



AKDENİZ ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ



İzel COŞKUN

FINANSAL PİYASALARDA YAPAY ZEKÂ UYGULAMALARI: BIST 30 ENDEKSİNİN
LSTM İLE TAHMİNİ

Finans ve Bankacılık Anabilim Dalı
Yüksek Lisans Tezi

Antalya, 2025



AKDENİZ ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ



İzel COŞKUN

FINANSAL PİYASALARDA YAPAY ZEKÂ UYGULAMALARI: BIST 30 ENDEKSİNİN
LSTM İLE TAHMİNİ

Danışman

Doç. Dr. Ulaş ÜNLÜ

Finans ve Bankacılık Anabilim Dalı
Yüksek Lisans Tezi

Antalya, 2025

T.C.
Akdeniz Üniversitesi
Sosyal Bilimler Enstitüsü Müdürlüğüne,

İzel Coşkun'un bu çalışması, jürimiz tarafından Finans ve Bankacılık Anabilim Dalı Yüksek Lisans Programı tezi olarak kabul edilmiştir.

Başkan :Doç. Dr. Nuri Avşarlıgil (İmza)

Üye (Danışman) : Doç. Dr. Ulaş ÜNLÜ (İmza)

Üye :Dr. Öğrt. Üyesi Ercüment Doğru (İmza)

Tez Başlığı: Finansal Piyasalarda Yapay Zekâ Uygulamaları: BIST 30 Endeksinin LSTM İle Tahmini
--

Onay: Yukarıdaki imzaların, adı geçen öğretim üyelerine ait olduğunu onaylarım.

Tez Savunma Tarihi : 17/09/2025

Mezuniyet Tarihi : 16/10/2025

AKADEMİK BEYAN

Yüksek Lisans Tezi olarak sunduğum “Finansal Piyasalarda Yapay Zekâ Uygulamaları: BIST 30 Endeksinin LSTM İle Tahmini” adlı bu çalışmanın, akademik kural ve etik değerlere uygun bir biçimde tarafımda yazıldığını, yararlandığım bütün eserlerin kaynakçada gösterildiğini ve çalışma içerisinde bu eserlere atıf yapıldığını belirtir; bunu şerefimle doğrularım.

(İmza)

İzel COŞKUN





T.C.
AKDENİZ ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ



09/10 /2025

TEZ ÇALIŞMASI ORJİNALLİK RAPORU BEYAN BELGESİ

Öğrenci Bilgileri	
Adı-Soyadı	İzel COŞKUN
Öğrenci Numarası	202252121007
Anabilim Dalı	Finans ve Bankacılık
Programı	Tezli Yüksek Lisans
Danışman Öğretim Üyesi Bilgileri	
Unvanı, Adı-Soyadı	Doç. Dr. Ulaş ÜNLÜ
Yüksek Lisans Tez Başlığı	Finansal Piyasalarda Yapay Zekâ Uygulamaları: BIST 30 Endeksinin LSTM İle Tahmini
Turnitin Bilgileri	
Ödev Numarası	2774884872
Rapor Tarihi	09/10/2025
Benzerlik Oranı	Alıntılar hariç: % 6 Alıntılar dahil: % 6
SOSYAL BİLİMLER ENSTİTÜSÜ MÜDÜRLÜĞÜNE, Yukarıda bilgileri bulunan öğrenciye ait tez çalışmasının a) Kapak sayfası, b) Giriş, c) Ana Bölümler ve d) Sonuç kısımlarından oluşan toplam 91 sayfalık kısmına ilişkin olarak Turnitin adlı intihal tespit programından Sosyal Bilimler Enstitüsü Tez Çalışması Orijinallik Raporu Alınması ve Kullanılması Uygulama Esaslarında belirlenen filtrelemeler uygulanarak yukarıdaki detayları verilen ve ekte sunulan rapor alınmıştır. Danışman tarafından uygun olan seçenek işaretlenmelidir: (X) Benzerlik oranları belirlenen limitleri aşmıyor ise: Yukarıda yer alan beyanın ve ekte sunulan Tez Çalışması Orijinallik Raporunun doğruluğunu onaylarım. () Benzerlik oranları belirlenen limitleri aşıyor, ancak tez/dönem projesi danışmanı intihal yapılmadığı kanısında ise: Yukarıda yer alan beyanın ve ekte sunulan Tez Çalışması Orijinallik Raporunun doğruluğunu onaylar ve Uygulama Esaslarında öngörülen yüzdelik sınırlarının aşılmasına karşın, aşağıda belirtilen gerekçe ile intihal yapılmadığı kanısında olduğumu beyan ederim.	
Gerekçe:	
Benzerlik taraması yukarıda verilen ölçütlere uygun olarak tarafımca yapılmıştır. İlgili tezin orijinallik raporunun uygun olduğunu beyan ederim.	
Danışman Öğretim Üyesi Doç. Dr. Ulaş ÜNLÜ İmza	

İÇİNDEKİLER

ŞEKİLLER LİSTESİ	iv
TABLolar LİSTESİ	v
KISALTMALAR LİSTESİ	vi
ÖZET	vii
ABSTRACT	viii
ÖNSÖZ	ix
GİRİŞ	1

BİRİNCİ BÖLÜM

YAPAY ZEKÂ VE KAVRAMSAL ÇERÇEVE

1.1. Yapay Zekânın Tanımı Ve Tarihi	2
1.2. Yapay Zekânın Kronolojik Sıralaması	3
1.3. Yapay Zekânın Geleceği	4
1.4. Yapay Zekânın Kullanım Alanları	5
1.4.1. Turizm	5
1.4.2. Finans	6
1.4.3. Sağlık	6
1.4.4. Eğitim	7
1.4.5. Ulaşım	8
1.4.6. Tarım	8
1.4.7. Savunma ve Güvenlik	8
1.5. Yapay Zekânın Türleri Ve Açıklamaları	10
1.5.1. Dar Yapay Zekâ	10
1.5.2. Genel Yapay Zekâ	11
1.5.3. Süper Yapay Zekâ	11

İKİNCİ BÖLÜM

FİNANSTA KULLANILAN YAPAY ZEKA MODELLERİ

2.1. Makine Öğrenmesi.....	13
2.1.1. Doğrusal Regresyon.....	17
2.1.2. Lojistik Regresyon.....	18
2.1.3. Destek vektör Makineleri	19
2.1.4. Karar Ağaçları	21
2.1.5. En Yakın Komşu.....	23
2.2. Derin Öğrenme Modelleri.....	26
2.2.1. Yapay Sinir Ağları	27
2.2.2. Tekrarlayan Sinir Ağları	31
2.2.3. Konvolüsyonel Sinir Ağları	32
2.3. Takviyeli Öğrenme	34
2.3.1. Q-Öğrenme	34
2.3.2. Derin Q- Öğrenme	36
2.4. Genetik Algoritma	36
2.4.1. Genetik Programlama	39
2.4.2. Genetik Algoritma Tabanlı Sıralama.....	41
2.4.3. Küme Tabanlı Genetik Algoritma	42
2.4.4. Çok Amaçlı Genetik Algoritma.....	43
2.4.5. Gelişmiş Genetik Algoritma	46

ÜÇÜNCÜ BÖLÜM

FİNANSAL PİYASALARDA YAPAY ZEKA UYGULAMALARI

3.1. Literatür	47
3.1.1. Ulusal Literatür	47
3.1.2. Uluslararası Literatür	52
3.2. Veri Yapısı ve Yöntem	53
3.2.1. Yöntem	54

3.3. Bulgular	55
SONUÇ	68
KAYNAKÇA.....	71
ÖZGEÇMİŞ	77



ŞEKİLLER LİSTESİ

Şekil 1.1 Toplumsal Değişim Ve Dönüşüm	10
Şekil 2.1 Makine Öğrenme Teknikleri	14
Şekil 2.2 Makine Öğrenmesi	16
Şekil 2.3 Lojistik Regresyon Eğrisi	18
Şekil 2.4 Destek Vektör Gösterimi	19
Şekil 2.5 Lineer Ayrılabilme Durumu Gösterimi	20
Şekil 2.6 Lineer Ayrılamama Durumu Gösterimi	21
Şekil 2.7 K-En Yakın Komşu Öğrenmesi Gösterimi.....	26
Şekil 2.8 Derin Öğrenme Üçgeni.....	27
Şekil 2.9 Yapay sinir Ağları İşleyiş Şeması	29
Şekil 2.10 Tek Katmanlı Yapay Sinir Ağları Modeli	30
Şekil 2.11 Çok Katmanlı Yapay Sinir Ağları Modeli.....	30
Şekil 2.12 İleri Beslemeli Yapay Sinir Ağları Modeli	31
Şekil 2.13 Geri beslemeli Yapay Sinir Ağları Modeli.....	31
Şekil 2.14 Tekrarlayan Sinir Ağları Modeli	31
Şekil 2.15 Konvolüsyonel Sinir Ağları Modeli	33
Şekil 2.16 Q Öğrenme Akış Modeli	35
Şekil 2.17 Derin Q Öğrenme Akış Modeli	36
Şekil 2.18 Genetik Algoritma Akış Modeli	37
Şekil 2.19 Genetik Programlama, Çaprazlama ve Mutasyon Modeli.....	40
Şekil 2.20 Çok Amaçlı Genetik Algoritma Akış Modeli	44
Şekil 3.1 LSTM Hücre Yapısı Ve Kapıları	54
Şekil 3.2 Eğitim Geçmiş Boyunca MSE Kayıplarının İzlenmesi.....	66
Şekil 3.3 LSTM Modeli Kullanılarak Son 200 Günlük Fiyat Ve 5 Günlük İleri Tahmin	67

TABLÖLAR LİSTESİ

Tablo 1.1 Yapay Zekanın Kronolojik Sıralaması	3
Tablo 3.1: LSTM Tabanlı Çok Değişkenli Zaman Serisi Modeli Yapısı.....	65
Tablo 3.2 Model Performansı (Log Getiri Uzayı)	66



KISALTMALAR LİSTESİ

ARIMA	: Otoregresif Bütünleşik Hareketli Ortalama (Auto Regressive Integrated Moving Average)
AUS	: Akıllı Ulaşım Sistemleri
BIST 100	: Borsa İstanbul 100 Endeksi
DNN	: Derin Sinir Ağı (Deep Neural Network)
DYZ	: Dar Yapay Zekâ
GARCH	: Genelleştirilmiş Koşullu Değişen Varyanslı Otoregresif Model (Generalized Autoregressive Conditional Heteroskedasticity)
GBM	: Gradyan Artırma Makinesi (Gradient Boosting Machine)
GYZ	: Genel Yapay Zekâ
İHA	: İnsansız Hava Araçları
LOG	: Lojistik Regresyon (Logistic Regression)
LSTM	: Uzun Kısa Süreli Bellek Ağı (Long Short-Term Memory)
MAE	: Ortalama Mutlak Hata (Mean Absolute Error)
MSE	: Ortalama Kare Hata (Mean Squared Error)
RAF	: Rastgele Orman Algoritması (Random Forest)
RMSE	: Kök Ortalama Kare Hata (Root Mean Squared Error)
RNN	: Yinelemeli Sinir Ağı (Recurrent Neural Network)
SARIMA	: Mevsimsel ARIMA (Seasonal ARIMA)
SİHA	: Silahlı İnsansız Hava Araçları
SVR	: Support Vector Regression
SYZ	: Süper Yapay Zekâ
TFT	: Zamansal Birleştirme Dönüştürücüleri (Temporal Fusion Transformers)
VAR	: Vektör Otoregresyon (Vector Autoregression)
XGBoost	: Aşırı Gradyan Artırma (eXtreme Gradient Boosting)
YSA	: Yapay Sinir Ağı

ÖZET

Bu tez çalışmasında, finansal piyasalarda yapay zekâ tabanlı yöntemlerin veriyle uygulama potansiyeli incelenmiş ve Borsa İstanbul 30 (BIST 30) endeksine ait 5 Ocak 1997 – 6 Eylül 2025 tarihleri arasındaki günlük kapanış verileri kullanılarak LSTM tabanlı bir tahmin modeli geliştirilmiştir. Çalışmanın amacı, geleneksel yöntemlerin yetersiz kaldığı piyasa tahmini süreçlerinde derin öğrenme tekniklerinin sunduğu avantajları ortaya koymaktır.

Analizler, Python programlama dili kullanılarak Google Colab ortamında gerçekleştirilmiş; logaritmik getiri, hareketli ortalamalar (MA5, MA20), RSI14 ve volatilité (Vol20) göstergeleri modele giriş değişkeni olarak dahil edilmiştir. Veri seti %70 eğitim, %15 doğrulama ve %15 test olmak üzere üç alt kümeye ayrılmış; giriş değişkenleri StandardScaler, hedef değişken ise yalnızca eğitim setine göre fit edilen MinMaxScaler ile ölçeklendirilmiştir.

LSTM(128) → Dropout(0.30) → LSTM(64) → Dense(32, ReLU) → Dense(1) mimarisiyle oluşturulan model, Adam optimizasyon algoritması ve MSE (Ortalama Kare Hata) kayıp fonksiyonu ile eğitilmiştir. Aşırı öğrenmeyi (overfitting) önlemek amacıyla EarlyStopping ve ReduceLROnPlateau stratejileri kullanılmıştır. Modelin performansı RMSE, MAE ve yön isabeti metrikleri ile değerlendirilmiş ve persistence yaklaşımı ile karşılaştırılmıştır.

Sonuçlar, LSTM tabanlı modelin logaritmik getiri tahminlerinde düşük hata oranları ve yön tahminlerinde rekabetçi başarı düzeyine ulaştığını göstermektedir. Elde edilen bulgular, LSTM mimarisinin finansal zaman serilerinin tahmininde etkili bir yöntem olduğunu ortaya koymakta; derin öğrenme tekniklerinin finansal piyasalarda daha isabetli ve esnek tahminler için güçlü bir araç sunduğunu desteklemektedir. Gelecek çalışmalarda, farklı piyasa rejimlerini, makroekonomik göstergeleri ve haber akışlarını içeren daha kapsamlı veri setleriyle modelin performansının geliştirilmesi önerilmektedir.

Anahtar Kelimeler: Yapay Zekâ, Derin Öğrenme, LSTM, Finansal Piyasalar, Borsa İstanbul, Zaman Serisi Tahmini, Makine Öğrenmesi, Tahmin Modelleri.

ABSTRACT

APPLICATION OF ARTIFICIAL INTELLIGENCE IN FINANCIAL MARKETS

In this thesis, the applicability of artificial intelligence-based methods in financial markets has been examined. A prediction model based on Long Short-Term Memory (LSTM) was developed using daily closing price data of the Borsa Istanbul 30 (BIST 30) index, covering the period from January 5, 1997, to September 6, 2025. The aim of the study is to demonstrate the advantages offered by deep learning techniques in market forecasting processes, where traditional methods remain limited and inadequate.

The analyses were conducted in the Google Colab environment using the Python programming language. Logarithmic return, moving averages (MA5, MA20), RSI14, and volatility (Vol20) indicators were used as input variables to the model. The dataset was divided into three subsets: 70% for training, 15% for validation, and 15% for testing. Input variables were scaled using StandardScaler, while the target variable was scaled using MinMaxScaler fitted only to the training set.

The model was built with the following architecture: LSTM(128) → Dropout(0.30) → LSTM(64) → Dense(32, ReLU) → Dense(1), and trained using the Adam optimization algorithm and Mean Squared Error (MSE) as the loss function. To prevent overfitting during training, EarlyStopping and ReduceLROnPlateau strategies were employed. The model's performance was evaluated using RMSE, MAE, and directional accuracy metrics, and compared against a persistence benchmark.

The results show that the LSTM-based model achieved low error rates in logarithmic return predictions and demonstrated competitive success in directional forecasting. These findings indicate that the LSTM model provides effective predictions of financial time series, and that deep learning techniques offer a powerful tool for more accurate and flexible forecasting in financial markets. Future studies are recommended to focus on enhancing model performance using more comprehensive datasets that incorporate different market regimes, macroeconomic indicators, and news flows.

Key Words: Artificial Intelligence, Deep Learning, LSTM, Financial Markets, Borsa Istanbul, Time Series Forecasting, Machine Learning, Forecasting Models.

TEŞEKKÜR

Bu tez çalışmamın tamamlanmasında emeği geçen herkese çok teşekkür ederim.

Öncelikle, değerli danışman hocam Doç. Dr. Ulaş ÜNLÜ 'ye, bilgi ve tecrübeleri ile çalışmamın her aşamasında yapıcı katkılarını esirgemeyen ve akademik rehberliğiyle çalışmamın yönünü belirlememe büyük destek, yönlendirme ve sabırlı yaklaşımıyla bana gerçek anlamda danışmanlık ettiği için en içten ve samimi teşekkürlerimi iletiyorum. Bu tez kendilerinin desteği ve yol göstericiliği olmasaydı tamamlanması zor olurdu.

Araştırma sürecinde bana moral olan ve desteğini daima hissettiren sevgili arkadaşlarım Remziye YAVUZ YILMAZ ve Şebnem DEMİR ve Sunay TOPÇU 'ya ayrıca teşekkür etmek isterim. Hem akademik hem de duygusal anlamda yanımda oldukları için çok şanlıyım.

İzel COŞKUN

Antalya, 2025

GİRİŞ

Bu tez çalışmasında, finansal piyasalarda yapay zekâ uygulamaları kapsamlı bir biçimde ele alınmakta ve Borsa İstanbul 30 (BIST 30) endeksinin LSTM tabanlı derin öğrenme modeli ile tahmin edilmesi amaçlanmaktadır. Dijitalleşmenin hız kazanması ve finansal verilerin hacminin artması, finans sektöründe veriye dayalı karar alma süreçlerinin önemini artırmıştır. Bu durumlarda, geleneksel analiz yöntemlerinin ötesine geçilerek daha hızlı, esnek ve yüksek doğruluk oranına sahip tahminler sunan yapay zekâ temelli yaklaşımların kullanımı yaygınlaşmıştır.

Finansal piyasalarda kullanılan başlıca yapay zekâ yöntemleri arasında makine öğrenmesi, derin öğrenme, takviyeli öğrenme ve genetik algoritmalar yer almaktadır. Makine öğrenmesi modelleri veri içerisindeki örüntüleri tespit etme, sınıflandırma ve tahmin görevlerinde etkili olurken; derin öğrenme modelleri özellikle karmaşık ve çok boyutlu veri setlerinin işlenmesinde önemli avantajlar sağlamaktadır. Takviyeli öğrenme algoritmaları dinamik piyasa koşullarında strateji optimizasyonu için kullanılmakta; genetik algoritmalar ise portföy yönetimi, risk analizi ve strateji geliştirme gibi alanlarda etkin çözümler sunmaktadır.

Bu çalışmada, finansal piyasalarda yapay zekâ uygulamaları incelenmiş; uygulama bölümünde BIST 30 endeksi verileri üzerinden LSTM modelinin tahmin gücü incelenmiştir. Modelin performansı, Ortalama Mutlak Hata (MAE), Ortalama Kare Hata (MSE) ve Kök Ortalama Kare Hata (RMSE) gibi hata ölçüm metrikleri üzerinden ölçülmüştür. Çalışmanın literatür taraması bölümünde hem ulusal hem de uluslararası alanda finansal piyasalarda yapay zekâ tekniklerinin kullanımına dair güncel çalışmalara yer verilmiştir; elde edilen bulgular, yapay zekâ teknolojilerinin finansal analiz ve karar destek süreçlerinde nasıl bir dönüşüm yarattığını ortaya koymuştur. Bu kapsamlı çalışma, gelecekteki akademik araştırmalar ve uygulayıcılar için bir referans niteliği taşımaktadır.

. Bu çalışma aşağıdaki bölümlerden oluşmaktadır: Birinci Bölüm 'de yapay zekâ kavramı, tarihsel gelişimi, türleri ve kullanım alanları ele alınmaktadır. İkinci Bölüm 'de finans alanında kullanılan temel yapay zekâ modelleri, makine öğrenmesi ve derin öğrenme algoritmalarından takviyeli öğrenme ve genetik algoritmalara kadar detaylı biçimde açıklanmıştır. Üçüncü Bölüm 'de çalışmanın veri seti, yöntem ve bulguları yer almakta; BIST 30 endeksi üzerinde yapılan LSTM tahmin uygulaması sunulmaktadır. Son bölümde ise çalışma genel bir değerlendirme ile özetlenmiş ve bulguların finansal piyasalarda yapay zekâ uygulamalarına katkısı tartışılmıştır.

BİRİNCİ BÖLÜM

YAPAY ZEKÂ VE KAVRAMSAL ÇERÇEVE

1.1. Yapay Zekânın Tanımı Ve Tarihi

Yapay zekâ kavramı geleceğe yönelik büyük bir adımdır. İlk olarak 17.yüzyılda ortaya çıktığı tahmin edilen bu kavramı ilk kullanan ünlü filozof Descartes (1596-1650), yapay zekâyı saat düzeni olarak görmüştür. Bu dönemden sonra ise Charles Babbage (1792-1871) ilk hesap makinesi olan ve ismine de “Fark Motoru” dediği bir ürün ortaya çıkarmıştır. Bu motor basit işlemler yapabilmesi, dama ve satranç oynayabilmesiyle dikkat çekmiştir. Bu motorla insan beyninin bazı özelliklerini taklit etmeyi hedeflemiştir. Geleceğe yönelik o dönem için atılmış çok büyük adımlardandır (Schultz ve Ellen-Schultz, 2007; Coşkun vd., 2021).

Modern olarak ikinci dünya savaşı sırası ve sonrasında robot çizimleriyle Cezeri’nin (1136-1206) çalışmaları ilk sayılabilmektedir. Savaşın kaderini değiştiren Alan Mathison Turing “bombe” olarak isimlendirilen otomatik kod kırma makinası o koşullar içerisinde en iyi sayılan icatlardandır (Acar, 2020; Coşkun vd., 2021).

Terim olarak ilk defa kullanılan yapay zekâ 1956 yılında Alan Turing tarafından ortaya çıkmıştır. Dartmouth Kolejinde bahsedilen bu terim John McCarthy, Marvin L.Minsky, Nathaniel Rochester ve Claude Shannon gibi önemli isimlerinde yer aldığı bu yapay zeka alanında çalışmalar hızla ilerlemiştir (Dick, 2019; Coşkun vd., 2021). 1972 yılında insan gibi olan robot WABOT-1 yapılmıştır (Acar, 2020; Coşkun vd., 2021). Her dönem hızlı ilerlediği söylenemez tabii devletlerin fonlarının durma noktası da olmuştur. 1974 ve 1980 yıllarında olumsuz yönlerinden bahsedilerek gerekli fon yardımları alınamamıştır. Alınamayan fonlar yapay zekâ için “yapay zekâ kışı” dönemi olarak tarihte yer almaktadır. İngiltere’nin bu durdurulma döneminde fon ayırarak Japonya’ya karşı yarış içerisine girmesi aralarında rekabeti ortaya çıkarmıştır (Öztürk ve Şahin, 2018; Coşkun vd., 2021).

“Roomba” adıyla piyasaya giriş yapan elektrikli süpürgeler 2000’li yıllarda evlere girmeye başlamıştır. Büyük şirketlerde Facebook, Netflix, Twitter 2006 yılından itibaren günümüze kadar yaygınlaşıp kullanımımıza sunulmuştur (Acar, 2020; Coşkun vd., 2021). Yapay zekânın genel olarak yaklaşımlarını dört başlık altında yazmak mümkündür. Bunlar bilişsel yapay zekâ, taklitçi yapay zekâ, mantıksal yapay zekâ, otonom yapay zekâdır (Russel & Norvig, 2009: 2-5; Emir, 2013).

