



**ÖNKESTİRİM AMAÇLI KULLANILAN
FARKLI YÖNTEMLERİN
KARŞILAŞTIRILMASI:
KRİPTO PARALAR ÜZERİNE BİR UYGULAMA**

YÜKSEK LİSANS TEZİ

Nefise FERMANCI

Danışman

Doç. Dr. Sinan SARAÇLI

İSTATİSTİK ANABİLİM DALI

Ekim 2021

AFYON KOCATEPE ÜNİVERSİTESİ

FEN BİLİMLERİ ENSTİTÜSÜ

YÜKSEK LİSANS TEZİ

**ÖNKESTİRİM AMAÇLI KULLANILAN
FARKLI YÖNTEMLERİN KARŞILAŞTIRILMASI:
KRİPTO PARALAR ÜZERİNE BİR UYGULAMA**

Nefise FERMANCI

Danışman

Doç. Dr. Sinan SARAÇLI

İSTATİSTİK ANABİLİM DALI

EKİM 2021

ÖZET

Yüksek Lisans Tezi

ÖNKESTİRİM AMAÇLI KULLANILAN FARKLI YÖNTEMLERİN KARŞILAŞTIRILMASI: KRİPTO PARALAR ÜZERİNE BİR UYGULAMA

Nefise FERMANCI

Afyon Kocatepe Üniversitesi

Fen Bilimleri Enstitüsü

İstatistik Anabilim Dalı

Danışman: Doç. Dr. Sinan SARAÇLI

Bu çalışmada saatlik ve günlük Bitcoin, Litecoin ve Ethereum kripto para birimlerine ait veri setleri kullanılarak, zaman serileri analizinde son yıllarda önemi gittikçe artan Bütünleşik Otoregresif Hareketli Ortalama (ARIMA), Yapay Sinir Ağları (YSA) ve ATA metotları yardımı ile önkestimler yapılarak elde edilen sonuçlar karşılaştırılmıştır. Gerçek değerlere en yakın sonuç veren modeli belirlemede Hata Kareler Ortalaması (HKO) değerleri dikkate alınarak modeller karşılaştırılmıştır.

Yapılan analiz sonuçlarında sırası ile ATA, YSA ve ARIMA modellerden elde edilen sonuçların gerçeğe en yakın ve bu metotlara ait HKO değerlerinin sırası ile en küçük olduğu gözlemlenmiştir. Çalışmadan elde edilen ayrıntılı sonuçlar ilgili şekil ve çizelgelerde verilmiştir.

2021, xi+96 sayfa

Anahtar Kelimeler: Zaman serileri, Bütünleşik otoregresif hareketli ortalama, Yapay sinir ağları, ATA metodu.

ABSTRACT

M.Sc. Thesis

COMPARISON OF DIFFERENT METHODS USED TO FORECAST: AN APPLICATION ON CRYPTOCURRENCIES

Nefise FERMANCI

Afyon Kocatepe University

Graduate School of Natural and Applied Sciences

Department of Statistics

Supervisor: Assoc. Prof. Sinan SARAÇLI

In this study, using datasets of hourly and daily Bitcoin, Litecoin and Ethereum cryptocurrencies, forecasting values are obtained with the help of Integrated Autoregressive Moving Average (ARIMA), Artificial Neural Networks (ANN) and ATA methods, which have become increasingly important in time series analysis in recent years. results were compared. In determining the model that gives the closest result to the real values, the mean squares of error (MSE) values are taken into account, and the models are compared.

In the analysis results, it was observed that the results obtained from the ATA, ANN and ARIMA models were the closest to the actual and the MSE values of these methods were the smallest, respectively. Detailed results obtained from the study are given in the relevant figures and tables.

2021, xi+96 pages

Keywords: Time series, Autoregressive integrated moving average, Artificial neural network, ATA method.

TEŞEKKÜR

Bu araştırmanın bütün aşamalarında gerek bilgi ve birikim gerekse motivasyon ve psikolojik destek olarak hiçbir zaman desteğini esirgemeyen, danışmandan öte iyi bir yol gösterici ve tecrübelerini aktaran iyi bir mentör olan, bir abi sıcaklığını ve samimiyetini her fırsatta hissettiren danışman hocam sayın Doç. Dr. Sinan SARAÇLI'ya sonsuz teşekkürlerimi sunarım. Çalışmanın uygulama kısmında samimi yardımlarını esirgemeyen sayın Dr. Ali Sabri TAYLAN hocama da ayrıca teşekkürlerimi sunarım.

Sadece yüksek lisans eğitimimde değil, tüm eğitim hayatımda maddi manevi her türlü desteği sağlayan her zaman yanımda olduklarını sonuna kadar hissettiren canım aileme sonsuz teşekkürlerimi sunarım.

Bu zorlu süreçte, desteğine ihtiyaç duyduğum her anda yanımda olduğunu hissettiren, başaracağıma inancını hiç yitirmeyen, beni her koşulda sonuna kadar destekleyen eşim Samet PEKSOY'a teşekkürlerimi sunarım.

Gerek ders gerekse tez döneminde beni her zorlukta destekleyen, enerjisiyle enerji veren, canım sıkıldığında benimle beraber üzülen, mutluluğum ile mutlu olan, hep destekleyen, kardeş sıcaklığını her seferinde hissettiren Şevkiye BABACAN'a ve Mustafa DEMİR'e teşekkürlerimi sunarım.

Nefise FERMANCI

Afyonkarahisar 2021

İÇİNDEKİLER DİZİNİ

Sayfa

ÖZET	i
ABSTRACT	ii
TEŞEKKÜR	iii
İÇİNDEKİLER DİZİNİ.....	iv
SİMGELER ve KISALTMALAR DİZİNİ	vi
ŞEKİLLER DİZİNİ	vii
ÇİZELGELER DİZİNİ.....	x
1. GİRİŞ.....	1
2. LİTERATÜR BİLGİLERİ	2
2.1 Kripto Para Birimleri	5
2.2 Zaman Serileri.....	6
2.2.1 Trend (Uzun Dönem Eğilim)	8
2.2.2 Mevsimsel (Seasonal) Dalgalanmalar	9
2.2.3 Konjonktürel (Cyclical) Dalgalanmalar	9
2.2.4 Düzensiz (Rassal) Hareketler	9
2.3 Durağanlık ve Durağan Olmama	11
2.3.1 Durağan Zaman Serileri	11
2.3.2 Durağan Olmayan Zaman Serileri	12
2.4 Otokorelasyon Fonksiyonu (OKF, ACF).....	13
2.5 Kısmi Otokorelasyon Fonksiyonu (KOKF, PACF).....	14
2.6 Box-Jenkins Metodolojisi (B.J)	15
2.7 Doğrusal Durağan Stokastik Modeller.....	17
2.7.1 Otoregresif Model (AR).....	17
2.7.2 Hareketli Ortalama Modeli (MA)	17
2.7.3 Otoregresif Hareketli Ortalama (ARMA) Modeli.....	18
2.8 Durağan Olmayan Doğrusal Stokastik Modeller	18
2.9 Yapay Sinir Ağları (YSA)	22
2.9.1 Aktivasyon Fonksiyonu	24
2.9.2 Yapay Sinir Ağlarında Öğrenme Algoritması.....	24
2.9.2.1 Geri Yayılım Algoritması.....	25

2.9.2.2 Levenberg-Marquardt Algoritması	25
2.10 ATA Metot.....	27
2.10.1 ATA (p,0) Temel Formu	27
2.10.2 ATA (p,0)'nın Ağırlıkları.....	28
2.10.3 ATA (p,0)'nın Ortalama Yaşı, (k)	29
2.10.4 ATA (p,0)'nın Ağırlıklandırılmış Kareler Toplamı (V)	30
2.10.5 ATA (p,0)'ın Temel Değerinin Ağırlığı	31
2.10.6 ATA (p,0)'ın Düzeltme Parametresi	32
3. MATERYAL ve METOT	35
4. BULGULAR	36
5. TARTIŞMA ve SONUÇ	88
6. KAYNAKLAR.....	90
ÖZGEÇMİŞ.....	96

SİMGELER ve KISALTMALAR DİZİNİ

Simgeler

X	Orijinal zaman serisi verisi
T	Zaman serisindeki son gözlem değeri
μ	Aritmetik ortalama
σ	Standart sapma
σ^2	Varyans
γ_k	Kovaryans
Corr	Korelasyon
$\rho(k)$	Otokorelasyon fonksiyonu
ϕ_n	n'inci kısmi otokorelasyon katsayısı
ε_t	1'den n'e kadar zaman aralığında rasgele hata
P	Otoregresif model sırası
D	Fark işlemi sırası
Q	Hareketli ortalama sırası
w_i	Girdi ağırlıkları
x_i	Girdi elemanları
$\bar{k}$	ATA (p,0)'ın ortalama yaşı
V	Belirtilen ağırlıkların kareler toplamı

Kısaltmalar

ABÖ	Akaike bilgi ölçütü
AR	AutoRegressive (OtoRegresif)
ARMA	AutoRegressive moving average (OtoRegresif hareketli ortalama)
ARIMA	Autoregressive integrated moving average (OtoRegresif bütünleşik hareketli ortalama)
B. J.	Box-Jenkins
ES	Exponential smoothing (üstel düzeltme)
HKO	Hata kareler ortalaması
KOKF	Partial autocorrelation function (kısmi otokorelasyon fonksiyonu)
LM	Levenberg-Marquardt
MA	Moving average (hareketli ortalama)
MAPE	Mean absolute percentage error (ortalama mutlak yüzde hata)
OKF	Autocorrelation function (otokorelasyon fonksiyonu)
OY	ATA (p,0)'ın ortalama yaşı
SBÖ	Schwarz bilgi ölçütü
SES	Simple exponential smoothing (basit üstel düzeltme)
sMAPE	symmetric mean absolute percentage error (simetrik ortalama mutlak yüzde hata)
YSA	Yapay sinir ağları

ŞEKİLLER DİZİNİ

	Sayfa
Şekil 2.1 Gerçekleşmesi muhtemel trend modelleri.	8
Şekil 2.2 Box ve Jenkins yönteminde model belirleme aşamaları.....	16
Şekil 2.3 Biyolojik Nöron Yapısı	23
Şekil 2.4 Yapay sinir ağları modeli.....	23
Şekil 4.1 Saatlik Bitcoin verisine ait korelogram.	36
Şekil 4.2 Saatlik Bitcoin verisine ait zaman serisi grafiği.	37
Şekil 4.3 Saatlik Ethereum verisine ait korelogram.....	39
Şekil 4.4 Saatlik Ethereum verisine ait zaman serisi grafiği.	39
Şekil 4.5 Saatlik Litecoin verisine ait korelogram.....	41
Şekil 4.6 Saatlik Litecoin verisine ait zaman serisi grafiği.....	42
Şekil 4.7 Günlük Bitcoin verisine ait korelogram.	44
Şekil 4.8 Günlük Bitcoin verisine ait zaman serisi grafiği.	45
Şekil 4.9 Günlük Ethereum verisine ait korelogram.....	47
Şekil 4.10 Günlük Ethereum verisine ait zaman serisi grafiği.....	48
Şekil 4.11 Günlük Litecoin verisine ait korelogram.....	50
Şekil 4.12 Günlük Litecoin verisine ait zaman serisi grafiği.....	51
Şekil 4.13 Saatlik Bitcoin verisine ait yapay sinir ağları modeli.	53
Şekil 4.14 Saatlik Bitcoin verisi için zamana göre çıktı, hedef ve hatalar.....	54
Şekil 4.15 Saatlik Bitcoin verisinin eğitim, doğrulama ve test kümelerine ait hata performansları.....	55
Şekil 4.16 Modeldeki gizli katmanda eğitim, doğrulama, test ve tüm model sonuçlarına ait R değerleri.	56
Şekil 4.17 Saatlik Bitcoin verisine ait gizli katman ile oluşan hata grafiği.	57
Şekil 4.18 Saatlik Bitcoin verisine ait sonraki 24 saatlik önkestirim grafiği.....	58
Şekil 4.19 Saatlik Ethereum verisi için zamana göre çıktı, hedef ve hatalar.	58
Şekil 4.20 Saatlik Ethereum verisinin eğitim, doğrulama ve test kümelerine ait hata performansları.....	59
Şekil 4.21 Modeldeki gizli katmanda eğitim, doğrulama, test ve tüm model sonuçlarına ait R değerleri.	60
Şekil 4.22 Saatlik Ethereum verisine ait gizli katman ile oluşan hata grafiği.	60

Şekil 4.23	Saatlik Ethereum verisine ait sonraki 24 saatlik önkestirim grafiği.	61
Şekil 4.24	Saatlik Litecoin verisi için zamana göre çıktı, hedef ve hatalar.	62
Şekil 4.25	Saatlik Litecoin verisinin eğitim, doğrulama ve test kümelerine ait hata performansları.	63
Şekil 4.26	Modeldeki gizli katmanda eğitim, doğrulama, test ve tüm model sonuçlarına ait R değerleri.	64
Şekil 4.27	Saatlik Litecoin verisine ait gizli katman ile oluşan hata grafiği.	65
Şekil 4.28	Saatlik Bitcoin verisine ait sonraki 24 saatlik önkestirim grafiği.	65
Şekil 4.29	Günlük Bitcoin verisine ait yapay sinir ağı modeli.	66
Şekil 4.30	Günlük Bitcoin verisi için zamana göre çıktı, hedef ve hatalar.	67
Şekil 4.31	Günlük Bitcoin verisinin eğitim, doğrulama ve test kümelerine ait hata performansları.	67
Şekil 4.32	Modeldeki gizli katmanda eğitim, doğrulama, test ve tüm model sonuçlarına ait R değerleri.	68
Şekil 4.33	Günlük Bitcoin verisine ait gizli katman ile oluşan hata grafiği.	69
Şekil 4.34	Günlük Bitcoin verisine ait sonraki 7 günlük önkestirim grafiği.	69
Şekil 4.35	Günlük Ethereum verisi için zamana göre çıktı, hedef ve hatalar.	70
Şekil 4.36	Günlük Ethereum verisinin eğitim, doğrulama ve test kümelerine ait hata performansları.	70
Şekil 4.37	Modeldeki gizli katmanda eğitim, doğrulama, test ve tüm model sonuçlarına ait R değerleri.	71
Şekil 4.38	Günlük Ethereum verisine ait gizli katman ile oluşan hata grafiği.	72
Şekil 4.39	Günlük Ethereum verisine ait sonraki 7 günlük önkestirim grafiği.	72
Şekil 4.40	Günlük Litecoin verisi için zamana göre çıktı, hedef ve hatalar.	73
Şekil 4.41	Günlük Litecoin Verisinin eğitim, doğrulama ve test kümelerine ait hata performansları.	73
Şekil 4.42	Modeldeki gizli katmanda eğitim, doğrulama, test ve tüm model sonuçlarına ait R değerleri.	74
Şekil 4.43	Günlük Litecoin verisine ait gizli katman ile oluşan hata grafiği.	75
Şekil 4.44	Günlük Litecoin verisine ait sonraki 7 günlük önkestirim grafiği.	75
Şekil 4.45	Saatlik Bitcoin verisine ait gerçek-önkestirim değer karşılaştırma grafiği.	80

Şekil 4.46	Saatlik Ethereum verisine ait gerçek-önkestirim değer karşılaştırma grafiği.	82
Şekil 4.47	Saatlik Litecoin verisine ait gerçek-önkestirim değer karşılaştırma grafiği.	84
Şekil 4.48	Günlük Bitcoin verisine ait gerçek-önkestirim değer karşılaştırma grafiği.	85
Şekil 4.49	Günlük Ethereum verisine ait gerçek-önkestirim değer karşılaştırma grafiği.	86
Şekil 4.50	Günlük Litecoin verisine ait gerçek-önkestirim değer karşılaştırma grafiği.	87



ÇİZELGELER DİZİNİ

	Sayfa
Çizelge 2.1 ATA(p,0) tarafından gözlemlere eklenen ağırlıklar.	29
Çizelge 4.1 Saatlik Bitcoin verisine ait ADF test istatistik sonucu.	37
Çizelge 4.2 Birinci dereceden farkı alınmış saatlik Bitcoin verisinin ADF test istatistik sonucu.	38
Çizelge 4.3 Saatlik Bitcoin serisine ait ARIMA modeli.	38
Çizelge 4.4 Saatlik Ethereum verisine ait ADF test istatistik sonucu.	40
Çizelge 4.5 Birinci dereceden farkı alınmış saatlik Ethereum verisinin ADF test istatistik sonucu.	40
Çizelge 4.6 Saatlik Ethereum serisine ait ARIMA modeli.	41
Çizelge 4.7 Saatlik Litecoin verisine ait ADF test istatistik sonucu.	42
Çizelge 4.8 Birinci dereceden farkı alınmış saatlik Litecoin verisinin ADF test istatistik sonucu.	43
Çizelge 4.9 Saatlik Litecoin serisine ait ARIMA modeli.	43
Çizelge 4.10 Günlük Bitcoin verisine ait ADF test istatistik sonucu.	45
Çizelge 4.11 İkinci dereceden farkı alınmış günlük Bitcoin verisinin ADF test istatistik sonucu.	46
Çizelge 4.12 Günlük Bitcoin serisine ait ARIMA modeli.	46
Çizelge 4.13 Günlük Ethereum verisine ait ADF test istatistik sonucu.	48
Çizelge 4.14 Birinci dereceden farkı alınmış günlük Ethereum verisinin ADF test istatistik sonucu.	49
Çizelge 4.15 Günlük Ethereum serisine ait ARIMA modeli.	49
Çizelge 4.16 Günlük Litecoin verisine ait ADF test istatistik sonucu.	51
Çizelge 4.17 Birinci dereceden farkı alınmış günlük Litecoin verisinin ADF test istatistik sonucu.	52
Çizelge 4.18 Günlük Litecoin serisine ait ARIMA modeli.	52
Çizelge 4.19 ATA metot ile kripto para birimleri model belirleme.	76
Çizelge 4.20 Saatlik veri setlerine ait önkestirim sonuçları.	77
Çizelge 4.21 Kripto Paralara ait HKO değerleri.	78
Çizelge 4.22 Bitcoin için saatlik gerçek ve önkestirim değerleri.	79
Çizelge 4.23 Ethereum için saatlik gerçek ve önkestirim değerleri.	81

Çizelge 4.24 Litecoin için saatlik gerçek ve önkestim değerleri.	83
Çizelge 4.25 Bitcoin için günlük gerçek ve önkestim değerleri.	85
Çizelge 4.26 Ethereum için günlük gerçek ve önkestim değerleri.	86
Çizelge 4.27 Litecoin için günlük gerçek ve önkestim değerleri.	87



1. GİRİŞ

Son yıllarda değişerek artan ihtiyaçlar, zorlaşan hayat şartları ve daha güvenilir yatırım araçları bulma, daha fazla kazanma isteği gibi kişisel çıkarlar gelişen teknoloji ile birlikte insanları süregelen para birimleri ve yatırım araçlarından farklı alanlara ilgi duymaya sürüklemiştir. Günümüzde bankalar üzerinden kısıtlı zamanlarda daha az işlem yapma olanağı sağlayan yatırım araçlarının aksine, kolay ulaşılabilen ve yönetilebilen, anlık işlem yapabilme olanağı sağlayan kripto paralar farklı ülkelerde yatırım ve alışveriş aracı olarak kabul görmektedir.

