

T.C.  
TRAKYA ÜNİVERSİTESİ  
SOSYAL BİLİMLER ENSTİTÜSÜ  
EKONOMETRİ ANABİLİM DALI  
YÜKSEK LİSANS TEZİ



# HİBRİT DERİN ÖĞRENME MODELLERİ İLE HİSSE SENEDİ FİYAT TAHMİNİ

KÜBRA KARADAĞ

TEZ DANIŞMANI

PROF.DR. NURCAN METİN

EDİRNE 2022

Tez Konusu: Hibrit Derin Öğrenme Modelleri İle Hisse Senedi Fiyat Tahmini

Hazırlayan: Kübra KARADAĞ

## ÖZET

Zaman serilerinde yüksek performanslı tahminler yapabilmek birçok uygulama alanı için temel öneme sahiptir. Zaman serisi verilerini tek bir yöntemle tahmin etmek yerine, veri setinin barındırdığı farklı fonksiyonel ilişkileri modelleyebilen birden çok yöntemi birleştirilerek tahminde bulunmak, daha etkili sonuçlar vermektedir. Tez kapsamında, Borsa İstanbul'da işlem gören XBANK bankalar endeksinin gelecek değer tahmini için derin öğrenme modelleri arasında zamansal ilişkileri dikkate alan LSTM ve GRU algoritmalarının kullanımı tercih edilmektedir. ARIMA modeli ve teknik analizde kullanılan göstergelerin de kullanımı ile farklı hibrit model yapıları ortaya koyularak tahmin performanslarının artırılması amaçlanmaktadır. Ele alınan farklı model yapılarının etkinliği, geçerliliği ve model performanslarının değerlendirilebilmesi için modellere ait öngörü değerleri ve hataya bağlı model performans metrikleri karşılaştırılmaktadır. Uygulama sonucunda, ARIMA model artıkları ve teknik analiz göstergelerinin kullanımı ile oluşturulan GRU hibrit modeli, oluşturulan diğer GRU, LSTM ve LSTM hibrit modellerine göre, örneklem dışı değerlere en yakın tahminler vermekte ve düşük hata oranı ile daha başarılı tahmin performansı gerçekleştiren model olarak dikkat çekmektedir.

**Anahtar Kelimeler:** Hisse senetleri, Derin Öğrenme, Hibrit Model, Zaman Serileri Analizi, Teknik Analiz

Thesis Subject: Stock Price Prediction with Hybrid Deep Learning Models

Posted by Kübra KARADAĞ

## **ABSTRACT**

Being able to make high-performance predictions in time series is of fundamental importance for many application areas. Instead of estimating time series data with a single method, estimating by combining multiple methods that can model different functional relationships in the data set gives more effective results. Within the scope of the thesis, the use of LSTM and GRU algorithms, which take into account the temporal relationships between deep learning models, is preferred for the future value estimation of the XBANK banks index traded in Borsa Istanbul. With the use of the ARIMA model and the indicators used in technical analysis, it is aimed to increase the forecast performances by revealing different hybrid model structures. In order to evaluate the effectiveness, validity and model performance of the different model structures under consideration, the predictive values of the models and the model performance metrics related to the error are compared. As a result of the application, the GRU hybrid model, which was created with the use of ARIMA model residues and technical analysis indicators, gives the closest estimates to the out-of-sample values compared to the other GRU, LSTM and LSTM hybrid models created, and draws attention as a model that performs more successful prediction performance with its low error rate.

**Keywords:** Stocks, Deep Learning, Hybrid model, Time Series Analysis, Technical Analysis

## TEŐEKKÜRLER

Tez yazım süreci boyunca verdiđi teővik ve yardımlarından dolayı tez danışmanım Sayın Prof. Dr. Nurcan METİN' e, yönlendirici bilgi, anlayış ve zamanını esirgemeyen Sayın Hocam Doç. Dr. Mehmet Kenan TERZİOĐLU' na, her zaman yanımda olan aileme, hayatı paylaştığım en büyük destekçim, eşim Erdem KARADAĐ' a sonsuz teőekkürler.

## İÇİNDEKİLER

ÖZET.....	I
TEŞEKKÜRLER.....	III
İÇİNDEKİLER.....	IV
ŞEKİLLER.....	V
TABLolar.....	VI
KISALTMALAR.....	VI
GİRİŞ.....	1
1.YATIRIM VE HİSSE SENETLERİ.....	11
1.1.Hisse Senedi Analiz Yöntemleri.....	12
1.1.1.Temel Analiz.....	13
1.1.2.Teknik Analiz.....	14
2.ZAMAN SERİLERİ ANALİZİ.....	22
2.1. Zaman Serilerinde Durağanlık Kavramı ve Birim Kök Testleri.....	23
2.1.1. Yapısal Kırılmasız Birim Kök Testleri.....	26
2.1.1.1.Dickey-Fuller Birim Kök Testi.....	26
2.1.1.2.Phillips-Perron (PP) Birim Kök Testi.....	27
2.1.1.3.KPSS Birim Kök Testi.....	27
2.1.2.Yapısal Kırılmalı Birim Kök Testleri.....	28
2.1.2.1.Zivot-Andrews Birim Kök Testi.....	28
2.1.2.2.Lee-Strazicich Birim Kök Testi.....	29
2.2. Doğrusal Durağan Stokastik Modeller.....	30
2.2.1. Otoregresif Süreç AR(p).....	31
2.2.2. Hareketli Ortalama Süreci MA(q).....	32
2.2.3. Otoregresif Hareketli Ortalama Süreci ARMA(p,q).....	33
2.3. Durağan Olmayan Doğrusal Stokastik Modeller.....	34
2.3.1. Otoregresif Bütünleşik Hareketli Ortalama Süreci ARIMA(p,d,q).....	34
3.YAPAY ZEKÂ.....	36
3.1. Makine Öğrenimi.....	37
3.2. Derin Öğrenme.....	39
3.2.1. Yapay Sinir Ağları (ANN) ve Çok Katmanlı Algılayıcılar (MLP).....	40
3.2.2. Tekrarlayan Sinir Ağları (RNN).....	47
3.2.2.1. Uzun Kısa Süreli Bellek modeli (LSTM).....	49
3.2.2.2. Kapılı Tekrarlayan Hücre (GRU).....	54

4. MODEL PERFORMANSINI DEĞERLENDİRME KRİTERLERİ .....	59
5. HİBRİT DERİN ÖĞRENME MODELLERİ İLE HİSSE SENEDİ FİYAT TAHMİNİ.62	
Sonuç .....	69
Kaynakça.....	74

## ŞEKİLLER

Şekil 1. BIST Banka Endeksi Kapanış Fiyatları 20 Günlük Basit Hareketli Ortalaması .....	17
Şekil 2. BIST Banka Endeksi Kapanış Fiyatları RSI İndikatörü.....	18
Şekil 3. BIST Banka Endeksi Kapanış Fiyatları Momentum İndikatörü .....	19
Şekil 4. BIST Banka Endeksi Kapanış Fiyatları Bolinger Bantları İndikatörü .....	20
Şekil 5. BIST Banka Endeksi Stokastik Osilatör İndikatörü .....	21
Şekil 6. Yapay Zekâ, Makine Öğrenmesi ve Derin Öğrenmenin Kronolojisi .....	37
Şekil 7. Sigmoid, Hiperbolik Tanjant Ve Relu Aktivasyon Fonksiyonları .....	42
Şekil 8. Yapay Sinir Hücre ve Çok Katmanlı Model Yapısı .....	44
Şekil 9. Bir Yapay Sinir Ağının İleri ve Geri Beslemeli Topolojisi .....	46
Şekil 10. RNN Ağ Bloğu .....	48
Şekil 11. LSTM'deki Yinelenen Modül, Dört Etkileşimli Katman İçermektedir .....	50
Şekil 12. LSTM Model Tahmin Adımları .....	52
Şekil 13. GRU Model Yapısı .....	55
Şekil 14. Stokastik Gradyan İniş .....	58
Şekil 15. BIST Banka Kapanış Fiyatı Verilerine Ait Zaman Serisi Grafiği .....	63
Şekil 16. ARIMA+TA+GRU Modeline Ait 100 Epoch Eğitim/Test Kayıp Grafiği .....	67
Şekil 17. GRU-ARIMA-TA Modeline İlişkin Test Verileri Tahmin Grafiği .....	68
Şekil 18. GRU-ARIMA-TA Modeline İlişkin Tahmin Grafiği.....	68

## TABLolar

Tablo 1. BIST Banka Endeksine Ait Tanımlayıcı İstatistikler .....	62
Tablo 2. ADF, PP ve KPSS Birim Kök Testi Sonuçları .....	64
Tablo 3. Derin Öğrenme Modellerinde Kullanılan Diğer Hiperparametreler .....	65
Tablo 4. Modellerin Performans Değerlendirme Ölçütleri .....	66
Tablo 5. Uygulama Sonucunda Elde Edilen 10 Günlük Tahmin Değerleri .....	67

## KISALTMALAR

MA :Hareketli Ortalama (moving average)

RSI :Göreceli Güç Endeksi (Relative Strength Index)

MACD :Hareketli Ortalamaların Yakınlaşma ve Uzaklaşması (Moving average convergence divergence)

ACF : Otokorelasyon Fonksiyonu (Autocorrelation Function)

PACF : Kısmi Otokorelasyon Fonksiyonu (Partial Autocorrelation Function)

ADF: Genişletilmiş Dickey-Fuller Testi (Augmented Dickey Fuller Test)

PP Test: Phillips-Perron Testi

KPSS Test: The Kwiatkowski–Phillips–Schmidt–Shin Test

AR : Otoresif Modeli ( Autoregressive Model)

MA : Hareketli Ortalama Modeli (Moving Average Model)

ARMA : Otoresif Hareketli Ortalamalar Modeli (Autoregressive–Moving-Average Model)

ARIMA : Otoresif Entegre Hareketli Ortalama Modeli (Autoregressive İntegrated Moving Average Model)

ANN : Yapay Sinir Ağları (Artificial Neural Network)

ReLU : (Rectified Linear Unit)

MLP: Çok Katmanlı Algılayıcılar (Multilayer perceptron)

RNN: Tekrarlayan Sinir Ağları (Recurrent Neural Networks)

LSTM : Uzun Kısa Süreli Bellek modeli (Long Short-Term Memory )

BPTT : Zaman Boyunca Geri Yayılım (Backpropagation through time)

GRU: Kapılı Tekrarlayan Hücre (Gated Recurrent Unit)

ME: Ortalama hata (Mean Error )

MAE: Ortalama mutlak hata (Mean Absolute Error)

MSE : Ortalama Kare Hata (Mean Squared Error)

RMSE : Kök Ortalama Kare Hata (Root Mean Squared Error)

MPE : Ortalama Yüzde Hata (Mean Percentage Error)

MAPE : Ortalama Mutlak Yüzde Hata (Mean Absolute Percentage Error )



## GİRİŞ

Zaman serisi analizlerinin temel amacı, bir sistem veya sürecin geçmiş gözlemlerini dikkate alarak süreçteki doğal yapıyı tanımlayabilen uygun bir model geliştirmek ve serinin karmaşık ve dinamik davranışını analiz etmektir. Geliştirilen başarılı bir model ile sürecin gelecekteki değerlerini veya oluşumlarını anlamak mümkün olmaktadır.

Finansal piyasa fiyatlarındaki tüm değişiklikler, anlık ekonomik olaylara veya haberlere dayandığından, finansal piyasa verilerinin modellenmesi ve tahmin edilmesi, akademisyenler, araştırmacılar ve yatırımcılar için ilgi çekici bir konu olup, yüksek gürültülü, küçük örnek boyutlu, durağan olmayan ve doğrusal olmayan özellikleri içinde barındırması sebebiyle zor bir tahmin problemi haline almaktadır.

Borsa, farklı sektörlerden şirketlerin hisse senetlerinin işlem gördüğü finansal piyasalar olup, aynı zamanda sermaye piyasasının da ana bileşenini temsil etmektedir. Halka açık şirketler, borsada hisse senedi ve tahvil ihraç ederek, geçici sermaye kıtlığı sorununu çözmek için atıl fonlar toplayabilmekte, yatırımcılar ise hisse senetleriyle kolay erişilebilir finansal ürünlere sahip olmaktadır. Yatırımcılar kâr odaklı düşünüp, alım satım kararlarında geçmiş analizlere veya planlara bakılmaksızın en güncel olaylara bakarak hareket ettiklerinden, ekonominin değişken yapısı nedeniyle büyük miktarda risk almaktadır. Bu nedenle hem özel yatırımcılar hem de bankalar gibi finansal kuruluşlar, hisse senedi fiyatlarında meydana gelen değişiklikleri önceden tahmin etmenin ve erken alım ve satım kararları vermenin yollarını her zaman tasarlamaya çalışmaktadır.

Hisse senetleri fiyat hareketleri çok değişken yapıya sahiptir ve bu karmaşık doğası, araştırmacı ve istatistikçilerin onları tahmin etmenin bir yolunu bulmaları için önemli bir çekişme sağlamaktadır. Hisse senetlerindeki fiyat hareketleri, piyasanın irrasyonel davranışı ve haberler gibi ölçülemeyen faktörlerden büyük ölçüde etkilendiğinden, siyasi ve makroekonomik çevreye oldukça duyarlı olmaktadır. Bu bilgiler toplanamayacak kadar karmaşık ve kararsız özellikte olduğundan, yüksek gürültü içermekte ve hisse senedi fiyatını bağımsız değişkenlerle yüksek doğrulukla tahmin etmek neredeyse imkânsız hale getirmektedir. Bu zorluğun üstesinden gelmek amacıyla hisse senedi fiyatlarını analiz ederken diğer faktörlerin etkilerini incelemek yerine, regresyon tahmini modellemeden farklı olarak, ekonometrik analizlerde

sıklıkla kullanılan zaman serisi tahmin modelleri kullanılarak, fiyat hareketlerinin daha önce gözlemlenen değerlere bağlı olarak gelecekteki değerleri tahmin edilmektedir. Zaman serisi modelleri ile hisse senetlerinin tarihsel verileri ele alınıp, gelecekteki değerinin ne olacağını hakkında tahminler elde edilirken, bir hisse senedi alıcısı, hisse senetlerini ne zaman satın alıp, kar elde etmek için ne zaman satacağına makul bir şekilde karar vermektedir.

Finansal analizlerde kullanılan teknik analiz yönteminde hisse senedi fiyat hareketlerine neden olabilecek tüm temel bilgilerin ve ekonomik faktörlerin zaten fiyatlara yansıdığı varsayıldığından, finansal piyasalardaki geçmiş fiyat hareketleri kullanılarak ve belirli analiz yöntemlerine göre yorumlanarak, gelecekteki fiyat hareketlerinin yönü tahmin edilmeye çalışılmaktadır.

Bilgisayar bilimi teknolojisinin gelişmesiyle birlikte, büyük veri ve yapay zekâ teknolojisinin finansal analiz alanında kullanımı da artmaktadır. Hisse senedi verilerinin analizinde fiyat hareketlerini dikkate alarak tahmin üretmek için, ekonometrik model ve teknik analiz dışında, son yıllarda makine öğrenme yöntemlerinin de kullanımına yönelik artan bir ilgi mevcuttur. Makine öğrenimi alanındaki gelişmeler, mevcut istatistiksel veri analizi yöntemlerini otomatikleştirerek finansal piyasaları tahmin etme görevinde bilgisayarların kullanılması yaygınlaştırmaktadır. Makine öğrenimi, verilerden öğrenebilen bilgisayar sistemleri veya programları oluştururken, hisse senedi fiyatları tahmininde, veri kümesi içerisinde hangi özelliklerin tahmin üzerinde ne kadar etkili olduğunu belirlemek için özellik seçimi ve farklı tekniklerle performans artırımına odaklanmaktadır.

Son yıllarda, makine öğrenimi yöntemlerinin, finansal piyasanın tahminindeki potansiyelleri dikkate alındığında, tüm makine öğrenimi yöntemleri arasında, sinir ağları öne çıkmakta ve finansal piyasayı tahmin etmek ve modellemek için başarılı sonuçlar vermektedir. Geleneksel makine öğrenimi modellerinden farklı olarak, sinir ağları, eldeki problem için bir girdi-çıkı eşlemesi oluşturarak örneklerden öğrenmektedir. Hisse senetleri fiyat verilerinin karmaşıklığı göz önüne alındığında, sinir ağlarının gürültü toleransı, eksik verilerle eğitime yeteneği ve yeni veri kalıplarını kullanarak yeniden eğitim süreci aracılığıyla dinamik sistemleri öğrenme yeteneğine sahip olmakta, geleneksel istatistiksel modellere kıyasla daha başarılı sonuçlar vermektedir.

Derin öğrenme ağları, birden çok temsil düzeyini öğrenmek için birçok basamaklı katmandan yararlanan güçlü makine öğrenimi algoritmaları arasında yer almaktadır. LSTM ve GRU modelleri, sıralı verilerin analizi için elverişli olup, benzersiz katmanları ve kullanan paralel hesaplama mimarileri ile eğitim ve tahmin görevlerini daha hızlı uygulanabilir hale getirmektedir. LSTM, zaman içinde geri yayılma mimarisi kullanılarak eğitilen ve kaybolan gradyan sorununun üstesinden gelen tekrarlayan bir sinir ağı modeli olup, yalnızca tek veri noktalarını değil, aynı zamanda tüm veri dizilerini (konuşma veya video gibi) işleyebilme ve bilgileri belirli bir süre boyunca saklayabilme yeteneğiyle zaman serileri analizinde son derece kullanışlı hale gelmektedir. LSTM ağlarına benzer şekilde, GRU, ünite içindeki bilgi akışını modelleyen ancak ayrı bir hafıza hücresine sahip olmayan geçit birimlerini kullanmakta olup, yine benzer şekilde zaman serisi verilerini ve uzun süreli bağımlılıklarını, zaman boyunca silmeden bellekte tutma kabiliyetine sahip olmaktadır.

Zaman serileri verilerinin çoğu doğrusal olmayan, yüksek gürültü içeren ve eksik veri barındıran özelliklere sahiptir. Verilerin sahip olduğu bu karmaşık yapıyı tahminlemek oldukça zordur. Geleneksel zaman serisi yöntemlerinin çoğu geçmiş gözlemlerin doğrusal kombinasyonunu kullanarak tahminler üretmekte ve doğrusal olmayan yapıyı modellemekte yetersiz kalmaktadır. Diğer yandan makine öğrenmesi yöntemleri ise doğrusal yapılarda başarısız kalmaktadır. Bu nedenle, hem istatistiksel hem de makine öğrenimi yöntemlerini birlikte kullanan hibrit bir model yaklaşımı kullanmak, verilerdeki hem doğrusal hem de doğrusal olmayan yapıları modelleyebilen ve tahmin için iyi ve verimli bir alternatif haline gelen bir model oluşturmaktadır.

Hibrit modellerin ana hedefi, başarı performanslarını arttırmak için modellerin birlikte kullanımına dayanmaktadır. Yaklaşımında modellerin her biri olayın farklı yönünü öğrenebilmekte ve hepsinin kararını bir araya getirerek daha başarılı sonuçlar elde etmek amaçlanmaktadır.

Hibrit yöntemler toplamsal ve çarpımsal olabilmektedir. Zhang (2003), geliştirdiği hibrit model yaklaşımında serideki doğrusal ( $L_t$ ) ve doğrusal olmayan ( $N_t$ ) yapıyı birlikte ( $y_t = L_t + N_t$ ) ele almayı amaçlamaktadır. Yaklaşımında ilk olarak doğrusal model olan ARIMA yöntemi kullanılarak tahmin yapılmakta, model çıktısı olarak artıkları ( $e_t = Y_t - \hat{L}_t$ ) kullanılmaktadır. Elde edilen artıklarda hala doğrusal yapı

mevcut ise doğrusal modelin yetersiz olduğunu ve doğrusal olmayan ilişki için ANN modelinin ( $\hat{e}_t = f(e_{t-1}, e_{t-2}, \dots, e_{t-n}) + \varepsilon_t$ ) kullanılmasını önermektedir. Burada  $f$ , ANN dönüştürme işlevini,  $\varepsilon$  ise rasgele hatayı belirtirken elde edilen doğrusal olmayan tahmin sonuçları doğrusal model sonuçları ile birleştirilerek sonuca varılmaktadır. Zhang(2003)'ün model yaklaşımında, Wolf'un güneş lekeleri, Kanada'da vahşi kedi sayıları ve İngiliz sterlini, ABD doları döviz kuru verileri ele almaktadır. Babu ve Reddy (2014), bu model yaklaşımı ile elde ettiği sonuçların, hem tek adımlı hem de çok adımlı tahminler için önerilen hibrit modelin daha yüksek tahmin doğruluğuna sahip olduğunu belirtmektedir. Khashei ve Bijari (2008), önerdikleri hibrit model yaklaşımında, zaman serisi tahmini için doğrusal ve doğrusal olmayan iki bileşenin toplamı olarak başka bir hibrit ARIMA-ANN modeli önermektedir. Yöntemde öncelikle zaman serisi verileri bir ARIMA modeli kullanılarak tahminlenmekte, sonra geçmiş orijinal veri değerleri, mevcut ARIMA tarafından tahmin edilen veri değeri ve geçmiş hata dizisi değerlerinin tümü bir ANN'ye girdi olarak verilerek nihai tahmin değeri elde edilmektedir. Khashei, Bijari ve Ardali (2012), hibrit model yaklaşımında aynı veri seti için ARIMA modeli ile olasılıksal sinir ağı modellerini ( Probabilistic Neural Network) birleştirerek yeni bir hibrit model ortaya koymuş olup, söz konusu hibrit model, sınıf ayrıştırıcılarından ve ARIMA modellerinin artıklarından oluşmaktadır. Babu ve Reddy (2014)' nin hibrit model yaklaşımı, zaman serisinin düşük oynaklık ve yüksek oynaklık değerlerinin toplamı olduğunu varsaymaktadır. Narendra ve Eswara (2014), yaklaşımda jarque-bera normallik testi ve basıklık (kurtosis) katsayısı hesaplanmakta, bu katsayının 3'den büyük olması halinde serinin Gauss dağılımına uygun olmadığı ve yüksek oynaklığa sahip olduğu belirtilirken, hesaplanan katsayının 3'e yaklaşması halinde ise, Gauss dağılımına uygun olduğu ve düşük oynaklığa sahip olduğu ifade edilmektedir. Gauss dağılımına sahip olan düşük oynaklıktaki bileşen doğrusal ARIMA yöntemiyle, yüksek oynaklıktaki bileşen ise doğrusal olmayan ANN yöntemiyle tahmin edilmesi önerilmektedir. Önerilen hibrit modelin tahmini de bu iki sonucun toplamı olarak ele alınmaktadır.

Literatürde zaman serileri analizini kullanarak hisse senetlerini ele alan birçok çalışma mevcuttur. Kurt ve Şenal (2018), Borsa İstanbul'da kote toplam beş şirkete ait hisse senedi kapanış fiyatlarını ARIMA modelleri ile analiz ederek, gelecek bir yıl için fiyat tahminlerini başarılı bir şekilde gerçekleştirmektedir. Almasarweh ve Wadi (2018), Ürdün'deki Amman borsasından alınan bankacılık verilerinin analizinde, ARIMA modelinin kısa vadeli tahmin için önemli sonuçlara sahip olduğunu

göstermektedir. Afeef vd. (2018), hisse senetleri fiyat tahmininde, ARIMA modellemesinin kısa vadeli tahmin için oldukça verimli çalıştığı sonucuna varmaktadır. Wadi vd. (2018), Amman Menkul Kıymetler Borsası'ndan (ASE) Ocak 2010'dan Ocak 2018'e kadar toplanan kapalı zaman serisi verilerini tahmin etmede ARIMA modelini kullanarak, modelinin kısa vadeli tahmin için önemli sonuçlara sahip olduğunu göstermektedir. Arslaargün ve Şakar (2000), çalışmasında ARIMA modeli kullanılarak IMKB Ulusal 100 endeksini mart 2000 itibariyle tahmin etmeyi amaçlamaktadır. Dassanayake vd. (2021), teknik analize dayalı ARIMA tahmin modelleri geliştirilmekte ve Yeni Zelanda borsası (NZX50) endeksi üzerinde ampirik olarak test edilmektedir. Khanderal vd. (2021), hisse senetlerini ele alırken ARIMA modellerini uygulayıp, kısa dönemli tahminde yükselen tahmin teknikleri ile oldukça başarılı olduğunu savunmaktadır. Meher vd. (2021), ARIMA modelini kullanarak NIFTY100 altında listelenen Hindistan'daki seçilmiş ilaç şirketlerinin hisse fiyatlarını tahmin etmeye çalışmaktadır.

Sinir ağı modellerini kullanarak hisse senetlerini analiz eden çalışmalar incelendiğinde, Çalışkan ve Deniz (2015), BİST30 endeksinin günlük bazda fiyatları ve fiyat yönlerini yapay sinir ağları ile tahmin etmekte, sonuçlarında, günlük bazda fiyat yönü ortalama %58 oranında doğru tahmin etmektedir. Onocak ve Koç (2018), BİST 100 endeksi kapanış fiyatını ele alarak, Ocak 2003- Ekim 2017 tarihleri arasındaki aylık verileriyle yapay sinir ağları modelini kullanmakta ve yüksek bir eğitim performansı ile ağın gerçek değerlere yakın tahmini değerler ürettiğini göstermektedir. Althelaya (2018), S&P500 endeksinin kısa ve uzun vadeli tahminlerini gerçekleştirmek için çok değişkenli girdilere sahip hem çift yönlü hem de tek yönlü yığın mimariler kullanmakta, LSTM mimarisinin hem kısa hem de uzun vadede en yüksek tahmin performansını gösterdiği belirtmektedir. Liu vd. (2019), iki hisse senedinin kısa vadeli kapanış fiyatı zaman serisi tahmininde, önerdikleri düzenlenmiş LSTM-GRU modelinin mevcut GRU ve LSTM ağ modellerinden üstün olduğunu belirtmektedir. Mehtab vd. (2021), NIFTY 50 zaman serisinin bir sonraki hafta değerini tahmin etmek için girdi olarak bir hafta önceki verileri kullanarak, LSTM tabanlı tek değişkenli modelin en doğru model olduğunu açıkça göstermektedir. Yürük (2021), yapay sinir ağları yöntemi ile zaman seri analizi yapmakta, ele aldığı hisse senedi değerlerini etkilemede önemli olan 5 bağımsız değişkeni kullanarak yüksek performanslı sonuçlar elde etmektedir. Gao vd. (2021), hisse senedi tahmininde LSTM ve GRU modellerinin eşit performans sağladıklarını göstermektedir.

