

**TOBB EKONOMİ VE TEKNOLOJİ ÜNİVERSİTESİ**  
**FEN BİLİMLERİ ENSTİTÜSÜ**

**DOĞRU VE YANLIŞ AL SAT ÖNERİLERİNİN FİNANSAL TEKNİK  
İNDİKATÖRLER İLE AYIRT EDİLMESİ**

**YÜKSEK LİSANS TEZİ**  
**Zeynep TÜFEKÇİ**

**Bilgisayar Mühendisliği Anabilim Dalı**

**Tez Danışmanı: Prof. Dr. Osman ABUL**

**MAYIS 2023**

## ÖZET

Yüksek Lisans Tezi

### DOĞRU VE YANLIŞ AL SAT ÖNERİLERİNİN FİNANSAL TEKNİK İNDİKATÖRLER İLE AYIRT EDİLMESİ

Zeynep TÜFEKÇİ

TOBB Ekonomi ve Teknoloji Üniversitesi

Fen Bilimleri Enstitüsü

Bilgisayar Mühendisliği Anabilim Dalı

Tez Danışmanı: Prof. Dr. Osman ABUL

Tarih: MAYIS 2023

Bu çalışmanın amacı, Doğru ve Yanlış Al / Sat önerilerini ayırt etmek için makine öğrenme yöntemi ile bir karar destek sistemi geliştirmektir. 30/70 Göreceli Güç İndeksi şeması gibi çeşitli öneri şemaları birçok yatırımcı tarafından etkin bir şekilde kullanılmaktadır. Bununla birlikte, bu öneri şemalarından üretilen sinyaller art arda ve çok sık olması dolayısıyla çoğu zaman şüpheli bulunmakta ve bu nedenle eyleme geçilememektedir. Bu çalışmada, fiyat verilerinden faydalanarak optimal bir yatırım modeli çıkarmak için dinamik programlama formülasyonu geliştirilmektedir. Bu optimal yatırım modeli, çeşitli finansal göstergelerle daha sonra çevrimiçi olarak başvurulabilecek ikili sınıflandırma modelini elde etmek için kullanılmaktadır. Dolayısıyla, önerilen sistem yatırımcılara birincil tavsiye veren indikatörlerden kalan belirsizliklerin ortadan kaldırılmasına yardımcı olur. Dinamik programlama formülasyonu, doğrusal zamanda verimli bir şekilde çalışmaktadır. Dinamik Programlama, birincil önericinin AL-SAT önerilerinin içinden daha iyi olanlarının belirlenip, etiketlenmesi aşamasında kullanılmıştır. Bu yaklaşım, deneysel olarak BIST-100, DOW-30 hisse senetleri ve döviz kurları üzerinde değerlendirilmiştir. Tahmin özellikleri olarak kullanılan teknik göstergeler; Göreceli Güç İndeksi, Trend Normalize edilmiş Göreceli Güç İndeksi, Yüzde Fiyat Osilatörü, Bollinger Bant Yüzdesi, Stokastik Osilatör, Fiyat Değişim Oranı ve Emtia Kanal İndeksi'dir. Bu çalışmada, Destek Vektör Makineleri, ikili sınıflandırma modeli olarak kullanılmaktadır. Bir günün sonunda oluşan göstergeleri öznitelik olarak

kullanmanın yanı sıra, ardışık iki günün teknik göstergeleri öznitelik olarak kullanılarak daha başarılı sonuç elde edilmiştir. Bu çok zor ikili sınıflandırma görevinde tek günün verileri ile %70 üzerinde, ardışık iki günün verileri ile %73'ün üzerinde doğruluk elde edilmiştir.

**Anahtar Kelimeler:** Finansal teknik analiz, Teknik indikatörler, Dinamik programlama, Optimal altdizgi, Destek vektör makinesi.



## ABSTRACT

Master of Science

Distinguishing True and False Buy/Sell Triggers from Financial Technical Indicators

Zeynep TÜFEKÇİ

TOBB University of Economics and Technology

Institute of Natural and Applied Sciences

Department of Computer Engineering

Supervisor: Prof. Dr. Osman ABUL

Date: May 2023

The objective of this study is to develop decision support system applying machine learning methods to distinguish True and False Buy/Sell recommendations. Various recommendation schemes, like 30/70 RSI (Relative Strength Index) scheme, are effectively used by many traders. However, the triggers produced by such recommendation schemes are found suspicious most of the time, and hence are non-actionable. In this study we develop a dynamic programming formulation to extract an optimal trade pattern from the price data sets. Such patterns are further augmented with several financial indicators to obtain binary classification model which is going to be consulted online. So, our system assists investors with removing uncertainties left from the primary recommender. We show that our dynamic programming formulation runs efficiently in linear time. Dynamic Programming is used to identify and label the better ones among the primary BUY and SELL recommendations. The approach is experimentally evaluated on BIST-100, DOW-30 stocks and currency pairs. The technical indicators used as predictor features are RSI, Trend Normalized RSI, Percentage Price Oscillator, Bollinger Band Percentage, Stochastic Oscillator, Rate of change (ROC), and Commodity Channel Index (CCI). We use Support Vector Machines as the binary classification algorithm. In addition to using the indicators formed at the end of each day as an attribute, better results were obtained by using the technical indicators of two consecutive days as attributes. Accuracy over %70 was achieved with data from a single day and over %73 with data from two consecutive days in this very difficult binary classification task.

**Keywords:** Financial technical analysis, Technical indicators, Dynamic programming, Optimal subsequence, Support vector machine.



## TEŐEKKÜR

Çalıőmalarım boyunca deęerli yardım ve katkılarıyla beni yönlendiren baőta sevgili hocam Prof. Dr. Osman ABUL, kıymetli tecrübelerinden öęrenim hayatım boyunca faydalandıęım ve faydalanacaęım TOBB Ekonomi ve Teknoloji Üniversitesi Bilgisayar Mühendislięi Bölüm Başkanımız Prof. Dr. Oęuz Ergin ve TOBB Ekonomi ve Teknoloji Üniversitesi öęretim üyelerine, eęitimim boyunca bana burs veren TOBB Ekonomi ve Teknoloji Üniversitesi'ne ve destekleriyle her zaman yanımda olan arkadaşlarım ve sevgili aileme çok teőekkür ederim. Ayrıca őunu belirtmek isterim ki, Sevgili Hocam Prof. Dr. Osman Abul'un görüőmelerimizde aldıęımız sonuçları deęerlendirip, geri bildirim ve düzeltmeleri, bir sonraki adıma yönlendirmeleri olmasaydı bu sonuçlara ulaşamazdık. Bu çalıőmanın Dinamik Programlama formülasyonu ilk olarak, C kodu ile Mustafa Erdem Kirez tarafından gerçekleştirilmiőtir. Bu çalıőmaya katkılarından dolayı Mustafa Erdem Kirez'e özel olarak teőekkür ederim.



## İÇİNDEKİLER

	<u>Sayfa</u>
<b>ÖZET</b> . . . . .	<b>iv</b>
<b>ABSTRACT</b> . . . . .	<b>vii</b>
<b>TEŞEKKÜR</b> . . . . .	<b>ix</b>
<b>İÇİNDEKİLER</b> . . . . .	<b>xi</b>
<b>ŞEKİL LİSTESİ</b> . . . . .	<b>xiii</b>
<b>ÇİZELGE LİSTESİ</b> . . . . .	<b>xv</b>
<b>KISALTMALAR</b> . . . . .	<b>xvii</b>
<b>1. GİRİŞ</b> . . . . .	<b>1</b>
1.1 Tezin Katkıları . . . . .	2
1.2 Tez Taslağı . . . . .	2
1.3 Literatür Araştırması . . . . .	2
<b>2. ÖNBİLGİ</b> . . . . .	<b>7</b>
2.1 Finansal Göstergeler . . . . .	7
2.1.1 Basit hareketli ortalama (Simple moving average SMA) . . . . .	7
2.1.2 Üstel hareketli ortalama (Exponential moving average EMA) . . . . .	8
2.1.3 Göreceli güç indeksi (Relative strength index RSI) . . . . .	9
2.1.4 Trend normalize edilmiş göreceli güç indeksi(Trend normalized RSI TN-RSI) . . . . .	10
2.1.5 Bolinger bant yüzdesi (Bolinger band percentage %B) . . . . .	11
2.1.6 Fiyat değişim oranı:(Rate of change ROC) . . . . .	12
2.1.7 Stokastik osilatör: (Stochastic oscillator SO) . . . . .	13
2.1.8 Emtia kanal indeksi (Commodity channel index CCI) . . . . .	13
2.1.9 Yüzde fiyat osilatörü( Price percentage oscillator PPO) . . . . .	13
2.2 Makine Öğrenmesi Yaklaşımı . . . . .	14
2.2.1 Destek vektör makineleri (SVM) . . . . .	14
2.2.1.1 Çekirdek fonksiyonları . . . . .	15
2.2.1.2 Çapraz doğrulama . . . . .	17
<b>3. ÖNERİLEN MODEL</b> . . . . .	<b>19</b>
3.1 Amaç . . . . .	19
3.2 AL/SAT Önericisi olarak Teknik Analiz Göstergeleri . . . . .	19
3.3 DOĞRU ve YANLIŞ Önericilerin Belirlenmesi . . . . .	22
3.4 DOĞRU ve YANLIŞ Önericilerin Tahmini . . . . .	26
<b>4. DENEYSEL ÇALIŞMALAR</b> . . . . .	<b>31</b>
4.1 Veri Seti . . . . .	31
4.2 Deneysel Çalışmanın İçeriği . . . . .	31
4.2.1 AL/SAT önericileri . . . . .	32
4.2.2 Tahmin edici olarak finansal teknik göstergeler . . . . .	33
4.2.3 Sınıflandırma . . . . .	34
4.3 Deneysel Sonuçları . . . . .	36
<b>5. SONUÇ VE ÖNERİLER</b> . . . . .	<b>49</b>
<b>KAYNAKLAR</b> . . . . .	<b>51</b>



<b>EKLER</b> . . . . .	<b>55</b>
<b>ÖZGEÇMİŞ</b> . . . . .	<b>67</b>



## ŞEKİL LİSTESİ

	<u>Sayfa</u>
Şekil 2.1: Basit Hareketli Ortalama $n = 20$ . . . . .	7
Şekil 2.2: Üstel Hareketli Ortalama $n = 12$ ve $n = 26$ için . . . . .	8
Şekil 2.3: Göreceli Güç İndeksi . . . . .	9
Şekil 2.4: Trend Normalize Edilmiş Fiyat Değeri . . . . .	10
Şekil 2.5: Bollinger Alt Bandı ve Üst Bandı . . . . .	12
Şekil 2.6: Destek Vektör Makineleri(SVM) hiper düzlem ve marjın gösterimi . . . . .	15
Şekil 4.1: AL veri seti (DA Matrisi). 7 tahmin edici öznitelik ve 1 tahmin edilen etiket (T/F) ile gösterimi . . . . .	36
Şekil 4.2: Şema 8 ve Şema 9 için \$100 yatırım ile gerçekleşen kârın grafik üzerinde karşılaştırılması. . . . .	44
Şekil 4.3: Temel model ve Önerilen modelin AXP hisse senedinde komisyon oranı=%0 için oluşturduğu yatırım kazancının karşılaştırması ve AXP kapanış fiyatı ile birlikte değerlendirilmesi. . . . .	45
Şekil 4.4: Temel model ve Önerilen modelin NKE hisse senedinde komisyon oranı=%0 için oluşturduğu yatırım kazancının karşılaştırması ve NKE kapanış fiyatı ile birlikte değerlendirilmesi. . . . .	46
Şekil 4.5: Temel model ve Önerilen modelin UNH hisse senedinde komisyon oranı=%0 için oluşturduğu yatırım kazancının karşılaştırması ve UNH kapanış fiyatı ile birlikte değerlendirilmesi. . . . .	47
Şekil EK1.1: Orijinal Veri seti. BIST-100 hisse senetleri kapanış fiyatı zaman serisi . . . . .	56
Şekil EK1.2: Orijinal Veri seti. DOW-30 hisse senetleri kapanış fiyatı zaman serisi . . . . .	57
Şekil EK2.1: SVM ile eğitilmeden önceki DA matrisi, 7 Teknik analiz göstergesinden oluşan öznitelikler ile DOĞRU ya da YANLIŞ olarak etiketlenmiş matrisi. . . . .	58
Şekil EK2.2: SVM ile eğitilmeden önceki DA matrisi, son iki vektörün Teknik göstergeleri ile oluşan 14 teknik analiz göstergesinden oluşan öznitelikler ve DOĞRU ya da YANLIŞ olarak etiketlenmiş matris. . . . .	59
Şekil EK3.1: Temel model ve Önerilen modelin AXP hisse senedinde komisyon oranı=%0.1 için oluşturduğu yatırım kazancının karşılaştırması ve AXP kapanış fiyatı ile birlikte değerlendirilmesi. . . . .	60
Şekil EK3.2: Temel model ve Önerilen modelin AXP hisse senedinde komisyon oranı=%0.2 için oluşturduğu yatırım kazancının karşılaştırması ve AXP kapanış fiyatı ile birlikte değerlendirilmesi. . . . .	61
Şekil EK3.3: Temel model ve Önerilen modelin NKE hisse senedinde komisyon oranı=%0.1 için oluşturduğu yatırım kazancının karşılaştırması. . . . .	62

Şekil EK3.4: Temel model ve Önerilen modelin NKE hisse senedinde komisyon oranı=%0.2 için oluşturduğu yatırım kazancının karşılaştırması. . . . .	63
Şekil EK3.5: Temel model ve Önerilen modelin NKE hisse senedinde komisyon oranı=%0.1 için oluşturduğu yatırım kazancının karşılaştırması ve NKE kapanış fiyatı ile birlikte değerlendirilmesi. . . . .	64
Şekil EK3.6: Temel model ve Önerilen modelin NKE hisse senedinde komisyon oranı=%0.2 için oluşturduğu yatırım kazancının karşılaştırması ve NKE kapanış fiyatı ile birlikte değerlendirilmesi. . . . .	65



## ÇİZELGE LİSTESİ

	<u>Sayfa</u>
Çizelge 3.1: $X$ hisse senedi NKE olarak alındığında $n=14$ için $F$ vektörü. . . .	20
Çizelge 3.2: $X$ hisse senedi NKE ve $n=14$ alındığında $Y=30/70$ RSI öneri sistemi altında $T$ vektörü. . . . .	20
Çizelge 3.3: $X$ hisse senedi NKE ve $n=20$ alındığında $Y=45/55$ TNRSI öneri sistemi altında $T$ vektörü. Ardarda birden fazla AL ya da SAT önerisi üretmektedir. . . . .	21
Çizelge 3.4: $X$ hisse senedi NKE ve $n=14$ alındığında $Y=30/70$ RSI öneri sistemi altında $T$ vektörü. . . . .	22
Çizelge 3.5: $X$ hisse senedi NKE ve $n=40$ alındığında $Y=45/55$ TNRSI öneri sistemi altında Maksimum kar. Temel model, ilk AL ve SAT önerisine göre karar alırken, Optimal model, maksimum kar getirecek öneriye göre karar almaktadır. . . . .	25
Çizelge 3.6: $X$ hisse senedi NKE ve $n=1$ alındığında $\vec{I}$ teknik analiz gösterge vektörü . . . . .	26
Çizelge 3.7: $X$ hisse senedi NKE ve $n=1$ alındığında bir önceki günün teknik göstergelerinin eklenmesi ile oluşan $\vec{I}_2$ teknik analiz gösterge vektörü	26
Çizelge 3.8: $X$ hisse senedi NKE ve $n=40$ alındığında $Y=45/55$ TNRSI öneri sistemi altında $I$ teknik analiz göstergeleri ile oluşan $D$ Matrisi. . .	27
Çizelge 3.9: $D$ matrisi AL önerileri gruplandığında oluşan matris. $T'$ modelinde seçilenler DOĞRU AL iken seçilmeyenler YANLIŞ AL olarak işaretlenir. SAT önerileri de $T'$ modeline göre aynı şekilde gruplanır.	28
Çizelge 3.10: $D$ matrisi SAT önerileri gruplandığında oluşan matris. $T'$ modelinde seçilenler DOĞRU SAT iken, seçilmeyenler YANLIŞ SAT olarak işaretlenir. . . . .	29
Çizelge 4.1: Kullanılan Veri Setinin içeriği. . . . .	31
Çizelge 4.2: Birincil önerici olarak RSI ve TN RSI kullanan farklı öneri şemaları	32
Çizelge 4.3: Birincil önerici olarak RSI ve TN RSI kullanan farklı öneri şemaları için komisyon oranı %0.1 olarak Dinamik Programla elde edilen maksimum getiri. . . . .	34
Çizelge 4.4: Örnek Adel hisse senedi için DOĞRU ve YANLIŞ öneriler eşitlenmeden önce . . . . .	35
Çizelge 4.5: Örnek Adel hisse senedi için DOĞRU ve YANLIŞ öneriler eşitlendikten sonra . . . . .	35
Çizelge 4.6: BIST-100 Veri Seti için SVM Modeli Doğrulama ve Test Doğruluk Oranları (Komisyon Oranı = %0.1) . . . . .	36
Çizelge 4.7: DOW-30 Veri Seti için SVM Modeli Doğrulama ve Test Doğruluk Oranları . . . . .	37

