, 1/2: 1-10.
- Diebold, F. X., Shin, M. (2019), “Machine Learning for Regularized Survey Forecast Combination: Partially-Egalitarian Lasso and Its Derivatives”, *International Journal of Forecasting*, 35(4): 1679–1691.
- Diebold, F.X., Mariano, R.S. (1995), “Comparing Predictive Accuracy”, *Journal of Business and Economic Statistics*, 13.
- Dijk, D., Franses, P. H. (1999), “Modelling Multiple Regimes in the Business Cycles”, *Macroeconomic Dynamics*, 3/3: 311-340.
- Diks, C., Panchenko V. (2006), “A New Statistic and Practical Guidelines for Nonparametric Granger Causality Testing”, *Journal of Economic Dynamics and Control*, 30: 1647-1669.
- Diniz, E. H., Cernev, A. K., Nascimento, E. (2016), “Mobile Social Money: An Exploratory Study of the Views of Managers of Community Banks”, *Revista de Administração*, 51: 299–309.
- Dirican, C., Canöz, İ. (2017), “Bitcoin Fiyatları ile Dünyadaki Başlıca Borsa Endeksleri Arasındaki Eşbütünlük İlişkisi: ARDL Modeli Yaklaşımı ile Analiz”, *Journal of Economics, Finance and Accounting*, 4/4: 377-392.
- Dizkırıcı, A. S., Gökgöz, A. (2018), “Kripto Para Birimleri ve Türkiye’de Bitcoin Muhasebesi”, *Journal of Accounting, Finance and Auditing Studies*, 4/2: 92-105.
- Dolgun, M. Ö., Güzel-Özdemir, T., Oğuz, D. (2009), “Veri Madenciliği’nde Yapısal Olmayan Verinin Analizi: Metin ve Web Madenciliği”, *İstatistikçiler Dergisi*, 2: 48-58.

- Douma, S. (2016), Bitcoin: The Pros and Cons of Regulation, Master Thesis.
- Drew, G., Anthony G., Fitzgerald, P. J., Livingston, J. A. (1950), "Outlook For Stock Market", *Financial Analysts Journal*, 6: 49–54.
- Droumagnet, M. (2012), "Markov-Switching Vector Autoregressive Models : Monte Carlo Experiment, Impulse Response Analysis, and Granger-Causal Analysis", European University Institute Department of Economics. <https://doi.org/10.2870/63610>
- Dulau, T. M., Dulau M. (2019), "Cryptocurrency – Sentiment Analysis in Social Media", *Acta Marisiensis Seria Technologica*, 16/2, 1-6.
- Dyson, R. G., Allen, R., Camanho, A. S., Podinovski, V. V., Sarrico, C. S., Shale, E. A. (2001), "Pitfalls and Protocols in DEA", *European Journal of Operational Research*, 132/2: 245-259.
- Dzielinski, M. (2012), "Measuring Economic Uncertainty and Its Impact on the Stock Market", *Finance Research Letters*, 93: 167–175.
- Ehrmann, M., Ellison, M., Valla, N. (2003), "Regime-dependent Impulse Response Functions in a Markov -Switching Vector Autoregression Model", *Economics Letters*, 78: 295–299.
- Eroğlu, E., Atasoy, M. C. (2006), "Veri Zarflama Analizi ile Etkinlik Ölçümü ve Etkin Karar Birimlerinin Duyarlılık Analizi", *İstanbul Üniversitesi İşletme Fakültesi Dergisi*, 35/2: 91–106.
- Ertuğrul, İ., Işık, A. T. (2008), "İşletmelerin VZA ile Mali Tablolarına Dayalı Etkinlik Ölçümü: Metal Ana Sanayiinde Bir Uygulama", *Afyon Kocatepe Üniversitesi İ.İ.B.F. Dergisi*, 10/1.
- Etzioni, O. (1996), "The World-Wide Web: Quagmire or Gold Mine?", *Communications of the ACM*, 39/11: 65-68.
- Faccia, A., Alnaqbi, M. Y., Lootah, S. A. (2019). "Integrated Cloud Financial Accounting Cycle: How Artificial Intelligence, Blockchain, and XBRL Will Change the Accounting, Fiscal and Auditing Practices", *3rd International Conference on Cloud and Big Data Computing*, 31-37.
- Fan, S., Lau, R. Y., Zhao, J. L. (2015), "Demystifying Big Data Analytics for Business Intelligence Through The Lens of Marketing Mix", *Big Data Research*, 2/1: 28-32.
- Fang, B., Zhang, P. (2016), "Big Data in Finance", *Big Data Concepts, Theories, and Applications*, 391–412. doi:10.1007/978-3-319-27763-9_11
- Farrell, M.J. (1957), "The Measurement of Productive Efficiency", *Journal of The Royal Statistical Society*, 120(3): 253-290.
- Fisher, D., Deline, R., Czerwinski, M., Drucker, S. (2012), "Interactions with Big Data Analytics", *Interactions*, 19/3: 50-59.
- Folkinshteyn, D., Lennon, M. (2016), "Braving Bitcoin: A Technology Acceptance Model (TAM) Analysis", *Journal of Information Technology Case and Application Research*, 18: 220–249.

- Fornell, C., Larcker, D. F. (1981), "Evaluating Structural Equation Models with Unobservable Variables and Measurement Error", *Journal of Marketing Research*, 18/1: 39-50.
- Forsberg, L., Ghysels, E. (2007), "Why Do Absolute Returns Predict Volatility So Well?", *Journal of Financial Econometrics*, 5: 31-67.
- Frazzini A. (2006), "The Disposition Effect and Underreaction to New", *The Journal of Finance*, 11/4: 22-30.
- Gahi, Y., Guennoun, M., Mouftah, H. T. (2016), "Big Data Analytics: Security and Privacy Challenges", *2016 IEEE Symposium on Computers and Communication (ISCC)*, Messina: 952-957.
- Gandomi, A., Haider, M. (2015). "Beyond the Hype: Big Data Concepts, Methods, and Analytics", *International Journal of Information Management*, 35/2: 137-144.
- Gantz, J., Reinsel, D. (2011), "Extracting Value from Chaos", *IDC iView*, 1-12.
- Gefang, D. (2014), Bayesian Doubly Adaptive Elastic-Net Lasso for VAR Shrinkage, *International Journal of Forecasting*, 30(1): 1–11.
- Ghysels, E. ve Kourtellos, A. (2010), "Forecasting with Mixed-Frequency Data", *Oxford Journal of Economic Forecasting*, 158(1): 12.
- Ghysels, E., Arthur, S. ve Valkanov, R. (2004), *The Cross Section of Firm Stock Returns and Economic Announcements: A Bird's Eye View*. UNC and UCSD Working Paper.
- Ghysels, E., Santa-Clara, P. ve Valkanov, R. (2004), "There is a Risk-Return Tradeoff After All", *Journal of Financial Economics*, 76(1): 509-548.
- Ghysels, E., Santa-Clara, P., Valkanov, R. (2004), "The MIDAS Touch: Mixed Data Sampling Regression Models".
- Ghysels, E., Sinko, A., & Valkanov, R. (2007), "MIDAS Regressions: Further Results and New Directions", *Econometric Reviews*, 26(1): 58. doi:10.1080/07474930600972467
- Giacomini, R., & White, H. (2006), "Tests of Conditional Predictive Ability", *Econometrica*, 74(6): 1545-1578.
- Go, A., Huang, L., Bhayani, R. (2009), "Twitter Sentiment Analysis", (Final Project Report CS224N).
- Goes, P. B. (2014), "Big Data and IS Research", *MIS Quarterly*, 38/3: 3-8.
- Golder, S., O'Connor, K., Hennessy, S., Gross, R., Gonzalez-Hernandez, G. (2020), "Assessment of Beliefs and Attitudes about Statins Posted on Twitter: A Qualitative Study", *JAMA Network Open*, 3/6.
- Golov, N., Rönnbäck, L. (2017), "Big Data Normalization for Massively Parallel Processing Databases", *Computer Standards & Interfaces*, 54/2: 86-93.
- Grable, J., Lytton, R. H. (1999), "Financial Risk Tolerance Revisited: The Development of a Risk Assessment Instrument", *Financial Services Review*, 8: 163–181.
- Grewal-Carr V., Marshall, S. (2016), "Blockchain Enigma, Paradox, Opportunity", *Deloitte*.

- Gunawan, F. E., Novendra, R. (2017), "An Analysis of Bitcoin Acceptance in Indonesia", *ComTech: Computer, Mathematics and Engineering Applications*, 8/4: 241-247.
- Gundecha, P., Liu, H. (2014), "Mining Social Media: A Brief Introduction", *New Directions in Informatics, Optimization, Logistics, and Production*, 1-17.
- Gupta, S., Gupta, S., Mathew, M., Sama, H. R. (2020), "Prioritizing Intentions Behind Investment in Cryptocurrency: A Fuzzy Analytical Framework", *Journal of Economic Studies*. doi: 10.1108/JES-06-2020-0285
- Güleç, Ö. F., Çevik, E., Bahadır, N. (2018), "Bitcoin ile Finansal Göstergeler Arasındaki İlişkinin İncelenmesi", *Kırklareli Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 7/2: 18-37.
- Gülle, M. T. (2013), "Büyük Veri ya da İçgörü", *Türk Kütüphaneciliği*. 27/4: 581-582.
- Ha, S. H., Park, S. C. (1998), "Application of Data Mining Tools to Hotel Data Mart on The Intranet for Database Marketing", *Expert Systems with Applications*, 15/1: 1-31.
- Hamilton, J.D., (1989), "A New Approach To The Economic Analysis Of Nonstationary Time Series." *Econometrica*, <https://doi.org/10.2307/1912559>
- Hansen, P.R., Zhuo, H. (2016), "Exponential GARCH Modeling with Realized Measures of Volatility", *Journal of Business & Economic Statistics*, 34: 269–87.
- Hasan, A., Moin, S., Karim, A., Shamshirband, S. (2018), "Machine Learning-Based Sentiment Analysis for Twitter Accounts", *Mathematical and Computational Applications*, 23/1: 11
- Hassani, H., Huang, X., Silva, E. (2018), "Big-Crypto: Big Data, Blockchain and Cryptocurrency", *Big Data and Cognitive Computing*, 2/4: 34.
- Hiemstra C., Jones J. D. (1994), "Testing for Linear and Nonlinear Granger Causality in the Stock Price-Volume Relation", *The Journal of Finance*, 49/5: 1639-1664
- Hoy, B. (2014), "Big Data: An Introduction for Librarians", *Medical Reference Services Quarterly*, 33/3: 320 – 326.
- Hughes, A., Yaisawarng, S. (2004), "Sensitivity and Dimensionality Tests of DEA Efficiency Scores", *European Journal of Operational Research*, 154: 410-422.
- Huynh, T. L. D., Nasir, M. A., Vo, X. V., Nguyen, T. T. (2020), "Small Things Matter Most: The Spillover Effects in The Cryptocurrency Market and Gold as a Silver Bullet", *North American Journal of Economics and Finance*, 54: 1-12.
- Hyndman, R.J., Koehler, A.B. (2006). Another Look at Measures of Forecast Accuracy, *International Journal of Forecasting*, 22(4): 679-688.
- İçellioglu, C. Ş., Öztürk, M. B. (2018), "Bitcoin ile Seçili Döviz Kurları Arasındaki İlişkinin Araştırılması: 2013-2017 Dönemi İçin Johansen Testi ve Granger Nedensellik Testi", *Maliye ve Finans Yazıları*, 109: 51-70.
- Jain, A., Tripathi, S., Dwivedi, H. D., Saxena, P. (2018), "Forecasting Price of Cryptocurrencies Using Tweets Sentiment Analysis", *Proceedings of 2018 11th International Conference*

