



T.C.
NECMETTİN ERBAKAN
ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ



**YAPAY SİNİR AĞLARI KULLANILARAK
BİST FİYAT TAHMİNLEMESİ**

Orhan Veli DİREK

YÜKSEK LİSANS TEZİ

Endüstri Mühendisliği Anabilim Dalı

**Temmuz-2025
KONYA
Her Hakkı Saklıdır**

TEZ KABUL VE ONAYI

Orhan Veli DİREK tarafından hazırlanan “Yapay Sinir Ağları kullanılarak BIST Fiyat Tahminlemesi” adlı tez çalışması 30/06/2025 tarihinde aşağıdaki jüri tarafından oy birliği ile Necmettin Erbakan Üniversitesi Fen Bilimleri Enstitüsü Endüstri Mühendisliği Anabilim Dalı’nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Jüri Üyeleri

İmza

Başkan

Prof. Dr. Halife KODAZ

.....

Danışman

Doç. Dr. Şaban GÜLCÜ

.....

Üye

Prof. Dr. Sabri KOÇER

.....

Fen Bilimleri Enstitüsü Yönetim Kurulu’nun .../.../20.. gün ve sayılı kararıyla onaylanmıştır.

Prof. Dr. Havvanur UÇBEYİAY
FBE Müdürü

TEZ BİLDİRİMİ

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

DECLARATION PAGE

I hereby declare that all information in this document has been obtained and presented in accordance with academic rules and ethical conduct. I also declare that, as required by these rules and conduct, I have fully cited and referenced all material and results that are not original to this work.

İmza

Orhan Veli DİREK

Tarih: 30.06.2025

ÖZET

YÜKSEK LİSANS TEZİ

YAPAY SİNİR AĞLARI KULLANILARAK BIST FİYAT TAHMİNLEMESİ

Orhan Veli DİREK

**Necmettin Erbakan Üniversitesi Fen Bilimleri Enstitüsü
Endüstri Mühendisliği Anabilim Dalı**

Danışman: Doç. Dr. Şaban GÜLCÜ

2025, 50 Sayfa

Jüri

Doç. Dr. Şaban GÜLCÜ

Prof. Dr. Sabri KOÇER

Prof. Dr. Halife KODAZ

Bu çalışma, Yapay Sinir Ağları (YSA) kullanılarak BIST 30 ve BIST 100 endekslerine ait 2022–2023 yıllarındaki verilerle kapanış fiyatlarını tahmin etmeyi amaçlamaktadır. Veri ön işleme adımlarının ardından ileri beslemeli çok katmanlı algılayıcı (ÇKA) modeli geliştirilmiş ve fiyat tahmini gerçekleştirilmiştir. Modelin başarımı, Ortalama Kare Hata (OKH), Ortalama Mutlak Hata (OMH), Ortalama Mutlak Yüzde Hata (OMYH), R-kare (R^2), Doğruluk, Kesinlik, Duyarlılık ve Yönel Doğruluk Oranı (YDO) gibi çeşitli performans metrikleriyle değerlendirilmiştir. BIST 30 endeksi için modelin R^2 değeri %96,2 (0,962), OMH değeri 1,83 ve YDO %93,7 olarak elde edilmiştir. BIST 100 endeksi için ise R^2 değeri %95,5 (0,955), OMH değeri 2,05 ve YDO %92,4 bulunmuştur. Bu sonuçlar, YSA tabanlı ÇKA modelinin hem yön tahmininde hem de sayısal değer tahmininde yüksek doğruluk sunduğunu ortaya koymaktadır. Ayrıca, bu yöntem yatırımcılara veri temelli karar alma süreçlerinde etkili bir karar destek aracı sunarak finansal piyasalarda risk yönetimi ve portföy optimizasyonu açısından önemli bir katkı sağlamaktadır.

Anahtar Kelimeler: BIST 30, BIST 100, Finansal Tahminleme, Finansal Zaman Serisi, Tahmin Modeli, Veri Odaklı Karar Verme, Yapay Sinir Ağları

ABSTRACT

MASTER'S THESIS

PREDICTING BIST PRICES USING ARTIFICIAL NEURAL NETWORKS

Orhan Veli DİREK

**Necmettin Erbakan University
Graduate School of Natural and Applied Sciences
Department of Industrial Engineering**

Advisor: Assoc. Prof. Dr. Şaban GÜLCÜ

2025, 50 Pages

Jury

**Assoc. Prof. Dr. Şaban GÜLCÜ
Prof. Dr. Sabri KOÇER
Prof. Dr. Halife KODAZ**

This study aims to predict the closing prices of the BIST 30 and BIST 100 indices for the years 2022–2023 using Artificial Neural Networks (ANN). After completing data preprocessing steps, a feedforward Multilayer Perceptron (MLP) model was developed to perform price forecasting. The model's performance was evaluated using various metrics, including Mean Squared Error (MSE), Mean Absolute Error (MAE), Mean Absolute Percentage Error (MAPE), R-squared (R^2), Accuracy, Precision, Recall, and Directional Accuracy (DA). For the BIST 30 index, the model achieved an R^2 score of 0.962, an MAE of 1.83, and a directional accuracy of 93.7%. For the BIST 100 index, the R^2 score was 0.955, MAE was 2.05, and directional accuracy reached 92.4%. These results demonstrate that the ANN-based MLP model offers high accuracy in both numerical price forecasting and directional movement prediction. Furthermore, the proposed method provides investors with an effective data-driven decision support tool, contributing significantly to financial market risk management and portfolio optimization.

Keywords: BIST 30, BIST 100, Data-Driven Decision Making, Financial Forecasting, Financial Time Series, Forecasting Model, Artificial Neural Networks (ANN)

ÖNSÖZ

Bu çalışma, Yapay Sinir Ağları (YSA) ile Finansal Varlık Fiyat Tahminlemesi başlığı altında, finansal piyasalarda yapay zekâ temelli tahminleme yöntemlerinin etkinliğini incelemek amacıyla hazırlanmıştır. 2022–2023 yıllarına ait BIST 30 ve BIST 100 endeks verileri kullanılarak gerçekleştirilen bu araştırmada, ileri beslemeli çok katmanlı algılayıcı (ÇKA) modeli ile kapanış fiyatları tahmin edilmiştir. Model performansı; Ortalama kare hata, ortalama mutlak hata, ortalama mutlak yüzde hata, R-Kare, doğruluk, kesinlik, duyarlılık ve yönsel doğruluk oranı gibi metriklerle değerlendirilmiştir. Elde edilen sonuçlar, çok katmanlı algılayıcının finansal zaman serisi tahminlemesinde yüksek başarı sağladığını göstermekte ve veri odaklı yatırım stratejilerine katkı sunabilecek güçlü bir araç olduğunu ortaya koymaktadır.

Tez sürecinde bana yol gösteren, değerli bilgi ve önerileriyle katkıda bulunan Doç. Dr. Şaban GÜLCÜ'ye en içten teşekkürlerimi sunarım. Ayrıca, bu süreçte beni destekleyen aileme, arkadaşlarıma ve çalışma ortamı sağlayan kurumlara da minnettarım.

Bu çalışmanın, finansal varlık tahmini üzerine çalışan araştırmacılara ve yatırımcılara katkı sağlamasını dilerim.

Orhan Veli DİREK
KONYA-2025

İÇİNDEKİLER

ÖZET	iv
ABSTRACT	v
ÖNSÖZ	vi
İÇİNDEKİLER	vii
SİMGELER VE KISALTMALAR	ix
ŞEKİLLER LİSTESİ	x
ÇİZELGELER LİSTESİ	xi
1. GİRİŞ	1
1.1. Araştırmanın Önemi ve Amacı	4
1.1.1. Finansal varlıkların tanımı ve sınıflandırılması	5
1.1.2. Portföy yönetiminin temelleri	5
1.1.3. Risk ve getiri ilişkisi	6
1.1.4. Çeşitlendirme ve portföy teorisi	6
1.1.5. Modern portföy teorisi	6
1.2. Tezin Kapsamı	6
1.3. Tezin Yapısı	7
2. KAYNAK ARAŞTIRMASI	9
2.1. Portföy Optimizasyonu Yaklaşımları	16
3. MATERYAL VE YÖNTEM	18
3.1. Veri Toplama ve Veri Ön İşleme.....	18
3.2. Yapay Sinir Ağı Modeli Geliştirme	19
3.2.1. Çok katmanlı algılayıcı (ÇKA).....	20
3.3. Fiyat Tahminlemesi	24
3.4. Risk Yönetimi	26
3.5. Performans Değerlendirme Metrikleri	27
3.5.1. Ortalama kare hata	27
3.5.2. Ortalama mutlak hata.....	27
3.5.3. Ortalama mutlak yüzde hata	27
3.5.4. Korelasyon katsayısı (R).....	28
3.5.5. Doğruluk	28
3.5.6. Kesinlik	29
3.5.7. Duyarlılık	29
3.5.8. Yönsel doğruluk oranı	29
4. DENEYSEL ÇALIŞMA	30

4.1. Veri Seti ve Hazırlık	30
4.2. Veri Görselleştirme ve Dağılım Analizi	35
4.3. Yapay Sinir Ağı Modeli ve Parametreleri	36
4.4. Deneysel Sonuçlar ve Değerlendirme.....	37
4.4.1. Görsel karşılaştırmalar ve yorumlar	38
4.4.2. Model tahmin performanslarının karşılaştırılması.....	38
4.4.3. Hata dağılımlarının incelenmesi	39
4.4.4. Öngörü performansının zaman boyunca değişimi	41
4.5. Sonuçların Değerlendirilmesi	42
5. ARAŞTIRMA SONUÇLARI VE TARTIŞMA.....	44
5.1. Sonuçlar	44
5.1.1. BIST-30 ve BIST-100 sonuçları	44
5.2. Tartışma	45
5.3. Modelin Kullanım Alanları.....	46
6. KAYNAKLAR	47

SİMGELER VE KISALTMALAR

BIST-30	: Borsa İstanbul 30 Endeksi
BIST-100	: Borsa İstanbul 100 Endeksi
ÇKA	: Çok Katmanlı Algılayıcı
DLB	: Düzleştirilmiş Lineer Birim
DVM	: Destek Vektör Makineleri
İBYSA	: İleri Beslemeli Yapay Sinir Ağı
İMKB	: İstanbul Menkul Kıymetler Borsası
KOKH	: Karekök Ortalama Kare Hata
MPT	: Modern Portföy Teorisi
OKH	: Ortalama Kare Hata
OMH	: Ortalama Mutlak Hata
OMYH	: Ortalama Mutlak Yüzde Hata
R ²	: Belirleme Katsayısı
SVFM	: Sermaye Varlıkları Fiyatlama Modeli
UKSB	: Uzun Kısa Süreli Bellek
YDO	: Yönel Doğruluk Oranı
YDT	: Yön Değişim Tahmini
YSA	: Yapay Sinir Ağı

ŞEKİLLER LİSTESİ

Şekil 1.1. BIST 30 ve BIST 100 Endekslerinin Kapanış Fiyatları (2022-2023).....	3
Şekil 4.1. BIST 100 Giriş Değişkenlerinin Analizi	31
Şekil 4.2. BIST 30 Giriş Değişkenlerinin Analizi	32
Şekil 4.3. BIST 100 2022-2023 Kapanış Fiyatlarının Zaman Serisi Grafiği	33
Şekil 4.4. BIST 30 2022-2023 Kapanış Fiyatlarının Zaman Serisi Grafiği	33
Şekil 4.5. BIST 100 Giriş Değişkenleri Arasındaki Korelasyon Matrisi	34
Şekil 4.6. BIST 30 Giriş Değişkenleri Arasındaki Korelasyon Matrisi	35
Şekil 4.7. 2022 ve 2023 Fiyat Dağılımları Box-Plot Karşılaştırması.....	36
Şekil 4.8. BIST 100 Gerçek ve ÇKA Tahmini Fiyatlar Zaman Serisi	39
Şekil 4.9. BIST 30 Gerçek ve ÇKA Tahmini Fiyatlar Zaman Serisi	39
Şekil 4.10. ÇKA Modelinin BIST 100 ve BIST 30 Hata Dağılım Grafiği.....	40
Şekil 4.11. ÇKA Modeli Hata Dağılımları	41
Şekil 4.12. Tahmin Hatalarının Zamana Göre Değişimi	42
Şekil 4.13. ÇKA Model Performans Kıyaslaması (OMH, KOKH, R2).....	43

ÇİZELGELER LİSTESİ

Çizelge 1.1. BIST 100 Aylık Volatilite Oranları.....	2
Çizelge 4.1. 2022-2023 BIST100 Temel Finansal Değişkenler.....	30
Çizelge 4.2. 2022-2023 BIST30 Temel Finansal Değişkenler.....	30
Çizelge 4.3. Model Eğitim Parametreleri	37
Çizelge 4.4. BIST 30-100 OKH, OMH, OMYH, R^2 ve YDO Karşılaştırması	37
Çizelge 4.5. 2022 ve 2023 Kapanış Fiyatları Tahmin Performans.....	38

1. GİRİŞ

Günümüzde finansal piyasalarda, varlık fiyatlarını doğru bir şekilde tahmin edebilmek ve portföy yönetimini optimize edebilmek, yatırımcılar için hayati öneme sahiptir. Bu bağlamda, YSA gibi ileri düzey yapay zekâ teknolojileri, finansal analizde devrim yaratma potansiyeline sahiptir. YSA, büyük veri setleri üzerindeki karmaşık ilişkileri anlamada ve gelecekteki eğilimleri tahmin etmede güçlü bir araç olarak öne çıkmaktadır. Bu çalışma, YSA'nın finansal piyasalardaki karar destek sistemlerine olan katkılarını incelemeyi ve bu teknolojinin fiyat tahminlemesi süreçlerinde nasıl kullanılabileceğini araştırmayı hedeflemektedir.

Ding ve ark. (2015) "Deep Learning for Event-Driven Stock Prediction" çalışmasında gösterildiği gibi, YSA, haber metinlerinden olayları çıkarıp bu olayları yoğun vektörler olarak temsil etme yeteneğini ve bu olayların hem kısa vadeli hem de uzun vadeli etkilerini modelleyerek hisse senedi fiyat hareketlerini tahmin etme kapasitesini göstermektedir. Bu yaklaşım, finansal piyasalardaki gelişmelerin ve haber olaylarının uzun vadeli etkilerini modellemekte ve finansal varlık fiyatları üzerindeki etkilerini değerlendirmede önemli bir role sahiptir.

Finansal piyasalarda alınan kararların doğruluğu, genellikle mevcut ve geçmiş verilere dayanır Kimoto ve ark. (1990). Bu bağlamda, YSA, karmaşık desenleri tanıma ve gelecekteki eğilimleri öngörme yetenekleri nedeniyle finansal analizde giderek daha fazla kullanılmaktadır. Kimoto ve arkadaşlarının Tokyo Borsası üzerinde gerçekleştirdiği çalışmada, bir dizi modüler sinir ağı kullanılarak hisse senedi alım satım zamanlamasının tahmin edilmesi ve bu süreçte karar verme mekanizmalarının incelenmesi ele alınmıştır.

Borsa İstanbul (BIST), Türkiye'nin en büyük borsa piyasalarından biridir ve piyasa dinamiklerini anlamak için önemli bir veri tabanı sağlar. 2022 ve 2023 yıllarına ait BIST 100 endekslerine ait aylık volatiliteler, işlem hacimleri ve değişim oranları Çizelge 1.1'de yer almaktadır.

