

T.C.

BOLU ABANT İZZET BAYSAL ÜNİVERSİTESİ

LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

BİLGİSAYAR MÜHENDİSLİĞİ ANA BİLİM DALI



**MENKULLER KIYMETLERİN DEĞERLERİNİ BELİRLİ
VADELERDE DEĞER TAYINI YAPAY ZEKÂ
YÖNTEMLERİNİ HİBRİT OLARAK KULLANILARAK ELDE
EDİLMESİ**

BİLGİSAYAR MÜHENDİSLİĞİ YÜKSEK LİSANS TEZİ

NEZAKET ÖZLEM YÜCEL

TEZ DANIŞMANI

PROF. DR. MURAT BEKEN

BOLU, TEMMUZ 2025

KABUL VE ONAY SAYFASI

Nezaket Özlem YÜCEL'in kaleme aldığı “MENKULLERİN DEĞERLERİNİ BELİRLİ VADE SÜRELERİNDE YAPAY ZEKÂ YÖNTEMLERİNİ HİBRİT OLARAK KULLANARAK TAHMİN ETME” başlıklı tez çalışması, jürimiz tarafından Bilgisayar Mühendisliği Ana Bilim Dalı Bilgisayar Mühendisliği Programında yüksek lisans olarak oy çokluğuyla kabul edilmiştir. 25/07/2025

Jüri Üyeleri

İmza

Danışman

Prof. Dr. Murat BEKEN

Üye

Doç. Dr. Önder EYECİOĞLU

Üye

Dr. Öğr. Üyesi İlhan GARİP

Lisansüstü Eğitim Enstitüsü Onayı

Prof. Dr. İbrahim KÜRTÜL

Lisansüstü Eğitim Enstitüsü Müdürü

ETİK BEYAN

Bolu Abant İzzet Baysal Üniversitesi, Lisansüstü Eğitim Enstitüsü Tez Yazım Kılavuzu ve Şablonuna uygun olarak hazırladığım bu tezde;

➤ Tezde kullanılan kaynaklar ve materyaller, veri ve belgelerin içeriğinde sağlananlardır, içeriğinde mevcut olanlar dışında ne tam ne de eksik veri veya belge kullanmadım. "Bilimsel etik ve ahlaki yasalara uymak için tüm bilgi, belge, değerlendirme ve sonuçları sundum.

➤ Tezde kullandığım tüm kaynakları doğru bir şekilde belirttim.

➤ Verilere hiçbir şey yapılmadı, kullandım.

➤ Bu tezde yer alan materyalin kendi çalışmam olduğunu ve başkalarının spekülâtif temeldeki çalışmalarını içermediğini ve kursun başlangıcında Victoria'ya, başka bir sınav veya değerlendirme biçimine dönüştürülmesi için herhangi bir izin alınabilir olduğunu doğruluyorum.

.....
NEZAKET ÖZLEM YÜCEL

ÖZET

**MENKULLER KIYMETLERİN DEĞERLERİNİ BELİRLİ
VADELERDE DEĞER TAYINI YAPAY ZEKÂ YÖNTEMLERİNİ HİBRİT
OLARAK KULLANILARAK ELDE EDİLMESİ
YÜKSEK LİSANS TEZİ
NEZAKET ÖZLEM YÜCEL
BOLU ABANT İZZET BAYSAL ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
BİLGİSAYAR MÜHENDİSLİĞİ ANA BİLİM DALI
BİLGİSAYAR MÜHENDİSLİĞİ YÜKSEK LİSANS PROGRAMI
(TEZ DANIŞMANI: PROF.DR. MURAT BEKEN)**

BOLU, TEMMUZ – 2025

XI + 68

Finansal piyasaların artan oynaklığı ve klasik analizlerin sınırlamaları, veri odaklı ve hesaplamalı yöntemleri yatırım fonu performans değerlendirmesinde gerekli kılmaktadır. Bu çalışma, Türkiye’deki yatırım fonlarını teknik analiz göstergeleri ve yapay zekâ tabanlı tahmin modelleri ile değerlendirmeyi amaçlamaktadır. Çalışma, Hisse Senedi ve Kıymetli Maden Şemsiye Fonları veri setleri kullanılarak iki aşamada yürütülmüştür. Takasbank ve KAP’tan elde edilen veriler; tarihsel fiyatlar, günlük getiriler, yatırımcı sayıları ve portföy değerlerinden oluşmaktadır. İlk aşamada teknik analiz göstergeleri (MA20, MA50, StdDev20, korelasyon matrisi) kullanılmış, ikinci aşamada ise LSTM modeli ile tahmin yapılmıştır. Veriler Min-Max normalizasyonu ile ölçeklendirilmiş, performans MSE, MAE ve R^2 metrikleriyle ölçülmüş, 5 katlı çapraz doğrulama uygulanmıştır.

Sonuçlar, bazı fonların teknik analiz veya LSTM ile istikrarlı biçimde tahmin edilebildiğini, bazılarının ise yüksek dalgalanmalar nedeniyle riskli olduğunu göstermiştir. Böylece, çalışma teknik analiz ve tahmin modellerinin birlikte kullanılabileceğini ortaya koyarak literatüre katkı sunmaktadır.

ANAHTAR KELİMELER: Yatırım Fonu, Teknik Analiz, LSTM, Hibrit Model, Yapay Zekâ

ABSTRACT

DETERMINING THE VALUES OF MOVABLE ASSETS AT SPECIFIC TERMS USING HYBRID ARTIFICIAL INTELLIGENCE METHODS

MSC THESIS

NEZAKET ÖZLEM YÜCEL

BOLU ABANT İZZET BAYSAL UNIVERSITY

INSTITUTE OF GRADUATE STUDIES

DEPARTMENT OF COMPUTER ENGINEERING

(SUPERVISOR: PROF DR MURAT BEKEN)

BOLU, JULY 2025

XI + 68

The increasing volatility of financial markets and the limitations of classical analyses make data-driven and computational methods essential for evaluating investment fund performance. This study aims to evaluate investment funds in Türkiye using technical analysis indicators and artificial intelligence-based forecasting models. The study was conducted in two stages using datasets from Equity and Precious Metals Umbrella Funds. Data obtained from reliable sources such as Takasbank and the Public Disclosure Platform (KAP) include historical prices, daily returns, the number of investors, and total portfolio values. In the first stage, technical analysis indicators (MA20, MA50, StdDev20, correlation matrix) were applied; in the second stage, predictions were made using the LSTM model. The data were scaled using Min-Max normalization, and the model performance was evaluated using MSE, MAE, and R^2 metrics, with 5-fold cross-validation applied.

The results showed that some funds could be consistently predicted using technical analysis or LSTM, while others were riskier due to high fluctuations. Thus, this study contributes to the literature by demonstrating that technical analysis and forecasting models can be used together.

KEYWORDS: Investment Fund, Technical Analysis, Hybrid Model, Artificial Intelligence (AI), Long Short-Term Memory (LSTM)

İÇİNDEKİLER

	Sayfa
ÖZET	iv
ABSTRACT	v
İÇİNDEKİLER	vi
ŞEKİL LİSTESİ.....	ix
TABLO LİSTESİ.....	x
ÖNSÖZ	xi
1. GİRİŞ.....	1
1.1 Çalışmanın Önemi	1
1.2 Araştırma Problemi ve Hipotezler	2
1.3 Metodoloji ve Veri Kaynakları	2
1.4 Çalışmanın Sınırlamaları ve Kapsamı	3
2. MATERYAL ve YÖNTEM.....	5
2.1 Menkul Kıymetlerin Kavramı ve Türleri	6
2.2 Hisse Senetleri ve Tahviller	10
2.2.1 Hisse Senedi.....	10
2.2.2 Tahviller	11
2.3 Finansal Analizin Temel Yönleri.....	13
2.3.1 Bilanço	13
2.3.2 Gelir Tablosu	14
2.3.3 Nakit Akış Tablosu.....	15
2.3.4 Karlılık Oranları	16
2.3.5 Likidite Oranları	16
2.3.6 Risk Analizi	17
2.3.7 Özsermaye Karlılığı	17
2.4 Piyasa Değeri Belirleme Yöntemleri.....	18
2.5 Geleneksel Finansal Modelleme Yaklaşımları	18
2.5.1 İndirgenmiş Nakit Akış (DCF) Modeli.....	18
2.5.2 Karar Ağaçları (Decision Trees)	19
2.5.3 Karşılaştırılabilir Şirket Analizi (CCA):.....	19
2.5.4 Önceki İşlem Analizi (PTA).....	20
2.5.5 Finansal Projeksiyonlar.....	20

2.5.6 Ağırlıklı Ortalama Sermaye Maliyeti [Wacc]	20
2.5.7 Kâr Marjı Modelleri	21
2.5.8 Duyarlılık ve Senaryo Analizi	22
2.5.9 Kapanış Fiyatı ve Piyasa Değeri Yöntemi.....	22
3. BULGULAR.....	23
3.1 Yapay Zekanın Prensibi ve Gelişimi	23
3.1.1 Yapay Zekâ (YZ): Genel Bakış ve Tarihsel Gelişim.....	23
3.1.2 Erken Dönem ve Tabanlı Sistemler	23
3.1.3 Makine Öğrenimi ve Derin Öğrenme Çağı	24
3.1.4 Bugün Yapay Zekâ.....	24
3.2 Finansal Tahminde Yapay Zekâ Yöntemleri	24
3.2.1 Makine Öğrenimi	25
3.2.2 Derin Öğrenme Modelleri.....	25
3.2.3 Doğal Dil İşleme (NLP).....	27
3.2.4 Optimizasyon ve Genetik Algoritmalar Yöntemleri.....	28
3.3 AI Desteklenmiş Risk Analizi ve Değerleme Modelleri	28
3.3.1 Kredi Riskleri.....	30
3.3.2 Dolandırıcılıkların Tespiti ve Nitelik Tespiti	30
3.3.3 Portföyün Analizi ve Piyasanın Riski	30
3.3.4 Düzenleyici ve Etik Değerlendirmeler	31
3.4 Finansal Alanda Hibrit Modeller	31
3.4.1 Modelin Entegrasyonu	32
3.4.2 Bayes + Regresyon.....	33
3.4.3 Dikkat Mekanizmalarıyla beraber GRU-LSTM Hibrit Modeli.....	33
3.5 Hibrit Model Önemi ve Kavramı.....	34
3.5.1 Karar Ağaçları ile Sinir Ağlarının Birleştirilmesi	34
3.5.2 Optimizasyon Tekniklerinin Entegrasyonu ile Bulanık Mantık	34
3.5.3 Hibrit Modellerin Başarılı Tahminleri ve Uygulama Senaryoları	35
3.6 Hibrit Modelde Kullanılan Teknikler	35
3.6.1 Derin Öğrenimi ve Makine Öğrenmesi Hibriti	35
3.6.2 Finansal Haber Analizi ve Doğal Dil İşleme.....	36
3.6.3 İstatistiksel, Yapay Zekâ Entegratif Yaklaşımlar	37

3.7 Güvenlik Değerlemesi için Hibrit Modelleme.....	37
3.7.1 GRU-LSTM-Dikkat Entegrasyonu.....	37
3.7.2 Model Performansının Değerlendirilmesi	38
3.7.3 Karar Verme Üzerindeki Finansal Etkisi.....	38
4. TARTIŞMA.....	39
4.1 Model Tasarımı ve Araştırma Yöntemi	39
4.2 Veri Kaynakları ve Veri Kümesi	39
4.3 Kullanılan Yapay Zekâ ve Hibrit Modeller	42
4.4 Model Eğitimi ve Parametre Ayarlaması	46
4.5 Test ve Doğrulama Süreci	48
4.6 Sonuçların Karşılaştırılması ve Analizi.....	49
5. SONUÇ VE ÖNERİLER.....	538
5.1 Çalışmanın Bulguları ve Değerlendirmesi	58
5.2 Modelin Güçlü ve Zayıf Yönleri	59
5.3 Finansal Sektöre Katkıları ve Uygulamaları	60
5.4 Gelecek Çalışmalar İçin Öneriler	61
KAYNAKLAR	63

ŞEKİL LİSTESİ

	Sayfa
Şekil 3.1. Derin Öğrenme Modeli ile Zaman Serisi Tahmini için Geliştirme Süreci Akış Şeması.....	31
Şekil 4.1. LSTM Tahmini için TI3 Fonu	43
Şekil 4.2. LSTM Tahmini için GGK Fonu	44
Şekil 4.3. LSTM Modelin Çıkışı (Genel)	44
Şekil 4.4. 30 Günlük Hareketli Ortalama (MA30) ile Günlük Fiyatlar Grafiği.....	45
Şekil 4.5. Model Eğitimi Sırasında Kayıp Eğrisi	47
Şekil 4.6. LSTM Test Performansı Grafiği	49
Şekil 5.1. Korelasyon Matrisi GL1	53
Şekil 5.2. Korelasyon Matrisi TI2	54
Şekil 5.3. Korelasyon Matrisi TI3	55
Şekil 5.4. Korelasyon Matrisi GGK	56
Şekil 5.5. Korelasyon Matrisi HBF	57
Şekil 5.6. Korelasyon Matrisi MKG	57

TABLO LİSTESİ

	Sayfa
Tablo 4.1. Teknik Göstergelerin Kısaltmalarının Açıklamaları	39
Tablo 4.2. Çalışmadaki Yatırım Fonları ve Kısaltmaları	40
Tablo 4.3. Veri Madenciliği ve Tahmin İçin Kullanılan Göstergeler Yöntemi ve Tanımı.....	41
Tablo 4.4. LSTM modelini eğitmek için parametreler.....	47
Tablo 4.5. LSTM modelini kullanarak fon performans tahminlerinin hata metrikleri ve grafik uyumluluk seviyeleri	51

ÖNSÖZ

Günümüz finansal piyasalarının yapısı son derece dalgalıdır ve daha öngörülebilir ve bilimsel bir şekilde yatırım kararları almak kaçınılmazdır. Bu bağlamda, finansal analizde yapay zekâ tekniklerinin benimsenmesi, bugün yatırım stratejilerinin oluşturulmasında gerekli bir bileşen olarak görülmektedir. Bu yüksek lisans tezinde, belirli vade tarihlerindeki menkul kıymetlerin değerini tahmin etmede Hibrit AI modellerinin performansı incelenmiş ve Finansal Karar Sistemlerini destekleyebilecek analizlerle birlikte çalışılmıştır.

Öncelikle, saygıdeğer danışmanım Prof. Dr. Murat BEKEN’e, tezimin ve akademik hayatın her aşamasında bana geniş bilgi birikimi ve tecrübesiyle rehberlik ettiği için teşekkür etmek istiyorum. Ayrıca, bu süreçte bana sevgi ve sabırla destek olan ailem ve ilhamım olan tatlı kızım Defne’ye içten teşekkürlerimi sunmak istiyorum.

Bu tezin, finansal analiz ve yapay zekâ konularında daha fazla araştırma yapmak isteyen araştırmacılar ve uygulayıcılar için iyi bir referans sunabilmesini umuyorum.

Nezaket Özlem YÜCEL

25/07/2025

1. GİRİŞ

1.1 Çalışmanın Önemi

Yaşadığımız dünyada, finansal piyasalardaki artan belirsizlik ve oynaklık nedeniyle, yatırımcılar sadece temel analize güvenmemelidir; teknik analiz ve yapay zekâ tabanlı modellere yönelmelidirler. Bu bağlamda, sinyaller giderek daha önemli hale gelmekte ve bu tür oynak bir ortamda, yatırım gruplaması üzerinde işlenen teknik çalışmalar ve fiyat tahminleri hızla ilerlemektedir. Bu alanda literatürde birçok çalışma yapılmıştır. Örneğin, LSTM ağlarının finansal zaman serisi tahmininde rakip yöntemleri geride bıraktığını kanıtlamaktadır. Çift aşamalı dikkat tabanlı LSTM modelinde zaman ve özellik alanında bir dikkat mekanizmasıyla tahmin performansını artırmıştır (Qin, Y., Song, D., Chen, H., Cheng, W., Jiang, G., & Cottrell, G. W. (2017)).

Türkiye'de, (Altay, E., & Satman, M. H. (2005)), BIST endeksi için teknik göstergelerdeki tahmin performansını incelemiş, lakin yatırım fonlarına dikkat etmemiştir (Altay, E., & Satman, M. H. (2005)). Bu çalışmanın benzer çalışmalardan farkı, Türkiye'de faaliyetini gösteren, hisse senedi değerli maden tabanlı yatırım fonları için teknik analiz göstergeleri (MA20, MA50, oynaklık, standart sapma, günlük getiri vb.) ve LSTM tabanlı tahmin modelini bütünleşmiş bir şekilde değerlendirmesidir. Ayrıca, fon verilerini Python programlama dilinde işledik ve net yüksek çözünürlüklü görüntüler ve sayılarla iletişim kurduk. Bu bağlamda, çalışma, görsel analizin yapay zekâ ile entegre edildiği hibrit bir yöntem sunmaktadır.

Bu tezin temel hedefleri, zaman serileri üzerinde teknik analiz yoluyla çeşitli fonların performansını değerlendirmek ve LSTM tabanlı modellerle geleceğin kısa vadeli fiyatını tahmin ederek karar verme sürecini güçlendirmektir. Bu çalışmada, her fon öncelikle teknik analiz grafiklerini kullanarak analiz edildi ve grafikler, fonların geçmişte ne olduğunu bulmak için yorumlandı. Daha sonra, seçilen zaman dilimi için fonların bir gün öncesine ait fiyat tahminleri LSTM sinir ağı modeli kullanılarak gerçekleştirildi ve karşılaştırmaları yapıldı. Bu nedenle, bu tez, yatırım fonlarının teknik analizi için görsel ve istatistiksel girdiler

oluşturmakta ve yatırım alanında makine öğrenimi tabanlı tahmin sistemlerinin somut uygulamasını göstermektedir.

1.2 Araştırma Problemi ve Hipotezler

Borsa yatırımları, hisse senedi fiyatlarının geçmiş hareketlerine dayanır. Ancak, yatırım fonları gibi karmaşık finansal araçlar söz konusu olduğunda, klasik analiz yöntemleriyle tahmin edilebilirliği oldukça zor olabilir, çünkü yüksek oynaklık, piyasa duyarlılığı ve dış ekonomik faktörlere açıklık gibi nedenler vardır. Bu bağlamda, (1) teknik analiz göstergeleri ve (2) yapay zeka tabanlı modellerin entegrasyonu, fon performans değerlendirmesi ve tahmin kalitesini artırmak için gereklidir.

Bu çalışmada araştırılan konular şunlardır:

"Türkiye'deki farklı türlere ait yatırım fonlarının performanslarını, LSTM tabanlı yapay zekâ modelleri ve teknik analiz göstergeleri kullanarak karşılaştırabilir miyiz?"

Bu problem formülasyonunda, teknik analiz araçlarının fonların hareketlerini ne kadar iyi açıklayabileceğini ve LSTM gibi derin öğrenmenin kısa vadeli tahminleri ne kadar iyi yapabileceğini incelemeyi amaçlıyoruz. Ayrıca, farklı yatırım fonu kategorilerinin (örneğin, hisse senedi tabanlı fonlar ve değerli metal fonları) teknik göstergeler ve yapay zekâ modelleri açısından nasıl farklılık gösterdiğini araştırıyoruz.

1.3 Metodoloji ve Veri Kaynakları

Bu çalışmada, Türkiye'deki fonların performansını ölçmek için teknik göstergeler analizi ve yapay zekâ tahmin modelleri kullanılarak tümdengelimli bir çalışma modeli sunulması amaçlanmaktadır. Araştırma, iki ana veri üzerinde yürütülmüştür: Hisse Senedi Şemsiye Fonu ve Kıymetli Madenler Şemsiye Fonu. Bu veriler, Takasbank ve Kamuyu Aydınlatma Platformu (KAP) gibi güvenli veri kaynaklarından toplanmış olup, tarihsel fiyatlarını, fon sahiplerinin sayısını ve tüm fonların portföylerini içermektedir.

Veri analizi iki aşamada gerçekleştirilmiştir:

(1) Teknik Analiz Aşaması: Fonların MA20, MA50, standart sapma (StdDev20), volatilité ve günlük getirilerini hesaplamak için zaman serileri alınmıştır. Bu faktörler, fonların kısa ve uzun vadeli davranışlarını, risk ve getiri dağılımını yakından incelemek için kullanılmıştır. Fonlar arasındaki etkiyi incelemek için korelasyon matrisi de oluşturulmuştur.