İki veya daha fazla bireysel modelin avantajlarını bir araya getiren hibrit modellere ilişkin birçok çalışma mevcut olup, Wedding ve Cios (1996), radyal bazlı fonksiyon ağlarını kullanarak zaman serisi tahminlerini üretmekte, çıktılarını tek değişkenli Box-Jenkins modelleriyle birleştirmektedir. Çalışmaları, bu kombinasyon yaklaşımının zaman serisi tahmininin genel güvenilirliğini iyileştirdiği göstermektedir. Luxhoj vd. (1996) altı aylık satış tahmini için ekonometrik modellerin yapısal özelliklerini, sinir ağlarının doğrusal olmayan örüntü tanıma özellikleriyle entegre ederek bir melez modelleme yaklaşımı kullanmaktadır. Donaltsan ve Kamstra (1997), yapay sinir ağı literatürüne dayalı yarı parametrik doğrusal olmayan bir genelleştirilmiş otoregresif koşullu değişen varyans modeli oluşturmakta ve örnek içi ve örnek dışı karşılaştırmalar, modelin diğer oynaklık modelleri tarafından gözden kaçırılan etkilerini yakaladığını ve başarılı örnek dışı oynaklık tahminleri ürettiğini ortaya koymaktadır. Doseuky ve Kateb (2000), yük talep trendi analizinde hem yapay sinir ağları hem de hibrit bütünlük otoregresif hareketli ortalama ve yapay sinir ağları modellerini kullanıp, tahmin sonuçlarının umut verici olduğunu belirtmektedir. Tseng vd. (2002), mevsimsel zaman serisi tahminleri için sezonsal bütünlük otoregresif hareketli ortalama ve geri yayılım algoritmalarını birleştiren hibrit bir tahmin modeli önermektedir. Dunis ve Huang (2002), döviz kuru oynaklığının tahmini için parametrik olmayan sinir ağı regresyonu ve tekrarlayan sinir ağı modelleri ve bunların kombinasyonunu ele alarak, genelleştirilmiş otoregresif koşullu değişen varyans model alternatif sonuçlarına karşı kıyaslamakta, dikkate alınan dönem ve para birimleri için döviz opsiyon piyasasının etkin olmadığını ve piyasa katılımcıları tarafından uygulanan fiyatlandırma formüllerinin yetersiz olduğunu, bu nedenle sonuçların iyileştirmede başarısız olduğunu belirtmektedir. Zhang (2003) çalışmasında, bütünlük otoregresif hareketli ortalama ve yapay sinir ağları hibrit modelini kullanarak farklı veri setleri üzerinde uygulamalar ortaya koymaktadır. Kim ve Lee (2004), çalışmasında hisse senedi fiyat endeksi yönünü tahmininde optimum özellik dönüşümü için yapay sinir ağları ve genetik algoritmaların birlikte çalıştığı melez bir modeli önermektedir. Yu vd. (2005), tahmin performanslarını iyileştirmek ve daha doğru tahmin sonuçları elde edebilmek için yapay sinir ağları ile genelleştirilmiş doğrusal otoregresyonu birleştirerek doğrusal olmayan yeni bir hibrit tahmin modeli önermektedir. Conejo vd (2005), gün öncesi elektrik fiyatlarını tahmin etmek için dalgacık (wavelet) dönüşümlü bütünlük otoregresif hareketli ortalama modellerini kullanmaktadır. Hassan vd. (2007), gizli markov model, yapay sinir ağları ve genetik

algoritmalarını birleştirerek hisse senedi fiyatının bir sonraki gündeki değerini tahmin eden bir model oluşturmaktadır. Zhou ve Hu (2008), gri ilişki analizi ve Box-Jenkins metotlarına dayanan hibrit model tahmin yaklaşımını önermektedir. Khashei vd. (2008), eksik veri setleri ile analiz yaparken yapay sinir ağları ve bulanık regresyon yöntemlerini kullanmakta ve modelin tahmin doğruluğunu iyileştirmenin etkili bir yolu olabileceğini göstermektedir. Tseng vd. (2008), türev menkul kıymetlerin fiyatının tahmin kabiliyetini yükseltmek için hibrit asimetric oynaklık yaklaşımını, yapay sinir ağları modeline entegre etmekte, yöntem eş zamanlı olarak hata terimi dizisinin doğrusal olmayan ve stokastik yapısını başarılı bir şekilde yakalayabilmektedir. Aladağ vd. (2008), çalışmalarında, elman tekrarlayan sinir ağları ve sezonsal bütünleşik otoregresif hareketli ortalama modelleri ile yeni bir hibrit yaklaşım önermekte, ele alınan veriler oldukça sınırlı sayıda olmasına rağmen uygulama sonuçları içerisinde hibrit metodun en başarılı olduğunu kanıtlamaktadır. Lai vd. (2009), Tayvan borsasındaki hisse senetleri için bulanık karar ağacı mekanizması oluşturmakta, karar ağacının optimizasyonu için genetik algoritma kullanarak, önerilen model ile %82'lik başarı performansı sağlamaktadır. Tsai ve Wang (2009), hisse senedi tahmini için karar ağaçları ve yapay sinir ağlarını birlikte kullanarak, bireysel modellerden daha yüksek olan %77 doğruluk oranını elde etmektedir. Wang (2009), bulanık eşik değerli genelleştirilmiş otoregresif koşullu değişen varyans modeli ile türev menkul kıymet fiyatlarının tahmin yeteneğini geliştirmekte, çalışması yüksek tahmin edilebilirlik sağlandığını vurgulamaktadır. Bildirici ve Ersin (2009), İMKB'de günlük getirilerin güçlü oynaklık kümelenmesi, asimetri ve doğrusal olmama özelliklerini gösterdiği için, genelleştirilmiş otoregresif koşullu değişen varyans ailesi modellerini ele alınarak yapay sinir ağları ile zenginleştiren yeni bir hibrit modeli önermektedir. Koutroumanidis vd. (2011), zaman serisinin öngörülen değerleri için güven aralıklarının oluşturulmasını amaçlamakta, tahmin için ham verilere yapay sinir ağları modelini uyguladıktan sonra bootstrap yöntemiyle tahmini gerçekleştirmekte, tahmin doğruluğu için tatmin edici sonuçlar elde etmektedir. Hajizadeh vd. (2012), üstel genelleştirilmiş otoregresif koşullu değişen varyans ve ileri beslemeli ağ modelini birleştiren iki tür hibrit model sunmakta, hibrit model, tek bir ekonometrik model ve tek bir yapay sinir ağı modelinden daha iyi sonuçlar göstermektedir. Wang vd. (2012), üstel yumuşatma, otoregresif hareketli ortalama süreci ve geri yayılım sinir ağını birleştiren hibrit bir yaklaşım modeli oluşturmakta ve eşit ağırlıklı hibrit model ve rastgele yürüyüş modeli dahil tüm geleneksel modellerden daha iyi performans

gösterdiğini ortaya koymaktadır. Hocoğlu vd. (2015), yapay sinir ağları ve regresyon yöntemlerini birlikte kullanarak oluşturdukları hibrit model sonucunda elde edilen hata sonuçları kıyaslamaya, hibrit model ile minimum hata sonucuna ulaşmaktadır. Mabu, Obayashi ve Kuremoto (2015), hisse senedi piyasalarında alım-satım kararlarını verebilmek için kural tabanlı bir evrimsel algoritma ile çok katmanlı algılayıcıları birleştirmekte, bileşik öğrenme mekanizmasının kullanımını önermektedir. Nayak, Mishra ve Rath (2015), çalışmalarında destek vektör makinaları ve K-en yakın komşu yaklaşımını kullanarak borsa endeks verilerinin tahmini için hibrit bir yöntem sunmakta, aynı zamanda eğilimi, volatilitiyi ve momentumu da ele almaktadır. Patel vd. (2015), borsa endekslerinin gelecekteki değerlerini öngörmek için iki aşamalı bir yöntem önermekte, birinci aşamasında, destek vektör makinalarını kullanılırken, ikinci aşamada ise yapay sinir ağları, random forest ve destek vektör makinalarını birlikte kullanmaktadır. Mingyue, Cheng ve Yu (2016), gelecekte borsa endeksi trendinin tahmin doğruluğunu iyileştirmek için, genetik algoritmaları kullanarak, yapay sinir ağları modelini optimize etmektedir. Deng (2017), önerdiği yöntemde emtia piyasası fiyatları için derin doğrudan güçlendirme yöntemini bulanık mantık ve tekrarlayan sinir ağları ile beraber kullanmaktadır. Lin vd. (2017), zaman serilerindeki trendi tahmin etmek için baştan sona yeni bir hibrit sinir ağı olan TreNet'i önermektedir. TreNet, zamansal bağımlılığı yakalamak için uzun-kısa süreli bellek mimarisini kullanmakta, sonuçlarında birçok modeli geride bırakarak etkinliğini göstermektedir. Milačić vd. (2017), gayri safi yurtiçi hâsıla büyüme oranını tahmin etmek için aşırı öğrenme makinesi ile yapay sinir ağını birlikte uygulamaktadır. Yıldız vd. (2017), ticari bina elektrik yükü tahmininde önerdikleri bayes düzenleme geri yayılım sinir ağı algoritmasının genel olarak başarılı olduğunu vurgulamaktadır. Hu ve Chen (2018), uzun-kısa süreli bellek, histerik aşırı öğrenme makinesi ve diferansiyel evrim algoritmasını birleştirerek, rüzgar hızının tahmin performansını iyileştirmeyi amaçlayan yeni bir doğrusal olmayan hibrit model kullanmakta, diğer modellerle karşılaştırılıp, önerilen modelin üstünlüğünü tam olarak göstermektedir. Liu vd. (2018), rüzgar enerjisinin planlanması, programlanması ve bakımı için çalışmalarında, varyasyon modu ayrıştırma, tekil spektrum analizi, uzun kısa süreli bellek ağı, aşırı öğrenme makinesini birleştirilerek yeni bir rüzgar hızı çok adımlı tahmin modeli önermekte, modelin trend bilgilerinin çıkarılmasında daha etkili ve sağlam olduğu savunulmaktadır. Kim ve Won (2018), Önerdikleri modelde, hisse senedi oynaklığını tahmin etmek için, bir sinir ağı modelini yalnızca tek bir ekonometrik model yerine çoklu ekonometrik modellerle



birleştirek mevcut literatürün tahmin performansını önemli ölçüde arttırmaktadır. Qi vd. (2019), hava kirliliği ile ilgili çalışmalarında, grafik evrimsel ağları ve uzun kısa vadeli bellek ağlarına entegre eden derin öğrenme yöntemlerine dayalı bir hibrit model önermekte, bu metodolojinin, gelecekte farklı hava kirleticilerinin konsantrasyon tahmini için kullanılabilir olduğunu göstermektedir. Sheng ve Jia (2020), sezonsal ve dışsal değişkenli bütünleşik otoregresif hareketli ortalama, uzun-kısa süreli bellek modellerini ve hibrit yöntemlerini kullanarak tahminler gerçekleştirip, hibrit modelin en büyük tahmin gücüne sahip olduğunu belirtmektedir. Somu vd. (2020), doğru ve sağlam bina enerji tüketimi tahmini için uzun kısa süreli bellek ağları ve gelişmiş sinüs kosinüs optimizasyon algoritması kullanan bir enerji tüketimi tahmin modeli olan, ISCOA-LSTM ile istikrarlı ve doğru tahmin sonuçlarının üretildiğini ve bu nedenle enerji tüketimi tahmin problemlerini çözmek için verimli bir araç olarak kullanılabileceğini göstermektedir. Metin vd. (2020), yapay sinir ağları ve genelleştirilmiş otoregresif koşullu değişen varyans ailesi modellerini kullanarak petrol fiyatlarındaki oynaklığı ele almakta, tahminler karşılaştırıldığında, en iyi performans değerlerine çok değişkenli genelleştirilmiş otoregresif koşullu değişen varyans model sınıfına ait olan dinamik koşullu korelasyon modeli ve çok katmanlı algılayıcı modeller tarafından oluşturulan model yapısı ile ulaşıldığını belirtmektedir. Temür vd. (2021), bütünleşik otoregresif hareketli ortalama, uzun-kısa süreli bellek ve bu iki modelden elde ettikleri hibrit model ile gerçekleştirdikleri çalışmada en iyi tahmin sonucunu hibrit modelden elde etmektedir. Prajapati vd. (2021), zaman serisi tahmin yöntemlerinin, bir salgının yayılmasını tahmin etmede kritik bir rol oynadığını belirterek, çalışmalarında uyguladıkları bütünleşik otoregresif hareketli ortalama ve doğrusal olmayan otoregresyon sinir ağı hibrit kombinasyonunun, seçilen modeller arasında azaltılmış bir RMSE ile en iyi sonucu verdiğini ve bunun en yaygın zaman serisi tahmin yöntemlerinden neredeyse %35,3 daha iyi olduğunu kanıtlamaktadır. Wang vd. (2021), çalışmalarında günlük yeni salgın vakalarını tahmin etmek için hareketli ortalama modelleri ve genelleştirilmiş regresyon sinir ağı modelleri ile hibrit model kurup performanslarını değerlendirmekte ve hibrit modelinin en iyi tahmin performansına sahip olduğunu raporlamaktadır. Yılmaz ve Buyrukoğlu (2021), araştırmalarında, COVID-19 salgın vakalarını tahmin etmek amacıyla geri yayılım tabanlı yapay sinir ağı, korelasyonlu toplamsal model ve otoregresif entegre hareketli ortalama modellerinden oluşan yeni bir özelleştirilmiş hibrit model geliştirilmektedir. Bhattacharyya vd. (2022), günlük COVID-19 salgın vakalarının doğrusal ve durağan

olmadığını, bu nedenle, pandeminin gelecekteki tahmini için tek bir spesifik modelin ideal olmayacağını belirtip, Theta yöntemi ve otoregresif sinir ağı modeline dayalı yeni bir hibrit yaklaşım geliştirmekte, önerilen yöntemin, ortalama olarak test veri kümeleri için geleneksel tek değişkenli ve hibrit tahmin modellerinden daha iyi performans göstermektedir.

Tezin genel amacında, hisse senetleri fiyat hareketlerinin tahmininde başarı olasılığını arttırmada etkisini gözlemlemek için hibrit modeller oluşturulmakta ve sonuçlar kıyaslanmaktadır. Bu amaç doğrultusunda tez 6 bölümden oluşmaktadır. Giriş bölümünde finansal yatırım ve hisse senetleri ve kullanılan terimler konusunda genel bilgiler yer almaktadır. 2. bölüm hisse senetleri fiyat hareketleri verilerini de içeren zaman serisi modelleri ele alınmakta, doğrusal ve durağan yapıdaki zaman serisi modelleri için kullanılan ARIMA modellerine yer verilmektedir. 3. bölüm yapay zekâ, makine öğrenmesi, derin öğrenme ve bu modeller arasında zamansal ilişkiyi dikkate alan derin öğrenme yöntemlerinden LSTM ve GRU modelleri açıklanmaktadır. Sonraki bölümde model performansının değerlendirilmesine yönelik metriklerin yer almakta olup sonuç bölümünde borsa İstanbul'da işlem gören XBANK banka endeksinin gelecek tahmini için, derin öğrenme kapsamında LSTM ve GRU modellerinin başarı performansını arttırmak amacıyla, ekonometrik modeller kapsamında ARIMA modeli ve teknik analizde kullanılan göstergelerin de kullanımı ile oluşturulan hibrit modellerin uygulama sonuçları verilmektedir.

## 1. YATIRIM VE HİSSE SENETLERİ

Yatırım, tasarrufların gelir sağlamak amacıyla değerlendirilmesidir. Yatırımcının bugünkü ihtiyaç fazlası tüketimlerinden vazgeçip yatırım yaparak, parasının değerini korumak ya da gelecekte daha fazlasını elde etmek istemektedir. Bu anlamda yatırımcı, bugün aldığı yatırım kararında beklentilerini zaman boyutunda değerlendirmektedir.

Yatırımcının yaşam tarzı, ekonomik özgürlüğü, risk alma konusunda tutumu ve yatırım hedefi yatırım tercihlerini şekillendirmektedir. Finansal yatırımlar, finansal araçlara yapılmakta olup, bu araçlardan hisse senetleri tercih edildiğinde, alacak hakkı veren senetler ve ortaklık hakkı veren senetler olmak üzere iki türden oluşmaktadır (Karan, 2001).

Finansal alanda yatırımlarda, kar payı getirisi elde etmek amacıyla, yatırım tercihi olarak fonların mal ve hizmet alımı dışında fonların başka alanlara bağlanması söz konusu olmaktadır (Gündoğdu, 2018).

Her tür yatırım kararının alınmasında olduğu gibi finansal varlıklara yapılan yatırımlarda da yatırımcı rasyonel davranmaktadır. Bu davranışında beklenti ve içgüdülerini dikkate alarak karar veren yatırımcı, aynı zamanda matematiksel hesaplamaları dikkate alarak, geçmiş dönem verilerini değerlendirerek ve daha önceki hatalarını tekrarlamayarak kararında başarı olasılığını arttırmaktadır. Yatırımcı, yatırımından doğacak bütün riskleri üstlenmekte, aynı zamanda riskleri en aza indirmeye çalışırken, kendi öz sermayesini en üst seviyede tutmaya çalışmaktadır (Bekçioğlu, 1983).

Kökene çiftçilerin ürün fazlalarını daha sonraki ihtiyaçlarını karşılamak amacıyla değiş tokuş yapmasına dayanan finansal piyasalar, günümüzde kaynak ihtiyacı olan girişimciler ile birikim sahibi yatırımcıların bir araya gelip kaynak alışverişi sağladıkları yapılardır (Levinson, 2007). Ekonominin temelini oluşturan finansal piyasalar tasarruf sahibi ve borç alanlara likidite sağlamak, bilgiye erişimi sağlamak ve risk paylaşımını sağlamak olan 3 temel işlevi yerine getirmektedir (Atıcı, 2018).

Ülkelerin ekonomik olarak kalkınmasında tasarruf stokunun önemi oldukça büyüktür. Finansal piyasaların gelişmiş olduğu ülkelerde yatırımcıların finansal

varlıklara yapmış olduğu yatırımlar da paralel olarak artmaktadır. Finansal libelleşme ve ulusal finans piyasaları üzerindeki denetim kalkması, uluslararası sermaye hareketlerinin serbestleşmesi, faiz oranlarının da artması ile birlikte tasarruf yapma eğiliminde artışla sonuçlanmaktadır (Altay, 2002). Teknolojinin de katkısıyla finansal piyasaları birbirine yakınlaştıran bu oluşum günümüzde finansal piyasa ortamını telefon, internet gibi farklı iletişim kanallarına taşımaktadır. Bu bağlamda bir araya gelmek aslında fiziksel anlamdan öte alım-satım kararlarının birlikteliği anlamına gelmektedir.

Hisse senetleri yatırım tercihi olarak finansal piyasalarda en çok rağbet gören finansal varlıklar arasında yer almaktadır. Tez kapsamında da konu olarak tercih edilmesinden dolayı hisse senetleri ve özellikleri üzerinde durulacaktır.

Literatürde pay senedi, esham veya aksiyon olarak da adlandırılan hisse senetleri, anonim şirketler, sermayesi paylara bölünmüş komandit şirketler veya kanunla kurulan iktisadi teşekküller tarafından ihraç edilen, ihraç eden ve satın alan arasında bağ kuran sermayelerinin birbirine eşit olan paylarından bir parçası olup, sahibine ortaklık hakkı veren, kanuni şekil ve şartlara uygun olarak düzenlenmiş hukuken kıymetli evrak hükmünde bir belgedir (Münyas, 2018). Türkiye’de Sermaye Piyasası Kurulu tarafından sadece anonim şirketleri tarafından hisse senetlerinin ihracına izin verilmektedir.

Yatırımcılar hisse senetlerini satın alarak iki farklı şekilde kar elde etme amacıyla olabilmektedir. İlk olarak satın aldıkları hisse senetlerinin zaman içindeki fiyat değişiminden kazanç sağlama amacıyla olabilmekte ya da satın alınan hisse senedi ortaklık hakkı sağlamasından dolayı, şirketin yıl bitiminde sermayeye katkıda bulunan ortaklarına dağıttığı şirket karından pay alma hakkına sahip olabilmektedirler.

## **1.1.Hisse Senedi Analiz Yöntemleri**

Finansal piyasalarda hisse senetlerinin fiyat hareketlerinden yararlanarak alım-satım kararı veren yatırımcılar, seçmiş oldukları hisse senetlerini takip ve analiz etmektedirler. Hisse senedi analizi yapılırken yatırımcılar şirketin karlılığı, yapmış olduğu yatırımlar, sektör ve ekonominin durumu ve geçmiş dönem fiyat hareketleri gibi birçok kriteri dikkate almaktadır.

Günümüzde gelişen finansal piyasalarda işlem yapmak için birçok analiz yöntemi bulunmakla beraber, sıklıkla kullanılan en önemli analiz teknikleri, temel analiz ve teknik analiz olarak 2 farklı yaklaşımla ele alınmaktadır.

### **1.1.1. Temel Analiz**

Temel analiz, hisse senedi fiyatını etkileyen bir takım finansal rasyoları, şirketlerin halka açık mali tablolarını, iş kolu ve sektör verilerini ve makroekonomik göstergeleri kullanılarak işletmenin değerlendirilmesi ve hisse senedinin gerçek değeri belirlenmesine ilişkin analizleri içermektedir (Uyar, 2001).

Temel analiz yapılırken şirket ile ilgili tüm bilgileri analiz kapsamına alınmasında şirketin faaliyet yapısı, muhasebe verileri gibi unsurların yanı sıra sektörün koşulları, ekonomik gelişmeler, uluslararası ilişkilere kadar çeşitli siyasi ekonomik ve dışsal faktörler incelemeye dâhil edilmektedir (Şahin, 1992).

Temel analizde bilanço ve gelir tablosu verileri kullanılarak, şirketin temettü politikası ve sermaye yapısına bağlı analizlerle çeşitli finansal rasyolara elde edilmekte, bu rasyolar ışığında şirketin şu anki durumu ortaya konulurken geleceğe dayalı değer tahminlerde bulunmaktadır (Berk, 1998).

Temel analiz ile yatırımcı, piyasa hareketlerinin altında yatan nedenlere odaklanmakta, tercih ettiği yatırım aracına ilişkin bilgileri edinerek gündem ve piyasa koşulları ışığında beklentileri yorumlamakta, analizleri sonuçlarına göre alım-satım kararı almaktadır.

Hisse senedi piyasasında temel analiz uygulaması ilk olarak ekonomi analizi ile başlamaktadır. Milli gelir, enflasyon, döviz kuru, dış ticaret açığı gibi ekonomideki değişimler sektörlerin dolayısıyla da şirketlerin karlılığını etkilemektedir. Bu nedenle ekonomik değişimlere göre hisse senedinden beklenen getiri olasılığı değişmektedir. Ardından işletmelerin faaliyet gösterdiği sektörün analizi incelenmektedir. Şirketler faaliyette bulunduğu sektörde konjonktürel dalgalanmalara karşı aşırı duyarlı olmaktadır. Hisse senedi yatırımcıları sektörlerin içinde buldukları durgunluk ve canlılık dönemlerini dikkate alarak yatırım kararlarını şekillendirmektedir. Genel ekonomi ve sektör koşulları incelendikten sonra son olarak şirket analizi ile şirketin gelecek yıllardaki olası kar ve zarar durumu tahmin edilerek yatırım kararı

alınmaktadır. Şirket analizi yaparken, şirketin hukuki durumu, mali durumu, ortaklık yapısı, üretim yapısı, karlılık durumu gibi faktörler dikkate alınarak şirketin finansal tabloları analiz edilir ve geleceğe yönelik tahminler elde edilmekte, elde edilen tahmin piyasa fiyatı ile karşılaştırılarak alım-satım kararı verilmektedir.

### 1.1.2. Teknik Analiz

Dow teorisi 19. Yüzyılın sonlarında The Wall Street Journal'ın editörü Charles Dow tarafından ortaya atılmış olup, yayınlamış olduğu makalelerin derlenmesi ile modern teknik analizin temellerini oluşturmaktadır (Özçam, 1996). Oldukça eski bir teori olmasına karşın günümüzde sıklıkla kullanılmakta ve birçok yöntemin geliştirilmesinde katkı sağlamaktadır. Dow teorisi'ne göre hisse senetlerinin büyük çoğunluğu piyasada genel eğilimleri takip etmekte olup, bu eğilimlerin tahmin etmeye çalışarak doğru pozisyonların alınması amaçlanmaktadır.

Teknik analiz, finansal piyasalardaki geçmiş fiyat hareketleri kullanılarak ve belirli analiz yöntemlerine göre yorumlanarak, gelecekteki fiyat hareketlerinin yönünün belirlenme çabası olarak tanımlanmaktadır (Gündoğdu, 2018).

Çeşitli kaynaklarda piyasa analizi, görsel analiz veya grafik analizi olarak da adlandırılan teknik analizde, ele alınan hisselerin fiyat hareketlerine bakarak bu hisselerin ne yaptığını ve gelecekte ne yapacağını tahmin etmekte kullanılan çalışmalardan oluşmaktadır (Murphy, 1998).

Teknik analiz, fiyat hareketlerine neden olabilecek tüm temel bilgilerin ve ekonomik faktörlerin zaten fiyatlara yansıdığını varsayımına dayanmaktadır. Ayrıca hisse senedi fiyatları psikolojik faktörlerden de oldukça etkilenmektedir. Bu nedenle teknik analizde, oluşan fiyat hareketlerinin piyasa hakkında her şeyi söylediği düşünülmekte ve tüm bu ölçülemez faktörleri göz ardı edilmektedir. Analiz kapsamında ekonomik koşullar ve finansal raporlarla ilgilenmek yerine fiyat ve hacim ilişkisine odaklanılmaktadır. Kısaca temel analiz fiyat hareketlerinin sayısız nedenleri ile ilgilenirken, teknik analiz fiyatın nasıl hareket ettiğine odaklanır ve gelecekteki hareketine yönelik çıkarımlarda bulunmaktadır. Bu bağlamda temel ve teknik analiz, aynı sorunu çözmek için probleme değişik yönlerden yaklaşan analiz yöntemleri olarak karşımıza çıkmaktadır.

Teknik analizinin temel ilkeleri arasında öncelikle, fiyatın arz ve talep dengesi tarafından belirlendiğini varsaymaktadır. Piyasada insan davranışları rasyonel olup, beklentiler doğrultusunda hareket etme eğilimi mevcutken, temel ekonomi teorisinde olduğu gibi, piyasada talebin artması fiyatı yükseltmekte, talebin azalması fiyatları düşürmektedir.

Hisse senedi fiyatları küçük dalgalanmaların etkileri dışında trendlerle hareket etme eğilimde olup, yatırımcılar yükseliş trendinin başladığında düşük bir fiyattan satın alma eğilimde iken, trend sonunda yüksek bir fiyatla hisse senetlerini satmak istemektedir.

Teknik analizde, piyasa hakkında bilinen her şeyin fiyatlara zaten yansıdığını görüşü hâkim olmaktadır. Bu varsayıma göre ekonomik, politik, psikolojik tüm bilgiler zaten fiyatlarda etkisini göstermektedir.

Teknik analizin başka bir varsayımına göre tarih kendini tekrarlama eğiliminde olup, yatırımcılar benzer koşullarda geçmişteki gibi benzer şekilde davranma eğilimi göstermektedir. Benzer davranış biçimleri ise tahmin edilebilir sonuçlara sebep olacağından, teknik analizde fiyat hareketlerinin grafiklerinde yinelenen kalıpların aranması söz konusu olmaktadır.

Teknik analiz psikolojik faktör ve duygulardan oldukça etkilenmektedir. Bir hisse senedine yatırım yapan ve kazanç sağlayan yatırımcılar psikolojik olarak kazanma hissini verdiği mutluluğu tekrarlamak istemekte ve tekrar aynı yatırımı yapma hatta çevresindeki herkese önerme eğilimine girmektedir. Birbirine bağımlı olarak devam eden bu hareketler fiyatların aşırı yükselmesine neden olmakta fakat zamanla ortalamaya dönme eğilimi ile sonuçlanmaktadır. Bu eğilim tersi için de geçerli olmaktadır.

Arz ve taleplerdeki değişimler çizgilerle tespit edilebileceği gibi grafik desenleri de kendini tekrarlama eğiliminde olmaktadır.

Yatırımcılar hisse senetlerinin seçimi konusunda temel analizi dikkate alsalar bile fiyatlara ilişkin trenlerin dönüş hareketlerini belirlemek gibi piyasaya ilişkin alım-satım zamanlamasını yakalamak için teknik analize sıklıkla başvururlar. Bu yararı

alım-satım kararı vermenin yanı sıra yatırımcılara oluşabilecek kayıplara karşı öngörü tahmini sağlayarak korunma ve risk kontrolü konusunda etkili bir çözüm sunmaktadır.

Teknik analize ilişkin yöneltilen eleştiriler de mevcuttur. Fiyat değişikliklerinin rasgele, serisel olarak bağımsız ve tahmin edilemez olduğu, geçmiş fiyat hareketlerinin gelecekteki fiyat yönünün güvenilir bir göstergesi olmadığını savunan rasgele yürüyüş teorisi fikri eleştirilerin çıkış noktasını oluşturmaktadır. Köklerini etkili piyasalar hipotezine dayanan diğer bir eleştiri ise fiyatları etkileyecek her türlü bilginin, piyasaya anında yansıtacağı düşüncesidir. Fakat piyasada yatırımcılar her zaman rasyonel hareket etme eğiliminde değildir ve piyasanın farklı düzeylerde etkinliği söz konusudur.

Teknik analiz yapılırken trendleri belirlemek ve oluşumları gözlemlemek zordur. Teknolojinin ilerlemesi ile birlikte bilgisayar kullanımı her alanda olduğu gibi finans alanında da etkisini göstermektedir. Bu ilerleme ile birlikte belirli bir dönemdeki fiyat ve işlem hacmi verileri kullanılarak yeni grafiklerin çizilmesi, yorumlanması ve geçmiş fiyat hareketlerindeki tekrarlama eğiliminde olan formasyonları saptanması için formüller kullanılarak yapılan analiz yönteminde teknik göstergeler/indikatörler kullanılmaktadır. Teknik göstergeleri kullanmanın temel amacı, piyasalarda ve kullanılan araçlarda oluşan trendin yönü ve gücünü belirlemektir. Bununla birlikte hisse senedinin aşırı alı veya satışı bölgelerini tespit etmek ve destek ve direnç bölgelerini saptamakta sıklıkla göstergelerden yararlanılmaktadır.


Teknik göstergeler sağladıkları fayda açısından 4 grupta sınıflandırılmaktadır. İlk olarak momentum göstergeleri, belirli bir zaman diliminde hisse senedi fiyatlarındaki değişimi ölçmekte kullanılmaktadır. Trend göstergeleri hisse senedi fiyatlarındaki eğilimin fark edilmesi ve ne kadar devam edeceğini tahminlemek için tercih edilmektedir. Oynaklık göstergeleri, fiyat hareketlerinin aralığını ve bu aralıktaki dalgalanmaların şiddeti hakkında bilgi vermektedir. Son olarak, güç göstergeleri, piyasanın gücünü ölçerken diğerlerinden farklı olarak parasal hacimleri dikkate almaktadır.

