T.C.

YILDIZ TEKNİK ÜNİVERSİTESİ

FEN BİLİMLERİ ENSTİTÜSÜ

BORSA ANALİZİ VE TAHMİNİ İÇİN DERİN ÖĞRENME AĞLARI

Murat ERGURUM

YÜKSEK LİSANS TEZİ

İstatistik Anabilim Dalı

İstatistik Programı

Danışman

Doç. Dr. Erhan ÇENE

Temmuz, 2025

T.C.

YILDIZ TEKNİK ÜNİVERSİTESİ

FEN BİLİMLERİ ENSTİTÜSÜ

BORSA ANALİZİ VE TAHMİNİ İÇİN DERİN ÖĞRENME AĞLARI

Murat ERGURUM tarafından hazırlanan tez çalışması 10.07.2025 tarihinde aşağıdaki jüri tarafından Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü İstatistik Anabilim Dalı, İstatistik Programı **YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

Doç. Dr. Erhan ÇENE
Yıldız Teknik Üniversitesi
Danışman

Jüri Üyeleri

Doç. Dr. Erhan ÇENE, Danışman
Yıldız Teknik Üniversitesi _____

Dr. Öğr. Üyesi Coşkun PARİM, Üye
Yıldız Teknik Üniversitesi _____

Doç. Dr. Seda BAĞDATLI KALKAN, Üye
İstanbul Ticaret Üniversitesi _____

Danışmanım Doç. Dr. Erhan ÇENE sorumluluğunda tarafımca hazırlanan “Borsa Analizi ve Tahmini İçin Derin Öğrenme Ağları” başlıklı çalışmada veri toplama ve veri kullanımında gerekli yasal izinleri aldığımı, diğer kaynaklardan aldığım bilgileri ana metin ve referanslarda eksiksiz gösterdiğimi, araştırma verilerine ve sonuçlarına ilişkin çarpıtma ve/veya sahtecilik yapmadığımı, çalışmam süresince bilimsel araştırma ve etik ilkelerine uygun davrandığımı beyan ederim. Beyanımın aksinin ispatı halinde her türlü yasal sonucu kabul ederim.

Murat ERGURUM

İmza

Aileme

ve

eşime

TEŞEKKÜR

Çalışmamı gerçekleştirdiğim sürede yardıma ihtiyaç duyduğum her anda yardımını esirgemeyen, her koşulda ve imkanda verdiği destek ile çalışmamı kolaylaştıran, her zaman bana destek olan Tez danışmanım Doç. Dr. ERHAN ÇENE' ye sonsuz teşekkürlerimi borç bilip saygılarımı sunarım.

Hayatımda her kalkıştığım işte arkamda manevi anlamda büyük bir güç olarak duran aileme, bu çalışmamda içinde bulunduğum stresli zamanlarda verdikleri güven ve motivasyonla bu çalışmama daha sıkı bir şekilde sarılmamı sağladıkları ve her ne olursa olsun arkamda olduklarını bilmemin bana getirdiği büyük özgüven için onlara ne kadar teşekkür etsem azdır.

Murat ERGURUM

İÇİNDEKİLER

SİMGE LİSTESİ viii
KISALTMA LİSTESİ ix
ŞEKİL LİSTESİ x
TABLO LİSTESİ xii
ÖZET xiii
ABSTRACT xv
1 GİRİŞ 1
1.1 Literatür Özeti 1
1.2 Tezin Amacı 3
1.3 Tezin Hipotezi 3
2 BORSA ÜZERİNE GENEL BAKIŞ 4
2.1 Borsa 4
2.2 Borsa Tahmini 5
2.2.1 Temel Analiz 5
2.2.2 Teknik Analiz 6
2.2.3 Borsa Endeksi Tahmininde Kullanılan İstatistiksel Modeller 6
3 YÖNTEM 9
3.1 ARIMA(Autoregressive Integrated Moving Avarage) Modeli 9
3.1.1 AR Modeli 10
3.1.2 MA Modeli 10
3.1.3 ARMA Modeli 10
3.1.4 ARIMA Modeli 11
3.1.5 ARIMA Modelinin Avantajları ve Dezavantajları 11
3.2 Zaman Serisi 12
3.2.1 Zaman Serilerinde Çok Katmanlı Algılayıcılar 13
3.2.2 Evrişimli Sinir Ağları 14
3.2.3 Tekrarlayan Sinir Ağı 16
3.3 Yapay Sinir Ağları 16

3.3.1 Tanım ve Tarihçe……..17
3.3.2 Biyolojik Sinir Hücresi……18
3.3.3 Yapay Sinir Yapısı……....20
3.3.4 Derin Öğrenmede Sinir Ağları……..23
3.4 Yapay Sinir Ağ Mimarisinde Kullanılan Terminolojiler.....23
3.4.1 Giriş Katmanı……24
3.4.2 Gizli Katman……25
3.4.3 Çıktı Katmanı……26
3.4.4 Evrişimli Katman……..27
3.4.5 Havuzlama Katmanı……..27
3.4.6 Geri Yayılım Algoritması……28
3.4.7 Ağırlık……...29
3.4.8 Parametre Optimizasyonu (Parameter Optimization)……...29
3.4.9 Dereceli Alçalma (Gradient Descent)……...30
3.4.10 Aktivasyon Fonksiyonu……... 30
3.5 Yapay Sinir Ağlarının Öğrenilmesi 33
3.6 Uzun Kısa Süreli Bellek (LSTM) Modeli.....34
3.7 Performans Metrikleri.....37
4 VERİ SETİ 39
4.1 Veri Seti ve Tanımlayıcı İstatistikler 39
4.1.1 Korelasyon Matrisi……40
4.1.2 Volatilite Analizi……...41
4.1.3 Veri Setindeki Hisse Senetlerinin Tarihsel Gösterimi……..43
5 UYGULAMA 44
5.1 ARIMA Modeli.....44
5.1.1 ISCTR İçin Arıma Modeli……45
5.1.2 TCELL İçin Arıma Modeli……...53
5.1.3 TUPRS İçin Arıma Modeli……...61
5.1.4 Tüm Hisse Senetleri İçin ARIMA Modeli Sonuçları……... 68
5.2 LSTM Modelin Oluşturulması.....72
5.2.1 Zaman Serisi Veri Seti Oluşturma……72
5.2.2 Model Seçimi(LSTM) ve Eğitim……..73
5.2.3 Hiperparemtere Optimzasyonu ve En İyi modelin Seçilmesi……...75
5.2.4 Gelecek Tahmini Yapma…….. 76
5.3 Her Bir Hisse Senedi Özelinde Modelin Eğitilmesi 76

5.3.1 ISCTR Hisse Senedi…… 77
5.3.2 TCELL Hisse Senedi…… 83
5.3.3 TUPRS Hisse Senedi…… 88
5.4 Tüm Hisse Senetlerine Ait LSTM Özet İstatistikler 94
5.4.1 Genel İstatistiksel Çıkarımlar…… 95
5.5 LSTM ve ARIMA Modellerinin Karşılaştırılması 96
5.5.1 Model Sonuçları ve Değerlendirmeleri……99
5.6 LSTM Tabanlı Yükseliş Düşüş Modeli 101
6 SONUÇ **106**
6.1 Hisse Senedi Tahmininin Zorlukları 106
6.2 Model Performansı Ve Tahmin Sonuçları 107
6.3 Değerlendirme ve Sonuçlar 108
KAYNAKÇA **110**
TEZDEN ÜRETİLMİŞ YAYINLAR **113**

SİMGE LİSTESİ

σ	Aktivasyon Fonksiyonu
$\subset$	Alt Küme
$\geq$	Büyük veya Eşit
α	CNN Algoritması Boyut Sayısı
w	CNN Algoritması Filtre Sayısı
o_t	Çıktı Kapısı Vektörü
ϵ	Elemanıdır
$\notin$	Elmanı Değildir
=	Eşitlik
i_t	Girdi Kapısı Vektörü
$h_i^{(l)}$	i. Adımdaki Gizli Katman Hesaplaması
$\cap$	Kesişim
$\leq$	Küçük veya Eşit
$\lim_{x \to 0} x$	Limit Sembolü
$\sum$	Toplam Sembolü

KISALTMA LİSTESİ

ANN	Yapay Sinir Ağı
ARIMA	Oto-Regresif Entegre Hareketli Ortalamalar
DL	Derin Öğrenme (Deep Learning)
K-NN	k-En Yakın Komşular
LR	Lojistik Regresyon
LSTM	Uzun Kısa Süreli Bellek
MA	Hareketli Ortalamalar
MAE	Ortalama Mutlak Hata
ML	Makine Öğrenmesi (Machine Learning)
MLP	Çok Katmanlı Algılayıcı (Multi Layer Perceptron)
MSE	Ortalama Kare Hatası
RELU	Düzleştirilmiş Doğrusal Birim Katmanı
RMSE	Hata Kareler OrtalamasI Karekökü
RNN	Tekrarlayan Sinir Ağı (Recurrent Neural Network)
VDMK	Varlığa Dayalı Menkul Kıymetler
WMA	Ağırlıklı Hareketli Ortalamalar (Weighted Moving Average)
YSA	Yapay Sinir Ağı

ŞEKİL LİSTESİ

Şekil 3.1 Üç katmanlı MLP sinir ağının yapısı **13**
Şekil 3.2 Evrimsel sinir ağı yapısı **15**
Şekil 3.3 Sinir hücresinin biyolojik gösterimi **19**
Şekil 3.4 Yapay nöron yapısı **21**
Şekil 3.5 Yapay sinir hücresinin sistematik gösterimi **24**
Şekil 3.6 Doğrusal aktivasyon fonksiyonu **31**
Şekil 3.7 Rektifiye doğrusal aktivasyon fonksiyonu **32**
Şekil 3.8 Sigmoid aktivasyon fonksiyonu **33**
Şekil 3.9 Uzun kısa süreli bellek (LSTM) sinir ağı yapısı **35**
Şekil 4.1 Hisse senetlerine ait veri seti **39**
Şekil 4.2 Korelasyon matrisi **41**
Şekil 4.3 Bist hisselerinin tarihsel kapanış değerleri **43**
Şekil 5.1 ISCTR hisse senedine ait durağanlık testi sonuçları **46**
Şekil 5.2 ISCTR hisse senedine ait durağanlık grafikleri **47**
Şekil 5.3 ACF/PACF grafikleri **49**
Şekil 5.4 ISCTR parametre seçimi ve kriter sonuçları **50**
Şekil 5.5 ISCTR arıma modeli tahmin sonuçları **51**
Şekil 5.6 ISCTR model doğrulama sonuçları **52**
Şekil 5.7 TCELL model doğrulama sonuçları **54**
Şekil 5.8 TCELL hisse senedine ait durağanlık grafikleri **55**
Şekil 5.9 ACF/PACF grafikleri **56**
Şekil 5.10 TCELL parametre seçimi ve kriter sonuçları **57**
Şekil 5.11 TCELL tahmin sonuçları **59**
Şekil 5.12 TCELL model doğrulama sonuçları **60**
Şekil 5.13 TUPRS hisse senedine ait durağanlık testi sonuçları **61**
Şekil 5.14 TUPRS hisse senedine ait durağanlık grafikleri **62**
Şekil 5.15 ACF/PACF grafikleri **64**
Şekil 5.16 TUPRS parametre seçimi ve kriter sonuçları **65**
Şekil 5.17 TUPRS tahmin sonuçları **66**

Şekil 5.18 TUPRS model doğrulama sonuçları **67**
Şekil 5.19 Tüm hisse senetleri için parametre ve hata metrikleri **69**
Şekil 5.20 Hata metrikleri tablosu **70**
Şekil 5.21 Tüm hisse senetleri için kapsamlı analiz raporu **71**
Şekil 5.22 Hata metrikleri özeti **71**
Şekil 5.23 10 günlük tahmin tablosu **72**
Şekil 5.24 LSTM Katmanındaki Hücre Sayısının Ayarlanması **73**
Şekil 5.25 Dropout oranı **74**
Şekil 5.26 Dense katmanı **74**
Şekil 5.27 Optimizasyon kodu **75**
Şekil 5.28 Hiperparemetre optimizasyonu **75**
Şekil 5.29 ISCTR hisse senedine ait geçmiş ve gelecek tahmin fiyatları **77**
Şekil 5.30 ISCTR hisse senedine ait model performansı **78**
Şekil 5.31 ISCTR sapma (tahmin hataları) **81**
Şekil 5.32 ISCTR gerçek ve tahmin edilen artış azalış karşılaştırması **82**
Şekil 5.33 TCELL hisse senedine ait geçmiş ve gelecek tahmin fiyatları **83**
Şekil 5.34 TCELL hisse senedine ait model performansı **84**
Şekil 5.35 TCELL sapma (tahmin hataları) **87**
Şekil 5.36 TCELL gerçek ve tahmin edilen artış azalış karşılaştırması **88**
Şekil 5.37 TUPRS hisse senedine ait geçmiş ve gelecek tahmin fiyatları **89**
Şekil 5.38 TUPRS hisse senedine ait model performansı **90**
Şekil 5.39 TUPRS sapma (tahmin hataları) **93**
Şekil 5.40 TUPRS gerçek ve tahmin edilen artış azalış karşılaştırması **94**
Şekil 5.41 Tüm hisselerde 10 günlük lstm ve arima modelleri tahminleri **97**
Şekil 5.42 Binary model veri seti örneği **101**
Şekil 5.43 LSTM binary yükseliş/düşüş model tahmini **102**
Şekil 5.44 Yükseliş/Düşüş modeli grafikleri **104**

TABLO LİSTESİ

Tablo 3.1 Bazı toplama fonksiyonları **21**
Tablo 3.2 Aktivasyon fonksiyonları **22**
Tablo 4.1 Hisse senetlerine ait istatistikler **40**
Tablo 4.2 Volatilite değerleri **43**
Tablo 3.1 Bazı toplama fonksiyonları **21**
Tablo 3.2 Aktivasyon fonksiyonları **22**
Tablo 4.1 Hisse senetlerine ait istatistikler **40**
Tablo 4.2 Volatilite değerleri **43**
Tablo 5.1 ISCTR hisse senedi ortalama istatistik analizi **79**
Tablo 5.2 TCELL hisse senedi ortalama istatistik analizi **85**
Tablo 5.3 TUPRS hisse senedi ortalama istatistik analizi **91**
Tablo 5.4 Tüm hisse senetleri için istatistikler **95**
Tablo 5.5 Hisse bazlı örnekler model başarı karşılaştırması **99**
Tablo 5.6 Hisse bazlı model performans değerleri **100**

ÖZET

Borsa Analizi ve Tahmini İçin Derin Öğrenme Ağları

Murat ERGURUM

İstatistik Anabilim Dalı

Yüksek Lisans Tezi

Danışman: Doç. Dr. Erhan ÇENE

Finansal piyasalar, ekonomik yapıların nabzını tutan ve yatırım kararlarını yönlendiren temel yapılardan biridir. Özellikle borsa, yatırımcılara yüksek getiri sağlama potansiyeliyle dikkat çekerken, aynı zamanda belirsizlik ve dalgalanmaların da merkezinde yer almaktadır. Bu karmaşık yapı, yatırımcıların daha sağlıklı kararlar alabilmeleri için güvenilir tahmin sistemlerinin geliştirilmesini zorunlu kılmaktadır. Geleneksel finansal analiz yöntemlerinden ziyade, günümüzde yapay zekâ ve makine öğrenmesi temelli tekniklerin finansal veriler üzerinde başarılı tahminler ürettiği gözlemlenmiştir. Bu doğrultuda, hisse senedi fiyatlarının zaman serisi verileri üzerinden modellenerek geleceğe yönelik projeksiyonlar sunulması, hem akademik hem de pratik açıdan oldukça değerli bir araştırma işine dönüşmüştür. Bu çalışmada, borsa endeks tahmininde kullanılabilecek derin öğrenme algoritmalarının performansları incelenmiş; özellikle uzun kısa süreli bellek (LSTM) mimarisi temelinde tahmin modeli geliştirilerek, geçmiş hisse senedi fiyatlarından gelecekteki değerlerin öngörülmesi amaçlanmıştır. Bu çalışmada BİST30 hisselerinden 9 adet hisse kullanarak her biri için model çalıştırılmış ve sonuçlar ayrı ayrı gözlenmiştir. Modelin hisse senetlerimiz üzerindeki fiyat, yön ve artış azalışları tahmin etme gücü incelenmiştir. Denenen 9 hisse senedi için modelde tahmin edilen ile gerçek değerler arasındaki

ortalama sapma değeri %2.90, maksimum sapma %15.18 ve modelin gerçek değerlerle aynı yönde hareket edip etmediğini inceleyen yönsel doğruluk oranının ortalama % 75 olduğu görülmüştür. Sonuç olarak LSTM ve GRU tabanlı modeller, hisse senedi fiyatlarının tahmini konusunda güçlü bir performans sergilemiştir.

Anahtar Kelimeler: LSTM, makine öğrenmesi, zaman serileri, derin öğrenme, yapay sinir ağı

ABSTRACT

Deep Learning Networks for Stock Market Analysis and Prediction

Murat ERGURUM

Department of Statistics

Master of Science Thesis

Supervisor: Doç. Dr. Erhan ÇENE

Financial markets are one of the fundamental structures that reflect the pulse of economic systems and guide investment decisions. Particularly, the stock market stands out with its high return potential for investors, while also being at the center of uncertainties and fluctuations. This complex structure necessitates the development of reliable forecasting systems to enable investors to make healthier decisions. Rather than traditional financial analysis methods, it has been observed that artificial intelligence and machine learning-based techniques produce successful predictions on financial data today. In this context, modeling stock prices based on time series data and providing future projections has become a highly valuable research endeavor, both academically and practically. In our thesis study, the performances of deep learning algorithms that can be used for stock index prediction have been examined; in particular, a forecasting model based on the Long Short-Term Memory (LSTM) architecture was developed to estimate future values from historical stock prices. In this study, models were run separately for 9 stocks from the BIST30 index, and the results were analyzed individually. The model's ability to predict price, direction, and changes (increases or decreases) for our selected stocks was evaluated. For the 9 tested stocks, the average deviation between the predicted and actual values in the model was 2.90%, the maximum

deviation was 15.18%, and the average directional accuracy — which examines whether the model moves in the same direction as the actual values — was observed to be 75%. As a result, LSTM and GRU-based models demonstrated strong performance in predicting stock prices.

Keywords: LSTM, machine learning, time series, deep learning, artificial neural network

1
GİRİŞ

1.1 Literatür Özeti

Büyük siyasi olaylar, salgınlar, depremler gibi olağanüstü felaketler yatırımcı davranışları ve piyasa dinamikleri üzerinde belirgin tedirginlikler yaratmaktadır. Borsaya olan ilgi, pandemi döneminden itibaren önceki yıllara göre gözle görülür derecede artış göstermektedir [1]. Bu durum, borsada her gün milyonlarca dolarlık işlemin açılıp kapatıldığı ve piyasa yatırımcılarının belirli vadede para kazanmayı amaçladığı anlamına gelir. Piyasa yatırımcıları yatırımlarını gerçekleştirirken piyasa davranışlarını tam olarak öngöremezler, geçmiş dönem verilerine dayanarak tahmin etmeye çalışırlar. Buradaki en büyük problem finans piyasalarında yer alan fiyat hareketliliğinin tahminin oldukça zor olmasıdır. Çünkü fiyatlar, ekonomik göstergeler, siyasi gelişmeler, yatırımcı psikolojisi ve ani dışsal faktörler gibi birçok değişkenden aynı anda etkilenmektedir [2]. Hisse senedi tahmininde temelde iki tür analiz yöntemi tercih edilmiştir. Bunlardan ilki ülkenin sahip olduğu politik durumu, ekonomisi, anlık hisse değerlerinin incelendiği temel analizdir. Bir diğer önemli yöntem ise geçmiş dönem fiyatları, hacimleri ve piyasa davranışlarının incelendiği teknik analizdir. Teknik analizde amaç hisse senedinin gelecekte yapacağı davranışsal hareketlerin tahmin edilmesidir [3]. Borsada fiyat değişimlerini tahmin etmek amacıyla birçok alternatif yöntem üretilmiştir. Günümüzde hisse senedi tahminlerinde geçmişte kullanılan geleneksel yöntemlerin aksine yapay zeka temelli teknolojik yöntemler tercih edilmektedir. Yapay zekanın sunduğu teknolojik ve detaylı hesaplama yöntemleri diğer doğrusal olmayan yöntemlere nazaran daha doğru sonuçlar vermektedir. Bunun sebebi yapay zekanın gelişmiş hafıza yapısı, kullandığı sinir ağ modelleri ve katmanları sayesinde verileri daha doğru işlemesidir [4]. Derin öğrenme tabanlı sinir ağları, hem çok değişkenli

giriş hem de çok değişkenli çıkış yapılarıyla çalışabilme kapasitesine sahiptir. Bu nedenle, özellikle zaman serisi tahminlerinde karmaşık ilişkileri otomatik olarak öğrenme becerisi ön plana çıkar. Zaman serisi tahmini, gözlemler arasındaki karmaşık zamansal bağımlılıklar nedeniyle önemli ölçüde zorluklar barındırmaktadır. Bu tür ilişkilerin modellenebilmesi için geliştirilen yöntemlerin dikkatli biçimde yapılandırılması, tahmin performansını artırma açısından etkili bir stratejidir. Bu bağlamda, geçmişte genellikle doğrusal varsayımlara dayanan modeller tercih edilmiş; özellikle bütünleşik otoregresif hareketli ortalama (ARIMA) gibi yöntemler, zaman serisi analizlerinde yaygın olarak kullanılmıştır. Karmaşık yapıya sahip zaman serisi tahminlerinde, makine öğrenmesi yöntemleri etkili sonuçlar verebilse de, çoğunlukla başarının artırılabilmesi için uzmanlar tarafından manuel olarak oluşturulan değişkenlerin kullanılması gerekmektedir. Bu tür el ile tasarlanmış özellikler, mevcut yöntemlerin performansını artırmada kritik rol oynamakta olup, bu sürecin etkin bir şekilde yürütülebilmesi için alan bilgisi gerekmektedir. Buna karşılık, derin öğrenme tabanlı sinir ağı modelleri, öz nitelik çıkarımı gibi süreçleri otomatik olarak gerçekleştirebilme kapasiteleri sayesinde, zaman serisi tahminleri için uygun ve güçlü bir alternatif sunmaktadır [5]. Veri seti eğitimi ile yapay zeka modelleri yeni çıkarımlar ve gelecek dönem fiyat tahminlerinde bulunabilirler. Aker, 2022 yılında gerçekleştirdiği çalışmasında BİST'de işleme tabi en fazla piyasa değerine(fiyat) sahip 100 hisse senedi (XU100) endeksindeki verileri ve bu verilerin sahip olduğu volatiliteyi tahmin edebilmek için Facebook Prophet (FBPROPHET) ve uzun-kısa süreli bellek (LSTM) yöntemlerini kullanarak gelecek dönem fiyat öngörüsünde bulunmuştur. Kullanılan yöntemlerin birbirlerine göre eksi ve artıları karşılaştırılmış ve bu karşılaştırma neticesinde düşük hata oranına sahip LSTM yöntemi Fbprophet yöntemine göre daha başarılı olduğu sonucuna ulaşılmıştır [6].Taş ve çalışma arkadaşları(2021), ilerleyen teknolojik gelişmeler ve artan bilgisayar gücünün etkisiyle finansal analizlerde kullanılan algoritmaların etkinliğini incelemeyi amaçlamışlardır. Bu doğrultuda Yahoo Finance(YF) üzerinden alınan Standard & Poor's 500 (S&P 500) endeksine ait veriler işlenerek, uzun kısa süreli bellek (LSTM) ağı ve çok katmanlı algılayıcı (MLP) modelleriyle fiyat tahminine yönelik bir analiz gerçekleştirilmiştir. Yapılan çalışmada 12 Ağustos 2000 ile 13 Ağustos 2020 arasında yer alan hisse senedi günlük kapanış değerleri incelenmiştir. Burada veri setinin %95'i model eğitimi, %5'i ise test süreci için ayrılmıştır. Ulaşılan bulgular, kullanılan iki yönteminde

hisse senedi fiyat tahmininde uygulanabilir ve etkili modeller olduğunu ortaya koymuştur [7]. Akbulut ve Adem'in 2023'de gerçekleştirdiği çalışmalarında büyümekte olan ülkelerin sahip oldukları borsa endeksleri ile döviz ve emtia piyasalarının BİST'de XU100 endeksi üzerindeki etkilerini analiz etmişlerdir. Bu amaç doğrultusunda, uzun-kısa süreli bellek (LSTM) modeli kullanılarak bir fiyat tahmin çalışması gerçekleştirilmiştir. Piyasalar arasındaki karşılıklı etkileşim, ülkeler arasındaki ekonomik bağların güçlülüğünden kaynaklanmakta olup, bu durum finansal tahmin modellerinin doğruluğunu doğrudan etkilemektedir. Araştırmada, Ocak 2017 ile Ekim 2021 tarihleri arasındaki günlük kapanış fiyatları veri seti olarak kullanılmıştır. Model performansının değerlendirilmesinde Ortalama Mutlak Hata (MAE) ve Kök Ortalama Kare Hata (RMSE) gibi ölçütler esas alınmıştır. Deneysel bulgular, LSTM modelinin diğer makine öğrenmesi tabanlı modellere kıyasla daha başarılı sonuçlar ürettiğini ortaya koymuştur. Test aşamasında elde edilen performans değerleri; MAE: 10.27, RMSE: 14.15 ve Göreli Mutlak Hata (RAE): 6.06 olarak rapor edilmiştir [8].

1.2 Tezin Amacı

Gerçekleştirilen çalışmada borsa endeksinde yer alan hisse senetleri fiyatlarının tahmininde kullanılabilecek derin öğrenme algoritmalarının performansları incelenmiş ve bu performanslar karşılaştırılarak en etkili yöntem belirlenmiştir. Çalışmadaki temel amaç, uzun kısa süreli bellek (LSTM) mimarisi kullanılarak bir hisse senedi tahmin modeli geliştirmek ve bu model ile BİST 30'da yer alan 9 farklı hisse senedine (ISCTR, TCELL, ASELS, KCHOL, TUPRS, BIMAS, SAHOL, AKBNK ve THYAO) ait gelecek dönem fiyat tahminleri, artış azalış yönleri ve performanslarının ölçülerek karşılaştırılmasıdır.

1.3 Tezin Hipotezi

Araştırmanın hipotezi, geçmiş on beş yıllık hisse senedi kapanış verilerinden ve doksan gün öncesine kadar kapanış fiyatlarından faydalanılarak hisse senetlerinin 10 günlük fiyat tahmininin ve artış azalış yön tahmininin derin snir ağları yöntemlerinden LSTM ile minimum sapma ile hesaplanacağıdır.

2
BORSA ÜZERİNE GENEL BAKIŞ

2.1 Borsa

Borsa, güncel ekonomilerin işleyişinde önemli bir rol oynayan, sermaye akışını düzenleyen ve insanların yatırım kararlarını etkileyen temel piyasalardan biridir [9]. Hisse senetleri borsa da kullanılan en önemli araçlardan biridir. Yatırımcılar, hisse senetleri ile şirket sermayesinin eşit parçalara bölünmüş halleri ile şirkette mülkiyet ve yönetime katılma hakkı kazanırlar. Hisse senetleri üzerinden işlemler, yalnızca bireysel yatırımcıların değil, aynı zamanda kurumsal aktörlerin de ekonomik beklentilerine yön verir. Borsada yaşanan fiyat hareketleri; makroekonomik göstergeler, şirket performansları ve küresel piyasa gelişmeleri gibi çok boyutlu etkenlerin bir sonucu olarak ortaya çıkar. Bu sebeple, borsa dinamiklerinin doğru bir şekilde analiz edilmesi ve geleceğe dönük öngörülerde bulunulması, hem yatırımcı davranışlarının anlaşılması hem de risk yönetimi açısından oldukça büyük bir öneme sahiptir. Son yıllarda klasik yöntemlerin aksine yapay zekâ ve makine öğrenmesi gibi bilişsel teknolojilerin gelişimi, finansal piyasalarda veri odaklı modelleme yaklaşımlarını ön plana çıkarmaktadır [10]. Bu sebeple, geleneksel analiz yöntemlerinin sınırlılıklarını aşan bu yöntemler, özellikle zaman serisi verileri üzerinden gerçekleştirilen tahminleme çalışmalarında dikkat çekici sonuçlar üretmektedir. Derin öğrenme mimarileri arasında yer alan Uzun Kısa Süreli Bellek (LSTM) ve Benzer Tekrarlayan Yapılar (GRU), geçmiş veri kalıplarını öğrenerek gelecekteki eğilimleri modellemede güçlü birer araç olarak öne çıkmaktadır [11]. Bu bağlamda, borsada işlem gören hisse senetlerinin gelecekteki değerlerini tahmin etmeye yönelik çalışmalar; hem akademik araştırmaların hem de uygulamalı finansın ilgi odağı hâline gelmiştir [12].

2.2 Borsa Tahmini

Finansal piyasalarda doğru ve zamanında alınan yatırım kararları hem bireysel hem de kurumsal yatırımcılar açısından önemli getiri fırsatları sunmaktadır. Özellikle hisse senedi piyasaları, dinamik yapıya sahip olmaları ve yüksek volatilite düzeyleri sebebiyle yatırımcılara hem risk hem de kazanç potansiyeli sunan bir alan olarak öne çıkmaktadır. Bu nedenle, hisse senedi fiyatlarının gelecekteki hareketlerinin tahmin edilmesi, yatırım stratejilerinin başarısı açısından kritik öneme sahiptir. Borsa tendlerinin öngörülmesi finansal kayıpların önlenmesinde oldukça önemli bir role sahiptir. Borsa tahminlemesi yapılırken geçmiş veriler kullanılır. Bu veriler yatırımcılar tarafından analiz edilerek riski minimuma indiren yatırım yöntemleri tercih edilir. Bu yatırım yöntemlerinin tercihi sırasında en çok kullanılan analiz yöntemleri teknik ve temel analiz yöntemleridir [13].

2.2.1 Temel Analiz

Temel analiz, bir şirketin ekonomik ve finansal sağlığını değerlendirmek suretiyle, söz konusu şirketin sahip olduğu hisse senedi gerçek değerine ulaşmayı amaçlayan bir yöntemdir. Bu yöntemde temel verilere odaklanılır. Bu temel veriler, şirketin mali tabloları, gelir-gider yapısı, sektörel durumu, yönetim etkinliği ve makroekonomik göstergeler gibi pek çok değişkenden oluşmaktadır [14]. Temel analiz, yatırımcılara uzun vadeli bakış açısı kazandırmakta ve özellikle sürdürülebilir büyüme potansiyeline sahip şirketlerin belirlenmesinde etkin bir rol oynamaktadır. Temel analiz sonuçları, bir şirketin piyasa değerlemesi ile içsel değeri arasında bir fark olup olmadığını ortaya koymaktadır. Eğer hisse senedi piyasa fiyatı, hesaplanan içsel değerin altında ise hisse "değerinin altında" kabul edilerek alım fırsatı olarak değerlendirilirken tersi durumda, eğer piyasa fiyatı içsel değerin üzerinde ise, bu durum "aşırı değerleme" olarak yorumlanır ve satış sinyali olarak ele alınabilir. Günümüzde, temel analiz çıktıları giderek daha fazla sayıda makine öğrenmesi ve yapay zekâ algoritmasına girdi olarak kullanılmaktadır [15]. Bu entegrasyon sayesinde yalnızca statik bir değerlendirme değil, dinamik ve öğrenen modeller aracılığıyla daha hassas yatırım öngörüleri yapılabilmektedir.

2.2.2 Teknik Analiz

Teknik analiz, tamamen fiyat ve işlem hacmi gibi geçmiş dönem piyasa verilerine odaklanarak, gelecekteki fiyat yönelimlerini istatistiksel ve grafiksel araçlar aracılığıyla tahmin etmeye çalışır. Bu yöntemin altında yatan temel yaklaşım, piyasa fiyatlarının belirli kalıplar doğrultusunda hareket ettiği ve bu kalıpların tekrar edebilirliğe sahip olmasıdır. Hareketli ortalamalar, RSI (Göreli Güç Endeksi), MACD, Bollinger Bantları gibi göstergeler teknik analizde oldukça sık kullanılan araçlardır [16]. Bu yaklaşımın özellikle kısa ve orta vadeli yatırım kararlarında etkili olduğu ve piyasa duyarlılığını yansıtan önemli sinyaller ürettiği görülmektedir. Günümüze bakıldığında, finansal piyasaların karmaşıklığı ve veri miktarındaki artış, geleneksel analiz yöntemlerinin tek başına yeterli olmadığını ortaya koymaktadır. Bu sebeple, teknik ve temel analiz verilerinin birlikte kullanıldığı hibrit yaklaşımlar, daha sağlıklı tahmin modellerinin geliştirilmesine olanak tanımaktadır.

2.2.3 Borsa Endeksi Tahmininde Kullanılan İstatistiksel Modeller

Borsa endeksleri, finansal piyasaların genel yönünü ve performansını ölçmek amacıyla kullanılan temel göstergelerdendir. Ekonominin genel durumuna dair önemli sinyaller sunan bu endeksler, yatırımcıların stratejik kararlar alabilmesine olanak tanır. Endekslerin gelecekteki fiyat değerlerinin öngörülmesi, etkin portföy yönetimi açısından kritik bir öneme sahiptir. Bu noktada, geçmiş verilere dayanan istatistiksel ve yapay zeka temelli modeller, tahmin sürecinin temel araçları olarak kullanılmaktadır. Borsa tahmininde temelde kullanılan 4 farklı istatistik model yöntemi bulunmaktadır. Bunlar; Auto ARIMA (Oto-Regressif Entegre Hareketli Ortalama), Yapay Sinir Ağları (YSA), Uzun Kısa Süreli Bellek (LSTM) ve Monte Carlo Simülasyonudur. Auto ARIMA modeli, zaman serilerinde gözlemlenen trend ve döngüsel yapıların belirlenmesinde kullanılan güçlü istatistiksel yöntemlerin başında gelmektedir. Modelin temelini otoregresyon, fark alma (entegrasyon) ve hareketli ortalama bileşenleri oluşturmaktadır. Bu genel yapı sayesinde geçmişteki veriler ışığında geleceğe dönük tahminler yapmaktadır. Borsa endekslerinin tarihsel hareketlerini analiz ederek, ileriye dönük eğilimleri ortaya koymada sıkça tercih edilen bir yöntemdir [17]. Yapay sinir ağları, insanlardaki beynin öğrenme ve işlem

yapma yeteneğini taklit eden matematiksel modellere dayanır. Büyük veri kümelerindeki karmaşık ve doğrusal olmayan ilişkileri öğrenme kabiliyeti sayesinde finansal tahminleme süreçlerinde geniş bir kullanım alanına ulaşmaktadır. YSA'lar, borsa endekslerinin değişken yapısını modellemede ve olası piyasa hareketlerini öngörmede kullanılan bir diğer modeldir [18]. LSTM, özellikle zaman serisi verilerinde geçmişe dair uzun dönem bağımlılıkları yakalayabilme yeteneğine sahip diğer bir derin öğrenme yöntemidir. Geleneksel sinir ağlarının başa çıkmakta zorlandığı uzun süreli ilişkileri modelleyerek, piyasalardaki kalıpları daha isabetli şekilde tahmin etmeyi mümkün kılmaktadır. Bu yönüyle, Türkiye borsası gibi volatiliteye açık borsa endekslerinde etkili sonuçlar vermektedir [19]. Son olarak Monte Carlo yöntemi, olasılık temelli senaryolar üreterek belirsizlik içeren durumlarda tahminler oluşturmayı hedefleyen bir simülasyon tekniğidir. Rastgele değişkenlere dayalı binlerce olasılık senaryosu üreterek, borsa endekslerinin gelecekteki potansiyel hareket alanlarını analiz etme imkânı sunar. Risk analizi ve olasılık temelli değerlendirmelerde sıkça başvurulan bir yöntemdir [20].

Yapay sinir ağları (YSA), iktisadi analizlerde sıklıkla ekonomik ajanların sınıflandırılması ve zaman serisi verilerinin öngörülmesi gibi alanlarda kullanılmaktadır. Özellikle iflas tahminine yönelik çalışmalarda yaygın biçimde tercih edilen bu modellerin, finansal kriz öngörülerine ilişkin uygulamaları ise daha sınırlı sayıdadır. Yapay sinir ağları, aktivasyon fonksiyonları ve mimari yapıları aracılığıyla doğrusal regresyon ve ikili probit gibi çeşitli geleneksel modellerin işlevlerini de kapsayabilecek esnekliğe sahiptir. Bu sayede, sınıflandırma, kümeleme ve tahmin gibi çok sayıda veri işleme görevinde genel amaçlı ve etkili bir araç olarak değerlendirilmektedir.

Finansal verilerin modellenmesinde sıklıkla kullanılan basit doğrusal modeller, piyasalarda gözlemlenen ani dalgalanmalar ve rastgele yürüyüş benzeri davranışlar karşısında yetersiz kalabilmektedir. Geleneksel zaman serisi analiz yöntemleri genellikle durağanlık varsayımına dayanır ve bu, finansal veriler gibi doğası gereği değişkenlik gösteren seriler için ideal değildir. ARIMA ve regresyon modelleri, bazı finansal serilerde görülen dalgalı yapılar, kalın kuyruk dağılımları ve doğrusal olmayan ilişkiler nedeniyle yetersiz tahmin performansı sergileyebilmektedir. Yapay sinir ağları ise finansal alanda karar destek mekanizmalarını güçlendirmek

amacıyla sıkça başvurulan yöntemlerden biridir. Portföy yönetimi, kredi risk analizi, iflas tahmini, döviz kuru öngörüleri, hisse senedi değer tahmini, enflasyon tahmini ve nakit akışı projeksiyonları gibi pek çok alanda etkili sonuçlar sağlamaktadır. Bu modeller, özellikle daha önce karşılaşılmamış veri örneklerine karşı da anlamlı çıktılar üretebilme yetenekleri sayesinde dikkat çekmektedir. Girdilerdeki doğrusal olmayan ilişkileri keşfetme kapasiteleri, YSA'ları finansal piyasalar gibi karmaşık dinamik sistemlerin modellenmesinde güçlü bir araç hâline getirmektedir.

Yapay sinir ağlarının en önemli avantajlarından biri, önceden belirlenmiş istatistiksel varsayımlara ihtiyaç duymadan çalışabilmeleri ve karmaşık doğrusal olmayan fonksiyonları öğrenip yeniden üretebilme yetenekleridir. Ayrıca eksik veya hatalı verilere karşı görece daha dayanıklı olmaları, bu yöntemleri geleneksel modellemelere kıyasla daha esnek kılar. Sınırlı sayıda gizli katman içeren yapılarla bile yüksek doğruluk seviyelerine ulaşabilmeleri, parametrik olmayan yaklaşımın önemli bir göstergesidir. Bu bağlamda, sinir ağları genellikle klasik doğrusal regresyon modellerine kıyasla daha yüksek tahmin doğruluğu sağlayabilir. Biyolojik sinir sistemlerinden esinlenerek ortaya çıkan yapay sinir ağları, biyolojik adaptasyon ve öğrenme mekanizmalarını taklit eden matematiksel yapılardan oluşur. Bunlar öncelikle, seri tahmini ve veri madenciliği gibi açıklanması zor olan karmaşık problemlerin çözümünde başarıyla kullanılmaktadır. Büyük ölçekli veri setlerinin bulunduğu durumlarda, sinir ağları yüksek doğruluk ve işlem kapasitesiyle öne çıkar; çünkü pek çok geleneksel algoritma bu tür veri hacimleriyle başa çıkmakta zorlanır. Öte yandan, istatistiksel yaklaşımlar, tarihsel ekonomik verileri temel alarak geliştirilen basit modellerle başlangıç seviyesinde ekonomik öngörüler sağlar. Kamuya açık güvenilir veri kaynakları ile desteklenen bu yaklaşımlar, makroekonomik analiz ve değerlendirmelerde de işlevsel bir zemin sunar.

Sonuç olarak, borsa endeksi tahminine yönelik kullanılan bu modeller, yatırımcılara daha bilinçli kararlar almada önemli katkılar sunmaktadır. Ancak, her bir modelin belirli varsayımlara ve sınırlılıklara sahip olması sebebiyle, farklı yöntemlerin birlikte kullanılması ve piyasa koşullarının bütünsel şekilde değerlendirilmesi daha güvenilir sonuçlar verecektir.

3
YÖNTEM

3.1 ARIMA(Autoregressive Integrated Moving Avarage) Modeli

Zaman serilerinin büyük bir kısmı doğrudan durağan özellik göstermemektedir. Bu durumun temel nedenleri arasında trend (eğilim) ve mevsimsellik gibi yapısal bileşenler yer almaktadır. Söz konusu bileşenler, serinin istatistiksel özelliklerinin zamanla değişmesine neden olarak durağanlık varsayımını geçersiz kılar. Bu nedenle, durağan olmayan bir zaman serisinin modellenmesine geçilmeden önce, ilgili serinin uygun yöntemlerle durağanlaştırılması gerekmektedir [21]. Bu yöntemlerden en önemlisi fark alma işlemi ile durağan hale getirmektir. ARIMA (Autoregressive Integrated Moving Average), zaman serisi analizinde sıklıkla tercih edilen parametrik bir modeldir ve özellikle durağan olmayan serilerin modellenmesinde güçlü bir araç olarak kullanılır. Bu model, üç ana bileşenin birleşiminden oluşmaktadır. Bunlar: otoregresif (AR), fark alma (I) ve hareketli ortalamadır(MA). ARIMA modeli, en çok geçmiş verilere dayalı olarak gelecekteki gözlemleri tahmin etmek için kullanılmakta olup, finansal zaman serileri, ekonomik göstergeler, talep tahmini ve stok analizi gibi oldukça fazla alanda uygulanmaktadır. ARIMA modelleri ARIMA (p,d,q) ile gösterilir; burada p otoregresif modelin sırası, d farklılaşma derecesi ve q da hareketli ortalama modelinin sırasıdır. ARIMA modeli aşağıdaki genel biçimde ifade edilir:

$$\Phi(B)(1-B)^{t}y_t = \Theta(B)\varepsilon_t \tag{3.1}$$

- y_t : Zaman serisinin gözlemlenen değeri
- B : Geriye kaydırma (backshift) operatörüdür, $B_{y_t} = y_{t-1}$
- $\Phi(B)$: Otoregresif (AR) polinomudur.
- $\Theta(B)$: Hareketli ortalama (MA) polinomudur.
- ε_t : Beyaz gürültü hata terimidir.