Çizelge 4.8: DOW-30 Veri Seti için Ardışık son iki günün teknik analiz göstergeleri birlikte bir vektör olarak alındığında oluşan SVM Modeli Doğrulama ve Test Doğruluk Oranları . . . . .	37
Çizelge 4.9: Şema 8 Komisyon Oranı = %0 . . . . .	38
Çizelge 4.10: Şema 8 Komisyon Oranı = %0.1 . . . . .	39
Çizelge 4.11: Şema 8 Komisyon Oranı = %0.2 . . . . .	40
Çizelge 4.12: Şema 9 Komisyon Oranı = %0 . . . . .	41
Çizelge 4.13: Şema 9 Komisyon Oranı = %0.1 . . . . .	42
Çizelge 4.14: Şema 9 Komisyon Oranı = %0.2 . . . . .	43
Çizelge 4.15: DOW-30 veri setinde 30 hisse senedi için her bir hisse senedine \$100 yatırım ile Temel Model ve Önerilen modelden alınan kâr karşılaştırması . . . . .	44

## KISALTMALAR

<b>BPNN</b>	: Geri Beslemeli Sinir Ağları
<b>CCI</b>	: Emtia Kanal Endeksi
<b>CNN</b>	: Evrişimsel Sinir Ağları
<b>DP</b>	: Dinamik Programlama
<b>EMA</b>	: Üstel Hareketli Ortalama
<b>LSS SVM</b>	: En Küçük Kareler Destek Vektör Makineleri
<b>LSTM</b>	: Uzun Kısa Vadeli Hafıza
<b>MLP</b>	: Çok Katmanlı Algılayıcı
<b>PPO</b>	: Yüzde Fiyat Osilatörü
<b>PSO SVM</b>	: Parçacık Sürü Optimizasyonu Destek Vektör Makineleri
<b>RBF</b>	: Radyal Tabanlı Fonksiyon
<b>RNN</b>	: Tekrarlamalı Yapay Sinir Ağları
<b>ROC</b>	: Fiyat Değişim Oranı
<b>RSI</b>	: Göreceli Güç İndeksi
<b>SMA</b>	: Basit Hareketli Ortalama
<b>SO</b>	: Stokastik Osilatör
<b>SVM</b>	: Destek Vektör Makineleri
<b>TN RSI</b>	: Trend Normalize Edilmiş Göreceli Güç İndeksi
<b>%B</b>	: Bolinger Bant Yüzdesi



## 1. GİRİŞ

Borsa, alıcı ve satıcıların yüz yüze gelme zorunluluğu bulunmadan menkul kıymetler, emtialar, döviz, vadeli işlemler, ve opsiyon sözleşmeleri gibi yatırım araçlarını alıp sattıkları sistemlerdir. Hisse senetleri ise, şirketlerin ortaklarına paylarını ve ortaklıklarını belgelemek için verdikleri kıymetli belgelerdir. Hemen hemen her ülkede, halka açık şirketlerin işlem gördüğü, hisse senetleri borsası bulunmaktadır. Hisse senetleri borsası, bir çok ülkede yatırımcıların başvurduğu bir yatırım noktası haline gelmiştir. Pek çok profesyonel uzman, hisse senetlerini analiz ederek daha iyi bir yatırım stratejisi oluştururken, bireysel yatırımcıların bu profesyonel analizden faydalanmaları kolay değildir. Profesyonel yöntemlerden faydalanmayan bireysel yatırımcılar genellikle paralarını bir kısır döngü içinde kaybeder ya da istenen maksimum karı elde edemezler.

Son zamanlarda adını oldukça fazla duymaya başladığımız kripto paralar, yatırımcılarına getirdiği büyük kar marjları nedeniyle bir çok yatırımcının dikkatini ve ilgisini çekmektedir. Kripto paralara yapılacak yatırımda doğru bir stratejinin uygulanması ve doğru zamanda yapılması büyük kârlar getireceği gibi, yanlış stratejinin uygulanması veya işlemin yanlış zamanda yapılması da büyük kayıplara neden olacaktır. Bu nedenle, analizin doğru yapılıp bireysel yatırımcının doğru yönlendirilmesi kripto para borsasında da önemli bir rol oynamaktadır.

Finansal piyasalarda yatırımcılar ve borsacılar halka açık şirket ve emtiaların hisselerini alıp satarken analiz metodlarından faydalanırlar. Bu analiz metodları temel ve teknik analiz olarak iki ayrı şekilde incelenir. Temel analiz, bir hisse senedinin içsel değerlerini inceler. Özellikle uzun vadeli yatırımcılar tarafından kullanılan temel analiz, şirketin bilançosu, gelir tablosu, nakit akış tablosu, döviz pozisyonları, şirket haberleri ve bunun gibi başlıkları inceler. Teknik analiz ise, o hisse senedinin fiyat ve hacim verilerinden türetilen göstergelere odaklanır. Teknik analizde, fiyat değerinin hisse senedi ile ilgili tüm bilgileri yansıttığı kabul edilmektedir. Geçmiş fiyat ve hacim verileri analiz edilerek gelecek fiyatlara dair bir tahminde bulunulur ve buna göre alım-satım işlemi yapılır yahut işlem yapılmaz. Hisse senedi piyasalarının teknik analiz ile tahmin edilebilirliği tartışmalı bir konu olsa da, hisse senedi veya emtia fiyatının teknik analiz yöntemi ile tahmin edilmesi geniş kabul görmektedir. [Abu-Mostafa ve Atiya , 1996]

Borsalardaki teknik analiz yönteminde, istatistiksel veriler ve oranlar hisse senedinin fiyat hareketinin anlaşılmasına yardımcı olurlar. Bunun arkasında, borsanın ya da hisse senedinin çeşitli dönemlerde belirli bir trendi takip ettiği ve bu trendin, bu göstergeler ile yakalanabileceği fikri yatmaktadır. Hisse senedinin fiyatı artış eğiliminde ise bu hisse senedi alımının güçlü olacağını gösterir. Fiyatın artmaya devam etmesi durumunda aşırı alım seviyesine ulaşması, her an satışların gelebileceğini ve bu noktada yapılan alımların riskinin yüksek olduğunu gösterir. Benzer şekilde hisse senedi fiyatı düşüş eğiliminde ise satımın güçlü olduğunu gösterir. Fiyatta düşüşün devam etmesi durumunda aşırı satım seviyesine geldiğini, bu noktada her an alımların gelebileceğini



ve satımların riskinin arttığını gösterir. Hisse senedinin geçmiş fiyat analizinden elde edilen gösterge değerlerinden hisse senedinin Al, Sat veya Tut öneri şemaları oluşturulmaktadır. Örneğin 30/70 Göreceli Güç İndeksi (RSI), bu öneri şemalarına bir örnek olarak gösterilebilir. Her bir bağımsız hisse senedi ve indeks için "Al", "Sat" veya "Tut" öneri sinyalleri üretilebilmektedir.

Fakat bu öneri şemalarının ürettiği sinyaller çok sık ve ardarda oluşabilmekte ve dolayısıyla yatırımcı bu sinyalleri güvenilir bulmamakta ve aldatici olarak görebilmektedir. Bundan dolayı, teknik göstergeler ve Al/Sat öneri sinyalleri alım satım işlemlerinde danışılmakta, fakat karar verme aşamasında bir çok sefer şüpheli bulunmaktadır. Yatırımcının ardarda gelen aynı sinyallerden hangisini seçeceğine karar verilmesi bu çalışmanın temel odak noktasını oluşturmaktadır.

Bu çalışmada, teknik analiz ve öneri şemaları ile üretilen Al/Sat sinyallerinden hangisinin daha güvenilir ve daha yüksek karı sağlayacak olduğunu bulma problemi ele alınmıştır. Bu bize, makine öğrenme yöntemi ile çözülen ikili tahmin problemini getirmiştir.

### **1.1 Tezin Katkıları**

Bu çalışmadaki en önemli katkı, bir öneri şemasındaki alım satım sinyalinin DOĞRU ya da YANLIŞ olduğuna nasıl karar verildiğidir. Bu amaçla, verilen gerçek fiyat değerlerini kullanarak maksimum getiriyi sağlayan optimal alt diziyi hesaplamak için, dinamik programlama yaklaşımı kullanılmaktadır. Bu yaklaşım ve sonuçları, İstanbul Borsası(BIST-100), Amerikan Borsası(DOW30), ALTIN ve DOVIZ kurları üzerinde değerlendirilmiştir[Abul ve Tufekci , 2020]

### **1.2 Tez Taslağı**

Çalışmanın devamı şu şekilde organize edilmiştir: Literatür araştırması, finansal zaman serilerinin gelecekteki durumlarının, yönelim ve fiyat değişiminin tahmin edilmesi alanındaki çalışmalarla ilgili genel bir perspektif sunulmaktadır. Ön bilgi bölümü, finansal analizde kullanılan göstergeler, öneri şemaları ve makine öğrenme algoritmaları hakkında ön bilgi vermektedir. Önerilen model bölümü, sunulan model ve bu çalışmada kullanılan metodları içermektedir. Deneysel çalışmalar bölümü, modelin değerlendirilmesi için uygulanan deneysel çalışmaları ve sonuçları göstermektedir. Sonuçlar ve gelecek çalışmalar bölümü modelin karşılaştırılması ve değerlendirmesini sunmaktadır.

### **1.3 Literatür Araştırması**

Hisse senetleri, endeks değerleri, döviz, emtia gibi finansal araçların verileri belirli aralıklarla analiz edildiğinden dolayı finansal zaman serisi olarak değerlendirilir. Finansal zaman serilerinin fiyat değişim yönünü ve değişim değerini doğru bir şekilde tahmin

etmek, yatırımcılar için kritik bir öneme sahiptir. Finans piyasasındaki geleceğe ait belirsizlikler ve risk bu tahminlerin yüksek doğrulukta olmasını engellemektedir. Finansal teori ve deneysel zaman serisi, bu verilerin gelecekteki hareketlerini tahmin etmek isterken, istatistiksel teori ve yöntemlerden faydalanır [Tsay , 2005]

Finansal verilerin analizinde farklı makine öğrenme algoritmaları kullanılmaktadır. Bunlardan Destek Vektör Makineleri(SVM) ve Yapay Sinir Ağları(ANN) en sık kullanılan algoritmalarıdır. Bu makine öğrenme algoritmalarının bir çok farklı varyasyonu çalışılmıştır.

Yapay Sinir Ağlarında derin öğrenme algoritmalarının geliştirilmesiyle, Çok Katmanlı Algılayıcı (MLP) [Naeini, Taremian ve Hashemi , 2010], Tekrarlamalı Yapay Sinir Ağları (RNN) [Roman ve Jameel , 1996] , Geri beslemeli Sinir Ağları (BPNN) [Qiu ve Song , 2016] , Evrimsel Sinir Ağları (CNN) [Gunduz, Yaslan ve Cataltepe , 2017], Uzun Kısa Vadeli Hafıza (LSTM) [Di Persio ve Honchar , 2016] gibi yöntemler finansal verilerin gelecek değerlerinin tahmin edilmesinde uygulanmıştır. [Cavalcante et al. , 2016] Genetik algoritma ile birlikte Tekrarlamalı Yapay Sinir Ağları [Kwon ve Moon , 2007] hisse senedi fiyat tahmininde kullanılmıştır. Bunların yanında, finansal seri tahmininde Derin Öğrenme (DL) algoritmaları, Derin İnanç Ağları (DBN), Derin Takviyeli Öğrenme (DRL), Sınırlı Boltzmann Makineleri (RBM) gibi modeller, kapsamlı bir şekilde bu araştırma raporunda paylaşılmıştır. [Sezer, Gudelek ve Ozbayoglu , 2020] Güncel çalışmalarda kullanılan Transformer tabanlı yaklaşımlar [Zou et al. , 2023] bu araştırmada incelenmiştir. Fiyat ve teknik göstergelerden faydalanarak [Ding et al. , 2020] çoklu ölçek transformer modeli ile stok hareketi tahmini yapmıştır.

Teknik Analiz göstergeleri makine öğrenme algoritmalarıyla tahmini iyileştirmek amacıyla kullanılmaktadır. Teknik Analiz göstergeleri ile Çok Katmanlı Algılayıcı modeli [Sezer , 2018]'in çalışmasında uygulanmıştır. Bunun bir sonraki aşamasında, Genetik Algoritma ile optimize edilmiş Teknik Analiz verileri Derin Çok Katmanlı Algılayıcı modeliyle finansal zaman serisine uygulanmıştır. Aynı çalışmada, zaman serisi verileri iki boyutlu görüntüye dönüştürülerek ve teknik analiz verileri görüntü verisine dönüştürülerek Evrimsel Sinir Ağları (CNN) ile finansal tahmin yapılmıştır.

Yapay Sinir Ağları haricinde karar ağaçları da [Barak, Arjmand ve Ortobelli , 2017] finansal tahminde başvurulan makine öğrenmesi metodlarındandır. Birden fazla karar ağacını bir araya getirerek daha güçlü bir model oluşturmayı amaçlayan Rastgele Orman (RF) tekniği ile karar ağaçlarının kombinasyonu sınıflandırma ve regresyonda uygulanarak finans piyasası tahmininde başarılı sonuçlar elde etmiştir. [Henrique, Sobreiro ve Kimura , 2019] Bunun yanında, En Yakın Komşu sınıflandırması ile teknik analiz göstergelerini kullanarak hisse senedi fiyat tahmini [Teixeira ve de Oliveira , 2010]'nin çalışmasında yapılmıştır. Ayrıca, hisse senedinin alım/satım tahmini için Bulanık Mantık (Fuzzy Logic) kural tabanlı finansal yatırım öneri sistemi [Cheung ve Kaymak , 2007]'de önerilmiştir.

Hisse senetleri tahmininde veri madenciliği teknikleri önışlem aşamasında kullanılmıştır. Öznitelik seçme metodu olarak Temel Bileşenler Analizi (PCA), Genetik Algoritma (GA), Sınıflandırma ve Regresyon Karar Ağaçları(CART) kullanılmıştır. Bu üç öznitelik seçme metodunun kombinasyonları uygulanarak en iyi başarıyı sağlayan

kombinasyon belirlenmiştir.[Tsai ve Hsiao , 2010] Finansal tahminde [Hoseinzade ve Haratizadeh , 2019]'nın çalışmasında öznitelik çıkarımı yapılırken Evrişimsel Sinir Ağları (CNN) kullanılmıştır.

Bunun haricinde kripto para alanında kur değeri tahmini üzerine çalışmalar yapılmıştır. Bir çalışmada, kripto paralar arasında en çok işlem gören bitcoin kur değeri, Uzun Kısa Vadeli Hafıza (LSTM) makine öğrenme algoritması kullanılarak tahmin edilmiştir. [Chen et al. , 2021] Kripto para alanındaki diğer bir çalışmada, bitcoin kurunun kısa dönemli dalgalanmalarını tahmin etmek üzerine çalışılmıştır. [Guo ve Antulov-Fantulin , 2018] Bu alanda yapılan diğer çalışmalara [Madan , 2014] ve [Greaves ve Au , 2015] örnek gösterilebilir.

Veri odaklı algoritmaların finansal piyasalarda portföy yönetiminde en iyi kararları almaya yönelik kullanılabileceği Evrensel portföy yönetimi çalışmasında paylaşılmıştır. Bu çalışmada, ekonomik göstergeler ve teknik analiz gibi bilgi taşıyan verilerin, yan bilgi olarak kullanılarak yatırım performansını optimize edeceği bir çerçeve sunulmaktadır. Önerilen yöntemlerin gerçek veriler ile doğrulanması yapılır. Veriye dayalı karar veren, adaptif yöntemler kullanan bu çalışma finansal tahmindeki çalışmalara bir örnek verilebilir. [Cover ve Ordentlich , 1996]

Destek Vektör Makineleri (SVM) [Vapnik , 2000] finansal market tahmininde, tahmin modeli hazırlanırken sıklıkla başvurulan ikili sınıflandırma algoritmasıdır. Son yıllarda, Destek Vektör Makinesi uygulamaları finansal market tahmininde önemli ilerlemeler kaydetmiştir. Finansal zaman serisi tahmininde Tay ve Cao [Tay ve Cao , 2001] tarafından SVM kullanılmıştır. En Küçük Kareler Destek Vektör Makineleri (LSS SVM) finansal market trendini bulmak amacıyla karma çekirdek yöntemi kullanılarak uygulanmıştır. [Yu et al. , 2009] Parçacık Sürü Optimizasyonu(PSO) ile optimize edilmiş SVM, finansal zaman serisi tahmininde kullanılan bir diğer önemli çalışmadır. [Guo, Huaiqing ve Quan , 2012] Günlük hisse senedi fiyat tahmininde LSS SVM algoritması PSO optimizasyonu ile kullanılmıştır. [Hegazy, Soliman ve Abdul Salam , 2013] Yarı doğrusal SVM ve korelasyon bazlı SVM filtresi bir başka çalışmada tanımlanmıştır. [Lin, Guo ve Hu , 2013] Hisse senedinin hareket yönünü teknik analiz indikatörleri girdisi ile tahmin etmeyi amaçlayan SVM algoritması bu çalışmada [Kim , 2003] önerilmiştir. Genetik algoritma ve SVM'ye dayalı hibrid makine öğrenme algoritması finansal piyasa tahmininde başvurulan bir diğer çalışmadır. [Choudhry ve Garg , 2008] Destek Vektör Regresyonu ile Parçacık Sürü Optimizasyonu kullanılarak üçüncü günün hisse senedi fiyatı tahminini yapan çalışma yüksek başarıyla sonuçlanmıştır. [Xie , 2011]

Destek Vektör Makinesinin zaman serisi analizinde ve tahmininde ARIMA (Otokorelasyonlu Entegre Hareketli Ortalama) lineer modeli geniş bir kabul bulmaktadır. [Box ve Jenkins , 1990] ARIMA, tek değişkenli zaman serisi verileri, örneğin hisse senedi fiyatları veya finansal göstergeler gibi alanlarda tahminler yapmak için kullanılan istatistiksel bir modeldir. ARIMA ile SVM hibrid modeli, hisse senedi fiyat tahmininde başvurulmuş ve tek tek uygulanmasına göre daha başarılı sonuç alınmıştır. [Pai ve Lin , 2005] ARIMA modelini kullanarak stok fiyat tahmini yapan bu çalışmada Bist hisse senedinde dönemsel trendlerin yakalanmasında Karma tamsayı programlama yakla-

şımı kullanılmıştır. [Arık , 2018]

Destek Vektör Makinesinin finansal piyasa tahminindeki başarılı sonuçlarından dolayı, bu çalışmada Destek Vektör Makinesini kullanılmıştır.