Teknik analizin varsayımları doğrultusunda fiyat hareketlerini inceleyebilmek için çeşitli göstergeler kullanılmaktadır. Bu araçlardan hangisi ya da hangilerinin kullanılacağına karar, amaca, yatırımın vadesine, piyasanın türüne ve uygulayıcının tercihlerine göre değişmektedir. Teknik analiz yöntemi çerçevesinde en sık kullanılan



indikatörler arasında, Hareketli Ortalamalar, MACD (Hareketli Ortalama Yakınlaşma ve Uzaklaşma Göstergesi), Göreceli Güç Endeksi, Momentum, Bollinger Bantları ve Stokastik göstergeleri sıralanabilmektedir.


Hareketli ortalamalar, geçmişe yönelik belirli sayıda fiyat verisinin ortalaması alınarak üretilen zaman serileri olup, hisse fiyatları değiştikçe ortalama fiyatlar da aşağı- yukarı yönde hareket etmektedir (Yaslıdağ, 2021). Cari fiyatın geçmişe yönelik ortalamadan farkı dikkate alınmakta ve fiyat değişkenliğini daha düzgün bir çizgiye indirdiği için trendin ne yönde değişmekte olduğu daha rahat bir şekilde görülmekte, böylece alım satım kararlarına yardımcı olmaktadır. Hareketli ortalamalar sadece trendin yönünü göstermekle kalmayıp, alternatif hisse senetlerinin analizi ile karşılaştırıldığında trendin eğilimini dikkate alarak seçim yapmayı kolaylaştırır bu da trendin gücünü yansıtmaktadır. Bu gösterge uygulanırken kaç günün fiyat ortalamasının ele alınacağı yatırımcının tercihine ve deneyimlerine göre değişmektedir. Ele alınan periyot kısa vadeli olduğunda, fiyat değişikliklerine verilen tepki hassasiyeti de doğru orantılı olarak artmaktadır. Farklı periyotlara ilişkin hareketli ortalama verileri aynı grafikte birlikte kullanılabilir.



**Şekil 1. BIST Banka Endeksi Kapanış Fiyatları 20 Günlük Basit Hareketli Ortalaması**

Şekil 1’de BIST Banka Endeksine ait kapanış fiyatlarının basit hareketli ortalama grafiği verilmekte olup, hareketli ortalamalar, basit, ağırlıklı ve eksponansiyel olarak hesaplanabilmekte, genellikle 5 ile 20 günlük süre baz alınmaktadır. Basit ortalamalar dikkate alınan süre içerisinde tüm günlere eşit önem verirken ağırlıklı ve eksponansiyel hareketli ortalama da son günler yada yoğun volatiliteye sahip günler daha fazla ağırlıklandırılmaktadır.

Hesaba katılan günlerin aynı ağırlıkta olduğu, fiyatların aritmetik ortalaması ile hesaplanan basit hareketli ortalamalar, hem işlem kolaylığı hem de verdiği iyi sonuçlardan dolayı sıklıkla kullanılmakta olup, hisse senedinin son  $x$  gündeki fiyatlarının toplanıp,  $x$  sayısına bölünmesi ile elde edilmektedir. Ağırlıklı hareketli ortalamada, dönem içinde eskiden başlanarak ilk veri 1, 2. Veri 2 son veri ise  $x$  ile çarpılarak ağırlıklandırıldıktan sonra toplanmakta ve  $x(x + 1)/2$ 'ye bölünerek her gün için hesaplanmaktadır. Eksponansiyel hareketli ortalamada ise ağırlık değeri  $k = 2/(x + 1)$  bulunmakta, daha sonra  $F_i$  hisse senedinin  $i$  günündeki değeri,  $EHO_i$ , , günündeki eksponansiyel hareketli ortalama değerini göstermek üzere;  $EHO_i = (k * F_i) + ((1 - k) * EHO_{i-1})$  formülü ile hesaplanmaktadır.



**Şekil 2. BIST Banka Endeksi Kapanış Fiyatları RSI İndikatörü**

Şekil 2'de zaman serisi grafiği verilen göreceli güç endeksi (Relative Strength Index/ RSI), bir güç osilatörüdür ve eğilimdeki terslikleri bir araya getirmeye çalışmaktadır (Welles - Wilder, 1978). Piyasadaki fiyat hareketlerindeki değişimin hem hızını hem de oranını ölçerken, hesaplamada belirtilen dönemdeki günlere ait düşüşler ve yükselişler ayrı ayrı toplanıp ortalaması alınarak, şu anki fiyat seviyesi ile karşılaştırılmaktadır (Hari - Dewi, 2018). Bu nedenle gösterge, geçmiş dönem fiyatının talebi karşılama gücünü dikkate alarak bugünkü dönemde taleplerin yaratacağı etkiyi kestirebilmektedir. RSI hesaplanırken genellikle, 9, 14, 25 günlük hesaplamalar kullanılmaktadır ve 0 ile 100 arasında yer alan endeks, 80 üzerinde iken yükselen piyasaları, 20'nin altında ise düşen piyasaları işaret etmektedir. Güçlü trendler sırasında, RSI uzun süreler boyunca aşırı alımda veya aşırı satımda kalabilmektedir. Ayrıca, pozitif momentum hızlanırken bir kırılmada o hisse senedini satın almak, negatif momentum hızlanırken bir kırılmada hisse senedini satmak yatırımcıya kar

sağlayacağından, RSI bir hisse senedinin fiyatının negatif ya da pozitif momentumda nasıl seyrettiği ve bu momentumun hızlanıp yavaşladığı hakkında yeterli bilgiyi sağlamaktadır.

Ele alınan gün sayısı azaldıkça, RSI daha değişken olmakta ve daha sık aşırı uç noktalar oluşturmaktadır, daha uzun vadeli bir RSI daha fazla yuvarlanıp, çok daha az dalgalanmaktadır.


RSI değeri, ortalama kazancın sayısı ve boyutu arttıkça yükselmekte, ortalama kaybın sayısı ve boyutu arttıkça düşmektedir. Formül sonucu seri yumuşamakta olup, güçlü bir trend olan bir piyasada 100 veya 0'a yakın salınım göstermektedir.

14 günlük bir periyod dikkate alındığında, 14 gün boyunca gerçekleşen ortalama kazanç hesaplanıp ve 14 gün boyunca gerçekleşen ortalama kayba bölünmekte ve daha sonra RSI değeri aşağıdaki formülden elde edilmektedir.

RS = Seçilen t Zaman İçin Ortalama Kazanç / Ortalama Kayıp

$$RSI_1 = 100 - \left[ \frac{100}{1+RS} \right] \quad (1.1.2.1)$$

Hesaplama kullanılan RS değerinin pozitif olması gerektiğinden, formülden, kayıplarının olduğu dönemlerde 0 değeri kullanılmaktadır.




**Şekil 3. BIST Banka Endeksi Kapanış Fiyatları Momentum İndikatörü**

Şekil 3'te momentum göstergesine ait zaman serisi grafiği verilmekte olup, momentum belirli bir dönem içerisinde fiyatların yüzde kaç değiştiğini gösteren, fiyatlardaki yükseliş ve düşüşün hızını dikkate alan bir göstergedir. Fiyat hareketleri incelendiğinde, fiyatların önce hızla yükselme eğiliminde olduğu, belirli bir noktaya ulaştıktan sonra yükselişin yavaşladığı ve momentum yitirmeye başladığı daha sonra bir noktadan dönerek düşüşe geçtiği görülür. Dolayısıyla gösterge zirvede sat, dipte al mantığı ile çalışmaktadır.



#### Şekil 4. BIST Banka Endeksi Kapanış Fiyatları Bollinger Bantları İndikatörü

Şekil 4'te zaman serisi grafiği verilen Bollinger Bantları indikatörü, John Bollinger (1980) tarafından geliştirilen volatilité göstergesi olup alt, üst, orta bant olmak üzere üç eğriden oluşmaktadır. Orta bant belirli bir dönemdeki günlük fiyatların basit ortalaması iken alt ve üst bantlar fiyatların standart sapması kullanılarak elde edilmektedir. Alt ve üst bantlardan elde edilen kanal fiyatların çok hareketli olduğu dönemlerde genişlemekte ve riskin arttığını göstermekteyken, hareketsiz olduğu dönemlerde kanal daralmaktadır. Fiyatların üst bantta olması kısa vadeli satım, alt bantta olması kısa vadeli alım sinyallerini vermektedir. Bununla birlikte kanal dışına çıkan fiyat noktası yeni bir trend başlangıcının öngörüsü olarak kabul edilmektedir.



**Şekil 5. BIST Banka Endeksi Stokastik Osilatör İndikatörü**

Şekil 5'te zaman serisi grafiği verilen stokastik göstergesi fiyatların yükseliş eğiliminde olduğu dönemlerde kapanış fiyatının seçilen dönem içerisinde en yüksek seviyede tersi durumda ise en düşük seviyede olması varsayımına dayanmaktadır. Bu yöntemde kapanış fiyatları dikkate alınarak %K ve %D (kesikli eğri) olmak üzere iki adet eğri çizilmektedir. Trendin gücünü ve trendin sonunun ne zaman yaklaşacağını belirlemekte kullanılan bu gösterge, 0 ile 100 arasında hareket edip, 0-20 aralığında aşırı satım, 80-100 aralığında aşırı alım yapıldığı durumları göstermektedir.

## 2. ZAMAN SERİLERİ ANALİZİ

Herhangi bir olaya ilişkin, günlük, aylık, yıllık veya daha uzun dönemli aralıklarla derlenen verilerin, ardışık şekilde zamana göre sıralanmış gözlemlerinden oluşan veri kümesi zaman serisi olarak adlandırılmaktadır. Zaman serileri farklı amaçlarla ekonomi, sağlık, mühendislik gibi çok farklı alandan elde edilen verilerden derlenmektedir. Zaman serisi analizi ise belirli bir zaman aralığında gözlemlenen bir olay hakkında, gözlemlenen serinin yapısını veren stokastik süreci modelleme, gözlemler arasındaki bağımlılığı araştırma ve geleceğe yönelik tahminde bulunma işlemi olarak tanımlanmaktadır. Doğal bir sürecin altında yatan etkilerin araştırılmasında, zamanla oluşan değişimi anlamada ve yapılan müdahalelerin etkisini görmekte zaman serisi analizinden faydalanılmaktadır. Serinin gelişimini görmek için verileri düzenli aralıklarda derlemek önem taşımaktadır.

Gelecekteki gözlemlerin öngörülemeyen değerlerini ele almak isterken, her bir  $y$  gözleminin, belirli bir rastgele değişken  $Y$ 'in gerçekleştirilmiş bir değeri olduğunu varsayarak,  $\{Y_t, T \in T\}$  zaman serisi,  $\{Y_t, T \in T\}$  rasgele değişkenler ailesinin gerçekleşmesidir. Burada  $T$  örneklem büyüklüğü,  $t$  gözlem değerini ifade ederken,  $T \in Z$  ile tanımlı  $Z_t, t=1,2,\dots,t$  biçiminde gösterilmektedir. Olasılık teorisinde zaman serisi  $\{Z(y,t): t = 0, \pm 1, \pm 2, \dots\}$  örneklem uzayında tanımlı stokastik sürecinden üretilmekte olup, burada  $\omega$  bir dönemde birden çok gözlem değeri toplandığını ifade etmektedir.

Herhangi bir zaman serisinin analizindeki ilk adım, verilerin grafiğini oluşturmaktır. Seride ani seviye değişikliği gibi belirgin süresizlikler varsa, seriyi önce homojen parçalara ayırarak analiz etmek önem taşımaktadır. Bir zaman serisi istatistiksel olarak, trend, mevsimsel hareketler, konjonktürel ve düzensiz hareketler olmak üzere 4 rassal bileşenden oluşmaktadır. Zaman serilerinde trend kalıpları, genellikle serideki uzun süreli artış ya da azalışları ifade etmektedir. Bir trendin ortaya çıkabilmesi için uzun dönemde hareketlerin izlenmesi gerekmektedir. Trend doğrusal ya da eğrisel yapıda olabilmekte olup, trend tamamen kestirilebilir bir niteliğe sahipse deterministik, değilse rassal olarak kabul edilmektedir. Zaman serilerinde mevsimsel etkilerin ortaya çıkmasında, iklimler, alışkanlıklar, indirimli satış zamanları, satış miktarları gibi birçok faktör etkili olmakta, zaman serisinde günlük, aylık, 3 aylık ve bütüncül toplamında meydana gelen döngüsel değişimleri göstermektedir. Mevsimsel

hareketler genellikle periyodik olarak tekrarlanırken, çoğu zaman seri yapısında sabit bir seyirle tekrarlamayan mevsimsel etkilerin varlığı da görülmektedir. Konjonktürel hareketler, ekonomik veya sektörel verilerle çalışırken karşılaşılan, refah ya da durgunluk dönemlerini içeren değişimlerden kaynaklanmaktadır. Refah dönemlerinde üretim ve tüketim miktarları, satışlar, gelirler artma eğilimindeyken, durgunluk dönemlerinde düşüşler görülmektedir. Konjonktürel hareketler genellikle 5-8 yıllık dalgalanmalardan oluşurken, mevsimsel hareketlerden farklı olarak periyodik salınım göstermemekte, uzunluğu ve yoğunluğu birbirinden farklı olabilmektedir. Genel olarak trendin etrafında meydana gelen dalgalanmalar şeklinde kendini göstermektedir. Konjonktürel harekete sahip bir seri ile çalışıldığında, serinin son dönem ortalamasında artma ya da azalma eğilimi dikkate alınarak önraporlama yapmak analizi kolaylaştırmaktadır. Zaman serilerindeki düzensiz hareketler tesadüfi bir değişken niteliğinde olup, öngörülemez, trend, mevsimsel ve konjonktür bileşenleri dışında kalan, tanımlanabilir bir seyri olmayan, yanıltıcı hareketlerden oluşmaktadır. Burada tesadüfi unsur genellikle verilerdeki gürültü olarak tanımlanmaktadır. Öngörülemeyen doğa olayları ya da toplumsal olaylar nedeniyle ortaya çıkan aykırı ve uç değerlerin varlığı zaman serilerinde düzensiz hareketlerin görülmesine yol açmaktadır.

Zaman serilerinde, hata bileşenine sahip  $Y_t$ 'nin, durağan rastgele bir sürece sahip olduğu bilindiğinden, bu sürece tanımlı olasılıksal model ele alınırken, durağan dışılığın sebebi olarak genellikle trend, konjonktürel ve mevsimsel hareketler ele alınmaktadır.

## **2.1. Zaman Serilerinde Durağanlık Kavramı ve Birim Kök Testleri**

Zamana bağlı olaylar rassal karaktere sahiptir ve bu gibi olaylarla ilgili serilerin gelecek dönemdeki seyrini, bugünkü ve geçmiş dönem değerlerine dayanarak incelemek için, serilere bir stokastik süreç olarak ele alınıp ve analiz için stokastik modeller kullanılması gereği ortaya çıkarmaktadır (Box - Jenkins, 1976). Stokastik sürece sahip bir zaman serisinin tüm özellikleri, yani ortalaması, varyansı, kovaryansı ve daha yüksek dereceden momentleri zamana göre değişmiyorsa, başka

bir ifade ile seri periyodik dalgalanmalardan arınmış ortalama etrafında dağılım gösteriyorsa, seri durağanlık özelliklerini taşımaktadır.

$\{y_t\}_{t=0}^T$  rassal değişkenler ailesinin, zamanla değişmeyen birinci ve ikinci momentleri  $\forall t, k \in \{1, \dots, T\}$  ile tanımlı ise zayıf durağan sürece sahip olduğu söylenebilmektedir. Burada; ortalaması  $E[y_t] = \mu$ , varyansı  $V[y_t] = E[y_t - \mu]^2 = \sigma_x^2$ , kovaryansı  $Cov[y_t, y_{t-s}] = \gamma(t, t+s) = \gamma(s)$  olmak üzere  $s \neq 0$  durumunda zaman serisi zayıf durağan (kovaryans durağan) olarak tanımlanmaktadır. Durağanlık, literatürde sıklıkla zayıf durağanlık, kovaryans durağanlığı, geniş anlamda durağanlık veya ikinci dereceden durağanlık olarak anılmaktadır. Zaman serilerinde gözlemlenen serinin yapısı hakkında istatistiksel çıkarımlar yapmak için serinin zayıf durağan olması yeterli olmaktadır. Çok değişkenli normal dağılım, birinci ve ikinci momentlerle tanımlanabildiği için, normal durağan süreç için zayıf durağanlık ile güçlü durağanlık eşdeğer olmaktadır (Maddala - Kim, 1998).

$F(Y_{t_1}, \dots, Y_{t_1}) = F(Y_{t_1+k}, \dots, Y_{t_1+k})$ ,  $\forall k, t_1, \dots, t_m \in \mathbb{R}, m \in \mathbb{N}$  koşulunda olması bir başka deyişle  $\{Y_{t_1}, \dots, Y_{t_m}\}$  gözlem değerleri kümesinin t zaman noktasına bağlı kalmayıp, birleşik olasılık dağılımının gözlemlerin yapıldığı zaman noktasında hareket ettirildiğinde herhangi bir değişikliğe uğramaması güçlü durağanlık olarak adlandırılmaktadır. Güçlü bir durağan süreç kovaryans durağan olmakla birlikte, kovaryans durağan bir süreç güçlü durağan sürece sahip değildir.

Beyaz Gürültü Süreci ekonometride özel bir stokastik süreç türü, saf rastsal ya da beyaz gürültü sürecidir.  $\{\varepsilon_t\}$  stokastik sürecinin ortalaması  $E\{\varepsilon_t\} = 0$  ve varyansı;  $V\{\varepsilon_t\} = \sigma^2$  şeklinde sabit  $k \neq 0$  için kovaryans  $Cov[\varepsilon_t, \varepsilon_s] = 0$  olan korelasyonsuz rassal değişkenler sürecine sahiptir. Böyle bir süreç aynı zamanda bağımsız, özdeş ve normal dağılımlı ise buna da Gaussyen beyaz gürültü (Gaussian white noise) adı verilmektedir.

Gerçek yaşamda zaman serisi örneklerinin durağan olması az rastlanan bir durumdur. Zaman serileri sahip oldukları trend, mevsimsel dalgalanmalar, konjonktür dalgalanmalar ve tesadüfi dalgalanmalar bileşenlerinden birini veya birkaçını birlikte içerebilmekte, serilerin değişik bölümleri arasında farklılıklar oluşturmaktadır. Zaman serileri analizi için geliştirilmiş ve kullanılan geleneksel olasılık modelleri sadece durağan zaman serilerine uygulanabildiği için uygulamada serilere bir takım dönüşüm



yöntemleri uygulayarak durağan hale getirildikten sonra analiz edilmesi gerekmektedir.

Durağan yapıda bir seri, sabit uzun dönem ortalama civarında dalgalanmalar gösterirken, zamanla değişmeyen bir varyansa sahip olup, gecikmelerin uzunluğu arttıkça teorik olarak otokorelasyonlarda azalma mevcuttur. Serilerin durağanlık yapılarının ortaya çıkarılmasında genellikle grafik yöntemi, korelogram yöntemi veya birim kök testleri kullanılmaktadır. Grafik yöntemi, serinin durağanlığı hakkında önsel bir bilgi sunarken, bir araştırmacı birim kökün varlığını ileri sürerken, diğer araştırmacı serinin seyrinin durağan bir sürece işaret ettiğini savunabilmektedir. Korelogram yönteminde ise, serinin bazı değerleri ve gecikmeli değerleri arasındaki ilişkinin boyutunu belirleyen otokorelasyon fonksiyonuna (ACF) dayanmaktadır. Bahsedilen iki yöntem de durağanlık yapısı hakkında kesin bilgi vermediğinden analizlerde birim kök testleri tercih edilmektedir.

Durağan olmayan serilerin durağanlığı ise ARIMA modelinde sürece uygun sayıda fark alma işlemi yapılarak sağlanmaktadır. Zaman serisinde, zincirleme bir şekilde son değerlerinden belli bir dönem önceki değerlerinin çıkarılması işlemine fark alma işlemi adı verilmektedir. Özellikle serideki değişimin yönünü ve büyüklüğünü ortaya çıkarmak amacıyla fark alma işlemi uygulanmakta ayrıca serideki trend ya da mevsimsel dalgalanmalardan arındırılmaktadır.

Birinci Fark;

$$\Delta Y_t = Y_t - Y_{t-1} , \text{ işlemiyle elde edilmektedir.} \quad (2.1.1)$$

Seri mevsimsel etkiye sahip olduğunda serinin son verilerinden mevsim periyodu kadar önceki verileri çıkartılarak yapılmaktadır.

Tez kapsamında durağanlık testi için, genişletilmiş Dickey-Fuller (ADF) testi, Phillips-Perron (PP) testi ve KPSS birim kök testi kullanılmakla birlikte, ekonomide yapısal kırılmaların olduğu dönemlerde ele alınan veriler için Zivot-Andrews Birim Kök Testi ve Lee-Strazicich Birim Kök Testi kullanılmaktadır.

## 2.1.1. Yapısal Kırılmasız Birim Kök Testleri

### 2.1.1.1. Dickey-Fuller Birim Kök Testi

Dickey Fuller (1979), Monte-Carlo simülasyonlarını kullanarak, sıfır hipotezi altında birim kökün varlığını  $\tau$  (tau) istatistiği çerçevesinde ele almaktadır. Serilerin durağanlığını sınamak için hata terimi beyaz gürültülü sürecine sahip olmak üzere, parametrelerin en küçük kareler tahmin edici modelin birim kök varlığı değerlendirilmektedir.

MA serisi her zaman durağan yapıya sahipken, durağan olmayan zaman serileri AR sürecine sahip olmaktadır. Standart DF birim kök testi, sadece 1. mertebeden otoregresif süreçlere (AR(1)) uygulanmaktadır.

$$\Delta Y_t = \delta Y_{t-1} + \varepsilon_t \quad (2.1.1.1.1)$$

Eşitliğinde,  $\theta = 1$  veya  $\delta = 0$  iken dönemler arası değişim rassal bir değişkene bağlı olduğundan seride birim kökün mevcut olduğunu ( $H_0: \delta \geq 0$ ) ifade eden yokluk hipotezi,  $\theta$  parametresinin pozitif olduğu varsayımı altında kurulmaktadır. Bu kapsamda, t zamanı göstermek üzere, sabitsiz-trendsiz ( $\Delta Y_t = \delta Y_{t-1} + \varepsilon_t$ ), sabitli-trendsiz ( $\Delta Y_t = \alpha + \delta Y_{t-1} + \varepsilon_t$ ) ve sabitli-trendli ( $\Delta Y_t = \alpha + \beta_t + \delta Y_{t-1} + \varepsilon_t$ ) olmak üzere 3 farklı model yapısı dikkate alınarak test edilmektedir. Dickey-Fuller (DF) birim kök testi, hata terimleri arasında korelasyon olmadığı ve sabit varyans varsayımına dayanmaktadır.

Bir zaman serisi AR(p) süreci izlerken, AR(1) süreci olarak ele alındığında,  $Y_t$  'nin dinamik yapısının yanlış tanımlanmasından dolayı hata terimlerinde otokorelasyon problemi ile karşılaşmaktadır. Otokorelasyonlu hata terimi, hata teriminin saf rastsal olduğu varsayımını ihlal etmektedir (Harris, 1995). Hata teriminde otokorelasyon problemi olduğu durumlarda bağımlı değişkene ait gecikmelerin, açıklayıcı değişken olarak modele ilave edilmesiyle oluşturulan Genişletilmiş Dickey-Fuller (ADF) testi daha yüksek dereceden otoregresif süreçlerde kullanılmaktadır.

$$\Delta Y_t = \beta_1 + \beta_2 t + \delta Y_{t-1} + a_i \sum_{i=1}^m \Delta Y_{t-i} + \varepsilon_t \quad (2.1.1.1.2)$$

Ele alınan regresyonlarda bütünleşme derecesi  $d = 0$  olup olmadığı sınanmaktadır. ADF test istatistiği kullanırken temel sorun gecikme uzunluğunun

seçimi olmaktadır. ADF testinin gücü ve boyut özellikleri modele dâhil edilen gecikme sayısına oldukça duyarlı olmaktadır.

### 2.1.1.2. Phillips-Perron (PP) Birim Kök Testi

ADF testleri hata terimlerinin istatistiksel olarak bağımsız ve sabit varyansa sahip rasgele değişkenler olduklarını varsaymaktadır. Phillips ve Perron (1988) , hata terimlerini kendi içinde otokorelasyonlu olması durumunda ADF testinin hatalı sonuçlar verdiğini ifade ederek, birim kökün varlığını test etmek için, bu varsayımlara dayanmayan ve test istatistiğine düzeltme faktörü ekleyen alternatif bir birim kök testi geliştirmektedir (Akdi, 2012). Yüksek dereceden ilişkilerin analizi için geliştirilen parametrik olmayan bir test olan Phillips-Perron birim kök testinde, hata terimlerinin geçmiş değerleri hareketli ortalama (MA) süreci olarak modele dahil edilmektedir. Phillips-Perron'a ait regresyon denklemleri aşağıda ifade edilmektedir (Phillips - Perron, 1988).

$$\hat{y}_t = \hat{\mu} + \hat{\alpha}y_{t-1} + \hat{\varepsilon}_t \quad (2.1.1.2.1)$$

$$y_t = \hat{\mu} + \tilde{\beta}(t - \frac{1}{2}T) + \tilde{\alpha}y_{t-1} + \hat{\varepsilon}_t \quad (2.1.1.2.2)$$

$\hat{\mu}$  ve  $\hat{\alpha}$  katsayıları ile ilgili hipotezleri sınarken serisel korelasyonun katsayıları etkilememesi için t istatistiğinin dönüştürülmüş biçimi olan  $Z_\alpha$  istatistiğini kullanmaktadır.

### 2.1.1.3. KPSS Birim Kök Testi

Kwiatkowski, Phillips, Schmidt ve Shin (1992) tarafından önerilen KPSS birim kök testinde, serideki deterministik trendin arındırılarak serinin durağanlaştırılmasını amaçlamaktadır. Test, artıkların uzun dönem varyansının nonparametrik tahmincisine dayanırken, sıfır hipotezindeki durağanlık temelde trend durağanlığı ifade etmektedir.

Modelde  $w_t$  rassal yürüyüşü, t deterministik trendi,  $\varepsilon_t$  durağan hataları gösterirken,  $u_t$ 'nin varyansının 0 olduğu varsayılmaktadır.

$$Y_t = \beta t + w_t + \varepsilon_t \quad (2.1.1.3.1)$$

$$w_t = w_{t-1} + u_t \quad (2.1.1.3.2)$$

Temel hipotezin testi için Lagrange Multiplier (LM) istatistiği kullanılmaktadır.

## 2.1.2.Yapısal Kırılmalı Birim Kök Testleri

### 2.1.2.1. Zivot-Andrews Birim Kök Testi

Ekonomide uzun zaman dönemi boyunca regresyon katsayılarında kademeli olarak değişime sebep olan yapısal kırılmanın olduğu bir dönemle çalışma yaparken, ele alınan serideki kırılmanın varlığı birim kök yok iken içerdiğine dair hatalı sonuçlara yol açabilmektedir. Yaklaşımda zaman serisinde kırılma zamanının bilinmeyip (TB) içsel olarak ele alınmakta ve tek bir noktada var olduğu varsayımına dayanmaktadır (Zivot - Andrews, 1992).

Yaklaşımda sıfır hipotezi herhangi bir yapısal kırılmayı içermeyen ve birinci dereceden entegre I(1) olan 3 farklı kayan rassal yürüyüş model çerçevesinde ele alınmaktadır. Model A düzeyde, Model B eğimde, Model C ise hem eğimde hem de düzeyde görülen yapısal değişimi ifade etmektedir.

$\Delta$  fark faktörü  $\varepsilon_t$  otokorelasyonsuz ve normal dağılımlı hata terimini göstermek üzere;

$$Model A = Y_t = \mu + \beta_t + \phi_1 Y_{t-1} + \gamma_2 DVU_t(\hat{\lambda}) + \sum_{j=1}^p \delta_j \Delta Y_{t-j} + \varepsilon_t \quad (2.1.2.1.1)$$

$$Model B = Y_t = \mu + \beta_t + \phi_1 Y_{t-1} + \gamma_3 DVU_t^*(\hat{\lambda}) + \sum_{j=1}^p \delta_j \Delta Y_{t-j} + \varepsilon_t \quad (2.1.2.1.2)$$

$$Model C = Y_t = \mu + \beta_t + \phi_1 Y_{t-1} + \gamma_2 DVU_t(\hat{\lambda}) + \gamma_3 DVU_t^*(\hat{\lambda}) + \sum_{j=1}^p \delta_j \Delta Y_{t-j} + \varepsilon_t \quad (2.1.2.1.3)$$

TB kırılma zamanı olmak üzere,  $t = \frac{TB}{T}$  kırılma noktasını göstermektedir. DVU,  $t > TB$  olması halinde 1, diğer durumlarda 0 değerini alan ve sabit terimdeki yapısal değişimi gösterirken,  $DVT^*$  ise  $t > TB$  iken  $t - TB$ , aksi durumlarda 0 değerini alan ve trend içerisinde meydana gelen yapısal değişimi gösteren gölge değişkenlerdir.