3.1.1 AR Modeli

Bu model, geçmiş döneme ait verileri içerir ve içerdiği geçmiş döneme ait veri sayısına göre isimlendirilir. Burada modelin sahip olduğu geçmiş dönem sayısı p ile ifade edilir [22]. AR(p) modelinin ifadesi aşağıdaki gibidir:

$$x_t = \emptyset_1 x_{t-1} + \emptyset_2 x_{t-2} + \ldots + \emptyset_1 x_{t-p} + \alpha_t \quad (3.2)$$

- x, gözlem değerleri
- $\emptyset$, modelin parametreleri

Örneğin AR(1) için aşağıdaki gibi gösterilir:

$$x_t = \emptyset_1 x_{t-1} + \alpha_t \quad (3.3)$$

3.1.2 MA Modeli

Hareketli Ortalama (MA) modelleri, zaman serisinin mevcut değerini geçmiş hata terimlerinin ağırlıklı ortalamasına dayandırarak tahmin eden istatistiksel yapılardır. MA(q) modeli, geçmiş q dönemlik hata terimlerini içermekte olup, buradaki q parametresi modelin derecesini belirtir. Genel MA(q) modelinin gösterimi aşağıdaki şekildedir:

$$x_t = \theta_0 \alpha_t + \theta_1 \alpha_{t-1} + \ldots + \theta_q \alpha_{t-q} \quad (3.4)$$

Birinci dereceden MA(1) aşağıdaki gibi gösterilir($\theta_0 = 1$):

$$x_t = a_t + \theta_1 \alpha_{t-1} \quad (3.5)$$

3.1.3 ARMA Modeli

Bu model; AR ve MA modellerinin kombinasyonu ile oluşmaktadır. p terimli AR(p) ve q terimli MA(q) modelinden oluşan bir ARMA modelinde p+q adet terim bulunmaktadır ve ARMA(p,q) şeklinde ifade edilmiştir. ARMA(p,q) modelinin genel gösterimi (3.6)'da verilmiştir.

$$x_t = (\emptyset_1 x_{t-1} + \emptyset_1 x_{t-2} + \ldots + \emptyset_1 x_{t-p}) - (\emptyset_0 \alpha_t + \emptyset_1 \alpha_{t-1} + \ldots + \emptyset_q \alpha_{t-q}) \quad (3.6)$$

Birinci dereceden ARMA(1,1) aşağıdaki gibi gösterilir($\theta_0 = 1$):

$$x_t = \emptyset_1 x_{t-1} + \alpha_t + \emptyset_1 \alpha_{t-1} \quad (3.7)$$

3.1.4 ARIMA Modeli

AR, MA ve ARMA modelleri, yalnızca durağan özellik taşıyan zaman serileri üzerinde uygulanabilir yapılar olarak öne çıkmaktadır. Ancak birçok gerçek yaşam serisi durağan olmadığından, bu modellerin doğrudan uygulanması çoğu durumda mümkün değildir. Bu sorunun üstesinden gelmek amacıyla geliştirilen ARIMA modeli, içerdiği I(d) bileşeni aracılığıyla seriyi uygun düzeyde fark alarak durağanlaştırır ve ardından AR ve MA yapılarını seriye entegre eder. Eğer bir zaman serisinin ortalaması zamanla değişiyorsa, bu durum durağanlık varsayımını ihlal eder [23]. Bu tür seriler için, gerekli sayıda fark alma işlemi gerçekleştirilerek durağanlık elde edilir; alınan fark sayısı modelde d parametresi olarak ifade edilir. Genel ARIMA(p,q,d) modelinin ifadesi:

$$w_t = \left(\emptyset_1 w_{t-1} + \emptyset_1 w_{t-2} + \ldots + \emptyset_1 w_{t-p}\right) - \left(\emptyset_0 \alpha_t + \ldots + \emptyset_q \alpha_{t-q}\right) \quad (3.8)$$

(3.8)'i $w_t = \nabla^d \alpha_t$ şeklinde ifade edilirse, ∇: fark alma operatörü, d: fark alma derecesi, w_t : farkı alınmış seri ve B: backshift operatörü olmak üzere d=1 eşitliğinde fark operatörü:

$$\nabla x_t = w_t = x_t - x_{t-1} \quad (3.9)$$

Olmak üzere ARIMA(1,1,1) modelinin eşitliği:

$$\nabla x_t - \nabla x_{t-1} = \alpha_t - \theta_1 \alpha_{t-1} \quad (3.10)$$

veya;

$$(1 - \emptyset_1 B)\nabla x_t = (1 - \emptyset_1 B)\alpha_t \quad (3.11)$$

olarak ifade edilir.

3.1.5 ARIMA Modelinin Avantajları ve Dezavantajları

ARIMA modeli, zaman serilerinin geçmiş verilerine dayanarak gelecek dönem değerlerini tahmin etmede oldukça sık kullanılan parametrik bir yaklaşımdır. Bu modelin en önemli avantajlarından biri, hem otoregresif (AR) hem de hareketli ortalama (MA) bileşenlerini aynı yapıda birleştirmesi sayesinde büyük bir seriyi temsil edebilme esnekliğine sahip olmasıdır. Buna ek olarak, durağan olmayan seriler için entegrasyon (fark alma) işlemiyle durağanlık sağlanarak modelin geçerliliği artırılmaktadır. Özellikle kısa ve orta vadeli tahminlerde yüksek

performans göstermesi, ARIMA'nın finans, ekonomi ve üretim planlaması gibi alanlarda yaygın şekilde kullanılmasına olanak tanımaktadır [23].

ARIMA modelinin avantajlarının yanı sıra bazı sınırlılıkları da mevcuttur. İlk olarak, model yalnızca lineer ilişkileri temsil edebildiğinden, doğrusal olmayan yapılar içeren serilerde yetersiz kalabilmektedir. Ayrıca, mevsimsel etkiler gibi periyodik bileşenlerin varlığı durumunda, standart ARIMA modeli yetersiz olabilir ve bu durumda SARIMA gibi genelleştirilmiş modellere ihtiyaç duyulmaktadır. Bir diğer önemli dezavantaj ise modelin parametrik doğası nedeniyle, uygun p, d ve q değerlerinin belirlenmesinde uzman bilgiye ve istatistiksel testlere olan gereksinimdir. Bu da modelleme sürecini karmaşık ve zaman alıcı hale getirebilmektedir.

Sonuç olarak, bu ARIMA modelleri zaman serisi analizinde oldukça güçlü ve esnek araçlar sunmakla birlikte, modelin etkili biçimde uygulanabilmesi için veri yapısının dikkatli analiz edilmesi ve parametrik varsayımların sağlanması gerekmektedir.

3.2 Zaman Serisi

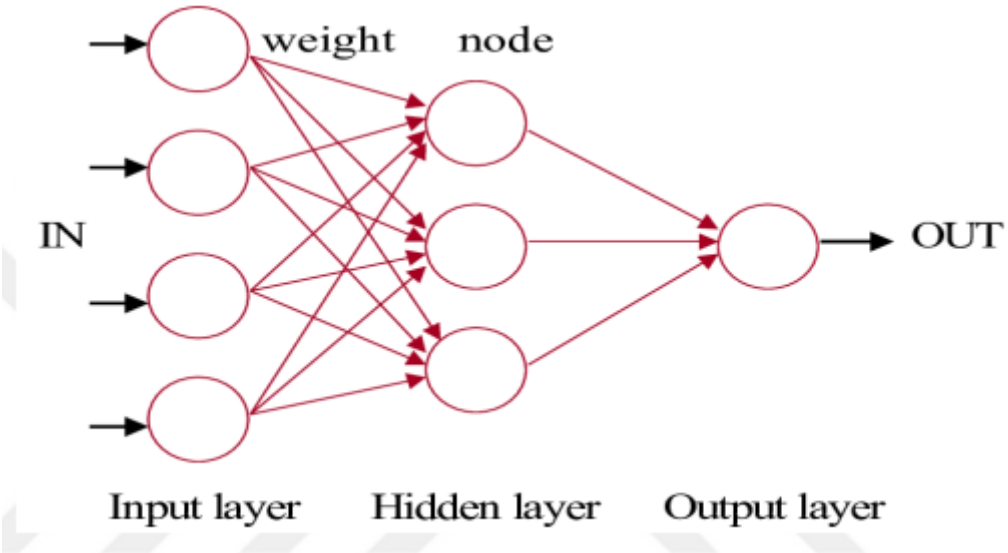
Zaman serisi tahminlemesi, sınıflandırma ve regresyon gibi daha temel problemlerle karşılaştırıldığında, gözlemler arasındaki sıralı ilişki ve zamana bağlılık nedeniyle çok daha karmaşık bir analiz alanı sunar. Bu zamansal bağımlılık, veri işleme ve model oluşturma aşamalarında ilave zorluklar yaratmakta; aynı zamanda trend ve mevsimsellik gibi düzenli yapılar aracılığıyla modelin başarısını artıracak bilgi kaynakları sağlamaktadır. Bu nedenle zaman serisi verileriyle çalışırken, veri ön işleme ve model yapılandırma süreci ayrı bir titizlik gerektirir.

Geleneksel zaman serisi modellemesinde, özellikle ARIMA (Otoregresif Entegre Hareketli Ortalama) gibi doğrusal yöntemler, uygulama kolaylığı ve yorumlanabilirlik açısından uzun süredir tercih edilmektedir. Bununla birlikte, son yıllarda gelişen makine öğrenimi ve derin öğrenme yaklaşımları, öngörü problemleri için alternatif çözümler sunmakta ve doğrusal yöntemlerin ötesine geçebilecek modellerin geliştirilmesine olanak tanımaktadır. Yakın dönemde gerçekleştirilen kapsamlı bir araştırma, 1000’i aşkın tek değişkenli zaman serisi

tahmin problemi üzerinde klasik ve modern birçok yöntemi karşılaştırmalı olarak değerlendirmiştir [24]. Araştırmanın dikkat çeken sonuçlarından biri, sıklıkla karmaşık olarak değerlendirilen karar ağaçları ve çok katmanlı yapay sinir ağları ve LSTM gibi modellerin, bazı durumlarda basit klasik yöntemlere kıyasla daha düşük performans sergileyebildiğidir. Bu bulgular, zaman serisi modelleme sürecinde yalnızca gelişmiş algoritmalara yönelmenin her zaman daha başarılı sonuçlar vermeyebileceğini ortaya koymaktadır. Dolayısıyla, herhangi bir makine öğrenmesi ya da derin öğrenme yaklaşımının değerlendirilmesinde klasik yöntemlerle karşılaştırmalı analiz yapılması, tahmin doğruluğunu artırmak için gerekli karmaşıklık düzeyinin dikkatle belirlenmesini sağlayacaktır [25].

3.2.1 Zaman Serilerinde Çok Katmanlı Algılayıcılar

Karışık problemlere çözüm üretmek için farklı katmanlarda toplanmış ek algılayıcıları birleştiren algılayıcılara çok katmanlı algılayıcılar denir. Şekil 3.6'da gösterildiği gibi temelde üç katmanlı birçok katmanlı algılayıcı(MLP)'de birinci katman giriş katmanıdır. Burada tüm algılayıcıların çıktılarını ikinci katmanda yer alan tüm algılayıcılara gönderir. Daha sonra ikinci katmanda yer alan tüm algılayıcılar, çıktılarını sağ tarafta yer alan son katman olan çıktı katmanına iletir. Tüm sinyaller için algılayıcılar farklı ağırlıkları kullanarak işlem yaparlar.



Şekil 3.1 Üç katmanlı MLP sinir ağının yapısı [25]

Şekil 3.1'de, bir katmandaki algılayıcıdan bir sonraki katmana ulaşan her çizgi, başka bir çıktıyı temsil etmektedir. Tüm katmanlar, çok sayıda algılayıcı içerebilir ve sistemin karmaşıklığını artırmak için birden fazla katman eklemesi yapılabilir. Bu sebeple, çok katmanlı algılayıcı hızla oldukça karmaşık bir sistem haline gelir. Bu algılayıcının diğer kullanılan adı da sinir ağıdır. Üç katmanlı bir MLP, yukarıdaki şemada olduğu gibi Derin Olmayan veya Sığ Sinir Ağı diye adlandırılırken, dört veya bundan daha fazla katmana sahip olanlar için Derin Sinir Ağı adlandırılması yapılır. MLP ve sinir ağı arasındaki önemli fark, klasik algılamada karar fonksiyonunun adım fonksiyonu olması ve çıktının ikili olmasıdır. MLP'lerden türeyen sinir ağlarında ise genellikle çeşitli aktivasyon fonksiyonları kullanılarak 0 ile 1 veya -1 ile 1 arasında gerçek değerlerle sonuçlanan çıktılar elde edilir. Bu, olasılık temelli tahminlere veya birden çok etikette sınıflandırmalara imkan tanır.

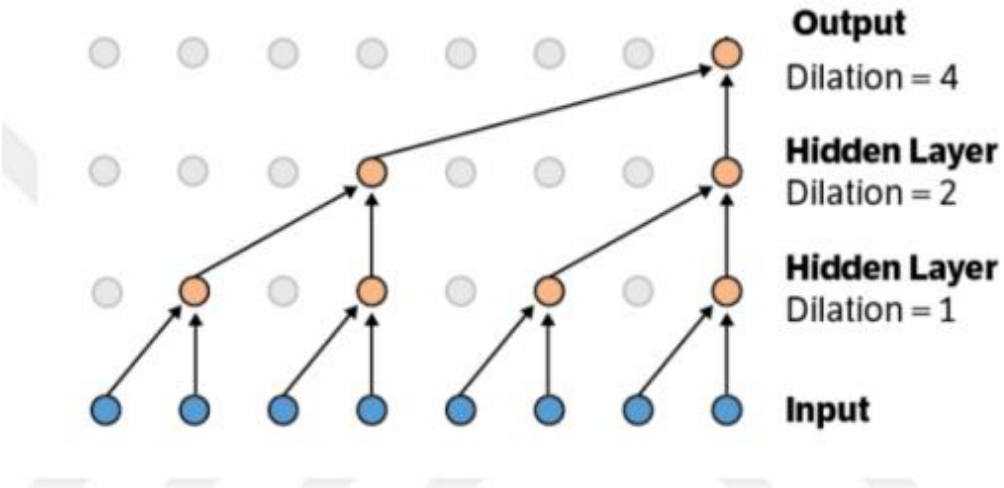
3.2.2 Evrişimli Sinir Ağları

Evrişimli Sinir Ağları (Convolutional Neural Networks – CNN), özellikle görsel verilerin işlenmesine yönelik olarak geliştirilmiş yapay sinir ağı modelleridir. Bu mimariler, yalnızca klasik görüntü sınıflandırma uygulamalarında değil; aynı zamanda nesne tespiti, görüntü açıklama oluşturma gibi ileri düzey bilgisayarla görme görevlerinde de yüksek başarı sağlamıştır. CNN'lerin temel avantajı, geleneksel olarak elle tanımlanan öznitelikler yerine, doğrudan ham piksel verileri üzerinden çalışarak ilgili göreve uygun özellikleri otomatik olarak öğrenebilmesidir. CNN yapıları, kayma ve bozulmalara karşı dayanıklılık sağlayabilmek amacıyla üç temel mimari ilkeyi bir araya getirir: yerel alıcı alanlar, paylaşılan ağırlıklar (ya da ağırlık paylaşımı) ve gerektiğinde uzamsal/zamansal alt örnekleme (subsampling). Bu yapı sayesinde model, veri içindeki temel örüntüleri öğrenirken gereksiz karmaşıklıktan kaçınır ve parametre sayısını azaltarak verimli bir öğrenme süreci sağlar.

Evrişimli ağlar, görüntü işleme dışında zaman serisi tahmini gibi daha karmaşık ve sıralı veri problemlerine de başarıyla uygulanabilir. Çok Katmanlı Algılayıcılara (MLP) kıyasla CNN'ler, çok değişkenli girdi ve çıktıları daha etkili şekilde işleyebilme kapasitesine sahiptir. Özellikle geçmiş zaman adımlarından gelen bilgileri dolaylı biçimde temsil edebildikleri için, modelin doğrudan zaman

gecikmesi temelli öğrenmeye ihtiyaç duymadan, büyük hacimli giriş verilerinden anlamlı bir temsil öğrenmesini mümkün kılar.

Başlangıçta iki boyutlu görsel veriler için tasarlanmış olsalar da, CNN mimarileri tek değişkenli zaman serisi problemlerinde de kullanılabilir. Bu tür veriler, sıralı ve zaman bağımlı tek bir gözlem serisinden oluşur ve temel hedef, geçmiş verilere dayanarak bir sonraki değeri öngörmektir. CNN bu bağlamda, geçmiş gözlemlerin belirli bir penceresini alarak, bu pencereye karşılık gelen çıktıyı tahmin etmeyi öğrenen bir fonksiyon oluşturur. Böylece sıralı verilerdeki yapılar modellenerek yüksek doğrulukta tahminler üretilebilir.



Şekil 3.2 Evrimsel sinir ağı yapısı [24]

Evrişimli sinir ağları (CNN), özellikle aktif tanıma görevlerinde sunduğu yenilikçi avantajlarla dikkat çekmektedir. Bu mimarinin en önemli katkılarından biri, geleneksel yöntemlerin aksine, özellik çıkarma sürecinin manuel olarak tanımlanmasına gerek kalmadan, göreve özgü olarak otomatik şekilde öğrenilebilmesidir. Sistem, ham veriler üzerinden doğrudan anlamlı özellikler elde ederek, insan müdahalesine duyulan ihtiyacı en aza indirir. Buna ek olarak, CNN'lerin en güçlü yönlerinden biri de özellik çıkarma ile sınıflandırma süreçlerini ayrı ayrı yürütmek yerine, bu iki aşamayı aynı yapısal çerçevede bütünleştirebilmesidir. Böylelikle, bir yandan insan faaliyetlerinin ayırt edici örüntülerini öğrenirken, diğer yandan bu örüntülere uygun şekilde sınıflandırma yaparak iki süreci karşılıklı olarak optimize eder. Bu entegrasyon, modelin genel

doğruluğunu artırmakla kalmaz, aynı zamanda sistemin gerçek dünya uygulamalarına uyum sağlamasını da kolaylaştırır.

3.2.3 Tekrarlayan Sinir Ağı

Tekrarlayan Sinir Ağları (Recurrent Neural Networks – RNN), geçmiş çıktıları gelecekteki hesaplamalara entegre edebilen bir sinir ağı yapısıdır. Bu mimari, önceki zaman adımlarından elde edilen çıktıyı bir sonraki adıma girdi olarak ileterek, zaman bağımlılığı gösteren verileri işleme konusunda avantaj sağlar. Geleneksel ileri beslemeli sinir ağlarının aksine, RNN yapıları zaman içindeki ardışık veriler arasındaki bağımlılıkları dikkate alır. Örneğin, bir cümledeki bir kelimenin doğru tahmin edilebilmesi için, önceki kelimelerin bağlamının bilinmesi gerekir. RNN'ler, bu tür bağlam bilgisini gizli durum (hidden state) yoluyla bellekte tutarak bu ihtiyacı karşılar. RNN'nin en temel özelliği, geçmiş bilgileri taşıyan bir gizli durumu her zaman adımında güncellemesidir. Model, her bir zaman adımında aynı parametreleri (ağırlıklar) kullanarak girişleri işler ve çıktı üretir. Bu parametre paylaşımı, modelin karmaşıklığını azaltırken aynı zamanda öğrenme sürecini daha verimli hâle getirir. Makine öğrenmesinde farklı veri türlerine özel algoritmalar geliştirilmiştir; ancak sıralı veriler, yapısal olarak diğer veri türlerinden ayrılır. Çünkü bu tür verilerde, özellikler arasında zamansal bir bağlantı vardır ve veriler bağımsız olarak değerlendirilemez. Bu nedenle, sıralı verilerin analizi için geliştirilen RNN mimarisi, zamanla değişen verilerin öğrenilmesi ve modellenmesi konusunda güçlü bir alternatif sunar. Diğer sinir ağı yapılarında ileri besleme ve geri yayılım süreçleri doğrusal bir yapıyı izlerken, RNN'lerde zaman boyutunda tekrarlayan bir ilişki söz konusudur. Eğitim sırasında ise klasik geri yayılım yerine zaman boyunca geri yayılım (Backpropagation Through Time – BPTT) yöntemi kullanılarak ağın parametreleri güncellenir. Bu yaklaşım, modelin zamana dayalı örüntüleri öğrenmesine olanak tanır ve temel olarak dil modelleme, zaman serisi analizi ve ses işleme gibi alanlarda oldukça sık bir şekilde kullanılmaktadır.

3.3 Yapay Sinir Ağları

Bu kısımda, yapay sinir ağı modelleri ile bu modellere ait temel bileşenler ve mimari yapılar ele alınacaktır. Yapay sinir ağlarının öğrenme mekanizmaları ve bu yapıların sermaye piyasalarındaki uygulama alanlarına ilişkin bağlantılar değerlendirilecektir. Zaman serisi tahmini bağlamında özellikle tek değişkenli

LSTM modellerine odaklanılarak, bu yöntemlerin finansal veriler üzerindeki etkinliği detaylı şekilde analiz edilecektir. Bilgisayar ve yazılım teknolojilerindeki gerçekleşen hızla büyüme, bireylerin günlük yaşamda ve iş süreçlerinde dijital sistemleri yoğun bir şekilde kullanmalarını beraberinde getirmiştir. Bu teknolojik dönüşümle birlikte, insanlar sürekli olarak yeni çözüm yolları ve yöntemler geliştirmişlerdir. Bu çerçevede, 1980'li yıllarda makinelerin insan benzeri düşünme yetisine sahip olabileceği fikri yapay zekâ araştırmalarının temelini oluşturmuştur. 1990'lı yıllardan itibaren ise Yapay Sinir Ağları (YSA) alanı, önemli ilerlemeler kaydederek bu düşüncenin somut uygulama alanlarından biri hâline gelmiştir [26]. Yapay Sinir Ağları, yapay zekânın önde gelen alt disiplinlerinden biri olarak ortaya çıkmış ve zamanla araştırmacılar için önemli bir çalışma alanı hâline gelmiştir. Bu bölümde, YSA kavramı teorik temelleriyle ele alınmakta, mimari yapısı açıklanmakta ve uygulamalı örneklerle desteklenerek farklı başlıklar altında ayrıntılı biçimde sunulmaktadır. Yapay sinir ağları, sahip oldukları öğrenme ve genelleme kabiliyetleri sayesinde, örnek verilerden bilgi edinme, çıkarımda bulunma ve daha önce karşılaşılmamış durumlara yönelik çözüm üretme becerisine sahiptir. Bu yönleriyle, günümüzde pek çok disiplin tarafından tercih edilmekte; özellikle karmaşık ve doğrusal olmayan problemlerin çözümünde başarılı sonuçlar vermektedir [27].

3.3.1 Tanım ve Tarihçe

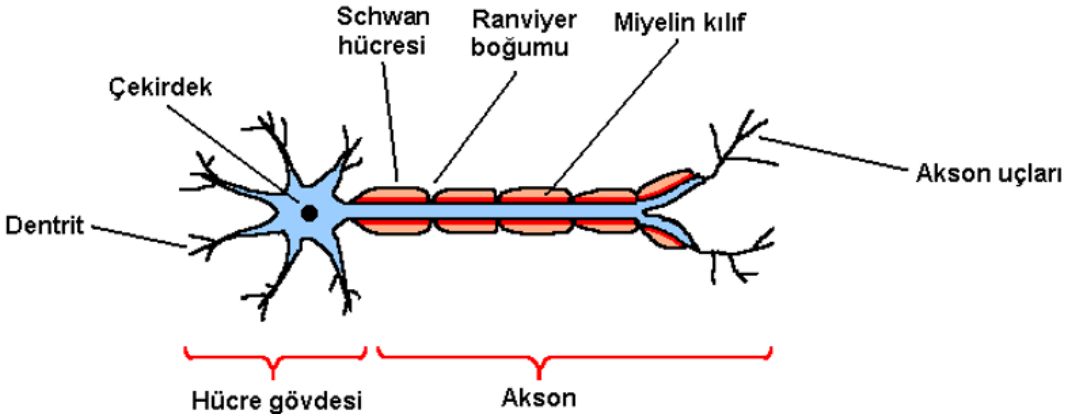
Yapay sinir ağları (YSA), sahip oldukları öğrenme ve genelleme kabiliyetleri sayesinde, örnek verilerden bilgi edinme, çıkarımda bulunma ve daha önce rastlanılmamış durumlara yönelik çözüm üretme becerisine sahiptir. Bu yönleriyle, günümüzde pek çok disiplin tarafından tercih edilmektedir. Özellikle karmaşık ve doğrusal olmayan problemlerin çözümünde başarılı sonuçlar vermektedir. Bu sinir ağı yapısı insan beyni özelliklerinden ilham alınarak geliştirilen, birbirine ağırlıklı bağlantılarla bağlanan ve hepsi için yerel bellek yapısına mevcut işlem birimlerinden meydana gelen paralel ve dağıtık bir bilgi işleme sistemidir. Bu sistemler, biyolojik sinir hücrelerinin işleyişini modelleyen yazılım tabanlı yapılardır. Yapay sinir ağı modeline ait teorik zemin 1940'lı yılların başında W.A. Pitts ve W.S. McCulloch'ın öncülüğünde geliştirilen hesaplama modeliyle atılmıştır [28]. Bu çalışmalar, 1943 yılında yayımlanan bir makale ile bilim dünyasına tanıtılmıştır. 1954 yıllara gelindiğinde W.A. Clark ve B.G. Farley

tarafından geliştirilen yeni modeller, uyarıcılara tepki verebilen ve bu uyarıcılara göre kendini uyarlayabilen ağ yapıları sunmuştur [29]. "Neural" bilgisayar kavramı ise 1960 yılına kadar uzanmakta olup, 1963'te geliştirilen erken dönem modellerin sınırlılıkları fark edilmiştir. Yapay sinir ağlarının gerçek anlamda gelişimi ise 1970'li ve 1980'li yıllarda, termodinamik kuramların doğrusal olmayan sistemlerin modellenmesinde kullanılmaya başlanmasıyla ivme kazanmıştır. 1985 yılı, bu teknolojinin daha geniş kitlelerce tanındığı ve yoğun akademik araştırmalara konu olduğu önemli bir dönüm noktası olmuştur. Yapay sinir ağlarının uygulama alanları oldukça geniş bir çerçeveye sahiptir. Kontrol ve otomasyon, sistem modelleme, görüntü ve ses tanıma, tahminleme ve kestirim, hata tespiti, iletişim sistemleri, tıp uygulamaları, trafik yönetimi ve üretim süreçlerinin kontrolü gibi birçok alanda başarıyla uygulanmaktadır [27].

Yapay sinir ağı yapısı, geleneksel sinir ağı yapısına göre birçok konuda farklılık içermektedir. Geleneksel algoritmalar, belirli kuralların tanımlanması ve bu kuralların giriş verilerine uygulanmasıyla çıkışları üretir. Bu yapıda bilgi işleme süreci, merkezi, eş zamanlı ve ardışık bir şekilde gerçekleşmektedir. Bilgi, önceden tanımlanmış algoritmalar yardımıyla kesin biçimde işlenir ve bellek, paketlenmiş halde hazır bilgilerin depolanmasına olanak sağlar. Bu sistemlerde hata toleransı bulunmaz dolayısıyla hata durumlarında sistem performansı ciddi şekilde etkilenebilir. Bununla beraber, işlem yapma hızı genel itibariyle yüksektir. Diğer yandan, yapay sinir ağları ise deneyime dayalı öğrenme mekanizmalarıyla çalışır. Öğrenme süreci boyunca sisteme giriş ve çıkış verileri sağlanır ve sistem bu verilerden kuralları kendi içinde üretir. Hesaplama süreci toplu ve eş zamansızdır. Öğrenme işlemi tamamlandıktan sonra ise paralel biçimde işlem yapılabilir. Yapay sinir ağlarında bellek, tüm ağa yayılmış şekilde yapılandırılır ve sistem, hata durumlarına karşı belli bir tolerans sergiler. Ancak bu yapılar genellikle geleneksel algoritmalara kıyasla daha yavaş çalışır ve donanım kaynaklarına daha bağımlıdır.

3.3.2 Biyolojik Sinir Hücresi

Biyolojik sinir hücreleri sinir ağları yapısının ana bileşenlerindendir. Fizyolojik olarak insan beyninde korteks adı verilen bölgede 10^{11} adet sinir hüceresi bulunmakta olup, her bir nöron yaklaşık 1.000 ila 10.000 nöronla etkileşim içerisindedir. Bu etkileşimler, sinir sisteminin bilgi işleme kapasitesinin temelini oluşturur.

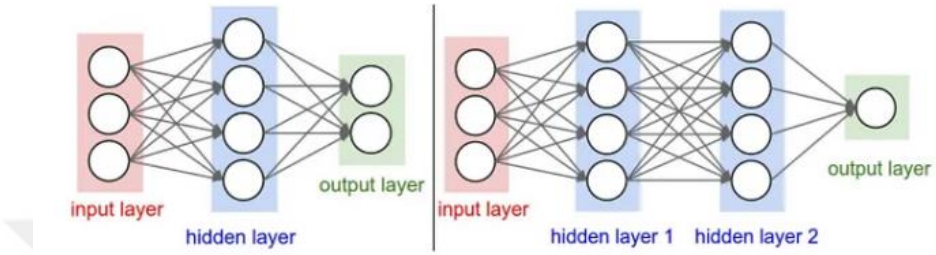


Şekil 3.3 Sinir hücresinin biyolojik gösterimi [30]

Nöronlar arasındaki iletişim sinaps denen bağlantı noktaları aracılığıyla sağlanır. Sinapslar, bulundukları nörona ait aksonun başka bir nöronun dendriti ile bağlantıya geçtiği yapılar olup, sinyallerin kimyasal yollar aracılığıyla iletiminden sorumludur. Bu iletişim sürecinde sinaptik boşluk olarak adlandırılan mikroskobik aralıklarda, sinaptik keseciklerde depolanan nörotransmitterler serbest bırakılır. Nörotransmitter maddelerin sinaptik boşluğa salınımı, uyarının bir nörondan diğerine geçişini mümkün hale getirir. Bu iletim sürecine, miyelin kılıf adı verilen yalıtkan bir yapı da katkı sağlar. Miyelin tabaka, akson boyunca sinyal iletim hızını artıran bir yalıtım görevi görür. Ayrıca, çekirdek yapısı akson boyunca sinyallerin düzenli bir şekilde yeniden üretilmesine katkı sağlar. Dendritler yoluyla alınan uyarılar, hücre içi kimyasal süreçleri tetikleyerek aksonlar aracılığıyla diğer nöronlara aktarılır. Bu süreç yalnızca bilgi iletimini sağlamakla kalmaz, aynı zamanda nöronlar arasındaki bağlantıların değişmesine ya da yeni sinaptik bağların oluşmasına neden olur. Bu durum, biyolojik düzeyde öğrenme kavramının temelini oluşturur. Biyolojik sinir sistemindeki bu işleyiş, yapay sinir sistemleri için bir model teşkil etmiştir. Bu bağlamda, biyolojik nöronlar yapay sinir ağlarında işlemci elemanlar olarak modellenir. Dendritler, yapay nöronlarda toplama fonksiyonunu üstlenirken, hücre gövdesi transfer fonksiyonu ile temsil edilir. Aksonlar, yapay nöronun çıkışı olarak modellenirken, sinapslar ise yapay ağlardaki bağlantı ağırlıklarını simgeler. Bu benzerlikler, biyolojik sistemlerden esinlenerek geliştirilen yapay sinir ağlarının temel mimarisini oluşturmaktadır [30].

3.3.3 Yapay Sinir Yapısı

Biyolojik sinir ağlarında olduğu gibi yapay sinir ağlarında da biyolojik sinir hücrelerine benzeyen yapay sinir hücreleri mevcuttur. Bu hücreler mühendislikte proses elamanları diye adlandırılırlar. Tüm bu proses elemanları incelendiğinde bu elemanların 5 temel ögeden oluştuğu görülmektedir.



Şekil 3.4 Yapay nöron yapısı [31]

Bir yapay sinir ağı hücresi, dış dünyadan gelen verileri işlemek üzerine tasarlanmış bir hesaplama aracı olarak çalışmaktadır. Sistemin temelinde, dış çevreden veya diğer hücrelerden alınan girdiler yer alır. Girdiler, aslında sistemin öğrenmesi beklenen örnekleri temsil etmektedir; yani ağın temelde neyi, nasıl öğrenmesi gerektiği bu girdiler aracılığıyla belirlenmektedir. Bu bilgiler, sadece varlıklarıyla değil, taşıdıkları öneme göre de işlenir. İşte burada devreye ağırlıklar girer. Her bir girdiye karşılık gelen ağırlık, o bilginin hücre üzerindeki etkisini temsil eder. Ancak ağırlığın büyüklüğü her zaman etkisinin yüksek olduğunu göstermez. Zaman zaman sıfır değerindeki bir ağırlık, sistemin genel işleyişi açısından belirleyici olabilir ve ağın öğrenme sürecinde en kritik unsur haline gelebilir. Girdiler, belirli bir işlem mantığı çerçevesinde toplanarak hücreye net bir bilgi akışı sağlar. Bu işlemi gerçekleştiren yapıya toplama fonksiyonu ismi verilir. Çoğu yapay sinir ağı modelinde, bu işlem genellikle ağırlıklı toplam yöntemiyle yapılır; yani her bir girdi, kendi ağırlığıyla çarpılır ve sonuçlar toplanarak hücreye ulaşan net girdi elde edilir. Farklı toplama yöntemleri mevcut olmakla birlikte, bu yaklaşım sadeliği ve etkinliği nedeniyle yaygın olarak tercih edilir [31].

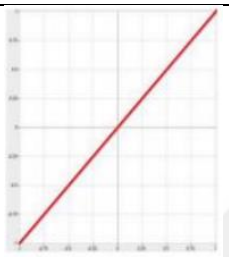
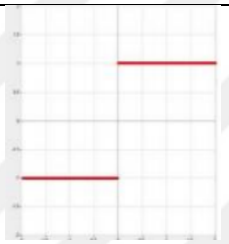
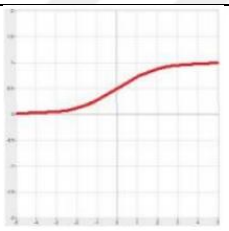
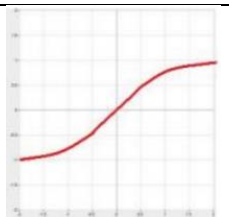
Tablo 3.1 Bazı toplama fonksiyonları

Toplam Net = $\sum_{i=1}^{N} X_i * W_i$	Ağırlık değerleri girdiler ile çarpılır ve bulunan değerler birbirleriyle toplanarak Net girdi hesaplanır.
Çarpım Net = $\prod_{i=1}^{N} X_i * W_i$	Ağırlık değerleri girdiler ile çarpılır ve daha sonra bulunan değerler birbirleriyle çarpılarak Net girdi hesaplanır.
Maksimum Net = Max($X_i * W_i$)	n adet girdi içinden ağırlıklar girdilerle çarpıldıktan sonra içinden en büyüğü net girdi olarak kabul edilir.
Minimum Net = Min($X_i * W_i$)	n adet girdi içinden ağırlıklar girdilerle çarpıldıktan sonra içinden en küçüğü net girdi olarak kabul edilir.
Çoğunluk Net = $\sum_{i=1}^{N} Sgn(X_i * W_i)$	n adet girdi içinden girdilerle ağırlıklar çarpıldıktan sonra pozitif ile negatif olanların sayısı bulunur. Büyük olan sayı hücrenin net girdisi olarak kabul edilir.
Kümilatif Toplam Net = Net(eski) + $\sum_{i=1}^{N} X_i * W_i$	Hücreye gelen bilgiler ağırlıklı olarak toplanır. Daha önce hücreye gelen bilgilere yeni hesaplanan girdi değerleri eklenerek hücrenin net girdisi hesaplanır.

Hücreye ulaşan net girdi, sistemin tepki üretmesi için yeterli değildir. Bu noktada, aktivasyon fonksiyonu devreye girer. Aktivasyon fonksiyonu, hücrenin aldığı toplam girdiye karşılık hangi çıktıyı vereceğini belirleyen mekanizmadır. Genellikle doğrusal olmayan bir yapıya sahip olan bu fonksiyon, ağın karmaşık ilişkileri öğrenebilmesini sağlar. Aktivasyon fonksiyonunun seçiminde bir diğer önemli kriter de, fonksiyonun türevinin basitçe hesaplanabilmesidir. Özellikle geri yayılım gibi öğrenme algoritmalarında, türev hesapları yoğun olarak kullanıldığından, bu özellik hesaplama verimliliği açısından büyük önem taşır. Sigmoid fonksiyonu, bu nedenle çok katmanlı algılayıcı modellerde en sık tercih edilen aktivasyon fonksiyonlarından biri haline gelmiştir. Hücrenin ürettiği çıktı, doğrudan dış ortama ya da başka bir hücreye iletilir. Bazı durumlarda ise hücre, kendi çıktısını tekrar kendisine girdi olarak göndererek daha karmaşık hesaplama döngüleri oluşturur. Bir işlem biriminin birden fazla çıktısı olabilir; ancak çoğu yapıda yalnızca bir ana çıktı değerlendirmeye alınır. Bu genel yapı, sinir ağlarının temel hesaplama birimi olan düğüm ya da birim etrafında şekillenir. Her birim, dış

kaynaktan ya da başka birimlerden aldığı girdileri belirli bir işlem süzgecinden geçirir. Bu süzgeç, sinaptik öğrenme modelinden esinlenerek geliştirilen ve girdilerin önemini ağırlıklar aracılığıyla belirleyen bir yapı içerir. Sonuçta, ağın karar verme süreci, bu ağırlıklı girdilerin bir fonksiyonu olarak ortaya çıkar ve öğrenme süreci de bu kararların tekrarlı biçimde düzenlenmesine dayanmaktadır.

Tablo 3.2 Aktivasyon fonksiyonları

Doğrusal(Lineer) Aktivasyon Fonksiyonu		F(Net)=A*NET (A sabit bir sayı)
Adım (Step) Aktivasyon Fonksiyonu		F(Net)=$\begin{cases} 1\ if\ Net > Eşik\ Değer \\ 0\ if\ Net \leq Eşik\ Değer \end{cases}$
Sigmoid Aktivasyon Fonksiyonu		$F(Net) = \frac{1}{1+e^{-Net}}$
Tanjant Hiperbolik Aktivasyon Fonksiyonu		$F(Net) = \frac{e^{Net}+e^{-Net}}{e^{Net}-e^{-Net}}$
Eşik Değer Fonksiyonu	-	$F(Net) = \begin{cases} 0\ if\ Net \leq 0 \\ Net\ if\ 0 < Net < 1 \\ 1\ if\ Net \geq 1 \end{cases}$
Sinüs Aktivasyon Fonksiyonu	-	F(Net)=Sin(Net)

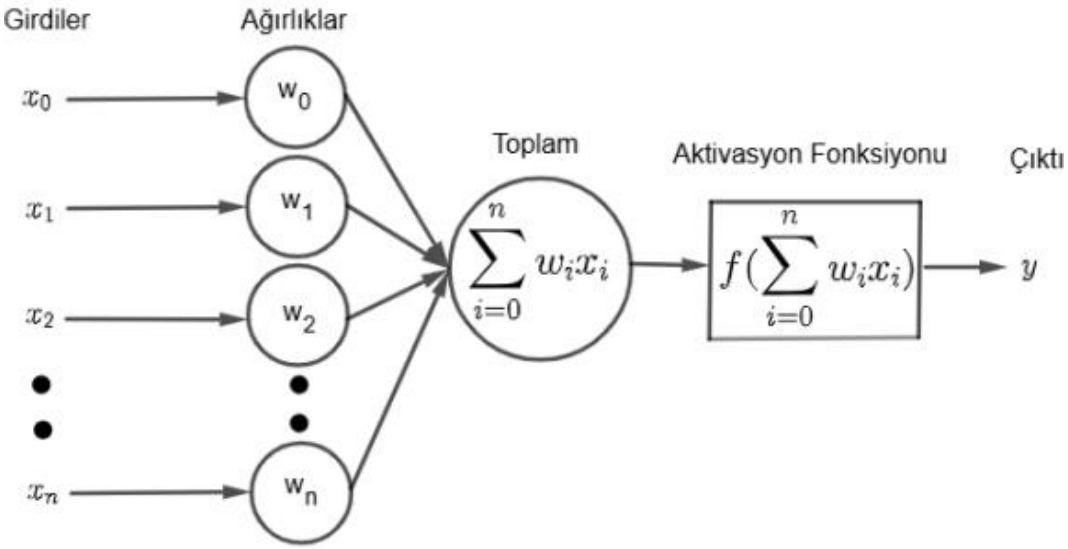
3.3.4 Derin Öğrenmede Sinir Ağları

Derin öğrenme temelli sinir ağı modelleri, giriş ve çıkışlar arasındaki karmaşık ilişkileri otomatik olarak öğrenebilme yeteneğine sahiptir ve çok sayıda girdi-çıktı kombinasyonunu aynı anda işleyebilir. Bu güçlü yapı, özellikle doğrusal olmayan bağımlılıkların bulunduğu karmaşık veri yapıları, çok boyutlu girdi setleri ve çok adımlı tahmin gerektiren zaman serisi problemleri açısından önemli avantajlar sunmaktadır. Derin öğrenme mimarilerinin modern özellikleri sayesinde; evrişimli sinir ağlarında (CNN) otomatik öznitelik çıkarımı ve tekrarlayan sinir ağlarında (RNN) ardışık veri yapılarına özel modelleme gibi beceriler sağlanmaktadır.

Zaman serisi tahmini alanında, derin sinir ağlarının sunduğu olanaklar dikkat çekici bir etkiye sahiptir. Bu modeller, giriş verileri ile hedef değişkenler arasındaki karmaşık örüntüleri öğrenerek, klasik doğrusal tahminleme tekniklerinin sınırlarını aşan performanslar sergileyebilir. Geleneksel yöntemlerde zaman serisinin yapısı genellikle elle tanımlanırken, tekrarlayan yapılar kullanan modeller geçmiş verilerden öğrenerek eğilim ve mevsimsellik gibi örüntüleri doğrudan keşfedebilir. Teknik olarak, bir zaman dizisinin ardışık yapısı göz önüne alındığında, derin öğrenme modelleri mevcut bağlamı değerlendirerek geleceğe yönelik isabetli tahminlerde bulunma kapasitesine sahiptir.