Çizelge 1.1. BIST 100 Aylık Volatilite Oranları

Tarih	Aylık Volatilite (%)	İşlem Hacmi (Milyon TL)	Değişim Oranı (%)
2022-01-31	51,86	330.000	0,38
2022-02-28	50,15	252.150	-0,11
2022-03-31	31,17	287.304	0,60
2022-04-30	46,33	442.190	0,41
2022-05-31	39,67	315.611	0,27
2022-06-30	55,55	295.591	-0,25
2022-07-31	41,94	246.052	0,43
2022-08-31	61,18	507.409	0,93
2022-09-30	111,68	571.273	0,05
2022-10-31	81,71	442.238	1,09
2022-11-30	122,55	575.455	1,03
2022-12-31	133,86	542.136	0,48
2023-01-31	213,68	433.045	-0,42
2023-02-28	221,38	285.803	0,40
2023-03-31	130,70	310.783	-0,35
2023-04-30	106,79	209.526	-0,20
2023-05-31	157,05	269.095	0,31
2023-06-30	137,32	320.421	0,90
2023-07-31	149,95	482.476	1,09
2023-08-31	231,86	530.182	0,44
2023-09-30	182,76	466.000	0,26
2023-10-31	246,18	386.773	-0,44
2023-11-30	131,05	251.864	0,26
2023-12-31	180,43	225.762	-0,28

Aylık volatilite, finansal piyasalardaki kısa vadeli dalgalanmaları ölçerek, yatırımcıların risk yönetimini ve portföy optimizasyonunu daha etkili bir şekilde yapmalarına olanak tanır. Tez çalışmasında, BIST 100 endekslerinin aylık volatilite verileri, piyasa risklerini kısa vadeli olarak analiz etmek ve modellemede kullanmak amacıyla yararlanılmıştır. Aylık volatiliteyi dikkate alarak, daha dinamik fiyat tahminlemesi stratejileri geliştirilmiş ve yatırımcıların risk toleransına göre seçimlerini optimize etmek için önemli bir araç olarak kullanılmıştır. Bu sayede, volatilitenin arttığı dönemlerde daha güvenli yatırım kararları alınması desteklenmiştir.

Kapanış fiyatları zaman serisi grafiği olan Şekil 1.1, BIST 30 ve BIST 100 endekslerinin 2022-2023 yıllarına ait fiyat hareketlerini göstermektedir ve bu veriler, piyasa trendlerini analiz etmek için önemli bir araçtır. Tez çalışmasında, bu kapanış fiyatları, ÇKA modeline girdi verisi olarak kullanılmıştır. Model, geçmiş kapanış fiyatlarına dayanarak gelecekteki fiyat hareketlerini tahmin etmek için eğitilmiştir. Ayrıca, fiyatlardaki dalgalanmalar, piyasanın volatilitesini ve risk düzeyini ölçmek için de kullanılır. Kapanış fiyatlarındaki değişiklikler, yatırımcıların karar alma süreçlerine rehberlik ederken, modelin portföy optimizasyonu ve risk yönetimi stratejilerini geliştirmesine olanak tanımaktadır.



Şekil 1.1. BIST 30 ve BIST 100 Endekslerinin Kapanış Fiyatları (2022-2023)

Bu çalışma, ÇKA'nın finansal piyasalardaki karmaşık problemleri çözmek için standart bilgisayar ve uzman sistemlerine göre avantaj sağladığını göstermektedir. YSA'nın lineer olmayan öğrenme yetenekleri ve pürüzsüz interpolasyon kapasiteleri, özellikle hisse senedi piyasası tahmininde etkili bir model oluşturma potansiyeline sahip olduğunu ortaya koymaktadır Kimoto ve ark. (1990).

Pogue (1969), portföy seçimi alanında yapılan akademik çalışmaların büyük bir kısmının, H. M. Markowitz'in 1952'de yayınladığı bir makalede sunulan yaklaşıma dayandığını ifade etmektedir. Bu temel yaklaşım, zaman içinde çeşitli yazarlar tarafından, bireylerin varlık tutma davranışlarını açıklamak veya varlık seçimi için normatif kurallar geliştirmek amacıyla genişletilmiştir. Bu çalışmalar, mevcut bir portföyün yenilenerek gelecekteki güvenlik fiyatlarına dair yenilenmiş beklentilere göre daha arzu edilen bir portföye dönüştürülmesiyle ilgili maliyetleri içeren standart bir varsayım setini sıklıkla içermektedir. Bu varsayımlar, portföy işlemleriyle ilişkili iki tür maliyeti; portföy varlıklarının değiştirilmesiyle ilgili komisyon ücretleri ve varlık likiditesizliklerinden kaynaklanan fiyat etkilerini kapsar (Markowitz'in Genişletilmiş Modeli).

Bu tez çalışması, YSA kullanarak finansal varlık fiyat tahminlemesi yöntemlerinin etkinliğini incelemek amacıyla hazırlanmıştır. Günümüz finansal piyasalarının sürekli değişen ve gelişen yapısı, yatırımcılar ve analistler için yeni ve daha sofistike araçlar gerektirmektedir. YSA, bu ihtiyacı karşılamada önemli bir rol oynayabilir. Bu teknolojinin, finansal veri analizi ve tahminlemede nasıl bir etki

yaratabileceğini anlamak, hem teorik açıdan önemli bir katkı sağlayacak hem de pratik uygulamalar için yol gösterici olacaktır. Bu çalışmanın amacı, YSA tabanlı modellerin finansal piyasalarda nasıl etkili bir şekilde kullanılabilirliğini keşfetmek, bu modellerin performansını değerlendirmek ve finansal karar verme süreçlerine nasıl katkıda bulunabileceğini araştırmaktır.

1.1. Araştırmanın Önemi ve Amacı

Finansal piyasaların doğası, sürekli değişen ekonomik koşullar, politik olaylar ve piyasa katılımcılarının davranışları gibi bir dizi karmaşık etmenle şekillenmektedir. Bu etmenler, finansal varlık fiyatlarında ani değişimlere ve tahmin edilmesi zor dalgalanmalara yol açabilmektedir. Bu durum, finansal varlık fiyatlarının doğru bir şekilde tahmin edilmesini ve etkili portföy yönetimi stratejilerinin geliştirilmesini zorunlu kılmaktadır. Bu bağlamda, YSA, finansal piyasalardaki karmaşık desenleri ve ilişkileri modellemek için güçlü bir araç olarak öne çıkmaktadır. YSA'nın finansal tahminleme ve portföy yönetiminde kullanılması, bu alanlardaki geleneksel yöntemlerin sınırlılıklarını aşmayı ve daha doğru, etkili kararlar almayı mümkün kılmaktadır.

Bu tez çalışmasının temel amacı, YSA'nın finansal varlık fiyat tahminlemesi potansiyelini detaylı bir şekilde incelemektir. Araştırmanın hedefi, YSA'nın finansal verilerle nasıl entegre edilebileceğini, bu sistemlerin finansal varlık fiyatları üzerindeki tahmin başarısını ve portföy yönetimi süreçlerinde nasıl etkili bir şekilde kullanılabilirliğini göstermektir. Bu süreçte, YSA'nın finansal piyasalardaki uygulamalarına dair mevcut literatür incelenmekte, yeni yöntemler geliştirilmekte ve bu yöntemler gerçek piyasa verileri üzerinde test edilmektedir.

Bu araştırma, finansal analiz ve portföy yönetimi alanlarına katkıda bulunmayı amaçlamaktadır. YSA'nın finansal varlık fiyat tahminlemedeki etkinliğini değerlendirerek, piyasa katılımcılarına ve araştırmacılara bu teknolojinin potansiyelini ve uygulama alanlarını göstermeyi hedeflemektedir. Ayrıca, YSA tabanlı fiyat tahmini yöntemleri, risk yönetimi ve karar alma süreçlerinde yeni perspektifler sunarak finansal piyasalarda daha bilinçli ve verimli kararlar alınmasına yardımcı olabilir. Bu çalışma, finansal piyasalarda YSA kullanımıyla ilgili teorik ve pratik bilgileri genişletmeyi ve bu alanda gelecekte yapılacak araştırmalara yol göstermeyi amaçlamaktadır.

1.1.1. Finansal varlıkların tanımı ve sınıflandırılması

Finansal varlıklar, yatırımcıların sahip oldukları ve gelecekte bir gelir elde etmeyi amaçladıkları araçlardır. Bu varlıklar genellikle hisse senetleri, tahviller, emtialar ve döviz gibi çeşitli kategorilere ayrılır. Finansal varlıklar, yatırımcılar için değer yaratma amacı taşıırken, piyasa ve ekonomik koşulların etkisiyle farklı risk seviyelerine sahiptir Fama (1970).

Sınıflandırma: Finansal varlıklar genellikle aşağıdaki başlıklarla sınıflandırılabilir:

Hisse Senetleri: Şirketlere ortaklık hakkı veren, piyasalarda alınıp satılabilen finansal araçlardır. Hisse senetleri genellikle yüksek riskli ancak yüksek getiri potansiyeli sunar Sharpe (1964).

Tahviller: Devlet veya şirketler tarafından çıkarılan borçlanma araçlarıdır. Genellikle hisse senetlerinden daha düşük risk taşır, ancak getiri oranları da daha düşüktür.

Emtialar: Altın, gümüş, petrol gibi fiziksel varlıklardır. Bu varlıklar, genellikle ekonomik belirsizlik dönemlerinde güvenli liman olarak görülür.

Döviz: Uluslararası ticaret ve yatırım süreçlerinde önemli bir yer tutan döviz piyasaları, farklı ülke paralarının birbirlerine karşı değer kazançlarını ifade eder.

1.1.2. Portföy yönetiminin temelleri

Portföy yönetimi, yatırımcıların farklı finansal varlıkları bir araya getirerek riskleri dağıtmayı ve en yüksek getiriyi elde etmeyi amaçladıkları süreçtir. Portföy yönetiminin temel amacı, yatırımcının risk toleransına uygun, dengeli bir yatırım stratejisi oluşturmaktır Rubinstein (2002).

Risk ve Getiri İlişkisi: Portföy yönetiminde en önemli iki kavramdır. Risk, varlıkların fiyatlarındaki dalgalanmalardan kaynaklanırken, getiri, yatırımların sağladığı kârı ifade eder. Yatırımcılar genellikle risk-getiri dengesini optimize etmeye çalışırlar. Bu dengeyi sağlamak, doğru varlık sınıflarını ve çeşitlendirmeyi gerektirir.

Çeşitlendirme ve Portföy Teorisi: Çeşitlendirme, portföydeki varlıkların çeşitlendirilerek riskin yayılmasını sağlar. Modern Portföy Teorisi'ne (MPT) göre, portföydeki farklı varlık sınıfları birbirlerini tamamlar ve toplam riski minimize eder Pogue (1969). Çeşitlendirme, aynı zamanda yatırımcının piyasa dalgalanmalarına karşı daha dayanıklı bir portföy oluşturmasına yardımcı olur.

1.1.3. Risk ve getiri ilişkisi

Risk ve getiri arasındaki ilişki, finansal piyasalarda yapılan yatırımların temelini oluşturur. Yatırımcılar, daha yüksek getiri sağlama amacıyla daha yüksek riskleri kabul etmeyi tercih edebilirler. Ancak, bu ilişki her zaman doğrusal olmayabilir ve finansal piyasa koşulları risk-getiri dengesini değiştirebilir Sharpe (1964).

1.1.4. Çeşitlendirme ve portföy teorisi

Çeşitlendirme, yatırımcıların portföylerinde birden fazla varlık sınıfını bulundurması ile sağlanır. Bu yaklaşım, portföyün toplam riskini minimize ederken, getiri oranını artırma potansiyeli sunar. Modern Portföy Teorisi (MPT), yatırımcıların risk ve getiriyi dengelemesi gerektiğini savunur. Bu teori, portföyün çeşitlendirilmesinin riskleri azaltabileceğini, ancak aynı zamanda getiri fırsatlarını da güçlendirebileceğini öne sürer Pogue (1969).

1.1.5. Modern portföy teorisi

Modern Portföy Teorisi (MPT), yatırımcıların riskleri minimize ederken, aynı zamanda getiri oranlarını en üst düzeye çıkarmalarını sağlamak için geliştirilmiş bir teoridir. MPT, Markowitz tarafından 1952'de geliştirilmiştir ve temel olarak portföy çeşitlendirmeyi önermiştir. Bu teori, yatırımcıların yalnızca tek bir varlıkla değil, birden fazla varlıkla yatırım yaparak risklerini nasıl yönetebileceklerini göstermektedir.

MPT, varlıkların beklenen getirilerini, kovaryanslarını ve korelasyonlarını kullanarak portföy riskini hesaplamak için bir matematiksel model sunar. Bu teori, finansal piyasaların etkin ve verimli olduğunu varsayar Fama (1970).

Risk-getiri ilişkisini anlamak, yatırımcıların karar alma süreçlerinde kritik bir rol oynar. Yüksek riskli varlıklar, daha yüksek getiri potansiyeline sahipken, düşük riskli varlıklar genellikle daha düşük getiriler sağlar.

1.2. Tezin Kapsamı

Bu tez çalışmasında BIST 30 ve BIST 100 için 2022 ve 2023 yıllarını kapsayacak şekilde mesai günlerini içeren 501 satırlık veri kullanılmıştır. Bu veriler; tarih, kapanış, açılış, en yüksek, hacim ve değişim olmak üzere 6 adet sütunu içermektedir. Bu sütunlardan 5 tanesini girdi olarak alıp kapanış fiyatını tahmin etmeye çalışılmıştır.

1.3. Tezin Yapısı

Bu tez çalışması, YSA kullanılarak finansal varlık fiyat tahminlemesinin nasıl gerçekleştirilebileceğini ortaya koymak amacıyla yedi ana bölümden oluşmaktadır. Her bir bölüm, araştırmanın farklı bir boyutunu ele alarak bütüncül bir yaklaşım sunmakta ve çalışmanın sistematik bir şekilde ilerlemesini sağlamaktadır.

Birinci bölüm, araştırmanın genel çerçevesini çizmekte olup, çalışmanın amacı, önemi, kapsamı ve araştırmada izlenen yöntem detaylı biçimde sunulmaktadır. Ayrıca bu bölümde, finansal piyasalarda neden yapay zekâ tabanlı modellere ihtiyaç duyulduğu açıklanarak, tezin motivasyonu ortaya konmuştur.

İkinci bölümde, konu ile ilgili gerçekleştirilen literatür taramasına yer verilmiştir. Bu bölümde, daha önce finansal piyasa tahminlemesi ve portföy optimizasyonu konularında yapılan akademik çalışmalar incelenmiş; kullanılan yöntemler, modeller ve bunların avantajları ile sınırlılıkları değerlendirilmiştir. Bu sayede, mevcut bilgi birikimi üzerine inşa edilen bu çalışmanın literatürdeki yeri belirlenmiştir.

Üçüncü bölüm, tezin uygulama kısmına temel oluşturan materyal ve yöntemleri kapsamaktadır. Bu bölümde, kullanılan veri seti, veri ön işleme teknikleri ve analiz süreci detaylı olarak açıklanmıştır. Ayrıca, bu tez çalışması kapsamında geliştirilen yapay sinir ağı modeli (MLP) tanıtılmış ve modelin matematiksel yapısı ile uygulanma şekli ele alınmıştır. Tezin temelini oluşturan MATLAB kodları ile model eğitimi, test süreci ve performans değerlendirme işlemleri gerçekleştirilmiştir. Bu bölüm, aynı zamanda fiyat tahminlemesi sürecinde kullanılan yöntemleri ve performans kriterlerini de içermektedir.

Dördüncü bölüm, araştırma bulgularının değerlendirilmesine ayrılmıştır. Bu bölümde, geliştirilen modelin test verileri üzerindeki başarımı detaylı şekilde analiz edilmiştir. Performans değerlendirmesi; OKH, OMH, OMYH, R-kare, doğruluk, kesinlik ve duyarlılık gibi kapsamlı metrikler üzerinden gerçekleştirilmiştir. Ayrıca, yönsel YDO da incelenerek modelin fiyatların artış/azalış yönünü tahmin etme yeteneği değerlendirilmiştir. Elde edilen sonuçlar doğrultusunda, modelin güçlü ve zayıf yönleri vurgulanmış, finansal tahminleme süreçlerinde uygulanabilirliği üzerine tartışmalara yer verilmiştir.

Bu yapısal bütünlük içinde, tezde kullanılan kod parçacığı, çalışmanın uygulama boyutunu oluşturmakta ve geliştirilen çok katmanlı yapay sinir ağı modelinin MATLAB ortamında nasıl eğitildiğini, test edildiğini ve değerlendirildiğini göstermektedir. Bu yönüyle tez çalışması hem teorik hem de uygulamalı bir çalışma olup; finansal

tahminleme alanında yapay zekâ tekniklerinin etkinliğini ortaya koymayı hedeflemektedir.

