



T.C.

**KIRIKKALE ÜNİVERSİTESİ
FEN BİLİMLER ENSTİTÜSÜ**

**KRİPTO PARA FİYATLARININ ARIMA VE YAPAY SİNİR AĞI
MODELLERİ İLE TAHMİNİ**

EMRE YILMAZ

İSTATİSTİK ANABİLİM DALI

YÜKSEK LİSANS TEZİ

DANIŞMAN

Dr. Öğr. Üyesi Serap YÖRÜBULUT

KIRIKKALE-2024



T.C.
KIRIKKALE ÜNİVERSİTESİ
FEN BİLİMLER ENSTİTÜSÜ

**KRİPTO PARA FİYATLARININ ARIMA VE YAPAY SİNİR AĞI
MODELLERİ İLE TAHMİNİ**

EMRE YILMAZ
İSTATİSTİK ANABİLİM DALI

YÜKSEK LİSANS TEZİ

DANIŞMAN
Dr. Öğr. Üyesi Serap YÖRÜBULUT

KIRIKKALE-2024

Emre YILMAZ tarafından hazırlanan “KRİPTO PARA FİYATLARININ ARIMA VE YAPAY SİNİR AĞI MODELLERİ İLE TAHMİNİ” adlı tez çalışması, aşağıdaki jüri tarafından OY BİRLİĞİ ile Kırıkkale Üniversitesi Fen Bilimleri Enstitüsü İstatistik Ana Bilim Dalında YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Danışman: Dr. Öğr. Üyesi Serap YÖRÜBULUT

İstatistik Ana Bilim Dalı, Kırıkkale Üniversitesi

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum.

İmza:.....

Başkan: Prof. Dr. Kamile ŞANLI KULA

Matematik Ana Bilim Dalı, Kırşehir Ahi Evran Üniversitesi

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum.

İmza:.....

Üye: Prof. Dr. Güvenç ARSLAN

İstatistik Ana Bilim Dalı, Kırıkkale Üniversitesi

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum.

İmza:.....

Tez Savunma Tarihi:20/09/2024

Jüri tarafından kabul edilen bu tezin Yüksek Lisan Tezi olması için gerekli şartları yerine getirdiğini onaylıyorum.

Prof. Dr. Recep ÇALIN

Fen Bilimleri Enstitü Müdürü

ETİK BEYANI

Kırıkkale Üniversitesi Fen Bilimleri Enstitüsü Tez Yazım Kurallarına uygun olarak hazırladığım bu tez çalışmada;

o Tez içinde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi,

o Tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu,

o Tez çalışmada yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi,

o Kullanılan verilerde herhangi bir değişiklik yapmadığımı,

o Bu tezde sunduğum çalışmanın özgün olduğunu,

bildirir, aksi bir durumda aleyhime doğabilecek tüm hak kayıplarımı kabullendiğimi beyan ederim.

Emre YILMAZ

ÖZET

KRİPTO PARA FİYATLARININ ARIMA VE YAPAY SİNİR AĞI MODELLERİ İLE TAHMİNİ

Kırıkkale Üniversitesi

Fen Bilimleri Enstitüsü

İstatistik Anabilim Dalı, Yüksek Lisans Tezi

Danışman: Dr. Öğr. Üyesi Serap YÖRÜBULUT

Eylül 2024, 97 sayfa

Dünya dijitalleşirken, fiziksel paranın yanında dijital para ve kripto para kullanımı da hızla artmaktadır. Bu dijital paraların hem günlük işlemlerde hem de yatırım için tercih edilmesi, finansal piyasaların dinamiklerini büyük ölçüde değiştirmiştir. Dijital çağdaki yeniliklerle birlikte; kripto para piyasasının hızla büyümesi, değişkenlik göstermesi ve belirsizlikleri, yatırımcılar için önemli fırsatlar sunmanın yanı sıra bazı riskler de ortaya çıkarmaktadır. Bu nedenle; kripto para fiyatlarının doğru bir şekilde tahmin edilmesi, yatırım kararlarının daha güvenilir ve bilinçli bir şekilde alınabilmesi açısından kritik öneme sahiptir. Bununla birlikte; yatırımcıların daha bilinçli ve sağlıklı yatırım yapmalarını sağlamak amacıyla, kripto para fiyat tahminine yönelik modelleme çalışmalarının geliştirilmesi büyük önem taşımaktadır. Bu çalışmada öncelikle kripto para ve temel kripto para birimlerinden olan Bitcoin ve Ethereum hakkında kısaca bilgiler verilerek bu kripto para birimleri için yapılacak zamana bağlı tahminler için geleneksel tahmin yöntemi olan Otoregresif Bütünleşik Hareketli Ortalama (ARIMA) ve son yıllarda tahmin yöntemleri arasında giderek popülerlik kazanan Yapay Sinir Ağları (YSA) ile modeller kurulmuştur. Elde edilen modeller karşılaştırıldığında incelenen yıllara göre tahmin performansları değişkenlik göstermekle birlikte; YSA yönteminin tahmin performansının ARIMA modeline göre daha tercih edilebilir olduğu belirlenmiştir. Elde edilen tahmin modelleri, kripto para piyasasındaki fiyat hareketlerinin daha iyi anlaşılması ve bu alanda etkili yatırım kararları alınabilmesi için önemli bulgular sunmanın yanı sıra kripto para piyasasının geleceği ve yatırımcılar için potansiyel stratejiler geliştirmede önemli olmaktadır.

Anahtar Kelimeler: Kripto Para Fiyat Tahmini, ARIMA Modeli, Yapay Sinir Ağları, Zaman Serisi Analizi, Kripto Para Piyasası

ABSTRACT

PREDICTION OF CRYPTOCURRENCY PRICES WITH ARIMA AND ARTIFICIAL NEURAL NETWORK MODELS

Kırıkkale University

Institute of Science

Department of Statistics, Master's Thesis

Supervisor: Asst. Prof. Serap YÖRÜBULUT

September 2024, 97 pages

As the world becomes increasingly digital, the use of digital currency and cryptocurrency is rapidly growing alongside physical money. The preference for these digital currencies in both daily transactions and investments has significantly altered the dynamics of financial markets. With the innovations of the digital age, the rapid growth, volatility, and uncertainties of the cryptocurrency market present significant opportunities for investors but also pose certain risks. Therefore, accurately predicting cryptocurrency prices is critically important for making more reliable and informed investment decisions. In this context, developing modeling studies aimed at forecasting cryptocurrency prices is crucial to help investors make more informed and sound investment choices. In this study, brief information is provided about cryptocurrencies, focusing on major ones like Bitcoin and Ethereum. For these cryptocurrencies, time-based predictions are made using the traditional forecasting method, ARIMA, and the increasingly popular Artificial Neural Networks models. When the obtained models are compared, their prediction performances vary depending on the years examined; It has been determined that the prediction performance of the ANN method is more preferable than the ARIMA model. The resulting prediction models are important in providing important findings for a better understanding of price movements in the cryptocurrency market and making effective investment decisions in this field, as well as developing potential strategies for the future of the cryptocurrency market and investors.

Keywords: Cryptocurrency Price Prediction, ARIMA Model, Artificial Neural Networks, Time Series Analysis, Cryptocurrency Market

TEŐEKKÜR

Bu tez, uzun ve titiz bir arařtırma sürecinin ürünüdür ve sizlerle bu önemli çalıřmayı paylařmaktan gurur duyuyorum. Tezim, ARIMA ve Yapay Sinir Ağları Modelleri ile kripto fiyat tahmini konusunda derinlemesine bir inceleme sunmayı amaçlamaktadır.

Bu tezin hazırlanmasındaki temel amacım, ARIMA ve YSA modelleri ile kripto para piyasasında daha bilinçli kararlar almak için bilimsel bir katkıda bulunmaktır. Bu çalıřma, kripto piyasası fiyat tahmini alanında bir dizi önemli soruyu yanıtlamayı ve ARIMA ve YSA ile yapılan tahminler üzerine yeni ışıklar tutmayı hedeflemektedir. Bu süreçte, farklı kaynaklardan elde edilen verilerin analizi ve deęerlendirmesi büyük bir önem taşımıştır.

Tezim, birçok kiřinin katkısı ve desteęi olmadan gerçekteşemeyecek bir proje olmuřtur. Bu tezin başarıyla tamamlanmasında katkıda bulunan deęerli tez danıřmanım Dr. Öğr. Üyesi Serap YÖRÜBULUT'a ve desteęini hiçbir zaman esirgemeyen sevgili eřim Firdevs YILMAZ'a teőekkür ederim. Umarım bu çalıřma, bilimsel düşünceye ve arařtırmaya olan sevginizi artırır ve sizi gelecekteki çalıřmalarınıza daha fazla katkıda bulunmaya teővik eder.

Saygılarımla,

Emre YILMAZ
Kırıkkale Üniversitesi
..../...../2024

*Bu tezi,
her zaman yanımda olan, desteęini ve sevgisini benden hiçbir zaman esirgemeyen
sevgili eřim Firdevs'e; hayata bakıř açımı deęiřtirmeme sebep olan ve bana umut
ıřığı olan sevgili oęlum Yaęız Yusuf'a ve sevgili kızım İpek'e ithaf ediyorum.*

İÇİNDEKİLER

ÖZET	iv
ABSTRACT	v
TEŞEKKÜR	vi
İÇİNDEKİLER	viii
ÇİZELGELER DİZİNİ	x
ŞEKİLLER DİZİNİ	xi
SİMGELER VE KISALTMALAR DİZİNİ	xiii
1. GİRİŞ	1
1.1. Literatür Taraması	2
1.2. Kripto Para Birimleri.....	3
1.2.1. Kripto Para.....	3
1.2.2. Temel Kripto Para Birimleri	4
2. ZAMAN SERİSİ ANALİZİ	7
2.1. Zaman Serisi Analizinde Belirleyici Unsurlar	7
2.1.1. Trend.....	7
2.1.2. Mevsimsellik.....	8
2.1.3. Konjoktürel Dalgalanmalar	9
2.1.4. Tesadüfi Bileşenler	10
2.2. Durağanlık ve Durağan Olmama.....	11
2.3. Durağanlık Testleri.....	12
2.3.1. Otokorelasyon Fonksiyonu	12
2.3.2. Kısmi Otokorelasyon Fonksiyonu	13
2.3.3. Durağan Olmama ve Birim Kök Testleri.....	14
2.4. Box-Jenkins Yöntemi	18
2.4.1. Box-Jenkins Yöntemi ile Modelleme Süreci.....	20
2.4.2. Model Belirleme	21
2.4.3. Model Tahmini	22
2.5. Doğrusal Durağan Stokastik Modeller	24

2.5.1. Otoregresif: AR(p).....	24
2.5.2. Hareketli Ortalama: MA(q)	25
2.5.3. Otoregresif Hareketli Ortalama: ARMA(p,q).....	26
2.6. Durağan Olmayan Doğrusal Stokastik Modeller	27
2.6.1. Otoregresif Bütünleşik Hareketli Ortalama: ARIMA(p,d,q)	28
3. YAPAY SİNİR AĞLARI.....	32
3.1. Yapay Sinir Ağlarının Temelleri	32
3.2. Yapay Sinir Hücre Yapısı.....	34
3.3. Biyolojik Sinir Ağı ve Yapısı	36
3.4. Yapay Sinir Ağlarının Geleneksel Sistemlerden Farkları	37
3.5. Yapay Sinir Ağları Sınıflandırılması.....	38
3.5.1. Katman Sayısına Göre Yapay Sinir Ağları.....	38
3.5.2. Ağıın Yapısına Göre Yapay Sinir Ağları.....	43
3.6. Yapay Sinir Ağlarında Öğrenme Yöntemleri ve Kuralları	45
3.6.1. Öğrenme Yöntemleri	45
3.6.2. Öğrenme Kuralları	48
3.7. Yapay Sinir Ağlarının Öğrenme Süreci	53
4. UYGULAMA.....	56
4.1. Materyal ve Metot	56
4.2. Bulgular	57
4.2.1. ARIMA Modeli İçin Analiz Sonuçları	57
4.2.2. Yapay Sinir Ağları Modeli İçin Analiz Sonuçları	67
4.3. ARIMA ve Yapay Sinir Ağları İle Tahmin Sonuçlarının Değerlendirilmesi	76
5. SONUÇ.....	86
KAYNAKÇA	88
ÖZGEÇMİŞ.....	97

ÇİZELGELER DİZİNİ

<u>ÇİZELGE</u>	<u>SAYFA</u>
2.1. ACF ve PACF'nin teorik davranışları (Akıncı, 2008).....	22
3.1. Biyolojik sınırlar ile yapay sınırların görevleri (Çelik, 2008).....	37
3.2. Geleneksel hesaplama yöntemleri ile YSA'ların karşılaştırılması (Ömrüuzun, 2019).....	38
4.1. 2016-2024 yılları BTC ve ETH verileri betimleyici istatistikleri.....	56
4.2. Günlük BTC verisine ait ADF test istatistik sonucu.	59
4.3. Birinci dereceden farkı alınmış günlük BTC verisinin ADF test istatistik sonucu.....	59
4.4. Günlük Bitcoin serisine ait ARIMA modeli.....	61
4.5. Günlük ETH verisine ait ADF test istatistik sonucu.	64
4.6. Birinci dereceden farkı alınmış günlük ETH verisinin ADF test istatistik sonucu.....	64
4.7. Günlük ETH serisine ait ARIMA modeli.....	66
4.8. 2022 yılı Ocak ayı BTC gerçek değerleri ve YSA ile ARIMA modelleri tahmin değerleri.....	77
4.9. 2022 yılı BTC verileri betimleyici istatistikleri.....	78
4.10. 2022 yılı Ocak ayı BTC verileri betimleyici istatistikleri.	78
4.11. ARIMA ve YSA modellerine ile elde edilen 2016-2024 yılları BTC günlük verilerine ait HKO değerleri.....	80
4.12. 2022 yılı Ocak ayı ETH gerçek değerleri ve YSA ile ARIMA modelleri tahmin değerleri.....	81
4.13. 2022 yılı ETH verileri betimleyici istatistikleri.....	82
4.14. 2022 yılı Ocak ayı ETH verileri betimleyici istatistikleri.	82
4.15. ARIMA ve YSA modellerine ile elde edilen 2016-2024 yılları ETH günlük verilerine ait HKO değerleri.....	84

ŞEKİLLER DİZİNİ

<u>SEKİL</u>	<u>SAYFA</u>
2.1. Trend gösterimleri (Mann, 1995; Tüzen, 2012).....	8
2.2. Mevsimsel bileşenler grafiği (Tüzen, 2012).....	9
2.3. Konjektürel dalgalanma grafiği (Tüzen, 2012).....	10
3.1. Yapay sinir hücresi (YSH).	34
3.2. Yapay sinir ağları arasındaki ilişki.....	35
3.3. Biyolojik sinir hücresi (Anderson & McNeill, 1992).....	37
3.4. Basit algılayıcı sinir ağı modeli (Akkurt, 2005).....	39
3.5. Perceptron örneği.	40
3.6. ADALINE ünitesi örneği.	41
3.7. Üç ADALINE ünitesinden oluşan MADALINE ağı örneği.	42
3.8. Çok katmanlı yapay sinir ağı modeli örneği.	43
3.9. İleri beslemeli yapay sinir ağı örneği (Öztemel, 2006).....	44
3.10. Geri beslemeli yapay sinir ağı örneği (Kabalcı, 2014).....	45
3.11. Denetimli öğrenme (turhost.com, 2021).	46
3.12. Denetimsiz öğrenme (turhost.com, 2021).	47
3.13. Pekiştirmeli öğrenme (turhost.com, 2021).....	47
3.14. Hopfield ağı örneği (Deveci, 2012).....	49
3.15. Geri bildirim ağı (Deveci, 2012).	51
3.16. İleri beslemeli bir sinir ağının eğitim ve test aşamaları (Ömrüuzun, 2019)....	55
4.1. Günlük BTC verisine ait korelogram.	57
4.2. Günlük BTC verisine ait zaman serisi grafiği.	58
4.3. Fark alınmış günlük BTC verisine ait korelogram.....	60
4.4. Akaike bilgi kriterine göre en iyi 20 model.	61
4.5. Günlük ETH verisine ait korelogram.	62
4.6. Günlük ETH verisine ait zaman serisi grafiği.	63
4.7. Fark alınmış günlük ETH verisine ait korelogram.....	65
4.8. Akaike bilgi kriterine göre en iyi 20 model.	66
4.9. Günlük BTC serisine ait YSA modeli.....	68

4.10.	Günlük BTC verisine ait eğitim, doğrulama ve test veri seti için ortalama karesel hata.	69
4.11.	Günlük BTC verisine ait gizli katman ile oluşan hata grafiği.	69
4.12.	Modeldeki gizli katmanda eğitim, doğrulama, test ve tüm model sonuçlarına göre tahmin başarısı grafiği.	70
4.13.	Günlük BTC verisi için zamana göre çıktı, hedef ve hatalar.	71
4.14.	Günlük BTC verilerinin hata otokorelasyonu.	71
4.15.	Günlük ETH serisine ait YSA modeli.	72
4.16.	Günlük ETH verisine ait eğitim, doğrulama ve test veri seti için ortalama karesel hata.	73
4.17.	Günlük ETH verisine ait gizli katman ile oluşan hata grafiği.	74
4.18.	ETH verisine ait modeldeki gizli katmanda eğitim, doğrulama, test ve tüm model sonuçlarına göre tahmin başarısı grafiği	74
4.19.	Günlük ETH verisi için zamana göre çıktı, hedef ve hatalar.	75
4.20.	Günlük ETH verilerinin hata otokorelasyonu.	76
4.21.	2022 yılı günlük BTC verisine ait gerçek ve tahmini değer karşılaştırma grafiği.	79
4.22.	2022 yılı Ocak ayı günlük BTC verisine ait gerçek ve tahmini değer karşılaştırma grafiği.	79
4.23.	2022 yılı günlük ETH verisine ait gerçek ve tahmini değer karşılaştırma grafiği.	83
4.24.	2022 yılı Ocak ayı günlük ETH verisine ait gerçek ve tahmini değer karşılaştırma grafiği.	84

SİMGELER VE KISALTMALAR DİZİNİ

α	Zaman serisi sabit terimi
B	YSA beklenen çıktı değeri
β_t	Zaman trendi
ϕ_p	Otoregresif katsayısı
ϕ	YSA eşik değeri
\checkmark	YSA gerçekleşen çıktı değeri
d	Fark alma derecesi
δ	DF model parametresi
Δ	Fark alma operatörü
$\hat{\epsilon}_t$	Hata terimi tahmini
e_t	Hata bileşeni
ϵ_t	Hata terimi
E	YSA hata değeri
$E(M)$	YSA hata matrisi
ϕ_n	n.kısmi otokorelasyon katsayısı
$G(m)$	YSA gradyan matrisi
$\hat{\gamma}$	Phillipse-Peron model parametresi tahmini
γ_k	Kovaryans
γ	Phillipse-Peron model parametresi
$h(m)$	Hessian matrisi
$j(m)$	Jakobiyen matrisi
L	Gecikme operatörü
μ	Ortalama
n	Gözlem sayısı

P	Otoregresif model terimi
q	Hareketli ortalama model terimi
$\rho(k)$	Otokorelayon katsayısı
σ^2	Varyans
θ_q	Hareketli ortalama katsayısı
w_i	YSA i . ağırlık değeri
x_i	YSA i . girdi değeri
X_t	Zaman serisinin t zamanındaki değeri
y_t	Zaman serisi verisi

KISALTMALAR DİZİNİ

AC	Otokorelasyon
ACF	Otokorelasyon Fonksiyonu
ADALINE	Yinelemeli Doğrusal Sinir Ağı
ADF	Genişletilmiş Dickey-Fuller Testi
AIC	Akaike Bilgi Kriteri
AR	Otoregresif
ARIMA	Otoregresif Bütünleşik Hareketli Ortalama
ARMA	Otoregresif Hareketli Ortalama
BIC	Bayes Bilgi Kriteri
BTC	Bitcoin
DF	Dickey-Fuller Testi
ETH	Ethereum
HKO	Hata Kareler Ortalaması

I	Bütünleşik
LM	Levenberg-Marquardt Algoritması
MA	Hareketli Ortalama
MADALINE	Çoklu Yinelemeli Doğrusal Sinir Ağı
MLE	En Büyük Olabilirlik Yöntemi
PAC	Kısmi Otokorelasyon
PACF	Kısmi Otokorelasyon Foksiyonu
PP	Phillips-Peron Testi
SIC	Schwarz Bilgi Kriteri
YSA	Yapay Sinir Ağları
YSH	Yapay Sinir Hücresi

1. GİRİŞ

Kripto para birimleri, son on yılda finansal piyasaların yapı taşlarından biri haline gelmiştir. Blok zinciri teknolojisinin bir ürünü olarak ortaya çıkan bu dijital varlıklar, geleneksel para birimlerine alternatif olarak sunulmuş ve özellikle genç yatırımcılar arasında popülerlik kazanmıştır. Ancak, kripto para piyasalarının aşırı volatilitesi, yatırımcılar için hem büyük kazanç fırsatları hem de ciddi riskler taşımaktadır.

Bu çalışma, kripto para piyasalarının öngörülebilirliğini artırmak ve yatırımcıların daha bilinçli kararlar almasını sağlamak için geçmiş verileri kullanarak Otoregresif Bütünleşik Hareketli Ortalama (ARIMA) ve Yapay Sinir Ağları (YSA) modellerini kullanarak gelecekteki kripto para fiyat tahminleri yapmayı amaçlamaktadır. ARIMA modeli, zaman serisi verilerinin analizinde güçlü bir araç olarak kabul edilirken, YSA, özellikle karmaşık ve doğrusal olmayan ilişkileri modelleme konusunda üstün kabiliyetlere sahiptir. Bu tez aynı zamanda her iki modelin performansını, kripto para piyasalarının öngörülebilirliği bağlamında değerlendirecek ve bu modellerin finansal tahminlerdeki potansiyelini ortaya koyacaktır.

Bu çalışmanın amaçlarından biri de, ARIMA ve YSA modelleri kullanılarak volatil kripto para piyasasında temel fiyatların tahmin edilebilirlik sınırlarını belirlemek ve gelecekteki fiyat hareketlerini en doğru şekilde tahmin edebilecek en uygun modeli tespit etmektir.

Araştırmanın yöntemi, hem teorik hem de uygulamalı bir çerçevede ele alınacaktır. İlk olarak, ARIMA ve YSA modellerinin finansal tahminlerdeki kullanımına dair mevcut çalışmalar üzerine literatür taraması yapılacak, ardından seçilen kripto para birimlerine ait zaman serisi verileri üzerinde ARIMA ve YSA modelleri uygulanacak ve elde edilen sonuçlar istatistiksel ölçütlerle değerlendirilerek karşılaştırılacaktır. Bu süreç, kripto para piyasalarının daha derinlemesine anlaşılmasına ve yatırım stratejilerinin geliştirilmesine katkı sağlayacaktır.

1.1. Literatür Taraması

ARIMA ve YSA modellerinin uygulanışı, avantajları, sınırlılıkları ve karşılaştırmalı performanslarına odaklanarak, konuyla ilgili literatürde yer alan önemli çalışmalar incelenmiştir.

Keskin Benli ve Yıldız (2014) tarafından yapılan çalışmada, Ocak 1996 ile Nisan 2012 dönemine ait altın (dolar/ons) verileri kullanılarak modeller belirlenmiş ve Mayıs 2012 - Aralık 2013 dönemine ait veriler tahmin (test) amacıyla kullanılmıştır. Yapılan uygulama sonucunda, Hata Kareler Ortalaması Karekökü (HKOK) ile yöntemlerin tahmin performansları ölçülmüş; ARIMA modeli için 0,0043 ve YSA modeli için ise 0,0061 değerleri elde edilmiştir. Bu sonuçlara göre, ARIMA modelinin YSA modeline kıyasla daha iyi bir tahmin performansı sergilediği belirlenmiştir.

Kaynar ve Taştan (2009) tarafından yapılan çalışmada, Ocak 2000 ile Haziran 2008 arasındaki döneme ait günlük ve aylık döviz kuru (YTL/Dolar) verileri kullanılarak, Çok Katmanlı İleri Beslemeli Yapay Sinir Ağları (MLP) ve Box-Jenkins metodolojisi ile ARIMA modelleri aracılığıyla fiyat tahminleri gerçekleştirilmiştir. ARIMA ve MLP modellerinin En Küçük Hata Kareler Ortalaması (MSE) ve Ortalama Mutlak Yüzde Hata (MAPE) değerleri, aylık veriler için sırasıyla (0.00174176-2.65680133), (0.00182647-3.27050090) şeklinde ve günlük veriler için ise (0.00008140-0.67077165), (0.00007166-0.61651801) şeklinde bulunmuştur. Bu sonuçlar, uygun model yapısı ve yeterli veri kullanımı durumunda, YSA modelinin ARIMA modeline alternatif bir yöntem olarak kullanılabileceğini göstermiştir.

Şahin (2018) tarafından gerçekleştirilen çalışmada, 02.02.2012-09.01.2018 tarihleri arasındaki Bitcoin kapanış verileri kullanılarak, klasik ARIMA yöntemi ve giderek önem kazanan YSA modelleri ile Bitcoin'in güncel fiyatlarını tahmin etme ve hangi yöntemin daha başarılı sonuçlar verdiğini belirleme amacı güdülmüştür. Çalışma, MSE ve MAPE değerlerine dayanarak YSA modelinin, ARIMA modeline göre daha başarılı sonuçlar verdiğini ortaya koymuştur. YSA modeli ile yapılan tahminler, hem fiyat yönü hem de fiyat olarak gerçekleşen fiyatlara daha yakın olarak bulunmuştur.

Karahan (2015) tarafından yürütülen çalışmada, 2008-2010 yılları arasına ait Malatya ili kuru kayısı ihracat miktarları üzerinde ARIMA ve YSA modeli gibi istatistiksel talep tahmin teknikleri kullanılmıştır. Bu uygulama neticesinde, MSE ve MASE değerleri hesaplanarak değerlendirilmiştir. Elde edilen bulgulara göre, YSA modeli, ARIMA modeline kıyasla daha düşük tahmin hataları sergilemiş ve kuru kayısı talep tahmininde kullanılan YSA modelinin, ARIMA modeline göre daha üstün bir tahmin performansına sahip olduğu saptanmıştır. Bu sonuçlar, YSA modeli tarafından yapılan tahminlerin güvenilir ve geçerli olduğunu kanıtlamıştır.

İncelemeye alınan çalışmaların genelinde, bir istisna hariç, yapay zeka teknolojisini temel alan YSA modelinin tahminleri, geleneksel istatistiksel model olarak görülen ARIMA modeline nazaran daha etkin, geçerli ve güvenilir bulunmuştur.

1.2. Kripto Para Birimleri

1.2.1. Kripto Para

Dijital paralar, günümüz finansal sistemlerinde önemli bir rol oynamaktadır. Elektronik olarak saklanabilen ve transfer edilebilen bu paralar, geleneksel fiziksel paraların yerini almaya başlamıştır. Banka hesaplarımızdaki dijital para, kağıt paraların sanal bir temsilidir. Bu dönüşümün arkasında, bankaların her yerde ve her zaman erişilebilir olması, elektronik paranın yaygınlaşması ve fiziksel paranın kullanımının azalması gibi faktörler yatmaktadır (Çarkacıoğlu, 2016).

Sanal paralar, dijital paradan türemiş olup, somut bir fiziksel karşılığa sahip değildir. Bu, onların yalnızca elektronik ortamlarda var olduğu ve fiziksel bir değer taşımadığı anlamına gelir. Diğer yandan, sanal para olmayan dijital paralar, genellikle itibari para birimlerinin elektronik eşdeğerleri olarak işlev görür (Çarkacıoğlu, 2016). Dijital para ve sanal para ile birlikte yapılan çalışmalar sonucu kripto para ve kripto para piyasası ortaya çıkmaya başlamıştır.

Merkezi bir otoriteye sahip olmayan ya da aracılık eden bir kuruma bağlılığı bulunmayan, çevrimiçi ortamda ve internet üzerinde kullanılan sanal bir para birimi kripto para olarak tanımlanır. Bu tür paralar, kriptografi yöntemleri kullanılarak sanal cüzdanlara yerleştirilerek saklanır ve aynı şekilde bu şifreleme yöntemleri sayesinde

irtibat sağlanarak kullanılır. Dolayısıyla, bu tür sanal para birimlerine “Kripto” adı verilmiştir. Kripto para birimleri, gerçek paralarla yapılan harcamalar gibi harcama yapmak ve her tür yatırım amacıyla hem bireyler hem de kurumlar tarafından kullanılır (Çetinkaya, 2018).

Günümüzde iki bini aşkın, aktif şekilde alım ve satımı yapılan farklı sayıda kripto para çeşidi bulunmaktadır. Sterlin, Türk Lirası, Dolar, Euro ve Altın gibi fiziksel olarak basılmış halde mevcut bulunmayan kripto paraların dijital (sanal) olmasının sebebi, kayıtlarının sadece dijital sistem ortamında tutulmasıdır. Ayrıca, madeni değerleri ve devlet desteği bulunmayan bu para birimlerinin geleneksel anlamda da bir karşılığı bulunmamaktadır. Kripto paraların değerleri, toplumun onları alım, satım ve ticaret yapabildikleri emtia sınıfına dâhil etmelerine bağlıdır. Bu değerler, kripto para borsalarında arz ve talep koşullarına göre anlık olarak belirlenir (Eğilmez, 2017).

Kripto paraların arz miktarı ve piyasaya sunulma zamanı, bu sistemler tasarlanırken önceden belirlenmiş kriterlere dayanmaktadır. Hiçbir devlet, kurum veya organizasyon, kripto para üretmediği gibi başkalarının sahip olduğu kripto paralara el koyma yetkisine sahip değildir. Kripto paralarda, işlem sırasında gönderici ve alıcı dışında herhangi bir üçüncü kişi veya aracı bulunmaması ve sisteminin sağlam ve güvenilir olması, bu paraların güvenliğinin ve transfer işlemlerinin sağlıklı bir şekilde işlemesine olanak sunar (Çarkacıoğlu, 2016).

1.2.2. Temel Kripto Para Birimleri

Bitcoin

2009 yılında Satoshi Nakamoto takma adını kullanan bir kişi veya grup tarafından ortaya çıkmış dijital ve kriptografik bir para birimidir. Kimliği hala bilinmeyen bu şahıs veya şahıslar, kripto parayı hala geliştirmeye devam etmektedirler.

BTC, dijital para ekonomisinin temelini oluşturan bir kavramlar bütünüdür ve açık kaynak kodlu yazılımlar üzerine kuruludur. Tamamen dijitaldir ve fiziksel bir temsile ihtiyaç duymaz. Düşük işlem maliyetleri, dünya çapında kullanılabilirliği, finansal özgürlük sağlaması, kullanım alanlarının sürekli genişlemesi ve güvenilir, anonim bir değer saklama aracı olarak görülmesi, BTC'nin popülerliğini sürekli artırmaktadır. Yeni bir dijital ekonomiye doğru sınırlarını genişleten BTC, ne herhangi bir resmi

devlet kurumu ne de özel bir kuruluş tarafından ihraç edilmektedir. Bu dijital para, hiçbir resmi ya da özel kuruluş tarafından garanti edilmemektedir (Sönmez, 2014).

BTC üretimi, dünya çapında dağıtık bir ağdaki gönüllü bilgisayarların işlem gücü ile gerçekleştirilir. Açık kaynaklı madencilik yazılımını çalıştırarak bu ağın bir parçası olan her birey, BTC madenciliği yapabilir. BTC'ler, işlem onayları sırasında karmaşık matematiksel problemleri çözme yarışına giren madenciler tarafından sağlanır. İlk problemi çözen madenci, belirli miktarda BTC ile ödüllendirilir. Zamanla bu problemler daha da zorlaşır ve madencilere verilen ödül miktarı dört yılda bir yarıya düşer. BTC'nin toplam arzı 21 milyon ile sınırlıdır ve bu sınırın dolması için tahmini olarak 100 yıldan fazla zaman gerekmektedir (Çarkacıoğlu, 2016).