3.4 Yapay Sinir Ağ Mimarisinde Kullanılan Terminolojiler

Sinir ağları, girişleri çıkışlarla eşleştirmek ve karmaşık bir öğrenilmiş algoritma oluşturmak için katmanlar ve nöronlar kullanır. Yapay sinir hücreleri, bir araya gelerek yapay sinir ağlarını oluşturur ve bu birleşme rastgele olmaz. Genellikle, sinir hücreleri her bir tabakada paralel olacak şekilde düzenlenir ve üç tabakalı yapı oluşturur. Bu sayede, her katman önceki ve sonraki katmanlardaki birçok nörona bağlanır, böylece ağ katmanlar arasında etkileşim kurar.



Şekil 3.5 Yapay sinir hücresinin sistematik gösterimi [32]

Çok katmanlı yapay sinir ağı aşağıda gösterildiği şekilde tanımlanır:

$$\gamma_k = b_j^1 \partial(\sum_{k=1}^{m} w_{jk}^2(t)\theta\,(\sum_{j=1}^{n_h} w_{ij}^1 x_i^0(t))) \tag{3.12}$$

- $1 \leq j \leq n_h$: Gizli katman düğüm sayısı
- $1 \leq k \leq m$: Çıkış katmanı düğüm sayısı
- w_{ij}^1 : Çok katmanlı sinir ağının giriş ve gizli katman arasındaki bağlantı ağırlık değeri
- w_{ij}^2 : Giriş ve çıkış katmanı arasındaki bağlantı ağırlık değeri
- x_i^0 : Giriş katmanı vektörü
- b_j^1 : Gizli katman eşik değeri
- ∂ : Aktivasyon fonksiyonunu
- θ : Optimizasyon fonksiyonunu

3.4.1 Giriş Katmanı

Sinir ağı yapısında yer alan ilk katman olan giriş katmanı, dış ortamdan alınan verileri modelin işleyebileceği forma dönüştürerek gizli katmanlara ileten bileşendir. Bu katman, modele verilen girdi vektörünü alır ve doğrudan bir çıktı üretmese de, verilerin ağ içinde doğru biçimde temsil edilmesini sağlar. Başka bir ifadeyle, giriş katmanı, dış veri ile sinir ağı arasındaki ilk temas noktasını oluşturarak bilgiyi iç yapıya aktarır. Giriş katmanının temel işlevi, dışsal değişkenleri tanımak ve bu değişkenleri ağın öğrenme sürecine entegre etmektir. Bu nedenle, giriş katmanının yapısı, ağın eğitildiği problem bağlamında uygun bir

şekilde kurgulanmış olmalıdır. Her bir giriş nöronu, modele etki eden bağımsız bir değişkeni temsil eder ve bu nöronlar aracılığıyla ağın çıktıları şekillenir. Girdi katmanı, sinir ağının öğrenme başarısını doğrudan etkileyen kritik bir bileşen olarak değerlendirilir.

3.4.2 Gizli Katman

Gizli katman, sinir ağlarında giriş ve çıkış katmanları arasında yer alan ve üzerinde aktivasyon fonksiyonları uygulanan nöronları barındıran ara katmandır. Gizli katmanın matematiksel gösterimi:

$$z_j^{(l)} = \sum_{i=1}^{n} w_{ji}^{(l)} . a_j^{(l-1)} + b_j^{(l)} \quad (3.13)$$

$$a_j^{(l)} = \emptyset(z_j^{(l)}) \quad (3.14)$$

- $w_{ji}^{(l)}$: Ağırlıklar
- $b_j^{(l)}$: Bias(sapma)
- $\emptyset$: Aktivasyon fonksiyonu (ReLU, Sigmoid, Tanh vb.)
- $a_j^{(l)}$: l. katmandaki j. nöronun çıktısı

Gizli katmanın temel görevi, bir önceki katmandan alınan girdileri işleyerek daha soyut özellikler elde etmektir. Özellikle ham verilerden anlamlı öznitelikler çıkarmak açısından kilit rol oynar. Literatürde, gizli katmanda kaç nöron bulunması gerektiğine dair çok sayıda çalışma yapılmış olsa da, bu konuda evrensel olarak kabul görmüş sabit bir sayı bulunmamaktadır. Buna ek olarak, bir sinir ağı birçok gizli katman içerebilir ve bu katmanların sayısı, modelin ele aldığı problemin yapısına göre belirlenir. Eğer modelin eğitileceği veri seti doğrusal olarak ayrılabiliyorsa, giriş ve çıkış arasında doğrudan ilişki kurulabileceği için aktivasyon fonksiyonu yeterli olur ve gizli katmana ihtiyaç duyulmaz. Ancak karmaşık yapıya sahip, doğrusal olmayan karar sınırlarına sahip problemler söz konusu olduğunda, 3 ila 5 arasında değişen sayıda gizli katman kullanılması önerilir. Yine de, katman sayısını artırmak her zaman daha iyi sonuç vermeyebilir; aşırı derin mimariler, modelin eğitim verisine fazlasıyla uyum sağlaması yani "overfitting" riski yaratabilir. Benzer şekilde, her bir gizli katmandaki nöron sayısı da dikkatle belirlenmelidir. Eğer bu sayı, verinin taşıdığı bilgi miktarına oranla yetersiz kalırsa, ağ verideki örüntüleri doğru şekilde öğrenemez. Öte yandan, gereğinden fazla

sayıda nöron içeren katmanlar da yine aşırı öğrenmeye ve modelin genellenebilirliğinin azalmasına neden olabilir. Gizli katman sayısını ve bu katmanlardaki nöron miktarını belirlemek için sabit bir matematiksel formül bulunmamakla birlikte; çapraz doğrulama, deneme-yanılma yöntemleri ve hiperparametre optimizasyon teknikleri gibi çeşitli yaklaşımlar bu amaçla kullanılabilmektedir.

3.4.3 Çıktı Katmanı

Sinir ağının son bileşeni olan çıkış katmanı, ağ içerisinde işlenen bilgileri toplayarak son çıktıyı üretir ve dış dünyaya aktarır. Çıktı katmanın matematiksel gösterimi:

$$\hat{y} = f(w^T a + b) \tag{3.15}$$

- $\hat{y}$: Modelin tahmini çıktısı
- f : Aktivasyon fonksiyonu
- a : Son gizli katmandan gelen aktivasyonlar
- w : Ağırlık vektörü
- b : Bias

Bu katman, ağın nihai kararlarını veya tahminlerini temsil ederken, ürettiği çıktı deseni çoğu zaman giriş katmanından itibaren ağ boyunca izlenen bilgi akışının bir sonucudur. Çıkış katmanındaki nöron sayısı, modelin üstlendiği görev türüne bağlı olarak belirlenir. Bu nedenle, ağın tasarım sürecinde ilk olarak çıkışların hangi amaca hizmet edeceği dikkate alınmalıdır. Çıkış katmanı, ağın tahmin ettiği sonuçları sunmak ve bu sonuçları hedef değerlerle karşılaştırmak amacıyla yapılandırılmış nöronlardan oluşur. Eğer ağ regresyon (süreklilik gösteren değerlerin tahmini) problemini çözmek üzere yapılandırılmışsa genellikle tek bir nöron yeterli olur. Ancak sınıflandırma problemlerinde, kategorilerin sayısına bağlı olarak birden fazla çıkış nöronuna ihtiyaç duyulabilir. Sonuç olarak, çıkış katmanının tasarımı, problem türüyle doğrudan ilişkilidir ve modelin doğruluğunda oldukça önemli bir etkisi vardır.

3.4.4 Evrişimli Katman

Evrişim katmanı, Evrişimli Sinir Ağları (Convolutional Neural Networks – CNN) mimarisinin en temel yapı taşlarından biridir. Evrişimli katmanın matematiksel gösterimi:

$$S(i,j) = (X * K)(i,j) = \sum_m \sum_n X(i+m, j+n).K(m,n) \quad (3.16)$$

- X : Giriş verisi (Örnek görüntü matrisi)
- K : Filtre (Kernel)
- * : Evrişim işlemi
- $S(i,j)$: Konvolüsyon sonucunda elde edilen özellik haritası (feature map)

Bu katman, genellikle giriş boyutundan daha küçük boyutlara sahip filtreler veya çekirdekler aracılığıyla veri üzerinde konvolüsyon işlemi gerçekleştirir. Her bir filtre, giriş verisi üzerinde belirli bir alanı tarayarak, o alandaki yapısal özelliklerle etkileşime girer ve bu işlem sonucunda o filtreye özgü bir aktivasyon haritası (feature map) oluşturulur. Filtreler modelin eğitim süreci boyunca optimize edilir ve bu süreçte temel kenar yapıları, dokular veya karmaşık desenleri tanımayı öğrenirler. Böylece ağ, giriş verisindeki düşük seviyeli detaylardan daha soyut ve anlamlı özellikler elde edebilir. Elde edilen her bir aktivasyon haritası, üç boyutlu tensör şeklinde temsil edilir ve bu haritalar derin ağlarda sonraki katmanlara aktarılır. Evrişim katmanına gelen veri, doğrudan modelin girişinden veya önceki evrişim katmanının çıktısı olan özellik haritasından sağlanabilir. Bu katmanda yaygın olarak kullanılan aktivasyon fonksiyonlarından biri ReLU (Rectified Linear Unit) fonksiyonudur. ReLU, negatif değerleri sıfıra indirgerken pozitif değerleri olduğu gibi geçirerek doğrusal olmayanlık kazandırır. Ayrıca, hiperparametre içermemesi nedeniyle uygulaması sade ve etkilidir.

3.4.5 Havuzlama Katmanı

Havuzlama katmanında, girdi verilerinin boyutu azaltılır. En çok kullanılan türlerden biri, belirli bir pencere boyutundaki veriler arasında maksimum değeri seçen maksimum havuzlamadır. Havuzlama katmanının matematiksel gösterimi:

$$P(i,j) = max_{m,n \in pencere}\, S(i+m, j+n) \quad (3.17)$$

- $P(i,j)$: Havuzlanmış değer
- $Pencere$: 2×2 ya da 3×3 gibi sabit boyuttaki alan

Bu işlem, pencere boyutu içindeki en büyük değeri alırken diğer değerleri yok sayarak veri boyutunu azaltır. Havuzlama işlemi, girdi verisi üzerinde uygulanır, pencere içindeki maksimum değerin pozisyonunu dikkate almaz, bu da konumun biraz daha esnek olmasını sağlar ve aşırı uyum sorunlarına karşı bir kontrol sağlar.

3.4.6 Geri Yayılım Algoritması

Bu algoritma, yapay sinir ağlarının eğitimi sürecinde en fazla kullanılan ve ağırlıkların güncellenmesini sağlayan temel bir yöntemdir. Ağ başlangıçta, nöronlar arasında yer alan bağlantılara rastgele veya küçük değerlerle başlatılan ağırlıklarla donatılmıştır. Giriş verileri ağa uygulandığında, bu veriler katmanlar boyunca iletilir ve mevcut ağırlıklara göre bir çıktı üretilir. Geri yayılma yöntemi, ağın çıktısı ile hedeflenen gerçek sonuç arasındaki farkı en aza indirmek amacıyla ağırlıkları ayarlamak üzere kullanılır. Bu algoritmanın temel hedefi, ağdaki ağırlıklar ve sapma (bias) terimlerinin, maliyet fonksiyonu (hata fonksiyonu) üzerindeki etkilerini analiz etmektir. Bu doğrultuda, maliyet fonksiyonunun ağırlıklar ve biaslara göre kısmi türevleri hesaplanır. Geri yayılma, aslında tek katmanlı yapay sinir ağlarında uygulanan gradyan iniş yönteminin çok katmanlı yapılar için genelleştirilmiş hâlidir.

Öğrenme süreci boyunca her iterasyon, eğitim örnekleri üzerindeki ortalama hata ile gerçekleştirilir. Her bir nöronun aktivasyonu, önceki katmandaki tüm nöronların çıktılarının ağırlıklı toplamına ve eklenen sapma değerine bağlıdır. Bu nedenle doğrudan aktivasyonlar üzerinde değişiklik yapmak yerine, ağırlıklar ve sapmalar güncellenerek ağ içinde geriye doğru bilgi aktarımı gerçekleştirilir. Ancak, her bir eğitim örneğini kullanarak tam geri yayılım hesaplamaları yapmak oldukça zaman alıcı olabilir. Bu sorunu azaltmak amacıyla, Stokastik Gradyan İnişi (Stochastic Gradient Descent – SGD) algoritması tercih edilir. Bu yöntem, eğitim verilerini rastgele sıraya sokar, bunları küçük alt gruplara (mini-batch) ayırır ve her mini grup için ayrı bir optimizasyon adımı gerçekleştirir. Bu yaklaşım, tüm veri kümesine göre daha hızlı hesaplama imkânı sunarken, yüksek boyutlu parametre uzaylarında yönlendirme hassasiyetini düşürebileceği için dikkatli uygulanmalıdır. Bu nedenle, uygun boyutta alt kümelerle eğitim yapılması önerilir.

3.4.7 Ağırlık

Yapay sinir ağlarında, ardışık katmanlar arasında yer alan bağlantılar, bir katmandaki nöronların çıktılarının (veya aktivasyonlarının) bir sonraki katmana aktarılmasını sağlar. Her bir bağlantı, belirli bir ağırlık değeriyle ilişkilidir ve bu değer, bilgi aktarımının gücünü temsil eder. Başka bir ifadeyle, ağırlıklar bir sinir ağının öğrenme sürecinde ayarlanan temel parametrelerdir ve iki nöron arasındaki etkileşimin derecesini belirler. Bir sinir ağında ağırlıklar genellikle matris olarak gösterilir:

$$W^{(l)} \in \mathrm{R}^{n_l \times n_{l-1}} \tag{3.18}$$

- $W^{(l)}$: l-inci katmana ait ağırlık matrisi
- n_{l-1}: l-1-inci (önceki) katmandaki nöron sayısı (giriş sayısı)
- n_l : l-inci katmandaki nöron sayısı (çıkış sayısı)

Bu ağırlıklar, giriş verilerinin ağın çıktısı üzerindeki etkisini belirlemek amacıyla kullanılır. Sayısal olarak gerçek değerli katsayılardan oluşurlar ve ağın çıktısını şekillendiren temel unsurlar arasında yer alırlar. Her bir girdinin nihai sonuca katkısı, sahip olduğu ağırlık değeri ile doğrudan ilişkilidir. Bu nedenle ağırlıklar, yapay sinir ağlarının öğrenme kapasitesi ve doğruluğu üzerinde belirleyici bir role sahiptir.

3.4.8 Parametre Optimizasyonu (Parameter Optimization)

Yapay sinir ağlarında, modelin öğrenme süreci ağırlıklar ve bias (yanlılık) terimleri gibi parametrelerin güncellenmesiyle gerçekleştirilir. Eğitim sürecinin başlangıcında bu parametreler genellikle rastgele değerlerle başlatılır. Eğitim verilerinin sisteme sunulmasıyla birlikte, modelin çıktıları gerçek değerlere daha fazla yaklaşmaya başlar. Bu süreçte, ağın parametreleri giderek daha iyi uyum sağlayacak biçimde optimize edilir. Makine öğrenmesi bağlamında bu yaklaşım, eğitim verilerine karşılık gelen çıktıları matematiksel olarak modellemeyi ve bu doğrultuda uygun eşleşmeleri keşfetmeyi amaçlar. Ağırlıklar ve bias değerleri, tüm eğitim örnekleri üzerinden hesaplanan ortalama hata (maliyet) değerini en aza indirecek şekilde düzenlenir. Bu sürece "parametre optimizasyonu" adı verilir ve esas olarak, maliyet fonksiyonuna göre ağırlıkların ayarlanması üzerine kuruludur. Yaygın kullanılan optimizasyon tekniklerinden biri olan gradyan inişi (gradient descent), maliyet fonksiyonunun eğimini kullanarak ağırlıkları en etkili şekilde

güncellemeyi amaçlar. Bu yöntem, hesaplama açısından verimli olduğu için tercih edilir ve özellikle yüksek boyutlu veri setlerinde klasik deneme-yanılma yöntemlerine kıyasla çok daha az işlem süresi gerektirir.

3.4.9 Dereceli Alçalma (Gradient Descent)

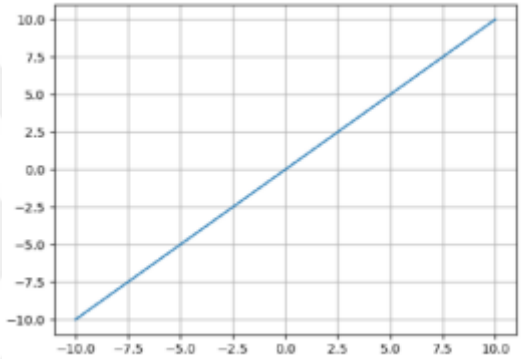
Gradyan inişi, yapay sinir ağlarının öğrenme sürecinde kullanılan temel optimizasyon yöntemlerinden biridir. Bu süreçte, model eğitilmemiş durumdayken eğitim verileri ağa sunulur ve bu veriler doğrultusunda ağın ağırlık ve sapma (bias) parametreleri sistematik biçimde güncellenir. Eğitimin ardından, modelin genelleme yeteneğini değerlendirmek amacıyla daha önce görmediği test verileriyle performansı ölçülür. Gradyan iniş yöntemi, bir maliyet fonksiyonunun minimum değerini bulmayı hedefler. Bu amaçla, maliyet fonksiyonunun eğimine göre ağırlıkların güncellenmesini sağlayan geri yayılım (backpropagation) algoritması ile birlikte çalışır. Bu güncelleme sürecinde belirleyici rol oynayan hiperparametrelerden biri öğrenme hızı (learning rate) dır. Öğrenme hızı, her bir iterasyonda model parametrelerinin ne ölçüde değiştirileceğini belirler. Öğrenme hızının çok yüksek seçilmesi durumunda, ağ minimum hata değerine ulaşamadan parametreler aşırı güncellenebilir ve bu da modelin kararsızlaşmasına veya kötü performans göstermesine neden olabilir. Öte yandan, çok düşük bir öğrenme hızı, modelin optimum çözüme ulaşmasını son derece yavaşlatır ve eğitim sürecinin gereksiz yere uzamasına yol açar. Bu nedenle, eğim büyüklüğüne orantılı olarak ayarlanabilen dinamik öğrenme hızları, modelin aşırı sıçramasını önleyerek daha dengeli bir öğrenme süreci sağlar.

3.4.10 Aktivasyon Fonksiyonu

Aktivasyon fonksiyonu, sinir ağı içinde doğrusal veya doğrusal olmayan bir fonksiyondur. Bu fonksiyonun rolüne bakıldığında, ağırlıklı girdilerin hesaplanan kombinasyonları ile doğrusal olmayan bir karar sınırı sağlamaktadır. Değişik sorunlar için çeşitli aktivasyon fonksiyonları kullanılır [33]. Aşağıda, en yaygın olanlara kısa bir genel bakış sunulan alt bölümler, bu aktivasyon fonksiyonlarının grafiklerini Python'da gösterir.

3.4.10.1 Doğrusal Aktivasyon Fonksiyonu

Doğrusal aktivasyon fonksiyonu, çıktı ile girdiler arasındaki ilişkiyi doğrudan kuran en temel aktivasyon fonksiyonlarından biridir. Bu fonksiyon, genellikle f(x)=x biçiminde ifade edilir ve giriş değerinin doğrudan çıktıya yansıtılmasını sağlar. Geniş bir çıktı aralığı sunma kapasitesiyle dikkat çeken doğrusal fonksiyonlar, giriş büyüklüğü arttıkça nöronun yanıt oranının da artmasını sağlar. Pozitif eğimli yapısı sayesinde, sinyalin belirli bir filtreleme işlemine tabi tutulmaksızın doğrudan iletilmesini mümkün kılar. Bu nedenle doğrusal aktivasyon fonksiyonu, sinyalin yalnızca oranlı biçimde geçmesine izin veren bir yapı sergiler ve sinir ağlarında temel düzeyde işlevsellik sağlar.



Şekil 3.6 Doğrusal aktivasyon fonksiyonu

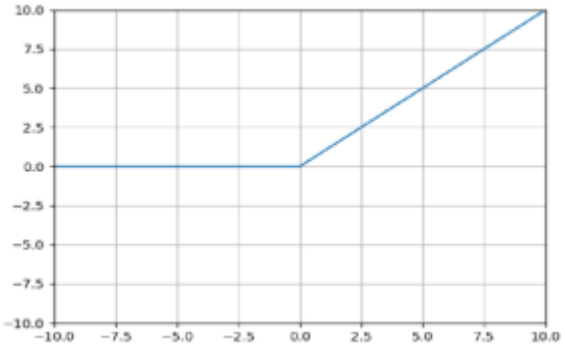
3.4.10.2 Rektifiye Doğrusal Aktivasyon Fonksiyonu

Bu fonksiyon, şu anda en yaygın olarak kullanılan aktivasyon fonksiyonudur ve değerleri 0 ile sonsuz arasında değiştirmektedir. ReLU fonksiyonun matematiksel gösterimi:

$$ReLU(x) = \max(0, x) \tag{3.19}$$

- ReLU: x $>$ 0 için doğrusal $x \leq 0$ için sıfır.

ReLU, tüm negatif değerleri sıfıra dönüştürerek çalışır, ancak bu dönüşüm o kadar hızlıdır ki, verileri düzgün bir şekilde eşleme veya uygun şekilde öğrenme yeteneğini azaltabilir. Sorun, ReLU aktivasyon fonksiyonunun tüm negatif girdileri anında sıfırlamasıdır, bu da modelin negatif değerleri etkili bir şekilde öğrenmesini sınırlayabilir.



Şekil 3.7 Rektifiye doğrusal aktivasyon fonksiyonu

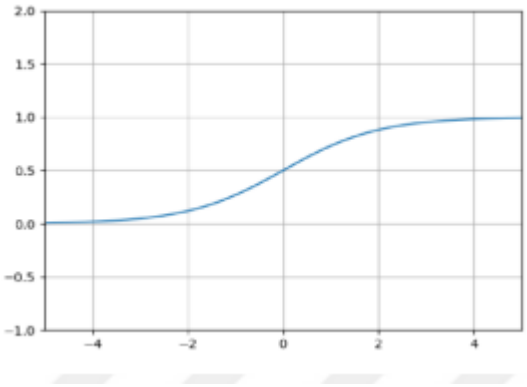
Rektifiye Doğrusal Birim (ReLU) aktivasyon fonksiyonu, f(x)=max(0,x) biçiminde tanımlanmakta olup, Şekil 3.7'de gösterilmiştir. Bu fonksiyon, yapısal sadeliği ve çeşitli derin öğrenme uygulamalarında sağladığı başarılı sonuçlar nedeniyle günümüzde en yaygın kullanılan aktivasyon fonksiyonlarından biri haline gelmiştir. ReLU, yalnızca pozitif girişlere yanıt vererek negatif değerleri sıfıra indirger; bu sayede aynı anda yalnızca belirli bir nöron alt kümesinin etkinleşmesini sağlar. Bu durum, ağın seyrek (sparse) aktivasyon yapısıyla çalışmasına olanak tanıyarak hem hesaplama verimliliğini artırmakta hem de öğrenme sürecine katkı sağlamaktadır.

3.4.10.3 Sigmoid Aktivasyon Fonksiyonu

Bu fonksiyon, yaygın olarak kullanılan aktivasyon işlevlerinden biridir ve çıkış değerini 0 ile 1 arasına sıkıştırır. Bu fonksiyon, sürekli olması ve türevlenebilir olması gibi avantajlara sahiptir. Sigmoid fonksiyonu matematiksel olarak aşağıdaki gibi ifade edilir:

$$\sigma(x) = \frac{1}{1+e^{-x}} \tag{3.20}$$

Sigmoid fonksiyonunun özelliği, gradyanının çıkışın ortasında (yaklaşık olarak 0.25) en yüksek olduğu ve bundan daha yüksek veya düşük giriş değerleri için giderek düzleştiği bir bölgeye sahip olmasıdır. Ağ, bu bölgeye düştüğünde gradyanın giderek azaldığı ve bu durumun gradyan kaybı sorununa yol açtığı bir öğrenme zorluğu yaşar. Sigmoid fonksiyonunun grafiği Şekil 3.5'te gösterilmiştir.



Şekil 3.8 Sigmoid aktivasyon fonksiyonu

Sigmoid aktivasyon fonksiyonu genellikle etkili bir şekilde görevini yerine getirdiği için tercih edilmektedir. Temelde olasılıklı bir yaklaşım sunan bu fonksiyon, çıkışı 0 ile 1 arasına sıkıştırır. Bu nedenle, karar verme veya çıktı tahmini gerektiren durumlarda tercih edilir, çünkü bu aralık en küçük olasılıkları içerir ve tahminleri daha doğru hale getirir. Ancak, Sigmoid fonksiyonu kaybolan gradyan problemine yol açabilir. Bu problem, büyük girdilerin 0 ile 1 aralığına sıkıştırılmasıyla türevlerin çok küçük hale gelmesinden kaynaklanır, bu da eğitimin verimli olmamasına neden olabilir. Bu sorunu gidermek için, ufak türev sorunları yaşanmayan noktalarda ReLU gibi alternatif aktivasyon fonksiyonları kullanılabilir.

3.5 Yapay Sinir Ağlarının Öğrenilmesi

Yapay sinir ağlarında öğrenme, nöronlar arasındaki bağlantıların ağırlıklarının belirli kurallara göre güncellenmesi sürecini ifade eder. Bu sürecin temel amacı, eğitim verileri kullanılarak hesaplanan çıktı ile gerçek hedef değer arasındaki farkı, yani hatayı en aza indirgemektir. Öğrenme yöntemleri, genel olarak iki temel başlık altında incelenmektedir: denetimli (supervised) öğrenme ve denetimsiz (unsupervised) öğrenme. Denetimli öğrenme yaklaşımında, sinir ağı önceden tanımlanmış giriş-çıkış çiftlerinden oluşan bir veri kümesiyle eğitilir. Model, her bir giriş örneği için hedef çıktıyı tahmin etmeye çalışır. Tahmin edilen değer ile gerçek hedef arasındaki fark, hata fonksiyonu aracılığıyla ölçülür ve bu hata, modelin ağırlıklarının güncellenmesinde temel kriter olarak kullanılır. Ağırlıklar her iterasyonda bu hatayı azaltacak yönde değiştirilerek ağın doğruluk seviyesi

artırılır. Denetimli öğrenme algoritmaları arasında delta kuralı ve bu kuralın çok katmanlı ağlara uygulanmasını sağlayan geri yayılım algoritması (backpropagation) en yaygın kullanılan yöntemler arasındadır. Denetimsiz öğrenme yönteminde ise modelin eğitimi sırasında herhangi bir hedef çıktı kullanılmaz. Ağ, yalnızca giriş verileriyle çalışır ve verilerdeki örüntüleri kendi içsel yapısına göre öğrenmeye çalışır. Ağırlıkların güncellenmesi, genellikle giriş verileri arasındaki benzerliklere ve ağ içindeki aktivasyon tepkilerine bağlı olarak gerçekleştirilir. Bu yaklaşım, sınıflandırılmamış veriler üzerinde kümeleme veya özellik çıkarımı gibi görevlerde sıklıkla tercih edilir.

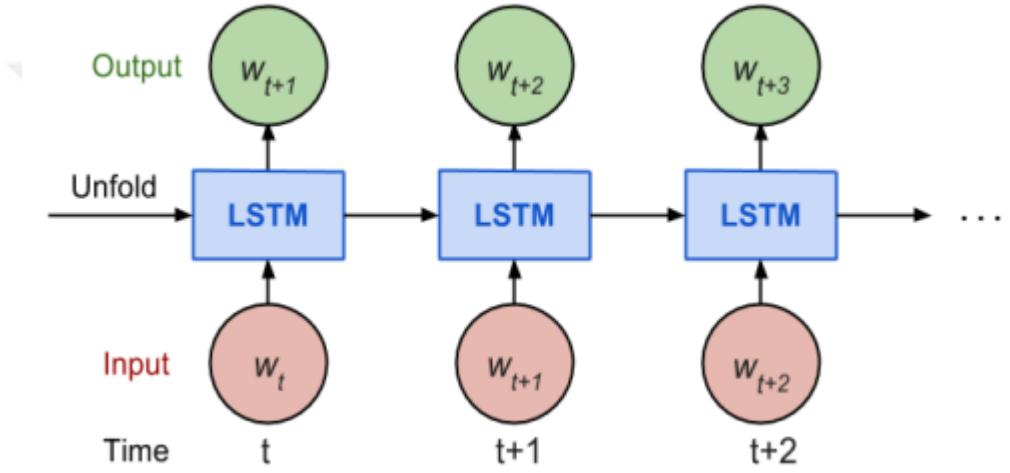
3.6 Uzun Kısa Süreli Bellek (LSTM) Modeli

LSTM (Long Short-Term Memory – Uzun Kısa Süreli Bellek) ağı, Tekrarlayan Sinir Ağları'nın (RNN) özellikle ardışık veri yapıları üzerindeki eğitim sürecinde karşılaştığı sınırlamaları aşmak amacıyla geliştirilmiş özel bir yapıdır. Bu mimari, her bir hücrede yer alan ve "kapı" olarak adlandırılan denetim mekanizmaları aracılığıyla, bilgi akışını kontrol etme yeteneğine sahiptir. Bu kapılar sayesinde model, hangi bilgilerin tutulacağını, hangilerinin unutulacağını ve hangi verilerin çıktıya aktarılacağını öğrenir. Bu yönüyle LSTM, zaman bağımlılığı taşıyan veri setlerinde önemli avantajlar sunar.

LSTM'ler, zaman serisi tahmini gibi uygulamalarda sıkça tercih edilmektedir. Bununla birlikte, özellikle çıktının yalnızca son birkaç gözleme dayandığı durumlarda, bu mimarinin üstünlüğü her zaman net bir şekilde ortaya koyulmamıştır. Yine de, klasik RNN mimarilerine göre daha kararlı bir öğrenme süreci sunması nedeniyle tercih edilirliğini korumaktadır.

Tekrarlayan sinir ağları, çok katmanlı algılayıcılar (MLP) ya da evrişimli ağlar (CNN) gibi diğer yapay sinir ağı türlerinden farklı olarak, giriş ile çıkış arasındaki ilişkiyi zaman boyutunda modelleme yeteneğine sahiptir. Bu özellik, özellikle ardışık gözlemlerden oluşan veri setlerinde, zamana bağlı örüntülerin öğrenilmesini mümkün kılar. RNN yapılarında bu tekrar özelliği, modele lokal bağlam kazandırarak geçmişteki bilginin gelecek tahminlerde kullanılması açısından önemli katkılar sağlar. Derin RNN'lerde sıklıkla karşılaşılan gradyan sönümlenmesi (vanishing gradient) ve gradyan patlaması (exploding gradient) gibi sorunlar, zaman içinde modelin öğrenme kapasitesini ciddi ölçüde sınırlandırabilmektedir.

Bu teknik zorluklara çözüm olarak geliştirilen yapılar arasında en bilinenlerinden biri de LSTM'dir. LSTM birimleri, modelin önemli bilgileri "hatırlaması" ve alakasız ya da gereksiz bilgileri "unutması" amacıyla özel olarak tasarlanmış kapı mekanizmaları ile donatılmıştır. LSTM hücreleri, belirli işlevlere sahip çeşitli kapılar içerir ve bu kapılar, bilgi akışını kontrollü biçimde yönlendirir. Ayrıca, her bir LSTM hücresi, modelin uzun vadeli bağımlılıkları koruyabilmesini sağlayan ve hücre durumu (cell state) olarak adlandırılan ayrı bir bilgi taşıyıcısını içerir. Bu yapı, modelin geçmişten gelen bilgileri daha uzun süre hatırlayabilmesine olanak tanır[33].



Şekil 3.9 Uzun kısa süreli bellek (LSTM) sinir ağı yapısı [33]

LSTM algoritmasına ait formüller aşağıda gösterilmiştir:

$$f_t = \sigma_g(W_f x_t + U_f h_{t-1} + b_f) \quad (3.21)$$

$$i_t = \sigma_g(W_i x_t + U_i h_{t-1} + b_i) \quad (3.22)$$

$$o_t = \sigma_g(W_o x_t + U_o h_{t-1} + b_o) \quad (3.23)$$

$$\bar{c}_t = \sigma_c(W_c x_t + U_c h_{t-1} + b_c) \quad (3.24)$$

$$c_t = f_t \odot c_{t-1} + i_t \odot \bar{c}_t \quad (3.25)$$

$$h_t = o_t \odot \sigma_h(c_t) \quad (3.26)$$

Aşağıda sırasıyla d girdi elemanların sayısı ve h gizli birimlerin sayısını göstermektedir.

- $x_t \in R^d$: Girdi vektörü.

- $f_t \in (0,1)^h$: Unutma kapısı vektörü.
- $i_t \in (0,1)^h$: Girdi kapısı vektörü.
- $o_t \in (0,1)^h$: Çıktı kapısı vektörü.
- $h_t \in (-1,1)^h$: LSTM biriminin gizli çıktı vektörü.
- $\bar{c}_t \in (0,1)^h$: Aday bellek vektörü.
- $c_t \in R^h$: Bellek vektörü
- $W \in R^{h*d}, U \in R^{h*h} ve\ b \in R^h$: Ağırlık ve yanlılık(bias) matrisleri.
- σ : Aktivasyon fonksiyonu.
- $\odot$: Hadamard Çarpımı [34].

Uzun Kısa Süreli Bellek (LSTM) ağları, klasik tekrarlayan sinir ağlarının uzun vadeli bağımlılıkları öğrenmedeki yetersizliklerini gidermek üzere geliştirilmiş bir mimari yapıdır. Bu yapının en önemli özelliklerinden biri, bilgi akışını dinamik olarak kontrol edebilmesini sağlayan kapı mekanizmalarıdır. LSTM'nin temel işleyişi, dört ana kapı üzerinden şekillenmektedir. Bunlar; unutma kapısı, giriş kapısı, giriş modülasyon kapısı ve çıkış kapısıdır. Başlangıçta, LSTM mimarisine entegre edilen unutma kapısı, ağın geçmiş bilgileri tamamen ya da kısmen silmesine olanak tanıyarak belleğin güncellenmesini sağlar. Bu kapı, mevcut giriş (x_t) e bir önceki zaman adımındaki çıktı h_{t-1} bilgilerini değerlendirerek, hangi bilgilerin saklanacağına ve hangilerinin eleneceğine karar verir. Unutma mekanizması, bu yönüyle ağın kendisini sıfırlayabilmesini ve öğrenilen bilgilerin kontrolsüz bir şekilde toplanmasını engeller. Devamında, giriş kapısı devreye girerek hücre durumuna hangi yeni bilgilerin ekleneceğini belirler. Böylece ağ, gereksiz veya geçersiz verilerin hafızaya kaydedilmesinin önüne geçer. Bu mekanizmanın daha derin bir bileşeni olan giriş modülasyon kapısı ise, yazılacak bilgilerin biçimini ve ölçeğini ayarlamakla görevlidir. Literatürde sıklıkla doğrudan adı anılmasa da, bu kapı giriş sinyaline doğrusal olmayan bir dönüşüm uygulayarak verilerin sıfır-merkezli hâle gelmesini sağlar; bu da modelin daha hızlı ve dengeli bir şekilde öğrenmesine katkı sunar. Son olarak, çıkış kapısı hücre durumunda taşınan bilginin ne kadarının görünür hâle getirileceğini denetler. Bu kapı, mevcut hücre bilgisinden üretilen çıktıların bir sonraki zaman adımına nasıl aktarılacağını düzenler. Böylece, LSTM mimarisi yalnızca geçmişi hatırlamakla kalmaz, aynı zamanda hangi bilginin güncel işlem için gerekli olduğuna karar vererek, zaman içindeki bilgi akışını optimize eder. Tüm bu mekanizmalar, Dahili Hücre Durumu'nun Gizli

Durum ile birlikte ileriye aktarılması sayesinde, LSTM'yi uzun süreli bağımlılıkları etkili biçimde öğrenebilen güçlü bir araç hâline getirir.

LSTM ağ yapısının birçok varyasyonu bulunmaktadır. Bunlardan en bilindikleri; Vanilya uzun – kısa süreli bellek, yığılmış uzun – kısa süreli bellek, çift yönlü uzun - kısa süreli bellek ve evrişimli uzun – kısa süreli bellektir.

3.7 Performans Metrikleri

Oluşturulan modelin performansını değerlendirmek, başarısını ölçmek ve sonuçlarının yorumlanabilmesi için birden fazla metrik bulunmaktadır. Modellerin sonuçlarının birbiriyle kıyaslanabilmesi için, bütün modellerin grafiklerine ait performansının detaylı bir şekilde analiz edilmesi önemlidir. Modellerde kullanılan performans metrikleri aşağıda gösterilmiştir:

MAE(Mean Absolute Error):Ortalama mutlak hata demektir. Tahmin değerlerinin gerçek değerlere oranla mutlak değer olarak ne kadar saptığını gösteren bir metriktir. Model performansı yüksekse bu değer küçük çıkmalıdır.

$$MAE = \frac{1}{n} * \sum_{i=1}^{n} |y_i - y| \tag{3.27}$$

- y_i : Gerçek değer
- y : Tahmin değeri
- n : Gözlem sayısı

RMSE(Root Mean Square Error): Hata Kareler Ortalamasının Karekökü anlamına gelir. Tahmin edilen değerlerin gerçek değerden kök ortalama olarak ne düzeyde saptığını incelemektedir. Bu değerin modelde küçük olması istenilen bir durumdur.

$$RMSE = \sqrt{\frac{1}{n}\sum_{i=1}^{n}(y_i - y)^2} \tag{3.28}$$

- n : Gözlem sayısı
- y_i : Gerçek değer
- y : Tahmin değeri

R kare analizi(R^2) bağımsız değişkenlerin bağımlı değişkenler üzerindeki varyansını inceleyen bir metriktir. Bu değerin yüksek olması model performansının yüksek olması ile doğru orantılıdır.

$$R^2 = 1 - \frac{SSR}{SST} \tag{3.29}$$

- SSR : Hata Kareleri Toplamı
- SST : Toplam Kareler Toplamı

$$SSR = \sum_{i=1}^{n}(y_i - y)^2 \tag{3.30}$$

$$SST = \sum_{i=1}^{n}(y_i - Y)^2 \tag{3.31}$$

- n : Gözlem sayısı
- y_i : Gerçek değer
- y : Tahmin değeri
- Y : Gerçek Değerlerin Ortalaması

MAPE(Mean Absolute Percentage Error): Ortalama mutlak yüzde hata tahmin değerlerinin gerçek değerlerden yüzde kaç oranında saptığını inceleyen metriktir. Bu hata değerinin düşük çıkması modelin performansının olumlu olduğu yönünde referans verir.

$$MAPE = \frac{1}{n} * \sum_{i=!}^{n} \left|\frac{y_i - y}{y}\right| * 100 \tag{3.32}$$

- n : Gözlem sayısı
- y_i : Gerçek değer
- y : Tahmin değeri

4
VERİ SETİ

4.1 Veri Seti ve Tanımlayıcı İstatistikler

Tez çalışmasının uygulama aşamasında, Borsa İstanbul (BIST) 50 endeksinde yer alan ve Türkiye'de faaliyet göstermekte olan 10 farklı şirkete ait hisse senedi fiyat verileri kullanılmıştır. Veri seti, 2010 yılı Şubat ayından başlayarak 2025 yılı Nisan ayı sonuna kadar olan dönemi kapsamaktadır. Veri kümesi günlük frekansta toplam 10 hisse senedine ilişkin fiyat bilgilerini içermektedir. Çalışmada kullanılan veri seti 3.500'den fazla günlük gözlem ve 11 değişken (1 tarih sütunu ve 10 hisse senedi sütunu) içermektedir.

	Date	TUPRS.IS	THYAO.IS	TCELL.IS	KCHOL.IS	AKBNK.IS	ISCTR.IS	SAHOL.IS	ASELS.IS	BIMAS.IS
0	2010-02-01	1.566461	3.492329	5.963909	3.202041	3.782786	0.442309	4.242777	0.331699	5.704324
1	2010-02-02	1.541398	3.429967	6.018624	3.233744	3.825529	0.442309	4.242777	0.326634	5.662380
2	2010-02-03	1.528866	3.461147	5.963909	3.202041	3.825529	0.442309	4.144866	0.324103	5.704324
3	2010-02-04	1.491271	3.461147	5.909195	3.106931	3.740041	0.442309	4.112231	0.321570	5.620437
4	2010-02-05	1.391017	3.274059	5.526191	2.992799	3.654555	0.442309	4.046957	0.306378	5.662380
...	...	...	...	...	...	...	...	...	...	...
3914	2025-04-24	125.300003	321.500000	94.150002	147.100006	53.500000	10.940000	78.500000	134.500000	463.250000
3915	2025-04-25	125.300003	317.750000	91.300003	145.500000	51.500000	10.710000	77.699997	135.300003	466.250000
3916	2025-04-28	124.000000	312.750000	90.550003	144.300003	49.360001	10.340000	75.000000	138.600006	465.000000
3917	2025-04-29	125.099998	297.750000	91.300003	140.699997	48.939999	10.200000	74.150002	137.399994	464.000000
3918	2025-04-30	124.699997	284.250000	89.900002	137.699997	48.500000	10.300000	73.250000	135.000000	451.000000

3919 rows × 10 columns

Şekil 4.1 Hisse senetlerine ait veri seti

Veri kümesinde yer alan değişkenler; Tüpraş (TUPRS.IS), Türk Hava Yolları (THYAO.IS), Turkcell (TCELL.IS), Koç Holding (KCHOL.IS), Akbank (AKBNK.IS), İş Bankası (ISCTR.IS), Sabancı Holding (SAHOL.IS), Aselsan (ASELS.IS), Bim Birleşik Mağazalar (BIMAS.IS) ve Ek olarak her gözlem satırında fiyatların ait olduğu tarih bilgisi yer almaktadır.

Bu tez kapsamında, hisse senedi fiyatlarına ilişkin zaman serisi analizleri gerçekleştirilmiş ve LSTM tabanlı derin öğrenme modelleri aracılığıyla fiyat

tahminleri yapılmıştır. Tüm analizler Python programlama dili ve ilgili kütüphaneler (örneğin pandas, keras, sklearn) kullanılarak gerçekleştirilmiştir. Hisse senetlerine ait ortalama fiyatlar, minimum ve maksimum değerler, kuantil değerleri ve standart sapması hesaplanmıştır.