1.2. Yapay Zekânın Kronolojik Sıralaması

Tablo 1.1 Yapay Zekânın Kronolojik Sıralaması

1950	“Turing Testi” tanıtıldı
1952	İlk oyun satranç oyununu Arthur Samuel geliştirdi
1955	Logic Theorist 'in geliştiricileri Herbert Simon, Allen Newell Whitehead ve Russell Principiadır.
1957	Algılayıcıyı Frank Rosenblatt geliştirmiştir.
1958	Lips'i John McCarthy geliştirmiştir.
1961	Saint' James Slagle geliştirmiştir.
1965	Eliza' Joseph Weizenbaum geliştirmiştir.
1966	Shakey' Kendi konumunu ve yönünü bulman bir programdır.
1968	Shrdlu'u Terry Winograd geliştirmiştir.
1970	Wabot-1' Japonlar tarafından geliştirilmiştir.
1978	Vax 'ı Dec geliştirildi.
1980	Wabot-2' Japonyalar tarafından geliştirildi.
1986	İlk sürücüsüz arabanın hızı 55 mil olarak Münih'teki Bundeswehr Üniversitesi'nde gözlemlenmiştir.
1988	Jabberwacky' Rollo Carpenter tarafından geliştirilmiştir.
1988	İki dil arası çeviri yapabilen program geliştirilmiştir.
1989	El yazılarının ayrımını yapabilen Yann LeCun tarafından algoritma geliştirilmiştir.
1995	Chatbot Alic'i Richard Wallace geliştirmiştir.
1997	Dünya şampiyonunu, yapay zekâ satranç turnuvasında yendi.
	Cynthia Breazeal, duyguların ayrımını yapabilen bir robot geliştirmiştir.
2000	ASIMO robotu insan hızında yürümesiyle ön plana çıkmıştır.
2006	Okuma yeteneği olan robotu Etzioni, Banko ve Cafarella geliştirmiştir.
2009	Northwestern Üniversitesi'nin tarafından spor haberleri üzerine bir program geliştirilmiştir.
2012	Youtube'da 10 M üzerindeki videoya tepki gösteren program geliştirilmiştir.
2012	Apple tanıtımını yaptığı Siri'yi kullanıcılara güncellemiştir.
2013	Sınıflandırma yeteneği ekleyen Facebook kendine uygulama geliştirmiştir.
2014	Captcha'nın ayrımını yapabilen program Vicarious ve ekibi geliştirmiştir.
2014	Ameli insan duygularını ve oluşan soruları algılayıp, insan düşüncelerine mantıkla yorumlayan sanal asistan geliştirmiştir.
2015	Youtube'da yer alan videolara bakarak yemek yapan robot Maryland üniversitesi geliştirmiştir.
2015	Google, Kendince videodaki oyunları öğrenerek oynayan bir program geliştirmiştir.
2015	Drone için bir programlama yapılmıştır Google tarafından.
2016	Yapay zekâ ile kısa film yazılıp yayınlanmıştır Ars Technica tarafından.
2017	Kendi kendine araç kullanabilen Pilotnet geliştirilmiştir.
2017	Makine Öğrenmesi' programı analiz edip edilen analizde sonuca bağlayan bir program geliştirilmiştir. Google tarafından.
2018	SingulartyNet ismiyle Blockchain tabanlı bir program geliştirilmiştir.
2019	Doğal dil işlemede çok büyük bir ilerleme BERT ortaya çıktı.
2020	GPT-3 modeli geliştirildi. Doğal dil işlemede büyük bir ilerleme daha gerçekleşti. İnsan ürünü gibi metin ve yazılar yazabilmesi özellikleriyle dikkat çekti.
2020	Covid-19 zamanlarında tıp alanında yapay zekâ ile bağlantılı erken teşhislerde ve tedavi süreçlerinde yardımcı olmuştur.

2021	Etik konularında yapay zekânın konuşması ve tartışılması artmıştır.
2022	Yeni ilaçların keşfedilmesinde bunlardan ilki DeepMind protein yüklemelerinde, AlphaFold ise Daha karmaşık protein yapılarında işlevlere sahip olduğunu söyleyebiliriz.
2023	ChatGPT, keşfedildi ve her alanda anlayıp konuşabilmesi büyük etki yarattı.

1.3. Yapay Zekânın Geleceği

Yapay zekânın geleceği ile ilgili olarak 10 tane maddeler şeklinde amaçlarını geleceğe yönelik güçlendirecek gösterim görmektedir. Bunlar;

- Çok daha yüksek gelişmişlik özelliğine sahip modelleri karşımıza çıkmaktadır. Piyasadaki dalgalanmaları ve oluşabilecek ekonomik dalgalanmaları tahminleriyle doğruluğunu gösteren modeller geliştirmesi beklenmektedir. Derin öğrenme gibi teknik ve daha farklı yöntemler ile tahminlerini destekleyici yöntemler kullanılmaktadır.
- Kuantum hesaplamalar kullanılarak finansal piyasalarda kullanılan yapay zekâ ile ilgili algoritmaların verimliliğini etkileyecek ve büyük veri kümelerinin hızının da artırılmasını etkileyecektir.
- Hisse senetleri, risklerin yönetilmesi ve portföyler için en uygun alanlar ile kullanımlarının yaygınlaşması beklenmektedir. Bu yaygınlaşma ile esneklik ve ticarete olumlu etkileri oluşabileceği beklenmektedir.
- Yatırımcının davranışları izlenerek analizler, istatistiksel yaklaşımlarda bulunma ve duygusal zekâlarının değerlendirilmesinde stratejik yaklaşımlar etkili olacaktır.
- Yapay zekânın kullanımının yaygınlaşması ile güvenlik problemlerinin artması beklenmektedir. Bu problemler yapay zekânın gelişiminde büyük bir gereklilik olarak değerlendirilecektir.
- Bireysel yatırımcılara ve kurumsal yatırımcılara özel tekliflerin geliştirilmesi gibi hizmetlerin ihtiyacını ortaya çıkaracaktır. Robot danışmanlıklar bu alanda önemli role sahip olacaktır.
- Yapay zekâ, farklı verilerin kaynaklarını örneğin sosyal medya gibi alanlarda finansal analizleri çok daha yaygın bir şekilde kullanabilecektir. Kararlar almada oldukça etkili olacağı düşünülmektedir.
- Çevresel, sosyal ve yönetim (ESG) kurallarına uygun yapabileceği yatırım taktikleri ile piyasalarda daha etkin olacağı öngörülmektedir.
- Küçük ve orta dereceli yatırımcılar için adil ve ulaşılabilir piyasalar oluşturabilmektedir. Ve bu durum rekabeti de oldukça iyi yönde etkilemekte olacaktır.
- İnsanların uzmanlığı, bilgi ve deneyimleriyle bağlantılı bir şekilde piyasaya daha dengeli ve çözüm odaklı fikirler ile karşılına çıkacaktır. İnsan ve makinaların işbirliği ile gelecekteki

kararlarını ve alabilecekleri risklerde önemli bir yere sahip olacağı beklenmektedir (Öztemel, 2020: s. 99-111).

1.4. Yapay Zekânın Kullanım Alanları

Toplumsal olarak bu teknolojiadaki gelişmeler ile uyumun yakalanması sosyal yaşamımızı da etkileyecektir. Burada çeşitlenen bulut sistem, baskılarda 3 boyut, verilerin büyük sistemi, block zincir gibi uygulamalar ile sosyal hayatımıza etkisi oldukça yüksek olmaktadır. Aklımıza gelebilecek hemen her alanda karşımıza çıkmaktadır. Bunlar tarım, sağlık, eğitim, ulaşım, imalat, ithalat, enerji vb. alanlarda etkili olmuştur. Yapay zekânın hayal gücü, dikkat, yenilikçi, bağımsız fikirler ya da icatlar ile tamamen rekabet ortamına dayalı bir topluma doğru yön verildiği de görülmektedir.

Bunlara örnek olarak; insan olmadan işleyen üretim fabrikaları, araçların insan olmadan seyir etmesi, asistanlık olarak destek almaları, şehir hayatına etki eden uygulamalar, yönlendirilebilen toplumlar, sosyal dijital platform uygulamaları, farklı alanlarda ve türden meslek gruplarının oluşması, ulaşımında çeşitlendirilen radar sistemleri, olası bir savaş durumunda algılayıcılar, sürüş destekli araçlar, sağlıkta kullanılan ameliyat gibi bu ameliyatlarda yardımcıları olma gibi bu alanlara birçok örnek vermek mümkündür (Öztemel, 2020: s. 99-111).

1.4.1. Turizm

Turizm sektöründe, 4.0 ile birlikte yapay zekâ teknolojileri birleşip birçok alanda olduğu gibi turizmde de kullanılıp ilerlemelerin olacağı düşünülmektedir (İbiş, 2019: s. 403, Ercan, 2020). Turizmde yapay zekânın önemi oldukça fazladır. Kesintisiz olarak 7 gün 24 saat boyunca hizmet verilebilmesinde yapay zekânın payı büyüktür. Müşterilerin sorunlarına ve sorularına sesli ve yazılı olarak cevap verilebilmektedir. Resepsiyondan bavul taşımaya kadar kullanılan robotik sistemlerde mevcuttur. Oteller ile birlikte bir bütün olan ulaşımında havaalanları, rezervasyon siteleri, yemek sektörü olan restoranlar, elektronik rehber ve beraberinde gezilecek yerler (müze, Avm vb.) turizmde yapay zekâyla bağlantılı alanlar diyebilmekteyiz (Ercan, 2020: s. 394-410).

Yapay zekâ sayesinde müşteri içinde bir kimlik oluşturulup algoritma olarak ne tür bir tatil ya da ne tür bir seyahatten hoşlandığı analiz edilerek her iki taraf içinde planlama yapması tercihler konusunda yardımcı ve fikir sahibi olmayı kolaylaştırmaktadır.

1.4.2. Finans

Finans sektöründe gözümüze çarpan uygulamalar ise daha detaylı olmaktadır. Bu sektörde yapay zekânın hızlı ve gelişmekte olan formu itibariyle bu sektörde çalışmakta ya da yer almak isteyen kişilere destek vermekte işlerini oldukça kolaylaştırmaktadır. Risk belirlemek ve hedefte durmak gibi birçok işlemi yaparak, rahatça müşterilere ulaşarak güvenli ve hızlı bir şekilde yardımcı olmaktadır. Bu alanda sahte evrakları belirlemek, başvuruları değerlendirmek, borsadaki belirlenen alış-satış politikalarına uymak gibi ve daha birçok yardımları mevcuttur (Öztemel, 2020: s. 99-111). Aynı zamanda finansal dolandırıcılık tespiti için makine öğrenmesi temelli sistemler, örneğin Random Forest modeli, gerçek-zamanlı veri analiziyle işlemleri değerlendirerek yüksek doğrulukla şüpheli işlemleri belirlemektedir (Borketey, 2024: s. 189-209). Portföy yönetiminde ise derin pekiştirmeli öğrenme kullanan robo-danışman yaklaşımları, yatırımcı risk tercihini analiz ederek, S&P 500'a kıyasla üstün performans gösteren sistemler geliştirmiştir (Wang & Yu, 2021). Ancak bu yapay zekâ tabanlı sistemlerin “kara kutu” doğası, açıklanabilirlik ve şeffaflık eksiklikleri gibi etik ve teknik zorluklar doğurmaktadır; bu nedenle XAI (açıklanabilir yapay zekâ) ve regülasyon uyumu şu anda alanın kritik gereksinimleri arasında yer almaktadır (Hernandez Aros et al., 2024).

Bu alanda kullanımında bazı engeller de mevcuttur. Sistemsel olarak çok dikkatli bir hassasiyet gerektirmektedir. En önemlilerinden bulut hizmetleri ve API gibi teknolojiler ile bağlantılı olarak güvenlik açığının oluşmaması gerekmektedir.

1.4.3. Sağlık

Sağlık sektöründe yapay zekâyı oldukça fazla görmekteyiz. Hastaların doktor randevularının alınması, sonuçlarının elektronik olarak takibi, araştırma motorları sayende ön bilgilere ulaşımı gibi birçok faydaları vardır. Doktor yeteneklerinin aştığı radyoloji, dermatoloji, nöroşirurji gibi birçok alanda karar vermede ve gözlemlemekte yardımcı cihazlar bulunmaktadır (Çilhoroz ve Işık, 2021: s. 3-9). Birçok uygulamalarda sağlık sektöründe insanları bilgilendirmektedir. Giyilebilir teknoloji ya da akıllı telefonlar gibi cihazlarda insan sağlığı için faydalı uyarılar ve bilgilendirmelerde yapmaktadır. Son yıllarda gelişen teknolojiyle ve yapay zekâ ile birlikte Google, Microsoft, Apple gibi büyük firmalar bu sektör için oldukça ciddi bütçe ayırmışlardır (Şeker, 2021: s. 10-26). Hasta, hemşire ve doktorlar için süreklilik sağlayan işlevsel bir sistem geliştirilmiştir. Öte yandan Microsoft, kanser ve kronik hastalıklarla ilgili tedavi süreçlerini desteklemeye yönelik araştırmalarına devam etmektedir. Apple ise sağlık alanında, bireylerin hareketlerini ve sağlık durumlarını anlık olarak kaydetme konusunda diğer şirketlere kıyasla daha hızlı çözümler sunmaktadır. Küresel ölçekte büyük

bir kullanıcı kitlesine sahip olan Apple, aynı zamanda sağlık verilerini gizlilik esasına göre saklamakta ve bu verilerin paylaşımı bireyin kendi iradesine bırakılmaktadır.

Genel olarak, bu tür dijital sağlık teknolojilerinin; hastalıkların erken tanısında kolaylık sağlaması, ameliyatlarda kullanılan robotik sistemlerde etkin rol oynaması, tedavi süreçlerinin ve sonuçlarının izlenmesi, ilaç geliştirme ve benzer ilaçların karşılaştırılması, kişiye özel tedavi planlarının oluşturulması, bazı hastalara evde bakım hizmetlerinin sunulması ve toplum sağlığının yönetilmesi gibi birçok alanda önemli faydalar sağladığı ifade edilebilir (Akalin & Veranyurt, 2021, s. 2–8).

Hasta, hemşire, doktor için oluşturulan süreklilik istenilen bir sistem geliştirmiştir. Microsoft'un ise kanser, kronik hastalıklar ile ilgili tedavilere destek veren bir gelişim içinde araştırmalarını yapmaktadır. Apple sağlık alanında her an hareketleri ve durumları kaydetmede diğerlerinde daha da hızlıdır. Global bir kitlede yer almaktadır. Bu verileri oldukça gizli bir şekilde tutması da bireyin kendi iradesine dayanmaktadır. Genel olarak erken tanıda kolaylık, yapılabilecek olan ameliyatlarda kullanılan robotlarda, sonuçların takibi, tedavi, sonuçların değerlendirilmesi, ilaç tedavilerinde takiplerin, ilaçların geliştirilmesi ve muadillerinin yapılması karşılaştırılması, kişilere özel tedaviler, bazı hastalara evde bakım, halkın sağlığını yönetmek gibi birçok alanda yarar sağladığı söylenebilmektedir (Akalin ve Veranyurt, 2021: s. 2-8).

1.4.4. Eğitim

Eğitim sektöründe yapay zekânın gelişimi, bilgisayar destekli öğretimle başlamış kabul edilmektedir. Bu süreci, akıllı öğrenme sistemlerinin geliştirilmesi takip etmiştir. Yapay zekâ, öğrencilere zamandan tasarruf sağlayarak birebir görüşmelerin uzaktan gerçekleştirilmesine olanak tanımakta; sorulara ve sorunlara anlık çözümler sunmakta; gerekli test ve analizlerle öğrenme sürecini desteklemektedir. Ayrıca kişiselleştirilmiş çalışmalar yoluyla farklı alanlarda ve bireylerde öğrenme verimliliğini artırdığı birçok örnekle gösterilebilmektedir (Arslan, 2020, s. 10–15).

Eğitimde yapay zekâ; uzman sistemler, akıllı öğrenci sistemleri ve diyalog tabanlı sistemler gibi alt başlıklar altında sınıflandırılabilir (Uzun vd., 2021, s. 25–64). Öğrencilerin performanslarını değerlendirerek hangi alanlarda başarılı ya da yetersiz olduklarını belirleyebilmesi, sınav ve test sonuçlarını hızlı şekilde analiz edebilmesi, öğrenme sürecindeki ilerlemeyi takip edebilmesi gibi işlevler bu teknolojinin sunduğu başlıca katkılar arasındadır. Ayrıca sanal ortamda öğrenci ve öğretmen etkileşimlerini artırmak, farklı dillere erişim

sağlamak ve yabancı dil öğrenimini desteklemek gibi pek çok alanda yapay zekâ, eğitim süreçlerine önemli faydalar sunmaktadır.

1.4.5. Ulaşım

Ulaşım sektöründe yapay zekâ destekli çeşitli uygulamalar geliştirilmiştir. Bu uygulamalardan biri olan Akıllı Ulaşım Sistemi (AUS), temelinde bir kontrol ve düzenleme mekanizması barındırmaktadır. AUS; trafik süresinin ve güvenliğinin optimize edilmesi, mevcut yolların en verimli şekilde kullanılması, çevresel etkilerin azaltılması, enerji tasarrufu sağlanması ve trafik akışının hızlandırılması gibi hedeflerle tasarlanmıştır (Erdal, 2018, s. 4–8).

Yapay zekâ ile entegre çalışan gelişmiş araçlar, çevrelerini sensörler, trafik yoğunluk analizleri ve kameralar aracılığıyla algılayarak anlık kararlar verebilmekte ve rotalarına güvenli şekilde devam edebilmektedir. Bu sistemler, verileri işleyerek güvenli ve konforlu yolculuklar için tercih edilmektedir. Trafik yönetimi alanında da yapay zekâ, trafik akışını kontrol etmek amacıyla kullanılmakta; özellikle trafik ışıklarının sürelerini trafik yoğunluğuna göre ayarlayabilen sistemler, önemli kazanımlar sağlamaktadır. Bu sayede sürücüler için gerçek zamanlı fayda ve zaman tasarrufu oluşturulmuştur.

Ayrıca, araç içi yapay zekâ sistemleri, kullanıcıya rutin bakım tarihlerini hatırlatma ve anlık bildirimlerle güvenli sürüşe katkı sunma gibi işlevler üstlenmektedir. Toplu taşıma sistemlerinde ise biletleme ve anlık güzergâh takibi, güzergâhtaki araçların doluluk oranlarının izlenmesi gibi özelliklerle, karşılaşılan sorunlara çözüm üretme süreçlerini kolaylaştırmakta ve yaşam kalitesine katkı sağlamaktadır (Tektaş vd., 2002, s. 13–35).

1.4.6. Tarım

Tarım sektöründe yapay zekâ kullanımı 19. yüzyıla kadar uzanmaktadır. Bu süreçte tarım ve sanayi eş zamanlı olarak gelişim göstermiştir. Yapay zekâ destekli uygulamalar, özellikle hassas tarım alanında önemli bir rol oynamaktadır. Bu sistemler, veri analizleri ve tahmin modelleri aracılığıyla çiftçilere destek sağlamakta; sulamanın ne zaman ve hangi sıklıkta yapılacağı, kullanılacak su miktarının ne olması gerektiği gibi konularda karar verme süreçlerini kolaylaştırmaktadır.

Teknolojik araçlardan biri olan dronlar; tarımsal arazilerin analiz edilmesi, oluşan zararların takibi, sorunların tespiti ve elde edilen verilerin depolanması gibi işlevlerde etkin şekilde kullanılmaktadır. Üretilcek bitkiler için toprak analizleri, iklim koşulları ve su kaynakları gibi çevresel faktörler değerlendirilerek, hasat tahminleri yapılmakta ve potansiyel riskler öngörülebilmektedir.


Ayrıca, insan gücünü azaltan tarım robotları, olgunlaşmış ya da çürümüş meyve ve bitkileri ayıklayarak verimliliği artırmakta ve iş gücü ihtiyacını azaltmaktadır (Akkaya, 2005, s. 4–7). Hava durumu verileri ve piyasa fiyatlandırmaları gibi faktörleri dikkate alan yapay zekâ tabanlı sistemler, çiftçilere ekonomik karar alma süreçlerinde de katkı sağlamaktadır.

Nem, sıcaklık gibi kaynakların ihtiyaca göre kullanımını optimize etmek ve Tarım 4.0 kapsamında elde edilen verilere dayanarak üretim verimliliğini değerlendirmek gibi birçok uygulama, artık mobil cihazlar aracılığıyla kolayca kontrol edilebilmektedir. Üniversitelerin yürüttüğü Ar-Ge projeleri ve tarımda kullanılacak araçların teknolojik gelişimi, bu alandaki üretkenliği artırmakta ve sektörün dijital dönüşümüne katkı sunmaktadır (Çeltek, 2021, s. 37).

1.4.7. Savunma ve Güvenlik

Savunma ve güvenlik alanından yapay zekânın kullanımı diğer bölümlerde olduğu kadar önemlidir. Bu alanda sadece insan gücü yeterli kalmamaktadır. Dinamik savunmalarda etkinliği artırmak için yapay zekâ devreye girmektedir. Öncelikle siber savunmada yapay zekâ hükümet ve devlete bağlı kuruluşlarının güvenliğini korumak için oldukça önemlidir. Siber Savunmada verilerin gizliliği ve önemi açısından da oldukça önemlidir. Oluşabilecek bir saldırı için erken uyarı sistemlerin de yapay zekânın bize sağladığı yararlardandır. Bu sistem, makina öğrenim algoritmaları, normal ağ ile anormal olanı ayırt edebilir. Saldırıları erkenden fark edilebilmesi erken uyarı sisteminin önemini bize göstermektedir (Şeker, 2020: s. 2-6).

Otonom araçlar ile bunlar insansız hava araçları (İHA) ve silahlı insansız hava araçları (SİHA) sayesinde hızlı ve kontrollü koruma yapılabilir. Görevleri yerine getirmede hata oranını en aza indirme, operasyonları yapay zekâ sayesinde bir karardan etkilenilmeden yerine getirirler. Oluşabilecek tehditlerin analizi ve senaryolara dayalı hızlı bir yöntem belirlemede çok kritik bir öneme sahiptir. Savaş simülasyonları da askeri eğitimde tercih edilen yapay zekâ uygulamalarındandır (Şahiner vd., 2021: s. 2-10).



Şekil 1.1 Toplumsal Değişim Ve Dönüşüm

1.5. Yapay Zekânın Türleri Ve Açıklamaları

Yapay zekâ sistemleri, gelişmişlik düzeylerine ve yeteneklerine göre üç temel kategori altında sınıflandırılmaktadır: Dar Yapay Zekâ (Narrow AI), Genel Yapay Zekâ (General AI) ve Süper Yapay Zekâ (Super AI).

1.5.1. Dar Yapay Zekâ

Dar yapay zekâ belirli yetkilendirmelerde görevlendirilmiş o alanda uzmanlaşmış ve performans açısından en yüksek seviyelerde olan bir sistemdir. En belirgin örnek olarak akıllı telefonlarda kullanılan asistanlardır. Bu yapay zekâ türünün alt başlıkları şunlardır: (Aksan, 2023).

- Görsel Ve İşitsel: Sesli ve yüz tanıma özellikleri bulunan bir teknoloji örneği olabilmektedir.
- Dil Algılama: Hızlı ve etkili iletişim önemi büyük olan bir sistemdir. Metinler hakkında anlık çeviriler ile bilgi saplanabilmektedir.
- Öneriye Dayalı Arama Motoru: Arama geçmişlerine bakarak benzer içerikleri karşımıza çıkartan bir algoritmaya sahiptir. Alışveriş sinema gibi birçok yerde karşımıza çıkmakta ve ihtiyaçları kişiselleştirerek önerilerini bizlere sunmaktadır.

- Otonom Teknoloji: Belirlenen görev dışına çıkmadan, bağımsız olarak belirli rota çerçevesinde kararlarını veren bir sistemdir.
- Güvenlik: Oluşabilecek tehditleri belirlemede ve önceden tedbir alınması noktasında oldukça kritik öneme sahiptir.
- Oyunsal Yapay Zekâ: Sınırları belirlenen kurallar çerçevesinde sınırlı olan oyunlardır. Yapılan hamlelere göre senaryosu belirlidir.
- Tahmine Dayalı: Elinde bulunan verileri toplayarak bir değerlendirmeye alarak tahinlerde bulunmasıdır. Örneğin hava tahmini ya da finansal tahminler bu türde yer alabilir.
- Tıbbi Tanı Sistemi: Kişiye özel olarak yapılan tetkiklerde örneğin radyolojik bulgulardan yola çıkarak bir tanıda bulunulması gibi örnekler vermek mümkündür (Pirim, 2006: s. 6-12; Turan, 2020: s. 3-15).

1.5.2. Genel Yapay Zekâ

Benzerliğiyle bilinen genel yapay zekâ aynı bir insan beyni gibi çalışmaktadır. Öğrendikleriyle karar vermesi gibi özelliği vardır.

Genel Yapay Zekâ (GYZ), Dar Yapay Zekâdan(DYZ) farklı olarak insanı bir yetkiyi yerine getirebilecek kadar iken DYZ belirlenen komutlarla sınırlı kalmaktadır. Çok farklı alanlarda GYZ 'yı görmektedir. En belirgin örneklerden olan sağlık sektöründe hastalık belirlenmesinde süreci ve farklı tedavi olanaklarını sunmakta yardımcıdır. Eğitimde ise tamamen kişiselleşmeye yönelik bir öğrenime yardım etmektedir (Artut, 2019: 5-9).

1.5.3. Süper Yapay Zekâ

Üstün bir yetenek ile beraber insan zekâsı ve yeteneklerinin de üzerinde bir performans sergiler. Tam olarak geliştirilmemiştir fakat insan zekâsından da öte olan karmaşık düşünme ve ileride olabilecek olasılıklarda hesaplama gibi farkları bulunmaktadır. Kısaca Genel Yapay Zekâ (GYZ) ile Süper Yapay Zekâ(SYZ) arasındaki farka şunu söylemek mümkündür. GYZ insan zekâ seviyelerinde ve görevi belirli bir düzeyde

yapabiliyor iken SYZ insan zekâ seviyesinin de üzerinde ve verilen görevleri hızıyla yapmaktadır.

Gelişmesi varsayımıyla planlanan özellikleri bulunmaktadır. Karmakarışık olan soru ve sorunları, insan beynine nazaran hızlıca çözmesi, insanlık geleceği için teknoloji ve bilime faydalı yararlarda bulunması, sürdürülebilir ve alternatif çözümler ile topluma faydalı olmak, farkı açılardan değerlendirip insan beyniyle hesaplanamayan açılardan bakarak adil ve eşitlikçi yaklaşımlarda bulunabilir (Turan, 2020: 57-66) (Aksan, 2023).