Ethereum

Vitalik Buterin tarafından geliştirilen açık kaynak kodlu bir blok zinciri platformudur. BTC'nin temel teknolojisi olan blok zincirine dayanan ETH, bu teknolojiyi daha çeşitli alanlarda kullanılabilir hale getirir. Akıllı sözleşmelerin kullanımını sağlayan ETH, programlanabilir bir blok zinciri sunar. Bu, dijital varlıklar, oylama sistemleri, oyunlar ve daha birçok farklı uygulama senaryosunda kullanılacak geniş bir özellik yelpazesi sunar (Buterin, 2013).

Dünya çapında en güvenilir ikinci kripto para olarak tercih edilen ETH, pek çok geliştirici ve şirket tarafından tercih edilmektedir. Blok zinciri teknolojisinin geleceği konusunda umut verici bir perspektif sunmakta ve ileride daha geniş çapta kullanılması öngörülmektedir. ETH'nin piyasa değeri, BTC'ye kıyasla daha düşüktür. Bunun sebebi, BTC'nin daha uzun süredir piyasada olması ve daha geniş bir kullanıcı kitlesine sahip olmasıdır. Ancak, ETH'nin piyasa değeri son zamanlarda hızla artmış ve kripto para piyasasında önemli bir rakip haline gelmiştir. ETH'nin piyasa değeri, piyasa koşulları ve talebe bağlı olarak dalgalanma gösterebilir (Salehihosseini, 2023).

ETH, dünya genelinde birçok kripto para borsasında işlem gören ve en popüler dijital para birimleri arasında bulunan bir platformdur. Ancak, ETH'nin geçmişi bazı zorluklarla da doludur. Örneğin, 2016 yılında Merkezi Olmayan Otonom Projesi'ne (DAO) yönelik bir siber saldırı, ETH blok zincirinin ikiye bölünmesine yol açmıştır. Bu olay sonucunda, orijinal blok zinciri ETH Classic adını almış ve saldırının sonuçlarını kabul etmiştir. Diğer blok zinciri ise ETH olarak anılmaya devam etmiş ve

saldırının etkilerini ortadan kaldırmak amacıyla blok zincirini sıfırlamıştır (Usta & Dođantekin, 2017).

Bu olay, ETH'nin gelişimini durdurmamış, aksine daha da güçlenmesine neden olmuştur. ETH, bu siber saldırının ardından güvenlik önlemlerini artırmış ve topluluđunu daha da sağlamlaştırmıştır. Günümüzde, ETH, blok zinciri teknolojisinin öncülerinden biri olarak gelişmeye ve yenilikler sunmaya devam etmektedir.



2. ZAMAN SERİSİ ANALİZİ

Zaman serisi analizi, bir değişkenin belirli zaman aralıklarında sıralı olarak gözlemlenmesi sonucu elde edilen veri dizisinin analiz edilmesi sürecidir (Can, 2009). Bu analiz, geçmiş verilere dayanarak gelecekteki değerleri ve hareketleri tahmin edebilmenin anahtarıdır (Arslan & Ertuğrul, 2022). Olasılık teorisinde örneklem boyutu n olmak üzere $\{Y(\omega, t): t = 0, \pm 1, \pm 2, \dots\}$ stokastik süreçinde üretilen $\{y_{t1}, y_{t2}, \dots, y_{tn}\}$ sonlu rassal değişkenler kümesi şeklinde ifade edilir (Kadılar, 2005). Günlük, haftalık, aylık hisse senedi fiyatlarındaki hareketler, günlük ortalama hava tahminleri veya aylık, yıllık işsizlik oranları zaman serisi analizine örnek verilebilir (Abushukur, 2022).

2.1. Zaman Serisi Analizinde Belirleyici Unsurlar

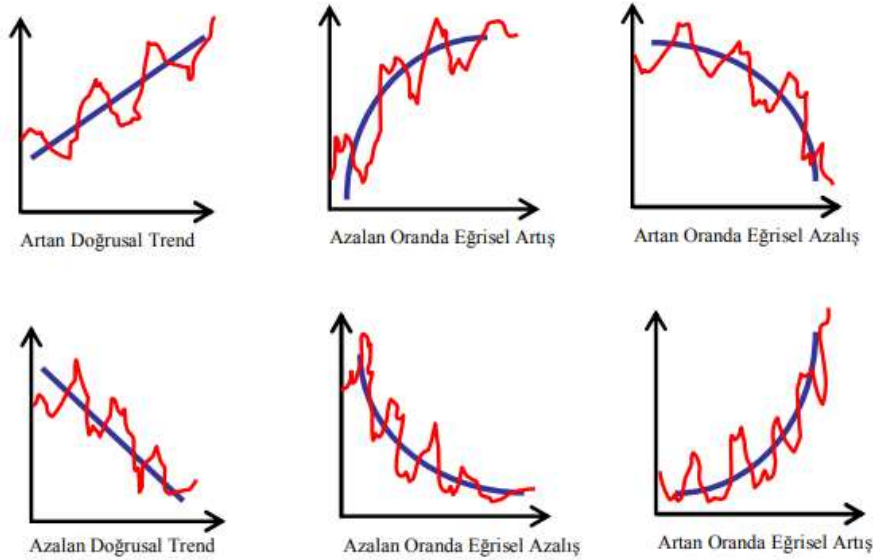
Zaman serilerindeki değerlerdeki dalgalanmaların genellikle dört ana faktörün etkisi altında olduğu kabul edilmektedir: trend, mevsimsellik, konjonktürel dalgalanmalar ve tesadüf bileşenler. Bu faktörler, zaman serisi analizinin temel yapı taşlarını oluşturur ve her biri serinin dinamiklerini farklı şekillerde etkilemektedir (Özmen vd., 2013). Bu dört faktör:

2.1.1. Trend

Trend, incelenen değişkenin zaman içindeki ortalamasındaki değişimi ifade eder ve bu, aşağı veya yukarı yönlü hareketlerle kendini gösterir. Hareketin yönü ve hızı, analizlerde önemli bir rol oynar. Trend, serideki değerlerin uzun dönemdeki artışlarını veya azalışlarını ifade eder. Kısacası, trend, serilerin uzun vadeli eğilimini temsil eder. Trendin belirlenebilmesi için sıklıkla 15 ila 18 aylık bir döneme ihtiyaç duyulmaktadır (Duru, 2007; Tüzen, 2012; Yüksel, 2015).

Trend analizi, serinin genel yönünü veya eğilimini belirlemek için kullanılır. Uzun vadeli hareketleri yansıtan trend, serideki sabit ve düzenli artış veya azalışı tanımlar ve bu sayede serinin gelecekteki davranışı hakkında önemli ipuçları sunar. Ani ve

beklenmedik hareketler, trend analizinin dışında tutularak analiz daha öngörülebilir ve düzenli desenlere odaklanır (Köse, 2016). Bu nedenle, zaman serisi analizinde trend kavramı, verilerden anlamlı bilgiler çıkarmanın ve etkili tahmin modelleri geliştirmenin anahtarı olarak kabul edilir.




Şekil 2.1. Trend gösterimleri (Mann, 1995; Tüzen, 2012).

2.1.2. Mevsimsellik

Mevsimsel bileşenler, ardışık yılların, mevsimlerin ve ayların aynı dönemlerindeki gözlemlerinde görülen düzenli artış ve azalışları ifade eder. Başka bir deyişle, zaman serilerinde kısa vadede gözlemlenen dalgalanmaları temsil eder. Bu dalgalanmaların süreleri, periyodun uzunluğunu belirler ve genellikle bu periyotlar 12 ay sürer. Birbirini izleyen iki mevsimsel değişimin en yüksek noktaları arasındaki mesafeye dalga boyu denir. Bir mevsimsel değişimin en yüksek ve en düşük noktaları arasındaki fark ise dalga şiddeti olarak adlandırılır. Mevsimsel bileşen, zaman serilerinde belirli aralıklarla meydana gelen ve tekrarlanan düzenli değişimleri tanımlar. Bu değişimler, doğal faktörler (örneğin, hava durumu), idari faaliyetler (örneğin, okul tatilleri) ve sosyal, kültürel veya dini gelenekler gibi çeşitli nedenlerden kaynaklanır. Mevsimsellik, bir zaman serisinin gerçek değerlerinin ortalama değerden sapması olarak da değerlendirilebilir. Örneğin, bayram dönemlerinde veya yaz aylarında ekonomik aktivitelerde artış gözlemlenebilir. Bu tür mevsimsel dalgalanmalar sabit veya değişken olabilir ve bu durum, zaman serilerinin analizinde önemli bir rol oynar (Duru, 2007; Güzel, 2010; Tüzen, 2012; Yeşilyayla, 2013).

Mevsimsel dalgalanmalar, kısa vadeli dalgaların anlaşılması, kısa vadeli tahminlerin yapılması ve serinin mevsimsel etkilerden arındırılması amacıyla incelenir. Serideki mevsimsel bileşenler çıkarılmadan yapılan tahminler, modelin varyansının yüksek olmasına yol açar. Bu nedenle, analiz öncesinde mevsimselliğin detaylı bir şekilde incelenmesi ve serinin mevsimsel etkilerden arındırılması gereklidir. Bu yaklaşım, zaman serisinin farklı mevsimlerini karşılaştırmayı mümkün kılar. Orijinal verideki mevsimsel etkiler, karşılaştırmaları zorlaştırabilir. Mevsimsel bileşenlerin arındırılması için seri deterministik ise kukla değişkenler, stokastik ise uygun dereceden mevsimsel farklar kullanılır. Bu şekilde, serideki mevsimsel etkiler modellenerek daha doğru analizler yapılabilir (Tüzen, 2012).

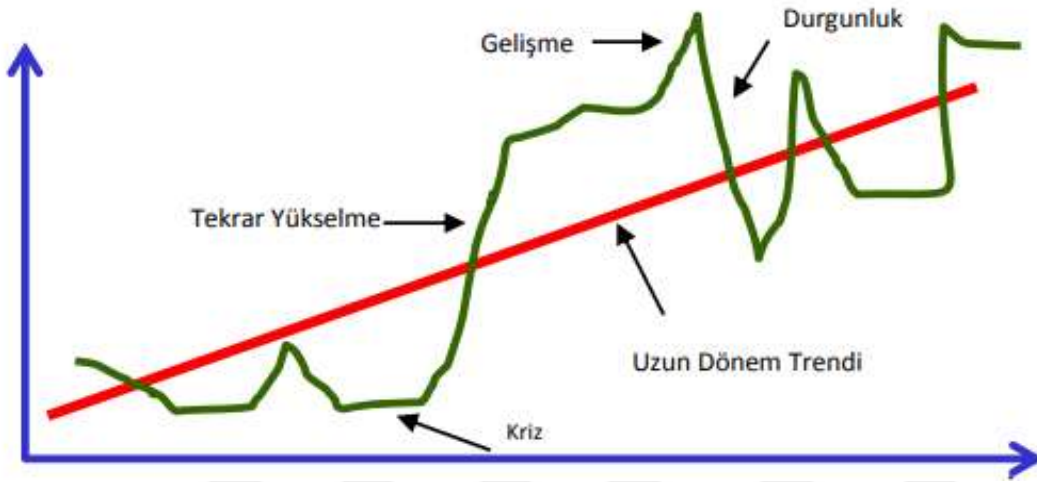


Şekil 2.2. Mevsimsel bileşenler grafiği (Tüzen, 2012).

2.1.3. Konjoktürel Dalgalanmalar

Konjoktürel dalgalanmalar, ekonomik göstergelerdeki genişleme ve daralma dönemlerini ifade eder ve genellikle yatırım, üretim, satış ve gelir gibi unsurların etkisiyle ortaya çıkar. Bu dalgalanmalar, düzensiz ve belirsiz sürelerde gerçekleştiği için mevsimsel dalgalanmalardan farklıdır. Mevsimsel dalgalanmalar düzenli ve öngörülebilir iken, konjoktürel dalgalanmalar daha karmaşık ve tahmin edilmesi zor süreçlerdir. Ekonomik krizler ve patlamalar gibi büyük ölçekli olaylar bu döngüleri belirgin hale getirebilir. Zaman serisi analizinde, konjoktürel dalgalanmaların tespiti, gelecekteki ekonomik eğilimlerin doğru tahmin edilmesi açısından kritik öneme sahiptir. Genel ekonomik durumlar konjoktürel dalgalanmaların değişimine neden olmaktadır. Konjoktürel dalgalanmaları, seriden düzensiz bileşenlerin, mevsimsel dalgalanmaların ve trendin çıkarılması sonrası geriye kalan kısım şeklinde tanımlamak da mümkündür. Bu dalgalanmalar periyodik olmamakla birlikte 5-10 yılda bir

tekrarlanmaktadır. Dalga uzunlukları eşit değildir. Herhangi bir konjunktürel dalgalanmanın süresini, izleyeceği değişimlerin türünü ve bu değişimlerin şiddetini ve sonuçlarını önceden tahmin etmek oldukça zor ve genellikle imkânsızdır. Konjunktürel dalgalanmaların ne zaman ortaya çıkacağı ve nasıl bir biçim alacağı belirsizdir. Ayrıca, bu dalgalanmaları kontrol etmek mümkün değildir. İşletmelerdeki bolluk, durgunluk, düşüş ve yükselme dönemleri, konjunktürel dalgalanmalara örnek teşkil etmektedir (Çevik, 1999; Duru, 2007; Bozdağ, 2011; Tüzen, 2012).



Şekil 2.3. Konjunktürel dalgalanma grafiği (Tüzen, 2012).

2.1.4. Tesadüfi Bileşenler

Tesadüfi bileşenler, zaman serisi analizinin önemli bir unsuru olarak, model tahminlerinde dikkate alınması zor olan rastgele olayları ve beklenmeyen dalgalanmaları kapsar. Bu bileşenler, genellikle doğal afetler, politik olaylar veya pandemiler gibi dışsal etkenlerden kaynaklanır ve zaman serisinin genel davranış kalıplarından sapmalara neden olur. Tesadüfi bileşenlerin varlığı, özellikle kısa vadeli tahminlerde belirsizliği artırır ve analistlerin bu tür olayların potansiyel etkilerini anlamaları ve modellerine entegre etmeleri için ekstra dikkat ve çaba gerektirir. Bu bileşenlerin analizi, zaman serilerinin daha kapsamlı bir şekilde anlaşılmasını sağlar ve öngörü modellerinin gerçek dünya koşullarına adaptasyonunu iyileştirir; böylece tahminlerin doğruluğu üzerindeki olumsuz etkileri minimize edilebilir (Duru, 2007; Yüksel, 2015; Kaya, 2019).

2.2. Durağanlık ve Durağan Olmama

Durağanlık, istatistik varsayımlarının belki de en kritik olanıdır. Eğer bir serinin olasılık yapısı zaman içinde dalgalanıyorsa, o seri durağanlık ilkesine uymuyor demektir. Bunun aksine, serinin olasılık yapısı zaman boyunca sabit kaldığında, bu süreç durağan olarak kabul edilir. Durağanlık, bir serinin tahmin edilebilirliği ve analiz edilebilirliği açısından temel bir unsur olarak karşımıza çıkar (Robert & Daniel, 1998). Bir zaman serisinin durağanlığı, serinin ortalamasının ve varyansının zaman içinde sabit kalması ve iki farklı zaman periyodundaki değişkenler arasındaki kovaryansın, zamanın kendisinden ziyade bu değişkenler arasındaki gecikmeye bağlı olması anlamına gelir. Başka bir deyişle, durağan bir seride istatistiksel özellikler zamanla değişmez; bu da serinin analiz edilebilirliğini ve öngörülebilirliğini büyük ölçüde artırır (Gujarati & Porter, 2009). Zaman serileri, stokastik süreçlerin önemli bir örneğidir ve durağanlık, bu süreçlerin analizinde temel bir kavramdır. Bir zaman serisinin ortalama, varyans, kovaryans ve daha yüksek dereceden momentleri zaman içinde sistematik bir değişim göstermiyorsa veya seri periyodik dalgalanmalardan arındırılmışsa, bu seriye durağan zaman serisi adı verilir. Meydana gelen duruma ise "durağanlık" denilmektedir. Durağanlık, zaman serilerinin öngörülebilirliğini ve analiz edilebilirliğini sağlar; böylece serinin özellikleri zaman boyunca sabit kalır (Tüzen, 2012).

Bir zaman serisinin ortalama değeri, varyansı ve kovaryansı zamanla değişmiyorsa, bu seri durağan olarak kabul edilebilir. Bu bağlamda;

$$\text{Ortalama} \quad E(X_t) = \mu \quad (\text{Tüm } t\text{'ler için.})$$

$$\text{Varyans} \quad \text{Var}(X_t) = \sigma^2 \quad (\text{Tüm } t\text{'ler için})$$

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

şeklinde yazılır. Beyaz Gürültü süreci, en temel ve basit durağan zaman serisi örneğidir. Beyaz gürültü süreci;

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

biçiminde yazılır. Beyaz gürültü süreci, durağanlık koşullarına çok benzer, ancak tek bir önemli farkla; o da kovaryansının sıfır olmasıdır. Bu bağlamda;

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, $k \neq 0$)

biçiminde yazılır (Oğhan, 2010).

Zaman serileri genellikle belirli özellikleri karşılamaz. Eğilimler, konjonktürel ve mevsimsel dalgalanmalar gibi faktörler, serinin ortalamasının değişmesine neden olabilir. Bu durum, serinin durağan olmadığını ve otokorelasyon değerlerinin sıfırdan önemli ölçüde farklı olduğunu gösterir. Zaman serilerini etkili bir şekilde modelleyebilmek için öncelikle serinin durağan hale getirilmesi gerekir. Olasılık teorisinin büyük bir kısmı, durağan zaman serileri üzerine inşa edilmiştir; bu nedenle, zaman serisi analizlerinde bu teorilerden faydalanmak için durağan olmayan serilerin durağan hale dönüştürülmesi gereklidir (Bölük, 2012).

2.3. Durağanlık Testleri

Birçok durağanlık testi bulunmaktadır. Burada en yaygın olarak uygulanan yöntemler arasında Otokorelasyon Fonksiyonları, Kısmi Otokorelasyon Fonksiyonları ve Birim Kök Testleri yer almaktadır.

2.3.1. Otokorelasyon Fonksiyonu

Otokorelasyon fonksiyonu (OKF&ACF) analiz sürecinde bir zaman serisinin hangi model ya da modellere uygun olabileceğini belirleme ve seçim süreçlerinde kritik bir araç olarak kabul edilir. Bu fonksiyon, aynı değişkenin zaman içindeki farklı noktalarda aldığı değerler arasındaki ilişkinin gücünü ölçer. Özellikle, zaman serisinde art arda gelen gözlemler arasındaki farklı zaman dilimlerindeki ilişkinin gücünü ölçen katsayı "otokorelasyon katsayısı" olarak adlandırılır ve $\rho(k)$ ile gösterilir. Farklı gecikme değerlerine ($k = 0, 1, 2, \dots, n$) karşılık gelen otokorelasyon katsayıları $\{\rho(k)\}$ ile bu gecikme sürelerini ilişkilendiren işleme "otokorelasyon fonksiyonu" adı verilir (Özmen, 1986).

X_t ile X_{t-k} arasındaki korelasyon;

$$Corr[X_t, X_{t-k}] = \frac{Cov[X_t, X_{t-k}]}{\sqrt{Var[X_t]} \sqrt{Var[X_{t-k}]}} \quad (2.1)$$

denklemini ile elde edilir. Durağanlık ile denklem sade bir hale çevrilebilir.

$$Cov[X_t, X_{t-k}] = \gamma(k) \quad (2.2)$$

$$\sqrt{Var[X_t]} = \sqrt{Var[X_{t-k}]} = \gamma(0) \quad (2.3)$$

$$Corr[X_t, X_{t-k}] = \frac{\gamma(k)}{\gamma(0)} \quad (2.4)$$

Otokorelasyon fonksiyonu;

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

şeklinde tanımlanır. Yani gecikme k iken otokorelasyon fonksiyonu

$$\rho(k) = \frac{\gamma(k)}{\gamma(0)} = ACF(k) \quad (2.5)$$

biçiminde de tanımlanır (Sampson, 2001).

2.3.2. Kısmi Otokorelasyon Fonksiyonu

Kısmi otokorelasyon fonksiyonu (KOKF&PACF), X_t ve X_{t-k} arasındaki ilişkinin gücünü, aradaki diğer zaman dilimlerinin etkilerini göz önünde bulundurmadan belirler. Diğer yandan, otokorelasyon fonksiyonu, bir zaman serisindeki farklı zamanlardaki değerler arasındaki ilişkileri değerlendirir. Bu iki fonksiyon, zaman serisi analizinde çeşitli ilişki türlerini anlamak için kullanılır (Oğhan, 2010).

Bir X_t zaman serisi verildiğinde, X_t 'nin $X_{t-1}, X_{t-2}, X_{t-3}, \dots, X_{t-n}$ değerlerine bağlı regresyon modelindeki X_t 'nin kendi katsayısı, n . dereceden kısmi otokorelasyon katsayısı,

$$X_t = \phi_1 X_{t-1} + \phi_2 X_{t-2} + \dots + \phi_n X_{t-n} + \varepsilon_t \quad (2.6)$$

şeklinde gösterilir. (2.6) denkleminde ϕ_n , n . kısmi otokorelasyon katsayısını göstermektedir.

(2.6) eşitliğini kullanmak, kısmi otokorelasyon katsayılarını hesaplamayı zor ve meşakkatli bir süreç haline getirir. Ancak, kısmi otokorelasyonları, otokorelasyon katsayıları aracılığıyla daha basit bir yöntemle:

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

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,

$$\phi_n = \frac{\det(P_h)}{\det(P_h^*)} \quad (2.7)$$

dir (Akdi, 2010; Özek, 2010).

Kısmi otokorelasyon katsayıları, otoregresif (AR) modellerinin derecesini belirlemede kullanıldığından, AR(p) süreçleri için kritik öneme sahiptir. AR modellerinin uygun derecesini belirlemek için, bu katsayıların hangi gecikmeden sonra sıfırdan farklı olmayan değerlere ulaştığını tespit etmek gereklidir (Box vd., 2008).

2.3.3. Durağan Olmama ve Birim Kök Testleri

Zaman serilerinin analizi sırasında durağan olmama durumu, serilerin istatistiksel özelliklerinin zamanla değişiklik göstermesi anlamına gelir. Bu, serinin ortalaması, varyansı ve kovaryansının zamanla sabit kalmadığı durumları ifade eder. Durağan olmayan seriler, modelleme ve tahmin süreçlerinde sorunlar yaratabilir. Bu tür serilerin durağan hale getirilmesi için çeşitli birim kök testleri uygulanır. Birim kök testleri, serinin birim kök içerip içermediğini belirlemeye yardımcı olur ve serinin durağan olup olmadığını test etmek için kullanılır. En sık kullanılan birim kök testleri arasında Dickey-Fuller (DF) Testi, Genişletilmiş Dickey-Fuller (ADF) Testi ve Phillips-Perron (PP) Testi bulunmaktadır. Ayrıca, Kwiatkowski, Phillips, Schmidt ve Shin (KPSS) Testi de yaygın olarak kullanılmaktadır. Bu testler, serinin durağan olup

olmadığını belirleyerek uygun modelleme ve analiz tekniklerinin seçilmesine katkı sağlar.

Dickey-Fuller Testi

Zaman serilerinde durağanlığı belirlemek amacıyla geliştirilen ilk birim kök testi, Fuller (1976) ile Dickey ve Fuller (1979) tarafından tanıtılmıştır. Bu test, daha sonra geliştirilerek yaygın bir şekilde kullanılmaya başlanmıştır. DF testi, serinin durağan olmadığını yani birim kök içerdiğini öne süren hipotezi, serinin durağan olduğunu yani birim kök içermediğini belirten alternatif hipoteze karşı test eder. Zaman serilerinin uzun dönemli davranışları, bir değişkenin önceki dönemdeki değerlerinin mevcut dönemi nasıl etkilediğini analiz ederek anlaşılabilir. Bu nedenle, serinin tarihsel süreç içerisindeki değerleri üzerinden regresyon analizi yapılmalıdır. Bu amaca hizmet eden birim kök testleri, serilerin durağan olup olmadığını belirlemek için geliştirilmiştir ve bu sayede zaman serilerinin özellikleri daha iyi anlaşılabilir (Torun, 2015; Ekmekçi, 2016).

Temel formül;

$$y_t = \rho y_{t-1} + \varepsilon_t \quad (2.8)$$

burada;

y_t : Zaman Serisi Verisi

ρ : Model Parametresi

ε_t : Durağan Hata Terimi

dir. Durağanlık hipotezini test etmek için bu model, (2.9) şeklinde de yeniden yazılabilir:

$$\Delta y_t = (\rho - 1)y_{t-1} + \varepsilon_t$$

$$\Delta y_t = \delta y_{t-1} + \varepsilon_t \quad (2.9)$$

burada:

- $\Delta y_t = y_t - y_{t-1}$: Birinci Fark
- $\delta = (\rho - 1)$

dir. Testin amacı δ parametresinin sıfır olup olmadığını test etmektedir.

- $H_0: \delta = 0$ (Zaman serisi birim kök içerir, yani durağan değildir.)
- $H_1: \delta < 0$ (Zaman serisi durağandır.) (Dickey & Fuller, 1979).

Genişletilmiş Dickey-Fuller Testi

Zaman serisinin daha yüksek dereceden otokorelasyonlarını hesaba katmak için genişletilmiş bir versiyonu kullanılır.

$$\Delta y_t = \alpha + \beta_t + \delta y_{t-1} + \sum_{i=1}^p \gamma_i \Delta y_{t-i} + \varepsilon_t \quad (2.10)$$

α : Sabit Terim (Intercept)

β_t : Zaman Trendi

γ_i : İlgili Gecikme Farklarının Katsayısı

p : Modeldeki Gecikme Sayısı

Denklem (2.10)'da, δ parametresinin sıfır olup olmadığını test ediyoruz:

- $H_0: \delta = 0$ (Seride birim kök vardır, yani seri durağan değildir.)
- $H_1: \delta < 0$ (Seride birim kök yoktur, yani seri durağandır.)

Dickey-Fuller Test İstatistiği:

DF testi istatistiği, δ parametresi için t-istatistiği hesaplanarak elde edilir:

$$DF = \frac{\hat{\delta}}{SE(\hat{\delta})} \quad (2.11)$$

burada;

$\hat{\delta}$: Tahmin edilen δ değeri

$SE(\hat{\delta})$: Tahmin edilen δ değerinin standart hatası

dır.

DF test istatistiği, belirli kritik değerlere karşılık gelir ve bu değerler, serinin durağan olup olmadığını belirlemek için kullanılır. Eğer DF test istatistiği kritik değerden küçükse (genellikle negatif bir değer), H_0 reddedilir ve serinin durağan olduğu sonucuna varılır (Dickey & Fuller, 1979).

Phillips-Perron Testi

DF testine benzer şekilde, Phillips-Perron (PP) testi de zaman serilerinde birim kök varlığını test etmek için kullanılır. Hata terimleri arasında otokorelasyon olmadığını kabul eden DF testi, hata terimlerinin otokorelasyonsuz ve sabit varyanslı olduğunu

varsayar. Bununla birlikte, PP testi, gecikmeli fark deęerlerini ekmeden parametrik olmayan istatistiksel yöntemler kullanır ve hata terimleri arasındaki ardışık ilişkiyi dikkate alır. Bu testte, parametrik olmayan bir yöntem olan Newey-West hata düzeltme mekanizması, hata terimleri arasındaki ilişkiyi düzeltmek için kullanılır. Hata terimlerinin zayıf bağımlı ve heterojen dağılımı, bu mekanizmanın otokorelasyon sorununu çözmesine izin verir. Trend içeren seriler için DF testi, PP testinden daha güçlüdür (Kaya, 2019).

PP testi, aşağıdaki regresyon modelini kullanır:

$$y_t = \alpha + \beta_t + \gamma y_{t-1} + \varepsilon_t \quad (2.12)$$

Burada:

y_t : Zaman Serisi Verisi

α : Sabit Terim

β_t : Zaman Trendi

γ : Model Parametresi (Birim Kök Testi İçin Önemli)

ε_t : Hata Terimi

PP testi, aşağıdaki hipotezleri test eder:

- $H_0: \gamma = 0$ (Zaman serisi birim kök içerir, yani durağan değildir.)
- $H_1: \gamma < 0$ (Zaman serisi durağandır.)

PP testi, DF testine benzer şekilde γ parametresinin sıfır olup olmadığını test eder; ancak hata terimlerinin otokorelasyonu ve heteroskedastisitesini dikkate alır. Bu nedenle, test istatistięi hesaplanırken hata terimlerinin yapılandırması için düzeltmeler yapılır.

PP testi için test istatistięi,

$$PP = \frac{\hat{\gamma}}{SE(\hat{\gamma})} \quad (2.13)$$

dir.

Burada:

$\hat{\gamma}$: Tahmin edilen γ değeri.

$SE(\hat{\gamma})$: Tahmin edilen γ değerinin standart hatası.

Standart hata $SE(\hat{\gamma})$:

$$SE(\hat{\gamma}) = \sqrt{\widehat{Var}(\hat{\epsilon}_t)} \quad (2.14)$$

dır. Burada, $\widehat{Var}(\hat{\epsilon}_t)$, hata teriminin düzeltilmiş varyansdır. Bu düzeltilmiş varyans, hata terimlerinin uzun dönem varyans tahminidir. Böylece PP test istatistiği hesaplanır ve bu değer, belirli kritik değerlere karşı test edilir. Eğer PP test istatistiği kritik değerden küçükse (genellikle negatif bir değer), H_0 hipotezi reddedilir; bu da serinin durağan olduğu anlamına gelmektedir (Phillips & Perron, 1988).

PP testi, DF testinin hata terimleri konusundaki katı varsayımlarından ayrılmak amacıyla, hareketli ortalama (Moving Average) olarak hata terimlerinin geçmiş değerlerini kullanır. Bundan dolayı, Phillips-Perron testinde otoregresif hareketli ortalama (ARMA) sürecine, Dickey-Fuller testindeki AR süreci dönüştürülür. Trend durağanlık kavramının daha güçlü bir şekilde test edilmesini, hareketli ortalama (MA) sürecinin kullanılmasını sağlar (Kuzu, 2013).

2.4. Box-Jenkins Yöntemi

Box-Jenkins yöntemi, ARIMA modeli olarak da bilinen, zaman serilerinin analiz sürecinde durağanlık koşulunu sağlamış tek değişkenli veriler için geliştirilmiş bir tahminleme metodolojisidir (Can, 2020). ARIMA modellerinin temelleri, 1921 yılında Yule'un AR modellerini ortaya koymasıyla atılmıştır. Bunu takiben, 1927'de Shutsky tarafından MA modelleri geliştirilmiştir. 1954 yılında Wold, AR ve MA modellerini birleştirerek ARMA (Otoregresif Hareketli Ortalama) modellerini tanıtmıştır (Çevik, 1999). 1970-1976 yılları arasında ise Box ve Jenkins tarafından ortaya konulan, durağan koşulları karşılayan tek değişkenli zaman serileri için tasarlanmış bir analiz ve tahmin yöntemi olan ARIMA modeli oluşturulmuştur. Bu metodoloji, durağan zaman serilerinin tahmin edilmesi konusunda en yaygın olarak tercih edilen ve metodolojik açıdan en uygun bulunan yaklaşım olarak kabul edilir (Can, 2020).

Box-Jenkins yöntemi, geleceği tahmin etmede en yeni tekniklerden biridir ve diğer yöntemlerin dezavantajlarını gidermeyi hedefler. Bu sebeple, bazı durumlarda diğer yöntemler de dahil edilebilir. Newbold ve Granger tarafından yapılan 50 seri üzerindeki araştırmalar, Box-Jenkins yönteminin diğer yöntemlere kıyasla daha doğru ve güvenilir sonuçlar verdiğini ortaya koymuştur (Çağıl, 2017).