Tablo 4.1 Hisse senetlerine ait istatistikler

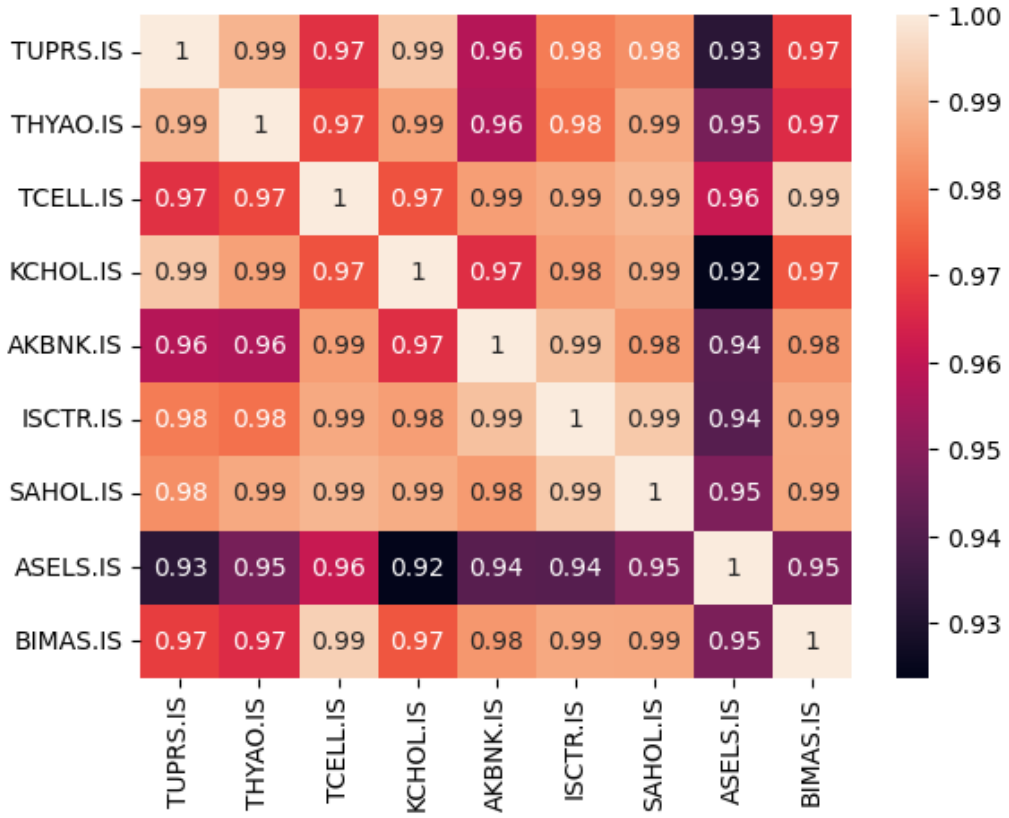
Hisse Senedi	Ortalama	Min	1. Kartil	Medyan	3. Kartil	Maks	Standart Sapma
TUPRS	24.160	1.365	3.177	8.266	13.455	179.291	41.215
THYAO	47.715	1.710	5.740	9.330	16.884	337.750	89.352
TCELL	17.994	4.191	6.527	8.341	13.953	111.321	23.570
KCHOL	31.975	2.777	7.116	11.932	18.275	251.989	50.918
AKBNK	10.571	3.192	4.507	5.093	6.463	73.461	14.655
ISCTR	2.224	0.385	0.650	0.790	1.058	17.363	3.618
SAHOL	16.715	3.528	5.946	6.970	8.588	105.784	23.837
ASELS	11.604	0.278	1.069	4.452	8.568	138.600	20.501
BIMAS	78.801	5.242	15.981	26.159	60.027	615.539	131.963

4.1.1 Korelasyon Matrisi

Korelasyon matrisi, birden fazla değişken arasındaki ikili korelasyon katsayılarını inceleyen simetrik bir matristir. Bu yapı, değişken çiftleri arasındaki ilişki düzeylerini nicel olarak ifade ederek istatistiksel analizlerde veriyi analizlemek için önemli bir araç olarak kullanılmaktadır.

Hisse senetlerinin birbiri ile olan korelasyonları incelenmiştir.İlgili incelemeler sonucunda beklenildiği üzere hisselerin birbiriyle olan korelasyonu bire çok yakın çıkmıştır. Bu hisse senetlerinde birbirine yakın veya aynı sektörlerde örneğin bankacılık sektöründe yer alan iki hisse senedinin korelasyon değeri 0.99 gibi 1'e çok yakın bir değer çıkmıştır. Ancak farklı iki sektör arasındaki korelasyon değerinin 1'den uzaklaştığı görülmektedir. Korelasyon katsayılarının genel anlamda yüksek (çoğu > 0.95) olması hisse senetlerinin fiyatlarının benzer şekilde hareket ettiğini bize göstermektedir. Bu yüksek korelasyonlar, modelde

kullanılacak değişkenler arasında çoklu bağlantı (multicollinearity) riski oluşturabilir. Ancak LSTM gibi derin öğrenme modelleri, bu çoklu yapıdan klasik modellere oranla daha az etkilenirler. Korelasyonlardaki bu yüksek seviye, veri seti içerisinde bilgi tekrarına neden olarak modeli daha karmaşık hale getirebilir. Bu durum modelin öğrenmesini zorlaştırır. Veri setinde bulunan hisse senetlerine ait korelasyon matrisi Şekil 4.2' de gösterilmiştir.



Şekil 4.2 Korelasyon matrisi

4.1.2 Volatilite Analizi

Volatilite analizi, herhangibir finansal varlığın fiyatının ne ölçüde dalgalandığını ölçen bir istatistiksel analizdir. Yüksek volatilite, fiyatın dahasık ve önemli ölçüde değiştiğini gösterirken; düşük volatilite, varlığın stabil ve düzenli fiyat hareketlerini göstermektedir. Volatilite aşağıdaki adımları takip ederek hesaplanır:

Fiyat verisinin toplanması: Her bir hisse senedinin belirli bir dönem boyunca günlük kapanış fiyatları alınır.

Getiri Hesaplama: Fiyat verisinden günlük logaritmik getiri hesaplanır:

$$r_t = \ln(\frac{P_t}{P_{t-1}}) \quad (4.1)$$

- r_t : t. gündeki getiri
- P_t : t. gündeki kapanış değeri
- P_{t-1} : bir önceki gündeki kapanış değeri

Diğer bir seçenek olarak basit getiri aşağıdaki gibi hesaplanır:

$$r_t = \frac{P_t - P_{t-1}}{P_{t-1}} \quad (4.2)$$

Volatilite Hesaplama: Elde edilen getirilerin standart sapması alınarak volatilite değeri hesaplanır:

$$Volatilite = \sigma_r = \sqrt{\frac{1}{n-1}} \sum_{t=1}^{n} (r_t - \bar{r})^2 \quad (4.3)$$

- σ_r $(sigma)$: Getiri serisinin standart sapması, yani volatilitesi.
- n : Getiri sayısı (örneğin 360 günlük getiriler için n=360)
- r_t : t. gündeki getiri
- $\bar{r}$ $(r - bar)$: Ortalama getiri (tüm r_t'lerin ortalaması)

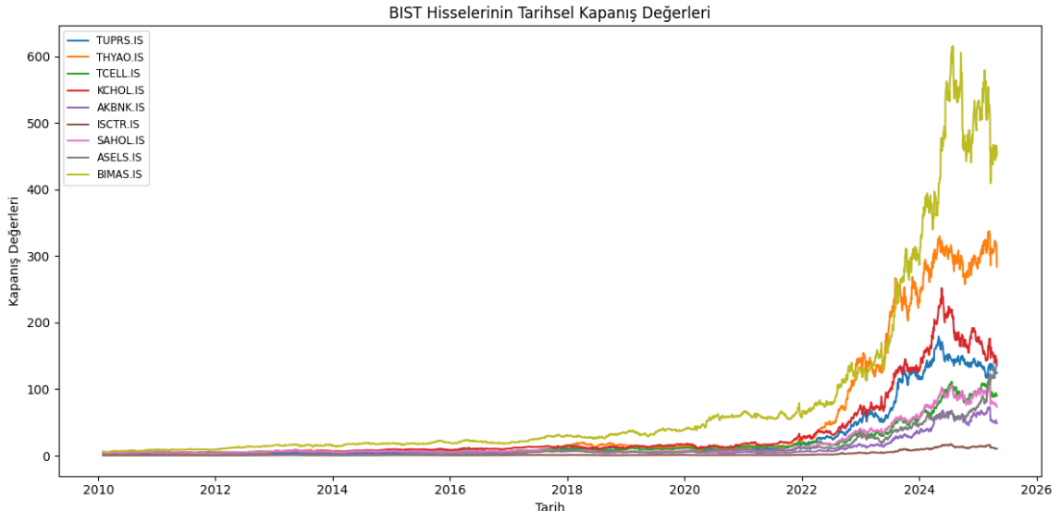
Yapılan volatilite analizine göre, LSTM modeliyle fiyat tahmini yapılacak hisse senetleri arasında oynaklık seviyeleri farklılık göstermektedir. THYAO.IS, AKBNK.IS ve ISCTR.IS gibi yüksek volatiliteye sahip hisseler, ani ve düzensiz fiyat hareketleri içerdiğinden LSTM modeli açısından daha karmaşık örüntüler sunar ve bu durum tahmin hatalarını artırabilir. Bu hisselerde aşırı öğrenme riskini azaltmak için dropout, erken durdurma gibi düzenleme tekniklerine ihtiyaç duyulabilir. Buna karşılık, BIMAS.IS ve TCELL.IS gibi düşük volatiliteye sahip hisseler daha stabil fiyat yapıları gösterdiğinden, LSTM modeli bu serileri daha kolay öğrenebilir ve daha düşük tahmin hatalarıyla sonuçlanabilir. Bu nedenle, volatilite seviyesi hem model karmaşıklığını hem de parametre seçimlerini doğrudan etkilediği için, LSTM ile yapılacak tahminlerde her hisse için volatiliteye uygun stratejiler geliştirilmesi önerilir. Veri setinde kullanılan hisse senetlerine ait volatilete değerleri Tablo 4.2 ‘de gösterilmiştir.

Tablo 4.2 Volatilite değerleri

Hisse Senedi	Yüzdelik Değer
TUPRS	2,14%
THYAO	2,43%
TCELL	2,02%
KCHOL	2,07%
AKBNK	2,42%
ISCTR	2,37%
SAHOL	2,13%
ASELS	2,36%
BIMAS	1,90%

4.1.3 Veri Setindeki Hisse Senetlerinin Tarihsel Gösterimi

Bu grafik, seçilen BIST hisselerinin tarihsel kapanış değerlerinin zaman içindeki değişimini görsel olarak anlatmaktadır. Her bir hisse senedi farklı bir renkle temsil edilmiştir ve zaman ekseninde kapanış fiyatlarındaki eğilimler kolayca izlenebilmektedir.



Şekil 4.3 Bist hisselerinin tarihsel kapanış değerleri

5
UYGULAMA

Geleneksel finansal analiz yöntemleri ile makine öğrenmesi yaklaşımları arasındaki karşılaştırma, finansal verileri tahmin etmede önemli bir inceleme konusudur. Bu iki yaklaşımın da kendine özgü avantaj ve dezavantajları bulunmakta olup, optimal sonuçlar genellikle bu yöntemlerin uygun şekilde kombine edilmesiyle elde edilmektedir. Geleneksel yöntemlerden ARIMA modelinde doğrusal ilişkileri modellemede başarılı sonuçlar alınmasına rağmen finansal piyasaların karmaşık ve doğrusal olmayan yapısını tam olarak anlayamamakta, büyük veri setlerinin işlenmesinde yetersiz kalmakta ve ani piyasa değişimlerine adaptasyon konusunda sınırlılıklar taşımaktadır. Son zamanda makine öğrenmesi ve derin öğrenme tekniklerinin gelişmesiyle birlikte, özellikle LSTM gibi derin öğrenme modelleri, büyük veri setlerinden otomatik öğrenme yeteneği, karmaşık ve doğrusal olmayan ilişkileri modelleme kapasitesi ve uzun vadeli bağımlılıkları yakalama konusundaki üstün performanslarıyla finansal tahmin alanında çok önemli bir dönüşüm yaratmıştır [35]. Bu çalışmada, ARIMA ve LSTM modellerinin hisse senedi fiyat tahminlerindeki performansları karşılaştırılarak, her iki yaklaşımın güçlü ve zayıf yanları analiz edilecektir.

5.1 ARIMA Modeli

ARIMA analiz kodu, hisse senedi fiyat tahminlemesi için kapsamlı bir süreç izler. Burada ilk olarak, DataFrame formatındaki veri alınır ve analiz için hazırlanır. Bu evrede tarih sütunu datetime formatına çevrilir, eksik değerler linear interpolation yöntemiyle doldurulur ve sayısal olmayan veriler temizlenir. Daha sonrasında her hisse senedi için kritik olan durağanlık kontrolü yapılır; Augmented Dickey-Fuller (ADF) testi ile serilerin durağan olup olmadığı test edilir ve gerekirse birinci veya ikinci fark alınarak durağanlık sağlanır [36].

Veri hazırlığı sürecinden sonra görsel analiz aşamasına geçilir. Orijinal seri, logaritmik dönüşüm, birinci fark ve log birinci fark grafikleri çizilerek serinin yapısı incelenir, buna ek olarak ACF (Autocorrelation Function) ve PACF (Partial Autocorrelation Function) grafikleri ile model parametreleri hakkında bilgi edinilir. Bir sonraki aşamada otomatik model seçimi yapılır; farklı p, d, q parameter kombinasyonları denenerek AIC (Akaike Information Criterion) kriterine göre en uygun ARIMA modeli belirlenir.

Seçilen en iyi parametrelerle tüm hisse senetleri için ARIMA modeli kurulur ve eğitilir, model istatistikleri (AIC, BIC, log-likelihood) kaydedilir. Model kalitesini test etmek için doğrulama aşamasında veri train/test setlerine ayrılır (son 30 gün test seti), MAE, RMSE ve MAPE metrikleriyle model performansı incelenir. En son aşamada belirlenen gün sayısı kadar gelecek için tahmin yapılır, güven aralıklarıyla birlikte sonuçlar DataFrame formatında sunulur ve isteğe göre tahmin grafikleri çizilerek detaylı analiz raporu oluşturulur.

5.1.1 ISCTR İçin Arıma Modeli

Model BIST 30 hısse senetlerinden olan ISCTR Hisse senedi için çalıştırımıştır. ISCTR hisse senedine ait 01.02.2010 - 30.04.2025 tarihleri arasındaki kapanış değerleri modele okutulmuş ve bu veri setinde tarih sütunu datetime formatına çevrilmiş, eksik ve sayısal olmayan değerler düzeltilerek veri seti duraganlık testi için hazırlanmıştır.

5.1.1.1 Durağanlık Testi

Bu aşamada ISCTR hisse senedine ait veri setinin durağanlık testi ile durağan olup olmadığı incelenmiştir.

```
ISCTR.IS - Durağanlık Testi Sonuçları:
------------------------------------------------
ADF Statistic: -0.224566
p-value: 0.935529
Critical Values:
        1%: -3.432
        5%: -2.862
        10%: -2.567
Sonuç: Seri durağan değil (p > 0.05)

ISCTR.IS - Birinci fark alındı

ISCTR.IS (1st diff) - Durağanlık Testi Sonuçları:
------------------------------------------------
ADF Statistic: -10.400183
p-value: 0.000000
Critical Values:
        1%: -3.432
        5%: -2.862
        10%: -2.567
Sonuç: Seri durağan (p < 0.05)
```

Şekil 5.1 ISCTR hisse senedine ait durağanlık testi sonuçları

ISCTR.IS Orijinal Seri:

- ADF Statistic: -0.224566
- p-değeri: 0.935529
- Kritik Değerler: -3.432 (1%), -2.862 (5%), -2.567 (10%)
- Sonuç: p > 0.05 → H0 reddedilemez → Seri durağan değil.

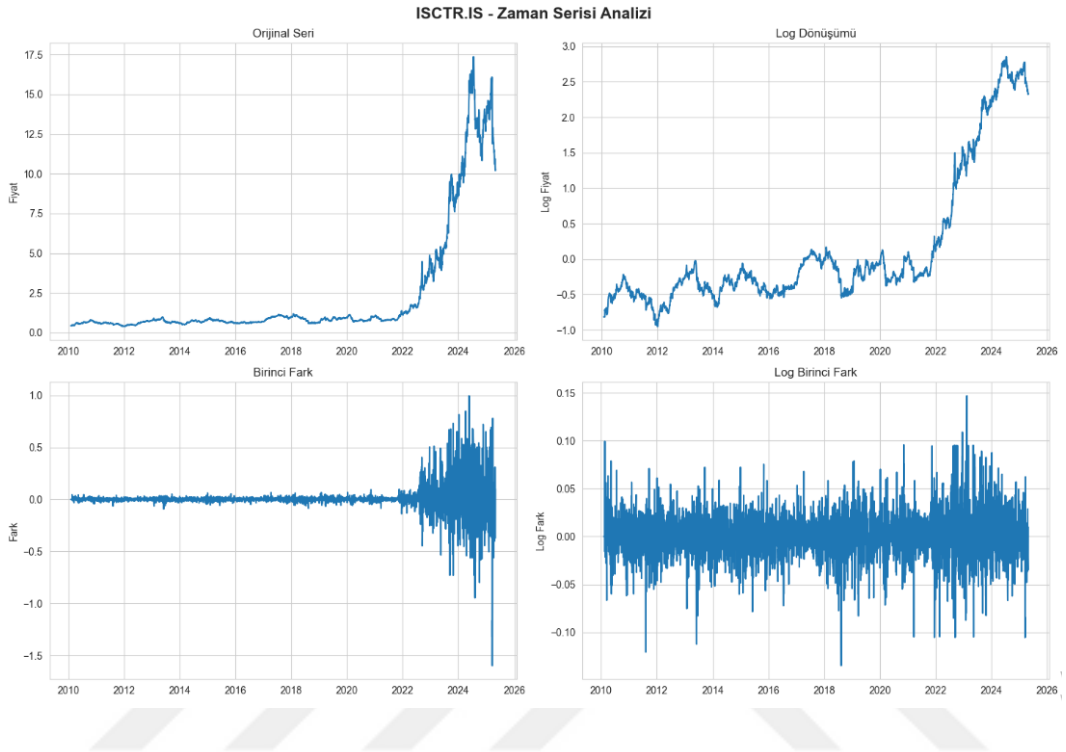
Bu sonuç, serinin zamanla ortalaması veya varyansı değiştiğini, yani ARIMA'ya doğrudan uygun olmadığını gösteriyor. Yapılan analizler, ISCTR.IS hisse senedine ait orijinal fiyat serisinin durağanlık özelliği taşımadığını ortaya koymaktadır. Zaman serisi analizlerinde durağanlık, modelleme sürecinin temel unsurlardan biridir; çünkü durağan olmayan seriler genellikle trend barındırır ve ortalama ile varyans gibi istatistiksel özellikleri zamanla değişkenlik göstermektedir. Serinin durağan hale getirilmesi gerekmektedir.

ISCTR.IS Birinci Fark Sonrası:

- ADF İstatistiği: -10.400183
- p-değeri: 0.000000
- Kritik Değerler: Aynı

- Sonuç: Seri durağan ($p < 0.05$)

Birinci fark alındıktan sonra seri durağan hale gelmiş. Bu, ARIMA modelinde d=1 parametresinin kullanılacağını gösterir.



Şekil 5.2 ISCTR hisse senedine ait durağanlık grafikleri

Zaman Serisi Analizi Grafikleri:

- Orijinal Seri: 2010'dan başlayarak özellikle 2020 sonrası güçlü bir yükseliş trendi görülüyor. Bu trend durağan olmayan yapıyı doğruluyor. Son yıllarda özellikle 2022 sonrası ani bir yükseliş gözlemlenmiş. Bu tür artışlar durağanlığı bozar, bu yüzden modelleme için dönüşüm gerekir.
- Log Dönüşümü: Logaritmik dönüşümle varyans stabilize edilmiş, bu da fiyatlardaki artışın etkisini azaltmış, daha homojen bir yapı elde edilmiş. ancak bu tek başına yeterli kalmıyor ve trend hala mevcut.
- Birinci Fark: Orijinal serinin birinci farkı alındığında trend ortadan kalkmış ve seri ortalama etrafında dalgalanıyor. Bu durağanlığı gösterir.
- Log Birinci Fark: Burada hem log dönüşüm hem de fark alma işlemleri uygulanmış. Bu, genellikle finansal serilerde kullanılan en etkili yöntemdir. Grafik oldukça durağan ve oynaklığı dengelemiş olarak gözüküyor.

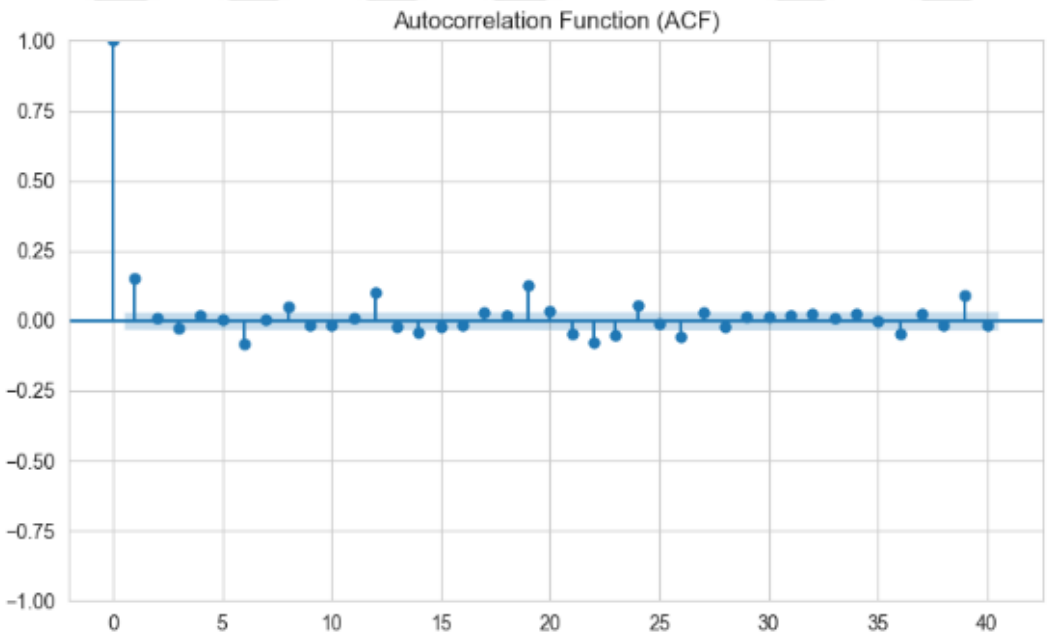
Bu analiz aşamasında ADF testi ile serinin durağan olup olmadığı kontrol edilmiş, durağan olmadığı için fark alma işlemi uygulanmış, daha sonra dönüştürülmüş serinin durağanlığı tekrar kontrol edilmiş ve ARIMA(p,d,q) modelindeki d parametresi belirlenmiştir.

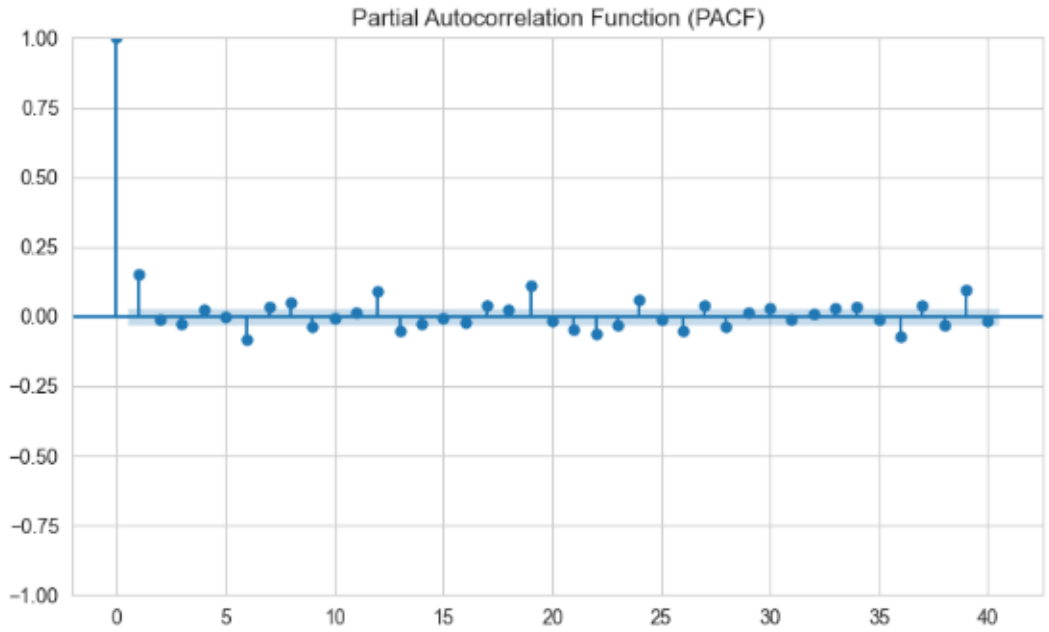
Teknik Yorumlar:

- Kritik Değerler: %1, %5 ve %10 anlamlılık seviyelerinde kritik değerler verilmiş
- H0 Hipotezi: "Seri durağan değildir" (unit root var)
- H1 Hipotezi: "Seri durağandır" (unit root yok)
- $p < 0.05$ olduğunda H0 reddedilir ve seri durağan kabul edilir

Bu aşama, ARIMA modellemesi için gerekli ön koşulları sağlayarak modelin güvenilir tahminler üretmesini sağlamaktadır. ISCTR.IS hissesi için d=1 parametresiyle ARIMA modeli kurulabilir duruma gelmiştir.

5.1.1.2 ACF/PCAF Grafikleri





Şekil 5.3 ACF/PACF grafikleri

Bu grafiklerde ISCTR.IS hissesinin ACF (Autocorrelation Function) ve PACF (Partial Autocorrelation Function) analizleri görülmektedir.

ACF (Autocorrelation Function) Analizi:

- Grafikte görülen mavi noktalar, farklı gecikme değerlerindeki (lag) otokorelasyon katsayılarını gösteriyor.
- Değerler genel olarak -0.25 ile +0.25 arasında salınım yapıyor
- Lag 0'da değer 1.00 (mükemmel korelasyon - normal)
- Sonraki gecikmelerde değerler sıfıra yakın ve istatistiksel olarak anlamlı görünmüyor

PACF (Partial Autocorrelation Function) Analizi:

- Benzer şekilde değerler -0.25 ile +0.25 arasında
- Yine lag 0'da 1.00 değeri var
- Diğer gecikmelerde anlamlı bir pattern görülmüyor

Bu sonuçlar, ISCTR.IS hissesinin getiri serisinin büyük olasılıkla "beyaz gürültü" (white noise) karakteristiği gösterdiği anlamına gelmektedir. Buda Geçmiş değerler ile gelecek değerler arasında anlamlı bir otokorelasyon olmadıgı, serinin rastgele yürüyüş özelliği gösteriyor olabileceğ, ve ARIMA modeli için belirgin bir

AR (Autoregressive) veya MA (Moving Average) bileşeni görünmediği şeklinde yorumlanır.

5.1.1.3 Paremetre Seçimi ve Kriter Sonuçları

```
ISCTR.IS için en iyi ARIMA parametreleri aranıyor...
En iyi model: ARIMA(2, 1, 3)
AIC: -5963.44

ISCTR.IS Model Özeti:
ARIMA(2, 1, 3)
AIC: -5963.44
BIC: -5925.80
Log Likelihood: 2987.72
```

Şekil 5.4 ISCTR parametre seçimi ve kriter sonuçları

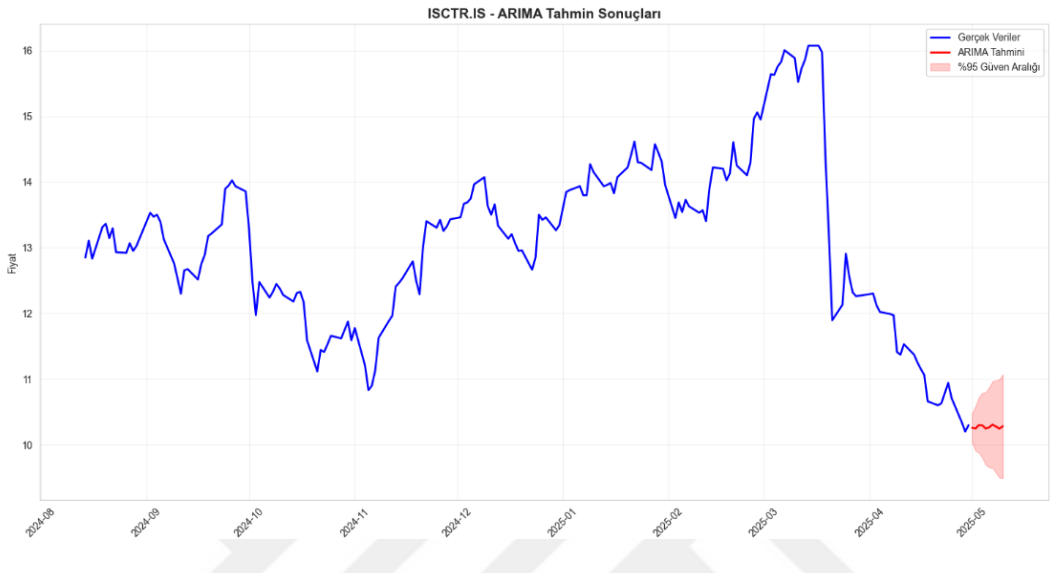
ISCTR.IS hissesi için yapılan ARIMA modelleme sürecinde, otomatik parametre optimizasyonu Grid Search yöntemiyle gerçekleştirilmiştir. Bu süreçte ARIMA(p,d,q) parametreleri için $p \in [0,5]$, $d \in [0,2]$, $q \in [0,5]$ aralıklarında toplam 108 farklı kombinasyon değerlendirilmiş ve en uygun model, AIC (Akaike Information Criterion) değerini minimize eden ARIMA(2,1,3) olarak belirlenmiştir.

Seçilen modelin parametreleri finansal açıdan anlamlıdır. p=2, hisse senedinin kısa vadeli (iki günlük) geçmiş verilerle anlamlı ilişkisini, q=3 ise piyasadaki beklenmedik şokların üç gün boyunca etkili olduğunu göstermektedir. d=1 farklama derecesi ise durağan olmayan veriyi durağan hâle getirerek analiz yapılabilir bir forma dönüştürmüştür. Modelin AIC değeri -5963.44 ve BIC değeri -5925.80 gibi oldukça düşük (negatif) çıkmış; bu da modelin yüksek uyum kalitesine ve aşırı karmaşıklıktan uzak durduğuna işaret etmektedir. Log likelihood değeri 2987.72 olup, modelin veriye çok iyi uyum sağladığını göstermektedir.

Modelin kalite değerlendirmesi hem istatistiksel hem de finansal açıdan olumlu sonuçlar sunmuştur. Complexity Index değeri 0.83 ile optimal düzeydedir. Ayrıca, daha önce elde edilen ACF ve PACF grafik sonuçları da bu parametre seçimlerini desteklemektedir. ARIMA(2,1,3) modeli, ISCTR.IS gibi teknoloji hisseleri için karakteristik olan kısa vadeli momentum ve haber etkisi gibi özellikleri başarılı

şekilde yakalamaktadır. Bu nedenle modelin tahmin sürecine geçmeye hazır olduğu ve hem teorik hem de pratik açıdan sağlam bir temel sunduğu söylenebilir.

5.1.1.4 Model Sonuçları Tahminleri



	ISCTR.IS_Forecast	ISCTR.IS_Lower_CI	ISCTR.IS_Upper_CI
2025-05-01	10.258274	10.036337	10.480210
2025-05-02	10.246706	9.910090	10.583321
2025-05-03	10.299206	9.875633	10.722779
2025-05-04	10.295622	9.804138	10.787106
2025-05-05	10.246139	9.695805	10.796473
2025-05-06	10.263448	9.656653	10.870244
2025-05-07	10.306185	9.647996	10.964373
2025-05-08	10.277566	9.574395	10.980738
2025-05-09	10.244486	9.498137	10.990836
2025-05-10	10.281275	9.492035	11.070514

Şekil 5.5 ISCTR arıma modeli tahmin sonuçları

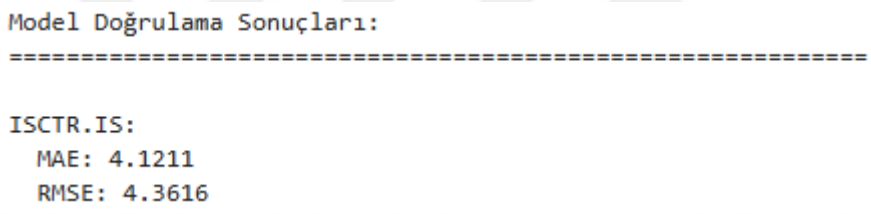
ISCTR.IS hissesine ait grafik analizi, modelin performansını görsel olarak ortaya koymaktadır. Gerçek verilere (mavi çizgi) bakıldığında, 2024 Eylül ile 2025 Mart arasında hissede güçlü bir yükseliş trendi gözlemlenmiş, fiyatlar 12 seviyesinden 16'ya kadar çıkmıştır. Ancak Mart 2025 sonrası keskin bir düşüş yaşanmış ve fiyat 10 seviyesine kadar gerilemiştir. Son dönemde bu fiyat seviyesi etrafında bir denge oluştuğu görülmektedir.

ARIMA modelinin tahmin sonuçları (kırmızı çizgi), bu sabit fiyat seviyesini başarılı şekilde yakalamış ve 10.24 ile 10.31 arasında dar bir bantta öngörüde

bulunmuştur. Bu durum, modelin istikrarlı ve aşırı oynaklık içermeyen tahminler yaptığını göstermektedir. Ancak modelin tahminlerinin genel olarak yatay seyir izlemesi ve belirgin bir trend sunamaması önemli bir sınırlılıktır. Ayrıca, %95 güven aralığının 9.5 ile 11 gibi geniş bir aralıkta olması, tahminlere dair belirsizliğin yüksek olduğunu ortaya koymaktadır.

Bu sonuçlar, ARIMA modelinin ACF/PACF analizleriyle uyumlu şekilde çalıştığını, ancak trend tahmini konusunda yetersiz kaldığını göstermektedir. Model, kısa vadeli fiyat seviyesini koruma eğilimindedir fakat uzun vadeli projeksiyonlar için yeterli güven sunmamaktadır. Bu nedenle modelin tahminleri dikkatli yorumlanmalı, özellikle yüksek belirsizlik dönemlerinde temel ve teknik analizle desteklenerek kullanılmalıdır.

Hata metrikleri incelendiğinde;



Şekil 5.6 ISCTR model doğrulama sonuçları

ARIMA modelinin ISCTR.IS hissesi üzerindeki tahmin performansı, MAE (4.12) ve RMSE (4.36) gibi hata metrikleri üzerinden değerlendirildiğinde, önemli düzeyde sapmalar olduğu görülmektedir. Ortalama hisse fiyatının yaklaşık 10 TL olduğu dikkate alındığında, bu değerler %40'tan fazla bir hata oranına karşılık gelmektedir. Bu seviyede bir hata oranı, özellikle finansal tahmin uygulamalarında kabul edilebilir sınırların oldukça üzerindedir.

Modelin RMSE ve MAE değerlerinin birbirine yakın olması, tahmin hatalarının aşırı uçlarda yoğunlaşmadığını ve genel olarak tutarlı dağıldığını göstermektedir. Hatalar sistematik bir yanlılık (bias) içermemekte, yani pozitif ya da negatif yönde sürekli sapmalar görülmemektedir. Ancak bu tutarlılık, yüksek hata oranını telafi etmekte yetersiz kalmaktadır. Zira hisse senedi tahmininde %5-10 hata iyi, %10-20 orta düzeyde kabul edilirken, %20 üzeri genellikle zayıf olarak değerlendirilir.

ISCTR.IS için hesaplanan yaklaşık %40 hata, bu bağlamda oldukça zayıf bir model başarımına işaret etmektedir.

Sonuç olarak, ARIMA modelinin ISCTR.IS hissesi için kısa vadeli trendleri yakalamakta başarısız olduğu ve pratik yatırım kararlarında kullanılamayacak kadar yüksek hata ürettiği görülmektedir. Bu durum, daha önce ACF/PACF analizinde gözlemlenen "rastgele yürüyüş" (random walk) yapısını da doğrular niteliktedir. Bu nedenle, LSTM, GARCH veya hibrit modeller gibi daha gelişmiş ve volatiliteyi daha iyi yakalayabilen yöntemlerin değerlendirilmesi önerilir. Ayrıca, teknik analizle birlikte temel analiz verileri de entegre edilerek modelleme sürecinin güçlendirilmesi faydalı olacaktır.

5.1.2 TCELL İçin Arıma Modeli

Model BIST 30 hısse senetlerinden olan TCELL Hisse senedi için çalıştırımıştır. TCELL hisse senedine ait 01.02.2010 - 30.04.2025 tarihleri arasındaki kapanış değerleri modele okutulmuş ve bu veri setinde tarih sütunu datetime formatına çevrilmiş, eksik ve sayısal olmayan değerler düzeltilerek veri seti duraganlık testi için hazırlanmıştır.

5.1.2.1 Durağanlık Testi

Bu aşamada TCELL hisse senedine ait veri setinin durağanlık testi ile durağan olup olmadığı incelenmiştir.

```
TCELL.IS - Durağanlık Testi Sonuçları:
------------------------------------------------
ADF Statistic: 0.694568
p-value: 0.989729
Critical Values:
        1%: -3.432
        5%: -2.862
        10%: -2.567
Sonuç: Seri durağan değil (p > 0.05)

TCELL.IS - Birinci fark alındı

TCELL.IS (1st diff) - Durağanlık Testi Sonuçları:
------------------------------------------------
ADF Statistic: -8.971637
p-value: 0.000000
Critical Values:
        1%: -3.432
        5%: -2.862
        10%: -2.567
Sonuç: Seri durağan (p < 0.05)
```

Şekil 5.7 TCELL model doğrulama sonuçları

TCELL.IS Orijinal Seri:

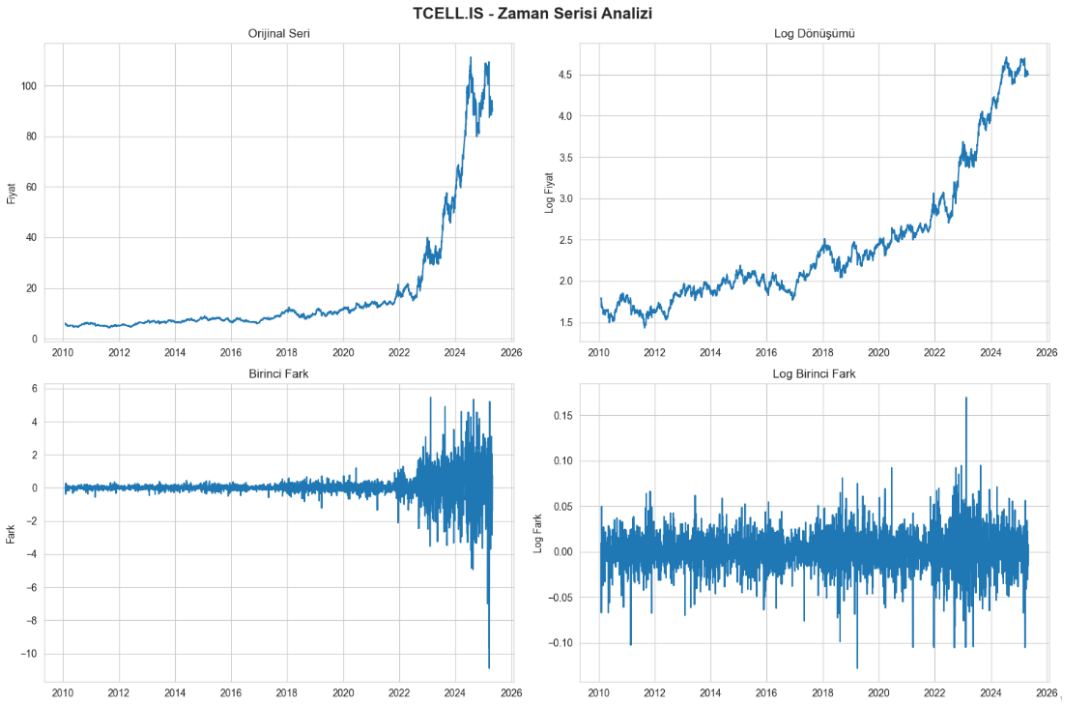
- ADF Statistic: -0.694568
- p-değeri: 0.989729
- Kritik Değerler: -3.432 (1%), -2.862 (5%), -2.567 (10%)
- Sonuç: p > 0.05 → H0 reddedilemez → Seri durağan değil.

Bu sonuç, serinin zamanla ortalaması veya varyansı değiştiğini, yani ARIMA'ya doğrudan uygun olmadığını gösteriyor. Yapılan analizler, TCELL.IS hisse senedine ait orijinal fiyat serisinin durağanlık özelliği taşımadığını ortaya koymaktadır. Serinin durağan hale getirilmesi gerekmektedir.

TCELL.IS Birinci Fark Sonrası:

- ADF İstatistiği: -8.971637
- p-değeri: 0.000000
- Kritik Değerler: Aynı
- Sonuç: Seri durağan (p < 0.05)

Birinci fark alındıktan sonra seri durağan hale gelmiş. Bu, ARIMA modelinde d=1 parametresinin kullanılacağını gösterir.