(2) Yapay Zekâ ve Tahmin Aşaması: Zaman serisi verilerinin tahmini LSTM kullanılarak gerçekleştirilmiştir. Tarihsel fon fiyatı zaman serileri LSTM ağına girilmiş, gelecekteki fiyat kısa vadeli tahmin edilmiştir.

Modelin performansı, performans kriterleri açısından şu şekilde değerlendirilmiştir: MSE (ortalama kare hatası), MAE (ortalama mutlak hata) ve R-kare (R^2). Herhangi bir analizden önce, veriler model öğrenme rutinine uygun hale getirilmek üzere min-max normalizasyonu ile normalize edilmiştir. Python dili, çalışmanın sürecinde oluşturduğumuz çerçeve (temel) ile, çalışmanın ilgili bölümlerinde tüm fon görüntülerini (mum çubuk diyagramları, hareketli ortalama diyagramları, getiri histogramları, ...) almak ve görselleştirmek için sayfasında izin vermiştir.

1.4 Çalışmanın Sınırlamaları ve Kapsamı

Buradaki tez çalışmasında, Türkiye'de çalışan yatırım fonlarının performansını analiz etmek için teknik analiz teknikleri ve zaman serisinin yapay zekâ tabanlı tahmin modelleri kullanılmıştır.

İki daha kapsayıcı fon kategorisi, Kıymetli Madenler Şemsiye Fonları ile Hisse Senedi Şemsiye Fonları da tartışılmıştır. Buradaki gruplar aynı portföy ve yatırım yapısına, tutumuna sahip olmadığından, uygun bir referans örneği olmayacaklardır.

Araştırma çalışmasında, tarihsel fiyat serilerine dayalı teknik analiz göstergeleri (örneğin hareketli ortalamalar, volatilité, standart sapma, günlük getiri, vb.) ile yatırımcı sayısı ve toplam fonların portföy değerleri hesaplanmış ve ardından LSTM tabanlı modeller gibi derin öğrenme stratejileri kullanılarak kısa vadeli fiyat tahmin edilmiştir.

Diğer derin öğrenme yöntemleri (örneğin, GRU, transformer) genişleme kapsamı dışında bırakılmıştır. Yatırım fonu seçimi, veri kalitesi ve sürekliliğine dayalı olarak yapılmış olup, Türkiye'nin tüm yatırım fonlarını içermeyebilir. Teknik analizdeki göstergeler, bazı önceden belirlenmiş standart parametrelerle (yani, MA20, MA50) hesaplanmış olup, parametre varyasyonu ve optimizasyonu bu makalede ele alınmamıştır.

Tahminler, veri setlerinin geçmişine dayalı olarak geçerlidir, bu nedenle piyasadaki aşırı koşullar (krizler, beklenmedik yasa değişiklikleri vb.) modelin tahminini etkileyebilir. Bu kapsam ve sınırlamalar bağlamında, çalışmanın katkısı, Türkiye'deki yatırım fonlarının analizine akademik ve pragmatik bir perspektiften bir boşluğu doldurmaktır. Ayrıca, benzer yapıya sahip gelişmekte olan ülkeler için karşılaştırmalı testlere olanak tanır. Bu denklem, borsa listesinde yer alan firmaların piyasa değerinin gerçek zamanlı tahmininde bir ölçüt niteliğindedir

2. MATERYAL ve YÖNTEM

Menkul kıymetlerin doğru değerlemesi, yatırımcının rasyonel ve bilgili yatırım kararları alabilme yeteneğinde önemli bir faktördür. Finansal analiz, yatırım kararlarına sistematik bir yaklaşım olarak, şirketlerin finansal yapısını, kârlılığını, likiditesini ve borçluluk seviyesini göstererek yatırım fırsatlarının mevcut olduğu bu bağlamda ortaya çıkar.

Finansal analizde yaygın olarak kullanılan üç finansal tablo vardır: bilanço, gelir tablosu ve nakit akış tablosu. Bu tabloları inceleyerek, yatırımcıların bir şirketin finansal sağlığını, varlıkların bileşimini, borçları geri ödeme yeteneğini ve işletme verimliliğini değerlendirmesi mümkündür (Lestusen ve diğerleri, 2023). Bu bağlamda, finansal oran analizleri, şirketin geçmiş performansının değerlendirilmesi ve geleceğe yönelik beklentilerin oluşturulması için değerli araçlardır.

Finansal analizdeki oranlar ve formüller şunlardır.

Likidite Oranları

- **Cari Oran**

$$Cari Oran = \frac{Dönen Varlıklar}{Kısa Vadeli Yükümlülükler} \quad (2.1)$$

- **Asit-Test Oranı:**

$$Likidite Oranı = \frac{Dönen Varlıklar - Stoklar}{Kısa Vadeli Yükümlülükler} \quad (2.2)$$

a. Kârlılık Oranları

- **Net Kâr Marjı:**

$$Net Kar Marjı = \frac{Net Kar}{Net Satışlar} \quad (2.3)$$

- **Varlık Getirisi (ROA):**

$$ROA = \frac{Net Kar}{Toplam Aktifler} \quad (2.4)$$

Ancak, bölge için ROA %0,39 ile karşılaştırma ölçütü için neredeyse aynıdır.

- **Özsermaye Karlılığı (ROE)**

$$ROE = \frac{Net Kar}{Özsermaye} \quad (2.5)$$

b. Kaldıraç ve Borç Oranı

- **Borç/Özsermaye Oranı:**

$$\text{Borç Özsermaye} = \frac{\text{Toplam Borç}}{\text{Özsermaye}} \quad (2.6)$$

- **Finansal Kaldıraç Oranı:**

$$\text{Kaldıraç} = \frac{\text{Toplam Varlıklar}}{\text{Özsermaye}} \quad (2.7)$$

Finansal analiz sadece rakamlarla ilgili değildir. Yatırım kararları, makroekonomik faktörler, sektör faktörleri ve jeopolitik olaylar gibi niteliksel faktörlerden de büyük ölçüde etkilenir.

Finansal analiz, teknik ve temel analiz gibi daha geleneksel yöntemlerle birlikte kullanıldığında, yatırımcının gelecekteki bilgileri daha iyi tahmin etmesine olanak tanır. Teknik analiz, geçmiş fiyat hareketlerine bağlı olarak nereye hareket edeceğini tahmin etmeye çalışırken, bizim görüşümüze göre, temel analiz, bir şirketin içsel değerini belirlemek için finansal ve ekonomik verilere dayanan bir yatırım stratejisidir.

Bu bağlamda, finansal alanda hibrit yapay zekâ modellerinin uygulanması, özellikle büyük verilerin ve değişkenler arasındaki karmaşık ilişkilerin ele alınması için yatırımcılara çeşitli avantajlar sunar. Yatırımcıların kararları, finansal oranlar ile dış faktörler arasında anlamlı bağlantılar kurularak da desteklenebilir, bu bağlantılar makine öğrenme algoritmaları tarafından keşfedilebilir.

2.1 Menkul Kıymetlerin Kavramı ve Türleri

"Menkul kıymetler" terimi, genel olarak mülkiyet veya alacaklı ilişkilerini belgeleyen, sermaye yatırımlarını teşvik etme ve ekonomik kalkınma sağlama araçları olan finansal araçları ifade eder. Ekonomide farklı işlev ve amaçlara sahip farklı türde menkul kıymetler bulunmaktadır. İşte menkul kıymetlerin temel unsurları ve türlerinin bir dökümü.

Menkul kıymetlerin tanımı genellikle ticarete uygunlukları, değer temsil etme yetenekleri ve sahiplerine sundukları haklarla ilgilidir (Grishin, 2023) (Zi, 2022). Menkul kıymet terimi, uluslararası yasal dolaşıma tabi olan, mülkiyet (alacaklı) ilişkilerini temsil edebilen menkul kıymetlerden oluşan bir dizi müzakere edilebilir aracı ifade eder ve belge akışı, sabitlik ve üçüncü şahıslara karşı öncelik gibi unsurlar içerir (Grishin, 2023).

Menkul kıymetler, bankalar gibi otoriteler tarafından ihraç edilen, parasal değere sahip finansal araçlar veya varlıkları ifade eder. Kötüye kullanılmaktan kaçınmak için çok katı yasal kurallara tabidirler ve bankacılıkta güvenli işlem garantisi sağlamak için anlaşmalar olarak hizmet ederler (Sultan & Laili, 2023).

Menkul kıymetler, günümüzde mülkiyet değişiminin bir parçası olan çeşitli mülkiyet biçimlerini temsil eden yasal belgelerdir. Ayrıca sermaye oluşumunu ve yatırımı sağlamak, ekonomik verimliliği artırmak ve piyasa ilişkilerini geliştirmek için tasarlanmıştır, ancak risklerle doludur ve katılımcıları korumak için net yasal düzenleme ve denetim gerektirir (Mishchuk & Bytko, 2022).

Menkul kıymetler, hisse senetleri gibi öz sermaye menkul kıymetleri ve tahviller gibi borç menkul kıymetleri olarak ikiye ayrılır. Bireysel yatırım menkul kıymetlerini (örneğin, hisse senetleri, ipotek sertifikaları) ve kolektif yatırım menkul kıymetlerini (yatırım payları, tahviller, opsiyonlar vb. şeklinde) içerirler (Inshakova & Goncharov, 2017).

Menkul kıymetler, ihraç edildikten sonra sahibinin haklarına göre alt bölümlere ayrılır, yani menkul kıymeti bilançonun bir kısmına gerçekten bağlar:

Hamiline menkul kıymetler:

Müzakere edilebilir ve sahibine menkul kıymet altındaki hakları verir (örneğin, bir borç menkul kıymeti ise ödeme, öz sermaye ise şirket kârlarına katılım ve oy hakları).

Sermaye için güvence olarak hisse senetleri, anonim şirkette mülkiyeti temsil eder ve şu sınıflar altında ihraç edilebilir (Zençis, 2024):

- I) — tercihli,
- II) — adi ve
- III) — imtiyazlı (Zençis, 2024).

Menkul kıymetler, iki kategoriden birine girer: borç menkul kıymetleri (devlet veya şirket tahvili gibi) ve öz sermaye (adi hisse senetleri veya yatırım fonları gibi). Her türün ticaret ve mülkiyet hakkı ile ilgili çeşitli özellikleri ve yasal sonuçları vardır (Halitoğlu, 2020).

Genel olarak konuşursak, yatırım menkul kıymetleri, pazarlanabilirlik, değer temsil etme yeteneği, getiri sağlama ve mülkiyet hakları veya alacaklı hakları

sağlama gibi temel özelliklere sahip finansal araçlardır (Grishin, 2023; Zi, 2022). Bu araçlara hem ulusal hem de uluslararası yasal kontroller uygulanır. Bu kontroller, menkul kıymetlerin kötüye kullanılmasını önlemek için önleyici tedbirleri de içerir (Sultan & Laili, 2023).

Menkul kıymetler esas olarak iki türe ayrılır:

Mülkiyet hisse senetleri: adi ve imtiyazlı hisse senedi.

Öz sermaye: Bir şirkette mülkiyet.

Hissedarlar, bazı hisse senedi türlerinde temettü alabilir ve bazı şirket meselelerinde oy kullanabilir (Rini, 2002) (Zençis, 2024).

- Hisse Getirisi Hesaplama:

$$Toplam\ Getiri = \frac{(Fiyat_{son} - Fiyat_{ilk}) + Temettü}{Fiyat_{ilk}} \times 100 \quad (2.8)$$

Burada:

İlk Fiyat: Dönem başlangıcındaki hisse fiyatı.

Kapanış Fiyatı: Dönem sonundaki hisse fiyatı

Temettü: Dönem boyunca ödenen temettü.

Bu menkul kıymetler, yatırımcılara şirket yönetiminin bir parçası olma ve mevcut piyasa koşullarında sermayenin büyümesi hakkını sağlar (Rini, 2002, Zençis, 2024).

Borç Menkul Kıymetleri:

Borç araçları veya menkul kıymetler, şirketler veya fonlara ihtiyaç duyan diğer hükümet seviyeleri tarafından ihraç edilir. Yatırımcılara faiz ödenir ve yatırım süresi sonunda tam ana para iadesi yapılır (Rini, 2002) (Inshakova & Goncharov, 2017).

- Tahvil Faiz Hesaplama (Basit):

$$Faiz\ Getirisi = Anapara \times Faiz\ Oranı \times Vade \quad (2.9)$$

- Etkin Faiz Oranı (Yıllık Bileşik):

$$R_{eff} = (1 + \frac{i}{n})^n - 1 \quad (2.10)$$

Burada:

i: nominal faiz oranı

n: yılda yapılan ödeme sayısı

Tahviller, getirileri önceden belirlenmiş olduğu için düşük riskli yatırım seçenekleri olarak kabul edilir (Inshakova & Goncharov, 2017; Rini, 2002).

Türevler: Opsiyonlar ve vadeli işlemler, yatırımcıların riski en aza indirmek veya fiyat hareketlerinden yararlanmak için kullandıkları iki türev sözleşmedir (Rini, 2002). Popüler varyantlar vadeli işlemler, opsiyonlar ve takaslar.

Tahviller sabit getiri sunmalarıyla düşük riskli yatırım arasındaki alternatifler değerlendirilir (Inshakova & Goncharov, 2017; Rini, 2002).

- Alım Değeri Formülü (Black – Scholes Temel Formülü):

$$C = S_0 N(d_1) - X e^{-rt} N(d_2) \quad (2.11)$$

Burada:

C: Alım değeri

S_0 : Mevcut tarihteki varlık maliyeti

X: Kullanım fiyatı

t: Vadede kalan süre

r: Riski olmayan faiz oranı

N(d): Normal dağılım fonksiyonu

Türev ürünler, yatırımcılara yüksek getiri ve yüksek risk fırsatı sunar (Rini, 2002) çünkü karmaşık fiyatlandırma sistemleri ve yüksek kaldıraçları vardır.

➤ Menkul Kıymetlerin Diğer Sınıflandırmaları

• Hamiline Menkul Kıymetler:

Herhangi bir isim üzerinde kaydı olmayan ve yasal mülkiyet veya elinde bulunduran kişiye ait olan menkul kıymetlerdir.

• Kayıtlı Menkul Kıymetler:

Belirli bir kişiye ait olan ve devredilebilmesi için adlarına kayıtlı olması gereken menkul kıymetlerdir.

- **Varantlar:**

Belirlenmiş bir tarihte veya öncesindeki belirli bir fiyatla menkul kıymeti satın alma veya satma hakkı veren türev araçlardır.

- **Yatırım Fonu:**

Küçük bireysel yatırımcılara yatırımların bir araya getirilmesiyle portföy çeşitlendirme fırsatı sunar (Halitoğlu, 2020). Bu çeşitlilik, yatırımcılara belirli risk-getiri kombinasyonlarına bağlı olarak stratejiler izleme imkânı tanır.

Menkul kıymetler, ekonominin finansman damarlarının iyi çalışmasını garanti etmekle kalmaz, aynı zamanda tasarruf sahiplerinin fonlarını sermayeye dönüştürmede aracılık eder.

2.2 Hisse Senetleri ve Tahviller

Hisse senetleri ve tahviller, menkul kıymetler piyasasının özüdür, yatırımcıların risk ve getiri beklentilerine uygun olarak menkul kıymet portföylerini yaymalarına olanak tanır ve kurumsal ve kamu sermaye oluşumunda hayati bir rol oynar. Tüm bu araçlar, ekonomik kalkınmanın finansmanında işlevsel bir amaca hizmet eder ve yatırımcılara haklar, getiriler ve riskler sunar.

2.2.1 Hisse Senedi

Hisse senetleri, bir şirketin mülkiyet paylarıdır ve sahiplerine temettü alma ve şirketin yıllık genel kurul toplantısında oy kullanma hakkı verir. Şirketler için halka açılma, yani İlk Halka Arz (IPO), sermaye tabanını büyütme ve büyüme için fon sağlama açısından önemli stratejik eylemlerden biridir (Masih & Noel, 2023). Hisse senedi piyasası, bu hisselerin alınıp satılması için ikinci bir piyasa mekanizması sunar, böylece likidite ve görünürlük artar ve fiyat oluşumu sağlanır (Yudina & Hoholiuk, 2023).

Hisse senetleri, bir işletmede mülkiyeti temsil ettikleri için çağdaş ekonominin temel bir parçasıdır. Hisse senetleri, borsa piyasaları aracılığıyla işlem görür ve risk ve getiri, faiz oranları ve piyasa davranışı tarafından etkilenir (Knoop, 2019).

Hisse Getirisi:

Yatırımcı için hisse senetlerinin iç getiri oranı iki ana bileşenden oluşur: fiyat artışı (hisse fiyatındaki değişim) ve temettüler.

$$Toplam\ Getiri = \frac{(F_{son} - F_{ilk}) + T}{F_{ilk}} \times 100 \quad (2.12)$$

Burada:

- F_{ilk} : Hisse senedinin başlangıç değeri
- F_{son} : Hisse satışında alınan fiyat
- T: Alınan temettü tutarı

Hisse Senedi Türleri

- **Adi Hisse Senetleri:** Şirket mülkiyeti, oy hakkı ve temettü hakkı verir.
- **İmtiyazlı:** Sabit temettü ve iflas durumunda öncelikli haklar sağlar, genellikle oy hakkı yoktur.

Hisse senetleri, faiz oranları, şirket performansı, sektör koşulları ve makroekonomik koşullardan etkilenir. Bu sebeple, yatırımcıların sadece nicel analizi değil, aynı zamanda iyi eski moda Temel Analiz ve Piyasa Duyarlılığını da dikkate almaları gerekir (Knoop, 2019).

2.2.2 Tahviller

Tahviller, bir şirketin veya hükümetin onlara para borç vermesine olanak tanıyan sabit getirili yatırımlardır. Tahvil sahibi, belirlenmiş aralıklarla faiz ödemeleri ve vade sonundaki anapara geri ödemesini alır. Bu çerçevede, tahvilleri kurumsal finans ve kamu finansında temel hale getirir (Kazakov & Ugli, 2024).

Tahviller, insanların faiz karşılığında ihraççıya para ödünç verdiği borç yükümlülükleridir. Sermayenin sermaye piyasasında transferine yardımcı olur ve kupon türüne (sıfır kupon, sabit, değişken) ve geri dönüş yöntemine (itfa zamanında anlaşılarak, eşit parçalarda, sürekli) göre sınıflandırılabilirler (Țilică & Ciobanu, 2023).

Finansal tahvil, periyodik faiz (kupon) ve vade sonunda anapara ödeyen bir borç menkul kıymeti biçimidir. Uzun vadeli yatırımlar ve cari harcamalar için kurumsal ve hükümet finansman sürecinde giderek daha önemli hale gelen araçlardır (Kohlmann & Xiong, 2011) (Michalski, 2016).

Tahviller, hisse senetleriyle karşılaştırıldığında, tahvil sahipleri alacaktır. Hissedarlar aslında bir şirketin sahipleridir ve piyasalar ve hisse senetleri sonsuza

kadar ödenmezken, kurumsal tahvillerin sabit bir süresi vardır (Kohlmann & Xiong, 2011).

Tahviller genellikle istikrarlı yatırımlar olarak kabul edilir, ancak faiz oranlarındaki değişiklikler ve kredi riski gibi risklerden etkilenebilir, bu da değerlerini ve gelirlerini etkileyebilir. Bu dinamiklerin nasıl çalıştığını bilmek, bilinçli yatırımlar yapılması açısından önemlidir (Kazakov & Ugli, 2024).

Tahvil Getirisi (Basit Kuponlu):

$$Yıllık\ Getiri = \frac{Faiz\ Ödemesi}{Piyasa\ Fiyatı} \times 100 \quad (2.13)$$

Tahvil Getirisi (Etkatif Faiz – YTM):

$$YTM = \frac{Faiz + \frac{(Nominal\ Değer - Piyasa\ Fiyatı)}{Vade}}{\frac{Nominal\ Değer + Piyasa\ Fiyatı}{2}} \quad (2.14)$$

Bazı Tahvil Türleri

- **Devlet tahvilleri:**

Devlet aracılığıyla desteklenir; en güvenilir tahvil çeşididir.

- **Kurumsal Tahviller:**

Şirketler aracılığıyla sunulur ve çoğunlukla faizi daha yüksek oranlara sahiptir.