İKİNCİ BÖLÜM

FİNANSTA KULLANILAN YAPAY ZEKÂ MODELLERİ

Bu bölümde, yapay zekânın farklı alt alanları ele alınarak literatürdeki temel yaklaşımlar incelenmiştir. Özellikle makine öğrenmesi, derin öğrenme, takviyeli öğrenme ve genetik algoritmaların temel özellikleri ve finans alanındaki yansımaları ele alınmaktadır.

2.1. Makine Öğrenmesi

Makine öğrenmesi, analitik modelleme sürecini otomatik hale getirerek insan etkisini minimum düzeye indirerek bir sistem geliştirmiştir. 1940 yıllarına kadar uzanan kökenin son yıllarımızda teknolojinin gelişmesi, artan verilerin depolama olanakları ve veri işleme kapasitelerinin hızlarıyla çok daha fazla yaygın hale gelmiştir. Bu ilerlemeler makine öğrenme algoritmalarının daha etkin ve farklı alanlarda kullanımını artırmıştır.

Genel olarak verilerin kolaylıkla ayırt edilmesi, öğrenerek belirlemeler yapmak ya da tahminlerde bulunmak için kullanılan bir yöntemdir. Makine öğrenmesi finansal piyasa analizlerinde yatırım analizlerinde, fonların işleyiş performanslarında, portföylerin yönetilmesinde, türev piyasalarda kullanılmaktadır. Oluşabilecek olan risklerin ise kredilerdeki riski, başarısızlıkları ve esnekliği olarak genel isimlendirilebilir (Aziz vd, 2021: s. 10-32).

Makine öğrenmesi, disiplinli gerektirir ve felsefe, sosyoloji gibi alanlarda birçok çalışmayı da kapsamaktadır. Hedge fonları, bankalar ve birçok yatırım firmaları, makine öğrenmesini benimsemekte ve bu alanda ciddi yatırımlardan söz etmek mümkündür. Veri bilimi ve bu alanın daha geniş öğrenilmesiyle ilgili ciddi bir artış görülmektedir. Sektör olarak finasta bu yöntemin öğrenilerek bir başarıya ulaşması, altyapıyı güzelce oluşturmak, doğru tercihler ile algoritmaları ve kullanım araçlarının etkileri oldukça yüksektir (Tatsat, Puri, ve Lookabaugh, 2021; Karakaşlı, 2024).

Makine öğrenmesini ile ilgili yapılan tanımlar:

- Arthur Samuel'e göre makine öğrenmesi, bilgisayarların açıkça programlanmadan öğrenmesini sağlayan bilgisayar bilimlerinin bir alt dalıdır.
- Mitchell'e göre makine öğrenmesi yapay zekâ, olasılık, istatistik, hesaplama karmaşıklığı, kontrol ve bilgi teorisi, felsefe, psikoloji gibi çok fazla alandaki kavramlar ile bulguları temel olarak geliştirmiştir.
- Svensson ve Soderberg'e göre makine öğrenmesi, bilgisayarların öğrenmesini sağlayan algoritmaların ve yöntemlerin tasarımı ve geliştirilmesiyle ilgilenir. Makine öğrenmesinin temel amacı, verilerden bilgiye dayalı yöntemlerle otomatik olarak anlam çıkarmaktır. Bu

yüzden, istatistik ve veri madenciliği ile yakından bir bağlantıya sahiptir (Kshyap, 2024, s. 9; Karakaşlı, 2024).

Makine öğrenmesinin finasta kullanım alanları şunlardır (Tatsat, Puri, ve Lookabaugh, 2021; Karakaşlı, 2024).

;

- Algoritmaya bağlı işlemler
- Portföylerin yönetilmesi
- Usulsüzlüklerin, dolandırıcılıkların belirlenmesi
- Bankasal değerlendirmeler (ipotek/kredi vs.)
- Otomasyonlar ve dijital mesajlaşmalar
- Risk analiz ve yönetilmesi
- Varlık fiyat tahminleri
- Türev
- Duygusal analizler
- Arabulma
- Kara para aklanmalarında
- Müşteri hizmetleri



Şekil 2.1 Makine Öğrenme Teknikleri

Makine öğrenmesinin avantajları vardır. Kullanıcıların deneyimlerine ve sorunlarını geliştirmek, Oluşabilecek ve oluşmuş riskleri azaltmak, verileri korumak, senaryolar oluşturmak ve bunu sunmak, maliyetleri kontrol edebilmek, müşterilerin hamlelerini tahmin etmek gibi faydaları bulunmaktadır (Akkaya, 2005: s. 45).

Makine öğrenmesi dört ana teknik altında sınıflandırılmaktadır: Denetimli Öğrenme, Denetimsiz Öğrenme, Pekiştirmeli Öğrenme ve Derin Öğrenme (Karakaşlı, 2024, s. 12–40).

Denetimli Öğrenme (Supervised Learning): Bu öğrenme türünde, algoritmalar etiketli veriler kullanılarak eğitilir. Girdiler ve çıktılar arasındaki ilişki analiz edilerek, belirli hedeflere ulaşmaya yönelik tahmin modelleri oluşturulur (Sarker et al., 2020; Kaya, 2024). Bu yöntemde veriler bir “öğretmen” görevi görür; algoritma, belirli bir girdinin hangi sınıfa ait olduğunu öğrenir. En yaygın kullanım alanı, sınıflandırma problemleridir (Danas & Garsva, 2009; Kaya, 2024). Denetimli öğrenme teknikleri arasında doğrusal regresyon (linear regression), lojistik regresyon (logistic regression), destek vektör makineleri (SVM), karar ağaçları (decision trees) ve rastgele ormanlar (random forests) gibi yöntemler yer almaktadır. Uygulama alanları arasında; iflas tahminleri, hisse senedi değer tahminleri, kredi puanlaması, finansal risk analizi, döviz kuru tahminleri, vadeli işlem tahminleri ve kara para aklama tespiti gibi konular bulunmaktadır (Härdle et al., 2005; Härdle et al., 2007; Danas & Garsva, 2009; Imandoust & Bolandraftar, 2013; Kaya, 2024).


Denetimsiz Öğrenme (Unsupervised Learning): Denetimsiz öğrenmede, veri setleri etiketlenmemiştir ve algoritma, herhangi bir çıktı bilgisine sahip olmadan veri içindeki desenleri keşfetmeye çalışır (Saravanan & Sujatha, 2018; Kaya, 2024). Bu algoritmalar, veri setindeki gizli yapıları, gruplamaları ve ilişkileri keşfetmeyi amaçlar. Bu teknikler, K-means kümeleme, hiyerarşik kümeleme, ana bileşen analizi (PCA) ve t-dağılımlı stokastik komşu gömme (t-SNE) gibi yöntemleri içerir. Ayrıca Gauss karışım modelleri ve K-ortalama algoritmaları gibi tekniklerle de çalışır. Denetimsiz öğrenme, denetimli öğrenme algoritmalarına tamamlayıcı nitelikte destek sağlar (Dixon et al., 2020; Kaya, 2024).

Pekiştirmeli Öğrenme (Reinforcement Learning): Pekiştirmeli öğrenme, bir ajan tarafından en uygun stratejinin geliştirilmesini sağlar. Algoritma, çevreden aldığı gözlemler ve geri bildirimler doğrultusunda eylemlerini optimize eder. Her eylem çevrede bir değişikliğe neden olur; bu değişimlere göre algoritma yeni stratejiler geliştirir (Sutton & Barto, 2018; Kaya, 2024).

Bu öğrenme modelinde öne çıkan teknikler arasında Q-Learning ve oyuncu-eleştirmen (actor-critic) algoritmaları yer almaktadır. Sistem, hedefe ulaşmak için en etkili yolu belirlemeyi ve bu yolu izlemeyi amaçlar.

Derin Öğrenme (Deep Learning): Derin öğrenme, yapay sinir ağlarının çok katmanlı yapıları üzerine kuruludur. Özellikle erişimli sinir ağları (convolutional neural networks -

CNNs), tekrarlayan sinir ağıları (recurrent neural networks - RNNs), derin yapay sinir ağıları (deep neural networks - DNNs) gibi yapılar bu alanda kullanılmaktadır (Kaya, 2024, s. 12). Bu teknik, büyük veri setlerinin ve karmaşık yapısal ilişkilerin analizinde önemli avantajlar sağlar. Aşağıda bu tekniklere ilişkin daha açıklayıcı bir tablo sunulmaktadır.



Şekil 2.2 Makine Öğrenmesi

Makine öğrenmesi, veri odaklı karar verme süreçlerinde çeşitli sektörlerde önemli katkılar sağlamaktadır. Farklı sektörlerde, ihtiyaçlara özel olarak yapılandırılmış makine öğrenmesi modelleri; tahminleme, sınıflandırma, anomali tespiti ve optimizasyon gibi işlevler için yaygın biçimde kullanılmaktadır. Aşağıda, makine öğrenmesinin bazı sektörlerdeki temel uygulama alanları özetlenmiştir:

Bankacılık ve Finans: Makine öğrenmesi, dolandırıcılık tespiti, kredi risk değerlendirmesi, müşteri davranışlarının analizi ve algoritmik alım-satım stratejileri gibi uygulamalarda aktif olarak kullanılmaktadır. Özellikle denetimli öğrenme modelleri sayesinde finansal riskler önceden tahmin edilebilmektedir.

Sağlık Hizmetleri: Hastalıkların erken teşhisi, hasta takibi, tanı destek sistemleri ve medikal görüntü analizi gibi alanlarda makine öğrenmesi önemli rol oynamaktadır. Ayrıca hasta verileri üzerinden bireyselleştirilmiş tedavi planlarının oluşturulmasına katkı sunar.

Ulaşım: Otonom araç sistemleri, trafik yoğunluğunun analizi, en uygun güzergâhların belirlenmesi ve trafik anormalliklerinin tespiti gibi konularda makine öğrenmesi yöntemleri yoğun şekilde kullanılmaktadır. Pekiştirmeli öğrenme özellikle otonom sürüş sistemlerinde tercih edilmektedir.

Tarım: Bitki türlerinin tanımlanması, toprak analizi, sulama planlaması ve verim tahmini gibi alanlarda makine öğrenmesi, tarımsal üretimi optimize etmeye yardımcı olur. Ayrıca robotik sistemlerle entegrasyonu, iş gücünü azaltarak süreçleri otomatikleştirmeyi sağlar.

Makine öğrenmesi, çok sayıda algoritmayı içeren kapsamlı bir uygulama alanıdır. Bu algoritmalar, verilerdeki örüntüleri analiz ederek belirli sonuçlara ulaşmayı ve geleceğe yönelik tahminlerde bulunmayı hedefler. Algoritmalar, denetimli öğrenme, denetimsiz öğrenme ve pekiştirmeli öğrenme gibi farklı öğrenme biçimlerine göre sınıflandırılmaktadır. Özellikle doğrusal regresyon, karar ağaçları ve destek vektör makineleri gibi denetimli öğrenme algoritmaları, sınıflandırma ve tahminleme problemlerinde sıkça kullanılmaktadır.

2.1.1. Doğrusal Regresyon

Doğrusal regresyon finasta fiyat tahminleri, talepleri ve risk gibi durumlar da ortaya çıkacak sorunların çözümünde kullanılması tercih edilir.

Doğrusal regresyon gerçekteki ve tahmini değerler arasındaki oluşabilecek hatayı en düşük seviyelerde tutmak için kullanılan bir yöntemdir.

Doğrusal regresyon istatistiksel olarak etkili bir yöntemdir. Bağımlı ve bağımsız değişkenleri bulunmaktadır. Bu değişkenler arasındaki bağlantılara bakarak yorumlamalar ve veri analizlerinde bulunulabilmektedir. Temel amaç bağımlı olan değişken yani y 'nin, bağımsız değişken yani x gibi ifade edilmesini içeren denklemde yer almasıdır (Kılıç, 2013: 26).

Matematik formülü şu şekildedir;

$$Y = b_0 + b_1 * X_1 + b_2 * X_2 + ... + b_n * X_n$$

- Y , değişken (sonuç değişkeni) bu değişken tahminde karşımıza gelmektedir.
- $X_1, X_2, ..., X_n$, bağımsızdır (açıklayıcı değişkenler) sonucu değiştirmeye etkisi olan faktörlerdir.
- $b_0, b_1, b_2, ..., b_n$, regresyonun çarpanlarıdır.

Modelin değerlendirilmesinde çeşitli teknikler kullanılmaktadır. Ortalama kare hata, R-kare gibi teknikleri vardır. Bu teknikler bize modelde tahmin yeteneklerini ölçmektedir.

Doğrusal regresyonun avantajlarında ise uygulamasında ve sonuçlarının değerlendirilmesinde kolaylık, basitlik olmasıdır. Temel ve anlaşılır olması tercih edilmesinde en etkili özelliğidir. Doğru tekniklerle uygun modelde istenilen bilgilere ulaşılmaktadır (Baghdadi, 2023: s. 34-45).

2.1.2. Lojistik Regresyon


Lojistik regresyon matematikten de yararlanılarak iki veri arasındaki ilişkilerde kullanılan bir yöntemdir. Tahmine dayalı olan bu yöntem de sonuç genellikle evet ya da hayır gibi olumlu olumsuz şeklinde sonuçlanmaktadır. Elde edilen sonuçlardan maliyetler açısından, verimliliğin artırılması gibi nedenlerle tahmine dayalı bir analiz söz konusudur.

Lojistik regresyonun avantajlarından olan basitlik daha az karmaşıklığının bulunması, hızının ise büyük veriler ile en hızlı şekilde sonuçlandırması gibi faydaları da bulunmaktadır.

Lojistik regresyonun temel amacı olasılık tahmin etmektir. Bu tahmini de 0 ile 1 arasında olacak şekilde sınırlandırmıştır. Formülü de şöyledir.

$$f(x) = \frac{1}{1 + e^{-x}}$$

Denklemi çizersek eğer S gibi bir görüntüye ulaşmaktayız.



Şekil 2.3 Lojistik Regresyon Eğrisi

Çizimde de görüldüğü üzere, lojistik regresyon modelinin çıktısı 0 ile 1 arasında bir değer almaktadır.

Lojistik regresyonun üç temel türü bulunmaktadır:
İkili lojistik regresyon: ikili sınıflandırma problemlerinde, yani yalnızca iki sonucun bulunduğu durumlarda kullanılır.

Çok terimli lojistik regresyon: sınırlı sayıda sonucun yer aldığı, çoklu fakat sırasız kategorilerin sınıflandırılmasında kullanılır.

Sıralı lojistik regresyon: kategoriler arasında belirli bir sıralamanın bulunduğu durumlar için uygundur (Amazon, 2024).

Sonuç olarak, lojistik regresyon sınıflandırma ve olasılık tahminlerinde etkili bir modeldir. Modelin uygunluğu sağlandıktan ve bağımsız değişkenlerin kontrolü yapıldıktan sonra elde edilen doğruluk oranı da buna paralel olarak artmaktadır.

2.1.3. Destek Vektör Makineleri

Destek vektör makineleri güçlü bir makine öğrenme modelidir. Sınıflandırma algoritmasıdır (Yang vd., 2011; Abacı, 2024). Genellikle sınıflandırma ve regresyon problemlerinin çözümlerinde kullanılmaktadır. Özellikle doğrusal olmayan problemlerin sınıflandırılarak çözülmesinde kullanılmaktadır.


$$W * x + b = 0$$

Bu formülde yer alan w ve b öğrenilen birimlerdir. X ise verilerin noktalarını bize göstermektedir. Eğer 0'dan büyük ise sınıf olarak birinci, 0'dan küçük ise de sınıf olarak ikinci göstermektedir. Eşitlik durumunda ise düzlem üzerinde demek olacaktır. Eşitlik durumumuz destek vektör noktamızı göstermektedir (Abacı, 2024: s. 20-38).

Destek vektör makinelerinin uygulamaları

- Yüz tanıma
- Metin gruplandırma
- Görsel gruplandırma
- Biyoinformatik
- Protein eşleştirmesi
- El yazısı hafızası
- Çevre tanımlama
- Kontrolü tahmine göre yapma

(Metlek ve Kayaalp, 2020: s. 19-36).



Şekil 2.4 Destek Vektör Gösterimi

Tabloda da görüldüğü üzere, iki farklı renk bulunmaktadır: siyah ve beyaz. Sınıflandırmanın yapılabilmesi, yeni gelecek verinin hangi sınıfa ait olduğunun belirlenmesine bağlıdır. Bu işlem için, iki uç nokta arasında bir doğru çizilir ve bu doğrunun her iki tarafında birer sınır belirlenerek bir ayırım alanı oluşturulur. Görselde bu alan yeşil

renkle gösterilmiştir. Bu alanın genişliği arttıkça, sınıflar arasındaki ayrım daha belirgin ve net hale gelmektedir (Balcı, 2020, s. 34–52).

Veri kümesi ve özellikleri: öğrenme işleminin gerçekleştiği ve ardından sınıflandırmaya geçildiği, girdilerin temelini oluşturan yapıdır.

Sınıflandırma: verilerin genellikle negatif ve pozitif olmak üzere iki gruba ayrıldığı, uç noktalar arasında karar sınırlarının oluşmasını sağlayan süreçtir

Destek vektörler: sınıflar arasındaki uç noktaları temsil eder ve bu noktalar arasındaki mesafenin en kısa sürede başarıyla ayrıştırılmasını hedefler.

Marj: sınıflar arasındaki farkı en iyi şekilde ayırmaya çalışan alanı ifade eder, daha iyi genelleme için geniş bir marj tercih edilir.

Kernel (çekirdek) fonksiyonları: doğrusal ve doğrusal olmayan veri kümeleri üzerinde sınıflandırma yapılmasını sağlar.

Karar sınırı ve karar fonksiyonları: destek vektör makineleri sonucunda ortaya çıkan, sınıflar arasındaki ayrımı belirleyen yapılardır.


Sınıf farklılıkları: sınıflar arasındaki ayrımı karar sınırı gösterirken, yeni verilerin hangi sınıfa ait olduğunu belirleme işlevi karar fonksiyonu tarafından gerçekleştirilir.

Optimizasyon ise, veri setindeki uç noktaların sınırlarını belirleme ve ayrım yapma konusunda önemli bir rol oynar (Baghdadi, 2023, s. 55–80).

Makine öğrenmesinde bu bağlamda iki temel durumla karşılaşılabilir: birincisi lineer olarak ayrılabilen veriler, ikincisi ise lineer olarak ayrılamayan verilerdir.


Lineer Ayrılabilir Durumu:

İki ayrı sınırlarda olan bölümlerin eş mesafede olmasını sağlamasıdır.



Şekil 2.5 Lineer Ayrılabilir Durumu Gösterimi

Lineer Ayrılama Durumu



Şekil 2.6 Lineer Ayrılama Durumu Gösterimi

Doğrusal düzlem her koşulda tam ortadan ayırması değil de daha esnek şekillerde bulunabilmektedir.

Destek vektör makinelerinin temel fonksiyonları şunlardır:

Doğrusal fonksiyon: verilerin doğrusal olarak ayrılabilirdiği durumlarda kullanılır.

Polinomiyal fonksiyon: veriler arasında daha karmaşık, çok terimli ilişkilerin olduğu durumlarda tercih edilir.

Sigmoid fonksiyon: yapay sinir ağlarıyla benzerlik gösteren, sınıflandırma problemlerinde kullanılan bir çekirdek fonksiyonudur.

Radyal tabanlı fonksiyon (RBF): özellikle doğrusal olarak ayrılabilen verilerde sınıflar arasındaki ayrımı başarılı şekilde gerçekleştiren yaygın bir fonksiyondur (Aytekin, 2019, s. 45–58).

2.1.4. Karar Ağaçları

1986 yılında J.R.Quinlan tarafından karar ağacı yöntemi keşfedilmiştir. Karar ağaçları, verilerin analizleri ya da bu verilerden tahminlerde bulunmak için kullanılan bir yöntemdir. Bu verilerden anlamlı olarak oluşturduğu bu yapıyı daha anlaşılır ve basit bir şekil olan ağaç şeklinde göstermektedir. Sınıflandırmalar yaparak açıklamalarını daha kolaylaştırması bu yöntemi daha donanımlı bir öğrenim modeli yapmaktadır. Denetimli öğrenme ile çalışsan bu yöntem girdiler ve çıktılarından oluşmaktadır. Girdi ve çıktı arasındaki bağlantıyı tespit etmektedir. Kredi değerlendirmesi, dolandırıcılar karşı koruma sağlama, portföy değerlendirmeleri gibi alanlarda kullanılan ve tercih edilen bir yöntemdir (Metlek ve Kayaalp, 2020: s. 56).

Karar ağacı, karar verme sürecinde oldukça faydalı olan ve veriler üzerinden yapılandırılan bir yöntemdir. Bu yapı; kök, dallar, yapraklar ve aralarındaki düğümlerden oluşur. Aynı gruba ait veriler, aynı dalda yer alan yapraklarda toplanır. Bir dal üzerindeki

yapraklar, olası tüm çıktıların değerlerini temsil eder. Girdi verileri, düğümler olarak adlandırılan belirli özelliklere göre sınıflandırılır ve alt gruplara ayrılır. Bu alt gruplar, her bir düğümün ardından gelen kararları doğrudan etkiler (Metlek & Kayaalp, 2020, s. 57).

Karar ağaçları temelde iki yapıda incelenir: İkili karar ağaçları: Her düğümde yalnızca iki olası seçeneğe dayalı kararlar alınır (örneğin: evet/hayır).

Çoklu karar ağaçları: Bir düğümden ikiden fazla seçenek çıkabilir, çok sayıda sınıflandırma içeren problemler için uygundur.

Karar ağaçları genellikle çok sayıda verinin bulunduğu ve bu verilerden anlamlı tahminler elde etmenin zor olduğu durumlarda tercih edilir. Ayrıca, tahmin için gerekli bilgilerin tam olmadığı belirsiz ortamlarda da etkili bir yöntemdir. Örneğin, bir tüketicinin çevrimiçi bir ürünü satın alıp almayacağını tahmin etmek için karar ağacı yönteminden faydalanılabilir (Arslan, 2020, s. 71–88).

Matematiksel olarak oldukça karmaşık bir yapıya sahip olmasına rağmen, karar ağaçları genellikle rastgele yapılandırılmış modeller temel alınarak oluşturulur.

Tahmin etme aşamaları şöyledir;

- Alt küme verileri için verilerin setlerinden herhangi bir set seçilerek başlanılır.
- Seçilen bu alt küme için en iyi seçenekler seçilerek bir karar ağacı oluşturulur.
- Tahmin edilen değerler ya da bu karar ağacının yaprakları denilen düğümlerindeki etiketler yani sınıflandırmalar için tahminlerde bulunur.

Tahminlerin hepsini bir araya getirerek tahminini tamamlamaktadır. Oy birliği kuralını ise genellikle sınıflandırmada kullanmaktadır. Yani en çok oyu alan bölüm kazanır gibi bir örnek verilebilir. Her bir ağaç için yukarı da bahsedilen aşama gerçekleşmelidir.

Karar ağacı iki temel türde kullanılmaktadır;

Sınıflandırma Ağaçları: Sonuçların belirli bir sınıflandırmayı ya da bölümü esas almasıyla oluşan bölümlerdir.

Regresyon Ağaçları: Veri sonuçlarının tahminlerinde kullanılan süreli bir türdür.

Karar ağaçlarının avantajları ve dezavantajlarını şu şekilde açıklayabiliriz:

Avantajlarından ilki: ağaç yapısının yorum yapmayı ve sınıflandırmalarda tahminde bulunmayı kolaylaştırmasıdır. Diğer bir avantajı ise modelin, en anlamlı ve etkili değişkenleri seçerek gereksiz detayları göz ardı etmesi ve bu yolla yorumlamayı sadeleştirmesidir. Dezavantajı ise, küçük veri tekrarları ve farklı değerler karşısında duyarlılık göstermesidir, bu

da analizlerin verimliliğini düşürebilmektedir. Ayrıca büyük ve karmaşık veri setlerinde modelin yapısının anlaşılmasını ve yorumlanmasını zorlaştırabilmektedir (Sakarya ve Yılmaz, 2019, s. 100–106).

Karar ağacının kullanıldığı alanlar:

Sınıfına karar verilecek veriler: hangi sınıfa ait olduğuna karar verilmesi gereken verilerde kullanılır

Olası olaylara yönelik tahminler: gerçekleşme ihtimali olan olayların veriye dayalı olarak tahmin edilmesi ve kurallar çerçevesinde değerlendirilmesi

Alt gruplar ve ilişkileri: özel ilişkilere sahip alt grupların sınıflandırılmasında tercih edilir (Albayrak ve Yılmaz, 2009, s. 56).

Karar ağacı uygulama alanları

İş hayatı: finans, pazarlama ve stratejik planlama gibi alanlarda kullanılır

Sağlık alanı: tedavi süreci takibi, değerlendirme ve hasta bakımını iyileştirme amacıyla tercih edilir.