Finansal piyasa tahmininde, bazı çalışmalar hisse senedinin gelecek fiyat tahminini yaparken, bazı çalışmalar [Chang et al. , 2009] hisse senedinin al/sat noktasının tahmin edilmesine odaklanır. Bu çalışmada temel olarak, hisse senedinin gelecek fiyat tahmininden öte, doğru al/sat noktalarının seçilmesi üzerine odaklanmıştır.

Dinamik Programlama(DP) finansal sistemlerde kullanılmaktadır. Uygulamalar arasında envanter, stok kontrolü ve benzer hisse senedi fiyat modellerinin getirilmesi bulunmaktadır. [Udagawa , 2017] Zaman serisindeki mum çubuğu örüntüleri arasındaki benzerlikleri bulmak için yapılan çalışma [Goumatianos, Christou ve Lindgren , 2013] ve kısa dönemde hisse senedi fiyat tahmini için benzer mum çubuğu örüntülerinin bulunmasında dinamik programlama yaklaşımı kullanılmıştır. [Udagawa , 2018] Dinamik programlamaya dayanan güncel çalışmalardan ARIMA modeli üzerinde [Xiao et al. , 2022] ters sıralı dinamik programlama karar şeması kullanarak maksimum getiri sağlayan en iyi yatırım stratejine ulaşmaya çalışmıştır.

Bu çalışmada, dinamik programlamaya teknik analiz verilerinin önerdiği birincil öneri sistemini geliştirmek ve iyileştirmek amacıyla başvurulmuştur. Bu çalışmadan önce dinamik programlama, hisse senedinin alım satım noktalarını tahmin etmek amacıyla kullanılmamıştır. Bu çalışma, literatürde bu alanda ilk olmaktadır.



## 2. ÖNBİLGİ

### 2.1 Finansal Göstergeler

Finansal göstergeler, bir hisse senedinin fiyat değişiminin sayısal olarak ifade edilmesinden faydalanarak fiyatın hareket yönü hakkında fikir veren sayısal değerlerdir. Günümüzde 200'ün üzerinde finansal teknik gösterge hisse senedinin değişimini öngörmek amacıyla kullanılmaktadır. Bu göstergeler hisse senedinin o günkü fiyatından, haciminden ya da her ikisinden türetilmiş göstergeler olabilir. Bu çalışmada, hisse senedinin fiyat değerinden türetilen 7 farklı gösterge kullanılmıştır. Bu değerler normalize edilmiş değerlerdir.


Öncelikle Finansal göstergeleri hesaplamak için kullanılan iki farklı hareketli ortalamaı inceleyelim.

#### 2.1.1 Basit hareketli ortalama (Simple moving average SMA)

Finansal uygulamalarda, basit hareketli ortalama, önceki  $n$  günlük fiyat değerlerinin ağırlıksız ortalamasını olarak hesaplanmaktadır.

$$SMA = \frac{1}{n} \sum_{i=0}^{n-1} Fiyat_{bugun-i} \quad (2.1)$$

Formüldeki  $Fiyat_{bugun-i}$   $i$ .gün önceki fiyatı göstermektedir. Örnek bir hisse senedi zaman serisi için basit hareketli ortalaması Şekil 2.1'de verilmiştir.



Şekil 2.1: Basit Hareketli Ortalama  $n = 20$

## 2.1.2 Üstel hareketli ortalama (Exponential moving average EMA)


Finansal piyasalarda fiyat tahmininde yakın zamanın verileri daha belirleyici olurken, basit hareketli ortalama son  $n$  günün ortalamasını her güne aynı ağırlık vererek hesaplar. Bunun aksine, Üstel hareketli ortalama, daha yakın güne daha yüksek ağırlık vererek ve geriye doğru gittikçe azalan ağırlıkla, son  $n$  günün ortalamasını hesaplar. Böylece, üstel ağırlıklandırılmış hareketli ortalama hesaplanmış olur. Üstel hareketli ortalama formülü aşağıdaki gibi hesaplanır:

$$EMA_n = \begin{cases} Fiyat_1, & n = 1 \\ \alpha Fiyat_n + (1 - \alpha)EMA_{n-1}, & n > 1 \end{cases} \quad (2.2)$$

Denklemden  $EMA_n$ ,  $n$  gündeki üstel hareketli ortalamayı,  $Fiyat_n$ ,  $n$  gündeki fiyatı temsil eder.  $\alpha$  katsayısı ağırlık azalmasının derecesini temsil eder. 0 ile 1 arasında bir değer alır. Daha yüksek  $\alpha$  değeri, daha önceki günlerin değerini daha hızlı düşürür.

$$\alpha = \frac{2}{N + 1} \quad (2.3)$$

$\alpha$  için genel kabul gören değer  $\frac{2}{N+1}$  'dir. Böyle olmasının sebebi, basit hareketli ortalama ve üstel hareketli ortalamanın ağırlıkları  $\alpha = \frac{2}{N+1}$  değerini aldığı anda aynı ağırlık merkezine sahip olurlar. Örnek bir hisse senedi zaman serisi için üstel hareketli ortalama Şekil 2.2'de verilmiştir.




Şekil 2.2: Üstel Hareketli Ortalama  $n = 12$  ve  $n = 26$  için

Bu çalışmada faydalanılan 7 teknik analiz göstergesi aşağıdaki gibidir;

### 2.1.3 Göreceli güç indeksi (Relative strength index RSI)

Teknik momentum göstergesi 0 ile 100 arasında bir değer üretir. Bu momentum göstergesi, belirli bir periyotta pozitif ve negatif farkları analiz eder. Şekil 2.3, Göreceli güç indeksinin bir hisse senedi için değişimini göstermektedir. Bu değişimlerde, değer uç noktalara ulaştığında aşırı alım ve ya aşırı satım bölgesine girdiği ve bu durumun alım-satımlarda anlamlı bir değer taşıdığı kabul edilmektedir. Periyot için standart n değeri 14'tür. RSI değerinin formülü aşağıdaki gibidir:



Şekil 2.3: Göreceli Güç İndeksi

$$RSI_n = 100 - 100 / (1 + RS_n) \quad (2.4)$$

$$RS_n = \frac{(\frac{1}{n} \sum_{i=1}^n \text{Pozitif Fark})}{(\frac{1}{n} \sum_{i=1}^n \text{Negatif Fark})} \quad (2.5)$$

$$(\text{Fiyat}_i - \text{Fiyat}_{i-1} \geq 0) \text{ ise Pozitif Fark} \quad (2.6)$$

$$(\text{Fiyat}_i - \text{Fiyat}_{i-1} < 0) \text{ ise Negatif Fark} \quad (2.7)$$

$$\text{Pozitif Fark} = \begin{cases} \text{Fiyat}_i - \text{Fiyat}_{i-1}, & \text{Fiyat}_i - \text{Fiyat}_{i-1} \geq 0 \\ 0 & \text{Diğer durumlarda} \end{cases} \quad (2.8)$$

$$\text{Negatif Fark} = \begin{cases} \text{Fiyat}_{i-1} - \text{Fiyat}_i, & \text{Fiyat}_i - \text{Fiyat}_{i-1} < 0 \\ 0 & \text{Diğer durumlarda} \end{cases} \quad (2.9)$$




#### 2.1.4 Trend normalize edilmiş göreceli güç indeksi(Trend normalized RSI TN-RSI)

Göreceli Güç İndeksi, trendin güçlü olduğu dönemlerde sınır bölgelerde uzun süre kalabilmekte, bu durum da yanlış sinyallerin oluşmasına neden olmaktadır. Bu durumu önlemek için, Trend Normalize Edilmiş Göreceli Güç İndeksi kullanılabilir. [Sahin ve Ozbayoglu , 2014]

Trend çizgisi doğrusal regresyon kullanılarak bulunur. Trend değeri normalizasyonda yumuşak geçişler yapmak için her gün tekrar hesaplanır. Daha sonra, gerçek fiyat değerinden trend değerinin çıkartılmasıyla fiyat değeri normalize edilmiş olur. (Şekil 2.4) Böylece Trend normalize edilmiş göreceli güç indeksi oluşturulur.

TNRSI değerinin hesaplanması, trend değerinin hesaplanıp çıkarılması dışında, RSI değerinin hesaplanmasına benzer şekilde yapılır, formülü Denklem 2.10-2.22'deki gibi hesaplanır.



Şekil 2.4: Trend Normalize Edilmiş Fiyat Değeri

$$TNRSI_n = 100 - 100/(1 + TNRS_n) \quad (2.10)$$

$$TNRS_n = \frac{(\frac{1}{n} \sum_{i=1}^n \text{Pozitif Fark})}{(\frac{1}{n} \sum_{i=1}^n \text{Negatif Fark})} \quad (2.11)$$

$$\text{Pozitif Fark} = \begin{cases} \text{TrendFark}_i - \text{TrendFark}_{i-1}, & \text{TrendFark}_i - \text{TrendFark}_{i-1} \geq 0 \\ 0 & \text{Diğer durumlarda} \end{cases} \quad (2.12)$$

$$NegatifFark = \begin{cases} TrendFark_{i-1} - TrendFark_i, & TrendFark_i - TrendFark_{i-1} < 0 \\ 0 & \text{Diğer durumlarda} \end{cases} \quad (2.13)$$

$$(TrendFark_i - TrendFark_{i-1} \geq 0) \text{ ise Pozitif Fark} \quad (2.14)$$

$$(TrendFark_i - TrendFark_{i-1} < 0) \text{ ise Negatif Fark} \quad (2.15)$$

$$TrendFark_i = Fiyat_i - Trend_i \quad (2.16)$$

$$Trend_i = B_{1i} * X_i + B_{0i} \quad (2.17)$$

$$B_{1i} = \frac{\frac{1}{n} \sum_{i=1}^n (Fiyat_i - Fiyat_{ort}) * (X_i - X_{ort})}{\frac{1}{n} \sum_{i=1}^n (X_i - X_{ort})^2} \quad (2.18)$$

$$B_{0i} = Fiyat_{ort} - B_{1i} * X_{ort} \quad (2.19)$$

$$X_i = i \quad (2.20)$$

$$Fiyat_{ort} = \frac{1}{n} \sum_{i=1}^n Fiyat_i \quad (2.21)$$

$$X_{ort} = \frac{1}{n} \sum_{i=1}^n i \quad (2.22)$$

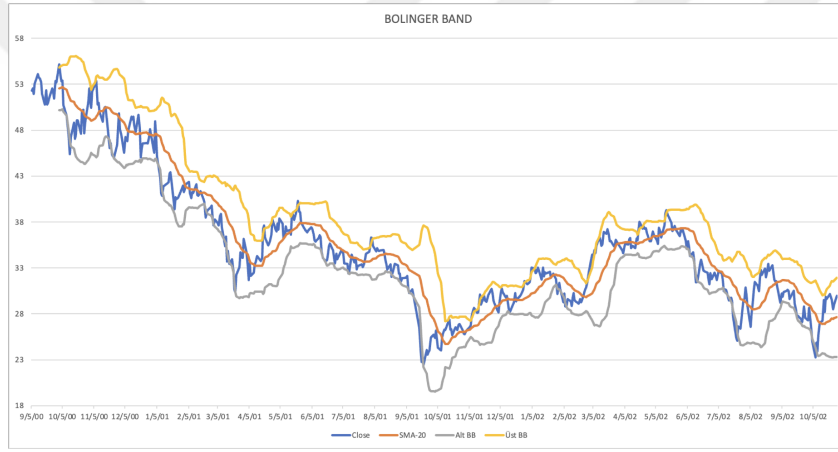
Yukarıdaki  $B_1$  değeri  $Fiyat$  ın, son  $n$  gündeki, doğrusal regresyondaki egim değerini,  $B_0$  ise kesme noktasını vermektedir.  $B_0$  ve  $B_1$  değerinden  $Trend$  değeri hesaplanmakta,  $Trend$  değeri  $Fiyat$  dan çıkartılarak  $Trend$  normalize edilmiş değer hesaplanmaktadır.

### 2.1.5 Bolinger bant yüzdesi (Bolinger band percentage %B)

Finansal analiz araçlarından Bolinger Bandı, bir hisse senedi fiyatının belirli bir alt band ve üst band arasında dalgalanma göstereceğini kabul eder. Son N-günlük Basit

Hareketli Ortalanın, standart sapmanın 2 katı eklenerek aldığı değer Üst Bandı, standart sapmanın 2 katı çıkarılarak aldığı değer Alt Bandı temsil eder. Fiyat değeri Üst banda yaklaştığı ve geçtiği zaman, bu aşırı alım sinyali verir. Aynı şekilde fiyat değeri Alt banda yaklaştığı ve geçtiği zaman aşırı satım sinyali verir. [Bollinger , 1980s]

Bolinger Band Yüzdesi, fiyatın Bolinger band aralığında hangi seviyede olduğunu gösterir. Yüzde değeri hisse senedinin fiyat ölçeğinden bağımsızdır. Böylece, farklı fiyat aralıklarında normalize edilmiş bir değer üretir. Bu nedenle, bu araştırmada, mutlak alt ve üst band değeri yerine bolinger bandı yüzdesi tercih edilmiştir. Şekil 2.5, fiyat hareketine bağlı alt bant ve üst banttan oluşan aralığı göstermekte ve fiyatın bu aralıktaki düştüğü yere göre bir yüzde değeri üretmektedir. Bolinger band yüzdesi, Denklem 2.23-2.26'deki gibi hesaplanır.



Şekil 2.5: Bollinger Alt Bandı ve Üst Bandı

$$\%B = \frac{(Fiyat - Alt Bant)}{(Ust Bant - Alt Bant)} \quad (2.23)$$

$$Ust Bant = Basit Hareketli Ortalama_{20} + 2 * \sigma \quad (2.24)$$

$$Alt Bant = Basit Hareketli Ortalama_{20} - 2 * \sigma \quad (2.25)$$

$$\sigma = \sqrt{\frac{1}{n} \sum_{i=1}^n \|Fiyat_i - Fiyat_{ort}\|^2} \quad (2.26)$$

### 2.1.6 Fiyat değişim oranı:(Rate of change ROC)

Fiyat Değişim oranı momentum tabanlı bir finansal teknik göstergedir. Hisse senedinin güncel fiyatı ile belirli bir süre önceki fiyatı arasındaki fiyattaki yüzde değişimini ifade eder. Formülü aşağıdaki (Denklem 2.27) gibi hesaplanır:

$$ROC = \frac{(Fiyat_{bugun} - Fiyat_{bugun-n})}{(Fiyat_{bugun-n})} \quad (2.27)$$

buradaki  $Fiyat_{bugun}$  hisse senedinin güncel fiyatını,  $Fiyat_{bugun-n}$  güncel fiyattan n gün önceki fiyatı göstermektedir. Bu çalışmada n değeri, genel olarak tercih edilen 14 olarak alınmıştır.

### 2.1.7 Stokastik osilatör: (Stochastic oscillator SO)

Stokastik Osilatör momentum göstergesidir. Belirli n gün aralıktaki en yüksek fiyat ve en düşük fiyat ile güncel fiyatı karşılatırır. Güncel fiyatın belirli periyottaki fiyat aralığında nereye düştüğünü gösterir. Denklem 2.28'de hesaplanması gösterilir.

$$SO = \frac{(Fiyat - EnDusuk_n)}{(EnYukseken - EnDusuk_n)} \quad (2.28)$$

denkleminde  $Fiyat$  = hisse senedinin güncel fiyatını,  $EnDusuk_n$  son n gündeki en düşük fiyatı,  $EnYukseken$  son n gündeki en yüksek fiyatı gösterir. Stokastik Osilatör için n değeri 14 alınmıştır.