Box-Jenkins yöntemi, zaman serilerinin herhangi bir dönemdeki değerini, geçmiş dönem değerleri ve hata terimlerinin doğrusal kombinasyonu ile açıklar. Bu nedenle, literatürde ARIMA olarak da bilinir. Box-Jenkins modelleri, farklı alınmış serilere uygulanan AR ve MA modellerinin kombinasyonudur. Bu yaklaşımın amacı, zaman serisine en uygun doğrusal modeli bulmak için en az parametreye sahip bir model bulmaktır. Box-Jenkins yöntemi, cimrilik prensibine dayanarak optimal sayıda parametre içeren modeller geliştirmeyi hedeflemektedir (Altın, 2007; Sevüktekin & Nargeleçekenler, 2007; Özer, 2013).

ARIMA modeli, tek değişkenli bir tahmin yöntemi olup, geçmiş ve mevcut gözlem değerlerinden tahminler yapmayı amaçlar. Verilere uygun bir model belirlenerek tahminlerin güvenilirliği artırılabilir. Doğru model seçimi, güvenilir tahminler için kritiktir ve bu nedenle ARIMA modeli, tekrarlayan bir süreçte formüle edilme, uyarlanma, kontrol edilme ve ayarlama gerektirir (Öncel, 2018).

Tek değişkenli zaman serilerinin tahmininde Box-Jenkins yöntemi kullanılır. Bu yöntem, serinin durağan ve kesikli olduğunu varsayar. ARIMA modeli, eşit zaman aralıklarıyla elde edilen kesikli ve durağan zaman serileri için tahmin modelleri geliştirmede sistematik bir yaklaşım sunar ve kısa dönem tahminlerinde oldukça başarılıdır. Bu yöntem, zamana bağlı rastlantısal olayları ve bu olaylarla ilgili zaman serilerini stokastik süreçler olarak ele alır. Verilerin kendi kendini açıklaması prensibiyle çalışır ve iç bağımlılığı yüksek oranda dikkate alır. Bu nedenle, Box-Jenkins modelleri doğrusal stokastik modeller olarak da bilinir. Ayrıca, uygun modelin seçilmesi ve her aşamada incelenip denetlenmesi imkânı sağlar. (Çevik, 1999; Duru, 2007; Gözcü, 2009; Ekmekçi, 2016).

Box-Jenkins yöntemi, serinin durağan olup olmamasına veya mevsimsel unsur içermesine bakılmaksızın çözüme ulaşabildiği için son zamanlarda oldukça popülerdir. Durağan olmayan zaman serilerine uygulanabilmesi için önce durağanlığı

bozan unsurlar dönüşüm yöntemleriyle giderilir ve seri durağan hale getirilir. Ardından ileriye dönük tahminler yapmak için uygun model belirlenir. Box-Jenkins yöntemi, durağanlaştırılan zaman serilerini hareketli ortalamalar ve otoregresif süreçlerle birleştirerek geleceğe yönelik tahminler yapmayı mümkün kılar. (Duru, 2007; Gözcü, 2009; Şen & Polat, 2013).

Zaman serisinin yapısı veya genel gelişme özelliği hakkında ön bilgiye ihtiyaç duymaması, Box-Jenkins yönteminin diğer yöntemlerden farkını ortaya koymaktadır. Aksine, serinin belirli bir eğilime sahip olması diğer yöntemlere göre gerekmez; bu da Box-Jenkins yöntemini karmaşık zaman serilerine uygulamayı mümkün kılar. Bu yöntemde, zamana bağlı olayların tesadüfi yapıda olduğu kabul edilerek modeller geliştirilir; bu da onu diğer yöntemlerden ayıran önemli bir özelliktir (Duru, 2007; Çağıl, 2017).

2.4.1. Box-Jenkins Yöntemi ile Modelleme Süreci

Box-Jenkins yönteminde model kurma süreci üç temel aşamadan oluşur: modelin tanımlanması, modelin tahmin edilmesi ve modelin doğrulanması.

İlk aşama, modelin tanımlanması aşamasıdır. Bu aşamada, zaman serisi verilerinin durağan olup olmadığı kontrol edilir. Durağan olmayan veriler, genellikle fark alma veya dönüşüm uygulanarak durağan hale getirilir. Ardından, otokorelasyon ve kısmi otokorelasyon fonksiyonları analiz edilerek veriler için uygun ARIMA modelinin dereceleri belirlenir. Bu süreçte amacımız verinin yapısal özelliklerini en iyi şekilde yakalayabilecek modeli seçmektir (Box & Jenkins, 1970).

İkinci aşama, modelin tahmin edilmesidir. Bu aşamada, seçilen ARIMA modelinin parametreleri, en küçük kareler veya maksimum olabilirlik gibi yöntemler kullanılarak tahmin edilir. Parametre tahminleri, modelin veriye ne kadar iyi uyduğunun bir göstergesidir. Uygun model parametrelerinin tahmini, modelin gelecekteki değerleri tahmin etme yeteneğini doğrudan etkiler (Box & Jenkins, 1976).

Son aşama, modelin doğrulanmasıdır. Bu aşamada, tahmin edilen modelin zaman serisi verilerine ne kadar iyi uyduğu değerlendirilir. Model doğrulama, çeşitli istatistiksel testler ve teşhis kontrol grafikleri kullanılarak yapılır. Ayrıca, modelin gelecekteki verileri ne kadar iyi tahmin edebileceği de değerlendirilir. Başarılı bir

model doğrulaması, modelin hem geçmiş hem de gelecekteki verileri etkili bir şekilde tahmin edebileceğini gösterir (Box & Jenkins, 1970).

2.4.2. Model Belirleme

Zaman serisi verilerinin analizinde ARIMA modelleri gibi gelişmiş istatistiksel yöntemlerin uygulanabilmesi, serinin durağanlık ve mevsimsellik özelliklerinin önceden belirlenmesine bağlıdır. Box-Jenkins metodolojisi temelinde, bir zaman serisinin analizi için en uygun modelin seçilmesi süreci, öncelikle serinin durağan olup olmadığının tespiti ile başlar. Durağanlık, Box-Jenkins tahmin modellerinin kullanılabilirliği için temel bir ön koşuldur. Serinin durağan olup olmadığını değerlendirmenin ilk adımı, genellikle serinin grafiğinin çizilmesidir. Eğer grafik, trend veya mevsimsellik gibi belirli özellikler sergiliyorsa, bu durum incelenen serinin durağan olmadığını gösterir. Ancak, bu yöntemle kesin bir sonuca varmak her zaman mümkün olmayabilir. İlk bakışta durağan gibi görünen seriler, zaman içerisinde minimal değişiklikler gösterebilir. Durağanlık analizinde daha güvenilir bir yöntem olarak, serinin otokorelasyon fonksiyonları ve bu fonksiyonların grafiksel temsili olan korelogramlar ön plana çıkarmaktadır (Özmen, 1986).

Zaman serisi analizinde durağanlık tespiti, otokorelasyon fonksiyonu analizi ve birim kök testleri ile gerçekleştirilir. Durağan olmayan seriler, fark alma yöntemiyle durağan hale getirilir. Mevsimsellik gösteren serilerde mevsimsel fark alma işlemi uygulanır. Hem mevsimsellik hem de trend içeren serilerde, önce trend fark alınarak ortadan kaldırılır, ardından mevsimsel fark alma işlemi yapılır. Bazı durumlarda fark alma yeterli olmayabilir; bu durumda serinin logaritması alınarak analiz yapılabilir. Durağanlık sağlandığında, otokorelasyon (ACF) ve kısmi otokorelasyon (PACF) fonksiyonları, model derecesinin belirlenmesinde kullanılır. ACF ve PACF fonksiyonları, bir serinin $AR(p)$, $MA(q)$, $ARMA(p,q)$ veya $ARIMA(p,d,q)$ modellerinden hangisine uygun olduğunu belirlemede büyük önem taşımaktadır (Biçen, 2006).

Çizelge 2.1. ACF ve PACF'nin teorik davranışları (Akıncı, 2008).

Model	Otokorelasyon Fonksiyonu (ACF)	Kısmi Otokorelasyon Fonksiyonu (PACF)
AR(p)	Azalı ve kaybolur.	p gecikme sonra kesilir.
MA(q)	q gecikme sonra kesilir.	Azalı ve kaybolur.
ARMA(p,q)	Azalı ve kaybolur ardından q gecikme sonra kesilir.	Azalı ve kaybolur ardından p gecikme sonra kesilir.

Bir süreç eğer Otoregresif (AR) model tipi AR(p) olarak modellenabiliyorsa, otokorelasyon katsayıları üstel bir şekilde azalarak sifıra yaklaşır; bu durumda kısmi otokorelasyon katsayıları ise p gecikme sonrası sıfır değerini alır. Otokorelasyon katsayılarının azalması sadece üstel bir düşüşle sınırlı kalmayıp, sinüs dalgası formunda veya sarkaç hareketini andıran bir yapı gösterebilir. Hareketli Ortalama (MA) modeli MA(q) şeklinde tanımlandığında, otokorelasyon katsayıları q gecikme sonrasında sifıra düşerken, kısmi otokorelasyon katsayıları üstel olarak azalarak sifıra yaklaşır ve bu katsayılar sinüsoidal dalgalanmalar da sergileyebilir. ARMA(p, q) modeli durumunda, üstel bir düşüş ile hem otokorelasyon hem de kısmi otokorelasyon katsayıları sifıra yaklaşır ve bu süreçlerde sinüsoidal dalgalanmalar gözlenebilir (Göktaş, 2005; Can, 2009).

2.4.3. Model Tahmini

Zaman serisi analizinde uygun modelin türü ve derecesi tespit edildikten sonra, söz konusu modelin otoregresif (AR) ve hareketli ortalama (MA) parametrelerinin tahmin işlemi gerçekleştirilir. Bu tahminlerin biasız (sapmasız), tutarlı ve verimli bir şekilde yapılması esastır. İlk parametre tahminleri, otokorelasyon katsayıları ile parametreler arasındaki ilişkileri gösteren denklem sistemlerinin çözümüyle elde edilir. Bu işlem, parametrelerin matematiksel ilişkilerini temel olarak yapılan bir analiz sonucudur.

İstatistik alanında, parametre tahminleri gerçekleştirilirken En Küçük Kareler Yöntemi (Ordinary Least Squares, OLS), En Büyük Olabilirlik Yöntemi (Maximum Likelihood Estimators, MLE), Momentler Metodu (Method of Moments Estimators) ve Bayes Tahmin Yöntemi (Bayesian Estimators) gibi yöntemler sıklıkla tercih edilmektedir.

Zaman serisi analizinde, bu genel yöntemlere ek olarak Yule-Walker tahminleri de önemli bir yer tutmaktadır. Örneklem büyüklüğü yeterli seviyede olduğunda, bu tahmin yöntemleri, serinin durağan olduğu varsayımı altında birbirine yakın sonuçlar üretmektedir (Akdi, 2010).

Modelin parametrelerinin "En Küçük Kareler" (EKK) yöntemiyle tahmin edilmesi halinde, hata terimlerindeki otokorelasyonun yol açtığı etkin olmayan ve yüksek varyansa sahip tahminler nedeniyle, "Doğrusal Olmayan En Küçük Kareler" (Nonlinear Least Squares, NLS) yönteminin kullanılması daha uygun olabilir. Hata terimleri normal dağılım gösterdiğinde, "En Çok Olabilirlik" (Maximum Likelihood, ML) yönteminin tercih edilmesi yaygındır. Tahmin sürecinde göz önünde bulundurulması gereken önemli noktalar aşağıdaki gibidir (Akgül, 2003):

* Tüm AR ve MA parametrelerinin tahminleri, durağanlık ve ters çevrilebilirlik koşullarını sağlamalıdır. Eğer tahmin edilen parametreler bu koşulları karşılamazsa, incelenen modelin reddedilmesi ve yerine yeni bir modelin araştırılması gereklidir. Özellikle, bir seri durağan olduğu halde yanlışlıkla farkının alınması veya durağan olmayan bir serinin farkının alınmaması gibi durumlarda, tahmin edilen AR ve MA parametreleri belirlenen bu sınırların dışına çıkabilir.

* AR ve MA parametre tahminlerinin istatistiksel olarak önemli olması gerekmektedir. Modelin veriye uyum sağlamasının ardından, tüm parametre tahminlerinin mutlaka istatistiksel anlam taşımaması zorunlu değildir. Parametrelerin anlamlılığı, t-testi aracılığı ile değerlendirilebilir. Kaliteli bir model için, t-değerlerinin kritik değeri aşması beklenir. İstatistiksel olarak anlamsız bulunan parametreler, modelin optimizasyonu amacıyla çıkarılıp model yeniden tahmin edilebilir.

Tahmin süreçlerinde sıklıkla çeşitli yazılım paketleri kullanılarak parametre tahminleri gerçekleştirilmektedir. Bu süreçte, farklı metodolojiler aracılığıyla sonuçta "En Küçük Hata Kareleri"ni sunan tahminler tercih edilmektedir. İteratif bir hesaplama süreci gerektirdiğinden, tahmin işlemine başlarken parametreler için başlangıç değerlerinin belirlenmesi önem arz etmektedir. İlk aşamada, deneme amaçlı bir model için başlangıç parametre değerleri hesaplanır ve ardından bu değerler, yazılım paketleri aracılığıyla iteratif yöntemler kullanılarak nihai tahminlere ulaşmak için kullanılır.

Ancak, elde edilen parametre tahminlerinin istatistiksel olarak anlamlı olması ve durağanlık ile ters çevrilebilirlik koşullarına uygun olması gerekmektedir.

Bu metodun temel prensiplerinden biri, belirli zaman aralıkları ile elde edilen gözlemlerin oluşturduğu serinin kesikli ve durağan olması gerektiğidir. AR ve MA modelleri, yanı sıra bu iki modelin entegrasyonu ile oluşturulan ARMA modelleri, özellikle durağan zaman serilerinin analizi için kullanılmaktadır. Durağan olmayan zaman serileri ise ARIMA modelleri ile analiz edilmekte, bu modeller durağanlık koşulunu sağlamayan serilere uygulanabilen stratejiler sunmaktadır (Şenyüz, 2019).

2.5. Doğrusal Durağan Stokastik Modeller

Bir zaman serisinin, rastgele şokların lineer kombinasyonu olarak oluşturulduğu varsayımı, genel bir lineer stokastik model olarak kabul edilir. Uygulamada, az sayıda parametre ile ifade edilen modellerin tercih edilmesi önerilir. Bu tür bir tasarruf, genellikle zaman serisinin az miktarda AR ve MA terimi kullanılarak modellenmesi şeklinde gerçekleşir (Box & Jenkins, 1976).

2.5.1. Otoregresif: AR(p)

AR(p) modeli, bir zaman serisinin mevcut değerinin, kendi geçmişindeki p kadar önceki değerlere bağlı olduğunu varsayan bir otokorelasyon regresyon modelidir. Bu model, zaman serilerindeki karmaşık yapıları modellemek için kullanılır ve serinin geçmiş değerlerinin mevcut değer üzerindeki etkisini geniş bir zaman aralığında incelemeye olanak tanır. AR(p) modelinin genel formülü şu şekildedir:

$$X_t = c + \phi_1 X_{t-1} + \phi_2 X_{t-2} + \dots + \phi_p X_{t-p} + \varepsilon_t \quad (2.15)$$

burada:

X_t :Zaman serisinin t zamandaki değeri.

p :İlişkiyi modellememiz için korelasyon katsayısını yani modelimizin derecesini gösterir.

c :Sabit terim.

$\phi_1, \phi_2, \phi_3 \dots \phi_p$:Modelin Parametreleri (Otoregresif Katsayılar)

ε_t :t zamanındaki hata terimi, genellikle beyaz gürültü olarak kabul edilir.

Bu modeller, bir zaman serisindeki önceki gözlemler için belleğe sahiptir. p değeri 0 olduğunda, komşu gözlemler arasında ilişki yoktur. p değeri 1 olduğunda, 1. derece gecikme değerleri arasında ϕ_1 korelasyon katsayılı bir ilişki bulunur. p değeri 2 olduğunda ise, 2. derece gecikme değerleri arasında ϕ_2 korelasyon katsayılı bir ilişki vardır.

AR(p) Modelinin Özellikleri

Gecikme Seçimi (p): AR modelindeki "p" değeri, modelin ne kadar geçmişe bakacağını belirler. Bu değer seçimi, modelin performansını doğrudan etkiler ve çeşitli istatistiksel yöntemler (Akaike Bilgi Kriteri (AIC), Bayes Bilgi Kriteri (BIC), vb.) kullanılarak belirlenebilir.

Katsayılar (θ): AR modelinin katsayıları, zaman serisinin geçmiş değerlerinin mevcut değer üzerindeki etkisini ölçer. Bu katsayılar, modelin eğitimi sırasında veriye en iyi uyan değerler olarak hesaplanır.

Durağanlık: AR(p) modelinin başarılı bir şekilde uygulanabilmesi için, analiz edilen zaman serisinin durağan olması gerekir. Bir zaman serisi, ortalama, varyans ve kovaryansın zamanla sabit kaldığı anlamına gelen durağan olduğunda, AR(p) modeli daha güvenilir sonuçlar üretebilir.

2.5.2. Hareketli Ortalama: MA(q)

Hareketli Ortalama (MA) modeli, zaman serileri analizinde kullanılan başka bir önemli modeldir. "MA(q)" modeli, bir hareketli ortalama modelinin "q" derecesini ifade eder; burada "q" gecikme sayısını (yani, hata terimlerinin sayısını) belirtir. Zaman serisindeki anlık değişimlerin mevcut ve gelecek değerler üzerindeki etkilerini modellemek için kullanılır. MA(q) modeli, bir zaman serisinin mevcut değerinin geçmiş hata terimlerinin bir fonksiyonu olarak ifade edilir. Matematiksel olarak MA(q) modeli şu şekilde tanımlanır:

$$X_t = \mu + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \dots + \theta_q \varepsilon_{t-q} \quad (2.16)$$

burada:

X_t :Zaman serisinin t zamanındaki değer

μ :Zaman serisinin ortalaması.

ε_t :t zamanındaki hata terimi, genellikle beyaz gürültü olarak kabul edilir.

$\theta_1, \theta_2, \dots, \theta_q$:Modelin parametreleri (hareketli ortalama katsayıları), geçmiş hata terimlerinin mevcut değer üzerindeki etkisini ölçer.

MA(q) Modelinin Özellikleri

Gecikme Seçimi (q): MA modelindeki "q" değeri, modelin kaç adet geçmiş hata terimini dikkate alacağını belirler. Bu değer, modelin karmaşıklığını ve geçmiş bilgilerin mevcut tahminler üzerindeki etkisini kontrol eder.

Hata Terimleri(ε): MA modelleri, zaman serisinin rassal şoklarını (hata terimlerini) doğrudan modellemeye odaklanır. Bu şoklar, zaman serisindeki beklenmedik değişimleri temsil eder.

Durağanlık: MA(q) modeli genellikle durağan zaman serileri için uygundur. Modelin durağan olup olmadığını kontrol etmek, analiz sürecinin önemli bir parçasıdır.

2.5.3. Otoregresif Hareketli Ortalama: ARMA(p,q)

Durağan bir zaman serisini yalnızca AR veya MA süreci olarak ifade etmek her zaman pratik değildir, çünkü yüksek dereceli AR veya MA modelleri çok fazla parametre gerektirir. Bunun yerine, ARMA modeli kullanılarak parametre sayısı azaltılabilir ve böylece yalnızca AR veya MA modellerine göre daha uygun bir model elde edilebilir (Tüzen, 2012).

Zaman serileri analizinde, ARMA modeli, iki temel modelin birleşimidir: AR(p) modeli ve MA(q) modeli. ARMA modeli, hem kendi geçmiş değerlerine (AR kısmı) hem de geçmiş hata terimlerine (MA kısmı) bağlı olarak bir zaman serisinin mevcut değerlerini modellemek için kullanılır. ARMA modeli, genellikle ARMA(p, q) olarak ifade edilir; burada "p" otoregresif bileşenin derecesini ve "q" hareketli ortalama bileşenin derecesini belirtir ve p+q sayıda terim içermektedir (Duru, 2007). Modelin matematiksel ifadesi şöyledir:

$$X_t = c + \phi_1 X_{t-1} + \phi_2 X_{t-2} + \dots + \phi_p X_{t-p} + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \dots + \theta_q \varepsilon_{t-q} \quad (2.17)$$

burada:

X_t :Zaman serisinin t zamanındaki değeri

c :Sabit terim

$\phi_1, \phi_2 \dots \phi_p$: AR bileşenin katsayıları.

ε_t :t zamanındaki hata terimi, genellikle beyaz gürültü olarak kabul edilir.

$\theta_1, \theta_2 \dots \theta_q$: MA bileşenin katsayıları.

Otoregresif ve Hareketli Ortalama modellerinin kombinasyonundan elde edilen karma model, ARMA(p,q) modeli olarak da adlandırılabilir. Modelimizi kurabilmek için p ve q model derecelerimiz, yani korelasyon katsayılarımız olmalıdır. ARMA(p,q) modelinde, p adet otoregresyon (ϕ) ve q adet hareketli ortalama (θ) parametresi bulunmaktadır. Toplamda p+q parametre sayısı bulunur. Bunlardan biri ortalama değer μ , diğeri ise varyans δ_ε^2 olarak hesaplanır (Duru, 2007).

ARMA Modelinin Özellikleri

Esneklik: ARMA modeli, bir zaman serisinin yapısal özelliklerini hem AR hem de MA terimleri aracılığıyla yakalayabilen esnek bir yapıya sahiptir. Bu, modelin çok çeşitli zaman serilerini etkili bir şekilde modelleyebileceği anlamına gelir.

Durağanlık Gereksinimi: ARMA modelinin etkili bir şekilde uygulanabilmesi için, analiz edilen zaman serisinin durağan olması gerekir. Durağan olmayan seriler için genellikle bir dönüşüm uygulanır.

Parametre Seçimi: Modelin "p" ve "q" parametrelerinin seçimi, genellikle otokorelasyon fonksiyonu (ACF) ve kısmi otokorelasyon fonksiyonu (PACF) analizleri gibi istatistiksel yöntemler kullanılarak yapılır.

2.6. Durağan Olmayan Doğrusal Stokastik Modeller

Box ve Jenkins'in 1976'da geliştirdiği ARIMA modeli, durağan olmayan zaman serileri için bir çözüm sunarak AR ve MA modellerinin birleşimi olan ARMA

modelinin kapsamını genişletmiştir. ARMA modeli, yalnızca durağan zaman serileri ile sınırlı iken, ARIMA modeli, zaman serisindeki durağan olmayan özellikleri ardışık fark alma yöntemiyle ele alır ve böylece zaman serisini durağan hale getirerek ARMA modelinin uygulanabilirliğini sağlar. Bu yaklaşım, durağanlık özelliği göstermeyen serilerdeki karmaşık yapıları modelleyebilmek için önemli bir adımı temsil eder ve zaman serisi analizinde kullanılan temel yöntemlerden biri haline gelmiştir. Box ve Jenkins'in bu yenilikçi çalışması, zaman serilerinin analizi ve tahmin edilmesi alanında devrim yaratmış ve birçok alanda uygulama bulmuştur (Erturan, 2017).

2.6.1. Otoregresif Bütünleşik Hareketli Ortalama: ARIMA(p,d,q)

ARIMA modeli, zaman serisi analizinde sıkça başvurulan bir yöntemdir (Özdemir, 2008). ARIMA yöntemi, zaman serilerini modellerken kullanılan bir tekniktir ve amacı olabildiğince az parametre kullanarak serinin en uygun doğrusal modelini tespit etmektir. Bu metodoloji, bir zaman serisinin gelecekteki değerlerini tahmin etmeye yöneliktir; bu tahminler, serinin geçmiş değerleri ve hata terimlerinin doğrusal kombinasyonları aracılığıyla gerçekleştirilir. Bu şekilde, ARIMA modeli geçmiş verilerden yararlanarak, bir zaman serisinin otokorelasyonunu ve trend bileşenlerini inceleyerek gelecekteki değerler hakkında bilgi sağlamayı amaçlar (Kaya, 2019; Abushukur, 2022).

ARIMA modeli, ekonomi, finans ve diğer birçok alanda karmaşık veri setlerinin analizini yapabilmek için yönlendirilmiş tahmin ve simülasyon araçlarıyla birlikte kullanılır (Aygören vd., 2012). AR bileşeni, bir zaman serisinin mevcut değerinin önceki değerlerle olan ilişkisini temsil eder (Tanışman vd., 2021). I bileşeni, bir zaman serisinin durağan olup olmadığını inceler. Eğer durağan değilse, fark alarak durağan hale getirilir (Tuna, 2019). MA bileşeni ise hata terimlerinin ortalamasını alarak zaman serisinin rastgele hareketlerini gösterir (Kaynak, 2022).

ARIMA modeli AR (Otoregresif), I (Bütünleşik) ve MA (Hareketli Ortalama) bileşenlerinden oluşmaktadır (Ergül, 2018). Modelin bileşenlerini daha ayrıntılı bir şekilde incelediğimizde:

Otoregresif (AR) bileşeni: Zaman serisi analizinde, bir değer kendi geçmişiyle olan ilişkisi otoregresif olarak adlandırılır. AR bileşeninin derecesi, bu ilişkiyi ifade eder

ve "p" ile gösterilir (Abushukur, 2022). Örneğin, AR(1) modeli mevcut değer bir önceki değere bağlı olduğunu belirtirken, AR(2) modeli mevcut değer hem bir önceki hem de iki önceki değere bağlı olduğunu ifade eder (Şahin, 2018).

Bütünleşik (I) bileşeni: Zaman serileri durağan olmayabilir; yani sabit bir ortalamaya veya varyansa sahip olmayabilirler. Durağanlık elde etmek için zaman serisinden belirli farklar alınır. Bu işlem "I" bileşeni ile ifade edilir ve derecesiyle belirtilir (Tuna, 2019).

Hareketli Ortalama (MA) bileşeni: MA, bir zaman serisindeki rastgele hataları ifade eder (Ergül, 2018). Bu hatalar, belirli bir zaman diliminde meydana gelen beklenmedik olaylardan kaynaklanabilir. MA bileşeni, bu rastgele hataların bir sonraki dönemdeki etkisini tanımlar (Tanışman vd., 2021).

ARIMA modelinin başarısı, bu üç bileşenin doğru parametrelerle belirlenmesine bağlıdır. Bu parametrelerin doğru bir şekilde ayarlanması, modelin veriyi doğru tahmin edebilmesi için kritik bir öneme sahiptir (Kaynak, 2022).

Model parametrelerini belirlerken, ACF ve PACF gibi araçlar kullanılır. Bu fonksiyonlar, AR ve MA bileşenlerinin optimal değerlerini belirlemek için kullanılır (Arslan & Ertuğrul, 2022).

ARIMA modeli zaman serisi analizinde oldukça güçlü bir araçtır, fakat doğru sonuçlar alabilmek için parametrelerinin dikkatli bir şekilde ayarlanması gerekmektedir. Bu, özellikle kripto para fiyatları gibi yüksek dalgalanma gösteren veri setleri için çok önemlidir (Özdemir, 2008).

Ekonomik zaman serileri gibi birçok zaman serisi durağan değildir ve bu durum, trendler, mevsimsel dalgalanmalar, konjonktürel etkiler ve rastlantısal şoklar gibi faktörlerden kaynaklanır. Durağan olmayan serilerin doğru modellenmesi için önce durağan hale getirilmesi gerekir. Bu, serideki sistematik bileşenlerin ortadan kaldırılmasıyla sağlanır. Durağanlık sağlandıktan sonra analiz ve modelleme yapılabilir, bu da tahminlerin güvenilirliği için kritik önem taşır. Trend, mevsimsellik, konjonktürel dalgalanmalar ve tesadüfi nedenler gibi faktörlerden dolayı durağanlıklarını kaybeden veriler, doğru modelleme için ARIMA modelini gerektirir (Duru, 2007).

ARIMA(p,d,q) modelinin genel formülasyonu, serinin d kez fark alınarak durağan hale getirilmesini takiben, bu durağan serinin AR(p) ve MA(q) modelleri ile modellemesini içerir.

$$(1 - \sum_{i=1}^p \phi_i L^i)(1 - L)^d X_t = (1 + \sum_{j=1}^q \theta_j L^j) \varepsilon_t \quad (2.18)$$

Burada:

L : Gecikme operatörü.

X_t : Zaman serisinin t zamanındaki değeri.

ε_t : Beyaz gürültü hata terimidir.

ϕ_i ve θ_j sırasıyla AR ve MA bileşenlerinin katsayılarıdır.

ARIMA Modelinin Özellikleri

Esneklik: ARIMA, geniş bir zaman serisi yelpazesini modelleyebilir çünkü hem trend hem de mevsimsellikten arındırılmış durağan olmayan serileri ele alabilir.

Durağanlık Dönüşümü: d parametresi, seriyi durağan bir yapıya dönüştürmek için kullanılır; bu da modelin analiz ve tahmin kapasitesini artırır.

Model Seçimi ve Tahmin: ARIMA modelinin parametreleri (p,d,q), genellikle Akaike Bilgi Kriteri (AIC) ve Bayes Bilgi Kriteri (BIC) gibi istatistiksel kriterler ile otokorelasyon fonksiyonları kullanılarak seçilir. Modelin tahmini için genellikle En Büyük Olabilirlik Yöntemi (MLE) kullanılır.

ARIMA Modelinin Uygulama Şeması

1-Durağanlık ve Varyans Sabitleme: İlk olarak, zaman serisinin varyansını sabitlemek amacıyla uygun dönüşümler yapılır. Daha sonra, seriyi durağanlaştırmak için gerekli olan farklar alınır. Bu süreçte, otoregresyon (p) ve hareketli ortalama (q) değerleri belirlenir.

2-Model Tanımlama: Deneme yanılma yöntemiyle bir dizi model tanımlanır ve en uygun olan model geleceğe yönelik tahminler için seçilir.

3-Parametre Tahmin ve Seçimi: Seçilen modelin parametreleri tahmin edilir. Model belirleme sürecinde, belirtme katsayısı (R^2), F-istatistiği, Akaike Bilgi Kriteri (AIC) ve Schwarz Bilgi Kriteri (SIC) gibi istatistiksel ölçütler kullanılır. Aday modelin

parametrelerinin tahmini için olabilirlik fonksiyonu veya en küçük kareler yöntemi gibi yöntemler kullanılarak parametreler belirlenir. Parametreler, olabilirlik fonksiyonunun maksimizasyonu veya hataların karelerinin minimizasyonu ile elde edilir.

4-Model Gözden Geçirme: Eğer seçilen model zaman serisini yeterli derecede açıklayamazsa, ikinci aşamaya geri dönülür ve tanımlama süreci yeniden ele alınır.

5-Model Doğrulama ve Tahmin: Bu aşama, seçilen modelin zaman serisini ne kadar etkili bir şekilde açıkladığını değerlendiren bir aşamadır. Ayrıca, bir veya birkaç dönem için geleceğe yönelik tahminler yapılır ve bu tahminler için güven aralıkları belirlenir. (Erdoğan, 2006; Şenesen & Günlük Şenesen, 2012; Torun, 2015).

Hata Kareler Ortalaması

Hata kareler ortalaması (HKO), tahmin edilen değerler ile gerçek değerler arasındaki farkların karelerinin toplamının ortalamasını ifade eder. Formülü şu şekildedir:

$$\varepsilon_i = y_i - \hat{y}_i$$

$$\varepsilon_i^2 = (y_i - \hat{y}_i)^2$$

$$\sum_{i=1}^n \varepsilon_i^2 = \sum_{i=1}^n (y_i - \hat{y}_i)^2$$

$$HKO = \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n} \quad (2.19)$$

y_i : Gerçek değer.

\hat{y}_i : Tahmin edilen değer.

n : Gözlem sayısı.

ε_i : Hata.

HKO, model tahminlerinin ne kadar doğru olduğunu ve bu tahminlerin performans karşılaştırmalarını anlamak için kullanılır. Küçük bir HKO değeri, modelin tahminlerinin gerçek değerlere yakın olduğunu gösterir.