Eğitim: veri madenciliği, öğrenci başarılarının takibi ve sınıflandırılması süreçlerinde kullanılır

Robotik: yol seçimi ve hareket kontrol algoritmalarında kullanılır

Üretim: tahmine dayalı süreçlerin yönetiminde ve üretim verimliliğinin artırılmasında etkilidir

Oyun: yapay zekânın aktif olduğu bilgisayar oyunlarında karar verme mekanizmalarında kullanılır (Bulutistan, 2024).

2.1.5. En Yakın Komşu

En yakın komşu yöntemi makine öğrenmesinde en sık kullanılan ve en eski yöntemlerdendir. En temel öğrenme algoritmalarındandır. Gruplandırma yani sınıflandırma önemli bir görevidir. Genel çalışma mantığı için yeni gelen bir verinin komşusu arasındaki mesafeye bakması gerekmektedir. Yüksek boyutlarda veri saklama alanına ihtiyaç duyulmaktadır. Bu öğrenme temelli yapının en belirgin özeliği ise eğitimde yer alan verilere göre gerçekleşmektedir. Eğitimde yer alan veriler ile yeni katılan veriler aralarındaki benzerlik ya da farklılıklara göre gruplandırılmaktadır. Her örneğe n boyutlu ve sayısal değerler ile gösterilmektedir. N boyutları uzayda bir noktayı temsil etmektedir. Tanınmayan bir örnek ile karşılaşıldığında ilgili olan örneğe en yakın olan k tane örnek seçilerek yeniden

bir sınıf oluşturulmaktadır. İsim olarak da o gruptaki çoğunluğa göre isim almaktadır (Taşçı ve Onan, 2016: s. 29-35).

- Mesafe hesaplamada en yakın olan komşular belirlenir ve aralarındaki mesafeyi ölçmeye yardımcı Öklid gibi hesaplamalardan destek alınabilir.
- Komşuların seçiminde ise mesafe olarak en yakın k adet komşu seçilir. Burada belirttiğimiz k adet bizim kullanacağımız bu yöntemde en önemli parametredir. Doğruluğunu etkileyebilecek öneme sahiptir.
- Kararın verilmesinde ise komşuların çoğunluğuna göre grup ve ortalamalarına bakılarak bir değer verilir.

Veriler ilk olarak eğitim ve test olarak ayrılır daha sonrasında k parametresi belirlenir. Bu ifade bize kısaca en yakınlarında bulunan komşularının sayısını söylemektedir. Önemli olan bu parametre için sınıflandırmadaki performans ile doğrudan ilgilidir. Sonrasında yeni verilerin, hazırda bulunan veriler ile uzaklıkları yeniden hesaplanmalıdır. Bu uzaklıkların hesaplanmasında değişik fonksiyon hesaplamalarının kullanılabilir. Bu uzaklıklardan en yakın olan seçilerek belirlenir (Metlek ve Kayaalp, 2020: s. 47-58).

K parametresi: En yakın komşu yönteminde en etkili değerlerdendir. Düşük k değeri algoritma olarak uyum verirken yüksek bir değer aldığında k değeri genel yapısını ve uyumunu kaybedebilmektedir. Denge olarak belirlenirken finansal piyasalardaki verilerin tahminlerinde kullanılabilir.

Parametreleri: Uzaklık ölçütlerinde Minkowski, Öklid, Manhattan, Chebyshev ve Dilca uzaklığıdır. Bu uzaklıklardan kısaca bahsedecek olursak aşağıdaki gibidir.

Minkowski Uzaklığı: Genel bir formüle sahiptir. P ifadesinin farklı değerleri için uzaklık tanımlamalarında kullanılmaktadır. Minkowski de $p=2$ durumunda, Öklid uzaklığı, $p=1$ durumunu Manhattan uzaklığı n sonsuz durumu da Chebyshev uzaklığına karşılık gelmektedir. P ve Q gibi herhangi iki nokta arası uzaklık hesaplamada kullanılmaktadır. Formülü aşağıdadır;

$$\left(\sum_{i=1}^n |x_i - y_i|^p \right)^{1/p}$$

Öklid Uzaklığı: Gruplandırmada en çok kullanılan uzaklık hesaplamasıdır. İki nokta arasındaki mesafenin doğrusal hesaplamasıdır. Temel bir uzaklık ölçümüdür. P ve Q gibi herhangi iki nokta arası uzaklık hesaplamada kullanılmaktadır. Formülü aşağıdadır.

$$\left(\sqrt{\sum_{i=1}^n (x_i - y_i)^2} \right)$$

Manhattan Uzaklığı: İki nokta arasındaki n boyutlu mutlak olan değerlerin toplamı denilebilir P ve Q gibi herhangi iki nokta arası uzaklık hesaplamada kullanılmaktadır. Formülü aşağıdaki gibidir;

$$\left(\sum_{i=1}^n |x_i - y_i| \right)$$

Chebyshev Uzaklığı: Bu uzaklık hesaplamasının bir diğer ismi ise maksimum değer uzaklığıdır. N değerinin sonsuz olduğu özel durumlar için kullanılmaktadır. İki nokta arasındaki farkların maksimum ulaşabileceği değer olarak tanımlanmaktadır. P ve Q gibi herhangi iki nokta arası uzaklık hesaplamada kullanılmaktadır. Formülü;

$$\lim_{p \rightarrow \infty} \left(\sum_{i=1}^n |x_i - y_i|^p \right)^{1/p} = \max_{i=1}^n |x_i - y_i|$$

Dilca Uzaklığı: İki aşamadan oluşan bir uzaklık hesaplamadır. Simetrik belirsizlik katsayısı yöntemi öncelikle hesaplanacak işlemdir. Bu hesaplamada bir tablo elde edilmektedir. Bu tablo üzerinde koşullu olasılık ve Öklid uzaklıkları hesaplanmaktadır. Simetrik belirsizlik katsayısı (SU) ,Bilgi kazancı (IG) gibi kısaltmalarla formülün çözümünde yardımcı olacak değerlerdir. Formülü;


$$SU = 2 \times \left[\frac{IG}{H(Y) + H(X)} \right]$$

Simetrik belirsizlik katsayısı hesaplandıktan sonra uzaklık hesaplanmasına geçilebilir onunda formülü aşağıdadır (Taşçı ve Onan, 2016: s. 29-48).

$$d(x_i, x_j) = \sqrt{\sum_{Y \in \text{baglam}(X)} \sum_{y_k \in Y} (P(x_i|y_k) - P(x_j|y_k))^2}$$

Bu yöntemin avantajları ve dezavantajlarından bahsedecek olursak, ilk olarak bu yöntemin ortalaması alındığı için karmaşık verilerden uzaktır. Diğer bir avantajı ise uygulaması ve bunun sonucunda analizi oldukça kolaydır. Yorumlanabilmesi kolaydır.

Dezavantajlarından ilki en yakın komşularına k denilmesi ikincisi iki nokta için uygulanan formüllerin seçilen noktanın mesafesinden etkilenmesi üçüncüsü ise eğitim verilerinin büyük olması bize verimin ve faydanın yüksek olduğunu göstermektedir (Köktürk, 2012: s. 27).



Şekil 2.7 K-En Yakın Komşu Öğrenmesi Gösterimi

W1, W2, W3 olmak üzere 3 gruba ayrılan bir örneklendirmeye özetleyebiliriz. Bilinmeyen bir x_u 'u gruplandırılalım. $K=5$ değeri için bakıldığında 4 adet komşunun W1 grubunda, 1 tane komşusunun ise W3 grubunda olduğu görünmektedir. Daha etkili olan grup W1 olduğu için değerimiz W1 grubuna aittir (Köktürk, 2012: s. 27).

2.2. Derin Öğrenme Modelleri

Büyük miktarlarda bulunan bulguların makine öğrenimin alt bölümü olarak ayrılır. Genelde insan beyni modeline benzer çalışmasıyla bilinmektedir. Birçok veri kaynaklarını tarayarak ve bu sonuçları analiz ederek hızlı görüntüleme yeteneğiyle insan müdahalesini azaltmaktadır. Derin öğrenme Türkçede ki karşılığı olarak çok sayıda ve gizli katmanları olduğu anlamına karşılık gelmektedir (Huang ve diğerleri, 2020; Yıldız, 2022).

Derin öğrenme, insan beyninin karmaşık karar alma yetisini taklit etmek için çok katmanlı sinir ağları olarak bilinen derin sinir ağlarını kullanan bir makine öğrenmesi türüdür. Derin öğrenme, görüntü gruplandırma, diller arası çeviri ve konuşmayı ayırt etme gibi alanlarda kullanılmaktadır. İnsanların bu konuda çok fazla müdahalesine gerek duymadan çeşitli rutinleri tanıma, problemleri çözmede derin öğrenme yönteminin faydaları oldukça fazladır.


Derin öğrenmenin önemi büyük verileri hızlıca işleyebilmesi, yüksek oranlarda doğruluk sağlaması ve desen, dil gibi alanlarda önceki katmanlardan gelen öğrenmeyle

gerçekleştirir. Tanıma hızı birbirleriyle bağlantılı ve oldukça hızlı olması önemini artırmaktadır.

Sinir ağları: Derin öğrenmenin temelinde, insan beyninden esinlenen hesaplamalı modeller olan sinir ağları bulunur. Bu ağlar, bilgiyi işleyip karar almak için birlikte çalışan bağlı düğümler oluşturur. Beyninde yer alan farklı bölgeler gibi, sinir ağları da belirli işlevlere yönelik katmanlara sahiptir.

Derin sinir ağları: Bir sinir ağını derinleşmesine neden olan, giriş ve çıkış arasındaki katmanların sayısıdır. Daha fazla olan katmanlar, bu ağın karmaşıklığını öğrenmesiyle birlikte isabetli ve yüksek tahminler yapmasını sağlar. Derinlik, derin öğrenmenin adını ve güçlü problem çözme yeteneğini belirleyen temel unsurdur.

Uyarıcı fonksiyonlar: Sinir ağlarında hangi bilgilerin bir sonraki katmana ileteceğini belirler. Ağın öğrenme sürecini yönlendirerek daha karmaşık ve detaylı kararlar almasına yardımcı olur.



Şekil 2.8 Derin Öğrenme Üçgeni

2.2.1. Yapay Sinir Ağları

İnsan beyni ile oldukça benzerdir. Matematiksel yapıların insan beyniyle olan çözümünde ki benzerliğinden kaynaklanmadır. En sık uygulanan yapay zekâ tekniklerindendir. İnsan beyninde bulunan nöronlar gibi yapay sinir ağlarında da üyelerin bir karşılığı bulunmaktadır. Kendi aralarında düğümler oluşturmaktadırlar. Düğümlerdeki bağlantılar davranışlarını ve dolayısıyla sonuçları etkilemektedir (Yıldız, 2021: s. 54).

Yapay sinir ağları üç ana bölümden oluşmaktadır. Bunlar giriş bölümü olan veri ve bulguların girişlerinin yapıldığı bölümdür. İkinci bölüm gizli bölümdür. Burası en ara kattır ve kendi içerisinde bile birden fazla bölümü olduğu için gizli denmektedir. Son bölümümüz olan çıkış bölümü sonuca ulaşıldığı bölümdür. Bu modellerin en güçlü hali derin katmana sahip olandır. Diğer katmanlar daha çok temel düzeyde sınıflandırma görevleri için tercih edilmektedir.

Yapay sinir ağıları günümüzde çok farklı alanlarda kullanılmaktadır. Finasta para birimlerinin kurlarında, pazar analizleri yapmada, karmaşık yapıdaki verilerin analizlerinde, hisse senetlerindeki işlemlerde kullanılmaktadır. Yapay sinir ağlarının sağlık alanında da hayat kolaylaştırmaktadır. Ayrıca robotik kodlamalar gibi alanlarda da kullanılmaktadır. Günümüzde ise kullanılan sistemlerde ve hayatımızı kolaylaştırmada büyük yardımları bulunmaktadır.

Kullanım alanlarını genel olarak bahsetmek gerekirse bunlar hisse senetlerinin fiyatlarının tahmininde, kredilerin değerlendirilmesi ve yorumlanmasında, piyasalar hakkında bilgiler, dolandırıcılıklara karşı önlemlerde bize oldukça fayda sağlamaktadır.

Ağ yapısı ve kullanılan yöntemler ve bu yöntemlerin bazı birimleri bulunmaktadır. Bunların isimleri ise şöyledir; Katman adetleri, nöron adetleri, ağırlık ve bias değerleri, aktivasyonları, öğrenme algoritmalarını değerlendirmek yaygındır (Öztemel, 2012: s. 40).

Yapay sinir ağların avantajları vardır. Karışık halde bulunan veriler üzerine bir öğrenme gerçekleştirebilmektedir. Diğer bir özelliği ise verilerin özelliklerini anlayıp öğrenmeleridir. Başka bir özelliği ise görüntüleri işleme alma, doğal dil öğrenme gibi bölümlerinde analizinde kullanılmaktadır.

Yapay sinir ağlarının avantajlarının yanında dezavantajları da bulunmaktadır. İlki verilere ihtiyaç duymakta ve ne kadar büyük olursa verilerin boyutu analizi fazla olmaktadır. Başka bir dezavantajı hesaplama için eğitime ihtiyacının olmasıdır. Başka bir dezavantajı ise nasıl sonuçlandırıldığını anlamak zordur.

Yapay sinir ağları çeşitli alanlarda kullanılmaktadır. Bu kullanımlara ek uygulamaları da şu şekildedir:

- Finasta tahminler, tekrarlananların belirlenmesi, sahteciliklerin belirlenmesi.
- Mühendislikte hata oranları, durumların analizleri, görsel analizler, sürecin iyi kullanılması,
- Satış pazarlama alanında tahminler, tekrarlananların belirlenmesi.
- Hizmette tahminler, tekrarlananların belirlenmesi.
- Üretimde hataların oranları, tahminler, sürecin iyi kullanılması.


Finans alanında örnekleri daha fazla çeşitlendirecek olursak iflasların tahminleri, ipotekler, tahvillerin kademelendirilmesi, kredi kartına dair uygulama ve değerlendirmeler, hisse senetlerinin seçilerek işlemleri, oluşabilecek banka iflasları, ekonomide tahminler, yatırım fonlarının seçilmesi, döviz kurların tahminleri, nakit akımların tahminleri gibi genellikle tahminlerden söz etmek mümkündür (Diler, 2003: 73; Emir, 2013).

Yapay sinir ağlarının en baskın ve güçlü yönleri şunlardır:

- Öğrenme
- Genelleme
- Evrensel yaklaşma
- Kendi kendine öğrenme yeteneği
- Sistematik çalışma
- Hassas yapı Dayanıklılığı ve düşük hata toleransları

Yapay sinir ağlarının zayıf yönleri aşağıdaki gibidir:

- Öğrenme süresi uzun olabilmektedir.
- Öğrenmeyi ön plana koyarak genelleme yapması zorlaşabilir.
- Verilerin miktarına ve doğruluğuna bağlı olması.
- Gelişmekte keşfedilmekte olan bir yapıdır.
- Güven aralığı bulunmamaktadır.
- Eğitimi esnasında verilerin doğruluğu gibi ayrıntılara fazlaca dikkat etmektedir (Vellido vd., 1999: s. 62; Emir, 2013).




Şekil 2.9 Yapay sinir Ağları İşleyiş Şeması

Her bir bilgisi birbiriyle bağlantılı olan bu yapılar birçok daha başka yapılarından verilere ulaşarak bir çıktı oluşturmaktadır. Bu işleyen yapı insan beynindeki nöronlara benzetilebilmektedir. Ulaşılan bu çıktı diğer bölümlere girdi olarak iletilmektedir (Reed & Marks, 1999: 1; Emir, 2013).


Yapay sinir ağları dört alt gruba sahiptir. Bunlar tek katmanlı, çok katmanlı, ileri beslenmeli ve geri beslenmeli yapay sinir ağları olarak ayrılabilir.

Tek Katmanlı Yapay Sinir Ağları: Çıktı fonksiyon olarak doğrusaldır. Sonuçlar 1 ile -1 arası değer alması beklenmektedir. Bu değerlerden 1 ise birinci sınıf, -1 ise çıktımız ikinci sınıf olarak kabul edilmektedir (Öztemel, 2006; Öztürk ve Şahin, 2018).




Şekil 2.10 Tek Katmanlı Yapay Sinir Ağları Modeli

Çok Katmanlı Yapay Sinir Ağları: Yapı itibariyle doğrusal değildir. Bağlantılar birbirleriyle oldukça çok katmanlar halindedir.




Şekil 2.11 Çok Katmanlı Yapay Sinir Ağları Modeli

İleri Beslemeli Yapay Sinir Ağları: Girişten çıkışa kadar bağlantılar düzenlidir. Hep ileri yönlü bir bağlantı sistemi bulunmaktadır. Kendinden sonraki katmanla ilgilenmektedir. Gizli bir katmana sahiptir. Bu gizli katmanda girişe gelen veriler ve bilgiler değişiklik yaşamadan orta noktada yani gizli katmana gelir. Çıkış katmanında veriler işlenerek bir çıktıya yani sonuca ulaşılmaktadır.



Şekil 2.12 İleri Beslemeli Yapay Sinir Ağları Modeli


Geri Beslemeli Yapay Sinir Ağları: Doğrusal olmayan oldukça dinamik bir yapıya sahiptir. Bu sistemin geri beslenmeli yapıya sahip olabilmesi için bağlantının bağlantı şekline ve ileri beslenmeli de olduğu gibi değil daha çok çıktısı, sadece kendinden sonra gelen katmanda veya kendi bulunduğu katmandaki bir bağlantıya girdi olarak bağlanmasından kaynaklanmaktadır (Doğan, 2016: s. 56).



Şekil 2.13 Geri beslemeli Yapay Sinir Ağları Modeli

2.2.2. Tekrarlayan Sinir Ağları

Yapay sinir ağlarının bir türüdür. Zamana dayalı ve bağlı olarak bulguları işleyip uygulamak için oluşturulan bir öğrenme yöntemidir. İsmi çıktıların belirli bir tekrara ya da zaman seriler içerisinde tekrarlamasından almaktadır. Girdileri işleme alırken geriye dönük verilerin analizlerini de yaparak tekrarına bakmaktadır. Yani önceki katmanlardan gelen bulguları ve öğrenmeleri sıradaki bölüme öğrenerek aktarmasıdır. El yazıları, konuşmalar, yazışmalar gibi zaman serilerini de inceleyerek oluşturmaktadır. Açılımını gösteren şema aşağıdadır.



Şekil 2.14 Tekrarlayan Sinir Ağları Modeli

Tekrarlayan sinir ağlarda her bir katman girişler için çıktı üretmektedir. Bu çıktılarda bir sonrası katmana dâhil edilerek ilerlemektedir. Sonunda bağlantılı veriler elde etmek mümkündür.

Tekrarlayan sinir ağlarının katmanlarının yapısı ise bulunduğu katmandaki girdilerin ve çıktılarının bir sonraki aşamaya devretmesidir. Gizli olan durumları da göz önünde bulundurulması gereken katmandır. Bu sebepten iki tür girdi almaktadır. İlki güncel olan girdiler ikincisi ise bir önceki katmandan devredilen gizli girdilerdir.

Matematiksel olarak bir formüle dökmek gerekirse şu döngüyü şu şekilde anlatabiliriz.

$$h_t = f(W_x \cdot x_t + W_h \cdot h_{t-1} + b_h)$$

- h_t : t zaman adımındaki gizli durum,
- x_t : t zaman adımındaki girdi,
- h_{t-1} : t-1 zaman adımındaki gizli durum,
- W_x ve W_h : Ağırlık matrisleri,
- b_h : Önyargı (bias),
- f : Aktivasyon fonksiyonu

Tekrarlayan sinir ağların avantajları için zaman ve sıra konusunda bilgiyi güncel tutmaktır. Bir diğer avantajına da girdilerin dinamik tutulmasıdır. Ve girdilerin miktarıyla orantılı olarak boyutlarının artmamasıdır. Son olarak geçmiş verilerindeki hesaplamaları da göz önünde bulundurmasıdır.

Tekrarlayan sinir ağların dezavantajları da bulunmaktadır. İlki çok uzun vadede hatırlanmasının zorlaşması yakın geçmişin karışıklığından etkilenmesi gibi bir sorun gözlemlene bilmektedir. Başka bir dezavantajı yön türevlerinin azalması ya da çoğalması gibi sorunlar bu ağın eski olan bilgileri öğrenmesini ve tekrarlamasında sorunlara neden olabilmektedir. Önceki verilere ulaşmasındaki zorluğu algoritmayı yavaşlatmaktadır. Ve son olarak da zaman olarak uzun hesaplama gerekmektedir (Öztürk ve Şahin, 2018: s. 84).


2.2.3. Konvolüsyonel Sinir Ağları

Derin öğrenme algoritmalarından olan ve bize farklı objeleri ve nesnelerin birbirlerinden ayrılmasında faydası bulunan bir sistemdir. Resim, video, metin ve sesler gibi veriler üzerinde kullanılan bir öğrenme modelidir. Katmanları konvolüsyonel katman, aktivasyon fonksiyonları, depolama katmanları, tam bağlantı katmanlı olarak bölümlere ayrılmaktadır. Herhangi bir resmin özelliklerinin belirlenmesinde sistem birçok aşamadan geçmektedir.

Yapay sinir ağlarında en özel ağıdır ve bu ağda en az bir katmanından matris çarpanı yerine konvolüsyon yani girdiler üzerinde özellikleri belirlemek için dolaşması demek olan işlem gerçekleştirilmektedir. Girdi verilinin tanımlanarak sınıflandırılmasında kullanılan bir

algoritmadır. Nesne tanıma, görüntü sınıflandırılması, yüz tanıma, analiz gibi uygulamalarda ve hayatı kolaylaştırmak amacıyla sıklıkla kullanılmaktadır.

Konvolüsyonel sinir ağları kendiliğinden öğrenme gerçekleştirir ve doğruluk oranı oldukça yüksektir (Datakapital, 2024).



Şekil 2.15 Konvolüsyonel Sinir Ağları Modeli

Konvolüsyon sinir ağlarının temel yapılarından bahsedelim. Giriş bölümü işlemlerin yapılacak olan ve görüntüden oluşan katmandır. Evrişim katmanı en önemli katmanlardandır. Görüntünün özelliklerini belirlemek için yararlı bir katmandır. Diğer bir katman ise havuzlama katmanıdır. Burada boyutuyla ilgili bir küçültme ya da hesaplanan maliyetler ile ilgili bir azaltma yapılacak olursa ve bilgi korumayı sağlarken kullanılması gerekmektedir. Bu katmanda da iki tane yöntem vardır Bu yöntemler ise Max Pooling ve Average Pooling yöntemleridir. Diğer katman tam bağlantı katmanlarıdır. Bu katmanda sınıflandırarak bölümlere ve çıktıların hesaplaması yapılmaktadır. Çoğunlukla bu katmanın sonlarında softmax yani çıktıların olasılıklarını gösteren bir veri ortaya çıkmaktadır (Tüfekçi ve Karpaz, 2019: s. 46-78).

Altıncı katmanımız olan çıkış katmanı ise eğer verilerden sınıflandırma yapıyor ise sınıflandırmaya esas olasılıkları hesaplamaktadır. Diğer katmanımız eğitim ve geri yayılımdır. Büyük verileri minimuma indirerek uygunluk fonksiyonlarına bakar. Diğer katmanımız uygunluktur. Tamamen performansını kontrol etmek için kullandığımız katmanıdır. Son katmanımız olan en uygun şekli alması gereken algoritması ağırlık ve öğrenme matrisleri için kullanılan katmandır ve stokastik gradyan inişi, Adam, RMSProp gibi algoritmalar kullanılmaktadır.

Konvolüsyon sinir ağlarının avantajlarından bahsetmek gerekirse şöyledir; her birimin giriş bölümüyle bağlantısı söz konusudur ve bu da hesaplamalarda minimizasyon sağlamaktadır. Katmanlar arası bağlantıya dayalı olarak görüntülerdeki piksellerin

analizlerinde bize konvolüsyon sinir ağlarının güçlülüğünü göstermektedir. Başka bir avantajı ise katmanların bağlantılı olup basitlikten karmaşıklığa geçmede herhangi bir sıkıntı çıkarmadan analiz edilebilmesidir.

Konvolüsyon sinir ağlarının dezavantajlarından bahsetmek gerekirse şöyledir; yetersiz verilerden sağlanan fayda da azalmaktadır. Başka bir zorluğu güçlü donanımına sahip olmalıdır. Bunun nedeni ise büyük verilerle işlemler yapıldığından eğitim süreci bu sinir ağının grafik işlemcileri kadar etkili ve güçlü olmalıdır.

Konvolüsyon sinir ağlarının kullanıldığı alanlar doğal dil işleme, otonom araçlar, video analiz ve algılama, tıbbi görüntüleme gibi alanlarda kullanılmaktadır (Datakapital, 2024).