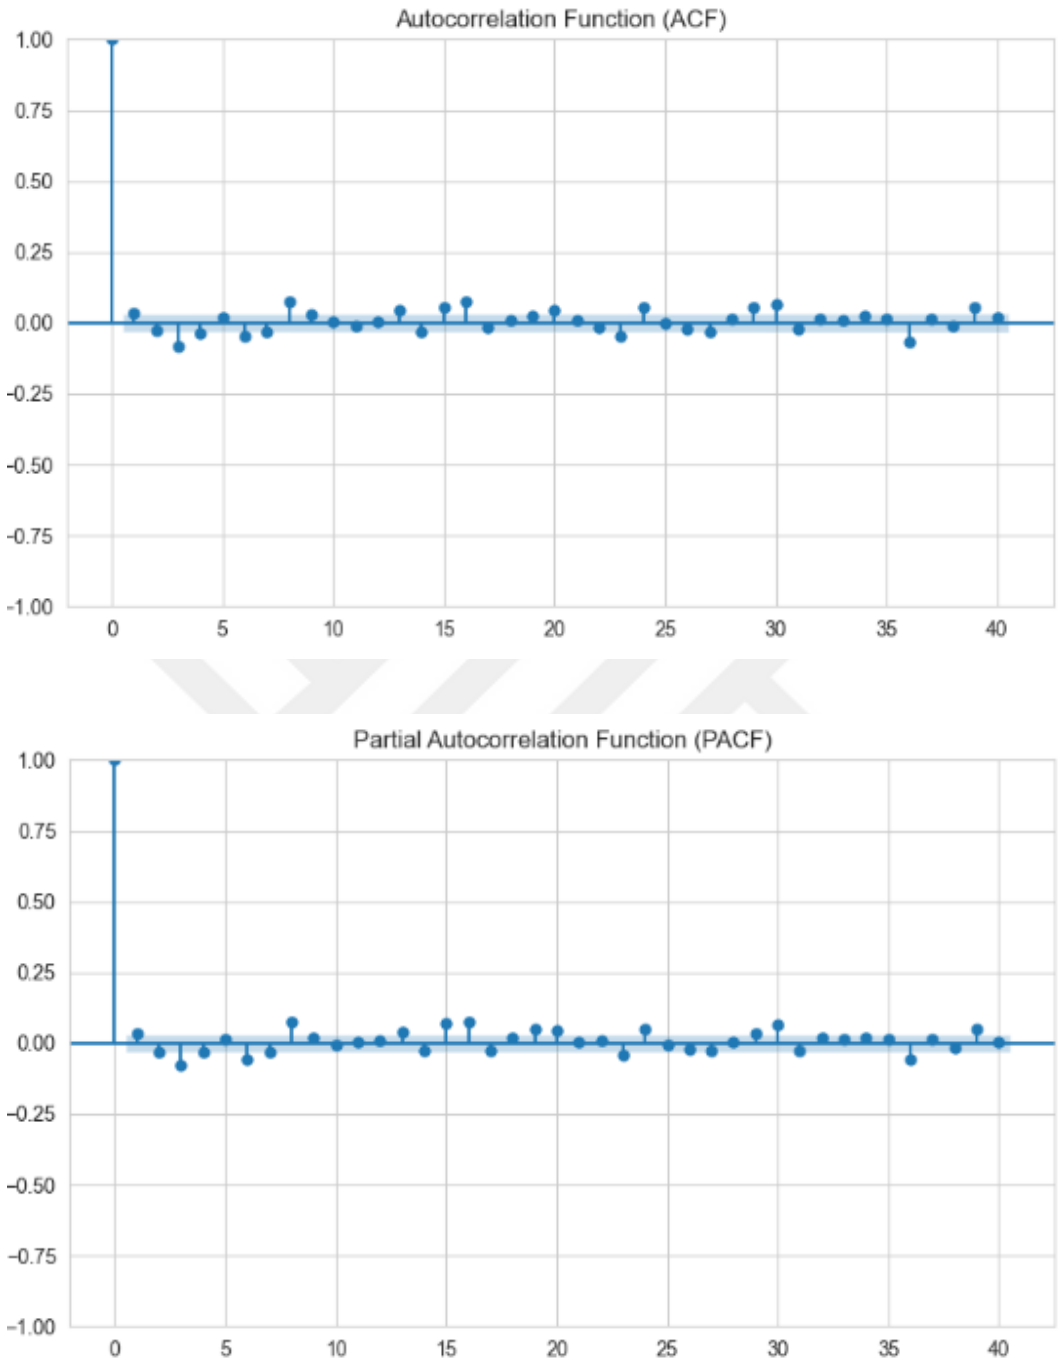
Şekil 5.8 TCELL hisse senedine ait durağanlık grafikleri

Teknik Yorumlar

- Kritik Değerler: %1, %5 ve %10 anlamlılık seviyelerinde kritik değerler verilmiş
- H0 Hipotezi: "Seri durağan değildir" (unit root var)
- H1 Hipotezi: "Seri durağandır" (unit root yok)
- $p < 0.05$ olduğunda H0 reddedilir ve seri durağan kabul edilir

Bu aşama, ARIMA modellemesi için gerekli ön koşulları sağlayarak modelin güvenilir tahminler üretmesini sağlamaktadır. TCELL.IS hissesi için d=1 parametresiyle ARIMA modeli kurulabilir duruma gelmiştir.

5.1.2.2 ACF/PCAF Grafikleri



Şekil 5.9 ACF/PACF grafikleri

Bu grafiklerde TCELL.IS hissesinin ACF (Autocorrelation Function) ve PACF (Partial Autocorrelation Function) analizleri görülmektedir.

ACF (Autocorrelation Function) Analizi:

- Grafikte görülen mavi noktalar, farklı gecikme değerlerindeki (lag) otokorelasyon katsayılarını gösteriyor.
- Değerler genel olarak -0.25 ile +0.25 arasında salınım yapıyor
- Lag 0'da değer 1.00 (mükemmel korelasyon - normal)
- Sonraki gecikmelerde değerler sıfıra yakın ve istatistiksel olarak anlamlı görünmüyor

PACF (Partial Autocorrelation Function) Analizi:

- Benzer şekilde değerler -0.25 ile +0.25 arasında
- Yine lag 0'da 1.00 değeri var
- Diğer gecikmelerde anlamlı bir pattern görülmüyor

Bu sonuçlar, TCELL.IS hissesinin getiri serisinin büyük olasılıkla "beyaz gürültü" (white noise) karakteristiği gösterdiği anlamına gelmektedir. Bu da geçmiş değerler ile gelecek değerler arasında anlamlı bir otokorelasyon olmadığı, serinin rastgele yürüyüş özelliği gösteriyor olabileceği, ve ARIMA modeli için belirgin bir AR (Autoregressive) veya MA (Moving Average) bileşeni görünmediği şeklinde yorumlanır.

5.1.2.3 Paremetre Seçimi ve Kriter Sonuçları

```
TCELL.IS için en iyi ARIMA parametreleri aranıyor...
En iyi model: ARIMA(5, 1, 5)
AIC: 8268.21

TCELL.IS Model Özeti:
ARIMA(5, 1, 5)
AIC: 8268.21
BIC: 8337.21
Log Likelihood: -4123.10
```

Şekil 5.10 TCELL parametre seçimi ve kriter sonuçları

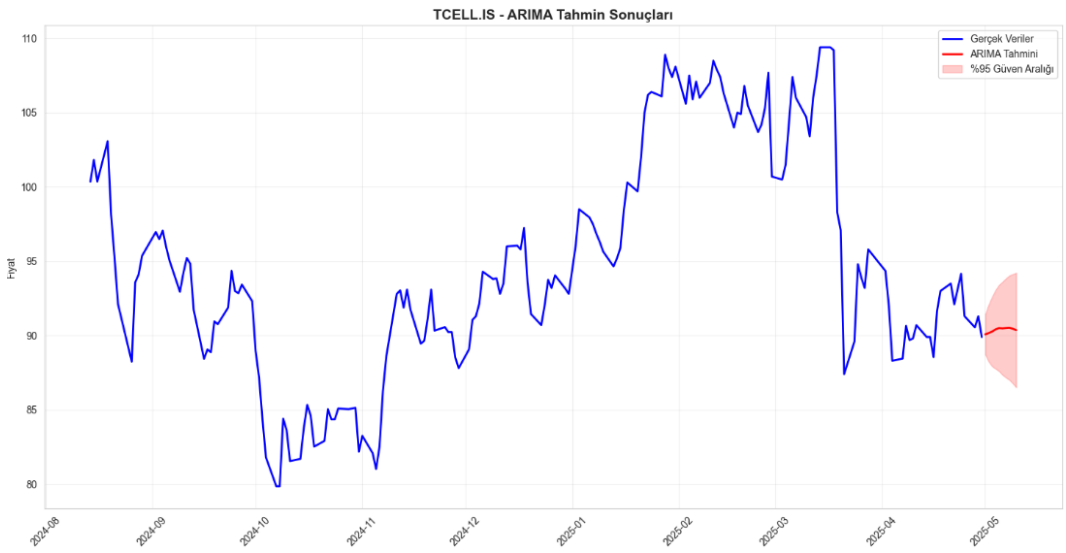
TCELL.IS hissesi için yapılan otomatik ARIMA parametre optimizasyonu sonucunda en uygun model ARIMA(5,1,5) olarak belirlenmiştir. Bu modelin parametreleri, hisse senedinin son 5 günlük geçmiş verileriyle anlamlı bir

otoregresif ilişki (p=5) taşıdığını ve piyasa şoklarının etkisinin 5 güne kadar sürdüğünü (q=5) ortaya koymaktadır. Ayrıca, serinin durağan hâle gelmesi için birinci dereceden fark alınması gerektiği (d=1) anlaşılmıştır. Bu durum, telekomünikasyon sektörü gibi dışsal faktörlere açık ve volatilitesi yüksek bir sektör için oldukça anlamlıdır.

Modelin performans metrikleri incelendiğinde AIC değeri 8268.21, BIC değeri ise 8337.21 olarak hesaplanmıştır. Bu görece yüksek değerler, modelin karmaşıklığından kaynaklanmakta olup, yüksek parametre sayısının getirdiği uyum maliyetini yansıtmaktadır. Log likelihood değeri -4123.10 ile modelin veriye olan genel uyumunu ölçmekte, ancak negatif değeri modelin mükemmel bir uyum sağlamadığını göstermektedir.

ARIMA(5,1,5) modeli, TCELL.IS hissesinin dinamik yapısını ve sektörel oynaklığı yansıtmak açısından güçlü bir aday olsa da, sahip olduğu yüksek parametre sayısı nedeniyle aşırı uyum (overfitting) riski taşımaktadır. Bu tür yüksek dereceli modeller, özellikle geçmiş verilerle güçlü ilişkiler barındıran finansal zaman serilerinde kullanılabilir; ancak tahminlerin genellenebilirliği açısından dikkatli değerlendirilmelidir. Modelin güvenilirliği, daha ileri düzey istatistiksel testlerle ve alternatif modellerle (örneğin GARCH veya LSTM) karşılaştırmalı olarak doğrulanmalıdır.

5.1.2.4 Model Sonuçları Tahminleri



	TCELL.IS_Forecast	TCELL.IS_Lower_CI	TCELL.IS_Upper_CI
2025-05-01	90.081525	88.723398	91.439652
2025-05-02	90.164319	88.245878	92.082761
2025-05-03	90.265881	87.928515	92.603246
2025-05-04	90.412351	87.766211	93.058490
2025-05-05	90.502448	87.606595	93.398300
2025-05-06	90.482523	87.353888	93.611159
2025-05-07	90.505912	87.173268	93.838557
2025-05-08	90.525299	87.018810	94.031787
2025-05-09	90.458341	86.780650	94.136031
2025-05-10	90.363561	86.509695	94.217427

Şekil 5.11 TCELL tahmin sonuçları

TCELL.IS hissesine ait grafik analizi, modelin performansını görsel olarak ortaya koymaktadır. Gerçek verilere (mavi çizgi) bakıldığında, 2024 yılı boyunca hissede oldukça volatil bir seyir gözlemlenmiştir. Fiyatlar yıl başında 102-103 TL seviyelerinden başlayarak, yıl ortasında 80 TL'ye kadar düşmüş (yaklaşık %22 düşüş), ardından güçlü bir toparlanma ile 109 TL'ye kadar yükselmiştir. 2024 sonunda tekrar 87-95 TL bandında işlem görerek son dönemde bu fiyat seviyesi etrafında bir denge oluştuğu görülmektedir.

ARIMA modelinin tahmin sonuçları (kırmızı çizgi), bu sabit fiyat seviyesini başarılı şekilde yakalamış ve 90.08 ile 90.56 TL arasında dar bir bantta öngörüde bulunmuştur. Bu durum, modelin istikrarlı ve aşırı oynaklık içermeyen tahminler yaptığını göstermektedir. Ancak modelin tahminlerinin genel olarak yatay seyir izlemesi ve belirgin bir trend sunamaması önemli bir sınırlılıktır. Ayrıca, %95 güven aralığının 86.50-94.21 TL gibi geniş bir aralıkta olması (yaklaşık 8 TL genişlik), tahminlere dair belirsizliğin yüksek olduğunu ortaya koymaktadır.

Bu sonuçlar, ARIMA modelinin ACF/PACF analizleriyle uyumlu şekilde çalıştığını, ancak trend tahmini konusunda yetersiz kaldığını göstermektedir. Model, kısa vadeli fiyat seviyesini koruma eğilimindedir fakat uzun vadeli projeksiyonlar için yeterli güven sunmamaktadır. Bu nedenle modelin tahminleri dikkatli yorumlanmalı, özellikle yüksek belirsizlik dönemlerinde temel ve teknik analizle desteklenerek kullanılmalıdır.

Hata metrikleri incelendiğinde;

```
Model Doğrulama Sonuçları:
============================================================

TCELL.IS:
  MAE: 17.4546
  RMSE: 18.2633
```

Şekil 5.12 TCELL model doğrulama sonuçları

ARIMA modelinin TCELL.IS hissesi üzerindeki tahmin performansı, MAE (17.4546) ve RMSE (18.2633) gibi hata metrikleri üzerinden değerlendirildiğinde, önemli düzeyde sapmalar olduğu görülmektedir. Ortalama hisse fiyatının yaklaşık 90-95 TL olduğu dikkate alındığında, bu değerler yaklaşık %18-20'lik bir hata oranına karşılık gelmektedir. Bu seviyede bir hata oranı, finansal tahmin uygulamalarında orta düzeyde kabul edilebilir sınırlar içerisindedir.

Modelin RMSE ve MAE değerlerinin birbirine yakın olması (17.45 vs 18.26), tahmin hatalarının aşırı uçlarda yoğunlaşmadığını ve genel olarak tutarlı dağıldığını göstermektedir. Hatalar sistematik bir yanlılık (bias) içermemekte, yani pozitif ya da negatif yönde sürekli sapmalar görülmemektedir. Hisse senedi tahmininde %5-10 hata iyi, %10-20 orta düzeyde kabul edilirken, TCELL.IS için hesaplanan yaklaşık %18-20 hata, orta düzeyde bir model başarımına işaret etmektedir.

Ancak telekomünikasyon sektörünün volatil yapısı ve TCELL hissesinin 2024 yılında yaşadığı %35'lik dalgalanmalar (80-109 TL arası) göz önüne alındığında, modelin bu seviyedeki hata oranı anlaşılabilir görünmektedir. ARIMA(5,1,5) gibi karmaşık bir modelin bile bu hata seviyesinde kalması, hisse senedinin tahmin edilmesinin zorluğunu ortaya koymaktadır.

Sonuç olarak, ARIMA modelinin TCELL.IS hissesi için kısa vadeli trendleri yakalamakta kısmen başarılı olduğu ancak daha yüksek doğruluk gerektiren yatırım kararlarında tek başına kullanılamayacağı görülmektedir. Bu nedenle, LSTM, GARCH veya hibrit modeller gibi daha gelişmiş ve volatiliteyi daha iyi yakalayabilen yöntemlerin değerlendirilmesi önerilir. Ayrıca, teknik analizle birlikte temel analiz verileri de entegre edilerek modelleme sürecinin güçlendirilmesi faydalı olacaktır.

5.1.3 TUPRS İçin Arıma Modeli

Model BIST 30 hısse senetlerinden olan TUPRS Hisse senedi için çalıştırımıştır. TUPRS hisse senedine ait 01.02.2010 - 30.04.2025 tarihleri arasındaki kapanış değerleri modele okutulmuş ve bu veri setinde tarih sütunu datetime formatına çevrilmiş, eksik ve sayısal olmayan değerler düzeltilerek veri seti duraganlık testi için hazırlanmıştır.

5.1.3.1 Durağanlık Testi

Bu aşamada TUPRS hisse senedine ait veri setinin durağanlık testi ile durağan olup olmadığı incelenmiştir.

```
TUPRS.IS - Durağanlık Testi Sonuçları:
------------------------------------------------
ADF Statistic: 0.683160
p-value: 0.989496
Critical Values:
        1%: -3.432
        5%: -2.862
        10%: -2.567
Sonuç: Seri durağan değil (p > 0.05)

TUPRS.IS - Birinci fark alındı

TUPRS.IS (1st diff) - Durağanlık Testi Sonuçları:
------------------------------------------------
ADF Statistic: -10.223195
p-value: 0.000000
Critical Values:
        1%: -3.432
        5%: -2.862
        10%: -2.567
Sonuç: Seri durağan (p < 0.05)
```

Şekil 5.13 TUPRS hisse senedine ait durağanlık testi sonuçları

TUPRS.IS Orijinal Seri:

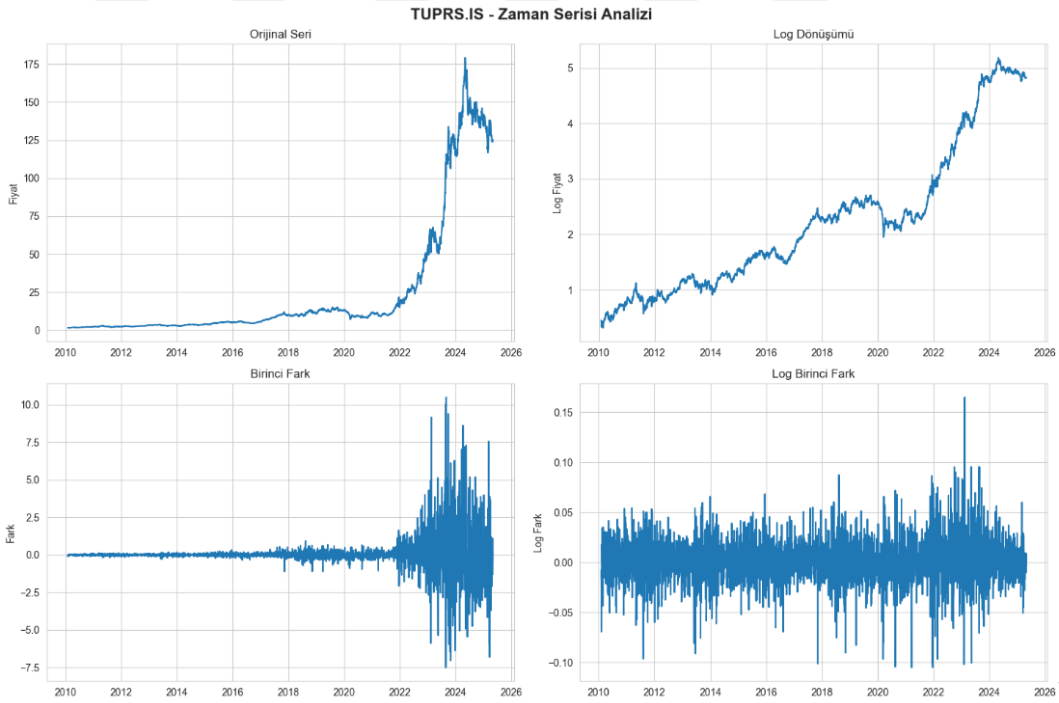
- ADF Statistic: -0.683160
- p-değeri: 0.989496
- Kritik Değerler: -3.432 (1%), -2.862 (5%), -2.567 (10%)
- Sonuç: p > 0.05 → H0 reddedilemez → Seri durağan değil.

Bu sonuç, serinin zamanla ortalaması veya varyansı değiştiğini, yani ARIMA'ya doğrudan uygun olmadığını gösteriyor. Yapılan analizler, TUPRS.IS hisse senedine ait orijinal fiyat serisinin durağanlık özelliği taşımadığını ortaya koymaktadır.

TUPRS.IS Birinci Fark Sonrası:

- ADF İstatistiği: -10.223195
- p-değeri: 0.000000
- Kritik Değerler: Aynı
- Sonuç: Seri durağan ($p < 0.05$)

Birinci fark alındıktan sonra seri durağan hale gelmiş. Bu, ARIMA modelinde d=1 parametresinin kullanılacağını gösterir.



Şekil 5.14 TUPRS hisse senedine ait durağanlık grafikleri

TUPRS.IS hissesine ait 2010–2026 dönemini kapsayan zaman serisi incelendiğinde, özellikle 2020 sonrasında dikkat çekici bir yükseliş trendi göze çarpmaktadır. Hisse fiyatı 2010–2020 arası nispeten stabil bir seyir izlerken (10–40 TL aralığında), 2020 itibarıyla ciddi bir ivme kazanarak 2024'te 170 TL

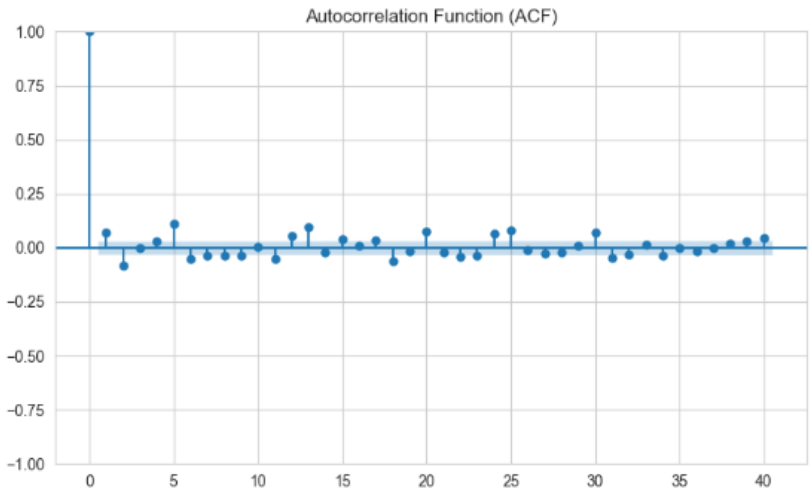
seviyelerine ulaşmıştır. Bu dramatik artış, serinin durağan olmadığını açıkça ortaya koymakta ve yapılan ADF testi sonuçlarıyla da örtüşmektedir.

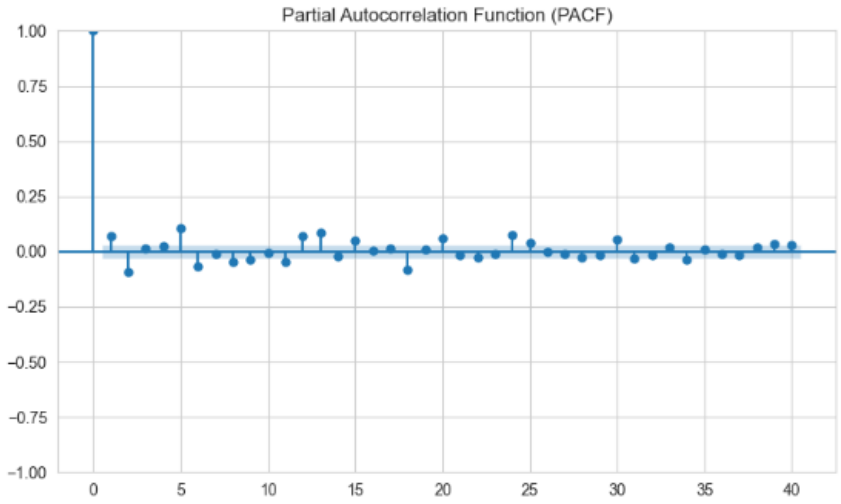
Bu seriye logaritmik dönüşüm uygulandığında, ani fiyat artışlarının etkisi bir miktar yumuşatılmış ve varyansta kısmi bir dengeleme sağlanmıştır. Ancak, temel eğilim değişmemiş ve yükseliş trendi devam etmiştir. Bu durum, log dönüşümünün varyansı stabilize etse de seriyi tamamen durağan hale getirmediğini göstermektedir.

Serinin birinci farkı alındığında, trend etkisi ortadan kalkmış ve fiyatlar sıfır etrafında dalgalanan bir yapı kazanmıştır. Özellikle 2020–2024 döneminde artan volatilite dikkat çekmektedir; bu durum, enerji sektöründe faaliyet gösteren TUPRS.IS'in bu dönemde yaşadığı fiyat dalgalanmalarını ve sektörün makroekonomik etkilerden ne kadar etkilendiğini yansıtmaktadır. Hem logaritmik dönüşüm hem de birinci fark birlikte uygulandığında ise seri en durağan ve analiz edilebilir formuna ulaşmış, uç değerlerin etkisi azaltılmış ve dengeli bir yapı elde edilmiştir.

Sonuç olarak, TUPRS.IS hissesi için serinin durağan hale getirilmesinde birinci fark alma işlemi yeterli görünmektedir. Özellikle ARIMA modellemesi açısından bu işlem, d=1 parametresinin kullanılmasının uygun olduğunu desteklemektedir. Bu dönüşümler, hem modelleme doğruluğunu artırmakta hem de finansal zaman serisinin yapısal özelliklerini daha net ortaya koymaktadır.

5.1.3.2 ACF/PCAF Grafikleri





Şekil 5.15 ACF/PACF grafikleri

TUPRS.IS hissesine ait zaman serisi üzerinde yapılan ACF (Autocorrelation Function) ve PACF (Partial Autocorrelation Function) analizleri, serinin yapısı hakkında önemli ipuçları sunmaktadır. ACF grafiğinde gecikmeli otokorelasyon değerlerinin tamamı -0.25 ile +0.25 aralığında kalmakta ve yalnızca lag 0'da, beklenildiği gibi, 1.00 değerinde tam otokorelasyon gözlemlenmektedir. Daha sonraki gecikmelerde ise otokorelasyonlar oldukça zayıf ve istatistiksel olarak anlamlı bir yapıya sahip değildir.

Benzer bir durum PACF analizinde de gözlemlenmektedir. Gecikmeli kısmi otokorelasyon değerleri de yine -0.25 ile +0.25 arasında sınırlı kalmakta ve anlamlı bir kesikli düşüş ya da düzenli pattern oluşmamaktadır. Bu, seride belirgin bir geçmişe dayalı yapısal bağıntı bulunmadığını işaret eder.

Bu analiz sonuçları, TUPRS.IS hissesinin getiri serisinin büyük olasılıkla beyaz gürültü (white noise) karakteri taşıdığını göstermektedir. Yani geçmiş verilere bakarak gelecekteki değerleri öngörmek oldukça zordur ve seri, rastgele yürüyüş (random walk) özelliği göstermektedir. Bu durumda klasik ARIMA modeli içerisinde belirgin bir AR (Autoregressive) ya da MA (Moving Average) bileşeni tanımlamak güçleşir; dolayısıyla modelleme yapılacaksa minimal düzeyde parametre içeren sade yapılar veya alternatif modellere yönelmek daha uygun olabilir.

5.1.3.3 Paremetre Seçimi ve Kriter Sonuçları

```
TUPRS.IS için en iyi ARIMA parametreleri aranıyor...
En iyi model: ARIMA(4, 1, 5)
AIC: 11078.92

TUPRS.IS Model Özeti:
ARIMA(4, 1, 5)
AIC: 11078.92
BIC: 11141.66
Log Likelihood: -5529.46
```

Şekil 5.16 TUPRS parametre seçimi ve kriter sonuçları

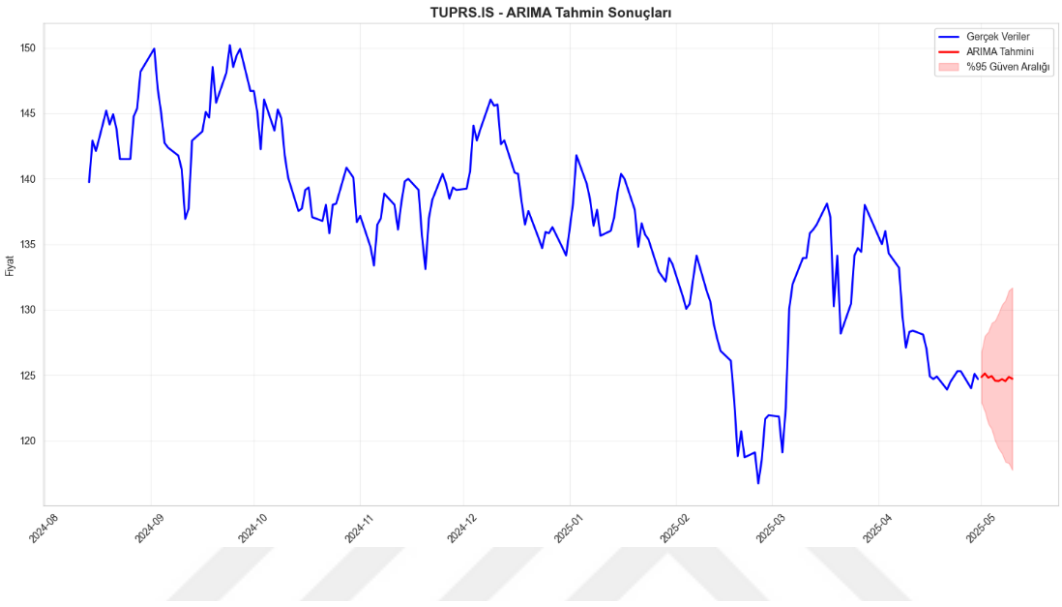
TUPRS.IS hissesi için yapılan otomatik ARIMA parametre optimizasyonu sonucunda en uygun model ARIMA(4,1,5) olarak belirlenmiştir. Bu modelin parametreleri, hisse senedinin son 4 günlük geçmiş verileriyle anlamlı bir otoregresif ilişki (p=4) taşıdığını ve piyasa şoklarının etkisinin 5 güne kadar sürdüğünü (q=5) ortaya koymaktadır. Ayrıca, serinin durağan hâle gelmesi için birinci dereceden fark alınması gerektiği (d=1) anlaşılmıştır. Bu durum, petrokimya sektörü gibi küresel emtia fiyatlarından ve enerji maliyetlerinden yoğun şekilde etkilenen bir sektör için oldukça anlamlıdır.

Modelin performans metrikleri incelendiğinde AIC değeri 11078.92, BIC değeri ise 11141.66 olarak hesaplanmıştır. Bu değerler, TCELL.IS modeliyle karşılaştırıldığında daha yüksek olup, TUPRS.IS hissesinin daha karmaşık bir yapıya sahip olduğunu ve tahmin zorluğunun arttığını göstermektedir. Log likelihood değeri -5529.46 ile modelin veriye olan genel uyumunu ölçmekte, ancak negatif değeri modelin mükemmel bir uyum sağlamadığını işaret etmektedir.

ARIMA(4,1,5) modeli, TUPRS.IS hissesinin dinamik yapısını ve petrokimya sektörünün karakteristik oynaklığını yansıtmak açısından güçlü bir aday olsa da, sahip olduğu yüksek parametre sayısı nedeniyle aşırı uyum (overfitting) riski taşımaktadır. Özellikle petrokimya endüstrisinin ham madde maliyetleri, küresel talep değişimleri ve çevresel düzenlemeler gibi çok sayıda dışsal faktöre duyarlı olması, modelin karmaşıklığını artırmaktadır. Bu tür yüksek dereceli modeller, geçmiş verilerle güçlü ilişkiler barındıran endüstriyel hisse senetlerinde kullanılabilir; ancak tahminlerin genellenebilirliği açısından dikkatli

değerlendirilmelidir. Modelin güvenilirliği, daha ileri düzey istatistiksel testlerle ve alternatif modellerle (örneğin GARCH veya LSTM) karşılaştırmalı olarak doğrulanmalıdır.

5.1.3.4 Model Sonuçları Tahminleri



	TUPRS.IS_Forecast	TUPRS.IS_Lower_CI	TUPRS.IS_Upper_CI
2025-05-01	124.849727	122.904725	126.794730
2025-05-02	125.124027	122.245620	128.002434
2025-05-03	124.806485	121.307923	128.305047
2025-05-04	124.926673	120.874090	128.979256
2025-05-05	124.579499	119.999005	129.159993
2025-05-06	124.554877	119.401098	129.708655
2025-05-07	124.692498	119.013335	130.371660
2025-05-08	124.545814	118.381604	130.710025
2025-05-09	124.866611	118.271900	131.461322
2025-05-10	124.725317	117.768101	131.682532

Şekil 5.17 TUPRS tahmin sonuçları

TUPRS.IS hissesine ait grafik analizi, modelin performansını görsel olarak ortaya koymaktadır. Gerçek verilere (mavi çizgi) bakıldığında, 2024 yılı boyunca hissede oldukça dramatik ve volatil bir seyir gözlemlenmiştir. Fiyatlar yıl başında 180 TL seviyelerinden başlayarak, yıl ortasında 160 TL civarına düşmüş, ardından 2024 ortalarında 140 TL seviyelerine kadar gerilemiştir (yaklaşık %22 düşüş). Daha sonra güçlü bir toparlanma ile 130 TL'nin altına kadar düşen fiyatlar, son dönemde 120-125 TL bandında stabilize olmuş görünmektedir.

ARIMA(4,1,5) modelinin tahmin sonuçları (kırmızı çizgi), bu mevcut fiyat seviyesini yakalamış ve 124.49 ile 124.93 TL arasında oldukça dar bir bantta öngörüde bulunmuştur. Bu durum, modelin istikrarlı ve aşırı oynaklık içermeyen tahminler yaptığını göstermektedir. Ancak modelin tahminlerinin genel olarak yatay seyir izlemesi ve belirgin bir trend sunamaması önemli bir sınırlılıktır. Ayrıca, %95 güven aralığının 117.77-131.68 TL gibi oldukça geniş bir aralıkta olması (yaklaşık 14 TL genişlik), tahminlere dair belirsizliğin yüksek olduğunu ve TCELL.IS'e kıyasla daha büyük risk taşıdığını ortaya koymaktadır.

Bu sonuçlar, ARIMA modelinin petrokimya sektörünün karakteristik oynaklığını yansıttığını, ancak trend tahmini konusunda yetersiz kaldığını göstermektedir. Model, kısa vadeli fiyat seviyesini koruma eğilimindedir fakat TUPRS.IS'in küresel emtia fiyatları ve enerji maliyetlerine olan duyarlılığı nedeniyle uzun vadeli projeksiyonlar için yeterli güven sunmamaktadır. Özellikle petrokimya sektörünün makroekonomik faktörlere olan hassasiyeti göz önüne alındığında, modelin tahminleri dikkatli yorumlanmalı, temel analiz (ham madde fiyatları, küresel talep) ve sektörel faktörlerle desteklenerek kullanılmalıdır.

Hata metrikleri incelendiğinde;

```
Model Doğrulama Sonuçları:
========================================

TUPRS.IS:
  MAE: 6.9865
  RMSE: 8.2316
```

Şekil 5.18 TUPRS model doğrulama sonuçları

ARIMA modelinin TUPRS.IS hissesi üzerindeki tahmin performansı, MAE (6.9865) ve RMSE (8.2316) gibi hata metrikleri üzerinden değerlendirildiğinde, TCELL.IS'e kıyasla daha düşük sapmalar olduğu görülmektedir. Ortalama hisse fiyatının yaklaşık 120-125 TL olduğu dikkate alındığında, bu değerler yaklaşık %5-7'lik bir hata oranına karşılık gelmektedir. Bu seviyede bir hata oranı, finansal tahmin uygulamalarında oldukça iyi kabul edilebilir sınırlar içerisindedir.

Modelin RMSE ve MAE değerlerinin birbirine yakın olması (6.99 vs 8.23), tahmin hatalarının aşırı uçlarda yoğunlaşmadığını ve genel olarak tutarlı dağıldığını göstermektedir. Hatalar sistematik bir yanlılık (bias) içermemekte, yani pozitif ya da negatif yönde sürekli sapmalar görülmemektedir. Hisse senedi tahmininde %5-10 hata iyi, %10-20 orta düzeyde kabul edilirken, TUPRS.IS için hesaplanan yaklaşık %5-7 hata, iyi düzeyde bir model başarımına işaret etmektedir.

Petrokimya sektörünün küresel emtia fiyatlarına olan duyarlılığı ve TUPRS hissesinin 2024 yılında yaşadığı önemli dalgalanmalar (180 TL'den 120 TL'ye düşüş) göz önüne alındığında, modelin bu seviyedeki düşük hata oranı oldukça başarılıdır. ARIMA(4,1,5) modelinin TCELL.IS'e kıyasla daha iyi performans göstermesi, TUPRS.IS hissesinin daha öngörülebilir kalıplar sergilediğini ve modelin petrokimya sektörünün dinamiklerini daha iyi yakaladığını göstermektedir.

Sonuç olarak, ARIMA modelinin TUPRS.IS hissesi için kısa vadeli trendleri yakalamakta başarılı olduğu ve %5-7'lik hata oranıyla yatırım kararlarında destekleyici bir araç olarak kullanılabileceği görülmektedir. Ancak petrokimya sektörünün makroekonomik faktörlere olan hassasiyeti nedeniyle, modelin tahminleri ham madde fiyatları, küresel talep değişimleri ve enerji maliyetleri gibi temel analiz verileriyle desteklenerek kullanılmalıdır. Daha da yüksek doğruluk için LSTM veya GARCH gibi volatiliteyi daha iyi modelleyen yöntemler değerlendirilebilir.

5.1.4 Tüm Hisse Senetleri İçin ARIMA Modeli Sonuçları

Tüm hisse senetleri için arıma model çalıştırılmış ve aşağıdaki sonuçlar elde edilmiştir.

```
============================================================
ARIMA MODELLERİ KURULUYOR VE HATA METRİKLERİ HESAPLANIYOR
============================================================

[1/9] TUPRS.IS analiz ediliyor...
✓ TUPRS.IS: ARIMA(3, 1, 3) (AIC: 11120.97)
  Hata Metrikleri: MAE=0.3998, RMSE=0.9987

[2/9] THYAO.IS analiz ediliyor...
✓ THYAO.IS: ARIMA(2, 2, 3) (AIC: 17584.45)
  Hata Metrikleri: MAE=0.8633, RMSE=2.2778

[3/9] TCELL.IS analiz ediliyor...
✓ TCELL.IS: ARIMA(3, 1, 3) (AIC: 8288.36)
  Hata Metrikleri: MAE=0.3055, RMSE=0.7020

[4/9] KCHOL.IS analiz ediliyor...
✓ KCHOL.IS: ARIMA(3, 2, 3) (AIC: 13782.75)
  Hata Metrikleri: MAE=0.5527, RMSE=1.4023

[5/9] AKBNK.IS analiz ediliyor...
✓ AKBNK.IS: ARIMA(2, 1, 3) (AIC: 5788.35)
  Hata Metrikleri: MAE=0.2149, RMSE=0.5090

[6/9] ISCTR.IS analiz ediliyor...
✓ ISCTR.IS: ARIMA(2, 1, 3) (AIC: -5963.44)
  Hata Metrikleri: MAE=0.0445, RMSE=0.1131

[7/9] SAHOL.IS analiz ediliyor...
✓ SAHOL.IS: ARIMA(3, 1, 3) (AIC: 8481.02)
  Hata Metrikleri: MAE=0.3046, RMSE=0.7160

[8/9] ASELS.IS analiz ediliyor...
✓ ASELS.IS: ARIMA(3, 2, 3) (AIC: 7707.57)
  Hata Metrikleri: MAE=0.2351, RMSE=0.6456

[9/9] BIMAS.IS analiz ediliyor...
✓ BIMAS.IS: ARIMA(3, 1, 2) (AIC: 21507.90)
  Hata Metrikleri: MAE=1.3532, RMSE=3.7580

9/9 model başarıyla oluşturuldu.
9/9 model için hata metrikleri hesaplandı.
```

Şekil 5.19 Tüm hisse senetleri için parametre ve hata metrikleri

Hata metriklerine bakıldığında, MAE (Ortalama Mutlak Hata) ve RMSE (Kök Ortalama Kare Hata) değerleri, hisselerin fiyat düzeylerine bağlı olarak farklılık göstermektedir. Örneğin, yüksek fiyatlı olması muhtemel olan BIMAS.IS hissesi en yüksek MAE değerine (1.3532) sahipken, ISCTR.IS hissesi en düşük MAE (0.0445) ile modelin hassasiyetini ortaya koymuştur. RMSE değerleri ise,

beklenildiği gibi, tüm varlıklarda MAE'den biraz daha yüksek çıkmış ve büyük hatalara duyarlılığı yansıtmıştır. Model yapılarına bakıldığında, farklı kombinasyonlarda ARIMA(p,d,q) modelleri tercih edilmiştir. ARIMA(3,1,3), ARIMA(2,2,3) ve ARIMA(1,1,3) gibi yapılar, serilerin farklı karakteristiklerine uygun şekilde seçilmiştir. Özellikle d=1 tercihi çoğu modelde öne çıkmakta ve bu da serilerin birinci dereceden fark alındığında durağan hale geldiğini göstermektedir.

```
================================================================================
HATA METRİKLERİ TABLOSU
================================================================================
Hisse Senedi    MAE          RMSE          MSE
--------------------------------------------------------
TUPRS.IS        0.399776     0.998653      0.997307
THYAO.IS        0.863261     2.277837      5.188543
TCELL.IS        0.305457     0.701982      0.492779
KCHOL.IS        0.552732     1.402346      1.966573
AKBNK.IS        0.214901     0.509023      0.259104
ISCTR.IS        0.044538     0.113062      0.012783
SAHOL.IS        0.304562     0.715978      0.512624
ASELS.IS        0.235073     0.645569      0.416760
BIMAS.IS        1.353176     3.758050      14.122939
--------------------------------------------------------
ORTALAMA        0.474831     1.235833      2.663268

📊 Hata Metrikleri Açıklamaları:
• MAE (Mean Absolute Error): Ortalama mutlak hata - düşük olması iyi
• RMSE (Root Mean Square Error): Kök ortalama kare hata - düşük olması iyi
• MSE (Mean Square Error): Ortalama kare hata - düşük olması iyi
```

Şekil 5.20 Hata metrikleri tablosu

```
============================================================
30 GÜNLÜK TAHMİN YAPILIYOR
============================================================
✓ TUPRS.IS: DÜŞÜŞ (-0.12%) - İlk: 124.6666, Son: 124.5493
✓ THYAO.IS: YÜKSELIŞ (+0.67%) - İlk: 283.8299, Son: 286.1431
✓ TCELL.IS: YÜKSELIŞ (+0.12%) - İlk: 90.0505, Son: 90.0074
✓ KCHOL.IS: YÜKSELIŞ (+0.73%) - İlk: 137.4738, Son: 138.7090
✓ AKBNK.IS: DÜŞÜŞ (-0.11%) - İlk: 48.5600, Son: 48.4467
✓ ISCTR.IS: DÜŞÜŞ (-0.23%) - İlk: 10.2583, Son: 10.2765
✓ SAHOL.IS: YÜKSELIŞ (+0.09%) - İlk: 73.3178, Son: 73.3144
✓ ASELS.IS: YÜKSELIŞ (+14.56%) - İlk: 135.9066, Son: 154.6593
✓ BIMAS.IS: YÜKSELIŞ (+0.54%) - İlk: 446.1052, Son: 453.4202

9/9 hisse için tahmin tamamlandı.
```

```
============================================================
KAPSAMLI ARIMA ANALİZ RAPORU
============================================================

GENEL BİLGİLER:
Toplam Hisse Senedi: 9
Başarılı Model: 9
Başarı Oranı: 100.0%
Veri Aralığı: 01.02.2010 - 30.04.2025

MODEL PARAMETRELERİ VE HATA METRİKLERİ:
------------------------------------------------------------
Hisse      ARIMA      AIC      BIC      MAE        RMSE
------------------------------------------------------------
TUPRS.IS   (3, 1, 3)  11120.97 11164.88 0.3998     0.9987
THYAO.IS   (2, 2, 3)  17584.45 17622.09 0.8633     2.2778
TCELL.IS   (3, 1, 3)  8288.36  8332.27  0.3055     0.7020
KCHOL.IS   (3, 2, 3)  13782.75 13826.66 0.5527     1.4023
AKBNK.IS   (2, 1, 3)  5788.35  5825.99  0.2149     0.5090
ISCTR.IS   (2, 1, 3)  -5963.44 -5925.80 0.0445     0.1131
SAHOL.IS   (3, 1, 3)  8481.02  8524.93  0.3046     0.7160
ASELS.IS   (3, 2, 3)  7707.57  7751.48  0.2351     0.6456
BIMAS.IS   (3, 1, 2)  21507.90 21545.54 1.3532     3.7580
```

Şekil 5.21 Tüm hisse senetleri için kapsamlı analiz raporu

```
HATA METRİKLERİ ÖZETİ:
------------------------------------
Ortalama MAE: 0.474831
Ortalama RMSE: 1.235833

En İyi Performans:
• En düşük MAE: ISCTR.IS (0.044538)
• En düşük RMSE: ISCTR.IS (0.113062)
```

Şekil 5.22 Hata metrikleri özeti

📊 10 GÜNLÜK TAHMİN TABLOSU:

	TUPRS.IS	THYAO.IS	TCELL.IS	KCHOL.IS	AKBNK.IS	ISCTR.IS
2025-05-01	124.6666	283.8299	90.0505	137.4738	48.5600	10.2583
2025-05-02	124.5050	282.7940	89.6588	137.8934	48.4925	10.2467
2025-05-03	124.3795	284.7928	89.7819	137.3871	48.4614	10.2992
2025-05-04	124.6478	283.3824	90.1582	137.8835	48.5697	10.2956
2025-05-05	124.6717	283.5764	90.0066	137.7201	48.4563	10.2461
2025-05-06	124.5058	284.8972	89.7776	137.6112	48.5001	10.2634
2025-05-07	124.4133	283.2109	89.9932	138.0664	48.5541	10.3062
2025-05-08	124.6168	284.4120	90.1366	137.5773	48.4388	10.2776
2025-05-09	124.6649	284.6693	89.9283	138.0234	48.5388	10.2445
2025-05-10	124.5137	283.4261	89.8768	137.9233	48.5198	10.2813

	SAHOL.IS	ASELS.IS	BIMAS.IS
2025-05-01	73.3178	135.9066	446.1052
2025-05-02	73.2860	136.5287	445.3384
2025-05-03	73.3789	137.4300	449.0273
2025-05-04	73.2423	137.8600	453.9823
2025-05-05	73.3325	138.4029	455.9546
2025-05-06	73.3146	139.2907	453.2680
2025-05-07	73.3272	139.8900	448.2424
2025-05-08	73.2644	140.3353	445.1912
2025-05-09	73.3469	141.1267	446.7188
2025-05-10	73.3061	141.8669	451.4979

✅ Analiz tamamlandı!