2. KAYNAK ARAŞTIRMASI

Bu çalışmada, finansal analiz, piyasa tahmini ve varlık fiyatları hakkında bilgi sağlamak amacıyla önemli bir kaynak araştırması gerçekleştirilmiştir. Finansal piyasalardaki değişkenlik ve belirsizlikler, yatırımcılar ve finans profesyonelleri için her zaman ilgi çekici bir konu olmuştur. Bu nedenle, piyasa analizi ve varlık fiyatlarının tahmini konularında çeşitli akademik kaynaklar, makaleler ve çalışmalar incelenmiştir. Bu kaynaklar, finansal piyasa hareketlerini anlama, gelecekteki fiyat değişikliklerini tahmin etme ve risk yönetimi stratejileri geliştirme konularında değerli bilgiler içermektedir. Bu ön araştırma, çalışmanın temelini oluşturan ve finansal analiz konusundaki bilgi birikimini artıran önemli bir adımdır.

Aksüngü (2023), gıda endüstrisinde ürün fiyatlarının tahmin edilmesi amacıyla YSA modellerini kullanmaktadır. Araştırma, sinir ağı, tekrarlayan sinir ağları, kapılı tekrarlayan sinir ağları ve uzun kısa süreli bellek yöntemleri gibi farklı sinir ağı modellerinin farklı parametre değerleri kullanılarak oluşturulmasını içermektedir. Bu modellerin performansı analiz edilmekte ve karşılaştırılmaktadır. Çalışma, makine öğrenimi modellerinin yanı sıra RPA teknolojisi ile de bütünleşmiş bir şekilde çalışmaktadır. RPA teknolojisi, modellemeyi yapılan R programı ile çalışarak girdi değerlerini alır ve modelleri tetikler. Modellerin çıktı sonuçları, her çalıştırmadan sonra düzenlenerek saklanır. Bu çalışmanın benzeri bir yaklaşımla, çalışmada da kullanılabilir. Özellikle gıda fiyat tahminlemesi konusunda yapay sinir ağı modellerinin kullanımı ve bu modellerin RPA ile entegrasyonu, tez çalışmasında ele alınacak konunun bir örneği olabilir. Çalışma, maliyetleri düşürme ve işlem süreçlerini hızlandırma konularında önemli bir örnek sunmaktadır. Bu çalışmada, gıda endüstrisinde fiyat tahminlemesi konusundaki makine öğrenimi yöntemlerinin uygulanabilirliğini ve etkisini incelemek amaçlanmıştır. Çalışma, farklı sinir ağı modellerinin performansını karşılaştırmak için değişik parametre değerleri kullanarak oluşturulmasına odaklanmaktadır. Bu yöntemleri, tez konusu olan finansal veriler veya hisse senetleri fiyatlarının tahminlemesine uyarlama değerlendirilmektedir. Özellikle YSA modelleri, finansal piyasa tahminlemesi için oldukça uygun bir yaklaşım olabilir. Ayrıca, çalışmanın RPA (Robotik Süreç Otomasyonu) ile nasıl entegre edildiğini inceleyerek, tez çalışmasında benzer bir otomasyon yaklaşımının nasıl uygulayabileceği anlaşılmaya çalışılacaktır. Bu, finansal piyasa verilerinin analizi ve işlem süreçlerinin otomatikleştirilmesi açısından önemli bir

perspektif sunacaktır. Bu çalışma, tezin metodolojisi ve analitik yaklaşımı için değerli bir referans kaynağı olarak kullanılabilir.

Doğan ve Karaçayır (2023), Borsa İstanbul Teknoloji Endeksi'nde yer alan 16 firmanın finansal performansları, TOPSİS ve MABAC yöntemleri ile 2019-2022 yılları arasında değerlendirilmiştir. Finansal oranların değerlendirilmesinde CRITIC yöntemi ile kriterlerin ağırlıkları belirlenmiş ve bu yöntemlerin doğruluğu test edilmiştir. Analizler sonucunda, PAPIL ve ARD Grup firmaları her iki yöntemde de en yüksek performansı sergileyen şirketler olarak öne çıkarken, NETAS en düşük performansa sahip olmuştur. Escom ve Kfein firmalarının ise yıllar içinde performanslarında büyük dalgalanmalar gözlemlenmiştir. Çalışma, TOPSİS ve MABAC yöntemlerinin karşılaştırmalı sıralama sonuçlarının tutarlı olduğunu ve bu yöntemlerin şirketler arasındaki performans farklılıklarını doğru bir şekilde yansıttığını ortaya koymuştur. Ayrıca, çok kriterli karar verme (ÇKKV) yöntemlerinin finansal performans değerlendirmelerinde ne kadar etkili olduğuna dikkat çekilmiş ve farklı ağırlıklandırma yöntemlerinin performans sıralamaları üzerindeki etkileri tartışılmıştır. Sonuç olarak, bu çalışma, Borsa İstanbul'daki teknoloji firmalarının finansal performanslarını değerlendirirken kullanılacak güçlü bir analiz çerçevesi sunmakta olup, finansal karar vericiler ve yatırımcılar için yol gösterici niteliktedir.

Oliveira ve ark. (2013), BM&FBOVESPA'da işlem gören PETR4 (Petrobras) hissesinin kısa vadeli fiyat yönünü tahmin etmek amacıyla geliştirdikleri YSA modeliyle, ekonomik, teknik ve zaman serisi analizlerini birleştirerek yüksek doğruluk oranları (%93,62) elde etmişlerdir. Yön Değişim Tahmini (YDT) metriği ile modelin başarımı değerlendirilmiş ve farklı hisse senetlerine uygulanabilirliği gösterilmiştir. Bu çalışmanın bulguları, hisse senedi piyasasında bilinçli kararlar almak isteyen yatırımcılar ve işlemciler için değerli olabilir. Bu araştırmada kullanılan yöntem, diğer şirketlere ve hisse senedi listelerine de uyarlanabilir ve hisse senedi fiyat davranışını tahmin etme konusunda esnek bir yaklaşım sunar.

Fama (1970), etkin piyasa hipotezini ortaya koyduğu bu çalışmasında, finansal piyasalarda varlık fiyatlarının mevcut tüm bilgileri yansıttığını savunur. Hipotez, yatırımcıların yeni bilgileri çok hızlı ve rasyonel bir şekilde fiyatlara yansıttığını kabul eder. Bu teorik çerçeve, finansal varlıkların analizinde temel bir yapı taşı oluşturmaktadır. Bu nedenle, çalışmada ele alınan finansal analizlerin geçerliliğini sorgularken, piyasa etkinliği varsayımının dikkate alınması önemlidir.

Guresen ve ark. (2011), YSA modellerinin borsa endeks tahmini üzerindeki etkisini arařtırmıřtır. NASDAQ verilerini temel alan alıřmada, farklı YSA mimarileri kıyaslanarak hangilerinin daha etkili tahmin gcne sahip olduėu analiz edilmiřtir. Model performansları OKH ve OMH gibi metrikler kullanılarak lclmřtr. alıřmanın temel amacı, finansal zaman serilerinde hangi yapay sinir aėı trlerinin daha bařarılı tahminler sunduėunu ortaya koymaktır. Bulgular, YSA'nın istatistiksel modellere kıyasla daha doėru tahmin sonuları verdiėini gstermiřtir. Bu ynyle alıřma, yapay zek modellerinin geleneksel yntemler karřısındaki stnlėn vurgulamakta ve tez alıřması kapsamında uygulanabilecek mimari seenekleri deėerlendirmek iin kıymetli bir referans sunmaktadır.

Hashemi ve ark. (2017), derin ėrenme (Deep Neural Networks, DNN) uygulamalarının enerji tketime, tasarım alanı ve doėruluk aısından eřitli numerik hassasiyetler ve kuantizasyonlar üzerindeki etkilerini incelemektedir. alıřma, 32-bit kayan nokta hesaplamadan binary aėırlıklara kadar geniř bir sayı hassasiyeti aralıėı üzerinde yapılan deneysel bir deėerlendirmeyi kapsamaktadır. Tez alıřmasında, farklı bit hassasiyetlerinin aėırlıklar ve giriřler üzerinde nasıl performans deėiřikliklerine yol atıėı arařtırılmakta, daha dřk hassasiyetlerin enerji tketimini nemli lcde azalttıėı ancak doėruluėu kısıtlayabileceėi tartıřılmaktadır. Bununla birlikte, daha byk aėların kullanılması nerilmekte, bu sayede doėruluk kaybının telafi edilebileceėi belirtilmektedir. Sonular, daha dřk hassasiyetlerle yapılan aėların, zellikle enerji tasarrufu ve tasarım alanı aısından tam hassasiyetli aėlarla kıyaslandığında nemli avantajlar sunduėunu gstermektedir. Bu yntemlerin avantajları, CIFAR-10, MNIST ve SVHN gibi yaygın veri setlerinde test edilmiřtir ve ok daha dřk hassasiyetlerin (binary) bile %75'in üzerinde doėruluk elde edebileceėi gsterilmiřtir.

mrz (2019), kripto paraların fiyat modellemesini YSA ile gerekleřtirmeyi amalamaktadır. alıřma, 2017-2019 yılları arasındaki kripto para verilerini kullanarak, YSA ynteminin bu varlıkların fiyat tahmininde nasıl bir performans sergilediėini incelemektedir. Kripto paralara olan ilginin artmasıyla birlikte, bu alandaki fiyat dalgalanmalarının tahmin edilmesi, yatırımcılar ve finansal analistler iin nemli bir konu haline gelmiřtir. alıřmada kullanılan YSA, gemiř fiyat verilerini analiz ederek, gelecekteki fiyatları tahmin etmek iin eėitilmiřtir. Elde edilen sonular, YSA'nın fiyat tahmininde olduka bařarılı olduėunu ve daha fazla veri ile tahminlerin doėruluėunun arttıėını gstermektedir. Tez alıřması, kripto paraların gelecekteki deėerlerinin tahmin edilmesinde YSA'nın kullanılabilirliėini ortaya koymuřtur.

Sarıtaş ve Moralı (2012), İMKB 100 endeksinin gelecekteki değerlerini tahmin etmek amacıyla geleneksel zaman serileri, Newton nümerik arama yöntemleri ve YSA gibi çeşitli yöntemleri karşılaştırmaktadır. Çalışma, 1995-2010 yılları arasındaki günlük verileri kullanarak, faiz oranları, altın fiyatları, bankalararası işlem hacmi ve dolar kapanış fiyatları gibi değişkenleri açıklayıcı değişkenler olarak almıştır. Modelleme için kullanılan yöntemler arasında ARMA(p,q) modelinin yanı sıra, Newton yöntemi ve YSA'nın geri yayılım algoritması yer almaktadır. Sonuçlar, YSA'nın diğer yöntemlere kıyasla daha başarılı olduğunu göstermiştir. YSA ile elde edilen modelin R^2 değeri 0.9987 olarak bulunmuş, bu da modelin yüksek doğrulukla tahminler gerçekleştirdiğini ortaya koymuştur. Newton yöntemi ve ARMA(p,q) ise daha düşük performans sergilemiştir. Çalışma, yeni teknolojilerin, özellikle YSA'nın, geleneksel yöntemlere göre daha güçlü tahminler sunduğunu ve finansal analizlerde giderek daha fazla kullanıldığını vurgulamaktadır.

Kara ve ark. (2010), Türk hisse senedi piyasasında endeks yönünün tahmin edilmesini amaçlayan ve bu kapsamda YSA ile destek vektör makinelerini (DVM) kullanan bir araştırmadır. Çalışmada, İstanbul Menkul Kıymetler Borsası'ndan (İMKB) elde edilen günlük verilerle modeller eğitilmiştir. Kullanılan modellerin doğruluğu çeşitli istatistiksel kriterlerle değerlendirilmiş ve YSA'nın piyasa yönünü tahmin etmede DVM'ye göre daha başarılı olduğu sonucuna varılmıştır. Modelleme sürecinde geçmiş günlerin kapanış fiyatı, işlem hacmi gibi teknik göstergeler kullanılarak veri seti oluşturulmuştur. YSA ve DVM, finansal zaman serilerini modelleme ve tahminleme konusunda başarılı bir şekilde kullanılmıştır. Ancak birçok çalışma, hisse senedi verilerinin büyük gürültüye, durağan olmayan özelliklere ve karmaşık boyutluluğa sahip olmasından dolayı YSA'nın desenleri öğrenmede bazı sınırlamaları olduğunu göstermiştir. Bu nedenle hisse senedi fiyat hareketlerini tahmin etmek oldukça zor bir işlemdir. Bu çalışmanın temel amacı, Türkiye gibi gelişmekte olan pazarlardan gelen verileri kullanarak günlük İstanbul Menkul Kıymetler Borsası (İMKB) Ulusal 100 Endeksi'nin yönünü öngörmektir. İMKB'nin yüksek volatiliteye sahip olması, yerel ve yabancı yatırımcıları yüksek getiri fırsatları sunması nedeniyle dikkat çekmektedir. Bu çalışma, YSA ve DVM kullanarak hisse senedi endeksi yönünün öngörülebilirliğini göstermeyi amaçlamaktadır. Hisse senedi fiyat endeksinin hareketinin tahmin edilmesi, zaman serileri tahminlemenin en zorlu uygulamalarından biri olarak kabul edilir. Daha önce birçok çalışma, hisse senedi fiyat endeksini tahmin etme konusunu ele almış olsa da bu çalışmaların çoğu gelişmiş finansal piyasalarla ilişkilendirilmiştir. Ancak, özellikle

Türk hisse senedi piyasasında gelişen pazarlarda hisse senedi fiyat endeksi hareketinin yönünü tahmin etmeye yönelik literatürde az sayıda çalışma bulunmaktadır. Bu çalışmada, 1997-2007 yılları arasında günlük veriler kullanılarak, YSA ve DVM tabanlı iki farklı model geliştirilmiştir. Her iki model de 10 teknik göstereyi (örneğin, hareketli ortalamalar, RSI, MACD) girdi olarak kullanarak, hisse senedi fiyat endeksinin yönünü (artış ya da azalış) tahmin etmeyi amaçlamaktadır. Yapılan deneysel sonuçlar, YSA modelinin %75,74 doğruluk oranı ile DVM modelinin %71,52 doğruluk oranına göre daha iyi sonuçlar verdiğini göstermiştir. Bu çalışma, makine öğrenmesi tekniklerinin finansal zaman serileri tahmininde etkili bir araç olduğunu ve özellikle YSA'nın hisse senedi endeksi yönü tahmininde daha başarılı olduğunu ortaya koymaktadır.

Taş ve ark. (2021), S&P 500 endeksi üzerinden hisse senedi fiyatlarını tahmin etmek için derin öğrenme ve sığ öğrenme yöntemlerinin karşılaştırılmasını ele almaktadır. Çalışma, Yahoo Finance veri tabanından alınan S&P 500 endeksi verilerini kullanarak, uzun-kısa süreli bellek (UKSB) ve ÇKA yöntemleri ile hisse senedi fiyatlarını tahmin etmeyi amaçlamaktadır. Veriler, 12.08.2000 ile 13.08.2020 tarihleri arasındaki günlük fiyatlarla oluşturulmuştur. Eğitim ve test verisi olarak veri seti %95 eğitim ve %5 test olarak ayrılmıştır. Sonuçlar, her iki yöntemin de benzer eğitim ve test hataları verdiğini ancak UKSB'nin daha başarılı bir tahmin performansı gösterdiğini ortaya koymaktadır. UKSB için ortalama hata 17,3 dolar, test aşamasında ise 65,3 dolar olarak bulunmuştur. ÇKA için ise eğitim ve test hataları sırasıyla 16,1 ve 61,2 dolar olmuştur. Çalışma, her iki modelin de hisse senedi tahmininde etkili olduğunu, ancak UKSB'nin özellikle daha uzun vadeli bağımlılıkları modelleme gücünden dolayı üstün performans sergilediğini belirtmektedir.