on Contemporary Computing (IC3), at Noida in 2-4 August, 2018, Noida.
<https://ieeexplore.ieee.org/document/8530659>

- Janssen, M., Voort, H., Wahyudi, A. (2017), “Factors Influencing Big Data Decision-Making Quality”, *Journal of Business Research*, 70: 338-345.
- Jenkins, H. (2004), “The Cultural Logic of Media Convergence”, *International Journal of Cultural Studies*, 7/1: 33–43. doi: 10.1177/1367877904040603
- Jirasakuldech, B., Emekter, R., Snaith, S.M., (2009), “Nonlinear Dynamics In Foreign Exchange Excess Returns: Test Of Assymetry”, *Journal of Multinational Financial Management*, 19: 179-192.
- Joseph, K., Wintoki, M. B., Zhang, Z. (2011), “Forecasting Abnormal Stock Returns and Trading Volume Using Investor Sentiment: Evidence From Online Search”, *International Journal of Forecasting*, 27/5: 1116-1127.
- Jörg H., Hubona, G., Ray, P. A. (2016), “Using PLS Path Modeling in New Technology Research: Updated Guidelines”, *Industrial Management & Data Systems*, 116/1: 2-20.
- Junadi, S., Fenrianto, J. (2015), “A Model of Factors Influencing Consumers Intention to Use E-payment System in Indonesia”, *Procedia Computer Science*, 59: 214–220.
- Kabak, A., Çelik Z. (2020), “Tüketicilerin Kripto Para Kullanım Niyeti ile İlişkili Faktörlerin Belirlenmesine Yönelik Uygulamalı Bir Araştırma”, *6th International GAP Social Sciences Congress, December 4-6, Şanlıurfa*.
- Kaldor, N. (1940), “A Model of the Trade Cycle”, *Economic Journal*, 50: 78-92.
- Kaminski, J., Gloor, P. (2014), “Nowcasting the Bitcoin Market with Twitter Signals”, *MIT Media Lab*.
- Kamioka, T., Tapanainen, T. (2014), “Organizational Use of Big Data and Competitive Advantage – Exploration of Antecedents”.
- Kanat, E., Öget, E. (2018), “Bitcoin ile Türkiye ve G7 Ülke Borsaları Arasındaki Uzun ve Kısa Dönemli İlişkilerin İncelenmesi”, *Finans Ekonomi ve Sosyal Araştırmalar Dergisi*, 3/3: 601-614.
- Kapetanios, G., Shin, Y., Snell, A. (2003), “Testing For a Unit Root in The Nonlinear STAR Framework” *Journal of Econometrics*, 112/2: 359-379.
- Katal, A., Wazid, M., Goudar, R. H. (2013), “Big Data: Issues, Challenges, Tools and Good Practices”, *2013 Sixth International Conference on Contemporary Computing (IC3)*, Noida: 404-409.
- Ke, G., Meng, Q., Finley, T., Wang, T., Chen, W., Ma, W., Ye, Q. & Liu, T.Y. (2017), “Lightgbm: A Highly Efficient Gradient Boosting Decision Tree”, *Advances in Neural Information Processing Systems*.
<https://proceedings.neurips.cc/paper/2017/file/6449f44a102fde848669bdd9eb6b76fa-Paper.pdf>
- Kethineni, S., Cao, Y. (2020), “The Rise in Popularity of Cryptocurrency and Associated Criminal Activity”, *International Criminal Justice Review*, 30/3: 325-344.

- Ketizmen, M., Kart, A. (2019). “Kişisel Veri ve Rekabet Hukuku Kapsamında ‘Big Data.’” *Kişisel Verileri Koruma Dergisi*, 1/1: 64-76.
- Ketrez, R. Ş., Saldanlı, A. (2018), “Yapay Sinir Ağları Yöntemi ile Petrol Fiyatları Tahmini”, *Kırklareli Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 7/3: 91-106.
- Kılıç, S. (2020), “Gündem Belirleme Kuramı Bağlamında Twitter ve İnternet Gazetelerinin Karşılaştırılması: Hürriyet ve Milliyet Gazeteleri Örneği”, *Selçuk İletişim*, 13/1: 91-129.
- Kızılkaya, Y. M., Oğuzlar, A. (2018), “Bazı Denetimli Öğrenme Algoritmalarının R Proglama Dili ile Kıyaslanması”, *Karadeniz Uluslararası Bilimsel Dergi*, 37/37: 90-98.
- Kim N., Lučivjanská K., Molnár P., Villa R. (2019), “Google Searches and Stock Market Activity: Evidence from Norway Finance”, *Research Letters*, 28: 208-220.
- Kim, Y. B., Kim, J. G., Kim, W., Im, J. H., Kim, T. H., Kang, S. J, Kim, C. H. (2016), “Predicting Fluctuations in Cryptocurrency Transactions Based on User Comments and Replies”, *PLoS ONE 2016*, 11: e0161197.
- Kinderis, M., Bezbradica, M., Crane, M. (2018), “Bitcoin Currency Fluctuation”, *3rd International Conference on Complexity, Future Information Systems and Risk*, 31-41.
- Kitchin, R. (2014), “Büyük Veri, Yeni Epistemolojiler ve Paradigma Kaymaları”, *Büyük Veri ve Toplum*, 1/1.
- Koç, S. (2008), “Tek ve Çok Değişkenli Rejim Değişim Modellerinin Türkiye İktisadî Göstergelerine Uygulanması”, Marmara Üniversitesi, Sosyal Bilimler Enstitüsü, Doktora Tezi, İstanbul.
- Koç, S., Akgül, I., (2013), “Türkiye Ekonomisinin Rejim Yapısının MSVAR ile Belirlenmesi”, *İktisat İşletme ve Finans*, 28(324): 9-34.
- Koçoğlu, Ş., Çevik, Y. E., Tanrıöven, C. (2016), “Bitcoin Piyasalarının Etkinliği, Likiditesi ve Oynaklığı”, *Journal of Business Research-Türk*, 8/2: 77-97.
- Koh, H. C., Tan, S. S. (1999), “A Neural Network Approach to The Prediction of Going Concern Status”, *Accounting and Business Research*, 29/3: 211-216. doi: 10.1080/00014788.1999.9729581
- Koki, C., Leonardos, S., Piliouras, G. (2020), “Exploring the Predictability of Cryptocurrencies via Bayesian Hidden Markov Models”, Papers 2011.03741, arXiv.org
- Korkmaz, T., Çevik, E., Çevik, N. (2017), “Yatırımcı İlgisi ile Pay Piyasası Arasındaki İlişki: BİST-100 Endeksi Üzerine Bir Uygulama”, *Business and Economics Research Journal*, 8/2: 203-215.
- Korobilis, D. (2013), Hierarchical Shrinkage Priors for Dynamic Regressions with Many Predictors, *International Journal of Forecasting*, 29(1): 43–59.
- Kosala, R., Blockeel, H. (2000), “Web Mining Research: A Survey”, *ACM SIGKDD Explorations Newsletter*, 2/1: 1–15.
- Kotchoni, R., Leroux, M, Stevanovic, D. (2019), “Macroeconomic Forecast Accuracy in a Data-Rich Environment”, *Journal of Applied Econometrics*, 34(7): 1050–1072.