3. YAPAY SİNİR AĞLARI

YSA, karmaşık desenleri tanıma ve veriden öğrenme yeteneğine sahip, insan beyninin bilgi işleme sürecinden ilham alınarak geliştirilmiş öğrenme algoritmasıdır. YSA için yapılan diğer bir tanım ise, insan beyninin öğrenme, yeni bilgiler üretme ve keşfetme gibi yeteneklerini taklit ederek, dışarıdan yardıma ihtiyaç duymadan bu becerileri gerçekleştirebilen algoritma modelleridir (Tekin, 2009).

YSA alanında ilk çalışmalar, önerme mantığı üzerinde araştırmalar yapan McCulloch ve Pitts tarafından 1943 yılında gerçekleştirilmiştir. Bu bilim insanları, yapay sinir ağlarının nöron mantığıyla öğrenme yeteneği kazanabileceğini ortaya koymuşlardır. Modellerini oluştururken, sadece 've' ve 'veya' mantıksal operatörlerini kullanarak fonksiyonları simüle etmeye çalışmışlardır (Crone, 2004). Sonraki YSA çalışmalarına Shannon, McCarthy, Hebb, Edmonds, Minsky ve Rochester gibi bilim insanlarının araştırmaları rehberlik etmiştir. Simon ve Newell, ilk teorem kanıtlama programlarını geliştirmişler ve sundukları Fiziksel Simge Varsayımı, insandan bağımsız yapay zeka sistemleri üzerinde çalışanlar için bir başlangıç noktası olmuştur (Saraç, 2005). YSA, karmaşık ve zaman alıcı sorunların çözümünde yaygın olarak kullanılmaktadır. Günümüzde, YSA teknolojilerine yalnızca laboratuvar ortamlarında değil, ev cihazları, bilgisayarlar ve cep telefonları gibi günlük yaşamın birçok alanında da erişim sağlanabilmektedir. YSA, endüstriyel uygulamalardan finans ve askeri sistemlere, sağlık sektöründen madencilik ve ses tanımaya kadar birçok farklı alanda geniş bir kullanım alanına sahiptir (Ömrüuzun, 2019).

3.1. Yapay Sinir Ağlarının Temelleri

YSA, beyin nöronları arasındaki iletişimini taklit eden sistematik yapılarıdır (Şenol & Denizhan, 2023). Bu yapılar, veri işleme, ölçüm ve tahminlerde hataları azaltmak amacıyla kullanılır; bu sayede makineler öğrenebilir hale gelir (Özdemir, 2008).

Katmanlar ve Nöronlar: YSA, insan beyninin işleyişinden esinlenerek oluşturulmuş, birbiriyle bağlantılı nöronlardan oluşan karmaşık bilgisayar sistemleridir. Bu sistemlerde, "katmanlar" olarak adlandırılan bir dizi nöron bulunur; bunlar arasında giriş, gizli ve çıkış katmanları yer alır. Her katmandaki nöronlar, bir önceki katmandan aldıkları sinyalleri işleyip bir sonraki katmana ileterek bilgi akışını sağlar. Nöronlar arasındaki bağlantıların gücü, "ağırlıklar" ile ifade edilir ve bu ağırlıklar, öğrenme sürecinde sürekli olarak güncellenir.

YSA, giriş katmanı, bir veya daha fazla gizli katman ve çıkış katmanı olmak üzere genellikle üç ana katmandan oluşur (Yılmaz vd., 2018). Giriş katmanı, verinin ağa sunulduğu ilk katmandır. Gizli katmanlar, veriyi işleyen ve dönüştüren katmanlardır. Gizli katmanların sayısı ve her katmandaki nöron sayısı, modelin karmaşıklığına bağlı olarak değişebilir. Çıkış katmanı, sonuçları temsil eder (Tuna, 2019).

Aktivasyon Fonksiyonları: Aktivasyon fonksiyonları, YSA nöronlarının çıktılarını belirleyen matematiksel işlevlerdir. Bu fonksiyonlar, bir nöronun toplam girdi sinyalini alıp, bu sinyali bir çıktı sinyaline dönüştürmek için kullanılır; böylece ağı öğrenme ve karar verme sürecine yön verirler.

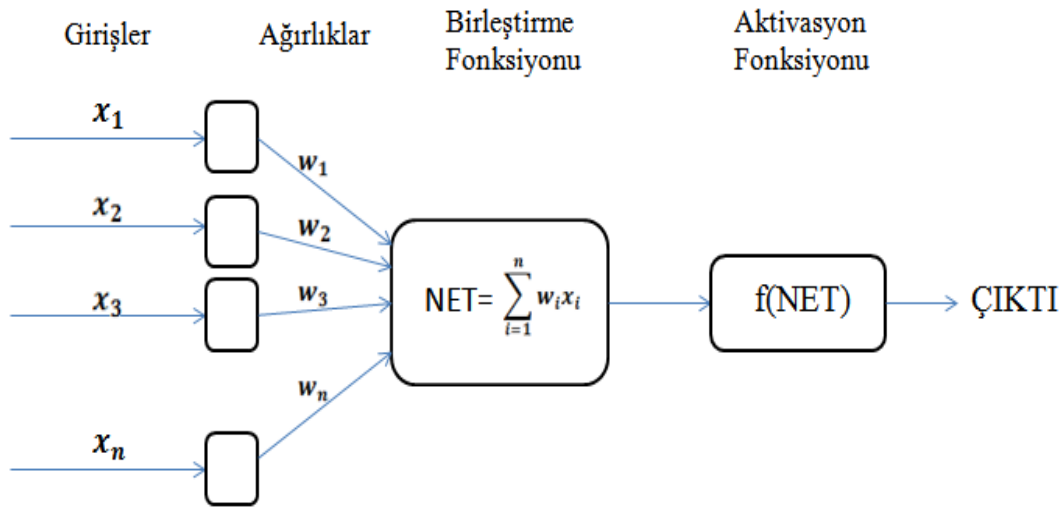
YSA'da her nöron bir aktivasyon fonksiyonu ile donatılmıştır. Bu fonksiyon, nöronun tepkiselliğini belirler ve tepkinin belirli bir eşiği aşp aşmadığına karar verir (Ahmet, Zengin, & Yıldız, 2020). Yaygın aktivasyon fonksiyonları arasında Sigmoid Fonksiyonu, Tanjant Hiperbolik (tanh) Fonksiyonu, ReLU (Rectified Linear Unit) Fonksiyonu, Leaky ReLU Fonksiyonu ve Softmax Fonksiyonu bulunmaktadır (Şahin, 2018).

Eğitim ve Öğrenme: Klasik programlama, programcı tarafından belirlenen talimatları adım adım izleyen sistemlerdir. Buna karşılık, YSA klasik anlamda programlanmaz. YSA'lar, çözülmesi istenen problemle ilgili örnekler üzerinde çalışarak veriler arasındaki ilişkileri öğrenir (Şahin, 2002). Bu süreçte, programcı tarafından belirlenen kurallar yerine, ağ eğitim yoluyla problemle ilgili bir algoritma geliştirir. YSA'lar, eğitim sırasında işledikleri örneklerden elde ettikleri bilgileri kullanarak genellemeler yapar ve eğitimde karşılaşmadıkları yeni problemlere uygun çıktılar üretebilirler (Grossberg, 1992). Ayrıca, YSA'lar, ilgili problemde meydana gelen değişikliklere

uyum sağlayabilmek için yeniden eğitilebilir; böylece yeni duruma uygun çözümler sunabilirler (Akkurt, 2005).

3.2. Yapay Sinir Hücre Yapısı

İnsan beyninin sinir yapısını milyonlarca sinir hücresi oluşturmaktadır. Günlük hayatta insanların algıladığı şeyler sinyaller aracılığıyla sinir hücrelerine gelir ve burada bir eylem oluşturur. Yapay Sinir Hücresi (YSH) de aynı sinir hücrelerinin taklidini yaparak öğrenme ve olgular arası ilişkiler ortaya koyar. Bu bilgiler gerçek sinir ağına benzer şekilde tüm sinir hücreleri arasında dolanarak iletilir (Çakır, 2018).

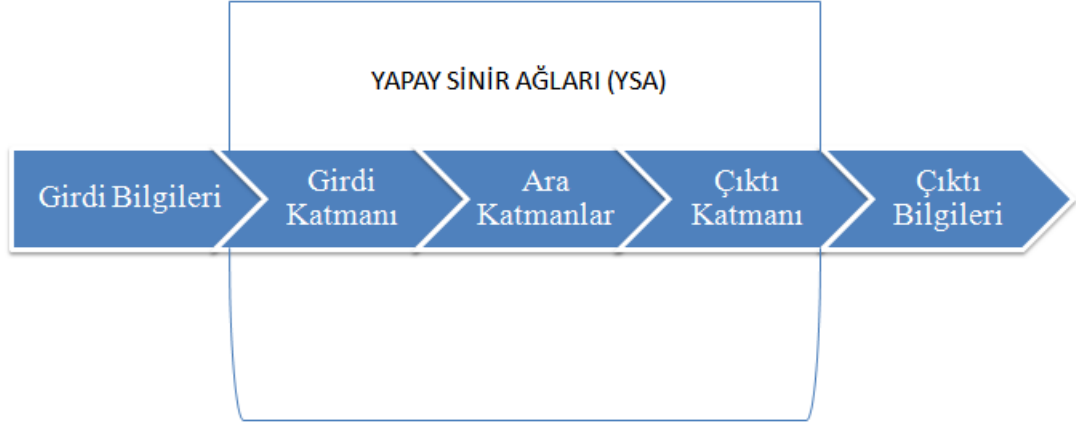


Şekil 3.1. Yapay sinir hücresi (YSH).

YSH'ye dış dünyadan gelen veri ve bilgiler, girdiler (girişler) olarak tanımlanır. YSA girdileri, öğrenmek veya tahmin etmek istediğimiz konuya göre şekillendirilmelidir. Ağırlıklar, yapay sinir hücresine iletilen bilgi ve verilerin önem derecesini belirtir. Bu ağırlıklar negatif veya pozitif değerler alabilir ve girdilerle ağırlıklar arasındaki çarpım ($x_i * w_i$), birleştirme fonksiyonuna aktarılır (Çakır, 2018).

Birleştirme fonksiyonu, YSA'daki bir sinir hücresine giren birden fazla değeri tek bir değere dönüştürür ve bu fonksiyonun toplama, çarpma, maksimum, minimum gibi çeşitli türleri vardır. Aktivasyon fonksiyonu ise bu birleştirme fonksiyonu tarafından elde edilen değerleri işler ve belirli bir aralıkta mı yoksa dışında mı olduklarını belirler. Sigmoid, Tanh, ReLU, Leaky ReLU ve Softmax gibi çeşitli aktivasyon fonksiyonları bu işlemde kullanılır. Aktivasyon fonksiyonu, işlenen değeri çıktı olarak üretir. Bu

çıktı, YSA dışına veya başka bir hücreye iletilebilir. Girdiler birden fazla olabilirken, çıktı tek bir değer olarak üretilir ve bu çıktı başka sinir hücrelerine girdi olarak kullanılabilir (Öztemel, 2006).



Şekil 3.2. Yapay sinir ağı arasındaki ilişki.

YSA; girdi katmanı, ara (gizli) katman(lar) ve çıktı katmanı olmak üzere üç temel katmandan oluşur.

Girdi Katmanı: Girdi katmanı, dış dünyadan alınan bilgi ve verilerin yapay sinir ağına girdiği ilk noktadır. Bu katmanın ana görevi, gelen bilgileri ara katmanlara, yani gizli katmanlara iletmektir. Girdi katmanında alınan veri üzerinde herhangi bir işlem yapılmaz. Bu katman, yapay sinir ağlarının öğrenme sürecinin temelini oluşturur.

Ara (Gizli) Katman(lar): Girdi katmanından alınan bilgi ve veriler, gizli katmanlar aracılığıyla işlenerek çıktı katmanına iletilir. Gizli katmanlar, ham verileri karmaşık işlemlerden geçirip bir sonraki katmana aktarır. Bu katmanların sayısı, modelin öğrenme kapasitesini ve problemleri çözme yeteneğini artırır.

Çıktı Katmanı: Gizli katmanlardan işlenmiş bilgi ve veriler, çıktı katmanına ulaştığında son kez işlenerek nihai çıktılar üretilir. Çıktı katmanı, ara katmanlarda işlenmiş bilgileri alır ve bu bilgileri dış dünyaya sunar. Genellikle tek bir düğümden oluşan bu katman, bir önceki gizli katmandaki tüm düğümlere bağlıdır. Böylece, Yapay sinir ağı tarafından gerçekleştirilen öğrenme süreci tamamlanmış olur. (Öztemel, 2006).


3.3. Biyolojik Sinir Ağı ve Yapısı

Biyolojik sinir hücresinin yapısını ve çalışma sistemini anlamak, YSA'nı daha kolay anlaşılır hale getirir. Biyolojik sinir sistemi, bilgiyi alıp işleyerek uygun kararlar veren beynin merkezinde yer alan üç katmanlı bir yapıdır. Bu katmanlar (Saraç, 2005):

1. Çevreden gelen sinyalleri elektriksel sinyallere dönüştürüp beyne ileten alıcı sinirler (nöral reseptörler (neural receptors)),
2. Beynin ürettiği elektriksel sinyalleri uygun tepkilere dönüştüren tepki sinirleri,
3. Alıcı ve tepki sinirleri arasında ileri ve geri besleme yoluyla uygun tepkiler üreten merkezi sinir ağıdır.

İnsan beyni, son derece hızlı çalışan ve mükemmel bir bilgisayar olarak kabul edilebilir. Biyolojik sinir ağları, üstün performansları ve karmaşık özellikleri yönetme yeteneğiyle öne çıkar. Geleneksel bilgisayarların tanıtıcı yüzleri çok daha uzun süre tanınır, ancak insan beyni daha hızlı tanınır. Bugün, insan beyninin kapasitesinin yalnızca bir bilgisayara sahip bir makine geliştirildiğinde olağanüstü bilgi işleme ve kontrol birimi geliştirilebilir. Bu tür bir cihaz mükemmel sonuçlar üretebilir. YSA ile bu yeteneklerin bilgisayarlara kazandırılması hedeflenmektedir (Öztemel, 2006).

Hücre gövdesi, dendritler, aksonlar ve sinapslar bir nöronun (sinir hücresi) yapısını oluşturur. Sinapslar, nöronlar arasındaki bağlantılar olarak kabul edilir. Bunlar fiziksel bağlantılar değildir; aksine, bir hücreden diğerine elektrik sinyallerinin geçişini sağlayan boşluklardır. Bu sinyaller hücre gövdesine iletilir ve burada işlenir. Nöron (sinir hücresi), kendi elektrik sinyalini üretir ve bunu akson aracılığıyla dendritlere gönderir. Dendritler ise bu sinyalleri sinapslara aktarır. İki hücre arasındaki bilgi alışverişi, sinaptik bağlantılar ve nörotransmitterler aracılığıyla gerçekleşir. Şekil 3.3.'de akson (axon) uçları başka bir hücre ile bağlantı kurmayı sağlar (Öztemel, 2006).



Şekil 3.3. Biyolojik sinir hücresi (Anderson & McNeill, 1992).

Çizelge 3.1.'de, YSA'nın insan sinir sisteminin benzer işlemlerini yürüttüğünü göstermektedir.

Çizelge 3.1. Biyolojik sinirler ile yapay sinirlerin görevleri (Çelik, 2008).

Biyolojik Sinir Ağı	Yapay Sinir Ağı	Görevi
Dentrit	Alıcı ve toplayıcı.	Çevreden gelen veriyi alır.
Akson	Verici.	Gövdenin oluşturduğu veriyi iletir.
Hücre Gövdesi	Aktivasyon fonksiyonu.	Gelen veriyi toplayarak yorumlar ve çıktıyı oluşturur.
Sinaptik Ağırlıklar	Bağlantı ağırlıkları.	Öğrenilenleri hafızada saklar.

3.4. Yapay Sinir Ağlarının Geleneksel Sistemlerden Farkları

YSA'nın geleneksel hesaplama yöntemlerinden, verilerin tahmini, analizi ve aralarındaki ilişkiler temelinde farkları bulunmaktadır. Çizelge 3.2.'de Anderson ve McNeill'e göre geleneksel hesaplama yöntemleri ile YSA arasındaki farklar ortaya konulmuştur.

Geleneksel hesaplama yöntemleri;

- Belirli bir algoritma veya adım adım işlem sürecine dayanır.
- Belirli bir model veya formül ile sınırlıdır.

- Genelleme yapabilme kapasitesi sınırlıdır.
- Karmaşık ve büyük veri seti ile çalışmak zorluk çıkarabilir.
- Gürültülü veya belirsiz veriler, sonuçları ciddi şekilde bozabilir.

YSA ise;

- Doğrusal olmayan ilişkileri öğrenme kapasitesine sahiptir.
- Eğitim sürecinde öğrenir ve bu sayede çeşitli durumlara uyum sağlayabilir.
- Genelleme yapabilme yeteneğine sahiptir.
- Büyük veri setlerini işlemek ve karmaşık çok boyutlu ilişkileri modellemek için uygun bir yapı sunar.
- Verilerdeki belirsizlik ve gürültü ile başa çıkma konusunda başarılı olabilir.

Çizelge 3.2. Geleneksel hesaplama yöntemleri ile YSA'ların karşılaştırılması (Ömrüuzun, 2019).

Karakteristik	Geleneksel Hesaplama	Yapay Sinir Ağları
İşlem Stili	Sıralı	Parelel
Fonksiyonlar	Kurallar, kavramlar ve hesaplama yoluyla, mantıksal (sol beyin)	Resimler, görüntüler, kontroller yoluyla (sağ beyin)
Öğrenme Metodu	Kurallarla	Örneklerle
Uygulamalar	Muhasebe, kelime işlem, matematik, stok, dijital işlem	Sensör işleme, ses tanıma, karakter tanıma, sınıflandırma

3.5. Yapay Sinir Ağları Sınıflandırılması

YSA, katman sayısına (mimari) ve çalışma ile öğrenme yapısına göre çeşitlilik gösterebilir ve sınıflandırılabilir.

3.5.1. Katman Sayısına Göre Yapay Sinir Ağları

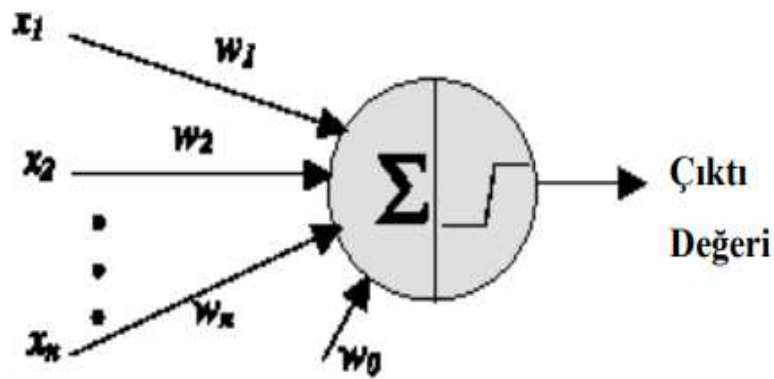
Sinir ağlarının yapısı ve performansı, içerdikleri katman sayısına göre büyük ölçüde değişiklik gösterir. Tek katmanlı sinir ağları, basit problemleri çözmek için kullanılırken, derin öğrenme olarak adlandırılan çok katmanlı sinir ağları, daha karmaşık veri setleri ve problemler üzerinde çalışmak için geliştirilmiştir. Bu katmanların artışı, modelin öğrenme kapasitesini ve veri içindeki derin, karmaşık

desenleri tanıma yeteneğini önemli ölçüde artırır; böylece daha doğru tahminler ve analizler sağlar.

Tek Katmanlı

YSA'nı anlamak için tek katmanlı yapay sinir ağları, en basit ve temel model olarak incelenmelidir. Bu ağlar, yalnızca giriş ve çıkış katmanlarından oluşur ve karmaşık yapıların temel prensiplerini kavramak için önemlidir. Tek katmanlı ağlar, ağırlıkların öğrenilmesi ve nöronlar arasındaki etkileşimleri anlamada kritik bir rol oynar. Bu basit yapılar, daha karmaşık problemlerin çözümüne zemin hazırlar. Bu nedenle, yapay sinir ağlarının temelini anlamak için ideal bir başlangıç noktasıdır (Krose & Smagt, 1996).

Algılayıcılar, girdi ve çıktı katmanlarına ek olarak gizli katmanlar barındırabilen yapı taşlarıdır; ancak geçmişte bu yapıların kullanımına dair çalışmalar, hesaplama zorlukları nedeniyle sınırlı kalmıştır (Müller vd., 2012). Şekil 3.4'de görüldüğü gibi algılayıcı, girdi nöronlarından gelen verileri bir toplama fonksiyonu ile bir araya getirir ve elde ettiği sonucu tanımlanmış bir eşik fonksiyonuna göre değerlendirerek çıktı değerini üretir. Sistemin oluşturulmasında ilk adım, girdi nöronlarının tanımlanması ve bağlantılara rassal değerlerin atanmasıdır. Eğitim süreci, önceden belirlenmiş bir eğitim kümesinin ilk girdi-çıkış bilgilerinin ağına girilmesi ve ağı çalıştırılması ile başlar. Algılayıcı, girdileri bir araya getirerek anlamlı bir veri haline dönüştürür (Arbib, 2003). Bu aşamadan sonra, anlamlandırılan veri değerlendirilir ve algılayıcının çıktısı üretilir.




Şekil 3.4. Basit algılayıcı sinir ağı modeli (Akkurt, 2005).

Tek katmanlı YSA, Perceptron ve ADALINE/MADALINE şeklinde iki başlık altında incelenebilir.

Perceptron

1960'lı yıllarda Frank Rosenblatt tarafından ortaya konulmuştur. Tek hücreli ve tek katmanlı bir ağıdır. Perceptron, algılayıcı girdilerin ağırlıklı toplamını hesaplar, bir θ değeri ile karşılaştırır ve sonuç olarak iki olası değerden (0 veya 1) birine geçer. Elde edilen bu değer 1 ise A, 0 ise B sınıfına aittir şeklinde yorumlanır (Elmas, 2011). Maalesef, perceptronun sınırlılığını gösteren çalışmalar da mevcuttur. Şekil 3.5'de perceptron örneği gösterilmiştir.



Şekil 3.5. Perceptron örneği.

$$NET = \sum_{i=1}^n w_i x_i \quad (3.1)$$

$$y = \begin{cases} 1 & \text{eğer } NET \geq \theta \\ 0 & \text{eğer } NET < \theta \end{cases}$$

Beklenen çıktı değeri (B) ile gerçekleşen çıktı değeri (Ç) birbirine eşitse, yani farkları 0 ise, ağırlık değerlerinde (w_i) herhangi bir değişiklik yapmamıza gerek yoktur. Ancak, eğer beklenen çıktı gerçekleşmediyse, λ değerli öğrenme oranlı bir denklem kullanılır.

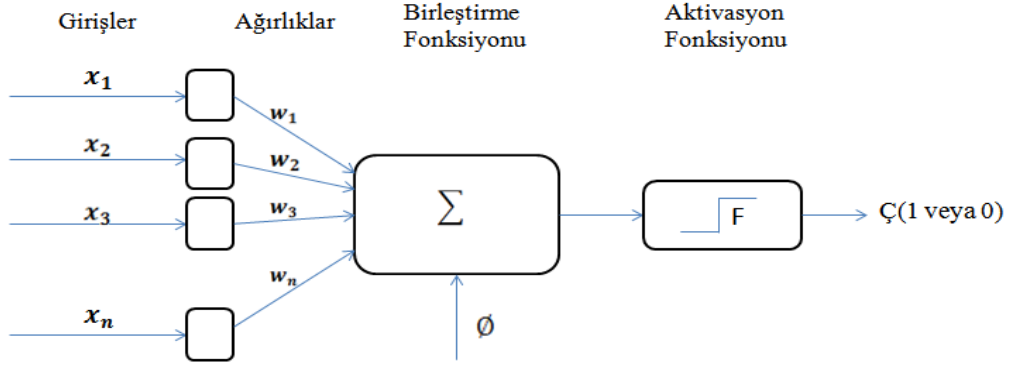
$$w_n = \begin{cases} w_0 - \lambda X & \text{eğer } B = 0 \text{ ve } NET \geq \theta \\ w_0 + \lambda X & \text{eğer } B = 1 \text{ ve } NET < \theta \end{cases}$$

Bu işlemler, tüm girdi örnekleri için doğru sonuç ve sınıflandırma verene kadar tekrarlanır (Öztemel, 2006).

ADALINE/MADALINE

Bernard Widrow ve Marcian Hoff tarafından 1959'da geliştirilen ADALINE (Adaptive Linear Neuron-Yinelemeli Doğrusal Sinir Ağı) ve MADALINE (Multiple ADaptive

LINear Elements-Çoklu Yinelemeli Doğrusal Sinir Ağı) modelleri, YSA alanında önemli kilometre taşlarıdır. Şekil 3.6’da ADALINE, girdilerin ağırlıklı toplamını alıp tek katmanlı bir yapıda işleyen bir modeli ifade etmektedir. Nöronun çıktısı, aktivasyon fonksiyonundan sonra elde edilir, ancak hata hesaplaması toplama biriminden yapılır; bu da ADALINE’i standart algılayıcılardan ayırır. En küçük kareler yöntemiyle ağırlıklar güncellenir, bu da tahminlerin iyileştirilmesini sağlar. Böylece, ADALINE kendini adapte edebilir ve hataları minimuma indirebilir (Öztemel, 2006).



Şekil 3.6. ADALINE ünitesi örneği.

ADALINE NET girdisi ve çıktısı denklemleri;

$$NET = \sum_{i=1}^m w_i x_i + \phi \quad (3.2)$$

$$\text{Çıktı} = f(x) = \begin{cases} -1, & \text{Eğer } NET < 0 \\ 1, & \text{Eğer } NET \geq 0 \end{cases}$$

ADALINE’da beklenen çıktı (B) ve gerçekleşen çıktı (Ç) arasındaki fark hatayı vermektedir. ($E=B-\text{Ç}$) Amacımız hatayı en aza indirmektir. Bunu da ağırlık ve yeni örnekler öğretmek ve ağırlıkları değiştirmek ile yapabiliriz. Bunun için de,

$$w_i(t) = w_i(t-1) + \alpha * E * X \quad (3.3)$$

denklemini kullanırız.

$w_i(t)$:t anındaki ağırlık

$w_i(t-1)$:(t-1) anındaki ağırlık

α : Öğrenme katsayısı

E :Beklenen çıktı ile gerçekleşen çıktı arasındaki hata farkı

X : Girdi seti

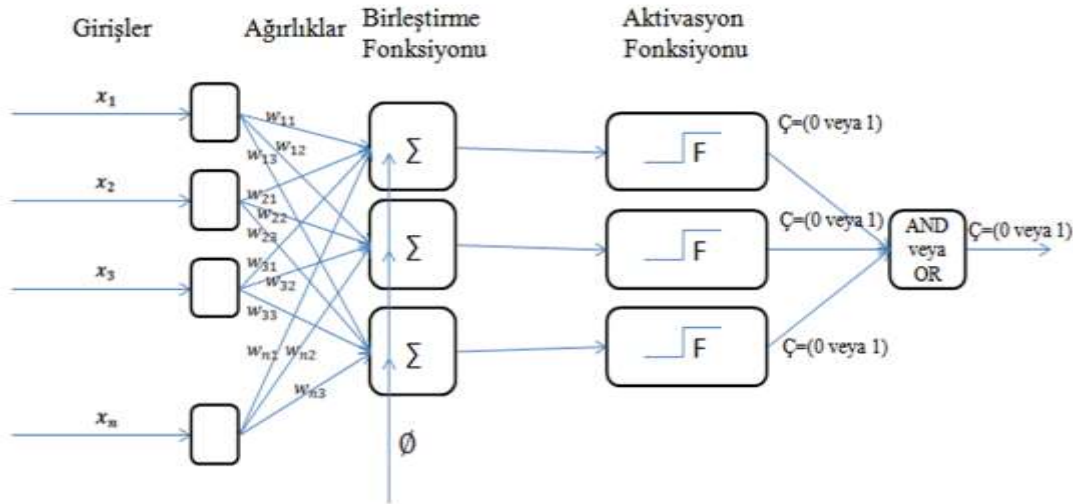
Eşik değeri de zaman içerisinde aşağıdaki denklem gibi hesaplanır.

$$\emptyset_y = \emptyset_e + \alpha * E \quad (3.4)$$

\emptyset_y :Yeni eşik değeri

\emptyset_e : Eski eşik değerini göstermektedir (Öztemel, 2006).

Şekil 3.7’de de görülmek üzere MADALINE ağı, farklı sayıda ADALINE üniteleri içeren katmanlardan oluşur ve lineer olmayan karar sınırları oluşturmayı hedefler. MADALINE ve ADALINE ağları, benzer öğrenme kurallarına sahiptir. MADALINE'nin çıkış katmanında bulunan AND ve OR operatörleri, ADALINE ünitelerinin çıktılarını birleştirir. AND operatörü, tüm ADALINE çıktıları 1 olduğunda 1, aksi halde 0 üretir. OR operatörü, en az bir ADALINE çıktısı 1 olduğunda 1, aksi halde 0 üretir. Bu operatörler, MADALINE'nin esnek ve karmaşık kararlar alabilmesini sağlar (Öztemel, 2006).




Şekil 3.7. Üç ADALINE ünitesinden oluşan MADALINE ağı örneği.

Çok Katmanlı

Bu model, giriş ve çıkış katmanlarının yanı sıra, tasarımcı tarafından belirlenen bir veya daha fazla ara katmanı içermektedir. Bu ara katmanlar, literatürde genellikle gizli katmanlar olarak da anılmaktadır. Uygulamanın özelliklerine göre giriş ve çıkış katmanlarındaki nöron sayıları değişiklik gösterir. Örneğin, üç giriş ve iki çıkışlı bir sistem için tasarlanan bir yapay sinir ağında, giriş katmanında üç, çıkış katmanında ise iki nöron bulunur. Gizli katmanların sayısı ve bu katmanlardaki nöron sayısında ise belirli bir kısıtlama yoktur. Ancak, gizli katmanların ve nöronların sayısının uygun

kriterlere göre seçilmemesi, yapay sinir ağının performansını olumsuz etkileyebilir. Bu sayıların belirlenmesi ise bir optimizasyon problemini ortaya çıkarmaktadır (Öğücü, 2006).



Şekil 3.8. Çok katmanlı yapay sinir ağı modeli örneği.


Çok katmanlı YSA, her bir katmanında düğümler arasında karmaşık bağlantılar ve ağırlıklar bulunan, birden fazla gizli katman içeren modellerdir. Bu yapılar, katmanlar arası ilişkiler sayesinde veriden karmaşık örüntülerin ve ilişkilerin öğrenilmesini sağlar; böylece model daha derin ve kapsamlı bir öğrenme süreci gerçekleştirebilir. Ağ, giriş katmanı ile başlar ve ardından gizli katmanlar ("Gizli Katman 1", "Gizli Katman 2" gibi) gelir. Bu gizli katmanlar, veriyi daha detaylı işleyerek farklı seviyelerdeki özellikleri çıkarır. Son katman, çıkış katmanı olup modelin nihai tahminlerini veya sınıflandırmalarını üretir. Bu katmanlı yapı, yapay sinir ağlarının karmaşık veri setlerinden anlamlı bilgiler öğrenmesini ve geniş bir uygulama alanında etkili olmasını sağlar (Öztemel, 2006). Şekil 3.8'de çok katmanlı yapay sinir ağı örneği gösterilmiştir.

3.5.2. Ağın Yapısına Göre Yapay Sinir Ağları

İleri Beslemeli

İleri beslemeli YSA'nda, nöronlar katmanlar halinde organize edilmiştir. Bir katmandaki nöronların çıktıları, bir sonraki katmana girdi olarak belirli ağırlıklar ile çarpılarak iletilir. Giriş katmanı, dış dünyadan aldığı ve herhangi bir işleme tabi tutmadığı bilgileri gizli katmanlardaki nöronlara iletir. Bu bilgiler, gizli katmanlarda işlendikten sonra çıktı katmanına ulaşır ve ağın nihai çıktısı elde edilir (Alataş, 2003).