Zivot-Andrews testinde meydana gelen yapısal kırılmadaki içsellik, veri setine bağlı olarak açıklanmakta, her olası kırılma tarihi için farklı bir gölge değişken kullanılarak,  $t=2, \dots, (T-1)$  için EKK yöntemiyle T-2 sayıda regresyon oluşturulmaktadır.  $Y_{t-1}$  değişkeninin katsayısında en küçük t istatistiğine sahip olan modeldeki tarih, uygun yapısal kırılma noktasını vermektedir. Uygun kırılma noktası seçildikten sonra

hesaplanan t istatistiği, Zivot-Andrews'in kritik değerleriyle (ZA) karşılaştırılmaktadır. Bu t istatistiğinin ZA kritik değerinden mutlak değerce küçük olması halinde, yapısal kırılma olmadan serinin birim kök içerdiğini gösteren temel hipotez kabul edilmekte, aksi halde ise yapısal kırılmayla birlikte serinin durağan halde olduğunu ifade eden alternatif hipotez reddedilememektedir.

Gecikme uzunluğuna duyarlı olan Zivot-Andrews yönteminin uygulaması ADF birim kök testinin spesifikasyonuna dayanmaktadır. Model C tahmin edildikten sonra DVU ile DVU\* gölge değişkenlerine ait parametrelerin anlamlılığına göre uygun model seçilmektedir.

Seri birden çok kırılmaya sahipken, tek kırılma varmış gibi test etmek hatalı sonuçlara yol açacağından, bu durumda çoklu yapısal kırılmanın dikkate alındığı Lee-Strazicich Birim Kök Testi kullanılmaktadır.

### 2.1.2.2. Lee-Strazicich (2003) Birim Kök Testi

Lee-Strazicich (2003), hem sıfır hem de alternatif hipotez altında kırılmalara izin veren, içsel iki kırılmalı Lagrange çarpan (LM) birim kök testi geliştirip, iki model ile sıfır hipotezinin reddi açıkça trend durağanlık anlamına gelmektedir.

LM test istatistiğinde model A serinin düzeyinde iki kırılma olması durumunu ele alınmakta ve kukla değişken olarak tanımlanmaktadır.

$$Z_t = \{1, t, D_{1t}, D_{2t}\} \quad (2.1.2.2.1)$$

$$D_{jt} = \begin{cases} 1 & t \geq T_{Bj} + 1 \\ 0 & \text{dd.} \end{cases} \quad j=1,2 \quad (2.1.2.2.2)$$

Model C serinin hem düzey hem de eğiminde iki kırılma durumunda ele alınmaktadır.

$$Z_t = \{1, t, D_{1t}, D_{2t}, DT_{1t}^*, DT_{2t}^*\} \quad (2.1.2.2.3)$$

$$DT_{jt}^* = \begin{cases} t - T_{Bj} & t \geq T_{Bj} + 1 \\ 0 & \text{dd.} \end{cases} \quad j=1,2 \quad (2.1.2.2.4)$$

Test istatistiği;

$$\Delta Y_t = \delta' \Delta Z_t + \phi \bar{S}_{t-1} + u_t \quad (2.1.2.2.5)$$

Burada  $\bar{S}_t = Y_t - \psi_x - Z_t \delta$  olup,  $t=2, \dots, T$  ve  $\psi_x$  ise  $Y_1 - Z_1 \delta$  ile bulunmaktadır.

LM testinde  $\tilde{\tau}$  istatistiği kullanılarak minimum olduğu noktalar bulunarak kırılma zamanları  $T_{Bj}$  belirlenmektedir. Elde edilen test istatistiği, tablo değerinden küçük olması halinde, yapısal kırılmalı birim kök temel hipotezi kabul edilmektedir.

LM birim kök testleri,  $\lambda_1 = TB_1/T$  ve  $\lambda_2 = TB_2/T$  kırılma noktalarıyla aşağıda belirtilen izgara araması yoluyla kırılma noktalarını içsel olarak belirlenmektedir.

$$LM_t = \inf_{\lambda} \tilde{\tau}(\lambda) \quad (2.1.2.2.6)$$

## 2.2. Doğrusal Durağan Stokastik Modeller

Zaman serisi modelleri bir değişkenin kendi geçmiş değerlerindeki bilgileri kullanarak gelecekteki değerlerini öngörülebilir. Burada model, verilerin kendi kendini açıklamasını sağlamak, mantığına dayanmaktadır. Klasik ekonometri ya da istatistik modellerden farklı olarak bir değişkenin ilgili cari değerinin yalnızca onun geçmiş değerleri ilişkilendirme fikri tek değişkenli zaman serileri yaklaşımı olarak tanımlanmakta ve yüksek oranda iç bağımlılığa sahip modeller olarak karşımıza çıkmaktadır. Model kapsamında, fonksiyonel biçim, gecikmelerin sayısı ve hata terimleri için bir yapı olmak üzere işlemsel olarak 3 noktanın üzerinde durulmaktadır. (Sevüktekin - Çınar, 2014).

Tek değişkenli bir tahmin metodu olan ARIMA modeli, geçmiş ve mevcut gözlem değerlerini kullanarak, tahminlerin hesaplanmasını sağlayan için bir süreçtir. ARIMA modellerinin ilk temeli 1921'de Yule tarafından AR modellerinin tanıtılmasıyla başlamakta, daha sonra 1927'de Shutsky tarafından MA modelleri ortaya atılmakta ve 1954'te Wold tarafından oluşturulan AR ve MA'nın birleşimi olan ARMA modelleri kullanılmaya başlanmaktadır. ARIMA modelleri ise 1970-1976 yıllarında ise Box ve Jenkins tarafından geliştirilmektedir (Çevik, 1999).

ARMA modelleri eşit zaman aralıklarıyla elde edilen gözlem değerlerinden meydana gelen kesikli ve durağan zaman serilerinin geleceğe yönelik tahmin modellerinin kurulmasında ve tahminlerinin yapılmasında sistemli yaklaşım sergileyerek özellikle kısa dönem tahminlerinde başarılı sonuçlar sağlamaktadır. Bu modeller zamana bağlı tesadüfi olaylar ve bu olaylarla ilgili zaman serilerinin stokastik süreç olduğu varsayımı ile oluşturulduğundan, doğrusal stokastik modeller olarak da

adlandırılmaktadır. ARIMA modellerinin bu kadar tercih edilmesinin sebebi, ele alınan seri durağan olsun veya olmasın ya da mevsimsel unsur içersin veya içermesin bir takım dönüşümler ile çözüme ulaşabilme kabiliyetinden gelmektedir. Ayrıca diğer yöntemlerden farklı olarak, serinin belirli bir eğilime sahip olması gerekirken bir kısıtlaması bulunmaması, yöntemin karmaşık zaman serilerine de uygulanabilmesine olanak sağlamaktadır.

### 2.2.1. Otoregresif Süreç AR(p)

Bağımlı değişkenin cari değerinin, sadece kendi geçmiş değerlerinin doğrusal kombinasyonu ile açıklandığı model yapısına sahiptir.

$Y_t$ 'nin sadece bir dönem öncesi ile ilişkili olduğu yani sadece  $Y_{t-1}$ 'e bağlı olduğu birinci derece otoregresif AR(1) modeli aşağıdaki şekilde ifade edilmektedir.

$$Y_t = \delta + \phi_1 Y_{t-1} + \varepsilon_t \quad \varepsilon_t \sim IID(0, \sigma^2) \quad (2.2.1.1)$$

AR(1) modelinin durağan olabilmesi için belirtilen modelde parametreler üzerinde kısıtlama mevcut olup,  $-1 < \phi_1 < 1$  koşulunun sağlanması gerekmektedir.

P'inci dereceden bir otoregresif sürecin model;

$$Y_t = \delta + \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + \varepsilon_t \quad t=1,2,\dots,T \quad (2.2.1.2)$$

Burada  $\delta$  sabit terimi,  $\phi$  bilinmeyenleri ise -1 ile +1 arasında değer alan, otoregresif parametreleri ifade etmektedir. Burada  $\varepsilon_t$  hata teriminin ortalaması 0 ve varyansı  $\sigma_\varepsilon^2$  sabit olan korelasyonsuz bir temiz dizi özelliği göstermektedir.

$Y_t$  ve  $Y_{t+k}$  arasındaki kovaryans zamana bağlı olmayıp, k sayıda öncüle ve gecikmeye bağlı olduğu varsayılmaktadır.

Bir zaman serisi modeli oluşturulurken otoregresif sürece uygun olduğu bilirse bile kaçınıcı derecen olduğunu bilmek önemlidir. Gecikme sayısının doğru tespit edilmesi modelin başarısını arttırmakla birlikte, uygun gecikme sayısından daha az sayıda gecikmenin kullanılması bilgi kaybına neden olurken, çok fazla sayıda gecikmenin kullanılması, çoklu doğrusal bağlılığın derecesini arttırarak öngörü performansını düşürmekte ve serbestlik derecesinin azalmasına neden olmaktadır.

Otokorelasyon, bir zaman serisinin geçmiş değerleriyle ne kadar ilişkili olduğunu ifade ederken, otokorelasyon fonksiyonu (autocorrelation function / ACF), gecikme birimi dâhil olmak üzere noktalar arasındaki korelasyonu görmek için kullanılmaktadır. Kısmi otokorelasyon fonksiyonu (Partial Autocorrelation Function / PACF) ise bir zaman serisindeki bir gözlem ile önceki zaman adımlarındaki gözlemler arasındaki ilişkinin bir özeti olup, araya giren gözlemlerin ilişkileri göz ardı etmektedir. Otoregresif süreçlerin ACF grafikleri sıfıra yaklaşan bir seyir izlediğinden, gecikme derecesini belirlemede PACF grafikleri kullanılmaktadır. PACF, p'den daha büyük gecikmeler ( $k \geq p$ ) için 0'dan değerini alırken ve  $k < p$  için 0 değerini almaktadır. Durağanlık koşulu gereği AR(p) modelinin otokorelasyon fonksiyonu üstel azalma, sinüs dalgalanması ya da ikisinin karışımı şeklinde seyir izlemektedir.

### 2.2.2. Hareketli Ortalama Süreci MA(q)

Hareketli ortalama sürecinde bağımlı değişken, 1, 2 ya da daha fazla dönem geriye doğru geçmiş dönem öngörü hataları ile açıklanmaktadır. Genel olarak modelin açıklanmayan kısmındaki hata terimleri, cari dönemi etkileyen önceki yıllardaki şok ve yeniliklerin etkisini göstermektedir. Burada rassal bileşen  $\varepsilon_t$  korelasyonsuz, ortalaması 0 ve sabit bir varyansa sahiptir.

Birinci dereceden bir hareketli ortalama süreci aşağıdaki şekilde tanımlanmaktadır.

$$Y_t = \mu + \varepsilon_t + \theta_1 \varepsilon_{t-1} \quad (2.2.2.1)$$

MA(1) sürecinde  $k > 1$  olduğu bütün durumlarda kovaryans 0 değerini alacağından, süreç sadece 1 dönemlik belleğe sahip olmaktadır.

q. dereceden bir hareketli ortalama süreci için model;

$$Y_t = \mu + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \dots + \theta_q \varepsilon_{t-q} \quad (2.2.2.2)$$

Bir MA(q) sonlu süreci, q tane durağan, sıfır ortalama ve sabit varyansa sahip hata terimlerinin ortalamasından meydana gelmektedir. Bu yüzden her hareketli ortalama sürecinin durağan olduğu söylenebilmektedir.



MA süreci yavaş etkileri modellemek amacıyla ve seride yer alan trend eğilimini ortadan kaldırmakta tercih edilen bir yöntemdir (Gujarati, 2004).

$Y_t$  bağımlı değişkeninin yalnızca  $Y_{t-1}$  ve  $Y_{t+1}$  ile korelasyonlu olup sınırlı bir belleğe sahip olması önem arz etmektedir.

Hareketli ortalama modelinin gecikme uzunluğunun belirlenmesinde ACF' grafiklerinden yararlanılmakta, gecikme uzunluğu çok olmayan modellerde ACF değeri,  $q$  gecikmeden sonraki değerler için 0 olmaktadır. MA (1) süreci için birinci gecikmedeki PACF sıfırdan farklı bir değer alırken diğer tüm değerler 0 olmaktadır.

MA süreci ile ilgili en önemli özelliklerden birisi tersine çevrilebilir olmasıdır. Bunu gecikme işlemcisi (L) kullanarak yapmaktadır. Sınırlı sayıdan bir AR sürecinin, sınırsız bir MA modeline veya sınırlı sayıdan bir MA modelinin, sınırsız sayıdan bir AR modeline dönüştürülebilmesine ters çevrilebilirlik adı verilmektedir. MA (1) modelinin tersine çevrilebilmesi için  $|\theta| < 1$  koşulunun sağlanması gerekmektedir. Yani daha farklı ifade etmek gerekirse pür bir MA sürecinin özellikleri, aynı zamanda pür bir AR sürecinin tersinin özelliklerini ifade etmektedir. (Tüzen, 2012).

### 2.2.3. Otoregresif Hareketli Ortalama Süreci ARMA(p,q)

Otoregresif Hareketli Ortalama Süreci (ARMA), bağımlı değişkenin cari değerinin, kendi geçmiş değerleri ile açıklanmasının yanı sıra, beyaz gürültülü hata terimlerinin de cari ve geçmiş değerleri ile açıklanabildiği model yapısına sahiptir. Durağan bir zaman serisini sadece AR ya da sadece MA modeli ile tanımlamak bazı durumlarda kullanışsız olabilmektedir. Uygun bir model seçiminde yüksek dereceden AR veya MA modeli için çok sayıda parametre gereksinime ihtiyaç duyulmakta, benzer özellikleri sağlayan birkaç farklı modelin olabileceği de bilinmektedir. Cimrilik prensibi, zaman serisi verilerinin özelliklerini ortaya koyan optimal yani minimum sayıda parametre içeren bir model formunu kullanmayı gerektirmektedir. (Enders, 1995). AR ve MA modellerinin bir kombinasyonu olan doğrusal yapıdaki tek değişkenli zaman serisi ARMA modelleriyle, parametre sayısı azaltılabilmekte ve seri için sadece AR ve sadece MA süreçlerinin ele alındığı modellerden veri yapısına daha uygun bir model elde edilebilmektedir.

ARMA(p,q) modeli;

$Y_t = \delta + \phi_1 Y_{t-1} + \dots + \phi_p Y_{t-p} + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \dots + \theta_q \varepsilon_{t-q}$  şeklinde ifade edilmektedir.

ARMA modelinin durağanlığı tamamen otoregresif kısma bağlıyken, modelinin tersine çevrilebilir olması ise modelin hareketli ortalamalar kısmıyla ilgili olmaktadır. Zaman serisi modelinde hem AR hem MA süreci birlikte yer aldığına, ARMA sürecinin derecesi belirlenirken ACF ve PACF grafikleri birlikte incelenmekte, belirli bir gecikme değerinde kesilmeyip görüntüsünün geometrik azaldığı görülmektedir.

## 2.3. Durağan Olmayan Doğrusal Stokastik Modeller

### 2.3.1. Otoregresif Bütünleşik Hareketli Ortalama Süreci

#### ARIMA(p,d,q)

Uygulamalarda karşılaşılan serilerin çoğu, özellikle ekonomik verilerden derlenen zaman serileri durağan özelliklere sahip olmamaktadır. Bu serilerin durağanlığı trend, mevsimsel ve konjonktürel dalgalanmalar ve düzensiz bileşenler gibi etkenler tarafından bozulmakta ve durağanlık varsayımının bozulmasından dolayı durağan olmayan zaman serilerinin modellenmesi, ancak serinin durağanlık koşulunun sağlanmasına bağlı olmaktadır. AR, MA ve ARMA modelleri durağan olan zaman serilerinin analizi amacıyla kullanılırken, durağan olmayan serilerde sürece uygun sayıda fark alma işlemi yapılarak ARIMA modelleri ile kullanılmaktadır. Durağan olmayan fakat fark alma işlemi yapılarak durağan hale getirilen serilere uygulanan modeller, durağan olmayan stokastik modeller olarak ifade edilmekte ve böyle bir zaman serisine entegre süreç olarak adlandırılmaktadır. Durağan olmayan seriyi durağan hale getirmek için alınması gereken fark sayısını gösteren fark alma derecesi, d ile gösterilip, uygulamada d çoğunlukla 1 ve en çok 2 değerini almaktadır. Serinin yeterince farkı alınıp alınmadığını belirlemek için, farkı alınmış seri çizilip, sabit bir ortalama ve varyans etrafında dağılıp dağılmadığı kontrol edilmektedir. Uygulamalarda, seri durağan hale gelene kadar fark alma işlemi yapılmakta, daha sonra daha sonra farkı alınmış seri üzerinde model kurulmaktadır. Birinci farkı alınarak durağan hale getirilen bir seri I(1) ile gösterilirken, d. derecede durağan olan bir seri ise I(d) biçiminde gösterilmektedir. Otoregresyon parametresinin derecesi p, hareketli ortalama parametresinin derecesi q ve d kez fark alma işlemi

uygulandığında, bu model (p,d,q) dereceden otoregresif entegre hareketli ortalama modeli olarak adlandırılmakta ve ARIMA(p,d,q) şeklinde yazılmaktadır (Sevüktekin - Nargeleçekenler, 2007).

ARIMA(p,d,q) süreci;

$$(1 - \phi_1 L - \phi_2 L^2 - \dots - \phi_p L^p) \Delta^d Y_t = \delta + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \dots + \theta_q \varepsilon_{t-q}$$

şeklinde gösterilebilir. Gecikme polinomu kullanılarak,

$$\phi(L) \Delta^d Y_t = \delta + \theta(L) \varepsilon_t \quad \text{yazılmaktadır.}$$

Model belirleme aşamasında serinin otokorelasyon (ACF) ve kısmi otokorelasyon (PACF) fonksiyonlarına bakılmakta olup, serinin AR(p), MA(q), ARMA(p,q) ya da ARIMA(p,d,q) modellerinden hangisine uyduğunun tespit edilmesinde çok önemli bir rol oynamaktadır.

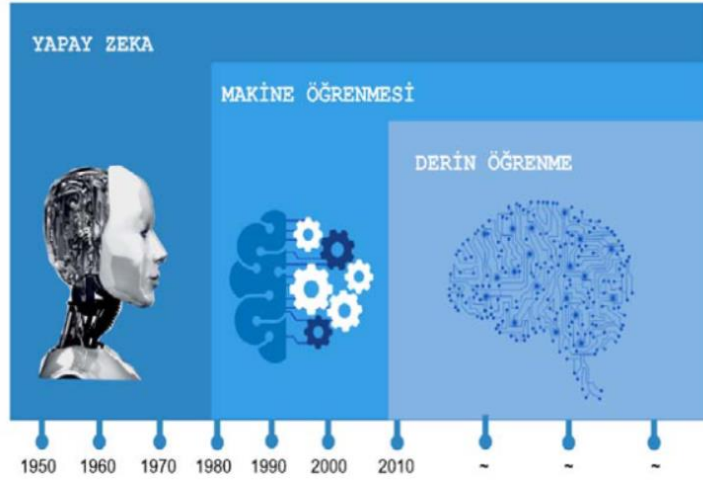
### 3. YAPAY ZEKÂ

Bilgisayarların ileride insana benzer bir şekilde düşünebileceğini hatta insanları aşabileceği öngörüsü yapay zekânın temelleri oluşturmaktadır (Turing, 1950). Yapay zekâ tanımlarına bakıldığında, tüm tanımlar insan gibi düşünen sistem, rasyonel düşünen sistem, insan gibi davranan sistem ve rasyonel davranan sistem olarak 4 kategoride sınıflandırılmaktadır (Yıldız, 2009). Russell ve Norvig (1995), değişik kaynaklardan derledikleri yapay zekâ tanımlarını, zeki davranışların matematiksel süreçler şeklinde tanımlanıp taklit edilmesi, zekâ gerektiren konularda görevleri bilgisayarlara yaptırma ve insanların yapmakta daha iyi olduğu işlevleri bilgisayarlara öğretme çabası olarak genellemektedir.

Yapay zekâ teknolojisi her geçen gün gelişmekte olup, günlük eylemlerimizi otomatikleştirme gibi görevleri üstlenen yapay zekâ teknolojileri, otonom sistemlerin geliştirilmesinde kullanılmaktadır (Förnkrantz, 1999).

Her alanda olduğu gibi finans alanında da değişim, eskiye oranla daha hızlı ilerlemektedir. Finansal analiz, genel anlamda ekonomi alanında uzmanlık gerektiren bir konu iken, günümüzde bilgisayarların iş hayatında kullanımı ve büyük boyutlu veri analizlerinin gereksinimi ile birlikte, bu alanda yapay zekâ teknolojilerinin gelişmesi zorunluluğunu ortaya koymaktadır. Finans alanında yapay zekâ uygulamaları, verilerin içerdiği örüntü ve ilişkileri kavrayıp çıktılar üretme işlevi ile başlayıp, zamanla daha başarılı sonuçlar için model tasarım ve performanslarının geliştirilmesi çabasını sergilemektedir (Goonatilake - Treleaven, 1995). Yapay zekâ tekniklerinin kullanımıyla, daha doğru risk ve getiri tahminleri elde etme, daha karmaşık kısıtlamalara dayalı portföyler oluşturma, alım satım algoritmalarının kullanımıyla yeni alım satım sinyalleri tasarlamak ve alım satımları daha düşük işlem maliyetleri sağlama avantajları elde edilmektedir.

Yapay zekâ kavramı çerçevesinde; makine öğrenimi, derin öğrenme ve yapay sinir ağları gibi yaklaşımlar veri işlemeyi ve veri analizini yeniden şekillendirmektedir. Öğrenme sürecine bakıldığında, 1940'li yıllarda başlayan yapay zekâ teknolojisi, 1980'li yılların başında yerini bir alt dalı olan makine öğrenmesine bırakmakta, 2010 yılının başında ise makine öğrenmesinin eksiklikleri derin öğrenme ile giderilmektedir.



**Şekil 6. Yapay Zekâ, Makine Öğrenmesi ve Derin Öğrenmenin Kronolojisi (Kayaalp - Süzen, 2018)**

### 3.1. Makine Öğrenimi

Günümüzde bilimin yöntemleri hızla değişmekte, bilgisayar ve internet yardımı ile daha fazla verinin toplanması ve analiz edilmesi kolaylaşmaktadır. Makine öğrenmesi yoluyla, makineler veriden öğrenmeye başlamaktadır (Gürsakal, 2019) Bilgisayarların belirli bir görevi verilere bakarak ve kurallar oluşturarak kendi başına öğrenme yoluyla gerçekleştirmesi makine öğreniminin temel prensibidir. Klasik programlamada kurallar ve bu kurallara göre işlenecek veriler ile yanıtlar ortaya koyulurken, makine öğrenmesi algoritmalarında veriler ve yanıtlar örnek olarak sunulur böylece sistemin istatistiksel yapıyı bularak görevi otomatikleştirmesi ve yeni verilere uygulandığında orijinal cevaplar vermesi beklenmektedir. Makine öğrenmesi 1990'lı yıllarda gelişmeye başlasa da, daha hızlı donanım desteği ve büyük verilerle çalışma ihtiyacının artması ile günümüzde popüler olarak kullanılan, yapay zekânın başarılı bir alt alanı haline gelmektedir. Birçok bilim insanının da ifade ettiği gibi makine öğrenimi ve yapay zekâ alanındaki gelişmeler içerisinde 'yazının bulunması' kadar önemli bir eşiktir (Köroğlu, 2017).

Makine öğrenmesi, matematik ve istatistikle sıkı sıkıya ilişkili olsa da birkaç önemli yönden farklılıkları mevcuttur. Makine öğrenimi, bayes analizi gibi klasik istatistiksel analizin pratik olmadığı büyük, karmaşık veri kümeleriyle ilgilenme eğilimindedir ve matematiksel olarak nispeten daha az teori barındırmaktadır. Makine

öğrenmesi modelleri, matematiksel ve istatistiksel yöntemler ile bilgisayar bilimlerinden yararlanılarak mevcut verileri analiz eden ve bu verilerden anlamlı çıkarımlar sunabilen modelleme ve algoritmalarla oluşmaktadır. Basitçe, algoritmalarla verilerin eğitim-öğretim setleri (metin, görüntü, sayısal ölçümler, kullanıcı anketleri, vb.) analiz edilmekte ve bu verilerden çeşitli örüntü ve bilgiler elde edilmektedir. Bu özellikleri ile makine öğrenmesi fikirlerin teorik olmaktan çok ampirik olarak daha sık kanıtlandığı uygulamalı bir disiplin olmaktadır.

Bir makine öğrenmesi modelini uygulamak için 3 önemli unsura ihtiyaç duyulmaktadır. Öncelikle, resim, ses ya da fiyat verisi gibi üzerinde çalışılacak probleme ilişkin giriş veri noktaları elde edilip, daha sonra beklenen çıktı örnekleri modele dâhil edilmektedir. Son olarak ise algoritmanın iyi bir iş yapıp yapmadığını değerlendirmek için bir ölçüt kullanılmaktadır. Tüm makine öğrenmesi modelleri, teknik olarak girdi verilerini kullanarak veriler için uygun temsiller bulan ve anlamlı çıktılara dönüştüren öğrenen bir süreç olarak tanımlanabilmektedir.

Son zamanlarda teknolojiye gelişmeler ile birlikte büyük veri yapılarının elde edilmesi, ekonomik eğilimlerin daha detaylı ve daha iyi ölçülmesinin yanı sıra yeni yöntemlerin geliştirilmesi, daha güçlü ve daha doğru analizler yapılmasına olanak sağlamaktadır.

Ekonometrik analizlerde makine öğrenmesinin özellikle boyut indirgeme, model seçimi ve veri analizi gibi konularda oldukça faydalı olmasının yanı sıra, nedensel ilişkilerin ortaya koyulmasında da makine öğrenimi konularının ele alınmaya başlaması bu konuda yapılan çalışmaların artmasına yol açmaktadır. Athey (2018)'e makine öğrenmesi, kestirim, tahmin, sınıflandırma ve kümeleme gibi amaçlarla, veri setlerine uygulanacak şekilde tasarlanmış algoritmalar geliştiren bir alan olup, makine öğrenmesinin ekonometri alanında kullanımının önemini vurgulamaktadır. Makine öğrenmesi yöntemleri ekonomi ve ekonometri literatüründe oldukça sınırlı bir şekilde yer alsa da, ekonometri alanında da büyük verinin toplanmasının mümkün olması ve algoritma ve yöntemlerin ekonometrik analizlere uygun bir şekilde geliştirilmesi ile son dönemlerde bu yöntemlere ilginin önemli ölçüde arttığı görülmektedir (Akay, 2018).

## 3.2. Derin Öğrenme

Derin öğrenme, makine öğreniminin belirli bir alt alanıdır. Derin öğrenmedeki derinlik kavramı, daha derin herhangi bir anlayışa referanstan ziyade, ardışık katmanlar fikrini belirtmektedir. Derin öğrenme modelleri, veri işleme için bir elek gibi işleve sahip olup, art arda artan şekilde iyileştirilmiş veri filtrelerinden yani bir tür aşamalı veri damıtma işlemi uygulayan basit katmanlardan oluşmaktadır. Katmanlar, çoklu soyutlama yapısı ile verilerin temsillerini öğrenmek için birlikte kullanılmaktadır (LeCun, Bengio, Hinton, 2015). Bir veri modelinde bulunan katman sayısı modelin derinliği olarak adlandırılmaktadır.

Literatürde derin öğrenme konusunda farklı tanımlar mevcut olsa da genel olarak derin öğrenme; denetimli ve denetimsiz, özellik çıkarma, dönüştürme, görüntü analizi, sınıflandırma ve tahmin gibi birçok doğrusal olmayan analizi, gizli katmanlardan yararlanarak analiz eden makine öğrenme teknikleri sınıfı olarak tanımlanmaktadır (Deng - Yu, 2014).

Derin öğrenmede, verilerin birden fazla özellik seviyesinin veya temsillerinin öğrenilmesine dayanan bir yapı mevcuttur. Bir görüntü analizi yapılırken; piksel başına yoğunluk değerlerinin vektörü veya kenar kümeleri gibi birçok özellik arasından veriyi en iyi temsil eden özellik çıkarımı için etkin algoritmalar kullanılmaktadır (Şeker, Diri, Balık, 2017).