Önkestirimde bulunmak, birçok alanda insanlar için önemli bir ihtiyaç haline gelmiştir. Önkestirime ihtiyaç duyulan alanlara şirketlerin gelecek dönem satışları için önkestirimde bulunmak istemesi, yatırım amacı ile kullanılacak araçların ne yönde seyredeceğinin öğrenilmek istenmesi, yapılacak çalışmalara yol gösterici olması için hava durumu önkestirimlerinin elde edilmesi, günümüzün bulaşıcı hastalığı olan covid-19'un geçmiş dönem verileri ile gelecek dönem ilerleyişinin izlenmesi vb. birçok örneğin verilmesi mümkündür.

Önkestirim yaparken en önemli nokta önkestirim yapmaya uygun bir zaman serisi belirlemektir. Günlük hayatta pek çok alanda karşımıza zaman serileri çıkmaktadır. Bu durum da zaman serilerine ve zaman serileri kullanılarak önkestirimde bulunmaya olan ilgiyi, önemi yadsınamayacak bir noktaya taşımaktadır.

Bu çalışmada ARIMA, YSA ve ATA metotları kullanılarak hatası en küçük modeli belirlemek ve belirlenen model ile gerçek değerlere en yakın önkestirim değerlerini elde etmek amaçlanmıştır.

2. LİTERATÜR BİLGİLERİ

Kripto para birimi, güvenlik için kriptografi kullanan dijital ya da sanal bir para birimidir. Kripto paranın özüne girmeden önce paranın tanımını anlamak gerekir. Ekonomistlerin çoğu, parayı bir değiş tokuş aracı, muhasebe birimi ve değer deposu olarak tanımlamaktadır. Paranın değerli olabilmesi için; yeterince insan paraya sahip olmalı, satıcılar bunu bir ödeme şekli olarak kabul etmeli ve toplum paranın değerli olduğuna ve gelecekte de değerli kalacağına güvenmelidir gibi özelliklere sahip olması gerekir. Eski zamanlarda da eşyaların takas edilmesi alışverişin doğasını oluşturmuştur. Daha sonralarda ise sırasıyla nakit para ve kredi kartları devreye girdi, böylece paranın tanımı ve daha da önemlisi paranın güven modeli değişmiştir. Paradaki bir diğer önemli değişiklik ise işlem kolaylığı olmuştur. Altın külçelerini bir ülkeden diğer ülkelere taşıma zorluğu nakit icadının ana sebeplerinden birisi olmuştur. Daha sonraları farklı ihtiyaçlar çıkınca ve insanlar tembellesince kredi kartları icat edilmiştir. Ancak kredi kartları hükümetin kontrolündeki parayı taşımaktadır. Dünya ülkeleri birbiriyle daha bağlantılı hale geldikçe ve insanların çıkarlarını en iyi şekilde düşünen ya da düşünmeyen otoritelerle daha fazla ilgilendikçe kripto para birimleri insanlar için değerli bir alternatif haline gelmiştir. Kriptografi kullanımı ile oluşan güvenlik özelliğinden dolayı kripto para biriminin sahtesini yapmak zordur. Bir kripto paranın tanımlayıcı özelliği ve tartışmasız en büyüleyici yanı, herhangi bir merkezi otorite tarafından çıkarılmamış olmasıdır. Bu da kripto parayı devlet müdahalesine veya manipülasyona karşı teorik olarak bağımsız kılmaktadır (Danial 2019, Bunjaku vd. 2017).

Kripto para birimlerinin avantajları ve dezavantajları vardır. Kripto para kullanımının ana faydaları arasında, güvenli amaçlar için özel anahtarlar ve halkın kullanımı aracılığıyla bir işlemde iki taraf arasında para transferini kolaylaştırması yer almaktadır. Bu işlemler minimum işlem ücreti ile yapılır. Çoğu bankanın internet tabanlı işlemlerinde talep ettiği yüksek ücretlerden kaçınmaya imkan tanır. Buna karşılık bilgisayar korsanlığı tehdidi kripto para birimi ödeme sisteminin en büyük tehdididir. Uzun kripto para birimleri listesinde Bitcoin piyasa değeri açısından liderdir. Litecoin

ve Ethereum gibi bazı kripto para birimlerinde daha az bir artan trend vardır (Bunjaku vd. 2017).

Chatfield (2000)'e göre zaman serisi zaman içinde sırayla ölçülen bir dizi gözlemdir. Bu ölçümler, sürekli olarak zaman içinde yapılabilir veya ölçüm yapılan süredeki farklı zaman dilimlerinden alınabilir. Geleneksel olarak bu iki tür seri sırası ile sürekli ve ayrık zaman serileri olarak adlandırılmaktadır.

Zaman serisi, yıllık, aylık, haftalık, günlük, saatlik gibi eşit aralıklı zaman dilimleri içinde toplanan gözlemlerin sıralanmasıyla oluşur. Zaman serileri ekonomi, mühendislik, meteoroloji, işletme, deniz bilimi, jeofizik, sağlık, eğitim vb. gibi alanlarda; firmaların harcamaları, satış ve alış rakamları, ihracat, ithalat miktarları, hisse senedi fiyatları, nüfus ölçümleri, hava sıcaklığı değerleri gibi farklı yapılarda, birçok zaman serisi türleri ortaya çıkar. Mühendislikte ve ekonomide çok karşılaşılmakla beraber özellikle istatistik alanında zaman serisi analiz yöntemleri önemli bir alanı oluşturmaktadır (Bölük 2012).

Bir literatür taramasına göre mevcut metodolojiler, öngörü ve önkestirim görevleri için sıklıkla kullanılmasına rağmen, kapsamlı ve karmaşık karar desteği için yeterli bilgi sağlamadıklarından genel olarak kötü performans gösterirler. Bu temel yöntemler yalnızca belirleyici nokta önkestirimleri veya basit aralık önkestirimleri sağlamaktadır. Bu durumda daha fazla istatistik ve belirsizlik analizi gerekmektedir. Bunu uygulamak için mevcut yöntemler geliştirilmeli veya yeni gelişmiş yöntemler araştırılmalıdır. Box-Jenkins gibi gelişmiş önkestirim yöntemleri içerdiği karmaşıklık nedeniyle uygulamalarda nadiren kullanılır (Lu ve AbouRizk 2009).

Box-Jenkins yönteminde hangi modelin kullanılacağına karar verirken ortalama, varyans, otokovaryans, otokorelasyon fonksiyonu, kısmi otokorelasyon fonksiyonu ve korelogram gibi araçlar kullanılabilir (Duru 2007).

Ataseven (2013)'e göre Box-Jenkins modelleri doğrusal zaman serileri analizinde oldukça başarılı sonuçlar vermektedir. Buna karşılık yapay sinir ağları (YSA) doğrusal

zaman serilerine ek olarak doğrusal olmayan modellemeyi de gerçekleştirebilme özelliğine sahiptir. Böylece YSA önkestirimde bulunurken diğer yöntemlere göre daha iyi sonuçlar verebilmektedir. YSA ile önkestirim yapma konusunda pek çok çalışma yapılmış olmasına rağmen YSA'da performansı etkileyen ana faktörlerin neler olduğuna dair kesin bir yargı yoktur.

Yapar (2018)'a göre zaman serisi verileri, bir şeyin herhangi bir zamanda gözlemlendiğinde, birçok farklı bağlamda ortaya çıkmaktadır. Bu durumda ana amaç bazı değişkenlerin bir dizi gözlemini kullanarak değişkenin gelecekteki değerini önkestirim etmektir. Bu, gelecekteki değerleri önkestirim etmek için geçmiş gözlemlerin bir kısmı kullanılarak elde edilir.

Yapar vd. (2019)'ne göre, yapılan çalışmada yeni bir önkestirim yaklaşımı olan ATA yöntemi tanıtılmış ve iki ana önkestirim yaklaşımı olan üstel düzeltme (exponential smoothing(ES)) ve ARIMA yaklaşımlarına alternatif olan bu yeni önkestirim yönteminin önkestirim doğruluğu değerlendirilmiştir. Çalışmada M3-yarışmasından elde edilen sonuçları kullanarak, bu yöntemin önkestirim performansı bu iki yaklaşıma ek olarak doğruluk ve basitlik açısından da karşılaştırılmıştır. Bu yarışmanın başlangıcından bu yana yapılan araştırmalar temel olarak üstel düzeltme ve ARIMA'nın belirli dönüşümlerine, ayrıştırmalarına, kurallarına ve kombinasyonlarına odaklanmaktadır. ATA modellerinin işlevsel biçimi genellikle üstel düzeltme modellerine çok benzer olsa da, bu iki yaklaşımı birbirinden ayıran özellik, gözlemlere atanan ağırlıklardır. En son gözleme eşit ağırlık atayan ATA ve üstel düzeltme modelleri karşılaştırıldığında ATA üstel düzeltmeye göre uzak geçmişe daha az, yakın geçmişteki gözlemlere daha fazla ağırlık verme eğilimindedir. Tüm üstel düzeltme modelleri başlatma gerektirirken ve başlangıç değerleri özellikle α ve n 'in küçük değerleri için önkestirimlerin kalitesini etkilerken, ATA başlatma gerektirmez ve parametre değerleri tamsayılarla sınırlandırıldığından diğer parametrelerin optimizasyonu daha basit ve hızlıdır.

M-yarışmaları, kendi uzmanlık yöntemleri için önkestirimler sağlayan uzman kişilerin kullandığı, çok sayıda ana zaman serisi yönteminin performansını karşılaştıran deneysel

alıřmalardır (Makridakis ve Hibon, 2000). M3 yarıřmasında veri toplama, her biri rakip yöntemlerin örnek dıřı performanslarını test etmek için kullanılan önceden belirlenmiř sayıda veri noktasına sahip olan 3003 zaman serisi veri setinden oluřur (Yapar vd. 2018).

2.1 Kripto Para Birimleri

Bitcoin 2009 yılında açık kaynak kodlu olarak piyasaya ıkan ilk kripto para birimidir. Kaynak kodu açık olduđu için günümüzde mevcut Bitcoin'in orijinali ile uyumlu binlerce eřidi vardır. Bu eřitlerine alternatif dijital para birimleri anlamına gelen alt coin denilmektedir (Matharu 2019).

Bitcoin kripto para birimi ve dünya apında geerli olan ödeme sistemidir. Tek yönetici ya da bir merkez bankası olmaksızın alıřan bir sistem olarak ilk merkezi olmayan dijital para birimidir. Ağ eřler arasındadır ve işlemler kullanıcılar arasında aracı olmadan, doğrudan geekleřir. Bu işlemler, kriptografi kullanılarak ağ düğümleri tarafından doğrulanır ve blok zinciri adı verilen halka açık olarak dağıtılmış bir ana hesap defterine kaydedilir. Bitcoin, Satoshi Nakamoto adı altında bilinmeyen bir kiři veya bir grup insan tarafından icat edilmiřtir ve 2009'da açık kaynaklı yazılım olarak piyasaya sürülmüřtür. Bitcoin madencilik olarak bilinen bir sürecin karřılıđı olarak oluřturulmuřtur. Diđer para birimleri, ürünler ve hizmetler ile deđiřtirilebilmektedir. řubat 2015 itibariyle, 100.000'den fazla tüccar ve satıcı, Bitcoin'i ödeme aracı olarak kabul etmiřtir. Cambridge Üniversitesi tarafından 2017 yılında çođu Bitcoin kullanan kullanıcılardan oluřan, kripto para cüzdanı kullanan 2.9 ila 5.8 milyon arasında benzersiz kullanıcı olduđunu gösteren bir arařtırma üretilmiřtir (Bhosale ve Mavale 2018).

Ethereum, küçük bir ücret karřılıđında herkese kripto para göndermeye izin veren bir teknolojidir. Dünyanın programlanabilir blok zinciridir. Bazı büyük farklılıklarla birlikte Bitcoin'in yeniliđi üzerine inşa edilmiřtir. Her ikisi de parayı ödeme sađlayıcıları veya bankalar olmadan kullanılmasına izin vermektedir (İnt.Kyn.1).

Ethereum kripto para birimi açık kaynak kodlu, blok zinciri tabanlı hesaplama sistemine sahip halka açık bir platformdur. Akıllı komut olanağına sahiptir. İşlem tabanlı ödeme sistemi ile Nakamoto'nun kripto para biriminin değiştirilmiş versiyonu üzerinde çalışmaktadır. Ethereum ilk olarak bilgisayar programcısı ve kripto para birimi araştırmacısı olan Vitalik Buterin tarafından tanıtılmıştır. Ethereum ile ilgili yazılım geliştirme 2014 Temmuz ve Ağustos arasında çevrimiçi bir kitle satışıyla finanse edilmiştir ve 30 Temmuz 2015'te bir sistem geliştirmesi ile hayata geçirildi. Başlangıçta kitle satışına hazır 11.9 milyon coin'e sahipti. Bu satış miktarı, dolaşımdaki toplam para biriminin neredeyse %13'ü idi. Ethereum para biriminin fiyatı 2014'ten 2017'ye kadar %13.000'in üzerinde arttı (Bhosale ve Mavale 2018).

Litecoin, Bitcoin ile farklı noktaları olmakla beraber benzer bir işleyişe sahiptir. 2011 Ekim ayında Charles Lee tarafından kurulmuştur. Bitcoin'in sahip olduğu eksiklikleri gidermek amacıyla oluşturulmuştur ve başarı sağlamıştır. Bitcoin ile Litecoin arasındaki fark, Bitcoin madenciliği için, nispeten daha az işlem gücüne sahip normal bir masaüstü bilgisayar tarafından çıkarılabilen Litecoin'in aksine, ağır ön işleme ve hızlı hesaplamanın gerekli olmasıdır. Diğer kripto para birimleri gibi Litecoin de blok zinciri sistemi üzerine işlem görmektedir ve Bitcoin'e nazaran daha yüksek hızda blok oluşturmaktadır. Bundan dolayı Litecoin ile yapılan işlemler daha kısa sürede gerçekleşmektedir (İnt.Kyn.2, Bhosale ve Mavale 2018).

2.2 Zaman Serileri

Zaman serisinin tipik olan içsel bir özelliği bitişik gözlemlerin birbirleri ile bağımlı olmasıdır. Bir zaman serisinin gözlemleri arasındaki bu bağımlılığın doğası, pratik açıdan oldukça ilgi çekicidir. Zaman serisi analizi, bu bağımlılığın analizindeki tekniklerle ilgilidir. Bu, zaman serisi verileri için stokastik ve dinamik modellerin geliştirilmesini ve bu tür modellerin önemli uygulama alanlarında kullanılmasını gerektirir (Box vd. 1994).

Zaman serisi analizi çalışmanın ana nedenlerinden bir tanesi gelecek veri önkestiminde bulunmaktır (Uzel 2008).

Zaman serisi önkestirimi, aynı değişkenin geçmiş gözlemlerinin toplandığı ve temeldeki ilişkinin tanımlandığı bir model geliştirmek için analiz edildiği önemli bir alandır. Geliştirilen model daha sonra zaman serilerinin gelecek değer önkestiriminde kullanılır. Bu modelleme yaklaşımı özellikle altta yatan veri üretme sürecinde çok az bilgi mevcut olduğunda veya önkestirim edici bir açıklama olmadığında faydalıdır. Son birkaç on yılda, zaman serisi önkestirim modellerinin geliştirilmesi ve iyileştirilmesi için çok çaba sarf edilmiştir (Zhang 2003).

Gözlenen bir zaman serisinin gelecekteki değerlerinin önkestirim edilmesi ekonomi, üretim planlaması, satış önkestirimi ve stok kontrolü gibi alanları da içeren pek çok alanda önemli bir problemidir (Chatfield ve Xing 2019).

Zaman serisi temel bileşenleri, trend, mevsimsel dalgalanmalar, konjonktürel dalgalanmalar ve rassal dalgalanmalar olmak üzere dört etkenin etkisi altında meydana gelirler. Zaman serilerinde, iç bağımlılık olarak da adlandırılabilen, gözlem değerlerinin birbirine bağlı olması nedeniyle zaman serisinin geçmiş gözlem değerleri arasındaki ilişki saptanarak, ileriye dönük öngöründe bulunulur (Yolcu 2008).

Zaman serisinin bu dört ana bileşeni:

T=Trend (Uzun Dönem Eğilim)

S=Mevsimsel (Seasonal) Dalgalanmalar

C=Konjonktürel (Cyclical) Dalgalanmalar

I=Düzensiz (Rassal) Hareketler

X_t zaman serisi gözlem değerleri olmak üzere bu dört bileşenin seri üzerindeki etkisi çarpımsal ve toplamsal şekilde gösterilmektedir. Toplamsal yaklaşımda serinin bu dört bileşenin toplamından oluştuğu varsayılır ve

$$X_t = T + S + C + I \quad (2.1)$$


denklem 2.1 ile gösterilir. Çarpımsal yaklaşımda ise zaman serisinin bu dört bileşenin çarpımından oluştuğu varsayılır, denklem 2.2 ile ifade edilir (Demirkoparan 2010).

$$X_t = TSCI \quad (2.2)$$

2.2.1 Trend (Uzun Dönem Eğilim)

Zaman serileri genel olarak Kartezyen koordinatlı bir grafikte gösterilir. Grafiğin x ekseninde zaman değişkeni, y ekseninde gözlem değerleri yer alır. Zaman değişkenine karşılık gelen gözlem değerleri koordinat sisteminde işaretlendiğinde noktalar diyagramı elde edilir. Zaman serilerine ait dağılım diyagramında noktalar ekseriyetle bir doğru etrafında toplanmışsa trendin yani genel eğilimin doğrusal (lineer) olduğu söylenebilir. Trendin yön ve şiddeti her zaman aynı kalmaz. Trend doğrusal ya da eğrisel olabilmektedir (Oğhan 2010).

Gerçekleşmesi muhtemel trend modelleri Şekil 2.1’de gösterilmekle beraber bu şekilde (c) ve (e) parabolik artış ve azalışı, (d) ve (f) ise üstel artış ve azalışı ifade etmektedir (Özek 2010).



Şekil 2.1 Gerçekleşmesi muhtemel trend modelleri.

2.2.2 Mevsimsel (Seasonal) Dalgalanmalar

Zaman serileri yıllık değil de, haftalık, aylık, üç aylık gibi yıl içindeki zaman birimlerine göre düzenlenmişlerse, bu durumda mevsim hareketleri denen kısa dönem hareketlerinin olup olmadığı araştırılır. Bu hareketler varsa, bunlar incelenir ve gerektiğinde mevsim katsayıları hesaplanarak hem bazı öngörüler için kullanılırlar hem de bunlar yardımıyla seri mevsim etkisinde arındırılarak, diğer hareketler incelenir (Uslu 2011).

2.2.3 Konjonktürel (Cyclical) Dalgalanmalar

Konjonktür dalgalanmaları sistematik bir karaktere sahip olup, ekonomik olaylarda meydana gelirler. Bu dalgalanmalar kısaca; ekonomide zaman zaman görülen iniş ve çıkışlardır. Konjonktür dalgalanmaları 1 yıldan daha uzun bir dönemde meydana gelir. Bu tür dalgalanmalar; gelişme evresi, olgunluk evresi, kriz evresi ve düzelme evresi olmak üzere 4 safhada kendini gösterir. Trend doğrusunun altında ve üzerindeki noktaların düzenli dizileri zaman serilerinin dairesel bileşenine yani konjonktüre atfedirilir. Buradan konjonktürün en önemli özelliği düzenli bir dairesel ritme sahip olmasıdır (Gençoğlu 1995).