YSA’nda giriş ve çıkış katmanlarındaki nöron sayıları genellikle veri yapısına göre belirlenirken, gizli katmanlardaki nöron sayısını optimize etmek için henüz kesin bir analitik yöntem yoktur. Bu nedenle, gizli katman yapılandırması, deneme-yanılma yöntemine dayanır ve bu süreç zaman alıcı olabilir. Gizli katmanların doğru yapılandırılması, ağın performansını ve genelleme yeteneğini büyük ölçüde etkiler. Bu adım, her problem için özel olarak uyarlanması gereken, yapay sinir ağı tasarımında kritik bir rol oynar (Efe & Kaynak, 2000).




Şekil 3.9. İleri beslemeli yapay sinir ağı örneği (Öztemel, 2006).

Şekil 3.9’da görüldüğü üzere ileri beslemeli YSA’nda sinyaller yalnızca girdi katmanından çıktı katmanına doğru tek bir yönde iletilir. Bir katmandan elde edilen çıktı, yalnızca bir sonraki katmandaki nöronlara iletilir ve onları etkiler; aynı katmandaki nöronları etkilemez. İleri beslemeli ağların çıktısı, tamamen ağa verilen girdilere bağlıdır. Bu tür ağlar dinamik değildir ve hem doğrusal hem de doğrusal olmayan problemler için uygulanabilir (Tolon & Tosunoğlu, 2008).

Geri Beslemeli

Geri beslemeli YSA’nda, en az bir nöron sonraki katmanlardaki nöronlardan geri beslenir. Bu tür ağlarda, çıktı ve ara katman çıktıları giriş birimlerine veya önceki ara katmanlara geri aktarılır; böylece bilgiler hem ileri hem de geri yönde taşınır. Geri beslemeli sinir ağları, ileri beslemeli ağlar gibi katmanlar içerir, ancak katmanlar arasındaki bağlantılar çift yönlüdür. Bu çift yönlü yapı, geri beslemeli ağların hem ileri hem de geri yönde bilgi akışını sağlamasına olanak tanır (Kaya vd., 2005).



Şekil 3.10. Geri beslemeli yapay sinir ağı örneği (Kabalcı, 2014).

Geribeslemeli YSA, karmaşık bir çalışma mekanizmasına sahiptir. Ancak dinamik hafıza yetenekleri sayesinde öngörü uygulamaları ve sınıflandırma işlemlerinde etkili sonuçlar üretirler. Geribeslemeli ağlar, çeşitli zaman serilerinin tahmin edilmesinde oldukça başarılıdır. Bu tür ağların önemli örnekleri arasında Hopfield, Elman ve Jordan ağları bulunur (Tüzen, 2012). Şekil 3.10'da geribeslemeli yapay sinir ağı örneği gösterilmiştir.

3.6. Yapay Sinir Ağlarında Öğrenme Yöntemleri ve Kuralları

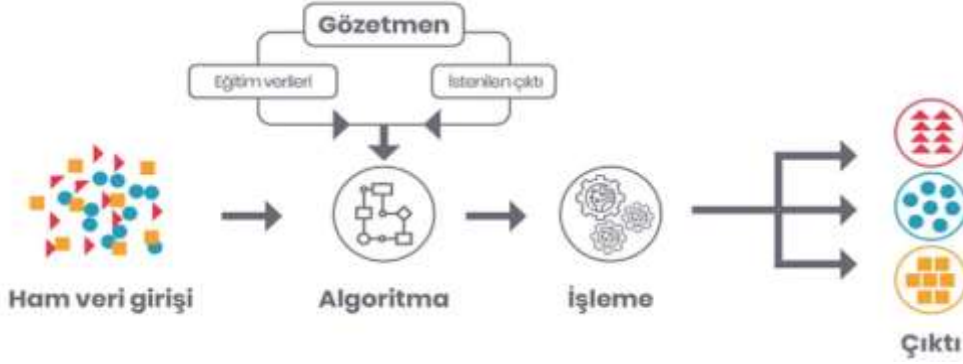
YSA'nda çeşitli öğrenme kuralları ve yöntemler mevcuttur. YSA için kullanılan öğrenme yöntemleri ve kuralları, ağların eğitim sürecinde temel stratejileri ve algoritmaları içerir.

3.6.1. Öğrenme Yöntemleri

Denetimli Öğrenme

Denetimli öğrenme yöntemi, öğretmenin öğrenciye yeni kavramlar öğretmesine benzer. Öğrenci, öğretmenden öğrendiği bilgileri görevler aracılığıyla uygular ve öğretmen, bu görevler için geri bildirim sağlar. Öğrenci hatalarını düzeltir ve en aza indirir. Denetimli öğrenmede, modelin ürettiği çıktı ile gerçek çıktı karşılaştırılır ve

aradaki fark, yani hata en aza indirilir. Bunun için ağırlıklar, üretilen ve gerçek çıktı birbirine yakın değerler alana kadar ayarlanır. Şekil 3.11’de denetimli öğrenme görülebilir.




Şekil 3.11. Denetimli öğrenme (turhost.com, 2021).

Örnek vermek gerekirse, bir veri setinde tavuk, kedi ve örümcek resimlerini ayırt etmek istediğimizi düşünelim. Denetimli öğrenme algoritması, önceden etiketlenmiş resimleri kullanarak bu hayvanları ayırt edecek belirleyici özellikleri öğrenir. Ardından, bir test resmi verildiğinde, bu özellikleri uygulayarak resmin hangi kategoriye en yakın olduğunu belirler ve sınıf tahmini yapar (lenorabilisim.com, 2021).

Denetimsiz Öğrenme

Bu öğrenme metodunda rehberlik eden bir öğretmenin olmaması, öğrencinin kendi başına deneyimleyerek hatalar yapmasını ve bu süreçte yeni kavramlar öğrenmesini sağlar. Hatalardan elde edilen deneyimler, öğrencinin benzer hataları en aza indirerek daha etkin öğrenmesini sağlar. Şekil 3.12’de denetimsiz öğrenme görülebilir.

Yapay sinir ağları, büyük miktarda veri ile beslenir ve bu verileri analiz ederek benzer özelliklere sahip olanları gruplandırır. Girdi değerlerine dayanarak ağın kendi başına çıktılar üretmesi beklenir; bu da ağın veriler arasındaki ilişkileri ve yapıları keşfetmesine olanak tanır. Bu yöntemler, karmaşık veri setleri üzerinde anlamlı bilgiler elde edilmesini sağlar (Çakır, 2018).




Şekil 3.12. Denetimsiz öğrenme (turhost.com, 2021).

Denetimli öğrenme yönteminde vermiş olduğumuz örneğe geri döndüğümüzde, tavuk, kedi ve örümcek resimlerini içeren bir veri setini daha önceden etiketlenmiş veri olmadan sınıflandırmak istediğimizi düşünelim. Bu durumda, hangi hayvanların resimlerde olduğu veya kaç farklı sınıf bulunduğu bilinmemektedir. Denetimsiz öğrenme algoritması, bu verileri analiz ederek doğal olarak oluşan sınıfları belirlemeye çalışır (lenorabilisim.com, 2021).

Pekiştirmeli Öğrenme

Pekiştirmeli öğrenme sürecinde bir tür öğretmen rolü vardır; ancak öğrenciye verilen yönlendirme, sağlanan geribildirimlere dayanır ve bu geribildirimler olumlu veya olumsuz olabilir. Bu model, sinir ağının ürettiği çıktının doğruluğunu mutlak değerler yerine yüzdelik oranlarla ifade eder. Örneğin, çıktının %75 doğru olduğu veya referans değerine %95 oranında yakın olduğu belirtilir. Bu nedenle, pekiştirmeli öğrenmede elde edilen bilgiler mutlak değil, göreceli veya olasılıksal terimlerle tanımlanır. Şekil 3.13’de pekiştirmeli öğrenme görülebilir.



Şekil 3.13. Pekiştirmeli öğrenme (turhost.com, 2021).

Pekiştirmeli öğrenme, mevcut bilgiye dayalı tahmin yapma ve rastgele keşfetmenin birleşimi olarak düşünülebilir. Bu duruma çocukken oynadığımız sıcak-soğuk oyunu güzel bir örnektir. Oyunda, aranan hedefin konumu hakkında hiçbir bilgiye sahip olmayan oyuncu, başlangıçta rastgele bir yöne ilerler. Diğer oyuncularından aldığı

"sıcak" veya "soğuk" geri bildirimlerine ve oyundaki deneyimlerine dayanarak hedefi bulmaya çalışır. Bu şekilde, anlık geri bildirimler ve deneyimler doğrultusunda en iyi sonuca ulaşmayı öğrenir (lenorabilisim.com, 2021).

3.6.2. Öğrenme Kuralları

YSA öğrenme süreci, dış dünyadan gelen girdileri temel yapıya uygun parametrik ayarlamalar veya değişiklikler yaparak istenen çıktıyı elde etmek için çalışır. Bu amaçla bir dizi öğrenme algoritması geliştirilmiştir.

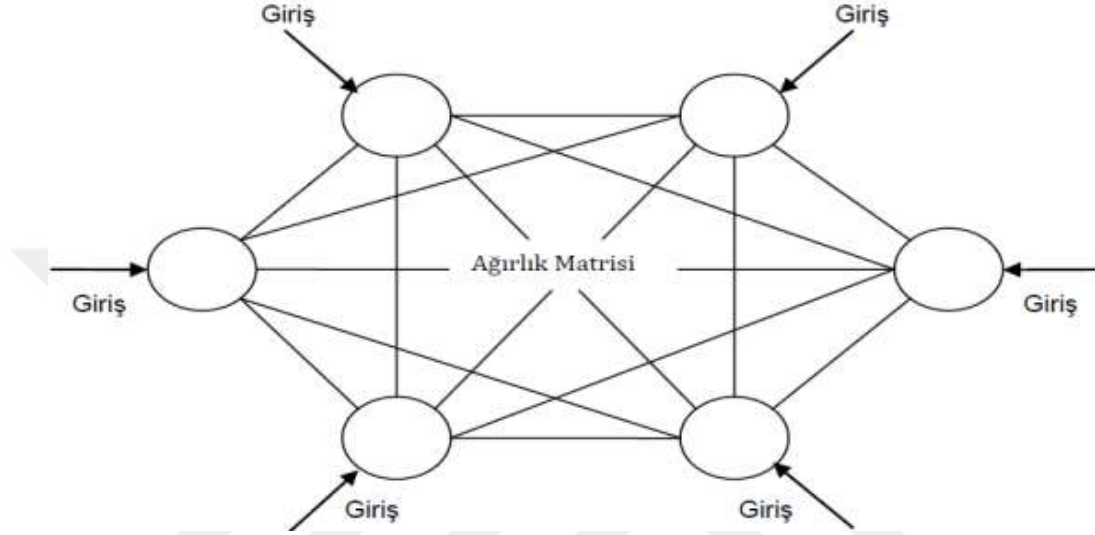
Hebb Öğrenme Kuralı

1949 yılında Kanadalı psikolog Donald Hebb, 'The Organization of Behavior' adlı eserinde, sinaptik bağlantılar yoluyla öğrenmeyi açıklayan fizyolojik kuralları tanımlamıştır. Bu kitapta, insan beyninin sürekli öğrenen ve öğrendikçe evrilen bir yapı olduğunu belirtmiş, nöronlar arası bağlantıların yeni görevlerle nasıl yeniden yapılandığından ve nöronların birbiriyle olan bağlantılarının eşzamanlı aktivasyonları sonucu güçlendiğinden bahsetmiştir. Hebb'in teorisini temel alan Rochester, Dula, Haibt ve Holland ise 1956 yılında yayımladıkları çalışmada, teorinin etkin bir şekilde işlemesi için inhibisyonun da dikkate alınması gerektiğini ortaya koymuşlardır. Bu bulgular, sinaptik plastisitenin daha kapsamlı anlaşılmasına zemin hazırlamıştır (Koşma, 2018). Hebb'in teoremi, aynı yönde sinyal ileten nöronlar arasındaki bağlantıların güçlenmesi, zıt yönde sinyal ileten nöronlar arasındaki bağlantıların ise zayıflaması gerektiğini öne sürer (Çelik, 2008). Hebb ayrıca, bir nöronun aktif olmaması durumunda, bu nöronla bağlantılı diğer nöronların da aktif olmayacağını belirtmiştir. Buna karşın, aktif bir nöronun bağlı olduğu diğer nöronların da aktif olacağını ifade etmiştir. Bu durum, nöronlar arasındaki bağlantıların karşılıklı aktivite durumlarına göre belirlendiğini göstermektedir (Adıyaman, 2007).

Hopfield Öğrenme Kuralı

Hebb kuralıyla benzer özellikler taşıyan Hopfield kuralına göre, hem giriş hem de çıkış pasif ya da her ikisi de aktif olduğunda, bağlantı ağırlıkları öğrenme oranına göre artar. Aksi durumda ise bu ağırlıklar öğrenme oranına göre azalır. Hopfield kuralı, yapay sinir ağı elemanları arasındaki bağlantıların güçlendirilmesini veya zayıflatılmasını yönlendirir. Bu kural, ağıdaki hızlanmalar arasındaki iletişimi düzenleyerek bellek ve

öğrenmeyi en üst düzeye çıkarır. Bağlantı ağırlıklarında yapılacak değişikliğin büyüklüğünü belirlemesi, Hebb kuralından farklı olarak görülebilir. Ağırlıkların artırılması veya azaltılması, öğrenme oranına bağlı olarak gerçekleşir. Öğrenme katsayısı genellikle 0 ile 1 arasında bir değere sahip olup, sabit bir pozitif değer olarak kullanıcı tarafından belirlenir (Öztemel, 2006). Şekil 3.14’de Hopfield ağı örneği görülmektedir.



Şekil 3.14. Hopfield ağı örneği (Deveci, 2012)

Hopfield ağları, bu öğrenme kuralı sayesinde desen tanıma, hafıza geri çağırma ve optimizasyon problemleri gibi alanlarda etkili bir şekilde kullanılabilir.

Delta Öğrenme Kuralı

Delta Öğrenme Kuralı, YSA içinde, ağı çıktılarının istenen çıktılarla karşılaştırılarak hata hesaplamasını ve ağı güncellemeyi sağlayan bir öğrenme kuralıdır. Bu kural, ağı her bir bağlantısının ağırlığını güncellerken, ağı performansını iyileştirmek için hata azaltma stratejilerini kullanır. YSA'nın çıktıları ile gerçek çıktılar arasındaki farklar, ağı içindeki her bir bağlantının güncellenmesinde kullanılır. Delta Öğrenme Kuralı, gerçek çıktılarla ağı tahmin ettiği çıktılar arasındaki farkı hesaplayarak, bu farkı minimize etmeye çalışır. Bu sayede, YSA istenen çıktıları daha doğru bir şekilde tahmin etme yeteneğini geliştirir ve adaptif bir şekilde öğrenir (Widrow & Hoff, 1960).

Kohonen Öğrenme Kuralı

1982 yılında Teuvo Kohonen tarafından geliştirilen bu kural, biyolojik sistemlerdeki öğrenme süreçlerinden esinlenmiştir. Kohonen kuralına göre, ağı elemanları

ağırlıklarını değiştirmek için birbirleriyle rekabet eder ve benzer özelliklere sahip giriş verilerini tanıyarak öğrenme sürecini gerçekleştirir. En yüksek çıktıyı üreten hücre kazanan olarak belirlenir. Kohonen kuralı, hedef bir çıkışa ihtiyaç duymadığı için danışmansız (denetimsiz) öğrenme yöntemi olarak sınıflandırılır (Ömrüuzun, 2019).

Boltzmann Öğrenme Kuralı

Boltzmann öğrenme kuralı, YSA’ında enerji fonksiyonları ve olasılık dağılımlarına dayanır. Bu kural, ağırlık enerji seviyelerini minimize ederek optimize olmasını sağlar. Boltzmann makineleri olarak da bilinen bu sistem, stokastik denetimli öğrenme algoritması olarak işlev görür. Öğrenme sürecinde, nöronlar açık (+1) veya kapalı (-1) durumlarını alır ve olasılık dağılımları arasındaki fark enerji fonksiyonu üzerinden hesaplanır. Bu yaklaşım, ağırlık hedefe ulaşmasını ve kararlarını optimize etmesine olanak tanır (Çakır, 2018).

Öğrenme Algoritmaları

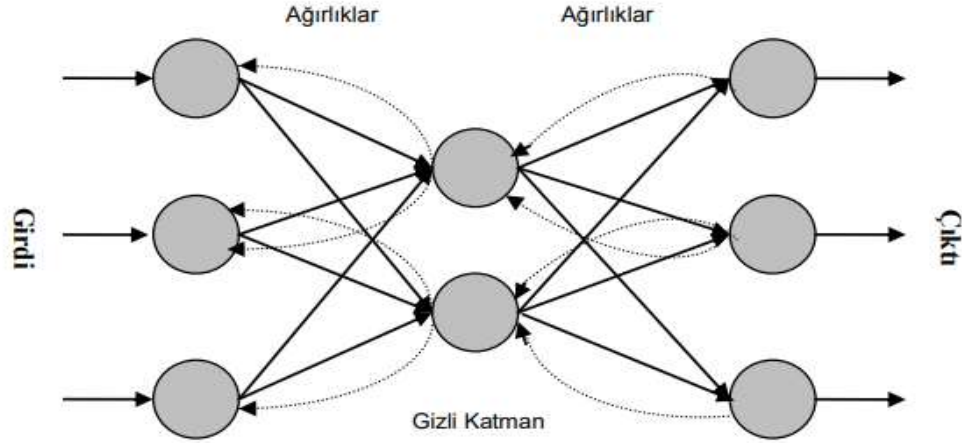
YSA’nda öğrenme süreci, adım adım ağırlıkların en uygun değerlerine ulaşmayı amaçlayan öğrenme algoritmaları ile gerçekleştirilir. Bu algoritmalar, önceden belirlenmiş bir kriter doğrultusunda çalışarak ağırlık performansını optimize eder (Fermancı, 2021). Burada YSA için temel olan Geri Yayılım ve Levenberg-Marquardt algoritmalarını inceleyeceğiz.

Geri Yayılım Öğrenme Algoritması

Tek katmanlı sinir ağları, sınırlı görevleri başarabilen pek çok kısıtlama ile karşı karşıyadır. Minsky ve Papert, iki katmanlı ileri beslemeli ağların bu kısıtlamaların çoğunu aşabildiğini göstermiş, ancak gizli katmanların ağırlıklarının nasıl ayarlanacağı sorununa çözüm bulamamışlardır. 1986 yılında Rumelhart, Hinton ve Williams, bu sorunun cevabını sunarak hata geri yayılım yöntemi ile gizli katman ve çıkış katmanı hatalarını tespit etme fikrini ortaya koymuşlardır. Bu yöntem, ağırlık bağlantı ağırlıklarını, gerçek ve istenen çıkış vektörleri arasındaki farkı minimize edecek şekilde ayarlar. Bu süreç, geri yayımlı öğrenme kuralı olarak adlandırılır (Rumelhart vd.,1986).

1970’lerde geliştirilmiş, bir girdi katmanı ve en az bir gizli katmandan oluşan tipik geri yayılım ağı, karmaşık ve doğrusal olmayan problemlere çözümler sunabilen popüler bir ağ türüdür (Elmas, 2003).

Bu algoritma, hatayı çıkıştan girişe doğru azaltmayı hedeflediği için geri yayılım algoritması adını almıştır. Ağın çıkışındaki hataya bağlı olarak, şekil 3.15’de de görüldüğü gibi her bir katmandaki ağırlıklar çıkış katmanından giriş katmanına doğru yeniden hesaplanır (Çetin, 2014).



Şekil 3.15. Geri bildirim ağı (Deveci, 2012).

Levenberg-Marquardt Algoritması

Levenberg–Marquardt (LM) algoritması, Kenneth Levenberg ve Donald Marquardt tarafından oluşturulmuştur. Bu algoritma, hızlı ve kararlı yakınsama özellikleriyle öne çıkar. Gauss-Newton ve Steepest-Descent (geri yayılım) algoritmalarının en iyi yanlarını birleştirerek, her iki metodun sınırlamalarını aşar. Gauss-Newton algoritmasının hız avantajını ve Steepest-Descent yönteminin kararlılığını bünyesinde barındıran LM algoritması, entegre bir eğitim süreci sunar. Bu nedenle, en iyi eğitim algoritmalarından biri olduğu düşünülmektedir (Can, 2014).

LM algoritması, türev tabanlı bir yöntemdir ve türev tabanlı yöntemlerde genellikle karşılaşılan ana sorun, çözümün optimum sonuca ulaşmasının başlangıç parametre tahminlerine bağlı olmasıdır. Model verilerine uygulanan ön kestirim değerleri gerçeğe yakın olsa bile, lokal minimuma yaklaşma olasılığı global minimuma yaklaşma olasılığından daha yüksektir ve bu durum çözümlerde ırsamaya neden olabilir. Bu sorunu çözmek için araştırmacılar, küresel minimumu daha etkili bir şekilde arayabilen ve çeşitli çözümler üretebilen optimizasyon yöntemlerini geliştirmiştir (Akkaş, 2020).

LM algoritması diğer algoritmalara alternatif olarak geliştirilmiş ve son yıllarda çok kullanılan bir yöntemdir. Bu algoritma hızlı ve yüksek performanslı olup ikiye ayrılmaktadır (Doğan, 2010). Bu algoritmalar:

1. Deneme yanılma tekniklerini kullanan,
2. Standart sayısal optimizasyon yöntemlerini kullanan,

şeklinde belirtilir.

Ağırlıkların güncellenmesi sürecinin ilk adımı, Hessian matrisinin elde edilmesidir. Hessian matrisi, performansın ağırlıklara göre ikinci dereceden türevleri alınarak oluşturulur.

$$h = \begin{bmatrix} \frac{\partial^2 P(m)}{\partial w_1^2} & \frac{\partial^2 P(m)}{\partial w_1 w_2} & \dots & \frac{\partial^2 P(m)}{\partial w_1 w_n} \\ \frac{\partial^2 P(m)}{\partial w_2 w_1} & \frac{\partial^2 P(m)}{\partial w_2^2} & \dots & \frac{\partial^2 P(m)}{\partial w_2 w_n} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial^2 P(m)}{\partial w_n w_1} & \frac{\partial^2 P(m)}{\partial w_n w_2} & \dots & \frac{\partial^2 P(m)}{\partial w_n^2} \end{bmatrix}$$

h= Hessian matrisi

p= Performans fonksiyonu

w= Ağın sinaptik ağırlığı

$$h(m) = \frac{\partial^2 P(m)}{\partial w^2 P(m-1)} \quad (3.5)$$

YSA için Hessian matrisinin hesaplanması zor ve karmaşık olduğundan, LM algoritması Gauss-Newton matrisinin yaklaşık değerini kullanır. Bu algoritmada, Hessian matrisinin yaklaşık değeri belirli bir eşitlikle hesaplanır (Kaftan, 2010).

$$h(m) \approx J^T(m) J(m) + \mu I \quad (3.6)$$

$J(m)$ = Jakobiyen matrisi

$J^T(m)$ = Jakobiyen matrisin tersi

I = Birim matrisi

m = Adım sayısı

μ = Marquardt parametresi

Jacobian matrisi, Hessian matrisine göre daha kolay hesaplandığı için tercih edilmektedir. Ağ hataları, ağırlıklara göre birinci dereceden türevleri içerir ve Jacobian matrisi bu türevleri kapsar.

$$h = \begin{bmatrix} \frac{\partial e_1}{\partial w_1} & \frac{\partial e_1}{\partial w_2} & \dots & \frac{\partial e_1}{\partial w_n} \\ \frac{\partial e_2}{\partial w_1} & \frac{\partial e_2}{\partial w_2} & \dots & \frac{\partial e_2}{\partial w_n} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial e_i}{\partial w_1} & \frac{\partial e_i}{\partial w_2} & \dots & \frac{\partial e_i}{\partial w_n} \end{bmatrix}$$

Ağın gradyanı,

$$G(m) = J^T(m) E(M) \quad (3.7)$$

ile elde edilir.

LM algoritması için ağırlık değişim bağıntısı;

$$a(m+1) = a(m) - [J^T(m)J(m) + \mu I]^{-1} J^T(m) E(M) \quad (3.8)$$

Bu yöntemin;

- 1.Kural: μ sıfır çıkması halinde Hessian matrisini kullanan Newton algoritması,
- 2.Kural: μ büyük bir değer ise küçük adımlı gradyan azalması haline dönüşür (Deveci, 2012).

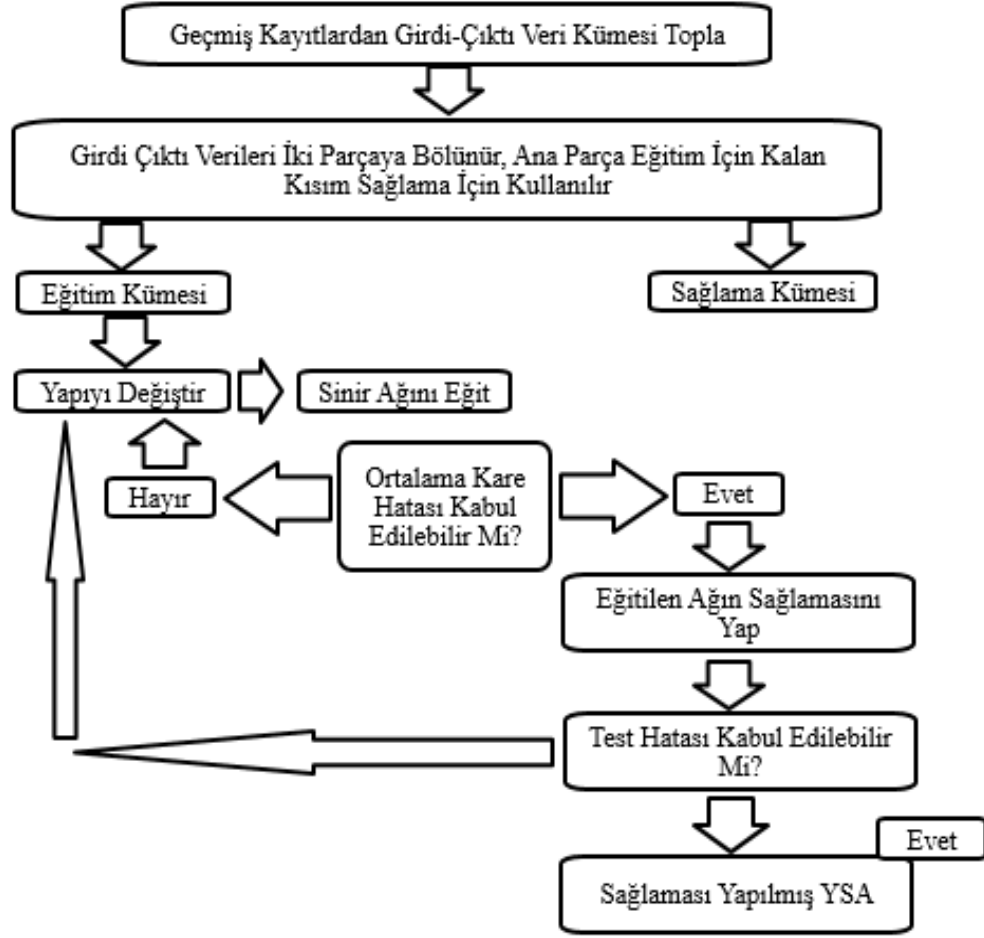
3.7. Yapay Sinir Ağlarının Öğrenme Süreci

Ağların öğrenme süreci, YSA'nda bulunan elemanların bağlantı ağırlıklarının belirlenmesi sürecini ifade eder. YSA'nın temel amacı, en az hata ile en iyi ağırlıkları bulmaktır. Belirli bir uygulama için tasarlanan bir sinir ağı, kullanılmadan önce eğitilmelidir; bu süreç öğrenme açısından kritik bir öneme sahiptir. YSA, başlangıçta rastgele seçilen ağırlıklarla eğitime başlar ve öğrenme süreci boyunca bu ağırlıklar güncellenir. Eğitim süreci, ağın hata fonksiyonunu minimize ederek en uygun ağırlıklara ulaşmasını sağlar. Bu, ağın genelleme yeteneği kazanarak yeni verilere doğru yanıt verebilme kapasitesine ulaştığını gösterir. Rastgele başlangıç ağırlıkları, nöronların farklı öğrenme yollarını takip etmesine ve modelin genelleme olmasına katkıda bulunur (Yılmaz, 2012). YSA'nın eğitimi, ağın giriş örneğine dayalı çıkışının

hesaplanması; ardından, bu çıkışın doğruluğuna göre bağlantı ağırlıklarının güncellenmesi aşamalarından oluşmaktadır (Öztemel, 2006).

YSA'nın öğrenme süreci şu adımlarla gerçekleşir (Ömrüuzun, 2019):

1. Sistem için gerekli olan girdi parametreleri tanımlanır; bu parametreler, operasyonel özellikleri kapsayacak şekilde seçilmelidir.
2. Sistem performansını güvenilirlik, dayanıklılık ve kullanılabilirlik gibi faktörler açısından değerlendirebilecek çıktı parametreleri belirlenir.
3. Bu çıktı parametreleri, basit bir ölçüm mekanizması ile entegre edilir.
4. Girdi ve çıktı çiftlerinden oluşan kapsamlı bir eğitim ve test veri seti hazırlanır.
5. Gizli katman sayısı ve her katmandaki nöron sayısı doğru şekilde belirlenmelidir. Genellikle bu süreç, başlangıçta belirli bir sayıyla başlanarak deneme-yanılma yöntemiyle yürütülür ve elde edilen sonuçlara göre gerekli ayarlamalar yapılır.
6. Eğitimden geçen yapay sinir ağı modeli, farklı durumlar karşısında nasıl davrandığını test etmek amacıyla simülasyona tabi tutulur.
7. İstenen sonuçlar elde edilene kadar bu adımlar tekrarlanır; sonuçlar tatmin edici değilse süreç yeniden gözden geçirilir ve gerekli düzenlemeler yapılır.



Şekil 3.16. İleri beslemeli bir sinir ağının eğitim ve test aşamaları (Ömrüuzun, 2019).

YSA'nın eğitim sürecinde gerçekleşen işlemleri ve eğitimi tamamlanan ağı uygun hata düzeyinin test edilmesi Şekil 3.16'da gösterilmektedir. Öğrenme süresinin uzun olması, bu süreçte karşımıza çıkan en büyük problemdir. Ağı yerel sonuçlara takılmasına ve bir yerel sonuçtan diğerine sıçramasına en büyük etken, başlangıç ağırlıklarının yüksek olmasıdır. İşlemci elemanların ağırlıkları büyük seçilmelidir; aksi halde doğru ağırlıkları bulmak daha uzun sürebilir. Bir problemin çözümü için iki yüz iterasyon yeterli olabilirken, başka bir problemin çözümü beş ila on milyon iterasyon gerektirebilir. Bu nedenle, başlangıç koşullarının rastgele belirlenmesi ve doğru başlangıç koşullarının deneyerek bulunması önemlidir (Öztemel, 2006).

4. UYGULAMA

4.1. Materyal ve Metot

Çalışma kapsamında, BTC ve ETH gibi önemli kripto para birimlerinin günlük değerlerini içeren veri setleri, <https://tr.investing.com/> platformundan toplanmıştır. Bu veriler, dolar cinsinden ifade edilmiş olup, 01 Nisan 2016 ile 01 Mart 2024 tarihleri arasındaki günlük dönemi kapsayacak şekilde derlenmiştir. Çizelge 4.1.'e göre ortalaması 18.015,25; ortanca değeri 10.260,45; maksimum değeri 67.527,90; minimum değeri 415,6 ve standart sapması 16.675,57 olan 2892 günlük BTC veri noktası ve ortalaması 1.033,31; ortanca değeri 431,84; maksimum değeri 4.808,38; minimum değeri 6,70 ve standart sapması 1.111,70 olan 2892 günlük ETH veri noktası analiz için kullanılmıştır. Yapılan istatistiksel analizlerin anlamlılık düzeyi 0,01 olarak belirlenmiştir. Analizlerde MATLAB ve Eviews gibi yaygın olarak kullanılan programlar tercih edilmiştir.