- Koy, A., (2017), "Vadeli İşlem Piyasaları : BİST30 Endeks Vadeli İşlem Sözleşmesinin Markov Rejim Değişim Modelleri ile Analizi", Derin yayınları, İstanbul.
- Köksal, B., Erdem, G., Türkeli, C., Öztürk, Z. (2021), "Twitter'da Duygu Analizi Yöntemi Kullanılarak Bitcoin Değer Tahminlemesi," *Düzce Üniversitesi Bilim ve Teknoloji Dergisi*, 280-297.
- Kraaijeveld, O., De Smedt, J. (2020), "The Predictive Power of Public Twitter Sentiment for Forecasting Cryptocurrency Prices", *Journal of International Financial Markets, Institutions and Money*, 65.
- Krolzig, H. (2006), "Impulse Response Analysis in Markov Switching Vector Autoregressive Models", In Economics Department, University of Kent, Keynes College.
- Krolzig, H.M., (1998), "Econometric Modelling of Markov-Switching Vector Autoregressions using MSVAR for Ox", *Institute of Economics and Statistics and Nuffield College*, Oxford. December 15.
- Krolzig, H.M., Toro, J. (2004), "Classical and Modern Business Cycle Measurement: The European Case." *Spanish Economic Review*, 7: 1-22.
- Kuiler, E. W. (2014), "From Big Data to Knowledge: An Ontological Approach to Big Data Analytics", *Review of Policy Research*, 31/4: 311-318.
- Kumar, S., Gulati, R. (2008), "An Examination of Technical, Pure Technical and Scale Efficiencies in Indian Public Sector Bank Using Data Envelopment Analysis", *Eurasian Journal of Business and Economics*, 1/2: 33-69.
- Kuzucu, S. C. (2019), "Investigation of The Relationship Between Bitcoin and Exchange Rates", *3rd International Conference on Economic Research*, 156-160.
- Laboure, M. (2021), "The Future of Payments: Series 2 - Part III. Bitcoins: Can the Tinkerbelle Effect Become a Self-Fulfilling Prophecy?", *Deutsche Bank Research*, 1-19.
- Lahmiri, S., Bekiros, S. (2019), "Cryptocurrency Forecasting with Deep Learning Chaotic Neural Networks", *Chaos, Solitons & Fractals*, 118: 35-40. <https://doi.org/10.1016/J.CHAOS.2018.11.014>
- Lamba, H. S., Dubey, S. K. (2015), "Analysis of Requirements For Big Data Adoption to Maximize IT Business Value in Reliability", *4th International Conference on Infocom Technologies and Optimization (ICRITO) (Trends and Future Directions)*, 1-6
- Lamon, C., Nielsen, E., Redondo, E. (2017), "Cryptocurrency Price Prediction Using News and Social Media Sentiment", *SMU Data Science Review*, 1/3: 1-22.
- Latoeiro, P., Ramos, S. B., Veiga, H. (2013), "Predictability of Stock Market Activity Using Google Search Queries", [Working Paper]. *Universidad Carlos III de Madrid*, 13-06.
- Lee, D. K. C., Guo, L., Wang, Y. (2018), "Cryptocurrency: A New Investment Opportunity?" *Journal of Alternative Investments*, 20/3: 16-40.
- Lee, L. (2015), "New Kids on the Blockchain: How Bitcoin's Technology Could Reinvent the Stock Market", *Hastings Bus, L. J.*, 12: 81-132.

- Lee, S. (2004), "Application of Likelihood Ratio and Logistic Regression Models to Landslide Susceptibility Mapping Using GIS", *Environmental Management*, 34/2: 223-232.
- Li, G.Y., Li, W., Tian, X.L. & Che Y.F. (2017), "Short-Term Electricity Load Forecasting Based on the XGBoost Algorithm", *Smart Grid Smart Grid*, 7:4: 274.
- Liu, Y., Lv, B., Peng, G., Zhang, C. (2012), "Relationship between Internet Search Data and Stock Return: Empirical Evidence from Chinese Stock Market", *Recent Progress in Data Engineering and Internet Technology*, 157: 25-30.
- Loughlin, C., Harnisch, E. (2013), *The Viability of Stocktwits and Google Trends to Predict the Stock Market [ArXiv Working Paper]*, 1-19.
- Lu, H. K., Yang, L. W., Lin, P. C., Yang, T. H., Chen, A. N. (2017), "A Study on Adoption of Bitcoin in Taiwan: Using Big Data Analysis of Social Media", *Proceedings of the 3rd International Conference on Communication and Information Processing at Tokyo in 24–26 November 2017*, Tokyo: 32–38.
- Ma, F., Lang, C., Ma, Y. & Wahab, M.I.M. (2020), "Cryptocurrency Volatility Forecasting: a Markov Regimeswitching MIDAS Approach", *Journal of Forecasting*, 39: 1277–1290
- Maciel, L. (2021.), "Cryptocurrencies Value-at-Risk and Expected Shortfall: Do Regime-Switching Volatility Models Improve Forecasting?", *International Journal of Finance and Economics* 26: 4840–55.
- Magnini, V. P., Honeycutt, E. D., Hodge, S. K. (2003), "Data Mining For Hotel Firms: Use and Limitations", *Cornell Hotel ve Restaurant Administration Quarterly*, 94-105.
- Mao, H., Counts, S., Bollen, J. (2011), "Predicting Financial Markets: Comparing Survey, News, Twitter and Search Engine Data", *arXiv preprint*, 1-10.
- Marcellino, M. (1999), "Some Consequences of Temporal Aggregation in Empirical Analysis", *Journal of Business & Economic Statistics*, 17/1: 129-136
- Matta, M., Lunesu, M. I., Marchesi, M. (2015), "Bitcoin Spread Prediction Using Social and Web Search Media"
- Matthes, J. (2005), "The Need for Orientation towards News Media: Revising and Validating a Classic Concept", *International Journal of Public Opinion Research*, 18/4: 422-444. doi: 10.1093/ijpor/edh118
- Maupin, T. (2019), "Can Bitcoin, and Other Cryptocurrencies, be Modeled Effectively with a Markov-Switching Approach?", (Degree Project) Royal Institute of Technology School of Engineering Sciences, Stocholm, Sweden.
- Mba, J.C., Mwambi, S. (2020), "A Markov-Switching COGARCH Approach to Cryptocurrency Portfolio Selection and Optimization, *Financial Markets and Portfolio Management* 34: 199–214.
- McCombs M. E., Shaw, D. L. (1972), "The Agenda-Setting Function of Mass Media", *The Public Opinion Quarterly*, 36/2: 176-187.
- McFarland, L. A., Ployhart, R. E. (2015), "Social Media: A Contextual Framework to Guide Research and Practice", *Journal of Applied Psychology*, 100: 1653-1677

- Medeiros, M. C., Vasconcelos, G. F. R., Veiga, A. & E. Zilberman (2021), "Forecasting Inflation in a Data-Rich Environment: The Benefits of Machine Learning Methods", *Journal of Business and Economic Statistics*, 39(1): 98–119.
- Medhat, W., Hassan, A., Korashy, H. (2014), "Sentiment Analysis Algorithms and Applications: A Survey", *Ain Shams Engineering Journal*, 5/4: 1093-1113.
- Mendoza-Tello, J. C., Mora, H., Pujol-Lopez, F. A., Lytras, M. D. (2018), "Social Commerce As A Driver to Enhance Trust and Intention to Use Cryptocurrencies for Electronic Payments, *IEEE Access*, 6.
- Merton, R. C. (1987), "A Simple Model of Capital Market Equilibrium with Incomplete Information", *Journal of Finance*, 42/3: 483-510.
- Moore, G. C., Benbasat, I. (1991), "Development of An Instrument to Measure the Perceptions of Adopting An Information Technology Innovation," *Information Systems Research*, 2/3: 192–222.
- Moradi, M., Salehi, M., Yazdi, H. S., Gorgani, M. E. (2012), "Going Concern Prediction of Iranian Companies by Using Fuzzy C-Means", *Open Journal of Accounting*, 1: 38-46. doi: 10.4236/ojacct.2012.12005
- Murphy, J., Hill, C. A., Dean, E. (2013), "Social Media, Sociality, and Survey Research", *Social Media, Sociality, and Survey Research*, 1–33. doi:10.1002/9781118751534.ch1
- Münyas, T. (2018), "Gayrimenkul Yatırım Ortaklıklarının Finansal Etkinliklerinin Veri Zarflama Analizi Yöntemi ile Değerlendirilmesi", *Journal of Life Economics*, 5/4: 111-126.
- Nagaraj, K., Hunter, C., Caplain, J. (2018), "Institutionalization of Cryptoassets: Cryptoassets Have Arrived. Are You Ready for Institutionalization?" *International Cooperative*, 27/11: 2019.
- Nagel, S. (2005), "Short Sales, Institutional Investors and The Cross-Section of Stock Returns", *Journal of Financial Economics*, 78: 277-309.
- Nair, G. R., Sebastian, S. (2017), "Blockchain Technology Centralised Ledger to Distributes Ledger", *International Research Journal of Engineering and Technology (IRJET)*, 4/3: 2823-2827.
- Narasimhan, R., Bhuvaneshwari, T. (2014), "Big Data-A Brief Study", *International Journal of Scientific & Engineering Research*, 5/9: 350-353.
- Narman H. S., Uulu A. D. (2020), "Impacts of Positive and Negative Comments of Social Media Users to Cryptocurrency", *International Conference on Computing, Networking and Communications (ICNC)*, 187-192.
- Netzer, O., Feldman, R., Goldenberg, J., Fresko, M. (2012), "Mine Your Own Business: Market-Structure Surveillance Through Text Mining", *Marketing Science*, 31/3: 369-547.
- Nguyen, T. V., Nguyen, B. T., Nguyen, T. C., Nguyen, Q. Q. (2019), "Bitcoin Return: Impacts From The Introduction of New Altcoins", *Research in International Business and Finance*, 48: 420-425.
- Nikolaos-Marios, T., (2015), "Markov Switching Models Application with R", Athens University of Economics and Business, Master Thesis, Athens.

- O'Dwyer, K. J., Malone, D. (2014), "Bitcoin Mining and Its Energy Footprint", *25th IET Irish Signals & Systems Conference 2014 and 2014 China-Ireland International Conference on Information and Communities Technologies (ISSC 2014/CICT 2014)*.
- Oberlechner, T., Hocking, S. (2004), "Information Sources, News, and Rumors in Financial Markets: Insights into the Foreign Exchange Market", *Journal of Economic Psychology*, 25: 407-424. doi: 10.1016/S0167-4870(02)00189-7.
- Okasha, M.K. (2014), "Using Support Vector Machines in Financial Time Series Forecasting", *International Journal of Statistics and Applications*, 4(1): 28-39.
- Okursoy, A., Tezsürücü, D. (2014), "Veri Zarflama Analizi ile Göreli Etkinliklerin Karşılaştırılması: Türkiye'deki İllerin Kültürel Göstergelerine İlişkin Bir Uygulama", *Celal Bayar Üniversitesi İktisadi ve İdari Bilimler Fakültesi Yönetim ve Ekonomi Dergisi*, 21/2: 1-18.
- Onan, A., Korukoğlu, S. (2016), "A Review of Literature on the Use of Machine Learning Methods for Opinion Mining", *Pamukkale University Journal of Engineering Sciences*, 22/2: 111-122.
- Ott, M., Cardie, C., Hancock, J. (2012), "Estimating the Prevalence of Deception in Online Review Communities". *Proceedings of the 21st International Conference on World Wide Web*, New York: ACM: 201-210.
- Ozili, P.K., Arun, T.G. (2020), "Spillover of COVID-19: Impact on the Global Economy", *SSRN Electronic Journal*.
- Öksüz-Karademir C., Kuş O. (2020), "Exploring Cryptocurrency Ownership in the Context of Technology Acceptance Model and Technology Adopter Categories: Coin-Optimistics, Observes and Coin-Sceptics", *Ankara Üniversitesi Sosyal Bilimler Dergisi*, 11/2: 43-59.
- Örkcü, H. H., Doğan, M. İ. (2015), "Veri Zarflama Analizi Tabanlı Yeni Bir Hibrid İki Gruplu Sınıflandırma Modeli", *Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 19/3: 26-38.
- Özçağlayan, M. (2008), "Gazetelerin Gelişimi ve Gazeteciliğin Geleceği (Yeni Teknolojiler ve Medya Ekonomisi Açısından Genel Bir Değerlendirme)", *Marmara İletişim Dergisi*, 13: 131-159.
- Özdemir, L., Göktaş, A. (2019), "Borsa İstanbul'da Yer Alan Petrol İşletmelerinin Etkinliklerinin Ölçülmesi: Veri Zarflama Analizi", *Afyon Kocatepe Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 21/2: 140-147.
- Özdemir, S., Akgül, I., (2015), "Inflationary Effects of Oil Prices and Domestic Gasoline Prices: Markov-Switching VAR Analysis", *Petroleum Science*, 12(2): 355-365.
- Özyurt, B., Akcayol, M. A. (2018), "Fikir Madenciliği ve Duygu Analizi, Yaklaşımlar, Yöntemler Üzerine Bir Araştırma", *Selçuk University Journal of Engineering Science and Technology*, 6/4: 668-693.
- Pak, A., Paroubek, P. (2010), "Twitter as a Corpus for Sentiment Analysis and Opinion Mining", *Proceedings of the 7th conference on International Language Resources and Evaluation (LREC'10)*.