Verilerin iyi temsil katmanlarını manuel olarak tasarlamak özellik mühendisliği adı verilen bir uzmanlık biçimi iken, derin öğrenme bu adımı tamamen otomatik hale getirip, iş akışlarını büyük ölçüde basitleştirip ve genellikle karmaşık çok aşamalı ardışık düzenleri, tek, basit, uçtan uca bir derin öğrenme modeliyle çözüme kavuşturmaktadır. Derin öğrenmenin bu kadar hızlı gelişmesinde, birçok problemde daha iyi performans sunmasının yanı sıra, problem çözmeyi çok daha kolay hale getirmesi etkili olmaktadır. Günümüzde, temel Python komut dosyası yazma becerileri, gelişmiş derin öğrenme araştırmaları yapmak için yeterlidir olmaktadır. Modellerin uygulanmasındaki basitlik, Theano'nun ve ardından TensorFlow'un geliştirilmesiyle açık kaynak kodlu kütüphanelerinin kullanımı ve Keras gibi kullanıcı dostu kitaplıkların yükselişiyle sağlanmaktadır. Uzun süredir üzerinde çalışılan bir alan olmasına rağmen, son yıllarda daha hızlı donanım, yeni teknikler, son derece

optimize edilmiş açık kaynak kitaplıklarının birlikte kullanımı ve büyük boyutlu ağların kolaylıkla oluşturulmasına olanak tanınması ile birlikte derin öğrenme modelleri popüler bir uygulama alanı haline gelmektedir. Görüntü sınıflandırma, konuşma tanıma, el yazısı transkripsiyonu gibi zor alanlarda da gerçekleştirdiği başarılı atılımlar ile de problemlerin çözümünde sıklıkla tercih edilmektedir.

Derin öğrenme sinir ağları, girdilerden çıktılara rastgele karmaşık eşlemeleri otomatik olarak öğrenebilmekte ve birden çok girdi ve çıktıyı destekleyebilmektedir. Bunlar, özellikle karmaşık doğrusal olmayan bağımlılıklar, çok değerli girdiler ve çok adımlı tahminlerle ilgili problemlerde zaman serisi tahmin için çok fazla vaat sunan güçlü özellikler olarak karşımıza çıkmaktadır. Daha basit sınıflandırma ve regresyon problemlerinin aksine, zaman serisi problemleri, sıranın karmaşıklığını veya gözlemler arasındaki zamansal bağımlılığını barındırmaktadır. Modelleri yerleştirirken ve değerlendirirken verilerin özel olarak işlenmesi gerekmektedir. Zamansal yapıyı modellerken, model becerisini geliştirmek için kullanılacak trend ve mevsimsellik gibi bileşenler ile ARIMA gibi klasik yöntemler kullanılmaktadır. Ancak bu modeller eksik veya bozuk verilerin varlığında elverişsiz olmaktadır.

### **3.2.1. Yapay Sinir Ağları (ANN) ve Çok Katmanlı Algılayıcılar (MLP)**

Canlı ve cansız tüm karmaşık yapıları inceleyip, matematiksel olarak modelleyip, yönetilme ve denetlenmesini sağlayan bilim dalına güdüm bilimi/siberteknik adı verilmektedir. Yapay sinir ağları (Artificial Neural Network / ANN) ise insan beyninden esinlenilerek geliştirilmiş, eğitilebilir, adaptif ve kendi kendine öğrenebilen bilgisayar sistemleri olarak değerlendirilen sayısal zekâ yapısına sahip sistemler olarak ifade edilmektedir. ANN'ler tıpkı insan beynindeki gibi ağırlıklı bağlantıları kullanarak öğrenme yoluyla keşfedebilme, yeni bilgiler türetebilme, genelleştirme ve örnekler kullanılarak hiç görmediği durumlar ile karşılaşılınca kararlar verebilmeyi, birbirine bağlanmış işlem yapılarını kullanarak gerçekleştirmektedir.

ANN modelleri örneklerden öğrenme işlemi gerçekleştirirken, tanımlanması zor olan veriler arasındaki fonksiyonel ilişkileri yakalanabilmekte ve eksik gözlemleri doğru bir şekilde tamamlayabilmektedir. Geçmiş dönem verilerinden yararlanarak




gelecek tahmini yapılmasına olanak sağlayan ANN'ler çok deęişkenli doğrusal olmayan yöntemler arasında yer almaktadır (Cheng - Titterington, 1994). Geleneksel istatistiksel yöntemlere göre daha genel ve esnek işleve sahip olan ANN'ler, problemlerin içinde barındırdığı karmaşıklığın çözümü için iyi bir alternatif tahminci olup, sisteme sunulan verilerden hareketle en uygun kural veya fonksiyonu oluşturarak, model seçimini, işlev tahminini, en uygun tahmin deęerini ya da sınıflandırmasını başarılı şekilde gerçekleştirmektedir (Çetin, 2011).

ANN modelinde ele alınan konunun uygunluğu için verilerin toplama yöntemi, ağıın tasarımı ve fizibilitesi, eğitim-test-geçerlilik aşamaları ve hata analizi önem arz etmektedir (Swingler, 1996).

Sinir ağlarının yapı taşları olan nöronlar, ağırlıklı giriş sinyallerine sahip olan ve bir aktivasyon işlevi kullanarak bir çıkış sinyali üreten basit işlemci elemanları olarak tanımlanmakta ve bilgi işleme özellikleri sayesinde birbirine bağlanarak fonksiyonları oluşturmaktadırlar. Nöron Ağırlıkları, doğrusal regresyonda kullanılan katsayılara benzemekte olup modelde kullanılan girdilerdeki ağırlıkları ifade etmektedir. Ağırlıklar genellikle 0 ila 0.3 aralığındaki deęerler gibi küçük rastgele deęerlerle başlatılmakta, ancak tercih edilmesi halinde daha karmaşık başlatma deęerleri kullanılabilir. Model eğitim aşamasında ağırlıklar optimal çözüm için zamanla güncellenmektedir.

Modele sunulan girdiler toplama ve bazen transfer işlevinden geçirilerek dönüştürülmektedir. Bir aktivasyon fonksiyonu, nöronun çıktısında toplam ağırlıklı girdinin basit bir haritalaması olup, aktivasyon fonksiyonunda bulunan eşik deęer ile veriler çıkış sinyalinin gücünü etkilemektedir. ANN eğitiminde minimum kayıp deęerini veren parametreler geri yayılım ile elde edildiğinden kullanılan aktivasyon fonksiyonları türevlenebilir olması gerekmektedir. En temel aktivasyon fonksiyonu, basit adım aktivasyon fonksiyonunda toplanan girdi 0,5 gibi belirlenen bir eşğin üstünde ise 1, aksi takdirde 0 çıktı deęerini alan ikili sınıflandırma durumunda kullanılmakta, genellikle çıkış katmanında tercih edilmektedir.



**Şekil 7. Sigmoid, Hiperbolik Tanjant Ve Relu Aktivasyon Fonksiyonları**

Şekil 7-(I)'de sigmoid fonksiyon grafiği verilmektedir. Doğrusal yapıda olmadığı için yapay sinir ağlarında sıklıkla tercih edilen bir fonksiyon olup, çıktı sonucu 0 ile 1 aralığında olduğu için gradyan patlaması sorunun önüne geçmektedir.

$$\sigma(x) = \frac{1}{1+e^{-x}} \quad (3.2.1.1)$$

Şekil 7-(II)'de fonksiyon grafiği verilen, Hiperbolik tanjant fonksiyonu  $[-1,1]$  aralığında çıktı üreten ve orijin etrafında simetrik bir fonksiyondur. Sigmoid fonksiyonuna çok benzemekle birlikte türevinin daha dik olmasından dolayı daha çok değer alabilmektedir. Daha geniş değer aralığına sahip olması hızlı öğrenme ve sınıflandırma işlemleri için avantaj sağlamaktadır.

$$\tanh(x) = \frac{2}{1+e^{-2x}} - 1 \quad (3.2.1.2)$$

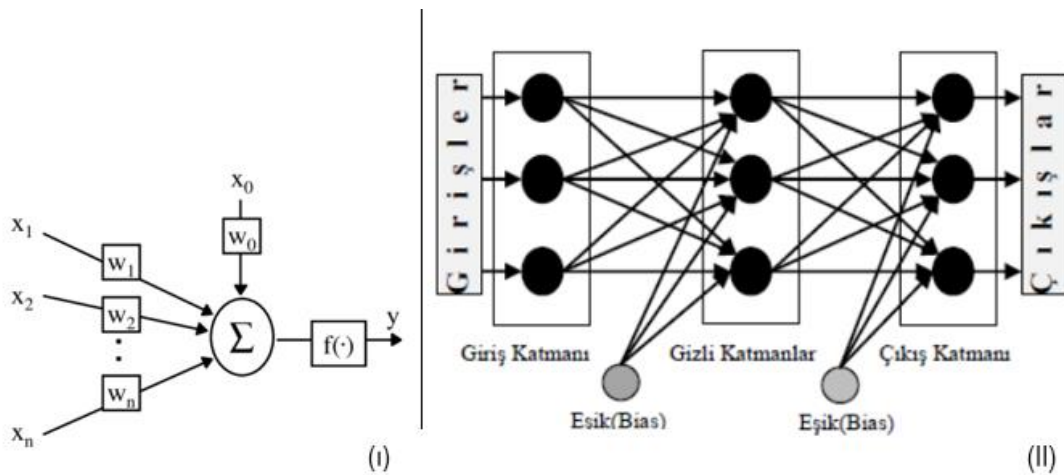
Şekil 7-(III)'de fonksiyon grafiği verilen, ReLu (Doğrusal Doğrultmaç Unitesi/ Rectified Linear Unit) aktivasyon fonksiyonu  $[0-\infty)$  aralığında değer alan doğrusal olmayan bir yapıya sahiptir. Negatif ekseninde 0 değerini alması daha hızlı çalışmasına sebep olmakla birlikte seyrek bir çıktı matrisi oluşturmaktadır. Hesaplama yükünün daha az olması çok katmanlı ağlarda sigmoid ve hiperbolik tanjant fonksiyonlarına göre daha çok tercih edilmesini sağlamaktadır.

$$ReLU(x) = \begin{cases} x & \text{eğer } x > 0 \\ 0 & \text{eğer } x < 0 \end{cases} \quad (3.2.1.3)$$

Nöronlar, ağ yapısı şeklinde düzenlenmekte olup, ağda bulunan bir sıra nöron dizilimine katman adı verilmekte ve bir ağda birden çok katman olabilmektedir. Ağdaki nöronların mimarisi kullanıcı tercihlerine göre denemeler yapılarak inşa edilmekte ve bu yapı genellikle ağ topolojisi olarak adlandırılmaktadır. Ağ yapısında verilerin giriş değerleri ile oluşturulan ve sütun başında bir nöron içeren katmana giriş katmanı adı verilmekte olup, giriş katmanı giriş değerlerini bir sonraki katmana aktarmaktadır. Son sütunda yer alan modelde amaçladığımız işlev biçimine göre şekillenen değer vektörüne ise çıktı katmanı adı verilmektedir. Modellerde girdi ve çıktı katmanı arasında kalan katmanlara ise gizli katman adı verilmektedir. Ağ yapısında gizli katman sayısı 0 ya da daha fazla sayıda olabilmektedir. Girdi ve gizli katmanlar arasında gizli katmanın mevcut olması durumunda model çok katmanlı algılayıcı olarak ifade edilmektedir. Bilgisayar teknolojilerinin gelişmesi ve verimli kütüphanelerin kullanılması ile birçok gizli katmana sahip olan derin öğrenme modellerinin kullanımı ilgi çekici hale gelmektedir.

ANN' de hücre elemanlarının bağlantılarının ağırlık değerlerinin belirlenmesi işlemine ağın eğitilmesi adı verilmektedir. Eğitim süreci veri setinin eğitim, doğrulama ve test olarak 3 alt veri setine ayrılması ile oluşmaktadır. Genellikle verilerin %50-80'i eğitim verisi olarak kullanılırken, %20-50'si doğrulama ve test için kullanıma ayrılmaktadır. Verilerin giriş ve çıkış şeklinde düzenlendiği, etkiye tepki mantığı ile çalışan modellere danışmalı (supervised) öğrenme adı verilmektedir. Tahmin ve sınıflandırma problemleri genellikle danışmalı öğrenme algoritmaları ile modellenmektedir. Danışmalı öğrenmede, işe doğru etiketler ile ilişkilendirilmiş eğitim örneklerini barındıran veri kümesini tanıtmakla başlanmaktadır (Gürsakar, 2018). Sadece giriş verilerinin modele tanıtıldığı, veri içerisinde grup yapılarının keşfedildiği modeller ise danışmasız (unsupervised) öğrenme olarak adlandırılmaktadır. Kümeleme teknikleri danışmasız öğrenme algoritmaları ile oluşturulan problemlere benzerlik göstermektedir. Veri yapısında sürekli güncelleme olması gibi bazı durumlarda ise modele veriyi tam olarak tanıtmak tercih edilebilmektedir. Bu öğrenme şekli ise yarı danışmalı (reinforcement) öğrenme olarak adlandırılmaktadır. Çevrimiçi (online) öğrenme, parametre güncellemelerini anlık gözlemlerden alan eşzamanlı öğrenme modelleri olup, çevrimdışı (offline) öğrenme yapısında ise güncelleme işlemi giriş-çıkış eşleştirilmesine bağlı olarak gerçekleştirilmektedir. Ağın önemli özellikleri ve ilişkileri öğrenmesi istendiğinde, girdi ve çıktılarda ihtiyaç duyulan bütün bilgileri sağlayacak düzeyde büyük veri örneğine sahip olunması gerekmektedir (Anderson - McNeill,

1992). Oluşturulan bir ağ modeli eğitim verileri üzerinde iyi performans gösterirken, daha önce görmediği test veri seti için mantıksız çıktılar üretiyorsa bu durum öğrenmenin tam olarak gerçekleşmediğini göstermektedir. Öğrenme oranının fazla girildiği durumlarda ise model problemi öğrenmekten ziyade ezberlemektedir. Bu durum modelin genelleme özelliğini kaybetmesine ve hatalı sonuçlar üretmesine sebep olmaktadır.



### Şekil 8. Yapay Sinir Hücre ve Çok Katmanlı Model Yapısı

Şekil 8-(I)'de insan düşünce modelini taklit etmek amacıyla eşik mantığı adını verdikleri son derece basit şekilde biyolojik modele dayanan nöronun MCCulloch ve Pits (1943)'tarafından tasarlanan biçimsel tanımı verilmektedir.

$x_1, x_2, \dots, x_n$ , sinir ağına beslenen girişler,  $w_1, w_2, \dots, w_n$  ağırlıklıkları temsil ederken, toplama fonksiyonu ( $\Sigma$ ) ile bir aktivasyon gerilimi üretmek için ağırlıklandırılan girdilere ait tüm sinyallerin toplanması sağlanmaktadır.

$$net = \sum x_i w_i = xw \quad (3.2.1.4)$$

Girişte sunulan veriler katmanlarda ilerlerken sinyalleri bir nörondan diğerine aksiyon potansiyeli aracılığı ile aktarılmaktadır. Aksiyon potansiyellerinde ya hep ya hiç ilkesi bulunmaktadır. Bu ilke doğrultusunda nöronlar arasında ilişki oluşturulurken Kanadalı nöropsikolog Donald Hebb'in tanımıyla birbirini ateşleyen nöronlar birbirine bağlanmaktadır (Hatipoğlu, 2010). ANN modelinde temel işlem; modelin en iyi skoru vereceği  $w$  (ağırlık parametresi) ve  $\theta$  (hata / bias değeri) parametrelerinin hesabını yapmaktır.

$$Y = f(\sum x_i w_i + \theta) \quad (3.2.1.5)$$

Temel sinir ağı modelleri farklı öğrenme yetenekleri ile geliştirilerek günümüzde tahmin problemleri dışında görüntü işleme, konuşma sınıflandırma gibi çok farklı alanlarda kullanıma sahiptir.

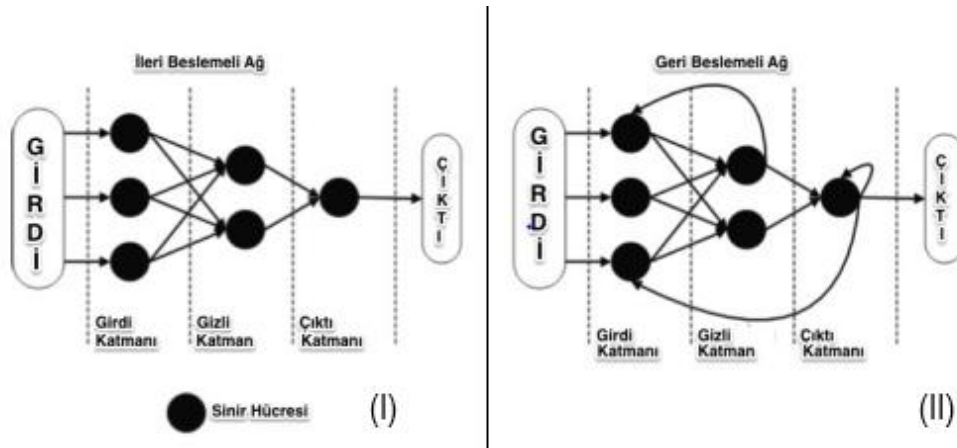
Sinir ağlarının gücü, eğitim verilerini temsili olarak öğrenme yeteneklerinden ve tahmin etmek istediğiniz çıktı değişkeniyle en iyi şekilde nasıl ilişkilendirebileceğinizden gelmektedir.

Şekil 8-(II)'de temsili verilen, Çok Katmanlı Algılayıcılar (Multi Layer Perceptron) veya kısaca MLP'ler olarak adlandırılan klasik sinir ağları, tahmin problemlerine uygulanabilmekte ve tahmin yeteneği ağların hiyerarşik veya çok katmanlı yapısından gelmektedir.

MLP'ler çok değişkenli tahmin için doğrudan destek sağlayan rastgele sayıda giriş özelliği belirtilebilirken, çok adımlı ve hatta çok değişkenli tahmin için rastgele sayıda çıktı değeri belirtilebilmektedir.

MLP yapılarında modele dâhil edilen ara katmanlar sayesinde doğrusal ve doğrusal olmayan ilişkileri kolayca öğrenilebilmektedir. Bu yetenek, klasik doğrusal yöntemleri kullanmanın sınırlamalarının üstesinden gelmektedir. Ayrıca gürültüye karşı dayanıklıdır ve eksik değerlerin olması durumunda kullanılabilir. Ancak modeldeki katman sayısı deneme yanılma yoluyla belirlenirken, gereksiz katman kullanmak hesaplama süresini etkilemektedir.

MLP ağları sabit boyutlu bir vektör girdisi ile sabit boyutlu çıktı üretmektedir. Modeldeki katman sayısı ağ tasarımında karar verilip değişmemektedir. Ayrıca zaman seri tahminlerinde kullanılabilen MLP ağları, gözlemler arasındaki zamansal yapı veya düzeni açık bir şekilde ele alamamasından dolayı, zaman serilerindeki zamansal ilişkiyi modelleme kabiliyetine sahip değildir. Bu nedenle MLP'ler, zaman serisi tahmin problemlerini modellemek için iyi bir başlangıç noktasıdır, ancak derin öğrenme ile birlikte daha iyi model yaklaşımları mevcuttur.



**Şekil 9. Bir Yapay Sinir Ağının İleri ve Geri Beslemeli Topolojisi (Krenker vd., 2011)**

Şekil 9-(I) 'de verilen ileri beslemeli sinir ağları tek yönlü sinyal akışı için izin vermektedir. İleri beslemeli bir ağ yapısında hücreler katmanlar şeklinde düzenlenmekte, girdi katmanına sunulan girdi verileri, aktivasyon fonksiyonundan geçerek gizli katmanlara ulaşmaktadır. Son gizli katmandan çıkan çıktılar, çıktı katmanına ulaşarak probleme uygun sonuçlar üretmektedir. Üretilen çıktılar sınıflandırma problemi ise sınıfı, regresyon problemi ise tahmin sonucunu vermektedir.

Basit bir sinir ağ modelinde ileri besleme

$$\hat{y}(x; w) = f_n(FC_n(f_{n-1}(FC_{n-1}(\dots f_1(FC_1(x)))))) \quad (3.2.1.6)$$

Mimarisi kullanarak tanımlanmakta, burada  $i$ 'inci tam bağlantılı katman  $FC_i$ ,  $\{h_j\}_{j=1}^{d_{i-1}}$  nöronları girdi olarak alan ve  $\{h_j\}_{j=1}^{d_i}$  nöronları çıktı olarak veren bir fonksiyondur. Her çıktı girdiler üzerinde doğrusal bir model olup,  $i$ 'inci aktivasyon fonksiyonu  $f_i: \mathbb{R} \rightarrow \mathbb{R}$  tanımlı olduğu göz önüne alınarak, tam bağlı katmanın hangi nöronlarının bir sonraki tam bağlı katmana aktarılacağına karar veren bir dönüşüm fonksiyonunu ifade etmektedir.

Şekil 10-(II)'de temsil edilen geri beslemeli ağ (backpropagation) yapılarında ise ilk katmandaki çıktı değerleri hesaplanmakta ve ileriye aktarıldıktan sonra hatanın her parametreye göre kısmi türevleri hesaplanarak ağda geriye gönderilmektedir. Geri yayılım, çıktıdan girdi katmanına doğru gradyanları ters sırada hesaplayarak

zincir farklılaşma kuralını kullanmamıza izin verirken çıktının  $\hat{y}(x; w)$  parametrelerle türevlenebilir olması gerekmektedir.

İlk olarak, son katmandan  $\hat{y}(x; w) = h_n(h_{n-1}, w_n, b_n)$  başlanarak kayıp fonksiyonunun türevleri hesaplanmaktadır. Daha sonra sondan bir önceki katman  $\hat{y}(x; w) = h_n(h_{n-1}(h_{n-2}, w_{n-1}, b_{n-2}))$  için kayıp fonksiyonunun türevleri hesaplanmakta, bu hesaplamalar, modeldeki tüm katmanları için sırayla hesaplanmaya devam etmektedir. Bir katmandaki gradyan hesaplamalarının, önceki katmanın gradyanı hesaplamak için yeniden kullanılabilirdiğinden, geri yayılım, kalan hesaplamalar için ara kısmi türevleri saklamaktadır. Bu yaklaşım, her katmanın gradyanını ayrı ayrı hesaplamak gibi saf bir yaklaşım kullanmaktan çok daha verimli olmaktadır.


Geri besleme, bir katmandaki hücreler arasında olduğu gibi katmanlar arasındaki hücreler arasında da olabilmektedir. Bu yapısı ile geri beslemeli ANN, doğrusal olmayan dinamik bir model yapısına sahiptir. Dolayısıyla, geri beslemenin yapılış şekline göre farklı yapıda ve davranışta geri beslemeli ANN yapıları elde edilebilmektedir. Geri beslemedeki amaç hata fonksiyonu ile güncellenen ağırlıklar kullanılarak problemde en iyi sonuca ulaşmaktır.

MLP'lerin eğitim sürecinde, öğrenme algoritması olarak geri yayılım algoritması kullanılmaktadır (Silva vd., 2017). Genelleştirilmiş delta kuralı olarak da bilinen geri yayılım algoritmasının kullanıldığı MLP modellerinin eğitim süreci, iki aşamanın birbiri ardına uygulanmasıyla tamamlanmaktadır.

### 3.2.2. Tekrarlayan Sinir Ağları (RNN)

İnsanlar düşüncelerine her an sıfırdan başlamamakta ya da film izlerken filmin her noktasında filmin olay yapısını yeniden gözden geçirmemektedir. Düşüncelerimizde ya da film sürecinde önceki olaylarla ilgili muhakememizi sürekli olarak sonraki olayları bilgilendirmek için kullanmaktayız. Tekrarlayan sinir ağlarında (Recurrent Neural Network / RNN) ağın çalışma prensibinde ağa gelen bilgi sadece ileri doğru işlenmez mevcut zaman adımındaki tahminleri güçlendirmek için ağa girdi olarak önceki bir zaman adımından ağ etkinleştirmeleri ile besleyen döngüleri de eklemektedir. RNN, tahmin problemleri için tasarlanmış özel bir sinir ağı türü olup, ilginin kalıcı olmasına izin veren döngüler barındırmaktadır. Geleneksel sinir ağlarının

eksikliği bu noktada ortaya çıkmakta ve çözümü tekrarlayan sinir ağlarının kullanılmasına dayanmaktadır.



### Şekil 10. RNN Ağ Bloğu (Amidi, 2022)

Şekil 10'de görseli verilen tekrarlayan sinir ağlarında ağ yapısına ilişkin sonuç, sadece o andaki girdi değerine bağlı değil, diğer girdilere de bağlı olarak hesaplanmaktadır.  $t$  anındaki girdi verilerinin yanında,  $t-1$  anından gelen gizli katman sonuçları da gizli katmanın  $t$  anındaki girdisi olarak kullanıldığı için,  $t-1$  anındaki girdisi için verilen karar,  $t$  anında verilecek olan kararı da etkilemektedir. Yani bu ağlarda girdiler şimdiki ve önceki bilgilerin birleştirilmesi ile çıktı üretmektedir. Bu etkinleştirmeler, ilke olarak uzun vadeli geçici bağlamsal bilgileri tutabilen ağın iç durumlarında depolandığı bir bellekte kaydedilmektedir. Farklı zamanlarda belleğe alınan veriler arasında korelasyon bulunuyorsa buna uzun dönem (long term) bağımlılık adı verilmektedir. Bu mekanizma sayesinde, RNN'lerin girdi dizisi geçmiş üzerinde dinamik zamansal davranış yapısını bağlamsal pencereden yararlanmasına olanak tanınmaktadır. Kısaca RNN'ler verilerden zamansal bağımlılığı öğrenebilmekte ve bunlardan faydalanabilmektedir. RNN'ler uzun dönem bağımlılıklar arasındaki ilişkiyi hesaplarken dizi verileriyle çalışmakta ve bu işlemi yaparken kullanılan matematiksel formül aşağıda verilmektedir.

$\{y_t\}_{t=0}^T$  serisinin olasılığını maksimize etmek istediğimizi varsayalım;

$$p(y, \dots, y_T) \prod_{t=1}^T p(y_t | y_{t-1}, \dots, y_1) \rightarrow \max \quad (3.2.2.1)$$

Burada  $\hat{y}_t$ 'ni elde etmek için, önceki tüm  $y_{t-1}, \dots, y_1$  değerleri verilen koşullu olasılığı modellemeye ihtiyaç vardır.



$$\hat{y}_t \sim p(y_t | y_{t-1}, \dots, y_1) \quad (3.2.2.2)$$

Burada, bellek gereksinimleri  $t$  zaman adımıyla katlanarak büyümektedir. Ancak, bu olasılığı modellemek yerine, RNN modellerinde şimdiye kadar gördüğü tüm verileri depolayan, gizli durum adı verilen gizli bir değişken  $h_t$  kullanılmaktadır.

$$p(\hat{y}_t | \hat{y}_{t-1}, \dots, \hat{y}_1) \approx p(y_t | h_{t-1}), \quad h_t = f(y_t, h_{t-1}) \quad (3.2.2.3)$$

Çok değişkenli bir zaman serisi için  $\{(x_t, y_t)\}_{t=1}^T$ ,  $x_t \in \mathbb{R}^d$  ve  $y_t \in \mathbb{R}$  olmak üzere,  $W_{xh}, W_{hh}, W_{hy}$  ağırlıkları,  $b_h, b_y$  sapmaları ve  $f_h, f_y$  aktivasyon fonksiyonlarını temsil ederken RNN model yapısı;

$$h_t = f_h(W_{xh}x_t + W_{hh}h_{t-1} + b_h) \quad (3.2.2.4)$$

$$\hat{y}_t = f_h(W_{hy}h_t + b_y) \quad (3.2.2.5)$$

Mimarisiyle tanımlanmaktadır.

RNN'ler ağırlık güncelleme durumunda hiçbir etkisi olmayacak kadar küçük olan kaybolan gradyan veya çok büyük değişikliklere neden olan patlayan gradyan sorunlarına neden olabilmektedir.

### 3.2.2.1. Uzun Kısa Süreli Bellek modeli (LSTM)

Sepp Hochreiter ve Juergen Schmidhuber 1997 yılında kaybolan ve patlayan gradyan (eğim) problemini çözmek için Uzun Kısa Süreli Bellek modelini ( Long Short-Term Memory / LSTM) geliştirmiş olup, Hinton ve Salakhutdinov (2006)' un katkılarıyla ağırlık eğitiminde katmanların kullanımı açıklanmakta, sonraki çalışmalarla revize edildikten sonra günümüzde kullanılan popüler LSTM model yapısını oluşturmaktadır.