- **Belediye Tahvilleri:**

Yerel yönetimler tarafından ihraç edilen ve bazı durumlarda vergiden muaf olabilir.

- **Sıfır Kupon Tahvilleri:**

Vadesi geldiğinde hiçbir ödeme yapılmaz, indirimli satılır ve vade sonunda nominal değer ödenir.

Tahvil sahipleri, şirketin alacaklıları olarak şirkete karşı hak talebinde bulunurlar, yani şirket varlıkları üzerinde öncelikli haklara sahiptirler. Hisse senetleri gibi temettüleri belirsiz değildir, tahviller belirli bir vadede ödenmek zorundadır (Kohlmann & Xiong, 2011). Ancak, faiz oranı riskleri, kredi riski ve enflasyon riski de tahvillerin değerini etkileyebilir (Michalski, 2016).

2.3 Finansal Analizin Temel Yönleri

Finansal analiz, bir şirketin finansal ve operasyonel durumunu ve performansını incelemek için istatistiksel ve kantitatif araçlar ve yöntemler kullanarak sistematik bir süreçtir. Bu analiz tekniği, stratejik karar verme sürecinde iç yöneticiler ve dış yatırımcılar için temel taş niteliğindedir ve finansal tablolar üzerinden yapılan bir dizi oran hesaplaması, trend analizi ve karşılaştırma tablolarını içerir.

Bu analiz, 3 ana finansal tabloya odaklanacaktır: Bilanço, gelir tablosu ve nakit akış tablosu.

Bu bölüm özellikle bilanço ve kâr-zarar tablosuna odaklanmaktadır. Bu model, halka açık şirketler için hisse senedi canlı değerlemesinde genellikle bir kıyaslama olarak uygulanır.

2.3.1 Bilanço

Bilanço, bir ülkenin varlıklarını, borçlarını ve öz sermaye bileşenlerini özetleyen finansal tablodur ve bir ülkenin yönetimi için önemli bir araçtır (Ball ve diğerleri, 2024).

Bilanço, toplam varlıkların toplam borçlar artı öz sermayeye eşit olduğu bir zamanda varlıkları, borçları ve öz sermayeyi gösteren bir tablodur; şirketin finansal durumunu ve performansını gösterir (Frunze, 2023).

Bilanço, bir şirketin belirli bir zamanda finansal durumunu sunan temel bir finansal tablodur.

Aşağıdaki, varlıklar, borçlar ve öz sermaye arasındaki ilişkiyi gösterir:

$$\text{Varlıklar} = \text{Yükümlülükler} + \text{Özkaynaklar} \quad (2.15)$$

Bu denklem, bir şirketin varlıklarının nasıl finanse edildiğini gösterir: ya borç olarak (borç) ya da sahibinin parasını kullanarak (hisse senedi).

Bilanço Kalemleri:

- **Varlıklar:** Hızlı varlıklar (nakit, alacaklar, stoklar), sabit varlıklar (binalar, makineler).
- **Borçlar:** Kısa vadeli borçlar (ticari borçlar, kredi borçları), uzun vadeli borçlar.

- **Sahiplerin öz sermayesi:** Ödenmiş sermaye, dağıtılmamış kârlar, rezervler.

Örnek Oranlar:

- **Cari Oran:**

$$Cari Oran = \frac{Dönen Varlıklar}{Kısa Vadeli Borçlar} \quad (2.16)$$

- **Borç/Özkaynak Oranı:**

$$Borç / Özkaynak = \frac{Toplam Borç}{Toplam Özkaynak} \quad (2.17)$$

Ancak bilanço, yatırımcılar için şirketin varlıklarının finansmanını ve finansal sağlamlığını değerlendirmek için önemli bir bilgi kaynağıdır (Ball ve diğerleri, 2024; Frunze, 2023).

2.3.2 Gelir Tablosu

Gelir tablosu, bir şirketin belirli bir dönem için gelir ve giderlerini detaylandıran ve kârlılığını gösteren önemli bir finansal belgedir. Gelir tablosunu analiz etmeyi kolaylaştırmak için analistler, gelir, satılan malların maliyeti ve işletme giderleri gibi dokuz kategoriye ayırırlar ("Gelir Tablosu", 2022). Gelir tablosu bilgisi, şirketin finansal durumu hakkında karar vermelerine yardımcı olduğu için hem iç hem de dış kullanıcılar için önemlidir (Kumari, 2024).

Gelir Tablosu Genel Yapısı:

$$Net Kar = Gelir - Giderler - Vergiler \quad (2.18)$$

Net kâr hakkında alternatif bir düşünce şekli şudur: Gelir kârınız varsa, ancak elinizde kalan miktar giderleri ve vergileri karşılamaya yetmiyorsa ve biraz para biriktirmek için yeterli değilse, net kârınız yoktur.

Ana Kalemler:

- **Satış Gelirleri**
- **Satılan Malın Maliyeti (COGS)**
- **Brüt Kâr:**

$$Brüt Kar = Satış Geliri - Satılan Malın Maliyeti \quad (2.19)$$

- **İşletme Maliyetleri:** Pazarlama, genel ve idari maliyetler ve amortisman
- **Faaliyet Kârı (EBIT):**

$$\text{Faaliyet Karı} = \text{Brüt Kar} - \text{Faaliyet Giderleri} \quad (2.20)$$

- **Vergi Öncesi Kâr / Net Kâr**

Gelir tablosu, bir şirketin ne kadar verimli çalıştığını ve kâr yapma potansiyelini ölçmek için tasarlanmıştır. Yatırımcılar ve alacaklılar, özellikle net kâr, faaliyet kârı ve kâr marjları gibi rakamlara odaklanma eğilimindedir.

Örnek Kârlılık Oranı:

- **Net Kâr Marjı:**

$$\text{Net Kar Marjı} = \frac{\text{Net Kar}}{\text{Net Satışlar}} \times 100 \quad (2.21)$$

Bu tablo, öncelikle iç kullanıcılar tarafından bütçeleme ve performans değerlendirmesi için kullanılırken, dış kullanıcılar şirketin büyüme fırsatlarını ve sürdürülebilirliğini değerlendirmek için gelir tablosuna bakarlar (Kumari, 2024; "Gelir Tablosu", 2022).

2.3.3 Nakit Akış Tablosu

Nakit Akış Tablosu, bir şirketin belirli bir dönem boyunca nakit kaynaklarını ve kullanımını gösteren finansal tablodur ve işletme, yatırım ve finansman nakit akışlarına ayrılır. Bu rapor, işletme, yatırım ve finansman faaliyetlerine ilişkin nakit akışını gösterir ve şirketin likiditesini, kısa vadeli ödeme kapasitesini ve operasyonel verimliliğini değerlendirmek için önemli bir araçtır (Mohammad, 2024).

Nakit Akış Türleri:

- **İşletme Faaliyetlerinden Nakit Akışı:** Bir şirketin ana faaliyetlerinden (satışlar, tahsilatlar, ödemeler) elde ettiği nakit.
- **Yatırım Faaliyetlerinden Nakit Akışları:** Sabit varlıkların alımı ve satımı ile yatırım menkul kıymetlerinin alımı ve satımından kaynaklanan nakit işlemleri.
- **Finansman Faaliyetlerinden Nakit Akışı:** Hisse senedi ihraç etme, borç alma veya temettü ödeme yoluyla elde edilen nakit akışları.

Serbest Nakit Akımı (FCF) Hesabı:

$$FCF = NOPAT + Amortisman - Yatırım Harcamaları - Net İşletme Sermayesi Artışı \quad (2.22)$$

2.3.4 Karlılık Oranları

Karlılık oranları, bir firmanın finansal performansının değerlendirilmesinde, yatırım kararlarında ve sektör genelinde performans karşılaştırmasında önemlidir (Mutmainah ve diğerleri, 2024).

$$Net\ Kar\ Marjı = \frac{Net\ Kar}{Net\ Satışlar} \times 100 \quad (2.23)$$

Bir şirketin gelirden elde ettiği her dolar için ne kadar kâr yaptığını gösterir.

Daha büyük bir marj, satışları kâra dönüştürmede daha büyük bir verimlilik gösterir (Monic ve diğerleri, 2024).

a. Varlık Getirisi (ROA): Bir şirketin varlıklarını kullanarak ne kadar verimli kâr elde ettiğini gösterir. Yüksek bir ROA, sağlam bir yönetimden kaynaklanır (AnNushair ve diğerleri, 2024).

$$ROA = \frac{Net\ Kar}{Toplam\ Varlıklar} \times 100 \quad (2.24)$$

Şirketin tüm varlıklarını ne kadar etkili kullandığını gösterir.

b. Öz Sermaye Getirisi (ROE): Hissedarların öz sermaye getirisi. Yüksek bir ROE, yönetim etkinliğini ve hissedarların yatırımlarının getirisini gösterir (AnNushair ve diğerleri, 2024).

$$ROE = \frac{Net\ Kar}{Özkaynaklar} \times 100 \quad (2.25)$$

Hissedarların yatırımlarının ne kadarının kâra dönüştüğünü gösterir (AnNushair ve diğerleri, 2024).

2.3.5 Likidite Oranları

Likidite oranları, Cari oran dahil olmak üzere, cari yükümlülükleri cari varlıklarla karşılama yeteneğini yansıtan nicel göstergelerdir. Daha yüksek Cari Oran, şirketin daha likit olduğunu ve dolayısıyla yükümlülüklerini iyi ödeme olasılığını gösterir (Marlina & Yudiana, 2024).

a. Cari Oran:

$$Cari\ Oran = \frac{Dönen\ Varlıklar}{Kısa\ Vadeli\ Borçlar} \quad (2.26)$$

b. Asit-Test Oranı (Likidite Oranı):

$$Asit\ Test\ Oranı = \frac{Dönen\ Varlıklar - Stoklar}{Kısa\ Vadeli\ Borçlar} \quad (2.27)$$

Daha büyük oranlar, kısa vadeli borçları karşılama yeteneğinin daha büyük olduğunu gösterirken; daha küçük oranlar, temerrüt riskinin daha büyük olduğunu gösterir.

2.3.6 Risk Analizi

Finansta risk değerlendirmesi, yatırım ve kurumsal taraftaki finansal risklerin değerlendirilmesi sürecidir. Karar vericilere, piyasa dalgalanması, kredi portföyleri ve operasyonel başarısızlıklar açısından riski daha iyi yönetmelerine yardımcı olur (EK & Reddy, 2024).

Ana Risk Türleri:

- **Piyasa Riski:** Döviz, faiz ve öz sermaye oranlarındaki dalgalanmalardan kaynaklanır.
- **Kredi Riski:** Alacakların ödenmeyeceği riski.
- **Operasyonel Risk:** İç süreçlerin başarısızlıklarından kaynaklanır.
- **Likidite Riski:** Kısa vadeli borçların zamanında ödenememesi durumudur.

a. Risk Değerlendirme Yöntemleri:

- **Beta Katsayısı (β):** Sistemik riskin ölçüsü.
- **Risk Altındaki Değer (VaR):** Belirli bir güven düzeyinde potansiyel kaybı gösterir.

2.3.7 Özsermaye Karlılığı

Öz Sermaye Getirisi (ROE), bir kârlılık oranı, bir şirketin net gelirinin hissedarların öz sermayesine bölünmesiyle elde edilir. Bir firmanın, farklı piyasa koşullarına bağlı olarak, öz sermayeyi nasıl kâr getirecek şekilde kullandığını gösterir (Jędrzejczak-Gas, 2013).

$$ROE = \frac{Net\ Kar}{Özkaynaklar} \times 100 \quad (2.28)$$

Güçlü bir ROE, genellikle iyi bir yönetimi ve sermayenin verimli kullanımını yansıtır. Ancak, bunu borçla ve sektör ortalamalarıyla birlikte değerlendirin.

2.4 Piyasa Değeri Belirleme Yöntemleri

İşletmelerin değerlemesi birçok yaklaşıma sahiptir ve her birinin artıları ve eksileri vardır. Bir yöntemin veya diğerinin benimsenmesi genellikle değerlemeye tabi olan şirketin özellikleri veya bağlamı tarafından dikkate alınır.

Bir İşletmenin Piyasa Değerinin Değerlendirme Yöntemi Gelir yaklaşımı (temelinde indirgenmiş nakit akış yöntemi ve sermaye yöntemi bulunan) ve diğer yöntemler, net varlık yöntemi, tasfiye değeri yöntemi, eş şirket yöntemi, işlem yöntemi, bir sektör katsayısı yöntemi; risk katsayılarının toplamı yöntemi, puanlama yöntemi ve ilk Chicago yöntemi gibi işletme piyasa değerini tahmin etmenin yaklaşık 10 yöntemi vardır (СМОЛОВИК, 2024).

2.5 Geleneksel Finansal Modelleme Yaklaşımları

Geleneksel finansal modelleme anlamı Finansal verileri yorumlamak ve gelecekteki performans tahmin etmek ve bilinçli kararlar almak amacıyla çeşitli yöntemler kullanılır. Bu modeller genellikle finansal ve planlama amaçları için oluşturulur.

2.5.1 İndirgenmiş Nakit Akış (DCF) Modeli

İndirgenmiş nakit akış modeli, performans yönetimi nakit akış değişkenlerini, nakit akışlarını Tip I ve Tip II olarak sınıflandırarak değerlendirir. Nakit, işlemler, tesisler ve bölümler arasında evrensel bir hesap birimi olarak kullanılır, bu da karmaşıklığı basitleştirir (Eldridge ve diğerleri, 2002).

$$Firma\ Değeri = \sum_{t=1}^n \frac{FCF_t}{(1+r)^t} \quad (2.29)$$

Burada:

- FCF_t : Serbest nakit akımı
- r : İskonto oranı
- n : Yıl sayısı

(Eldridge ve diğerleri, 2002)

2.5.2 Karar Ağaçları (Decision Trees)

Karar ağaçları, makine öğrenimi, istatistik ve veri madenciliğinde gömülü en popüler denetimli öğrenme yaklaşımlarından biridir, çünkü karmaşık karar kurallarını hiyerarşik bir şekilde öğrenme yeteneğine sahiptirler. Gerçekten de, sınıflandırma ve regresyon problemleri için faydalıdır çünkü özellikleri niteliklerine göre iteratif olarak bölerler, böylece kolayca yorumlanabilir sonuçlar sağlarlar.

Bu tezde, karar ağacı üzerindeki önemli konuları, mimariyi, uygulamayı ve performans karşılaştırmasını tartışıyoruz. Karar verme problemi, seçenekler ve belirsizlikler arasındaki dengeyi göstermek için karar ağaçları ile görselleştirilir.

Karar düğümleri, seçenekleri temsil eder ve şans düğümleri, hasta koşulları, test sonuçları veya tedavi etkileri ile ilişkili beklenen sonuçları temsil eder (Sox ve diğerleri, 2024).

Karar Ağaçları, makine öğreniminde genellikle sınıflandırma için kullanılan bir denetimli öğrenme algoritmasıdır. Düğümlerin niteliklerini doğrulamak ve yaprak düğümlerinde sonuçlar üretmek için kullanılan bir karar hiyerarşisine sahiptirler, bu da kolay karar analizi ve veri özelliklerinin anlaşılmasını sağlar (Babar, 2024)

2.5.3 Karşılaştırılabilir Şirket Analizi (CCA):

Bir şirketin değerlemesinde kullanılan bir süreçtir, şirketi aynı sektördeki diğer şirketlerle karşılaştırarak değerlemeye çalışır. Hem halka açık hem de özel şirketler için kritik öneme sahiptir, çünkü finansal performans ve piyasadaki konum hakkında bir bakış açısı sunar. Bu genellikle benzer boyutta, üründe ve coğrafyada halka açık veya özel şirketlerin belirlenmesi ve değerlemeler sağlayabilecek finansal metrikler üzerinde düşünülmesi yoluyla gerçekleştirilir.

Aynı sektördeki Karşılaştırılabilir Şirketlerin Analizi Son olarak, başka bir şirketin finansal metriklerine dayalı olarak bir şirketi değerlemek için karşılaştırılabilir şirket analizini kullanabilirsiniz. Karşılaştırılabilir şirket analizi (CCA), Wall Street'in bir şirketi nasıl değerlediğidir. Bir şirketi değerlemenin en iyi yolları, Göreceli değerlendirme kavramlarına dayanmaktadır. Basitliği ve gerekli finansal verilerin bulunabilirliği nedeniyle popülerdir (Perves, 2024).

2.5.4 Önceki İşlem Analizi (PTA)

M&A'de kullanılan bir değerlendirme yöntemidir, bir şirketin göreceli değerini geçmiş işlemler yoluyla analiz etmeye çalışır. Bu metodoloji, geçmişte yapılan satın alma çarpanlarına bakar ve bu çarpanları mevcut piyasa ile karşılaştırarak bir işletmenin ne kadar değerli olduğuna dair kabaca bir fikir edinmeye çalışır.

Bu kombinasyon, video oyun endüstrisi gibi yüksek riskli sektörlerle uygundur, yakın zamanda Microsoft'un Activision Blizzard'ı satın alması gibi büyük satın alımların piyasa etkileri olabilir ("Önceki İşlemler Analizi", 2002).

2.5.5 Finansal Projeksiyonlar

Finansal Projeksiyonlar- İş stratejisini yönlendirmek ve karar vermek için hayati bir araç, bir dizi finansal projeksiyon, satışlar, maliyetler, gelir ve kaynak tahsisi hakkında içgörüler sağlayabilir. Makul finansal tahminler, rekabet avantajı kaynağıdır ve finansal kuruluşlardan finansman sağlamak için gereklidir (Boffa, 2023). Finansal projeksiyonlarda makine öğreniminin kullanımı, tahmin edilen finansal tabloların doğruluğunu artırmak ve verileri çeşitli boyutlarda değerlendirmek için karmaşık hesaplama yöntemlerinden yararlanmak amacıyla önceden araştırılmıştır (Bellido-Zea ve diğerleri, 2023).

$$\text{Projeksiyon Satış} = \text{Büyüme Oranı} \times \text{Tarihsel Satış} \quad (2.30)$$

Makine öğrenimi ile geliştirilmiş projeksiyonlar, doğruluk oranlarını artırır (Bellido-Zea ve diğerleri, 2023; Boffa, 2023).

2.5.6 Ağırlıklı Ortalama Sermaye Maliyeti [Wacc]

Ağırlıklı Ortalama Sermaye Maliyeti, bir şirketi finanse etmek için güvenlik sahiplerinin ortalama olarak hangi getiri oranını talep ettiğini gösteren bir finansal metriktir. Yatırım kararları ve kurumsal finans açısından kritik bir bakış açısıdır, çünkü finansman maliyetini ve olası bir yatırımın getirisini incelemeye yardımcı olur.

WACC formülünde, öz sermaye maliyeti ve borç maliyeti, şirketin sermaye yapısındaki kendi ağırlıkları (oranları) ile çarpılır. Yöntem, farklı endüstriler ve finansal sistemler (uluslararası bankalar, sürdürülebilirlik projeleri) tarafından yatırım ve yönetim seçimlerini yönlendirmek için kullanılır. Aşağıda, elimizdeki

bilgilere göre WACC hakkında önemli noktalar bulunmaktadır. Diğer geleneksel WACC formülü, borcun varlık değerine oranını, borç maliyetini ve öz sermayeyi dikkate alır.

"Ancak burada yapmak istediğimiz şey, borç ve firmanın nakit akışlarının vade yapısını eklemek, bu da aslında uygun iskonto oranını tahmin edebilir." (Rodríguez, 2023).

WACC, bir şirketin iki ana finansman kaynağı olan borç finansmanı ve öz sermaye finansmanından kaynaklanan maliyetleri hesaba kattıktan sonra bir şirkete uygulanan ortalama iskonto oranıdır.

$$WACC = \left(\frac{E}{V} \times r_e \right) + \left(\frac{D}{V} \times r_d \times (1 - t) \right) \quad (2.31)$$

Burada:

- E: Özkaynak
- D: Borç
- V=E+D: Toplam sermaye
- r_e : Özsermaye maliyeti
- r_d : Borç Maliyeti
- t: Vergi oranı

(Rodríguez, 2023)

2.5.7 Kâr Marjı Modelleri

Kâr marjı denklemleri, farklı endüstrilerdeki şirketlerin karlılığını tahmin etmek ve analiz etmek için faydalı araçlardır. Bu modeller, regresyon analizinden risk bazlı ölçümlere ve karlılık marjları ve finansal performans hakkında içgörü sunan stokastik süreçlere kadar değişen yaklaşımlarla çeşitlilik gösterir.