2.2.4 Düzensiz (Rassal) Hareketler

Bu dalgalanmaların ne zaman hangi şiddette çıkacağı önceden önkestitilemez. Genelde sel, deprem gibi doğal afetlerde ve savaş, grev, toplu işten çıkarma gibi olaylarda düzensiz dalgalanmalara rastlanır. Elimizdeki seriyi trend ve konjonktürel dalgalanmalardan arındırdıktan sonra geriye rassal olan ya da olmayan artık serisi kalacaktır. Düzensiz dalgalanmaları çeşitli modellerle, otoregresif ve hareketli ortalama gibi, açıklanabilmesi için birçok tekniğin incelenmesi gerekir. Ayrıca trend ve konjonktürel dalgalanmaları çıkardıktan sonra artıklar arasında konjonktürel dalgalanmaların var olup olmadığının görülmesi için de önemli olacaktır (Bölük 2012).

İç bağımlılık zaman serileri analizini, bağımsız gözlem değerlerinden meydana gelen serilerin analizinden ayıran en önemli özelliktir. Bu özellik nedeniyle, bir zaman serisinin bugünkü ve geçmiş dönem gözlem değerlerini kullanarak gelecek dönemde alacağı değerleri önkestirim etme imkânı olabilir. Burada sözü edilen “bugünkü dönem”, analiz edilecek zaman serisindeki en son gözlem değerinin ait olduğu zaman noktasıdır ve (t) ile gösterilir. t dönemine ilişkin gözlem değerine “bugünkü gözlem değeri” denir ve X_t ile gösterilir. Geçmiş dönem ise, zamana bağlı olayın (t) dönemine kadar olan tarihsel gelişimini gösteren dönemdir. $t=1,2,3, \dots$ değerleri için “geçmiş dönem” ve “geçmiş dönem gözlem değerleri” sırasıyla $t - 1, t - 2, \dots, t - n$ ve $X_{t-1}, X_{t-2}, \dots, X_{t-n}$ şeklinde simgelenir. Zamana bağlı olayla ilgili önkestirimlerin yapıldığı döneme “gelecek dönem” adı verilir. Bu döneme ilişkin zaman aralığı ve gözlem değerleri de yine $t = 1, 2, \dots, n$ değerleri için, sırasıyla $t + 1, t + 2, \dots, t + n$ ve $X_{t+1}, X_{t+2}, \dots, X_{t+n}$ şeklinde ifade edilir (Özmen 1986).

Stokastik süreç, durağan ve durağan olmayan süreçler olarak sınıflandırılır. Bir süreçte tüm gerçekleştirmelerdeki istatistik momentleri (örneğin ortalama değer) tüm değerler için aynı (zaman içerisinde değişmiyor) ise durağan denilir. Bu sürecin tam tersi ise durağan olmayan olarak isimlendirilir. Stokastik süreçlerin belirlenmesinde çok sayıda küme ortalaması gerekmektedir. Bu işlem pahalı ve aynı zamanda karmaşık bir işlemdir. Bu nedenle mümkünse az sayıda gözlem ile yetinilmeye çalışılır. Durağan süreçlerde ortalama elde edilen ölçülerin aritmetik ortalaması ile elde edilen ölçülerin aritmetik ortalaması ile hesaplanır. Bu ortalama μ ile tanımlanırsa:

$$\mu = \frac{1}{N} \sum_{i=0}^{N-1} X_i \quad (2.3)$$

denklem 2.3’ten elde edilir. Bu denklemde N toplam gözlem sayısını ifade etmektedir. Ayrıca analiz değerlerinin küme ortalamasıyla karşılaştırılması gerekir. Yani hesaplanan ortalamanın ölçülerden farkı alınır. Bu farkı bize ortalamadan sapmayı verecektir. Ortalamadan sapma ölçü sayısına oranlanırsa örneklemin varyansı hesaplanmış olur. Bu varyans denklem 2.4 ile hesaplanır (Kara 2009).

$$\sigma^2 = \frac{1}{N-1} \sum_{i=0}^{N-1} (y_i - \mu)^2 \quad (2.4)$$

2.3 Durağanlık ve Durağan Olmama

Zaman serileri bir stokastik süreçtir. Durağanlık ise bu stokastik süreç ile ilgili önemli bir kavramdır. Stokastik süreç olarak bir zaman serisinin bütün özellikleri; ortalaması, varyansı, kovaryansı, ve daha yüksek dereceden momentlerinde zamana göre sistematik bir değişme mevcut değilse ya da seri dönemsel değişmelerden arınmışsa, seri durağan zaman serisi denilmektedir ve bu durum da “durağanlık” olarak adlandırılmaktadır (Tüzen 2012).

Pratikte ortaya çıktıkları şekliyle birçok zaman serisi durağan değildir. Örneğin, birçok ülkenin ekonomisi gelişiyor ve büyüyor. Bu nedenle tipik ekonomik göstergeler zaman içinde bir eğilim gösterecektir. Bu eğilim ortalamada, varyansta veya her ikisinde de olabilir. Bu tür durağan olmayan zaman serileri bazen evrimsel olarak adlandırılır. Zaman serileri analizinin pratiğinin büyük bir kısmı, durağan bir zaman serisinde gelişen bir zaman serisinin dönüşümü ile bağlantılıdır (Fuller 1996).

Durağanlığın iki farklı türü ayırt edilebilir. Stokastik sürecin ortak dağılım fonksiyonunun zamandaki kayma ile değişmediğini varsayarsak bu süreç güçlü durağandır. Bu kavramın pratikte uygulanması zor olduğundan zayıf durağanlığı ya da ikinci momentteki durağanlığı dikkate alınır (Kirchgässner ve Wolters 2007).

2.3.1 Durağan Zaman Serileri

Bir zaman serisinin ortalaması, varyansı ve kovaryansı zaman boyunca sabit kalıyorsa, serinin durağan olduğu söylenebilir. Buna göre;

Ortalama, $E(X_t) = \mu$ (tüm t’ler için)

Varyans, $Var(X_t) = \sigma^2$ (tüm t’ler için)

Kovaryans, $Cov(X_t, X_{t-k}) = \gamma_k$ (tüm t'ler için, $k \neq 0$)

olarak yazılır. En basit durağan zaman serisi Beyaz Gürültü (white noise) sürecidir. Beyaz gürültü süreci;

$$X_t = e_t \quad e_t \approx IID(0, \sigma^2)$$

şeklinde gösterilir. Beyaz gürültü sürecinin durağanlık koşullarından tek farkı kovaryansının sıfır olmasıdır. Buna göre;

Ortalama, $E(X_t) = \mu$ (tüm t'ler için)

Varyans, $Var(X_t) = \sigma^2$ (tüm t'ler için)

Kovaryans, $Cov(X_t, X_{t-k}) = 0$ (tüm t'ler için, $k \neq 0$)

olarak yazılır (Oğhan 2010).

2.3.2 Durağan Olmayan Zaman Serileri

Zaman serileri yukarıda tanımlanan özellikleri genellikle sağlamamaktadır. Seri azalan veya artan bir trendi, konjonktürel ve mevsimsel dalgalanmalar gibi etkileri barındırıyorsa, bütün bu etkiler serinin ortalamasının değişmesine neden olacaktır. Böyle bir durumda seri durağan değildir ve otokorelasyonlar önemli ölçüde sıfırdan sapmaktadır. Zaman serilerini uygun bir modelle ifade edilebilmesi için ise bu serinin önce durağan hale getirilmesi gerekir. Ayrıca zaman serilerinin, olasılık teorilerinin büyük bir kısmı durağan zaman serileri ile ilgilidir ve bu nedenle zaman serisi analizinde bu teorileri kullanabilmek için durağan olmayan serilerin durağan hale dönüştürülmesi gerekir (Bölük 2012).

2.4 Otokorelasyon Fonksiyonu (OKF, ACF)

Otokorelasyon fonksiyonu, analiz edilecek seri için uygun olabilecek model veya modellerin belirlenmesinde ve seçiminde kullanılan önemli analiz araçlarından birisidir. Otokorelasyon aynı değişkenin farklı zaman aralıklarında aldığı değerlerin ilişkisinin derecesini belirler. Zamana göre art arda elde edilmiş gözlem kümesinde farklı zaman aralıklarına sahip gözlemler arasındaki ilişkinin derecesinin ölçülmesinde kullanılan katsayıya “otokorelasyon katsayısı” denir ve $\rho(k)$ ile gösterilir. Farklı değerdeki k gecikmeleri $k = 0, 1, 2, \dots, n$ için hesaplanan $\{\rho(k)\}$ ları k gecikmelerine bağlayan fonksiyona “otokorelasyon fonksiyonu” denir (Özmen 1986).

X ve X_{t-k} arasındaki korelasyon;

$$Corr[X_t, X_{t-k}] = \frac{Cov[X_t, X_{t-k}]}{Var[X_t]^{\frac{1}{2}} Var[X_{t-k}]^{\frac{1}{2}}} \quad (2.5)$$

denklem 2.5 ile elde edilir. Durağanlık kullanılarak denklem 2.5 oldukça basitleştirilebilir. Çünkü;

$$Cov[X_t, X_{t-k}] = \gamma(k) \quad (2.6)$$

$$Var([X_t]^{\frac{1}{2}}) = [X_{t-k}]^{\frac{1}{2}} = \gamma(0)^{\frac{1}{2}} \quad (2.7)$$

$$Corr[X_t, X_{t-k}] = \frac{\gamma(k)}{\gamma(0)} \quad (2.8)$$

denklem 2.6 2.7 2.8 ile verilen denklemler mevcuttur. Bu akılda tutarak otokorelasyon fonksiyonu

$$\rho(k) = Corr[X_t, X_{t-k}] \quad (2.9)$$

denklem 2.9 ile tanımlanabilir. Otokorelasyon fonksiyonu $\rho(k) = \frac{\gamma(k)}{\gamma(0)}$ olarak da tanımlanır (Sampson 2001).

2.5 Kısmi Otokorelasyon Fonksiyonu (KOKF, PACF)

Otokorelasyon fonksiyonu zaman serisindeki iki nokta arasındaki ilişkiyi incelemektedir. Kısmi otokorelasyon fonksiyonu ise, diğer zaman gecikmelerinin etkisini arındırarak, $\mathbf{X}_t$ ve $\mathbf{X}_{t-k}$ arasındaki ilişkinin derecesini ölçmektedir (Oğhan 2010).

Verilen bir X_t zaman serisi için, X_t 'nin $X_{t-1}, X_{t-2}, \dots, X_{t-n}$ üzerine regresyondaki X_{t-n} 'in katsayısı n. kısmi otokorelasyon katsayısı olarak adlandırılmaktadır ve

$$X_t = \phi_1 X_{t-1} + \phi_2 X_{t-2} + \dots + \phi_n X_{t-n} + \varepsilon_t \quad (2.10)$$

denklem 2.10 ile gösterilir. Denklem 2.10 göz önüne alındığında n'inci kısmi otokorelasyon katsayısı ϕ_n olacaktır. Yukarıdaki eşitliği kullanarak kısmi otokorelasyonları hesaplamak zor ve zahmetli olmaktadır. Kısmi otokorelasyonları daha kolay olarak otokorelasyon katsayılarına bağlı olarak

$$P_h = \begin{bmatrix} 1 & \rho_1 & \rho_2 & \dots & \rho_{h-1} \\ \rho_1 & 1 & \rho_1 & \dots & \rho_{h-2} \\ \rho_2 & \rho_1 & 1 & \dots & \rho_{h-3} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ \rho_{h-1} & \rho_{h-2} & \rho_{h-3} & \dots & 1 \end{bmatrix}$$

ve

$$P_h^* = \begin{bmatrix} 1 & \rho_1 & \rho_2 & \dots & \rho_1 \\ \rho_1 & 1 & \rho_1 & \dots & \rho_2 \\ \rho_2 & \rho_1 & 1 & \dots & \rho_3 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ \rho_{h-1} & \rho_{h-2} & \rho_{h-3} & \dots & 1 \end{bmatrix}$$

olmak üzere,

$$\phi(n) = \frac{\det(P_h^*)}{\det(P_h)} \quad (2.11)$$

2.11 denkleminde elde edilebilir (Akdi 2003; akt. Özek 2010).

2.6 Box-Jenkins Metodolojisi (B.J)

Box ve Jenkins tarafından 1970 yılında durağanlık şartını sağlamış tek değişkenli zaman serilerinin analiz süreci için geliştirilmiş ve önkestirim metodolojisinde ARIMA (otoregresif bütünleşik hareketli ortalama, autoregressive integrated moving average) modeli olarak da isimlendirilen bir yöntemdir. Durağan halde bulunan zaman serilerinin önkestirim edilmesinde en sık kullanılan ve en uygun olan yöntem Box-Jenkins metodudur (Can 2020).

Bu yöntemin önemli varsayımları arasında eşit zaman aralıklarıyla gözlenen değerlerin oluşturduğu serinin kesikli ve durağan olması yer almaktadır. Otoresif (autoregressive(AR)) modelleri ve hareketli ortalama (moving average(MA)) modelleri ve bunların birleşimi olan otoregresif hareketli ortalama (autoregressive moving average, ARMA) modelleri durağan süreçlere uygulanmaktadırlar. ARIMA modelleri durağan olmayan süreçlere uygulanan modellerdir (Şenyüz 2019).

Box- Jenkins yöntemi dört adımdan oluşmaktadır. Bu adımlar şu şekilde sıralanabilir (Gujarati ve Porter 2009):


Birinci adım, tanımlama adımı olan model tipinin belirlenmesi aşamasıdır. Bu aşamada uygun p, d ve q değeri bulunur. Korelogram ve kısmi korelogram bu aşamada değerleri belirlemede yardımcı olur.

İkinci adım, model parametrelerinin önkestirimidir. Uygun p ve q değerleri belirlendikten sonraki etap modelin içerdiği otoregresif ve hareketli ortalama terimlerinin parametrelerini önkestirmektir. Bu hesaplama bazen basit en küçük kareler

ile yapılabilir fakat bazen de doğrusal olmayan önkestirim yöntemlerine başvurmak gerekebilir. Bu işlem birkaç istatistiksel paket tarafından yapılabilmektedir.

Üçüncü adım, belirlenen modelin yeterliliğinin test edilmesi adıdır. Belirli bir ARIMA modeli seçildikten ve parametreler belirlendikten sonra, seçilen modelin verilere uyup uymadığına bakılır çünkü başka bir ARIMA modelinin de verilere uyması mümkündür. Box-Jenkins ARIMA modellemesinin bilimden çok bir sanat olmasının nedeni, doğru modeli seçmenin önemli bir beceri gerektirmesidir. Model önkestiriminden elde edilen sonuçlar modeli açıklamaya yetiyorsa model belirlenmiş olur fakat modeli açıklamada yeterli değilse işleme baştan başlanmalıdır. Bu nedenle Box- Jenkins metodolojisi Şekil 2.2’de de gösterildiği gibi yinelemeli bir süreçtir.

Dördüncü ve son adım ise önkestirim adıdır. ARIMA modellemesinin popüler olmasının nedenlerinden birisi önkestirimlerdeki başarısıdır. Çoğu durumda, özellikle kısa vadeli önkestirimlerde bu yöntemle elde edilen önkestirimler geleneksel ekonometrik modellemekten elde edilenlerden daha güvenilirlerdir. Yine de her durum değerlendirilmelidir.



Şekil 2.2 Box ve Jenkins yönteminde model belirleme aşamaları (Özmen 1986).

2.7 Doğrusal Durağan Stokastik Modeller

Rassal şokların doğrusal olarak bir araya gelmesi ile bir zaman serisi üretileceğinin varsayılması genel bir doğrusal stokastik model olarak tanımlanır. Pratik gösterim için, parametreleri cimri bir şekilde kullanan modellerin kullanılması arzu edilir. Cimrilik genellikle doğrusal sürecin az sayıda AR ve MA terim ile temsil edilmesiyle ifade edilir (Box ve Jenkins 1976).

2.7.1 Otoregresif Model (AR)

Bu modeller bir zaman serisinin herhangi bir dönemindeki gözlem değerini, aynı serinin ondan önceki belirli sayıda dönemin (geçmiş dönemin) gözlem değerlerine ve hata terimine bağlı olarak açıklayan modellerdir. Başka bir ifade ile AR modeller bir zaman serisinin herhangi bir dönemindeki gözlem değerini, aynı serinin ondan önceki belirli sayıda dönemin gözlem değerinin ve hata teriminin doğrusal bir bileşimi olarak ifade eden modellerdir (Özdemir 2008).

2.7.2 Hareketli Ortalama Modeli (MA)

Aynı dönemdeki hata terimine bağlı zaman serileri ve belirli sayıda önceki dönemlerin hata terimlerine bağlı olarak herhangi bir dönemdeki gözlem değerlerini ifade eden modellere MA modelleri denir (Öcal 2020).

“Hareketli ortalama” terimi, X_t en son iki ε değerinin ortalamasına benzer ağırlıklı bir toplamından oluşturulduğu gerçekliğinden gelir (Hamilton 1994).

Bir sürecin hareketli ortalama gösteriminde, eğer yalnızca sonlu sayıda ψ ağırlığı sıfır değilse, örneğin, $k > q$ için $\psi_1 = -\theta_1$, $\psi_2 = -\theta_2, \dots, \psi_q = -\theta_q$ ve $\psi_k = 0$, ortaya çıkan işlemin hareketli bir ortalama süreç veya q 'inci mertebeden olduğu söylenir ve MA(q) olarak gösterilir. MA(q) modeli

$$X_t = a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q} \quad (2.12)$$

denklem 2.12 ile ya da

$$X_t = \theta(B)a_t \quad (2.13)$$

denklem 2.13 olarak gösterilir. Burada

$$\theta(B) = (1 - \theta_1 B - \dots - \theta_q B^q) \quad (2.14)$$

denklem 2.14 ile ifade edilir. Çünkü sonlu bir hareketli ortalama $1 + \theta_1^2 + \dots + \theta_q^2 < \infty$, her zaman durağandır. $\theta(B) = 0$ 'ın kökleri birim çemberin dışında ise bu hareketli ortalama süreci tersine çevirebilir. Hareketli ortalama süreçler, olayların kısa süreler için devam eden ani bir etki ürettiği olayları tanımlamada yararlıdır (Wei 2006).

2.7.3 Otoregresif Hareketli Ortalama (ARMA) Modeli

ARMA(p, q) modellerinin bir zaman serisine uygulanabilmesi için seri durağan olmalıdır. Fakat gerçek hayatta karşımıza çıkan çoğu zaman serisi durağan değildir. Durağan olmayan zaman serilerinin varyansı ve ortalaması zaman içinde değiştiğinden güvenilir sonuçlar elde edilememektedir. Bu sorunu aşabilmek için serinin durağan hale getirilmesi gerekmektedir (Erturan 2017).

2.8 Durağan Olmayan Doğrusal Stokastik Modeller

Box ve Jenkins (1976) tarafından otaya atılan ARIMA, AR ve MA modelinin bir arada kullanıldığı ARMA modeli temel alınarak geliştirilmiştir. ARMA modeli durağan zaman serilerine uygulanamamakta, ARIMA modeli ise zaman serisini ardışık fark alma yöntemiyle durağan hale getirerek ARMA modelini uygulamaktadır (Erturan 2017).