### 2.1.8 Emtia kanal indeksi (Commodity channel index CCI)

Emtia Kanal Endeksi, momentum tabanlı bir teknik analiz göstergesidir. Bir hisse senedinin aşırı alım ya da aşırı satım noktasına ulaşıp ulaşmadığına karar vermede kullanılır. Formülü aşağıdaki gibidir:

$$CCI = \frac{(Fiyat - SMA_n)}{(0,015 * Ortalama Sapma_n)} \quad (2.29)$$

$$Ortalama Sapma = \frac{1}{n} \sum_{i=1}^n \|Fiyat_i - Fiyat_{ort}\| \quad (2.30)$$

Denklem 2.29'de,  $Fiyat$  hisse senedinin güncel fiyatını,  $SMA_n$  son n günün Basit Hareketli Ortalamasını,  $Ortalama Sapma_n$  n günün ortalama sapmasını gösterir. Emtia Kanal Endeksi için n değeri 14 alınmıştır.

### 2.1.9 Yüzde fiyat osilatörü( Price percentage oscillator PPO)

Yüzde Fiyat Osilatörü bir momentum göstergesidir. Hızlı Üstel Hareketli Ortalama ile Yavaş Üstel Hareketli Ortalamasının farkının Yavaş Üzsel Harketli Ortalamaya oranı ile hesaplanır. MACD(Hareketli Ortalamaların Mesafesi) göstergesi Hızlı ve Yavaş Üstel

ortalmanın farkını hesaplayarak bulunurken, Yüzde Fiyat Osilatörü MACD göstergesinden farklı olarak farkın yüzde değerini hesaplar. Bu nedenle Yüzde Fiyat Osilatörü, fiyat değerinden bağımsızdır.

Yani iki farklı hisse senedinde fiyatlar arasında büyük fark olsa bile, fiyatın büyüklüğüne bakılmaksızın aynı değişim oranında aynı sayıyı üretir. Böylece, fiyattan bağımsız olarak normalize edilmiş olur. Bu nedenle biz bu çalışmamızda MACD değeri yerine Yüzde Fiyat Osilatörünü tercih ettik.

$$PPO = \frac{(EMA_{12-gün} - EMA_{26-gün})}{EMA_{26-gün}} \quad (2.31)$$

Denklem 2.31'de  $EMA_{n-gün}$   $n$  gün periyotta Üstel Hareketli Ortalama'dır. Biz bu çalışmada Yavaş Hareketli Ortalama için genel olarak tercih edilen  $n = 26$ , Hızlı Hareketli Ortalama için  $n = 12$  değerlerini aldık.

## 2.2 Makine Öğrenmesi Yaklaşımı

Makine öğrenmesi algoritması, dışarıdan herhangi bir karar verici olmadan örnek veriye göre modelin eğitilerek, daha sonra karşılaşılan verilerde karar verme ve tahmin etmeyi sağlayan modeli oluşturmayı amaçlar. Makine öğrenme algoritmaları geleneksel metodlarla çözülmesi mümkün olmayan problemlerin çözümlerinde sıklıkla başvurulmaktadır. İlaç sektöründen üretim sahasına, görüntü tanımadan finansal öngörü alanına kadar çok geniş bir çalışma alanında kullanılmaktadır.

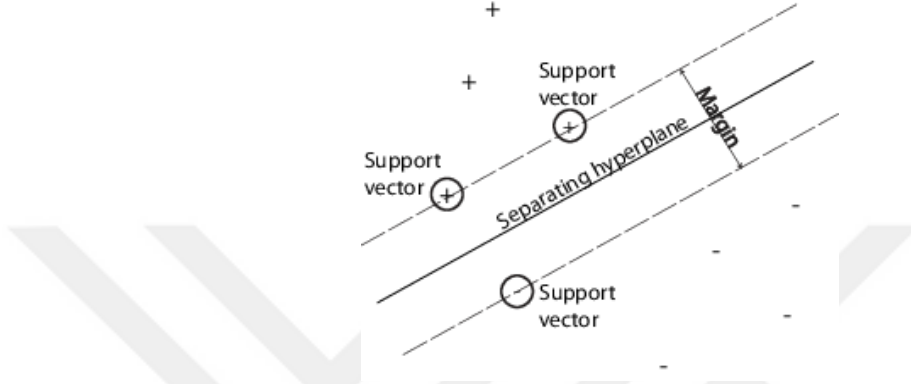
Gözlemlenen birimin hangi kategoriye ait olduğunu belirleme problemi sınıflandırma olarak adlandırılır. İstatistikte, genellikle gözlemler, ölçülebilir özellikler üzerinden analiz edilirler. Bu birimlerin tanınmasını ve birbirinden ayırt edilmesini sağlayan özellikler, öznitelik uzayı olarak isimlendirilir.

Sınıflamayı gerçekleştiren matematiksel algoritmalar sınıflandırıcı olarak adlandırılır. Destek Vektör Makineleri, sağlam sonuçlar veren makine öğrenmesi ve sınıflandırma metodlarının başında gelir.

### 2.2.1 Destek vektör makineleri (SVM)

Destek Vektör Makinesi (SVM), ayırt edilmek istenen sınıfları birbirinden ayıran en iyi hiper düzlemi çizmeyi amaçlayan bir sınıflandırıcıdır. İki boyutlu düzlemde, bu hiper düzlem bir doğrudur. Bu doğru, iki sınıfın elemanlarını doğrunun bir tarafında kalacak şekilde ayırır. Destek vektörleri, sınıfları ayıran hiper düzleme en yakın olan verileri ifade eder. Bir SVM modeli için en iyi hiper düzlem, iki sınıfın destek vektörlerinin arasındaki marjın en büyük olduğu düzlemdir. Destek Vektörlerinin ve hiper düzlemin görsel şekli Şekil 2.6'de görülebilir.

Örneğin iki sınıftan oluşan bir sınıflandırma probleminde sınıflarımız  $X$  ve  $Y$  olsun. Destek Vektör Makinesinin amacı  $X$  ve  $Y$  sınıflarını ayıracak en iyi ayırıcıyı çizmektir. Tercih edilecek çekirdek fonksiyonuna göre, bu dönüşüm fonksiyonu doğrusal, polinomsal ya da gaussian (radyal tabanlı) olabilir.



**Şekil 2.6:** Destek Vektör Makineleri(SVM) hiper düzlem ve marjin gösterimi

Destek Vektör Makineleri hakkında detaylı bilgiye bu çalışmalardan [Borges , 1998] ve [Evgeniou, Pontil ve Poggio , 1999] ulaşılabilir.

Destek Vektör Makineleri, doğrusal olmayan, çok boyutlu verilerde etkili bir şekilde sonuç vermesi sebebiyle tercih edilmektedir. Veri setinin çok büyük olması durumunda, sonuç almak uzun sürebilir.

Sınıflandırılmak istenen veri seti her zaman doğrusal olarak ayıramayabilir. Doğrusal olarak ayrılması mümkün olmayan veriler doğrusal olmayan ayırıcılar kullanarak sınıflandırılabilir. Bu fonksiyonlar çekirdek(kernel) fonksiyonlar olarak adlandırılır. Veriyi daha büyük boyuttaki bir uzaya taşıyarak sınıflandırılması sağlanır.

### 2.2.1.1 Çekirdek fonksiyonları

İlk olarak tanımlanan Maksimum marjlı hiper düzlem algoritması doğrusal ayırıcılar için tanımlanmıştır. Doğrusal olmayan problemler için tanımlanan çekirdek fonksiyonları daha sonra [Boser, Guyon ve Vapnik , 1992] tarafından literatüre eklenmiştir. Çekirdek fonksiyonları, bir çok doğrusal ve doğrusal olmayan problemin çözümünde kullanılmaktadır. Çekirdek fonksiyonları Destek Vektör Makinelerinin temel özelliğini oluşturur. Çekirdek fonksiyonu modelin ayrıştırılabilir bir boyuta dönüşmesini sağlayan fonksiyondur. Doğrusal olmayan bir model, çekirdek fonksiyonu ile doğrusal bir modele dönüşebilir. Bu dönüşüm, örtük öznelik uzayı kullanılarak yapılır. [Cristianini ve Shawe-Taylor , 2000] Farklı çekirdek fonksiyonları aşağıdaki gibidir;

- **Doğrusal çekirdek fonksiyonu:** Verinin doğrusal olarak hiper düzlemde ayrıla-

bildiği durumda tercih edilir.

$$K(x, y) = x^T y \quad (2.32)$$

- **Polinomsal çekirdek fonksiyonu:** Polinomsal çekirdek fonksiyonu, örnek verinin benzerliklerini karşılaştırırken sadece verilen özniteliklere bakmaz, özniteliklerin kombinasyonuna da bakar. Doğrusal çekirdek fonksiyonu, polinomsal çekirdek fonksiyonunun  $c = 0$  ve  $d = 1$  olduğu basit halidir.

$$K(x, y) = (x^T y + c)^d \quad (2.33)$$

Eğer  $d = 2$  olarak alınırsa, ikinci dereceden (Kuadratik) polinomsal fonksiyon alınır.

$$K(x, y) = (x^T y + c)^2 \quad (2.34)$$

Eğer  $d = 3$  olarak alınırsa, Üçüncü dereceden (Kübik) polinomsal fonksiyon alınır.

$$K(x, y) = (x^T y + c)^3 \quad (2.35)$$

- **Radyal tabanlı çekirdek fonksiyonu:**

$$K(x, x') = \exp\left(-\frac{\|x - x'\|^2}{2\sigma^2}\right) \quad (2.36)$$

Bu denklemde  $x$  ve  $x'$  girdi öznitelik vektör uzayını temsil etmektedir. Gaussyan çekirdek fonksiyonunda  $\sigma$  çekirdek genişliğini vermektedir. Destek Vektör Makinesi sınıflandırmasında en sık kullanılan çekirdek fonksiyonudur.

- Ince (Fine) Gaussyan fonksiyonu, çekirdek ölçeğini  $\sqrt{P}/4$  olarak ayarlar.
- Orta (Medium) Gaussyan çekirdek fonksiyonu, çekirdek ölçeğini  $\sqrt{P}$  olarak ayarlar.
- İri (Coarse) Gaussyan fonksiyonu, çekirdek ölçeğini  $\sqrt{P} * 4$  olarak ayarlar. Burada belirtilen  $P$ , tahmin edici öznitelik vektörünün boyutunu temsil etmektedir.

Bu çalışmada, doğrusal, ikinci ve üçüncü derece polinomsal ve farklı gaussyan çekirdek fonksiyonları Destek Vektör Makinesinde denenmiştir. Finansal zaman serisinin doğrusal olmayan ve tahmini güç bir yapıda olması sebebiyle Gaussyan çekirdek fonksiyonu ile daha iyi sonuçlar alınmıştır. Daha sonra sırası ile polinomsal ve doğrusal çekirdek fonksiyonu gelmektedir.

### 2.2.1.2 apraz doęrulama

Bir tahmin modelinin baęımsız bir veri setindeki başarısını len model doęrulama teknięidir. Bunun iin veri seti iki kısıma ayrılır. Veri setinin bir kısmı ile modeli ęrenirken, kalan kısmı ile model doęrulandır. Bu oran %90 Eęitim-%10 Doęrulama, %80 Eęitim-%20 Doęrulama, %70 Eęitim-%30 Doęrulama vb. farklı oranlar alınabilir. Aynı veri setinin farklı gruplanmasıyla model tekrarlayarak modelin başarısı lölür. Bylece varyansı azaltarak, daha doęru bir model elde edilmesi amalanır. apraz doęrulamada bir dięer nemli nokta da, varyansı azaltırken, modelin veri setini ezberlemesini ve seim yanlılıęını nlemesidir. Veri seti  $k$  paraya blündüğünde,  $\frac{1}{k}$  kısmı doęrulama verisi olurken,  $\frac{k-1}{k}$  kısmı eęitim verisi olur. Buna  $k$ -katlı apraz doęrulama denir.  $k$  defa tekrar ile model eęitilip, aprazlanan grupların doęrulama sonuçlarının ortalaması alınarak modelin genel tahmin başarısı hesaplanır.

Burada dikkat edilmesi gereken nokta, apraz doęrulamada kullanılan veri seti (eęitim ve doęrulama), daha sonra modeli test etmek iin kullanılan test veri setiden ayrıdır. Bu alıřmada 10 katlı apraz doęrulama tercih edilmiřtir.





### 3. ÖNERİLEN MODEL

#### 3.1 Amaç

Önerilen modelin amacı, bir ticari enstrümanın en uygun yatırım zamanını (Alım ya da Satım) tahmin ederken başvuru öneri şemalarına ek bir karar destek sistemi geliştirmektir. Finansal teknik göstergelerden türetilen öneri şemaları yatırımcıların Alım ya da Satım zamanlarında sinyaller oluşturarak yatırımcıya yardım etmektedir. Önerilen model ile, bu öneri şemalarının ürettikleri sinyallerin iyileştirilmesi amaçlanmıştır. Öneri Şemalarının verdikleri YANLIŞ sinyaller ile DOĞRU sinyaller ayırt edilerek, yatırımcının daha doğru kararlar almasına yardım eden karar destek sistemi oluşturulmaktadır.

#### 3.2 AL/SAT Önericisi olarak Teknik Analiz Göstergeleri

Bir  $X$  ticari enstrümanın (hisse senedi, döviz kuru, indeks, emtia)  $n$  zaman süresindeki fiyatı  $F = \langle f_1, f_2, \dots, f_n \rangle$  vektörü ile gösterilsin. Çalışmamızda daha çok hisse senedi değerlerini kullandığımız için bu  $X$  ticari enstrümanı bundan sonraki kısımlarda hisse senedi olarak adlandırılacaktır. Daha açık bir şekilde ifade etmek gerekirse,  $X$  bir hisse senedi,  $f_i$ 'de bu hisse senedinin  $i$ 'nci gündeki fiyatını temsil etmektedir. Çizelge 3.1, bir hisse senedinin  $n$  günlük periyotta fiyat vektörünü temsil etmektedir.

Finansal göstergeler, herhangi bir  $X$  hisse senedi için çevrimiçi olarak eyleme geçirilebilir yatırım önerisi üretebilirler. Mesela, Göreceli güç indeksine(RSI) dayalı bir yatırım öneri sisteminde, RSI değeri 30'un altında iken (düşük değerli fiyat aralığı) AL önerisi oluştururken, bu değer 70'in üzerinde iken (yüksek değerli fiyat aralığı) SAT önerisi oluşturmaktadır. Bu yatırım öneri şeması 30/70 kuralı olarak bilinmektedir. Bu şemada, 30 ve 70 arasındaki herhangi bir değer AL ya da SAT önerisi oluşturmamakta dolayısı ile bu aralıktaki fiyat değerleri TUT önerisi oluşturmaktadır. Bu TUT önerisinde herhangi bir işlem yapılmamaktadır.

$Y$ , verilen  $X$  hisse senedinin her bir  $i$ 'nci gün için AL, SAT ya da TUT önerisi oluşturan bir öneri sistemi olsun. Örneğin 30/70 kuralı gibi. Bu öneri sisteminden elde edilen karar vektörü de  $T = \langle t_1, t_2, \dots, t_n \rangle$  vektörü olsun. Her bir  $t_i = (AL, SAT, TUT)$  de  $Y$  öneri sistemi tarafından  $i$ 'nci gün için alınan karar olsun. Yani,  $Y$ ,  $F$  vektörünü  $T$ 'ye eşleyen bir öneri fonksiyonudur. Çizelge 3.2, 30/70 RSI kuralı altında RSI  $Y$  öneri sisteminin yardımı ile AL/SAT/TUT kararından oluşan  $T$  vektörünü göstermektedir.

Çevrimiçi öneri sistemleri ardarda AL-AL ya da SAT-SAT önerisi üretebilmektedirler. Bu tip öneri sistemlerinde iki ana problem ile karşılaşılır:

- Yatırımcı ilk AL önerisinden sonra sonra yatırım yapmaya karar verirse, daha

**Çizelge 3.1:** X hisse senedi NKE olarak alındığında n= 14 için F vektörü.

<b>F</b>	
i	$f_i$
1	4,63
2	4,55
3	4,63
4	4,67
5	4,90
6	4,79
7	4,87
8	4,99
9	4,98
10	5,30
11	5,17
12	5,34
13	5,38
14	5,56

**Çizelge 3.2:** X hisse senedi NKE ve  $n = 14$  alındığında  $Y = 30/70$  RSI öneri sistemi altında T vektörü.

$\vec{F}$		$\vec{Y}$	$\vec{T}$
i	$f_i$	RSI	30/70 RSI KURALI
1	4,63	40,4	TUT
2	4,55	32,3	TUT
3	4,63	37,4	TUT
<b>4</b>	<b>4,67</b>	<b>27,3</b>	<b>AL</b>
5	4,90	47,7	TUT
6	4,79	46,9	TUT
7	4,87	46,6	TUT
8	4,99	54,4	TUT
9	4,98	57,0	TUT
10	5,30	64,9	TUT
11	5,17	57,3	TUT
12	5,34	67,8	TUT
13	5,38	69,8	TUT
<b>14</b>	<b>5,56</b>	<b>71,7</b>	<b>SAT</b>

sonra gelen AL önerisi, elinde yeni yatırım için bir para kalmadığı için geçersiz olacaktır. Yani, daha sonra gelen daha iyi bir AL önerisinde işlem yapılamayacaktır.