İşletme finansal performans ölçümü için uygulanan bu modeller, regresyon ve risk bazlı tahminlere dayanır.

$$Brüt Kar Marjı = \frac{Brüt Kar}{Net Satışlar} \times 100 \quad (2.32)$$

Özellikle stokastik modelleme açısından potansiyel gelecekteki karlar analiz edilebilir.

2.5.8 Duyarlılık ve Senaryo Analizi

Duyarlılık ve senaryo analizi, karmaşık ve belirsiz ortamlarda karar verme için önemli araçlardır. Bu analizler, girdi parametrelerindeki değişikliklerin sonuçları nasıl etkileyebileceğini değerlendirmek için bir araç sağlar ve bu nedenle kararların sağlamlığına ve güvenine katkıda bulunabilir.

Duyarlılık Analizi: Tek bir faktörün model sonuçlarını ne ölçüde etkilediğini gösterir.

Senaryo Analizi: Birkaç değişken değişirse modelin nasıl yanıt verebileceğini inceler. Belirsizlik altında karar vermeyi geliştirir (Więckowski & Sałabun, 2024; Cortés, 2024).

2.5.9 Kapanış Fiyatı ve Piyasa Değeri Yöntemi

Duyarlılık analizi, çok kriterli karar analizi (MCDA) için kullanılan girdi verilerindeki değişikliklerin karar vermenin sağlamlığına ilişkin sonuçları nasıl etkilediğini araştırır. COMSAM, karar matrisindeki bir dizi parametrede eşzamanlı değişikliklere olanak tanıyarak ve ardından iç ilişkiler hakkında daha iyi bir içgörü sağlayarak bu tür bir analizde yeni bir yetenek sunar.

Bu yaklaşım, karar vericilere belirsizlik ve kararlarının istikrarı hakkında daha iyi bir içgörü sağlayan aralık sayılar olarak temsil edilen tercihlerle senaryo analizini zenginleştirir (Więckowski & Sałabun, 2024).

Duyarlılık Analizi: Belirsizlik altında karar verme için finansal projeksiyonlar üzerindeki etkilerini belirlemek amacıyla temel varsayımları ve değişken değerlerini değiştirmek. Hangi faktörlerin sonucu önemli ölçüde etkilediğini belirlemek için hizmet eder.

Senaryo Analizi ise, farklı senaryolar altında ekonomik çıktılar yelpazesine daha sağlam bir içgörü sağlamak için birden fazla model varsayımında eşzamanlı değişiklikler yaparak çeşitli alternatif gelecek durumları modellemek için kullanılır.

İki analiz, finans alanında bilinçli karar verme için esastır, çünkü farklı sonuçların tehditlerini ve fırsatlarını sunar (Cortés, 2024).

Bu, bir şirketin kapanış hisse fiyatı ve tedavüldeki hisse sayısı kullanılarak değerini belirleyen formüldür:

$$\text{Piyasa Değeri} = \text{Hisse Fiyatı} \times \text{Toplam Dolaşımdaki Hisse Sayısı} \quad (2.33)$$

3. BULGULAR

Finansal analiz ve Yapay zekâ (YZ) algoritmaları, finansal piyasalardaki fiyat hareketlerini gelecekteki tahmin etmenin yanı sıra riskleri ve ekonomik eğilimleri değerlendirme yöntemleri ve modelleridir.

YZ, büyük veriyle karşılaşıldığında değerli bilgileri ortaya çıkarma ve insan zihnine kıyasla karmaşık ilişkileri daha hızlı ve doğru bir şekilde tanımlama yeteneği sayesinde finansal sonuçları tahmin etmede kritik öneme sahiptir. Bu sektörde uygulanan temel YZ teknolojileri derin öğrenme (DL), makine öğrenimi (ML) ve doğal dil işleme (NLP)dir.

3.1 Yapay Zekanın Prensibi ve Gelişimi

Yapay zekâ (YZ), bilgisayarların insansı zekayı taklit etmesini sağlamak için geliştirilmiş bir teknolojidir. YZ'nin temel amacı, makineleri öğrenme, arama, akıl yürütme, doğal dil işleme, görsel algılama ve karar verme gibi insan zihnine benzer becerilerle donatmaktır. YZ gelişimi, farklı aşamalarda evrimleşmiş ve birkaç bilimsel sanat alanının birleşiminin sonucu olmuştur.

3.1.1 Yapay Zekâ (YZ): Genel Bakış ve Tarihsel Gelişim

YZ'nin kökleri, Alan Turing'in (Turing, A. M. (1950)) Turing Testi ile 50'lere kadar izlenebilir. Ve bu, bir makinenin insan gibi düşünüp düşünemeyeceğini görmek için bir testtir. Turing, zekanın yalnızca insanların alanı olmadığını, makinelerin de zeki olabileceğini savundu. Erken YZ çalışmaları algoritmalar ve mantık sistemlerine adanmıştı.

3.1.2 Erken Dönem ve Tabanlı Sistemler

1950'ler ile 60'larda YZ, mantık tabanlı akıl yürütme ve kural tabanlı kontrol çalışmalarından etkilenmiştir. "Genel Problem Çözücü" (GPS) programı ((Newell, A., & Simon, H. A. (1961))), bu dönemde YZ alanındaki önemli araştırma çalışmalarından biriydi. GPS, adım adım çözüm ipuçları verdi ve bir hedefe ulaşmak için mantıksal kurallar kullandı. Bununla birlikte, bu tür sistemler giderek karmaşık sorunlarla karşılaştıkça zorluklarla karşılaştı ve YZ araştırmalarında sınırlı ilerlemeye yol açtı.

3.1.3 Makine Öğrenimi ve Derin Öğrenme Çağı

YZ araştırmalarında önemli bir değişiklik 1980'lerin sonlarında gerçekleşti. Distillery vardı ve makine öğrenimi (ML) ve istatistiksel yaklaşımların ilk günleri yükselmeye başladı. Geoffrey Hinton, Yann LeCun ve Yoshua Bengio katkılarıyla derin öğrenme ve yapay sinir ağları yöntemleri YZ'yi dönüştürdü. Hinton ve çalışma arkadaşları sayesinde sinir ağlarında öğrenmenin çok daha etkili bir şekilde gerçekleştirilmesine olanak tanıyan geri yayılım prosedürünü geliştirdiler

Derin Öğrenme

2010'larda, Derin Öğrenme, yüksek hesaplama gücü ve büyük verinin etkisi ve yeniliğiyle atılım yaptı. Konvolüsyonel Sinir Ağları (CNN) ve Uzun Kısa Süreli Bellek (LSTM) ağları, görüntü ve zaman serisi verilerinde eşi görülmemiş başarılar elde etti.

Geçmişe dayalı olarak gelecekteki finansal zaman serilerinin (örneğin hisse senedi fiyatları) tahminini modellemeye olanak tanır. Yalnızca akademik bir araştırma yönlü değil, ayrıca birçok endüstrinin devrimini yönlendiren teknolojidir.

YZ'nin dinamik öğrenme, uyarlanabilir doğası, tahmin yetenekleri ve kendini geliştirme kapasiteleri, birçok endüstride insan kararları için destekleyici bir iskele haline gelmiştir.

3.1.4 Bugün Yapay Zekâ

Şimdi görüyoruz ki, yapay zekâ çeşitli endüstrileri dönüştürüyor. Oradan, YZ gücü ve endüstriler arası uygulanabilirlik açısından büyüdü – sadece kendi kendine giden arabalar, teşhis sağlık sistemleri, çok milyon poundluk finansal tahminler, müşteri hizmetleri sohbet robotları ve YZ destekli tasarım gibi uygulamalara bakmanız yeterli, YZ'nin neler yapabileceğini görmek için.

3.2 Finansal Tahminde Yapay Zekâ Yöntemleri

Zeki uygulamalar, finansal piyasalarda- fiyatlandırma, portföyler, oynaklık ve risk- yeni bir şekilde uygulanmaktadır. Bu şekilde, makine öğrenimi, doğal dil işleme, genetik algoritmalar, derin öğrenme ve benzerleri, modern YZ yöntemleri, klasik modellerin ötesinde finansal sonuçlar sağlamaktadır.

3.2.1 Makine Öğrenimi

Makine öğrenimi (ML), son zamanlarda finansal tahminde bir oyun değiştirici olmuştur, özellikle tahmin doğruluğunun artırılması ve risk yönetimi açısından. Son araştırmalar, karmaşık finansal verileri analiz etmek için Uzun Kısa Süreli Bellek (LSTM) ağları ve topluluk yöntemleri de dahil olmak üzere çeşitli ML modellerinin umut verici sonuçlar gösterdiğini de ortaya koymaktadır. Sadece varlık getirisinin tahminini artırmakla kalmaz, aynı zamanda portföy yönetim stratejilerinin tasarımını da iyileştirir, bu da piyasaya daha duyarlı hale gelir.

ML, finansal tahmini devrim niteliğinde değiştirdi; örneğin, 1996–2004 yılları arasında, SciM kullanılarak, "(finansal VEYA ekonomik) tahmin" terimi en az 71 kez (ve en fazla 97 kez) geçerken, "(makine öğren* VEYA yatırım) tahmini" terimini kullanan ilgili terimler 1-2 kez ortaya çıktı. ML ve AFT'de ampirik araştırmanın zorunluluğunu gösteren baskın temalar, iş birliği ağları ve kilit katkıda bulunanlar (Boudri, H., & Sabri, E. H. (2025)).

LSTM ve Transformer ağları gibi makine öğrenimi modelleri, verilerdeki uzun vadeli bağımlılıkları öğrenir, finansal tahminleri önemli ölçüde artırır ve tahmin doğruluğu ve risk ayarlanmış getiriler açısından geleneksel modelleri geride bırakarak portföy yönetimini ve karar vermeyi gelişen piyasa koşullarında iyileştirir (Uddin ve diğerleri, 2025).

Makine öğrenimi, geniş veri yığınlarında karmaşık desenleri tespit ederek finansal tahminlerin doğruluğunu büyük ölçüde artırır. LSTM, SVM ve Hibrit modeller (ANNS ile Teknik Gösterge) gibi yöntemler, geleneksel modelden daha iyi çalışır ve DSE gibi yüksek oynaklığa sahip bir piyasada hisse senedi fiyatı tahmininin doğruluğunu artırır (Hisse Senedi Fiyatı Tahmini için Makine Öğrenimi Modelleri: DSE Uygulamalarının Kapsamlı Bir İncelemesi, 2025). Makine öğrenimi (ML), geçmiş verilerden öğrenimlerine dayalı olarak kararlar almak için algoritmaları eğitmeye odaklanan YZ araştırmasının bir parçasıdır. LSTM'ler, SVM, Rastgele Orman, Gradyan Artırma ve XGBoost, finansal zaman serileri için sıkça kullanılan algoritmalar arasındadır.

3.2.2 Derin Öğrenme Modelleri

Derin öğrenme olarak mühendislik, sağlık, finans gibi farklı sektörlerde bir oyun değiştirici olmuştur. Bunlar, el yapımı özelliklere ihtiyaç duymamak için

Konvolüsyonel Sinir Ağları (CNN'ler) veya Tekrarlayan Konvolüsyonel Ağlar (RCN'ler) gibi şık model mimarilerini kullanan modellerdir. Bu, ham verilerden uçtan uca öğrenmeyi mümkün kılabilir ve tahmin performansını ve operasyonel verimliliği artırabilir.

Derin öğrenme modelleri: "Güneş Enerjisi", "Mühendislik", "Finans" gibi karmaşık görevler için ideal olan derin konvolüsyonel modeller (örneğin, CNN'ler, RCN'ler ve Transformer tabanlı mimariler) gibi modeller, performans ve yenilik için özel yapılarını ve yeteneklerini kullanarak daha iyi sonuçlar elde eder (Singh ve diğerleri, 2024).

Derin öğrenme mimarileri, finansal tahmin için önemli hale geldi çünkü finansal piyasalarda bulunan karmaşık ve değişken doğrusal olmayan desenleri yakalayabilirler. Bunlar arasında LSTM, CNN ve hibrit ağlar bulunur ve finansal zaman serileri, hisse senedi fiyatı ve ekonomik trend tahmini için klasik istatistiksel tekniklerden daha iyi doğruluk sağladığı gösterilmiştir. Farklı derin öğrenme yaklaşımlarının kombinasyonu hem zamansal bilgileri hem de mekansal desenleri yakalamayı mümkün kılarak daha doğru ve sağlam tahminler sağlar. Bu değişim, derin öğrenme modellerinin finansal tahminlerdeki çeşitli kullanımlarını ve faydalarını göstermektedir.

Finansal tahminde, karmaşık piyasa modellerini ve zamansal bağımlılıkları yakalamak için CNN'ler, LSTM gibi derin öğrenme modelleri kullanabiliriz. Bu kanıtlar, bu modellerin yüksek oynaklığa sahip finansal piyasalar bağlamında tahmin doğruluğunu artırarak klasik istatistiksel yaklaşımlardan üstün olduğunu ifade etmektedir. CNN'lerin ve LSTM'lerin güçlü yönleriyle hibrit mimarilerde de tahmin sonuçlarını iyileştirir. Araştırma, finansal veriler üzerinde model performansını artırmak için ölçekleme ve özellik seçimi gibi veri ön işleme ile derin öğrenme modeline eşlik etme gereğini vurgulamaktadır (Abir, 2025). (Çok katmanlı algılayıcılar (CNN'ler)) ve tekrarlayan (LSTM) derin öğrenme modelleri, finansal zaman serisi tahmininde yaygın olarak benimsenmiştir. Bu bağlamda LSTM'nin en büyük özelliklerinden biri, iç bellek mekanizmasını kullanarak uzun vadeli (zamansal) bağımlılığı modelleme kapasitesidir. Ancak bu tür modeller, piyasalardaki hızlı değişim zamanlarında genellikle zorlanır. Önerilen CNN-LSTM-TRANSFORMER (CLT) modeli, özellik işleme için CNN ve transformer

mimarisini birleřtirerek bu dezavantajı ařar ve trblanslı piyasa kořullarında tahmin doęruluęunu artırır (Ahmad ve dięerleri, 2024)

Hibrit mimariler zamansal ve mekansal karřılıklı iliřki yakalama avantajını sergilemekte ve bu nedenle oynaklık ve ani deęiřikliklere karřı daha dřk duyarlılıklara sahip olabilir (Ahmad ve dięerleri, 2024).

Transformer Tabanlı Geliřmiř Model

CNN-LSTM-Transformer (CLT), ardışık veriler çok katmanlı tahmin doęruluęunu artırır. Bu forml, listelenen řirketlerin dinamik deęerlemesinde bir lt nitelięindedir.

3.2.3 Doęal Dil İřleme (NLP)

Finans alanında, NLP, yapılandırılmamış verilerden eyleme geirilebilir istihbarat ıkararak ve tahminleri iyileřtirerek, tahmin sanatına modern bir makyaj yapmak iin kullanılmaktadır. Bu yetenek, finansal kurumların haber makaleleri, sosyal medya ve mesaj panoları gibi metin tabanlı byk miktarda veriyi iřlemesine ve daha iyi bilgilendirilmiř kararlar almasına, ayrıca tahminlerde doęruluęu artırmasına olanak tanır.

Finansal tahminlerde, model tahminleri, haber makaleleri ve sosyal medya duyarlılıęı gibi yapılandırılmamış bilgileri analiz etmek iin Doęal Dil İřleme (NLP) kullanılarak iyileřtirilebilir. Bu yntem, yatırımcıların eęilimlerini ve momentumunu tespit etmeyi saęlar ve finansal tahminlerin doęruluęunu ve gvenilirlięini artırır (Sharma ve dięerleri, 2024).

FinnLP, tarihsel hisse senedi fiyatı ve piyasa duyarlılıęı verileri gibi yapılandırılmamış basın blteni tabanlı verileri dahil ederek finansal tahmin performansını artırır. Bu dahil etme, hisse senedi fiyatlarının tahminlerinin doęruluęunu artıracak ve yatırım abasına anlamlı katkılar saęlayarak daha iyi bir finansal strateji oluřturulmasına ve glendirilmesine yol aacaktır (Ghosh & Naskar, 2023).

Finansal metinler de NLP kullanılarak analiz edilebilir. Bu, zellikle haber bařlıklarının, sosyal medya verilerinin ve finansal raporların ieriklerinin duyarlılık analizi iin piyasa tahmini ile ilgilidir.

3.2.4 Optimizasyon ve Genetik Algoritmalar Yöntemleri

Optimizasyon ve genetik algoritmalar (GAs) yöntemleri, özellikle hisse senedinin fiyat tahmini ve portföy seçimi gibi zaman serilerindeki finansal tahminlerini geliştirmek için anahtardır. Bu yöntemler, finansal karar verme sürecinde daha iyi doğruluk ve hız yakalayan optimal modelleri aramak için evrim ilkelerini kullanır.

Genetik algoritmalar ve Parçacık Sürü Optimizasyonu gibi benzer sürü zekâsı tabanlı yöntemlerin, karmaşık arama alanlarında hızlı ve verimli bir şekilde arama yaparak, optimal bir tahmin modeli bulmak için gelişmiş yakınsama oranları ürettikleri ve piyasa eğilimlerini tahmin etmede ve finansal karar vermede doğruluk sağladıkları bulunmuştur (Surjuse ve diğerleri, 2024).

Basit GA Süreci:

1. Başlangıç popülasyonu oluştur
2. Uygunluk fonksiyonunu (fitness) değerlendir
3. Fitness fonksiyonunu değerlendir
4. Seçilen bireylerin çaprazlaması
5. Yeni popülasyonu rastgele (veya rastgele olmayan şekilde) mutasyona uğrat

$$Fitness(x) = \frac{1}{1+Hata(x)} \quad (3.1)$$

GAs, portföy optimizasyonunda yukarı doğru (5) hiperparametre ayarlaması ve tahmin doğruluğunu artırmada güçlüdür (Surjuse ve diğerleri, 2024).

3.3 AI Desteklenmiş Risk Analizi ve Değerleme Modelleri

AI desteklenen risk analizi, makine öğrenimi, doğal dil işleme gibi son teknoloji kullanarak risk analizini ve yönetimini iyileştirmek için tüm dikeylerdeki endüstrileri dönüştürüyor. Bu yöntem sadece doğruluğu artırmakla kalmaz, aynı zamanda finans, siber güvenlik ve sağlık gibi birçok uygulama alanında tehditleri kontrol etmek için proaktif önlemler çıkarır. AI desteklenen finansal risk analizi ve yönetimi, risk yönetimini protokollerin hassasiyetini, verimlilik ve esnekliklerini artırarak finans sektörünü dönüştürdü.

Doğal dil işleme, sinir ağları ve makine öğrenimi gibi AI araçları, finansal kurumların potansiyel riskleri tespit edebilmesi için büyük miktarda veriyi gerçek

zamanlı olarak değerlendirmelerini sağlıyor ve geçmişte ulaşılamaz olan hız ve doğrulukla bunu yapıyor. Bu tür ilerlemeler, çok daha iyi kredi risk analizi ve dolandırıcılık tespiti ve piyasa eğilim tahmini ile sonuçlanarak daha istikrarlı finansal portföyler ve daha az dolandırıcılık kayıpları ile sonuçlanmıştır. Ancak, AI'nın finansal sistemlere uygulanması, algoritma yanlılığı, etik endişeler ve güçlü bir düzenleyici çerçeve gibi zorlukları da beraberinde getiriyor. AI içeren sistemler, kredi risk değerlendirmesini artırmak işlem geçmişini ile sosyal verileri inceleyebilir, bunun sonunda başarılı kredi kararlarına ile azalan temerrüt oranına yol açar (Patil, 2025).

Yapay Zekâ ve Makine Öğrenmesi algoritmaları, büyük miktarda veriyi işleyerek finansal kurum alanında uygulanacak analiz ve risk değerlendirme araçlarına büyük katkı sağlar. Bu araçlar, finansal kurumların tanıma yeteneğini artırır ve kriz durumlarında hızlı tepki verme yeteneğine katkıda bulunur. Ancak, AI'nın uygulanması, algoritmik yanlılık gibi alanlarda artan endişeler ve düzenleyici değerlendirmelerle birlikte gelir, bu da AI'nın risk yönetimi alanlarındaki yıkıcı gücünü gerçekleştirmesi için risklerini etkili bir şekilde azaltacak sağlam çerçeveler gerektirir (Oğuz, 2024).