Denklem 2.14 de verilen X_t yerine $\nabla^d X_t$ alınarak ortalamasına göre durağan olmayan seri modellenebilir. Böyle bir model bütünleşik model olarak isimlendirilmektedir. Buradaki d, X_t serisinin durağanlığının sağlanabilmesi amacı ile uygulanması gereken

fark işlemi sayısını göstermektedir ve uygulamada genellikle $d=1$ durumu ile karşılaşılmaktadır. Durağan olmayan X_t zaman serisi için,

$$W_t = \nabla^d X_t = (1 - B)^d X_t \quad (2.15)$$

denklem 2.15'teki denklemi yazarak genel ARIMA serisini denklem 2.16 ile,

$$W_t = \phi_1 W_{t-1} + \phi_2 W_{t-2} + \dots + \phi_p W_{t-p} + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \dots + \theta_q \varepsilon_{t-q} \quad (2.16)$$

daha kısa olarak denklem 2.17 veya denklem 2.18,

$$\phi_p(B)W_t = \theta_q(B)\varepsilon_t \quad (2.17)$$

$$\phi_p(B)(1 - B)^d Y_t = \theta_q(B)\varepsilon_t \quad (2.18)$$

şeklinde yazılabilir. Denklem 2.18 ile verilen model kısaca ARIMA(p,d,q) ile gösterilmektedir. X_t zaman serisi için oluşturulan denklem 2.18 açık bir şekilde durağan olmayan bir modeldir. Çünkü modelin sol tarafındaki otoregresif kısma ait $\phi_p(B)(1 - B)^d$ ifadesinin d tane kökü 1 çıkacaktır (Özek 2010).

Rakip yöntemler ve modeller arasından seçim yapmak için kullanılan kriterlerden bazıları R^2 , adj. R^2 ($\bar{R}^2$), akaike bilgi ölçütü (ABÖ), schwarz bilgi ölçütü (SBÖ), Mallow'un C_p kriteri ve χ^2 'dir. Bütün bu kriterler kalıntı kareler toplamını (KKT) minimuma indirmeyi ya da R^2 değerini artırmayı hedefler. Bir regresyon modelinin uyum iyiliğinin ölçülerinden birinin R^2 olduğu bilinmektedir ve R^2 ,

$$R^2 = \frac{AKT}{BKT} = 1 - \frac{KKT}{BKT} \quad (2.19)$$

denklem 2.19 ile ifade edilmektedir. R^2 0 ile 1 arasındadır. 1'e ne kadar yakınsa, uyum o kadar iyidir. Artan R^2 değerine karşılık bir ceza olarak Henry Theil tarafından düzeltilmiş R^2 geliştirilmiştir ve $\bar{R}^2$ şeklinde gösterilir. Denklem 2.20 ile gösterilir:

$$\bar{R}^2 = 1 - \frac{KKT/(n-k)}{BKT/(n-1)} = 1 - (1 - R^2) \frac{n-1}{n-k} \quad (2.20)$$

denklem 2.20’de n gözlem sayısını k ise parametre sayısını ifade etmektedir. Bu denklemden $\bar{R}^2 \leq R^2$ olduğunu, eklenen daha fazla açıklayıcı değişken için $\bar{R}^2$ ’nin nasıl cezalandırdığı görülebilir. R^2 ’nin aksine sadece eklenen değişkenin t değeri 1’den büyük ise $\bar{R}^2$ yükselir. Bu yüzden $\bar{R}^2$, R^2 ’den daha iyi bir ölçüdür (Gujarati ve Porter 2009).

Modele açıklayıcı değişkenleri eklemek için etkileyici ceza fikri denklem 2.21 ile ifade edilen Akaike Bilgi Ölçütü (ABÖ) ile daha da ileriye taşınmıştır:

$$ABÖ = e^{2k/n} \frac{\sum \hat{u}_i^2}{n} = e^{2k/n} \frac{KKT}{n} \quad (2.21)$$

denklemden k sabit terimi de içeren parametre sayısını n ise modeldeki parametre sayısını temsil eder. Matematiksel kolaylık için:

$$\ln ABÖ = \left(\frac{2k}{n} \right) + \ln \left(\frac{KKT}{n} \right) \quad (2.22)$$

denklem 2.22 ile ifade edilebilir. Denklemde $\ln ABÖ = ABÖ$ ’nün doğal logaritması, $2k/n$ ise ceza terimidir. Bazı kitaplar ve yazılımlar ABÖ’yü hep logaritmik dönüşümüyle tanımlar. Bu yüzden ABÖ’den önce $\ln$ koymaya gerek yoktur. Bu denklemden ABÖ’nün, daha fazla açıklayıcı değişken eklemeye, $\bar{R}^2$ ’ye göre daha büyük bir ceza verdiği görülmektedir. İki veya daha fazla model karşılaştırmasında ABÖ’nün daha düşük olduğu model tercih edilir. Bir regresyon modelinin sadece örneklem içi değil aynı zamanda örneklem dışı önkestirim performansında da faydalı olmasıdır. Ayrıca yuvalanmış ve yuvalanmamış modellerde de işe yarar. Bir AR(p) modelinde gecikme uzunluğunu belirlemede de kullanılır. Schwarz Bilgi Ölçütü (SBÖ), ABÖ ile benzer anlamları barındırmaktadır. Schwarz Bilgi Ölçütü:

$$SBÖ = n^{k/n} \frac{\sum \hat{u}^2}{n} n^{k/n} \frac{RSS}{n} \quad (2.23)$$

denklem 2.23 ile ya da denklem 2.24'te verilen logaritmik formu:

$$\ln SBÖ = \frac{k}{n} \ln n + \ln \left(\frac{RSS}{n} \right) \quad (2.24)$$

ile gösterilir. Burada $[(k/n) \ln n]$ ceza terimidir. Denklem 2.24 ile denklem 2.22 karşılaştırıldığı zaman SBÖ, ABÖ'ye göre daha ağır ceza uygular çıkarımı yapılabilir. ABÖ'ye benzer şekilde model karşılaştırmada düşük SBÖ tercih edilir ve sadece örneklem içi değil aynı zamanda örneklem dışı önkestirim performansının karşılaştırılmasında kullanılabilir (Gujarati ve Porter 2009).

Hata kareler ortalaması (HKO) önkestirim yöntemlerini değerlendirme yöntemidir. Her hata veya artık karesi alınmıştır. Bu yaklaşım, büyük önkestirim hatalarını düzenler. Yöntem, küçük hatalar için daha iyi olabilecek orta düzeyde hatalar üretir ve

$$HKO = \sum_{t=1}^n |Y_t - \hat{Y}_t|^2 \quad (2.25)$$

denklem 2.25 ile gösterilir. Denklemde X_t gerçek değerleri $\hat{X}_t$ önkestirim edilen çıktıları, n ise toplam gözlem sayısını göstermektedir (Prayudani vd. 2019).

Ortalama mutlak yüzde hata (MAPE), her periyottaki mutlak hataların o periyot için gerçek gözlem değerlerine bölümü kullanılarak hesaplanır. Bu yaklaşım, önkestirimlerin doğruluğunu değerlendirmede boyut veya önkestirime dayalı değişkenlerin boyutu önemli olduğunda faydalıdır. MAPE, serideki gerçek değerle karşılaştırıldığında önkestirimde ne kadar hata olduğunu gösterir. MAPE, aynı veya farklı yöntemlerin iki farklı serideki doğruluğunu karşılaştırmak, mutlak yüzde hata ortalaması cinsinden ifade edilen modelin önkestirimi değerinin doğruluğunu ölçmek için de kullanılabilir ve

$$MAPE = \frac{\sum_{t=1}^n \left| \frac{X_t - \hat{X}_t}{X_t} \right|}{n} * 100\% \quad (2.26)$$


2.26 denklemi ile gösterilir. X_t gerçek değerleri, $\hat{X}_t$ önkestirim edilen çıktıları, n toplam gözlem sayısını ifade eder (Prayudani vd. 2019).

2.9 Yapay Sinir Ağları (YSA)

Önkestirimi geliştirmek, özellikle zaman serisi önkestirim doğruluğunu, birçok alanda karar vericilerin karşı karşıya kaldığı önemli ancak çoğu zaman zor bir görevdir. Hem teorik hem de ampirik bulgular, entegrasyonun farklı modellerin önkestirime dayalı performanslarını, özellikle kombinasyon halindeki modeller oldukça farklı olduğunda, iyileştirmenin etkili bir yolu olabilir. Yapay sinir ağları, çok çeşitli önkestirim problemlerine yüksek derecede doğrulukla uygulanabilen esnek bilgi işlem çerçeveleri ve evrensel önkestirimcilerdir (Khashei ve Bijari 2011).

Yapay sinir ağları, insanların beyin yapısını modelleyerek elde ettiği örnekleri kullanarak olayları öğrenen, bu olaylara tepkiler üreten bilgisayar sistemleridir. Beynin öğrenmek, ilişkilendirmek, gruplandırmak gibi işlevsel özelliklerine benzer şekilde; pek çok alanda başarılı bir şekilde uygulanabilmektedir. Örneklerden elde edilenler dahilinde kendi deneyimlerini oluşturarak sonrasında, benzer konular hakkında benzer sonuca ulaşabilirler. Yapay sinir ağları birbirine hiyerarşik olarak bağlı ve paralel olarak çalışabilen, süreç elemanları da denilen yapay hücrelerden oluşmuştur. Bu hücrelerin birbirlerine bağlandıkları ve her bağlantının bir değerinin olduğu kabul edilmektedir. Süreç elemanlarının birbirleri ile bağlanmaları sonucu oluşan ağa yapay sinir ağı adı verilmektedir (Uslu 2011).


YSA günümüzde istatistik, işletme, tıp, teknoloji, biyoloji, otomotiv, finans ve bankacılık, ekonomi ve mühendislik gibi pek çok alanda ve konuda karşımıza çıkmaktadır (Keskenler ve Keskenler 2017).



Şekil 2.3 Biyolojik Nöron Yapısı (Fausett 1994).

Şekil 2.3 ile biyolojik bir nöronun yapısı verilmiştir. Bir sinir ağının temel işlem ögesi nörondur. Temel olarak biyolojik bir nöron diğer kaynaklardan girdi alır ve bunları birleştirir. Birleştirme işlemi ile elde edilen sonuç üzerinde genellikle doğrusal olmayan bir işlem gerçekleştiren nöron ardından nihai sonucu verir. Bir nöronun genel yapısı, biyolojik isimleri ile dentritler, soma, akson ve sinapslar olarak dört temel bileşene sahiptir. Her nöron genel olarak sadece bir aksone, fakat tipik olarak pek çok dentrite sahiptir. Akson, sinir sinyalinin hücre gövdesinden diğer nöronlara taşır. Dentritler ise girdi kanalları gibi hareket eden somanın saç benzeri uzantıdır. Bu giriş kanalları diğer nöronların sinapsları yoluyla onların girdisini alır. Soma bu girdi sinyallerini zamanla işler ve daha sonra akson ve sinapslar yoluyla nöronlara gönderilen işlenmiş değeri bir çıktıya dönüştürür (Anderson ve McNeill 1992, Cavuto 1997).

Ağın modeli şekil 2.4 ile verilmiştir.



Şekil 2.4 Yapay sinir ağı modeli (Ansari 2020).

Bu gösterime göre her bir girdi x_i ($i: 1,2, \dots, m$), w_i ($i: 1,2, \dots, m$) faktörü ile ağırlıklandırılmıştır. Her bir girdi birimi, ağırlıkları çarpılarak girdilerin toplamı hesaplanmaktadır. Bu hesaplama sonucunda elde edilen y_{girdi} F aktivasyon fonksiyonunda işlenerek çıktı olan Y 'nin elde edilmesini sağlar. Bu şekilde birçok girdi kullanılarak tek bir çıktı elde edilmiş olur.

2.9.1 Aktivasyon Fonksiyonu

Transfer fonksiyonu da denilen aktivasyon fonksiyonu, hücreye gelen net girdiyi ağırlıklar ile işleyerek hücrenin bu girdiye karşılık gelen net çıktısını belirler. Bu fonksiyon performansa etki edeceğinden doğru seçilmelidir. Transfer fonksiyonu olarak çıktıyı hesaplamada farklı formüller kullanılmaktadır (Özdemir 2008, Öztürk ve Şahin 2018).

Hücreye gelen ağırlıklandırılmış net girdi, hücre tarafından aktivasyon fonksiyonundan geçirilerek, nihai çıktı olarak dış dünyaya girdi olarak kullanılmak üzere diğer bir nöronun girişlerine gönderilir. Aktivasyon fonksiyonunun işlevi, denklem 2.27 ile ifade edilmektedir (Çelik 2008).

$$f(v_i) = \hat{y} \quad (2.27)$$

2.9.2 Yapay Sinir Ağlarında Öğrenme Algoritması

En önemli yapay sinir ağı özelliği veriyi kaynağından öğrenebilme kabiliyetine sahip olmasıdır. Öğrenme işlemi, ağırlıkların en iyi değerinin bulunması işlemidir. Çünkü ağırlıklar veriler arasındaki en uygun değeri bulmaya odaklanır ve bu işlem yapay sinir ağının eğitimi olarak isimlendirilmektedir. Yapay sinir ağlarında öğrenme işlemi, önceden belirlenmiş bir ölçüte göre adım adım ağırlıkların en iyi değerine ulaşmaya çalışılan, öğrenme algoritması adı verilen algoritmanın kullanılmasıyla gerçekleştirilir. Öğrenme algoritmaları, öğrenme kuralı adı verilen değişik kurallara göre işler. En çok bilinen ve kullanılan iki öğrenme kuralı, denetimli (supervised) ve denetimsiz (unsupervised) öğrenme kuralıdır. Denetimli öğrenmede, elde edilecek her bir çıktı

değerinin, önceden bilinen bir hedef değeri vardır. Buna göre, öğrenme algoritmasının her bir adımında, yapay sinir ağının çıktı değeri ve karşılık gelen hedef değeri arasındaki hata azaltılarak ağırlık değerleri güncellenir (Yolcu 2008, Öztürk ve Şahin 2018).

2.9.2.1 Geri Yayılım Algoritması

Bir ağın geri yayılım yoluyla eğitimi üç aşamadan oluşur: girdi eğitimi modelinin ileri bildirimi, ilgili hatanın geri yayılımı ve hesaplanması, ağırlıkların ayarlanması. Eğitimden sonra, ağın uygulaması sadece ileri besleme aşamasının hesaplamalarını içerir. Eğitim yavaş olsa bile, eğitilmiş bir ağ çıktıları çok hızlı bir şekilde üretebilir. Eğitim sürecinin hızını artırmak için çok sayıda geri yayılım varyasyonu geliştirilmiştir. Tek katmanlı bir ağ öğrenebileceği haritalanmalar ciddi şekilde sınırlı olsa da çok katmanlı bir ağ sürekli bir eşlemeyi rasgele bir doğrulukla öğrenebilir. Bazı uygulamalar için birden fazla gizli katman yararlı olabilir, ancak bir gizli katman yeterlidir (Fausett 1994).

2.9.2.2 Levenberg-Marquardt Algoritması

Levenberg-Marquardt (LM) algoritması en yaygın kullanılan optimizasyon algoritmasıdır. Çok çeşitli problemlerde basit gradyan iniş ve diğer eşlenik gradyan yöntemlerinden daha iyi performans gösterir. LM algoritması geleneksel gradyan inişi ve Gauss-Newton yinelemesinin bir karışımıdır (Ranganathan 2004).

LM yaklaşımı ilk olarak Levenberg (1944) tarafından geliştirilmiş, sonrasında Marquardt (1963, 1970) tarafından detaylı olarak ele alınmıştır. Bu yaklaşım genelde doğrusal olmayan problemlerin ters çözümünde Δp düzeltme vektörünün sınırsız değişimini ifade etmektedir. Sönümlü En Küçük Kareler yöntemi şeklinde de anılmaktadır. Bunun sebebi Δp 'nin elemanlarının enerjisini Marquardt sönüm faktörü olan λ gerçel sabiti ile kısıtlama şartı konulabilir olması ve çözüm içeriğindeki sonsuz titreşimi “söndürmeyi” amaçlamasından kaynaklanmaktadır (Oruç 2012; akt. Akkaş 2020).

I birim matris ve Δp düzeltme vektörü olmak üzere,

$$\Delta p = (A^T A + \lambda I)^{-1} A^T \Delta d \quad (2.28)$$

denklem 2.28 ile ifade edilebilir . Denklemden A $n \times m$ boyutundaki Jacobian matrisini tanımlamaktadır (İnt.Kyn.3).

Levenberg Marquardt algoritması türev tabanlı bir algoritmadır ve türev tabanlı yöntemlerde karşılaşılan temel problem parametrelerdeki çözüm işleminin optimum sonuç vermesi önkestim değeri olarak atanan değerlere bağlıdır. Model verileri için önkestim değerleri uygulanırken gerçeğe yakın değerlerin verildiği durumlarda bile lokal minimuma yaklaşımın global minimuma yaklaşımdan daha fazla olduğu ve çözümlerde ıraksama meydana geldiği görülmüştür. Bu duruma engel olmak için araştırmacılar son yıllarda optimum çözüm sağlayabilmek için, çok daha geniş aralıkta çözüm arayışı yapabilen, global minimum arayışını daha etkili gerçekleştirme kabiliyetine sahip optimizasyon yöntemlerini geliştirmiştir ve bu yöntemlerin kullanımı yaygınlaşmıştır (Akkaş 2020).

Son zamanlarda yapılan çalışmalar yapay sinir ağlarının sınıflandırma ve önkestim gücünü göstermiştir. Klasik Box-Jenkins, ARMA veya ARIMA gibi zaman serisi önkestim için kullanılan yöntemler girdiler ve çıktılar arasında doğrusal ilişki olduğunu farz eder. Bu klasik yöntemlere karşılık yapay sinir ağları veri setinin özellikleri hakkında ön bilgi olmaksızın herhangi bir doğrusal olmayan fonksiyona yaklaşabilme avantajına sahiptir (İnt.Kyn.4).

Remus ve O'Connor (2002)'a göre; yapay sinir ağları aylık ve üç aylık zaman serilerinde geleneksel önkestim yöntemlerinden doğru ya da daha doğru olabilir. Süreksiz seriler için geleneksel bilinene dayalı önkestim yöntemlerinden daha iyi olabilir ve genellikle diğer durumlarda geleneksel önkestim yöntemleri kadar iyidir. Uzun dönem önkestimlerinde geleneksel önkestim yöntemlerinden daha iyidir fakat kısa dönem önkestimleri için daha iyi değildir. Bu bilgilere ek olarak sinir ağlarını karakterize eden parametreleri önkestim etmek için birçok gözlem gerekli olabilir.

Böylece küçük veri setleri için üstel yumuşatma gibi daha basit geleneksel modeller tercih edilebilir.

2.10 ATA Metot

Tek değişkenli zaman serileri için, modelleme ve önkestirim sürecine çok sayıda zaman serisi dahil edildiğinde, doğru ve sağlam önkestirim yöntemlerinin geliştirilmesi çok önemlidir. Model seçim algoritmalarının avantajlarına rağmen, doğru kestirim yöntemlerine hala ihtiyaç vardır. Önkestirim rekabeti, yüksek performanslı yöntemleri belirleme hedefiyle, çok sayıda zaman serisinin önkestirimine doğru ilerlemede önemli bir rol oynamıştır. ATA yöntemi, basitliği, kolay etkinlik sağlaması ve şaşırtıcı derecede iyi performansı ile büyük ilgi çekmiştir. ATA yöntemi mevsimsel olmayan ya da mevsimsizleştirmenin çarpımsal klasik ayrıştırma yoluyla gerçekleştirildiği zaman serilerine uygulanabilir (Selamlar 2017).