- İkinci problem ise, Bir AL önerisi geldikten sonra yatırımcının daha uygun bir fiyat ile yeni bir AL önerisini bekleyip beklemeyeceğidir. Diğer bir ifadeyle, eğer ilk gelen AL önerisinde almayı bekleyecekse, hangi AL önerisine karar vereceğini bilmesi gerekir.

Aynı problem, SAT önerisi içinde geçerlidir. Çizelge 3.3'de  $T$  vektörü, TNRSI 45/55 kuralı sonrasında oluşan ardarda AL-AL ve SAT-SAT sinyallerini göstermektedir. Çevrimiçi öneri sistemlerindeki bu problemden dolayı, bu çalışmada, AL ve SAT önerilerinin DOĞRU ya da YANLIŞ olduğunu değerlendiren ek bir danışma mekanizması geliştirilmiştir.

**Çizelge 3.3:**  $X$  hisse senedi NKE ve  $n = 20$  alındığında  $Y = 45/55$  TNRSI öneri sistemi altında  $T$  vektörü. Ardarda birden fazla AL ya da SAT önerisi üretmektedir.

	$\vec{F}$	$\vec{Y}$	$\vec{T}$	Temel Model
i	$f_i$	$TNRSI_i$	45/55 TNRSI	
1	4,63	45,6	TUT	
2	<b>4,55</b>	<b>41,4</b>	<b>AL</b>	<b>AL</b>
3	4,63	49,6	TUT	
4	<b>4,67</b>	<b>44,8</b>	<b>AL</b>	
5	<b>4,9</b>	<b>68,2</b>	<b>SAT</b>	<b>SAT</b>
6	<b>4,79</b>	<b>64,6</b>	<b>SAT</b>	
7	<b>4,87</b>	<b>64</b>	<b>SAT</b>	
8	<b>4,99</b>	<b>68,7</b>	<b>SAT</b>	
9	<b>4,98</b>	<b>67</b>	<b>SAT</b>	
10	<b>5,3</b>	<b>69,5</b>	<b>SAT</b>	
11	<b>5,17</b>	<b>57,2</b>	<b>SAT</b>	
12	<b>5,34</b>	<b>65,8</b>	<b>SAT</b>	
13	<b>5,38</b>	<b>62,1</b>	<b>SAT</b>	
14	<b>5,56</b>	<b>60,7</b>	<b>SAT</b>	
15	<b>5,45</b>	<b>57,1</b>	<b>SAT</b>	
16	5,2	48,5	TUT	
17	<b>5,17</b>	<b>43,1</b>	<b>AL</b>	<b>AL</b>
18	<b>5,22</b>	<b>41,6</b>	<b>AL</b>	
19	<b>5,27</b>	<b>34,5</b>	<b>AL</b>	
20	<b>5,16</b>	<b>34,7</b>	<b>AL</b>	

**Çizelge 3.4:**  $X$  hisse senedi NKE ve  $n = 14$  alındığında  $Y = 30/70$  RSI öneri sistemi altında  $T$  vektörü.

	$\vec{F}$	$\vec{Y}$	$\vec{T}$	M	HISSE
i	$f_i$	RSI	30/70 RSI KURALI		
1	4,63	40,4	TUT	\$100	
2	4,55	32,3	TUT	\$100	
3	4,63	37,4	TUT	\$100	
<b>4</b>	<b>4,67</b>	<b>27,3</b>	<b>AL</b>	<b>\$100</b>	<b>21,4</b>
5	4,90	47,7	TUT		21,4
6	4,79	46,9	TUT		21,4
7	4,87	46,6	TUT		21,4
8	4,99	54,4	TUT		21,4
9	4,98	57,0	TUT		21,4
10	5,30	64,9	TUT		21,4
11	5,17	57,3	TUT		21,4
12	5,34	67,8	TUT		21,4
13	5,38	69,8	TUT		21,4
<b>14</b>	<b>5,56</b>	<b>71,7</b>	<b>SAT</b>	<b>\$119</b>	<b>21,4</b>

### 3.3 DOĞRU ve YANLIŞ Önericilerin Belirlenmesi

$M_0$ , 0'ncı gündeki sermaye olsun ve  $X$  hisse senedine maksimum getiri sağlayacak şekilde yatırım yapmak istensin. Başlangıçta elimizde olan  $F$  fiyat vektörü ve  $T$  birincil karar vektörü dikkate alındığında, bir finansal alım-satım modeli,  $T$ 'nin bir alt dizgisi  $T'$  olarak tanımlansın. Bu alım satım modelinde;

- i Bu alt dizgi AL kararı ile başlar,
- ii Sırası ile SAT ve AL kararı ile değişerek devam eder,
- iii SAT kararı ile sona erer.

Özetle,  $M_0$  sermayesi ile bir  $X$  hisse senedine yatırım yapmaya başlayarak, başta  $X$  hisse senedi almalı, daha sonra  $X$  hisse senedi satmalı, ve ara aşamalar bu düzen ile devam etmeli, en sonda  $X$  hisse senedini satarak, nihai  $M'$  parasal değerini elde etmelidir. Çizelge 3.4, tek AL/SAT önerisi üretildiğinde oluşan,  $M_0$  sermayesi ile başlayan işlem adımlarını göstermektedir.

Fakat her zaman tek AL ve tek SAT önerisi olmamakta, ardarda birden çok AL veya birden çok SAT önerisi gelebilmektedir. Çizelge 3.3'de bunun örneği görülebilir. Bu

önerilerden en karlı olanını seçebilmek için bir optimizasyon uygulamamız gerekir. Bu optimizasyon ile optimum alım-satım modelini bulmak amaçlanır.

Optimum alım-satım modelini bulma problemi aşağıdaki gibi tanımlanır;  $F$  fiyat vektörü ve  $T$  birincil karar vektörünü alarak, en sonda elde edilecek kârı maksimum yapacak optimum alım-satım deseni  $T'$  bulunur. Bu kâr  $K = M' - M$  olarak ifade edilir. Bu problemin doğrusal zamanda ( $O(n)$ ) çözümü, ileriki bölümde detayı verilecek olan dinamik programlama formülasyonu ile mümkündür.

$MaxCap(i)$ ,  $i$ 'nci günün sonundaki maksimum parasal değeri ifade ederken,  $MaxStock(i)$ ,  $i$ 'nci günün sonundaki sahip olduğumuz maksimum hisse senedi sayısını gösterebilir.  $i$ 'nci gündeki karara ( $t_i$ ) bağlı olarak,  $MaxCap(i)$  ve  $MaxStock(i)$  değerleri aşağıdaki gibi güncellenir; (Denklem 3.1-3.2)

$$MaxCap(i) = \begin{cases} Max\{fiyat_i * MaxStock(j) \mid j = 0..i-1 \text{ and } t_j = Al\}, & t_i = Sat \\ 0, & t_i = Al \\ MaxCap(i-1), & t_i = Tut \end{cases} \quad (3.1)$$

$$MaxStock(i) = \begin{cases} Max\{MaxCap(j)/fiyat_i \mid j = 0..i-1 \text{ and } t_j = Sat\}, & t_i = Al \\ 0, & t_i = Sat \\ MaxStock(i-1), & t_i = Tut \end{cases} \quad (3.2)$$

Yukarıda, başlangıç durumunda  $MaxCap(0) = M$ ,  $MaxStock(0) = 0$  ve  $t_0 = Sat$  olarak kabul edilmiştir. Yukarıda geçen  $fiyat_i$ ,  $i$  günündeki hisse senedi fiyatını,  $t_i$ ,  $i$  günündeki birincil önerici kararını temsil etmektedir.

Güncelleme kuralının ilk işlem günü AL ile başladığı, ve daha sonraki sefer SAT ve AL ile sırası ile değişerek devam ettiği hatırlanmalıdır. Son işlemin SAT kararı ile bitmesi gerektiği için,  $i$ . gündeki son işlemin  $MaxCap(i)$  değerinin elde edilen maksimum değeri verdiği bilinmektedir. Bu son SAT işlem gününü  $i'$  ile, elde edilen maksimum değeri  $M' = MaxCap(i')$  ile gösterilsin.

Başlangıç sermayesi  $M = MaxCap(0)$  olduğu biliniyor, elde edilecek maksimum kâr  $K = MaxCap(i') - MaxCap(0)$  ile gösterilir. Böylece, maksimum kârı veren yatırım modeli  $i'$  günden ilk işlem gününe doğru geriye gidilerek kolay bir şekilde oluşturulabilir.

Maalesef, yukarıdaki üç güncelleme kuralının doğrudan uygulanması, dinamik prog-

ramlama algoritmasının  $O(n^2)$  zaman karmaşıklığı ile sonuçlanır.  $O(n^2)$  zaman karmaşıklığı büyük  $n$  değerleri için büyük sıkıntı oluşturmaktadır. Bununla birlikte,  $MaxCap(i)$  ve  $MaxStock(i)$  de yapılan küçük anlamsal değişiklik ile  $O(n)$  lineer zamanda dinamik programlama çözümü bulunabilmektedir. Buradaki  $MaxCap(i)$ , ardından gelecek işleme bakmaksızın  $i$  günü sonunda elde edilebilecek maksimum sermayeyi,  $MaxStock(i)$  ise  $i$  günü sonunda elde edilebilecek maksimum hisse senedi miktarını vermektedir.  $O(n)$  zaman karmaşıklığındaki algoritmanın detayları aşağıdaki gibidir;

$$MaxStock(i) = \begin{cases} Max \{MaxStock(i-1), MaxCap(i-1)/fiyat_i\}, & t_i = Al \\ MaxStock(i-1), & t_i = Tut \end{cases} \quad (3.3)$$

$$MaxCap(i) = \begin{cases} Max \{MaxCap(i-1), fiyat_i * MaxStock(i-1)\}, & t_i = Sat \\ MaxCap(i-1), & t_i = Tut \end{cases} \quad (3.4)$$

Denklem 3.1-3.2'deki  $fiyat_i$ ,  $i$  günündeki hisse senedi fiyatını,  $t_i$ ,  $i$  günündeki birincil önerici kararını göstermektedir.

Bahsedilen  $T'$  optimal karar vektörünü hesaplamak için, bir dizide optimal vektörün sıralı işlemlerinin AL, SAT olmak üzere kaydı tutulur. Bu şekilde optimal vektörün kuralı sağladığından, yani AL, SAT olarak değişerek devam ettiğiinden ve SAT işlemi ile sonlandığından emin olunur.

Çizelge 3.5,  $T$  birincil karar vektörüyle gerçekleştirilen ve dinamik programlama ile öğrenilen yeni model ile AL-SAT-AL simülasyonuna bir örnek olarak gösterilmiştir. Buradaki Temel model, ardarda gelen önericilerden ilkinin alınması ile yapılan ekstra bir model kullanılmadan yapılan alım-satımı temsil etmektedir. Optimal model ise ardarda gelen AL ve ya SAT lardan  $T'$  optimal karar vektörü ile en kârlı olanını seçmektedir.

Dinamik Programlama formülasyonunun sonucu olarak,  $T$  vektörünün optimal alt dizisi olan  $T'$  vektörünü elde edelim.  $F'$  vektörü,  $T'$  optimal kararlarının olduğu günleri içeren fiyat vektörü,  $F''$  vektörü ise,  $T$  vektörünün  $T'$  optimal kararlarını içermeyen günlerin fiyat vektörü olsun. O halde, bu çalışmada önerilen hipotez,  $Y$  öneri sistemi tarafından  $F'$  günlerinde üretilen önericiler DOĞRU Al/Sat önericileri iken,  $F''$  günlerinde üretilen önericiler YANLIŞ Al/Sat önericileri kabul edilmektedir.

Bir sonraki bölümde, Bu DOĞRU ve YANLIŞ Al/Sat önericilerini çevrimiçi olarak ayırt edebilecek makine öğrenmesi modelinin nasıl geliştirildiğinden bahsedilecektir.

**Çizelge 3.5:**  $X$  hisse senedi NKE ve  $n = 40$  alındığında  $Y = 45/55$  TNRSI öneri sistemi altında Maksimum kar. Temel model, ilk AL ve SAT önerisine göre karar alırken, Optimal model, maksimum kar getirecek öneriye göre karar almaktadır.

	$\bar{F}$ $f_i$	$\bar{Y}$ $TNRSI_i$	$\bar{T}$ 45/55	Temel Model	$M_i$	$Hisse_i$	Optimal Model	$M_i$	$\bar{T}'$ $Hisse_i$
1	4,63	45,56	TUT		\$100			\$100	
<b>2</b>	<b>4,55</b>	<b>41,35</b>	<b>AL</b>	<b>AL</b>	<b>\$100</b>	<b>22,0</b>	<b>AL</b>	<b>\$100</b>	<b>22,0</b>
3	4,63	49,63	TUT			22,0			22,0
4	4,67	44,79	AL			22,0			22,0
<b>5</b>	<b>4,90</b>	<b>68,23</b>	<b>SAT</b>	<b>SAT</b>	<b>\$107,7</b>	<b>22,0</b>			<b>22,0</b>
6	4,79	64,57	SAT		\$107,7				22,0
7	4,87	63,97	SAT		\$107,7				22,0
8	4,99	68,72	SAT		\$107,7				22,0
9	4,98	67,01	SAT		\$107,7				22,0
10	5,30	69,5	SAT		\$107,7				22,0
11	5,17	57,21	SAT		\$107,7				22,0
12	5,34	65,78	SAT		\$107,7				22,0
13	5,38	62,14	SAT		\$107,7				22,0
<b>14</b>	<b>5,56</b>	<b>60,69</b>	<b>SAT</b>		<b>\$107,7</b>		<b>SAT</b>	<b>\$122,49</b>	<b>22,0</b>
15	5,45	57,05	SAT		\$107,7			\$122,49	
16	5,20	48,53	TUT		\$107,7			\$122,49	
<b>17</b>	<b>5,17</b>	<b>43,08</b>	<b>AL</b>	<b>AL</b>	<b>\$107,7</b>	<b>20,8</b>		<b>\$122,49</b>	
18	5,22	41,6	AL			20,8		\$122,49	
19	5,27	34,49	AL			20,8		\$122,49	
20	5,16	34,66	AL			20,8		\$122,49	
21	5,21	34,57	AL			20,8		\$122,49	
<b>22</b>	<b>5,00</b>	<b>28,58</b>	<b>AL</b>			<b>20,8</b>	<b>AL</b>	<b>\$122,49</b>	<b>24,5</b>
23	5,00	32,81	AL			20,8			24,5
24	5,03	28,89	AL			20,8			24,5
25	5,06	37,25	AL			20,8			24,5
26	5,38	46,75	TUT			20,8			24,5
27	5,49	51,67	TUT			20,8			24,5
28	5,35	45,37	TUT			20,8			24,5
29	5,33	50,77	TUT			20,8			24,5
<b>30</b>	<b>5,46</b>	<b>65,33</b>	<b>SAT</b>	<b>SAT</b>	<b>\$113,57</b>	<b>20,8</b>			<b>24,5</b>
31	5,63	70,63	SAT		\$113,57				24,5
32	5,53	63,08	SAT		\$113,57				24,5
33	5,41	56,5	SAT		\$113,57				24,5
34	5,20	52,49	TUT		\$113,57				24,5
35	5,32	53,3	TUT		\$113,57				24,5
36	5,50	61,46	SAT		\$113,57				24,5
37	5,60	61,14	SAT		\$113,57				24,5
38	5,63	58,13	SAT		\$113,57				24,5
<b>39</b>	<b>6,00</b>	<b>62,17</b>	<b>SAT</b>		<b>\$113,57</b>		<b>SAT</b>	<b>\$147,00</b>	<b>24,5</b>
40	5,95	49,99	TUT		\$113,57			\$147,00	



**Çizelge 3.6:**  $X$  hisse senedi NKE ve  $n = 1$  alındığında  $\vec{I}$  teknik analiz gösterge vektörü

$i$	$f_i$	$RSI_i$	$TNRSI_i$	$BB_i$	$ROC_i$	$SO_i$	$CCI_i$	$PPO_i$
		$I_1$	$I_2$	$I_3$	$I_4$	$I_5$	$I_6$	$I_7$
1	4,90	47,7	68,2	53,5	-1,3	84,9	9,6	-1,1

**Çizelge 3.7:**  $X$  hisse senedi NKE ve  $n = 1$  alındığında bir önceki günün teknik göstergelerinin eklenmesi ile oluşan  $\vec{I}_2$  teknik analiz gösterge vektörü

$i$	$f_i$	$RSI_i$	$TNRSI_i$	$BB_i$	$ROC_i$	$SO_i$	$CCI_i$	$PPO_i$	$RSI_{i2}$	$TNRSI_{i2}$	$BB_{i2}$	$ROC_{i2}$	$SO_{i2}$	$CCI_{i2}$	$PPO_{i2}$
		$I_1$	$I_2$	$I_3$	$I_4$	$I_5$	$I_6$	$I_7$	$I_8$	$I_9$	$I_{10}$	$I_{11}$	$I_{12}$	$I_{13}$	$I_{14}$
1	4,90	47,7	68,2	53,5	-1,3	84,9	9,6	-1,1	27,27	44,8	24,55	-13,08	15,09	-88,82	-1,49

### 3.4 DOĞRU ve YANLIŞ Önericilerin Tahmini

Finansal piyasalarda fiyat ve hacim değişiminin farklı oranlarından türemiş onlarca teknik gösterge bulunmaktadır. Bu teknik göstergeler farklı amaçlar için fiyatın hareket yönünün, alım ya da satım noktasında olup olmadığının tahmin edilmesinde kullanılırlar.