2.3. Takviyeli Öğrenme

Takviyeli öğrenme, dinamik ve alınan kararlar ile karşımıza çıkan problemlerin çözümünde kullanılmaktadır Ticaret stratejileri geliştirmede kullanılmaktadır. Daha çok denemelere dayalı bir öğrenme tekniğidir. Strateji olarak ise Markov Karar sürecini kullanmaktadır. Kullanılan bu Markov stratejisi, gelecek durumlardan etkilendiği ve sıralı olarak ilerleme olan bir süreçtir. Ajan olarak belirlenen birim karşılaştığı durumlar için bir aksiyon almakta sayısal olarak bir ödül hak etmektedir. Ajan olabilecek değişik durumlar için ödülünü yükseltmek üzere farklı durum denemelerinde bulunur. Takviyeli öğrenme modeli, dinamik ve belirsiz durumlar için kullanılmaktadır. Finansal piyasalar, robotik sistemler ve son olarak oyun teorilerinde sık sık uygulanmaktadır (Çeltek, 2021: s. 41-57).

Avantajları ve dezavantajları ise şunlardır: Avantajlarından biri ortamın önceden belirlenmesi gerekmez olabilecek durumlara karşı esnektir. Diğer bir avantajı ise gelecekte olacak ödüllere göre politikalar izleyebilmektedir.

Dezavantajlarından bahsedecek olursak da. Birinci dezavantajı durumun karmaşıklığına bağlı olarak süreç uzayabilmektedir. İkinci dezavantajı yeterli veriler sağlanmazsa modelin öğrenmesi zorlaşabilir. Üçüncü dezavantajı ise genelleme özelliğinin hızlı kaybolmasıdır. Tek bir duruma yatkınlığının olması olumsuz etkilemektedir.


2.3.1. Q-Öğrenme

Çevrimiçi olarak öğrenilen ve çevre hakkında bilginin olmadığı durumlarda kullanan bir yöntemdir. Verilerden etmen role sahip olanının ve uygulanacak politikanın model üzerinde birden öğrenmesi zordur. Daha önceden bir eğitimi yoktur sadece ödüllere odaklı çalışmaktadır. Daha kolay bir politikası olan sayısal verilerden fonksiyon öğrenmesi ve bu öğrenme sonucunda en uygununu seçmek olacaktır. Bu yöntemde ajanın rolü baskındır ve

hareketlere göre kazanacağı ödüllerin hepsine ulaşabilmektir. Labirent ve arama gibi problemlerde sıklıkla kullanılmaktadır.

Q öğrenmenin avantajları ve dezavantajlarından kısaca bahsedecek olursak şunları söyleyebiliriz. Avantajlarından ilki ortamın dinamiklerine bağlı olmadan öğrenimin gerçekleşmesine fayda sağlamak. İkincisi değişen ve oluşabilecek koşullara hızlı uyum sağlayabilmesidir. Üçüncüsü ise geleceğe yönelik stratejilerde bulunabilmesidir.

Dezavantajlarına ise ilk olarak q tablosunun boyutu hızlıca büyüyebilir ve bu durum hesaplama maliyetlerinde olumsuz bir etki yaratmaktadır. İkinci dezavantajı mevcuttaki durum ile rastgele keşifler arası dengeyi korumanın zor olmasıdır. Üçüncü dezavantajı sürekli olan durumlarda q öğrenmesinin uygulanması zordur fakat derin q öğrenmesinin daha kolay olacaktır. Avantaj ve dezavantaj olarak bunları söyleyebiliriz.



Şekil 2.16 Q Öğrenme Akış Modeli

Yukarıda gösterilen akış şemasını detaylıca göstermektedir. Aşağıda ise formülü yer almaktadır. Formülü de şu şekildedir:

$$Q(s, a) = (1 - \alpha) * Q(s, a) + \alpha * (r + \gamma * \max_{a'} Q(s', a'))$$


- Q değeri durumdan s ve aksiyondan a almaktadır.
- Öğrenme hızını α gösterir.
- Anlık alınan ödülün göstergesini de r ifade etmektedir.
- İndirimi de bize γ sembolü göstermektedir.
- Bir sonraki durumu da S' göstermektedir.
- Bir sonraki durumdaki aksiyonu da bize a' göstermektedir.

Maksimum değeri gösterir fakat bir sonraki durumlar için bunu da formülümüzde $\max Q(s', a')$ ile görmekteyiz.

2.3.2. Derin Q- Öğrenme

Derin q öğrenme modeli takviyeli öğrenme ve derin öğrenmenin birlikte uygulanmasıyla ortaya çıkan bir yöntemdir. Derin sinir ağları kullanılarak en uygun q değeri seçilmektedir. Temel fonksiyonlardan olan takviyeli öğrenme ve derin sinir ağları bileşenleri ile bağlantılı olması büyük boyutlardaki verileri derin sinir ağlarıyla çözebilmesidir.

Aşağıda derin q öğrenmenin işleyişi karşılaştırılmalı olarak şema ile gösterilmektedir. Derin öğrenme bölümünde aksiyonun oluşturduğu bir q tablosu bulunmaktadır. Eylemler bu tabloda belirlenmektedir. Derin q öğrenmesinde ise durum biraz daha farklıdır. Eylemlerin belirlenmesinde yöntem olarak derin sinir ağları kullanılmaktadır. Durum bilgileri öncelikle giriş katmanında yer alır. Durum bilgi sayısı bize giriş katman sayısı ile aynı sayıda olmalıdır. Ajanın alacağı aksiyonlar ise bize çıkış katmanında karşımıza çıkmaktadır. Çıkış katmanındakiler bize aksiyonları göstermektedir. Ara katman ve buradaki aksiyonların sayısı bize derin öğrenme yöntemindekine benzer şekilde rastlantısaldır (Fan ve ark., 2020; Çeltek, 2021).




Şekil 2.17 Derin Q Öğrenme Akış Modeli

2.4. Genetik Algoritma

Genetik algoritma, en uygun şekliyle ve karmaşık problemlerinin çözümünde kullanılmaktadır. Özellikle çözüm uzayı büyük sorunlarda, klasik metotlar ile çözüme ulaşılmayan sorunlarda veya ulaşılabilecek sorunların çözümü vakit alan durumlarda kullanılmaktadır. Genetik algoritma permütasyon tabanlı verileri analiz eder ve oluşabilecek olasılıkları da değerlendirerek sonuca ulaşmamızı sağlayan bir yöntemdir. Kısaca arama ve en iyileme algoritması da demek mümkündür. Genetik algoritma daha çok doğal seçimlere bağlı

olaraktan arama ve optimizasyona ulaşma yöntemidir. John Holland tarafından temel özellikleri oluşturulmuştur. Bu konu üzerine birçok bilimsel çalışmalar ve araştırmalar bulunmaktadır. Fonksiyon optimizasyonu, çizelgeleme, mekanik öğrenme, tasarım, hücresel öğrenim gibi alanlarda oldukça başarılıdır (Goldberg, 1989: s. 1-7; Emel ve Taşkın, 2002).

Bu yöntemin arama yapısı için alt diziler teoremi ve yapı blokları hipotezi ile açıklamak mümkündür.



Şekil 2.18 Genetik Algoritma Akış Modeli

Kaynak: <https://www.veribilimiokulu.com/genetik-algoritma/>

Amaç fonksiyonun en uygun şekilde olması, yapay sinir ağlarının gerekli eğitimlerinin verilmesi, sistemde üyelik kimliklerinin verilmesi gibi ya da sistem kontrolü gibi alanlarda yukarıdaki şekilde görüldüğü gibi başarıyla çalışmaktadır.

Genetik algoritmanın işleyiş adımları

- Kodlamanın yönteminin karar verilmesi
- Başlangıç popülasyonun yani ilk neslin belirlenmesi
- Oluşturulan başlangıç popülasyonun her bir bireyin performansına göre amaç fonksiyonlarının belirlenmesi
- Yeni nesil için ve bu nesilde kullanılacak olan elemanların seçilmesi
- Seçilen bu elemanlara, genetik işlemlerden sonra yeni nesille dâhil etmek

- Yeni nesildeki elemanlara performansları dikkat edilerek uygunluk fonksiyonları hesaplanması
- Koşullardan istenilen sonuç alınmadıysa dördüncü aşamaya geri dönmeli
- Bitiş için istenilen sonuç alındıysa en iyi elemanın sonuç olarak dönülüp kaydedilmesidir (Eren, 2024: s. 25-47).

Genetik algoritma, portföy optimizasyonunda kullanılabilecek bir yöntemdir. Yatırımcıların portföylerinde yardımcı olabilecek bir algoritmadır. Karmaşık problemlerin hızlı bir şekilde çözülmesini sağlamaktadır (Gonzales, 2000: 683; Emel ve Taşkın, 2002).

Genetik algoritmanın uygulanabilmesi için ilk olarak algoritmaya uygun matematiksel formülle gösterilmesi gerekmektedir. Her bir varlığa karşılık olarak belirlenmiş bir getiri ve risk oranı olmalıdır. Genetik algoritmanın kullanımı şunlardır (Mitchell ve Forest, 1994; Eren, 2024):

- Uygun portföy seçimi
- Ulaşım problemleri
- Algoritmik bir ticaret
- Opsiyon fiyat değerlendirme
- Risk belirleme ve yönetim
- Tahminlerin optimizasyonu

Genetik algoritmanın avantaj ve dezavantajlarından bahsedecek olursak. Avantajlarından ilki karmaşık sorunları hızlıca çözebilmesidir. İkincisi küresel olarak çözüm bulması olasılıkları daha yüksektir. Üçüncüsü farklı sorun ve problemlere kolayca adapte olarak uyarlanabilmesidir. Dördüncüsü popülasyon tabanlı bir algoritma olmasından kaynaklı paralel hesaplamalar ile birlikte hızına hız katmaktadır.

Dezavantajları için de ilk olarak işlem süresi olarak uzun ve maliyetli durumlar ile karşılaşılabilir. İkincisi çaprazlama oranı, mutasyon oranı, popülasyon büyüklüğü gibi parametreler bu algoritmanın başarısında oldukça etkilidir. Üçüncüsü küresel optima yerine yerel bir durum haline gelebilmektedir.

Dikkat edilmesi gereken bazı noktalar vardır. Örneğin fitness fonksiyonun doğruluğunun belirlenmesi sonuçlarla bağlantılıdır. Tek başına bu yöntemle güvenerek karar vermek çok sağlıklı olmayabilir. Özellikle portföy optimizasyonunda genetik algoritmanın kullanılması ve haliyle birçok değişkenin bulunması, oluşabilecek risk oranlarına da dikkat

etmemiz gerektiğini göstermektedir. Genetik algoritma uygulama yöntemleri olarak niteliklerinin gereği olarak nicel bir şekildir (Forrest, 1996, s. 79; Baghdadı, 2023).

2.4.1. Genetik Programlama

John Koza tarafından 1992 yılında geliştirilip genetik programlama adı verilerek ortaya çıkmıştır (Telcioğlu, 2007: s. 62). Genetik algoritmanın bir türü kullanım şekli bakımından ayrılmaktadır. Otomatik kod sorunlarını çözmede ve regresyon modelinde kullanılmaktadır. Popülasyona bağlı olarak sembolik ifadeler ya da problemler oluşur ve bunlara çözüm arayıp en uygunun seçimi yapılarak ilerleme gerçekleşmektedir.

Yedi tane temel bileşeni bulunmaktadır.

1. Popülasyon oluşturma (bir toplum üret) :

İlk adımımız olan popülasyonun oluşturulmasıdır. Sembolik ifadelerden ve programlar içermesi oldukça önemlidir. Her bir program, bir problemin olası çözümüne karşılık gelen bir adaydır.

2. Uygunluk (Fitness fonksiyonu) :

Programların uygunluk değeri mutlaka olur. Bu fonksiyondaki uygunluk değeri programın ne kadar iyi ya da iyi olmayan bir çözüm sunduğunu göstermektedir. Bu fonksiyonun diğer bir amacı ise en uygun seçilmesi istenilen hedefi temsil etmektedir. Çoğunlukla bizlere program çıktısı ile gerçek değer arasında oluşabilecek farkı göstermektedir.

3. Evrimsel işlemler :

Çaprazlama ve mutasyon olarak iki alt başlığı bulunmaktadır. Çaprazlama iki tane programdan belirlenen iki noktanın kesilerek birleştirilmesi ve yeniden bir programa dönüşmesidir. Mutasyon ise sembolik ifadelerin rastgele değiştirilerek yeniden bir program oluşmasıdır. Genetik çeşitliliğin artmasında önemli bir rolü bulunmaktadır.

4. Seçim:

Programlar uygunluk seviyelerine göre değerlendirilir ve en iyi performansı olanlar seçilir. Daha yüksek uygunluk değerine sahip programlar, sonraki nesillerde daha fazla temsil edebilme şansına sahiptir.

5. Elitizm:

En iyi programlar, bir nesilde korunarak en iyi çözümlerin kaybolmasını engeller. Bu yöntem, daha hızlı ve etkili bir sonuca ulaşmamızı sağlamaktadır.

6. Nesiller:


Genetik programlama, belirli bir nesil sayısına ulaşana veya istenilen uygunluk düzeyine erişene kadar ardışık olarak nesiller üretir ve geliştirir.

7. Gözlem ve analiz:

Genetik programlama sürecinde her neslin en iyi programları takip edilerek analiz edilir. Bu ilerlemenin değerlendirilmesini ve çözümün optimize edilip edilmediğini kontrol edilmesini sağlar (Çayıroğlu, 2010: s. 74).

Genetik Programlamanın Kullanılan Alanları:

- Fonksiyon keşfi olarak bilinmeyen matematiksel fonksiyonların modellenmesinde kullanılır.
- Finansal modelleme olarak piyasadaki hareketleri incelemek ve stratejiler oluşturmada kullanılır.
- Bir sorun için en uygun çözümü aramada kolaylık sağlayıp algoritma optimizasyonunda kullanılmaktadır.
- Oyunlardaki simülatif stratejilerin geliştirilmesinde ve en hızlı, etkili hamlelerin kararında kullanılmaktadır.
- Optimal kontrol
- Robotik sistemler



Şekil 2.19 Genetik Programlama, Çaprazlama ve Mutasyon Modeli

Rastgele iki düğüm seçilerek başlanmaktadır. Bu çaprazlamadır. Mutasyon ise gerçekleşmesinin bir oranı vardır. Bu alanda gerçekleşebilmektedir. Mutasyonda tamamen rastgele bir düğüm belirlenir ve yine rastgele bir düğümle değiştirilir.

Genetik programlamanın avantaj ve dezavantajlarından bahsedecek olursak. Avantajlarından ilki doğrusal olmayan ve karmaşık problemlerin çözümünde kolaylık sağlamamıza yardımcı olmaktadır. İkincisi birçok farklı probleme adapte olması kolaydır.

Üçüncüsü otomatik kod üretebilmesi ilave bir insan beyni kontrolüne gerek göstermemektedir. Dördüncüsü farklı bilinmeyen kalıplar ve modellerde çalışabiliyor olmasıdır.

Dezavantajlarından ilki karmaşık problemler için oluşacak maliyetin artması bir dezavantajdır. İkinci dezavantajı bazı durumlarda oldukça karışık çözümler üretmesi risk oluşturabilmektedir ve bakımı süreci oldukça zordur. Üçüncüsü genetik programının başarısını doğrudan etkileyen elemanları vardır bunlar popülasyon büyüklüğü, nesil sayısı, çaprazlama gibi etkenler ile bağlantılıdır (Çayıroğlu, 2010: s. 74).

2.4.2. Genetik Algoritma Tabanlı Sıralama

Genetik algoritma tabanlı sıralama en çok sıralama problemlerinin çözümünde kullanılması planlanan bir yöntemdir. Veriler belirli bir sıra ve düzene bağlı olarak sıralamak ve sıralananlar arasından en uygununun seçilmesiyle devam eden işlemdir. Bu sıralamalar daha çok tablo oluşturma, turnuvaların sıralanması sıralı veriler çıkarıp analizlerinin yapılması gibi alanlarda kullanılmaktadır.

Geleneksel sıralama algoritmalarının bize gerekli bilgi ve analizleri yapamadığı ve yüksek boyutlu verilerde kullanılmaktadır.

Temel bileşenleri ve kısaca tanımları şöyledir;

- Popülasyon oluşturma: İlk adım budur. Çözüm adaylarının gösterilmesi ve her adayın sıralamada yerinin olduğunu göstermektedir.
- Uygunluk Fonksiyonu: Her sıralamada bulunan adayların bir uygunluk değeri bulunmaktadır. Bu fonksiyon bize o sıralamanın ne kadar iyi ya da kötü olduğunu göstermektedir. Hedefleri her zaman belirli bir kritere göre olmalı ve sıralamaya sahip olmalıdır.
- Evrimsel çevrimler: Çaprazlama ve mutasyon olarak iki alt başlık yazabiliriz. İlk çaprazlama için iki sıralaması olan verilerin sıralarının birleştirilmesi yeniden bir sıralama oluşturmaktır. İkinci olan mutasyon için sıralamadaki sırayı rastgele değiştirmesi ve yeniden farklı bir sıralama elde etmesidir.
- Seçim: Kendisinden sonraki nesille daha uygun gördüğü seçim sıralamasının aktarılmasını yapmaktadır.
- Elitizm: En iyisi olduğu düşünülen sıralamaların her nesilde korunmasıdır. Amaç en iyi sıralamaların kaybolmasını önlemek olacaktır.

- Nesiller: Belirli sayı ya da istenilen uygunluğa ulaşılan kadar nesillerin sıralanıp geliştirmesidir.
- Gözlem ve analiz: En iyisi sıralama belirlenir ve analiz edilir (Baghdadi, 2023: s. 58-87).

Uygulama alanları olarak çoklu görevlendirmelerde kaynakların verimini artırmak amaçlı sıralamalar, belirli kriterlere göre önceliklendirmek, sınırlı olana kaynakların kullanım planlamalarının yapılması, depolama ve dağıtımın en uygun şekilde planlanması, karışık verilerde belirli kriterlere göre sınıflandırılır.

Sıralama problemlerinin çözümünde oldukça yardımcı ve etkili bir yöntemdir. Birçok farklı sıralamalara göre algoritma gerçekleştirilebilir.

Genetik algoritma tabanlı sıralamanın avantaj ve dezavantajlarından bahsedecek olursak. Avantajlarından ilki karmaşık ve en uygun seçimlerin yapılmasında etkilidir. İkincisi esnekliği oldukça yüksektir. Farklı problemlere kolay uyum sağlayabilmektedir. Üçüncüsü çözüm kümesi geniştir ve küresel boyutlarda olabilmektedir.

Dezavantajlarından ilki hesaplama maliyetlerinin yüksekliği olabilmektedir. İkincisi esnek olmasından kaynaklı sorunların çözümünde bazı zamanlarda karmaşık bir sonuca götürebilmesidir. Üçüncüsü çaprazlama ve mutasyon gibi verilerin doğruluğu sonucumuzun başarısıyla doğru orantılı ve etkilemektedir.

2.4.3. Küme Tabanlı Genetik Algoritma

Küme tabanlı genetik algoritmalar isminden de anlaşılacağı gibi kümeleme problemlerinin çözümünde daha etkili çalışabilmektedir. Verilerdeki benzer verileri gruplayarak en uygun olanlar arasından seçim yapılarak kümeleme işlemini gerçekleştirmektedir. Özellikle veri madenciliği ve veri analizlerinde kullanılmaktadır. En önemli amacı ise verileri aynı özelliklere sahip şekilde kümelemek ve bu kümenin sınırlarını belirlemektir.

Temel bileşenleri ve kısaca tanımları şöyledir;

- Popülasyon oluşturma: İlk adım budur. İçerisinde küme merkezi ve sınırlarını göstermektedir. Çözüm kümesini de içermektedir. Adaylar kümelemede çözümü temsil etmektedir.
- Uygunluk Fonksiyonu: Kümenin merkezinin sınırlarını ve ne kadar adapte olabildiğini göstermektedir. Bu fonksiyon bize o sıralamanın ne kadar iyi ya da kötü olduğunu göstermektedir.

- Evrimsel çevrim: Çaprazlama ve mutasyon olarak iki alt başlık yazabiliriz. İlk çaprazlama için iki kümelemenin kümelerinin ve sınırlarının birleştirilmesiyle yeniden kümeleme çözümü oluşturmaktır. İkincisi olan mutasyon ise küme merkezlerinin ve sınırlarının rastgele değiştirilmesiyle farklı bir kümelemenin olması demektir.
- Seçim: Kendisinden sonraki nesille daha uygun gördüğü seçim kümesinin aktarılmasını yapmaktadır.
- Elitizm: En iyisi olduğu düşünülen kümelemenin her nesilde korunmasıdır. Amaç en iyi kümelemenin kaybolmasını önlemek olacaktır.
- Nesiller: Belirli sayı ya da istenilen uygunluğa ulaşılan kadar nesillerin sıralanıp geliştirmesidir.
- Gözlem ve analiz: En iyisi sıralama belirlenir ve analiz edilir.

Uygulama alanları olarak verilerin kümelere ayrılması, en iyi finansal kararlarda, kaynakların en verimli şekilde kullanılmasında, makine öğrenmesinde kullanılmaktadır.

Küme tabanlı genetik algoritmanın avantaj ve dezavantajlarından bahsedecek olursak. Avantajlarından ilki kümeleri ile en uygun seçim yapılabilen ve bu da hızını oldukça etkilemektedir. İkincisi geniş bir çeşitliliğe sahiptir. Farklı kümeleri farklı çözüm uzaylarının çeşitli bölümlerini de araştırabilmektedir. Üçüncüsü karmaşık ve veri boyutlarının yüksek olduğu problemlerde daha iyi çalışabilmektedir. Dördüncüsü kümelerin kendi aralarında bilgi aktarımı olabilmektedir.

Dezavantajlarından ilki kümeleme ve kümeler arası etkileşim oldukça maliyetleri yükseltmektedir. İkincisi küme sayıları algoritmaları ve verilerinin en iyisi seçilmesi oldukça önemlidir. Üçüncüsü yanlışlık yapılan algoritma genetik algoritmanın başarısını etkilemektedir (Baghdadi, 2023: s. 58-87).

2.4.4. Çok Amaçlı Genetik Algoritma


Popülasyona dayalı bir algoritmadır. Çok amaçlı genetik algoritmalar amaç ve kriteri fazla olan sorunların çözümünde kullanılmaktadır. Genetik algoritmalar, tek bir çalışmada birden fazla en uygun olmayan ama etkili çözüm olanakları elde edecek şekilde uygulanabilir. Çok amaçlı optimizasyon problemleri, bu esneklik sayesinde genetik algoritmalarla oldukça verimli şekilde çözümlere ulaşabilir. Bu nedenle, çok amaçlı optimizasyon yöntemlerinin kullanılması her geçen gün daha da yaygınlaşmaktadır.

İsim olarak bahsedecek olursak birçok genetik algoritma türü mevcuttur.

- Vektör değerlendirmeli genetik algoritma (VEGA)

- Çok amaçlı Genetik Algoritma (MOGA)
- Hücrelendirilmiş Pareto Genetik Algoritma (NPGA)
- Ağırlık Tabanlı Genetik Algoritma (WBGA)
- Rastgele Ağırlıklandırılmış Genetik algoritma (RWGA)
- Bastırılmış Sınıflandırılmalı Genetik Algoritma (NSGA)
- Kuvvet Pareto Evrimsel Algoritma (SPEA)
- Pareto-Arşivlenmiş Evrim Stratejisi (PAES)
- Pareto Zarflama-Temelli Seçim Algoritması (PESA)
- Bölge Tabanlı Seçim Evrimsel Çok Amaçlı Optimizasyon (PESA-II)
- Bastırılmamış Sınıflandırılmalı Genetik Algoritma II (NSGA- II)
- Çok Amaçlı Evrimsel Algoritma (MOEA)
- Micro-GA, Rank-Yoğunluk Tabanlı Genetik Algoritma (RDGA)
- Dinamik Çok Amaçlı Evrimsel Algoritma (DMOEA)

Vb. şeklinde sıralanabilir (Hark, 2012: s. 54-65).



Şekil 2.20 Çok Amaçlı Genetik Algoritma Akış Modeli

Temel bileşenleri ve kısaca tanımları şöyledir;

- Popülasyon oluşturma: İlk adım olup çözüm adaylarının gösterilmesi ve her adayın görevini göstermektedir. Yani her bir aday, farklı bir problemin potansiyel çözümüdür.

- Uygunluk Fonksiyonu: Her bir çözümün belirli amaçlar karşısındaki performansını ve etkinliğini değerlendirmede kullanılabilir. Bu fonksiyonlar, her bir amaç için uygunluk değeri bulunmaktadır.
- Pareto Ön Sahil: Bu fonksiyonda amaç mevcuttaki durumu kötüleşmesine izin vermeyen ve iyileştirmeye yönelik bir fonksiyondur. Yani bir ön kontroldür. Çözüm adaylarının pareto ön sahilinde olup olmadığını kontrol eder.
- Evrimsel çevrimler: Çaprazlama ve mutasyon olarak iki alt başlık yazabiliriz. İlk çaprazlama için iki çözümleri olan verilerin çözüm kümelerinin birleştirmesiyle yeniden bir çözüm kümesinin oluşturmasıdır diyebiliriz. İkinci olan mutasyon için çözümdeki verilerin özellikleri rastgele değiştirmesi ve yeniden farklı bir çözüm adayları elde etmesidir.
- Seçilim: Pareto ön sahilindeki konumlarına göre seçilen ve bu ön elemanın önemli olduğu bir kısımdır. Kısaca ön sahilde olan verilerin kendisinden sonraki nesille daha uygun ve sonraki nesille aktarılmasını yapılmaktadır.
- Elitizm: En iyisi olduğu düşünülen çözümlerin her nesilde korunmasıdır. Amaç en iyi sıralamaların kaybolmasını önlemek olacaktır.
- Nesiller: Belirli sayı ya da pareto ön sahilde istenilen uygunluğa ulaşılan kadar nesillerin sıralanıp geliştirmesidir (Baghdadi, 2023: s. 48-75).