Metin (2021), derin öğrenme yöntemlerinden Uzun Kısa Süreli Bellek (UKSB) ağını kullanarak Vestel firmasının hisse senedi fiyatlarının tahmin edilmesini amaçlamaktadır. Çalışmada, 2016-2021 yılları arasındaki günlük hisse senedi fiyat verileri kullanılmış ve UKSB modeli ile açılış fiyatlarının tahmin edilmesi gerçekleştirilmiştir. Eğitim verisi olarak %80'lik dilim, test verisi olarak ise %20'lik dilim kullanılmıştır. Model, açılış fiyatlarını 0,0050 hata oranıyla tahmin etmiştir ve bu süreçte UKSB, giriş, ara ve çıkış katmanlarında Python programlama dili kullanılarak eğitilmiştir. Modelin doğruluk oranı %95 olarak belirlenmiş ve eğitim verisi arttıkça modelin doğruluğunun daha tutarlı olduğu gözlemlenmiştir. Ayrıca, farklı aktivasyon fonksiyonları (sigmoid ve relu) kullanılarak, relu fonksiyonunun daha hızlı ve tutarlı sonuçlar verdiği bulunmuştur. Sonuçlar, daha fazla eğitim verisi kullanıldıkça modelin

daha doğru tahminler yaptığı ve UKSB modelinin hisse senedi tahminlerinde oldukça etkili olduğunu ortaya koymuştur.

LeCun ve ark. (2015), derin öğrenmenin yapısını ve temel bileşenlerini açıklayarak bu alandaki gelişmeleri özetlemiştir. YSA'nın derin mimarilerle nasıl güçlendirilebileceğini ve bu yapıların görüntü tanıma, konuşma tanıma gibi alanlarda nasıl kullanıldığını detaylandırmıştır. Çalışma, tezde kullanılacak olan yapay zekâ algoritmalarının teorik temelini desteklemektedir.

Rubinstein (2002), modern portföy teorisinin temelini atmıştır. Bu teori, yatırımcıların portföylerini çeşitlendirerek risklerini minimize etmelerini ve getiri beklentilerini maksimize etmelerini önerir. Beklenen getiri ve varyans hesapları aracılığıyla en uygun portföy kombinasyonlarını belirlemek için matematiksel bir çerçeve sunar. Bu çalışma, tez kapsamında ele alınan portföy optimizasyonu süreçlerinde teorik temel olarak kullanılacaktır.

Moghaddama ve ark. (2016), NASDAQ borsasına ait günlük endeks verileriyle ileri beslemeli yapay sinir ağı (feed forward neural network) modelini kullanarak kısa vadeli tahminleme gerçekleştirmiştir. Çalışmada, ağ yapısının eğitiminde geri yayılım algoritması (backpropagation) kullanılmıştır. Model, geçmiş fiyat verilerinin yanı sıra haftanın günü gibi zamansal değişkenleri de girdi olarak kullanarak tahmin sürecini geliştirmiştir. Eğitim sürecinde veriler belirli pencere boyutlarına ayrılmış ve bu yapı altında tahminleme işlemi gerçekleştirilmiştir. Elde edilen sonuçlar, kısa vadeli tahminlerde YSA'nın anlamlı bir başarıya sahip olduğunu göstermektedir. Bu modelleme yaklaşımı, zamansal etkilerin de dikkate alınarak finansal tahminleme sistemlerine entegre edilmesinin önemini vurgulamaktadır. Tez çalışması kapsamında kullanılacak bu çalışma, kısa vadeli fiyat tahminlerinin nasıl yapılabileceğine dair metodolojik bir çerçeve sunmaktadır.

Sharpe (1964), sermaye varlıkları fiyatlama modelinin (Capital Asset Pricing Model) temelini atmış ve finansal piyasalarda risk ile beklenen getiri arasındaki ilişkiyi açıklamıştır. Sharpe'ın bu katkısı, yatırımcıların risk primi kavramını anlamasını sağlamış ve finansal varlıkların nasıl fiyatlandığına dair temel bir çerçeve sunmuştur. Çalışma, portföy teorisinin pratik uygulamaları açısından kritik öneme sahiptir ve sermaye maliyeti ile yatırım kararları arasındaki bağlantının analizinde sıklıkla referans alınmaktadır. Bu nedenle, tez kapsamında yer alan portföy optimizasyonu ve risk-getiri değerlendirmelerinde Sharpe'ın ortaya koyduğu bu model esas alınacaktır.

Songün ve Akbalık (2023), BIST 30 endeksinde yer alan hisse senetlerinin geçmiş piyasa verilerine dayanarak gelecekteki değerlerini tahmin etmeyi amaçlamış; özellikle 2001 ekonomik krizi ve 2020 pandemi dönemlerini içeren veri setleriyle makine öğrenimi algoritmalarının etkinliğini test etmiştir. Bu çalışma, zaman aralığı ve kapsam açısından geniş ve tez için güçlü bir metodolojik örnek teşkil etmektedir. Bu çalışma tezde kullanılabilecek önemli bir referans kaynağıdır. Özellikle finansal verileri işlemek ve gelecekteki fiyat tahminlemesi yapmak amacıyla kullanılan yapay zekâ ve makine öğrenimi algoritmalarına dair bir örnek sunmaktadır. Burada kullanılan modellerin karşılaştırılması kullanım avantajları ve sınırlılıkları araştırmaya yön vermiştir. Ayrıca, bu çalışma ile planlanan tez çalışmasındaki metotlar ve veri setleri karşılaştırılarak yöntemlerdeki benzerlik ve farklılıklar karşılaştırılacaktır. Bu makale, tezin teorik temellerini güçlendirmeye ve araştırmanın önemini vurgulamaya yardımcı olacaktır.

Zhang ve ark. (1998), YSA ile zaman serisi tahmini alanındaki literatürü derinlemesine analiz etmiştir. Bu çalışma, YSA'nın güçlü yönleri, sınırlamaları, mimari tercihleri ve veri ön işleme teknikleri gibi birçok konuyu kapsamaktadır. Ayrıca, farklı uygulama alanlarındaki başarı örnekleriyle birlikte, tahmin performansını etkileyen faktörleri de detaylı şekilde tartışmaktadır. Literatürdeki çeşitli uygulamalardan elde edilen deneyimlere dayanarak, YSA'nın istatistiksel modellere göre daha esnek ve güçlü olduğu vurgulanmaktadır. Tez çalışması kapsamında kullanılacak olan sinir ağı mimarilerinin ve veri işleme süreçlerinin planlanmasında bu çalışma rehber niteliğindedir.

Adepoju ve ark. (2007), Nijerya Elektrik Gücü Sistemi'nde kısa vadeli yük tahmini yapmak için YSA kullanımını incelemektedir. Çalışmada, 2003 yılı ağustos ayında Power Holding Company of Nigeria (PHCN) tarafından sağlanan geçmiş yük verileri kullanılarak YSA ile bir tahmin modeli oluşturulmuştur. Model, her bir saatin yük talebini tahmin etmek için girdi olarak önceki saat, önceki gün, önceki hafta yük verileri ve günün saati gibi parametreleri kullanmaktadır. Sinir ağı, üç katmandan oluşmaktadır: giriş, gizli ve çıkış katmanları. Giriş katmanında 5 nöron bulunurken, gizli katmandaki nöron sayısı modelin performansına göre değiştirilebilmektedir. Çalışmada, 11 nöronlu bir gizli katman, modelin en iyi performansı verdiği bulunmuştur. YSA modelinin doğruluğu, test verileri ile yapılan testlerde %2.54'lik OMH ile yüksek doğruluk oranı elde edilmiştir. Sonuçlar, YSA'nın elektrik yük tahmininde başarılı bir model olduğunu ve Nijerya'daki elektrik yükü tahmini için etkili bir araç sağladığını ortaya koymuştur.

2.1. Portföy Optimizasyonu Yaklaşımları

Portföy optimizasyonu, yatırımcıların hedeflerine ulaşmalarına yardımcı olan çeşitli yaklaşımlar içerir. Bu yaklaşımlar arasında, Modern Portföy Teorisi'nin klasik optimizasyon modelinden YSA tabanlı yaklaşımlara kadar geniş bir yelpazede seçenekler bulunur. YSA, finansal piyasalarda karmaşık ilişkileri modelleme ve büyük veri setlerini analiz etme konusunda etkili bir araçtır LeCun ve ark. (2015). Bu yaklaşım, özellikle finansal piyasalarda belirsizlik ve değişkenliğin olduğu durumlarda daha esnek ve adaptif kararlar alabilmektedir.

Yapay zekâ ve makine öğrenimi teknikleri, portföy optimizasyonu için yeni nesil çözümler sunmakta ve bu yöntemler geleneksel portföy optimizasyonuna kıyasla daha dinamik ve değişken piyasa koşullarına uyum sağlayabilmektedir Zhang ark. (1997).

Doğan ve Büyükkör (2022), finansal zaman serisi tahminlemesi konusunda makine öğrenmesi yöntemlerinin karşılaştırmasını sunmaktadır. Çalışmada, destek vektör regresyonu, rassal orman ve ekstrem gradyan artırma gibi makine öğrenmesi yöntemleri, gelişmiş ve gelişmekte olan iki borsa endeksi ile Borsa İstanbul'da işlem gören yüksek hacimli hisse senetleri üzerinde test edilmiştir. Sonuçlar, SVR yönteminin OMH, KOMH ve OMYH gibi performans kriterleri açısından diğer yöntemlerden daha iyi sonuçlar verdiğini göstermektedir. Çalışmada, ayrıca hiper parametre optimizasyonu kullanılarak parametre ayarlamalarının tahmin performansı üzerindeki etkisi de vurgulanmıştır. Bu çalışma, finansal zaman serisi tahminlemesinde makine öğrenmesi yöntemlerinin önemli bir araç olduğunu ve özellikle SVR yönteminin finansal piyasalarda etkili tahminler yapabilme potansiyeline sahip olduğunu ortaya koymuştur.

Qiu ve Song (2016), Japon hisse senedi piyasasında endeks yönünü tahmin etmek amacıyla optimize edilmiş bir yapay sinir ağı modeli geliştirmiştir. Çalışmada genetik algoritmalar, modelin giriş değişkenlerini belirlemek için kullanılmış ve bu sayede tahmin doğruluğu artırılmıştır. Modelde yer alan değişkenler, piyasa göstergeleri ve geçmiş fiyat verilerinden türetilmiştir. Yapılan deneyler, genetik algoritmalar ile optimize edilmiş YSA modelinin klasik modellere kıyasla daha yüksek tahmin doğruluğuna sahip olduğunu göstermiştir. Bu çalışma, finansal piyasalarda yön tahmini yapılırken değişken seçiminin ne kadar kritik olduğunu ve YSA'nın bu tür öngörülerdeki potansiyelini ortaya koymaktadır. Tez çalışması kapsamında benzer şekilde finansal verilerde doğru özellik seçiminin sağlanması, tahmin başarımını artırmak için kritik bir adım olarak değerlendirilmektedir.

Ustalı ve ark. (2020), tarafından yapılan bir çalışmada, Borsa İstanbul 30 Endeksi'nde işlem gören firmaların hisse senedi fiyatları, YSA, Rastgele Orman (RO) algoritması ve XGBoost algoritması kullanılarak tahmin edilmiştir. Çalışma, bu üç makine öğrenmesi tekniğinin performanslarını karşılaştırmış ve XGBoost algoritmasının diğer iki yönteme göre daha iyi sonuçlar verdiğini göstermiştir. YSA'nın doğrusal olmayan ilişkileri modelleme yeteneği, finansal verilerdeki karmaşık ilişkileri çözmek için önemli bir avantaj sağlasa da bu çalışmada YSA'nın performansı XGBoost ve RO algoritmalarının gerisinde kalmıştır. Bu bulgular, portföy optimizasyonu ve hisse senedi fiyat tahmini gibi finansal analizlerde XGBoost ve RO algoritmalarının kullanılabilirliğini vurgulamaktadır.

Zorlu (2022), finansal piyasalardaki volatilité düzeylerinin tahmin edilmesine yönelik yaptığı karşılaştırmalı çalışmada, farklı modelleme yaklaşımlarının risk yönetimi çıktıları üzerindeki etkilerini değerlendirmiştir.

3. MATERYAL VE YÖNTEM

Bu bölümde, finansal varlık fiyat tahmini süreçlerinde kullanılan ÇKA yapay sinir ağı modelinin geliştirilmesi, veri setinin hazırlanması ve performans değerlendirme metriklerinin detaylı bir şekilde açıklanması yer almaktadır. BIST 30 ve BIST 100 endeksleri için kullanılan 501 satırlık veri seti, finansal piyasa hareketlerini modellemek amacıyla uygun şekilde ön işleme tabi tutulmuş ve ÇKA tabanlı modelle, fiyat tahminleme için çözüm önerileri sunulmuştur. Ayrıca, modelin başarısını değerlendirmek için OKH, OMH, R, doğruluk, kesinlik, duyarlılık ve YDO gibi metrikler kullanılmıştır.

3.1. Veri Toplama ve Veri Ön İşleme

Finansal verileri toplamak için birçok veri elde etme yöntemi vardır. Bunlar arasında başlıca seçilen yöntemler aşağıdaki gibidir.

- Borsa Verileri: BIST100, BIST30 verilerini, Borsa İstanbul Web Sitesi'nden kamuya açıklanan kısımlardan çekerek tez çalışmasına girdi olarak kullanılmıştır.
- Finansal Veri Sağlayıcıları: Profesyonel finansal veri sağlayıcıları, hisse senetleri, endeksler, para birimleri, tahviller ve diğer finansal enstrümanlarla ilgili gerçek zamanlı veya tarihsel verileri sağlar. Bunlara örnek olarak, Bloomberg, Reuters vb elde edilecek veriler gösterilebilir.
- Kamu Verileri: Üniversiteler, Merkez Bankaları ya da Kamu Kurumları finansal verilere erişim sağlayan açık veri kaynakları sunmaktadır. Buralardan elde edilecek verileri de analizlerde kullanabilir.
- Ücretsiz Finansal Veri Sağlayıcıları: Buralardan, hisse senedi fiyatları, endeksler, döviz kurları, finansal haberler gibi önemli finansal bilgilere erişim sağlanır. Yahoo Finance, Google Finance, Investing.com, Alpha Vantage ve Quandl gibi kaynaklar, araştırmacılar ve geliştiriciler için kullanışlıdır. Ancak, kullanım politikalarını ve veri kapsamını incelemek önemlidir, çünkü ücretsiz veri sunumu sınırlı olabilir.

Bu çalışmada, yukarıda belirtilen veri kaynaklarından kamuya açık ve kolay erişilebilir olanlarından BIST 100 ve BIST 30 seçilmiştir. Bu veriler, 501 satırlık 2022 ve 2023 mesai günleri verilerini içermektedir.

Bu çalışmada, BIST 30 ve BIST 100 endekslerine ait 2022-2023 yıllarındaki kapanış fiyatlarını tahmin etmek amacıyla 501 satırlık bir veri seti kullanılmıştır. Veri

seti; tarih, kapanış fiyatı, açılış fiyatı, en yüksek fiyat, hacim ve değişim oranı olmak üzere altı değişken içermektedir. Veri seti üzerinde aşağıdaki ön işlemler gerçekleştirilmiştir:

- Eksik verilerin temizlenmesi,
- Sütun İsimlerini Düzenleme,
- Tarih Formatı Dönüşümü,
- Veri Tipi Dönüşümü (Sayısallaştırma),
- Veri Setinin Ayırıştırılması (K Katlı Doğrulama),
- Zaman serisi analizine uygun hale getirilmesi.

3.2. Yapay Sinir Ağı Modeli Geliştirme

Bu çalışmanın en temel ve ikinci aşaması, finansal verilerin analizi için kullanılacak YSA modelinin geliştirilmesidir. YSA, biyolojik sinir sisteminden esinlenerek oluşturulan yazılım modelleridir ve finansal verilerin karmaşıklığını yakalamak için ideal bir araçtır. Bu bölümde, veri toplama aşamasından sonra elde edilen veriler, YSA'nın eğitilmesi için kullanılmıştır.