- Panagiotidis, T., Papapanagiotou, G., Stengos, T. (2022), "On the Volatility of Cryptocurrencies", *Research in International Business and Finance*, 62(101724).
- Pang, B., Lee, L., Vaithyanathan, S. (2002), "Thumbs Up? Sentiment Classification Using Machine Learning Techniques", *Proceedings of EMNLP-02, 7th Conference on Empirical Methods in Natural Language Processing in Philadelphia, 2002*, Morristown: Association for Computational Linguistics: 79–86.
- Pant, D. R., Neupane, P., Poudel, A., Pokhrel, A. K., Lama, B. K. (2018), "Recurrent Neural Network Based Bitcoin Price Prediction by Twitter Sentiment Analysis", *IEEE 3rd International Conference on Computing, Communication and Security (ICCCS)*, Nepal.
- Park, S., Lee, W., Moon, I. C. (2015), "Efficient Extraction of Domain Specific Sentiment Lexicon with Active Learning", *Pattern Recognition Letters*, 56: 38-44. doi: 10.1016/j.patrec.2015.01.004
- Parkan, Ç., Ming-Lu, W. (1999), "Measurement of The Performance of an Investment Bank Using The Operational Competitiveness Rating Procedure" *The International Journal of Management Science*, 27: 201-217.
- Paulus, M. P., Angela, J. Y. (2012), "Emotion and Decision-Making: Affect-Driven Belief Systems in Anxiety and Depression", *Trends in Cognitive Sciences*, 16/9: 476-483.
- Pawar, K. K., Shrishrimal, P. P., Deshmukh, R. R. (2015), "Twitter Sentiment Analysis: A Review", *International Journal of Scientific & Engineering Research*, 6/4: 957-964.
- Pirinççi, A. E. (2018), "Yeni Dünya Düzeninde Sanal Para Bitcoin'in Değerlendirilmesi (Evaluation of Virtual Money Bitcoin in the New World Edition)", *Uluslararası Ekonomi Siyaset İnsan ve Toplum Bilimleri Dergisi*, 1/1: 45-52.
- Pisa, M., Juden, M. (2017), Blockchain and Economic Development: Hype vs. Reality. *Center For Global Development*, 107: 5-7.
- Polat, M., Akbıyık, A. (2019), "Sosyal Medya ve Yatırım Araçlarının Değeri Arasındaki İlişkinin İncelenmesi: Bitcoin Örneği", *Akademik İncelemeler Dergisi*, 14/1: 443-462.
- Pollock, T. G., Rindova, V. P. (2003), "Media Legitimation Effects in the Market for Initial Public Offerings", *Academy of Management Journal*, 46/5: 631–642.
- Preis T., Reith D., Stanley H. (2010), "Complex Dynamics of Our Economic Life on Different Scales: Insights from Search Engine Query Data", *Philosophical Transactions of the Royal Society A Mathematical Physical and Engineering Sciences*, 368/1933: 5707-5719.
- Preis, T., Moat H. S., Stanley H. E. (2013), "Quantifying Trading Behavior in Financial Markets Using Google Trends", *Scientific Reports*, 3/1: 1684.
- Rajpurohit, A. (2013), "Big Data for Business Managers- Bridging The Gap Between Potential and Value", *2013 IEEE International Conference on Big Data*, Silicon Valley, CA: 29-31.
- Rawat, R., Tiku, N. (2017), "Introduction of Bitcoin with Comparison to Other Alternative Coins Called Altcoin", *International Research Journal of Engineering and Technology (IRJET)*, 4/6: 2490-2494.

- Rojas, O., Coronado, S. (2020), "A Bayesian Study of Changes in Volatility Of Bitcoin", *Contaduría y Administración*, Article in Press, 1-17.
- Ruggiero, J., Bretschneider, S. (1998), "The Weighted Russell Measure of Technical Efficiency", *European Journal of Operational Research*, 108/2: 438-451
- Ryu, K., Han, H. (2010), "Predicting Tourists' Intention to Try Local Cuisine Using a Modified Theory of Reasoned Action: The Case of New Orleans", *Journal of Travel & Tourism Marketing*, 27: 491-506.
- Salisu, A. A., Ogbonna, A. E., Adewuyi, A. (2020), "Google Trends and The Predictability of Precious Metals", *Resources Policy*, 65: 101542.
- Samırkaş, M.C. (2021), "Bitcoin Fiyatlarındaki Değişimin Markov Rejim Değişim Modeli ile Analizi", *İşletme Araştırmaları Dergisi*, 13(1): 813-824.
- Sánchez-Rada, J. F., Iglesias, C. A. (2019), "Social Context in Sentiment Analysis: Formal Definition, Overview of Current Trends and Framework for Comparison", *Information Fusion*, 52: 344–356. doi: 10.1016/j.inffus.2019.05.003.
- Savage, N. (2011), "Twitter as Medium and Message", *Communications of the ACM*, 54/3: 18. doi: 10.1145/1897852.1897860
- Sayre, B., Bode, L., Shah, D., Wilcox, D., Shah, C. (2010), "Agenda Setting in a Digital Age: Tracking Attention to California Proposition 8 in Social Media", *Online News, and Conventional News, Policy & Internet*, 2/2: 7-32.
- Schaupp, L. C., Festa, M. (2018), "Cryptocurrency Adoption and the Road to Regulation," *Proceedings of the 19th Annual International Conference on Digital Government Research: Governance in the Data Age*, 1–9.
- Schreiber, T. (2000), "Measuring Information Transfer", *Physical Review Letters*, 85(2): 461-464.
- Shahzad, F., Xiu, G., Wang, J., Shahbaz, M. (2018), "An Empirical Investigation on The Adoption of Cryptocurrencies among The People of Mainland China", *Technology in Society*, 55: 33–44. doi: 10.1016/j.techsoc.2018. 05.006
- Shannon, C.E. (1948), "A Mathematical Theory of Communication", *The Bell System Technical Journal*, 27(3), 379-423
- Shapoval, V., Wang, M. C., Hara, T., Shioya, H. (2018), "Data Mining in Tourism Data Analysis: Inbound Visitors to Japan", *Journal of Travel Research*, 57/3: 310-323.
- Sharma, S. K., Modanval, R. K., Gayathri, N., Kumar, S. R., Ramesh, C. (2020), Impact of Application of Big Data on Cryptocurrency", *Cryptocurrencies and Blockchain Technology Applications*, 181–195. doi:10.1002/9781119621201.ch10
- Singh, A. (2015), "Twitter Sentiment Analysis" (Report No. CS365A: 12056).
- Siswantoro, D., Handika, R., Mita, A. (2020), "The Requirements of Cryptocurrency For Money, An Islamic View", *Heliyon*, 6/1: 1-9.

- Sivrikaya, A., İren, P., Umay, T. (2021), "The Relationship between Stock Returns, Bitcoin Returns, and Risk Aversion: Evidence from a Multivariate GARCH Model", *Sosyoekonomi*, 29/47: 107-118.
- Söylemez, Y. ve Yılmaz Türkmen, S. (2019). "Bitcoin Volatilitesinin Analizinde Markov Rejim Değişken Karar Destek Modellerinin Kullanılması", 23. Finans Sempozyumu, Marmara Üniversitesi, İstanbul.
- Srivastava, A., Bhattacharya, P., Singh, A., Mathur, A. (2018), "A Systematic Review on Evolution of Blockchain Generations", *ITEE Journal*, 1/8.
- Stenqvist, E., Lönnö, J. (2017), *Predicting Bitcoin Price Fluctuation with Twitter Sentiment Analysis*, Stockholm.
- Strauss, N. (2017), "News Media and the Stock Market: Assessing Mutual Relationships. An Interdisciplinary Multi-Method Study of Financial Journalism, News Media, Emotions, Market Events and the Stock Market".
- Strauss, N., Vliegthart, R., Verhoeven, P. (2016), "Ladding Behind? Emotions in Newspaper Articles and Stock Market Prices in the Netherlands", *Public Relations Review*, 42: 548-555. doi: 10.1016/j.pubrev.2016.03.010.
- Strauss, N., Vliegthart, R., Verhoeven, P. (2018), "Intraday News Trading: The Reciprocal Relationships Between the Stock Market and Economic News", *Communication Research*, 45/7: 1054-1077. doi: 10.1177/0093650217705528.
- Szetela, B., Mentel, G., Gedek, S. (2016), "Dependency Analysis Between Bitcoin and Selected Global Currencies", *Dynamic Econometric Models*, 16: 133-144.
- Taboada, M., Brooke, J., Tofiloski, M., Voll, K., Stede, M., (2011), "Lexicon-Based Methods For Sentiment Analysis", *Computational Linguistics*, 37/2: 267-307.
- Talluri, S. (2000), "Data Envelopment Analysis: Models and Extensions", *Production/Operations Management*, 8-11.
- Tan, C. Y., Koh, Y. B., Ng, K. H., & Ng, K. H. (2021), "Dynamic Volatility Modelling of Bitcoin Using Time-Varying Transition Probability Markov-Switching GARCH Model", *The North American Journal of Economics and Finance*, 56, 101377.
- Taş, O., Kiani, F. (2018), "Blokzinciri Teknolojisine Yapılan Saldırıları Üzerine Bir İnceleme", *Bilişim Teknolojileri Dergisi*, 11/4: 370.
- Taylor, S., Todd, P. A. (1995), "Understanding Information Technology Usage: A Test of Competing Models", *Information Systems Research* 6/2: 144-176.
- Tayman, J., Swanson, D.A. (1999), "On the Validity of MAPE as A Measure of Population Forecast Accuracy", *Population Research and Policy Review*, 18(4): 299-322.
- Teräsvirta, T. (1994), "Specification, Estimation, and Evaluation of Smooth Transition Autoregressive Models", *Journal of the American Statistical Association*, 89(425): 208-18.
- Tetlock, P. C. (2007), "Giving Content to Investor Sentiment: The Role of Media in The Stock Market", *The Journal of Finance*, 62/3: 1139-1168.