Kullanım alanları olarak mühendislik tasarımlarında, enerji yönetimlerinde gibi alanlarda kullanılmaktadır.

Çok amaçlı genetik algoritmanın avantaj ve dezavantajlarından bahsedecek olursak. Avantajlarından ilki birbiriyle zıtlaşan amaçlar arasından en uygununun seçilmesidir. İkincisi farklı olan amaçların dengelenerek istenileni karşılayabilmesidir. Üçüncüsü pareto ön sahilinden seçim yapılabilmesidir. Dördüncüsü esnekliği oldukça yüksektir.

Dezavantajlarından ilki ise hesaplamanın maliyetleri diğer algoritmalara göre biraz daha yüksek olabilmektedir. İkinci dezavantajı çözüm kümelerinin korunması için stratejilere sahip olmak gerekmektedir.

Uygulama alanları olarak finansallar için en uygunun olması, dengede risk ve getirisinin olması, maliyetler ile de verimlilik gibi konuların denge halinde olması esastır. Maliyetler arası en uygun olanını hızlı bir seçim ile sonuçlandırmak olduğunu söyleyebiliriz.

2.4.5. Gelişmiş Genetik Algoritma

Gelişmiş genetik algoritma, genetik algoritmanın performans olarak daha iyileştirilmiştir. Karışık problemlerin çözümlerinde genetik algoritmanın da eksiklerini kapatarak geliştirilmiş bir algoritmadır. Yapı olarak aynıdır fakat iyileştirmeler ile geliştirilmiştir.

Özellikleri:

- Kişiselleştirilmiş genetik algoritmalar: Problemlerin türlerine ve özelliklerine göre şekil alabilen çaprazlama, mutasyon ve seçim gibi bölümlere sahip olabilmektedir.
- Hibritleşmiş genetik algoritmalar: Çeşitli en uygun seçimleri ve bunların tekniklerini birleştirerek hibrit algoritmalar geliştirebilir. Bunlar yapay sinir ağları, yerleşik arama yöntemleri gibi örnekler ile çoğaltılabilmektedir. Bu özelliği onun güçlü yanlarıyla ve esnekliğinin diğer tekniklerle uygulanabilmesine sahiptir.
- Özellik çıkarımı: Verilerin depolanması ve belirli bir sıralama problemleri için gelişmiş genetik algoritmaların özellik seçimlerinde özel bir planlamaya sahip olması gerekmektedir.
- Değişken parametre: Gelişmiş genetik algoritmalar, genetik algoritmaların birimlerinde değişken verilerinin esnekliğine sahip olması istenmektedir.
- Farklı popülasyon yapıları: Farklı olan bu popülasyonların yapılarında kendilerine has bir kişiselleştirme yapabilmektedir. Hücrelerini yapıları ya da çevre ile olan etkileşimlerini ele alan bir model oluşturabilmektedir.
- Özel uygunluk fonksiyonları: Kendilerine has problemin türüne göre uygunluk fonksiyonlarını ve değerlendiremeye alacağı koşulları içerebilir.

Gelişmiş genetik algoritmanın avantaj ve dezavantajlarından bahsedecek olursak. Avantajlarından ilki daha hızlı bir yakınlık sağlayabilmesidir. İkincisi karmaşık ve boyut olarak yüksek olan sorunlarda sonuca hızlı ulaşmasıdır. Üçüncüsü en iyi sonuca ulaşma olasılıklarının yüksek olmasıdır.

Dezavantajlarından ilki zaman olarak ve harcama maliyeti olarak güç ister. İkincisi parametrik birimlerinin belirlenmesi karışık olabilmektedir. Üçüncüsü performansını etkileyecek unsurlardan oldukça fazla etkilenebilmektedir.

Uygulama alanları olarak portföylerin yönetimlerinde, risk ve getiri analizlerinde, mühendislik yani karmaşık problemlerde, büyük boyuttaki verilerin saklanması gerektiğinde bir model oluşturulmasında, makinelerin öğrenmesinde yapay sinir ağlarını etkileyecek sisteme sahip olması gibi alanlarda kullanılmaktadır (Ergül, 2010: s. 82).

ÜÇÜNCÜ BÖLÜM

FİNANSAL PİYASALARDA YAPAY ZEKÂ UYGULAMALARI

Bu çalışmanın temel amacı, finansal piyasalarda yapay zekâ uygulamalarının uygulanabilirliğini ortaya koymak olup, bu doğrultuda Borsa İstanbul 30 (BIST 30) endeksine yönelik LSTM tabanlı bir tahmin modeli geliştirilmiştir.

Bu çalışma, 5 Ocak 1997 – 6 Eylül 2025 dönemine ait günlük kapanış verilerini kullanarak endeksin ertesi günkü hareketini tahmin etmeyi amaçlamaktadır. Böylelikle, yapay zekâ yöntemlerinin finansal zaman serilerinde geleneksel yöntemlere göre sağladığı katkılar değerlendirilmektedir.

Borsa İstanbul 30 endeksine ait günlük kapanış fiyatlarından oluşan veri seti, Yahoo Finance platformundan elde edilmiştir. Çeşitli piyasa koşullarını yansıtan uzun dönemli bu veri seti, modelin performansını değerlendirmek açısından uygun bir yapı sunmaktadır. Çalışmada fiyat seviyeleri doğrudan tahmin aracı olarak kullanılmamış, yalnızca grafiklerde görsel destek sağlamak amacıyla değerlendirilmiştir. Çalışmanın esas odak noktası, endeksin logaritmik getiri serisinin tahmini üzerine kurulmuştur.

Bu çalışma, finansal piyasalarda yapay zekâ tabanlı yöntemlerin uygulanabilirliğini göstermesi açısından önemli bir katkı sunmaktadır. BIST 30 endeksine ilişkin uzun dönemli verilerle gerçekleştirilen analizler, LSTM modelinin zaman serisi tahminlerinde kayda değer bir potansiyele sahip olduğunu ortaya koymaktadır. Bulgular, yapay zekâ tabanlı yöntemlerin yalnızca akademik araştırmalar için değil, yatırım karar süreçleri için de değerli bir araç olabileceğini göstermektedir.

3.1. Literatür

Bu bölümde, konuya ilişkin akademik çalışmalar ulusal ve uluslararası olmak üzere iki başlık altında incelenmiştir. Literatür taramasının amacı, çalışmanın kuramsal çerçevesini oluşturmak ve mevcut araştırmaları değerlendirerek araştırmaya sağlam bir zemin hazırlamaktır.

Bu bölümün odak noktasını, yapay sinir ağları, regresyon analizleri ve LSTM modellemelerine ilişkin çalışmaların ulaştığı bulgular oluşturmaktadır. Literatürde kullanılan veri dönemleri, yöntemler, değişkenler ve elde edilen sonuçlar ayrıntılı biçimde ele alınmıştır. Bu doğrultuda, mevcut çalışmanın literatüre önemli katkılar sunacağı değerlendirilmektedir.

3.1.1. Ulusal Literatür

Kantar (2020) tarafından gerçekleştirilen çalışmada, 2009–2019 yıllarını kapsayan on yıllık dönem incelenmiştir. Araştırmanın amacı, BIST 100 endeksinin gelecekteki fiyatlarını tahmin etmektir. Bu kapsamda, karşılaştırmalı olarak iki farklı model uygulanmıştır: geleneksel bir yöntem olan ARMA(1,1) modeli ve yapay sinir ağları tabanlı bir tahmin modeli.

Modellemelerde bağımsız değişkenler olarak altın fiyatları, döviz kuru, mevduat faizi, emisyon miktarı, doğrudan sermaye yatırımları, portföy yatırımları ve sanayi üretim endeksi gibi makroekonomik göstergeler kullanılmıştır. Çalışmanın bulgularına göre, yapay sinir ağları, geleneksel ARMA(1,1) modeline kıyasla daha yüksek tahmin performansı sergilemiştir. Bu sonuca ulaşılmasında R^2 ve MSE gibi performans ölçütleri belirleyici rol oynamıştır (Kantar, 2020, s. 87).

Tektaş ve Karataş (2004) çalışmalarında, dönemin İMKB 100 endeksi (günümüzde Borsa İstanbul) kapsamında iki sektör seçilmiştir: çimento ve gıda. Bu sektörlerden altı şirket (Arçelik, Ereğli Demir Çelik, Petkim, Tüpraş, Vestel ve İş Bankası (C)) analiz kapsamına dâhil edilmiştir. Çalışmada, yapay sinir ağları ile doğrusal regresyon yöntemleri karşılaştırmalı olarak uygulanmıştır.

Veriler haftalık ve günlük olmak üzere iki grup halinde değerlendirilmiştir. Haftalık veriler, farklı dönemlerdeki etkileri incelemek amacıyla; günlük veriler ise kısa vadeli fiyat tahminlerini gerçekleştirmek için kullanılmıştır. Analizde hisse senetlerinin kapanış fiyatları esas alınmıştır. Yapay sinir ağları modeli üç katmandan (girdi, gizli ve çıktı) oluşmakta olup, girdi katmanında son beş günün kapanış fiyatları kullanılmıştır. Günlük verilerde faiz ve enflasyon değişkenlerine yer verilmezken, haftalık verilerde aylık enflasyon, ağırlıklı mevduat faizi ve İMKB 100 endeksi dikkate alınmıştır.

2002–2003 dönemine ait verilerle gerçekleştirilen analiz sonucunda, günlük verilerin tahmin performansını haftalık verilere kıyasla artırdığı belirlenmiştir. Ayrıca, yapay sinir ağlarının tahmin yeteneğinin doğrusal regresyon yöntemine göre daha üstün olduğu ortaya konmuştur (Tektaş ve Karataş, 2004, ss. 337–349; Gündoğdu, 2023).

Karaatlı vd. (2005) çalışmasının temel amacı, geleneksel regresyon modeli ile yapay sinir ağlarını karşılaştırarak hisse senedi fiyat tahminlerini analiz etmektir. Çalışma, Ocak 1990 – Aralık 2002 dönemini kapsamaktadır.

Bağımsız değişkenler olarak hazine bonosu faizi, cumhuriyet altını fiyatı, enflasyon oranı, sanayi üretim endeksi, tasarruf mevduatı faiz oranı, döviz kuru ve zaman değişkeni kullanılmıştır. Veriler altı aylık frekansta işlenmiş ve analizler Matlab (6.1) algoritmasıyla

gerçekleştirilmiştir. Elde edilen sonuçlar, yapay sinir ağlarının geleneksel regresyon yöntemine kıyasla daha yüksek tahmin doğruluğu sağladığını ortaya koymuştur. Performans değerlendirmesinde hata kareleri ortalamasının karekökü (RMSE) belirleyici bir ölçüt olmuştur (Karaatlı vd., 2005; Aytekin, 2021).

Baş (2006) çalışmasının amacı, yapay sinir ağları kullanılarak bazı finansal veriler ve ekonomik göstergelerin tahmin doğruluğunu analiz etmektir. Çalışmada, çok değişkenli ve doğrusal olmayan veriler üzerinde yapay sinir ağları modeli uygulanmıştır. Öğrenme sürecinde geri yayılım algoritması kullanılarak modelin hata oranları en uygun biçimde belirlenmiştir. Modellemede kullanılan başlıca değişkenler arasında dolar alış fiyatı ve faiz oranı yer almıştır. Çalışma kapsamında 1990'lı ve 2000'li yıllara odaklanılmış; özellikle 1995–2005 dönemi esas alınmıştır. Sonuçlara göre, yapay sinir ağları modeli %85–90 doğruluk oranına ulaşarak, finansal tahminlerde tercih edilmesi muhtemel yöntemlerden biri olarak öne çıkmıştır (Baş, 2006, s. 135).

Vural (2007) çalışmasında 2005 yılının kapanış verilerini kullanmıştır. Veriler Borsa İstanbul'dan alınmıştır. Algoritmanın öğrenmesinde geriye doğru bir yayılım olan algoritma kullanılmıştır. Örnek verilerde hisse senedi olarak Akbank seçilmiştir. 2005 yılının ilk 10 ayı temel alınmıştır. Yapay sinir ağlarının hisse senetlerinin tahmininde etkisini gösteren bir çalışma olmuştur (Vural, 2007: s. 87).

Gemici (2012) çalışmasında hisse senetlerinin aralarındaki ilişkiyi ve en iyi yatırım gibi doğru hedeflerle alınmasını sağlamaktır. Borsa İstanbul'da Ulusal Pazar'da işlem gören 10 hisse senedi seçilerek başlanmıştır. Tarih aralığı olarak 01.07.2011 ve 03.10.2011 alınmıştır. Veri hazırlığında ise Apriori algoritması tercih edilmiştir. Hisse senetleri arasında yüksek destek, güven ve lift değerleri içeren bir kural elde edilmiştir (Gemici, 2012: s. 91).

Okutkan (2014) çalışmasında BIST 'te işlem gören hisse senetlerinin getirilerinin tahmin edilmesi ve finansal oranlar kullanılarak analiz edilmiştir. Çoklu regresyon ve yapay sinir ağları karşılaştırılarak bir sonuca varılmıştır. Bağımsız değişkenleri piyasa değeri/defter değeri, hisse başına kar, öz sermaye karlılığı, kaldıraç oranı, euro, dolar, altın fiyatları ve endeks değerleri kullanılmıştır. Belirli bir yıl değil de genelde yıllık bazda finansal raporlamalardan yararlanmışlardır. Çalışmanın sonucundan her iki yöntem ile tahmin etmenin etkili olduğu sonucuna ulaşılmıştır. Fakat yapay sinir ağlarının doğrusal olmayan modellerde daha yüksek doğruluk oranına sahip olması nedeniyle yapay sinir ağlarının tercih edilmesinin tahmin için daha faydalı olduğu sonucuna ulaşılmıştır (Okutkan, 2014: s. 97).

Sarıkaya (2019) çalışmasında borsa endeksi tahminlerinin zorluklarından ve uygulanan yöntemler yapay sinir ağları ve regresyon ile karşılaştırılmasının da hangi

yöntemin daha etkin olduğunu göstermektedir. Yıl olarak 2005 ve 2012 yılları kapanış fiyatları tercih edilmiştir. Çıkan sonuçları ile de 2013 yılındaki kapanış fiyatlarının bir karşılaştırılması yapılmıştır. Bağımsız değişken olarak hazine bonosu, cumhuriyet altın satış fiyatı, enflasyon oranı (TÜFE) ,sanayi üretim endeksi, döviz kurları ve zaman değişkeni tercih edilmiştir. Yapay sinir ağları modeli olan Matlab algoritması kullanılmıştır. Regresyon modeli olarak kübik regresyon modeli kullanılmış ve düşük RMSE değeri ile güzel bir performansa sahip olmuştur. Yapay sinir ağlarında regresyona göre daha düşük bir RMSE değerine ulaştığı görülmüştür. Sonuç olarak yapay sinir ağlarının tahmin edilebilirliği daha gerçekçi ve düşük hata oranı ile de güvenilirliğini tercih edilebileceğini göstermiştir (Sarıkaya, 2019: s. 105).

Yiğit vd. (2019) çalışmasında brent petrol fiyatlarında geçmişteki fiyatları kullanılarak gelecekteki fiyatı tahminlemesini araştırmıştır. Bu tahminleme için zaman serisi ve derin öğrenme yöntemleri kullanmıştır. Çalışmada ortaya çıkan sonucun doğruluğunun karşılaştırılması içinde ARIMA modeli kullanılmıştır. Veriler 1987 ve 2020 yıllarını kapsayan geniş bir zamanı kapsamaktadır. Seçilen bu iki modelin performans açıdan değerlendirecek ölçütler belirlenmiştir. Bunlardan ilki korelasyon katsayısı (R), İkincisi RMSE (Root Mean Squared Error) sonuncusu ise MAE (Mean Absolute Error) seçilmiştir. Sonuç olarak LSTM modelinin ARIMA modeline kıyasla daha düşük hata oranlarına ve daha tahminci sonuçlara ulaştığı görülmüştür. Bu sonuç bize derin öğrenme modellerinin daha etkin ve tahminci olabildiğini göstermektedir (Yiğit vd., 2019: s. 34-38).

Alpay (2020) çalışmasında LSTM modelinin performansı başarılı ve tahminlerinde düşük hata oranları görülmüştür (Alpay, 2020: 452-456). Arslankaya ve Toprak (2021) çalışmasında finansal piyasalardaki hisse senetlerinin iki model üzerinden karşılaştırmıştır. Bu iki model içinde farklı ikişer adet daha model kullanılarak hisse senetlerinin fiyat tahminleri karşılaştırılmıştır. Makine öğrenmesinde Çok Katmanlı Öğrenme (MLP) ve Destek Vektör Makineleri (SVM), Derin öğrenme ise Tekrarlayan Sinir Ağları (RNN) ve Uzan Kısa Dönemli Öğrenme (LSTM) tercih edilmiştir. Sonuç olarak LSTM modeli hisse senetlerinin fiyat tahminlerinde karşılaştırılan modellere göre daha başarılı olduğu görünmüştür. Risk ve stratejik olarak daha başarılı sonuçlar elde edilmiştir (Arslankaya ve Toprak, 2021: s. 19).

Öztürk ve Tokat (2021) çalışmasında hisse senedi ve döviz kurları arasındaki bağlantıyı araştırmıştır. Yöntem olarak iki derin öğrenme yöntemini tercih edilmiştir. Birincisi doğrusal olmayan (NARX) yapay sinir ağlarından olan yöntem olup diğer yöntem ise LSTM modelidir. Veriler Borsa İstanbul'dan günlük hisse senedi fiyatı ve döviz kuru esas alınarak yapılmıştır. Döviz kuru olarak USD/TRY tercih edilmiştir. Tarih aralığı olarak 2002 Ocak ve 2021 Ocak gibi çok uzun süreli bir aralık tercih edilmiştir. Sonuçlar ise LSTM modelinin

diğer NARX modeline göre uzun vadede daha iyi sonuçlar verdiği sonuçlarla görülmüştür (Öztürk ve Tokat, 2021: s. 10).

Akbaşı (2022) çalışmasında yapay sinir ağıları ve regresyon modelleri üzerine bir karşılaştırma yapmıştır. Çalışmanın sonucunda regresyon ve yapay sinir ağlarının karşılaştırılmasında 3 adet değişken değerlendirilmiştir. İlki yüzdesel hata ikincisi karekök ortalama hata ve üçüncüsü belirlilik katsayısı gibi göstergelere bakılmıştır. Sonuç olarak yapay sinir ağlarının yaptığı tahminler daha doğrucu olduğu sonucuna ulaşılmıştır (Akbaşı, 2022: s. 95).

Gündoğdu (2023) çalışmasında değişkenler olarak Borsa İstanbul 30 endeksi, tüketici fiyat Endeksi, para arzı, altın ons fiyat, dolar kuru, euro kuru, mevduat faizi, finansal hizmetler güven endeksi, brent petrol gibi değişkenler tercih edilmiştir. Analizde Matlab (R2021b) programı kullanılmıştır. Ağ yapıları olarak 8-5-1, 8-7-1, 8-2-4-1, 8-10-1, 8-17-1, 8-5-8-1, 8-10-10-1, 8-14-1, 8-8-10-1 ağ yapıları seçilerek denemeler yapılmıştır. Sonuç olarak yapay sinir ağları Aralık 2022 kapanış değerlerini yüksek doğrulukla tahmin etmiştir (Gündoğdu, 2023: s. 98).

Erden (2023) çalışmasında derin öğrenme yöntemlerinden LSTM, GRU, RNN modelleri geleneksel modellemeye ise ARIMA kullanılmıştır. Performans ve doğruluk başarıları açısından bir sıralama yapılacak olduğunda ise RNN, GRU, LSTM ve ARIMA olarak belirlenmiştir (Erden, 2023: s. 421-433).

Sönmez ve Coşkun (2024) çalışmasında finansal piyasalarda fiyatların değişimini tahmin etmek için Long Short-Term Memory (LSTM) modelini incelemiştir. Sonuç olarak geleneksel modellere kıyasla LSTM modeli daha başarılı bir sonuç elde etmiştir (Sönmez ve Coşkun, 2024).

Polat (2024) çalışmasında Bitcoin'in geçmiş verileri ve piyasa göstergeleri kullanılarak gruplar oluşturmuştur. Sonuç olarak LSTM modelin Bitcoin fiyatının tahminindeki seçilen model etkin ve verimli bir şekilde çalıştığı tespit edilmiştir (Polat, 2024).

Aydın vd. (2024) çalışmasının temel amacı piyasalardaki hisse senetlerinin fiyatlarını tahmin etmektir. LSTM modelinde Borsa İstanbul 30 endeksindeki dört adet hisse seçilmiştir. Türk Hava Yolları, Akbank, Koç Holding, Kardemir Demir Çeliktir. Bu hisse senetlerin MAPE ve R^2 değerlerine bakılmıştır. Sonuç olarak LSTM modeli veriler arası karmaşık olan durumdan ARIMA modeline göre daha düşük hata oranlarıyla ve tahminci yeteneğiyle başarılı bir şekilde kullanmaktadır. Bu yeteneği sayesinde tercih edilebilirliği ve güvenilirliği yüksektir (Aydın vd., 2024).

Topakkaya (2024) çalışmasında zaman serisi için ARIMA, SARIMA, LSTM, RNN, TFT, ETS, VAR, GARCH, XGBoost, GBM gibi algoritmam teknikler kullanılmıştır. Sonuç olarak LSTM modelinin hisse senedinin gelecek için tahmin edilen yöntemlerde daha başarılı olduğu gözlenmiştir (Topakkaya, 2024).

Karakaşlı (2024) çalışmasında yöntem olarak LSTM ve derin öğrenme tabanlı modellemeler kullanmıştır. Performans ölçütleri doğruluk, kesinlik, duyarlılık, özgüllük, f-skoru, hata oranı, karışıklık matrisidir. Sonuç olarak LSTM modelinde yüksek doğruluk oranına sahip olduğu görülmüştür. Geleneksel öğrenme yöntemlerine göre LSTM'nin daha başarılı ve avantajlı olduğu tespit edilmiştir (Karakaşlı, 2024).

3.1.2. Uluslararası Literatür

Lawrence (1997) çalışmasında regresyon ve yapay sinir ağlarının karşılaştırıldığında regresyon modelinin daha uygun ve tahminlerinde doğrucu olduğu sonucuna ulaşmıştır (Lawrence, 1997; Sarıkaya, 2019).

Jao (2000) çalışmasında Black Scholes ve yapay sinir ağları modelinde karşılaştırmış ve sonuç olarak yapay sinir ağlarının daha iyi bir tahminci olduğu sonucuna ulaşmıştır (Jao, 2000; Aytekin, 2021).

Chen vd. (2003) çalışmasında geleneksel modellere kıyasla yapay sinir ağlarının daha iyi tahmin gücüne sahip olduğu sonucuna ulaşmıştır (Chen ve arkadaşları, 2003; Sarıkaya, 2019). Fernandez ve Gomez (2005) çalışmasında yapay sinir ağlarının daha güvenilir ve iyi tahminde bulunduğu sonucuna ulaşmıştır (Fernandez ve Gomez, 2005; Aytekin, 2021).

Zhang ve Wu (2009) çalışmasında geri yayımlı modeli yapay sinir ağları kullanılarak tahmin etmiştir. Çalışmada 2005 ve 2008 yılları arası S&P 500 endeksinin kapanış fiyatları esas alınmıştır. Modelde kısa vadeli 1 günlük uzun vadeli ise 15 günlük tahminler yapmıştır. Ortalama kare hatası (MSE) ve Ortalama mutlak yüzde hata (MAPE) gibi ölçütlerin sonuçlarından yararlanılmıştır. Çalışmanın sonucunda yapay sinir ağlarının hisse senedi gibi karmaşık ve doğrusal olmayan modellerde tahmin gücünün oldukça yüksek olduğu bulunmuştur (Zhang ve Wu, 2009; Aytekin, 2021).

Fischer ve Krauss (2018) çalışmasında 1992-2005 dönemli içim S&P 500 endeksinde yer alan hisse senetlerinin günlük fiyatları kullanılmıştır. RAF, DNN, LOG gibi geleneksel olarak kabul edilen modellerle karşılaştırma yapılmıştır. Çalışmanın sonucunda 2010 yılından sonra gerçekleşen işlemlerin maliyetleri nedeniyle LTSM modeliyle elde edilen karlılığın sıfır değerine kadar yaklaştığı tespit edilmiştir (Fischer ve Krauss, 2018: 654-669; Alpay, 2020).