Çizelge 4.1. 2016-2024 yılları BTC ve ETH verileri betimleyici istatistikleri.

BTC/USD		ETH/USD	
Ortalama	18.015,25	Ortalama	1.033,31
Ortanca Değer	10.260,45	Ortanca Değer	431,84
Maksimum Değer	67.527,90	Maksimum Değer	4.808,38
Minumum Değer	415,60	Minimum Değer	6,70
Standart Sapma	16.675,57	Standart Sapma	1.111,70
Veri Sayısı	2.892	Veri Sayısı	2.892

Literatürde, zaman serisi tahmininde kullanılan pek çok yöntem bulunmaktadır. Bu çalışmada ise ARIMA ve YSA yöntemleri tercih edilmiştir. Seçilen kripto paralar için en uygun ARIMA modelini belirlemek amacıyla Akaike ve Schwarz bilgi kriterleri kullanılmıştır. YSA'da ise en iyi modeli bulmak için LM algoritması uygulanmıştır.

Uygun ARIMA ve YSA modelleri belirlendikten sonra, bu modellerin karşılaştırılmasında HKO kriteri kullanılmıştır. Bu yöntemlerin kullanımı, kripto para birimi piyasalarının karmaşıklığını ve belirsizliğini daha iyi anlamak ve gelecekteki değer değişimlerini tahmin etmek için önemli bir adımdır.

4.2. Bulgular

Bu bölümde, ARIMA ve YSA modelleriyle yapılan öngörü analizi sonuçlarına odaklanılmıştır. İlk olarak, BTC ve ETH verileri için ARIMA modeli kullanılarak yapılan analiz ile elde edilen sonuçlar ve bu sonuçlara ilişkin yorumlar sunulmaktadır.

4.2.1. ARIMA Modeli İçin Analiz Sonuçları

Bitcoin İçin ARIMA Model Sonuçları

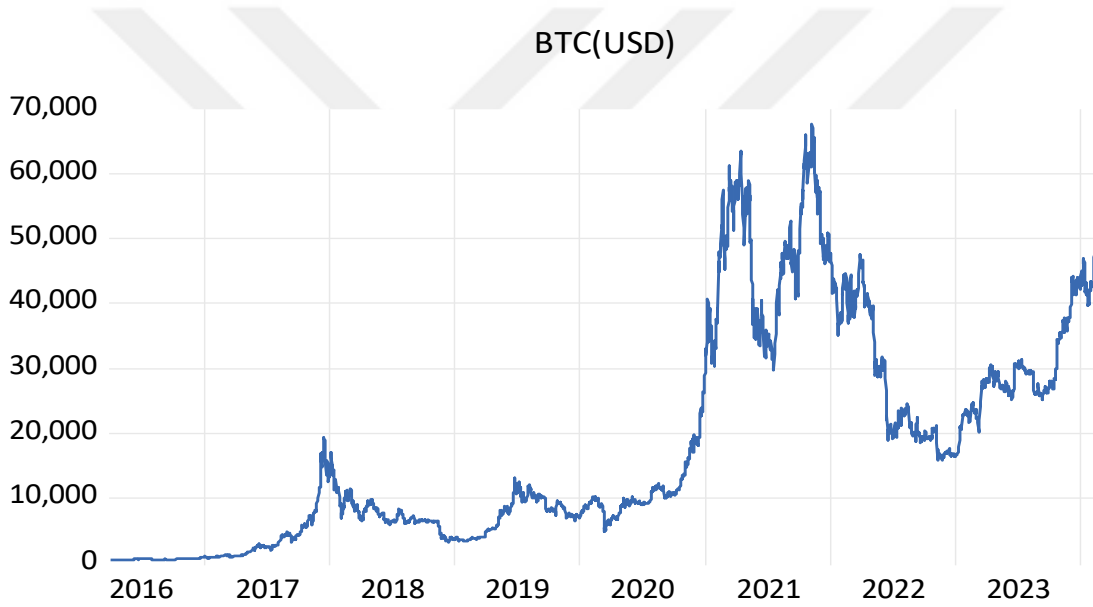
Sample: 4/01/2016 3/01/2024

Included observations: 2892

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
		1	0.997	0.997	2878.9	0.000
		2	0.995	0.024	5743.5	0.000
		3	0.992	-0.023	8593.2	0.000
		4	0.989	0.039	11429.	0.000
		5	0.987	0.010	14252.	0.000
		6	0.984	0.020	17062.	0.000
		7	0.982	-0.007	19860.	0.000
		8	0.980	0.026	22645.	0.000
		9	0.978	0.010	25419.	0.000
		10	0.975	-0.040	28180.	0.000
		11	0.973	-0.015	30928.	0.000
		12	0.970	0.006	33663.	0.000
		13	0.968	0.018	36386.	0.000
		14	0.965	-0.014	39096.	0.000
		15	0.963	-0.006	41793.	0.000
		16	0.960	0.008	44477.	0.000
		17	0.958	0.005	47149.	0.000
		18	0.956	0.008	49810.	0.000
		19	0.953	-0.003	52458.	0.000
		20	0.951	0.029	55096.	0.000
		21	0.949	-0.020	57722.	0.000
		22	0.947	0.013	60336.	0.000
		23	0.945	0.018	62940.	0.000
		24	0.943	0.027	65534.	0.000
		25	0.941	-0.013	68118.	0.000
		26	0.939	-0.002	70692.	0.000
		27	0.937	-0.004	73255.	0.000
		28	0.935	-0.027	75807.	0.000
		29	0.932	-0.029	78347.	0.000
		30	0.930	0.027	80876.	0.000
		31	0.928	-0.009	83394.	0.000
		32	0.925	-0.037	85899.	0.000
		33	0.923	0.022	88393.	0.000
		34	0.921	-0.031	90875.	0.000
		35	0.918	-0.010	93344.	0.000
		36	0.916	-0.001	95801.	0.000

Şekil 4.1. Günlük BTC verisine ait korelogram.

Şekil 4.1. incelendiğinde, günlük BTC verilerinde otokorelasyonun (Autocorrelation) hızlı bir şekilde değil, yavaş yavaş azaldığı ve değerlerin belirli bir eşik değeri dışında yoğunlaştığı, ayrıca olasılık (Prob) değerlerinin hepsinin 0,01'den küçük olduğu için otokorelasyonların olduğu görülmektedir. Bu durum, serinin durağan olmadığını işaret etmektedir. Bu otokorelasyon analizinin daha net anlaşılabilmesi ve serinin yapısal özelliklerinin görsel olarak da incelenebilmesi amacıyla, serinin zaman serisi grafiğinin çizilmesi gereklidir. Zaman serisi grafiği, serinin zaman içindeki davranışını ve olası trend, mevsimsellik veya diğer dinamikleri daha açık bir şekilde ortaya koyacaktır. Bu grafik sayesinde, serinin durağan olup olmadığı, trend içerip içermediği veya mevsimsel dalgalanmalara sahip olup olmadığı gibi önemli özellikler daha kolay belirlenebilir.



Şekil 4.2. Günlük BTC verisine ait zaman serisi grafiği.

Şekil 4.2'de gösterilen grafik, günlük BTC verilerinin belirgin bir yükselen trende sahip olduğunu göstermektedir. Bu eğilim, zaman içinde verinin sürekli olarak yukarı yönlü hareket ettiğini göstermektedir. Ayrıca, grafikte belirli bir ortalamaya doğru düşme veya yükselme eğilimi olmadığı gözlemlenmektedir. Bu durum, verinin istikrarlı olmadığını işaret etmekte olup, zaman serisinin istatistiksel özelliklerinin sabit kalmadığını ortaya koymaktadır. Dolayısıyla, gelecekteki tahminlerin doğruluğunu artırmak için zaman serisinin durağan hale getirilmesi gerekmektedir. Serinin durağanlığını belirlemek için Augmented (Genişletilmiş) Dickey-Fuller (ADF) testi kullanılmıştır. Bu test, bir zaman serisinin durağanlık özelliklerini tespit etmek için yaygın olarak kullanılan bir istatistiksel testtir.

Çizelge 4.2. Günlük BTC verisine ait ADF test istatistik sonucu.

		t-istatistik	p-değeri
ADF Test İstatistiği		-0.345	0.9157
Test(t)-Kritik Değer	1%	-3.432	
	5%	-2.862	
	10%	-2.567	

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

$H_1: \delta < 0$ Seri durağandır.

Çizelge 4.2'ye göre elde edilen p değeri 0,9157'dir; ki bu değer 0,01'den büyüktür. Bu sonuçla hipotezimiz reddedilemez ve günlük BTC serisinin istatistiksel olarak %99 güvenilirlikle durağan olmadığı ve birim kök içerdiği sonucuna varılır. Bu durum, zaman serisinin sabit bir ortalama etrafında değişmediğini ve dolayısıyla durağan olmadığını işaret etmektedir. Serinin durağan hale getirilmesi için bir fark işlemi uygulanmalıdır. Bu, serideki durağanlık özelliklerini artırmaya ve istatistiksel analiz için uygun bir zemin oluşturmaya yardımcı olacaktır.

Çizelge 4.3. Birinci dereceden farkı alınmış günlük BTC verisinin ADF test istatistik sonucu.

		t-istatistik	p-değeri
ADF Test İstatistiği		-55.224	0.0001
Test(t)-Kritik Değer	1%	-3.432	
	5%	-2.862	
	10%	-2.567	

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

$H_1: \delta < 0$ Seri durağandır.

Çizelge 4.3'e göre elde edilen p değeri 0,0001'dir; ki bu değer 0,01'den küçüktür. Bu sonuçla hipotezimiz reddedilir ve serinin istatistiksel olarak %99 güvenilirlikle durağan hale geldiği sonucuna varılır. Bu durum, zaman serisinin istikrarlı bir yapıya sahip olduğunu ve birim kök içermediğini işaret etmektedir. Dolayısıyla, fark alma işlemi sonlandırılarak veri seti durağan hale getirilmiştir. Bu, gelecekteki analizlerde daha güvenilir sonuçlar elde etmek için önemlidir.

Sample (adjusted): 4/02/2016 3/01/2024
 Included observations: 2891 after adjustments


Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
		1	-0.028	-0.028	2.1949	0.138
		2	0.018	0.018	3.1794	0.204
		3	0.025	0.026	5.0200	0.170
		4	0.032	0.034	8.0592	0.089
		5	0.010	0.011	8.3479	0.138
		6	0.019	0.018	9.4396	0.150
		7	-0.039	-0.040	13.904	0.053
		8	-0.028	-0.033	16.207	0.040
		9	0.066	0.064	28.805	0.001
		10	0.019	0.025	29.896	0.001
		11	-0.001	0.001	29.900	0.002
		12	-0.047	-0.050	36.371	0.000
		13	0.031	0.025	39.209	0.000
		14	-0.006	-0.005	39.301	0.000
		15	-0.010	-0.014	39.569	0.001
		16	-0.015	-0.010	40.195	0.001
		17	0.020	0.026	41.386	0.001
		18	0.001	0.002	41.388	0.001
		19	-0.023	-0.031	42.982	0.001
		20	0.052	0.050	50.859	0.000
		21	-0.025	-0.015	52.686	0.000
		22	0.009	0.004	52.903	0.000
		23	-0.036	-0.040	56.699	0.000
		24	0.056	0.055	65.912	0.000
		25	0.004	0.016	65.959	0.000
		26	0.019	0.011	66.987	0.000
		27	0.042	0.044	72.255	0.000
		28	0.048	0.052	79.003	0.000
		29	-0.054	-0.060	87.622	0.000
		30	0.028	0.013	89.971	0.000
		31	0.053	0.053	98.175	0.000
		32	-0.063	-0.049	109.64	0.000
		33	0.092	0.080	134.35	0.000
		34	0.008	0.012	134.53	0.000
		35	0.006	0.006	134.64	0.000
		36	-0.045	-0.050	140.45	0.000

Şekil 4.3. Fark alınmış günlük BTC verisine ait korelogram.

Durağanlık sağlandıktan sonra, serinin Şekil 4.3'deki korelogramı detaylı bir şekilde incelenir ve en iyi model seçilir. Bu aşamada kısmi otokorelasyon (PAC) ve otokorelasyon (AC) değerleri göz önünde bulundurularak model seçilmelidir. PAC, otoregresif (AR) bileşenleri doğru bir şekilde belirlemede yardımcı olurken, otokorelasyon hareketli ortalama (MA) bileşenlerini belirlemede yardımcı olur. Bu iki analiz türü, modelin doğruluğunu artırmak ve serinin gelecekteki davranışlarını daha doğru tahmin edebilmek için çok önemlidir. Bu işlem, doğru tahminler yapmak için modelin tüm dinamiklerini ve yapısal özelliklerini dikkatlice göz önünde bulundurarak yürütülmelidir.

Çizelge 4.4. Günlük Bitcoin serisine ait ARIMA modeli.

Değişken	Katsayı	Std. Hata	t-istatistik	p-değeri
C	22.959	22.972	0.999	0.318
AR(1)	-0.260	0.026	-9.950	0.000
AR(2)	-0.607	0.027	-22.898	0.000
AR(3)	0.015	0.039	0.387	0.699
AR(4)	0.327	0.036	9.172	0.000
AR(5)	-0.397	0.027	-14.623	0.000
AR(6)	-0.132	0.037	-3.544	0.000
AR(7)	0.509	0.037	13.798	0.000
AR(8)	0.184	0.024	7.548	0.000
AR(9)	0.921	0.020	45.874	0.000
AR(10)	0.037	0.012	3.138	0.002
MA(1)	0.243	0.051	4.805	0.000
MA(2)	0.631	0.040	15.756	0.000
MA(3)	0.000	0.060	0.004	0.997
MA(4)	-0.297	0.045	-6.650	0.000
MA(5)	0.416	0.035	11.873	0.000
MA(6)	0.162	0.062	2.596	0.0095
MA(7)	-0.527	0.061	-8.657	0.000
MA(8)	-0.154	0.046	-3.352	0.001
MA(9)	-0.935	0.037	-25.466	0.000
AIC(Akaike Info Criterion)	16.355			
SIC(Schwarz Criterion)	16.398			



Şekil 4.4. Akaike bilgi kriterine göre en iyi 20 model.

Olası modeller arasından en uygun model seçilirken, modeldeki katsayıların anlamlılığı, Akaike Bilgi Kriteri (AIC) ve Schwarz Bilgi Kriteri (SIC) gibi bilgi kriterleri dikkate alınır. Bu kriterlere göre, günlük BTC verileri için en uygun model ARIMA (10,1,9) olarak belirlenmiştir. Bu model, en fazla anlamlı katsayılara sahiptir; aynı zamanda AIC (16,355) ve SIC (16,398) değerleri en düşük olan modeldir. Modelin özellikleri Çizelge 4.3'te sunulmuştur.

Etherum İçin ARIMA Model Sonuçları

Sample: 4/01/2016 3/01/2024

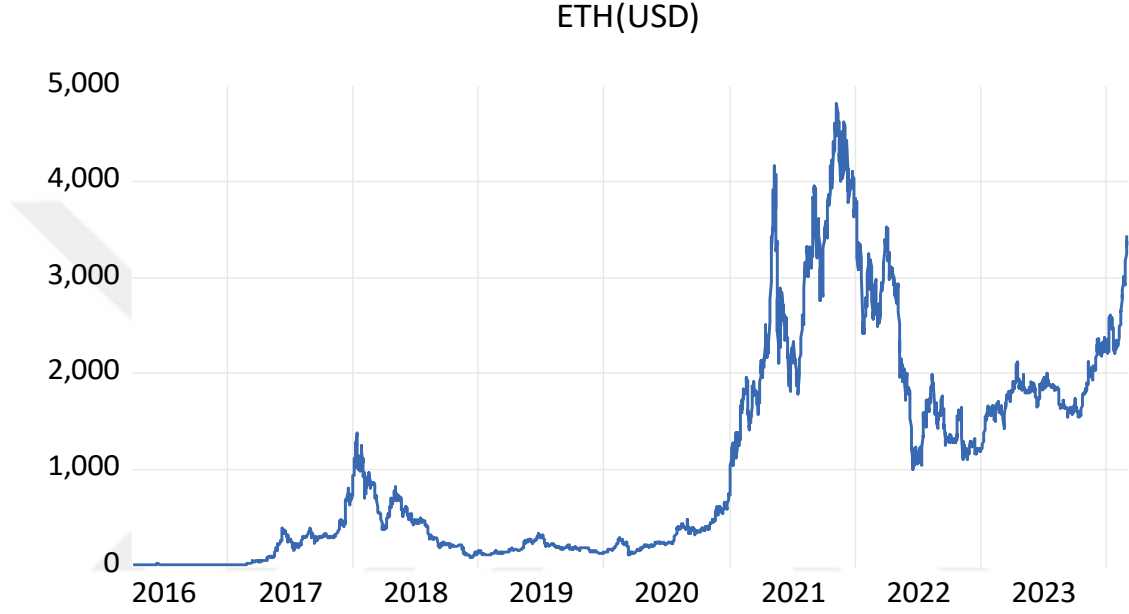
Included observations: 2892

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
		1	0.997	0.997	2878.9	0.000
		2	0.995	0.062	5744.8	0.000
		3	0.992	-0.019	8596.9	0.000
		4	0.990	-0.002	11435.	0.000
		5	0.987	-0.014	14260.	0.000
		6	0.985	0.044	17072.	0.000
		7	0.982	-0.052	19870.	0.000
		8	0.980	0.019	22655.	0.000
		9	0.977	0.018	25426.	0.000
		10	0.975	-0.003	28185.	0.000
		11	0.972	-0.022	30930.	0.000
		12	0.970	0.014	33663.	0.000
		13	0.967	0.044	36383.	0.000
		14	0.965	-0.018	39092.	0.000
		15	0.963	0.019	41789.	0.000
		16	0.961	-0.004	44474.	0.000
		17	0.959	0.045	47149.	0.000
		18	0.956	-0.022	49813.	0.000
		19	0.954	0.010	52467.	0.000
		20	0.953	0.032	55111.	0.000
		21	0.951	0.002	57746.	0.000
		22	0.949	-0.014	60371.	0.000
		23	0.947	-0.001	62986.	0.000
		24	0.945	0.000	65591.	0.000
		25	0.943	0.004	68187.	0.000
		26	0.941	-0.004	70772.	0.000
		27	0.939	-0.000	73348.	0.000
		28	0.937	-0.033	75914.	0.000
		29	0.935	-0.040	78467.	0.000
		30	0.932	0.027	81010.	0.000
		31	0.930	-0.017	83541.	0.000
		32	0.928	-0.035	86059.	0.000
		33	0.925	0.031	88566.	0.000
		34	0.923	-0.038	91061.	0.000
		35	0.921	0.004	93543.	0.000
		36	0.918	-0.020	96013.	0.000

Şekil 4.5. Günlük ETH verisine ait korelogram.

Günlük ETH verilerinin analizinde ACF incelenmesi, serinin otokorelasyonlarının hızla değil, kademeli olarak azaldığını ortaya koymaktadır. Bu durum, otokorelasyon

katsayılarının belirli bir eşik değerinin ötesinde yoğunlaştığını ve bu nedenle serinin özgün bir yapıya sahip olduğunu göstermektedir. Tüm prob değerlerinin 0,01'den küçük olması, otokorelasyonların istatistiksel olarak anlamlı olduğunu ve rastgele bir dağılım yerine belirli bir düzenin varlığını işaret etmektedir. Bu bulgular, serinin durağan olmadığını ve zamanla değişen bir yapıya sahip olduğunu güçlü bir şekilde göstermektedir. Ancak, bu durumun daha net anlaşılabilmesi için serinin zaman serisi grafiği çizdirilmelidir.



Şekil 4.6. Günlük ETH verisine ait zaman serisi grafiği.

Şekil 4.6 incelendiğinde, günlük ETH verilerinin belirgin bir artış trendi gösterdiği görülmektedir. Bu eğilim, verinin zamanla yukarı yönlü bir hareket sergilediğini ortaya koymaktadır. Ayrıca, grafikte verilerin belirli bir ortalamaya yakınsama eğilimi göstermediği de gözlemlenmiştir. Bu durum, verinin durağan olmadığını, yani zaman serisinin istatistiksel özelliklerinin zamanla sabit kalmadığını işaret etmektedir. Bu nedenle, gelecekteki tahminlerin doğruluğunu artırmak amacıyla serinin durağan hale getirilmesi gerektiği ortaya çıkmaktadır. Zaman serisinin durağan olup olmadığını tespit etmek için ADF test istatistiğini kullanacağız.

Çizelge 4.5. Günlük ETH verisine ait ADF test istatistik sonucu.

		t-istatistik	p-değeri
ADF Test İstatistiği		-1,122	0,709
Test(t)-Kritik Değer	1%	-3.432	
	5%	-2.862	
	10%	-2.567	

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

$H_1: \delta < 0$ *Seri durağandır.*

Çizelge 4.4'e göre elde edilen p değeri 0,709'dur ve bu değer 0,01'den büyüktür. Bu sonuçla hipotezimiz reddedilemez ve günlük ETH serisinin istatistiksel olarak %99 güvenilirlikle durağan olmadığı ve birim kök içerdiği sonucuna varılır. Bu durum, zaman serisinin durağan olmadığını işaret etmektedir. Seriyi durağan hale getirmenin ilk adımı fark işlemidir.

Çizelge 4.6. Birinci dereceden farkı alınmış günlük ETH verisinin ADF test istatistik sonucu.

		t-istatistik	p-değeri
ADF Test İstatistiği		-20.114	0.000
Test(t)-Kritik Değer	1%	-3.432	
	5%	-2.862	
	10%	-2.567	

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

$H_1: \delta < 0$ *Seri durağandır.*

Çizelge 4.5'e göre elde edilen p değeri 0,000'dır ve bu değer 0,01'den küçüktür. Bu sonuçla, hipotezimiz reddedilir ve serinin istatistiksel olarak % 99 güvenilirlikle durağan hale geldiği sonucuna varılır. Bu durum, zaman serisinin istikrarlı bir yapıya sahip olduğunu ve birim kök içermediğini işaret etmektedir. Dolayısıyla veri seti durağan hale getirildiği için fark alma işlemi sonlandırılır.

Sample (adjusted): 4/02/2016 3/01/2024

Included observations: 2891 after adjustments


Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
		1 -0.079	-0.079	17.946	0.000
		2 0.024	0.018	19.628	0.000
		3 0.023	0.026	21.158	0.000
		4 0.031	0.035	23.930	0.000
		5 -0.060	-0.056	34.338	0.000
		6 0.108	0.098	68.298	0.000
		7 -0.031	-0.015	71.007	0.000
		8 -0.031	-0.038	73.844	0.000
		9 0.004	-0.002	73.882	0.000
		10 0.027	0.021	75.935	0.000
		11 -0.022	-0.004	77.311	0.000
		12 -0.044	-0.059	82.911	0.000
		13 0.046	0.041	89.096	0.000
		14 -0.041	-0.027	94.028	0.000
		15 0.004	0.001	94.069	0.000
		16 -0.057	-0.064	103.68	0.000
		17 0.064	0.057	115.69	0.000
		18 -0.036	-0.009	119.54	0.000
		19 -0.007	-0.027	119.70	0.000
		20 -0.004	0.000	119.75	0.000
		21 0.026	0.022	121.74	0.000
		22 -0.002	0.022	121.76	0.000
		23 0.011	-0.011	122.13	0.000
		24 0.002	0.005	122.14	0.000
		25 0.014	0.023	122.70	0.000
		26 0.001	0.001	122.70	0.000
		27 0.055	0.047	131.40	0.000
		28 0.050	0.054	138.84	0.000
		29 -0.051	-0.035	146.42	0.000
		30 0.041	0.021	151.45	0.000
		31 0.037	0.039	155.38	0.000
		32 -0.050	-0.045	162.68	0.000
		33 0.072	0.070	177.69	0.000
		34 -0.007	-0.020	177.84	0.000
		35 0.019	0.037	178.91	0.000
		36 -0.001	0.002	178.92	0.000

Şekil 4.7. Fark alınmış günlük ETH verisine ait korelogram.

Seride durağanlık sağlandıktan sonra, durağan serinin Şekil 4.7'deki korelogramı dikkate alınarak olası modeller belirlenir ve bu modeller arasından en uygun model seçilir. Model belirleme sürecinde AC ve PAC birlikte değerlendirilmelidir. Modelin MA bileşenini belirlemek için AC, AR bileşenini belirlemek için ise PAC kullanılır.

Çizelge 4.7. Günlük ETH serisine ait ARIMA modeli.

Değişken	Katsayı	Std. Hata	t-istatistik	p-değeri
C	0.002	0.001	1.472	0.141
AR(1)	-0.289	0.040	-7.229	0.000
AR(2)	0.356	0.046	7.735	0.000
AR(3)	-0.461	0.032	-14.615	0.000
AR(4)	0.233	0.045	5.157	0.000
AR(5)	0.899	0.038	23.480	0.000
MA(1)	0.248	0.042	5.951	0.000
MA(2)	-0.320	0.046	-6.941	0.000
MA(3)	0.500	0.035	14.486	0.000
MA(4)	-0.250	0.051	-4.899	0.000
MA(5)	-0.854	0.041	-20.988	0.000
MA(6)	0.062	0.015	4.216	0.023
MA(7)	-0.041	0.018	-2.279	0.000
AIC(Akaike Info Criterion)		-3,079		
SIC(Schwarz Criterion)		-3.069		



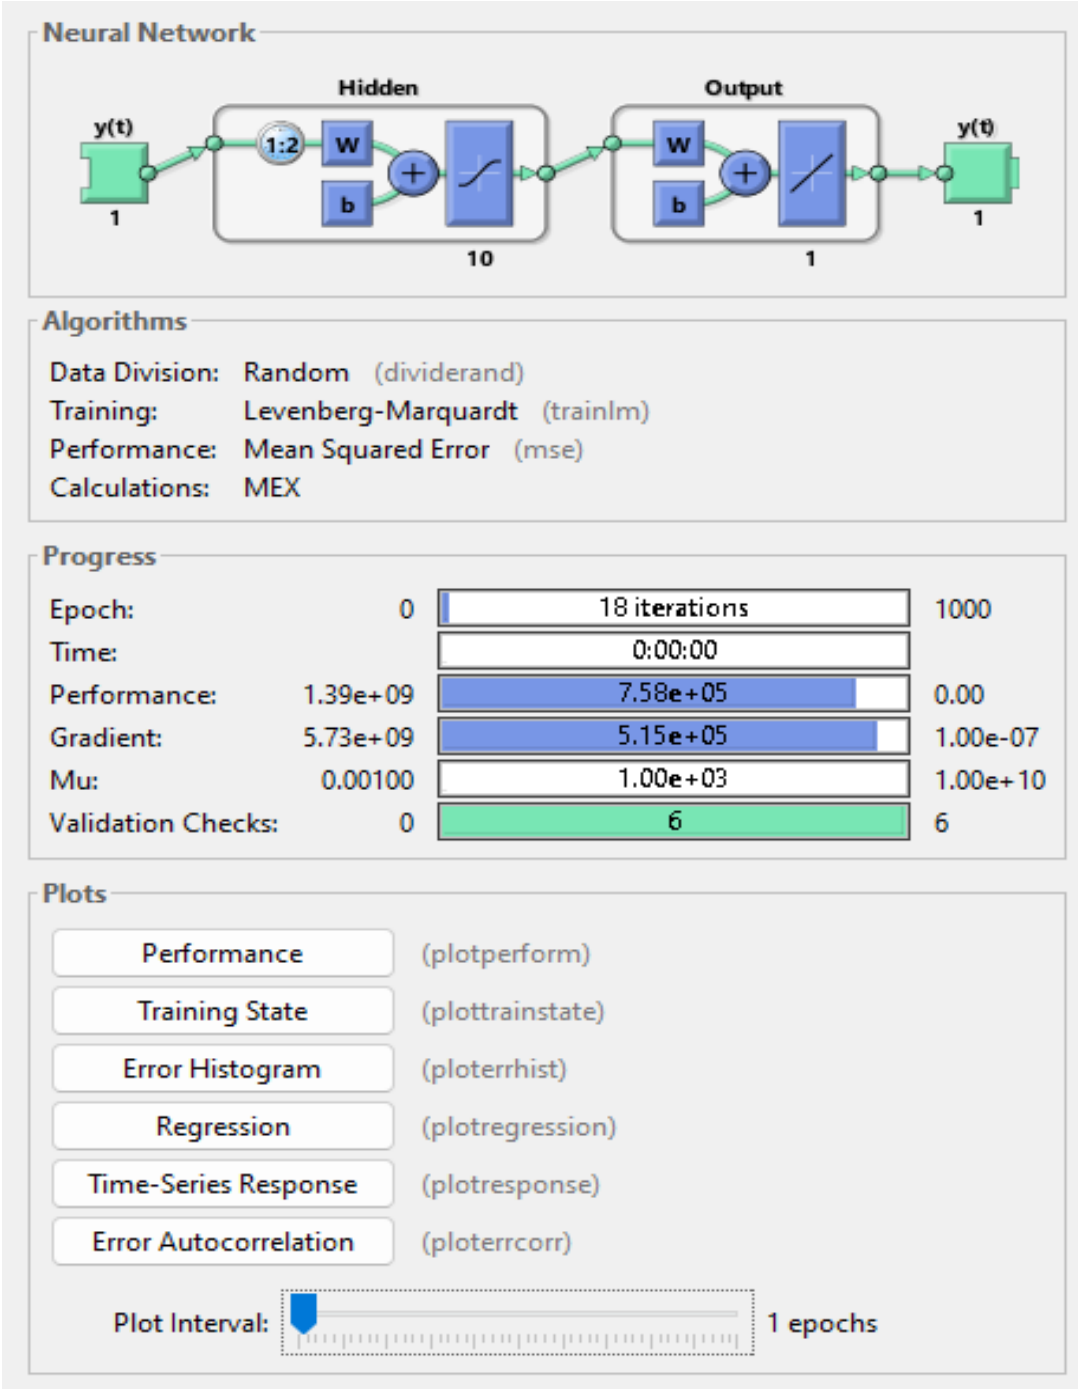
Şekil 4.8. Akaike bilgi kriterine göre en iyi 20 model.

Çizelge 4.6 incelendiğinde, olası modeller arasında en fazla anlamlı katsayıya sahip ve en düşük AIC ile SIC değerlerine sahip olan ARIMA (5,1,7) modelinin en uygun model olduğu belirlenmiştir. Bu kriterler, ARIMA (5,1,7) modelinin en iyi performansı sergilediğini göstermektedir.