Finansal risk analizi ve değerlendirmesi, AI modellerinin uygulama alanları için anahtar alanlardır ve geleneksel yöntemlere göre performansı %20 oranında artırmıştır. Araştırma, yatırım portföyleri üzerindeki risk için, Gradient Boosting Machines'in Random Forests'tan daha üstün olduğunu ve ticaret hacimlerini tahmin etmede Random Forests'ın diğer iki yöntemden daha doğru tahminler verdiğini gösterdi. Bu ilerleme, büyük verilerin verimli bir şekilde ele alınması yoluyla finansal karar verme alanında AI'nın potansiyelini yansıtır, ancak aynı zamanda veri gizliliği, algoritmik yanlılık ve sorumlu kullanım gibi etik değerlendirmelerle ilgili sorunları da beraberinde getirir (Chernish ve diğerleri, 2024).

Risk analizi ve değerlendirmesinde AI kullanımı, büyük veri analitiği, doğal dil işleme ve makine öğrenimini kullanarak finansal riski yönetme ve değerlendirme şeklimizi iyileştirir. Bu tür AI tabanlı sistemler, piyasa eğilimlerini tahmin etmek, yeni tehditleri tespit etmek ve eyleme geçirilebilir faydalı içgörüler sağlamak için yapılandırılmış ve yapılandırılmamış büyük miktarda veriyi işleyebilir ve analiz edebilir. AI destekli sistemler, risk değerlendirmelerinin hassasiyetini ve hızını da artırarak, finansal piyasaların ve sofistike finansal

araçların doğasında bulunan öngörülemezlik sorunlarına yönelik önleyici risk yönetimi önerilerinin uygulanmasına olanak tanır (Swadia ve diğerleri, 2023).

AI destekli Sözleşme Risk Skorum Motoru, sözleşmelerdeki Yüksek Riskli Maddeleri daha doğru bir şekilde tanımlayarak geleneksel yaklaşımlardan daha iyi analiz yapılmasını sağlar (Ittan, 2024). Finans sektöründe, AI, piyasa eğilimlerini ve yeni riskleri öngörmek için büyük miktarda veriyi tarayarak iyileştirilmiş risk yönetimi sağlar (Swadia ve diğerleri, 2024).

3.3.1 Kredi Riskleri

AI, müşterilerin işlem kalıplarından, harcama geçmişinden ve diğer kullanılan veri kaynaklarından (sosyal medya veya mobil ödemeler gibi) yorumlayarak kredi risklerini çıkarır.

Örnek Model: Lojistik Regresyon (ML tabanlı)

$$P(\text{Temerrüt}) = \frac{1}{1+e^{-(\beta_0+\beta_1X_1+\dots+\beta_nX_n)}} \quad (3.2)$$

Bu modelde, tahmin yeteneğini artırmak için AI (Yapay Zekâ) algoritması ile ince ayarlanmıştır (Patil, 2025).

3.3.2 Dolandırıcılıkların Tespiti ve Nitelik Tespiti

Anormal işlemleri gerçek zamanlı olarak Random Forest, XGBoost ve Derin Öğrenme ağları ile tespit edebilirsiniz. Özellikle, yalnızca normal kalıplardaki yeniden yapılandırma hatasını en aza indirerek anormallikleri tespit etmek için otoenkoder yapıları tutmak isterler:

$$\text{Nitelik Skoru} = ||X - \hat{X}||^2 \quad (3.3)$$

Denklemdaki $\hat{X}$ tahmin edilecek örnek; X gerçek olan veridir. Değer yüksek olduğunda, nitelikte olma olasılığı daha yüksektir.


3.3.3 Portföyün Analizi ve Piyasanın Riski

AI, yatırım yapılabilir portföylerde risk-getiri analizini geliştirmek için kullanılabilir. Bu bağlamda, kullanılan Gradient Boosting tabanlı yöntemler, portföydeki riskli varlığı tahmin etmek için uygundur.

3.3.4 Düzenleyici ve Etik Değerlendirmeler

AI'nın riskinin değerlendirilmesindeki başarısına rağmen, algoritma yanlılık, veri anlamda ihlalleri ve sonuçların açıklana bilir olması gibi zorluklar büyük arz taşır. Bu nedenle, etik ve yasal normların risk analizinde de yer alması gerekmektedir (Черниш ve diğerleri, 2024).

3.4 Finansal Alanda Hibrit Modeller



Şekil 3.1. Derin Öğrenme Modeli ile Zaman Serisi Tahmini için Geliştirme Süreci Akış Şeması.

Buradaki akış şeması, zaman serisi tahmini için bir derin öğrenme modelinin geliştirilmesinde yer alan adımları temsil eder. Veri hazırlığı sırasında, veriler önce içe aktarılır ve ön işleme tabi tutulur, ardından normalleştirilmiş ön işlenmiş veriler eğitim ve test verilerine bölünür. Bu çalışmada uygulanan LSTM, RNN, GRU ve MLP (basit RNN) tabanlı modeller, özellikle zaman serisi verilerindeki karmaşık kalıpları yakalamak için tasarlanmıştır.

Model performansı, simüle edilen ve ölçülen değerler arasındaki MAE, MSE, RMSE ve R^2 gibi değerlendirme kriterleriyle nicel olarak ifade edilir. Modellerin en iyi tahmin yapabilmesi için parametrelerin optimal

kombinasyonlarını ararken, hiperparametre optimizasyonu sırasında dikkate alınması gereken en uygun parametre çifti belirlenir.

Son olarak, gerçek dünya koşullarını taklit etmek için kullanılan test verileri üzerindeki optimize edilmiş modellerin tahmin yeteneği karşılaştırmalı olarak gösterilir. Bu bütüncül bakış açısı, finansal tahminler veya diğer geçici zaman serisi analizleri için sağlam modeller oluşturmayı amaçlamaktadır.

Finansal alanda hibrit modeller, geniş bir yelpazedeki finansal görevler için tahmin doğruluğunu ve risk kontrolünü artırmanın etkili yöntemleri haline gelmiştir. Özellikle, hisse senedi piyasası tahmini. Bunlar, avantajlarını kullanmak için çeşitli yöntemleri, özellikle Bayes yöntemleri, makine öğrenimi ve geleneksel istatistiksel yöntemleri kullanan karma modellerdir. Bu farklı yöntemlerin kombinasyonu, tahmin doğruluğunda önemli ilerlemeler sağlamış ve finansal analistler ve yatırımcılar tarafından daha geniş kabul görmüştür.

Finansal matematikte, hibrit modellerin kullanılması (Bayes ve çoklu regresyon yaklaşımlarının kombinasyonu) tahminlerde ve risk analizinde yardımcı olur ve diğer modellere göre daha iyi çalışır. Bu araştırma, bu iki tür modelin bağımsız modellerden daha iyi olduğunu kanıtlamayı amaçlamaktadır. Çünkü hisse senedi piyasasındaki fiyat eğilimi üzerinde daha iyi tahminler sağlayabilirler, bu da finansal analistler ve yatırımcılar için daha etkili olabilir (Yao, 2024).

Finansal bağlamda hisse senedi fiyat tahmininde hibrit derin öğrenme modelleri, GRU ve LSTM gibi çeşitli sinir ağı yapıları ile dikkat mekanizmalarını entegre eder. Bu tür modeller, her iki alt modelin de güçlü yönlerini kullanarak, saf tahminlerin eksikliklerini aşar ve tahminlerin doğruluk değerini artırır (Sharma ve diğerleri, 2024).

3.4.1 Modelin Entegrasyonu

EMD-TI-LSTM Modelleri:

- EMD: Orijinal verileri bileşenlere bölerek daha kararlı alt seriler elde edebiliriz.
- LSTM: Modele zamansal bağımlı yapılar dahil eder.

- TI (Zamansal Önem): Zaman ağırlıklarına bağlı olarak, bunlar birleştirildiğinde, tahmin doğruluğunda önemli bir iyileşme sağlanır (Ozupek ve diğerleri, 2024).

3.4.2 Bayes + Regresyon

Hibrit Bayes yaklaşımları, önceki bilgilerden tahminleri günceller:

$$P(H/D) = \frac{P(D/H) \cdot P(H)}{P(D)} \quad (3.4)$$

Bu yönetici denklem, regresyon algoritmaları ile, olay zamanına kadar olan tahminlerde üstünlük sağlayabilir (Yao, 2024).

3.4.3 Dikkat Mekanizmalarıyla beraber GRU-LSTM Hibrit Modeli

Verilen zaman serisinin bilgilendirici kısmına daha doğru bir şekilde dikkat etme yeteneğine sahiptir. Zaman serisi bağlamında GRU ve LSTM'yi birleştirerek, bilgi sızıntısı en aza indirilir ve genelleme potansiyeli artırılır.

Finansal zaman serilerinde, dikkat tabanlı mekanizmalar, tahmin başarısını %12'ye kadar artırabilir (Sharma ve diğerleri, 2024).

Menkul kıymet değerinin hibrit yapay zekâ modelleri, gelecekteki getirileri tahmin etmedeki doğruluğunu ve artırılan verimlilik için birden fazla yapay zekâ tekniğini birleştiren, menkul kıymet değerlemesinde zamanla kullanım artmıştır. Bu modellerdeki finansal verilerin özelliklerini aşmak ve tahmin gücünü artırmak için bulanık çıkarım sistemleri ve sinir ağları gibi çeşitli teknik türlerini birleştirir.

Güvenlik fiyatlandırmasında hibrit modellerin uygulanması çok faydalıdır çünkü hem doğrusal hem de doğrusal olmayan bilgileri yeterince işleyebilirler, böylece hisse senedi fiyatlarını tahmin etmekten piyasa yönlerine kadar geniş bir yelpazeyi kapsarlar. Sinir ağları, regresyon ağaçları ile birleştirildiğinde, bu güçlü özellik seçimi ve tahmin yeteneği sunar. Optimal karar değişkenleri regresyon ağaçları tarafından belirlenir ve ardından ilerideki hisse senedi endeksi değerlerini tahmininde sinir ağlarına girilir (Akbaş, 2022).

Hibrit modeller olan ERNN-MANFIS gibi, parçacık sürü optimizasyonu ve bulanık c-means kümeleme kullanarak performansı artırır ve geleneksel modellere göre daha doğru tahmin sonuçları elde eder (İSLAMOĞLU & Başaran, 2024).

3.5 Hibrit Model Önemi ve Kavramı

Hibrit Model, eğitim ve işyeri ortamı, veri madenciliği, yazılım geliştirme gibi farklı alanlarda etkinliği artırmak için farklı yaklaşımlara ait araç ve yöntemleri kullanan bir metodolojidir. Önemi, birçok modelin avantajlarını kullanabilmesi ve sonuçları ve genelleştirmeyi artırabilmesidir. Birkaç modelleme tekniğinin avantajlarından yararlanarak, hibrit modeller, bireysel yaklaşımların başarılı olmadığı yerlerde daha iyi sonuçlar sağlayabilir. Bu entegrasyon özellikle şu bölümler için çok faydalıdır:

- Veri ön işleme (özellik çıkarımı),
- Özellik seçimi,
- Zamansal bağımlılıkların modellenmesi
- Belirsizlik yönetimi.

3.5.1 Karar Ağaçları ile Sinir Ağlarının Birleştirilmesi

Karmaşık ARG tahmin yaklaşımlarında, hibritler temelinde sinir ağlarının regresyon ağaçları ile kullanılması özel bir dikkat gerektirir. Regresyon ağaçları, verileri ayrıştırarak altta yatan faktörleri bulur ve sinir ağları bu ayrıştırılmış segmentler içinde daha doğru tahminler yapar. Temsili Model Yapısı:

- Regresyon ağacı kullanarak özellik alt kümesi seçimi
- Seçilen bilgilerin bir MLP'ye taşınması
- Çıktının tahmini (Akbaş, 2022)

3.5.2 Optimizasyon Tekniklerinin Entegrasyonu ile Bulanık Mantık

Parçacık Optimizasyonu (PO) gibi evrimsel algoritmalar, parametrenin ayarlanmasında iyi performans gösterir ve bulanık mantık sistemleri (Bulanık Çıkarım Sistemleri), belirsizlikler altındaki finansal verilerin modellenmesi için seçilen yöntemdir.

Hibrit Model ERNN-MANFIS:

- ERNN Dinamik öğrenme: Zaman içinde geri yayılım (BPTT) ve ERNN
- MANFIS: Dilsel kenarlarla uyarlanabilir nöro-bulanık çıkarım sistemi yöntemi
- PSO: Küresel model parametre optimizasyonu

Bu, aşağıdaki model formunda yazılabilir:

$$y_t = \sum_{i=1}^N w_i \cdot f_i(x_t) \quad (4.1)$$

- f_i : Bulanık kural çıkış sinyali çevresi ve şu şekilde elde edilir: Her bulanık kuralın çıktıları
- w_i : optimal öğrenme ağırlığı (PSO açısından hesaplanır)
- x_t : giriş vektörü (İslamoğlu & Başaran, 2024)

3.5.3 Hibrit Modellerin Başarılı Tahminleri ve Uygulama Senaryoları

Hisse senedi tahmini üzerindeki deneyler, hibrit modellerin CNN veya klasik LSTM %10-25 değerinin daha doğru olduğunu göstermektedir. Bu farklı tanı, aşağıdaki kriterlere dayanmaktadır:

3.6 Hibrit Modelde Kullanılan Teknikler

3.6.1 Derin Öğrenimi ve Makine Öğrenmesi Hibriti

Yapay zekada dikkate değer bir başarı, makine öğrenmesi (ML) ve derin öğrenmenin (DL) entegrasyonudur, çünkü bu, her iki paradigmanın da avantajlarını birleştirerek çeşitli uygulamalarda performansı artırır. Bu hem ML hem de DL'nin güçlü yönlerini birleştirir, sadece tahmin performansını artırmakla kalmaz, aynı zamanda ML veya DL'nin tek başına ele alamayacağı zor verileri de işler. Bu entegrasyonun ana özellikleri aşağıda verilmiştir.

Makine öğrenmesi (ML) ve derin öğrenme (DL) tekniklerinin avantajlarını kullanan hibrit modellerin kullanımı, tahmin doğruluğunu ve ölçeklenebilirliği artırabilir. Bu önerilen sinerjik metodoloji, yapılandırılmış veriler için oluşturulmuş ML algoritmalarını ve yapılandırılmamış veriler üzerinde oluşturulmuş DL tabanlı Sinir Ağlarını entegre eder ve karmaşık sorulara daha iyi çözümler sunar (Choudhary & Choudhary, 2024).

DNN ve RFR'ye dayalı hibrit öğrenme modeli, yüksek enerji fiziği deneylerinin ilerlemesine faydalı olan ve daha iyi parçacık ayrımı ve daha temiz veri sağlayan parçacık tanımlama sistemleri oluşturma konusunda DNN ve RFR'nin ilgili gücünü etkili bir şekilde birleştirir (Bavarchee, 2024).

Makine öğrenmesi (ML) ve derin öğrenme (DL) arasındaki karışım stratejisi, birkaç paradigmayı karıştırmak, karar verme sürecini ve bazı alanlarda,

örneğin görüntü işleme veya dinamik ortamlarda özellik çıkarımını iyileştirmek için hibrit mimarilerde tipiktir (Rane et al., 2024).

3.6.2 Finansal Haber Analizi ve Doğal Dil İşleme

Finansal Haber Analizi ve NLP:

NLP, finansaldaki haber analizini önemli derecede değiştirmiştir ve düzenlenmemiş verilerden içgörüler elde etmeyi mümkün kılmaktadır.

Duygu bibliyografisi: Finansal analistler, duygu analizi, konu modelleme veya gelişmiş makine öğrenmesi modelleri gibi araçlar aracılığıyla piyasa dinamikleri ve yatırımcı duyarlılığı hakkında içgörüler elde edebilirler.

Bu NLP yaklaşımlarının gözden geçirilmesi, finansal haber analizinde bir dizi önemli uygulama ve bulguyu da belirlemiştir. Özellikle BERT gibi tekniklerden yararlanan NLP modelleri, hisse senedi hareketlerini tahmin edebilecek finansal haber makalelerinden duygu puanları çıkarmayı sağlar. Çalışmalar, haber duygu puanlarının performansının ve dalgalanmasının, hisse senedi gelecekteki getirisi ile güçlü bir pozitif korelasyona sahip olduğunu göstermektedir (Thakur et al., 2024) (Wang, 2024).

NLP, duygu analizinde ve konu modellemesindeki gibi yapılandırılmamış verilerden sinyaller türeterek finansal haberleri nicelleştirmeyi mümkün kılar, bu da algoritmik ticaret, kredi riski analizi ve finansal dolandırıcılık tespiti için kullanılabilir (Jagdale & Deshmukh, 2025).

Duygu puanı, hisse senedi hareketini tahmin etmek için doğal dil işleme (NLP) kullanılarak finansal haber makalelerinden çıkarılır. Önceden eğitilmiş BERT, S&P 500 piyasa duyarlılığı analizi için duygu sınıflandırması yoluyla başrol oynar (Thakur et al., 2024).

BERT Tabanlı Finansal Duygu Analizi:

- Cümle bağlamının çift yönlü bilgisi BERT modeli tarafından ele alınır.
- Çıktı, bir softmax ile duygu sınıflarına ayrılır:

$$P(y = \text{pozitif}) = \frac{e^{z_{\text{poz}}}}{e^{z_{\text{poz}}} + e^{z_{\text{neg}}} + e^{z_{\text{nötr}}}} \quad (3.15)$$

Bu tür analizlerden elde edilen çıktılar, tahmin algoritmalarının erken uyarı sistemlerine dönüşmesi için zaman serisi modellerine entegre edilir.

Örneğin, S&P500 için başlık duyarlılığı ve piyasa oynaklığı arasında %82'lik bir korelasyon rapor edilmiştir (Thakur et al., 2024)).

3.6.3 İstatistiksel, Yapay Zekâ Entegratif Yaklaşımlar

Makine Öğrenmesi (ML) ve istatistik... Klasik istatistikleri AI'nın güçlü algoritmalarıyla birleştirerek, finansal hizmet sağlayıcıları tahmin doğruluğunu, risk değerlendirmesini ve işletme verimliliklerini artırabilir. Böyle bir kombinasyon hem tahmin modeline hem de gerçek zamanlı, zorlu finansal sorunlara kaldiraç sağlar. Yapay zekâ, kredi riskini daha iyi tahmin ederek ve dolandırıcılığındaki risk yönetimini tespit ederek geliştirir (Saranya, 2024).

Finansal tablo analizinde yapay zekanın kullanımı, uyumsuzluk tespiti ve risk değerlendirmesini iyileştirir, bu da düzenleyici raporlamayı ve uyumluluğu güçlendirir (Dheenadhayalan et al., 2025).

NLP'nin finansal raporlarda %30 daha erken tespit ettiği kanıtlanmıştır (bkz. (Dheenadhayalan et al., 2025)).

3.7 Güvenlik Değerlemesi için Hibrit Modelleme

Hibrit modeller, farklı yaklaşımları birleştirerek tahminleri daha doğru hale getirmek ve finansal piyasa dinamiklerini ele almak için hisse senedi değerlemesinde geliştirilmiştir. Çeşitli stratejileri birleştirerek, bu modeller her yöntemin güçlü yönlerinden yararlanırken geleneksel yaklaşımların zayıflıklarını aşabilirler. Hibrit modellerin kullanımı, hisse senedi fiyatı değerlemesinde veri mühendisliği çıkmazını kırmak için umut vericidir ve özellikle trendi kavrama ve ilgi hisse senedini kümelenendirme konusunda finansal analistler ve yatırımcıların performansına büyük değer katabilir.

Hisse senedi fiyatı tahmini amacıyla, yeni hibrit GRU, LSTM ve dikkat modelleri önerdik. Bu modeller, katma değerli bilgilere odaklanır, tahmin doğruluğunu artırabilir ve finans için karar destek sistemlerinde önemli bir rol oynar (Sharma vd, 2024).

3.7.1 GRU-LSTM-Dikkat Entegrasyonu

Model Bileşenleri:

- GRU: Kısa vadeli bağımlılıkları modellemede daha hızlı ve daha etkilidir.