Cheng, Huang ve Wu (2018) çalışmasında dikkat mekanizmalı LSTM modelinin, geleneksel LSTM modellerine kıyasla daha iyi bir performans ve yüksek tahmin yeteneğine sahip olduğu görülmüştür (Cheng vd., 2018; Alpay, 2020).

Mehtab, Sen, Dutta (2020) çalışmasında girdi değişkenleri açılış, kapanış fiyatlar ve işlem hacimleri gibi değişkenler kullanmıştır. Çalışmanın sonucunda, LSTM modelinin kısa vadeli tahminlerde diğer makine öğrenme yöntemlerine kıyasla daha düşük hata oranı gösterdiği ve bu nedenle yüksek performans ile güçlü bir tahmin yeteneğine sahip olduğu sonucuna varılmıştır (Mehtab vd., 2020).

Huang, You, Gao ve Cheng (2023) çalışmasında ARIMA modelinde trendler belirlenmiş olup daha sonrasında ise GARCH modeliyle de fiyatlar üzerinde yapılan değişikliklerin tahminleri yapılmıştır. Çalışmanın sonucunda LSTM modelinin doğruluk ve tahmin yeteneğinin diğer modellere göre daha başarılı olduğu tespit edilmiştir (Huang vd., 2023).

3.2. Veri Yapısı ve Yöntem

Bu çalışmada, Borsa İstanbul 30 (BIST 30) endeksine ait günlük kapanış verileri Yahoo Finance platformundan elde edilmiştir. Veri seti, XU030.IS, ^XU030 ve ISY30.IS sembollerinden elde edilen seriler üzerinden oluşturulmuş ve 5 Ocak 1997 – 6 Eylül 2025 dönemini kapsamaktadır. Çalışmanın temel amacı, bir gün ileriye dönük logaritmik getiri tahmini yapmaktır. Fiyat seviyesinde doğrudan bir değerlendirme yapılmamış, fiyat grafikleri yalnızca görsel referans amacıyla sunulmuştur. Modelleme sürecinde kullanılan özellikler kapanış fiyatı (Close), logaritmik getiri (logret), 5 ve 20 günlük hareketli ortalamalar (MA5, MA20), 14 günlük Göreceli Güç Endeksi (RSI14) ve 20 günlük volatilité (Vol20) olarak belirlenmiştir. Veri seti eğitim (%70), doğrulama (%15) ve test (%15) olmak üzere üçe ayrılmıştır.


Girdi değişkenleri için StandardScaler, hedef değişken için ise yalnızca eğitim verisine fit edilen MinMaxScaler kullanılmıştır. Tahmin modeli, LSTM(128) → Dropout(0.30) → LSTM(64) → Dense(32, relu) → Dense(1) mimarisi ile oluşturulmuş; optimizasyon için Adam (1e-3) algoritması, kayıp fonksiyonu olarak ise MSE kullanılmıştır.

Eğitim sürecinde aşırı uyumu önlemek için EarlyStopping ve ReduceLROnPlateau yöntemleri uygulanmıştır. Model performansı log getiri uzayında RMSE, MAE ve yön isabeti metrikleriyle değerlendirilmiş; ayrıca persistence yöntemi temel alınarak karşılaştırma yapılmıştır. Bulgular, çok değişkenli LSTM modelinin tek değişkenli yaklaşıma kıyasla yön tahmininde daha yüksek isabet oranı sağladığını göstermektedir. Fiyat seviyesindeki

sapmaların, getirilerin kümülatif toplanarak fiyat seviyesine dönüştürülmesinden kaynaklandığı gözlemlenmiştir. Model, makroekonomik haber akışları, yapısal kırımlar ve rejim değişiklikleri gibi faktörleri içermediğinden bu unsurlar çalışmanın kapsamı dışında kalmaktadır.

3.2.1. Yöntem

Bu bölümde kullanacak olduğumuz yöntem LSTM yöntemi yani uzun – kısa süreli bellektir. Kısaca kullanılacak yöntemin özellikleri şöyledir:



Şekil 3.1 LSTM Hücre Yapısı Ve Kapıları

Şekil LSTM' nin genel işleyiş yapısını anlatmaktadır. Fonksiyon olarak Sigmoid aktivasyon kullanılır ve 0 ile 1 arasında bir değer üretilir. 1 de bilgi silinmez 0 ise silinir demektir (Çolak,2025:8). Matematiksel gösterimi aşağıda yer almaktadır:

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f)$$

Giriş kapısının görevi, hücre durumuna eklenecek yeni bilgilerin miktarını belirlemektir. Bu kapı iki aşamalı olarak çalışır: ilk aşamada, sigmoid fonksiyonu aracılığıyla hangi bilgilere ne ölçüde izin verileceğine karar verilir; ikinci aşamada ise, tanh fonksiyonu yardımıyla yeni aday değerler oluşturulur. Bu işlemin matematiksel gösterimi aşağıdaki formülde sunulmuştur:

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i)$$

$$\tilde{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c)$$

Unutma kapısının geçmiş verileri silmesi ve giriş kapısının yeni bilgileri eklemesiyle birlikte hücre durumu güncellenmiş olur. Bu sayede ağ, hangi bilgilerin korunacağına ve

hangilerinin unutulacağına karar vererek öğrenme sürecini optimize eder. Bu işlemin matematiksel gösterimi aşağıdaki formülde verilmiştir:

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t$$

Son olarak, çıkış kapısının görevi hücre durumundaki bilgilerin hangi kısmının çıktı olarak aktarılacağını belirlemektir. Bu işlemde, sigmoid fonksiyonu aracılığıyla hangi bilgilerin çıkışa iletileceğine karar verilir; ardından tanh fonksiyonu ile bu bilgiler ölçeklendirilerek çıktı katmanına aktarılır. Bu sürecin matematiksel gösterimi aşağıdaki formülde sunulmuştur:

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o)$$

$$h_t = o_t * \tanh(C_t)$$

Çıkışlar arasında yer alan **ht**, gizli (hidden) durum değerini ifade ederken; **ct**, hücrenin güncellenmiş son durumunu temsil etmektedir (Sönmez ve Arslan, 2024, ss. 48–61).

3.3. Bulgular

Çalışmamızın bulgularına geçmeden önce, kodlama sürecinin adım adım açıklanması faydalı olacaktır.

Adım 1: Ortam ve kurulum

Bu adım, tekrar üretilebilirliği sağlamak amacıyla gerekli paketlerin kurulmasını ve rastgelelik kaynaklarının sabitlenmesini kapsamaktadır.

```
# Ortam kurulumu (Colab için güvenli)
```

```
!pip -q install yfinance numpy pandas scikit-learn tensorflow matplotlib
```

```
import os, sys, warnings
```

```
import numpy as np
```

```
import pandas as pd
```

```
import matplotlib.pyplot as plt
```

```
from sklearn.preprocessing import StandardScaler, MinMaxScaler
from sklearn.metrics import mean_absolute_error, mean_squared_error
```

```
import tensorflow as tf
from tensorflow import keras
from tensorflow.keras import layers
```

```
# Tekrarlanabilirlik
np.random.seed(42)
tf.random.set_seed(42)
```

```
print("Python:", sys.version.split()[0])
print("TensorFlow:", tf.__version__)
```

Adım 2: Veri Toplama (Yahoo Finance) ve temel temizlik

BIST 30 endeksi günlük kapanış verisini almak için Yahoo veri tabanı kullanılmıştır, Yahoo da bazı semboller farklı güncellikte olabileceğinden ötürü **fallback** stratejisi tercih edilmiştir.

```
import yfinance as yf
```

Güncel veri için sırayla denenecek semboller:

```
CANDIDATES = ["XU030.IS", "^XU030", "ISY30.IS"] # Endeks ve onu izleyen ETF
(proxy)
```

```
def fetch_first_ok(symbols):
```

```
    """
```

```
    Sembolleri gezip en geniş kapsamlı/güncel olanı döndürür.
```

```
    Dönüş: (symbol_name, raw_df)
```

```
    """
```

```
    best = None
```

```
    for s in symbols:
```

```
        try:
```

```
            df_ = yf.Ticker(s).history(period="max", interval="1d", auto_adjust=False)
```

```
            if df_ is not None and len(df_) > 0:
```

```

df_ = df_.dropna()
if best is None or df_.index.max() > best[1].index.max():
    best = (s, df_)
except Exception as e:
    warnings.warn(f'{s} çekilemedi: {e}')
if best is None:
    raise RuntimeError("Yahoo'dan veri alınamadı.")
return best

symbol, raw = fetch_first_ok(CANDIDATES)

# Zaman dilimi: Europe/Istanbul'a çevir
if not raw.index.tz:
    raw.index = raw.index.tz_localize("UTC")
raw.index = raw.index.tz_convert("Europe/Istanbul")

# Kapanış serisi
close = raw[["Close"]].rename(columns={"Close": "Close_BIST30"}).dropna()

print("Seçilen sembol:", symbol)
print("Gözlem sayısı:", len(close))
print("İlk tarih:", close.index.min(), "→ Son tarih:", close.index.max())

# Hızlı görsel
plt.figure(figsize=(12,4))
plt.plot(close.index, close["Close_BIST30"])
plt.title("BIST 30 Günlük Kapanış (Yahoo Finance)")
plt.xlabel("Tarih (Europe/Istanbul)")
plt.ylabel("Kapanış")
plt.grid(True); plt.show()

```

Adım 3: Özellik Mühendisliği (MA, RSI, volatilité) ve Hedef Tanımı

Öncelikle yalnızca fiyat verileriyle tahminleme yapılmış, ancak başarı sağlanamayınca logaritmik verilerle yeniden denemeler gerçekleştirilmiştir. Son aşamada ise model, teknik

göstergeler (MA5, MA20, RSI14, volatilité) ile beslenmiştir. Hedef değişken olarak, bir gün sonrası log getirisi kullanılmıştır.

Log getiri ve teknik göstergeler

def rsi(series: pd.Series, period: int = 14) -> pd.Series:

delta = series.diff()

up = delta.clip(lower=0)

down = (-delta).clip(lower=0)

up_ema = up.ewm(alpha=1/period, adjust=False, min_periods=period).mean()

down_ema = down.ewm(alpha=1/period, adjust=False, min_periods=period).mean()

rs = up_ema / (down_ema + 1e-12)

return 100 - (100 / (1 + rs))

px = close["Close_BIST30"].astype(float)

logret = np.log(px / px.shift(1))

feat = pd.DataFrame(index=px.index)

feat["Close"] = px

feat["logret"] = logret

feat["MA5"] = px.rolling(5, min_periods=5).mean()

feat["MA20"] = px.rolling(20, min_periods=20).mean()

feat["RSI14"] = rsi(px, 14)

feat["Vol20"] = logret.rolling(20, min_periods=20).std()

Hedef: 1 gün sonrası log getiri

feat["target_logret_t+1"] = feat["logret"].shift(-1)

Başlangıç ve son kısımlardaki zorunlu NaN'ları at

LOOKBACK = 60

HORIZON = 1

WARMUP = max(LOOKBACK, 20)

feat = feat.iloc[WARMUP:].copy() # ısınma

feat = feat.iloc[:-HORIZON].copy() # hedefteki shift nedeniyle sondan kırp

feat = feat.dropna()

```
print("Özellik seti boyutu:", feat.shape)
feat.tail(3)
```

Adım 4: Train/Val/Test Bölme, Ölçekleme ve Sekans Oluşturma

Bu adımın amacı, zaman serisini kaydırmalı pencereler (lookback=60) kullanarak LSTM'e uygun 3B tensörlere (num_seq, 60, num_features) dönüştürmektir.

```
# Giriş özellikleri (multivariate)
feature_cols = ["Close", "logret", "MA5", "MA20", "RSI14", "Vol20"]

X_all = feat[feature_cols].values
y_all = feat["target_logret_t+1"].values.reshape(-1,1)

n = len(feat)
assert n > LOOKBACK + HORIZON + 10, f"Özellik seti çok kısa: n={n}"

# 70/15/15 bölme
train_size = int(n*0.70)
val_size = int(n*0.15)
test_size = n - train_size - val_size
X_train = X_all[:train_size]
X_val = X_all[train_size:train_size+val_size]
X_test = X_all[train_size+val_size:]

y_train = y_all[:train_size]
y_val = y_all[train_size:train_size+val_size]
y_test = y_all[train_size+val_size:]

# Ölçekleyiciler: girdiler StandardScaler, hedef MinMax
x_scaler = StandardScaler()
X_train_s = x_scaler.fit_transform(X_train)
X_val_s = x_scaler.transform(X_val)
X_test_s = x_scaler.transform(X_test)
y_scaler = MinMaxScaler()
```

```

y_train_s = y_scaler.fit_transform(y_train)
y_val_s = y_scaler.transform(y_val)
y_test_s = y_scaler.transform(y_test)

def make_seq(X_scaled, y_scaled, lookback=60, horizon=1):
    Xs, ys = [], []
    for i in range(lookback, len(X_scaled) - horizon + 1):
        Xs.append(X_scaled[i-lookback:i, :])
        ys.append(y_scaled[i+horizon-1, 0])
    return np.array(Xs), np.array(ys).reshape(-1,1)

Xtr_seq, ytr_seq = make_seq(X_train_s, y_train_s, LOOKBACK, HORIZON)
Xva_seq, yva_seq = make_seq(X_val_s, y_val_s, LOOKBACK, HORIZON)
Xte_seq, yte_seq = make_seq(X_test_s, y_test_s, LOOKBACK, HORIZON)

print("Sekans şekilleri →",
      "Xtr:", Xtr_seq.shape, "| Xva:", Xva_seq.shape, "| Xte:", Xte_seq.shape)
print("Özellik sayısı:", Xtr_seq.shape[-1])

```

Adım 5: LSTM Mimarisi Ve Eğitim

Bu adımda ise çok değişkenli LSTM modeliyle bir gün ileriye yönelik log getiri tahmini yapılmış olup, aşırı uyumu sınırlamak için Dropout ve erken durdurma teknikleri kullanılmıştır.

```

Tf.random.set_seed(42)

model = keras.Sequential([
    layers.Input(shape=(LOOKBACK, Xtr_seq.shape[-1])),
    layers.LSTM(128, return_sequences=True),
    layers.Dropout(0.30),
    layers.LSTM(64),
    layers.Dense(32, activation="relu"),
    layers.Dense(1) # tek adım log getiri])

model.compile(optimizer=keras.optimizers.Adam(1e-3),

```

```

        loss="mse", metrics=["mae"])
model.summary()

callbacks = [
    keras.callbacks.EarlyStopping(monitor="val_loss",
                                   patience=10,
                                   restore_best_weights=True),
    keras.callbacks.ReduceLROnPlateau(monitor="val_loss",
                                       factor=0.5,
                                       patience=5,
                                       min_lr=1e-6, verbose=1),
    keras.callbacks.ModelCheckpoint("/content/best_lstm.keras",
                                    monitor="val_loss", save_best_only=True, verbose=1)]

history = model.fit(
    Xtr_seq, ytr_seq,
    validation_data=(Xva_seq, yva_seq),
    epochs=120,
    batch_size=64,
    verbose=1,
    callbacks=callbacks)

# Eğitim eğrisi
plt.figure(figsize=(9,4))
plt.plot(history.history["loss"], label="train")
plt.plot(history.history["val_loss"], label="val")
plt.title("Eğitim Geçmişi (MSE – Çok Değişkenli LSTM)")
plt.xlabel("Epoch"); plt.ylabel("Loss"); plt.grid(True); plt.legend(); plt.show()

```

Adım 6 : Değerlendirme (log getiri uzayı) ve kıyas (baseline)

Bu adımın amacı, test setinde RMSE ve MAE (log getiri) metrikleri ile yön isabeti (sign equality) ölçütünü raporlamaktır. Karşılaştırma amacıyla persistence modeli ($y_t \approx y_{t-1}$) temel alınmıştır.

```

Def inv_y(y_s): # hedefi ölçekten çıkar
    return y_scaler.inverse_transform(y_s.reshape(-1,1)).ravel()

```

```

# Tahminler (train/val/test)

```

```

p_tr = inv_y(model.predict(Xtr_seq, verbose=0)); y_tr = inv_y(ytr_seq)
p_va = inv_y(model.predict(Xva_seq, verbose=0)); y_va = inv_y(yva_seq)
p_te = inv_y(model.predict(Xte_seq, verbose=0)); y_te = inv_y(yte_seq)

def report(name, y, p):
    rmse = np.sqrt(mean_squared_error(y, p)) # squared=False kullanmıyoruz
    mae = mean_absolute_error(y, p)
    print(f'{name:>6} | RMSE: {rmse:.6f} | MAE: {mae:.6f}')

def direction_acc(y, p):
    return (np.sign(y) == np.sign(p)).mean() * 100
report("Train", y_tr, p_tr)
report("Valid", y_va, p_va)
report("Test", y_te, p_te)
print(f'Yön isabeti (Train): {direction_acc(y_tr,p_tr):.2f}%')
print(f'Yön isabeti (Valid): {direction_acc(y_va,p_va):.2f}%')
print(f'Yön isabeti (Test): {direction_acc(y_te,p_te):.2f}%')

# Baseline: persistence (dünkü getiriyi yarına tahmin et)
base_y = y_te[:-1]
base_hat = y_te[1:]
base_rmse = np.sqrt(mean_squared_error(base_y, base_hat))
base_dir = direction_acc(base_y, base_hat)
print(f'Baseline (persistence) RMSE: {base_rmse:.6f} | Yön isabeti: {base_dir:.2f}%')

```

Adım 7: Test Dönemi

Tahmin edilen günlük log getiriler, yalnızca görsel bir referans sağlamak amacıyla kümülatif olarak toplanarak fiyat seviyesine dönüştürülmüştür.

```

# Test zaman eksenini
idx_start = int(len(feats)*0.70) + int(len(feats)*0.15)
n_pred = len(p_te)
dates_te = feats.index[idx_start + LOOKBACK + HORIZON - 1 :
                        idx_start + LOOKBACK + HORIZON - 1 + n_pred]

```

```

# Başlangıç fiyatı: ilk tahmin gününden bir iş günü önceki gerçek kapanış
p0_date = dates_te[0] - pd.tseries.offsets.BDay(1)
p0 = close["Close_BIST30"].asof(p0_date)

# Fiyat patikası:  $P_t = P_0 * \exp(\text{cumsum}(r_{\text{hat}}))$ 
price_hat = p0 * np.exp(np.cumsum(p_te))

# Karşılaştırma için gerçek fiyat
px_true = close["Close_BIST30"].reindex(dates_te, method="pad")

plt.figure(figsize=(12,5))
plt.plot(dates_te, px_true.values, label="Gerçek (Test)")
plt.plot(dates_te, price_hat, label="Tahmin (Getiriden)")
plt.title("Test Dönemi: Fiyat (Log Getiri Modelinden Türetilen)")
plt.xlabel("Tarih"); plt.ylabel("Kapanış"); plt.grid(True); plt.legend(); plt.show()

```

Adım 8: Kısa Vadeli İleri (5 iş günü) Tahmin

Bu adımda Son pencereye dayanarak 5 iş günü için log getiri tahmini ve fiyat projeksiyonu yapılmıştır.

sdfs

N_FUTURE = 5

last_price = close["Close_BIST30"].iloc[-1]

Son LOOKBACK pencereyi (özellik uzayında) al ve ölçekle

win = feat[feature_cols].iloc[-LOOKBACK:].values

win_s = x_scaler.transform(win).reshape(1, LOOKBACK, -1)

future_scaled = []

for _ in range(N_FUTURE):

 nxt = model.predict(win_s, verbose=0)[0,0] # ölçekli log getiri

 future_scaled.append(nxt)

 # pencereyi kaydır: son satırı tekrar kullan

 win_s = np.append(win_s[:,1:,:], win_s[:,-1,:], axis=1)

```

# logret kanalını ileri değerle güncelle (varsa)
try:
    logret_idx = feature_cols.index("logret")
    win_s[0,-1,logret_idx] = nxt
except ValueError:
    pass

# Ölçekten çıkar ve fiyat projeksiyonu
future_logret = y_scaler.inverse_transform(np.array(future_scaled).reshape(-1,1)).ravel()
future_prices = last_price * np.exp(np.cumsum(future_logret))
future_dates = pd.bdate_range(close.index[-1] + pd.offsets.BDay(1),
                               periods=N_FUTURE, tz=close.index.tz)

future_df = pd.DataFrame({"Pred_LogRet": future_logret,
                          "Pred_Close": future_prices}, index=future_dates)
print("5 İş Günü İleri Tahmin:")
print(future_df)

# Görsel
plt.figure(figsize=(12,5))
tail_n = 200
plt.plot(close.index[-tail_n:], close["Close_BIST30"].iloc[-tail_n:], label="Son Kapanışlar")
plt.plot(future_df.index, future_df["Pred_Close"], marker="o", label="İleri Tahmin")
plt.title("Son 200 Gün + 5 Günlük İleri Tahmin (Çok Değişkenli LSTM)")
plt.xlabel("Tarih"); plt.ylabel("Kapanış"); plt.grid(True); plt.legend(); plt.show()

```

Adım 9: Çıktıları Kaydetme

```

feat.to_csv("/content/feat_table.csv", index_label="Date")
pd.DataFrame({"Date": close.index, "Close_BIST30":
close["Close_BIST30"].values}).to_csv(
    "/content/bist30_close.csv", index=False)
model.save("/content/best_lstm_final.keras")
print("Kaydedildi:")
print(" - /content/feat_table.csv")

```

```
print(" - /content/bist30_close.csv")
print(" - /content/best_lstm_final.keras")
```

Modelde kullanılan değişkenler aşağıda sunulmuştur:

- **Close:** Günlük kapanış fiyatı
- **logret:** Günlük logaritmik getiri ($\ln(P_t/P_{t-1})$)
- **MA5:** 5 günlük hareketli ortalama
- **MA20:** 20 günlük hareketli ortalama
- **RSI14:** 14 günlük Göreceli Güç Endeksi
- **Vol20:** 20 günlük getirilerin standart sapması


Veri seti eğitim (%70), doğrulama (%15) ve test (%15) olmak üzere üçe ayrılmıştır. Girdi değişkenleri için **StandardScaler**, hedef değişken için ise yalnızca eğitim verisine fit edilen **MinMaxScaler** kullanılmıştır.

Model, LSTM tabanlı çok değişkenli bir zaman serisi tahmin ağıdır. Modelin mimarisi aşağıda özetlenmiştir:

Tablo 3.1: LSTM Tabanlı Çok Değişkenli Zaman Serisi Modeli Yapısı

Katman	Boyut	Aktivasyon	Notlar
LSTM	128	–	return_sequences=True
Dropout	0.30	–	Aşırı uyumu azaltmak
LSTM	64	–	
Dense	32	ReLU	Tam bağlantılı katman
Dense	1	Linear	Çıkış (log getiri)

Aşağıdaki grafikte, epoch'lar boyunca eğitim ve doğrulama kaybındaki azalma görülmektedir. Doğrulama kaybının kararlı bir seyir izlemesi, modelin aşırı uyum (overfitting) göstermediğini ortaya koymaktadır.




Şekil 3.2 Eğitim Geçmişi Boyunca MSE Kayıplarının İzlenmesi

Modelin performansı log getiri uzayında RMSE, MAE ve yön isabeti metrikleri ile ölçülmüştür. Ayrıca persistence ($y_t \approx y_{t-1}$) yöntemi temel alınarak karşılaştırma yapılmıştır.

Tablo 3.2 Model Performansı (Log Getiri Uzayı)

Veri Seti	RMSE	MAE	Yön İsbeti (%)
Train	0.025537	0.017772	51.08
Valid	0.014736	0.010773	50.15
Test	0.025136	0.019389	45.62
Baseline (Persistence)	0.027842	0.020441	53.14

Aşağıdaki grafikte, son 200 günlük fiyat hareketi ve modelin 5 iş günü için ürettiği tahminler gösterilmektedir:



Şekil 3.3 LSTM Modeli Kullanılarak Son 200 Günlük Fiyat Ve 5 Günlük İleri Tahmin

Model, doğrulama setinde düşük hata değerleri üretmiş; test setinde yön tahmini performansı sınırlı kalsa da log getiri tahminlerinde tutarlı sonuçlar elde edilmiştir. Fiyat seviyesindeki sapmaların, getirilerin kümülatif toplanarak fiyat seviyesine dönüştürülmesinden kaynaklandığı gözlenmiştir. Model makroekonomik haber akışları, yapısal kırılmalar ve rejim değişiklikleri gibi dışsal faktörleri içermediğinden, bu unsurlar çalışmanın kapsamı dışında bırakılmıştır.

SONUÇ

Bu tez çalışması, finansal piyasalarda yapay zekâ tabanlı yöntemlerin uygulanabilirliğini incelemek ve söz konusu yöntemlerin tahmin performansını değerlendirmek amacıyla gerçekleştirilmiştir. Çalışmanın motivasyonu, küresel düzeyde hızlanan dijitalleşme süreci ve finansal piyasalarda artan veri hacmi karşısında, geleneksel tahmin yöntemlerinin yetersiz kalmaya başlamasıdır. Özellikle piyasa dinamiklerinin yüksek volatilité ve karmaşıklık içerdiği ortamlarda daha isabetli ve esnek tahminler üretebilecek yapay zekâ modellerine duyulan ihtiyaç giderek artmaktadır. Bu bağlamda, tez kapsamında Borsa İstanbul 30 (BIST 30) endeksine ait günlük kapanış fiyatları kullanılarak LSTM tabanlı derin öğrenme modelinin performansı değerlendirilmiş ve modelin finansal tahmin süreçlerindeki etkinliği ortaya konmuştur.