$I = \langle I_1, I_2, \dots, I_k \rangle$ , seçilen  $k$  farklı teknik analiz göstergesinin vektörü olsun.  $F$  fiyat vektörünün ilgili teknik gösterge değerleri hesaplandığında  $n \times k$  boyutunda  $D$  matrisi elde edilir.  $D(i, j)$  değeri,  $i$  günündeki  $I_j$  teknik gösterge değerini belirtmektedir. Çizelge 3.6, fiyat verisinden türetilmiş örnek bir teknik analiz gösterge vektörünü göstermektedir. Çizelge 3.7 ise, ardışık iki günün özniteliklerinin birlikte temsil edildiği öznitelik vektörünü göstermektedir.

$D$  matrisinden (Çizelge 3.8),  $T'$  vektörünün yardımıyla, sadece AL önericilerini içeren  $DA$  ve sadece SAT önericilerini içeren  $DS$  matrisi oluşturulur.

- 1 İlk olarak,  $DA$  matrisini elde etmek için,  $D$  matrisinin AL önericileri dışındaki satırları silinir. Bu satırlar, TUT ve SAT öneren satırlardır.
- 2 Daha sonra,  $T'$  vektörünün yardımıyla, her bir satır için DOĞRU ya da YANLIŞ olduğuna dair ikili değer (D/Y) içeren bir sütün ilave edilir. Bu ikili değer,  $i$  gününün AL önerisinin  $T'$  optimal altdizisinde olup olmadığına göre verilir.
- 3 Eğer  $i$  gününün verisi  $T'$  optimal altdizisinde bulunuyorsa, ikili değer DOĞRU, diğer durumda YANLIŞ olarak işaretlenir.

Böylece  $DA$  matrisi oluşturulur. (Çizelge 3.9)

AL önericilerini içeren  $DA$  matrisi için yapılan işlemler, aynı aşamalarla SAT önericilerini içeren  $DS$  matrisini oluşturmak için de uygulanır, (Çizelge 3.10). Bu işlemler sonunda  $DA$  ve  $DS$  matrisleri oluşturulur. (Çizelge 3.9-3.10)

**Çizelge 3.8:** *X* hisse senedi NKE ve  $n = 40$  alındığında  $Y = 45/55$  TNRSI öneri sistemi altında *I* teknik analiz göstergeleri ile oluşan *D* Matrisi.

<b>i</b>	<b>F</b>	<b>RSI</b>	<b>TNRSI</b>	<b>BB</b>	<b>ROC</b>	<b>SO</b>	<b>CCI</b>	<b>PPO</b>	<b>T</b>	<b>T'</b>
1	4,63	40,4	45,6	4,9	-7,3	-13,1	-176,9	-0,9	TUT	
<b>2</b>	<b>4,55</b>	<b>32,3</b>	<b>41,4</b>	<b>1,4</b>	<b>-12,3</b>	<b>-11,6</b>	<b>-189</b>	<b>-1,3</b>	<b>AL</b>	<b>AL</b>
3	4,63	37,4	49,6	16,9	-8,9	10,4	-119,5	-1,5	TUT	
4	4,67	27,3	44,8	24,6	-13,1	15,1	-88,8	-1,5	AL	
5	4,9	47,7	68,2	53,5	-1,3	84,9	9,6	-1,1	SAT	
6	4,79	46,9	64,6	41,1	-1,8	58,5	-32,8	-1	SAT	
7	4,87	46,6	64	51,8	-1,9	77,4	4,2	-0,8	SAT	
8	4,99	54,4	68,7	70,5	2,6	116,3	72,7	-0,4	SAT	
9	4,98	57	67	70,7	3,9	98,3	74,2	-0,1	SAT	
10	5,3	64,9	69,5	121	10,2	170,2	294,3	0,7	SAT	
11	5,17	57,3	57,2	95,5	4,9	82,5	172,4	1	SAT	
12	5,34	67,8	65,8	106	12,3	104,1	219	1,6	SAT	
13	5,38	69,8	62,1	101,6	13,9	105	198,1	2	SAT	
<b>14</b>	<b>5,56</b>	<b>71,7</b>	<b>60,7</b>	<b>107,6</b>	<b>16</b>	<b>122,6</b>	<b>219,3</b>	<b>2,6</b>	<b>SAT</b>	<b>SAT</b>
15	5,45	74	57,1	91,7	17,7	89,2	143	2,9	SAT	
16	5,2	67,2	48,5	68,5	14,3	63,9	56,1	2,7	TUT	
17	5,17	64,8	43,1	65,4	11,6	58	44,9	2,5	AL	
18	5,22	65	41,6	67,4	11,7	61,4	50,8	2,3	AL	
19	5,27	61,1	34,5	69,2	7,5	61,6	56,2	2,3	AL	
20	5,16	61,4	34,7	59,3	7,8	48,5	26	2	AL	
21	5,21	60,7	34,6	61,4	7,1	49,4	33,3	1,9	AL	
<b>22</b>	<b>5</b>	<b>50,2</b>	<b>28,6</b>	<b>39,3</b>	<b>0,2</b>	<b>2,7</b>	<b>-35,9</b>	<b>1,4</b>	<b>AL</b>	<b>AL</b>
23	5	50,5	32,8	36	0,3	2,7	-47,2	1,1	AL	
24	5,03	40,2	28,9	35,9	-5,2	5,6	-48,1	0,8	AL	
25	5,06	45,8	37,3	38,3	-2,1	11,1	-40,9	0,7	AL	
26	5,38	51,4	46,8	77	0,7	66,7	89,7	1	TUT	
27	5,49	53,8	51,7	90	2,2	87,5	137	1,4	TUT	
28	5,35	42,9	45,4	67,8	-3,8	62,5	55,2	1,6	TUT	
29	5,33	45,5	50,8	62,4	-2,3	66,7	37,2	1,6	TUT	
30	5,46	60,5	65,3	81	5,1	93,7	98,6	1,8	SAT	
31	5,63	66,1	70,6	97,6	8,8	127	161,2	2,2	SAT	
32	5,53	60,8	63,1	82	6	85	100,8	2,3	SAT	
33	5,41	54,9	56,5	66,2	2,8	66,3	47,6	2,2	SAT	
34	5,2	51,2	52,5	40,3	0,8	32,5	-31,6	1,8	TUT	
35	5,32	53,2	53,3	57,6	2,1	51,3	21,8	1,6	TUT	
36	5,5	65	61,5	79,9	10	80	95,1	1,7	SAT	
37	5,6	67	61,1	88,7	12	96,3	126,1	2	SAT	
38	5,63	67	58,1	87,8	12	101,3	123,3	2,2	SAT	
<b>39</b>	<b>6</b>	<b>72,2</b>	<b>62,2</b>	<b>113,7</b>	<b>18,5</b>	<b>164,4</b>	<b>241,3</b>	<b>2,8</b>	<b>SAT</b>	<b>SAT</b>
40	5,95	65,7	50	99,9	10,8	94,1	185,2	3,2	TUT	

**Çizelge 3.9:** *D* matrisi AL önerileri gruplandığında oluşan matris. T’ modelinde seçilenler DOĞRU AL iken seçilmeyenler YANLIŞ AL olarak işaretlenir. SAT önerileri de T’ modeline göre aynı şekilde gruplanır.

i	F	RSI	TNRSI	BB	ROC	SO	CCI	PPO	T	T’	
1	<b>4,55</b>	<b>32,3</b>	<b>41,4</b>	<b>1,4</b>	<b>-12,3</b>	<b>-11,6</b>	<b>-189,0</b>	<b>-1,3</b>	AL	AL	<b>DOĞRU</b>
2	4,67	27,3	44,8	24,6	-13,1	15,1	-88,8	-1,5	AL		YANLIŞ
3	5,17	64,8	43,1	65,4	11,6	58,0	44,9	2,5	AL		YANLIŞ
4	5,22	65,0	41,6	67,4	11,7	61,4	50,8	2,3	AL		YANLIŞ
5	5,27	61,1	34,5	69,2	7,5	61,6	56,2	2,3	AL		YANLIŞ
6	5,16	61,4	34,7	59,3	7,8	48,5	26,0	2,0	AL		YANLIŞ
7	5,21	60,7	34,6	61,4	7,1	49,4	33,3	1,9	AL		YANLIŞ
8	<b>5,00</b>	<b>50,2</b>	<b>28,6</b>	<b>39,3</b>	<b>0,2</b>	<b>2,7</b>	<b>-35,9</b>	<b>1,4</b>	AL	AL	<b>DOĞRU</b>
9	5,00	50,5	32,8	36,0	0,3	2,7	-47,2	1,1	AL		YANLIŞ
10	5,03	40,2	28,9	35,9	-5,2	5,6	-48,1	0,8	AL		YANLIŞ
11	5,06	45,8	37,3	38,3	-2,1	11,1	-40,9	0,7	AL		YANLIŞ

Teknik gösterge değerleri, DOĞRU ve YANLIŞ kayıtlar için ayırt edici özellik taşımaktadır. Mesela DOĞRU(D) olarak etiketlenen bir satırın teknik gösterge değerleri, YANLIŞ(Y) olarak etiketlenen satırlardan belirgin bir farklılık göstereceği ve bu durumun sisteme öğretilbileceği kabul edilmektedir.

Sonraki işlem, teknik göstergeleri tahmin özellikleri olarak, her satırın DOĞRU ya da YANLIŞ olduğunu içeren ikili değer sütununu ise tahmin edilmek istenen etiket olarak belirlemektir. Bu durum, biri *DA* matrisi, diğeri *DS* matrisi için iki ayrı ikili sınıflandırma problemini getirir.

Sınıflandırma algoritması Destek Vektör Makinesi’ni *DA* ve *DS* matrislerine uyguladıktan sonra, sırasıyla iki sınıflandırma modeli *MA* ve *MS*’yi elde ediyoruz. Daha sonra, bu iki model çevrimiçi danışılmak üzere kullanılır. Bu çevrimiçi sınıflandırma modeli, birinci öneri sistemindeki Al ve Sat önerilerinin DOĞRU ya da YANLIŞ olduğunu tahmin eder. Bu tahmin, birçok yatırım kararında önemli bir danışma mekanizmasını oluşturur. Sonuç olarak, bu çalışmada geliştirilen yöntem, yatırım karar destek sisteminde kullanılmaktadır.

**Çizelge 3.10:** D matrisi SAT önerileri gruplandığında oluşan matris. T' modelinde seçilenler DOĞRU SAT iken, seçilmeyenler YANLIŞ SAT olarak işaretlenir.

i	F	RSI	TNRSI	BB	ROC	SO	CCI	PPO	T	T'	
1	4,90	47,7	68,2	53,5	-1,3	84,9	9,6	-1,1	SAT		YANLIŞ
2	4,79	46,9	64,6	41,1	-1,8	58,5	-32,8	-1,0	SAT		YANLIŞ
3	4,87	46,6	64,0	51,8	-1,9	77,4	4,2	-0,8	SAT		YANLIŞ
4	4,99	54,4	68,7	70,5	2,6	116,3	72,7	-0,4	SAT		YANLIŞ
5	4,98	57,0	67,0	70,7	3,9	98,3	74,2	-0,1	SAT		YANLIŞ
6	5,30	64,9	69,5	121,0	10,2	170,2	294,3	0,7	SAT		YANLIŞ
7	5,17	57,3	57,2	95,5	4,9	82,5	172,4	1,0	SAT		YANLIŞ
8	5,34	67,8	65,8	106,0	12,3	104,1	219,0	1,6	SAT		YANLIŞ
9	5,38	69,8	62,1	101,6	13,9	105,0	198,1	2,0	SAT		YANLIŞ
<b>10</b>	<b>5,56</b>	<b>71,7</b>	<b>60,7</b>	<b>107,6</b>	<b>16,0</b>	<b>122,6</b>	<b>219,3</b>	<b>2,6</b>	<b>SAT</b>	<b>SAT</b>	<b>DOĞRU</b>
11	5,45	74,0	57,1	91,7	17,7	89,2	143,0	2,9	SAT		YANLIŞ
12	5,46	60,5	65,3	81,0	5,1	93,7	98,6	1,8	SAT		YANLIŞ
13	5,63	66,1	70,6	97,6	8,8	127,0	161,2	2,2	SAT		YANLIŞ
14	5,53	60,8	63,1	82,0	6,0	85,0	100,8	2,3	SAT		YANLIŞ
15	5,41	54,9	56,5	66,2	2,8	66,3	47,6	2,2	SAT		YANLIŞ
16	5,50	65,0	61,5	79,9	10,0	80,0	95,1	1,7	SAT		YANLIŞ
17	5,60	67,0	61,1	88,7	12,0	96,3	126,1	2,0	SAT		YANLIŞ
18	5,63	67,0	58,1	87,8	12,0	101,3	123,3	2,2	SAT		YANLIŞ
<b>19</b>	<b>6,00</b>	<b>72,2</b>	<b>62,2</b>	<b>113,7</b>	<b>18,5</b>	<b>164,4</b>	<b>241,3</b>	<b>2,8</b>	<b>SAT</b>	<b>SAT</b>	<b>DOĞRU</b>



## 4. DENEYSEL ÇALIŞMALAR

### 4.1 Veri Seti

Bu çalışmada 9 farklı BIST-100 hisse senedi ve BIST 100 indeksi, 27 Dow-30 hisse senedi, Altın, Dolar-TL, Euro-TL döviz değerleri kullanılmıştır. Her hisse senedi veya döviz kuru için günlük kapanış fiyatları yer almaktadır. BIST-100 veri seti 2006'dan 2016'ya kadar 10 yıllık toplamda 2546 günlük veriyi içerir. Amerikan Borsası DOW-30 indeksindeki hisse senetleri ise 2000'den 2020'ye kadar 20 yıllık, toplamda 5000 günlük kapanış fiyatı verisini içerir. Veri setinin ayrıntıları aşağıdaki gibidir;

BIST-100'deki hisse senetleri: ADEL, ARCLK, ASELS, EGEEN, FENER, GOLTS, GOODY, THYAO, TTRAK ve BIST100 indeksinden oluşur.

DOW-30'daki hisse senetleri: AAPL, AMGN, AXP, BA, CAT, CSCO, CVX, DIS, GS, HD, HON, IBM, INTC, JNC, JPM, KO, MCD, MMM, MRK, MSFT, NKE, PG, TRV , UNH, VZ, WBA, WMT'den oluşmaktadır.

DOW-30'daki hisse senetleri yanında, ALTIN, DOLAR-TL, EURO-TL döviz kurları da ikinci veri setine dahil edilmiştir.

Veri setinin detayları Çizelge 4.1'de verilmiştir. İki farklı zaman periyodu ve iki farklı grup hisse senedini içeren, hisse senetlerinin kapanış fiyatlarından oluşan veri setine bu linkten ulaşılabilir. [Abul ve Tufekci , 2020]

### 4.2 Deneysel Çalışmanın İçeriği

Deneysel çalışmamız öncelikle, Al/Sat öneri şemalarını belirleyerek ve alınan veri setine bu öneri şemalarının uygulanması ile başlar.

Bu aşamadan sonra, Dinamik Programlama ile optimal yatırım örüntüsü kullanılarak DOĞRU ve YANLIŞ AL/SAT önericileri belirlenir.

Üçüncü aşamada, belirlenen finansal teknik göstergeler hesaplanıp veri setine tah-

**Çizelge 4.1:** Kullanılan Veri Setinin içeriği.

	Tarih Aralığı	Türü	Veri sayısı	Hisse senedi
<b>Veri Seti 1</b>	02.01.2006 - 02.12.2016	BIST100	2545	9
		BIST100 İndeksi	2545	1
<b>Veri Seti 2</b>	20.10.2000 - 04.09.2020	DOW30	5000	27
		DOVIZ (DOLAR, EURO)	5180	2
		ALTIN	5077	1

**Çizelge 4.2:** Birincil önerici olarak RSI ve TN RSI kullanan farklı öneri şemaları

Şema No	Alt Sınır	Üst Sınır	Finansal Gösterge
1	30	70	RSI
2	30	70	TN-RSI
3	35	65	RSI
4	35	65	TN-RSI
5	40	60	RSI
6	40	60	TN-RSI
7	45	55	RSI
8	45	55	TN-RSI
9	45	55	TN-RSI
	75	35	RSI
10	45	55	TN-RSI
	60	40	RSI

min edici veri olarak yeni bir sütunda eklenir. Son olarak, sınıflandırma yöntemi ile DOĞRU ve YANLIŞ önericiler eğitilip, çevrimiçi yatırım karar destek sistemi için hazırlanan model oluşturulur.