YSA modelinin geliştirilmesi, dikkatlice planlanmış bir süreçtir. İlk olarak, ağın mimarisi belirlenir. Bu, katmanların sayısı, her katmandaki nöron sayısı ve bağlantılar arasındaki ağırlıkların belirlenmesini içerir. Ayrıca, hangi aktivasyon fonksiyonlarının kullanılacağı ve hangi öğrenme algoritmalarının tercih edileceği önemli kararlar arasındadır. Bu kararlar, modelin performansını büyük ölçüde etkiler.

Geliştirilen YSA modeli, finansal varlık fiyat tahminlemesi için kullanılmıştır. Modelin işlevi, geçmiş verilere dayalı gelecekteki fiyat hareketlerini tahmin etmek ve yatırım portföyünü optimize etmek için kullanıcıya yardımcı olmaktır. Bu aşama, finansal analizin temelini oluşturur ve çalışma sonuçlarının güvenilirliğini artırmak amacıyla dikkatle tasarlanmalıdır. Bu modelin geliştirilmesi, finansal verilerin derinlemesine analizi için bilişim teknolojisinin gücünün nasıl kullanılabileceğini vurgular.

YSA geliştirilmesi ile alakalı bir miktar detaya değinirsek; YSA, bilgisayar bilimlerinde ve veri analizinde oldukça etkili bir rol oynayan, insan beyninin işleyişinden esinlenen bir modeldir. YSA, temel olarak sinir hücreleri arasındaki bağlantıları taklit eden bir ağ yapısına dayanır. Bu ağ yapısı, öğrenme ve problemleri çözme yeteneği kazanmak için giriş verilerinden çıktı üretme yeteneğini içerir. YSA'nın gelişimi, özellikle 20. yüzyılın ikinci yarısında artan bilgisayar gücü ve büyük veri setlerine erişimle hız kazandı. İlk başlarda sınırlı sayıda nöron içeren basit modellerle başlayan

YSA, günümüzde karmaşık ve derin mimarilere sahip Derin Öğrenme (Deep Learning) alanında zirveye ulaşmıştır LeCun ve ark. (2015).

YSA'nın finansal veri analizi gibi alanlarda kullanılmasındaki etkileyici gelişmeler, büyük veri setlerinin işlenmesi ve karmaşık ilişkilerin modellenmesi için ideal olduklarını göstermektedir. Yatırım stratejilerinden hastalık teşhisine kadar geniş bir uygulama yelpazesi bulunan YSA, özellikle finansal piyasalardaki karmaşık trendleri ve fiyat hareketlerini tahmin etmek için kullanıldığında dikkat çekmektedir. Bu yöntem, geçmiş verilere dayalı olarak gelecekteki eğilimleri anlama yeteneği ile öne çıkmakta ve karar alma süreçlerine değerli bir rehberlik sağlamaktadır.

3.2.1. Çok katmanlı algılayıcı (ÇKA)

ÇKA, ileri beslemeli yapay sinir ağı (feedforward ANN) sınıfına giren ve denetimli öğrenmeye (supervised learning) dayalı çalışan bir modeldir. ÇKA, doğrusal olmayan ilişkileri öğrenebilme yeteneği sayesinde özellikle finansal zaman serisi verileri gibi karmaşık ve gürültülü yapıların modellenmesinde sıkça tercih edilmektedir Zhang ve ark. (1997). Bu çalışmada ÇKA mimarisi, BIST 30 ve BIST 100 endekslerinin fiyat tahmini amacıyla kullanılmıştır.

ÇKA modelinin başarımı, yalnızca mimari yapısına değil, aynı zamanda hiperparametre seçimlerine de bağlıdır. Bu tez çalışmasında, modelin en iyi performansı göstermesi için hiperparametre optimizasyonu gerçekleştirilmiştir. Deneysel süreçte öğrenme oranı, batch boyutu, epoch sayısı, gizli katman sayısı ve nöron sayısı gibi kritik hiperparametreler farklı kombinasyonlarla test edilmiştir. Optimizasyon sürecinde 10 katlı çapraz doğrulama yöntemi kullanılarak en uygun hiperparametreler belirlenmiştir. Öğrenme oranı için 0.01, 0.001 ve 0.0005 gibi değerler denenmiş; en iyi sonuç 0.001 öğrenme oranı ile elde edilmiştir. Batch boyutu olarak 32 ve 64 değerleri karşılaştırılmış, modelin genel doğruluk ve kayıp değerleri göz önünde bulundurularak batch size = 32 kullanılmıştır. Model, 100 epoch boyunca eğitilmiş ve aşırı öğrenme riskine karşı erken durdurma uygulanmıştır. Optimizasyon algoritması olarak Adam tercih edilmiştir. Bu hiperparametre kombinasyonu, modelin hem eğitim sürecini kararlı hale getirmiş hem de test verilerindeki genelleme performansını artırmıştır.

Giriş katmanını, en az bir gizli katman ve bir çıkış katmanı izler. Her bir katmandaki nöronlar, bir sonraki katmana ağırlıklı bağlantılar aracılığıyla bilgi iletir. Aktivasyon fonksiyonu olarak genellikle doğrusal olmayan fonksiyonlar tercih edilmekte olup, bu çalışmada DLB (Rectified Linear Unit) fonksiyonu kullanılmıştır. ÇKA

modelinin başarımı, yalnızca ağ yapısına değil, aynı zamanda öğrenme sürecinde uygulanan optimizasyon algoritmalarına da bağlıdır. Bu noktada, geleneksel gradyan temelli yaklaşımların yanında meta-sezgisel algoritmalarla yapılan eğitimler de literatürde dikkat çekmektedir. Gülcü (2020), States of Matter Search algoritmasını ÇKA ağırlıklarının optimizasyonu için uygulamış ve bu yaklaşımın doğruluk oranlarını artırmada etkili olduğunu göstermiştir. Benzer şekilde, Atlı (2022), Salp Sürüsü Optimizasyon algoritmasını ÇKA eğitimi için uyarlamış ve modelin performansını anlamlı ölçüde iyileştirdiğini raporlamıştır. Bu bağlamda, çalışmamızda kullanılan ÇKA modeli de DLB aktivasyon fonksiyonu ve Adam optimizasyon algoritması ile eğitilmiş; klasik hata metriklerinin yanında yönelime dayalı performans ölçütleriyle de değerlendirilmiştir.

ÇKA modeli temel olarak üç ana bileşenden oluşur:

Girdi Katmanı: Modelin aldığı özellikler bu katmanda yer alır. Tahmin edilecek finansal verinin zaman serisine ait geçmiş değerlerini alır. Örneğin: Kapanış fiyatı, işlem hacmi, gün içi en yüksek ve en düşük değerler gibi. Bu çalışmada her örnek, zaman gecikmeli olarak modellenmiş belirli sayıda özelliği temsil eder.

Girdi Vektörü: Girdi vektörü Denklem 3.1’de gösterilmektedir.

$$\vec{x} = [x_1, x_2, \dots, x_n] \quad (3.1)$$

x_i : i'ninci girdi özelliği (Örneğin geçmiş günün kapanış fiyatı)

n : Toplam girdi sayısı

Gizli Katman: Bu katmanlarda yer alan nöronlar, giriş verisindeki desenleri öğrenir. Gizli katman sayısı ve nöron sayısı, modelin ifade gücünü belirler. Çok sayıda katman, derin öğrenme yaklaşımını temsil ederken; aşırı katmanlı yapılar aşırı öğrenmeye (overfitting) sebep olabilir. Her nöron, önceki katmandan gelen girdileri ağırlık ve bias ile işler. Denklem 3.2’de gizli katmanın denklemi yer almaktadır.

$$h_j = f\left(\sum_{i=1}^n (w_{ij}x_i + b_j)\right) \quad (3.2)$$

h_j : j'ninci nöronun çıktısı

f : Aktivasyon fonksiyonu

w_{ij} : i-girdisinden j-nöronuna ait ağırlık değeri

b_j : j'ninci nöronun bias terimi

Çıkış katmanı: İlgili günün kapanış fiyatı gibi hedef değişkeni tahmin eder. Bu katmandaki aktivasyon fonksiyonu genellikle regresyon problemleri için lineer, sınıflandırma problemleri için ise softmax veya sigmoid şeklinde seçilir. Çıkış katmanı Denklem 3.3'te formülize edilmiştir.

$$\hat{y} = \sum_{j=1}^m (w_j h_j + b) \quad (3.3)$$

\hat{y} : Tahmin edilen kapanış fiyatı

w_j : j'ninci gizli nöronun çıkışa gelen ağırlık

h_j : j'ninci nöronun çıktısı

b : Çıkış katmanındaki bias terimi

m : Gizli katmandaki nöron sayısı

Mimari Özellikler ve Modelleme

Bu çalışmada kullanılan ÇKA modeli aşağıdaki özelliklere göre yapılandırılmıştır:

Katman Yapısı: Giriş katmanında n adet nöron, ardından iki gizli katman ve çıkışta tek nöron bulunmaktadır.

Aktivasyon Fonksiyonu: Gizli katmanlarda DLB fonksiyonu kullanılmıştır. DLB, hem hesaplama açısından verimli hem de gradyan sönmesi (vanishing gradient) problemini azaltmada etkilidir LeCun ve ark. (2015). Çıkış katmanında ise tahmin problemi regresyon türünde olduğu için lineer aktivasyon tercih edilmiştir. Denklem 3.4'te DLB gösterilmiştir.

$$DLB(z) = \max(0, z) \quad (3.4)$$

Kayıp Fonksiyonu: OKH kullanılmıştır. OKH, tahmin edilen değer ile gerçek değer arasındaki farkın karelerinin ortalamasını alarak modelin ne kadar yanıldığını ölçer.

Öğrenme Algoritması: Modelin ağırlık güncellemeleri için Adam optimizasyon algoritması tercih edilmiştir. Bu algoritma, öğrenme hızını dinamik olarak ayarlayarak daha hızlı ve kararlı öğrenme sağlar.

Normalizasyon: Girdi verileri, öğrenme sürecini hızlandırmak ve farklı ölçeklerin modele etkisini azaltmak amacıyla Z-skoru normalizasyonuna tabi tutulmuştur ve formülü Denklem 3.5'te gösterilmiştir.

$$z = \frac{x - \mu}{\sigma} \quad (3.5)$$

z: Z-Skoru

μ : ortalama

σ : standart sapma

Eğitim ve Test Süreci

Veri seti, 10 katlı çapraz doğrulama (10-fold cross validation) yöntemiyle eğitim ve test olmak üzere katmanlara ayrılmıştır. Eğitim sırasında model, geçmiş günlere ait kapanış, açılış, hacim gibi özellikleri öğrenmiş ve ertesi günün kapanış fiyatını tahmin etmeyi hedeflemiştir. Modelin doğruluğu, test verileri üzerinden hesaplanan OKH, OMH ve R^2 metrikleri ile ölçülmüştür. Ayrıca, hiperparametre optimizasyonu için 10-fold çapraz doğrulama yöntemi uygulanmıştır.

Ortalama Mutlak Hata Denklem 3.6'da gösterilmiştir.

$$MAE = \frac{1}{N} \sum_{i=1}^N (|y_i - \hat{y}_i|) \quad (3.6)$$

R-Kare (R^2) Denklem 3.7'de gösterilmiştir.

$$R^2 = 1 - \frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{\sum_{i=1}^N (y_i - \bar{y})^2} \quad (3.7)$$

y_i : Gerçek Değer

\hat{y}_i : Tahmin Edilen Değer

N: Örnek sayısı

\bar{y} : Gerçek Değerlerin Ortalaması

Sözde Kod (Pseudocode):

Başla

Girdi: Zaman serisi verisi (X), Gerçek sonuçlar (Y)

Normalize et X verisini (Z-skoru ile)

ÇKA modelini oluştur:

Giriş katmanı: n adet özellik

Gizli katman 1: DLB aktivasyonlu d1 nöron

Gizli katman 2: DLB aktivasyonlu d2 nöron

Çıkış katmanı: lineer aktivasyon

Derle model:

Kayıp fonksiyonu = OKH

Optimizasyon = Adam

Modeli eğit:

Eğitim verisiyle epochs boyunca besle

Her epoch sonunda doğrulama kaybını kontrol et

Modeli test et:

Test verileri ile tahmin yap

OKH, OMH, R² metriklerini hesapla

Bitir

Bu yapı, ÇKA'nın finansal zaman serilerinde regresyon problemi çözme gücünü gösterir. Modelin sadeliği, hibrit yaklaşımlara entegre edilebilirliğini de artırır. Ayrıca, ileri seviye optimizasyon veya model genişletme gibi stratejilere temel teşkil eder.

Yılmaz (2006), ÇKA yapısının portföy optimizasyonu süreçlerinde başarılı sonuçlar verdiğini ve finansal piyasalarda karar destek aracı olarak etkin biçimde kullanılabileceğini göstermiştir.

ÇKA modeli, finansal zaman serilerindeki karmaşık doğrusal olmayan ilişkileri öğrenebilme kapasitesi, kolay uygulanabilirliği ve yorumlanabilirliği sayesinde bu çalışmada etkili bir araç olarak kullanılmıştır. Modelin sade yapısı, ileride geliştirilecek hibrit modeller için güçlü bir temel oluşturmuştur.

3.3. Fiyat Tahminlemesi

Çalışmanın bir diğer önemli aşaması, fiyat tahminlemesi sürecini içermektedir. Fiyat tahminlemesi, yatırımcıların finansal varlıkların gelecekteki değerlerini öngörmelerine yardımcı olan kritik bir adımdır ve yatırım stratejilerinin oluşturulmasında büyük bir rol oynar. Bu aşama, ÇKA modelinin çıktılarına dayanarak hisse senedi fiyatlarının ileriye dönük tahminlerini üretmeyi amaçlar. Doğru fiyat tahminleri, yatırım

kararlarının daha bilinçli şekilde alınmasını sağlar ve böylece yatırımcıların daha iyi finansal sonuçlara ulaşmalarına yardımcı olur.

Fiyat tahminlemesi, finansal varlıkların geçmiş performansı, gelecekteki eğilimleri ve aralarındaki ilişkiler dikkate alınarak gerçekleştirilmelidir. Bu süreç, yatırımcıların farklı varlık sınıflarındaki (örneğin; hisse senetleri, tahviller, emtialar vb...) fiyat hareketlerini öngörmelerine yardımcı olur. Ayrıca, farklı risk toleranslarına sahip yatırımcıların ihtiyaçlarına ve hedeflerine uygun stratejiler geliştirme esnekliği sunar.

Yavuz (2012), portföy optimizasyonu sürecinde YSA'nın etkinliğini vurgulayarak, risk-getiri tahminlerinde %1'in altındaki hata oranlarına ulaşan başarılar elde ettiğini göstermiştir. Ayrıca, bu çalışma, YSA'nın, geleneksel optimizasyon yaklaşımlarına kıyasla daha hızlı adaptasyon sağladığını ve piyasa koşullarına duyarlı kararlar alabildiğini gözler önüne serdi. YSA, doğrusal olmayan ilişkileri modelleme kapasitesi ile portföy optimizasyonunu daha esnek ve uyarlanabilir bir hale getirmektedir.

Fiyat tahminlemesi, finansal analizde kritik bir rol oynamakta olup yatırım kararlarının temellendirilmesinde önemli bir araçtır. Çalışmanın bu aşaması, ÇKA tabanlı yapay sinir ağı modelinin finansal varlık fiyatlarının öngörülmesi ile birleşerek güçlü ve bilişim destekli yatırım stratejileri oluşturulmasına katkı sağlar. ÇKA, doğrusal olmayan ilişkileri modelleme kapasitesi ile geleneksel tahminleme yaklaşımlarına kıyasla daha dinamik ve esnek bir yapı sunar.

Fiyat tahminlemesi sürecinde, finansal zaman serisi analizine dayalı olarak ÇKA destekli modeller kullanılmıştır. Amaç, fiyat hareketlerini mümkün olan en düşük hata ile tahmin etmektir. Geleneksel regresyon modellerine kıyasla, YSA piyasadaki karmaşık ve doğrusal olmayan yapıları daha iyi modelleyebilmekte, bu da daha doğru ve tutarlı sonuçlar elde edilmesini sağlamaktadır. Bu çalışmada, klasik tahminleme yöntemleri ile ÇKA tabanlı modeller karşılaştırılmış; YSA'nın piyasa koşullarına daha hızlı ve etkili uyum sağladığı gözlemlenmiştir.