- Thong, J. Y., Venkatesh, V., Xu, X., Hong, S. J., Tam, K. Y. (2011), "Consumer Acceptance of Personal Information and Communication Technology Services", *MIS Quart*, 58: 613–625.
- Topaloğlu, E. A. (2019), "Kripto Para Bitcoin ve Döviz Kurları İlişkisi: Yapısal Kırılmalı Eşbütünleşme ve Nedensellik Analizi", *CBÜ Sosyal Bilimler Dergisi*, 17/2: 367-382.
- Tsay, R.S. (2006), "Analysis of Financial Time Series", *Technometrics*, 48. <https://doi.org/10.1198/tech.2006.s405>
- Tsay, R.S., (1989), "Testing and Modeling Threshold Autoregressive Processes", *Journal of the American Statistical Association*, 84(405): 231–240.
- Tumasjan, A., Sprenger, T. O., Sandner, P. G., Welpe, I. (2010), "Predicting Elections with Twitter: What 140 Characters Reveal about Political Sentiment", *Proceedings of the Fourth International Conference on Weblogs and Social Media*, Washington.
- Türkmen, N.C. (2017), Konjonktürel Dalgalanma Modelleri Bağlamında Yeni Monetarist Yaklaşımın MS-VAR Modeli İle Analizi. Yıldız Teknik Üniversitesi Sosyal Bilimler Enstitüsü, Doktora Tezi.
- Urquhart, A. (2017), "Price Clustering in Bitcoin", *Economics Letters*, 159: 145–148.
- Uscinski, J. E. (2009), "When Does the Public's Issue Agenda Affect the Media's Issue Agenda (and Vice-Versa)? Developing a Framework for Media-Public Influence", *Social Science Quarterly*, 90/4: 796-815
- Van Wijk, D. (2013), *What Can Be Expected from the BitCoin? [Working Paper No. 345986]. Erasmus Rotterdam Universiteit.*
- Veerasingam, N., Teoh, A. P. (2022), "Modeling Cryptocurrency Investment Decision: Evidence from Islamic Emerging Market", *Journal of Islamic Marketing*, 13/8. doi: 10.1108/JIMA-07-2021-0234
- Venkatesh, V., Morris, M. G., Davis, G. B., Davis, F. D. (2003), "User Acceptance of Information Technology: Toward a Unified View", *Management Information Systems Quarterly*, 27/3: 425–478. doi:10.2307/30036540
- Vlastakis, N., Markellos, R. N. (2012), "Information Demand and Stock Market Volatility", *Journal of Banking and Finance*, 36/6: 1808-1821.
- Vockathaler, B. (2015), "The Bitcoin Boom: An in Depth Analysis of The Price of Bitcoins", *Major Research Paper University of Ottawa*, 1-75.
- Wang, C., Kang, W. (2021), "Forecasting China's Steam Coal Prices Using Dynamic Factors and Mixed-Frequency Data", *Pol. J. Environ. Stud.*, 30(5): 4241-4254.
- Wang, L., Wu, J., Cao, Y., Hong, Y. (2022), "Forecasting renewable energy stock volatility using short and long-term Markov switching GARCH-MIDAS models: Either, neither or both?", *Energy Economics*, 111: 1-12.
- Wu, C. Jinliang, L. & Wei, Z. (2005), "Intradaily Periodicity and Volatility Spillovers Between International Stock Index Futures Markets", *Journal of Futures Markets*, 25: 553–85.

- Xu, H., Zhang, N., Zhou, L. (2020), “Validity Concerns in Research Using Organic Data”, *Journal of Management*, 46/7: 1257–1274. doi: 10.1177/0149206319862027
- Yadollahi, A., Shahraki A. G., Zaiane O. (2017), “Current State of Text Sentiment Analysis from Opinion to Emotion Mining”, *ACM Computing Surveys*, 50/2: 25-33.
- Yavuz, M. S. (2019), “Ekonomide Dijital Dönüşüm: Blokchain Teknolojisi ve Uygulama Alanları Üzerine Bir İnceleme”, *Finans Ekonomi ve Sosyal Araştırmalar Dergisi*, 4/1: 15-29.
- Yavuzdoğan A., Tanır Kayıkçı, E. (2021), “Ege Denizi’nde Makine Öğrenimi Yöntemleri ile Anlık Deniz Seviyesi Değişimlerinin Tahmini”, *Jeodezi ve Jeoinformasyon Dergisi*, 8(2): 84-103
- Yermack, D. (2013), *Is Bitcoin a Real Currency? An Economic Appraisal*, (NBER Working Paper No: 19747), Cambridge: National Bureau of Economic Research Working Paper Series.
https://www.nber.org/system/files/working_papers/w19747/revisions/w19747.rev0.pdf
- Yıldırım, H. (2018), “Günlük Bitcoin ile Altın Fiyatları Arasındaki İlişkinin Test Edilmesi: 2012-2013 Yılları Arası Johansen Eşbütünleşme Testi”, *İnsan ve Toplum Bilimleri Araştırmaları Dergisi*, 7/4: 2328-2343.
- Yıldırım-Taşer, P. (2021), “Kapalı Ortamlarda Kişi Tespitinde Makine Öğrenmesi Algoritmalarının Karşılaştırmalı Başarım Analizi”, *Academic Platform Journal of Engineering and Science*, 9/1: 182-193.
- Yin, L., Nie, J., Han, L. (2021), “Understanding Cryptocurrency Volatility: The Role of Oil Market Shocks”, *International Review of Economics & Finance*, 72: 233-253.
- Yu, Y. (2013), “The Impact of Social and Conventional Media on Firm Equity Value: A Sentiment Analysis Approach”, *Decision Support Systems*, 55: 919-926.
- Yue, L., Chen, W., Li, X., Zuo, W., Yin, M. (2019), “A Survey of Sentiment Analysis in Social Media”, *Knowledge and Information Systems*, 1-47.
- Zaki, M. J., Limsoon, W. (2003), “Data Mining Techniques”, *WSPC/Lecture Notes Series*.
- Zhang, L. (2013), Sentiment Analysis on Twitter with Stock Price and Significant Keyword Correlation, Master Thesis, The University of Texas at Austin, Department of Computer Science.
- Zhang, L., Bian, W., Qu, W., Tuo, L. & Wang, Y. (2021), “Time series forecast of sales volume based on XGBoost”, *Journal of Physics: Conference Series*, 1873(012067): 1-9. doi:10.1088/1742-6596/1873/1/012067
- Zhang, W., Shen, D., Zhang, Y., Xiong, X. (2013), “Open Source Information, Investor Attention and Asset Pricing”, *Economic Modelling*, 33: 613-619.
- Zhu Y., Dickinson D., Li Jianjun (2017), “Analysis on The Influence Factors of Bitcoin’s Price Based on VEC Model”, *Financial Innovation*, 3/3: 1-13.
- Zweig, M. E. (1973), “An Investor Expectations Stock Price Predictive Model Using Closed-End Fund Premiums”, *Journal of Finance*, 28: 67–87.

Kitaplar

- Ajzen, I. (1985), "From Intentions to Actions: A Theory of Planned Behavior", Kuhl, J., Beckman, J. (Ed.), *Action Control, From Cognition to Behaviour*, Berlin: Springer: 11-39.
- Aksu H. (2015), *Big Data: Bilginin Gücü* (1.Baskı), İstanbul: Pusula Yayıncılık.
- Armknrecht, F., Karame, G. O., Mandal, A., Youssef, F. (2015), "Ripple: Overview and Outlook", Conti, M., Schunter, M., Askoxylakis, I. (Ed.), *Trust and Trustworthy Computing*, Cham: Springer.
- Ateş, E. C. (2021), "Siber Ansiklopedi: Siber Ortama Çok Disiplinli Bir Yaklaşım", Akdemir, N., Tuncer, C.O. (Ed.), *Web Madenciliği (Web Mining)*, Ankara: Pegem Akademi, 629-632.
- Ayan, Ö. (2020), *Küreselleşme ve Kripto (Sanal) Para Hukuku, Küreselleşmenin Finansal ve Reel Yaşama Yansımaları*, İstanbul: Beta Basım Yayın.
- Berry, M. J., Linoff, G. S. (2004), *Data Mining Techniques: For Marketing, Sales, and Customer Relationship Management*, Indiana: Wiley Publishing, Inc.
- Beyer, M. A., Laney, D. (2012), *The Importance of 'Big Data': A Definition*, Stanford, CT: Gartner, 2014-2018.
- Bildirici, M., Alp, A., Ersin, Ö.Ö. & Bozoklu, Ü. (2010), "İktisatta Kullanılan Doğrusal Olmayan Zaman Serisi Yöntemleri", Türkmen Kitapevi, İstanbul.
- Birch, D. (2017), *Before Babylon, Beyond Bitcoin*, (1.Baskı), London: London Publishing Partnership.
- Bot, J. (2007), *Text-mining in the Life-Sciences, An Exploration*, Netherlands: Bioinformatics Track Delft University of Technology Delft.
- Brooks, C. (2008), *Introductory Econometrics for Finance*, Second Edition, Cambridge University Press.
- Charnes, A., Cooper, W. W., Lewin, A. Y., Seiford, L. M. (1994), *Data Envelopment Analysis: Theory, Methodology and Application*, Boston: Kluwer Academic Publisher.
- Chen, H. (2011), *Dark Web: Exploring and Data Mining the Dark Side of the Web*, Springer Science & Business Media.
- Chuen, D. L. K. (Ed.) (2015), *Handbook of Digital Currency: Bitcoin, Innovation, Financial Instruments, and Big Data*. USA: Academic Press.
- Cohen, B.C. (1963), *The Press and Foreign Policy*, New Jersey: Princeton University Press.
- Coleman, R., McCombs, M., Shaw, D., Weaver, D. (2009), "Agenda Setting", Wahl-Jorgensen, K., Hanitzsch, T. (Ed.), *The Handbook of Journalism Studies*, London, New York: Routledge, 147-160.
- Cont, R. (2010), *Encyclopedia of Quantitative Finance*, New Jersey: Wiley.