Kaybolan gradyan problemi, genellikle büyük zaman serisi verileriyle çalışıldığında ortaya çıkmakta, LSTM ağı, zaman içinde geri yayılma mimarisi kullanılarak eğitilen ve kaybolan gradyan sorununun üstesinden gelen yapay tekrarlayan bir sinir ağı modelleri arasında yer almaktadır. Büyük (yığılmış) tekrarlayan ağlar oluşturularak, makine öğrenimindeki zor dizi problemlerini ele almakta ve çok çeşitli

problemler üzerinde son derece iyi sonuçlar verdiği için günümüzde yaygın olarak kullanılmaktadır.

Sıralı verilerin öğrenilmesi ve örüntü tanıma, makine öğreniminde karşılaşılan zorluklar arasında yer almaktadır. Uzun Kısa Süreli Bellek modelleri son derece güçlü zaman serisi modelleri olarak kullanılmakta, standart ileri beslemeli sinir ağlarının aksine, LSTM'nin geri bildirim bağlantıları bulunmaktadır. LSTM ağları, tekrarlayan döngüleri kullanmakta ve bilgileri daha kalıcı kılmaktadır. Yalnızca tek veri noktalarını değil, aynı zamanda tüm veri dizilerini (konuşma veya video gibi) işleyebilme ve bilgileri belirli bir süre boyunca saklayabilme yeteneğiyle zaman serileri veya sıralı verileri analiz ederken son derece kullanışlı hale gelmektedir.

LSTM'ler, uzun vadeli bağımlılık sorununu önlemek için elverişli bir şekilde tasarlandığından, bilgiyi uzun süre hatırlamak, pratik olarak modelin ana prensibinde bulunmaktadır. LSTM, unutulması ve hatırlanması gereken bilgileri kontrol ederken hafızanın ne zaman ve nasıl dönüştürüleceğine karar verip, uzun süreli belleğin depolanmasına yardımcı olmakta ve uzun vadeli kalıpları öğrenmede diğer sinir ağlarından çok daha hızlı çalışmaktadır. Bir LSTM mimarisini oluştururken hangi bilgilerin depolanıp, hangi verilerin atılacağına karar vermekte özgür davranılabilmektedir.

LSTM hücre durumunda, kapılar adı verilen yapıları kullanarak bilgi ekleme veya kaldırma yeteneğine sahiptir. Kapılar, isteğe bağlı şekilde bilginin aktarılmasını sağlayan yolu ifade etmekte, sigmoid sinir ağı katmanı ve noktalı çarpma işlemlerinden oluşmaktadır.



**Şekil 11. LSTM'deki Yinelenen Modül, Dört Etkileşimli Katman İçermektedir (Olah, 2022).**

Şekil 11' de temsili verilen LSTM yapısında, yapay sinir ağı katmanından farklı olarak tek bir katman yerine özel bir şekilde bağlanmış 4 katman bulunmaktadır. Katmanlarda bulunan kapılar yardımıyla hücrelerin depolayacağı bilgiler seçilmekte, okunmakta ya da atılacak veriler seçilmektedir. Ayrıca kapılar içlerinde bir ağ yapısı ve aktivasyon fonksiyonunu da barındırdığı için ağa gelen bilgilerin ağırlık güncellemeleri yapılarak filtreleme işlemi sağlanmaktadır.

Hücreler içlerinde barındırdığı kapılar sayesinde yapı içerisinde dikkatlice düzenlenen hücre durumunda bilgileri kaldırma veya ekleme yeteneğiyle küçük değişikliklere izin verirken, hangi bilgi bölümlerinin hatırlanacağını, unutulacağını ve bir sonraki adıma geçeceğini kontrol etmek için giriş, unutma ve çıkış seçenekleri değerlendirmektedir (Kilimci - Akyokuş, 2019). Değişiklikler yapılırken kapılar isteğe bağlı olarak bilginin iletilmesini sağlayan yolla oluşturmakta, sigmoid veya relu işlevini kullanarak 0 ile 1 arasında değerler alırken, 0 değeri bilgi geçişini sınırlandırmakta, 1 değeri ise bilgi geçişlerine izin veren noktasal çarpma işlemlerini oluşturmaktadır. Kapıların kullanılması modeldeki parametre sayısını artırırken, aynı zamanda birçok pratik uygulamada uzun dizilerin işlenmesinde önemli gelişmeler sağlamaktadır.

LSTM Ağ Yapısında  $w$  ağırlık matrisi,  $b$  yanlılık (bias) belirten terim,  $\sigma$  sigmoid işlevi, tahn işlevi olmak üzere bir LSTM hücresi aşağıdaki bileşenlere sahiptir.

Hücre durumu ( $c_t$ ), hem kısa süreli hem de uzun süreli hafızaları depolayan hücrenin dahili hafızasını temsil emektedir.

Gizli durum ( $h_t$ ), mevcut girdinin, önceki gizli durum ( $h_{t-1}$ ) ve mevcut hücre girdisine göre hesaplanan çıktı durum bilgisidir. Ayrıca bir sonraki tahmini yapmak için hücre durumunda depolanan yalnızca kısa veya uzun vadeli veya her iki bellek türünü geri almaya karar verebilmektedir.


Giriş kapısı ( $i_t$ ), geçerli girişten hücre durumuna ne kadar bilgi akacağına karar verirken, unutma kapısı ( $f_t$ ), girdilerden ve önceki hücre durumundan ne kadar bilginin mevcut hücre durumuna akacağına karar vermektedir.

Çıkış kapısı ( $o_t$ ), mevcut hücre durumundan ne kadar bilginin gizli duruma akacağına karar vermekte, böylece gerekirse LSTM yalnızca uzun vadeli anıları veya

kısa süreli anıları ve uzun süreli anıları seçebilmektedir. Çıkış kapısı, hücrenin gerçekte ne çıkardığı konusunda son bir sınırlayıcı olmaktadır.

Geleneksel bir MLP nöronunun aksine, bir LSTM bellek birimini temiz bir şekilde çizmek zordur. Her yerde çizgiler, ağırlıklar ve kapılar bulunmaktadır.

Şekilde gösterilen LSTM bloğu, yalnızca gizli bir durum  $h_t$  kullanarak değil, aynı zamanda zaman içinde bilgiyi hatırlayabilen bir bellek hücresi  $C_t$  kullanarak uzun vadeli bilgi koruma ve kısa vadeli girdi atlama işlemlerini ele almak için tasarlanan bir forma sahiptir.



**Şekil 12. LSTM Model Tahmin Adımları (Olah, 2022).**

Şekil 12-(I)'de temsili verilen LSTM mimarisini oluştururken ilk adım hangi bilgilerin atılacağına karar vermektir. Unutma kapısı verilen sigmoid katmanında  $h_{t-1}$  ve  $x_t$  değerleri kullanılarak her bir  $y_{t-1}$  için 0 ile 1 arasında değer üretilmektedir. 0 atılması gereken 1 ise tamamen korunması gereken değerler anlamına gelmektedir.

$$f_t = \sigma (W_f \cdot [h_{t-1}, x_t] + b_f) \quad (3.2.2.1.1)$$

Şekil12-(2)'de bir sonraki adım gösterilmekte olup, depolanan bilgilerin güncellenmesini içermektedir. Öncelikle giriş kapısı katmanı adı verilen bu katmanda bilgiler güncellenmekte ardından tanh tabakası ile eklenebilecek yeni aday değerler vektörü oluşturulmaktadır.

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (3.2.2.1.2)$$

$$\tilde{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (3.2.2.1.3)$$

Şekil12-(III)'te verilen bu aşamada hücrenin eski değerini tutmakta olan  $c_{t-1}$  vektörü ile giriş kapısından çıkan sonuç olan  $c_t$  vektörlerinden hangisinin saklanacağına unutmaya kapısı karar vermektedir. Unutmaya kapısından gelen  $f_t$  sonucu ile eski vektör çarpılmaktadır.

$$C_t = f_t \cdot C_{t-1} + i_t \cdot \tilde{C}_t \quad (3.2.2.1.4)$$

Son olarak Şekil12-(IV)'te verilen çıktı kapısı, tahmin sonucu olarak kullanılmak üzere ya da bir sonraki LSTM hücresine gönderilmek üzere çıktımızın ne olacağına karar vermektedir. Bu aşamada ilk olarak, sigmoid katman çıktı değerlerinin önemine karar verip, ardından mevcut hücre durumu bir tanh katmanından geçirilmekte (değerleri -1 ile 1 arasında tutmak için) ve nihai çıktı elde edilmektedir.

$$o_t = \sigma(W_o [h_{t-1}, x_t] + b_o) \quad (3.2.2.1.5)$$

$$h_t = o_t \cdot \tanh(C_t) \quad (3.2.2.1.6)$$

BPTT olarak bilinen zamana bağlı sıralı bir dizi hesaplamasının tümü için backprop kullanılarak kayıp fonksiyonlarının türevleri aşağıdaki şekilde hesaplanmaktadır.

$$\frac{\partial L}{\partial W} = \sum_{t=1}^T \frac{\partial L_t}{\partial W} = \sum_{t=1}^T \frac{\partial L_t \partial h_t}{\partial h_t \partial c_t} \frac{\partial c_t}{\partial c_{t-1}} \dots \frac{\partial c_1}{\partial W} = \sum_{t=1}^T \frac{\partial L_t \partial h_t}{\partial h_t \partial c_t} \left( \prod_{j=i+1}^t \left[ \frac{\partial c_j}{\partial c_{j-1}} \right] \right) \frac{\partial c_1}{\partial W}$$

$$\forall W \in \{W_{xi}, W_{hi}, W_{xf}, W_{hf}, W_{xc}, W_{hc}, W_{xo}, W_{ho}\} \quad (3.2.2.1.7)$$

Her ağırlık değeri için kayıp fonksiyonunun türevleri hesaplandıktan sonra gizli durum değerleri kaybolan veya patlayan gradyan problemi için  $\left\| \frac{\partial c_j}{\partial c_{j-1}} \right\|_2 \approx 1$  eşitliği sağlanmalıdır.

$$\begin{aligned} \frac{\partial c_j}{\partial c_{j-1}} &= \frac{\partial}{\partial c_{j-1}} (f_t \cdot C_{t-1} + i_t \cdot \tilde{C}_t) = \frac{\partial}{\partial c_{j-1}} (f_t \cdot C_{t-1}) + \frac{\partial}{\partial c_{j-1}} (i_t \cdot \tilde{C}_t) = \frac{\partial}{\partial c_{j-1}} C_{t-1} + \\ &\frac{\partial}{\partial c_{j-1}} f_t + \frac{\partial}{\partial c_{j-1}} C_{t-1} + i_t \end{aligned} \quad (3.2.2.1.8)$$

LSTM toplama özelliği ile BPTT sırasında gradyan değerlerini dengelememizi sağlamaktadır.

$$\frac{\partial L}{\partial W} = \sum_{t=1}^T \frac{\partial L_t \partial h_t}{\partial h_t \partial c_t} \left( \prod_{j=i+1}^t \left[ \frac{\partial i_t}{\partial c_{j-i}} \frac{\partial c_t}{\partial c_{j-i}} \frac{\partial f_t}{\partial c_{j-i}} c_{j-1} + i_t \right] \right) \frac{\partial c_1}{\partial W} \quad (3.2.2.1.9)$$

LSTM ağ yapıları temel olarak bu şekilde oluşturulmakta olup, özel kullanımlar için gözetleme deliği kapıları gibi farklı yapılar oluşturmak da mümkündür. Jozefowicz vd. (2015), LSTM mimarisinin optimal olup olmadığını veya çok daha iyi mimarilerin var olup olmadığını belirlemeyi amaçlamakta, on binin üzerinde farklı RNN mimarisini değerlendirerek yapıların benzer olduğuna dikkat çekmektedir. Greff vd. (2016), 5000'in üzerinde deneysel çalışma sonucunda, varyantların hiçbirinin standart LSTM mimarisini önemli ölçüde iyileştiremeyeceğini ve unutmaya geçidinin ve çıktı etkinleştirme işlevinin en kritik bileşenleri olduğunu göstermektedir.


LSTM ağları ile zaman serisi tahminleri yaparken çıktının girdi dizisinde çok daha fazla boyutlu fonksiyon ile tanımlanması, yani çok uzun sayıda girdi ile tek bir gözlemi tahminlemeye çalışması gereksiz bir uygulamaya neden olmaktadır. Bu durum LSTM ağlarının hafızalarının suistimalini ortaya koymaktadır. Doğru formüle edilmiş bir geri beslemeli çok katmanlı ağ ile problemin çözümü mümkünken, LSTM mimarisini kullanmak gerekli değildir. Fakat daha karmaşık problemlerin çözümünde LSTM modelinde yalnızca gizli durumun son değerini kullanmak yerine ara gizli durumların kullanılması ( $h_t$ 'nin yanısıra  $h_{t-1}, h_{t-2}$  ve  $h_{t-3}$ 'ün de kullanılması) özellikle doğal dil işleme problemlerinde, uzun vadeli bağımlılıkları modellemede önemli iyileştirmelere yol açabileceğini göstermektedir.

### 3.2.2.2. Kapılı Tekrarlayan Hücre (GRU)

Chu vd. (2014) tarafından geliştirilen Kapılı Tekrarlayan Hücre (Gated Recurrent Unit - GRU) modelleri, yeni bir tekrarlayan sinir ağı modeli olup, uzun süreli ilişkilerin öğrenilmesini zorlaştıran gradyan kaybolma veya patlama probleminin üstesinden gelmek için dâhili bellek özelliğini kullanmakta, güncelleme ve sıfırlama kapıları ile bilgileri saklamayı ve filtrelemeyi sağlamaktadır.

LSTM ağlarına benzer şekilde, GRU, ünite içindeki bilgi akışını modelleyen ancak ayrı bir hafıza hücresine sahip olmayan geçit birimlerini kullanmakta olup, yine

benzer şekilde sıralı giriş verilerinin uzun süreli bağımlılıklarını veya sıralı giriş verilerini uzun zaman boyunca silmeden bellekte tutma kabiliyetine sahiptir.



**Şekil 13. GRU Model Yapısı (Haberal, 2020)**

Şekil 13'te temsili verilen Gru model ağ yapısında, LSTM ağlarında bulunan giriş ve unutmaya kapıları, güncelleme kapısı olarak tek bir kapıda birleştirilmekte olup, GRU'nun bu daha basit tasarımı, daha az parametreyle eğitimini daha hızlı hale getirmektedir. Ayrıca LSTM ise uzun vadeli bağımlılıkları hücre durumunda ve kısa vadeli belleği gizli durumda tutarak ayırmaktayken, GRU ağları, LSTM ağlarındaki gibi ayrı bir bellek hücresi veya gizli duruma sahip olmadığından, hem kısa hem de uzun vadeli bilgileri aynı gizli durumda tutmaktadır.

Chung ve ark. (2014), LSTM ve GRU ağlarının arasındaki küçük farklılıkların teorik olarak bir algoritmanın diğerinden daha üstün olduğunu savunmada yetersiz olduğunu belirtmektedir.

GRU ağlarında kapılar önemli olan bilgileri korurken önemsiz olan bilgileri seçici olarak filtrelemek için sigmoid işlevini kullanarak 0 ile 1 arasında değerler oluşturmaktadır. Zaman adımlarındaki bilgi akışının kontrolü güncelleme kapısı tarafından yapılmakta olup, LSTM ağındaki giriş kapısına benzer olarak, geleceği tahmin etmek için önceki katmanlardan gelen bilgilerin ne kadarının hatırlanacağına karar vermektedir. Bu nedenle uzun hafızadan sorumlu olup, kaybolan gradyan sorununu üstesinden gelmektedir. Öte yandan, sıfırlama kapısı, önceki katmanlardan geçmiş bilgilerin ne kadarının unutulacağına karar vermekte, başka bir deyişle kısa hafızadan sorumlu olmaktadır.

Ağ, mevcut girdi vektörü  $x_t$  tarafından beslenirken, önceki katman değerleri  $h_{t-1}$  olup, modelin parametreleri  $W_z, W_r, W_h$  (ileri besleme bağlantıları) ve  $U_z, U_r, U_h$  (tekrarlayan ağırlıklar) matrislerini oluşturmaktadır. Mimari son olarak, doğrusal olmayanlar uygulanmadan önce eklenen  $b_z, b_r, b_h$  eğitilebilir gürültü vektörlerini içermektedir.

Bu durumda güncelleme kapısı ( $z_t$ );

$$z_t = \sigma(W_z \cdot [h_{t-1}, x_t] + b_z) \quad (3.2.2.2.1)$$

Sıfırlama kapısı ( $r_t$ );

$$r_t = \sigma(W_r \cdot [h_{t-1}, x_t] + b_r) \quad (3.2.2.2.2)$$

formülleri kullanılarak hesaplanmaktadır.

GRU biriminde, doğrudan  $h_t$  vektörünü hesaplamak yerine, önce bunun için bir aday ( $\tilde{h}_t$ ) hesaplanmakta olup, Hadamart (eleman bazında) çarpımı  $\odot$  kullanılarak mevcut hafıza içeriği;

$$\tilde{h}_t = \tanh(W_h \cdot r_t \odot h_{t-1}, x_t] + b_h) \quad (3.2.2.2.3)$$

Son olarak, mevcut andaki çıktı vektörü;

$$h_t = (1 - z_t) \odot h_{t-1} + z_t \odot \tilde{h}_t \quad (3.2.2.2.4)$$

formülleri kullanılarak hesaplanmaktadır.

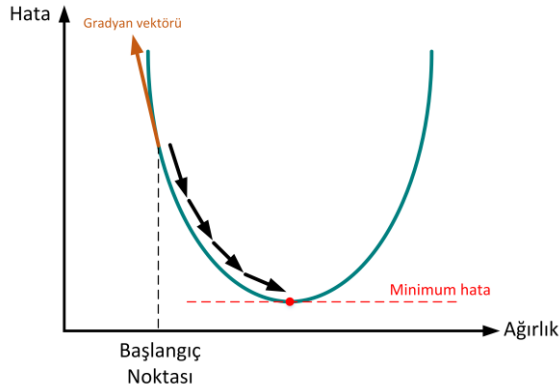
Derin öğrenme modelleri oluşturulurken, çok katmanlı ağ yapısını en iyi şekilde tasarlamak problemin çözümünde büyük etkiye sahiptir. Katman sayısı ve aktivasyon fonksiyonu gibi ANN'lerde kullanılan temel parametrelerin yanı sıra, derin öğrenme modellerinde tasarımcı tarafından karar verilmesini bekleyen bir dizi hiperparametre grubu da mevcut olup, hiperparametre seçimi, sinir ağlarının daha hızlı öğrenmesini ve gelişmiş performans elde etmesini sağlamaktadır. Hiperparametrelerin seçimi genelde tasarımcının sezgisine, daha önceki problemlerden elde edilen tecrübeler, farklı alanlardaki uygulamaların kendi problemimize yansımalarına, güncel trendlere, model içindeki tasarım bağımlılığı vb.



göre değişmektedir. Tez kapsamında derin öğrenme modelleri arasında ele alınan LSTM ve GRU modelleri için kullanılan hiperparametrelere ilişkin açıklamalar bu bölümde ele alınmaktadır.

Derin öğrenme modelleri oluşturulurken, veri hazırlama sürecinde modelimize uygun veri yapıları kullanmak önem arz etmektedir. Eğitim için kullanılacak veriler sayısal olarak ifade edilmeli, nitel veriler mevcut ise kategorik sınıflara ayrılarak niceliksel olarak ifade edilmesi gerekmektedir. Verilerin hazırlanması işleminden sonra girdilerin sonuç üzerinde tutarlı sonuçlar sağlamasını sağlamak için verilere normalleştirme işlemi uygulanmaktadır. Normalleştirme verileri genellikle 0 ile 1 arasında bir aralığa yeniden ölçeklendirme işlemi oluşturmaktadır. Epochs (Dönem) sayısı, modelin kaç kez eğitildiği veya tüm eğitim tamamlandıktan sonra ağırlıkları güncellemek için geri dönüp veri setini yeniden kullanıldığı sayı olarak tanımlanmaktadır. Bu parametre oldukça ampirik bir parametre olup çok fazla tekrar sayısı test doğruluğunu düşürmekte, çok az tekrar ise modelin optimal sonuca yakınsamadan durdurulmasına sebep olabilmektedir. Düşüm seyreltme (Dropout), sinir ağları için aşırı uydurma ile başa çıkmak için kullanılmaktadır. Ağ içindeki bazı bağlantıların kaldırılması ağırlık değişimlerinin daha aza indirilmesi ile hem zamandan tasarruf edilmekte hem de eğitim performansı açısından daha iyi performans sağlaması amaçlanmaktadır. 0 ile 1 arasındaki herhangi bir kayan değer kullanılabilir. Dropout yöntemi derin öğrenme yöntemlerinde en sık kullanılan iyileştirme (regularization) yöntemlerinden biridir. Büyük veri setleri ile çalışırken, veri setinde bulunan tüm verileri aynı anda işlemek, öğrenme, zaman ve bellek açısından maliyetli oluşturmaktadır. Batch boyutu ağa verilen alt numunelerin sayısı olarak tanımlanmakta olup aynı anda kaç verinin işleneceğini de belirlemektedir. Öğrenme oranı, model ağırlıkları her güncellendiğinde tahmini hataya yanıt olarak modelin ne kadar değiştirileceğini kontrol eden bir hiperparametre olarak ayarlanmaktadır. Sabit değer olarak ya da adım adım artan bir değer olarak da belirlenebilmektedir. Çok küçük bir değer, takılıp kalabilecek uzun bir eğitim süreci ile sonuçlanabilirken, çok büyük bir değer, optimal olmayan bir ağırlık setinin çok hızlı öğrenilmesi veya kararsız bir eğitim süreci ile sonuçlanabilmektedir. Optimize ediciler modelimizin amaç fonksiyonunu en aza indirmekten sorumludur. Türevlenebilir bir fonksiyon için teorik olarak minimum noktayı bulmak kolayken, sinir ağlarında olası en küçük kayıp fonksiyonunu veren ağırlık değerlerini bulmak kolay olmamaktadır.  $X = \{(x_t, y_t)\}_{t=1}^T$  bir öğrenme

veri kümesi olup,  $\hat{y}(x_t; w)$  optimize edilmiş bir modeli tanımlarken, ağ modellerinde optimizasyon problemi, amaç fonksiyonunu minimize eden bir algoritma tanımlanarak  $(Q(\hat{y}, X) = \frac{1}{T} \sum_{t=1}^T L(y_t, \hat{y}(x_t; w)) \rightarrow \min_w)$  çözüme ulaşmaktadır. Optimizasyon için çeşitli gradyan tabanlı optimizasyon algoritmaları kullanılmaktadır. RMSprop algoritması, öğrenme oranını ölçeklemek için kare gradyanları kullanırken, momentumlu stokastik gradyan iniş algoritması, gradyanın kendisi yerine gradyanın hareketli ortalamasını kullanmaktadır. Adam algoritması, derin sinir ağlarını eğitmek için özel olarak tasarlanan, eğitim verilerine dayalı olarak ağ ağırlıklarını yinelemeli olarak güncellemek için klasik stokastik gradyan iniş prosedürü yerine kullanılabilen, uyarlanabilir bir öğrenme oranına sahip optimizasyon algoritmasıdır.



**Şekil 14. Stokastik Gradyan İniş (Güdelek, 2019)**

Şekil 14'te literatürde sık kullanılan ve tez kapsamında tercih edilen Stokastik gradyan iniş (olasılıksal dereceli azalma) algoritmasının temsili verilmektedir. Veri setinin büyük olduğu durumlarda ya da çevrimiçi öğrenme yöntemi tercih edildiğinde sıklıkla tercih edilen bir algoritma olarak karşımıza çıkmaktadır. Veri setinin tümünü hafızasında tutup optimizasyon uygulamaktansa yalnızca birkaç eğitim örneği gördükten sonra amaca yönelik negatif eğim izleyerek optimizasyonu sağlamaktadır. Olasılıksal dereceli azalmanın bu yaklaşımı yapay sinir ağlarında büyük bir maliyetten kurtarmakta ve hız kazandırmaktadır.

## 4. MODEL PERFORMANSINI DEĞERLENDİRME KRİTERLERİ

Farklı tahmin modellerinin tahmin güçlerini karşılaştırmak istendiğinde ya da en iyi modelin seçilmesi istendiğinde, performans karşılaştırması için sayısal bir kriter gerekmektedir. En iyi modelin verilere uygun olmasının yanı sıra tahmin başarısının da yüksek olması beklenmektedir. Bu nedenle, aynı sürecin yeni ve bağımsız gözlemlerindeki tahmin hatası, bir doğruluk ölçüsünün temelini oluşturmaktadır.

Genel olarak, bir tahmin edicinin  $\theta$  parametresi etrafına yayılması, tahmin edicinin verimliliği ve performansının bir ölçüsüdür. Bu performans, ortalama hata karesi bulunarak hesaplanmaktadır.

Model hatasının minimum olma beklentisi, tahmin edilen parametre sayısı ile ilgili olmakla birlikte gözlem sayısından bağımsız olmaktadır. Varyansı düşük olan yöntem ile tahminlenen parametreler gerçek değerlerine yakın olacağından, parametre tahmininde kullanılan yöntemlerden varyansı en düşük olan yöntem seçilmektedir.

Çeşitli tahmin modelleri arasından en uygun modeli seçme sürecinde yaygın kabul gören kriterlerden birisi, modelin verilere iyi uyum gösteren yani modelin öngörü başarısının yüksek olan modeli tercih etmektir. Bu amaçla modellerin tahmin başarılarının karşılaştırılmaları amacıyla çeşitli kriterler kullanılmaktadır.

Ortalama hata (Mean Error - ME) bir modelin öngördüğü tahmin değerleri ile gerçek değerlerin arasındaki ortalama hatayı vermektedir. Aykırı değerlere karşı duyarlı olmayan bir ölçüt olup, tahmini değer ile gerçek değer arasındaki farkı dikkate alarak hesaplanmaktadır.

$n$ , durağan hale getirilen serinin gözlem sayısı,  $k$ , modeldeki parametre sayısı,  $\hat{Y}_t$ ; modelden elde edilen tahmin değeri,  $Y_t$ ; gözlem değeri olmak üzere;

$$ME = \frac{1}{n} \sum_{i=1}^n e_i \quad (4.1)$$

şeklinde hesaplanmaktadır.

Ortalama mutlak hata (Mean Absolute Error - MAE) ise iki sürekli deęişken arasındaki farkın ölçüsüdür. MAE, her gerçek deęer ile veriye en iyi uyan çizgi arasındaki ortalama dikey mesafeyi başka bir deyişle, tahmin nedeniyle oluşan genel hatanın büyüklüğünü dikkate almaktadır. Kolay yorumlanabilir olması nedeniyle regresyon ve zaman serisi problemlerinde sıkça kullanılmaktadır.

$$MAE = \frac{1}{n} \sum_{i=1}^n |e_i| \quad (4.2)$$

Ortalama Kare Hata (Mean Squared Error- MSE), hatanın büyüklüğünü kuadratik olarak ölçen bir metrik olduğu için büyük sapmaların olması durumunda abartılı sonuçlar verebilmektedir. Tahminin yanlışlık ve varyansının bir kombinasyonu olarak hesaplanmaktadır.

$$MSE = \frac{1}{n} \sum_{i=1}^n e_i^2 \quad (4.3)$$

RMSE Kök Ortalama Kare Hata (Root Mean Square Error - RMSE), ortalama kare hatanın standart sapmasını vermektedir. Hatalar regresyon çizgisinin veri noktalarından ne kadar uzakta olduğunu ölçerken, RMSE bunların ne kadar yayıldığıнын bir ölçmektedir. RMSE deęerinin sıfır olması halinde modelin hiç hata yapmadığı anlamı çıkartılırken, RMSE hesaplamada büyük hatalardan daha fazla etkilenmektedir.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n e_i^2} \quad (4.4)$$

Ortalama Yüzde Hata (Mean Percentage Error - MPE), hataların ortalama yüzdesidir. MPE deęeri hesaplanırken tahmin hatalarının mutlak deęerlerinden ziyade gerçek deęerleri kullanıldığı için, pozitif ve negatif tahmin hataları birbirini dengeleyebilmektedir. Tahmin yönteminin yansız olup olmadığının belirlenmesi gerektiğinde, modelden hesaplanan deęerler, gerçekleşen deęerlerin altında veya üstünde çıkıyorsa yansızlık gerçekleşmemekte, bu gibi durumlarda MPE tercih edilmektedir. Eksik deęerlerin olduğu veya tek bir gerçek deęerin 0 olması durumunda ölçüt kullanılamamaktadır.

$$MPE = \frac{100}{n} \sum_{i=1}^n \frac{e_i}{Y_i} \quad (4.5)$$

Ortalama Mutlak Yüzde Hata (Mean Absolute Percentage Error - MAPE): Regresyon ve zaman serileri modellerinde tahminlerin doğruluğunu ölçmek için sıkça kullanılmakta olup, tahmin yapılırken meydana gelen ortalama hata yüzdesini temsil etmektedir. Gerçek değerler içerisinde 0 gözlem değeri olduğunda, MAPE ölçütü hesaplanamamaktadır. MAPE, tahminleyicilerin doğruluğunu karşılaştırmak için kullanıldığında, tahminleri çok düşük olan bir yöntemi sistematik olarak seçmesi nedeniyle önyargılı olabilmektedir. Ele alınan verilerden hesaplanan hata değerlerinin birim değerleri farklı olduğunda, örneğin bir tahmin modeli gerçek değerleri kullanıyor iken bir başka tahmin modeli doğal logaritması alınmış değerleri kullanıyorsa bu ölçüt kullanılmaktadır.

$$MAPE = \frac{100\%}{n} \sum_{i=1}^n \frac{|e_i|}{Y_i} \quad (4.6)$$

Hesaplanan ölçütlerde daha düşük değere sahip modelin daha iyi performans gösterdiği anlamına gelmektedir.