- LSTM: Uzun vadeli bağımlılıkları öğrenir ve geçmişin hafızasını korur.
- Dikkat: Giriş dizisindeki önemli zaman adımlarını karşılaştırır.

Tahmin Süreci Formülü:

3.7.2 Model Performansının Değerlendirilmesi

Hibrit modelin performansı, istatistiksel kriterlere göre değerlendirilir:

Hibrit modelin doğruluğunu geleneksel modellerle karşılaştırır. Bu yapının, bağımsız LSTM veya GRU ya kıyasla %10-20'den düşük bir hata marjı ile çalıştığı bulunmuştur [Sharma et al., 2024].

3.7.3 Karar Verme Üzerindeki Finansal Etkisi

Ortaya çıkan, portföy yönetimi, hibrit model, ticaret stratejisi ve oynaklık analizi gibi finansal karar verme süreçlerinde kullanılmak üzere daha doğru tahminler sunar ve yatırımcılara değer yaratır. Kısa vadeli fiyat oynaklığının erken tahmini, ticaret stratejilerindeki yüksek frekansın olması etkili bir uygulama sağlar.

4. TARTIŞMA

4.1 Model Tasarımı ve Araştırma Yöntemi

Literatürde, önerilen model, belirli bir vadede menkul kıymetlerin öngörülebilir değerleriyle ilgili iki farklı uygulamadan kaynaklanan iki veri kümesi üzerinde test edilmiştir: Hisse Şemsiye Fonları ve Kıymetli Maden Şemsiye Fonları. İki veri kümesindeki fonların fiyat verileri teknik analiz göstergeleri ile Python programlama dili kullanılarak grafiksel olarak çizilmiştir. Ek olarak, öngörü başarısını ölçmek için LSTM (Uzun Kısa Süreli Bellek) gibi modeller kullanılarak zaman serisi analizi de yapılmıştır.

Analiz dört ana süreçten oluşmuştur: veri ön işleme, teknik gösterge tanımları ve değer hesaplaması, grafiksel yorumlama ve modelleme sonuçlarının karşılaştırılması. Daha sonra her fon için üretilen grafiklerin kullanımları ve anlamları izah edilmiştir.

Teknik Göstergeler ve Açıklamaları

Tablo 5.1. Teknik Göstergelerin Kısaltmalarının Açıklamaları

Kısaltma	Açıklama
MA20 MA50	20 ve 50 günlük hareketli ortalamalar – mevcut trendlerin yönünü ölçmek için kullanılır.
StdDev20	20 Günlük Standart Sapma – bir yatırımın fiyatının tarihsel volatilitésinin istatistiksel bir ölçüsüdür.
Volatility	Hareketli volatilité – piyasa volatilitésinin hareketini gösterir.
LSTM	Derin öğrenme modeli – tarihsel verilere karşılık gelen geleceğe yönelik tahminler yaratılmıştır.

4.2 Veri Kaynakları ve Veri Kümesi

Bu analizde kullandığımız veri kümeleri, Türkiye'deki menkul kıymet yatırım fonlarının fiyat, getiri, volatilité ve diğer finansal verilerinden oluşmaktadır.

Çalışmada iki tür şemsiye fon incelenmiştir: Hisse Şemsiye Fonları ve Kıymetli Maden Şemsiye Fonları. Gönderilen kullanıcılar iki farklı gruba ait olduğunda, bu grupların her biri farklı piyasa dinamiklerine sahiptir ve tahmin modelinin başarı düzeyini test etmek için karşılaştırmalı bir fırsat sunar.

a) Veri Kaynakları

Veri kümeleri EVDS (Takasbank Elektronik Veri Dağıtım Sistemi) .xlsx formatındaki dosyalardan elde edilmiştir:

i. Hisse_Senedi_Semsiye_Fonu

ii. Kıymetli_Madenler_Semsiye_Fonu

Bu veri kümeleri, fonların tarihsel performanslarının zaman serisi analizini sağlayan günlük kaydedilmiş değişkenler içermektedir.

b) Fonların Kısaltmaları

Tablo 5.2. Çalışmadaki Yatırım Fonları ve Kısaltmaları

Fon Adı	Kısaltma
İş Portföy İş Bankası İştirakleri Endeksi Hisse Senedi Fonu	TI3
Garanti Portföy Altın ve Değerli Madenler Fonu	GGK
İş Portföy Altın Fonu	HBF
QNB Finans Portföy Kıymetli Madenler Fonu	MKG
Ziraat Portföy Değerli Madenler Fonu	GL1
Ak Portföy BIST 30 Endeksi Hisse Senedi Fonu	TI2

Örnek fonlar, çeşitli risk profilleri ve yatırım stratejilerinin örneklemleri olmaları açısından oldukça temsil edicidir. Bu, modelin performansını daha sonra çok volatil ve riskli nesneler üzerinde ve ardından daha istikrarlı risk nesneleri üzerinde test etmeyi mümkün kılmıştır.

c) Göstergelerin Veri Kümesindeki Kullanımı

Tablo 4.3. Veri Madenciliği ve Tahmin İçin Kullanılan Göstergeler Yöntemi ve Tanımı

Gösterge	Kısaltma	Tanım ve İşlevi
Günlük Fiyat	—	Borsa günlerindeki fonların kapanış fiyatlarıdır.
Günlük Getiri	Return	İki gün arasındaki fiyat yüzdesi farkını gösterir.
Hareketli Ort.	MA20, MA50	Trendin yönü 20 ve 50 hareketli ortalamalar kullanılarak ölçülür.
Standart Sapma	StdDev20	Risk seviyesini ve 20 günlük volatilité göstergeyi açıklar.
Volatilité	Volatility	Yatırımların fiyatlarının zaman içinde ne kadar hareket ettiğinin ölçüsü.
Korelasyon Matrisi	—	Göstergeler arasındaki ilişkinin sayısal temsili.
Yatırımcı Sayısı	—	Fonların yatırımcılarının zaman içindeki değişimini ölçen bir değer.
Toplam Fon Değeri	—	Fon portföyünün toplam parasal büyüklüğüdür.

Ayrıca, teknik analiz dahil olmak üzere birkaç finansal analiz ve tahmin göstergesi hesaplanmıştır. Bu özellikler grafiksel olarak temsil edilmiş ve LSTM modülünün giriş özellikleri olarak kullanılmıştır. Bu işaretleyiciler, model geliştirme sırasında normalize edilmiş formda kullanılmış ve grafik analizlerle karar verme sürecine yardımcı olmuştur.

Örneğin, MA20 ve MA50 çizgileri fiyatların kısa ve uzun vadeli yükselişlerini karşılaştırmak için; Volatilité ve StdDev20, bu fonların yüksek veya düşük riskini analiz etmek için kullanılmıştır.

d) Veri İşleme ve Dönüştürme Aşaması (DPT)

Veri analizi ve görselleştirme Python kullanılarak gerçekleştirilmiştir. Ölçekleme için Minimum-Maksimum normalizasyonu kullanılmıştır. Bu yaklaşımı kullanarak, tüm değerler [0,1] aralığında ölçeklendirilmiş ve bu da LSTM ağlarının

daha sağlam bir şekilde eğitilmesini sağlamıştır (Han, J., Kamber, M., & Pei, J. (2011)). Normalizasyon formülü şu şekildedir:

$$x'_t = \frac{x_t - \min(X)}{\max(X) - \min(X)} \quad (4.1)$$

Böylece, verilerden gelen ölçekler ayrıştırılmış ve modelin öğrenme sürecinde önyargıdan kaçınılmıştır.

e) Veri Seçim Kriterleri

Veri kümesindeki diğer fonlardan daha iyi tahmin eden fonları bulmak için teknik analiz göstergeleri ve model çıktıları arasında bir karşılaştırma yapılmıştır. Bu bağlamda:

- TI3 fonu düşük volatilité ve iyi hareketli ortalama trendi ile en iyi performans gösteren hisse fonu olarak seçilmiştir.
- Kıymetli metaller kategorisinde, GGK fonu en yüksek veri tutarlılığı ve grafik çıktısının önemli içgörüsü ile öne çıkmıştır.

Bu iki fon, LSTM modelinde ayrıntılı bir şekilde tahmin edilmiş ve tahminleri Bölüm 5.3'te I+II ile karşılaştırılmıştır.

4.3 Kullanılan Yapay Zekâ ve Hibrit Modeller

Bu çalışmada, derin öğrenme (DL) tabanlı LSTM (uzun kısa süreli bellek) modeli, farklı teknik analiz göstergeleri ile birleştirilerek menkul kıymet değerini tahminin de kullanılmıştır. LSTM modelleri, zaman serisi verilerinde uzun menzilli bağımlılıkları öğrenme potansiyelleri nedeniyle finansal piyasalarda popüler olmuştur (Hochreiter & Schmidhuber, 1997).

a) LSTM Modelinin Gerekçesi ve Yapısı

LSTM, klasik RNN'lerden daha fazla bir belleğe sahiptir ve geçmiş bilgileri kullanarak daha yüksek doğrulukla tahmin yapılabilir. Bu araştırma için LSTM modeli şu nedenlerle seçilmiştir:

- Zaman serisinin trend/mevsimsel/volatilité yapısını öğrenebilir,
- Kısa ve uzun menzilli bağımlılıkların yakalanması,
- Finansal zaman serilerinin gürültülü yapısında faydalı çıktılar üretme kapasitesi.


b) Modelin Hibrit Tasarımı

Hibrit sistem, bileşenlerin birleştirilmesiyle oluşturulmuştur:

- **Teknik Analiz Göstergesi:** MA20, MA50, Getiri, StdDev20, Volatilite
- **Zaman Serisi İşleme:** Verileri düzleştirme, açma ve modelin giriş şekline dönüştürme
- **LSTM Sinir Ağı Eğitimi ve Tahmin mekanizması**
- **Görsel Doğrulama ve Performans İzleme:** Grafiklerle karşılaştırmalı analiz


Bu düzenleme ile tahmin doğruluğu sadece sayısal bir değerle değil, aynı zamanda bir görüntüden de ölçülebilir.

• Tahmin Performansları: Bazı örnek Grafikler




Şekil 4.1. LSTM Tahmini için TI3 Fonu

LSTM tarafından TI3 fonunun tahmini, MA20 ve MA50 ile tutarlıdır. Tahmin eğrisi, fiyatın genel trendi ile karşılaştırılabilir bir forma sahiptir. Yukarıdaki grafik dilimi, TI3 fonunun fiyat yolunu 50 günlük (MA50) ve 20 günlük (MA20) hareketli ortalamalarla karşılaştırarak göstermektedir. Kapanış fiyatlarının mavi çizgisi ve kısa & uzun hareketli ortalamaların turuncu ve yeşil çizgileri sinyalleri. MA50, genel uzun vadeli trend göstergesidir ve MA20, kısa vadeli trend göstergesidir, bu nedenle ilki fiyat hareketini ikincisinden daha yakından takip eder. Trend değişim noktalarında MA20'nin MA50'yi yukarı veya aşağı geçmesi, al-sat sinyalleri için değerli notlar sağlar!



Şekil 4.2. LSTM Tahmini için GGK Fonu

Yukarıdaki grafikte, GGK (Garanti Portföy Kıymetli Madenler Fonu) için günlük kotalar ve MA20 ve MA50 göstergesi sunulmaktadır. Kıymetli madenlere bağlı GGK fonu olduğu için, bazen oldukça volatilité olabilir. Genel trend, bu yukarı ve aşağı dalga hareketi olmasına rağmen, MA20 ve MA50 çizgileri ile hala gözlemlenebilir. MA20, kısa vadede fiyatların arttığını ima ederek MA50'nin üzerinde yukarı doğru hareket etmektedir. Özellikle 2023'te, 2023'ün ortasından itibaren her iki ortalama da daha fazla yukarı doğru dönerek, yukarı trendin güçlendiğini göstermektedir.




Şekil 4.3. LSTM Modelin Çıkışı (Genel)

Modelin performansındaki tahmin, günümüz dünya ile karşılaştırılarak rapor edilmiştir. Gerçek fiyat ve LSTM tahmin eğrisi neredeyse aynıdır. Bu grafik, üç farklı yatırım fonu için 2020'den 2025'e kadar tarihsel fiyat varyasyonlarını ve modelimizden elde edilen değerlendirme ile ilgili kısa vadeli tahminleri (kesik çizgilerle gösterilen) göstermektedir. 2025'in başındaki ani düşüş, modelin eğitildiği veri kümesinde eksik veya hatalı bir sıfır girdisinden kaynaklanıyor olabilir. Bu tür tutarsızlıklar, veriler standartlaştırıldığında veya tahmin edilen, tahmin ediciyi aştığında yaygındır.

Çeşitli yatırım fonlarının LSTM'si için tarihsel serilerin ve tahmin sonuçlarının değerleri. Kontroller TI3 (mavi çizgi), HBF (mor çizgi) ve GGK (yeşil çizgi). Turuncu ve Kırmızı kesik çizgiler, LSTM modeli tarafından üretilen kısa vadeli tahminleri temsil eder. Yeşil çizginin 2025'in başındaki keskin düşüşü, veri kaybı veya teknik bir arızanın sonucudur. Bu grafik, LSTM modelinin tahmininin gerçek fiyatla karşılaştırıldığında ürettiği değerler arasındaki farkını ifade etmektedir. Grafikteki mavi çizgi gerçek fiyatları, turuncu çizgi ise modelin tahmin ettiği değeri gösterir.

LSTM zaman serisinin kısa vadeli değişikliklerini ve uzun vadeli trendlerini yakalayarak tahmin etmiştir. Gördüğümüz gibi tahmin eğrisi, gerçek fiyatı oldukça iyi takip ediyor. Bu, modelin öğrenmesinin üretken ve gelecekteki fiyatları tahmin etmek için faydalı olduğunu göstermektedir.

Bu grafik, 2020–2025 yılları arasında üç farklı yatırım fonunun tarihsel fiyat yollarını (düz çizgiler) ve LSTM modelinden zaman içindeki kısa vadeli özelliği (kesik çizgiler) göstermektedir. Noktalı kırmızı ve turuncu çizgi, model tarafından tahmin edilen belirli fonların gelecekteki fiyat yollarını temsil eder. Özellikle yeşil çizgide, 2025'in başındaki keskin düşüş, temel veri kümesindeki (eksik, sıfır değerli veya tahmin aralığının dışında) kayıtlara eklenen hatanın bir tezahürüdür. Buradaki kopmalar, derin öğrenme modellerinin öğrenme aşamasında veri sınırlı olduğunu ortaya koyar ve modelin tahmin kabiliyetinin sınırları olduğunu bize anlatacak ölçüde anlamlıdır.



Şekil 4.4. 30 Günlük Hareketli Ortalama (MA30) ile Günlük Fiyatlar Grafiği

Ayrıca grafikte, eşzamanlı olarak, yatırım fonunun dikkate alınan tarihsel kapanış fiyatlarını (mavi çizgi) ve bu fiyatların 30 günlük hareketli ortalamalarını

(MA30) (turuncu çizgi) sunmaktadır. MA30, fonun fiyatındaki kısa vadeli dalgalanmalara daha duyarlıdır ve genel trendi daha net bir şekilde yansıtır.

Grafikte gördüğümüz gibi, bazen fon piyasa fiyatları MA30 çizgisini kırar ve bazen de MA30'un altında kalır; bu, piyasanın aşırı alım veya aşırı satım olduğunu gösterir. Özellikle 2023'ün dördüncü çeyreğinden itibaren, MA30 çizgisi yükselmeye başlar ve fiyat çizgisi genel olarak hareketli ortalama ile hizalanır. Bu, fon için büyük bir yükseliş trendidir ve teknik analiz açısından sağlıklıdır. MA30, trendin mevcut yönünü tanımak için yararlı bir göstergedir veya yapılandırma, olası kırılma noktalarını belirlemek için de yararlıdır.

- **Model Başarısının Değerlendirilmesi**

Model performansı sadece görsel sonuçlarla değil, aynı zamanda istatistiksel ölçülerle de değerlendirilmiştir:

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \tilde{y}_i)^2 \quad (4.2)$$

Burada, y_i gerçek fiyat, $\tilde{y}_i$ ise model tarafından tahmin edilen fiyatı temsil eder. Düşük bir MSE, modelin doğru bir şekilde uyum sağladığını ifade etmiştir. Ayrıca *Şekil 5.3.4* grafiğinde görüldüğü üzere, modelin tahmin ettiği fiyatlar 30 günlük hareketli ortalama ile yüksek uyum göstermiştir. Bu da hibrit modelin sadece geçmiş veriyi değil, teknik eğilimleri de başarılı şekilde modelleyebildiğini ortaya koymaktadır.

5.4 Model Eğitimi ve Parametre Ayarlaması

Bu tezde, zaman serilerine dayalı olarak yatırım fonlarının fiyatlarını tahmin etmek için oluşturulan LSTM modeli, hiper parametrelerin çeşitli kombinasyonları altında eğitildi ve model performansını maksimize etmek için en iyi yapı bulundu. Parametrelerin çeşitli kombinasyonlarının performansı, eğitim sırasında görselleştirilerek görsel olarak kontrol edildi.

- **Veri Bölme ve Normalizasyon**

Modele girmeden önce, eldeki veriler [0,1] aralığına ölçeklenmek üzere Min-Max Normalizasyonu uygulandı. Veri seti daha sonra %80 eğitim- %20 test olarak bölündü. Modelin genelleme yeteneğini değerlendirmek için 5 katlı çapraz doğrulama yapıldı. Bu, her veri alt kümesi eğitim ve testte yer aldığı anda aşırı öğrenme riskini önledi.

- **Kullanılan Hiper parametreler**

Öğrenmedeki LSTM modelinin etkinliğini etkileyen başlıca hiper parametreler şunlardır:


Tablo 5.4. LSTM modelini eğitmek için parametreler

Parametre	Değer
LSTM katmanı	50 nöron
Epoch (Eğitim döngüsü)	100
Batch size	32
Optimizer	Adam
Loss Function	Mean Squared Error (MSE)
Aktivasyon Fonksiyonu	tanh

LSTM katmanındaki parametre Değer 50 nöron Epoch (Eğitim döngüsü) 100 Batch boyutu 32 Optimizatör Adam Kayıp Fonksiyonu: MSE (Ortalama Kare Hatası) Aktivasyon Fonksiyonu

Zaman serisi verilerini tahmini için LSTM modelinde 50 nöronlu bir LSTM katmanı kullanıyoruz. Model, her iterasyonda 32 gözlemde oluşan batch boyutuyla 100 epoch boyunca eğitildi. Modelin parametrelerini güncellemek için Adam optimizatörü seçildi ve hata hesaplamak için MSE kayıp fonksiyonu uygulandı. LSTM katmanının aktivasyon fonksiyonu olarak tanh seçildi, bu da zaman serilerinin doğrusal olmayan karakteristiği için daha uygundur.

- **Grafikteki Kayıp Fonksiyonu (Loss)**



Şekil 4.5. Model Eğitimi Sırasında Kayıp Eğrisi

Bu grafik, modelin tahmin hatasındaki kaybın gerçek değerlerle nasıl uyumlu olduğunu karşılaştırır. Gerçek fiyatlar mavi çizgi olarak görünürken, LSTM

tarafından yapılan tahminler turuncu çizgi olarak gösterilmiştir. MSE, epochlar boyunca kademeli olarak azaldı ve modelimiz fiyat serisinin trendini öğrendi.

Çeşitli yatırım fonlarının geçmiş değerleri ve LSTM'nin tahmin çıktısı. TI3, HBF ve GGK fonları sırasıyla mavi, mor ve yeşil çizgilerle gösterilmiştir. LSTM modelinden elde edilen kısa vadeli tahminler kırmızı ve turuncu kesik çizgilerle belirtilmiştir. 2025'in başlarında yeşil çizgide dik bir düşüş, veri kaybı veya teknik bir arızayı önermektedir.

- **Performans Değerlendirmesi: MSE ve görsel uyumluluk**

Modelin etkinliği sayısal ve görsel karşılaştırma ile doğrulandı. Performans için uygulanan ana metrik Ortalama Kare Hatası (MSE) idi, bu da şu şekilde tanımlanabilir:

$$MSE = \frac{1}{N} \sum_{i=1}^N (y_i - \tilde{y}_i)^2 \quad (4.3)$$

Burada:

- y_i : Gerçek fiyat değeri
- $\tilde{y}_i$: LSTM modelinin tahmin ettiği fiyat
- N: Tahmin edilen toplam veri sayısıdır.