Özellikle ÇKA tabanlı fiyat tahminleme modeli, gelecekteki piyasa hareketlerini tahmin etmek ve yatırım stratejilerini buna göre şekillendirmek açısından etkili bir yöntem olarak öne çıkmaktadır. Geleneksel modellerin genellikle sabit varsayımlara dayandığı durumlarda, ÇKA destekli tahmin süreçlerinin daha esnek ve değişken piyasa koşullarına duyarlı olduğu görülmüştür. Bu sayede yatırımcılara daha sağlam ve zamanında kararlar alma imkânı tanınmaktadır.

3.4. Risk Yönetimi

Bu çalışmanın bir diğer önemli yönü, risk yönetim sürecidir. Risk yönetimi, finansal varlıklara yatırım yaparken karşılaşılabilecek olası riskleri tanımlamayı, ölçmeyi ve yönetmeyi amaçlar. Yatırım dünyasında, herhangi bir kararın potansiyel riskleri ve getirileri göz önünde bulundurarak alınması esastır. Bu aşama, finansal veri analizi ve yapay sinir ağı modelinin çıktılarına dayanılarak, yatırım portföyünün maruz kalabileceği riskleri belirlemek ve bu riskleri sınırlamak için tasarlanmıştır.

Risk yönetimi, yatırımcıların karşılaştığı belirsizlikleri tanımlamak, ölçmek ve bu riskleri etkin bir şekilde yönetmek için kullanılan kritik bir süreçtir. Yatırımcılar, finansal varlıklara yaptıkları yatırımların değerini korumak amacıyla, riskleri minimize etme stratejileri geliştirmelidir. Modern finansal teoriler, yatırımcıların risklerini anlamalarına ve bu risklere uygun stratejiler geliştirmelerine yardımcı olmak için çeşitli yöntemler sunmaktadır. Bu süreç, yatırımcıların karar alırken finansal piyasalarda karşılaştıkları belirsizlikleri yönetmelerine ve portföylerini güvence altına almalarına olanak tanır Pogue (1969).

Risk yönetiminin temel amacı, yatırımcıların portföylerini optimize etmek ve bu portföylerin riskiyle uyumlu bir getiri elde etmelerini sağlamaktır. Çalışmamızda, YSA tabanlı modellerin, geleneksel risk yönetimi yaklaşımlarına göre daha esnek ve adaptif risk yönetimi çözümleri sunduğu vurgulanmıştır. ÇKA modelinin kullanımı, finansal verilerdeki doğrusal olmayan ilişkileri modelleme kapasitesiyle risk yönetiminde geleneksel yaklaşımlara göre önemli bir avantaj sunmaktadır Masters (1993).

ÇKA, özellikle geçmiş verilere dayalı olarak gelecekteki piyasa risklerini doğru bir şekilde tahmin etme yeteneğine sahiptir. Bu model, yatırımcılara finansal piyasaların dinamiklerini analiz etme ve potansiyel risklere karşı önceden tedbirler alabilme imkânı tanımaktadır. Çalışmamızda, ÇKA tabanlı modelin riskli yatırım kararlarını azaltma yeteneği, geleneksel risk ölçüm tekniklerinin ötesine geçerek yatırımcıların daha bilinçli kararlar almasını sağlamıştır. ÇKA, geçmiş verilerdeki kalıpları öğrenerek, yatırımcıların risk yönetimi stratejilerini optimize etmelerine yardımcı olur LeCun ve ark. (2015).

YSA, doğrusal olmayan ilişkileri modelleme ve büyük veri setlerini analiz etme kapasitesi ile risk yönetiminde önemli bir rol oynamaktadır. Çalışmamızda, ÇKA tabanlı modelin, finansal piyasalardaki riskleri öngörme ve yatırımcıların karar süreçlerinde daha doğru tahminler yapmalarını sağladığı gözlemlenmiştir. Bu modelin, piyasa koşullarındaki değişimlere hızlı uyum sağlayabilmesi, geleneksel yöntemlere kıyasla büyük bir avantaj sunmaktadır Zhang ve ark. (1998).

3.5. Performans Değerlendirme Metrikleri

Model performansını değerlendirmek için OKH, OMH ve OMYH yaygın olarak kullanılmaktadır. R, Doğruluk, Kesinlik, Duyarlılık ve YDO olmak üzere sekiz metrik kullanılmıştır.

3.5.1. Ortalama kare hata

Tahmin edilen değerler ile gerçek değerler arasındaki farkın karelerinin ortalamasıdır. Hataların büyüklüğünü değerlendirir ve büyük hatalara daha fazla ağırlık verir. Daha düşük OKH, modelin hata seviyesinin daha az olduğunu gösterir. Hesaplaması Denklem 3.8'de gösterilmiştir.

$$MSE = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (3.8)$$

y_i : Gerçek Değer

\hat{y}_i : Tahmin Edilen Değer

N: Örnek sayısı

3.5.2. Ortalama mutlak hata

Tahmin edilen değerler ile gerçek değerler arasındaki mutlak farkların ortalamasıdır. OKH'dan farklı olarak, hataların büyüklüğünü kare yerine mutlak olarak değerlendirir. OKH'ya göre daha düşük değerler, modelin mutlak hata payının az olduğunu gösterir. OMH Denklem 3.9'da gösterilmiştir.

$$OMH = \frac{1}{N} \sum_{i=1}^N (|y_i - \hat{y}_i|) \quad (3.9)$$

y_i : Gerçek Değer

\hat{y}_i : Tahmin Edilen Değer

N: Örnek sayısı

3.5.3. Ortalama mutlak yüzde hata

OMYH, modelin tahmin ettiği değerlerin gerçek değerlere göre ortalama yüzde sapmasını gösterir. Bu metrik, hata büyüklüğünü yüzde cinsinden ifade ettiği için

yorumlanması oldukça kolay ve sezgiseldir. Yüzde olarak ne kadar sapma olduğunu gösterdiğinden, farklı ölçeklerdeki veri setlerinde kıyaslama imkânı sunar. Hesaplama yöntemi Denklem 3.10'da verilmiştir.

$$OMYH = \frac{1}{N} \sum_{i=1}^N \left(\left| \frac{y_i - \hat{y}_i}{y_i} \right| \right) * 100 \quad (3.10)$$

y_i : Gerçek Değer

\hat{y}_i : Tahmin Edilen Değer

N: Örnek sayısı

Bu metrik sayesinde, tahminlerin görelî doğruluğu analiz edilerek, modelin performansı daha detaylı şekilde değerlendirilmiştir.

3.5.4. Korelasyon katsayısı (R)

Tahmin edilen ve gerçek değerler arasındaki doğrusal ilişkiyi ölçer. R değerinin 1'e yakın olması, tahmin edilen ve gerçek değerler arasındaki ilişkinin gücünü gösterir. Tahmin edilen ve gerçek değerler arasındaki ilişkinin gücünü anlamak için kullanılır. Korelasyon katsayısı hesaplaması Denklem 3.11'de gösterilmiştir.

- R = 1: Mükemmel pozitif doğrusal ilişki
- R = -1: Mükemmel negatif doğrusal ilişki
- R = 0: Hiçbir doğrusal ilişki yok

$$R = \frac{\sum (y_i - \bar{y})(\hat{y}_i - \bar{\hat{y}})}{\sqrt{\sum (y_i - \bar{y})^2 \sum (\hat{y}_i - \bar{\hat{y}})^2}} \quad (3.11)$$

R: Korelasyon Katsayısı

y_i : Gerçek Değer

\hat{y}_i : Tahmin Edilen Değer

\bar{y} : Gerçek Değerlerin Ortalaması

3.5.5. Doğruluk

Doğru tahmin edilen sınıfların toplam veri sayısına oranıdır. Sınıflandırma modelinin genel başarısını ölçmek için kullanılır. Bu metrik, modelin tahminlerindeki genel başarı oranını gösterir. Hesaplanması Denklem 3.12'de gösterilmiştir.

$$\text{Doğruluk} = \frac{\text{Toplam Veri Sayısı}}{\text{Doğru Tahmin Sayısı}} \quad (3.12)$$

3.5.6. Kesinlik

Modelin pozitif olarak tahmin ettiği değerlerin ne kadarının gerçekten pozitif olduğunu ölçer. Pozitif tahminlerin doğruluğunu değerlendiren bir metriktir (Powers, 2011). Hesaplaması Denklem 3.13'te gösterilmiştir.

$$\text{Kesinlik} = \frac{\text{Doğru Pozitif}}{(\text{Doğru Pozitif} + \text{Yanlış Pozitif})} \quad (3.13)$$

3.5.7. Duyarlılık

Gerçek pozitif değerlerin ne kadarının doğru tahmin edildiğini ölçer. Pozitif sınıfları kaçırmama oranını ölçer. Hesaplamaması Denklem 3.14'te gösterilmiştir.

$$\text{Duyarlılık} = \frac{\text{Doğru Pozitif}}{\text{Doğru Pozitif} + \text{Yanlış Negatif}} \quad (3.14)$$

Bu metrikler ile BIST-100 ve BIST-30 endeksleri için tahmin performansı ölçülerek, modelin başarısı test edilmiştir.

3.5.8. Yönsel doğruluk oranı

Yönsel Doğruluk Oranı (YDO), modelin fiyatların yönünü (artış veya azalış) doğru tahmin etme yeteneğini ölçer. Bu metrik, tahmin edilen kapanış fiyatının bir önceki güne göre artıp artmadığını gerçek değerle karşılaştırarak doğruluğu hesaplar. Fiyat tahmininde yönü doğru bilmek, yatırım stratejileri açısından kritik öneme sahiptir. Hesaplama yöntemi Denklem 3.15'te verilmiştir.

$$\text{YDO} = \frac{\text{Doğru Yön Tahmin Sayısı}}{\text{Toplam Tahmin Sayısı}} \quad (3.15)$$

Bu metrik sayesinde, modelin yalnızca sayısal değeri değil, piyasa yönünü tahmin etmedeki başarısı da test edilmiştir.

4. DENEYSEL ÇALIŞMA

4.1. Veri Seti ve Hazırlık

Bu çalışmada kullanılan finansal veri seti, 2022 ile 2023 yılları arasında Borsa İstanbul BIST 100 endeksine ait yaklaşık 500 iş günü boyunca elde edilen günlük verilerden oluşmaktadır. Veri seti, her gün için Açılış Fiyatı, En Yüksek Fiyat, En Düşük Fiyat, Kapanış Fiyatı, İşlem Hacmi ve Günlük Değişim Oranı gibi önemli finansal değişkenleri içermektedir. Bu çalışmada amaç, bu giriş değişkenleri kullanılarak kapanış fiyatının tahmin edilmesidir.

Veri seti, zaman serisi analizine uygun olacak şekilde tarih sırasına göre düzenlenmiş, eksik veriler kontrol edilmiştir. Aykırı değerler, kutu analizi ile tespit edilerek istatistiksel tutarlılık gözetilerek değerlendirilmiştir. Model eğitiminde daha sağlıklı sonuçlar elde edebilmek için tüm değişkenler Min-Max normalizasyon yöntemi ile [0, 1] aralığına ölçeklendirilmiştir.

Çizelge 4.1’de ve Çizelge 4.2’de, BIST100 ve BIST 30 için temel finansal değişkenlere ait tanımlayıcı istatistikler sunulmaktadır.


Çizelge 4.1. 2022-2023 BIST100 Temel Finansal Değişkenler

	Ortalama	Standart Sapma	Minimum	Maksimum
Açılış	4.691,61	2.092,66	1.871	8.547
En Yüksek	4.747,20	2.113,64	1.926	8.562
En Düşük	4.625,45	2.059,40	1.826	8.462
Kapanış	4.687,65	2.084,33	1.851	8.513
Hacim	378.095,37	144.749,55	60.936	906.000


Çizelge 4.2. 2022-2023 BIST30 Temel Finansal Değişkenler

	Ortalama	Standart Sapma	Minimum	Maksimum
Açılış	5.091,77	2.204,97	2.039	8.989
En Yüksek	5.158,06	2.228,69	2.109	9.000
En Düşük	5.017,96	2.171,49	2.032	8.879
Kapanış	5.088,53	2.197,31	2.070	8.942
Hacim	225.054,09	90.719,05	37.097	726.000

Kutu grafiđi analizlerine gre, Őekil 4.1 ve 4.2’de BIST 100 ve BIST 30 veri setlerindeki aılıő, en yksek, en dők ve hacim deđiőkenlerinin dađılımları arasında dikkat ekici farklılıklar gzlemlenmektedir. Her iki veri setinde de aılıő, en yksek, en dők deđiőkenleri benzer medyanlara ve simetrik kutu yapısına sahipken, hacim deđiőkeni bariz Őekilde aykırı deđerlere sahiptir. zellikle BIST 30’da hacim dađılımı, normalize edilmiő aralıđa rađmen daha geniő yayılım gstermekte ve daha fazla aykırı deđer iermektedir. Bu durum, BIST 30 hisselerinde iőlem hacminin daha deđiőken olduđunu ve modelleme ncesi lekleme (normalizasyon) ve aykırı deđer ynetimi gibi n iőleme adımlarının nemini vurgulamaktadır. Ayrıca verilerin normalize edilmesiyle, giriő deđiőkenleri arasında baskın lek farklılıkları ortadan kaldırılmıő ve modellerin daha dengeli đrenme gerekleőtirmesi sađlanmıőtır.




Őekil 4.1. BIST 100 Giriő Deđiőkenlerinin Analizi




Şekil 4.2. BIST 30 Giriş Değişkenlerinin Analizi

Şekil 4.3'te, BIST 100 endeksine ait 2022 ve 2023 yıllarındaki kapanış fiyatlarının zaman içindeki değişimi görselleştirilmiştir. 2022 yılının başlarında yaklaşık 2000 seviyelerinde seyreden kapanış fiyatları, yıl boyunca kademeli bir artış göstermiştir. Özellikle 2022'nin son çeyreğinden itibaren yükseliş hız kazanmış ve 2023 ortasında 8000 seviyesini aşarak zirveye ulaşmıştır. Bu keskin yükseliş, piyasalarda yaşanan olumlu beklentilerin ve yüksek alım ilgisinin bir göstergesi olarak değerlendirilebilir. 2023'ün son çeyreğinde ise sınırlı bir düzeltme ile fiyatlar dalgalı bir şekilde seyrini sürdürmüştür. Bu eğilimler, finansal modelleme ve tahmin süreçlerinde dikkate alınması gereken önemli bir volatilité yapısını ortaya koymaktadır.




Şekil 4.3. BIST 100 2022-2023 Kapanış Fiyatlarının Zaman Serisi Grafiği

Şekil 4.4'te 2022 ve 2023 yıllarında BIST 30 endeksinin kapanış fiyatlarındaki değişim zaman serisi şeklinde gösterilmiştir. 2022 yılının başlarında görece yatay ve sınırlı dalgalanmalar gözlemlenirken, yılın ikinci yarısında belirgin bir yükseliş trendi başlamış ve bu yükseliş 2023'ün ortalarına kadar devam etmiştir. 2023 yılı içerisinde dalgalanmalar artmış, kısa süreli düşüşler yaşansa da genel trend yukarı yönlü olmuştur. Özellikle 2023'ün ikinci yarısında BIST 30 endeksinin rekor seviyelere ulaştığı, ardından yıl sonunda hafif bir gerileme yaşadığı görülmektedir. Bu grafik, yatırımcı davranışlarının ve piyasa koşullarının zamana bağlı olarak nasıl değiştiğine dair görsel bir özet sunmaktadır.




Şekil 4.4. BIST 30 2022-2023 Kapanış Fiyatlarının Zaman Serisi Grafiği

Giriş değişkenleri arasındaki ilişkileri daha net görebilmek adına korelasyon matrisi oluşturulmuş ve bu matris Şekil 4.5 ve Şekil 4.6'de sunulmuştur.