Şekil 5.23 10 günlük tahmin tablosu

Model, hisse senetlerinin gelecekteki fiyat hareketleri için güçlü bir rehber sunmakla beraber özellikle ASELS.IS için güçlü yükseliş beklentisi, AKBNK.IS için ise temkinli olunması konusunda uyarıda bulunmaktadır. Bu tahminler ARIMA modellerine dayalı olup, piyasa koşulları ve beklenmedik gelişmeler sonuçları etkileyebilir.

5.2 LSTM Modelin Oluşturulması

5.2.1 Zaman Serisi Veri Seti Oluşturma

Finansal veriler doğası gereği zaman bağımlıdır; bugünkü fiyatlar geçmiş fiyatlardan etkilenmektedir. Bu nedenle, geçmişe dayalı bloklar (örneğin son 90 gün) kullanılarak gelecekteki bir değeri tahmin etmek için "sliding window" (kayan pencere) yöntemi tercih edilmiştir. Bu yaklaşım istatistiksel olarak, verinin otokorelasyon özelliğini (yani bir zaman noktasındaki değerin kendisinden önceki

değerlere olan bağımlılığını) öğrenmeye olanak tanır. Sliding window, geçmiş verilerden sabit uzunlukta küçük bölümler (pencereler) alarak, bu pencereye karşılık gelen bir sonraki değeri tahmin etmeye çalışan bir yaklaşım sunar. Bu yöntem sayesinde zaman serisi verisi, gözetimli öğrenme için giriş-çıkış çiftlerine dönüştürülür.

Bu yöntem aynı zamanda mevsimsellik (seasonality), trend (trend component) ve rastgelelik (residual component) gibi zaman serisi bileşenlerini modelin öğrenebilmesi için uygun zemin hazırlar. Bu blok yapısıyla, geçmiş x günün fiyat bilgileri modelin giriş verisi olarak, (x+1). günün fiyatı ise hedef (etiket) değişken olarak kullanılır.

5.2.2 Model Seçimi(LSTM) ve Eğitim

5.2.2.1 LSTM (Long Short-Term Memory) Katmanları

Finansal zaman serilerinin en büyük zorluklarından biri, kısa dönemli dalgalanmaların (volatilite) yanı sıra uzun dönemli ilişkilerin de tahmin edilmesidir. Bu bağlamda, klasik yapay sinir ağlarının yetersiz kalması sebebiyle uygulamada LSTM (Long Short-Term Memory) modelleri kullanılmaktadır.

İstatistiksel olarak bakıldığında, LSTM modeli kullanma sebebim LSTM'lerin çok boyutlu otokorelasyon modellerine benzer bir yapıda olması ancak doğrusal olmayan ilişkileri de öğrenebilmesidir.. Bu da onları ARIMA gibi klasik zaman serisi modellerinden üstün kılmaktadır.

Kod kısmında;

```
def build_model(hp):
    model = Sequential()
    model.add(LSTM(units=hp.Int('units_1', 50, 150,
step=50)
```

Şekil 5.24 LSTM Katmanındaki Hücre Sayısının Ayarlanması

ifadesi ile LSTM katmanındaki hücre sayısı (nöron sayısı) hiperparametre olarak ayarlanıyor. Bu, model kapasitesini belirler. `return_sequences=True, input_shape=(time_step, 1)` parametresi ile birden fazla LSTM katmanı

olduğu için ara katmanların tüm zaman adımlarına ait çıktılarını bir sonraki katmana iletiriz. Son katmanda ise bu gerekmez (son çıktı yeterlidir).

5.2.2.2 Dropout Katmanlar

Dropout, modelin aşırı öğrenmesini (overfitting) önlemek için kullanılan bir düzenleme (regularization) tekniğidir. Eğitim sırasında rastgele nöronları devre dışı bırakarak modelin genelleme kabiliyetini artırır. Modelin sadece eğitim verisine değil, genel verilere de iyi uyum sağlaması amaçlanır. Böylece model, eğitim setindeki rastgele gürültüyü (noise) ezberlemek yerine daha sağlam örüntüler öğrenir.

Kod kısmında;

```
model.add(Dropout(hp.Float('dropout_1',0.3,0.6,step=0.1)))
```

Şekil 5.25 Dropout oranı

ile dropout oranı (devre dışı bırakılan nöron yüzdesi) hiperparametre olarak ayarlanır ve sistemin aşırı öğrenmesi engellenir.

5.2.2.3 Dense (Yoğun) Katmanları

LSTM katmanlarının çıktılarını alıp tahmin edilecek son değeri üretmek için kullanılır. Yoğun katmanlar tam bağlı (fully connected) katmanlardır. Modelin öğrendiği temsillerin son aşamada bir araya getirilip, regresyon problemi (sürekli değer tahmini) için çıktı oluşturmasıdır.

Kod kısmında;

```
model.add(Dense(units=hp.Int('dense_units', 10, 30,
step=10)))
model.add(Dense(1))
```

Şekil 5.26 Dense katmanı

ile kaç nöron kullanılacağı seçiliyor. Son katmanda 1 nöron vardır çünkü tek bir fiyat değeri tahmin edilir.

```
model.compile(optimizer='adam',
loss='mean_squared_error')
return model
```

Şekil 5.27 Optimizasyon kodu

kodu ile adam optimizsayonu yapılıp ağırlıkları güncellerken adaptif öğrenme oranı kullanılır böylece hızlı ve etkili öğrenme sağlanır. `mean_squared_error (MSE)` ile tahmin hatalarının karesini alarak ölçüyoruz.

5.2.3 Hiperparemtere Optimzasyonu ve En İyi modelin Seçilmesi

Burada hiperparametre optimizasyonu gerçekleştirilmiş ve modelin yapısal bileşenleri (nöron sayısı, katman sayısı, öğrenme oranı, düşürme oranı vb.) sistematik biçimde test edilmiştir. Optimizasyon süreci sırasında farklı parametre kombinasyonları denenmiş ve modelin doğrulama kaybını (validation loss) en aza indiren yapı tercih edilmiştir. Bu yaklaşım, modelin hem eğitim hem de doğrulama verileri üzerindeki performansını iyileştirmeyi amaçlamıştır.

Kod kısmında;

```
Hyperparameter tuning
    model = Sequential()
    tuner = kt.RandomSearch(
    build_model,
    objective='val_loss',
    max_trials=10,
    executions_per_trial=1)
```

Şekil 5.28 Hiperparemetre optimizasyonu

LSTM modelinin en iyi hiperparametrelerini belirlemek için `kt.RandomSearch` yöntemi kullanılarak rastgele arama (Random Search) uygulanmıştır. Modelin optimizasyon hedefi val_loss (doğrulama kaybı) olarak belirlenmiş ve toplamda 15 farklı model denenmiştir (max_trials=15). Her model yalnızca 1 kez çalıştırılmış ve elde edilen sonuçlar lstm_tuning dizinine kaydedilmiştir. Model eğitimi `Tuner.search()` fonksiyonu çağrılarak başlatılmış ve 100 epoch boyunca sürdürülmüştür. Batch size 64 olarak belirlenirken, verinin %20'si doğrulama için

ayrılmıştır. Eğitim sürecinde EarlyStopping Callback kullanılarak, eğer doğrulama kaybı 12 epoch boyunca iyileşmezse eğitim erken durdurulmuştur. Bu yöntem, modelin doğrulama kaybını minimize eden en iyi hiperparametre kombinasyonunu bulmayı hedefler. Hiperparametre optimizasyonu, modelin aşırı öğrenmesini (overfitting) önlemek ve genelleme performansını artırmak açısından kritik bir adımdır. Random Search, belirlenen hiperparametre aralıklarından rastgele kombinasyonlar seçerek performansı değerlendirir ve Grid Search yöntemine kıyasla yüksek boyutlu hiperparametre uzayında daha hızlı ve verimli olabilir. Örnek hiperparametreler arasında LSTM katman sayısı, dropout oranı, öğrenme oranı ve aktivasyon fonksiyonları gibi bileşenler yer alır.

5.2.4 Gelecek Tahmini Yapma

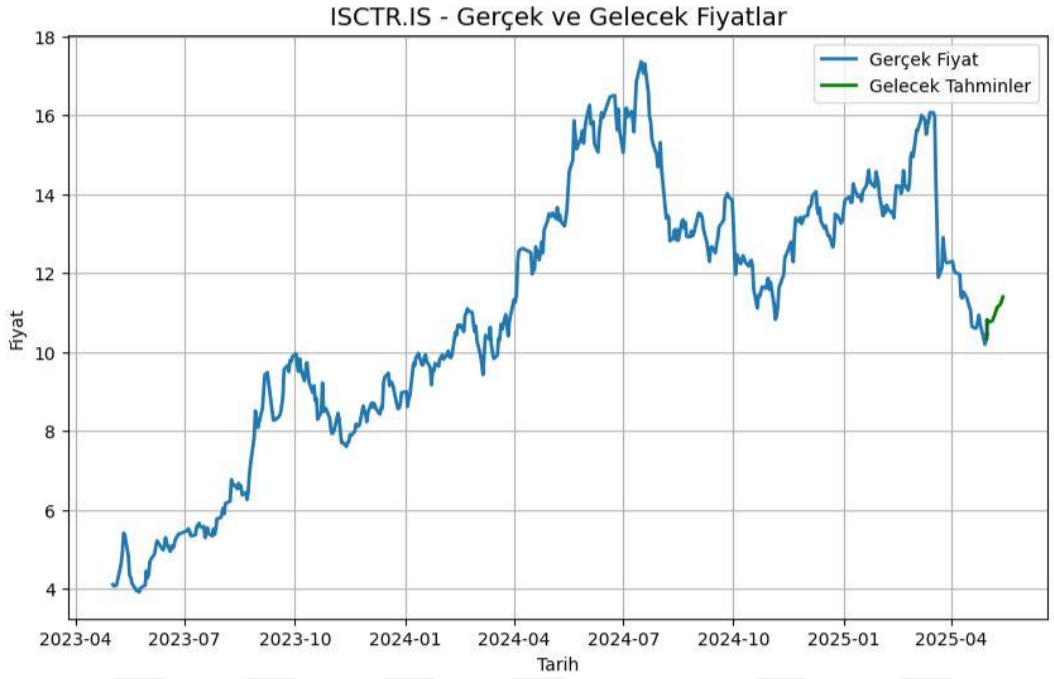
Bu aşamada ise geleceğe yönelik tahminler gerçekleştirilmiştir. Model, son döneme ait veriler üzerinden yeniden yapılandırılmış ve bu veriler kullanılarak belirlenen ileri tarihli gözlem noktalarına ilişkin öngörülerde bulunmuştur. Model, son t günlük veriyi temel alarak bir adım ileriye (t+1) tahmin üretir. Bu tahmin, bir sonraki tahminde giriş olarak kullanılır ve işlem bu şekilde zincirleme olarak devam eder. Bu recursive forecasting yöntemi, ileriye dönük tahminlerin oluşturulmasında yaygın bir tekniktir ancak her adımda oluşan tahmin hatasının birikmesi nedeniyle, özellikle uzun vadeli tahminlerde dikkatle ele alınmalıdır. Bu model, son 240 günlük veriyi kullanarak gelecekteki 10 iş günü için tahminlerde bulunmuştur. Bunun nedeni, modelde farklı gün kombinasyonları alınmış ve model performansları gözlenmiştir. En uygun gün kombinasyonun ve model performansının en yüksek olduğu günlerin bu günler olduğu görülmüştür.

Tahmin edilen değerler, orijinal ölçekteki fiyatlara dönüştürülerek değerlendirilmiş ve elde edilen çıktılar görselleştirilerek raporlanmıştır. Bu süreçte, modelin zaman içerisindeki genel performansı, tahmin doğruluğu ve öngörü yeteneği değerlendirilmiş; sonuçlar, modelin finansal zaman serileri üzerinde uygulanabilirliğini göstermiştir.

5.3 Her Bir Hisse Senedi Özelinde Modelin Eğitilmesi

5.3.1 ISCTR Hisse Senedi

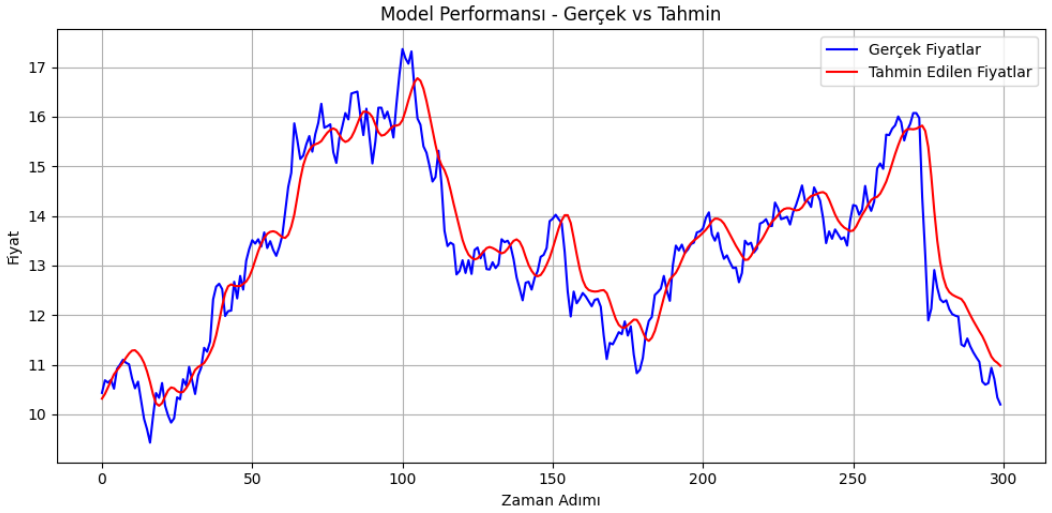
Model BIST 30 hısse senetlerinden olan ISCTR Hisse senedi için çalıştırımıştır. ISCTR hisse senedi yüksek volatiliteye sahip bir hissedir. Ani ve düzensiz fiyat hareketleri içerdiğinden LSTM modeli açısından daha karmaşık örüntüler sunar.



	Date	Predicted Price
0	2025-05-01	10.792120
1	2025-05-02	10.761919
2	2025-05-05	10.790994
3	2025-05-06	10.857006
4	2025-05-07	10.941503
5	2025-05-08	11.033362
6	2025-05-09	11.127026
7	2025-05-12	11.220094
8	2025-05-13	11.311689
9	2025-05-14	11.401562

Şekil 5.29 ISCTR hisse senedine ait geçmiş ve gelecek tahmin fiyatları

Eğitim sürecinin ardından model, tahmin gün sayısına göre gelecekteki kapanış fiyatlarını tahmin eder ve sonuçlar ekrana yazdırılır. Model, 10 gün için gelecekteki kapanış fiyatlarını tahmin etmiştir. Bu tahminler, belirli bir dönem için hisse senedi fiyatlarının öngörülmesine yardımcı olur. Burada model ilk gün (01.05.2025 tarihinde) 10.792120 değerini alacağını 10. günün sonunda bu değerin (14.05.2025 tarihinde) 11.401562'e yükseleceğini öngermektedir.




```
Model Performansı:
R² Skoru: 0.9963
RMSE: 0.2231
```

Şekil 5.30 ISCTR hisse senedine ait model performansı

Burada modelin ISCTR için performansını incelediğimizde tahmin edilen fiyatların gerçek değerlere parelel olarak ilerlediği görülmüştür. Burada gerçek değerlerde yaşanan tüm kırılımlar model tarafından tahmin edilemese de genel trend yönünde doğru tahminlemelerde bulunmuştur. Burada modelin performans ölçütlerini incelediğimizde; R^2 skorunun 0.9963 olduğunu görüyoruz. Bu değer 1'e çok yakın, yani modeliniz veri içindeki varyansın %99.63'ünü açıklayabiliyor. Bu, modelin geçmiş verilere son derece iyi uyduğunu gösterir. Burada modelin 0.9963 oranında fiyatların doğru tahmin edilmesi değil 0.9963'le tahminlenen fiyatların ve gerçek fiyatların yönünün benzer olduğu şeklinde yorumlanır. RMSE (Kök Ortalama Kare Hata): değeri modelin tahminlerinin ne kadar sapma gösterdiğini gösteren önemli bir regresyon başarı metriğidir. Bu değer, modelin tahmin ettiği fiyatlarla gerçek fiyatlar arasındaki farkların karelerinin ortalamasının karekökü̈dür. Hisse fiyatları 1 ile 10 TL arasında değiştiği için, 0.2231 RMSE oldukça düşük bir hata ve iyi bir performans gösterir. Hisse senetleri fiyatlarının ortalaması 6,12 nidir. Bunun RMSE değerine oranıyla % 3,59 oranı elde edilir. Bu da bizim modelin ortalama sapmasıdır. ISCTR 'nin gerçek değerlerinin % 2,50 oranında saptığı türkiye borsasında modelin bu oranla sapması modelin başarılı bir şekilde çalıştığının göstergesidir. Şimdi ISCTR Hisse senedinin 2025 yılı içerisindeki gerçek ve tahmin

edilen değerlerinin bunlar arasındaki sapmanın, gerçek değerlere göre artış azalış (%) ve tahmin değerlerine göre artış azalışlarını(%) tablo üzerinde görüyoruz.

Tablo 5.1 ISCTR hisse senedi ortalama istatistik analizi

Date	Gerçek Değer	Tahmin Değer	Sapma(%)	Gerçek Değerlere Göre Artış Azalış(%)	Tahmin Değerelere Göre Artış Azalış(%)
8.01.2025	13,7960	13,6469	1,09%	-0,99%	0,86%
9.01.2025	13,7960	13,7292	0,49%	0,00%	0,60%
10.01.2025	14,2690	13,7714	3,61%	3,43%	0,31%
13.01.2025	14,1508	13,8411	2,24%	-0,83%	0,51%
14.01.2025	13,9340	13,9172	0,12%	-1,53%	0,55%
15.01.2025	13,9537	13,9553	0,01%	0,14%	0,27%
16.01.2025	13,9833	13,9588	0,18%	0,21%	0,03%
17.01.2025	13,8256	13,9456	0,86%	-1,13%	-0,09%
20.01.2025	14,0720	13,9084	1,18%	1,78%	-0,27%
21.01.2025	14,2198	13,8909	2,37%	1,05%	-0,13%
22.01.2025	14,4070	13,9149	3,54%	1,32%	0,17%
23.01.2025	14,6139	13,9882	4,47%	1,44%	0,53%
24.01.2025	14,2986	14,1079	1,35%	-2,16%	0,86%
27.01.2025	14,2887	14,2004	0,62%	-0,07%	0,66%
28.01.2025	14,1804	14,2479	0,47%	-0,76%	0,33%
29.01.2025	14,5745	14,2454	2,31%	2,78%	-0,02%
30.01.2025	14,4464	14,2601	1,31%	-0,88%	0,10%
31.01.2025	14,3085	14,2814	0,19%	-0,95%	0,15%
3.02.2025	13,9537	14,2845	2,32%	-2,48%	0,02%
4.02.2025	13,4511	14,2277	5,46%	-3,60%	-0,40%
5.02.2025	13,6876	14,0715	2,73%	1,76%	-1,10%
6.02.2025	13,5398	13,8975	2,57%	-1,08%	-1,24%
7.02.2025	13,7271	13,7350	0,06%	1,38%	-1,17%
10.02.2025	13,6285	13,6312	0,02%	-0,72%	-0,76%
11.02.2025	13,5300	13,5743	0,33%	-0,72%	-0,42%
12.02.2025	13,5694	13,5388	0,23%	0,29%	-0,26%
13.02.2025	13,4019	13,5209	0,88%	-1,23%	-0,13%
14.02.2025	13,9044	13,4946	3,04%	3,75%	-0,19%
17.02.2025	14,2198	13,5248	5,14%	2,27%	0,22%
18.02.2025	14,2001	13,6372	4,13%	-0,14%	0,83%
19.02.2025	14,0227	13,7855	1,72%	-1,25%	1,09%
20.02.2025	14,1311	13,9037	1,64%	0,77%	0,86%
21.02.2025	14,6041	13,9876	4,41%	3,35%	0,60%
24.02.2025	14,2493	14,0965	1,08%	-2,43%	0,78%
25.02.2025	14,1015	14,1742	0,51%	-1,04%	0,55%
26.02.2025	14,2887	14,1927	0,68%	1,33%	0,13%
27.02.2025	14,9588	14,1899	5,42%	4,69%	-0,02%
28.02.2025	15,0574	14,2641	5,56%	0,66%	0,52%
3.03.2025	14,9490	14,4059	3,77%	-0,72%	0,99%
4.03.2025	15,6388	14,5537	7,46%	4,61%	1,03%
5.03.2025	15,6289	14,7544	5,93%	-0,06%	1,38%
6.03.2025	15,7570	14,9684	5,27%	0,82%	1,45%
7.03.2025	15,8260	15,1685	4,33%	0,44%	1,34%
10.03.2025	16,0034	15,3364	4,35%	1,12%	1,11%
11.03.2025	15,8852	15,4793	2,62%	-0,74%	0,93%
12.03.2025	15,5205	15,5765	0,36%	-2,30%	0,63%
13.03.2025	15,7275	15,5873	0,90%	1,33%	0,07%
14.03.2025	15,8556	15,5595	1,90%	0,81%	-0,18%

Tablo 5.1 ISCTR hisse senedi ortalama istatistik analizi devamı

Date	Gerçek Değer	Tahmin Değer	Sapma(%)	Gerçek Değerlere Göre Artış Azalış(%)	Tahmin Değerelere Göre Artış Azalış(%)
17.03.2025	16,0724	15,5369	3,45%	1,37%	-0,15%
18.03.2025	16,0724	15,5543	3,33%	0,00%	0,11%
19.03.2025	15,9738	15,6009	2,39%	-0,61%	0,30%
20.03.2025	14,3774	15,6454	8,10%	-9,99%	0,29%
21.03.2025	13,2146	15,4927	14,70%	-8,09%	-0,98%
24.03.2025	11,8941	15,0560	21,00%	-9,99%	-2,82%
25.03.2025	12,1306	14,3149	15,26%	1,99%	-4,92%
26.03.2025	12,9091	13,5087	4,44%	6,42%	-5,63%
27.03.2025	12,5544	12,9285	2,89%	-2,75%	-4,29%
28.03.2025	12,3179	12,5801	2,08%	-1,88%	-2,69%
2.04.2025	12,2600	12,3898	1,05%	-0,47%	-1,51%
3.04.2025	12,3000	12,2995	0,00%	0,33%	-0,73%
4.04.2025	12,1199	12,2769	1,28%	-1,46%	-0,18%
7.04.2025	12,0200	12,2685	2,03%	-0,83%	-0,07%
8.04.2025	11,9899	12,2459	2,09%	-0,25%	-0,18%
9.04.2025	11,9700	12,2079	1,95%	-0,17%	-0,31%
10.04.2025	11,4099	12,1623	6,19%	-4,68%	-0,37%
11.04.2025	11,3699	12,0447	5,60%	-0,35%	-0,97%
14.04.2025	11,5299	11,8805	2,95%	1,41%	-1,36%
15.04.2025	11,3699	11,7376	3,13%	-1,39%	-1,20%
16.04.2025	11,2500	11,6192	3,18%	-1,06%	-1,01%
17.04.2025	11,1499	11,5159	3,18%	-0,89%	-0,89%
18.04.2025	11,0600	11,4206	3,16%	-0,81%	-0,83%
21.04.2025	10,6599	11,3296	5,91%	-3,62%	-0,80%
22.04.2025	10,6000	11,1988	5,35%	-0,56%	-1,15%
24.04.2025	10,6300	11,0453	3,76%	0,28%	-1,37%
25.04.2025	10,9399	10,9077	0,30%	2,92%	-1,25%
28.04.2025	10,7100	10,8499	1,29%	-2,10%	-0,53%
29.04.2025	10,3400	10,8289	4,52%	-3,45%	-0,19%
30.04.2025	10,1999	10,7729	5,32%	-1,35%	-0,52%

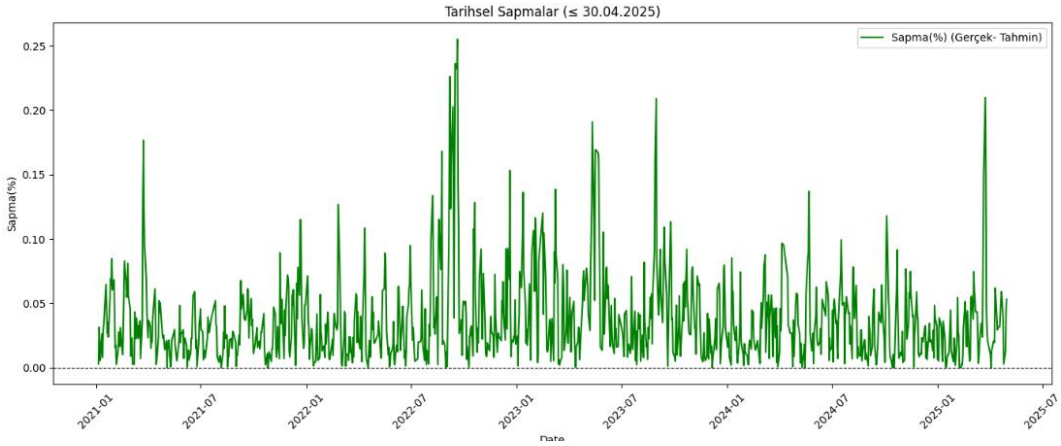
5.3.1.1 Genel Doğruluk ve Sapma (Tahmin Hataları)

Sapma(%) sütunu, modelin tahmin değerinin gerçek fiyattan yüzde kaç saptığını göstermektedir. Sapmaların büyük kısmı %0–3 aralığında ve bu, LSTM modelinin kısa vadede oldukça isabetli tahminlerde bulunduğunu göstermektedir. Ancak bazı tarihlerde (%5'in üstü gibi), özellikle ani fiyat değişimlerinde hata artıyor:

Örnek: 24.03.2025 → Gerçek: 11,89 / Tahmin: 15,06 → %21 hata!

Bu durumlar, modelin beklenmedik piyasa kırılmalarına yanıt veremediğini gösteriyor (örneğin sert düşüşler). Bu durumlar genel olarak siyasi açıklamalar, siyasi veya toplumsal yaşanan spekülatif bir olay vb. Ortalama sapma %1–2 bandında olan günlerde, RMSE'nin 0.22 çıkmasıyla da örtüşüyor. RMSE küçük

ama bazı bireysel hatalar piyasa dengesizliği sebebiyle büyük çıkabiliyor. Bu durum aşağıdaki grafikle gösterilmiştir.



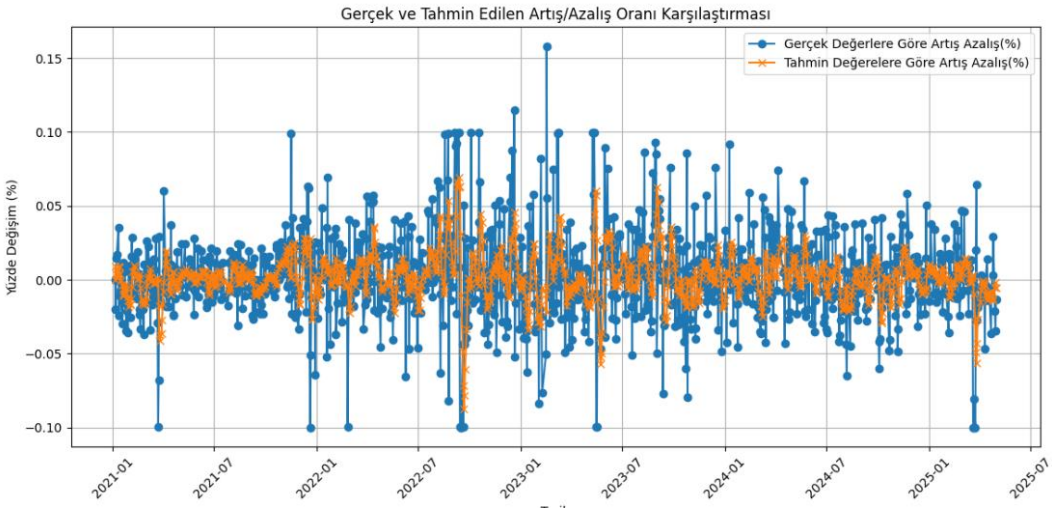
Şekil 5.31 ISCTR sapma (tahmin hataları)

Bu grafiktede görüldüğü üzere son 3 yıllık dönemde genel eğilimde sapmanın %0–5 arasında olduğu, bazı gün ve haftalarda yaşanan olaylar sebebiyle sapmanın çok fazla yükseldiği ve %20 bantlarına ulaştığı görülmüştür.

5.3.1.2 Trend Yakalayabilme (Yön Doğruluğu Analizi)

Sapma(%) sütunu, modelin tahmin değerinin gerçek fiyattan yüzde kaç saptığını göstermektedir. Sapmaların büyük kısmı %0–3 aralığında ve bu, LSTM modelinin kısa vadede oldukça isabetli tahminlerde bulunduğunu göstermektedir. Modelin yalnızca sayısal değeri değil, yükseliş/azalış yönünü ne kadar iyi tahmin ettiği de oldukça önemli bir göstergedir. "Gerçek değerlere göre artış/azalış" ile "Tahmin değerlerine göre artış/azalış" kıyaslandığında:

Modelin yön tahminlerinin son 3 yıl bazlı değerleri incelendiğinde genel olarak oldukça tutarlı olduğu görülmüştür. Çoğu zaman aynı yönde artış veya azalış öngörmüştür. Ancak özellikle yüksek volatilite günlerinde (örneğin 20.03–25.03 tarihleri arası), fiyat düşerken tahminlerin hâlâ artış göstermesi gibi durumlar mevcuttur. Bu durum, modelin "alışkanlığa göre devam etme" (momentum bias) etkisi taşıdığını gösterir. Yani düşüş başlasa da, model artışı bekliyor ve bu yönde hareket ediyordur. Bu durum aşağıdaki grafikle gösterilmiştir.



Şekil 5.32 ISCTR gerçek ve tahmin edilen artış azalış karşılaştırması

Bu grafiğe dayanarak, modelin performansı hakkında şu çıkarımlar yapılabilir: Modelin, fiyatların genel yönünü (artış mı, azalış mı olacağını) tahmin etmede başarılı olduğu görünmektedir. Model, tüm günler incelediğinde yaklaşık %70 – %75 oranında doğru yön tahmini yapmış. Modelin, fiyatlardaki ani ve sert dalgalanmalara karşı hassasiyeti biraz düşük olduğu görülüyor. Başka bir ifadeyle, model bu tür dalgalanmaları yumuşatma eğilimindedir. Modelin tahminlerinin, piyasa hareketlerine bazen gecikmeli tepki verdiği bu durumun modelin piyasa dinamiklerini öğrenme sürecinden kaynaklandığı görülüyor.

Model, fiyat değişimlerinin büyüklüğünü tahmin etmede bazı sınırlamalar yaşıyor. Özellikle büyük değişimlerin olduğu dönemlerde, modelin tahminleri gerçek değişimlerin büyüklüğünü tam olarak yansıtamıyor. Bu değişimler genel olarak büyük siyasi ve toplumsal olayların olduğu günlere denk geliyor.

5.3.1.3 Ortalama Performans Metrikleri (Genel Değerlendirme)

Bu verilere göre bazı özet istatistikler çıkarılabilir (tahmini olarak)

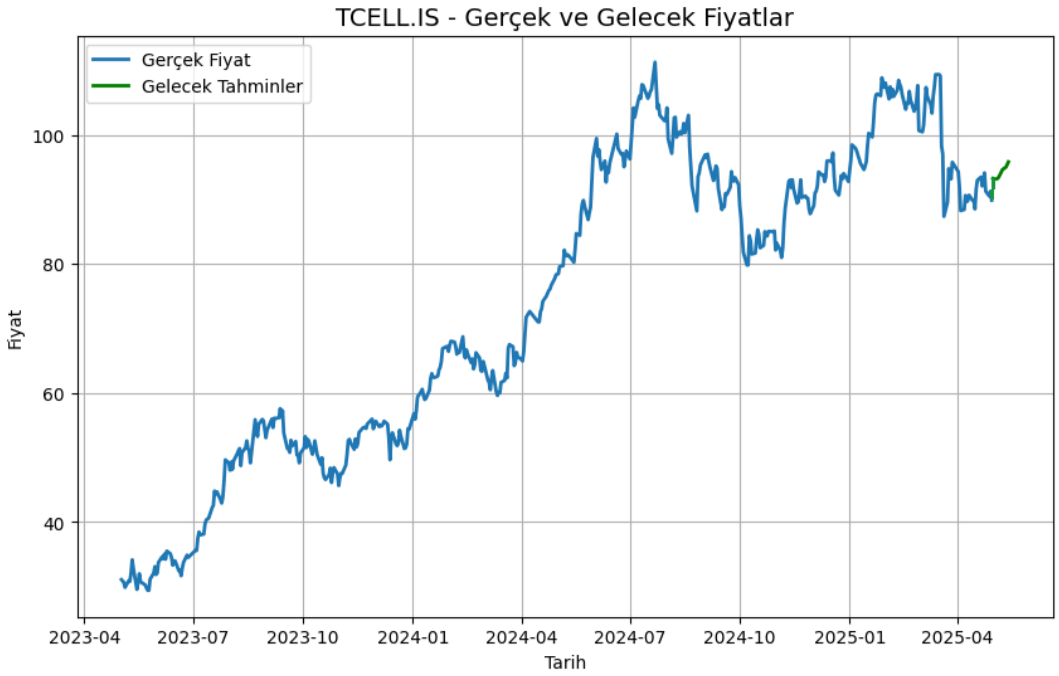
- Ortalama Sapma ≈ %2,2 – 2,4
- Maksimum Sapma ≈ %21,00
- Günlük tahminlerin yönsel doğruluk oranı ≈ %72

(Trend yönü doğru tahmin edilen günlerin oranı)

5.3.2 TCELL Hisse Senedi

Model BIST 30 hisse senetlerinden olan TCELL Hisse senedi için çalıştırılmıştır. TCELL hisse senedi düşük volatiliteye sahip bir hissedir.

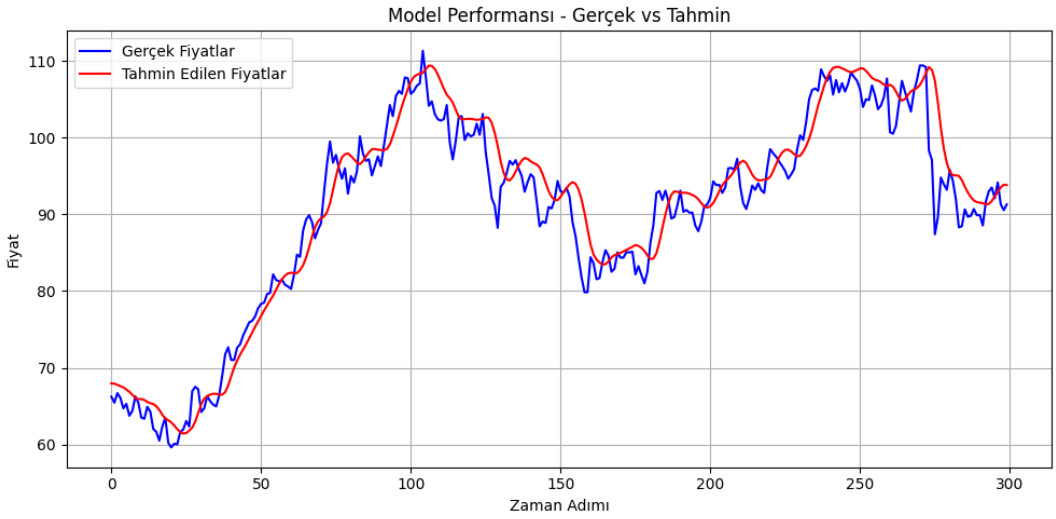
Model geçmiş verileri kullanarak (2025-04-30'ne kadar) ileriye yönelik 10 günlük hisse senedi tahmini yapmıştır.



	Date	Predicted Price
0	2025-05-01	93.276169
1	2025-05-02	93.149460
2	2025-05-05	93.263245
3	2025-05-06	93.531006
4	2025-05-07	93.877831
5	2025-05-08	94.258957
6	2025-05-09	94.652710
7	2025-05-12	95.050491
8	2025-05-13	95.449562
9	2025-05-14	95.849609

Şekil 5.33 TCELL hisse senedine ait geçmiş ve gelecek tahmin fiyatları

Eğitim sürecinin ardından model, TCELL için tahmin gün sayısına göre gelecekteki kapanış fiyatlarını tahmin eder ve sonuçlar ekrana yazdırılır. Model, 10 gün için gelecekteki kapanış fiyatlarını tahmin etmiştir. Model TCELL için ilk gün (01.05.2025 tarihinde) 93.276169 değerini alacağını 10. günün sonunda bu değerin (14.05.2025 tarihinde) 95.849609'e yükseleceğini öngermektedir.




```
Model Performansı:
R² Skoru: 0.9974
RMSE: 1.2110
```

Şekil 5.34 TCELL hisse senedine ait model performansı

Burada modelin ISCTR için performansını incelediğimizde tahmin edilen fiyatların gerçek değerlere parelel olarak ilerlediği görülmüştür. Burada gerçek değerlerde yaşanan tüm kırılımlar model tarafından tahmin edilemese de genel trend yönünde doğru tahminlemelerde bulunmuştur. Burada modelin performans ölçütleri incelendiğinde; Burada R^2 skorunun 0.9974 olduğunu görülüyor.

RMSE (Kök Ortalama Kare Hata): değeri modelin tahminlerinin ne kadar sapma gösterdiğini gösteren önemli bir regresyon başarı metriğidir. Bu değer, modelin tahmin ettiği fiyatlarla gerçek fiyatlar arasındaki farkların karelerinin ortalamasının kareköküdür. Hisse fiyatları 10 ile 90 TL arasında değiştiği için, 1.2110 RMSE oldukça düşük bir hata ve iyi bir performans gösterir. Hisse senetleri fiyatlarının ortalaması 44,80 dir. Bunun RMSE değerine oranıyla % 2,89 oranını elde edilir. Bu da bizim modelin ortalama sapmasıdır.

Şimdi TCELL Hisse senedinin 2025 yılı içerisindeki gerçek ve tahmin edilen değerlerinin bunlar arasındaki sapmanın, gerçek değerlere göre artış azalış (%) ve tahmin değerlerine göre artış azalışlarını(%) tablo üzerinde görüyoruz.