Üstel düzeltme (exponential smoothing (ES)), zaman serileri literatüründe en başarılı önkestirim yöntemlerinden birisi olarak duyurulsa ve basitliği nedeniyle pratikte yaygın olarak kullanılsa da doğruluğu takip edilen başlatma ve optimizasyon prosedürlerinden etkilenebilir. Ayrıca ağırlıklandırma şeması yakından incelendiğinde açıkça görülebilen bazı temel sorunlardan mustarıptır. Üstel düzeltme, geçmiş verilere ağırlık atarken önkestirime katkıda bulunabilecek veri noktalarının miktarını hesaba katamaz. ATA, düzeltmeye alternatif bir önkestirim yöntemi olarak önerilmiştir ve deneysel veriler üzerinde doğruluklar karşılaştırıldığında ES'ten daha iyi performans gösterdiği gösterilmiştir (Yapar vd. 2017).

2.10.1 ATA (p,0) Temel Formu

$q=0$ olduğunda, ATA (p,q)'nın basit üstel düzeltme (simple exponential smoothing (SES)) modeline benzer bir biçime sahip bir modele indirgenildiğini göstermeye değer, örneğin $t > p$ için;

$$S(t) = \left(\frac{p}{t}\right) X_t + \left(\frac{t-p}{t}\right) S_{t-1}, \quad t > p, \quad (2.29)$$

$$S_t = X_t, \quad t \leq p, \quad (2.30)$$

$$\hat{\alpha} = \hat{X}_t(h) = S_t \quad (2.31)$$

denklem 2.29, 2.30 ve 2.31 kullanılır. Burada p , düzeltme parametresidir ve düzeltme sürecini düzenler. Model bundan sonra basit ATA($p,0$) formu olarak adlandırılacaktır. S_t geçmiş gözlemlerin ağırlıklı ortalaması olarak yorumlanabilir. Bu nedenle, düzeltilmiş S_t değeri tekrarlamalı biçimde, denklem 2.32'deki gibi yazılabilir.

$$S_t = \sum_{k=0}^{t-(p+1)} \frac{\binom{t-k-1}{p-1}}{\binom{t}{p}} x_{t-k} + \frac{1}{\binom{t}{p}} S_p \quad (2.32)$$

Burada S_p , ilk değer ya da ATA($p,0$) için başlangıç değeridir; bu basitçe p 'inci gözlemi veya en eski p gözlemlerinin ortalaması olabilir. Böylece, t zamanındaki düzeltilmiş değerin, geçmiş gözlemlerin ağırlık ortalaması ve S_p başlangıç değeri olduğu olayca görülebilir. Denklem 2.30'a bakıldığında, S_p 'nin başlangıç değerinin p 'nin düzeltme parametresine bağlı olduğu açıktır. Bu nedenle, düzeltme parametresi ve başlangıç değeri aynı anda optimize edilir (Selamlar 2017).

2.10.2 ATA ($p,0$)'nın Ağırlıkları

Bazı temel özelliklere sahip olan ATA yönteminin ağırlıkları basit üstel düzeltme modelinin aynısıdır. Bu özellikler 2.31 denkleminde ve ATA ($p,0$) tarafından gözlemlere eklenen ağırlıklar çizelge 2.1 ile verilmiştir (Yılmaz 2018).

- $w_t \in [0,1] t = 1, \dots, n$
- $w_1 \leq w_2 \leq \dots \leq w_n$
- $\sum_{t=1}^n w_t = 1$ (2.33)

Çizelge 2.1 ATA(p,0) tarafından gözlemlere eklenen ağırlıklar.

ATA(p,0) tarafından X_t ağırlığı	
$w_n = \binom{p}{n}$	(2.34)
$w_{n-1} = \binom{p}{n} \binom{n-p}{n-1}$	(2.35)
$w_{n-2} = \binom{p}{n} \binom{n-p}{n-1} \binom{n-p-1}{n-2}$	(2.36)
$\vdots$	(2.37)
$\vdots$	(2.38)
$w_{p+1} = \frac{\binom{p}{p-1}}{\binom{n}{p}}$	
$w_p = \dots w_1 = 0$	(2.39)

2.10.3 ATA (p,0)'nın Ortalama Yaşı, ($\bar{k}$)

Bir taze verinin modelinin yeteneği, modelin ortalama yaşı (OY) ile ölçülür. Ortalama yaş $\bar{k}$ ile ifade edilir. Model karşılaştırması için daha küçük olan $\bar{k}$ daha iyidir. Ortalama yaş ölçüm denklemi Brown (1959) tarafından:

$$OY(\hat{\alpha}) = \bar{k} = n - \sum_{t=1}^n tw_t \quad (2.40)$$

denklem 2.40 ile tanımlanmıştır. Burada önkestirimi elde etmeye çalışırken verilen t'inci gözlemin ağırlığı w_t 'dir. Basit ATA biçimi için ortalama yaş:

$$OY_{ATA(p,0)} = \bar{k}_{ATA} = \frac{n-p}{p+1} \quad (2.41)$$

denklem 2.41 ile verilmiştir. ATA'nın basit formunun ortalama yaşını, basit üstel düzeltme ile karşılaştırsak, basit üstel düzeltmenin ortalama yaşına $\alpha = p/n$ olan aynı α seviyesinde:

$$OY_{SES} = \bar{k}_{SES} = \frac{1-\alpha}{\alpha} = \frac{1-p/n}{p/n} = \frac{n-p}{p} \quad (2.42)$$

denklem 2.42 ile bakılabilir. Bu iki formül karşılaştırıldığında, ATA'nın aynı α seviyesinde basit üstel düzeltmesinin ortalama yaşından daha küçük olduğu,

$$\bar{k}_{ATA} = \frac{n-p}{p+1} < \frac{1-\alpha}{\alpha} = \frac{n-p}{p} = \bar{k}_{SES} \quad (2.43)$$

denklem 2.43'de görülmektedir (Brown 1959; akt. Şalk 2019).

2.10.4 ATA (p,0)'nın Ağırlıklandırılmış Kareler Toplamı (V)

Önkestirim yöntemlerini karşılaştırmada kullanılan ölçütler arasında yer alan varyans, bu ölçütler arasında önemli bir yere sahiptir. Varyansın formülü denklem 2.44 ile verilmiş olup,

$$Var(\hat{\alpha}) = E \left[\left(\sum_{t=1}^n w_t X_t - \alpha \right)^2 \right] = \sum_{t=1}^n w_t^2 \sigma^2 = V \sigma^2 \quad (2.44)$$

ATA önkestirimcisinin varyansını hesaplamak için V ile belirtilen ağırlıkların kareler toplamını hesaplamak gerekir. Kareler toplamı çizelge 2.1'de verilen ağırlıklarla denklem 2.45 ile:

$$V_{ATA(p,0)} = \sum_{t=1}^n w_t^2 \quad (2.45)$$

yazılabilir. Denklem 2.45'da ağırlıklı değerler yerine koyulduğu zaman,

$$\begin{aligned} V_{ATA(p,0)} &= \left(\frac{p}{n}\right)^2 + \left(\frac{p}{n}\right)^2 \left(\frac{n-p}{n-1}\right)^2 + \cdots + \left(\frac{p}{n}\right)^2 \left(\frac{n-p}{n-1}\right)^2 \left(\frac{n-p-1}{n-2}\right)^2 \cdots \left(\frac{1}{p}\right)^2 \\ &= \left(\frac{p}{n}\right)^2 \left[1 + \sum_{i=0}^{n-p-1} \prod_{j=0}^i \left(\frac{n-p-j}{n-1-j}\right)^2 \right] \\ &= \left(\frac{p}{n}\right)^2 {}_3F_2((1, p-n, p-n), (1-n, 1-n), 1) \end{aligned} \quad (2.46)$$

elde edilir. Denklem 2.46'dan ATA (p,0) önkestirimcisinin varyansının genelleştirilmiş hiper-geometrik seri içerdiği görülür:

$${}_3F_2((1, m - n, m - n), (1 - n, 1 - n), 1)$$

Bu model daha yüksek seviyeli bileşenleri dahil etmek için kolayca düzenlenebilir. Bu bağlamda:

$$\bar{k}_{ATA} = \bar{k}_{SES} \Rightarrow \frac{n - p}{p + 1} = \frac{1 - \alpha}{\alpha} \Rightarrow \alpha = \frac{p + 1}{n + 1} \quad (2.47)$$

2.47 denklemi elde edilir ve ayrıca ATA ortalamasının basit üstel düzeltmenin yaşına eşit olduğu denklem 2.48 ile elde edilir,

$$\bar{k}_{ATA} = \bar{k}_{SES} \Leftrightarrow \alpha = \frac{p + 1}{n + 1} \quad (2.48)$$

ve sonra ATA'nın varyansının basit üstel düzeltmenin varyansından daima daha küçük olduğu söylenir ($V_{ATA} < V_{SES}$). Her iki model için aynı düzeltme sabiti kullanıldığında, ATA'nın her zaman daha küçük ortalama yaşa (OY) sahip olduğu, ATA'nın ağırlıklarının karesi değerinin toplamı basit üstel düzeltmeden daha büyük olduğu görülür (Yılmaz 2018).

2.10.5 ATA (p,0)'ın Temel Değerinin Ağırlığı

Daha önce ATA yönteminin denklem 2.49 de başlangıç değeri gerektirmediğinden bahsedilmişti. Bu denklemde:

$$S_t = \sum_{k=0}^{t-p-1} \frac{\binom{t-k-1}{p-1}}{\binom{t}{p}} X_{t-k} + \frac{1}{\binom{t}{p}} S_p \quad (2.49)$$

$$S_p = X_t \quad , \quad t \leq p$$

p'inci zamandan önceki zaman noktaları içi düzeltilmiş değerler onların gerçek gözlemlerine eşittir. Ayrıca, aynı SES için tekrarlanan formül,

$$S_t = \alpha \sum_{k=0}^{t-1} (1 - \alpha)^k X_t + (1 - \alpha)^t S_0 \quad (2.50)$$

denklem 2.50 ile verilmiştir. Burada S_0 başlangıç değerini ifade etmektedir. Başlangıç değerine eklenen ağırlıklar, t zamandaki S_p ve S_0 , ATA (p,0) için $1/\binom{t}{p}$ ve SES için başarılı bir şekilde $(1 - \alpha)^t$ 'ye eşittir. Basit üstel düzeltme için çoğu bilim insanı 0.01 ve 0.3 değerleri arasında konu üzerine çalışmıştır. Fakat bu başlatma problemi olarak da bilinmektedir ve t ya da α küçük olduğunda, basit üstel düzeltme en son gözlemden başlangıç değerine, daha fazla ağırlığı ilişkilendirir. Bu nedenle basit üstel düzeltme başlangıç değeri oldukça önemli bir hale gelmektedir (Yılmaz 2018).

2.10.6 ATA (p,0)'ın Düzeltme Parametresi

Basit üstel düzeltmedeki ana fikir, yakın tarihin yakın geleceği daha iyi temsil etmesi ve bu nedenle son gözlemlere daha fazla vurgu yapılması gerektiğidir. Dolayısıyla sezgisel olarak, bir sistem araştırmasının başlangıç noktası, tüm geçmiş gözlemleri eşit olarak ağırlıklandırmalı (ortalama yöntem) ve ardından son gözlemi 1 ile ağırlıklandırana kadar son gözlemlere kademeli olarak daha fazla vurgu yapmalıdır (denenmemiş yöntem). Bu, başlangıç değerinin ağırlığının en güncel gözlemin ağırlığından daha az veya daha ona eşit kalmasını garanti eder. Bu, denklem 2.51'de herhangi bir t değeri için p=1 olan bir ATA modeli ile kolayca elde edilebilir (Selamlar 2017).

$$S_t = \left(\frac{1}{t}\right) X_t + \left(\frac{t-1}{t}\right) S_{t-1} \quad (2.51)$$

$$S_t = \left(\frac{1}{t}\right) X_t + \left(\frac{1}{t}\right) X_{t-1} + \dots + \left(\frac{1}{t}\right) X_2 + \left(\frac{1}{t}\right) S_1 \quad (2.52)$$

$t \leq p$ ve h adım önkestirimi ($\hat{X}_t(h) = \bar{X}_t$) tüm geçmiş gözlemlerin basit ortalamasına eşit olduğu zaman $S_p = X_p$ olduğundan $S_1 = X_1$ olduğunda, diğer bir deyişle, tüm gözlemler önkestirime eşit katkıda bulunur (Selamlar 2017).

p=2 için t zamanındaki ATA düzeltme değeri;

$$S_t = \left(\frac{2}{t}\right) X_t + \left(\frac{t-2}{t}\right) S_{t-1} \quad (2.53)$$

$$S_t = \left(\frac{2}{t}\right) X_t + \frac{2(t-2)}{t(t-1)} X_{t-1} + \frac{2(t-2)}{t(t-1)} X_{t-2} + \dots + \left(\frac{2}{t}\right) \frac{2}{(t-1)} X_3 + \frac{2}{t(t-1)} S_2$$

denklem 2.53 deki yazılabilir. Burada $S_2 = X_2$ 'dir. Herhangi bir t için p=2 olduğunda, ATA modeli, $2/t(t-1)$ eğimi ve kesişim $2/t$ ile doğrusal olarak azalan ağırlıklar üretir; bu da, gözlemlere her zaman parametre seçimi ne olursa olsun üssel olarak azalan ağırlıklar atadığı için, basit üstel düzeltme ile asla elde edilemez. Benzer şekilde $p \geq 3$ için ağırlıklar basit üstel düzeltmede olduğu gibi gözlemler eskidikçe üssel olarak azalmaya başlar, ancak tam olarak aynı oranda değildir. Bu durumda ATA, en yakın geçmişe basit üstel düzeltmeden daha vurgu yapar ve aynı yumuşatma sabitinde en uzak geçmişe basit üstel düzeltmeden daha az vurgu yapar (Şalk 2019).

Sadece ATA (p,0) daha esnek değil, aynı zamanda veri setine de daha uyumludur. Gözlemlere, eldeki örneklem boyutlarından bağımsız olarak $\alpha, \alpha(1-\alpha), \alpha(1-\alpha)^2, \dots, \alpha(1-\alpha)^n$ ağırlıkları atanmıştır. Ağırlıklar sırasıyla denklem 2.54'te olduğunda örneklem boyutuna göre ağırlıklar değiştiğinden ATA için durum bu şekilde değildir:

$$\left(\frac{p}{n}\right), \left(\frac{p}{n}\right) \left(\frac{n-p}{n-1}\right), \left(\frac{p}{n}\right) \left(\frac{n-p}{n-1}\right) \left(\frac{n-p-1}{n-2}\right), \dots \quad (2.54)$$

basitlik ve ispat amacı için p=3 seçilirse, düzeltme formülü;

$$S_t = \left(\frac{3}{t}\right) X_t + \left(\frac{t-3}{t}\right) S_{t-1}, \quad t > 3 \text{ ise} \quad (2.55)$$

denklem 2.55'teki gibi olur. Formül tekrarlamalı olarak genişletilirse,

$$S_4 = \left(\frac{3}{4}\right) X_4 + \left(\frac{1}{4}\right) S_3 \quad (2.56)$$

$$S_5 = \left(\frac{3}{5}\right)X_5 + \left(\frac{2}{5}\right)\left(\frac{3}{4}\right)X_4 + \left(\frac{2}{5}\right)\left(\frac{1}{4}\right)S_3 \quad (2.57)$$

$$S_6 = \left(\frac{3}{6}\right)X_6 + \left(\frac{3}{6}\right)\left(\frac{3}{5}\right)X_5 + \left(\frac{3}{6}\right)\left(\frac{2}{5}\right)\left(\frac{3}{4}\right)X_4 + \left(\frac{3}{6}\right)\left(\frac{2}{5}\right)\left(\frac{1}{4}\right)S_3 \quad (2.58)$$

S_4, S_5, S_6 denklemler 2.56, 2.57, 2.58 ile elde edilir ve işleme devam edilir. $t=10$ 'a kadar devam edilirse, 3 basamaklı hesaplamalarla düzeltme denklemi elde edilir. $S_3 = X_3$ 'te:

$$S_{10} = 0.300X_{10} + 0.233X_9 + 0.175X_8 + 0.125X_7 + 0.083X_6 + 0.050X_5 + 0.025X_4 + 0.008S_3 \quad (2.59)$$

denklem 2.59 elde edilir (Şalk 2019).

En uygun ATA modelini belirlemede pek çok kriter kullanılmakla beraber bu çalışmada sMAPE (simetrik ortalama mutlak yüzde hata, symmetric mean absolute percentage error) kriterinden faydalanılmıştır. Yapar vd. (2018), bir adım ileri için sMAPE değerini, denklem 2.60 ile vermiştir. Bu denklemde X_t gerçek, $\widehat{X}_t$ bir adım ileri önkestim edilen değerdir.

$$sMAPE = 200 \times \frac{|X_t - \widehat{X}_t|}{|X_t| + |\widehat{X}_t|} \quad (2.60)$$


3. MATERYAL ve METOT

Çalışmada kullanılmak üzere Bitcoin, Litecoin ve Ethereum kripto para birimlerine ait saatlik ve günlük kapanış değerlerini içeren veri setleri tradingview.com sitesi üzerinden, para birimi olarak dolar cinsinden (\$), Aralık 2020-Mart 2021 tarihleri arasındaki 3 aylık dönemi kapsayacak şekilde elde edilmiştir. 2126 saatlik ve 91 günlük veri seti ile çalışılmıştır. Veri setlerinin analizlerde MATLAB, Eviews programlarından ve R Studio programında ATA metodu için geliştirilen ATAforecasting paketinden yararlanılmıştır.

Literatürde önkestirim amaçlı kullanılan pek çok zaman serisi yöntemi mevcut olmakla beraber bu çalışmada ARIMA, YSA ve ATA metotlarından yararlanılmıştır. Ele alınan kripto paralara ait ilgili zaman serisi için en uygun ARIMA modelinin belirlenmesinde Akaike- Schwarz bilgi kriterlerinden yararlanılırken, YSA’da en iyi model belirlenirken Levenberg- Marquardt algoritmasından, ATA modeller içerisinde en iyi modeli belirlemede ise sMAPE kriterinden yararlanılmıştır. Uygun ARIMA, YSA ve ATA modelleri elde edildikten sonra modellerin karşılaştırılmasında, ise HKO kriteri kullanılmıştır.


4. BULGULAR

Çalışmanın bu bölümünde önkestirim amacıyla kullanılan ARIMA, YSA ve ATA modellerine ait analiz sonuçlarına yer verilmektedir. İlk olarak ARIMA modelleri için elde edilen sonuçlar ve bu sonuçlara ilişkin yorumlar aşağıda verilmektedir.



Şekil 4.1 Saatlik Bitcoin verisine ait korelogram.

Şekil 4.1’de gösterilen ve saatlik Bitcoin verileri için incelenen korelogram grafiğinden yola çıkarak otokorelasyonun sıfıra doğru hızlı bir şekilde değil de yavaş yavaş azalması ve değerlerin eşik değer dışında yoğunluk göstermesi serinin durağan olmadığını göstermektedir. Bunun daha net anlaşılabilmesi için serinin zaman serisi grafiği çizdirilir.