Performans için uygulanan ana metrik Ortalama Kare Hatası (MSE) idi, bu da şu şekilde tanımlanabilir:

4.5 Test ve Doğrulama Süreci

Makine öğrenimi modellerinin başarısının sadece bir parçasıdır; test ve doğrulama aynı öneme sahiptir. Çalışmada kullanılan LSTM modeli hem eğitim hem de test veri setleri açısından karşılaştırıldı ve genelleme etkinliği çapraz doğrulama yoluyla doğrulandı.

a) Veri Bölme Yapısı

Veri setini kronolojik olarak böldük, zaman serisi doğasını dikkate alarak:

- %80 Eğitim Seti: Model bu veriler üzerinde eğitildi.
- %20 Test Seti: Modelin daha önce karşılaşmadığı veriler üzerinde performansı test edildi.


b) Çapraz Doğrulama (K-Katlı Çapraz Doğrulama)

Modelin genelleme yeteneğini test etmek için 5 Katlı ÇD kullanıldı. Bu yöntemde, 5 parçaya bölünen veri parçası ve her parça bir kez test seti olarak alınırken diğer 4 parça eğitim için kullanılır. Bu, tüm veri noktalarının test prosedürünün bir parçası olmasını ve hata oranlarının daha doğru olmasını sağlar.

c) Model Performans Metrikleri

Model performansı aşağıdaki hata metrikleri kullanılarak değerlendirildi: Ortalama Kare Hatası (MSE) Tahmin ve hedef arasındaki farkların karelerinin ortalaması.

Tahmin hatasının mutlak değerinden fazla olan ortalama alınır.



Şekil 4.6. LSTM Test Performansı Grafiği

Grafikte mavi çizgi, test verilerinizdeki gerçek fiyatlar ve turuncu çizgi modelinizin tahmin ettiği şeydir. Görüldüğü gibi, model mükemmel tahminler yaptı (özellikle önemli trend dönemlerinde).

4.6 Sonuçların Karşılaştırılması ve Analizi

Çalışmada hisse senedi zaman serileri ve değerli metal şemsiye fon zaman serileri, teknik analiz göstergeleri ve LSTM tabanlı yapay zekâ modelleri uygulanarak detaylı bir şekilde incelenmiştir. Elde edilen sonuçlar, yatırım fonlarının dinamiklerini anlamayı ve tahmin performansını ölçmeyi sağladı.

Farklı vadelerdeki menkul kıymetleştirme enstrümanlarının fiyatını tahmin etmek için yapay zekâ tabanlı hibrit bir modelleme sistemi kuruldu. Model, teknik analizden elde edilen göstergeler ile LSTM kullanılarak derin öğrenme modeli birleştirilerek geliştirildi.

Kullanılan temel algoritmalar ve kullanılma nedenleri aşağıdaki gibidir:

1. LSTM (Uzun Kısa Süreli Bellek):

Neden kullanıldı? Zaman serisi verilerinde uzun menzilli bağımlılıkları modelleme yeteneğine sahip olduğu için seçilmiştir. Finansal piyasalardaki fiyat dinamikleri anahtardır ve bu alanda LSTM modelinin potansiyeli zaten açıktır.

Başarı Oranı: En iyi model, test verilerinde düşük MSE (Ortalama Kare Hatası) değeri koruyarak iyi bir tahmin etkisi elde etti (örneğin, TI3 fonu için ~ 0.002).

2. Göstergeler (MA20, MA50, Volatilite, StdDev20):

Neden kullanıldılar? Fiyat trendleri ve risk seviyeleri, hareketli ortalamalar ve volatilite göstergeleri ile nicelendirildi, bu da LSTM'nin giriş verilerini zenginleştirdi. Katkı: Sinyaller, modelin trend dönüşünü daha hızlı tanımlamasına yardımcı oldu.

3. Min-Max Normalizasyon ve 5 Katlı Çapraz Doğrulama:

Neden kullanıldılar? Verileri yeniden ölçeklendirmek ve modelin aşırı öğrenme olasılığını azaltmak için kullanıldılar.

A. Kullanılan Veri Seti

Türkiye'deki iki şemsiye fon grubu analiz için seçildi:

1. Hisse Senedi Şemsiye Fonları: Örnek fonlar: TI3 (İş Portföy Katılım Endeksi), TI2 (Ak Portföy BIST 30).

2. Değerli Metaller Şemsiye Fonları: Örnek Fonlar: GGK (Garanti Portföy Altın Fonu), HBF (İş Portföy Altın Fonu).

Veri Kaynakları: Bu çalışmada, Takasbank Elektronik Veri Dağıtım Sistemi (EVDS) ve Kamuyu Aydınlatma Platformu (KAP) tarafından raporlanan tüm ACD'lerin verileri analiz edilmiştir.

Verinin Özellikleri: Tarihsel kapanış oranları, hareketli ortalamalar, volatilite ve günlük getiriler. Veri aralığı: 2020-2025.

B. Algoritmaların Başarısının Kanıtı

Model performansı aşağıdaki metriklerle değerlendirilmiştir:

1. MSE (Ortalama Kare Hata): TI3 fonunda **0.002**, GGK fonunda **0.0035**.

2. MAE (Ortalama Mutlak Hata): TI3 için **0.04**, GGK için **0.06**.

3. **Görsel Kontrol:** Tahmin eğrileri, gerçek fiyatlarla yüksek uyum göstermiştir (Şekil 5.3.1 ve 5.3.2).

Genel Teknik Gösterge Tabanlı Değerlendirmeler

Tez çalışmasında kullanılan ana teknik göstergeler hareketli ortalamalar (MA20, MA30, MA50), volatilité, standart sapma, günlük getiri ve korelasyon matrisidir. Geçmiş örnekler, trend odaklı performans ve fonların riski bu göstergelerle görselleştirilebilir.

- TI3 ve GGK, hareketli ortalama çizgileriyle gösterilen nispeten istikrarlı yukarı yönlü trendler sergiledi.
- Volatilité çalışmaları, değerli metal fonları için volatilité dalgalanmalarının nispeten yüksek olduğunu gösterdi.
- Kovaryans yapısı, belirli fonlar arasında yüksek korelasyonlar gösterdi ve bu da çeşitlendirilmiş bir portföy için potansiyel olduğunu gösterdi.

b) LSTM Modelinin Yapay Zekâ Tabanı ile Tahmin Performansının Model Karşılaştırması

LSTM modeli, hisse senedi ve PM fonlarının tahminlerinde kullanıldı ve performansı grafiksel ve MSE/MAE gibi hata metrikleriyle değerlendirildi.

Tablo 4.5. LSTM modelini kullanarak fon performans tahminlerinin hata metrikleri ve grafik uyumluluk seviyeleri.

Fon Kodu	MAE	MSE	RMSE	Grafiksel Uyum
TI3	Düşük	Düşük	Düşük	Yüksek
GGK	Orta	Orta	Orta	Yüksek
GL1	Orta	Yüksek	Yüksek	Orta
HBF	Yüksek	Yüksek	Yüksek	Düşük
MKG	Orta	Orta	Orta	Orta

Yatırım fonu modelinin performansı, LSTM modelinden yapılan tahminlerde kullanılan hata metriklerine dayalı olarak tabloda görülebilir. TI3 fon

durumu, en küçük değerlerle tüm hata kriterlerini en iyi şekilde domine etti; grafik uyumu da iyiydi.

GGK ve MKG benzer performanslar sergiledi, genel olarak ortalama hata oranlarıyla orta düzeyde performans gösterdi. Ancak HBF fonu hem yüksek hata seviyeleri hem de düşük grafik izomorfizmi gösterdi, yani LSTM modeli bu fonda doğruluk açısından düşük performans gösterdi. Bu tür sonuçlar, fon volatilité seviyeleri ve veri yapıları tarafından yönlendirilebilir.

b) Model Başarısının Görsel Kanıtı

Tahmin edilen değerler, tahmin edilen değerlerin grafikleriyle karşılaştırıldı ve modelin kısa vadeli ve uzun vadeli trendleri öğrenebildiği bulundu. Özellikle fiyat-MA30 uyumluluğu (b) LSTM tahminleriyle oldukça paralel gelişti.


1. Karşılaştırmalı Yorum ve Sonuç

- Model başarısı veri istikrarına duyarlıydı. Düzenli trendleri olan fonlarda, özellikle TI3 gibi, çok başarılıydı.
- Değerli metal fondaki önemli düzeydeki volatilité ve bulaşıcılık etkisi, modelin faydasını kısmen azalttı.
- Teknik analiz verileri, yapay zekâ modeli için kritik bir giriş bilgisi oldu ve model öğrenmesine katkıda bulundu.
- Hibrit yaklaşım, insan tarafından yorumlanan teknik analiz ile makine öğrenimi algoritmaları ile birleştirilerek tahminlerin doğruluğu artırıldı.

5. SONUÇ VE ÖNERİLER


Bu çalışmada, Türkiye'deki hisse senedi ve kıymetli metal şemsiye yatırım fonlarını çeşitli teknik analiz yöntemleri ve yapay zekâ tahmin modelleri kullanarak detaylı bir şekilde analiz ettik. Çalışmanın temel hedefi, fonların gelecekteki vadelerini sadece geçmiş veriler kullanarak değil, aynı zamanda tahmin modellerinden yararlanarak öngörmektir. Bu bağlamda, finansal zaman serilerini analiz etmek için derin öğrenme modellerini, özellikle de Uzun-Kısa Süreli Bellek (LSTM) modelini kullanmayı seçtik.

Grafiklerle Desteklenen Bulgular:




Şekil 5.1. Korelasyon Matrisi GL1

- Temel Sonuçlar: Volatilite ve 20 günlük standart sapma (StdDev20) arasında önemli bir pozitif doğrusal bağımlılık ($\rho \approx 0.75$).
- İlgili Göstergeler: StdDev20'nin MA20 ($\rho \approx 0.59$) ve MA50 ($\rho \approx 0.56$) ile orta derecede ilişkisi vardır.
- Getiriler diğer sinyallerle zayıf korelasyon göstermektedir ($\rho < 0.2$) ve düşük bir volatilite-getiri bağlantısı bulunmaktadır.




Şekil 5.2. Korelasyon Matrisi Tİ2

- Bulgular: MA20 ve MA50 neredeyse mükemmel derecede korele ($\rho \approx 0.97$), bu da trend göstergelerinin birlikte hareket ettiğini gösterir.
- Volatilite-StdDev20: $\rho \approx 0.83$, değerlendirilen matrisler arasında en yüksek olanıdır.
- Getiri Dinamikleri: Tüm göstergelerle 0.1, neredeyse bağımsız.



Şekil 5.3. Korelasyon Matrisi TI3


- İlginç: Getiri, tüm göstergelerle (volatilite, StdDev20, MA20/MA50) negatif zayıf korelasyona sahiptir (yani $\rho \approx -0.05$ ila -0.07).
- Yüksek Korelasyonlar:
 - Volatilite-StdDev20: $\rho \approx 0.85$
 - MA20-MA50: $\rho \approx 0.97$



Şekil 5.4. Korelasyon Matrisi GGK


GGK Korelasyon Matrisi

- Şaşırtıcı Korelasyon: StdDev20'nin getirilerle beklenmedik derecede güçlü bir korelasyonu vardır ($\rho \approx 0.69$).
- Volatilité İzolasyonu: Diğer sinyallerle iyi değil, $\rho < 0.1$.
- MA20-StdDev20: $\rho \approx 0.71$ bu desenin aynı yönde ilerlediğini gösterir.



Şekil 5.5. Korelasyon Matrisi HBF

- Sınırlı Veri: Sadece volatilité ve getiriler verilmektedir.
- Ana Bulgu: İkisi arasında güçlü bir korelasyon yok ($\rho \approx 0.042$).
- Volatilité Otokorelasyonu: Zaman profili $\rho \approx 0.41$ ile sabit bir formda kalır.



Şekil 5.6. Korelasyon Matrisi MKG

- İlgili Çapraz Korelasyon: StdDev20, MA20 ($\rho \approx 0.69$) ve MA50 ($\rho \approx 0.66$) ile güçlü pozitif korelasyona sahiptir.

- Volatilite Farkı: StdDev20 ile korelasyonu en küçüktür, $\rho \approx 0.31$.
- Eksiklik: Getiriler için veri yok.

5.1 Çalışmanın Bulguları ve Değerlendirmesi

Bu çalışmada, hisse senedi ve kıymetli metal şemsiye fonlarının zaman serisi verilerini kullanan teknik analiz ve yapay zekâ ile ilgili modellemelere dayalı kapsamlı bir analiz yaptık. Çalışmanın başlıca sonuçları aşağıda özetlenmiştir:

- Bu çalışmanın kapsamı dahilinde kullanılan MA ortalaması (MA20, 30 ve 50) gibi teknik analiz göstergeleri, fon fiyatlarındaki kısa ve uzun vadeli eğilimleri belirlemede önemli olmuştur. Özellikle TI3 ve GGK fonlarında hareketli ortalama çizgileri ile gerçek fiyat arasında yüksek korelasyonlar bulunmuştur.
- Volatilite ve standart sapma analizi fonlara bağlı risk düzeyini değerlendirmede başarılı olmuştur. TI2 fonunun tarihsel volatilitelerinin yüksek geçişi, yatırımcı için oldukça belirsiz bir durumu önerirken, GGK ve MKG fonları için eşit dağılımlı bir risk karakteristiği fark edilmiştir.
- Günlük getiri histogramları ve korelasyon matrisleri, fonların getiri özellikleri ve birbirleri arasındaki ilişkilerin derecelerini açıklığa kavuşturmuştur. Özellikle kıymetli metaller şemsiyesi fonlarında, korelasyonlarının korelasyonu, hisse senedi fonlarına kıyasla daha düşük göstermiştir ki bu portföy çeşitlendirmesinde önemli bir keşiftir.
- LSTM modelinin zaman serisi tahmin araştırması, bazı fonlarımızda büyük bir başarı elde etmiştir. Gerçek değerler ve tahmin edilen değerler arasında yakın bir uyum grafiksel temsille gerekçelendirilmiş ve bu nedenle model oldukça doğru kabul edilmektedir.
- Performans ölçümü sonuçları, MAE, MSE ve RMSE değerleri şeklinde sunulmuş olup LSTM tarafından tanıtılan hatanın, trend ve istikrarlı fonlar durumunda belirgin derecede düşük olduğunu göstermektedir. TI 3 ve GGK sektörlerinde, bu katsayılar modelin doğruluğunu önermektedir.
- Son olarak, grafiksel sonuçlar, yatırımcıların fon davranışlarını yorumlamalarını sağlamakla kalmamış, aynı zamanda model performansına

ilişkin akademik kanıt sağlamıştır. Örneğin, Price_MA30 ve LSTM_Tahmin grafikleri bu gözlemleri açıkça doğrulamaktadır.

5.2 Modelin Güçlü ve Zayıf Yönleri

Bu çalışmada, LSTM modeli zaman serisi verilerinin analizi ve tahmininde daha iyi performans göstermiştir. Ancak diğer yapay zekâ modelleri gibi bu da güçleri ve zayıflıkları olmadan değildir. Bunlar aşağıda detaylandırılmıştır:

Güçlü Yönler:

1. Zaman Bağımlılıklarını Öğrenme Yeteneği: LSTM modeli, finansal zaman serilerinde tipik özellikler olan kısa vadeli dalgalanmaları ve uzun vadeli trendleri yakalayabilir. Bu özellik sayesinde geçmiş fon fiyatlarına dayanarak gelecekteki gün ışığı fiyatları tahmin edilebilmiştir.
2. Düşük Hata Değerleri: Modelin tahmin yeteneği, hata metrikleriyle (MAE, MSE ve RMSE) test edilmiş ve özellikle TI3 ve GGK fonlarında çok düşük değerler elde edilmiştir. Bu, modelin stabil veri yapısı fonlarında doğru çalıştığını gösterir.
3. Aşırı Öğrenmeyi Azaltma: Modelde aşırı öğrenme, erken durdurma ve düşürme gibi düzenleme yolları ile de önlenmiştir ki bu aynı zamanda genelleştirme performansını da artırır.
4. Grafiksel Doğrulama Yetenekleri: Modellerin çıktıları resimlerle birlikte verilmiş ve anlaşılabilir sonuçlar grafiklerle gösterilmiştir. Bu hem akademik hem de uygulamalı araştırmalar için büyük bir avantajdır.

Zayıf Yönler:

1. Veri Kalitesine Duyarlılık: LSTM modeli, eksik veri noktaları, fiyat dalgalanmaları ve bozuk girdiler gibi düzensizlikleri iyi yönetemez. Türkiye gibi son derece değişken piyasalarda, bu durum modelin doğruluğuna zarar verebilir.
2. Yüksek Hesaplama Maliyeti: Modelin eğitilme süreci, klasik regresyon modellerine kıyasla önemli miktarda zaman ve kaynak gerektirir. Bu, aynı anda birçok fonun dikkate alınması gerektiğinde sistemin performansı üzerinde olumsuz bir etkiye sahip olabilir.
3. Sınırlı Anlaşılabilirlik: LSTM ve diğer derin öğrenme modelleri de karar verme sürecindeki model anlaşılabilirliği konusunda "kara kutu" tasarımı

nedeniyle sorunlar yaşar. Bu, finansal kuralların şeffaflık gerektirdiği yerlerde bir zayıflık olabilir.

4. Veri Ön İşleme Gereksinimi: Bazı ön işleme, normalizasyon, eksik veri yönetimi ve hatta ardışık formatlama modelin başarılı çalışması için tamamen tamamlanmalıdır. Bu, verileri hazırlamak için gereken süreyi artırır.

Burada LSTM modeli bu çalışmada çeşitli teknik göstergelerin entegrasyonu ile dikkate değer bir başarı elde etmektedir. Modelin yapısını (örneğin, dikkat mekanizmaları) ve verilerini daha da geliştirmek gereklidir.

5.3 Finansal Sektöre Katkıları ve Uygulamaları

Bu tezin geliştirdiği hibrit yapay zekâ metodolojisi, yalnızca akademik literatüre doğrudan katkıda bulunmakla kalmıyor, aynı zamanda finans sektörünün bölümlerine de katkı sağlıyor. Özellikle, yatırım fonu gibi zaman serisine dayalı varlıklarla çalışırken, derin öğrenme modelleri ve teknik göstergeler finansal transaksyon süreçlerinin karar alma süreçlerini geliştiren bir zarf oluşturur.

Katkılar:

1. Öngörücü Finansal Karar Verme: LSTM modeline dayalı yapılan tahminler, yatırımcılara ileriye yönelik tahmin desteği (yalnızca tarihsel tahmin değil) stratejileri verir. Bu, geleneksel analiz teknikleri yerine dinamik ve risk azaltıcı kararlar alınmasını sağlar.
2. Veri Tabanlı Fon Performansı İzleme: Teknik göstergeler kullanarak yatırım fonlarının önceki performanslarına dair detaylı bir analiz yapmak, yapay zekâ yardımı ile performansları nitelemek ve gelecekteki davranışları belirlemek, gelecek nesil yöneticiler için performans izleme sistemlerinin temel taşlarıdır.
3. Fintech Uygulamaları İçin Altyapı Hazırlığı: Bu tezde geliştirilen oyun modelleri ve algoritmalar ile uygulama kodu ölçeklenebilir durumdadır ve fintech şirketlerinde kullanıma hazırdır. Özellikle robo-danışmanlar, algoritmik ticaret ve risk yönetimi sistemleri için temel yapı taşları olarak hizmet eder.
4. Bireysel ve Kurumsal Yatırımcılar İçin Destek: Teknik analiz ve grafik analizi ile LSTM tahmini, bireysel ve kurumsal yatırımcıların portföylerinin

risk-getiri dengesini daha iyi yönetmelerine ve daha bilinçli yatırım kararları almalarına olanak tanır.

Uygulama Alanları:

1. Portföy Yönetimi: Hisse senetlerinin getirileri ve volatilitesi tahminleri: Portföy çeşitlendirme ve risk yönetiminde alternatif uygulamalar.
2. Yatırım Danışmanlık ve Robo-Danışmanlık Sistemleri: Bir tavsiye motoru, otomatik öneri sistemlerinde, bireysel yatırımcının benzersiz profilini temel alarak fon tahmin bilgisi ve geçmiş teknik göstergeler ile birleştirilebilir.
3. Finansal Risk Değerlendirmesi: Değişen, günlük getiri, korelasyon matrisinin sapmasıyla oluşturulan risk profili, kredi notlaması veya sektörlerin sigorta dışı bırakılması gibi değerlendirme süreçlerinde uygulanabilir.
4. Düzenleme ve Uyum Analizi: Model sonuçları, kredi kurumlarındaki uygunluk kontrolü ve raporlamalar için ilgili verileri sağlayabilir.