- Cooper, W. W., Lawrence M. S., Tone, K., (2007), *Data Envelopment Analysis: A Comprehensive Text with Models, Applications, References and DEA Solver Software*, New York: Springer Science+Business Media.
- Dannen, C. (2017), *Introducing Ethereum and Solidity: Foundations of Cryptocurrency and Blockchain Programming for Beginners*, New York: Apress.
- Davenport, T. (2018), *Big Data @Work*, (Çev. M. Çavdar), İstanbul: Türk Havayolları Yayınları.
- Davenport, T. H. (2014), *Dispelling the Myths, Uncovering the Opportunities*, Harvard Business Review Press.
- Diebold, F.X. (2013), “‘Big Data’ Dynamic Factor Models for Macroeconomic Measurement and Forecasting”, Dewatripont, M., Hansen, L. P., Turnovsky, S. J. (Ed.), *Advances in Economics and Econometrics, Theory and Applications, Eighth World Congress of the Econometric Society*, Cambridge: Cambridge University Press: 115-122.
- Diebold, F.X., (2012), “Comparing Predictive Accuracy, Twenty Years Later: A Personal Perspective on the Use and Abuse of Diebold-Mariano Tests”, Nber Working Paper Series, Working Paper 18391. <http://www.nber.org/papers/w18391>
- Emrouznejad, A., Charles, V. (2018), “Big Data for the Greater Good”, Kacprzyk J. (Ed.), *Studies in Big Data*, Springer.
- Fang, B., Jia, Y. (2019), *Online Social Network Analysis: Information and Communication*, Walter de Gruyter, 3.
- Finlay, S. (2014), *Predictive Analytics, Data Mining and Big Data: Myths, Misconceptions and Methods*, Palgrave Macmillan.
- Fishbein, M., Icek, A. (1975), *Belief, Attitude, Intention and Behavior: An Introduction to Theory and Research*, Canada: Addison-Wesley Publishing.
- Franco, P. (2015), *Understanding Bitcoin*, Birleşik Krallık: Wiley.
- Franks, B. (2012), *Taming The Big Data Tidal Wave: Finding Opportunities in Huge Data Streams with Advanced Analytics*, Wiley.
- Galbraith, J. K. (1990), *Ekonomi Kimden Yana*, (Çev. B. Çorakçı, N. Himmetoğlu), İstanbul: Altın Kitaplar.
- Gezgin, S. (2008), “Gazeteciliğin Türkiye’deki Serüveni”, Işık, M., Erdem, A. (Ed.), *Tüm Yönleriyle Medya ve İletişim*, Konya: Eğitim Kitabevi.
- Ghysels, E., Plazzi, A., Valkanov, R. (2007), “Valuation in the US Commercial Real Estate,” Manuscript, UNC-Chapel Hill, Chapel Hill, NC.
- Ghysels, E., Valkanov, R. (2006), *Linear Time Series Processes with Mixed Data Sampling and MIDAS Regressions Models*, Mimeo: Chapel Hill, N.C.
- Gürsakal, N. (2014), *Büyük Veri* (Genişletilmiş 2. Basım), Bursa: Dora.
- Hair, J., Anderson, R., Tatham, R., Black, W. (1998), *Multivariate Data Analysis* (5th Edition), New Jersey: Prentice Hall.

- Hansen, C. D., Johnson, C. R. (2011), *Visualization Handbook*, Elsevier.
- Harari, Y. N. (2015), *Hayvanlardan Tanrılara-Sapiens (İnsan Türünün Kısa Bir Tarihi)*, İstanbul: Kolektif Kitap.
- Hicks, J. R. (1950), *A Contribution to the Theory of Trade Cycle*, Oxford: Clarendon Press.
- Hristev, R. M. (1998), *The ANN Book*, Boston, USA.
- Hurwitz, J., Nugent, A., Halper, F., Kaufman, M. (2013), *Big Data For Dummies*, Wiley and Sons.
- Işık, M. (2014), *Kitle İletişim Teorilerine Giriş*, Konya: Eğitim Yayınevi.
- James W. Dearing, M.R.Rogers, Agenda Setting, Thousand Oaks, CA: Sage Publication, 1996'dan aktaran Cem Yaşın, Gündem Belirleme Kuram ve Araştırmaları içinde "Gündem Belirleme Kuram ve Araştırmalarının Tarihsel Gelişimi", Der.: Cem Yaşın, Ankara: Yargı.
- Jensen, K. B. (2011), "New Media, Old Methods-Internet Methodologies and the Online/offline Divide", Consalvo, M., Ess, C. (Ed.), *The Handbook of Internet Studies*, Malden: Wiley Blackwell, 43-58.
- Keynes, J. M. (1935), *The General Theory of Employment, Money and Interest*, (1st Edition), England: Macmillan Cambridge University Press.
- Keynes, J. M. (1936), *The General Theory of Employment, Interest and Money*, London: MacMillan.
- Kotler, P. (2000), *Pazarlama Yönetimi*, (Çev. N. Muallimoğlu), İstanbul: Beta Basım A.Ş.
- Kutlar, A., Bakırcı, F. (2018), *Veri Zarflama Analizi (Data Envelopment Analysis DEA) Teori ve Uygulama DEA-Solver Win4DEAP MALMQUIST Endeksi*, Ankara: Orion Kitabevi.
- Lee, D. K., Low, L. (2018), *Inclusive Fintech: Blockchain, Cryptocurrency and Ico*, Singapur: World Scientific Publishing Co. Pte. Ltd.
- Lilleker, D. G. (2013), *Siyasal İletişim Temel Kavramlar*, (Çev. A. Altın), İstanbul: Kaknüs Yayınları.
- Littlejohn, S. W., Foss, K. A. (2009), *Encyclopedia of Communication Theory*, SAGE Publications, Inc.
- Liu B. (2010), "Sentiment Analysis and Subjectivity", Indurkha, N, Damerau, F. J. (Ed.), *Handbook of Natural Language Processing*.
- Liu, B. (2012), *Sentiment Analysis and Opinion Mining*, Toronto: Morgan & Claypool Publishers
- Liu, B. (2020), *Sentiment Analysis: Mining Opinions, Sentiments, and Emotions*, Cambridge University Press.
- Manyika, J., Chui, M., Brown, B., Bughin, J., Dobbs, R., Roxburgh, C., Hung Byers, A. (2011), *Big Data: The Next Frontier for Innovation, Competition, and Productivity*, McKinsey Global Institute.

- Maynard, D., Funk, A. (2011), *Automatic Detection of Political Opinions in Tweets*, Berlin: Springer.
- Miner G., Delen, D., Elder, J., Fast, A., Hill, T., Robert A. (2012), *Practical Text Mining and Statistical Analysis for Non-structured Text Data Applications*, Massachusetts: Elsevier.
- Miner, G., Elder IV, J., Hill, T. (2012), *Practical Text Mining and Statistical Analysis for Non-structured Text Data Applications*, Academic Press.
- Mishkin, F. S. (2003), *The Economics of Money, Banking and Financial Markets*, (7th Edition), New York: Columbia University Press.
- Mucherino, A., Papajorgji, P. J., Pardalos, P. M. (2009), *Data Mining in Agriculture*, Springer Science & Business Media
- Nisbet, R., Elder, J., Miner, G. (2009), *Handbook of Statistical Analysis and Data Mining Applications*, Canada: Elsevier.
- Öztemel, E. (2006), *Yapay Sinir Ağları* (2. Baskı). Ankara: Papatya Yayıncılık.
- Özyurt, H. (2012), *Para Teorisi ve Politikası*, (3.Baskı), Trabzon: Derya Kitabevi.
- Pang, B., Lee, L., (2008), “Opinion Mining and Sentiment Analysis”, Liu, Y., Kelly, D. (Ed.), *Foundations and Trends in Information Retrieval*, 1-135.
- Poria, S., Hussain, A., Cambria, E. (2018), *Multimodal Sentiment Analysis*, Cham: Springer.
- Pozzi, F. A., Fersini, E., Messina, E., Liu, B. (2017), “Challenges of Sentiment Analysis in Social Networks: An Overview”, Pozzi, F.A., Fersini, E., Messina, E., Liu, B. (Eds.), *Sentiment Analysis in Social Networks*, 1-11.
- Prypto (2018), *Bitcoin For Dummies*, (Çev. E. Arıcan), İstanbul: Nobel Yaşam.
- Raykov, T., Marcoulides, G. A. (2006), *A First Course in Structural Equation Modeling*, London: Lawrence Erlbaum Associates.
- Rogers, E. M. (1995), *Diffusion of Innovations*, New York: Simon & Schuster Press.
- Rud, O. P. (2001), *Data Mining Cookbook; Modeling Data for Marketing, Risk, and Customer Relationship Management*, New York: John Wiley & Sons, Inc.
- Sarp-Nebil, F. (2018), *Bitcoin ve Kripto Paralar Sistemi Yıkan Bir Araç Olabilecek mi? Dünyada ve Türkiye'deki Gelişmeler*, (1.Baskı), İstanbul: Pusula 20 Teknoloji ve Yayıncılık A.Ş.
- Schumacker, R. E., Lomax, R.G. (2004), *A Beginner's Guide to Structural Equation Modeling* (2nd Edition), Mahwah: Lawrence Erlbaum Associates.
- Schwab, K. (2016), *Dördüncü Sanayi Devrimi*, (Çev. Z. Dicleli), Optimist Yayınevi.
- Simon, P. (2013), *Too Big to Ignore: The Business Case For Big Data*, Wiley.
- Singh, V. (2018), *Understand Blockchain in a Day: Your Guide to Understand Blockchain within 24 Hours*. Kindle Edition.