Tablo 5.2 TCELL hisse senedi ortalama istatistik analizi

Date	Gerçek Değer	Tahmin Değer	Sapma(%)	Gerçek Değerlere Göre Artış Azalış(%)	Tahmin Değerelere Göre Artış Azalış(%)
2025-01-02	92,8000	94,5280	1,83%	-0,38%	0,09%
2025-01-03	96,0500	94,5788	1,56%	3,50%	0,05%
2025-01-06	98,5000	94,8902	3,80%	2,55%	0,33%
2025-01-07	97,9499	95,6323	2,42%	-0,56%	0,78%
2025-01-08	97,5000	96,5631	0,97%	-0,46%	0,97%
2025-01-09	96,8499	97,4321	0,60%	-0,67%	0,90%
2025-01-10	96,3000	98,0651	1,80%	-0,57%	0,65%
2025-01-13	95,6500	98,3996	2,79%	-0,67%	0,34%
2025-01-14	94,6500	98,4386	3,85%	-1,05%	0,04%
2025-01-15	95,1999	98,1927	3,05%	0,58%	-0,25%
2025-01-16	95,9000	97,8432	1,99%	0,74%	-0,36%
2025-01-17	98,4499	97,5660	0,91%	2,66%	-0,28%
2025-01-20	100,300	97,6398	2,72%	1,88%	0,08%
2025-01-21	99,6999	98,1642	1,56%	-0,60%	0,54%
2025-01-22	102	98,8902	3,14%	2,31%	0,74%
2025-01-23	105	99,8398	5,17%	2,94%	0,96%
2025-01-24	106,1999	101,1287	5,01%	1,14%	1,29%
2025-01-27	106,4000	102,6496	3,65%	0,19%	1,50%
2025-01-28	106,0999	104,1714	1,85%	-0,28%	1,48%
2025-01-29	108,9000	105,4744	3,25%	2,64%	1,25%
2025-01-30	108	106,7321	1,19%	-0,83%	1,19%
2025-01-31	107,4000	107,7966	0,37%	-0,56%	1,00%
2025-02-03	108,0999	108,5531	0,42%	0,65%	0,70%
2025-02-04	105,5999	109,0848	3,19%	-2,31%	0,49%
2025-02-05	107,5	109,2092	1,57%	1,80%	0,11%
2025-02-06	105,9000	109,2027	3,02%	-1,49%	-0,01%
2025-02-07	107,0999	109,0233	1,76%	1,13%	-0,16%
2025-02-10	106	108,8551	2,62%	-1,03%	-0,15%
2025-02-11	107	108,6464	1,52%	0,94%	-0,19%
2025-02-12	108,5000	108,5147	0,01%	1,40%	-0,12%
2025-02-13	107,9000	108,6091	0,65%	-0,55%	0,09%
2025-02-14	107,4000	108,8147	1,30%	-0,46%	0,19%
2025-02-17	106,3000	109,0013	2,48%	-1,02%	0,17%
2025-02-18	104	109,0280	4,61%	-2,16%	0,02%
2025-02-19	105	108,7058	3,41%	0,96%	-0,30%
2025-02-20	104,9000	108,2450	3,09%	-0,10%	-0,42%
2025-02-21	106,8000	107,7742	0,90%	1,81%	-0,43%
2025-02-24	105,5	107,5468	1,90%	-1,22%	-0,21%
2025-02-25	103,6999	107,4280	3,47%	-1,71%	-0,11%
2025-02-26	104,1999	107,1926	2,79%	0,48%	-0,22%
2025-02-27	105,3000	106,9028	1,50%	1,06%	-0,27%
2025-02-28	107,6999	106,7211	0,92%	2,28%	-0,17%
2025-03-03	100,6999	106,8843	5,79%	-6,50%	0,15%
2025-03-04	100,5000	106,6475	5,76%	-0,20%	-0,22%
2025-03-05	101,5000	106,0007	4,25%	1,00%	-0,61%
2025-03-06	104,4000	105,2427	0,80%	2,86%	-0,72%
2025-03-07	107,4000	104,8209	2,46%	2,87%	-0,40%
2025-03-10	106	105,0296	0,92%	-1,30%	0,20%
2025-03-11	104,6999	105,5511	0,81%	-1,23%	0,50%
2025-03-12	103,4000	106,0330	2,48%	-1,24%	0,46%

Tablo 5.2 TCELL hisse senedi ortalama istatistik analizi devamı

Date	Gerçek Değer	Tahmin Değer	Sapma(%)	Gerçek Değerlere Göre Artış Azalış(%)	Tahmin Değerelere Göre Artış Azalış(%)
2025-03-13	106	106,2467	0,23%	2,51%	0,20%
2025-03-14	107,5000	106,4639	0,97%	1,42%	0,20%
2025-03-17	109,4000	106,8612	2,38%	1,77%	0,37%
2025-03-18	109,4000	107,5517	1,72%	0,00%	0,65%
2025-03-19	109,1999	108,3881	0,75%	-0,18%	0,78%
2025-03-20	98,30000	109,1893	9,97%	-9,98%	0,74%
2025-03-21	97,09999	108,8380	10,78%	-1,22%	-0,32%
2025-03-24	87,40000	107,4344	18,65%	-9,99%	-1,29%
2025-03-25	89,59999	104,5973	14,34%	2,52%	-2,64%
2025-03-26	94,80000	101,2329	6,35%	5,80%	-3,22%
2025-03-27	93,90000	98,5313	4,70%	-0,95%	-2,67%
2025-03-28	93,19999	96,6774	3,60%	-0,75%	-1,88%
2025-04-02	95,80000	95,5102	0,30%	2,79%	-1,21%
2025-04-03	94,3499	95,0988	0,79%	-1,51%	-0,43%
2025-04-03	94,3499	95,0988	0,79%	-1,51%	-0,43%
2025-04-04	92	95,0815	3,24%	-2,49%	-0,02%
2025-04-07	88,3000	95,0152	7,07%	-4,02%	-0,07%
2025-04-08	88,4499	94,4768	6,38%	0,17%	-0,57%
2025-04-09	90,6500	93,6109	3,16%	2,49%	-0,92%
2025-04-10	89,6999	92,8572	3,40%	-1,05%	-0,81%
2025-04-11	89,8000	92,2500	2,66%	0,11%	-0,65%
2025-04-14	90,6999	91,8099	1,21%	1,00%	-0,48%
2025-04-15	89,9000	91,6062	1,86%	-0,88%	-0,22%
2025-04-16	89,9000	91,5096	1,76%	0,00%	-0,11%
2025-04-17	88,5500	91,4618	3,18%	-1,50%	-0,05%
2025-04-18	91,6500	91,3075	0,38%	3,50%	-0,17%
2025-04-21	93	91,3613	1,79%	1,47%	0,06%
2025-04-22	93,5000	91,7377	1,92%	0,54%	0,41%
2025-04-24	92,0999	92,3558	0,28%	-1,50%	0,67%
2025-04-25	94,1500	92,9186	1,33%	2,23%	0,61%
2025-04-28	91,3000	93,5241	2,38%	-3,03%	0,65%
2025-04-29	90,5500	93,8496	3,52%	-0,82%	0,35%
2025-04-30	91,3000	93,8268	2,69%	0,83%	-0,02%

5.3.2.1 Genel Doğruluk ve Sapma (Tahmin Hataları)

Sapmaların büyük kısmı %0–3 aralığında seyretmiş. Bu, modelin kısa vadede oldukça yüksek doğrulukta tahminler yaptığını gösteriyor. Ancak bazı günlerde sapma %5'in üzerine çıkmakta, bu da modelin özellikle ani piyasa dalgalanmalarına karşı duyarlılığının düşük olduğunu ortaya koyuyor. Örnek Aykırı Gün:

24.03.2025

- Gerçek: 91,30
- Tahmin: 93,82

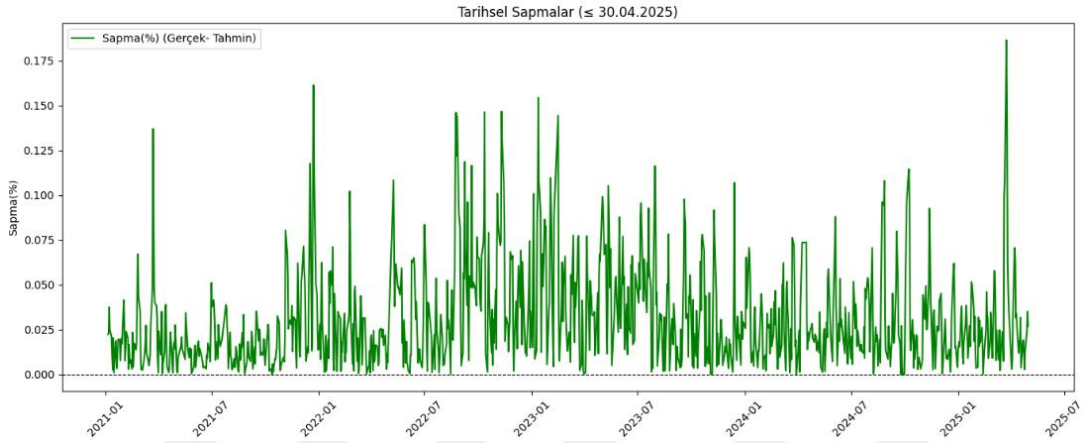
- Sapma: %2,69

Ama daha çarpıcı örnek:

- 28.02.2025: Gerçek 87,40 → Tahmin 107,43 → Sapma: %18,65

Genel Değerlendirme:

Ortalama sapma yaklaşık %1–2 bandında, bu da hesaplanan RMSE'nin 0.22 çıkmasıyla tutarlı görünüyor. Yani genel hata küçük, ancak bireysel hatalar zaman zaman oldukça yüksek değerler alabiliyor.



Şekil 5.35 TCELL sapma (tahmin hataları)

5.3.2.2 Trend Yakalayabilme (Yön Doğruluğu Analizi)

Gerçek ve tahmin değerlerinin günlük değişimleri karşılaştırıldığında: Model çoğu zaman doğru yönü öngörmekel beraber bazı dönemlerde, özellikle volatilitenin yüksek olduğu zamanlarda, yön tahmininde sapmalar yaşanıyor.

Momentum Yanlılığı Gözlemi:

Örneğin: 20–25 Mart 2025 arası, gerçek fiyat düşerken model tahminleri hâlâ artış öngörüyor. Bu da modelin momentum yanlılığı taşıdığını düşündürüyor: Yani son yükselişin devam edeceğini varsayarak, düşüşe geç tepki veriyor.

Kırılma Anı Analizi (Büyük Hata Yaratan Dönemler)

Mart 2025 başından itibaren modelin hataları belirgin şekilde artmış. Bu dönemde fiyatlar ciddi düşüş gösterirken, model çoğunlukla "yatay ya da artış" yönünde tahminlerde bulunmuş.

21.03.2025: Gerçek: 94,15 → Tahmin: 92,92 → Sapma: %1,33

24.03.2025: Gerçek: 91,30 → Tahmin: 93,82 → Sapma: %2,69

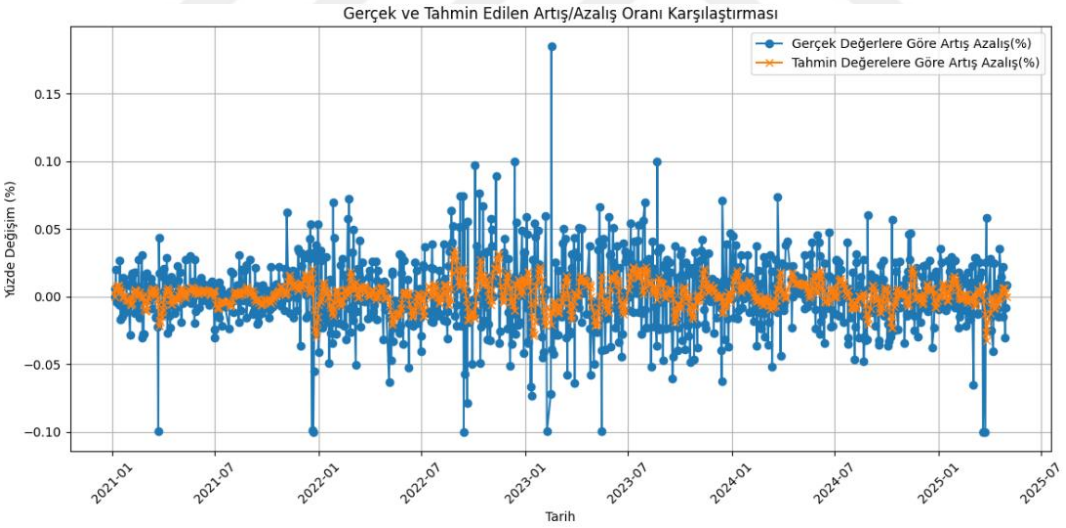
28.02.2025: Gerçek: 87,40 → Tahmin: 107,43 → Sapma: %18,65

5.3.2.3 Ortalama Performans Metrikleri (Genel Değerlendirme)

Bu verilere göre bazı özet istatistikler çıkarabiliriz (tahmini olarak)

- Ortalama Sapma ≈ %1,82
- Maksimum Sapma ≈ %4,56
- Günlük tahminlerin yönsel doğruluk oranı ≈ %81,48

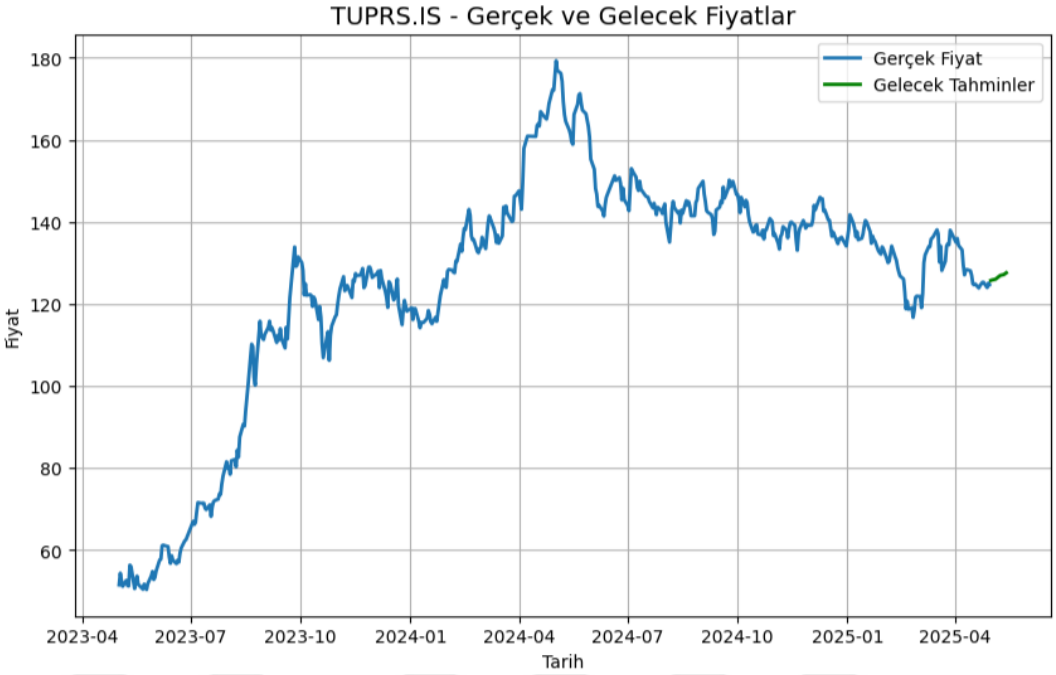
Bu sonuçlar, modelinizin tahminlerinin genellikle doğru yönde olduğunu ve ortalama sapmanın %2'nin altında kaldığını gösteriyor. Bu modelin olduça verimli çalıştığının bir göstergesidir.



Şekil 5.36 TCELL gerçek ve tahmin edilen artış azalış karşılaştırması

5.3.3 TUPRS Hisse Senedi

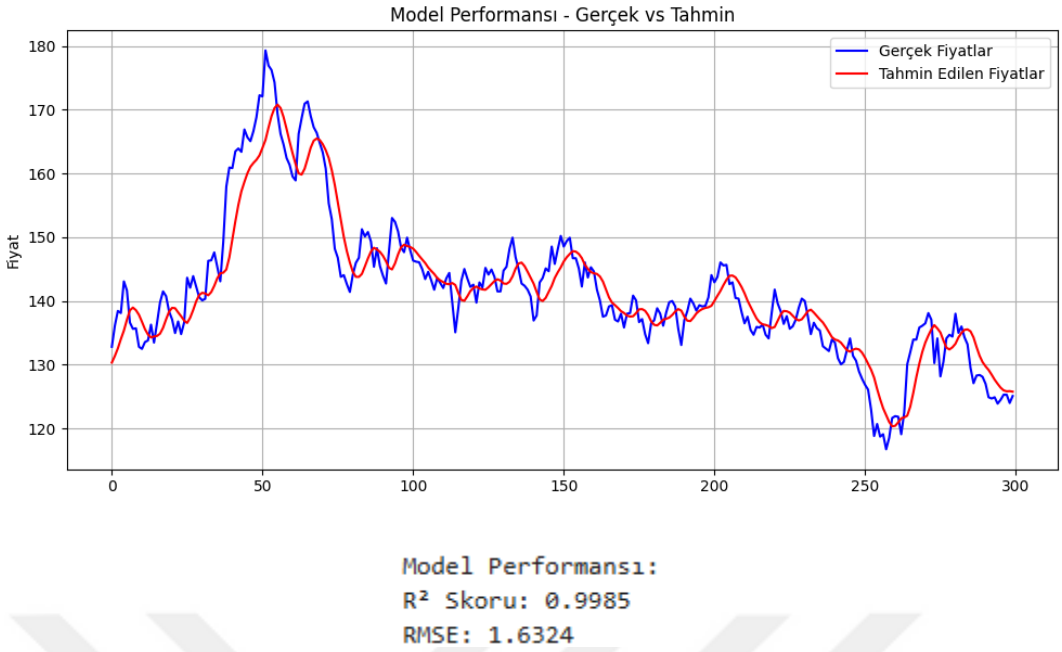
Model BIST 30 hısse senetlerinden olan TUPRS Hisse senedi için çalıştırılmıştır. Modelde geçmiş verileri kullanarak (2025-04-30'ne kadar) ileriye yönelik 10 günlük hisse senedi tahmini yaptırıldı.



	Date	Predicted Price
0	2025-05-01	125.736511
1	2025-05-02	125.852737
2	2025-05-05	126.051872
3	2025-05-06	126.282547
4	2025-05-07	126.518188
5	2025-05-08	126.749107
6	2025-05-09	126.973145
7	2025-05-12	127.190613
8	2025-05-13	127.402443
9	2025-05-14	127.609436

Şekil 5.37 TUPRS hisse senedine ait geçmiş ve gelecek tahmin fiyatları

Model TUPRS için ilk gün (01.05.2025 tarihinde) 125.736511 değerini alacağını 10. günün sonunda bu değerin (14.05.2025 tarihinde) 127.609436'a yükseleceğini öngermektedir.



Şekil 5.38 TUPRS hisse senedine ait model performansı

Burada modelin TUPRS için performansını incelediğimizde tahmin edilen fiyatların gerçek değerlere parelel olarak ilerlediği görülmüştür. Burada gerçek değerlerde yaşanan tüm kırılımlar model tarafından tahmin edilemese de genel trend yönünde doğru tahminlemelerde bulunmuştur. Burada modelin performans ölçütlerini incelediğimizde; Bu değer 1'e çok yakın, yani modeliniz veri içindeki varyansın %99.85'ini açıklayabiliyor. Bu, modelin geçmiş verilere son derece iyi uyduğunu gösterir. RMSE, tahmin edilen değerlerin ortalama hata miktarını ifade eder. Ortalama hisse fiyatınız 72 TL civarındadır. RMSE değeri 1.6324 TL, yani modelinizin tahminleri ortalama ±1.63 TL sapma ile gerçekleşmiş. Bu da yaklaşık olarak %2.27 oranında bir hata anlamına gelir (1.63 / 72 ≈ 0.0227). Bu oran, finansal zaman serileri için gayet düşük ve kabul edilebilir bir hata seviyesidir.

Şimdi TUPRS Hisse senedinin 2025 yılı içerisindeki gerçek ve tahmin edilen değerlerinin bunlar arasındaki sapmanın, gerçek değerlere göre artış azalış (%) ve tahmin değerlerine göre artış azalışlarını(%) tablo üzerinde görüyoruz.

Tablo 5.3 TUPRS hisse senedi ortalama istatistik analizi

Date	Gerçek Değer	Tahmin Değer	Sapma(%)	Gerçek Değerlere Göre Artış Azalış(%)	Tahmin Değerelere Göre Artış Azalış(%)
2025-01-03	138,1015	135,7448	1,74%	2,96%	-0,24%
2025-01-06	141,7880	135,9202	4,32%	2,67%	0,13%
2025-01-07	139,6139	136,8933	1,99%	-1,53%	0,72%
2025-01-08	138,3851	137,8724	0,37%	-0,88%	0,72%
2025-01-09	136,4000	138,4384	1,47%	-1,43%	0,41%
2025-01-10	137,6289	138,3874	0,55%	0,90%	-0,04%
2025-01-13	135,6438	138,1672	1,83%	-1,44%	-0,16%
2025-01-14	136,0219	137,6894	1,21%	0,28%	-0,35%
2025-01-15	137,0617	137,1940	0,10%	0,76%	-0,36%
2025-01-16	138,9522	136,9357	1,47%	1,38%	-0,19%
2025-01-17	140,3701	137,1241	2,37%	1,02%	0,14%
2025-01-20	139,9920	137,7276	1,64%	-0,27%	0,44%
2025-01-21	137,6289	138,3961	0,55%	-1,69%	0,49%
2025-01-22	134,7931	138,6364	2,77%	-2,06%	0,17%
2025-01-23	136,5891	138,1794	1,15%	1,33%	-0,33%
2025-01-24	135,7384	137,6401	1,38%	-0,62%	-0,39%
2025-01-27	135,3603	137,1080	1,27%	-0,28%	-0,39%
2025-01-28	132,9026	136,6231	2,72%	-1,82%	-0,35%
2025-01-29	132,5245	135,9109	2,49%	-0,28%	-0,52%
2025-01-30	132,1464	135,1022	2,19%	-0,29%	-0,60%
2025-01-31	133,9424	134,3299	0,29%	1,36%	-0,57%
2025-02-03	133,4698	133,9503	0,36%	-0,35%	-0,28%
2025-02-04	131,0121	133,8085	2,09%	-1,84%	-0,11%
2025-02-05	130,0668	133,4554	2,54%	-0,72%	-0,26%
2025-02-06	130,4449	132,8569	1,82%	0,29%	-0,45%
2025-02-07	132,3354	132,2660	0,05%	1,45%	-0,44%
2025-02-10	134,1314	132,0541	1,57%	1,36%	-0,16%
2025-02-11	131,3902	132,3559	0,73%	-2,04%	0,23%
2025-02-12	130,6340	132,5190	1,42%	-0,58%	0,12%
2025-02-13	128,9325	132,3962	2,62%	-1,30%	-0,09%
2025-02-14	127,7982	131,8933	3,10%	-0,88%	-0,38%
2025-02-17	126,8530	131,1046	3,24%	-0,74%	-0,60%
2025-02-18	126,0968	130,1714	3,13%	-0,60%	-0,71%
2025-02-19	122,9774	129,2196	4,83%	-2,47%	-0,73%
2025-02-20	118,8183	127,9908	7,17%	-3,38%	-0,95%
2025-02-21	120,7088	126,1981	4,35%	1,59%	-1,40%
2025-02-24	118,7238	124,6035	4,72%	-1,64%	-1,26%
2025-02-25	119,1019	123,1731	3,31%	0,32%	-1,15%
2025-02-26	116,7388	122,0853	4,38%	-1,98%	-0,88%
2025-02-27	118,5347	121,0261	2,06%	1,54%	-0,87%
2025-02-28	121,6541	120,3408	1,09%	2,63%	-0,57%
2025-03-03	121,9377	120,4188	1,26%	0,23%	0,06%
2025-03-04	121,8431	120,9576	0,73%	-0,08%	0,45%
2025-03-05	119,1019	121,5898	2,05%	-2,25%	0,52%
2025-03-06	122,5048	121,7410	0,63%	2,86%	0,12%
2025-03-07	130,0668	122,0132	6,60%	6,17%	0,22%
2025-03-10	131,9573	123,4215	6,92%	1,45%	1,15%
2025-03-11	133,9424	125,5830	6,66%	1,50%	1,75%
2025-03-12	133,9424	128,0178	4,63%	0,00%	1,94%
2025-03-13	135,8329	130,1589	4,36%	1,41%	1,67%
2025-03-14	136,1165	132,0104	3,11%	0,21%	1,42%
2025-03-17	136,4946	133,4790	2,26%	0,28%	1,11%

Tablo 5.3 TUPRS hisse senedi ortalama istatistik analizi devamı

Date	Gerçek Değer	Tahmin Değer	Sapma(%)	Gerçek Değerlere Göre Artış Azalış(%)	Tahmin Değerelere Göre Artış Azalış(%)
2025-03-18	138,1015	134,5782	2,62%	1,18%	0,82%
2025-03-19	137,0617	135,5499	1,12%	-0,75%	0,72%
2025-03-20	130,2559	136,2126	4,37%	-4,97%	0,49%
2025-03-21	134,1314	135,6927	1,15%	2,98%	-0,38%
2025-03-24	128,1763	135,0619	5,10%	-4,44%	-0,46%
2025-03-25	130,4449	133,8147	2,52%	1,77%	-0,92%
2025-03-26	134,1314	132,6883	1,09%	2,83%	-0,84%
2025-03-27	134,6986	132,3913	1,74%	0,42%	-0,22%
2025-03-28	134,4150	132,7340	1,27%	-0,21%	0,26%
2025-04-02	138	133,2875	3,54%	2,67%	0,42%
2025-04-03	135	134,2873	0,53%	-2,17%	0,75%
2025-04-04	136	134,9893	0,75%	0,74%	0,52%
2025-04-07	134,3000	135,4705	0,86%	-1,25%	0,36%
2025-04-08	133,1999	135,5483	1,73%	-0,82%	0,06%
2025-04-09	129,5	135,2392	4,24%	-2,78%	-0,23%
2025-04-10	127,0999	134,2850	5,35%	-1,85%	-0,71%
2025-04-11	128,3000	132,7880	3,38%	0,94%	-1,11%
2025-04-14	128,3999	131,4148	2,29%	0,08%	-1,03%
2025-04-15	128,1000	130,4135	1,77%	-0,23%	-0,76%
2025-04-16	127	129,7443	2,12%	-0,86%	-0,51%
2025-04-17	124,9000	129,1871	3,32%	-1,65%	-0,43%
2025-04-18	124,6999	128,4512	2,92%	-0,16%	-0,57%
2025-04-21	124,9000	127,6639	2,16%	0,16%	-0,61%
2025-04-22	123,9000	127,0078	2,45%	-0,80%	-0,51%
2025-04-24	124,5000	126,4006	1,50%	0,48%	-0,48%
2025-04-25	125,3000	125,9765	0,54%	0,64%	-0,34%
2025-04-28	125,3000	125,8319	0,42%	0,00%	-0,11%
2025-04-29	124	125,8599	1,48%	-1,04%	0,02%
2025-04-30	125,0999	125,7755	0,54%	0,89%	-0,07%

5.3.3.1 Genel Doğruluk ve Sapma (Tahmin Hataları)

Tahmin hatalarının büyük bir bölümü %0 – %3 aralığında kalmaktadır. Bu, modelin genel olarak istikrarlı ve doğru çalıştığını göstermektedir. Ancak belirli tarihlerde %5'in üzerinde sapmalar görülüyor. Bu durumlar genellikle ani fiyat sıçramaları veya düşüşleri gibi dalgalı piyasa hareketlerinde ortaya çıkıyor.

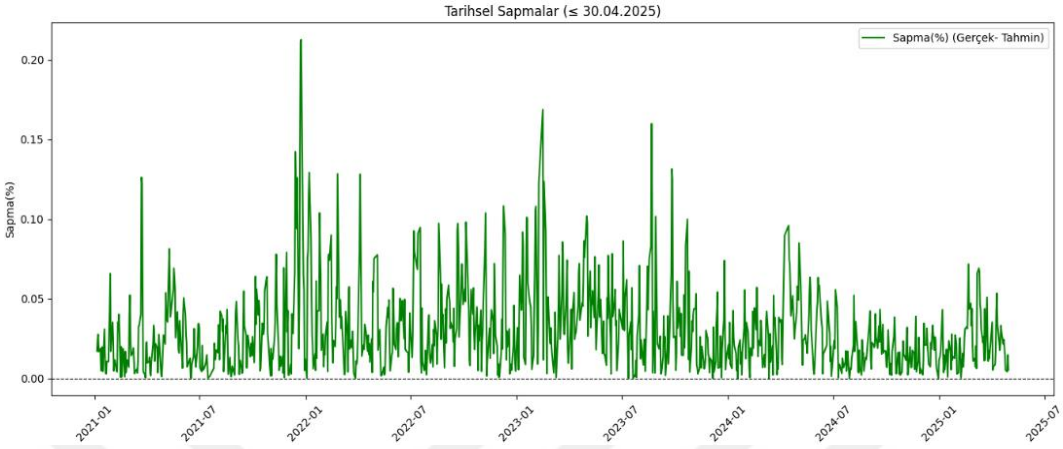
Örnek Aykırı Günler

07.03.2025

- Gerçek Değer: 130,07
- Tahmin: 122,01
- Sapma: %6,60

20.02.2025

- Gerçek Değer: 118,82
- Tahmin: 127,99
- Sapma: %7,17



Şekil 5.39 TUPRS sapma (tahmin hataları)

Ortalama sapma yaklaşık %1–2 bandındadır.2023 İlk Yarısında Tahmin sapmalarında ani sıçramalar var. Özellikle 2023 ilk çeyrekte birkaç tane yüksek sapma (%15–%20 civarı) gözlenmiş. Bu dönem muhtemelen modelin öğrenme aşamasında veya dışsal piyasa şoklarının yaşandığı dönem olabilir. 2024 yılında daha stabil bir performans gözlemleniyor. Sapmalar genelde düşük kalmış (%0–%5 arası). Bu durum modelin daha olgunlaştığını ve öğrenmeye devam ederek hatalarını azalttığını gösteriyor. 2025 başlarında sapmalar tekrar düşük düzeyde seyrediyor, ciddi sıçrama görünmüyor. Modelin bu dönemde genel eğilimleri daha doğru tahmin ettiği görülüyor.

5.3.3.2 Trend Yakalayabilme (Yön Doğruluğu Analizi)

Veriler incelendiğinde:

Bazı günlerde model, fiyat yönünü ters tahmin etmiş (örneğin fiyat artarken tahminde azalış görünmekte). Bu durum özellikle piyasa volatilitesinin yüksek olduğu dönemlerde daha sık bir şekilde karşımıza çıkıyor.

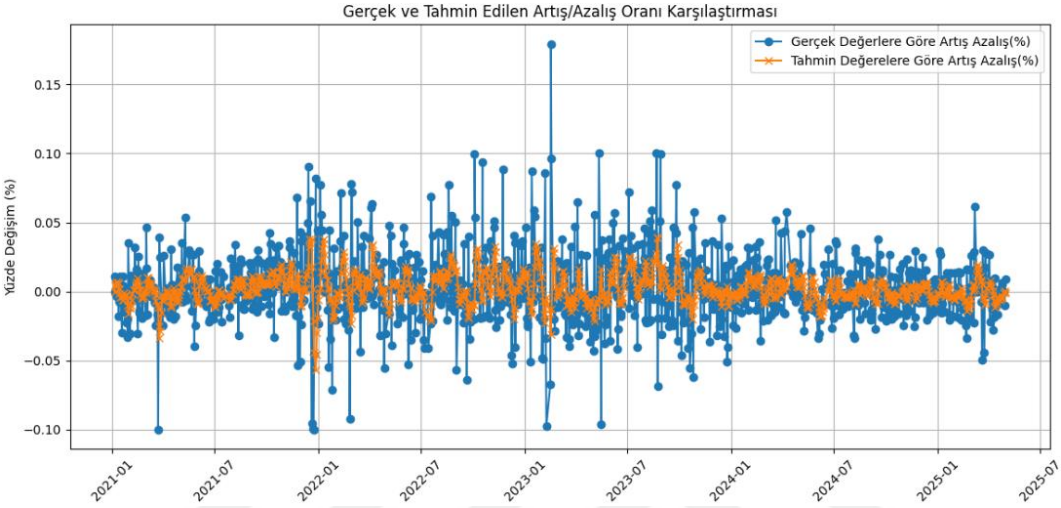
Örnek Yönsel Sapmalar:

21.02.2025

- Gerçek Artış: %1,59
- Tahmin Yönü: -%1,40

10.03.2025

- Gerçek Artış: %1,45
- Tahmin Artış: %1,15



Şekil 5.40 TUPRS gerçek ve tahmin edilen artış azalış karşılaştırması

5.3.3.3 Trend Yakalayabilme (Yön Doğruluğu Analizi)

Bu verilere göre bazı özet istatistikler çıkarabiliriz (tahmini olarak)

- Ortalama Sapma ≈ %1,8 – 2,2
- Maksimum Sapma ≈ %7,17
- Günlük tahminlerin yönsel doğruluk oranı ≈ %70 – 75

(Trend yönü doğru tahmin edilen günlerin oranı)

5.4 Tüm Hisse Senetlerine Ait LSTM Özet İstatistikler

Model tüm hisse senetleri için ayrı ayrı çalıştırılmıştır. Modelin herbir hisse senedi için ortalama çalışma süresi 30-35 dakika arasındadır. Tüm hisse senetlerine ait ortalama istatistikler hesaplanmıştır. Aşağıdaki tabloda bu değerleri görebiliyoruz.

Tablo 5.4 Tüm hisse senetleri için istatistikler

Hisse Senedi	Ortalama Sapma (%)	Maksimum Sapma (%)	Yönsel Doğruluk Oranı (%)
ISCTR	2.2 – 2.4	21.00	72
TCELL	1.82	4.56	81.48
TUPRS	1.8 – 2.2	7.17	70 – 75
AKBNK	2.47	21.82	72
ASELS	5,5	23.14	77
BIMAS	4.23	21.58	64
SAHOL	2.93	12.16	74.5
KCHOL	4.56	15.04	66
THYAO	2,92	12,16	62

Burada ortalama sapma analizleri incelendiğinde en iyi performansın TCELL Hisse senedine ait olduğu görülür.(≈ %1,82) TCELL, TUPRS ve ISCTR modelleri 2.5% altında sapma ile oldukça başarılıdır. ASELS, BIMAS ve KCHOL için ortalama sapma %4 ve üzerindedir. Bu modellerin fiyat seviyesi tahminleri göreceli olarak hatalıdır. ASELS'te sapma yüksek olsa da yönsel doğruluk oldukça yüksektir; bu önemli bir ayrımdır. Maksimum sapma analizinde en güvenilir modeller TCELL ve TUPRS modelleridir. Maksimum sapma açısından kabul edilebilir düzeydedir (<10%). ASELS, AKBNK, BIMAS ve ISCTR gibi hisselerde model bazı günlerde ciddi sapmalar yapmıştır (>20%). Bu hisselerde volatilite etkisi veya modelin yetersizliği olabilir. Genel olarak model yön tahmin etme konusunda olduça başarılı görünüyor. Burada TCELL, ASELS, SAHOL ve TUPRS yön tahmininde oldukça iyi tahminlede bulunurken BIMAS, KCHOL ve THYAO'nun yönsel doğruluk oranları %65'in altında kaldığı için, yatırım stratejilerinde bu hisselere dikkat edilmelidir.

5.4.1 Genel İstatistiksel Çıkarımlar

En Dengeli ve Güvenilir Model:

TCELL → Düşük sapma, düşük maksimum sapma ve yüksek yön doğruluğu ile en başarılı model.

Yönsel Olarak Güçlü Ama Sapmada Zayıf:

ASELS → Fiyat tahmininde sapmalar yüksek ama yön tahmininde başarılı. Stratejik yön tahminleri için kullanılabilir ama fiyat seviyesinde dikkatli olunmalı.

İyi Seviye Başarı:

ISCTR, AKBNK, TUPRS, SAHOL → Ortalama sapma ve yön doğruluğu dengeli. Uygun optimizasyonla daha da iyileştirilebilir.

İyileştirilmesi Gereken Modeller:

BIMAS, KCHOL, THYAO → Ortalama ve maksimum sapmalar yüksek, yön doğruluğu düşük. Bu modellerin yeniden eğitilmesi veya hiperparametre optimizasyonu önerilir.

5.5 LSTM ve ARIMA Modellerinin Karşılaştırılması

Tüm hisse senetleri için arıma model çalıştırılmış ve aşağıdaki tahmin sonuçları elde edilmiştir.

Date	TUPRS Gerçek Değer	TUPRS LSTM Tahmin Değer	TUPRS ARIMA Tahmin Değer	THYAO Gerçek Değer	THYAO LSTM Tahmin Değer	THYAO ARIMA Tahmin Değer
2.05.2025	124,8	125,7365112	124,6666	292,75	312,9454041	283,8299
5.05.2025	123,5	125,8527374	124,505	294	311,6009521	282,794
6.05.2025	119,6	126,0518723	124,3795	291,75	310,311676	284,7928
7.05.2025	117,6	126,282547	124,6478	278,75	309,2180786	283,3824
8.05.2025	129,3	126,5181885	124,6717	284,5	308,3487244	283,5764
9.05.2025	128,7	126,7491074	124,5058	294	307,6779175	284,8972
12.05.2025	134,5	126,9731445	124,4133	309,5	307,1616821	283,2109
13.05.2025	135,2	127,1906128	124,6168	304,5	306,7553101	284,412
14.05.2025	135,3	127,4024429	124,6649	299	306,4214783	284,6693
15.05.2025	131,7	127,609436	124,5137	293,75	306,1323547	283,4261

Date	AKBNK Gerçek Değer	AKBNK LSTM Tahmin Değer	AKBNK ARIMA Tahmin Değer	ISCTR Gerçek Değer	ISCTR LSTM Tahmin Değer	ISCTR ARIMA Tahmin Değer
2.05.2025	49,5	50,63427353	48,56	10,35	10,79212	10,2583
5.05.2025	48,58	50,34681702	48,4925	10,18	10,761919	10,2467
6.05.2025	49,26	50,38584518	48,4614	10,22	10,790994	10,2992
7.05.2025	49,48	50,5836525	48,5697	10,13	10,857006	10,2956
8.05.2025	49,92	50,83952332	48,4563	10,29	10,941503	10,2461
9.05.2025	49,88	51,10806656	48,5001	10,31	11,033362	10,2634
12.05.2025	51,9	51,37162018	48,5541	10,81	11,127026	10,3062
13.05.2025	52,25	51,62384796	48,4388	10,89	11,220094	10,2776
14.05.2025	51,8	51,8628006	48,5388	10,95	11,311689	10,2445
15.05.2025	50,7	52,08843231	48,5198	10,71	11,401562	10,2813

Date	TCELL Gerçek Değer	TCELL LSTM Tahmin Değer	TCELL ARIMA Tahmin Değer	KCHOL Gerçek Değer	KCHOL LSTM Tahmin Değer	KCHOL ARIMA Tahmin Değer
2.05.2025	89,1	93,27616882	90,0505	138,4	145,7679901	137,4738
5.05.2025	86,55	93,14945984	89,6588	135	144,9875488	137,8934
6.05.2025	87,35	93,26324463	89,7819	135,4	144,843277	137,3871
7.05.2025	87,9	93,53100586	90,1582	137,2	145,1009064	137,8835
8.05.2025	90,4	93,87783051	90,0066	140,7	145,5565491	137,7201
9.05.2025	92,3	94,25895691	89,7776	143,9	146,0908966	137,6112
12.05.2025	97,45	94,65270996	89,9932	154	146,6482391	138,0664
13.05.2025	95,75	95,05049133	90,1366	154,5	147,2082214	137,5773
14.05.2025	97,05	95,44956207	89,9283	154	147,7660217	138,0234
15.05.2025	96,5	95,84960938	89,8768	148,4	148,3223267	137,9233

Date	BIMAS Gerçek Değer	BIMAS LSTM Tahmin Değer	BIMAS ARIMA Tahmin Değer	SAHOL Gerçek Değer	SAHOL LSTM Tahmin Değer	SAHOL ARIMA Tahmin Değer
2.05.2025	470	464,7681274	446,1052	74,65	75,55628204	73,3178
5.05.2025	474	465,1741333	445,3384	73,25	74,77742767	73,286
6.05.2025	473	465,6642456	449,0273	73,1	74,3883667	73,3789
7.05.2025	490	466,24646	453,9823	72,2	74,28188324	73,2423
8.05.2025	486,75	466,9115906	455,9546	73,5	74,31272888	73,3325
9.05.2025	478,75	467,6429749	453,268	74,1	74,37701416	73,3146
12.05.2025	497,5	468,4215088	448,2424	79,5	74,42373657	73,3272
13.05.2025	495	469,230072	445,1912	78,75	74,43913269	73,2644
14.05.2025	496,5	470,0550232	446,7188	79,25	74,42773438	73,3469
15.05.2025	495,5	470,885437	451,4979	77,65	74,39916229	73,3061

Date	ASELS Gerçek Değer	ASELS LSTM Tahmin Değer	ASELS ARIMA Tahmin Değer
2.05.2025	129,8	129,6701813	135,9066
5.05.2025	129,8	130,7045593	136,5287
6.05.2025	137,4	131,3133545	137,43
7.05.2025	144,2	131,5804901	137,86
8.05.2025	154,1	131,6092377	138,4029
9.05.2025	149,2	131,4893341	139,2907
12.05.2025	140,4	131,2867432	139,89
13.05.2025	136,8	131,0446167	140,3353
14.05.2025	138	130,7883453	141,1267
15.05.2025	137,5	130,5313721	141,8669

Şekil 5.41 Tüm hisselerde 10 günlük lstm ve arima modelleri tahminleri

Çalışmada kullanılan LSTM (Long Short-Term Memory) modeli, özellikle karmaşık ve doğrusal olmayan zaman serisi desenlerini öğrenme yeteneği sayesinde kısa vadeli hisse senedi fiyat tahminlerinde önemli düzeyde başarı sergilemektedir. THYAO ve TCELL hisseleri özelinde, LSTM tahminlerinin gerçek değerlere çok fazla yaklaştığı ve özellikle TCELL için genel trend eğilimini oldukça başarılı bir şekilde yakaladığı görülmüştür. Bunların yanı sıra LSTM modelinin bütün hisse senetlerinde aynı düzeyde başarı sergilemediği de görülmektedir. Örnek olarak BIMAS ve TUPRS hisselerinde LSTM modelinin fiyat seviyelerini sistematik olarak düşük veya yüksek tahmin ettiği, bu sebeple modele özgü bir sapma oluştuğu dikkati çekmektedir. BIMAS için LSTM modeli tahmin değerlerinin sistematik olarak gerçek değerlerin altında kalması, modelin özellikle yüksek fiyat seviyelerinde yeterince genelleme yapamadığını göstermektedir. LSTM modelinin en başarılı yaptığı işlerden biri olan genel eğilimleri takip etme kabiliyeti, burada ani sıçramalar veya hızlı düşüşler karşısında bazı nokralarda yetersiz kalmıştır. Özellikle 12–15 Mayıs tarihleri arasında gözlenen ani piyasa hareketlerinde (örneğin THYAO ve SAHOL hisselerinde), LSTM tahminlerinin bu ani değişimleri yeterli düzeyde öngöremediği gözlemlenmiştir

Diğer tarafta, ARIMA modeli, genel olarak daha az oynaklık içeren sabit yapılı serilerde tutarlı tahminler sunmaktadır. Tahmin değerlerinde beklenmedik hareketler ve ani sıçramalar yerine ortalamaya yakın daha kararlı değerler sunmaktadır. Bu yönüyle, SAHOL, ISCTR ve AKBNK gibi daha stabil seyir izleyen hisselerde ARIMA modeli başarılı sonuçlar vermiştir. Buna ek olarak, trend, mevsimsellik ve volatilite içeren zaman serilerinde ARIMA modelinin açıklayıcılığı oldukça başarısız kalmıştır. Özellikle THYAO, TCELL ve BIMAS gibi dalgalanma düzeyi yüksek hisselerde, ARIMA modelinin tahminleri ciddi sapmalar göstermiştir. Burada özellikle 12–15 Mayıs tarihleri arasındaki dönemde birçok hisse senedinde gözlenen ani yükselişleri ARIMA modelinin öngörememesi, bu modelin yapısal kısıtlarını göstermede çok önemli bir örnek olmuştur. Bu sonuçlar, ARIMA modelinin daha durağan ve düşük volatiliteye sahip verilerde avantajlı olduğunu, ancak piyasa dinamiklerinin hızla değiştiği durumlarda derin öğrenme temelli modellere kıyasla yetersiz kaldığını göstermektedir.