Mutlak doğruluk ölçüleri, değişimler arasındaki farkın mutlak değerini hesaplar, fakat büyük gecikmelere sahip zaman serileri modellerinde, gecikmeli tahminin otokovaryansının her zaman gerçek otokovaryans fonksiyonundan uzak olduğu durumlarda, başarılı bir değerlendirme ölçütü olmamaktadır (Broersen, 2006).

## 5. HİBRİT DERİN ÖĞRENME MODELLERİ İLE HİSSE SENEDİ FİYAT TAHMİNİ

Borsa İstanbul'da, piyasada oluşan hareketlerin takip edilebilmesi, ihraç edilen finansal ürünlerde dayanak varlık olarak ele alınması, kolektif yatırım araçları için karşılaştırma ölçütü sağlama amaçlarıyla farklı nitelikte endeksler hesaplamaktadır (BIST Endeksleri, 2022). Bu amaçla Yıldız Pazar'da işlem gören şirketler arasından seçilen, fiili dolaşımdaki hisselerin ortalama piyasa değeri ve günlük ortalama işlem hacmi yüksek olan 14 adet banka hissesinden oluşan XBANK endeksi uygulama verisi olarak seçilmektedir.

**Tablo 1. BIST Banka Endeksine Ait Tanımlayıcı İstatistikler**

Değişkenler	Ortalama	Standart Sapma	Minimum	Maksimum	Gözlem Sayısı
Kapanış Değeri	1378,56	200,9	932,24	1992,54	3036

Tablo 1'de çalışmada kullanılan BIST Banka endeksi kapanış verilerine ilişkin tanımlayıcı istatistikler gösterilmektedir. 4 Ocak 2010 – 31 Ocak 2022 dönemini kapsayan verilerde teknik analiz göstergelerinin hesaplanabilmesi için ilk 14 veri çıkartılmış olup, toplam 3036 günlük kapanış veriler dikkate alınmaktadır. İstatistiklere bakıldığında, ortalama 1378,56 değerine sahipken, 200,90 standart sapması değeri ile verilen tarih aralığında en yüksek 1992,54, en düşük 932,24 değerini almaktadır.

Zaman serilerinin analizi için literatürde farklı model yaklaşımları mevcuttur. Uygulamada XBANK banka endeksinin analizi için derin öğrenme kapsamında zamansal ilişkileri dikkate alan LSTM ve GRU modelleri tercih edilmiş olup, ayrıca ekonometrik modeller kapsamında ARIMA modeli ve teknik analizde kullanılan göstergelerin kullanımı ile farklı model yapıları ortaya koyulmaktadır. Ortaya konulan farklı model yapılarının etkinliğinin ve geçerliliğinin ve model performanslarının değerlendirilebilmesi için modellere ait öngörü değerleri ve hataya bağlı model performansı değerlendirme metrikleri karşılaştırılmaktadır.


Tüm uygulamalar Intel(R) Core(TM) i5-10300H CPU, 2.50GHz işlemci, 8GB RAM donanımlarına sahip bir bilgisayarda gerçekleştirilmiş olup, uygulamaları gerçekleştirmek için Python programlama dilinin 3.8.8 versiyonu kullanılmıştır.

Uygulamalar Jupyter Notebook üzerinde gerçekleştirilmiş olup, Google tarafından geliştirilen TensorFlow kütüphanesi ve bu kütüphane üzerine inşa edilmiş derin öğrenme uygulamalarında sıklıkla kullanılan Keras kütüphanesi ve bunların yanı sıra destekleyici olarak Python veri işlemlerinde kullanılan Pandas, Numpy, Scikit-Learn, TA-lib, Matplotlib kütüphanelerinden faydalanılmıştır.

Tezin uygulama çerçevesinde, XBank endeksine ait kapanış fiyatlarının öngörü tahminleri için, LSTM, ARIMA-LSTM, TA-LSTM, ARIMATA-LSTM, GRU, ARIMA-GRU, TA-GRU VE ARIMA-TA-GRU OLMAK ÜZERE 8 farklı model kombinasyonu ele alınmaktadır. LSTM modelinde sadece kapanış fiyatları ele alınırken, ARIMA-LSTM modelinde ARIMA modelinden elde edilen artıklar LSTM modeline girdi olarak sunulmaktadır. TA-LSTM modelinde ise teknik analiz gösterge serileri girdi olarak ele alınırken ARIMA-TA-LSTM modelinde hem ARIMA model artıkları hem de teknik göstergeler modele dâhil edilmektedir. Benzer girdi değişkeni kombinasyonları GRU modeli içinde geçerli olmaktadır.

İlk olarak ARIMA modelinin tahmin edilen değeri ile gerçek değeri arasındaki fark olarak elde edilen artıklar hesaplanarak, tahmin için LSTM ve GRU modellerine girdi olarak sunulması ve doğrusal olmayan yapıdaki problemler için derin öğrenme yönteminin avantajlarının kullanılması amaçlanmaktadır.

XBank endeksine ait kapanış fiyatları zaman serisi grafiği Şekil 15'te verilmektedir.



**Şekil 15. BIST Banka Kapanış Fiyatı Verilerine Ait Zaman Serisi Grafiği**

Şekil 15'te verilen serinin zamana göre eğilimi incelendiğinde trendin varlığı söz konusu değil iken mevsimsellik de barındırmadığı görülmektedir. Ayrıca otokorelasyonun varlığı araştırılmış olup, ilişkinin olmadığı ve hataların normal dağılıma yakınsadığını sonucuna varılmaktadır. Seriyeye ARIMA modelinin uygulanabilmesi için öncelikle durağanlık yapısı araştırılmaktadır. Zaman serilerinin durağanlığı ACF ve PACF şeklindeki otokorelasyon ya da kısmi korelasyon testleriyle veya birim kök testleriyle yapılabilmektedir.

**Tablo 2. ADF, PP ve KPSS Birim Kök Testi Sonuçları**

Test	ADF		PP		KPSS	
	Sabit	Sabit ve Trendli	Sabit	Sabit ve Trendli	Sabit	Sabit ve Trendli
İstatistiği	-3,6238	-3,6486	-3,6358	-3,6607	0,2024	0,1660
1%	<b>-3,4323</b>	-3,9611	<b>-3,4323</b>	-3,9611	0,7390	0,2160
5%	<b>-2,8623</b>	<b>-3,4113</b>	<b>-2,8623</b>	<b>-3,4113</b>	0,4630	<b>0,1460</b>
10%	<b>-2,5672</b>	<b>-3,1275</b>	<b>-2,5672</b>	<b>-3,1275</b>	0,3470	<b>0,1190</b>

Tablo 2’te ADF, PP ve KPSS birim kök testi sonuçlarına yer verilmektedir. Sonuçlar, modelin yalnızca sabitli olarak ele alındığında, 0,05 anlamlılık seviyesinde, ADF ve PP testlerine göre durağan olduğu göstermektedir. Sabitli ve trendli olarak analiz yeniden yapıldığında her üç test için serinin durağan olduğu görülmektedir. Sonuçların durağanlığa işaret etmesi, yapısal kırılmalı birim kök testlerinin yapılması gerekliliğini ortadan kaldırmakta, XBANK kapanış fiyatları için klasik birim kök test sonuçlarının dikkate alınmasının yeterli olduğunu göstermektedir.

Birim kök testlerinin sağladığı bilgiler sonrasında, serinin ARIMA modellerinin oluşturulması amacıyla, p ve q gecikme değerleri için yapılan en iyi model aramalarında kapanış fiyatı tahmin modelleri için, Python programında piramid-arima kitaplığı kullanılarak auto.arima fonksiyonu ile 7 gecikme değerine kadar farklı model kombinasyonları otomatik olarak oluşturulmaktadır. AIC (Akaike Bilgi Kriteri) değeri, bir modelin verilere ne kadar iyi uyduğunu karşılaştırmamıza ve bir modelin karmaşıklığını hesaba katmamıza olanak tanımaktadır. Kurulan modeller arasında daha iyi (daha düşük) AIC değerini ARMA (4,3) modeli vermektedir. Seçilen ARIMA modeli kullanılarak gerçek değer ve tahmin edilen değer arasındaki fark olarak elde edilen artıklar, LSTM ve GRU modellerine girdi olarak sunulmaktadır.



Geleneksel teknik göstergeleri kullanarak yatırım kararı almak sıklıkla kullanılan bir yöntemdir. Fakat teknik göstergelerin yorumu özeldir ve sinyallerin yanlış yorumlanması ihtimalini barındırmaktadır. Yatırım stratejisine karar vermek için sadece teknik göstergelerin kullanılmasından ziyade bir tahmin modeli ile birleştirmek karar verici için riski azaltmaktadır. LSTM ve GRU gibi derin öğrenme modellerini kullanmak, trendi anlamak ve hisse senedi fiyatında beklenmeyen sıçramaları tahmin etmek başarılı yöntemler olarak karşımıza çıkmaktadır. Çalışma kapsamında teknik analiz göstergelerinin model başarısına etkisini değerlendirmek amacıyla, RSI ve MA göstergeleri seçilerek, 14 gün periyodla hesaplanırken, ilk 14 gün için RSI hesaplanamayacağı için eğitim verisinden çıkarılmıştır. Modelde günlük kapanış değerlerinin tahmini için teknik analiz verilerinin kullanılmasının tahmin performansına etkisinin ölçülmesi için RSI-14 ve EMA-14 değerleri girdi verisi olarak eklenmiştir.

Her derin öğrenme modelinin görevinin bir parçası olarak, istenen doğruluğu elde etmek için hiperparametrelerin ayarlanması son derece önemlidir. Derin öğrenmede katmanlarının sayısı veya modelin derinliği kararı, hesaplama karmaşıklığı ve ince ayar arasında bir ödünleşmeye sahiptir. Derinlikteki artışla daha yüksek doğruluk elde etmek mümkün olmakla birlikte, bu durum modelin eğitilmesi için gereken süreyi önemli ölçüde arttırmaktadır.

Derin öğrenme yöntemlerinin analizi için veri setinin %80'i eğitim veri seti, %10'si ise test, %10 doğrulama veri seti olarak kullanılmaktadır. Eğitim veri seti modeli eğitmek için kullanılırken, modelin performansı için test veri seti kullanılmaktadır. Bu amaçla eğitim veri seti için hesaplanan metrikler modelin eğitiminin nasıl ilerlediğini görmemizi sağlarken, test veri seti için hesaplanan metrikler modelin başarısını ölçmek için daha doğru sonuç vermektedir.

**Tablo 3. Derin Öğrenme Modellerinde Kullanılan Diğer Hiperparametreler**

<b>Optimizasyon:</b>	Stochastic gradient descent
<b>Aktivasyon fonk.:</b>	ReLU
<b>Batch Boyutu (batch size):</b>	8
<b>Eğitim Sayısı (epoch):</b>	100
<b>Öğrenme Oranı (learning rate):</b>	0,001
<b>Seyreltme Değeri (dropout):</b>	0,5

Tablo 3'te model kurma aşamasında kullanılan hiper parametreler verilmekte olup, derin öğrenme modelleri ile çalışılırken, genellikle iterasyon sayısı arttıkça kayıplar azalmakta ve doğruluk oranı artmaktadır. Modellerin kıyaslanabilmesi için her model 100 (epoch) kez eğitilmektedir.


Gelecek 10 günün tahmini için model geçmiş 10 (n\_back) günün değerleri ile beslenmekte ve çıktı olarak gelecek 10 (n\_future) günün değerini üretmektedir. Burada tahmin değerinden bir sonraki günü tahmin etmek için, son tahmin değeri ile birlikte n-1 günlük değerler dikkate alınmaktadır.

Model eğitim verilerine başarılı bir uyum gerçekleştirirken, daha önce görmediği doğrulama veri setine başarılı sonuçlar vermemesi modelin aşırı öğrendiği ve verileri ezberlediği anlamına gelmektedir. Modelin aşırı uyum gösterip göstermediği ölçmek için modelin performansını ölçen metriklerin yanı sıra validasyon kaybı (val\_loss) ve validasyon doğruluğu (val\_acc) ölçütleri de kullanılmaktadır.

**Tablo 4. Modellerin Performans Değerlendirme Ölçütleri**

	LSTM	LSTM - Arima	LSTM - TA	LSTM-ARIMA-TA	GRU	GRU-ARIMA	GRU-TA	GRU-ARIMA-TA
<b>MSE</b>	0,0086	0,0089	0,0084	0,0047	0,0035	0,0035	0,0032	<b>0,0031</b>
<b>MAE</b>	0,0711	0,0714	0,0693	0,0520	0,0445	0,0444	0,0428	<b>0,0421</b>
<b>Val_MSE</b>	0,0060	0,0057	0,0054	0,0034	0,0035	0,0034	0,0035	<b>0,0032</b>
<b>Val_MAE</b>	0,0606	0,0596	0,0586	0,0439	0,0461	0,0458	0,0457	<b>0,0441</b>

Tablo 4'te verilen sonuçlara göre, GRU modeli LSTM modeli ile kıyaslandığında, genel olarak küçük hatalara sahip olduğu görülmektedir. Ele alınan 8 farklı model içerisinde ARIMA modelinin artıkları ve teknik analiz göstergeleri girdi olarak kullanılan GRU modelinin 0,0031 MSE, 0,0421 MAE ile en düşük hata oranlarına sahip, en başarılı model olduğu sonucuna varılmaktadır. Doğrulama verileri için hesaplanan hata metriklerine bakıldığında 0,0032 MSE ve 0,0441 MAE oranı ile modelin daha önce görmediği verilerde de başarılı tahminler ürettiği görülmektedir.




**Şekil 16. ARIMA+TA+GRU Modeline Ait 100 Epoch Eğitim/Test Kayıp Grafiği**

Şekil 16'da GRU-ARIMA-TA modelinin 100 epoch değeri boyunca kayıp grafiği verilmektedir.

**Tablo 5. Uygulama Sonucunda Elde Edilen 10 Günlük Tahmin Değerleri**

	Örnekl em Dışı Veriler	LSTM	LSTM-ARIMA	LSTM-TA	LSTM - ARIMA TA	GRU	GRU-ARIMA	GRU-TA	GRU-ARIMA-TA
<b>1.02.2022</b>	1.769,28	1692,83	1697,65	1681,36	1761,15	<b>1763,33</b>	1759,96	1831,12	1777,20
<b>2.02.2022</b>	1.817,16	1710,35	1713,26	1686,64	1762,53	1763,53	1761,48	<b>1831,09</b>	1783,66
<b>3.02.2022</b>	1.750,40	1680,70	1721,30	1693,07	<b>1759,20</b>	1765,09	1764,95	1840,58	1800,65
<b>4.02.2022</b>	1.742,99	1683,39	1687,86	1689,27	<b>1754,64</b>	1760,04	1760,59	1839,67	1796,24
<b>7.02.2022</b>	1.750,60	1691,59	1690,44	1681,27	<b>1755,41</b>	1762,04	1760,55	1846,66	1808,93
<b>8.02.2022</b>	1.765,53	1702,13	1656,09	1674,07	1749,24	<b>1755,23</b>	1751,88	1845,00	1799,23
<b>9.02.2022</b>	1.787,85	1707,67	1685,15	1670,47	1751,14	1754,83	1752,25	1849,35	<b>1802,07</b>
<b>10.02.2022</b>	1.781,18	1671,54	1674,65	1682,19	1748,23	1743,88	1743,23	1835,58	<b>1787,89</b>
<b>11.02.2022</b>	1.790,35	1702,49	1662,09	1673,59	1745,06	1743,30	1744,21	1838,22	<b>1791,02</b>
<b>14.02.2022</b>	1.763,22	1679,39	1688,52	1668,97	1740,78	1740,76	<b>1747,30</b>	1839,83	1790,48

Tablo 5'da verilen sonuçlar incelendiğinde, GRU modelinin, kapanış fiyatları tahmininde LSTM modeline göre üstün olduğu görülmektedir. Ayrıca GRU-ARIMA-TA modeli, örnekleme dışı gerçek verilere en yakın sonuçları vermiş olup, hibrit model kullanmanın model tahmin başarısına arttırmada etkisi olduğu görülmektedir.



**Şekil 17. GRU-ARIMA-TA Modeline İlişkin Test Verileri Tahmin Grafiği**

Şekil 17’de seçilen modele ilişkin test verilerinin tahmin grafiği verilmekte olup, modelin test verilerini tahmin etmede başarılı bir uyum gösterdiği görülmektedir.



**Şekil 18. GRU-ARIMA-TA Modeline İlişkin Tahmin Grafiği**

Şekil 18’de verilen zaman serisi tahmin grafikleri incelendiğinde modelin gerçek değerlere mükemmele yakın uyum gösterdiği görülmektedir.

## Sonuç

Hisse senetleri yatırım tercihi olarak finansal piyasalarda en çok rağbet gören finansal varlıklar arasında yer almaktadır. Her tür yatırım kararının alınmasında olduğu gibi hisse senedi satın alınarak yapılan yatırımlarda da yatırımcı rasyonel davranmaktadır. Bu davranışında beklenti ve içgüdülerini dikkate alarak karar veren yatırımcı, aynı zamanda matematiksel hesaplamaları dikkate alarak, geçmiş dönem verilerini değerlendirerek ve daha önceki hatalarını tekrarlamayarak, kararında başarı olasılığını arttırmaktadır. Yatırımcı, yatırımından doğacak bütün riskleri üstlenmekte, aynı zamanda riskleri en aza indirmeye çalışırken, kendi öz sermayesini en üst seviyede tutmaya çalışmaktadır.

Günlük eylemlerimizi otomatikleştirme gibi görevleri üstlenen yapay zekâ teknolojileri her geçen gün gelişmekte olup, finans alanında da değişim eskiye oranla daha hızlı ilerlemektedir. Bilgisayarların iş hayatında kullanımının yaygınlaşması ve büyük verileri hızlı ve başarılı şekilde analiz etmeye imkân sağlayan algoritmaların geliştirilmesi ile finansal analiz sadece uzmanlık alanı gerektiren bir konu olmayıp, yapay zekâ teknolojilerinin desteği ile daha kolay uygulanabilir hale gelmektedir. Son yıllarda finansal yatırım alanında yapay zekânın kullanımına ilişkin gelişmeler dikkate alındığında, yapay zekâ teknolojileri ile yatırım maliyetlerinin azaltılması, analizlerin daha hızlı gerçekleştirilmesi, yatırım riskinin azalması, her zaman ulaşılabilir danışmanlık sağlanması ve kişisel kullanım sağlanması yönleriyle büyük avantajlar sağlamaktadır.

Zaman serisi analizlerinin temel amacı, bir sistem veya sürecin geçmiş gözlemlerini dikkate alarak süreçteki doğal yapıyı tanımlayabilen uygun bir model geliştirmek ve serinin karmaşık ve dinamik davranışını analiz etmektir. Geliştirilen başarılı bir model ile sürecin gelecekteki değerlerini veya oluşumlarını anlamak mümkün olmaktadır. Finansal zaman serisi verileri, genellikle kompleks, yüksek gürültü içeren, dinamik, doğrusal olmayan ve parametrik olmayan, veriler olduğu ve öngörülmenin zorlaştığı değişken bir yapıya sahip olup, bu zorluğun çözümünde bir finansal varlığın değeri yapay zeka alanının alt alanı olan makine öğrenim algoritmalarını kullanılarak farklı yaklaşımlar ile başarılı bir şekilde tahmin edilebilmektedir. Finansal alanında yapılan yatırımlarda daha yüksek kazançlar sağlamak amacıyla makine öğrenim algoritmalarının kullanılması, verilerin içerdiği

örüntü ve ilişkiler başarılı bir şekilde öğrenilip, daha doğru risk ve getiri tahminleri elde edilmesini ve alım satım kararlarında daha düşük maliyetleri sağlama avantajlarını sağlamaktadır.

Makine öğrenimi yöntemlerinin finansal piyasanın tahminindeki potansiyelleri dikkate alındığında, tüm makine öğrenimi yöntemleri arasından sinir ağları, finansal piyasayı tahmin etmek ve modellemek için başarılı sonuçlar vermektedir. Sinir ağları, problem için bir girdi-çıkıı eşlemesi oluşturarak örneklerden öğrenmektedir. Hisse senetleri fiyat verilerinin karmaşıklığı göz önüne alındığında, sinir ağlarının gürültü torelansı, eksik verilerle eğitim ve yeni veri kalıplarını kullanarak yeniden eğitim süreci aracılığıyla dinamik sistemleri öğrenme yetenekleriyle, probleme yönelik oldukça elverişli modeller olmaktadır. Sinir ağlarının son zamanlarda oldukça popüler ve geliştirilmiş hali olan, derin öğrenme, birçok basamaklı katmandan oluşan güçlü makine öğrenimi algoritmaları arasında yer almaktadır. Derin öğrenme modelleri arasında yer alan LSTM ve GRU modelleri, zaman serilerinin analizinde benzersiz katmanları ve kullanan paralel hesaplama mimarileri ile eğitim ve tahmin görevlerini daha hızlı uygulanabilir hale getirmektedir. LSTM, zaman içinde geri yayılma mimarisi kullanılarak eğitilen ve kaybolan gradyan sorununun üstesinden gelen tekrarlayan bir sinir ağı modeli olup, yalnızca tek veri noktalarını değil, aynı zamanda tüm veri dizilerini işleyebilme ve bilgileri belirli bir süre boyunca saklayabilme yeteneğiyle zaman serileri analizinde son derece kullanışlı modeller arasında yer almaktadır. LSTM ağlarına benzer şekilde, GRU, ünite içindeki bilgi akışını modelleyen ancak ayrı bir hafıza hücresine sahip olmayan geçit birimlerini kullanmakta olup, yine benzer şekilde zaman serisi verilerini ve uzun süreli bağımlılıklarını, zaman boyunca silmeden bellekte tutma kabiliyetine sahip olmaktadır.

Makine öğrenimi algoritmaları, hem tarihsel hem de gerçek zamanlı olarak tahmin değerlerini elde edilip, alım-satım kararlarının alımında hızlı davranma kolaylığını sağlamaktadır. Ancak birçok makine öğrenimi algoritması, faydalı sonuçlar vermeye başlamadan önce büyük miktarda veri gerektirmektedir. Özellikle sinir ağları, bol miktarda eğitim verisi gerektiren modeller olmakta, mimari ne kadar büyük olursa, uygulanabilir sonuçlar üretmek için o kadar fazla veri gerekmektedir. İstatistiksel analizler ile makine öğrenimi karşılaştırıldığında, istatistiksel analizler doğası gereği doğrulayıcı özellikteyken, makine öğrenimi algoritmaları keşfedici özellikler

sergilemektedir. Büyük veri boyutları ile birlikte ele alınan model içerisinde çok fazla değişken kullanılması, makine öğrenme algoritmalarını nedensel ilişkilerden ziyade anlamlı sonuçlar gösteren korelasyonlar bulana kadar çalışmasını sağlamakta ya da aşırı uyum ile sonuçların geçerliliği kaybolmaktadır. Ayrıca büyük boyutlu analizler için bilgisayar donanım ihtiyacı fazla olan sinir ağları, eğitilebilmeleri için de fazla bellek ve süre gerektirmektedir. Makine öğrenimi algoritmalarını finans alanında uygulamanın zorluğu, makine öğreniminin sadece tahminle ilgilenmesiyken, finans alanındaki araştırmaların nedensel çıkarım ve hipotez testlerini de içermesinden kaynaklanmaktadır.

Zaman serisi verilerini analiz etmek için kullanılacak ve tez kapsamında ele alınan bir diğer yöntem, ARIMA modellerini uygulamaktır. Kısa vadeli tahminler için genellikle başarılı sonuçlar vermekte olan yöntem, çoğu model yapısında ön koşul ve uygulama için alanında uzman bilgisi gerektirmektedir. Ekonomide meydana gelen değişimler ve siyasi olayların etkisiyle, finansal alanda derlenen serilerde şoklar, yüksek volatilité kümelenmeleri ve yapısal kırılmalar oluşmakta ve durağanlık yapısı bozulmaktadır. Ele alınan verilerde, durağan olmayan yapının yanı sıra kalın kuyruk dağılımı gibi özellikler ile normal olmayan dağılım sergilediğinde, ARIMA modelleri uygulanamamaktadır. Zaman serisi analizinin diğer bir dezavantajı, ele alınan veri seti içinde çok sayıda uç değer olması durumunda, hataların tüm tahminler boyunca yayılarak, doğru sonuçlar vermemesine yol açmaktadır. ARIMA modelleri, tahmin modellerini oluştururken geçmiş verilere dayanan zaman serisi analizini kullanmaktadır. Bu modeller, geçmiş verilerden öğrenmekte ve gelecekteki değeri tahmin etmek için geçmiş eğilimleri bir temel olarak kullanmaktadır. Finans piyasalarının dinamik yapısı göz önüne alındığında, geçmiş eğilimlerin istikrarlı ve sürekli olduğu varsayımı sorunla karşılaşmaktadır. Bununla birlikte bazı durumlarda, zamansal etkiler o kadar zayıftır ki, sadece geçmiş verileri ele alarak tek değişkenli model yapılarını kullanmak yetersiz kalmaktadır. Ayrıca gelişen internet ve bilgisayar teknolojileri ile birlikte bilinen veri ve veri analizi kavramlarının değişmesine neden olmaktadır. Teknolojideki gelişmeler verinin boyutunda ve çeşitliliğinde önemli bir artış yaratmakta, çok yüksek boyutlu verilerin analizi yeni analiz tekniklerinin kullanımını gerekli kılmaktadır.

Finansal analizlerde tahminler yapabilmek için teknik analiz yöntemi sıklıkla kullanılmakta olup, hisse senedi fiyat hareketlerine neden olabilecek tüm temel

bilgilerin ve ekonomik faktörlerin zaten fiyatlara yansıdığı varsaymakta, finansal piyasalardaki geçmiş fiyat hareketleri kullanılarak ve belirli analiz yöntemlerine göre yorumlanarak, gelecekteki fiyat hareketlerinin yönü tahmin edilmeye çalışılmaktadır. Fakat teknik göstergelerin yorumu öznel ve sinyallerin yanlış yorumlanması ihtimalini barındırmaktadır.

Model seçim konusunda veri en önemli niteleyici olmaktadır. Amaç ya da probleme ilişkin uygun model seçiminde veri yapısı ve kullanılacak yöntemin avantaj ve dezavantajları dikkate alınarak karar vermek gerekmektedir. Tek bir kullanıma hazır yöntemin, zaman serisi verilerinin dinamikliği nedeniyle tüm gereksinimleri karşılamasında yeterli olmaması halinde, hem geleneksel hem de makine öğrenimi yöntemlerini birlikte kullanan hibrit bir model yaklaşımı kullanmak, verilerdeki hem doğrusal hem de doğrusal olmayan yapıları modelleyebilen ve tahmin için iyi ve verimli bir alternatif haline gelen bir model oluşturmaktadır.

Hibrit modellerin ana hedefi, başarı performanslarını arttırmak için modellerin birlikte kullanımına dayanmaktadır. Veri yapılarındaki farklı yapıları birlikte ele almak için farklı model yaklaşımlarını bir araya getirilen modeller ile daha başarılı sonuçlar elde etmek amaçlanmaktadır. Bu amaçla, hem ekonometrik modelleri hem de makine öğrenim algoritmalarını birlikte kullanan hibrit bir model yaklaşımı kullanmak, verilerdeki hem doğrusal hem de doğrusal olmayan yapıları dikkate alabilen, tahmin için daha başarılı bir model yaklaşımını oluşturmakta, tahmin performansını iyileştirmenin etkili bir yolu olabilmektedir. Hibrit yöntemler, her iki yöntem tipinin avantajlarını aynı anda kullanabildikleri için tekil yöntemlerden daha iyi sonuçlar vermektedir.