- Smith, T. P. (2013), *How Big is Big and How Small is Small: The Sizes of Everything and Why*, Oxford University Press.
- Tuckett, D. (2011), *Minding the Markets: An Emotional Finance View of Financial Instability*, London-New York: Palgrave MacMillan.
- Usta, A., Dođantekin, S. (2018), *Blockchain 101*. İstanbul: Bankalararası Kart Merkezi.
- Wattenhofer, R. (2016), *The Science of the Blockchain*, Inverted Forest Publishing.
- Yücel-İşbilen, L. (2017), *Veri Zarflama Analizi, Frontier Analyts ve WinDeap ile Portföy Etkinlik Ölçümü Örneđi ve Çeşitli Uygulamalar*, İstanbul: DER Yayınları
- Yüksel, E. (2001), *Medyanın Gündem Belirleme Gücü*, Konya: Çizgi Kitabevi.
- Zohar, E.Y. (2002), *Introduction to Text Mining, Supercomputing, Automated Learning Group National Center for Supercomputing Applications*, University of Illinois.

İnternet Kaynakları

- Bilgi Teknolojileri ve İletişim Kurumu (2020), *Kripto Para Araştırma Raporu*, Ankara. <https://www.btk.gov.tr/uploads/pages/arastirma-raporlari/kripto-para-raporu-5f11dfe709c25.pdf>
- Bitinfocharts, <https://bitinfocharts.com/comparison/tweets-btc-eth-xrp-ltc.html#log&3y> (Accessed Date: 30.05.2022).
- Brito, J., Castillo, A. (2013), “Bitcoin A Primer for Policymakers”. https://www.mercatus.org/system/files/Brito_BitcoinPrimer.pdf (Accessed Date: 30.04.2021).
- Britto, A., Schwart, D., Youngs, N. (2014), “The Ripple Protocol Consensus Algorithm”, https://ripple.com/files/ripple_consensus_whitepaper.pdf (Accessed Date: 30.04.2021).
- Buterin, V. (2013), “Ethereum White Paper”, *GitHub Repository*, 1: 22-23.
- Coinhills, <https://www.coinhills.com/market/currency/> (Accessed Date: 01.05.2021).
- CoinMarket, <https://coinmarketcap.com/currencies/bitcoin/> (Accessed Date: 01.05.2021).
- Çarkacıođlu, A. (2016), Kripto-Para Bitcoin, “Sermaye Piyasası Kurulu Araştırma Dairesi Araştırma Raporu”, <https://www.ekovizyon.com.tr/wp-content/uploads/2017/01/SPKBitcoin-Raporu.pdf> (Erişim Tarihi: 20.04.2021).
- Dilek, Ş. (2018), Blockchain Teknolojisi ve Bitcoin, (*Analiz, Siyaset, Ekonomi ve Toplum Araştırmaları Vakfı (SETA)*) <https://setav.org/assets/uploads/2018/02/231.-Bitcoin.pdf> (Erişim Tarihi: 30.04.2021).
- Dünya Bankası, *Financial Inclusion* www.worldbank.org/en/topic/financialinclusion (Accessed Date: 28 Nisan 2022).
- Ege Bölgesi Sanayi Odası Araştırma Müdürlüğü (2015), *Sanayi 4.0.*, www.ebso.org.tr/ebsoimedia/documents/sanayi-40_88510761.pdf (Erişim Tarihi: 09.05.2021).

- Frasco, M. (2019), *Metrics*, GitHub, <https://github.com/mfrasco/Metrics> (Erişim Tarihi: 21.06.2022).
- Gartner, I. (2016), “Gartner's 2016 Hype Cycle for Emerging Technologies Identifies Three Key Trends That Organizations Must Track to Gain Competitive Advantage” <https://gtnr.it/3vQRMxq> (Accessed Date: 14.04.2021).
- Google Trends, <https://trends.google.com/trends/?geo=TR> (Accessed Date: 01.05.2021).
- Hamilton, B. A. (2015), *The Field Guide to Data Science*, <https://124.im/iHP>
- Healey, C. G. (2017), Visualizing Twitter Sentiment, <https://124.im/IdPAZj>
- IDC (2018), *Data Age 2025*, www.seagate.com/files/www-content/ourstory/trends/files/idc-seagate-dataage-whitepaper.pdf (Accessed Date: 13 Nisan 2022).
- International Monetary Fund (IMF) (2018), *Global Financial Stability Report* (International Monetary Fund). <https://www.imf.org/en/Publications/GFSR/Issues/2018/04/02/Global-Financial-Stability-Report-April-2018>
- Mariano, R., Preve, D. (2008), *Statistical Tests for Multiple Forecast Comparison*, <https://twa.ckirby.su.domains/conference/Roberto%20Mariano.pdf> (Erişim Tarihi: 01.08.2022).
- Marketwatch (2021) <https://www.marketwatch.com/investing/fund/bitco> (Accessed Date: 01.12.2021).
- Merriam-Webster (2021), “Big Picture”, Merriam-Webster.com Dictionary. Merriam-Webster. <https://www.merriam-webster.com/dictionary/big+picture>
- Merriam-Webster, <https://www.merriam-webster.com/dictionary/emotion> (Accessed Date: 18.06.2022).
- Morde, V. (2019), “XGBoost Algorithm”, <https://towardsdatascience.com/https-medium-comvishalmorde-xgboost-algorithm-long-she-may-reinedd9f99be63d> (Erişim Tarihi: 20.07.2022).
- Nakamoto, S. (2008), “Bitcoin: A Peer-to-Peer Electronic Cash System”, <https://bitcoin.org/bitcoin.pdf> (Accessed Date: 20.04.2021).
- Sharma A. (2018), *Restricted Boltzman Machines-Simplified*, <https://towardsdatascience.com/restricted-boltzman-machines-simplified-eab1e5878976> (Accessed Date: 20.07.2022).
- Song, Y. (2016), “A Study of Bitcoin Price's Relationship with Local Currency Exchange Rate and Stock Market Index in Emerging Economies Using VECM”, *ETD Collection for Fordham University*. <https://research.library.fordham.edu/dissertations/AAI10246887/>.
- Sundaram, R. B. (2018, Eylül 06), *Understanding the Math behind the XGBoost Algorithm*, <https://www.analyticsvidhya.com/blog/2018/09/an-end-to-end-guide-to-understand-the-math-behind-xgboost/> (Erişim Tarihi: 27.07.2022).
- TC. Strateji ve Bütçe Başkanlığı (2019), On Birinci Kalkınma Planı. <https://www.sbb.gov.tr/wp-content/uploads/2019/07/OnbirinciKalkinmaPlani.pdf> (Erişim Tarihi: 16.12.2021).

- Wriston W, (1996), *The Future of Money*, Reporter: Thomas A. Bass, (Wired, 10 Ocak 1996).
<https://www.wired.com/1996/10/wriston/> (Accessed Date: 16.12.2021).
- Xu, X., Weber, I., Staples, M. (2019), *Architecture for Blockchain Applications*, Springer.
doi:10.1007/978-3-030-03035-3 (Accessed Date: 01.05.2021).
- Yermack, D. (2013), *Is Bitcoin a Real Currency? An Economic Appraisal*, (NBER Working Paper No: 19747), Cambridge: National Bureau of Economic Research Working Paper Series.
https://www.nber.org/system/files/working_papers/w19747/revisions/w19747.rev0.pdf



EKLER

Ek 1: Türkçe UTAUT Ölçeği

1: Kesinlikle Katılmıyorum

2: Katılmıyorum

3: Ne Katılıyorum Ne Katılmıyorum

4: Katılıyorum

5: Kesinlikle Katılıyorum

No	Aşağıdaki ifadelere katılım derecenizi (x) olarak işaretleyiniz.	1	2	3	4	5
1	Kripto para teknolojilerini kullanışlı buluyorum.	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
2	Kripto para teknolojileri yatırımlarımı daha hızlı yapmamı sağlamaktadır.	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
3	Kripto paralar, yatırım performansımı iyileştirmektedir.	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
4	Kripto para teknolojisine istediğim zaman erişim sağlayabildiğim için, esnek buluyorum.	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
5	Kripto para piyasası, geleneksel piyasalara (borsa, döviz vb.) kıyasla daha fazla bilgiye ulaşmama izin vermektedir.	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
6	Kripto para kullanımını açık ve anlaşılır buluyorum.	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
7	Kripto para teknolojisi kullanımında yetkinlik kazanmak benim için kolaydır.	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
8	Kripto para teknolojisi kullanımını kolay buluyorum.	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
9	Kripto para işlemleri kullanımını öğrenmek kolaydır.	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
10	Çevremdeki kişiler kripto para alım-satım işlemlerini yapmam gerektiğini düşünüyor.	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
11	Benim için önemli kişiler kripto para alım-satım işlemlerini yapmam gerektiğini düşünüyor.	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
12	Sosyal medya platformları, kripto para kullanımı konusunda destek olmaktadır.	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
13	Çevremdeki insanlar kripto para kullanmam konusunda destek olmaktadır.	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
14	Kripto para alım-satım işlemlerinde gerekli teknolojileri kullanmak için gereken kaynaklara sahibim.	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
15	Kripto para alım-satım işlemlerini gerçekleştirmek için yeterli bilgiye sahibim.	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
16	Kripto para piyasasında kullanılan teknolojiler, diğer geleneksel piyasaların (borsa, döviz vb.) teknolojilerine benzerdir.	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
17	Kripto para ile ilgili karşılaştığım problemleri çözmeye yardımcı olacak birilerini bulabilirim.	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
18	Gelecekte kripto para teknolojilerini kullanma niyetindeyim.	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
19	Gelecekte kripto para teknolojisini kullanacağımı tahmin ediyorum.	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
20	Gelecekte kripto para teknolojisini kullanmayı planlıyorum.	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
21	Günlük işlemlerde kripto para teknolojisinin kullanılacağını düşünüyorum.	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
22	Kripto para teknolojisi kullanarak yeni şeyler keşfetmeyi seviyorum.	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
23	Kripto para teknolojisi kullanıyor olmak iyi bir şeydir.	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
24	Kripto para teknolojisini sık sık kullanıyorum.	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
25	Kripto para işlemlerini gerçekleştirmek, geleneksel para birimlerine (dolar, euro vb.) göre daha kolaydır.	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>

Demografik Bilgiler

Cinsiyetiniz: Kadın Erkek

Yaşınız:

Aylık Geliriniz (TL cinsinden):

Son Mezun Olduğunuz Okul:

Sadece Okur-Yazar İlköğretim Lise Üniversite Yüksek Lisans Doktora

En sık kullandığınız sosyal medya platformu hangisidir?:

Twitter Instagram Facebook WhatsApp Linkedin Diğer:.....