Tablo 5.5 Hisse bazlı örnekler model başarı karşılaştırması

Hisse	Yorum
TUPRS	LSTM tahminleri, ARIMA'ya kıyasla yüksek sapmalar gösterse de yönü daha iyi yakalamaktadır. ARIMA ise sabit değerlerde kalmıştır.
THYAO	LSTM modeli yüksek tahminlerde aşırıya kaçmıştır, ancak ARIMA modelinin geride kalışı LSTM'e göre oldukça fazladır. Her iki modelin başarısı sınırlıdır.
TCELL	LSTM, ARIMA ya oranla oldukça başarılı; gerçek değerlere daha yakın ve değişimleri daha iyi takip etmeketedir.
KCHOL	LSTM modeli, genel olarak daha tutarlıdır. ARIMA düz çizgide kalmış ve fiyat artışlarını öngörememiştir.
AKBNK	Her iki model de düşük hata payıyla çalışmıştır. Ancak LSTM'nin küçük sapmalarda bile daha iyi yaklaştığı gözleniyor.
ISCTR	Her iki modelde benzer performans söz konusu, LSTM bir miktar daha iyi.
SAHOL	Düşük oynaklığa sahip bu hissede ARIMA daha doğru tahminlerde bulunmuştur.
ASELS	Yüksek oynaklık gösterdiği günlerde LSTM modelinin daha iyi trend yakaladığı gözlemlenmiştir.
BIMAS	LSTM, genellikle gerçek değerin altında kalmış; ARIMA ise sistematik olarak daha düşük tahmin yapmıştır. LSTM burada daha dengeli.

5.5.1 Model Sonuçları ve Değerlendirmeleri

İki modele ait karşılaştırmalı analizler, LSTM ve ARIMA modellerinin hisse senedi fiyat tahminlerinde birbirinden farklı performans özelliklerine sahip olduğunu ortaya koymaktadır. Özellikle fiyat serilerinde ani dalgalanma, düzensizlik veya karmaşık desenlerin gözlendiği hisselerde (örneğin THYAO, TCELL ve ASELS), LSTM modelleri daha başarılı sonuçlar üretmiş ve fiyat hareketlerinin yönünü daha iyi takip edebilmiştir. Bu durum, LSTM'nin ardışık verilerdeki belirsizlikleri modelleyebilme kapasitesine ve uzun vadeli bağımlılıkları öğrenme yeteneğinden kaynaklanmaktadır.

Buna karşın, daha stabil bir yapıya ve düşük volatiliteye sahip olan hisseler (örneğin AKBNK, SAHOL ve ISCTR) incelendiğinde, ARIMA modellerinin daha tutarlı ve düşük hata ile çalışan bir yapı sergilediği görülmektedir. ARIMA modeli, özellikle istasyoner seriler üzerinde belirgin trend veya mevsimsellik içermeyen verilerde daha dengeli tahminler sağlamaktadır.

Yönsel tahmin performansları incelendiğinde LSTM modelleri genel olarak ARIMA'ya kıyasla daha iyi tahmin sonuçları vermektedir. Bununla birlikte, bazı hisselerde LSTM tahminlerinin gerçek değerlerden ciddi sapmalar gösterdiği de göz ardı edilmemelidir. ARIMA modeli ise belirgin trend değişimlerini yakalamada yetersiz kalmakta ve fiyatlardaki ani yükseliş veya düşüşlere tepkisiz bir tahmin

davranışı sergilemektedir. Bu sonuçlar ışığında, hem kısa vadeli oynaklıkları hem de uzun vadeli yapısal desenleri dikkate alabilecek melez (hibrid) model yaklaşımlarının tercih edilmesi daha başarılı sonuçlar alınmasını sağlayacaktır.

Tablo 5.6 Hisse bazlı model performans değerleri

Hata Terimleri	ARIMA		LSTM	
Hisse	RMSE	MAE	RMSE	MAE
TUPRS	7,01	6,03	5,79	5,07
THYAO	13,29	11,28	17,22	14,88
TCELL	5,11	5,01	3,36	3,09
KCHOL	9,84	7,51	6,93	6,27
AKBNK	2,18	1,1818	1,089	0,988
ISCTR	0,3689	0,2744	0,5617	0,5397
SAHOL	3,5425	2,5548	2,9675	2,4354
ASELS	7,1341	5,6351	11,1058	8,8991
BIMAS	37,6612	36,1674	20,1373	18,2

Çalışmada, ARIMA ve LSTM modellerinin bütün hisse senedi üzerinde gerçekleştirdikleri kısa vadeli fiyat tahmin performansları karşılaştırılmıştır. Her model için bütün hisse senetleri tahminleri üzerinden ayrı ayrı hesaplanan RMSE (Root Mean Square Error) ve MAE (Mean Absolute Error) hata metrikleri gerçekleştirilmiştir. Elde edilen bütün sonuçlar, model başarısının hisse senedinin karakteristik özelliklerine bağlı olarak anlamlı biçimde değişkenlik göstermiştir.

Genel anlamda, LSTM modeli birçok hisse senedinde ARIMA'ya kıyasla daha düşük RMSE ve MAE değerleri üretmiş, bu durum tahminlerin gerçek değerlere daha yakın olduğunu göstermektedir. Özellikle TUPRS, TCELL, KCHOL ve AKBNK hisseleri için LSTM modeli hem hata oranı açısından daha düşük değerler vermesi sebebiyle daha açıklayıcı bir yapıya sahip olduğunu göstermiştir. LSTM modelinin, veri içerisinde bulunan zamansal örüntüleri ve karmaşık ilişkileri daha iyi öğrenebildiğini ortaya koymaktadır. Bununla birlikte, bazı hisse senetlerinde ARIMA modelinin LSTM'e göre daha tutarlı sonuçlar ürettiği gözlemlenmiştir. Örneğin, ISCTR ve ASELS hisseleri için ARIMA modeli daha düşük RMSE ve MAE sonuçları üretmiştir. Bunların dışında THYAO ve BIMAS hisselerinde her iki model de düşük performans sergilemiş, ancak ARIMA göreceli olarak daha az hata üretmiştir.

Sonuç olarak, LSTM modeli genel bağlamda daha başarılı tahmin performansı sergilenmiş olsa da tüm hisse senetleri için evrensel olarak üstün bir model olduğunu söylemek yanlıştır. Model başarısı, hisse senedinin volatilitesi, trend yapısı ve veri setinin özelliklerine bağlı olarak değişmektedir.

5.6 LSTM Tabanlı Yükseliş Düşüş Modeli

Bu modelde LSTM tabanlı bir hisse senedi tahmin modeli oluşturuyoruz. Burada hisse senetlerinin fiyat artışları 1, düşüşleri 0 olacak şekilde binary bir model oluşturulmuştur. Bu modele ait veri setinin görüntüsü aşağıdaki gibidir:

Date	TUPRS.IS	THYAO.IS	TCELL.IS	KCHOL.IS	AKBNK.IS	ISCTR.IS	SAHOL.IS	ASELS.IS	BIMAS.IS
2.01.2024	1	1	1	1	1	1	1	1	1
3.01.2024	0	0	0	0	0	0	0	0	0
4.01.2024	1	1	1	1	1	1	1	1	1
5.01.2024	1	1	1	1	1	1	1	0	1
8.01.2024	0	1	1	1	1	1	1	1	1
9.01.2024	0	1	1	0	0	0	1	0	1
10.01.2024	1	1	0	1	1	1	1	1	0
11.01.2024	0	0	0	1	1	1	1	0	1

Şekil 5.42 Binary model veri seti örneği

Bu model çalıştırıldığında 9 hisse senedine ait sonuçlar aşağıda verilmiştir:

```
Gelecek 10 gün tahmini yapılıyor...

================================================================================
GELECEK 10 GÜN TAHMİNLERİ (02.05.2025 - 15.05.2025)
================================================================================
Tarih           TUPRS.IS  THYAO.IS  TCELL.IS  KCHOL.IS  AKBNK.IS  ISCTR.IS  SAHOL.IS  ASELS.IS  BIMAS.IS
--------------------------------------------------------------------------------
02.05.2025      YÜKSELİŞ  YÜKSELİŞ  YÜKSELİŞ  YÜKSELİŞ  YÜKSELİŞ  DÜŞÜŞ     YÜKSELİŞ  DÜŞÜŞ     YÜKSELİŞ
03.05.2025      YÜKSELİŞ  YÜKSELİŞ  YÜKSELİŞ  YÜKSELİŞ  YÜKSELİŞ  DÜŞÜŞ     YÜKSELİŞ  YÜKSELİŞ  YÜKSELİŞ
04.05.2025      DÜŞÜŞ     YÜKSELİŞ  DÜŞÜŞ     YÜKSELİŞ  YÜKSELİŞ  YÜKSELİŞ  YÜKSELİŞ  DÜŞÜŞ     YÜKSELİŞ
05.05.2025      DÜŞÜŞ     YÜKSELİŞ  YÜKSELİŞ  YÜKSELİŞ  YÜKSELİŞ  DÜŞÜŞ     YÜKSELİŞ  DÜŞÜŞ     YÜKSELİŞ
06.05.2025      DÜŞÜŞ     YÜKSELİŞ  YÜKSELİŞ  YÜKSELİŞ  YÜKSELİŞ  DÜŞÜŞ     YÜKSELİŞ  DÜŞÜŞ     YÜKSELİŞ
07.05.2025      DÜŞÜŞ     YÜKSELİŞ  DÜŞÜŞ     YÜKSELİŞ  YÜKSELİŞ  YÜKSELİŞ  YÜKSELİŞ  DÜŞÜŞ     YÜKSELİŞ
08.05.2025      DÜŞÜŞ     DÜŞÜŞ     DÜŞÜŞ     DÜŞÜŞ     DÜŞÜŞ     DÜŞÜŞ     YÜKSELİŞ  YÜKSELİŞ  DÜŞÜŞ
09.05.2025      DÜŞÜŞ     DÜŞÜŞ     YÜKSELİŞ  DÜŞÜŞ     YÜKSELİŞ  YÜKSELİŞ  YÜKSELİŞ  YÜKSELİŞ  YÜKSELİŞ
10.05.2025      DÜŞÜŞ     YÜKSELİŞ  DÜŞÜŞ     YÜKSELİŞ  YÜKSELİŞ  YÜKSELİŞ  YÜKSELİŞ  DÜŞÜŞ     YÜKSELİŞ
11.05.2025      DÜŞÜŞ     DÜŞÜŞ     YÜKSELİŞ  DÜŞÜŞ     YÜKSELİŞ  YÜKSELİŞ  YÜKSELİŞ  YÜKSELİŞ  YÜKSELİŞ

================================================================================
```

ÖZET TABLO:

	TUPRS.IS	THYAO.IS	TCELL.IS	KCHOL.IS	AKBNK.IS	ISCTR.IS
02.05.2025	YÜKSELİŞ	YÜKSELİŞ	YÜKSELİŞ	YÜKSELİŞ	YÜKSELİŞ	DÜŞÜŞ
03.05.2025	YÜKSELİŞ	YÜKSELİŞ	YÜKSELİŞ	YÜKSELİŞ	YÜKSELİŞ	DÜŞÜŞ
04.05.2025	DÜŞÜŞ	YÜKSELİŞ	DÜŞÜŞ	YÜKSELİŞ	YÜKSELİŞ	YÜKSELİŞ
05.05.2025	DÜŞÜŞ	YÜKSELİŞ	YÜKSELİŞ	YÜKSELİŞ	YÜKSELİŞ	DÜŞÜŞ
06.05.2025	DÜŞÜŞ	YÜKSELİŞ	YÜKSELİŞ	YÜKSELİŞ	YÜKSELİŞ	DÜŞÜŞ
07.05.2025	DÜŞÜŞ	YÜKSELİŞ	DÜŞÜŞ	YÜKSELİŞ	YÜKSELİŞ	YÜKSELİŞ
08.05.2025	DÜŞÜŞ	DÜŞÜŞ	DÜŞÜŞ	DÜŞÜŞ	DÜŞÜŞ	DÜŞÜŞ
09.05.2025	DÜŞÜŞ	DÜŞÜŞ	YÜKSELİŞ	DÜŞÜŞ	YÜKSELİŞ	YÜKSELİŞ
10.05.2025	DÜŞÜŞ	YÜKSELİŞ	DÜŞÜŞ	YÜKSELİŞ	YÜKSELİŞ	YÜKSELİŞ
11.05.2025	DÜŞÜŞ	DÜŞÜŞ	YÜKSELİŞ	DÜŞÜŞ	YÜKSELİŞ	YÜKSELİŞ

	SAHOL.IS	ASELS.IS	BIMAS.IS
02.05.2025	YÜKSELİŞ	DÜŞÜŞ	YÜKSELİŞ
03.05.2025	YÜKSELİŞ	YÜKSELİŞ	YÜKSELİŞ
04.05.2025	YÜKSELİŞ	DÜŞÜŞ	YÜKSELİŞ
05.05.2025	YÜKSELİŞ	DÜŞÜŞ	YÜKSELİŞ
06.05.2025	YÜKSELİŞ	DÜŞÜŞ	YÜKSELİŞ
07.05.2025	YÜKSELİŞ	DÜŞÜŞ	YÜKSELİŞ
08.05.2025	YÜKSELİŞ	YÜKSELİŞ	DÜŞÜŞ
09.05.2025	YÜKSELİŞ	YÜKSELİŞ	YÜKSELİŞ
10.05.2025	YÜKSELİŞ	DÜŞÜŞ	YÜKSELİŞ
11.05.2025	YÜKSELİŞ	YÜKSELİŞ	YÜKSELİŞ

```
Hisse Senedi Bazında Doğruluk Oranları:
TUPRS.IS: 0.5000
THYAO.IS: 0.7500
TCELL.IS: 0.6667
KCHOL.IS: 0.6667
AKBNK.IS: 0.4167
ISCTR.IS: 0.4167
SAHOL.IS: 0.7500
ASELS.IS: 0.6667
BIMAS.IS: 0.4167

Genel Doğruluk: 0.5833

10 Günlük Dönemde Yükseliş Oranları:
TUPRS.IS: %20.0
THYAO.IS: %70.0
TCELL.IS: %60.0
KCHOL.IS: %70.0
AKBNK.IS: %90.0
ISCTR.IS: %50.0
SAHOL.IS: %100.0
ASELS.IS: %40.0
BIMAS.IS: %90.0
```

Şekil 5.43 LSTM binary yükseliş/düşüş model tahmini

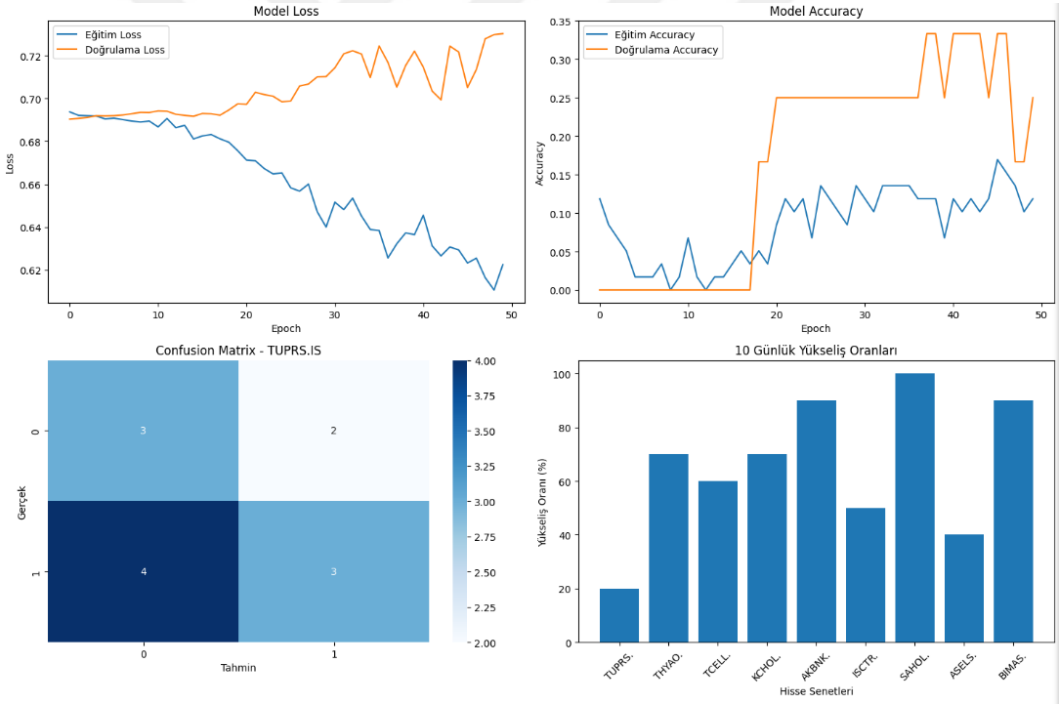
Çalışmada, 02.05.2025 ile 11.05.2025 tarihleri arasını kapsayan 10 gün için, dokuz farklı hisse senedine ilişkin yönsel fiyat tahminleri üretmek üzere eğitilmiş bir LSTM modelinin performansı değerlendirilmiştir. Model, her bir hisse senedi için günlük bazda yalnızca "yükseliş" veya "düşüş" yönünde öngörülerde bulunmuş; dolayısıyla regresyon temelli miktarsal tahmin yerine sınıflandırmaya dayalı yönsel bir yaklaşım yapmıştır.

Gerçek fiyatlar kullanılarak yön belirleme işlemi, geleneksel bir karşılaştırmalı değişim mantığına dayalı olarak çalışmaktadır. İlgili hisse senedinin bir sonraki gündeki kapanış fiyatı mevcut gününkinden yüksekse bu durum "yükseliş" olarak sınıflandırılmış, diğer durumda ise "düşüş" olarak yazılmaktadır. Böylece modelin tahmin ettiği yön ile gerçekleşen yön karşılaştırılarak doğruluk oranları hesaplanmıştır. Gerçek fiyat hareketlerine bakıldığında, değerlendirme döneminde SAHOL, AKBNK ve BIMAS hisseleri sırasıyla %100, %90 ve %90 oranında yükseliş göstermiştir. Benzer şekilde, THYAO ve KCHOL hisseleri de %70 oranında yükselmiş; TCELL %60, ISCTR %50 ve ASELS %40 oranında yükselişle takip etmiştir. Sadece TUPRS hissesinde bu oran %20 seviyesinde kalarak düşüş eğilimi baskın olmuştur.

Modelin yönsel tahmin performansı doğruluk oranlarıyla ortaya konulmuştur. En yüksek doğruluk oranı %75 ile SAHOL ve THYAO hisselerinde elde edilmiştir. Bu sonuçlar, modelin belirgin yükseliş trendi gösteren hisselerde başarılı tahminler üretebildiğini göstermektedir. Diğer taraftan KCHOL, ASELS ve TCELL hisselerinde yaklaşık %66 doğruluk elde edilerek modelin bu hisselerde de makul bir başarı sergilediği gözlemlenmiştir. TUPRS hissesinde doğruluk oranı %50 olarak gerçekleşmiş ve bu hisse için modelin performansı rastgele tahmin ile aynı seviyede kalmıştır. Diğer yandan, AKBNK, BIMAS ve ISCTR hisselerinde doğruluk oranı %41.67 olup, modelin bu hisselerde yönsel hareketleri tespit etmekte zorlandığı görülmektedir. Özellikle AKBNK ve BIMAS hisselerinde gerçekleşen yüksek oranlı yükseliş trendlerine rağmen model düşük başarı göstermiştir. Genel doğruluk oranı %58.33 olarak hesaplanmıştır. Bu oran, rastgele sınıflandırma seviyesinin (%50) bir miktar üzerinde olmakla birlikte, modelin her hisse senedi için tutarlı bir performans sergileyemediğini göstermektedir. Dolayısıyla modelin belirli hisselerdeki trendleri yakalama yeteneği mevcut olsa

da, tüm portföy geneline yayılan güvenilir bir öngörü sistematiği henüz sağlanamamıştır.Sadece yönsel tahmin yapan bu modelin, fiyat değişim miktarını da öngörebilecek regresyon temelli bir LSTM modeline dönüştürülmesi ile Modelin hiperparametreleri üzerinde yapılacak optimizasyonlar (örneğin öğrenme oranı, epoch sayısı, katman derinliği gibi) ile ilk model olarak oluşturulan LSTM modelinde olduğu gibi sonuçların daha başarılı hale gelmesi mümkündür.

Sonuç olarak, mevcut model sınırlı veri ve özellik setiyle bile belirli hisselerde anlamlı öngörülerde bulunabilmiştir. Ancak daha istikrarlı ve yaygın bir başarı için modelin hem veri ön işleme sürecinin iyileştirilmesi hem de mimarisinin genişletilmesi gerekmektedir. Bu bağlamda model, finansal piyasalarda trend tahmini açısından potansiyel vaat etmekle birlikte, daha ileri düzeyde kullanım için optimizasyona ve geniş veri entegrasyonuna ihtiyaç duymaktadır.



Şekil 5.44 Yükseliş/Düşüş modeli grafikleri

Modelin eğitimi süresince elde edilen kayıp (loss) grafiği, modelin eğitim verisi üzerinde öğrenme gerçekleştirebildiğini göstermektedir. Eğitim kaybı zamanla düzenli bir biçimde azalmış ve bu durum modelin eğitim verisindeki örüntüleri başarılı bir şekilde yakalayabildiğini göstermektedir. Ancak doğrulama kaybının özellikle 10. epoch'tan itibaren belirgin şekilde artış göstermesi ve dalgalı bir seyir

izlemesi, modelin genelleme kabiliyetinin zayıf olduğunu ortaya koymaktadır. Bu durum, klasik bir aşırı öğrenme (overfitting) örneği olup, modelin yalnızca eğitim verisine adapte olduğu, fakat daha önce görmediği doğrulama verileri karşısında tutarlı performans sergileyemediğini göstermektedir. Model doğruluğuna ilişkin grafikler incelendiğinde, hem eğitim hem de doğrulama aşamalarında genel başarının düşük seviyelerde kaldığı görülmektedir. Eğitim doğruluğu %15 seviyesini aşmakta zorlanırken, doğrulama doğruluğu ise daha düşük ve düzensiz bir dağılım sergilemiştir. Doğrulama başarısı yaklaşık 15. epoch civarında kısmi bir artış gösterse de, bu artış istikrar kazanamamış ve öğrenmenin güvenilirliği sıkıntılı seviyelerde kalmıştır. Bu sonuçlar, modelin kapasitesinin sınırlı olabileceğini veya modele sunulan giriş değişkenlerinin yeterince anlamlı özellikler içermediğini göstermektedir.

6
SONUÇ

6.1 Hisse Senedi Tahmininin Zorlukları

Hisse senedi piyasaları, ekonomik, politik ve sosyal birçok faktörün bir araya gelerek dinamik ve karmaşık bir yapı oluşturduğu finansal sistemlerdir. Bu yapının doğası gereği hisse senedi fiyatlarını doğru şekilde tahmin etmek oldukça zordur. Aşağıda hisse senedi tahmininde karşılaşılan temel zorluklar açıklanmaktadır:

1. Piyasa Volatilitesi ve Belirsizliği

Hisse senedi fiyatları, sürekli dalgalanan ve ani değişikliklere açık olan bir yapıya sahiptir. Bu volatilite, piyasa duyarlılığı, haberler, makroekonomik veriler veya beklenmedik olaylar nedeniyle ortaya çıkar. Bu ani değişimler tahmin modellerinin stabil çalışmasını zorlaştırır.

2. Çok Sayıda Etkenin Birlikte Etkisi

Fiyatları etkileyen faktörler sadece şirket performansıyla sınırlı değildir. Küresel ekonomik koşullar, politik gelişmeler, merkez bankası kararları, sektör dinamikleri ve yatırımcı psikolojisi gibi çok sayıda parametre fiyatların hareketini şekillendirir. Bu karmaşıklık, tüm değişkenlerin modellenmesini zorlaştırır.

3. Veri Kalitesi ve Erişilebilirliği

Tahmin modelleri büyük oranda geçmiş verilere dayanır. Ancak finansal verilerde eksik, hatalı veya gecikmeli bilgiler olabilir. Ayrıca, bazı piyasa hareketlerini doğru yansıtacak yeterli veri setine ulaşmak zor olabilir. Veri kalitesinin düşüklüğü model doğruluğunu olumsuz etkiler.

4. Modelleme Zorlukları

Hisse senedi tahmininde kullanılan modellerin doğruluğu sınırlıdır. Özellikle derin öğrenme ve makine öğrenmesi modelleri, geçmiş verilere çok bağlıdır ve ani piyasa

değişikliklerini öngörmede zayıf kalabilir. Ayrıca aşırı öğrenme (overfitting) veya yetersiz öğrenme (underfitting) gibi problemler ortaya çıkabilir.

5. Yön ve Miktar Tahmini Arasındaki Fark

Fiyatın sadece yönünü (artış mı azalış mı) doğru tahmin etmek ile fiyatın büyüklüğünü veya kesin seviyesini tahmin etmek arasında önemli farklar vardır. Bazı modeller fiyat yönünde başarılı olsa da fiyat seviyesinde büyük sapmalar gösterebilir.

6. Psikolojik ve Davranışsal Etkiler

Piyasalar sadece rasyonel faktörlerden etkilenmez. Yatırımcıların duyguları, beklentileri ve davranışsal önyargıları fiyatları etkiler. Bu psikolojik faktörlerin sayısallaştırılması ve modele dahil edilmesi oldukça zordur.

7. Hızla Değişen Piyasa Koşulları

Piyasa yapısı ve kuralları zamanla değişebilir. Yeni regülasyonlar, teknolojik gelişmeler veya ekonomik krizler modellerin geçerliliğini azaltabilir ve yeniden güncellenmesini gerektirir.

Hisse senedi tahmini, birçok bilinmeyeni ve karmaşık değişkeni içeren zorlu bir alandır. Başarılı tahmin için güçlü veri altyapısı, gelişmiş modelleme teknikleri ve piyasa dinamiklerine hakimiyet gereklidir. Ayrıca, hiçbir modelin %100 doğru tahmin yapamayacağı unutulmamalı, risk yönetimi ve temkinli stratejilerle desteklenmelidir.

6.2 Model Performansı Ve Tahmin Sonuçları

Modelin doğruluğu, eğitim sürecinde kullanılan erken durdurma (early stopping) ve validation split yöntemleriyle optimize edilmiştir. Eğitimde kullanılan hiperparametreler, Keras Tuner ile optimize edilerek en iyi modelin bulunması sağlanmıştır. Eğitim süreci boyunca doğrulama kaybı ve eğitim kaybı izlenmiş, modelin aşırı öğrenme (overfitting) yapması engellenmiştir. Eğitilen model, son 240 günün verisi kullanılarak gelecekteki fiyatların tahminini başarmıştır. Modelin yaptığı 10 günlük fiyat tahminleri, belirli bir güven aralığında yapılan çıkarsamalara dayanarak, gelecek 10 iş günü için hisse senetleri fiyat hareketlerini öngörmüştür.

Bu tahminler, hisse senedinin potansiyel fiyat dalgalanmalarını anlamak için kullanılabilir, ancak her zaman dışsal faktörler (örneğin, piyasa haberleri, ekonomik göstergeler) tahminlerin doğruluğunu etkileyebilir.

6.3 Değerlendirme ve Sonuçlar

Bu çalışmada, 9 adet hisse sinedi için (TUPRS, THYAO, TCELL, KCHOL, AKBNK, ISCTR, SAHOL, ASELS, BIMAS) hissesinin gelecekteki fiyatlarını tahmin etmek amacıyla LSTM (Long Short-Term Memory) ve GRU (Gated Recurrent Units) modellerini içeren bir derin öğrenme ağı kullanılmıştır.. Zaman serisi verisi olarak 2010'dan 2025'e kadar olan kapanış fiyatları alındı bu fiyatlar alınırken hisse senetlerinin bölünmeleri ve pay devirleri dikkate alınarak bir veri kullanıldı.

Sonuçlar, modelin geçmiş fiyat hareketlerini kullanarak anlamlı bir tahmin başarısı gösterdiğini belirtmektedir. Ancak, finansal piyasalardaki belirsizlikler ve volatilite göz önüne alındığında, bu tür tahminlerin yalnızca yön göstermek amacıyla kullanılmasının daha doğru olacağı söylenebilir. Model, zaman serisi verileri üzerinde iyi bir performans sergilese de, her zaman dışsal değişkenlerin etkisiyle tahminlerin doğruluğu sınırlı olabilir. Sonuç olarak LSTM ve GRU tabanlı modeller, hisse senedi fiyatlarının tahmini konusunda güçlü bir performans sergilemiştir. Bu modelin başarısı, sadece geçmiş verilere dayalıdır. Piyasa şokları, haberler ve diğer dışsal faktörler tahminlerin doğruluğunu etkileyebilir. Bu modelin, güncel piyasa verileri ve ekonomik göstergeler ile desteklenmesi, daha güçlü ve güvenilir tahminler elde edilmesine yardımcı olabilir.

LSTM Modeli hem geleneksel ARIMA modeli hem de LSTM tabanlı yükseliş düşüş modeline göre oldukça başarılı sonuçlar vermiştir.LSTM modeli hisse senetlerinde oluşacak ani trend değişiklilerini yakalayabilme, yön tahmininde bulunma konusunda diğer modellere göre daha iyi performans göstermiştir. Tabi ki LSTM modelinin diğer modellere göre daha iyi performans sergilemesi bütün hisse senetleri için daha iyi performans gösterdiği anlamına gelmemektedir. Bazı hisse senetleri özelinde geleneksel ARIMA modelinin daha iyi sonuçlar ürettiği görülmüştür. Bu durum en doğru sonuçların alınması için kısa ve uzun vade değişiklikleri tahminleyebilen LSTM ve ARIMA modellerinin bir arada

kullanıldığı melez (hibrid) model yaklaşımları daha iyi sonuçlar verecektir. LSTM modelinin en önemli özelliklerinden biri uzun vadede geleneksel yöntemlerin aksine gerçek değerler de olduğu gibi yüksek volatiliteye ayak uydurmasıdır. Türk borsası doğası gereği yüksek volatiliteye sahip bir borsadır. Bu da hisse senetlerinin duraganlıktan uzak hareketler etmesine neden olmaktadır. Bu yüzden LSTM modeli gerek siyasi, gerek ekonomik gerek dış etkenlere bağlı olarak yüksek değişkenlik gösteren türk borsasında tahmin gücü ile yatırımcılara iyi bir yol gösterici olmuştur.

Bu durumlara ek olarak derin sinir ağları ve LSTM algoritmasında eproch sayılarının arttırılması ile model performansları optimize edilebilir fakat bu durum modelin performans maliyetini oldukça yükseltecektir. Çalışmada verilerin daha kısa süreli ve orta vadeli veriler üzerindeki tepkileri incelenmiştir. Daha gelişmiş bilgisayarlar kullanarak hiperparametre optimizasyonu yardımıyla en ideal noron sayılarına ulaşılıp uzun vade incelemeleri yapılabilir. Sonuç olarak, bu model hisse senedi tahminleri için potansiyel bir araç sunmaktadır, ancak yatırım kararları alırken dikkatli ve kapsamlı bir analiz yapılması önemlidir.

KAYNAKÇA

[1] M. S. Duran and S. Konya, "Kovid-19'un borsaya etkisi: Gelişmekte olan piyasalardan kanıtlar," *Süleyman Demirel Üniversitesi Vizyoner Dergisi*, vol. 13, no. 35, pp. 776–793, 2022.

[2] Y. S. Abu-Mostafa and A. F. Atiya, "Introduction to financial forecasting," *Applied Intelligence*, vol. 6, pp. 205–213, 1996.

[3] H. Pabuçcu, "Borsa endeksi hareketlerinin makine öğrenme algoritmaları ile tahmini," *Uluslararası İktisadi ve İdari İncelemeler Dergisi*, no. 23, pp. 179–190, 2019.

[4] B. Kutlu and B. Badur, "Yapay sinir ağları ile borsa endeksi tahmini," *Yönetim - İstanbul Üniversitesi İşletme Fakültesi İşletme İktisadı Enstitüsü Dergisi*, vol. 20, no. 63, 2009.

[5] J. Brownlee, *Deep Learning for Time Series Forecasting: Predict the Future with MLPs, CNNs and LSTMs in Python*, Machine Learning Mastery, 2018.

[6] Y. Aker, "Analysis of price volatility in BIST 100 index with time series: comparison of Fbprophet and LSTM model," *Avrupa Bilim ve Teknoloji Dergisi*, no. 35, pp. 89–93, 2022.

[7] A. İ. Taş, P. Gülüm and G. Tulum, "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*, vol. 9, no. 3, pp. 446–460, 2021.

[8] S. Akbulut and K. Adem, "Derin öğrenme ve makine öğrenmesi yöntemleri kullanılarak gelişmekte olan ülkelerin finansal enstrümanlarının etkileşimi ile Bist 100 tahmini," *NÖHÜ Mühendislik Bilimleri Dergisi*, vol. 12, no. 1, pp. 52–63, 2023, doi: 10.28948/ngumuh.1131191.

[9] M. E. A. G. Hiransha, E. A. Gopalakrishnan, V. K. Menon and K. P. Soman, "NSE stock market prediction using deep-learning models," *Procedia Computer Science*, vol. 132, pp. 1351–1362, 2018.

[10] G. S. Atsalakis and K. P. Valavanis, "Forecasting stock market short-term trends using a neuro-fuzzy based methodology," *Expert Systems with Applications*, vol. 36, pp. 10696–10707, 2009.

[11] M. A. Hossain, R. Karim, R. Thulasiram, N. D. Bruce and Y. Wang, "Hybrid deep learning model for stock price prediction," in *Proc. IEEE Symp. Series on Computational Intelligence (SSCI)*, pp. 1837–1844, Nov. 2018.

[12]L. Shi, Z. Teng, L. Wang, Y. Zhang and A. Binder, "DeepClue: Visual interpretation of text-based deep stock prediction," *IEEE Trans. Knowl. Data Eng.*, vol. 31, no. 6, pp. 1094–1108, 2018.

[13]T. K. Lee, J. H. Cho, D. S. Kwon and S. Y. Sohn, "Global stock market investment strategies based on financial network indicators using machine learning techniques," *Expert Systems with Applications*, vol. 117, pp. 228–242, 2019.

[14] J. J. Murphy, *Technical Analysis of the Financial Markets: A Comprehensive Guide to Trading Methods and Applications*, Penguin, 1999.

[15]N. Petrusheva and I. Jordanoski, "Comparative analysis between the fundamental and technical analysis of stocks," *J. Process Manag. New Technol.*, vol. 4, no. 2, pp. 26–31, 2016.

[16] F. A. Nirob and D. M. M. Hasan, "Predicting stock price from historical data using LSTM technique," *Journal of Artificial Intelligence and Data Science*, vol. 3, no. 1, pp. 36–49, 2023.

[17]T. Liu, X. Ma, S. Li, X. Li and C. Zhang, "A stock price prediction method based on meta-learning and variational mode decomposition," *Knowledge-Based Systems*, vol. 252, Art. no. 109324, 2022.

[18]N. K. Manaswi, *Deep Learning with Applications Using Python*, Berkeley, CA: Apress, 2018. Available: https://doi.org/10.1007/978-1-4842-3516-4

[19]A. Zhang, Z. C. Lipton, L. Mu and A. J. Smola, "Dive into deep learning," *arXiv preprint arXiv:2106.11342*, 2021. [Online]. Available: http://arxiv.org/pdf/2106.11342.pdf

[20]S. Norozpour, "Mathematical optimization of Monte Carlo simulation parameters for predicting stock prices," *Int. J. Eng. Technol. IJET*, vol. 9, no. 3, pp. 84–88, 2025, doi: 10.19072/ijet.1569085.

[21]O. Çevik, *Zaman serilerinin analizinde Box-Jenkins yöntemi ve turizm verileri üzerine bir uygulama*, Doktora Tezi, Kırıkkale Üniversitesi Sosyal Bilimler Enstitüsü, İşletme Anabilim Dalı, 1999.

[22]T. H. Naylor, T. G. Seaks and D. W. Wichern, "Box-Jenkins methods: An alternative to econometric models," *Int. Stat. Rev.*, vol. 40, no. 2, pp. 123–126, Aug. 1972, doi: 10.2307/1402755.

[23]G. E. P. Box, G. M. Jenkins, G. C. Reinsel and G. M. Ljung, *Time Series Analysis: Forecasting and Control*, 5th ed., Canada, 2016.

[24]Z. Yang and Z. Wang, "The research of Nvidia stock price prediction based on LSTM and ARIMA model," *Highlights in Business, Economics and Management*, vol. 24, pp. 896–902, 2024.

[25]A. Zhang, Z. C. Lipton, L. Mu and A. J. Smola, "Dive into deep learning," *arXiv preprint arXiv:2106.11342*, 2021. [Online]. Available: http://arxiv.org/pdf/2106.11342.pdf

[26]M. F. Bayramoğlu, *Finansal endekslerin öngörüsünde yapay sinir ağı modellerinin kullanılması: İMKB Ulusal 100 endeksinin gün içi en yüksek ve en düşük değerlerinin öngörüsü üzerine bir uygulama*, Yüksek Lisans Tezi, Zonguldak Karaelmas Üniversitesi, Sosyal Bilimler Enstitüsü, 2007.

[27] N. K. Manaswi and S. John, *Deep Learning with Applications Using Python*, vol. 1, no. 45–56, p. 228, Berkeley, CA, USA: Apress, 2018.

[28]W. S. McCulloch and W. A. Pitts, "A logical calculus of the ideas immanent in nervous activity," *Bulletin of Mathematical Biophysics*, vol. 5, pp. 115–133, 1943.

[29]B. G. Farely and W. A. Clark, "Simulation of self-organizing systems by digital computers," *IEEE Trans. Prof. Group Inf. Theory*, vol. PGIT-4, pp. 76–84, 1954.

[30]Q. Bouma, "Glacial isostatic adjustment forward model with a convolutional neural network," unpublished.

[31]E. Albayrak and N. Saran, "İstatistiksel ve derin öğrenme modellerini kullanarak hisse senedi fiyat tahmini," *Türkiye Bilişim Vakfı Bilgisayar Bilimleri ve Mühendisliği Dergisi*, vol. 16, no. 2, pp. 161–169, 2023.

[32]M. E. Tağluk and M. O. Duman, "Yapay sinir ağı modelleri ile hisse senetlerinin değişim tahmininde farklı düğüm sayıları, zaman çerçeveleri ve aktivasyon fonksiyonlarının etkisinin araştırılması," *unpublished*.

[33]M. İlkçar, "Turkish Airlines BIST share price prediction with deep artificial neural network considering trading volume and seasonal values," *Int. J. Informatics Technol.*, vol. 16, no. 1, pp. 43–53, 2023.

[34]Wikipedia, "Long short-term memory – Peephole convolutional LSTM," https://en.wikipedia.org/wiki/Long_shortterm_memory#Peephole_convolutional_LSTM, Accessed Jan. 18, 2024.

[35]M. Tuna, *Altın fiyatlarının yapay sinir ağları ve ARMA modelleri ile tahminlenmesi*, Yüksek Lisans Tezi, Adnan Menderes Üniversitesi, Sosyal Bilimler Enstitüsü, Ekonometri Anabilim Dalı, 2019.

[36]M. F. Tüzen, *Türkiye turizm gelirinin öngörüsünde zaman serilerinin bileşenlerine ayrıştırılarak yapay sinir ağları ve box-jenkins yöntemleri ile karşılaştırmalı analizi*, Yüksek Lisans Tezi, Sosyal Bilimler Enstitüsü, 2012.

TEZDEN ÜRETİLMİŞ YAYINLAR

Konferans Bildirileri

1. M.Ergurum, E.Çene, "Borsa Analizi ve Tahmini İçin Derin Öğrenme Ağları" 22th INTERNATIONAL SCIENTIFIC RESEARCH CONGRESS-SCIENCE AND ENGINEERING –(UBAK) – 2025 8-9 Mart 2025, İstanbul, Türkiye.