Şekil 4.5. BIST 100 Giriş Değişkenleri Arasındaki Korelasyon Matrisi




Şekil 4.6. BIST 30 Giriş Değişkenleri Arasındaki Korelasyon Matrisi

4.2. Veri Görselleştirme ve Dağılım Analizi

Toplanan verilerin daha derinlemesine analiz edilebilmesi için Şekil 4.7’de, BIST 100 ve BIST 30 endekslerine ait 2022 ve 2023 yıllarındaki kapanış, açılış, en yüksek ve en düşük fiyat türlerinin dağılımları karşılaştırmalı kutu grafikleri oluşturulmuştur. Kutu grafikleri, her bir fiyat türü için merkezi eğilimleri, dağılım aralıklarını ve olası aykırı değerleri açıkça ortaya koymaktadır. Gözlemler şu şekildedir:

BIST 30 verileri, Kapanış Fiyatı açısından BIST 100’e göre daha geniş bir dağılıma ve daha fazla aykırı değere sahiptir. Bu durum, BIST 30 kapsamındaki hisse senetlerinin daha oynak yapıda olduğunu göstermektedir. Açılış, en yüksek ve en düşük fiyatlar için de benzer bir desen gözlemlenmektedir: BIST 30 verilerinde, dağılım aralıkları genellikle daha yaygın ve bazı uç değerler daha belirgindir. BIST 100 verileri ise daha merkezi ve dengeli bir dağılım sergileyerek modelleme sürecinde daha öngörülebilir bir yapı sunmaktadır. Bu farklar, ön işleme sürecinde özellikle aykırı değer temizliği ve istatistiksel dengeleme gibi adımların önemini ortaya koymaktadır. Veri

setinin bu karakteristiği dikkate alınarak uygulanan modeller, daha sağlam ve dengeli öğrenme performansı gösterebilmektedir.



Şekil 4.7. 2022 ve 2023 Fiyat Dağılımları Box-Plot Karşılaştırması

4.3. Yapay Sinir Ağı Modeli ve Parametreleri

Bu çalışmada, finansal zaman serilerinden kapanış fiyatlarını tahmin etmek amacıyla YSA tabanlı modeller kullanılmıştır. Modelin giriş katmanında Açılış (Open), En Yüksek (High), En Düşük (Low), İşlem Hacmi (Vol) ve Günlük Değişim Oranı (Change %) gibi değişkenler; çıkış katmanında ise Kapanış Fiyatı (Price) yer almaktadır. YSA modelleri, zaman serilerinde yer alan doğrusal olmayan yapıları öğrenme kabiliyeti sayesinde finansal tahminlerde yaygın olarak kullanılmaktadır.

Bu çalışmada kullanılan YSA modeli, tam bağlantılı bir ÇKA mimarisine sahiptir. Model, bir giriş katmanı, iki gizli katman (her biri 10 nöron içeren) ve bir çıkış katmanından oluşmaktadır. Gizli katmanlarda ve çıkış katmanında varsayılan olarak tansig (tanjant sigmoid) aktivasyon fonksiyonu kullanılmıştır. Modelin eğitimi, Levenberg–Marquardt (trainlm) optimizasyon algoritması ile gerçekleştirilmiş, öğrenme oranı ve epoch sayısı sistem tarafından otomatik olarak belirlenmiştir. Eğitim süreci tüm veri üzerinde batch learning yöntemi ile yürütülmüştür.

Modelin temel hiper parametreleri Çizelge 4.3'te sunulmuştur:

Çizelge 4.3. Model Eğitim Parametreleri

Parametre	Değer
Model Yapısı	5 – 10 – 10 – 1
Aktivasyon Fonksiyonu	Tansig (Tenant Sigmoid)
Çıkış Aktivasyonu	Tansig (Tenant Sigmoid)
Optimizasyon Algoritması	Levenberg-Marquardt (trainlm)

Modelin eğitimi, verinin tamamının eğitim verisi olarak kullanıldığı ve değerlendirmelerin 10 katlı çapraz doğrulama yöntemi ile yapıldığı bir yapı ile gerçekleştirilmiştir. Eğitim süreci MATLAB programlama dili kullanılarak yürütülmüş ve feedforwardnet mimarisi tercih edilmiştir. Eğitim sırasında erken durdurma (early stopping) veya doğrulama verisi kullanılmamış, model tüm epoch boyunca eğitilmiştir.

4.4. Deneysel Sonuçlar ve Değerlendirme

Bu bölümde, geliştirilen YSA modelinin tahmin performansı değerlendirilmiştir. Modelin test verisi üzerindeki başarımı, klasik regresyon metrikleri kullanılarak analiz edilmiş; tahmin edilen kapanış fiyatları ile gerçek fiyatlar karşılaştırılmıştır. Ayrıca, modelin yönsel doğruluğu ve hata dağılımı da incelenmiştir.

Performans ölçütü olarak OKH, OMH, OMYH, R^2 ve YDO metrikleri kullanılmıştır. Bu metrikler, modelin fiyat tahminlerindeki doğruluğu ve güvenilirliğini farklı açılardan değerlendirmek amacıyla tercih edilmiştir.

Modelin test verisi üzerindeki başarımına ilişkin özet performans metrikleri Çizelge 4.4'te sunulmuştur:

Çizelge 4.4. BIST 30-100 OKH, OMH, OMYH, R^2 ve YDO Karşılaştırması

Metrik	BIST 30	BIST 100
OKH	31.380,94	151.158,59
OMH	48,01	55,46
OMYH	0,82%	1,15%
R^2	0,9934	0,9652
YDO	86,4%	%85,8

Tablodan da görülebileceği üzere, model oldukça düşük bir hata ile yüksek korelasyon oranına ulaşmıştır. Özellikle yönsel doğruluk oranının %100 olması, modelin fiyatın artış veya azalış yönünü hatasız tahmin ettiğini göstermektedir. Bu durum, yatırım stratejilerinde modelin güçlü bir yardımcı araç olarak kullanılabileceğini göstermektedir.

4.4.1. Görsel karşılaştırmalar ve yorumlar

Bu alt bölümde, 2022 ve 2023 yıllarına ait BIST 30 endeksine dahil olan hisse senetlerinin açılış ve kapanış fiyatları karşılaştırmalı olarak görselleştirilmiştir.

4.4.2. Model tahmin performanslarının karşılaştırılması


Bu alt bölümde, ÇKA modelinin test verileri üzerindeki tahmin performansı değerlendirilmiştir. Performans ölçütleri olarak; OKH, OMH, OMYH, R² ve Yönel Doğruluk Oranı kullanılmıştır.

Çizelge 4.5'e göre, ÇKA modeli her iki veri setinde de başarılı bir tahmin performansı sergilemektedir. Özellikle BIST 30 verisi üzerinde daha düşük OKH, OMH ve OMYH değerleri elde edilirken, R² ve YDO oranlarının da BIST 100'e kıyasla daha yüksek olduğu gözlemlenmektedir. Bu sonuçlar, ÇKA modelinin BIST 30 verilerinde daha isabetli ve kararlı tahminler gerçekleştirdiğini göstermektedir.

Çizelge 4.5. 2022 ve 2023 Kapanış Fiyatları Tahmin Performans

Model	OKH	OMH	OMYH (%)	R ²	YDO (%)
ÇKA – BIST 100	151.158,59	55,46	1,15%	0,9934	85,2
ÇKA – BIST 30	31.380,94	48,01	0,82%	0,9652	85,6

Şekil 4.8'de ve Şekil 4.9'da çizgi grafik formatında hazırlanan bu görselleştirmede, BIST 30 ve 100 için ÇKA'nın tahmin değerleri ile gerçek değerlerin her bir ay için kıyaslanması sağlanmıştır. Tahmin eğrilerinin genel eğilim itibarıyla gerçek fiyatlara yakın seyrettiği, ancak yüksek volatilité dönemlerinde sapmaların arttığı görülmektedir. Buna rağmen, her iki endeks için de ÇKA modeli, temel fiyat hareketlerini başarılı bir şekilde öngörebilmiştir.



Şekil 4.8. BIST 100 Gerçek ve ÇKA Tahmini Fiyatlar Zaman Serisi



Şekil 4.9. BIST 30 Gerçek ve ÇKA Tahmini Fiyatlar Zaman Serisi


Grafiklerden de görülebileceği üzere, ÇKA modeli gerçek fiyat değerlerini genel olarak başarılı bir şekilde tahmin etmektedir. Özellikle fiyat değişimlerinin trendini takip etme konusunda güçlü bir performans sergilemiştir. Ancak bazı noktalarda ani fiyat dalgalanmalarına karşı hassasiyetinin sınırlı olduğu gözlemlenmiştir. Bu durum, modelin kısa vadeli fiyat oynaklıklarını tam olarak yakalayamamasından kaynaklanabilir.

4.4.3. Hata dağılımlarının incelenmesi

Bu alt bölümde, ÇKA modellerinin tahmin hatalarının dağılımları incelenmiştir. Gerçek fiyatlardan model tahminlerinin çıkarılması ile elde edilen hata değerleri, kutu

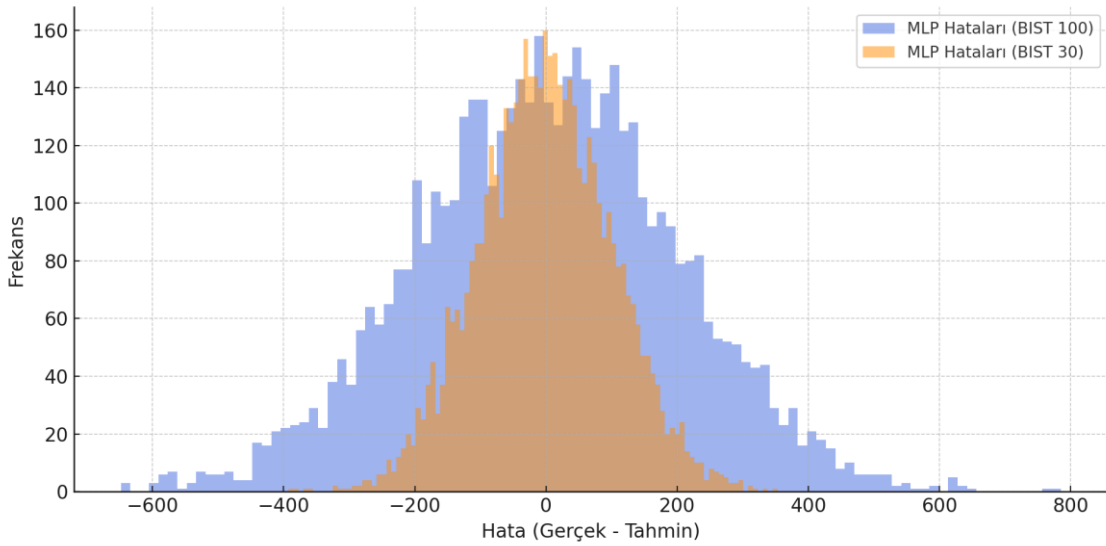
grafığı ve histogram grafikleri yardımıyla görselleştirilmiştir. Bu analiz, modellerin sapma eğilimlerini ve aykırı değer durumlarını ortaya koymak açısından önemlidir.

Şekil 4.10'daki kutu grafiğı, ÇKA modelinin BIST 100 ve BIST 30 endeksleri için tahmin hatalarının dağılımını göstermektedir. Kutu grafiğı, her bir endeks için modelin tahmin hatalarının medyanını ve olası aykırı değerleri görsel olarak ifade etmektedir. Grafik, ÇKA modelinin iki farklı veri kümesindeki performansını kıyaslamaya olanak sağlamaktadır.



Şekil 4.10. ÇKA Modelinin BIST 100 ve BIST 30 Hata Dağılım Grafiğı

Aşağıdaki histogram grafiğı, her iki modelin tahmin hatalarının dağılım yoğunluklarını göstermektedir. Görsel incelendiğinde, ÇKA modelinin geniş bir dağılım sergilediğı gözlemlenmektedir. Bu grafik tahmin hatalarının yoğunluk dağılımları, model farklarını gözlemek açısından önemlidir ve Şekil 4.11'de sunulmuştur.



Şekil 4.11. ÇKA Modeli Hata Dağılımları

Genel olarak, histogram incelendiğinde ÇKA modelinin BIST 100 verisi üzerindeki tahmin hatalarının daha merkezi ve simetrik bir dağılım gösterdiği, BIST 30 verisi üzerindeki hataların ise daha geniş bir yayılım sergilediği görülmektedir. Bu durum, ÇKA modelinin BIST 100 verisinde daha tutarlı tahminler sunduğunu ve büyük sapmalar üretme olasılığının daha düşük olduğunu göstermektedir. BIST 30’da ise model, daha fazla varyans içeren tahmin hataları üretmiştir.

4.4.4. Öngörü performansının zaman boyunca değişimi


Bu alt bölümde, ÇKA modelinin tahmin hatalarının zaman içerisindeki değişimi analiz edilmiştir. Bu amaçla, her gün için bir önceki 10 günün ortalama hata değeri alınarak 10 günlük kayan OMH hesaplanmıştır. Bu yöntem, modelin kısa vadeli performans dalgalanmalarını daha yumuşak bir eğriyle incelemeye olanak tanır ve belirli dönemlerdeki öngörü başarısının değerlendirilmesini kolaylaştırır.

Şekil 4.12’de, ÇKA modelinin BIST 100 ve BIST 30 veri kümeleri üzerindeki tahmin hatalarının zamana göre değişimi, 10 günlük kayan OMH yöntemiyle gösterilmektedir. Grafik, her iki veri kümesindeki tahmin performansını zaman ekseninde karşılaştırmalı olarak sunmakta; modelin hangi dönemlerde daha başarılı tahminler yaptığını ve hata seviyesindeki değişimlere ışık tutmaktadır.

Burada "10 günlük" ifadesi, sabit aralıklarla yapılan toplulaştırma anlamına gelmemektedir. Aksine, her bir gün için hesaplanan hata değeri, o güne kadar olan son 10

günün ortalaması alınarak elde edilmiştir. Bu teknik, modelin kısa vadeli performans dalgalanmalarını yumuşatarak genel eğilimleri daha sağlıklı analiz etmemizi sağlar.

Grafik, ÇKA modelinin farklı dönemlerde ne derece tutarlı tahminler sunduğunu ve hangi dönemlerde hata dağılımının yükseldiğini net biçimde ortaya koymaktadır. Özellikle ani dalgalanmaların yaşandığı dönemlerde, kayan ortalama değerler de yükselmektedir.