Kripto paralardaki güncel gelişmeleri takip etmekte en sık kullandığınız sosyal medya platformu hangisidir?:

Twitter Instagram WhatsApp Linkedin Forum Siteleri Diğer:.....

Akıllı telefon, bilgisayar, tablet gibi cihazları günlük kaç saat kullanıyorsunuz?:

Gerçekleşen Yatırım Davranışı İçin Sorular

1. Aşağıda herhangi bir dönem içerisinde yer alan yatırım alternatifleri size sunulmaktadır. Geleneksel para ve kripto para piyasasının her ikisinde de aşağıdaki haberlerin yer aldığı bir dönem içerisinde olduğunuzu düşünerek, SAHİP OLDUĞUNUZ 1000 TL ile yatırım kararı vermeniz beklenmektedir. 1000 TL'niz ile gerçekleştireceğiniz yatırım nasıldır?



- Yatırım yapmam.
- Uzun vadede altın her zaman kazandırır.
- 1000 TL ile döviz alırım.
- 1000 TL ile kripto para birimlerinden alırım.
- 1000 TL'mi her ikisine eşit olarak bölerim.
- Daha yüksek miktarda döviz alıp, daha az kripto para alırım.
- Daha yüksek miktarda kripto para alıp, daha az döviz alırım.
- 1000 TL'nin yalnızca bir kısmıyla kripto para alır, kalanını harcamam.
- 1000 TL'nin yalnızca bir kısmıyla döviz alır, kalanını harcamam.
- Diğer

2. Aşağıda herhangi bir dönem içerisinde yer alan yatırım alternatifleri size sunulmaktadır. Geleneksel para ve kripto para piyasasının her ikisinde de aşağıdaki haberlerin yer aldığı bir dönem içerisinde olduğunuzu düşünerek, SİZE HİBE EDİLEN (KENDİ PARANIZ DEĞİL SİZE

HEDİYE OLARAK VERİLEN) 1000 TL ile yatırım kararı vermeniz beklenmektedir. 1000 TL'niz ile gerçekleştireceğiniz yatırım nasıldır?



- Yatırım yapmam.
- Uzun vadede altın her zaman kazandırır.
 - 1000 TL ile döviz alırım.
- 1000 TL ile kripto para birimlerinden alırım.
 - 1000 TL'mi her ikisine eşit olarak bölerim.
- Daha yüksek miktarda döviz alıp, daha az kripto para alırım.
- Daha yüksek miktarda kripto para alıp, daha az döviz alırım.
- 1000 TL'nin yalnızca bir kısmıyla kripto para alır, kalanını harcamam.
- 1000 TL'nin yalnızca bir kısmıyla döviz alır, kalanını harcamam.
- Diğer

3. Aşağıda herhangi bir dönem içerisinde yer alan yatırım alternatifleri size sunulmaktadır. Geleneksel para ve kripto para piyasasının her ikisinde de aşağıdaki haberlerin yer aldığı bir dönem içerisinde olduğunuzu düşünerek, SAHİP OLDUĞUNUZ 1000 TL ile yatırım kararı vermeniz beklenmektedir. 1000 TL'niz ile gerçekleştireceğiniz yatırım nasıldır?



- Yatırım yapmam.
- Uzun vadede altın her zaman kazandırır.
 - 1000 TL ile döviz alırım.
- 1000 TL ile kripto para birimlerinden alırım.
 - 1000 TL'mi her ikisine eşit olarak bölerim.
- Daha yüksek miktarda döviz alıp, daha az kripto para alırım.

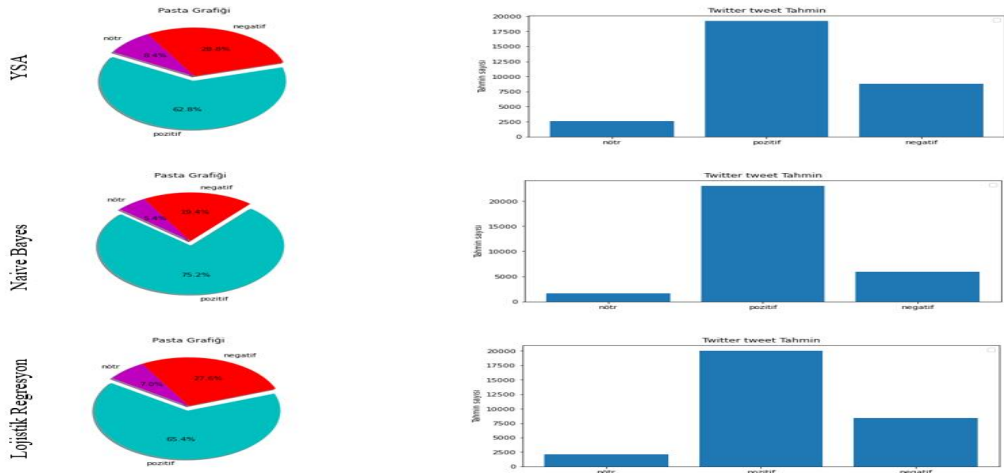
- Daha yüksek miktarda kripto para alıp, daha az döviz alırım.
- 1000 TL'nin yalnızca bir kısmıyla kripto para alır, kalanını harcamam.
- 1000 TL'nin yalnızca bir kısmıyla döviz alır, kalanını harcamam.
- Diğer

4. Aşağıda herhangi bir dönem içerisinde yer alan yatırım alternatifleri size sunulmaktadır. Geleneksel para ve kripto para piyasasının her ikisinde de aşağıdaki haberlerin yer aldığı bir dönem içerisinde olduğunuzu düşünerek, SİZE HİBE EDİLEN ((KENDİ PARANIZ DEĞİL SİZE HEDİYE OLARAK VERİLEN) 1000 TL ile yatırım kararı vermeniz beklenmektedir. 1000 TL'niz ile gerçekleştireceğiniz yatırım nasıldır?




- Yatırım yapmam.
- Uzun vadede altın her zaman kazandırır.
- 1000 TL ile döviz alırım.
- 1000 TL ile kripto para birimlerinden alırım.
- 1000 TL'mi her ikisine eşit olarak bölerim.
- Daha yüksek miktarda döviz alıp, daha az kripto para alırım.
- Daha yüksek miktarda kripto para alıp, daha az döviz alırım.
- 1000 TL'nin yalnızca bir kısmıyla kripto para alır, kalanını harcamam.
- 1000 TL'nin yalnızca bir kısmıyla döviz alır, kalanını harcamam.
- Diğer

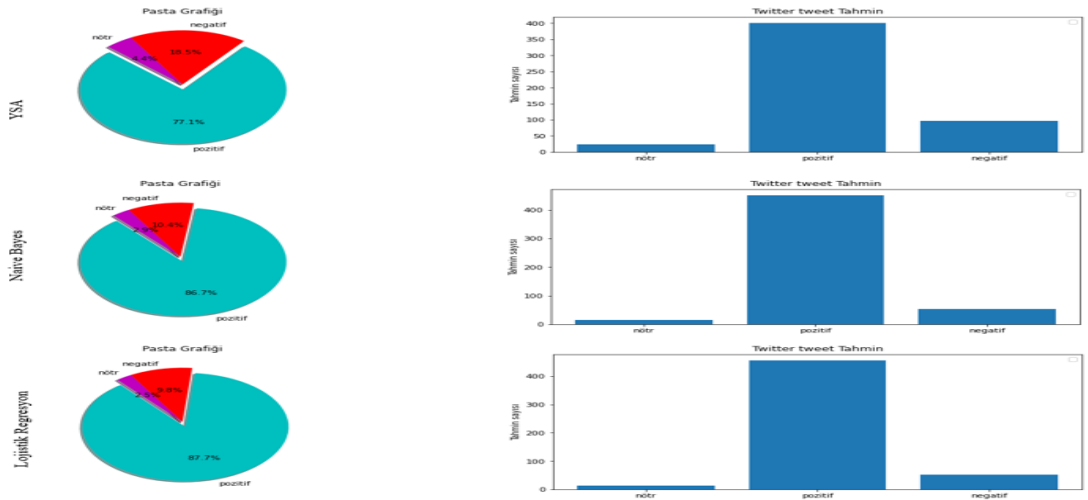
Ek 2: Duygu Analizi Sınıflandırıcı Algoritmaları Sınıflama Oranları





BTC Duygu Analizi Sınıflama Oranları (2020)




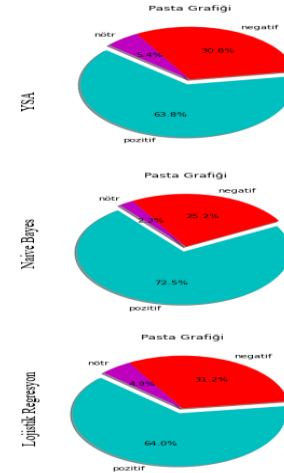
ETH Duygu Analizi Sınıflama Oranları (2020)





LTC Duygu Analizi Sınıflama Oranları (2020)





XRP Duygu Analizi Sınıflama Oranları (2020)





BTC Duygu Analizi Sınıflama Oranları (2021)



ETH Duygu Analizi Sınıflama Oranları (2021)



LTC Duygu Analizi Sınıflama Oranları (2021)



XRP Duygu Analizi Sınıflama Oranları (2021)