Şekil 4.2 Saatlik Bitcoin verisine ait zaman serisi grafiği.

Serinin Şekil 4.2’de gösterilen grafiğine bakıldığında da serinin artan bir trende sahip olduğu görülmektedir. Ayrıca bu grafikte veri belirli bir ortalama etrafında dağılma eğilimi göstermediği için verinin durağan olmadığı çıkarımı yapılmaktadır. Gelecek dönem önkestirimi yapılmadan önce seri durağan hale getirilmelidir. Durağanlığı belirlemek için Augmented Dickey-Fuller (ADF) testi kullanılmıştır.

Çizelge 4.1 Saatlik Bitcoin verisine ait ADF test istatistik sonucu.

		t-istatistik	p-değeri
ADF test istatistiği		-2.71	0.2324
t-kritik değerleri	%1	-3.96	
	%5	-3.41	
	%10	-3.12	

$H_0: \delta = 0$ Seri durağan değildir.

$H_1: \delta < 0$ Seri durağandır.

Çizelge 4.1’e göre p-değeri=0.2324>0.05’tir. Bu durumda H_0 hipotezi reddedilemez ve serinin istatistiksel olarak %95 güvenilirlikte durağan olmadığı çıkarımı yapılır. Serinin durağan hale gelebilmesi için fark işlemi uygulanmalıdır.

Çizelge 4.2 Birinci dereceden farkı alınmış saatlik Bitcoin verisinin ADF test istatistik sonucu.

		t-istatistik	p-değeri
ADF test istatistiği		-48.18	0.0000
t-kritik değerleri	%1	-3.96	
	%5	-3.41	
	%10	-3.12	

Çizelge 4.2'ye göre $p\text{-değeri}=0.0000<0.05$ 'tir. Bu durumda H_0 hipotezi reddedilemez ve serinin istatistiksel olarak %95 güvenlilikte durağan hale geldiği çıkarımı yapılır.

Seride durağanlık sağlandıktan sonra, durağan serinin korelogramı göz önünde bulundurularak olası modeller belirlenir ve olası modeller arasından önkestirim yapmada kullanılacak en uygun model seçilir. Olası modelleri belirlemede otokorelasyon ve kısmi otokorelasyon beraber değerlendirilmelidir. Modelin MA bileşenini belirlemede otokorelasyon, AR bileşenini belirlemede kısmi otokorelasyon kullanılır.


Olası modeller arasından modelde en fazla anlamlı katsayıya sahip, en düşük Akaike Bilgi Kriteri (AIC) ve Schwarz bilgi kriterine (SIC) sahip olan model ile en yüksek R^2 'ye sahip model uygun model olarak seçilir. Bu koşullar altında saatlik Bitcoin verisi için olası modeller arasından analize en uygun model ARIMA (13,1,1) modeli olarak belirlenmiştir. Modele ait bilgiler Çizelge 4.3 ile verilmiştir.

Çizelge 4.3 Saatlik Bitcoin serisine ait ARIMA modeli.

Değişken	Katsayı	p-değeri
C	15.47	0.1473
AR(13)	0.07	0.0004
MA(1)	-0.05	0.0071
R^2	0.0065	
AIC	15.1636	
SIC	15.1742	


Modele ait 24 saatlik önkestirim sonuçları ve karşılaştırmalı grafikler çalışmanın sonunda ele alınmıştır.

Örnekleme aralığı: 12/23/2020 00:00 03/21/2021 13:00
Gözlem sayısı:2126



Şekil 4.3 Saatlik Ethereum verisine ait korelogram.

Saatlik Ethereum verileri için Şekil 4.3'teki korelogram grafiğinden yola çıkarak serinin durağan olmadığı görülmektedir.



Şekil 4.4 Saatlik Ethereum verisine ait zaman serisi grafiği.

Saatlik Ethereum serisine ait olan, Şekil 4.4'te de seri durağan değildir çıkarımı yapılır. Durağanlığı belirlemek için Augmented Dickey-Fuller (ADF) testi uygulanır.

Çizelge 4.4 Saatlik Ethereum verisine ait ADF test istatistik sonucu.

		t-istatistik	p-değeri
ADF test istatistiği		-1.86	0.3517
t-kritik değerleri	%1	-3.43	
	%5	-2.86	
	%10	-2.57	

$H_0: \delta = 0$ Seri durağan değildir.

$H_1: \delta < 0$ Seri durağandır.

Şekil 4.4'e göre p-değeri=0.3517>0.05'tir ve H_0 hipotezi reddedilemez ve serinin istatistiksel olarak %95 güvenilirlikte durağan olmadığı çıkarımı yapılır. Seriyeye fark işlemi uygulanır.

Çizelge 4.5 Birinci dereceden farkı alınmış saatlik Ethereum verisinin ADF test istatistik sonucu.

		t-istatistik	p-değeri
ADF test istatistiği		-48.18	0.0000
t-kritik değerleri	%1	-3.96	
	%5	-3.41	
	%10	-3.12	


Çizelge 4.5'e göre p-değeri=0.0000<0.05'tir. Bu durumda H_0 hipotezi reddedilemez ve serinin istatistiksel olarak %95 güvenilirlikte durağan hale geldiği çıkarımı yapılır.

Seride durağanlık sağlandıktan sonra saatlik Ethereum verisi için olası modeller arasından analize en uygun model ARIMA (1,1,4) modeli olarak belirlenmiştir. Modele ait bilgiler Çizelge 4.6 ile verilmiştir.

Çizelge 4.6 Saatlik Ethereum serisine ait ARIMA modeli.

Değişken	Katsayı	p-değeri
C	0.53	0.1630
AR(1)	-0.02	0.1655
MA(4)	0.02	0.0046
R^2	0.0027	
AIC	8.6705	
SIC	8.6744	

Modele ait 24 saatlik önkestirim sonuçları ve karşılaştırmalı grafikler çalışmanın sonunda ele alınmıştır.



Şekil 4.5 Saatlik Litecoin verisine ait korelogram.

Saatlik Litecoin verisi için elde edilen Şekil 4.5'teki korelogram grafiğinin de Bitcoin ve Ethereum ile aynı sonucu verdiği görülmekle beraber ve serinin durağan olmadığı çıkarımı yapılabilir. Şekil 4.6 ile gösterilen zaman serisi grafiği de çizdirilerek serinin durağan olmadığı anlaşılmıştır



Şekil 4.6 Saatlik Litecoin verisine ait zaman serisi grafiği.

Durağanlığı belirlemek için Augmented Dickey-Fuller (ADF) testinden yararlanılmıştır.

Çizelge 4.7 Saatlik Litecoin verisine ait ADF test istatistik sonucu.

		t-istatistik	p-değeri
ADF test istatistiği		-1.90	0.3322
t-kritik değerleri	%1	-3.43	
	%5	-2.86	
	%10	-2.57	

$H_0: \delta = 0$ Seri durağan değildir.

$H_1: \delta < 0$ Seri durağandır.

Çizelge 4.7'e göre p-değeri=0.3322>0.05'tir. Bu durumda H_0 hipotezi reddedilemez ve serinin istatistiksel olarak %95 güvenilirlikte durağan olmadığı çıkarımı yapılır. Serinin durağan hale gelebilmesi için fark işlemi uygulanmalıdır.

Çizelge 4.8 Birinci dereceden farkı alınmış saatlik Litecoin verisinin ADF test istatistik sonucu.

		t-istatistik	p-değeri
ADF test istatistiği		-51.23	0.0001
t-kritik değerleri	%1	-3.43	
	%5	-2.86	
	%10	-2.57	

Çizelge 4.8'e göre $p\text{-değeri}=0.0001<0.05$ 'tir. Bu durumda H_0 hipotezi reddedilemez ve serinin istatistiksel olarak %95 güvenilirlikte durağan hale geldiği çıkarımı yapılır.


Seride durağanlık sağlandıktan sonra saatlik Ethereum verisi için olası modeller arasından analize en uygun model ARIMA (4,1,1) modeli olarak belirlenmiştir. Modele ait bilgiler Çizelge 4.9 ile verilmiştir.

Çizelge 4.9 Saatlik Litecoin serisine ait ARIMA modeli.

Değişken	Katsayı	p-değeri
C	0.04	0.4390
AR(4)	-0.04	0.0167
MA(1)	-0.10	0.0000
R^2	0.0130	
AIC	4.7099	
SIC	4.7205	


Modele ait 24 saatlik önkestirim sonuçları ve karşılaştırmalı grafikler çalışmanın sonunda ele alınmıştır.

Örneklem aralığı: 12/22/2020 3/22/2021
Gözlem sayısı: 91



Şekil 4.7 Günlük Bitcoin verisine ait korelogram.

Şekil 4.7’de gösterilen ve günlük Bitcoin verileri için de saatlik Bitcoin, Litecoin ve Ethereum veri setlerindeki yorumlar incelenen korelogram grafiğinden yola çıkılarak yapılır ve serinin durağan olmadığı yorumu yapılabilir. Bunun daha net anlaşılabilmesi için yine serinin zaman serisi grafiği çizdirilir.



Şekil 4.8 Günlük Bitcoin verisine ait zaman serisi grafiği.

Şekil 4.8’de de görüldüğü üzere seri belirli bir değer etrafında dağılım göstermemektedir ve durağan değildir. Durağanlık tespiti için ADF testi uygulanır.

Çizelge 4.10 Günlük Bitcoin verisine ait ADF test istatistik sonucu.

	t-istatistik	p-değeri
ADF test istatistiği	-1.41	0.5739
t-kritik değerleri		
%1	-3.50	
%5	-2.89	
%10	-2.58	

$H_0: \delta = 0$ Seri durağan değildir.

$H_1: \delta < 0$ Seri durağandır.

Çizelge 4.10’ye göre p-değeri=0.5739>0.05’tir. Bu durumda H_0 hipotezi reddedilemez ve serinin istatistiksel olarak %95 güvenlilikle durağan olmadığı çıkarımı yapılır. Serinin durağan hale gelebilmesi için fark işlemi uygulanır.

Çizelge 4.11İkinci dereceden farkı alınmış günlük Bitcoin verisinin ADF test istatistik sonucu.

		t-istatistik	p-değeri
ADF test istatistiği		-11.58	0.0001
t-kritik değerleri	%1	-3.51	
	%5	-2.90	
	%10	-2.58	


Çizelge 4.11'e göre $p\text{-değeri}=0.0001<0.05$ 'tir. Bu durumda H_0 hipotezi reddedilemez ve serinin ikinci farkta istatistiksel olarak %95 güvenilirlikte durağan hale geldiği çıkarımı yapılır ve seride durağanlık sağlandıktan sonra günlük Bitcoin verisi için olası modeller arasından analize en uygun model ARIMA (1,1,2) modeli olarak belirlenmiştir. Modele ait bilgiler çizelge 4.12 ile verilmiştir.

Çizelge 4.12 Günlük Bitcoin serisine ait ARIMA modeli.

Değişken	Katsayı	p-değeri
C	-4.61	0.5652
AR(1)	-1.00	0.0000
MA(2)	-1.00	0.0000
R^2	0.5179	
AIC	18.2001	
SIC	18.3120	


Modele ait 7 günlük önkestirim sonuçları ve karşılaştırmalı grafikler çalışmanın sonunda ele alınmıştır.

Örnekleme aralığı: 12/22/2020 3/22/2021
Gözlem sayısı: 91



Şekil 4.9 Günlük Ethereum verisine ait korelogram.

Şekil 4.9 incelendiğinde serinin otokorelasyonunun sıfıra bir anda değil yavaşça yaklaştığı görülmektedir. Bununla beraber serinin durağan olmadığı çıkarımı yapılmakla beraber, bu çıkarım seriye ait olan şekil 4.10'daki zaman serisi grafiğinden de anlaşılmaktadır.



Şekil 4.10 Günlük Ethereum verisine ait zaman serisi grafiği.

Durağan olmayan seriye ADF testi ile durağanlık testi yapılır.

Çizelge 4.13 Günlük Ethereum verisine ait ADF test istatistik sonucu.

		t-istatistik	p-değeri
ADF test istatistik		-1.98	0.2965
t-kritik değerleri:	%1	-3.50	
	%5	-2.89	
	%10	-2.58	

$H_0: \delta = 0$ Seri durağan değildir.

$H_1: \delta < 0$ Seri durağandır.

Çizelge 4.13'e göre p-değeri=0.2965>0.05'tir. Bu durumda H_0 hipotezi reddedilemez ve serinin istatistiksel olarak %95 güvenilrlikte durağan olmadığı çıkarımı yapılır. Seriyeye fark işlemi uygulanmalıdır.

Çizelge 4.14 Birinci dereceden farkı alınmış günlük Ethereum verisinin ADF test istatistik sonucu.

		t-istatistik	p-değeri
ADF test istatistik		-10.00	0.0000
t-kritik değerleri:	%1	-3.50	
	%2	-2.89	
	%3	-2.58	

$H_0: \delta = 0$ Seri durağan değildir.

$H_1: \delta < 0$ Seri durağandır.


Çizelge 4.14'e göre p-değeri=0.0000<0.05'tir. Bu durumda H_0 hipotezi reddedilemez ve serinin istatistiksel olarak %95 güvenilrlikte durağan hale geldiği çıkarımı yapılır. Seride durağanlık sağlandıktan sonra günlük Ethereum verisi için olası modeller arasından analize en uygun model ARIMA (10,1,10) modeli olarak belirlenmiştir. Modele ait bilgiler Çizelge 4.15 ile verilmiştir.

Çizelge 4.15 Günlük Ethereum serisine ait ARIMA modeli.

Değişken	Katsayı	p-değeri
C	10.17	0.4378
AR(10)	0.23	0.5192
MA(10)	0.14	0.7029
R^2	0.1408	
AIC	11.6209	
SIC	11.7320	


Modele ait 7 günlük önkestirim sonuçları ve karşılaştırmalı grafikler çalışmanın sonunda ele alınmıştır.

Örnekleme aralığı: 12/22/2020 3/22/2021
Gözlem sayısı: 91



Şekil 4.11 Günlük Litecoin verisine ait korelogram.

Litecoin için elde edilen Şekil 4.11 ile gösterilen korelogram grafiğinden yapılan çıkarım ile serinin durağan olmadığı çıkarımı yapılabilir. Şekil 4.12 ile gösterilen aynı veri setine ait olan zaman serisi grafiği çizdirilerek serinin durağan olmadığı anlaşılmıştır.



Şekil 4.12 Günlük Litecoin verisine ait zaman serisi grafiği.

Durağanlığı belirlemede ADF test istatistik aşaması kullanılmalıdır.

Çizelge 4.16 Günlük Litecoin verisine ait ADF test istatistik sonucu.

		t-istatistik	p-değeri
ADF test istatistik		-1.89	0.3334
t-kritik değerleri:	%1	-3.50	
	%5	-2.89	
	%10	-2.58	

$H_0: \delta = 0$ Seri durağan değildir.

$H_1: \delta < 0$ Seri durağandır.

Çizelge 4.16'ya göre p-değeri=0.3334>0.05'tir. Bu durumda reddedilemeyen H_0 hipotezi ile serinin istatistiksel olarak %95 güvenilirlikte durağan olmadığı çıkarımı yapılır. Serinin durağan hale gelebilmesi için fark işlemi uygulanmalıdır.

Çizelge 4.17 Birinci dereceden farkı alınmış günlük Litecoin verisinin ADF test istatistik sonucu.

		t-istatistik	p-değeri
ADF test istatistik		-8.82	0.0000
t-kritik değerleri:	%1	-3.50	
	%2	-2.89	
	%3	-2.58	

$H_0: \delta = 0$ Seri durağan değildir.

$H_1: \delta < 0$ Seri durağandır.

Çizelge 4.17'e göre p-değeri=0.0000 <0.05'tir. Bu durumda kabul edilen H_0 hipotezi ile serinin istatistiksel olarak %95 güvenilirlilikte durağan olmadığı çıkarımı yapılır.


Seride durağanlık sağlandıktan sonra günlük Litecoin verisi için olası modeller arasından analize en uygun model ARIMA (13,1,1) modeli olarak belirlenmiştir. Modele ait bilgiler Çizelge 4.18 ile aktarılmıştır.

Çizelge 4.18 Günlük Litecoin serisine ait ARIMA modeli.

Değişken	Katsayı	p-değeri
C	0.78	0.3915
AR(13)	-0.28	0.0506
MA(1)	0.05	0.0000
R^2	0.0904	
AIC	7.5321	
SIC	7.6432	


Modele ait 7 günlük önkestirim sonuçları ve karşılaştırmalı grafikler çalışmanın sonunda ele alınmıştır.

Ele alınan zaman serilerine ait YSA modelleri için elde edilen sonuçlar ve bu sonuçlara ilişkin yorumlar aşağıda verilmektedir.




Şekil 4.13 Saatlik Bitcoin verisine ait yapay sinir ağı modeli.

Şekil 4.13 Saatlik Bitcoin verisine ait olan Yapay Sinir Ağları (YSA) modelini göstermektedir. Bu modele bakarak algoritmaya ait bilgilere, eğitim süreci bilgilerine ve model performansını değerlendirmede kullanılacak grafiklere ulaşılabilmektedir. Bu bilgilerden yola çıkılarak model ile ilgili ağıda eğitim yaparken verilerin rassal olarak alındığı, eğitim algoritması olarak Levenberg-Marquardt algoritmasının kullanıldığı, model performansını ölçmede hata kareler ortalamasının kullanıldığını (HKO), eğitimin 66 iterasyonda tamamlandığı gibi çıkarımlar yapılabilmektedir.




Şekil 4.14 Saatlik Bitcoin verisi için zamana göre çıktı, hedef ve hatalar.

Şekil 4.14 girdileri, hedefleri ve hataları zamana karşı gösterir. Ayrıca eğitim, test ve doğrulama için hangi zaman noktalarının seçildiğini de gösterir.




Şekil 4.15 Saatlik Bitcoin verisinin eğitim, doğrulama ve test kümelerine ait hata performansları.

Şekil 4.15 veri setinin eğitilmesi sonucunda her iterasyondaki eğitim, doğrulama ve test kümelerine ait HKO değerlerinin değişimini göstermektedir ve eğitimin 60. iterasyonda tamamlandığını göstermektedir. Doğrulamadaki en düşük HKO 60. iterasyonda ölçülen 216249.4807 değeridir.




Şekil 4.16 Modeldeki gizli katmanda eğitim, doğrulama, test ve tüm model sonuçlarına ait R değerleri.

Şekil 4.16’da modeldeki eğitim, doğrulama ve test veri gruplarının regresyon değerleri yer almaktadır. Burada R değerleri korelasyonu ve modelin öğrenme başarısını göstermektedir. R değerleri 0.95 ve üzeridir. Yüksek olan bu R değerleri modelde öğrenme işleminin başarılı olduğunu göstermektedir.




Şekil 4.17 Saatlik Bitcoin verisine ait gizli katman ile oluşan hata grafiği.

Şekil 4.17 ile gösterilen hata histogramı, bir sinir ağıının eğitim sonrası hedef değerler ile önkestirim edilen değerler arasındaki hataların histogramını göstermektedir. Bu hata değerleri, önkestirim edilen değerlerin hedef değerlerden ne kadar farklı olduğunu gösterdiğinden negatif de olabilir. Bins'ler, grafikte gözlemlediğimiz dikey çubukların sayısıdır. Toplam hata aralığı burda 20 küçük kutuya bölünmüştür. Hata ekseninde (X eksen) sıfır hata değerine karşılık gelen sıfır hata satırı 203.5 merkezli kutunun altına düşmektedir.