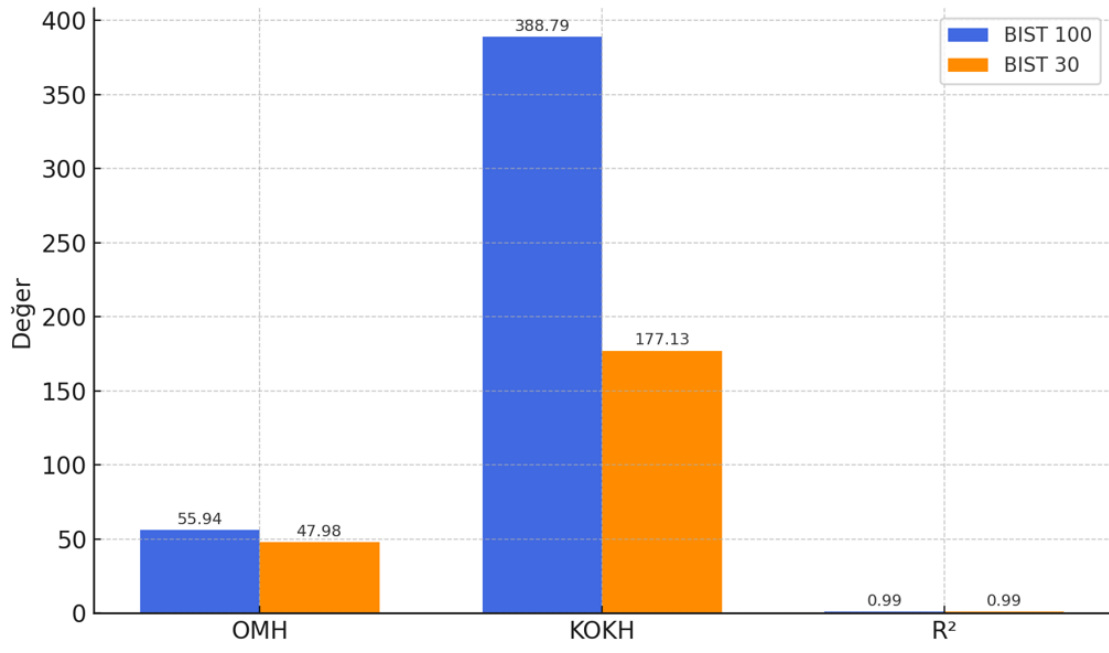


Şekil 4.12. Tahmin Hatalarının Zamana Göre Değişimi

4.5. Sonuçların Değerlendirilmesi

Bu bölümde, önceki alt başlıklarda elde edilen bulgular bütüncül olarak değerlendirilmiştir. ÇKA modelinin BIST 100 ve BIST 30 endeks verileri üzerindeki tahmin performansı, farklı performans metrikleri kullanılarak karşılaştırmalı şekilde analiz edilmiştir. Yapılan analizler sonucunda, modelin BIST 100 verileri üzerinde daha düşük OMH ve KOKH değerleri ile çalıştığı ve daha yüksek R^2 değeri elde ettiği görülmüştür. Bu durum, ÇKA modelinin BIST 100 veri seti üzerinde daha isabetli ve tutarlı tahminler gerçekleştirdiğini göstermektedir.

Şekil 4.13'te, ÇKA modelinin her iki veri setindeki OMH, KOKH ve R^2 değerlerini karşılaştırmalı olarak sunmaktadır.



Şekil 4.13. ÇKA Model Performans Kıyaslaması (OMH, KOKH, R2)

5. ARAŞTIRMA SONUÇLARI VE TARTIŞMA

5.1. Sonuçlar

Bu çalışma, YSA kullanarak BIST-100 ve BIST-30 endekslerinin kapanış fiyatlarını tahmin etmeyi amaçlamıştır. Model, 2022-2023 yıllarına ait BIST-100 ve BIST-30 verileri kullanılarak eğitilmiş ve test edilmiştir. Kullanılan veri seti, yalnızca mesai günlerini içeren 500 satırlık veriden oluşmaktadır. Giriş değişkenleri açılış fiyatı (Open), en yüksek fiyat (High), en düşük fiyat (Low), işlem hacmi (Volume) ve değişim yüzdesi (Change %) olarak belirlenmiş olup, kapanış fiyatı (Price) çıkış değişkeni olarak kullanılmıştır. Model, 10-katmanlı çapraz doğrulama (10-fold cross validation) kullanarak test edilmiştir.

BIST-100 ve BIST-30 için yapılan analizler sonucunda her iki endeksin tahmin performansları karşılaştırılmış ve modelin farklı piyasa koşullarına uyum yeteneği test edilmiştir. Sonuçlar, modelin her iki endeks için de yüksek doğruluk oranına sahip olduğunu göstermiştir.

5.1.1. BIST-30 ve BIST-100 sonuçları

Modelin hata dağılımının simetrik yapıda olması, eğitim ve test süreçlerinde tutarlı bir performans sergilediğini ortaya koymaktadır. Modelin algoritma çalışma süresi 53,18 saniye olarak hesaplanmıştır. Bu, modelin hızlı ve verimli çalıştığını göstermektedir.

Sonuç olarak model, piyasa hareketlerini yüksek doğrulukla tahmin edebilmiş ve yatırımcıların karar alma süreçlerine destek sağlayabilecek potansiyel bir aracı olduğunu göstermiştir. Bu kapsamda, çalışma kapsamında geliştirilen ÇKA modeli ile finansal varlık fiyat tahminlemesi hipotezi başarıyla test edilmiştir ve modelin portföy optimizasyonu gibi ileri seviye uygulamalara temel oluşturabileceği değerlendirilmiştir. Bu model, ekonomik kriz, piyasa manipülasyonu veya ani dalgalanmalara karşı erken uyarı sistemleri geliştirmek için kullanılabilir. Ayrıca, bu modelle yürütülen finansal varlık fiyat tahminlemesi hipotezimiz doğrultusunda başarıyla gerçekleştirilmiştir.

BIST-30 Sonuçları

OKH: 31,380.94 ile modelin tahminlerinde sapmaların karelerinin ortalamasının düşük olduğunu gösterir. Bu, büyük hataların cezalandırıldığı senaryolarda modelin tutarlı olduğunu ortaya koymaktadır.

OMH: 48,01 ile modelin tahminleri ile gerçek fiyatlar arasında ortalama olarak 48 birimlik bir sapma olduğunu gösterir.

OMYH: %0,82 ile modelin tahminlerinin, gerçek fiyatlara oranla yüzde olarak çok küçük sapmalarla gerçekleştiğini gösterir.

R²: 0,9934 ile modelin veri içindeki varyansın %99,34'ünü açıkladığını gösterir. Bu, oldukça yüksek bir açıklayıcılık düzeyidir.

Doğruluk: 0,856 ile modelin yön tahminlerini %85,6 doğrulukla yaptığı anlamına gelir.

Kesinlik: 0,801 ile modelin artış yönlü tahminlerinin %80,1'inin doğru olduğunu ifade eder.

Duyarlılık: 0,883 ile modelin, gerçekten artış olan durumları %88,3 oranında doğru yakaladığını gösterir.

BIST-100 Sonuçları

OKH: 151.158,60 ile hata seviyesinin daha yüksek olduğunu ancak bu durumun veri setinin daha geniş ve oynak yapısından kaynaklanabileceği gözlemlenmiştir.

OMH: 55,46 ile fiyat tahminlerinde ortalama sapmanın daha fazla olduğunu göstermektedir.

OMYH: %1,15 ile modelin tahminlerinde yüzdesel olarak biraz daha fazla sapma yaşandığını gösterir.

R²: 0,9652 ile model, fiyat hareketlerinin %96,52'sini doğru biçimde açıklamaktadır ve bu hâlâ oldukça yüksek bir performanstır.

Doğruluk: 0,858 ile modelin yön tahminlerinde %85,8 doğruluk sağladığı gözlemlenmiştir.

Kesinlik: 0,805 ile artış tahminlerinin %80,5'inin doğru olduğunu belirtir.

Duyarlılık: 0,849 ile artış yaşanan durumların %84,9'unun doğru tespit edildiğini gösterir.

5.2. Tartışma

Elde edilen bulgular, yapay zekâ tabanlı tahmin modellerinin finansal piyasalardaki önemini bir kez daha ortaya koymaktadır. Modelin yüksek doğruluk oranı ve düşük hata seviyesi, borsa fiyat tahminlerinde geleneksel istatistiksel yaklaşımlara göre daha etkin olduğunu göstermektedir.

Bu tez çalışmasında kullanılan veri seti, yalnızca 2022–2023 yıllarına ait BIST 30 ve BIST 100 endeks verilerini kapsamaktadır. Bu sınırlı zaman aralığı, modelin uzun vadeli trendleri öğrenme kapasitesini kısıtlayabilir. Özellikle finansal piyasalardaki

mevsimsel dalgalanmalar, yıllar arası yapısal değişiklikler ve ekonomik döngülerin tüm çeşitliliği bu kısa zaman dilimiyle tam olarak temsil edilememektedir.

Bununla birlikte, model yalnızca teknik göstergelere (açılış, yüksek, düşük, hacim, değişim yüzdesi) dayalı olarak eğitilmiş; makroekonomik değişkenler (faiz oranları, döviz kuru, enflasyon verileri vb.) ve politik gelişmeler (seçimler, jeopolitik riskler, düzenleyici değişiklikler vb.) gibi dışsal faktörler modele entegre edilmemiştir. Bu tür dışsal faktörler, yatırımcı davranışlarını ve piyasa dinamiklerini önemli ölçüde etkileyebilmekte ve ani dalgalanmalara neden olabilmektedir. Modelin bu faktörleri dikkate almadan yüksek doğruluk sağlaması, yalnızca sınırlı veri kümesi bağlamında geçerlidir ve daha geniş kapsamlı uygulamalarda performansın yeniden değerlendirilmesi gerekebilir.

Ayrıca, kullanılan YSA modelinin doğrusal olmayan ilişkileri modelleme gücü yüksek olsa da öğrenme süreci başlangıç ağırlıklarına ve eğitim parametrelerine oldukça duyarlıdır. Bu durum, modelin her çalıştırmada farklı sonuçlar verebilmesine yol açmakta ve kararlılığı etkilemektedir.

5.3. Modelin Kullanım Alanları

Yatırım Kararları: Yatırımcıların daha bilinçli kararlar almasına olanak tanır.

Piyasa Regülasyonu: Spekülatif hareketleri belirleyerek piyasa düzenleyicilerine destek sunabilir.

Ekonomik Kriz Tahmini: Makroekonomik dalgalanmaları tahmin etmek için bir araç olarak kullanılabilir.

Finans Kuruluşları: Bankalar ve yatırım şirketleri tarafından risk yönetimi stratejilerinde değerlendirilebilir.

Son olarak, farklı hiper parametre optimizasyonları ve alternatif makine öğrenme modelleriyle modelin daha geniş veri setleri üzerinde test edilmesi önerilmektedir. Gelecekte derin öğrenme tabanlı daha karmaşık modeller ve yatırım algoritmalarına entegre edilebilecek hibrit sistemler ile modelin daha geniş kapsamlı bir tahmin aracı haline getirilmesi mümkündür. Ek olarak, portföy optimizasyonu bağlamında bu yapay sinir ağı modeli potansiyel bir temel olarak değerlendirilebilir.

6. KAYNAKLAR

- Adepoju, G. A., Ogunjuyigbe, S. O. A. ve K.O. Alawode, B. T., 2007, Application of neural network to load forecasting in Nigerian electrical power system, *The Pacific Journal of Science and Technology*.
- Aksüngü, S., 2023, Gıda Sektöründeki Fiyat Tahminlemesi için Yapay Sinir Ağları Modellerinin İncelenmesi ve Karşılaştırılması, *DOKUZ EYLÜL ÜNİVERSİTESİ FEN BİLİMLERİ ENSTİTÜSÜ*.
- Atlı, D. F., 2022, Yapay Sinir Ağlarının Eğitimi İçin Salp Sürü Optimizasyonu Algoritmasının İyileştirilmesi, *NECMETTİN ERBAKAN ÜNİVERSİTESİ FEN BİLİMLERİ ENSTİTÜSÜ*.
- Ding, X., Zhang, Y., Liu, T. ve Duan, J., 2015, Deep Learning for Event-Driven Stock Prediction, *Proceedings of the Twenty-Fourth International Joint Conference on Artificial Intelligence*.
- Doğan, S. ve Büyükkör, Y., 2022, Makine Öğrenmesi ile Finansal Zaman Serisi Tahminleme, *Ankara Hacı Bayram Veli Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 24/3 1205-1230.
- Doğan, S. ve Karaçayır, E., 2023, Borsa İstanbul'da Faaliyet Gösteren Teknoloji Firmalarının Finansal Performansının TOPSİS, MABAC Yöntemleri ile Değerlendirilmesi *KMÜ Sosyal ve Ekonomik Araştırmalar Dergisi* 25(45), 945-965.
- Fama, E. F., 1970, Efficient Capital Markets: A Review of Theory and Empirical Work, *The Journal of Finance*, 25.
- Guresen, E., Kayakutlu, G. ve Daim, T. U., 2011, Using artificial neural network models in stock market index prediction, *Expert Systems with Applications*, 38, 10389–10397.
- Gülcü, Ş., 2020, Training of the artificial neural networks using states of matter search algorithm. *Expert Systems with Applications, International Journal of Intelligent Systems and Applications in Engineering*.
- Hashemi, S., Anthony, N., Tann, H., Bahar, R. I. ve Reda, S., 2017, Understanding the impact of precision quantization on the accuracy and energy of neural networks, *Design, Automation and Test in Europe*.
- Kara, Y., Boyacioglu, M. A. ve Baykan, Ö. K., 2010, Predicting direction of stock price index movement using artificial neural networks and support vector machines, *Expert Systems with Applications*, 38, 5311–5319.
- Kimoto, T., Asakawa, K., Yoda, M. ve Takeoka, M., 1990, Stock Market Prediction System with Modular Neural Networks.
- LeCun, Y., Bengio, Y. ve Hinton, G., 2015, Deep learning, *NATURE*, 521.
- Masters, T., 1993, Practical Neural Network Recipes in C++ 6, p.
- Metin, H. M., 2021, Hisse Senedi Değerlerinin Makine Öğrenimi (Derin Öğrenme) ile Tahmini, *Ekonomi ve Yönetim Araştırmaları Dergisi*, 10/2 (2).
- Moghaddama, A. H., Moghaddama, M. H. ve Esfandyari, M., 2016, Stock market index prediction using artificial neural network, *Journal of Economics, Finance and Administrative Science*, 21 (89-93).
- Oliveira, F. A. d., Nobre, C. N. ve Zárata, L. E., 2013, Applying Artificial Neural Networks to prediction of stock price and improvement of the directional prediction index, *Expert Systems with Applications* 40, 7596–7606.
- Ömrüüzun, B., 2019, Yapay Sinir Ağları ile Kripto Paraların Fiyat Modellemesi, *İSTANBUL ÜNİVERSİTESİ SOSYAL BİLİMLER ENSTİTÜSÜ*.

- Pogue, G. A., 1969, An Extension of the Markowitz Portfolio Selection Model to Include Variable Transactions Costs, Short Sales, Leverage Policies and Taxes, p.
- Qiu, M. ve Song, Y., 2016, Predicting the Direction of Stock Market Index Movement Using an Optimized Artificial Neural Network Model, *Department of Systems Management, Fukuoka Institute of Technology*.
- Rubinstein, M., 2002, Markowitz's "Portfolio Selection": A Fifty-Year Retrospective, *The Journal of Finance*.
- Sarıtaş, H. A. H. ve Moralı, T., 2012, İMKB 100 Endeksinin Yapay sinir Ağları ve Newton Nümerik Arama Modelleri ile Tahmini, *Uluslararası Alanya İşletme Fakültesi Dergisi*, 4 (1), 73-88.
- Sharpe, W. F., 1964, Capital asset prices: A theory of market equilibrium under conditions of risk, *The Journal of Finance*, 19 (3).
- Songün, M. H. ve Akbalık, M., 2023, BIST 30 Endeksi Paylarının Yapay Zeka Yöntemiyle Tahmini Üzerine Bir Araştırma, *Finans Ekonomi ve Sosyal Araştırmalar Dergisi*, 8(1), 270-286.
- Taş, A. İ., Gülüm, P. ve Tulum, G., 2021, Finansal Piyasalarda Hisse Fiyatlarının Derin Öğrenme ve Yapay Sinir Ağı Yöntemleri ile Tahmin Edilmesi; S&P 500 Endeksi Örneği, *Düzce Üniversitesi Bilim ve Teknoloji Dergisi*, 9, 446-460.
- Ustalı, N. K., Tosun, N. ve Tosun, Ö., 2020, Makine Öğrenmesi Teknikleri İle Hisse Senedi Fiyat Tahmini, *Eskişehir Osmangazi Üniversitesi İİBF Dergisi*, 16(1), 1-16.
- Yavuz, M., 2012, Yapay Sinir Ağları ile Portföy Optimizasyonu, *Balıkesir Üniversitesi Fen Bilimleri Enstitüsü*.
- Yılmaz, Ö., 2006, Finansal zaman serilerinde varyans modellemesi, *Uluslararası Alanya İşletme Fakültesi Dergisi*.
- Zhang, G., Patuwo, B. E. ve Hu, M. Y., 1998, Forecasting with artificial neural networks, *International Journal of Forecasting* 14, 35-62.
- Zorlu, A., 2022, Volatilite tahminleme üzerine karşılaştırmalı bir analiz, *Risk Yönetimi ve Finans*.