Çalışma kapsamında kullanılan veri seti Yahoo Finance platformundan elde edilmiş olup 5 Ocak 1997 – 6 Eylül 2025 tarihleri arasındaki dönemi kapsamaktadır. Kodlama süreci Google Colab ortamında Python dili kullanılarak gerçekleştirilmiş, veri işleme ve modelleme adımlarında pandas, numpy, scikit-learn, TensorFlow ve Keras gibi açık kaynak kütüphanelerden yararlanılmıştır. Özellik mühendisliği aşamasında logaritmik getiriler, kısa ve uzun dönem hareketli ortalamalar (MA5, MA20), göreceli güç endeksi (RSI14) ve volatilité göstergeleri oluşturularak modelin daha kapsamlı bir veri yapısına dayanması sağlanmıştır. Veriler % 70 eğitim, % 15 doğrulama ve % 15 test olmak üzere üçe ayrılmış, giriş değişkenleri için StandardScaler, hedef değişken için yalnızca eğitim setinde fit edilen MinMaxScaler kullanılmıştır. Model, LSTM(128) → Dropout(0.30) → LSTM(64) → Dense(32, ReLU) → Dense(1) mimarisiyle yapılandırılmış ve optimizasyon sürecinde Adam (1e-3) algoritması ile MSE kayıp fonksiyonu tercih edilmiştir. Eğitim sırasında EarlyStopping ve ReduceLROnPlateau stratejileri uygulanarak modelin aşırı uyuma düşmesi engellenmiştir.

Modelin log getiri tahminlerindeki performansı RMSE, MAE ve yön isabeti metrikleri ile ölçülmüş ve persistence ($y_t \approx y_{t-1}$) yöntemi ile karşılaştırılmıştır. Bulgular, modelin log getiri uzayında düşük hata oranları elde ettiğini ve trend yönü tahminlerinde rekabetçi bir performans sergilediğini göstermektedir. Fiyat seviyesindeki sapmaların, getirilerin kümülatif toplanarak fiyat seviyesine dönüştürülmesinin doğal bir sonucu olduğu görülmüştür. Doğrulama setinde kayıpların kararlı seyretmesi, modelin aşırı uyum göstermediğini doğrulamaktadır. Bu sonuçlar, LSTM tabanlı modellerin geleneksel yöntemlerin ötesinde daha sofistike bir piyasa tahmin aracı olarak değerlendirilebileceğine işaret etmektedir.

Bu çalışma, finansal piyasalarda veri bilimi ve yapay zekâ tabanlı sistemlerin entegrasyonunun önemine dikkat çekmektedir. Özellikle büyük veri analitiği, makine öğrenmesi ve derin öğrenme gibi yöntemlerin finansal karar destek süreçlerine dahil edilmesi; piyasa risklerinin daha etkin yönetilmesine, yatırım stratejilerinin iyileştirilmesine ve portföy optimizasyonu süreçlerinin geliştirilmesine katkı sunabilir. Bu çerçevede finansal kurumların, geleneksel risk ölçüm yaklaşımlarını yapay zekâ destekli tahmin modelleriyle zenginleştirmeleri stratejik bir gereklilik hâline gelmektedir.

Regülasyon ve denetim otoriteleri açısından bakıldığında, algoritmik ticaret ve yapay zekâ tabanlı uygulamaların giderek artan kullanımı, veri şeffaflığı, etik standartlar, model güvenilirliği ve sistemik risk yönetimi alanlarında yeni düzenlemeleri gerekli kılmaktadır. Özellikle kara kutu niteliği taşıyan derin öğrenme modellerinde şeffaflık ve açıklanabilirlik (explainable AI) unsurlarının ön plana çıkarılması, piyasa güvenilirliği açısından kritik önem taşımaktadır. Ayrıca düzenleyici çerçevenin, inovasyonu teşvik eden fakat yatırımcı haklarını da gözetten dengeli bir yapıda tasarlanması gerekmektedir.

Bireysel yatırımcılar açısından ise, bu teknolojilerin doğru ve bilinçli biçimde kullanılabilmesi için finansal okuryazarlığın ve yapay zekâ farkındalığının artırılması önem arz etmektedir. Eğitim programları, sertifika süreçleri ve dijital yatırım platformları üzerinden sağlanacak bilgi desteği, yatırımcıların yapay zekâ tabanlı modelleri daha etkin değerlendirmelerine yardımcı olabilir. Bu sayede yapay zekâ destekli sistemlerin sunduğu potansiyel, yalnızca bireysel kazanç artışına değil, aynı zamanda piyasa istikrarının güçlendirilmesine de katkı sağlayacak şekilde kullanılabilir.

Gelecek çalışmalar, bu araştırmanın bulgularını daha geniş bir perspektiften ele almak amacıyla veri setinin kapsamını genişletmeyi içerebilir. Özellikle makroekonomik göstergelerin, haber akışlarının, sektörel verilerin ve alternatif finansal araçlara ilişkin zaman serilerinin modele dahil edilmesi, finansal piyasalardaki dinamiklerin daha bütüncül bir şekilde analiz edilmesine katkı sağlayacaktır. Bu tür genişletilmiş veri entegrasyonları, yalnızca kısa vadeli fiyat hareketlerini değil, aynı zamanda piyasalardaki yapısal eğilimleri ve yatırımcı duyarlılığını da yakalama imkânı sunabilir.

Yöntemsel açıdan bakıldığında, Transformer tabanlı mimariler, GRU ve 1D-CNN gibi farklı derin öğrenme yaklaşımlarının LSTM ile karşılaştırmalı performans analizlerinin yapılması, model seçimi konusunda daha güçlü çıkarımlar elde edilmesine olanak sağlayacaktır. Ayrıca hiperparametre optimizasyon tekniklerinin (Optuna, Keras Tuner vb.) sistematik olarak uygulanması, tahmin doğruluğunun artırılmasına ve modelin daha istikrarlı sonuçlar üretmesine katkıda bulunabilir.

Bunun yanında, çalışmanın farklı piyasa rejimleri altında test edilmesi de önemli bir araştırma alanı olarak öne çıkmaktadır. Özellikle kriz dönemleri, ani volatilité şokları veya yüksek oynaklık içeren piyasa koşulları gibi senaryolarda modelin dayanıklılığının ölçülmesi, hem akademik literatüre hem de uygulamaya değerli katkılar sağlayacaktır. Böylelikle, geliştirilen yapay zekâ tabanlı tahmin modelleri yalnızca normal koşullarda değil, aynı zamanda stresli piyasa ortamlarında da etkinliklerini kanıtlama fırsatı bulacaktır.



KAYNAKÇA

- Abacı, B. (2024). *Hanehalkı Yoksulluk Düzeyinin Makine Öğrenmesi Ve Yapay Sinir Ağları İle Tahmini: Türkiye Örneği*. Konya: Yüksek Lisans Tezi. Necmettin Erbakan Üniversitesi Sosyal Bilimler Enstitüsü Maliye Anabilim Dalı.
- Acar, O. (2020). Yapay zekâ fırsat mı yoksa tehdit mi? *Kriter Yayınevi*. içinde İstanbul.
- Ahmet İlker A., Ç. G. (2021). “Bankacılık Hizmetlerinde Yapay Zekâ Kullanımı ” . *Erzurum teknik üniversitesi , Journal of Academic Value Studies dergisi*, 7(3), 298-315.
- Akalın, B. v. (2021). “Sağlık Hizmetleri ve Yönetiminde Yapay Zekâ”. *Acta Infologica*, 5(1), 231-240.
- Akay, E. S. (2020). “Makine öğrenmesi ve ekonomi: Bibliyometrik analiz”. *Marmara Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 42(2), 1-6.
- Akbaş, M. (2022). Yapay Sinir Ağları Tahminleme Modeli ile Hisse Senedi Fiyat Endeksi Tahminlemesi Üzerine Bir Çalışma . *Antalya Bilim Üniversitesi Uluslararası Sosyal Bilimler Dergisi* , 97-110.
- Akkaya, G. (2007). “Yapay Sinir Ağları ve Tarım Alanındaki Uygulamaları”. *Atatürk Üniversitesi Ziraat Fakültesi Dergisi*, 38(2), 195-202.
- Akyel, S. v. (2012). “ k-En Yakın Komşuluk Algoritmasının Hile Denetiminde Kullanımı”. *Sakarya Üniversitesi Geyve MYO ve Yıldırım Beyazıt Üniversitesi. Muhasebe ve Vergi Uygulamaları Dergisi*, 5(1), 21-40.
- Albayrak, A. V. (2009). “Veri Madenciliği: Karar ağacı Algoritmaları Ve İMKB Verileri Üzerine Bir Uygulama”. *Süleyman Demirel Üniversitesi İktisadi Ve İdari Bilimler Fakültesi Dergisi*, 14(1), 31-52.
- Anderson, B. (2007). *Hayali Cemaatler: Milliyetçiliğin Kökeni ve Yayılması*. (İ. Savaşır, Çev.) İstanbul: Metis Yayınları.
- Arslan, K. (tarih yok). “Eğitimde Yapay Zekâ ve Uygulamaları”. *Batı Anadolu Eğitim Bilimleri Dergisi*, 11(1), 71-88.
- Arslankaya, S. V. (2021). Makine Öğrenmesi ve Derin Öğrenme Algoritmalarını Kullanarak Hisse Senedi Fiyat Tahmini. *Uluslararası Mühendislik Araştırma ve Geliştirme Dergisi*, 13(1), 178-192.
- Artut, K. .. (2019). “Yapay Zekâ Olgusunun Güncel Sanat Çalışmalarındaki Açılımları”. *İnsan ve İnsan Dergisi*, 6(22), 767-783.
- Aydın, Y. ., (tarih yok). “Hisse Senedi Fiyatlarının LSTM Ve ARIMA Modelleri Kullanılarak Tahmin Edilmesi ”. *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, 36(2), 903-911.

- Aytekin, Ç. (2019). “Yapay Zekâ ve Uygulama Alanları”. *İstanbul Üniversitesi Bilgisayar Bilimleri Dergisi*, 12(2), 45-58.
- Baghdadı, B. (2023). *Yapay Zekâ Modelleri Ve Borsa İstanbul Endeks Verileriyle Uygulama*. İstanbul: Yüksek Lisans Tezi. Marmara Üniversitesi Bankacılık Ve Sigortacılık Enstitüsü.
- Balcı, A. (2020). *Lojistik Sektörünün Uluslararası Alanda Dijitalleşme Süreci ve Türkiye’ye Etkileri*. İstanbul: Yüksek Lisans Tezi. Marmara Üniversitesi Sosyal Bilimler Enstitüsü, Uluslararası Ticaret ve Para Yönetimi.
- Baş, N. (2006). *Yapay Sinir Ağları Yaklaşımı Ve Bir Uygulama*. İstanbul: Yüksek Lisans Tezi. Mimar Sinan Güzel Sanatlar Üniversitesi Fen Bilimleri Enstitüsü İstatistik Anabilim Dalı.
- Baumann, T. (2004). Defining Ethnicity. *The SAA Archaeological Record*, 4(4), 12-14.
- Borketey, B. (2024). Real- Time Farud Detection Using Machine Learning. 12, s. 189-209.
- Brubaker, R. (2002). Ethnicity without groups. *European Journal of Sociology*, 43(2), 163-189.
- Candan, F. ., (2018). “ Takviyeli Q-Öğrenme Yöntemiyle Labirent Problemi Çözümü”. *Teknolojik ve Uygulamalı Araştırmalar Konferansı (TOK 2018)*. Kayseri: Erciyes Üniversitesi.
- Çayıroğlu, M. (2010). *Genetik Programlama İçin Alana Özgü Programlama Dili*. İstanbul: Yüksek Lisans Tezi. İstanbul Teknik Üniversitesi.
- Çeltek, S. (2021). *Şehir İçi Trafik Sinyal Ağının Takviyeli Öğrenme Algoritmaları Ve Nesnelerin İnterneti Tabanlı Kontrolü*. Konya: Doktora Tezi. Konya Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü.
- Çilhoroz, A. v. (2021). “Yapay Zekâ: Sağlık Hizmetlerinde Uygulamalar”. *Ankara Hacı Bayram Veli Üniversitesi İİBF Dergisi*, 23(2), 573-588.
- Çokluk, Ö. (2010). “Lojistik Regresyon Analizi: Kavram ve Uygulama”. *Ankara Üniversitesi Eğitim Bilimleri Fakültesi Dergisi*, 43(2), 123-135.
- Çolak, Z. (2025). Derin Öğrenme Modelleri İle Hisse Senedi Fiyat Tahmini:LSTM,GRU,RNN,MLP Modellerinin Karşılaştırmalı Analizi. *Yönetim Bilimleri Dergisi*, 23(56), s. 8-10.
- Emel, G. V. (2002). “ Genetik Algoritmalar Ve Uygulama Alanları”. *Uludağ Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 21(1), 129-152.
- Ercan, F. (tarih yok). “Turizm Pazarlamasında Yapay Zekâ Teknolojilerinin Kullanımı ve Uygulama Örnekleri ”. *AHBVÜ Turizm Fakültesi Dergisi*, 23(2), 394-410.

- Erdal, H. (tarih yok). “Yapay Zekâ Teknikleri Ve Uzman Sistemlerin Karasal Akıllı Ulaşım Sistemlerinin Denetiminde Kullanımı”. *Akıllı Ulaşım Sistemleri Ve Uygulamaları Dergisi*, 1(1), 32-39.
- Erden, C. (2023). Derin Öğrenme ve ARIMA Yöntemlerinin Tahmin Performanslarının Kıyaslanması: Bir borsa İstanbul Hissesi Örneği. (C. B. İ.İ.B.F., Dü.) *Yönetim Ve Ekonomi*, 30(3), 421-433.
- Eren, A. (2024). *Hedef programlama ve genetik algoritma ile optimal portföy seçimi: BIST-30’da bir uygulama*. Ankara: Yüksek lisans tezi. Ankara Hacı Bayram Veli Üniversitesi, Lisansüstü Eğitim Enstitüsü.
- Fearon, J. D., & Laitin, D. D. (2000). Violence and the Social Construction of Ethnic Identity. *International Organization*, 54(4), 845-877.
- Gemici, B. (2012). *Veri Madenciliği Ve Bir Uygulama*. İzmir: Yüksek Lisans Tezi. Dokuz Eylül Üniversitesi Sosyal Bilimler Enstitüsü Ekonometri Anabilim Dalı.
- Göloğlu, C. V. (2006). “Genetik Programlama İle İmalat İçin Yüzey Pürüzlülük Modeli Geliştirilmesi”. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 667-674.
- Gülcü, T. v. (2019). “Yapay zekâ tabanlı modelleme yöntemlerinin karşılaştırılması: Bir uygulama. ”. *Gazi Üniversitesi Fen Bilimleri Dergisi(GUJSCI)*, 32(4), 1185-1199.
- Gündoğdu, E. (2023). *Veri Madenciliği Çerçevesinde Yapay Sinir ağları Ve Birliktelik Kuralı Analizi Üzerine Borsa İstanbul 30 Endeksinde Bir Uygulama*. Bursa: Yüksek Lisans Tezi. Bursa Uludağ Üniversitesi Sosyal Bilimler Enstitüsü Ekonometri Anabilim Dalı.
- Güven, M. v. (2023). “Yapay Zekâ Uygulamalarının E-Ticarette Kullanımı”. *Uluslararası Yönetim Akademisi Dergisi*, 5(2), 5-24.
- Hale, H. E. (2004). Explaining Ethnicity. *Comparative Political Studies*, 37(4), 458-485.
- Hark, H. (2012). *Çok Amaçlı Genetik Algoritmalarla Çoklu Dizi Hizalama*. Elazığ: Yüksek Lisans Tezi. Fırat Üniversitesi.
- Hernandez Aros, L. B. (2024). Financial fraud detection through the application of machine learning techniques: a literature review. 11(article 1130).
- İbiş, S. (tarih yok). “Turizm endüstrisinde robotlaşma”. *İstanbul Gelişim Üniversitesi, İİSBF, Turizm Rehberliği Bölümü Türk Turizm Araştırmaları Dergisi*, 3(3), 403-420.
- Kantar, L. (2020). Bist 100 Endeksinin Yapay Sinir Ağları ve ARMA Modeli İle Tahmini. *İstanbul Gelişim Üniversitesi Muhasebe ve Finans İncelemeleri Dergisi*, 121-131.
- Karaatlı, H. G. (2005). Hisse senedi fiyat hareketlerinin yapay sinir ağları yöntemi ile tahmin edilmesi. *Afyon Kocatepe Üniversitesi İ.İ.B.F. Dergisi*, 173-190.

- Karakaşlı, H. (2024). *LSTM Derin Öğrenme Yöntemi İle Manipülasyonlu İşlemlerin Tespiti: borsa İstanbul Uygulaması*. Kocaeli: İşletme anabilim dalı muhasebe ve finans bilim dalı.
- Karasoy, O. V. (2016). “Google Maps Ve Genetik Algoritmalarla GSP Çözümü İçin Öneri” . *Akademik Bilişim Konferansı*, (s. 4-23).
- Köktürk, F. (2012). *K-en Yakın Komşuluk, Yapay Sinir Ağları Ve Karar Ağaçları Yöntemlerinin Sınıflandırma Başarılarının Karşılaştırılması*. Zonguldak: Doktora tezi. Bülent Ecevit Üniversitesi Sağlık Bilimleri Enstitüsü, Biyoistatistik Anabilim Dalı.
- Metin, S. v. (2019). “Derin öğrenme yöntemleri ile insan aktivitelerinin sınıflandırılması”. *Avrasya Sosyal ve Ekonomi Araştırmaları Dergisi*, 6(5), 141-152.
- O.K.M., Y. T. (tarih yok). “ Petrol Fiyatlarının Zaman Serileri ve LSTM Modeli Kullanılarak Tahminlenmesi ”. *Uluslararası Teknolojik Bilimler Dergisi*, 13(1), 34-38.
- Okutkan, C. (2014). *Borsa İstanbul Şirketlerinin Hisse Senedi Getirilerinin yapay Sinir Ağları ve Çoklu Regresyon Yöntemleri Kullanarak Analizi*. Kocaeli: Yüksek Lisans Tezi. Kocaeli Üniversitesi Fen Bilimleri Enstitüsü Mühendislik Ana Bilim Dalı.
- Öztürk, K. V. (2018). “Yapay sinir ağları ve yapay zekâ ’ya genel bir bakış”. *Takvim-i Vekayi dergisi*, 25-36.
- Pirim, H. (2006). “Yapay Zekâ ”. *Yaşar Üniversitesi E-Dergisi*, 1(1), 81-93.
- Polat, O. (2024). *LSTM model İle Bitcoin Fiyatı Tahminlemesi*. İstanbul: Yüksek lisans Tezi. İstanbul Ticaret Üniversitesi Finans Enstitüsü.
- Polat, O. (2024). *LSTM Model İle Bitcoin Fiyatı Tahminlemesi*. İstanbul: İstanbul ticaret Üniversitesi Finans Entitüsü Sermaye Piyasası Anabilim Dalı .
- Sakarya, Ş. v. (2019). “ Derin öğrenme mimarisi kullanarak BIST30 indeksinin tahmini ” . *European Journal of Educational and Social Sciences*, 4(2), 106-121.
- Sarıkaya, G. (2019). Yapay sinir ağları ve regresyon modelleri ile BIST Ulusal-100 endeksinin tahmini. *21. Yüzyılda Eğitim ve Toplum*, 325-340.
- Smith, A. D. (2000). *The Nation in History: Historiographical Debates about Ethnicity and Nationalism*. Cambridge: Polity Press.
- Sönmez, L. v. (2024). LSTM Modeli İle Volatilite Temelli Borsa Tahmini. *Uluslararası Muhasebe ve Finans Araştırmaları Dergisi*, 48-61.
- Sönmez, L. v. (2024). LSTM Modeli İle Volatilite Temelli Borsa Tahmini. *Uluslararası Muhasebe ve Finans Araştırmaları Dergisi*, 6(2), 48-61.
- Şeker, M. (2020). “Yapay Zekâ Tekniklerinin/Uygulamalarının Siber Savunma Kullanımı”. *Uluslararası Bilgi Güvenliği Mühendisliği Dergisi*, 6(2), 108-115.

- Tanişman, S. K. (2021). Bitcoin Fiyatının LSTM Ağı ve ARIMA Zaman Serisi Modeli Kullanarak Tahmini Ve Karşılaştırılması. *Avrupa Bilim Ve Teknoloji Dergisi*(32), 514-520.
- Taşcı, E. V. (2016). “ K-en Yakın Komşu Algoritması Parametrelerinin Sınıflandırma Performansı Üzerine Etkisinin İncelenmesi ”. *18. Akademik Bilişim Konferansı (AB 2016)*. Aydın: Adnan Menderes Üniversitesi.
- Tektaş, M. A. (2002). “*Yapay zekâ tekniklerinin trafik kontrolünde kullanılması üzerine bir inceleme*”. Konya: I. Uluslararası Trafik ve Yol Güvenliği Kongresi ve Fuarı.
- Tüfekçi, M. &. (2019). “ Derin öğrenme mimarilerinden konvolüsyonel sinir ağları (CNN) üzerinde görüntü işleme-sınıflandırma kabiliyetininim arttırılmasına yönelik yapılan çalışmaların incelenmesi ”. *HORA2019* (s. 1-4). Human Computer Interaction Conference, Ürgüp, Nevşehir: Bursa Uludağ Üniversitesi, Bursa.
- Uzun, Y. ., (2021). “Günümüzde ve Gelecekte Eğitim Alanında Kullanılan Yapay Zekâ”. *1st International Conference on Applied Engineering and Natural Sciences (ICAENS 2021)*. Konya.
- van den Berghe, P. L. (1978). Race and ethnicity: A sociobiological perspective. *Ethnic and Racial Studies*, 1(4), 401-411.
- Vural, B. (2007). *Yapay Sinir Ağları İle Finansal Tahmin*. Ankara: Yüksek Lisans Tezi. Ankara Üniversitesi Sosyal Bilimler Enstitüsü İşletme Anabilim Dalı.
- Wang, H. &. (2021). Robo Advising: Enhancing Investment with Inverse Optimization and Deep Reinforcement Learning. *ArXiv*.
- Yetiz, F. ., (2021). “Makina Öğrenmesi Yöntemleri ile Türk Mevduat Bankalarının Müşteri Tahminine Yönelik Bir Uygulama”. *Sosyoekonomik*, 29(50), 413-432.
- Yiğiter, Ş. Y. (2016). Hisse senedi kapanış fiyatlarının yapay sinir ağları ve bulanık mantık çıkarım sistemleri ile tahmin edilmesi. *Kahramanmaraş Sütçü İmam Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 173-190.
- Yıldız, A. (2022). Finans Alanında Yapay Zekâ Teknolojisinin Kullanımı: Sistemik Literatür İncelemesi. *Pamukkale Sosyal Bilimler Enstitüsü Dergisi*, 47-66.

İnternet kaynakları

<https://aksan.av.tr/yeni-yapay-zeka-cagi-ve-turkiye/> (erişim Tarihi:12.10.2024).

<https://aksan.av.tr/yeni-yapay-zeka-cagi-ve-turkiye/>,(erişim Tarihi:12.10.2024).

<https://aws.amazon.com/tr/what-is/logistic-regression/>,(Erişim tarihi:19.12.2024).

<https://bulutistan.com/blog/makine-ogrenmesi-karar-agaci-decision-tree-nedir/>,(Eriřim Tarihi:25.12.2024).

<https://datakapital.com/blog/konvolusyonel-sinir-aglari-nedir/>,(Eriřim Tarihi:15.01.2025).

[\(https://datakapital.com/blog/konvolusyonel-sinir-aglari-nedir/](https://datakapital.com/blog/konvolusyonel-sinir-aglari-nedir/) , (Eriřim Tarihi:20.01.2025).

<https://www.veribilimiokulu.com/genetik-algoritma/>, (Eriřim Tarihi:02.01.2025).



ÖZGEÇMİŞ

Adı ve SOYADI	İzel COŞKUN
EĞİTİM DURUMU	
Lise	Mustafa Kaçıkoc Anadolu Lisesi
Lisans	Akdeniz Üniversitesi, İktisadi Ve İdari Bilimler Fakültesi, İşletme Bölümü (2015-2021)
Yüksek Lisans	Akdeniz Üniversitesi, Sosyal Bilimler Enstitüsü, Finans Ve Bankacılık Bölümü (2022-2025)
Tez Konusu	Finansal Piyasalarda Yapay Zekâ Uygulamaları
Yabancı Dil / Diller	İngilizce
İŞ DENEYİMİ	
2022-2024	Antalyaspor Kulübü İktisadi İşletmesi, Muhasebe Yardımcı Elemanı (Antalya)
2019-2022	Antmer Teknik Hizmetler A.Ş.(Arçelik),Muhasebeci (Antalya)