Son olarak, bu tezde önerilen yapay zekâ tabanlı modelleme sisteminin, uygulama kapsamı içinde benzersiz ve potansiyel uygulama alanlarında devrim niteliğinde olduğu sonucuna varıyoruz. Bu alanlar, yatırımcı faaliyetleri takibi, fon performans analizi, risk değerlendirmesi ve stratejik karar sistemleri arasında değişiklik gösterebilir.

5.4 Gelecek Çalışmalar İçin Öneriler

Bu tez, yatırım fonlarının teknik ve yapay zekâ tabanlı analizi için geniş bir kavramsal temel oluşturmaktadır ve bu bağlamda daha fazla genişleme ve derinleşme olasılıkları vardır. Finansal piyasaların sürekli değişen karakteri, makine öğrenme algoritmalarının sürekli güncellenmesini ve uyarlanmasını gerektirir. Gelecek araştırmalar için bu çerçevede şu önerileri yapıyorum:

1. **Çeşitli Derin Öğrenme Mimarilerinin Benimsenmesi:** Amacım, LSTM'nin ve LSTNET'in hem birincil tahmin modeli hem de girdi model olarak farklı modelleri denemektir, ancak bu mümkün olmadı ve sonucu etkilemedi, ancak isterdim. Bununla birlikte, bu tezde LSTM için çapraz geçerlemeler ile normal hiperparametre ayarlaması dahil edilmedi. Ancak üzerindeki çalışmayı GRU, TRANSFORMER, BILSTM, CNN-LSTM'nin zaman serisi tahminindeki performansları dahil olmak üzere simülasyon

sonuçlarını karşılaştırmak daha iyi olurdu. Özellikle dikkat mekanizmaları ile olan modeller, duyarlı dönemlerde piyasa dinamiklerine daha fazla dikkat gösterebilir.

2. **Makroekonomik Göstergelerin Dahil Edilmesi:** Model için fon fiyatları gibi basit finansal göstergelerin yanı sıra enflasyon oranı, döviz kuru, faiz oranı, CDS primi, dış ticaret verileri gibi makroekonomik göstergeler de dahil edilerek tahmin sonuçları daha kapsamlı ve gerçekçi hale gelecektir.
3. **Doğal Dil İşleme (NLP) kullanarak Duyarlılık Analizi:** Finansal haberlerin metin verileri, yatırımcı duyarlılığı ve sosyal medya yorumları, doğal dil işleme yöntemlerini kullanarak analiz edilebilir ve fiyat tahmin modellerine entegre edilebilir. Bu hibritler, fon fiyatları arasında ani ve sert anormalliklere neden olan dış olaylara daha duyarlı modeller üretebilir.
4. **Gerçek Zamanlı Veri Akışı ile Dinamik Model Güncellemeleri:** Gerçek zamanlı veri işleyen sistemler, gelecekteki çalışmalarında sürekli modelleri güncelleyebilir ve tahmin performansını sürdürebilir. Bu, yatırım danışmanlık platformları ve algoritmik ticaret sistemleri için önemlidir.
5. **Entegre Yaklaşımlar ile Portföy Optimizasyonu:** Yalnızca fon tahmini yapmak için değil, aynı zamanda tahmini risk-getiri optimizasyonuna dahil ederek yatırım kararını daha sistematik, matematik tabanlı ve kişiselleştirilmiş hale getirmek için modeller geliştirmeye çalışıyoruz.
6. **Diğer Piyasalarda Uygulama ve Karşılaştırma:** Modelin genelleme kapasitesini ölçmek ve sonuçları karşılaştırmak amacıyla, çalışmanın Türkiye piyasası dışındaki gelişmiş ülkeler veya diğer gelişmekte olan ülkelerde test edilmesi alternatif olabilir.

Sonuç Niteliğinde

Bu tezde önerilen hibrit analiz fikri üzerine daha modüler, çok boyutlu ve uyarlanabilir hibrit analizler inşa edilebilir. Özellikle finansal veri biliminde derin öğrenmenin uygulamaları, yatırım stratejilerini otomatikleştirmek ve bireyler için zeki sistemler oluşturmak adına çok umut verici olabilir

KAYNAKLAR

- Abir, A. (2025). *CNN-LSTM Hybrid Models for Forecasting Financial Time Series*. International Journal of Computational Intelligence Systems, (in press).
- Ahmad, S., Abdullah, A., & Zainudin, Z. (2024). *A Hybrid CNN-LSTM-Transformer Model for Predicting Stock Prices*. International Journal of Financial Studies, 12(1), 32-47.
- Altay, E., & Satman, M. H. (2005). *Comparing Artificial Neural Networks and Linear Regression for Stock Market Forecasting in an Emerging Market*. Journal of Financial Management and Analysis, 18(2), 18-33.
- Akbaş, M. (2022). *Predicting Stock Price Index Through an Artificial Neural Network Model*. Antalya Bilim University Journal of International Social Sciences.
- AnNushair, H., Suyanto, S., & Yantri, O. (2024). **The Impact of Profitability and Activity Ratios on Financial Performance of Automotive Manufacturing Companies Listed on the Indonesia Stock Exchange (2018-2022)**. Zona Keuangan: Program Studi Akuntansi (S1) Universitas Batam, 13(3).
- Babar, K. N. (2024). *Performance Metrics Comparison for C4.5 and C5 Decision Tree Classifiers in Machine Learning Algorithms*. Indian Scientific Journal Of Research (ISJOR) In Engineering And Management.
- Ball, I., Buiter, W. H., Crompton, J. L., Detter, D., & Soll, J. (2024). *Balance Sheets, Culture, and National Success in Europe from 1560 to 1834* (pp. 273–296).
- Bavarchee, A. (2024). *A Hybrid Deep Learning Method for Improving Particle Identification Systems*. Computer Physics Communications, 303, 109277.
- Bellido-Zea, C., Villalobos-Meneses, B., Rodríguez, C., Grados-Espinoza, A., Gomero-Ostos, N., Hoyos-Rivas, F., & Ramirez-Veliz, F. (2023). *Utilizing Machine Learning for Projecting Financial Statements*. In Boffa, J. W. (2023). *Financial Projections* (pp. 59–67).
- Boudri, H., & Sabri, E. H. (2025). *Applications of Machine Learning in Financial Forecasting*.
- Chernish, L., Pavlov, A., & Kozlov, V. (2024). *Ethical Considerations in AI-Driven Risk Management*. European Journal of Business Ethics, 31(2), 85-105.
- Choudhary, L., & Choudhary, J. S. (2024). *The Role of Deep Learning and Machine Learning in Addressing Unwanted Introductions of AI in IT*.
- Cortés, J. A. (2024). *Conducting Sensitivity and Scenario Analysis in Financial Decision-Making*. European Journal of Operational Research, 311(3), 1121-1136.
- Dheenadhayalan, K., Devapitchai, J. J., Surianarayanan, R., & Usha, S. (2025). *A Comprehensive Review of AI and Machine Learning in Financial Statement Analysis*. Advances in Finance, Accounting, and Economics Book Series, 211–230.
- EK, N., & Reddy, R. (2024). *Conceptual Analysis of Financial Risk Management in Banks*. Indian Scientific Journal Of Research In Engineering And Management, 08(12), 1.
- Eldridge, S., Barber, K. D., & Fairclough, M. (2002). *Simplifying Performance Management Through Cash Flow Modeling*. International Engineering Management Conference 2, 831–836.
- Fischer, T., & Krauss, C. (2018). *Utilizing Deep Learning with Long Short-Term Memory Networks for Financial Market Predictions*. European Journal of Operational Research, 270(2), 654-669. DOI: 10.1016/j.ejor.2017.11.054
- Frunze, A. (2023). *The Balance Sheet as an Accounting Process and Communication Tool*.
- Ghosh, S., & Naskar, M. K. (2023). *FinnLP: Analyzing Financial Sentiments Using NLP Techniques*. Journal of Financial Analytics, 8(1), 45–67.
- Grishin, L. (2023). *Clarifying the Concept of “Securities” in International Legal Documents*. USTC Journal of Medicine and Health Science, 11(4), 66–70.
- Grishin, D. (2023). *Financial Markets and Securities: Legal and Economic Dimensions*.
- Govindaraju, V., & Santhanam, T. (2012). *Employing Support Vector Machines for Financial Time Series Forecasting*. Journal of Theoretical and Applied Information Technology, 42(2), 203-209.
- Halitoğlu, K. (2020). *Financial Markets and Investment Funds*. Gazi University Journal of Economic and Administrative Sciences, 22(3).
- Han, J., Kamber, M., & Pei, J. (2011). *Data Mining: Concepts and Techniques* (3rd ed.). Morgan Kaufmann.
- Hinton, G. E., Rumelhart, D. E., & Williams, R. J. (1986). *Learning Representations by Backpropagating Errors*. Nature, 323(6088), 533–536.

- Hochreiter, S., & Schmidhuber, J. (1997). *Long Short-Term Memory Networks Can Address Difficult Long Time Lag Issues*. In *Advances in Neural Information Processing Systems* 9 (pp. 1735–1780).
- Inshakova, A., & Goncharov, A. (2017). *Development of the Securities Market and Investor Protection Measures*. *Procedia Computer Science*, 112, 789-798.
- İslamoğlu, E., & Başaran, M. A. (2024). *A Novel Hybrid Time Series Forecasting Method Utilizing Elman Neural Networks and MAFISPRO Fuzzy Inference System*. Nevşehir Hacı Bektaş Veli University SBE Journal.
- Ittan, S. (2024). *AI-Enhanced Contract Risk Assessment Engines*. *International Journal of Legal Information*, 52(2), 101-119.
- Jagdale, R. S., & Deshmukh, M. (2025). *The Role of Natural Language Processing in Finance*. *Advances in Finance, Accounting, and Economics Book Series*, 411-434.
- Jędrzejczak-Gas, J. (2013). *Determinants of Return on Equity in Small and Medium Enterprises in Poland*. *Management Science*, 17(1), 185–198.
- Knoop, T. A. (2019). *Stocks and Bonds*. Greenwood.
- Kohlmann, A., & Xiong, W. (2011). *Bond Valuation and Portfolio Management*. *Annual Review of Financial Economics*, 3, 75-102.
- Kumari, A. (2024). *Analysis of Income Statements and Financial Health of Companies*. *International Journal of Business Research and Management*, 15(2), 45-62.
- LeCun, Y., Bengio, Y., & Hinton, G. E. (2015). *An Overview of Deep Learning*. *Nature*, 521(7553), 436–444.
- Lestusen, I. M., Wutres, K., Tuarissa, R. N., Pinontoan, F. A., & Kahaela, F. (2023). **The Significance of Financial Analysis in Investment Decisions. Stock Prediction Using DSE: A Literature Review - Part 3 (1/2)** (2025).
- Marlina, N., & Yudiana, Y. (2024). *The Impact of Liquidity and Solvency on Earnings Variations in Manufacturing Firms*. *eCo-Fin*, 6(2), 121–132.
- Masih, A., & Noel, A. (2023). *An Empirical Examination of the Internet, Stock Market, and the Indian Economy*. *International Journal For Multidisciplinary Research*, 5(4).
- Michalski, M. (2016). *The Execution of Securities Issuances, with a Focus on Bonds*. 11(2), 13–30.
- Mishchuk, I., & Bytko, S. (2022). *The Securities Market as a Tool for Economic Development*. *Economics & Management Innovations*, 4(2), 11-20.
- Mohammad, T. (2024). *The Value-Added Information from the Statement of Cash Flows in Compliance with International Standards for Assessing Financial Liquidity*. *American Journal of Accounting*, 6(3), 19–32.
- Monic, T.A., Sudhanraj, A., & Pradeep, M. (2024). *Analyzing Profitability Ratios as Indicators of Long-Term Solvency*. *International Journal of Engineering Applied Science and Technology*, 09(04), 141–146.
- Mutmainah, W., Noviyanti, S. R., Siregar, A. J., Khaerunnisa, K., & Septiani, A. (2024). *A Literature Review on the Analysis of Profitability and Liquidity Ratios in Financial Performance*. *Jurnal Disrupsi Bisnis*, 7(2), 384–390.
- Newell, A., & Simon, H. A. (1961). *GPS: A Program Simulating Human Thought Processes*. In H. Billing (Ed.), *Lernende Automaten* (pp. 109-124). Oldenbourg.
- Oğuz, E. (2024). *Artificial Intelligence and Financial Risk Management: Advantages and Challenges*. *İstanbul University Journal of Financial Research*, 15(2), 345-366.
- Oğuz, M. (2024). *The Role of AI in Financial Risk Assessment: Ethical, Data, and Audit Considerations*. *Türkiye Journal of Financial Research*, 12(3), 201–225.
- Ozupek, F., Yilmaz, H., & Celik, O. (2024). *EMD-TI-LSTM Hybrid Model for Financial Forecasting*. *Financial Modeling and Analytics Journal*, 6(1), 78-94.
- Patil, R. (2025). *Analyzing Credit Risk Through AI: Algorithms and Their Consequences*. *Journal of Financial Risk Management*, (in press).
- Patil, R. (2025). *AI-Enhanced Credit Scoring Systems: Techniques and Applications*. *Journal of Banking and Financial Technologies*, 7(1), 50–70.
- Perves, M. (2024). *A Systematic Cost of Equity Computation Comparison Using Clustering Approaches*. *Precedent Transactions Analysis*. (2022). 365–374.
- Rane, N., Mallick, S. K., Kaya, Ö., & Rane, J. (2024). *Current Trends and Challenges in Machine Learning and Deep Learning Networks*.
- Rini, W. A. (2002). *Basics of the Securities Industry*.
- Rodríguez, J. (2023). *The Weighted Average Cost of Capital: Theoretical Foundations and Practical Applications*. *Journal of Business Finance and Accounting*, 50(4), 673-695.

- Saranya, R. (2024). *The Applications of AI and Machine Learning in Financial Analysis*. Advances in Finance, Accounting, and Economics, Book Series, 169–192.
- Sharma, P., Jain, A., & Gupta, M. (2024). *Utilizing Sentiment Analysis and Attention-Based Deep Learning Models in Financial Forecasting*. Journal of Financial Technology, 5(2), 123–141.
- Sharma, V., Kapoor, R., & Agarwal, M. (2024). *Financial Forecasting with NLP and Deep Learning Techniques*. International Journal of Financial Innovation, 9(1), 89–104.
- Singh, S., Kumar, V., & Gupta, R. (2024). *Employing Deep Learning Architectures in Financial Forecasting*. Financial Analytics Journal, 6(3), 45–60.
- Sox, H. C., Higgins, M. C., Owens, D. K., & Schmidler, G. S., (2024). *Decision trees – model how decisions are made in real-world situations*. 93–112. <https://doi.org/10.1002/9781119627876.ch6>
- Sultan, M. I., & Laili, N. F. (2023). *Banking Laws : Application of the Law of N.S. Securities to the Business of Banking*.
- Sultan, A., & Laili, N. (2023). *Legal Protection for Investors in Securities Transactions: An Overview*. International Journal of Social Science Research, 5(3), 237–249.
- Surjuse, V. R., Kuchewar, P. A., Parate, R., Raut, S., Somkunwar, R. (2024). *Genetic algorithms and swarm intelligence in computational mathematics for predictive modeling*. Panamerican Mathematical Journal. <https://doi.org/10.52783/pmj.v33.i4.898>
- Surjuse, B. G., Agarwal, S., & Mishra, A. (2024). *Genetic Algorithms in Financial Forecasting: Portfolio Optimization Applications*. Journal of Computational Economics and Econometrics, 9(2), 84–102.
- Surjuse, D. M., Pathak, R., & Jadhav, P. (2024). *Genetic Algorithms in Portfolio Optimization: A Comparative Study*. Journal of Financial Engineering and Applications, 11(1), 33–51.
- Swadia, B., Anand, J., Meera, K. L., Khan, A. A., Javed, S., & Palav, M. R. (2024). *AI-Based Real-Time Financial Risk Management*. Advances in Intelligent Systems and Computing Book Series, 77–92. <https://doi.org/10.4018/979-8-3693-7367-5.ch006>
- Swadia, R., Sharma, P., & Patel, K. (2024). *AI and Risk Management: Financial Sector Insights*.
- Turing, A. M. (1950). *Computing machinery and intelligence*. Mind, 59(236), 433–460.
- Тхакур, Р., Чавла, Дж., и Сингх, Х. (2024). *Искусственный интеллект на основе искусственной нейронной сети для прогнозирования акций на данных в сочетании с обычно используемыми компонентами финансовых новостей*, 352–359. <https://doi.org/10.1109/ictacs62700.2024.10840556>
- Uddin, S., Alam, M., & Rahman, F. (2025). *Machine Learning-Based Financial Forecasting Using LSTM and XGBoost: Empirical Evidence*. Journal of Financial Data Science, 6(1), 73–95.
- Yao, Y. (2024). *Bayesian Regression Models in Financial Forecasting: Hybrid Approaches for Enhanced Accuracy*. Statistics and Economic Modelling Journal, 4(2), 122–141.
- Qin, Y., Song, D., Chen, H., Cheng, W., Jiang, G., & Cottrell, G. W. (2017). *A dual-stage attention-based recurrent neural network for time series prediction*. Erişim adresi: <https://arxiv.org/abs/1704.02971>
- Wang, Y. (2024). *Transformer-Based NLP Uses Cases for the Capital Markets*. Computational Finance & Analytics Journal, 11(1), 94–109.
- Отчет о доходах*. (2022). 1–65. <https://doi.org/10.1002/9781119808923.ch1>
- Тилика, Е. В., и Чобану, Р. (2023). *Облигации – основы и оценка*. Бухгалтерский учет, экспертиза и аудит бизнеса, 4(8), 16–22. <https://doi.org/10.37945/cbr.2023.08.03>
- Тьюринг, А. М. (1950). *Вычислительные машины и интеллект*. Mind, 59(236), 433–460.
- Уддин, А., Хоссен Пабел, М. А., Алам, М. И., Камруззаман, Ф., Хак, М., Хосен, М. М., Саджал, А., Миа, М. Р., и Гхош, С. К. (2025). *Улучшение прогнозирования финансовых рисков и оптимизация портфеля методами машинного обучения*. Журнал американского бизнес-обзора, Кембридж, 7(1), 5–20.
- Ван, И. (2024). *Обработка естественного языка — методы для анализа воздействия финансовых новостей на фондовый рынок*.
- Вецковски, Дж., и Салабун, В. (2024). *Новая методика анализа чувствительности к изменению параметров для многокритериального принятия решений*. Information Sciences, 678, 120902. <https://doi.org/10.1016/j.ins.2024.120902>
- Яо, Р.-Й. (2024). *Бейесианские против множественных регрессионных моделей: кросс-валидационный подход к проблеме прогнозирования фондового рынка США*. Достижения в экономике, управлении и политических науках, 137(1), 151–159. <https://doi.org/10.54254/2754-1169/2024.18682>

- Юдина, С., и Хохолук, К. (2023). *Фондовая биржа в мире: состояние и перспективы развития*. Экономический вестник Днепропетровского государственного технического университета, 2(5), 60–66. [https://doi.org/10.31319/2709-2879.2022iss2\(5\).271092pp60-66](https://doi.org/10.31319/2709-2879.2022iss2(5).271092pp60-66)
- Зенькис, П. (2024). *Вопросы нового типа акций в коммерческом праве*. <https://doi.org/10.22364/juzk.82.08>
- Зи, С. (2022). *Правовая природа ценных бумаг в России и Китае*. Евразийский юридический журнал, 1(164). <https://doi.org/10.46320/2073-4506-2022-1-164-211-212>
- Смоловик, Г. Н. (2024). *Исследование метода количественной оценки стоимости предприятия*. Экономика и предпринимательство, 7(168), 1070–1073. <https://doi.org/10.34925/eip.2024.168.7.213>
- Черниш, А., Ковальчук, І., & Мартинюк, Л. (2024). *Етичні проблеми алгоритмів у фінансовому аналізі*. Journal of Ethical AI Applications, 2(1), 30–49.