#### 4.2.1 AL/SAT önericileri

DeneySEL olarak, hazırlanan veri seti çeşitli RSI ve TN RSI öneri şemaları ile çalıştırılır. Bir hisse senedinin RSI ve TN RSI değerleri 0 ile 100 arasında değişmektedir. Hisse senedi aşırı alım noktasında ise değer 100'e yaklaşmakta, aşırı satım noktasında ise değer 0'a yaklaşmaktadır. Bir RSI ve TN RSI öneri şeması iki değer tarafından tanımlanır; Alt Sınır ve Üst Sınır. Sınır değerleri ve o günün fiyat değerleri dikkate alındığında, öneri şemasına 3 kural uygulanır;

- Eğer (Değer < Alt Sınır) → AL
- Eğer (Değer > Üst Sınır) → SAT
- Eğer (Alt Sınır < Değer < Üst Sınır) → TUT

Bir hisse senedinin fiyat vektörü  $F$  ve bu fiyat ile ilişkili RSI ve TNRSI değerleri  $Y$  öneri sistemine verildiğinde, her bir gün için önerilen kararı(AL/SAT/TUT) içeren  $T$  vektörü oluşturulur.

Bu çalışmada 8 farklı öneri şeması uygulanmıştır. Çizelge 4.2, Şema No 1-8 bu öneri şemalarını göstermektedir. Çizelge 4.2'de, Şema 1-8 arası sadece RSI ya da TN RSI önerici kullanılarak oluşturulmuştur. Bunun haricinde, birden fazla öneri şemasını birleştirerek yeni bir öneri şeması oluşturmak mümkündür. Birden fazla şemanın birleştirilmesinin amacı daha sağlam bir karar sistemi oluşturmak ve bir eşik değer koyarak gereksiz önerileri elemektir.

Çizelge 4.2’de Şema 9 ve 10, birden fazla öneri şemasının uygulanması ile oluşturulmuştur. Bu öneri şemaları, RSI ve TN RSI arasındaki uyumsuzluğu kullanarak oluşturulur. Örneğin, Şema 9’da TNRSI değeri 45’den küçük ise (Al önerisi kuralı) ve RSI değeri 75 den küçük ise (Sat önerisi değil kuralı) AL kararı oluşturulur. Benzer şekilde, SAT kararı, TNRSI değeri 55 den büyük ise (Sat önerisi kuralı) ve RSI değeri 35 den büyük ise (Al önerisi değil kuralı) alınır.

Öncelikle, BIST-100 indeksi içinden bir hisse senedi seçilerek(ADEL) yukarıda önerilen farklı öneri şemaları bu hisse senedine uygulanmıştır. Başlangıç sermayesi  $M = \$100$  seçildiğinde ve dinamik programlama ile optimal yatırım modeli uygulandığında oluşan maksimum getiri Çizelge 4.3’de gösterilmiştir. Bu tabloda, komisyon oranı  $C = \%0.1$  olarak alınmıştır. Bu örnek hisse senedi için çalıştırılan optimal yatırım modelinde tüm zaman(2546 gün) boyunca optimal kârı sağlayan 112 Al-Sat ikilisi seçilmiştir.

Çizelge 4.3’deki öneri şemalarının maksimum getirisi incelendiğinde, Şema 8’de maksimum getiri elde edildiği görülür. TNRSI 45-55 öneri şemasını kullanan Şema 8, en yüksek değeri verdiği için karar verici olarak seçilir. Bu şema, toplamda 2546 günden oluşan seride, 843 gün AL önerisi ile, 883 gün SAT önerisi ile işaretlenir. Kalan günler TUT olarak belirlenir. Çizelge 4.4’de görüldüğü gibi, Dinamik Programlama algoritması bu seriye uygulandıktan sonra, optimal yatırım modeli 112 günü AL ve 112 günü SAT olarak seçer. Bu şekilde, öneri şemasının AL olarak önerdiği 843 günden sadece 112 tanesi DOĞRU, kalan 731 gün YANLIŞ olarak işaretlenir. Benzer şekilde, 883 SAT önerisinden sadece 112 gün DOĞRU, kalan 771 SAT önerisi YANLIŞ olarak işaretlenir.

Burada bir noktaya dikkat edilir; Şema 8 ve 9 daki DOĞRU ve YANLIŞ Al/Sat sayıları incelendiğinde, DOĞRU ve YANLIŞ sayılarında dengesiz bir dağılım olduğu görülür (Örneğin Şema 8 için; 112 DOĞRU AL, 731 YANLIŞ AL). Bu dengesiz dağılım daha sonraki sınıflandırma aşamasında dengeli hale getirilir.

#### 4.2.2 Tahmin edici olarak finansal teknik göstergeler

Teknik analiz göstergeleri hisse senedi alım satım işlemlerinde sıklıkla danışılan ve yardım alınan araçlardır. 200’den fazla farklı teknik gösterge yatırımcılar ve borsacılar tarafından kullanılmaktadır. [Achelis , 2014] Bu göstergeler, fiyat ve/veya hacim verisinden türetilmektedir. Bu çalışmada, hisse senedinin/ticari enstrümanın fiyatı üzerinden hareket ettiğimiz için , sadece fiyattan türetilmiş teknik göstergeler dikkate alınır. Fiyattan türetilmiş teknik göstergelerin bir kısmı ölçekten bağımsız ve normalize edilmiş değildir. Bunun yanında, birçok gösterge normalize edilmiş değerleri taşımaktadır. Bu normalize edilmiş göstergeler, bu çalışmanın kapsamında odaklanılan göstergelerdir. Normalize edilmiş göstergelerin kullanılma nedeni, daha iyi bir sınıflandırma modeli elde edebilmek için, farklı hisse senetlerine ait veri setlerini tek bir büyük veri setinde toplamak istememizdir. Böylece farklı hisse senetlerinden alınan veriler ile sistem eğitilerek daha sağlam bir model oluşturulur.



**Çizelge 4.3:** Birincil önerici olarak RSI ve TN RSI kullanan farklı öneri şemaları için komisyon oranı %0.1 olarak Dinamik Programla elde edilen maksimum getiri.

Şema No	Alt Sınır	Üst Sınır	Finansal Gösterge	Maksimum Getiri
1	30	70	RSI	\$ 803,878
2	30	70	TN-RSI	\$ 82,318
3	35	65	RSI	\$1,964,247
4	35	65	TN-RSI	\$ 362,105
5	40	60	RSI	\$ 6,513,289
6	40	60	TN-RSI	\$ 5,149,689
7	45	55	RSI	\$ 13,697,158
<b>8</b>	<b>45</b>	<b>55</b>	<b>TN-RSI</b>	<b>\$ 29,548,052</b>
<b>9</b>	<b>45</b> <b>75</b>	<b>55</b> <b>35</b>	<b>TN-RSI</b> <b>RSI</b>	<b>\$ 27,726,186</b>
10	45 60	55 40	TN-RSI RSI	\$ 19,168,438

Bu çalışmada, fiyat ölçeğinden bağımsız, normalize edilmiş 7 finansal teknik göstergeye, bir sonraki aşamadaki sınıflandırma işlemi için tahmin edici öznelik olarak başvurulmuştur. Bu göstergeler RSI, TN RSI, PPO-14, ROC-14, BB PERC-20, SO-14 ve CCI-20'dır.

#### 4.2.3 Sınıflandırma

Sınıflandırma aşamasına gelindiğinde, Al ve Sat matrisi tahmin edici teknik göstergelerle ve tahmin edilmek istenen ikili (DOĞRU/YANLIŞ) sınıf etiketi ile elde hazır bulunur.

Öncelikle, DOĞRU va YANLIŞ sınıf arasındaki dengesiz sayı dağılımını gidermek için (Örneğin, ADEL hisse senedi AL için, 112 DOĞRU/ 731 YANLIŞ, Çizelge 4.4), iki sınıftan da sayıca az olan eleman sayısı kadar eleman alınır. DOĞRU etiketli sınıftan tüm elemanları alınırken, YANLIŞ etiketli sınıftan rastgele örnekleme ile eşit sayıda eleman seçilir. Aynı işlem SAT matrisi içinde uygulanır. Sonuç olarak, AL ve SAT matrisi tam olarak yarısı DOĞRU, yarısı YANLIŞ olarak etiketli elemandan oluşur hale gelir. Adel hisse senedine Şema 8 öneri şeması uygulandığında, 112 DOĞRU, 112 YANLIŞ etiketli 224 elemanlı Al ve Sat matrisleri elde edilir. (Çizelge 4.5)

Bu çalışmada, sadece fiyat ölçeğinden bağımsız teknik göstergeler kullanıldığı için, farklı hisse senetlerinin veri setlerini birleştirip daha sağlam bir model oluşturabiliriz. İlk olarak, her bir hisse senedi için ayrı ayrı, yukarıda açıkladığımız aşamalar ile DA AL ve DS SAT matrisleri hesaplanır. Daha sonra, bu DA AL matrisleri büyük bir AL matrisi oluşacak şekilde birleştirilir. Aynı şekilde SAT matrisleri de büyük bir SAT matrisi oluşacak şekilde birleştirilir.

**Çizelge 4.4:** Örnek Adel hisse senedi için DOĞRU ve YANLIŞ öneriler eşitlenmeden önce

	DOĞRU	YANLIŞ	
AL	112	731	843
SAT	112	771	883
TUT			820
TOPLAM	224	1502	2546

**Çizelge 4.5:** Örnek Adel hisse senedi için DOĞRU ve YANLIŞ öneriler eşitlendikten sonra

	DOĞRU	YANLIŞ	
AL	112	112	843
SAT	112	112	883
TUT			820
TOPLAM	224	224	2546

Örnek bir *DA* AL Matrisi Şekil 4.1'de görülebilir. Şekil 4.1'de, T ile etiketli satırlar, DOĞRU(TRUE) AL önericilerini gösterirken, F ile etiketli satırlar, YANLIŞ(FALSE) AL önericilerini temsil etmektedir. *DS* SAT Matrisi de benzer görünüme sahiptir.

BIST-100 veri setindeki 10 hisse senedi ve index matrisleri (AL veri seti için *DA* ve Sat veri seti için *DS* matrisleri) iki ayrı matris olarak birleştirildiğinde yaklaşık 2000 elemandan oluşan büyük AL ve SAT matrisi oluşturulur. Gerçek veri seti boyutları Çizelge 4.6'den incelenebilir.

Benzer şekilde, aynı çalışma DOW-30 veri setine de uygulanır. Dow-30 matrisi birleştirildiğinde yaklaşık 12000 veriye sahip büyük bir AL ve SAT matrisleri oluşturulur. Gerçek veri seti boyutları Çizelge 4.7'den incelenebilir.

Çalışmamızın son deneyinde ardışık son iki günün vektörünün birleşiminden tek bir vektör oluşturulması amaçlanmıştır.

Ardışık son iki günün teknik göstergelerini birleştirerek yeni bir vektör oluşturulur. Bu  $I_2$  vektörü  $I = \langle I_1, I_2, \dots, I_k \rangle$ , seçilen  $k$  farklı teknik analiz gösterge vektörünün bir önceki günün teknik göstergeleri eklenmesi ile oluşturulur. Yeni oluşan vektör, ardışık son iki günün teknik göstergelerini içeren  $I_2 = \langle I_1, I_2, \dots, I_{2k} \rangle$  vektörü  $2k$  boyutunda olmaktadır.

$I_2$  vektörü kullanılarak *DA* ve *DS* matrisleri aynı şekilde oluşturulur. Elde edilen sonuçlara Çizelge 4.8'de ulaşılabilir. Oluşan matrisler model oluşturmak üzere ikili sınıflandırma algoritması ile doğrulama ve test yapılmıştır.

Bu çalışmada, ikili sınıflandırma algoritması olarak istatistiksel öğrenme teorisine dayanan, en güçlü tahmin yöntemlerinden biri olan SVM tercih edilir. Veri seti %80 doğrulama ve %20 test grubu olarak ikiye ayrılır. %80 Doğrulama verisi ile model öğrenilir, %20 test verisi ile model başarısı ölçülür. Modelde 10 katlı çapraz doğrulama

RSI	TN RSI	PPO-14	ROC-14	BB PERC-20	SO-14	CCI-20	T / F
13.17	17.46	-5.2	-12.85	0.19	-3.23	-106.87	F
13.5	26.56	-5.16	-12.48	0.14	0	-119.69	F
22.44	38.45	-5	-8.03	0.22	9.71	-88.19	F
22.44	40.03	-4.92	-8.12	0.19	-2.91	-95.72	T
70.97	42.77	1.89	12.14	0.88	73.69	127.32	F
68.81	39.7	2.02	10.61	0.82	70.85	105.85	F
62.57	36.82	1.95	8.13	0.62	50	38	T
71.31	34.04	3.15	8.05	0.63	68.09	38.12	T
51.5	35.28	1.83	0.46	0.57	34.4	23.18	F
38.5	25.68	1.58	-3.19	0.42	5.5	-28.56	F
38.61	33.35	1.05	-3.18	0.22	-2	-95.26	T
23.21	37.06	-0.67	-9.23	-0.1	-13.02	-255.09	T
59.1	29.5	0.32	1.87	0.71	54.67	77.89	T
63.59	35.54	0.42	3.14	0.84	84.11	130.73	F
70.99	37.36	0.96	4.09	0.73	87.55	71.14	F
25.52	28.38	0.47	-3.54	0.11	-8.57	-154.71	F
21.43	43.15	-1.36	-5.76	-0.09	-24.9	-243.37	T
42.79	24.74	-0.79	-2.01	0.05	-24.58	-152.78	T
35.06	28.58	-1	-3.22	-0.31	-143.14	-415.14	T
33.83	33.16	3.72	-6.24	0.25	-8.16	-93.7	T

**Şekil 4.1:** AL veri seti (DA Matrisi). 7 tahmin edici öznitelik ve 1 tahmin edilen etiket (T/F) ile gösterimi

kullanılır. Bu şekilde, varyansı azaltmak için doğrulama veri seti her seferinde farklı gruplara ayrılarak tekrar eğitilir. Tüm SVM fonksiyonları (Doğrusal, İkinci dereceden, Üçüncü dereceden, Gaussyan) ile veri seti modellenir ve farklı SVM fonksiyonları ile sonuçlar alınır. Tüm SVM fonksiyonları arasında Gaussyan SVM en iyi doğrulama doğruluk oranını verir.

### 4.3 Deney Sonuçları

BIST-100 Eğitim ve Test veri seti için doğruluk sonuçları Çizelge 4.6’te gösterilmektedir. DOW-30 Eğitim ve Test veri seti için doğruluk sonuçları ise Çizelge 4.7’te gösterilmektedir. Çizelge 4.6 ve Çizelge 4.7’teki %70 ve üzeri doğruluk sonuçları, DOĞRU ve YANLIŞ önericilerin ayırt edilmesinde ikili sınıflandırma modeli ile yakalanabilen belirgin bir örüntünün olduğunu göstermektedir. Aynı zamanda doğruluk sonuçları, bu sınıflandırmanın zor bir ikili sınıflandırma problemi olduğunu göstermektedir.

DOW-30 veri setine ardışık iki günün teknik öznitelikleri vektör olarak alınarak model eğitildiğinde elde edilen doğruluk oranları Çizelge 4.8’de paylaşılmıştır.