Hisse senedi fiyatlarını hibrit bir model yapısı kullanarak ele alındığında, fiyat serisinin geçmiş değerlerine bakarak gelecekteki değerinin ne olacağı hakkında daha başarılı tahminler yapılabilen, yatırımcı bu tahmin sonuçları ile birlikte alım satım kararlarını şekillendirerek kar sağlayabilmektedir. Tez kapsamında, hisse senetleri kapanış fiyatlarına ilişkin yüksek frekanslı verilerin analizi için hibrit derin öğrenme yaklaşımları ele alınmaktadır. LSTM ve GRU gibi derin öğrenme modelleri, trendi belirlemek ve hisse senedi fiyatında beklenmeyen sıçramaları fark etmek ve oynaklığı fazla olan verileri tahmin etmek için başarılı yöntemler olarak karşımıza çıkmaktadır. Tercih edilen derin öğrenme modellerin tahmin başarısını arttırmak amacıyla ARIMA



model artıkları ve teknik analizde kullanılan RSI ve MA göstergeleri seçilerek, 14 gün periyodla hesaplanmakta, ilk 14 gün için RSI hesaplanamayacağı için eğitim verisinden çıkartılmaktadır. Elde edilen veriler derin öğrenme modeline girdi olarak sunulduktan sonra performansları değerlendirilmektedir. Farklı model yapıları oluştururken, model performanslarını kıyaslamak amacıyla dönem sayısı, parti boyutu, öğrenme oranı, aktivasyon fonksiyonu, kayıp fonksiyonu, zaman adımı vb. hiperparametrelerin seçiminde sabit değerler kullanılmaktadır. Sonuçlar incelendiğinde, genel olarak GRU modelinin performansı diğer modellere göre daha iyi sonuçlar vermekte olup, ARIMA modeli ve teknik göstergelerin kullanımı ile oluşturulan hibrit modelde başarı olasılığı artmaktadır.

Gelecekteki çalışmalarda, yapay zekâ algoritmaları ve hibrit model kullanımının tahmin performansını arttırmada etkisi araştırılırken, günlük veriler yerine saatlik veriler kullanılarak veri seti boyutunun genişletilmesi, farklı teknik göstergelerden yararlanılması ya da siyasi ve ekonomik haberlerin internetten taranması ve anlam çıkarımı yapıldıktan sonra veri özelliklerine girdi olarak eklenmesi ile başarı oranlarını arttırmada etkili olup olmadığı dikkate alınabilir. Ayrıca, hisse senedi fiyatlarını tahmin etmede hisse senetleriyle ilgili bilgilerin duygu analizini ve hisse senetlerinin tarihsel değeriyle ilişkili sayısal değeri birleştirerek, her iki bilgiden birlikte yararlanılıp, daha etkili hisse senedi tavsiye sistemleri de oluşturulabilir. Daha iyi ve verimli özellik çıkarma teknikleri için derin öğrenme tabanlı yaklaşımlardan daha fazla yararlanılabilir.

## Kaynakça

Afeef, Mustafa - Anjum Ihsan - Hassan Zada, "Forecasting stock prices through univariate ARIMA modeling", *NUML International Journal of Business & Management*, Sayı13.2, 2018, s. 130-143.

Akay, Ebru Çağlayan, "Ekonometride yeni bir ufuk: Büyük veri ve makine öğrenmesi" *Sosyal Bilimler Araştırma Dergisi*, Sayı 7.2, 2018, s. 41-53.

Akdi, Yılmaz, *Zaman serileri analizi:(birim kökler ve kointegrasyon)*, Gazi Kitabevi, Ankara 2012.

Aladag, Cagdas-Hakan Erol Egrioglu-Cem Kadilar, "Forecasting nonlinear time series with a hybrid methodology" ,*Applied Mathematics Letters*, Sayı 22.9, 2009, s.1467-1470.

Almasarweh, Mohammad -Sadam Alwadi, "ARIMA model in predicting banking stock market data", *Modern Applied Science*, Sayı 12.11, 2018, s.309.

Altay, Oğuzhan, Uluslararası Finansal Piyasaların Genişlemesi Karşısında Türk Finans Piyasalarında Yenilenme, *SDÜ, İİBF, VI. Türkiye Finans Eğitimi Sempozyumu*, 2002, s.11-14.

Althelaya, Khaled A.- El-Sayed M- El-Alfy- Salahadin Mohammed, "Stock market forecast using multivariate analysis with bidirectional and stacked (LSTM, GRU)", *2018 21st Saudi Computer Society National Computer Conference (NCC)*, IEEE, 2018.

Amidi, S, "Recurrent Neural Network", <https://stanford.edu/~shervine/teaching/cs-230/cheatsheet-recurrent-neuralnetworks>, ,(2022 03 23).

Anderson, Dave-Mcneill, George, Artificial neural networks technology, *Kaman Sciences Corporation*, 1992, 258.6, s.1-83.

Aslanargun, Atilla- S. Ünal Şakar, "İmkb Ulusal-100 Endeksi'nin Box-Jenkins Arıma Modeli Kullanılarak Tahmin Edilmesi", *Anadolu Üniversitesi İktisadi Ve İdari Bilimler Fakültesi Dergisi*, Sayı 16.1, 2000, S. 43-56.

Athey, Susan, "The impact of machine learning on economics", *The economics of artificial intelligence: An agenda*, 2018, s. 507-547.

Atıcı, Gonca, "Finansal Piyasalar ve Kurumlar", *Finansal Yönetim Temel Teoriler ve Açıklamalı Örnekler*, Ed. Gündoğdu Aysel, Seçkin Yayıncılık, Ankara 2018, s. 51-64.

Babu, C. Narendra-B. Eswara Reddy, "A moving-average filter based hybrid ARIMA-ANN model for forecasting time series data" ,*Applied Soft Computing*, Sayı 23, 2014, s. 27-38.

Bekçioğlu Selim, *Menkul Kıymet Analizleri ve Türkiye'deki Uygulama*, (Gazi Üniversitesi Sosyal Bilimler Enstitüsü Yayınlanmamış Doktora Tezi), Ankara 1983.

Berk, Niyazi, *Finansal Yönetim*, Türkmen Kitabevi, İstanbul 1998.

Bhattacharyya, Arinjita-Tanujit Chakraborty-Shesh N. Rai., "Stochastic forecasting of COVID-19 daily new cases across countries with a novel hybrid time series model", *Nonlinear Dynamics*, 2022, s.1-16.

Bildirici, Melike-Ersin, Özgür Ömer, "Improving Forecasts Of Garch Family Models With The Artificial Neural Networks: An Application To The Daily Returns In Istanbul Stock Exchange", *Expert Systems With Applications*, Sayı 36.4, 2009 s. 55-62.

BIST Endeksleri, <https://www.borsaistanbul.com/tr/sayfa/2915/bist-endeksleri>, (15 Mart 2022).

Bollinger, John, "Using bollinger bands", *Stocks & Commodities*, Sayı 10.2,1992, s. 47-51.

Box, George. E., Jenkins, Gwilym. M., Reinsel, Gregory. C., Ve Ljung Greta. M., "Stochastic Models And Their Forecasting" , *Time Series Analysis Forecasting And Control*, Ed. G. Box, G. M. Jenkins, G. C. Fifth Edition Wiley, 2009, s. 21-126.

Broersen, Petrus MT, *Automatic autocorrelation and spectral analysis*, Springer Science & Business Media, Germany, 2006, 251-261.

Cheng, Bing,- D. Michael Titterington, "Neural networks: A review from a statistical perspective", *Statistical science*, Sayı 9.1, 1994, s. 2-30.

Chu, K., Van Merriënboer, B., Gulcehre, C., Bahdanau, D., Bougares, F., Schwenk, H., & Bengio, Y, "Learning phrase representations using RNN encoder-decoder for statistical machine translation", *arXiv preprint arXiv:1406.1078*, 2014.

Chung, J., Gulcehre, C., Cho, K., & Bengio, Y., "Empirical evaluation of gated recurrent neural networks on sequence modeling", *arXiv preprint arXiv:1412.3555*, 2014.

Conejo, A., & Conejo, A. J. , "Day-ahead electricity price forecasting using the wavelet transform and ARIMA models", *IEEE transactions on power systems*, Sayı 20.2 ,2005, s.1035-1042.

Çalışkan, Muhammed-Mustafa Tuncer-Devran Deniz, "Yapay Sinir Ağlarıyla Hisse Senedi Fiyatları Ve Yönlerinin Tahmini", *Eskişehir Osmangazi Üniversitesi İİBF Dergisi* 10.3, 2015, s.177-194.

Çetin, Elmas, *Yapay zeka uygulamaları:(yapay sinir ağı, bulanık mantık, genetik algoritma)*. Seçkin Yayıncılık, Ankara 2011.

Çevik, Osman, *Zaman serileri analizinde Box-Jenkins yöntemi ve turizm verileri üzerine bir uygulama*, (Kırıkkale Üniversitesi Sosyal Bilimler Enstitüsü İşletme Anabilim Dalı Yayınlanmamış Doktora Tezi) , Kırklareli 1999.

Dassanayake, Wajira vd., "Effectiveness of Stock Index Forecasting using ARIMA model: Evidence from New Zealand", *2021 3rd International Conference on Advancements in Computing (ICAC)*, IEEE, 2021.

Deng, Li,-Dong Yu, "Deep learning: methods and applications", *Foundations and trends in signal processing*, Sayı 7.3–4,2014, s.197-387.

Deng, Y., Bao, F., Kong, Y., Ren, Z., & Dai, Q., "Deep direct reinforcement learning for financial signal representation and trading", *IEEE transactions on neural networks and learning systems*, Sayı 28.3, 2017, s. 653-664.

El Desouky, A. A.- M. M. Elkateb, "Hybrid adaptive techniques for electric-load forecast using ANN and ARIMA", *IEE Proceedings-Generation, Transmission and Distribution*, Sayı 147.4, 2000, s. 213-217.

Dickey, David A.,- Wayne A. Fuller, "Distribution of the estimators for autoregressive time series with a unit root" ,*Journal of the American statistical association*, Sayı 74.366a, 1979, s. 427-431.

Donaldson, R. Glen - Mark Kamstra, "An artificial neural network-GARCH model for international stock return volatility", *Journal of Empirical Finance*, Sayı 4.1,1997, s17-46.

Dunis, Christian L.,- Xuehuan Huang, "Forecasting and trading currency volatility: An application of recurrent neural regression and model combination", *Journal of forecasting*, Sayı 21.5 ,2002, 317-354.

Enders, Walter, "Applied econometric time series, 1sd New York, Ed. John Willey & Sons", 1995, s. 251-276.

Fürnkranz, Johannes, "Separate-and-conquer rule learning", *Artificial Intelligence Review*, Sayı 13.1,1999, s.3-54.

Gao, Ya-Rong Wang-Enmin Zhou, "Stock Prediction Based on Optimized LSTM and GRU Models", *Scientific Programming* 2021.

Goonatilake, Suran-Philip C. Treleaven, eds., *Intelligent systems for finance and business*, , Intelligent Systems for Finance and Business 1st Edition, Ed. S. Goonatilake, West Sussex, Wiley, 1995, s. 1-29.

Greff, Klaus, vd., "LSTM: A search space odyssey", *IEEE transactions on neural networks and learning systems*, Sayı 28.10, 2016, s. 2222-2232.

Gujarati, Damodar, *Basic econometrics fourth (4th) edition* ,Magraw Hill Inc, New York 109 ,2004.

Güdelek, Mehmet Uğur, *Zaman serisi analiz ve tahmini: Derin öğrenme yaklaşımı*. (MS thesis. TOBB ETÜ Fen Bilimleri Enstitüsü) 2019.

Gündoğdu, Aysel, *Finansın temel kavramları*, Gazi Kitapevi, Ankara 2018, s. 459-460, 511-512.

Gürsakal, Necmi, *Makine öğrenmesi*, Dora Basım Yayın, Bursa 2018.

Gürsakal, Necmi, *Veri Bilim*, Dora Yayınları, Bursa 2019.

Haberal, İsmail, (2020), *Derin Öğrenme Ağları Kullanılarak Protein Metal Bağlanma Yerlerinin Analizi*, (Başkent Üniversitesi, Fen Bilimleri Enstitüsü, Yayınlanmamış Yüksek Lisans Tezi), 2020, s. 26.

Hajizadeh, Ehsan, vd., "A hybrid modeling approach for forecasting the volatility of S&P 500 index return", *Expert Systems with Applications*, Sayı 39.1, 2012, s. 431-436.

Hari, Yulius-Lily Puspa Dewi, *Forecasting system approach for stock trading with relative strength index and moving average indicator*, (Doctoral Disserttation Diss. Petra Christian University), 2018.

Harris, Richard, *Using cointegration analysis in econometric modelling*, Prentic Hall, London 1995.

Hassan, Md Rafiul, Baikunth Nath, and Michael Kirley", "A fusion model of HMM, ANN and GA for stock market forecasting", *Expert systems with Applications*, Sayı 33.1, 2007, s.171-180.

Hatipoğlu, Tuğçen, *Galvaniz Sektöründe Bir Yapay Sinir Ağı Uygulaması*, (Sakarya üniversitesi, Fen Bilimleri Enstitüsü, Yayınlanmamış Yüksek Lisans Tezi), 2010.

Hinton, Geoffrey E.,- Ruslan R. Salakhutdinov, "Reducing the dimensionality of data with neural networks", *Science*, Sayı 313.5786, 2006, s. 504-507.

Hocaoğlu, Fatih Onur-Kübra Kaysal-Ahmet Kaysal, "Yük tahmini için hibrit (YSA ve regresyon) model" *Academic Platform Journal of Engineering and Science*, Sayı 3.2, 2015, s. 33-39.

Hochreiter, Sepp,- Jürgen Schmidhuber, "Long short-term memory", *Neural computation*, Sayı 9.8,1997, s.1735-1780.

Hu, Ya-Lan - Liang Chen, "A nonlinear hybrid wind speed forecasting model using LSTM network, hysteretic ELM and Differential Evolution algorithm", *Energy conversion and management*, Sayı 173, 2018, s.123-142.

Jozefowicz, Rafal - Wojciech Zaremba - Ilya Sutskever", "An empirical exploration of recurrent network architectures", *International conference on machine learning*. PMLR, 2015, s. 2342-2350.

Karan, Mehmet Baha, *Yatırım Analizi ve Portföy Yönetimi*, Ankara: Hacettepe Üniversitesi Finansal Yayınları, Baskı 1, 2001.

Kayaalp, K.,-A. A. Süzen, *Derin Öğrenme ve Türkiye'deki Uygulamaları, Institution Of Economic Development And Social Researches Publications*. ISBN 978-605-7510-51-2, 2018.

Khanderwal, Supriti - Debasis Mohanty, "Stock price prediction using ARIMA model", *International Journal of Marketing & Human Resource Research*, Sayı2.2, 2021, s.98-107.

Khashei, Mehdi - Mehdi Bijari, "A new hybrid methodology for nonlinear time series forecasting", *Modelling and Simulation in Engineering*, Sayı 4, 2011.

Khashei, Mehdi-Mehdi Bijari,- Gholam Ali Raissi Ardali, "Hybridization of autoregressive integrated moving average (ARIMA) with probabilistic neural networks (PNNs)", *Computers & Industrial Engineering*, Sayı 63.1, 2012, s.37-45.

Khashei, Mehdi- Seyed Reza Hejazi-Mehdi Bijari, "A new hybrid artificial neural networks and fuzzy regression model for time series forecasting", *Fuzzy sets and systems*, Sayı 159.7, 2008, s. 769-786.

Kilimci, Zeynep Hilal-Selim Akyokuş", "The evaluation of word embedding models and deep learning algorithms for Turkish text classification", *2019 4th International Conference on Computer Science and Engineering (UBMK)*. IEEE, 2019.

Kim, Ha Young-Chang Hyun Won, "Forecasting the volatility of stock price index: A hybrid model integrating LSTM with multiple GARCH-type models" , *Expert Systems with Applications*, Sayı 103, 2018, s. 25-37.

Kim, Kyoung-jae-Won Boo Lee, "Stock market prediction using artificial neural networks with optimal feature transformation", *Neural computing & applications*, Sayı 13.3, 2004, s. 255-260.

Koutroumanidis, Theodoros-Konstantinos Ioannou-Eleni Zafeiriou", "Forecasting bank stock market prices with a hybrid method: the case of Alpha bank" *Journal of Business Economics and Management* ,Sayı 12.1,2011, s.144-163.

Köroglu, Yavuz, *Yapay Zeka'nın Teorik Ve Pratik Sınırları*, Bogaziçi Üniversitesi Yayınevi , 2017, S. 1-19.

Krenker, Andrej - Janez Bester - Andrej Kos, "Introduction To Artificial Neural Networks", *Artificial Neural Networks-Methodological Advances and Biomedical Applications* (Ed. K. Suzuki), InTech, 2011, s.3-19.

Kurt, Fatma Esin - Serpil Senal, "Borsa İstanbul'da Kote Bireysel Emeklilik, Hayat Ve Hayat-Dışı Sigorta Şirketlerinin Hisse Senedi Fiyat Tahmininde Box-Jenkins Yöntemi", *Muhasebe ve Finansman Dergisi*, Sayı 80, 2018, s. 233-252.

Kwiatkowski, Denis, vd., "Testing the null hypothesis of stationarity against the alternative of a unit root: How sure are we that economic time series have a unit root?", *Journal of econometrics*, Sayı 54.1-3, 1992, s.159-178.

Lai, Robert K., vd., "Evolving and clustering fuzzy decision tree for financial time series data forecasting", *Expert Systems with Applications*, Sayı 36.2, 2009, s.3761-3773.

LeCun, Yann-Yoshua Bengio-Geoffrey Hinton, "Deep learning", *Nature*, Sayı 521.7553 ,2015, s. 436-444.

Lee, Junsoo- Mark C. Strazicich, "Minimum Lagrange multiplier unit root test with two structural breaks", *Review of economics and statistics*, Sayı 85.4, 2003, s. 1082-1089.

Levinson, Marc, *Finansal Piyasalar Kılavuzu (Çev. İlhan Ege)*, Liberte Yayınları, Ankara 2007.

Lin, Tao-Tian Guo-Karl Aberer, "Hybrid neural networks for learning the trend in time series", *Proceedings of the twenty-sixth international joint conference on artificial intelligence*. Melbourne, Australia, 2017, s. 273-2279.

Liu, Hui- Xiwei Mi-Yanfei Li, "Smart multi-step deep learning model for wind speed forecasting based on variational mode decomposition, singular spectrum analysis, LSTM network and ELM", *Energy Conversion and Management*, Sayı 159, 2018, s.54-64.



Liu, Yiwei-Zhiping Wang-Baoyou Zheng, "Application of regularized GRU-LSTM model in stock price prediction", *2019 IEEE 5th International Conference on Computer and Communications (ICCC)*, IEEE, 2019.

Luxhøj, James T-Jens O. Riis-Brian Stensballe, "A hybrid econometric—neural network modeling approach for sales forecasting", *International Journal of Production Economics*, Sayı 43.2-3 ,1996, s.175-192.

Mabu, Shingo- Masanao Obayashi-Takashi Kuremoto, "Ensemble learning of rule-based evolutionary algorithm using multi-layer perceptron for supporting decisions in stock trading problems", *Applied soft computing*, Sayı 36, 2015, s.357-367.

Maddala, Gangadharrao S.,- In-Moo Kim, *Unit Roots, Cointegration, And Structural Change*, Cambridge University Pres, UK 1998.

McCulloch, Warren S.,-Walter Pitts", "A logical calculus of the ideas immanent in nervous activity", *The bulletin of mathematical biophysics*, Sayı 5.4, 1943, s.115-133.

Mehtab, Sidra-Jaydip Sen-Abhishek Dutta, "Stock price prediction using machine learning and LSTM-based deep learning models", *Symposium on Machine Learning and Metaheuristics Algorithms, and Applications*, Springer, Singapore 2020.

Meher, Bharat Kumar vd., "Forecasting stock market prices using mixed ARIMA model: A case study of Indian pharmaceutical companies", *Investment Management and Financial Innovations*, Sayı18.1, 2021, s. 42-54.

Metin, Nurcan-Kübra Karadağ-M. Kenan Terzioğlu, "Mlp/Rbf Ağ Mimarileriyle Hibrit Mgarch-Ann Model Performans Karşılaştırması: Petrol Fiyat Oynaklığı", *Ankara Hacı Bayram Veli Üniversitesi İktisadi Ve İdari Bilimler Fakültesi Dergisi*, 2020, S. 78-93.

Milačić, Ljubiša, vd., "Application of artificial neural network with extreme learning machine for economic growth estimation", *Physica A: Statistical Mechanics and its Applications*, Sayı 465, 2017, s.285-288.

Mingyue, Qiu-Li Cheng-Song Yu, "Application of the Artificial Neural Network in predicting the direction of stock market index", *2016 10th International Conference*

on Complex, Intelligent, and Software Intensive Systems (CISIS), IEEE, 2016, s. 219-223.

Murphy, John J.,-Ali Perşembe, *Görsel Yatırımcı*, Scala Yayıncılık, İstanbul 1998.

Münyas, Turgay, *Finansal Yönetim ve Portföy Yönetim Teorisi*, Seçkin Yayıncılık, Ankara 2018.

Nayak, Rudra Kalyan - Debahuti Mishra - Amiya Kumar Rath, "A Naïve SVM-KNN based stock market trend reversal analysis for Indian benchmark indices", *Applied Soft Computing*, Sayı 35 ,2015, s.670-680.

Olah, Colah, *colah's blog*, <http://colah.github.io/posts/2015-08-Understanding-LSTMs/>, (2 Mart 2022).

Onocak, Derya-Selahattin Koç, "Yapay Sinir Ağları İle Emeklilik Yatırım Fonu Hisse Senedi Fiyatlarının Tahmini", *Finans Ekonomi ve Sosyal Araştırmalar Dergisi* 3.3,2018, s. 590-600.

Özçam, Ferhat, *Teknik Analiz ve İstanbul Menkul Kıymetler Borsası*, 1. Baskı, Sermaye Piyasası Kurulu Yayınları, Ankara 1996.

Patel, Jigar, vd., "Predicting stock market index using fusion of machine learning techniques", *Expert Systems with Applications*, Sayı 42.4, 2015, s.2162-2172.

Phillips, Peter C.B. - Pierre Perron", "Testing for a unit root in time series regression", *Biometrika*, Sayı 75.2, 1988, s. 335-346.

Prajapati, Samyak, vd., "Comparison of Traditional and Hybrid Time Series Models for Forecasting COVID-19 Cases" Research Square, 2021.

Qi, Yanlin, vd., "A hybrid model for spatiotemporal forecasting of PM2. 5 based on graph convolutional neural network and long short-term memory" *Science of the Total Environment*, Sayı 664, 2019, s. 1-10.

Russell, Stuart-Peter Norvig. *Prentice Hall series in artificial intelligence*. Englewood Cliffs, Prentice Hall, New Jersey 1995.

Sevüktekin, Mustafa-Mehmet Nargeleçekenleri, *Ekonometrik zaman serileri analizi E views uygulamalı*, Nobel Yayın Dağıtım, Ankara 2007.

Sevüktekin, Mustafa- Mehmet Çınar, *Ekonometrik Zaman Serileri Analizi: Eviews Uygulamalı*, Dora Yayıncılık, Bursa 2014.

Sheng, Feng-Li Jia", Short-term load forecasting based on SARIMAX-LSTM", *2020 5th International Conference on Power and Renewable Energy (ICPRE)*. IEEE, Shanghai, 2020, s. 90-94.

Silva, Ivan Nunes, vd., *Artificial neural networks: a practical course*, Springer International Publishing, Berlin 2017.

Somu, Nivethitha-Gauthama Raman MR-Krithi Ramamritham", A hybrid model for building energy consumption forecasting using long short term memory networks", *Applied Energy*, Sayı 261 ,2020, s. 114-131.

Swingler, Kevin, *Applying neural networks: a practical guide*, Morgan Kaufmann, 1996.

Şahin, Mahmut, *Borsada Teknik Analiz*, MOM Yayıncılık, İstanbul 1992.

Şeker, Abdulkadir-Diri Banu Diri- Balık, Hasan Hüseyin, "Derin öğrenme yöntemleri ve uygulamaları hakkında bir inceleme", *Gazi Mühendislik Bilimleri Dergisi (GMBD)*, Sayı 3.3, 2017, s.47-64.

Temür, Ayşe Soy-Şule YILDIZ, "Comparison of Forecasting Performance of ARIMA LSTM and HYBRID Models for The Sales Volume Budget of a Manufacturing Enterprise", *Istanbul Business Research*, Sayı 50.1, 2021, s.15-46.

Tsai, Chih F.,-Sammy P. Wang", Stock price forecasting by hybrid machine learning techniques", *Proceedings of the international multiconference of engineers and computer scientists*. Sayı 1, 2009.

Tseng, Chih-Hsiung, vd., "Artificial neural network model of the hybrid EGARCH volatility of the Taiwan stock index option prices", *Physica A: Statistical Mechanics and its Applications*, Sayı 387.13, 2008, s.3192-3200.

Tseng, Fang Mei- Hsiao Cheng Yu-Gwo Hsiung Tzeng", Combining neural network model with seasonal time series ARIMA model", *Technological forecasting and social change*, Sayı 69.1 2002, s.71-87.

Turing, Alan. M., *Computing Machinery and Intelligence*, Oxford University Press. Sayı 59, 1950,s. 433-460.

Tüzen, M. Fatih, *Türkiye Turizm Gelirinin Öngörüsünde Zaman Serilerinin Bileşenlerine Ayırıştırılarak Yapay Sinir Ağları Ve Box-Jenkins Yöntemleri İle Karşılaştırmalı Analizi*, (Kafkas Üniversitesi Sosyal Bilimler Enstitüsü İşletme Anabilim Dalı Yayınlanmamış Yüksek Lisans Tezi), 2012.

Uyar, Aydın, *Temel analiz*, Beta Basım Yayın, İstanbul 2001.

Wadi, S. A. L., vd., "Predicting closed price time series data using ARIMA Model." *Modern Applied Science*, Sayı 12.11, 2018, s.181-186.

Wang, Gang, vd., "Comparison of ARIMA, ES, GRNN and ARIMA–GRNN hybrid models to forecast the second wave of COVID-19 in India and the United States", *Epidemiology & Infection*, Sayı 149, 2021.

Wang, Ju-Jie, vd., "Stock index forecasting based on a hybrid model", *Omega*, Sayı 40.6 ,2012, s. 758-766.

Wang, Yi-Hsien, "Nonlinear neural network forecasting model for stock index option price: Hybrid GJR–GARCH approach", *Expert Systems with Applications*, Sayı 36.1, 2009, s.564-570.

Wedding II, Donald K.,- Krzysztof J. Cios", Time series forecasting by combining RBF networks, certainty factors, and the Box-Jenkins model", *Neurocomputing*, Sayı 10.2, 1996, s. 149-168.

Wilder, J. Welles, *New concepts in technical trading systems*, Trend Research, North Carolina 1978.

Yaslıdağ, Beyhan, *Forex Piyasası İşlemleri Ve Kripto Paralar*, Seçkin Yayıncılık ,Ankara 2021.

Yıldız, Birol, *Finansal analizde yapay zeka*, Beta Yayıncılık, Ankara 2009.

Yildiz, Baran - Jose I. Bilbao - Alistair B. Sproul", A review and analysis of regression and machine learning models on commercial building electricity load forecasting", *Renewable and Sustainable Energy Reviews*, Sayı 73, 2017, s.1104-1122.

Yılmaz, Yıldırım -Selim Buyrukoğlu", Hybrid Machine Learning Model Coupled with School Closure For Forecasting COVID-19 Cases in the Most Affected Countries", *Hittite Journal of Science and Engineering*, Sayı 8.2, s.123-131.

Yu, Lean - Shouyang Wang - Kin Keung Lai", A novel nonlinear ensemble forecasting model incorporating GLAR and ANN for foreign exchange rates", *Computers & Operations Research*, Sayı 32.10, 2005, s.2523-2541.

Yürük, Muhammed Fatih, "Yapay Sinir Ağları ile Hisse Senedi Fiyat Tahmin Modeli: Türk Hava Yolları Uygulaması", *Journal of Aviation*, Sayı5.2, 2021, s. 282-289.

Zhang, G. Peter", Time series forecasting using a hybrid ARIMA and neural network model", *Neurocomputing*, Sayı 50, 2003, s.159-175.

Zhou, Zhi Jie- Chang-Hua Hu", An effective hybrid approach based on grey and ARMA for forecasting gyro drift", *Chaos, Solitons & Fractals*, Sayı 35.3, 2008, s.525-529.

Zivot, Eric-Donald W. K. Andrews", Further evidence on the great crash, the oil-price shock, and the unit-root hypothesis", *Journal of business & economic statistics*, Sayı 10.3, 1992, s.251-270.