Şekil 4.18 Saatlik Bitcoin verisine ait sonraki 24 saatlik önkestirim grafiği.

Şekil 4.18’de grafiğin sonunda daire içinde belirtilmiş olan değerler Bitcoin için 24 saatlik YSA önkestirim değerlerini göstermektedir. Önkestirim değerleri çalışma sonunda karşılaştırılmalı olarak grafiklerle ele alınacaktır.




Şekil 4.19 Saatlik Ethereum verisi için zamana göre çıktı, hedef ve hatalar.

Şekil 4.19 belirli zamandaki girdileri, hedefleri ve hataları göstermekle beraber eğitim, test ve doğrulama için hangi zaman noktalarının seçildiğini de gösterir.




Şekil 4.20 Saatlik Ethereum verisinin eğitim, doğrulama ve test kümelerine ait hata performansları.

Şekil 4.20'de 16. iterasyonda tamamlandığını ve en düşük HKO değerinin 16. iterasyondaki 412.6644 olduğunu göstermektedir.




Şekil 4.21 Modeldeki gizli katmanda eğitim, doğrulama, test ve tüm model sonuçlarına ait R değerleri.

Şekil 4.21’de tüm R değerleri 0.99 ve üzeridir. Bu R değerleri modelde öğrenme işleminin başarılı olduğunu göstermektedir.




Şekil 4.22 Saatlik Ethereum verisine ait gizli katman ile oluşan hata grafiği.

Şekil 4.22 incelendiğinde, hata ekseninde (X eksen) sıfır hata değerine karşılık gelen sıfır hata satırı 4.706 merkezli kutunun altına düşmektedir.




Şekil 4.23 Saatlik Ethereum verisine ait sonraki 24 saatlik önkestirim grafiği.

Şekil 4.23’da grafiğin sonunda daire içinde belirtilmiş olan değerler Ethereum için 24 saatlik önkestirim değerlerini vermekle beraber bu 24 saatlik değerler çalışma sonucunda karşılaştırılmalı grafiklerle açıklanacaktır.




Şekil 4.24 Saatlik Litecoin verisi için zamana göre çıktı, hedef ve hatalar.

Şekil 4.24 girdileri, hedefleri ve hataları zamana karşı gösterir. Ayrıca eğitim, test ve doğrulama için hangi zaman noktalarının seçildiğini de gösterir.




Şekil 4.25 Saatlik Litecoin verisinin eğitim, doğrulama ve test kümelerine ait hata performansları.

Şekil 4.25' te eğitimin 3. iterasyonda tamamlanmasına ek olarak 3. iterasyonda 6.3628 ile en düşük HKO değerini verdiği görülmektedir.




Şekil 4.26 Modeldeki gizli katmanda eğitim, doğrulama, test ve tüm model sonuçlarına ait R değerleri.

Şekil 4.26’da tüm R değerleri 0.99 ve üzeridir. Yüksek olan bu R değerleri modelde öğrenme işleminin başarılı olduğunu göstermektedir.




Şekil 4.27 Saatlik Litecoin verisine ait gizli katman ile oluşan hata grafiği.

Şekil 4.27 incelendiğinde, hata ekseninde (X eksen) sıfır hata değerine karşılık gelen sıfır hata satırı -0.239 merkezli kutunun olduğu sütuna denk gelmektedir.




Şekil 4.28 Saatlik Bitcoin verisine ait sonraki 24 saatlik önekestirim grafiği.

Şekil 4.28, 24 saatlik YSA önkestirim değerlerini göstermektedir. Önkestirim değerleri çalışma sonucunda karşılaştırılmalı olarak grafiklerle açıklanacaktır.




Şekil 4.29 Günlük Bitcoin verisine ait yapay sinir ağıları modeli.

Şekil 4.29'dan yola çıkılarak model ile ilgili ağda eğitim yaparken verilerin rassal olarak alındığı, eğitim algoritması olarak Levenberg-Marquardt algoritmasının kullanıldığı, model performansını ölçmede hata kareler ortalamasının kullanıldığını (HKO), eğitimin 14 iterasyonda tamamlandığı gibi çıkarımlar yapılabilmektedir.




Şekil 4.30 Günlük Bitcoin verisi için zamana göre çıktı, hedef ve hatalar.

Şekil 4.30 girdileri, hedefleri ve hataları zamana karşı gösterir. Ayrıca eğitim, test ve doğrulama için hangi zaman noktalarının seçildiğini de gösterir.




Şekil 4.31 Günlük Bitcoin verisinin eğitim, doğrulama ve test kümelerine ait hata performansları.

Şekil 4.31 HKO değerlerinin değişimini göstermektedir ve eğitimin 8. iterasyonda tamamlandığını ve en düşük HKO değerinin 8. iterasyondaki 6791319.5237 olduğunu göstermektedir.




Şekil 4.32 Modeldeki gizli katmanda eğitim, doğrulama, test ve tüm model sonuçlarına ait R değerleri.

Şekil 4.32’te modeldeki eğitim, doğrulama ve test veri gruplarının regresyon değerleri yer almaktadır. Burada R değerleri korelasyonu ve modelin öğrenme başarısını göstermektedir. R değerleri 0.95 ve üzeridir. Yüksek olan bu R değerleri modelde öğrenme işleminin başarılı olduğunu göstermektedir.




Şekil 4.33 Günlük Bitcoin verisine ait gizli katman ile oluşan hata grafiği.

Şekil 4.33'te hata ekseninde (X eksen) sıfır hata değerine karşılık gelen sıfır hata satırı -161.6 merkezli kutunun olduğu sütuna denk gelmektedir.




Şekil 4.34 Günlük Bitcoin verisine ait sonraki 7 günlük önekestirim grafiği.

Şekil 4.34'te grafiğin sonunda daire içinde belirtilmiş olan değerler Bitcoin için 7 günlük YSA önekestirim değerlerini göstermektedir. Önekestirim değerleri çalışma sonucunda karşılaştırılmalı olarak grafiklerle açıklanacaktır.




Şekil 4.35 Günlük Ethereum verisi için zamana göre çıktı, hedef ve hatalar.

Şekil 4.35 girdileri, hedefleri ve hataları zamana karşı gösterir. Ayrıca eğitim, test ve doğrulama için hangi zaman noktalarının seçildiğini de gösterir.




Şekil 4.36 Günlük Ethereum verisinin eğitim, doğrulama ve test kümelerine ait hata performansları.

Şekil 4.36 veri setinin eğitilmesi sonucunda her iterasyondaki eğitim, doğrulama ve test kümelerine ait HKO değerlerinin değişimini göstermektedir ve eğitimin 3. İterasyonda tamamlandığını, bu noktada en düşük HKO değerinin 13992.8643 olduğunu göstermektedir.




Şekil 4.37 Modeldeki gizli katmanda eğitim, doğrulama, test ve tüm model sonuçlarına ait R değerleri.

Şekil 4.37’de 0.95 üzeri olan R değerleri modelin yüksek öğrenme başarısını göstermektedir.




Şekil 4.38 Günlük Ethereum verisine ait gizli katman ile oluşan hata grafiği.

Şekil 4.38 incelendiğinde, hata ekseninde sıfır hata değerine karşılık gelen sıfır hata satırı 0.5552 merkezli kutunun olduğu sütuna denk gelmektedir.




Şekil 4.39 Günlük Ethereum verisine ait sonraki 7 günlük önkestirim grafiği.

Şekil 4.39’da grafiğin sonunda daire içinde belirtilmiş olan değerler Ethereum için 7 günlük YSA önkestirim değerlerini göstermektedir. Önkestirim değerleri çalışma sonucunda karşılaştırılmalı olarak grafiklerle açıklanacaktır.




Şekil 4.40 Günlük Litecoin verisi için zamana göre çıktı, hedef ve hatalar.

Şekil 4.40 girdileri, hedefleri ve hataları zamana karşı gösterir. Ayrıca eğitim, test ve doğrulama için hangi zaman noktalarının seçildiğini de gösterir.




Şekil 4.41 Günlük Litecoin Verisinin eğitim, doğrulama ve test kümelerine ait hata performansları.

Şekil 4.41 veri setinin eğitilmesi sonucunda her iterasyondaki eğitim, doğrulama ve test kümelerine ait HKO değerlerinin değişimini göstermektedir ve eğitimin 2. iterasyonda en düşük HKO değeri olan 121.9727 değeri ile tamamlandığını göstermektedir




Şekil 4.42 Modeldeki gizli katmanda eğitim, doğrulama, test ve tüm model sonuçlarına ait R değerleri.

Şekil 4.42’de yüksek olan R değerleri modelin öğrenme başarısını göstermektedir ve tüm R değerleri 0.90 üzeridir. Modelde öğrenme işleminin başarılı olduğunu göstermektedir.



Şekil 4.43 Günlük Litecoin verisine ait gizli katman ile oluşan hata grafiği.

Şekil 4.43 incelendiğinde, hata ekseninde sıfır hata değerine karşılık gelen sıfır hata satırı -0.03062 merkezli kutunun olduğu sütuna denk gelmektedir.



Şekil 4.44 Günlük Litecoin verisine ait sonraki 7 günlük önkestirim grafiği.

Şekil 4.44'te grafiğin sonunda daire içinde belirtilmiş olan değerler Litecoin için 7 günlük YSA önkestirim değerlerini göstermektedir. Önkestirim değerleri çalışma sonucunda karşılaştırmalı olarak grafiklerle açıklanacaktır.

İlgilenilen zaman serileri için ATA metod için elde edilen sonuçlar ve bu sonuçlara ilişkin yorumlar aşağıda verilmektedir.

Daha önce bahsedilen ARIMA ve YSA yöntemleri ile yapılan analizlerde olduğu gibi ATA metodunda da önkestirim yaparken günlük verilerde veri setinde kullanılan son günlük veriyi takip eden 7 günlük veri ve saatlik verilerde kullanılan son veriyi takip eden 24 saatlik veri kullanılmayarak metodun doğruluğu test edilmiştir.

Yılmaz (2018), ortalama mutlak hata (Mean Absolute Error(MAE)), HKO (Hata Kareler Ortalaması) ve simetrik ortalama mutlak hata (symmetric Mean Absolute Percentage Error (sMAPE)) ölçütlerinin uygun doğruluk ölçütlerinden bazıları olduğunu belirtmiştir.

Çizelge 4.19 ATA metod ile kripto para birimleri model belirleme.

Kripto Paralar	Model	sMAPE
Bitcoin Günlük	Mevsimsel olmayan	3.05
	Mevsimsel	14.58
Ethereum Günlük	Mevsimsel olmayan	4.43
	Mevsimsel	13.32
Litecoin Günlük	Mevsimsel olmayan	3.21
	Mevsimsel	13.28
Bitcoin Saatlik	Mevsimsel olmayan	0.69
	Mevsimsel	0.99
Ethereum Saatlik	Mevsimsel olmayan	0.78
	Mevsimsel	0.62
Litecoin Saatlik	Mevsimsel olmayan	0.65
	Mevsimsel	0.74

Çizelge 4.19'de kripto para birimlerine ait kurulan mevsimsel ve mevsimsel olmayan model belirlemede sMAPE ölçütü kullanılmıştır. Alınan sonuçlara göre Ethereum saatlik verisinde uygun model mevsimsel model olarak, diğer verilerde ise mevsimselliğin olmadığı modeller uygun model olarak belirlenmiştir.

Çizelge 4.20 Saatlik veri setlerine ait önkestirim sonuçları.

Bitcoin (\$)	Ethereum (\$)	Litecoin (\$)
56916.74	1784.13	195.65
56943.72	1782.50	195.65
56970.71	1787.31	195.65
56997.72	1789.11	195.65
57024.73	1786.04	195.65
57051.76	1790.17	195.65
57078.80	1790.08	195.65
57105.86	1787.82	195.65
57132.93	1789.62	195.65
57160.01	1792.36	195.65
57187.10	1792.31	195.65
57214.21	1794.28	195.65
57241.32	1789.06	195.65
57268.46	1783.09	195.65
57295.60	1787.44	195.65
57322.76	1790.62	195.65
57349.93	1789.49	195.65
57377.11	1794.32	195.65
57404.31	1803.66	195.65
57431.52	1803.45	195.65
57458.74	1802.23	195.65
57485.97	1799.89	195.65
57513.22	1797.28	195.65
57540.48	1800.97	195.65

Çizelge 4.20’de uygun modeller ile elde edilen saatlik veri setlerine ait 24 saatlik önkestirim sonuçları verilmiştir.

Çizelge 4.21 Kripto Paralara ait HKO değerleri.


	Kripto Paralar	HKO Değerleri
ARIMA	Bitcoin Saatlik	1352667.81
	Ethereum Saatlik	1350.68
	Litecoin Saatlik	3.69
	Bitcoin Günlük	15150813.96
	Ethereum Günlük	22332.56
	Litecoin Günlük	185.05
YSA	Bitcoin Saatlik	513277.75
	Ethereum Saatlik	288.52
	Litecoin Saatlik	2.82
	Bitcoin Günlük	7213778.49
	Ethereum Günlük	17682.97
	Litecoin Günlük	82.92
ATA	Bitcoin Saatlik	205117.14
	Ethereum Saatlik	217.29
	Litecoin Saatlik	2.62
	Bitcoin Günlük	4706651.29
	Ethereum Günlük	8034.01
	Litecoin Günlük	58.519

Çizelge 4.21 ile verilen sonuçlarda, model belirlemede kullanılan HKO değerleri ARIMA, YSA ve ATA yöntemleri için karşılaştırıldığında, ATA yöntemi hatayı en aza indirerek gerçek değerlere en yakın önkestirim sonuçlarını vermiştir.

Çizelge 4.22 Bitcoin için saatlik gerçek ve önkestirim değerleri.

ZAMAN	BITCOIN (\$)	ARIMA (\$)	YSA (\$)	ATA (\$)
21.03.2021/14:00	57226.70	56237.97	57013.11	56916.74
21.03.2021/15:00	57238.39	56214.40	56989.95	56943.72
21.03.2021/16:00	57255.31	56240.10	56967.45	56970.71
21.03.2021/17:00	57297.08	56193.66	56945.60	56997.72
21.03.2021/18:00	57425.55	56226.28	56924.42	57024.73
21.03.2021/19:00	57583.82	56235.24	56903.89	57051.76
21.03.2021/20:00	57819.01	56247.71	56884.02	57078.80
21.03.2021/21:00	58143.87	56271.55	56864.80	57105.86
21.03.2021/22:00	57604.01	56205.57	56846.22	57132.93
21.03.2021/23:00	57381.79	56232.86	56828.27	57160.01
22.03.2021/00:00	56585.27	56253.00	56810.94	57187.10
22.03.2021/01:00	56611.91	56263.10	56794.23	57214.21
22.03.2021/02:00	56988.52	56279.71	56778.11	57241.32
22.03.2021/03:00	57584.31	56294.43	56762.58	57268.46
22.03.2021/04:00	57606.61	56307.31	56747.62	57295.60
22.03.2021/05:00	57600.00	56323.46	56733.22	57322.76
22.03.2021/06:00	57677.50	56334.84	56719.36	57349.93
22.03.2021/07:00	57585.38	56351.44	56706.03	57377.11
22.03.2021/08:00	57213.17	56366.48	56693.22	57404.31
22.03.2021/09:00	57387.73	56381.76	56680.90	57431.52
22.03.2021/10:00	57942.06	56397.78	56669.06	57458.74
22.03.2021/11:00	57720.67	56407.86	56657.69	57485.97
22.03.2021/12:00	57266.22	56424.12	56646.77	57513.22
22.03.2021/13:00	56748.00	56439.90	56636.29	57540.48

Çizelge 4.22’de saatlik Bitcoin verileri için, gerçek değerler ve kullanılan yöntemlerden elde edilen önkestirim sonuçları verilmiştir.




Şekil 4.45 Saatlik Bitcoin verisine ait gerçek-önkestirim değer karşılaştırma grafiği.

Şekil 4.45'te saatlik Bitcoin verisine ait gerçek ve önkestirim değer karşılaştırma grafiği verilmiştir.

Çizelge 4.23 Ethereum için saatlik gerçek ve önkestirim değerleri.

ZAMAN	ETHEREUM (\$)	ARIMA	YSA	ATA
21.03.2021/14:00	1786.65	1814.61	1783.26	1784.13
21.03.2021/15:00	1790.47	1815.15	1782.18	1782.49
21.03.2021/16:00	1781.04	1815.69	1781.14	1787.31
21.03.2021/17:00	1790.90	1816.23	1780.14	1789.11
21.03.2021/18:00	1794.85	1816.77	1779.16	1786.04
21.03.2021/19:00	1797.56	1817.31	1778.22	1790.17
21.03.2021/20:00	1799.73	1817.84	1777.31	1790.08
21.03.2021/21:00	1810.79	1818.38	1776.43	1787.82
21.03.2021/22:00	1785.98	1818.92	1775.58	1789.62
21.03.2021/23:00	1783.59	1819.46	1774.75	1792.36
22.03.2021/00:00	1757.38	1820.00	1773.96	1792.31
22.03.2021/01:00	1763.96	1820.54	1773.19	1794.28
22.03.2021/02:00	1771.79	1821.08	1772.45	1789.06
22.03.2021/03:00	1784.03	1821.62	1771.74	1783.09
22.03.2021/04:00	1788.38	1822.16	1771.05	1787.44
22.03.2021/05:00	1787.78	1822.70	1770.38	1790.62
22.03.2021/06:00	1789.41	1823.24	1769.74	1789.49
22.03.2021/07:00	1788.27	1823.78	1769.12	1794.32
22.03.2021/08:00	1780.22	1824.32	1768.52	1803.66
22.03.2021/09:00	1781.97	1824.86	1767.94	1803.45
22.03.2021/10:00	1794.30	1825.40	1767.38	1802.23
22.03.2021/11:00	1795.85	1825.94	1766.84	1799.89
22.03.2021/12:00	1784.00	1826.48	1766.33	1797.28
22.03.2021/13:00	1778.41	1827.02	1765.83	1800.97

Çizelge 4.23'te saatlik Ethereum verileri için, gerçek değerler ve kullanılan yöntemlerden elde edilen önkestirim sonuçları verilmiştir.




Şekil 4.46 Saatlik Ethereum verisine ait gerçek-önkestirim değer karşılaştırma grafiği.

Şekil 4.46’da saatlik Ethereum verisine ait gerçek ve önkestirim değer karşılaştırma grafiği verilmiştir.

Çizelge 4.24 Litecoin için saatlik gerçek ve önkestim değerleri.