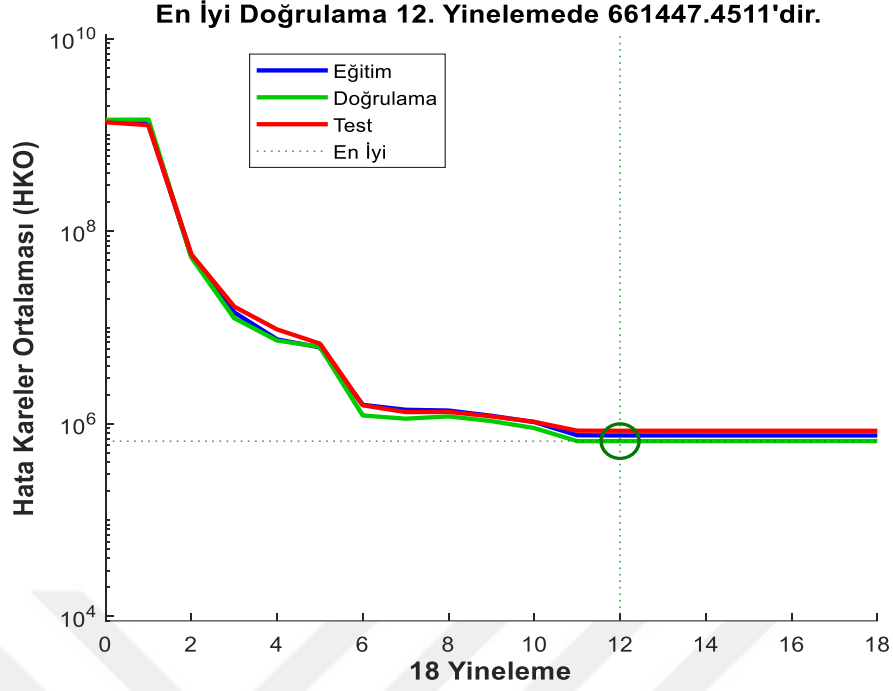
4.2.2. Yapay Sinir Ağları Modeli İçin Analiz Sonuçları

Bitcoin İçin Yapay Sinir Ağları Model Sonuçları

Günlük BTC veri seti için Matlab programı kullanılarak yapay sinir ağları yöntemi ile tahmin yapılmıştır. Kullanılan veri setinin %80'i eğitim, %10'u değerlendirme ve %10'u test verisi olarak ayrılmış ve ele alınmıştır. Şekil 4.9'un Neural Network kısmına baktığımızda 1 giriş, 1 çıkış ve 10 nöronlu ara katmanı olan YSA yapısında olduğu görülmüştür. Model ile ilgili ağda eğitim yaparken veriler rassal olarak alınmış ve eğitim (öğrenme) algoritmalarından iyi sonuç veren Levenberg-Marquardt algoritması kullanılmıştır. Model performans ölçümünde hata kareler ortalamasının (HKO) kullanılmış ve hata kareler ortalaması en küçük olan sonuç seçilmiştir. Eğitim 18 iterasyonda tamamlanmış, performans değerinin (performance) $1.39e+09$ ve veri değişim oranının (gradient) $5.73e+09$ olduğu ve gizli katman sayısının denemeler sonunda 10 olduğu görülmüştür.




Şekil 4.9. Günlük BTC serisine ait YSA modeli.




Şekil 4.10. Günlük BTC verisine ait eğitim, doğrulama ve test veri seti için ortalama karesel hata.

Veri setinin her eğitim iterasyonunda, eğitim, doğrulama ve test kümeleri için HKO değerlerinin nasıl değiştiği Şekil 4.10'da gösterilmektedir. Bu analiz, eğitimin on sekizinci iterasyonda tamamlandığını ortaya koymaktadır. Ayrıca, doğrulama aşamasında en düşük HKO değeri ve en iyi doğrulama sonucu 12. iterasyonda ölçülen 661447.4511 olarak kaydedilmiştir.



Şekil 4.11. Günlük BTC verisine ait gizli katman ile oluşan hata grafiği.

Eđitim sonrası hedef deęerler ile tahmin edilen deęerler arasındaki hata daęılımını, Őekil 4.11'deki hata histogram grafięi ile gsterilmektedir. Tahmin edilen ve hedef deęerler arasındaki fark nedeniyle hata deęerleri negatif olabilir. Grafikte hata aralıkları dikey ubuklarla gsterilir ve toplam hata aralığı yirmi kk kutuya ayrılmıřtır. Hata ekseninin (X eksen) sıfır hata deęeri, -204,4 merkezli kutuya eřittir.




Őekil 4.12. Modeldeki gizli katmanda eđitim, doęrulama, test ve tm model sonularına gre tahmin bařarısı grafięi.

Őekil 4.12'de, ađın eđitim, doęrulama ve test veri setleri iin tahmin ettięi regresyon doęrularını sunulmuřtur. Her bir grafikte, dikey eksen tahminlenen (ıktı) deęeri, yatay eksen ise hedef deęerini gstermektedir. Ađ sonucunda istenen durumu $Y=T$ doęrusu temsil eder. Grafik zerindeki noktaların $Y=T$ doęrusu zerinde yer alması arzu edilir. Tahminlenen (ıktı) deęerlerin kesikli doęruya yakın olması beklenir. Kesikli olmayan doęru(fit) ile kesikli doęru ($Y=T$) arasındaki paralellik, ađın uyumunun ve đrenme srecinin iyi olduęunu gsterir.


Grafikte, eđitim, doęrulama ve test veri setlerinin yanı sıra modelin genel bařarı oranları da grlmektedir. Eđitim verilerinde bařarı oranı $R = 0,99863$, doęrulama verilerinde $R = 0,99869$ ve test verilerinde $R = 0,99865$ olarak hesaplanmıřtır. BTC

verilerine ait yapay sinir ağıımızın toplam model başarısı ise 0,99864'tür. Bu yüksek R değerleri, modeldeki öğrenme işleminin oldukça başarılı olduğunu göstermektedir.



Şekil 4.13. Günlük BTC verisi için zamana göre çıktı, hedef ve hatalar.

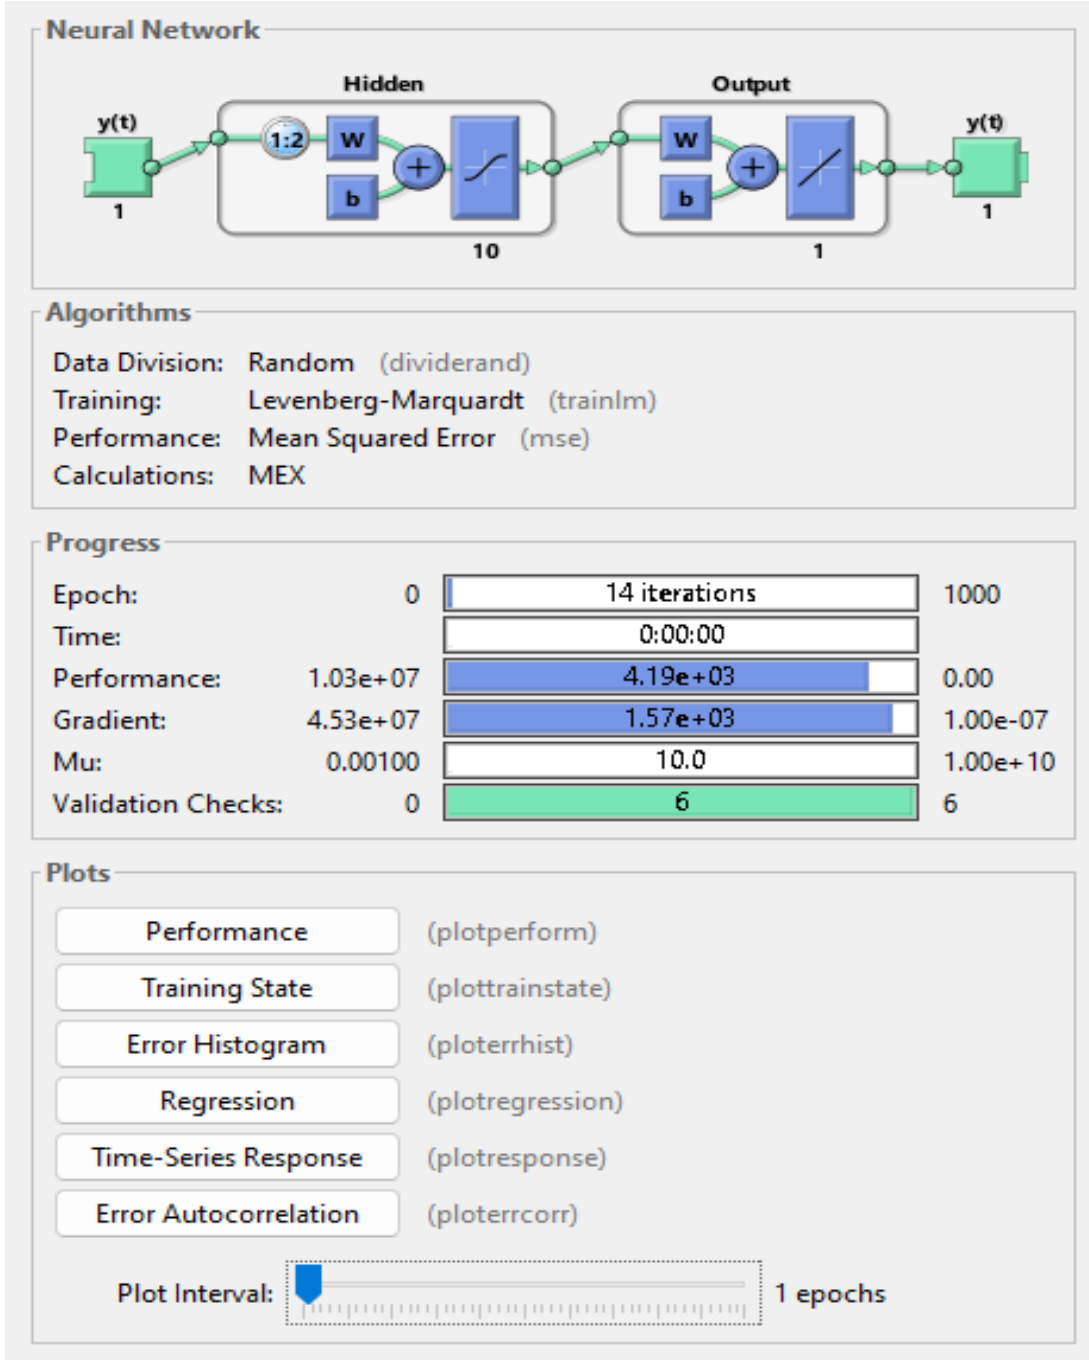
Şekil 4.13, belirli bir zamandaki girdileri, hedefleri ve hataları zamana karşı gösterirken, eğitim, test ve doğrulama aşamaları için seçilen zaman noktalarını da belirtir. Ayrıca, hataları temsil eden sarı çizgiler, bu noktalar üzerinde uzanarak hata değerlerinin görsel temsilini sağlar.



Şekil 4.14. Günlük BTC verilerinin hata otokorelasyonu.


Şekil 4.14'te günlük BTC verileri hata otokorelasyon fonksiyon grafiği incelendiğinde, 0 noktasında güven aralığını aşan bir değer olduğu görülmektedir. Bu durum, tahmin hatalarının birbirleriyle korelasyonsuz olduğunu gösterir.

Etherum İçin Yapay Sinir Ağları Model Sonuçları




Şekil 4.15. Günlük ETH serisine ait YSA modeli.

ETH günlük verileri için yapay sinir ağı yöntemiyle tahmin yapılmıştır. Veri setinin %80'i eğitim, %10'u değerlendirme ve %10'u test için kullanılmıştır. Şekil 4.15'de görülen model, 1 giriş, 1 çıkış ve 10 nöronlu ara katmandan oluşmaktadır. Eğitimde LM algoritması kullanılmış ve model performansı HKO ile ölçülmüştür. Eğitim 14 iterasyonda tamamlanmış, performans değeri $1.03e+07$ ve veri değişim oranı $4.53e+07$ olarak bulunmuştur.



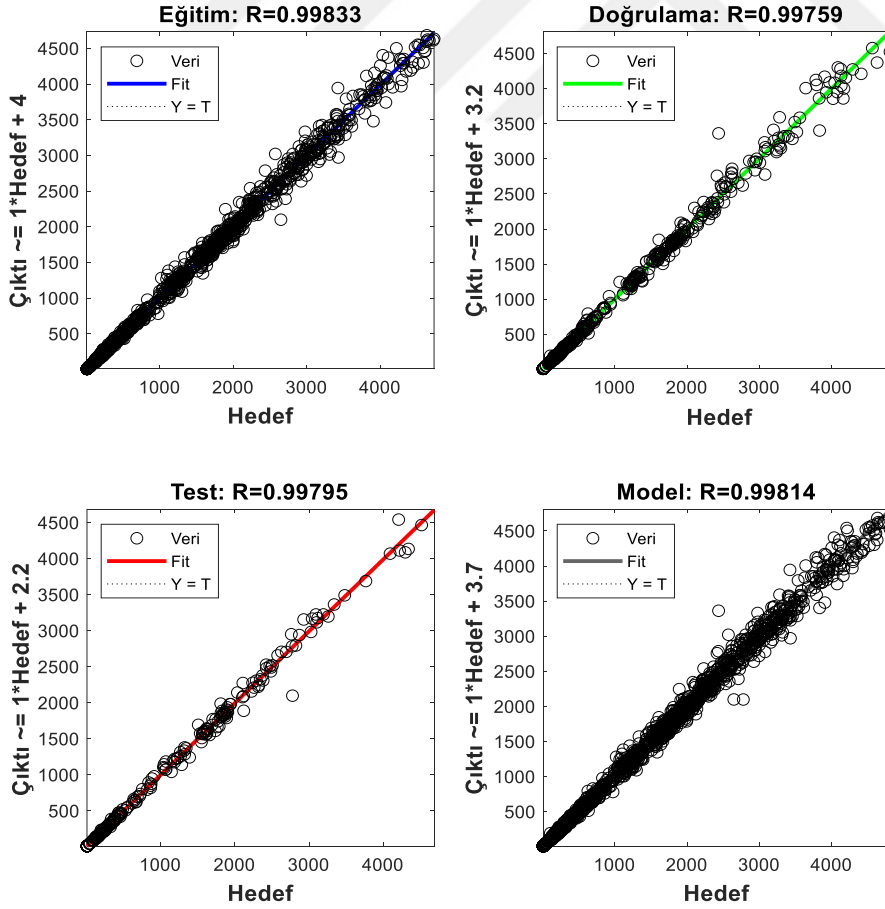
Şekil 4.16. Günlük ETH verisine ait eğitim, doğrulama ve test veri seti için ortalama karesel hata.

HKO değerleri, veri setinin eğitim süreci boyunca her iterasyonda eğitim, doğrulama ve test kümelerine ait olarak Şekil 4.16'da gösterilmektedir. Bu grafik, on dördüncü iterasyonda eğitimin tamamlandığını göstermektedir. Sekizinci iterasyonda doğrulama aşamasında en düşük HKO değeri ve en iyi doğrulama sonucu 6012.1585 olarak kaydedilmiştir.



Şekil 4.17. Günlük ETH verisine ait gizli katman ile oluşan hata grafiği.


Şekil 4.17'deki hata histogramı, sinir ağının tahmin ve hedef değerleri arasındaki farkları göstermektedir. Hatalar negatif olabilir ve histogram, bu farkların dağılımını 20 küçük kutuya bölmektedir. Sıfır hata değeri, -4,28 merkezli kutuda yer almaktadır.



Şekil 4.18. ETH verisine ait modeldeki gizli katmanda eğitim, doğrulama, test ve tüm model sonuçlarına göre tahmin başarısı grafiği

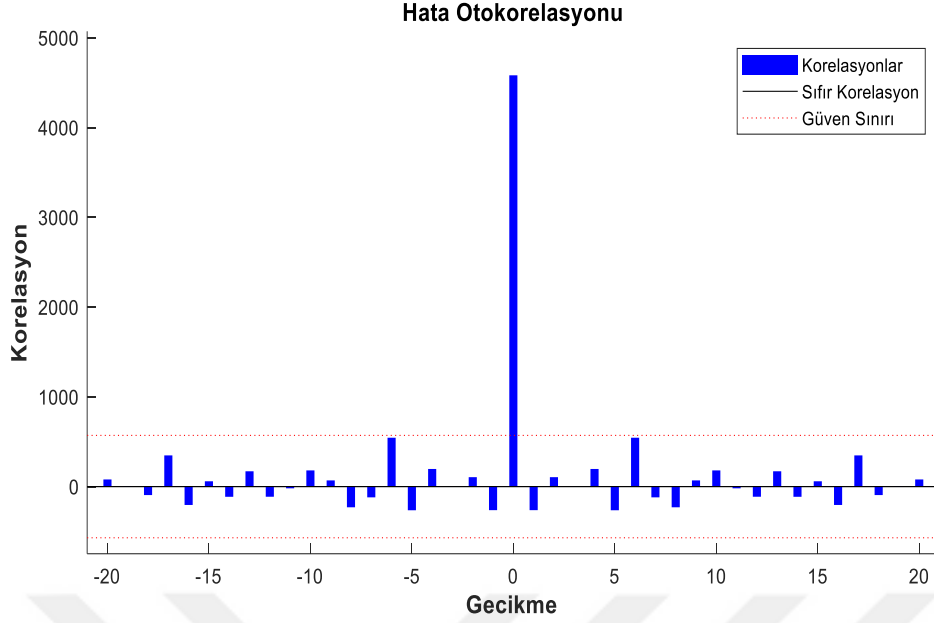
Şekil 4.18'de, ağın tahmin ettiği regresyon doğruları gösterilmektedir. Yatay eksen hedef, dikey eksen ise tahmin edilen değerleri temsil eder. $Y=T$ doğrusu, ideal durumu ifade eder. Tahmin edilen değerlerin bu doğruya yakın olması istenir. Kesikli doğruya paralel olan fit doğrusu, ağın iyi uyum sağladığını göstermektedir.

Grafikte, eğitim, doğrulama ve test veri setlerinin yanı sıra modelin genel başarı oranları da görülmektedir. Eğitim verilerinde başarı oranı $R = 0,99833$, doğrulama verilerinde $R = 0,99759$ ve test verilerinde $R = 0,99795$ olarak hesaplanmıştır. Ethereum verilerine ait yapay sinir ağımızın toplam model başarısı ise $0,99814$ 'tür. Bu yüksek R değerleri, modeldeki öğrenme işleminin oldukça başarılı olduğunu göstermektedir.



Şekil 4.19. Günlük ETH verisi için zamana göre çıktı, hedef ve hatalar.

Belirli bir zamanda girdiler, hedefler ve hatalar zamana göre Şekil 4.19'da gösterilmektedir. Ayrıca eğitim, test ve doğrulama aşamaları için seçilen zaman noktalarını ve hataları gösteren sarı çizgiler de içerir.



Şekil 4.20. Günlük ETH verilerinin hata otokorelasyonu.

Şekil 4.20'de günlük ETH verileri için hata otokorelasyon fonksiyonu grafiği incelendiğinde, 0 noktasında güven aralığını geçen bir değer olduğu görülmektedir. Bu, tahmin hatalarının birbiriyle korelasyonsuz olduğunu ve modelin uygun olduğunu göstermektedir.

4.3. ARIMA ve Yapay Sinir Ağları İle Tahmin Sonuçlarının Değerlendirilmesi

ARIMA ve YSA modelleri kullanılarak yapılan BTC ve ETH fiyat tahminlerinin karşılaştırılması amacıyla grafikler hazırlanmış ve bu grafikler, modellerin tahmin doğruluğunu detaylı bir şekilde analiz etmek için kullanılmıştır. Bu karşılaştırmalar, yıllar içinde modellerin performanslarındaki değişiklikleri ortaya koymanın yanı sıra, belirli dönemlerde hangi modelin daha başarılı olduğunu tespit etmemize yardımcı olmuştur. Özellikle 2022 yılına odaklanıldığında, yüksek volatilité, likidite krizleri ve düzenleyici belirsizlikler nedeniyle tahmin yapmanın daha zor hale geldiği görülmüştür. Bu doğrultuda, 2022 yılı verilerine dayalı olarak hazırlanan detaylı grafikler, ARIMA ve YSA modellerinin piyasa dinamiklerini ne kadar doğru yansıttığını kapsamlı bir şekilde incelemeye imkan tanımıştır. Bu zorlu piyasa koşulları altında, iki modelin performans farklılıklarının daha belirgin hale gelmesi beklenmiş ve karşılaştırmalar bu bağlamda yapılmıştır.

Çizelge 4.8. 2022 yılı Ocak ayı BTC gerçek değerleri ve YSA ile ARIMA modelleri tahmin değerleri.

TARİH	BTC GERÇEK DEĞER	BTC TAHMİN (YSA)	BTC TAHMİN (ARIMA)
1.01.2022	47.738,00	46.128,01	46.596,53
2.01.2022	47.311,80	47.657,49	47.228,57
3.01.2022	46.430,20	47.234,93	47.409,96
4.01.2022	45.837,30	46.341,87	46.154,50
5.01.2022	43.425,90	45.737,98	45.631,87
6.01.2022	43.097,50	43.316,10	43.708,82
7.01.2022	41.546,70	42.974,01	43.061,48
8.01.2022	41.672,00	41.435,04	41.313,19
9.01.2022	41.848,30	41.552,94	41.426,14
10.01.2022	41.832,20	41.727,59	41.513,26
11.01.2022	42.733,20	41.712,04	41.804,27
12.01.2022	43.901,00	42.606,77	43.104,49
13.01.2022	42.560,00	43.775,48	43.472,17
14.01.2022	43.073,30	42.441,76	42.558,85
15.01.2022	43.097,00	42.947,06	42.883,93
16.01.2022	43.079,10	42.972,16	42.812,23
17.01.2022	42.209,30	42.954,40	43.286,11
18.01.2022	42.364,60	42.089,76	42.273,58
19.01.2022	41.677,80	42.240,71	42.085,37
20.01.2022	40.715,90	41.561,03	41.650,23
21.01.2022	36.475,50	40.612,07	40.498,15
22.01.2022	35.075,20	36.533,01	36.333,78
23.01.2022	36.269,50	35.196,82	35.366,12
24.01.2022	36.686,30	36.318,20	35.830,36
25.01.2022	36.950,60	36.716,75	36.564,20
26.01.2022	36.800,40	36.968,66	36.711,18
27.01.2022	37.164,30	36.825,92	36.527,14
28.01.2022	37.745,10	37.172,48	37.366,58
29.01.2022	38.170,80	37.728,03	37.970,62
30.01.2022	37.917,70	38.136,28	37.612,04
31.01.2022	38.498,60	37.893,01	37.791,43

Çizelge 4.7’de 2022 yılı Ocak ayına ait BTC günlük fiyat gerçek değerleri, YSA modeli ve ARIMA modeli kullanılarak yapılan tahmin değerleri sunulmuştur. Çizelge incelendiğinde, BTC için YSA ve ARIMA modelleriyle yapılan tahminlerin, gerçek değerlere oldukça yakın olduğu görülmüştür.

Çizelge 4.9. 2022 yılı BTC verileri betimleyici istatistikleri.

BTC/USD (2022)	
Ortalama	28.185,67
Ortanca Değer	23.153,00
Maksimum Değer	47.738,00
Minumum Değer	16.537,40
Standart Sapma	10.178,43
Veri Sayısı	365


Çizelge 4.8’de, 2022 yılına ait BTC verilerinin betimleyici istatistikleri incelendiğinde, ortalama fiyatın 28.185,67; ortanca değer 23.153,00; maksimum fiyatın 47.738,00; minimum fiyatın ise 16.537,40 olduğu görülmektedir. Ayrıca, fiyat verilerindeki dalgalanmaların bir göstergesi olan standart sapmanın 10.178,43 olduğu tespit edilmiştir. Bu istatistikler, 2022 yılı boyunca BTC fiyatlarında önemli ölçüde değişiklikler olduğunu ve piyasanın dalgalı bir seyir izlediğini göstermektedir. Verilerin ortalama ve ortanca değerleri arasındaki fark, fiyat dağılımının asimetrik olduğunu işaret ederken, yüksek standart sapma değeri fiyatlarda yaşanan belirsizliğin ve volatilitenin altını çizmektedir.

Çizelge 4.10. 2022 yılı Ocak ayı BTC verileri betimleyici istatistikleri.

BTC/USD (OCAK 2022)	
Ortalama	42.954,40
Ortanca Değer	43.118,30
Maksimum Değer	47.738,00
Minumum Değer	38.498,60
Standart Sapma	6.533,24
Veri Sayısı	31


Çizelge 4.9’da, 2022 yılı Ocak ayına ait BTC fiyat verilerinin betimleyici istatistikleri incelendiğinde, ortalama fiyatın 42.954,40; ortanca değer 43.118,30; maksimum fiyatın 47.738,00; minimum fiyatın ise 38.498,60 olduğu görülmektedir. Ayrıca, fiyat verilerinin standart sapmasının 6.533,24 olması, Ocak ayı boyunca fiyatların belirli bir aralıkta dalgalandığını göstermektedir. Ortalama ve ortanca değerlerin birbirine yakın olması, fiyatların genel olarak simetrik bir dağılım gösterdiğini işaret ederken, yüksek maksimum ve düşük minimum değerler, dönem içinde yaşanan belirgin fiyat hareketlerine dikkat çekmektedir. Bu istatistikler, Ocak ayında BTC fiyatlarının

nispeten istikrarlı bir seyir izlediği, ancak yine de belirgin dalgalanmaların yaşandığını ortaya koymaktadır.



Şekil 4.21. 2022 yılı günlük BTC verisine ait gerçek ve tahmini değer karşılaştırma grafiği.

Şekil 4.21’de, 2022 yılına ait BTC gerçek fiyat verileri ile YSA ve ARIMA modelleri kullanılarak elde edilen tahmin değerlerinin karşılaştırıldığı grafik sunulmuştur. Bu grafikte, her iki modelin zaman içindeki performansı, gerçek fiyatlarla olan uyumu ve sapmalar net bir şekilde gözlemlenebilmekte; ayrıca, hangi modelin fiyat hareketlerini daha isabetli bir şekilde yakalayabildiği görsel olarak incelenebilmektedir.



Şekil 4.22. 2022 yılı Ocak ayı günlük BTC verisine ait gerçek ve tahmini değer karşılaştırma grafiği.

Şekil 4.22’de, 2022 yılı Ocak ayına ait BTC gerçek fiyat verileri ile YSA ve ARIMA modelleri kullanılarak elde edilen tahmin değerlerinin karşılaştırıldığı grafik sunulmuştur. Bu grafikte, her iki modelin kısa vadeli tahmin performansı detaylı olarak incelenmiş, özellikle günlük fiyat dalgalanmalarına ne ölçüde uyum sağladıkları ve gerçek verilerle olan sapmaları görsel olarak karşılaştırılabilir hale getirilmiştir. YSA ve ARIMA modellerinin tahmin başarısı arasındaki farklar, Ocak ayı boyunca yapılan analizlerle daha belirgin bir şekilde ortaya konmuştur.

Çizelge 4.11. ARIMA ve YSA modellerine ile elde edilen 2016-2024 yılları BTC günlük verilerine ait HKO değerleri

	HKO Değerleri	Kripto Paralar	HKO Değerleri	
ARIMA	807,92	BTC 2016	340,88	YSA
	142.712,20	BTC 2017	142.439,34	
	147.261,96	BTC 2018	148.369,13	
	104.873,06	BTC 2019	105.371,50	
	181.884,88	BTC 2020	179.886,87	
	3.477.590,93	BTC 2021	3.638.382,25	
	1.034.360,18	BTC 2022	1.034.308,27	
	432.112,91	BTC 2023	430.385,26	
	1.809.908,22	BTC 2024	1.866.299,23	

Çizelge 4.10’de ARIMA ve YSA modelleri ile hesaplanan 2016, 2017, 2018, 2019, 2020, 2021, 2022, 2023 ve 2024 yıllarına ait günlük BTC verilerine ilişkin HKO değerleri verilmiştir. Ele alınan yıllar için ayrı ayrı ortaya konulan YSA ve ARIMA modellerinin tahmin performansları değişkenlik göstermektedir. ARIMA yöntemi kullanılarak yapılan tahminler; 2018, 2019, 2021 ve 2024 yılları için daha iyi performans gösterirken; YSA yöntemi ise 2016, 2017, 2020, 2022 ve 2023 yılları için daha iyi tahmin performansına sahiptir. Bu bulgular, her iki modelin zaman içindeki tahmin performanslarını karşılaştırarak, hangi modelin belirli yıllarda daha etkili tahminler ortaya koyduğunu göstermektedir.

Çizelge 4.12. 2022 yılı Ocak ayı ETH gerçek değerleri ve YSA ile ARIMA modelleri tahmin değerleri.

TARİH	ETH GERÇEK DEĞER	ETH TAHMİN (YSA)	ETH TAHMİN (ARIMA)
1.01.2022	3.765,67	3.689,95	3.685,50
2.01.2022	3.830,67	3.757,87	3.764,32
3.01.2022	3.764,24	3.828,78	3.791,48
4.01.2022	3.789,52	3.786,60	3.757,14
5.01.2022	3.535,86	3.795,34	3.825,42
6.01.2022	3.407,77	3.554,24	3.536,74
7.01.2022	3.195,31	3.414,05	3.388,91
8.01.2022	3.080,02	3.193,75	3.213,11
9.01.2022	3.150,30	3.090,27	3.077,30
10.01.2022	3.085,43	3.154,11	3.133,74
11.01.2022	3.237,89	3.097,02	3.050,01
12.01.2022	3.370,89	3.229,32	3.238,82
13.01.2022	3.238,03	3.353,70	3.362,23
14.01.2022	3.307,90	3.240,84	3.231,29
15.01.2022	3.327,74	3.299,85	3.314,49
16.01.2022	3.346,59	3.322,99	3.320,31
17.01.2022	3.209,35	3.341,42	3.351,28
18.01.2022	3.160,15	3.212,57	3.226,51
19.01.2022	3.083,65	3.166,73	3.136,65
20.01.2022	3.004,72	3.095,13	3.093,78
21.01.2022	2.571,29	3.021,61	3.006,92
22.01.2022	2.412,52	2.530,10	2.596,63
23.01.2022	2.540,81	2.427,01	2.385,52
24.01.2022	2.441,01	2.554,03	2.520,85
25.01.2022	2.458,07	2.459,74	2.442,66
26.01.2022	2.461,41	2.475,57	2.458,44
27.01.2022	2.424,66	2.479,75	2.417,95
28.01.2022	2.545,95	2.442,68	2.422,38
29.01.2022	2.600,02	2.560,00	2.577,94
30.01.2022	2.602,77	2.621,40	2.572,44
31.01.2022	2.686,82	2.626,92	2.586,48

Çizelge 4.11’de 2022 yılı Ocak ayına ait ETH günlük fiyat gerçek değerleri, YSA modeli ve ARIMA modeli kullanılarak yapılan tahmin değerleri sunulmuştur. Çizelge incelendiğinde, ETH için YSA ve ARIMA modelleriyle yapılan tahminlerin, gerçek değerlere oldukça yakın olduğu görülmüştür.

Çizelge 4.13. 2022 yılı ETH verileri betimleyici istatistikleri.

ETH/USD (2022)	
Ortalama	1.986,67
Ortanca Değer	1.680,00
Maksimum Değer	3.765,67
Minimum Değer	1.195,67
Standart Sapma	1.817,26
Veri Sayısı	365

Çizelge 4.12’de, 2022 yılına ait ETH fiyat verilerinin betimleyici istatistikleri incelendiğinde, ortalama fiyatın 1.986,67; ortanca değer 1.680,00; maksimum fiyatın 3.765,67; minimum fiyatın ise 1.195,67 olduğu görülmektedir. Ayrıca, fiyat verilerinin standart sapmasının 1.817,26 olması, yıl boyunca ETH fiyatlarında önemli ölçüde dalgalanmalar yaşandığını göstermektedir. Ortalama ve ortanca değerler arasındaki fark, fiyatların asimetric bir dağılım gösterdiğini işaret ederken, yüksek maksimum ve düşük minimum değerler, ETH fiyatlarının belirli dönemlerde yüksek volatiliteye maruz kaldığını ortaya koymaktadır. Bu istatistikler, 2022 yılı genelinde ETH fiyatlarının geniş bir aralıkta değişkenlik gösterdiğine dair önemli bulgular sunmaktadır.

Çizelge 4.14. 2022 yılı Ocak ayı ETH verileri betimleyici istatistikleri.

ETH/USD (OCAK 2022)	
Ortalama	3.226,25
Ortanca Değer	3.226,25
Maksimum Değer	3.765,67
Minumum Değer	2.686,82
Standart Sapma	762,86
Veri Sayısı	31


Çizelge 4.13’de, 2022 yılı Ocak ayına ait ETH fiyat verilerinin betimleyici istatistikleri incelendiğinde, ortalama ve ortanca fiyatın 3.226,25 olduğu, maksimum fiyatın 3.765,67, minimum fiyatın ise 2.686,82 seviyesinde gerçekleştiği görülmektedir. Fiyat verilerinin standart sapmasının 762,86 olması, Ocak ayı boyunca ETH fiyatlarında belirgin dalgalanmalar yaşandığını göstermektedir. Ortalama ve ortanca değerlerin birbirine eşit olması, fiyatların genel olarak simetric bir dağılım gösterdiğine işaret ederken, yüksek maksimum ve düşük minimum değerler, bu dönemdeki volatilitenin

dikkat çekici olduğunu ortaya koymaktadır. Bu istatistikler, ETH fiyatlarının Ocak ayı boyunca geniş bir aralıkta dalgalanarak istikrarlı bir seyir izlediğini yansıtmaktadır.



Şekil 4.23. 2022 yılı günlük ETH verisine ait gerçek ve tahmini değer karşılaştırma grafiği.

Şekil 4.23’de, 2022 yılına ait ETH gerçek fiyat verileri ile YSA ve ARIMA modelleri kullanılarak yapılan tahminlerin karşılaştırıldığı bir grafik sunulmuştur. Bu grafikte, her iki modelin yıl boyunca ETH fiyatlarını ne derece isabetli bir şekilde tahmin ettiği görsel olarak incelenmiş ve modellerin performansları, özellikle fiyat hareketlerini yakalama konusundaki başarıları açısından değerlendirilmiştir. Grafik, her iki modelin gerçek fiyat verileriyle olan uyumunu ve sapmalarını açıkça göstererek, YSA ve ARIMA modellerinin tahmin gücü arasındaki farkların belirginleşmesini sağlamaktadır. Bu karşılaştırma, her iki modelin ETH fiyatlarındaki dalgalanmaları ne kadar iyi öngörebildiğini ortaya koymaktadır.



Şekil 4.24. 2022 yılı Ocak ayı günlük ETH verisine ait gerçek ve tahmini değer karşılaştırma grafiği.

Şekil 4.24’de, 2022 yılı Ocak ayına ait ETH gerçek fiyat verileri ile YSA ve ARIMA modelleri kullanılarak elde edilen tahmin değerlerinin karşılaştırıldığı grafik sunulmuştur. Bu grafik, her iki modelin tahminlerinin gerçek fiyat verileriyle olan uyumunu görsel olarak sergileyerek, modellerin performansını değerlendirmeye olanak tanımaktadır. Özellikle, YSA ve ARIMA modellerinin tahminlerinin zaman içindeki değişimlerle nasıl örtüştüğü ve hangi modelin daha doğru sonuçlar verdiği, grafik aracılığıyla daha belirgin hale getirilmektedir. Bu karşılaştırma, Ocak ayı boyunca ETH fiyatlarının dinamiklerini anlamak açısından önemli bir analiz sağlamaktadır.

Çizelge 4.15. ARIMA ve YSA modellerine ile elde edilen 2016-2024 yılları ETH günlük verilerine ait HKO değerleri.

	HKO Değerleri	Kripto Paralar	HKO Değerleri	
ARIMA	3,44	ETH 2016	1,75	YSA
	396,81	ETH 2017	391,14	
	1.373,73	ETH 2018	1.390,93	
	74,50	ETH 2019	69,15	
	248,48	ETH 2020	242,79	
	21.654,40	ETH 2021	23.179,72	
	8.269,08	ETH 2022	8.237,05	
	1.928,81	ETH 2023	1.941,33	
	5.085,23	ETH 2024	4.958,48	

Çizelge 4.14’de ARIMA ve YSA modelleri ile hesaplanan 2016, 2017, 2018, 2019, 2020, 2021, 2022, 2023 ve 2024 yıllarına ait günlük ETH verilerine ilişkin hata kareler ortalama değerleri verilmiştir. Ele alınan yıllar için ayrı ayrı ortaya konulan YSA ve ARIMA modellerinin tahmin performansları değişkenlik göstermektedir. ARIMA yöntemi ile 2018, 2021 ve 2023 yılları için tahmin performansları daha iyi iken, YSA yöntemi 2016, 2017, 2019, 2020, 2022 ve 2024 yılları için daha iyi tahmin performansına sahiptir. Yıllara göre ARIMA ve YSA yöntemlerinin tahmin performansları değişmekle birlikte YSA ile ortaya konulan modellerin tahmin performanslarının daha iyi olduğu söylenebilir.



5. SONUÇ

İstatistiksel analizin geleneksel yöntemlerinden biri olan zaman serileri analizi, ileriye yönelik bilgi aktarımı bakımından kritik bir öneme sahiptir. Geleceğe yönelik öngörülerin gerçek değerlere en yakın sonuçları vermesi için çeşitli yöntemler kullanılmaktadır. Zaman serileri, modele doğrudan dahil edilemeyen birçok dış etken ve değişkenden etkilenebilir. Bu dış etkenler arasında ekonomik dalgalanmalar, politik gelişmeler, teknolojik yenilikler ve doğa olayları gibi faktörler yer alabilir. Bu değişkenlerin etkilerini göz önünde bulundurarak, gerçeğe en yakın tahminleri üretebilen modelin belirlenmesi kritik bir öneme sahiptir. Doğru modelin seçilmesi, yalnızca gelecekteki olayların daha isabetli bir şekilde tahmin edilmesini sağlamakla kalmaz, aynı zamanda bu öngörüler doğrultusunda gerekli önlemlerin alınmasını ve stratejik yatırımların yapılmasını da mümkün kılar. Böylece, zaman serileri analizinin doğruluğu ve güvenilirliği, karar vericiler için hayati bir rol oynar. Yüksek doğruluk ve güvenilirlik sunan öngörüler, belirsizlikleri azaltır ve karar alma süreçlerini daha etkin hale getirir. Bu nedenle, zaman serileri analizinde kullanılan modellerin performansı, analiz sonuçlarının kalitesini doğrudan etkiler ve bu modellerin sürekli olarak iyileştirilmesi ve optimize edilmesi gerekmektedir.

Öngörülerde bulunmak amacıyla kullanılan farklı modellerin karşılaştırılmasında çeşitli kriterler ve yaklaşımlar mevcuttur. Temel kriter, gözlemlerle tahmin edilen değerler arasındaki farklılıkları gösteren hata üzerinde odaklanmaktadır. Bu bağlamda, öngörü modellerinin performans değerlendirmesi, tahminlerin doğruluğunu ölçen hata metrikleri ile yapılır. Hata değerlerinin düşük olması, modelin gerçek verilere yakın sonuçlar ürettiğini ve en iyi modelin bu olduğunu gösterir.

Bu çalışma, ARIMA ve YSA tekniklerini kullanarak temel kripto paralardan BTC ve ETH'nin günlük zaman serilerini modellemiştir. Bu yöntemlerin performanslarının karşılaştırılması amacıyla HKO kriteri temel alınmıştır. Bu kriterin kullanılması, ARIMA ve YSA modellerinin tahmin doğruluğunu ve güvenilirliğini karşılaştırmak için sağlam bir temel sunmaktadır. Elde edilen sonuçlar, hangi modelin kripto para

fiyat tahminlerinde daha etkili olduğunu belirlemeye yönelik değerli bilgiler sağlamaktadır.

ARIMA modelleri, zaman serisi analizinde de yaygın olarak kullanılan ve oldukça bilinen bir model grubudur. Ayrıca, zaman serisi analizinde de YSA algoritma yaklaşımı giderek daha popüler hale gelmektedir. YSA'nın doğrusal olmayan ilişkileri ve karmaşık desenleri öğrenme yeteneği, zaman serisi verilerinin analizinde güçlü bir alternatif sunmaktadır. Bu iki metodoloji, farklı veri özelliklerine ve tahmin ihtiyaçlarına göre avantajlar sağlamakta ve bu alanda yapılan çalışmaların çeşitliliğini artırmaktadır.

Sonuç olarak, bu çalışmada 2016-2024 yılları arasındaki günlük veriler kullanılarak BTC ve ETH gibi temel kripto para birimleri için ARIMA ve YSA yöntemleri ile tahminler yapılmıştır. Bu tahminler, gerçek değerlerle karşılaştırılarak yöntemlerin etkinliği değerlendirilmiştir. Analizler sonucunda, yıllara göre değişkenlik göstermekle birlikte; YSA yönteminin tahmin performansının ARIMA modeline göre daha tercih edilebilir olduğu belirlenmiştir. Özellikle, YSA'dan elde edilen tahmin değerlerinin gerçek verilere daha yakın olduğu gözlemlenmiştir. Bu bulgu, YSA'nın zaman serisi tahminlerinde daha hassas ve etkili bir yaklaşım sunduğunu ortaya koymuştur. ARIMA ve YSA'nın karşılaştırılması, farklı modelleme tekniklerinin kripto para tahminlerindeki performanslarını değerlendirmek için önemli bir temel sunmuştur. Kripto para piyasasının dinamik ve değişken doğasına rağmen, YSA'nın gelecekteki fiyat hareketlerini tahmin etme konusunda etkili bir araç olabileceğini göstermiş ve farklı zaman dilimlerindeki fiyat dalgalanmalarını anlamada ve tahmin etmede avantajlar sunmuştur. Bu nedenle, kripto para piyasasının gelecekteki yönünü tahmin etmek isteyen yatırımcılara ve analistlere bu çalışma güzel bir rehber olabilir ve YSA yönteminin kullanılması ve geliştirilmesi tavsiye edilebilir.

KAYNAKÇA

- Abushukur, A. M. (2022). *Yapay sinir ağıları ve ARIMA hibrit zaman serisi modeli ile havayolu rezervasyonu tahmini* (Yüksek lisans tezi). Karabük Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliği Anabilim Dalı.
- Adıyaman, F. (2007). *Talep tahmininde yapay sinir ağlarının kullanılması* (Yüksek Lisans Tezi). İstanbul Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliği Anabilim Dalı.
- Ahmet, S. E. L., Zengin, N., & Yıldız, Z. (2020). Alternatif yatırım araçları ile Bitcoin fiyatları arasındaki ilişkinin yapay sinir ağı ile tahmini. *Cumhuriyet Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 21(2), 157-169.
- Akdi, Y. (2010). *Zaman serileri analizi: Birim kökler ve kointegrasyon* (2. baskı). Ankara: Gazi Kitabevi.
- Akgül, I. (2003). *Zaman serileri analizi ve ARIMA modelleri*. Der Yayınları, İstanbul.
- Akıncı, M. (2008). *Zaman serilerinde durağanlık analizi ve ihracatın GSMH içindeki payı üzerine bir uygulama* (Yüksek lisans tezi). Kafkas Üniversitesi, Sosyal Bilimler Enstitüsü, İşletme Anabilim Dalı.
- Akkaş, F. E. (2020). *Balina optimizasyon algoritması ve Levenberg-Marquardt yöntemi ile doğal uçlaşma verilerinin ters çözümü için ardışık melez bir yaklaşım* (Yüksek lisans tezi). Süleyman Demirel Üniversitesi, Fen Bilimleri Enstitüsü, Jeofizik Mühendisliği Anabilim Dalı.
- Akkurt, A. (2005). *Yapay sinir ağıları ve Türkiye elektrik tüketimi tahmin modeli* (Yüksek lisans tezi). İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliği Anabilim Dalı.
- Alataş, B. (2003). *Sinirsel ağlar*. Fırat Üniversitesi. <http://www.firat.edu.tr/akademik/fakulteler/muhendislik/bilgisayar/balatas/Sinirselaglar.pdf> [Erişim tarihi: 05 Ekim 2023].
- Altın, A. (2007). Dodurga Barajı'na giren su miktarının Box-Jenkins tekniği ile modellenmesi. *Eskişehir Osmangazi Üniversitesi Mühendislik ve Mimarlık Fakültesi Dergisi*, 20(1), 81-100.
- Anderson, D., & McNeill, G. (1992). Artificial neural networks technology. *Kaman Sciences Corporation*, 258(6), 1-83.

- Arbib, M. A. (Ed.). (2003). *The handbook of brain theory and neural networks*. MIT Press.
- Arslan, B. (2022). Çoklu regresyon, ARIMA ve yapay sinir ağı yöntemleri ile Türkiye elektrik piyasasında fiyat tahmin ve analizi. *Journal of Management and Economics Research*, 20(1), 331-353.
- Aygören, H. S. (2012). İMKB 100 endeksinin yapay sinir ağları ve Newton nümerik arama modelleri ile tahmini. *Uluslararası Alanya İşletme Fakültesi Dergisi*, 4(1), 73-88.
- Benli Keskin, Y., & Yıldız, A. (2014). Altın fiyatının zaman serisi yöntemleri ve yapay sinir ağları ile öngörüsü. *Dumlupınar Üniversitesi Sosyal Bilimler Dergisi*, (42), 213-224.
- Biçen, C. (2006). *Box-Jenkins zaman serisi analiz yöntemi ile ileri beslemeli yapay sinir ağları tahminlerinin karşılaştırması* (Yüksek lisans tezi). Hacettepe Üniversitesi, Sağlık Bilimleri Enstitüsü, Biyoistatistik Anabilim Dalı.
- Box, G. E. P., & Jenkins, G. M. (1970). *Time series analysis: Forecasting and control*. Holden-Day.
- Box, G. E. P., & Jenkins, G. M. (1976). *Time series analysis: Forecasting and control* (Revised ed.). Holden-Day.
- Box, G. E. P., Jenkins, G. C., & Reisel, G. C. (2008). *Time series analysis*. Wiley series in probability and statistics.
- Bozdağ, H. (2011). *Box-Jenkins ve yapay sinir ağı yöntemleri ile havalimanı yolcu talebi öngörülmesi: Antalya Havalimanı örneği* (Yüksek lisans tezi). Süleyman Demirel Üniversitesi, Sosyal Bilimler Enstitüsü, Ekonometri Anabilim Dalı.
- Bölük, E. (2012). *Zaman serisi modellerinin belirlenmesinde artıklara uygulanan tanı teknikleri üzerine bir çalışma* (Yüksek lisans tezi). Dokuz Eylül Üniversitesi, Sosyal Bilimler Enstitüsü.
- Buterin, V. (2013). *Ethereum white paper*. GitHub repository. <https://github.com/ethereum/wiki/wiki/White-Paper>
- Can, A. (2014). *Yapay sinir ağları ile heyelan duyarlılık haritalarının üretilmesinde farklı algoritmaların kullanımının araştırılması* (Yüksek lisans tezi). Hacettepe Üniversitesi, Fen Bilimleri Enstitüsü, Jeoloji Mühendisliği Ana Bilim Dalı.
- Can, M. (2009). *İşletmelerde zaman serileri analizi ile tahmin* (Doktora tezi). İstanbul Üniversitesi, Sosyal Bilimler Enstitüsü, İşletme Anabilim Dalı.
- Can, S. (2020). *Rüzgar türbinleri kullanılarak üretilen elektrik enerjisi miktarının zaman serileri ile analizi ve uygulaması* (Yüksek lisans tezi). İskenderun Teknik Üniversitesi, Mühendislik ve Fen Bilimleri Enstitüsü, Elektrik-Elektronik Mühendisliği Anabilim Dalı.

- Crone, S. F. (2004). A business forecasting competition approach to modeling artificial neural networks for time series prediction. In *Proceedings of the International Conference on Artificial Intelligence (IC-AI '04)* (Vol. 1). Las Vegas, NV, USA.
- Çağlı, G. (2017). Mevsimlik olmayan Box-Jenkins modellerinde iki aşamalı yapay sinir ağlarının kullanılması. *Academic Platform-Journal of Engineering and Science*, 5(3), 123–130.
- Çakır, F. S. (2018). Yapay sinir ağları matlab kodları ve matlab toolbox çözümleri. Nobel Akademik Yayıncılık. *Yapay sinir ağları Matlab kodları ve Matlab toolbox çözümleri* (1. baskı). Nobel Kitabevi. Ankara.
- Çarkacıoğlu, A. (2016). *Kripto-para Bitcoin*. Sermaye Piyasası Kurulu Araştırma Dairesi, Araştırma Raporu.
- Çelik, B. (2008). *Yapay sinir ağları metodolojisi ile zaman serisi analizi: Teori ve uygulama* (Yüksek lisans tezi). Marmara Üniversitesi, Sosyal Bilimler Enstitüsü, Ekonometri Ana Bilim Dalı.
- Çetin, O. (2014). *Yapay sinir ağlarının uyarlanabilir donanımsal yapılarda gerçekleştirilmesi* (Doktora tezi). Sakarya Üniversitesi, Fen Bilimleri Enstitüsü, Elektrik-Elektronik Mühendisliği Ana Bilim Dalı.
- Çetinkaya, Ş. (2018). Kripto paraların gelişimi ve para piyasalarındaki yerinin SWOT analizi ile incelenmesi. *Uluslararası Ekonomi ve Siyaset Bilimleri Akademik Araştırmalar Dergisi*, 2(5), 11–21.
- Çevik, O. (1999). *Zaman serileri analizinde Box-Jenkins yöntemi ve turizm verileri üzerine bir uygulama* (Doktora tezi). Kırıkkale Üniversitesi, Sosyal Bilimler Enstitüsü, İşletme Anabilim Dalı.
- Deveci, M. (2012). *Yapay sinir ağları ve bekleme süresinin tahmininde kullanılması* (Yüksek lisans tezi) Gazi Üniversitesi, Sosyal Bilimler Enstitüsü, İşletme Ana Bilim Dalı, Üretim Yönetimi Bilim Dalı.
- Dickey, D. A., & Fuller, W. A. (1979). Distribution of the estimators for autoregressive time series with a unit root. *Journal of the American Statistical Association*, 74(366a), 427–431. <https://doi.org/10.1080/01621459.1979.10482531>
- Doğan, G. (2010). *Yapay sinir ağları kullanılarak Türkiye'deki özel bir sigorta şirketinde portföy değerlendirilmesi* (Yüksek lisans tezi). Hacettepe Üniversitesi, Fen Bilimleri Enstitüsü, İstatistik Anabilim Dalı.
- Duru, Ö. (2007). *Zaman serileri analizinde ARIMA modelleri ve bir uygulama* (Yüksek lisans tezi). İstanbul Üniversitesi, Sosyal Bilimler Enstitüsü, Ekonometri Anabilim Dalı.
- Efe, Ö., & Kaynak, O. (2000). *Yapay sinir ağları ve uygulamaları*. İstanbul: Boğaziçi Üniversitesi Yayını.

- Eğilmez, M. (2017). *Kendime yazılar: Kripto paralar, Bitcoin ve blockchain*. <https://www.mahfiegilmez.com/2017/11/kripto-paralar-bitcoinve-blockchain.html>
- Ekmekçi, H. (2016). *Türkiye'deki doğalgaz kullanımının arıma metodu ile istatistiksel analizi* (Yüksek lisans tezi). Karabük Üniversitesi, Fen Bilimleri Enstitüsü, Makine Mühendisliği Anabilim Dalı.
- Elmas, Ç. (2003). *Yapay sinir ağları*. Ankara: Seçkin Yayıncılık.
- Elmas, Ç. (2018). *Yapay zeka uygulamaları*. Ankara: Seçkin Yayıncılık.
- Erdoğan, E. (2006). *Zaman serilerinde ARIMA modelleri* (Yüksek lisans tezi). Muğla Üniversitesi, Fen Bilimleri Enstitüsü, İstatistik ve Bilgisayar Bilimleri Anabilim Dalı.
- Ergül, B. (2018). Türkiye'deki iş kazalarının zaman serisi analiz teknikleri ve yapay sinir ağları tekniği ile incelenmesi. *Karaelmas Journal of Occupational Health and Safety*, 2(2), 63–74.
- Erturan, M. (2017). *Zaman serileri için optimize ARIMA-YSA hibrit modeli ve finansal zaman serileri ile örnek uygulamalar* (Doktora tezi). Akdeniz Üniversitesi, Sosyal Bilimler Enstitüsü, Ekonometri Anabilim Dalı.
- Fermancı, N. (2021). *Önkestirim amaçlı kullanılan farklı yöntemlerin karşılaştırılması: Kripto paralar üzerine bir uygulama* (Yüksek lisans tezi). Afyon Kocatepe Üniversitesi, Fen Bilimleri Enstitüsü, İstatistik Anabilim Dalı.
- Göktaş, Ö. (2005). *Teorik ve uygulamalı zaman serileri analizi*. İstanbul: Beşir Kitabevi.
- Gözcü, O. (2009). *Türkiye'de hava ulaşım talebinin ARIMA modelleri ile tahminlenmesi* (Yüksek lisans tezi). Atatürk Üniversitesi, Fen Bilimleri Enstitüsü, İnşaat Mühendisliği Anabilim Dalı.
- Grossberg, S. (1992). *Neural networks and natural intelligence*. Massachusetts Institute of Technology. The MIT Press. USA.
- Gujarati, N., & Porter, D. (2009). *Temel ekonometri* (Ü. Şenesen & G. G. Şenesen, Çev.). Literatür Yayıncılık.
- Güzel, T. (2010). *Filyos Hisarönü dalga verilerinin yapay sinir ağları, arıma modelleri ve melez modeller ile tahmini* (Yüksek lisans tezi). Gazi Üniversitesi, Fen Bilimleri Enstitüsü, İnşaat Mühendisliği Anabilim Dalı.
- Kabalıcı, E. (2014). *Yapay sinir ağları* [Ders notları]. <https://ekblc.wordpress.com/wp-content/uploads/2014/02/ysa.pdf> [Erişim tarihi: Ocak 2024].
- Kadılar, C. (2005). *SPSS uygulamalı zaman serileri analizine giriş*. Ankara: Bizim Büro Basımevi.

- Kaftan, İ. (2010). *Batı Türkiye gravite ve deprem katalog verilerinin yapay sinir ağları ile değerlendirilmesi* (Doktora tezi). Dokuz Eylül Üniversitesi, Fen Bilimleri Enstitüsü, Jeofizik Mühendisliği Bölümü, Jeofizik Mühendisliği Anabilim Dalı.
- Karahan, M. (2015). Yapay sinir ağları metodu ile ihracat miktarlarının tahmini: ARIMA ve YSA metodunun karşılaştırmalı analizi. *Ege Akademik Bakış*, 15(2), 165–172.
- Kaya, E. (2019). *Zaman serileri analizinde Box-Jenkins yöntemi ile savunma sanayi verileri üzerine bir uygulama* (Yüksek lisans tezi). Karamanoğlu Mehmetbey Üniversitesi, Sosyal Bilimler Enstitüsü, İşletme Anabilim Dalı.
- Kaya, İ., Oktay, S., & Engin, O. (2005). Kalite kontrol problemlerinin çözümünde yapay sinir ağlarının kullanımı. *Erciyes Üniversitesi Fen Bilimleri Enstitüsü Fen Bilimleri Dergisi*, 21(1), 92–107.
- Kaynak, G. (2022). *Kestirimci bakım planlaması için zaman serisi modellerine dayalı arıza zamanı tahmini* (Yüksek lisans tezi). Necmettin Erbakan Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliği Anabilim Dalı.
- Kaynar, O., & Taştan, S. (2009). Zaman serisi analizinde MLP yapay sinir ağları ve ARIMA modelinin karşılaştırılması. *Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 33, 161–172.
- Koşma, E. (2018). *Türkiye genelinde Bahel modeli ve yapay sinir ağları ile güneş radyasyonu tahmini* (Yüksek lisans tezi). İstanbul Teknik Üniversitesi, Enerji Enstitüsü, Enerji Bilim ve Teknoloji Anabilim Dalı.
- Köse, N. (2016). *İstatistik ve olasılığa giriş-II*. Ankara: Gazi Kitabevi.
- Krose, B., & Smagt, P. (1996). *An introduction to neural networks*. The University of Amsterdam.
- Kuzu, S. (2013). *Yapısal kırılmaları göz önüne alarak Türk imalat sanayi ekonomik değişkenleri arasında uzun dönemli ilişkilerin araştırılması* (Yüksek lisans tezi). İstanbul Üniversitesi, Sosyal Bilimler Enstitüsü, İşletme Anabilim Dalı, Sayısal Yöntemler Bilim Dalı.

- Lenora Bilişim. (2021). *Yapay zeka konuları: Makine öğrenmesi, yapay sinir ağları ve derin öğrenme nedir?* <https://lenorabilisim.com/yapay-zeka-konulari-makine-ogrenmesi-yapay-sinir-aglari-ve-derin-ogrenme-nedir/>
- Mann, S. P. (1995). *Statistics for business and economics* (s. 771). Wiley.
- Müller, B., Reinhardt, J., & Strickland, M. T. (2012). *Neural networks: An introduction*. Springer Science & Business Media.
- Oğhan, S. (2010). *Zaman serisi analiz yöntemlerinin karşılaştırılması* (Yüksek lisans tezi). Ege Üniversitesi, Fen Bilimleri Enstitüsü, Zootekni Anabilim Dalı.
- Öğücü, M. (2006). *Yapay sinir ağları ile sistem tanıma* (Yüksek lisans tezi). İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Elektrik Mühendisliği Anabilim Dalı.
- Ömrüuzun, B. (2019). *Yapay sinir ağları ile kripto paraların fiyat modellemesi* (Yüksek lisans tezi). İstanbul Üniversitesi, Sosyal Bilimler Enstitüsü, İşletme Anabilim Dalı.
- Öncel, Ç. H. (2018). Examination of industry production index in Turkey with time series method. *Balıkesir Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 20(1), 547-554.
- Özdemir, Ö. (2008). *Zaman serisi modellemesinde yapay sinir ağlarının kullanımı ve bir uygulama* (Yüksek lisans tezi). Anadolu Üniversitesi, Fen Bilimleri Enstitüsü, İstatistik Anabilim Dalı.
- Özek, T. (2010). *Zaman serisi modelleri üzerine bir simülasyon çalışması* (Yüksek lisans tezi). Selçuk Üniversitesi, Fen Bilimleri Enstitüsü, İstatistik Ana Bilim Dalı.
- Özer, O. O., & İlkdoğan, U. (2013). Box-Jenkins modeli yardımıyla dünya pamuk fiyatının tahmini. *Tekirdağ Ziraat Fakültesi Dergisi*, 10(2), 13-20.
- Özmen, A. (1986). *Zaman serisi analizinde Box-Jenkins yöntemi ve banka mevduat tahmininde uygulama denemesi* (Doktora tezi). Anadolu Üniversitesi, Sosyal Bilimler Enstitüsü.

- Özmen, A., Şıklar, E., Durcasu, H., Atlas, M., & Er, F. (2013). *İstatistik II* (1. baskı). Açıköğretim Anadolu Üniversitesi Yayınları.
- Öztemel, E. (2006). *Yapay sinir ağları*. İstanbul: Papatya Yayıncılık.
- Phillips, P., & Perron, P. (1988). Testing for a unit root in time series regression. *Biometrika*, 75(2), 335-346. <https://doi.org/10.2307/2336182>
- Robert, S., & Daniel, L. (1998). *Econometric models and economic forecasts*. Singapore: Irwin/McGraw-Hill International Edition.
- Rumelhart, D. E., Hinton, G. E., & Williams, R. J. (1986). Learning representations by back-propagating errors. *Nature*, 323(6088), 533-536.
- Salehihosseini, P. (2023). *Kripto paralar, blockchain teknolojisi ve kripto paraların kullanım alanları* (Yüksek lisans tezi). Ufuk Üniversitesi, Sosyal Bilimler Enstitüsü, Uluslararası Ticaret ve Finansman Ana Bilim Dalı.
- Sampson, M. (2001). *Time series analysis*. Montreal, Canada: Loglinear Publications.
- Saraç, T. (2005). *Yapay sinir ağları ile yazılım proje süresinin tahmini* (Yüksek lisans tezi). Gazi Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliği Anabilim Dalı.
- Sevüktekin, M., & Nargeleçekenler, M. (2007). *Ekonometrik zaman serileri analizi: Eviews uygulamalı*. Nobel Yayın Dağıtım.
- Sönmez, A. (2014). Sanal para Bitcoin. *The Turkish Online Journal of Design, Art and Communication*, 4(3), 1-14. İstanbul Kültür Üniversitesi.
- Şahin, E. E. (2018). Kripto para Bitcoin: ARIMA ve yapay sinir ağları ile fiyat tahmini. *Fiscaoeconomia*, 2(2), 74-92.
- Şahin, Ş. (2002). *Yapay sinir ağları yardımı ile dinamik bir senaryo analizi* (Doktora tezi) İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliği Ana Bilim Dalı.
- Şen, H., & Polat, H. (2013). Yıllık küresel sıcaklık anomalilerinin zaman serileri analizi ile incelenmesi ve öngörülmesi. *Journal of Science and Technology of Dumlupınar University*, (30), 16-32.
- Şenesen, Ü., & Günlük Şenesen, G. (2012). *Temel ekonometri*. Literatür Yayınları.

- Şenol, D., & Denizhan, B. (2023). Kripto para değerinin yapay sinir ağları ile tahmini. *Endüstri Mühendisliği*, 34(1), 42-69.
- Şenyüz, M. (2019). *Türkiye'deki organik tarım ürünlerinin zaman serileri ile analizi* (Yüksek lisans tezi) İstanbul Üniversitesi, Sosyal Bilimler Enstitüsü, İşletme Ana Bilim Dalı.
- Tanışman, S., Karcıoğlu, A. A., Uğur, A., & Bulut, H. (2021). LSTM sinir ağı ve ARIMA zaman serisi modelleri kullanılarak Bitcoin fiyatının tahminlenmesi ve yöntemlerin karşılaştırılması. *Avrupa Bilim ve Teknoloji Dergisi*, 32, 514-520. <https://doi.org/10.31590/ejosat.1039890>
- Tekin, M. (2009). *Üretim yönetimi* (Cilt 1, 6. baskı). Günay Ofset.
- Tolon, M., & Tosunoğlu, N. G. (2008). Tüketici tatmini verilerinin analizi: Yapay sinir ağları ve regresyon analizi karşılaştırması. *Gazi Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 10(2), 247-259.
- Torun, N. (2015). *Birim kök testlerinin performanslarının karşılaştırılması* (Yüksek lisans tezi) İstanbul Üniversitesi, Sosyal Bilimler Enstitüsü, Ekonometri Anabilim Dalı.
- Tuna, M. (2019). *Altın fiyatlarının yapay sinir ağları ve ARMA modelleri ile tahminlenmesi* (Yüksek lisans tezi) Adnan Menderes Üniversitesi, Sosyal Bilimler Enstitüsü, Ekonometri Anabilim Dalı.
- turhost.com. (2021). *Makine öğrenmesi: Machine learning nedir?* <https://www.turhost.com/blog/makine-ogrenmesi-machine-learning-nedir/>
- Tüzen, F. (2012). *Türkiye turizm gelirinin öngörüsünde zaman serilerinin bileşenlerine ayrıştırılarak yapay sinir ağları ve Box-Jenkins yöntemleri ile karşılaştırmalı analizi* (Yüksek lisans tezi) Kafkas Üniversitesi, Sosyal Bilimler Enstitüsü, İşletme Anabilim Dalı.
- Usta, A., & Doğantekin, S. (2017). *Blockchain 101 V2*. BKM.
- Widrow, B., & Hoff, M. (1960, August). Adaptive switching circuits. *IRE WESCON Convention Record*, 4(1), 96-104.

- Yeşilyayla, H. (2013). *X-12 ARIMA metoduyla sosyo-ekonomik verilerin analizi* (Yüksek lisans tezi). Pamukkale Üniversitesi Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği Anabilim Dalı.
- Yılmaz, E. (2012). *Hidrolik bir sistemin yapay sinir ağları ile modellenmesi ve katsayıları genetik ve parçacık sürü algoritmaları ile optimize edilmiş PID ile kontrolü* (Yüksek lisans tezi). Marmara Üniversitesi, Fen Bilimleri Enstitüsü, Elektronik ve Bilgisayar Eğitimi Anabilim Dalı.
- Yılmazel, Ö., Afşar, A., & Yılmazel, S. (2018). Konut fiyat tahmininde yapay sinir ağları yönteminin kullanılması. *Uluslararası İktisadi ve İdari İncelemeler Dergisi*, 20, 285-300. <https://doi.org/10.18092/ulikidince.341584>
- Yüksel, D. (2015). *Arap Baharından etkilenen yakın ve Ortadoğu ülkeleri ile Türkiye arasındaki ithalat ve ihracat miktarlarının ARIMA modelleri ile incelenmesi* (Yüksek lisans tezi). Dokuz Eylül Üniversitesi, Sosyal Bilimler Enstitüsü, Ekonometri Anabilim Dalı.

ÖZGEÇMİŞ

Ad-Soyad : Emre YILMAZ

İletişim :