ZAMAN	LITECOIN (\$)	ARIMA (\$)	YSA (\$)	ATA (\$)
21.03.2021/14:00	196.26	194.08	196.10	195.64
21.03.2021/15:00	195.77	194.11	196.00	195.64
21.03.2021/16:00	195.96	194.17	196.09	195.64
21.03.2021/17:00	196.70	194.20	196.08	195.64
21.03.2021/18:00	197.12	194.24	196.08	195.64
21.03.2021/19:00	196.95	194.28	196.07	195.64
21.03.2021/20:00	198.18	194.31	196.06	195.64
21.03.2021/21:00	198.14	194.35	196.05	195.64
21.03.2021/22:00	196.48	194.39	196.03	195.64
21.03.2021/23:00	195.53	194.43	196.01	195.64
22.03.2021/00:00	192.40	194.46	195.99	195.64
22.03.2021/01:00	191.99	194.50	195.97	195.64
22.03.2021/02:00	192.95	194.54	195.94	195.64
22.03.2021/03:00	194.62	194.58	195.90	195.64
22.03.2021/04:00	194.82	194.61	195.86	195.64
22.03.2021/05:00	194.61	194.65	195.80	195.64
22.03.2021/06:00	194.80	194.69	195.74	195.64
22.03.2021/07:00	194.80	194.73	196.00	195.64
22.03.2021/08:00	193.29	194.76	195.56	195.64
22.03.2021/09:00	194.48	194.80	195.44	195.64
22.03.2021/10:00	195.66	194.84	195.29	195.64
22.03.2021/11:00	196.27	194.88	195.01	195.64
22.03.2021/12:00	195.38	194.91	194.86	195.64
22.03.2021/13:00	196.71	194.95	194.57	195.64

Çizelge 4.24'te saatlik Litecoin verileri için, gerçek değerler ve kullanılan yöntemlerden elde edilen önkestim sonuçları verilmiştir.




Şekil 4.47 Saatlik Litecoin verisine ait gerçek-önkestirim değer karşılaştırma grafiği.

Şekil 4.47’de saatlik Litecoin verisine ait gerçek ve önkestirim değer karşılaştırma grafiği verilmiştir.

Çizelge 4.25 Bitcoin için günlük gerçek ve önkestim değerleri.

ZAMAN	BITCOIN (\$)	ARIMA (\$)	YSA (\$)	ATA (\$)
23.03.2021	54361.57	57711.34	53388.85	55454.12
24.03.2021	52287.52	57645.99	52960.36	55420.56
25.03.2021	51326.11	58022.45	52821.61	55410.49
26.03.2021	55081.37	57947.89	52789.92	55407.47
27.03.2021	55839.42	58315.14	52783.33	55406.57
28.03.2021	55790.92	58231.36	52781.98	55406.29
29.03.2021	57600.10	58589.39	52781.71	55406.21

Çizelge 4.25'te günlük Bitcoin verileri için, gerçek değerler ve kullanılan yöntemlerden elde edilen önkestim sonuçları verilmiştir.




Şekil 4.48 Günlük Bitcoin verisine ait gerçek-önkestirim değer karşılaştırma grafiği.

Şekil 4.48'de günlük Bitcoin verisine ait gerçek ve önkestim değer karşılaştırma grafiği verilmiştir.

Çizelge 4.26 Ethereum için günlük gerçek ve önkestirim değerleri.

ZAMAN	ETHEREUM (\$)	ARIMA (\$)	YSA (\$)	ATA (\$)
23.03.2021	1670.160	1832.410	1743.160	1730.560
24.03.2021	1582.940	1812.720	1774.490	1729.530
25.03.2021	1586.260	1798.250	1791.840	1729.010
26.03.2021	1699.370	1803.530	1804.510	1728.750
27.03.2021	1713.60	1811.460	1814.250	1728.620
28.03.2021	1686.50	1795.20	1821.50	1728.560
29.03.2021	1817.220	1812.460	1826.570	1728.530

Çizelge 4.26’da günlük Ethereum verileri için, gerçek değerler ve kullanılan yöntemlerden elde edilen önkestirim sonuçları verilmiştir.




Şekil 4.49 Günlük Ethereum verisine ait gerçek-önkestirim değer karşılaştırma grafiği.

Şekil 4.49’da günlük Ethereum verisine ait gerçek ve önkestirim değer karşılaştırma grafiği verilmiştir.

Çizelge 4.27 Litecoin için günlük gerçek ve önkestirim değerleri.

ZAMAN	LITECOIN (\$)	ARIMA (\$)	YSA (\$)	ATA (\$)
23.03.2021	185.85	194.89	184.14	186.55
24.03.2021	175.95	195.54	180.28	186.55
25.03.2021	171.48	191.01	176.55	186.55
26.03.2021	183.70	190.51	175.75	186.55
27.03.2021	184.14	194.93	175.67	186.55
28.03.2021	184.27	199.73	175.66	186.55
29.03.2021	193.66	200.49	175.66	186.55

Çizelge 4.27’de günlük Litecoin verileri için, gerçek değerler ve kullanılan yöntemlerden elde edilen önkestirim sonuçları verilmiştir.



Şekil 4.50 Günlük Litecoin verisine ait gerçek-önkestirim değer karşılaştırma grafiği.

Şekil 4.50’de günlük Litecoin verisine ait gerçek ve önkestirim değer karşılaştırma grafiği verilmiştir.

5. TARTIŞMA ve SONUÇ

Zaman serileri analizi, istatistik biliminde gelecek dönemler hakkında bilgi sağlaması özelliği bakımından oldukça önemli bir yere sahip olmakla beraber, gelecek dönem önkestirimlerinin gerçek değerlere en yakın sonuçları vermede kullanılan farklı yaklaşımlar söz konusudur. Her ne kadar zaman serileri modele katılamayan pek çok unsur ve değişkenden etkilense de bu etkileri hesaba katarak gerçeğe en yakın sonucu veren modelin belirlenmesi, gelecek dönemler için doğru önkestirim sonuçlarına bağlı olarak gerekli önlemlerin alınması ya da yatırımların yapılabilmesi bakımından da büyük önem arz etmektedir.

Önkestirim yapmak amacıyla farklı kullanılan modellerin karşılaştırılmasında farklı kriter ve yaklaşımlar olmakla beraber, ana kriter gözlem değerleri ile elde edilen kestirim değerleri arasındaki farkın genelini ifade eden hata üzerine kurulu olup bu hatanın en küçük olduğu model en iyi model olarak belirlenmektedir.

Bu çalışmada ele alınan kripto paralara ait zaman serilerinin modellenmesinde ARIMA, YSA ve ATA metotları kullanılarak, bu metotların performanslarını karşılaştırmada HKO ölçütünden yararlanılmıştır.

ARIMA modeller zaman serisi analizinde çok bilinen bir model grubu olmakla beraber, Yapay Sinir Ağları da zaman serileri analizinde kullanılan ve önemi gün geçtikçe artan bir algoritma yaklaşımı olarak karşımıza çıkmaktadır. ATA metodu ise, son zamanlarda önkestirim yapmada bilinen yöntemlere alternatif olarak ortaya çıkan ve uluslararası alanda yapılan yarışmalarda önkestirim doğruluğu yanında basitliği açısından oldukça başarılı sonuçlar vermiş olan yeni ve etkili bir zaman serisi modelleme yaklaşımıdır.

Bu çalışmada kripto para birimleri olan Bitcoin, Ethereum ve Litecoin için saatlik ve günlük veriler kullanılarak olarak ARIMA, YSA ve ATA metotları ile önkestirimler elde edilerek bu önkestirim değerleri gerçek değerlerle karşılaştırılarak en etkili metot belirlenmiştir.

Elde edilen analiz sonuçlarından da görüleceği üzere YSA'ndan elde edilen önkestirim değerleri ARIMA modellerinden elde edilen önkestirim değerlerinden gerçeğe daha yakın iken, ATA Metot aracılığı ile elde edilen önkestirim değerlerinin de YSA'dan elde edilen değerlere göre gerçeğe daha yakın olduğu belirlenmiştir.

ATA metodu son yıllarda önemi artan ve mevcut diğer yöntemlere göre daha yansız önkestirimler veren bir yaklaşım olmakla beraber, bu çalışmadan elde edilen sonuçlar Yapar vd. (2017, 2018, 2019)'nin yaptığı çalışmalardan elde edilen sonuçlara benzer olup, ATA metodunun karşılaştırıldığı diğer yöntemlere karşı başarısına benzer sonuçlar göstermektedir.

Bu çalışmada kripto paralara ait zaman serilerinin modellenmesinde ve önkestirim değerlerinin elde edilmesinde kullanılan teknikler ve elde edilen sonuçlar çalışmanın özgünlüğünü ortaya koyma bakımından da oldukça önemli olup, en azından ilgili veri seti dikkate alındığında elde edilen sonuçlara da bağlı olarak kripto paraların modellenmesinde diğer yaklaşımlara nazaran ATA metodunun kullanılarak önkestirim değerlerinin elde edilmesi ve buna bağlı politikaların geliştirilmesi önerilebilir.

6. KAYNAKLAR

- Anderson D, McNeill G, 1992, Artificial Neural Networks Technology, Griffiss AFB, 83p, the United States of America.
- Akdi Y, 2003, Zaman Serileri Analizi Birim Kökler ve Kointegrasyon, Bıçaklar Kitabevi, 298s, Ankara.
- Akkaş F E, 2020, Balina Optimizasyon Algoritması ve Levenberg-Marquardt Yöntemi ile Doğal Uçlaşma Verilerinin Ters Çözümü İçin Ardışık Melez Bir Yaklaşım, Süleyman Demirel Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, 86s, Isparta.
- Ansarı H, 2020, Artificial Neural Network: Learn About Electronics, Independently Publisher, 87p, the United States of America.
- Ataseven B, 2013, Yapay Sinir Ağları ile Öngörü Modellemesi, Öneri Dergisi, 10, 101–115.
- Box G E P, Jenkins G M, 1976, Time Series Analysis Forecasting and Control, Revised Edition, Holden-Day, 575p, the United States of America.
- Box G E P, Jenkins G M, Reinsel G C, 1994, Time Series Analysis Forecasting and Control, Prentice-Hall, 598p, the United States of America.
- Bölük E, 2012, Zaman Serisi Modellerinin Belirlenmesinde Artıklara Uygulanan Tanı Teknikleri Üzerine Bir Çalışma, Dokuz Eylül Üniversitesi, Sosyal Bilimler Enstitüsü, Yüksek Lisans Tezi, 126s, İzmir.
- Bunjaku F, Trajkovska G O, Kacarski M E, 2017, Cryptocurrencies – Advantages and Disadvantages, Journal of Economics, 2, 31–39.
- Bhosale J, Mavale S, 2018, Volatility of Select Crypto-currencies: A comparison of Bitcoin, Ethereum and Litecoin, Annual Research Journal of SCMS, 6, 132–141.
- Brown B L, 1959, Statistical Forecasting for Inventory Control, McGraw- Hill, 232p, New York.

- Can S, 2020, Rüzgar Türbinleri Kullanılarak Üretilen Elektrik Enerjisi Miktarının Zaman Serileri ile Analizi ve Uygulaması, İskenderun Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, 87s, İskenderun.
- Cavuto D J, 1997, An Exploration and Development of Current Artificial Neural Network Theory and Applications with Emphasis on Artificial Life, Albert Nerken School of Engineering, Degree of Master, 117p, New York.
- Chatfield C, 2000, Time Series Forecasting, Chapman & Hall/CRC, 265p, The United States of America.
- Chatfield C, Xing H, 2019, The Analysis of Time Series an Introduction with R, Chapman & Hall/CRC, 398p, the United States of America.
- Çelik B, 2008, Yapay Sinir Ağları Metodolojisi ile Zaman Serisi Analizi: Teori ve Uygulama, Marmara Üniversitesi, Sosyal Bilimler Enstitüsü, Yüksek Lisans Tezi, 224s, İstanbul.
- Danial K, 2019, Cryptocurrency Investing for Dummies, John Wiley & Sons, 326s, New Jersey, The United States of America.
- Demirkoparan F, 2010, Zaman Serisi Analizinde Esnek Hesaplama Teknikleri (Türkiye Dış Ticaret Örneği), Cumhuriyet Üniversitesi, Sosyal Bilimler Enstitüsü, Yüksek Lisans Tezi, 93s, Sivas.
- Duru Ö, 2007, Zaman Serileri Analizinde ARIMA Modelleri ve Bir Uygulama, İstanbul Üniversitesi, Sosyal Bilimler Enstitüsü, Yüksek Lisans Tezi, 92s, İstanbul.
- Erturan M B, 2017, Zaman Serileri için Optimize ARIMA – YSA Hibrit Modeli ve Finansal Zaman Serileri ile Örnek Uygulamalar, Akdeniz Üniversitesi, Sosyal Bilimler Enstitüsü, Doktora Tezi, 127s, Antalya.
- Fausett L, 1994, Fundamentals Of Neural Networks Architectures, Algorithms and Applications, Prentice-Hall, 461p, the United States of America.
- Fuller W A, 1996, Introduction to Statistical Time Series, John Wiley & Sons, Inc., 698p, Canada.

- Gençoğlu M T, 1995, Zaman Serilerinde Mevsim Dalgalanmaları ve Ortalama Altın Fiyatları Üzerine Bir Deneme, Fırat Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, 51s, Elazığ.
- Gujarati D N, Porter D C, 2009, Basic Econometrics, McGraw-Hill, 921p, the United States of America.
- Hamilton J D, 1994, Time Series Analysis, Copyright, 407s, Amerika Birleşik Devletleri.
- Keskenler M F, Keskenler E F, 2017, Geçmişten Günümüze Yapay Sinir Ağları ve Tarihçesi, Takvim-i Vekayi, 5, 8–18.
- Khashei M, Bijari M, 2011, A Novel Hybridization of Artificial Neural Networks and ARIMA Models for Time Series Forecasting, Applied Soft Computing, 11, 2664–2675.
- Kirchgässner G, Wolters J, 2007, Introduction to Modern Time Series Analysis, Springer- Verlag Berlin Heidelberg, 274p, Germany.
- Lu Y, AbouRizk S M, 2009, Automated Box-Jenkins Forecasting Modelling, Automation in Construction, 18, 547–558.
- Makridakis S, Hibon M, 2000, The M3-Competition: Results, Conclusions and Implications, International Journal of Forecasting, 16, 451–476.
- Matharu A, 2019, Understanding Cryptocurrencies The Money of the Future, Business Expert Press, 107p, the United States of America.
- Oğhan S, 2010, Zaman Serisi Analiz Yöntemlerinin Karşılaştırılması, Ege Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, 75s, İzmir.
- Oruç B, 2012, Teori ve Örneklerle Jeofizikte Modelleme, Umuttepe Yayınları, 364s, İstanbul.
- Öcal S, 2020, Diagnostic Methods for Outlier Detection in Time Series, Çukurova University, Graduate School of Natural and Applied Sciences, Master of Degree, 93p, Adana.

- Özdemir Ö, 2008, Zaman Serisi Modellemesinde Yapay Sinir Ağlarının Kullanımı ve Bir Uygulama, Anadolu Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, 110s, Eskişehir.
- Özek T, 2010, Zaman Serisi Modelleri Üzerine Bir Simülasyon Çalışması, Selçuk Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, 56s, Konya.
- Özmen A, 1986, Zaman Serisi Analizinde Box-Jenkins Yöntemi ve Banka Mevduat Önkestiriminde Uygulama Denemesi, Anadolu Üniversitesi, Sosyal Bilimler Enstitüsü, Doktora Tezi, 156s, Eskişehir.
- Öztürk K, Şahin M E, 2018, Yapay Sinir Ağları ve Yapay Zeka'ya Genel Bir Bakış, Takvim-i Vekayi, 6, 25–36.
- Prayudani S, Hizriadi A, Lase Y Y, Fatmi Y, Al-Khowarizmi, 2019, Analysis Accuracy of Forecasting Measurement Technique on Random K-Nearest Neighbor (RKNN) Using MAPE and MSE, Journal of Physics: Conference Series, 1361, 1–8.
- Ranganathan A, 2004, The Levenberg- Marquardt Algorithm, Tutorial on LM Algorithm, 11, 101–110.
- Remus W, O'Connor M, 2002, Extrapolation, Armstrong J S, Principles of Forecasting a Handbook for Researchers and Practitioners (215–256), Kluwer Academic Publishers, 849p, the United States of America.
- Sampson M, 2001, Time Series Analysis, Loglinear Publishing, 218p, USA.
- Selamlar T H, 2017, Modelling and Forecasting Time Series Data Using ATA Method, Dokuz Eylül University, Graduate School of Natural and Applied Sciences, Degree of Doctor, 137p, İzmir.
- Şalk S, 2019, Financial Data Analysis By Exponential Smoothing and ATA Method, Dokuz Eylül University, Graduate School of Natural and Applied Sciences, Degree of Master, 64p, İzmir.
- Şenyüz M, 2019, Türkiye'deki Organik Tarım Ürünlerinin Zaman Serileri ile Analizi, İstanbul Üniversitesi, Sosyal Bilimler Enstitüsü, Yüksek Lisans Tezi, 69s, İstanbul.

- Tüzen M F, 2012, Türkiye Turizm Gelirinin Öngörüsünde Zaman Serilerinin Bileşenlerine Ayrıştırılarak Yapay Sinir Ağları ve Box-Jenkins Yöntemleri ile Karşılaştırmalı Analizi, Kafkas Üniversitesi, Sosyal Bilimler Enstitüsü, Yüksek Lisans Tezi, 139s, Kars.
- Uslu Ç S, 2011, Zaman Serisi Analizi ile Yapay Sinir Ağları Kestirimlerinin Karşılaştırılması, Mimar Sinan Güzel Sanatlar Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, 59s, İstanbul.
- Uzel S, 2008, Zaman Serisi Analizi Yöntemi Üzerine Bir Uygulama, Yıldız Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, 45s, İstanbul.
- Wei W W S, 2006, Stationary Time Series Models, Lynch D (Ed.), Time Series Analysis Univariate and Multivariate Methods (33–67), Copyright, 614s, The United States of America.
- Yapar G, 2018, Modified Simple Exponential Smoothing, Hacettepe Journal of Mathematics and Statistics, 47, 741–754.
- Yapar G, Yavuz I, Selamlar H T, 2017, Why and How Does Exponential Smoothing Fail? An In Depth Comparison of ATA-Simple and Simple Exponential Smoothing, Turkish Journal of Forecasting, 01, 30–39.
- Yapar G, Çapar S, Yavuz İ, Selamlar H T, 2019, ATA Metod, Hacettepe Journal of Mathematics and Statistics, 48, 1838–1844.
- Yapar G, Çapar S, Selamlar H T, Yavuz İ, 2018, Modified Holt's Linear Trend Method, Hacettepe Journal of Mathematics and Statistics, 47, 1394–1403.
- Yılmaz E T, 2018, Time Series Forecasting of Intermittent Demand By Using ATA Method and Computational Intelligence, Dokuz Eylül University, Graduate School of Natural and Applied Sciences, Degree of Master, 67p, 2018.
- Yolcu U, 2008, Yapay Sinir Ağına Dayalı Yüksek Dereceli Bulanık Zaman Serisi Öngörü Modeli, On Dokuz Mayıs Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, 85s, Samsun.
- Zhang P G, 2003, Time Series Forecasting Using a Hybrid ARIMA and Neural Network Model, Neurocomputing, 50, 159–175.

İnternet Kaynakları

- 1–<https://ethereum.org/en/what-is-ethereum/>, 15.06.2021
- 2–<https://coinrot.com/litecoin-ltc-nedir-madenciligi-nasil-yapilir-ltc-grafik/>, 15.06.2021
- 3–<https://arxiv.org/ftp/arxiv/papers/1401/1401.1333.pdf>, 05.10.2021
- 4–<https://www.harita.gov.tr/uploads/files/articles/turev-tabanli-parametri-kestirim-yontemleri-1069.pdf>, 08.10.2021