**Çizelge 4.6:** BIST-100 Veri Seti için SVM Modeli Doğrulama ve Test Doğruluk Oranları(Komisyon Oranı = %0.1)

Veri Boyutu	SVM Modeli Doğrulama Oranı			
	Şema No	Al/Sat	Doğrulama(% 80)	Test(% 20)
2178	Şema 8	Al	68.40%	68.35%
2162		Sat	69.70%	69.83%
2064	Şema 9	Al	68.30%	68.68%
2052		Sat	68.50%	67.56%

**Çizelge 4.7:** DOW-30 Veri Seti için SVM Modeli Doğrulama ve Test Doğruluk Oranları

Veri seti Boyutu	Şema No	Komisyon Oranı(%C)	Al		Sat	
			Doğrulama	Test	Doğrulama	Test
13282	Şema 8	0	70.1%	71.3%	71.0%	71.6%
12968		0.1	71.3%	70.9%	71.5%	71.8%
12696		0.2	70.9%	70.9%	70.7%	70.2%
12767	Şema 9	0	69.4%	70.9%	69.9%	68.1%
12530		0.1	69.3%	71.3%	69.5%	68.9%
12324		0.2	69.9%	71.6%	70.1%	69.5%

**Çizelge 4.8:** DOW-30 Veri Seti için Ardışık son iki günün teknik analiz göstergeleri birlikte bir vektör olarak alındığında oluşan SVM Modeli Doğrulama ve Test Doğruluk Oranları

Veri seti Boyutu	Şema No	Komisyon Oranı(%C)	Al		Sat	
			Doğrulama	Test	Doğrulama	Test
13282	Şema 8	0	72.7%	73.8%	72.2%	72.5%
12968		0.1	73.8%	74.5%	72.7%	72.3%
12696		0.2	73.8%	74.0%	71.9%	71.9%
12767	Şema 9	0	71.8%	73.7%	70.4%	69.9%
12530		0.1	71.6%	72.9%	70.6%	70.7%
12324		0.2	72.1%	73.4%	71.4%	69.8%

Çizelge 4.9'den itibaren, Dinamik Programlamanın ideal durumda oluşturacağı getiri, herhangi bir optimizasyon uygulamadan ilk önerilenin uygulandığı model ve bu çalışmanın sonunda elde edilen optimal modelin uygulanması ile oluşan gerçek getiri karşılaştırılmıştır. Başlangıç sermayesi \$100 olarak alınmıştır. Şema 8 ve 9, farklı komisyon oranları ile (C = %0, %0.1 ya da %0.2) modellenip, sonuçları Çizelge 4.9'den itibaren paylaşılmıştır. (Çizelge 4.9 - 4.14)

Çizelge 4.9'deki DOW30 hisse senetlerinden 100\$ yatırım sonrası bazı hisse senetleri daha yüksek kârlılık göstermiştir. En yüksek kârlılık gösteren AXP, NKE ve UNH hisse senetleri için önerilen model uygulanarak ve sadece birincil modelin ilk önerilenin uygulanarak iki farklı simülasyon gerçekleştirilmiş, bu simülasyonun kârlılık grafiği AXP için Şekil 4.3, NKE için Şekil4.4, UNH için Şekil4.5'de paylaşılmıştır. Fiyat değişiminin de etkisini gözlemlemek için hisse senetlerinin kapanış fiyatları aynı grafiğe eklenmiştir. %0.1 ve %0.2 komisyon oranı ile olan sonuçlar EK3'de paylaşılmıştır. (Şekil EK3.1 - EK3.6)

**Çizelge 4.9:** Şema 8 Komisyon Oranı = %0

<b>Hisse Senedi</b>	<b>DP İdeal</b>	<b>Temel Model</b>	<b>Önerilen Model</b>	<b>Fark</b>
AAPL	$1.22 \times 10^{12}$	1476	1645	169
ALTIN	$4.76 \times 10^7$	924	960	36
AMGN	$1.50 \times 10^9$	470	269	-201
<b>AXP</b>	$7.25 \times 10^9$	284	1363	1078
BA	$7.13 \times 10^9$	74	124	50
CAT	$3.72 \times 10^{10}$	181	306	125
CSCO	$1.15 \times 10^{10}$	73	804	731
CVX	$7.21 \times 10^7$	54	237	183
DIS	$1.06 \times 10^9$	348	408	60
DOLAR	$3.02 \times 10^6$	329	181	-148
EURO	$4.59 \times 10^6$	748	356	-392
GS	$2.37 \times 10^{10}$	311	314	4
HD	$1.79 \times 10^9$	314	731	417
HON	$7.68 \times 10^8$	154	351	197
IBM	$5.08 \times 10^7$	96	104	8
INTC	$8.01 \times 10^9$	98	245	148
JNC	$4.32 \times 10^6$	187	272	85
JPM	$2.87 \times 10^{10}$	234	820	586
KO	$4.12 \times 10^6$	84	194	110
MCD	$4.59 \times 10^7$	220	495	275
MMM	$3.29 \times 10^7$	174	398	224
MRK	$1.03 \times 10^8$	135	208	73
MSFT	$1.01 \times 10^9$	793	575	-218
<b>NKE</b>	$2.87 \times 10^9$	901	3330	2429
PG	$5.59 \times 10^6$	450	487	37
TRV	$1.78 \times 10^8$	152	164	13
<b>UNH</b>	$6.97 \times 10^9$	403	1360	956
VZ	$2.77 \times 10^7$	128	120	-8
WBA	$5.48 \times 10^8$	190	259	69
WMT	$2.32 \times 10^7$	284	448	165
<b>Toplam</b>	$1.36 \times 10^{12}$	\$10268	\$17527	<b>\$7259</b>

Çizelge 4.10: Şema 8 Komisyon Oranı = %0.1

Hisse Senedi	DP Ideal	Temel Model	Önerilen Model	Fark
AAPL	$8.20 \times 10^{11}$	935	253	-682
ALTIN	$3.04 \times 10^7$	565	393	-172
AMGN	$9.67 \times 10^8$	293	199	-93
AXP	$4.64 \times 10^9$	176	387	211
BA	$4.56 \times 10^9$	47	62	16
CAT	$2.41 \times 10^{10}$	113	295	182
CSCO	$7.54 \times 10^9$	47	168	121
CVX	$4.76 \times 10^7$	35	154	119
DIS	$6.76 \times 10^8$	218	201	-18
DOLAR	$1.95 \times 10^6$	202	92	-110
EURO	$2.89 \times 10^6$	451	159	-292
GS	$1.50 \times 10^{10}$	191	102	-89
HD	$1.15 \times 10^9$	196	401	205
HON	$4.99 \times 10^8$	97	240	143
IBM	$3.35 \times 10^7$	61	111	50
INTC	$5.21 \times 10^9$	62	79	17
JNC	$2.78 \times 10^6$	116	207	91
<b>JPM</b>	$1.85 \times 10^{10}$	145	623	478
KO	$2.71 \times 10^6$	53	171	118
MCD	$2.95 \times 10^7$	137	346	209
MMM	$2.16 \times 10^7$	108	358	250
MRK	$6.64 \times 10^7$	83	110	27
MSFT	$6.38 \times 10^8$	474	320	-154
<b>NKE</b>	$1.81 \times 10^9$	550	1337	787
PG	$3.57 \times 10^6$	275	276	1
TRV	$1.13 \times 10^8$	93	178	85
<b>UNH</b>	$4.51 \times 10^9$	253	1264	1011
VZ	$1.81 \times 10^7$	81	123	42
WBA	$3.50 \times 10^8$	117	270	153
WMT	$1.49 \times 10^7$	176	463	287
<b>Toplam</b>	$9.10 \times 10^{11}$	\$6348	\$9340	<b>\$2992</b>

**Çizelge 4.11:** Şema 8 Komisyon Oranı = %0.2

<b>Hisse Senedi</b>	<b>DP Ideal</b>	<b>Temel Model</b>	<b>Önerilen Model</b>	<b>Fark</b>
AAPL	$5.55 \times 10^{11}$	592	924	332
ALTIN	$1.97 \times 10^7$	345	490	145
AMGN	$6.26 \times 10^8$	182	157	-26
AXP	$2.99 \times 10^9$	109	758	649
BA	$2.94 \times 10^9$	29	46	17
CAT	$1.57 \times 10^{10}$	70	303	233
CSCO	$5.01 \times 10^9$	30	424	395
CVX	$3.16 \times 10^7$	23	112	89
DIS	$4.35 \times 10^8$	137	262	125
DOLAR	$1.28 \times 10^6$	124	139	15
EURO	$1.86 \times 10^6$	272	325	53
GS	$9.57 \times 10^9$	118	126	8
HD	$7.47 \times 10^8$	122	311	189
HON	$3.28 \times 10^8$	61	267	206
IBM	$2.22 \times 10^7$	38	85	47
INTC	$3.40 \times 10^9$	39	110	71
JNC	$1.81 \times 10^6$	72	171	99
JPM	$1.20 \times 10^{10}$	90	436	346
KO	$1.79 \times 10^6$	33	135	101
MCD	$1.92 \times 10^7$	86	322	237
MMM	$1.43 \times 10^7$	67	270	202
MRK	$4.32 \times 10^7$	51	81	30
MSFT	$4.11 \times 10^8$	283	415	132
NKE	$1.15 \times 10^9$	335	1592	1257
PG	$2.32 \times 10^6$	168	269	101
TRV	$7.29 \times 10^7$	57	80	23
UNH	$2.95 \times 10^9$	159	1226	1067
VZ	$1.20 \times 10^7$	51	73	22
WBA	$2.24 \times 10^8$	72	192	120
WMT	$9.67 \times 10^6$	109	261	152
<b>Toplam</b>	$6.14 \times 10^{11}$	\$3924	\$10360	<b>\$6436</b>

Çizelge 4.12: Şema 9 Komisyon Oranı = %0

Hisse Senedi	DP Ideal	Temel Model	Önerilen Model	Fark
AAPL	$9.15 \times 10^{11}$	664	333	-331
ALTIN	$4.43 \times 10^7$	730	506	-224
AMGN	$1.23 \times 10^9$	262	202	-60
AXP	$5.40 \times 10^9$	257	556	300
BA	$5.71 \times 10^9$	156	121	-35
CAT	$2.83 \times 10^{10}$	175	231	56
CSCO	$8.88 \times 10^9$	71	297	226
CVX	$6.67 \times 10^7$	66	213	147
DIS	$9.32 \times 10^8$	353	254	-99
DOLAR	$2.72 \times 10^6$	329	159	-170
EURO	$3.68 \times 10^6$	519	185	-334
GS	$1.87 \times 10^{10}$	295	142	-153
HD	$1.59 \times 10^9$	414	434	21
HON	$5.92 \times 10^8$	80	288	209
IBM	$4.35 \times 10^7$	43	147	104
INTC	$5.90 \times 10^9$	76	103	27
JNC	$3.95 \times 10^6$	229	228	-1
<b>JPM</b>	$2.24 \times 10^{10}$	250	929	679
KO	$3.64 \times 10^6$	85	216	131
MCD	$3.68 \times 10^7$	258	464	206
MMM	$2.96 \times 10^7$	218	390	172
MRK	$8.94 \times 10^7$	188	120	-68
MSFT	$8.61 \times 10^8$	1015	402	-613
<b>NKE</b>	$2.61 \times 10^9$	893	1640	747
PG	$5.21 \times 10^6$	441	319	-122
TRV	$1.56 \times 10^8$	239	237	-2
<b>UNH</b>	$6.37 \times 10^9$	624	1598	974
VZ	$2.50 \times 10^7$	137	166	29
WBA	$4.77 \times 10^8$	312	364	52
WMT	$2.16 \times 10^7$	356	686	329
<b>Toplam</b>	$1.03 \times 10^{12}$	\$9735	\$11932	<b>\$2197</b>



**Çizelge 4.13:** Şema 9 Komisyon Oranı = %0.1

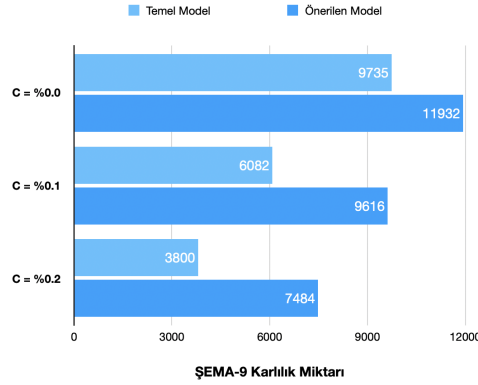
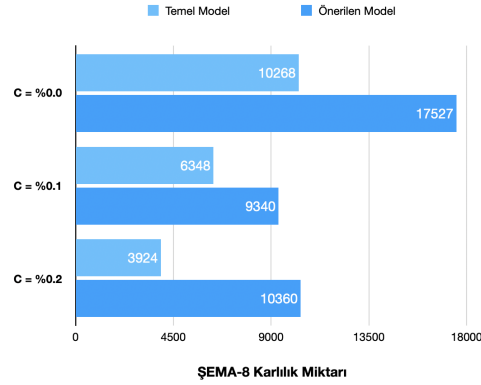
<b>Hisse Senedi</b>	<b>DP Ideal</b>	<b>Temel Model</b>	<b>Önerilen Model</b>	<b>Fark</b>
AAPL	$6.31 \times 10^{11}$	433	224	-209
ALTIN	$2.89 \times 10^7$	453	444	-9
AMGN	$8.12 \times 10^8$	167	182	15
AXP	$3.52 \times 10^9$	161	272	112
BA	$3.71 \times 10^9$	99	105	6
CAT	$1.87 \times 10^{10}$	110	232	122
CSCO	$5.99 \times 10^9$	45	282	237
CVX	$4.47 \times 10^7$	43	184	142
DIS	$6.04 \times 10^8$	224	195	-29
DOLAR	$1.78 \times 10^6$	206	143	-63
EURO	$2.38 \times 10^6$	320	173	-147
GS	$1.21 \times 10^{10}$	183	136	-46
HD	$1.03 \times 10^9$	260	385	125
HON	$3.93 \times 10^8$	51	239	188
IBM	$2.90 \times 10^7$	27	127	99
INTC	$3.90 \times 10^9$	48	93	45
JNC	$2.58 \times 10^6$	143	194	50
<b>JPM</b>	$1.47 \times 10^{10}$	158	708	550
KO	$2.42 \times 10^6$	54	158	105
MCD	$2.41 \times 10^7$	162	362	200
MMM	$1.97 \times 10^7$	138	347	210
MRK	$5.83 \times 10^7$	116	97	-19
MSFT	$5.55 \times 10^8$	616	244	-372
<b>NKE</b>	$1.68 \times 10^9$	550	1218	667
PG	$3.37 \times 10^6$	271	260	-11
TRV	$1.01 \times 10^8$	149	206	57
<b>UNH</b>	$4.17 \times 10^9$	392	1488	1095
VZ	$1.66 \times 10^7$	87	145	58
WBA	$3.07 \times 10^8$	194	255	61
WMT	$1.39 \times 10^7$	222	516	294
<b>Toplam</b>	$7.03 \times 10^{11}$	\$6082	\$9616	<b>\$3533</b>

Çizelge 4.14: Şema 9 Komisyon Oranı = %0.2


Hisse Senedi	DP İdeal	Temel Model	Önerilen Model	Fark
AAPL	$4.36 \times 10^{11}$	283	205	-78
ALTIN	$1.90 \times 10^7$	280	399	118
AMGN	$5.35 \times 10^8$	106	144	37
AXP	$2.31 \times 10^9$	101	323	222
BA	$2.42 \times 10^9$	62	75	12
CAT	$1.24 \times 10^{10}$	69	147	78
CSCO	$4.07 \times 10^9$	29	122	93
CVX	$3.00 \times 10^7$	28	112	84
DIS	$3.94 \times 10^8$	142	197	55
DOLAR	$1.20 \times 10^6$	129	91	-38
EURO	$1.57 \times 10^6$	198	130	-67
GS	$7.87 \times 10^9$	113	74	-39
HD	$6.81 \times 10^8$	163	317	154
HON	$2.63 \times 10^8$	32	209	177
IBM	$1.94 \times 10^7$	17	91	74
INTC	$2.58 \times 10^9$	31	81	50
JNC	$1.72 \times 10^6$	90	167	77
<b>JPM</b>	$9.78 \times 10^9$	99	480	381
KO	$1.62 \times 10^6$	34	158	124
MCD	$1.59 \times 10^7$	102	282	180
MMM	$1.32 \times 10^7$	87	289	202
MRK	$3.83 \times 10^7$	71	82	10
MSFT	$3.62 \times 10^8$	373	253	-120
<b>NKE</b>	$1.08 \times 10^9$	339	1204	865
PG	$2.21 \times 10^6$	167	242	75
TRV	$6.61 \times 10^7$	93	141	48
<b>UNH</b>	$2.77 \times 10^9$	247	777	530
VZ	$1.12 \times 10^7$	55	103	48
WBA	$1.98 \times 10^8$	120	232	112
WMT	$9.06 \times 10^6$	139	358	219
<b>Toplam</b>	$4.84 \times 10^{11}$	\$3800	\$7484	<b>\$3684</b>

**Çizelge 4.15:** DOW-30 veri setinde 30 hisse senedi için her bir hisse senedine \$100 yatırım ile Temel Model ve Önerilen modelden alınan kâr karşılaştırması


Şema No	Komisyon Oranı(%)	Temel Model(\$)	Önerilen Model(\$)	Fark(\$)
Şema 8	C=0	10268	17527	7259
	C=0.1	6348	9340	2992
	C=0.2	3924	10360	6436
Şema 9	C=0	9735	11932	2197
	C=0.1	6082	9616	3533
	C=0.2	3800	7484	3684




**Şekil 4.2:** Şema 8 ve Şema 9 için \$100 yatırım ile gerçekleşen kârın grafik üzerinde karşılaştırılması.



**Şekil 4.3:** Temel model ve Önerilen modelin AXP hisse senedinde komisyon oranı=%0 için oluşturduğu yatırım kazancının karşılaştırması ve AXP kapanış fiyatı ile birlikte değerlendirilmesi.



**Şekil 4.4:** Temel model ve Önerilen modelin NKE hisse senedinde komisyon oranı=%0 için oluşturduğu yatırım kazancının karşılaştırması ve NKE kapanış fiyatı ile birlikte değerlendirilmesi.



**Şekil 4.5:** Temel model ve Önerilen modelin UNH hisse senedinde komisyon oranı=%0 için oluşturduğu yatırım kazancının karşılaştırması ve UNH kapanış fiyatı ile birlikte değerlendirilmesi.



## 5. SONUÇ VE ÖNERİLER

Bu çalışmada, çevrimiçi olarak danışılmak üzere SVM tabanlı finansal karar destek sistemi sunulmaktadır. Bu karar destek sistemini oluşturmak için, öncelikle finansal teknik göstergelere bağlı öneri şemaları oluşturulur. Bu öneri şemaları yatırımcıya AL-SAT önerileri oluşturur. Bu AL-SAT önerilerinin DOĞRU ve YANLIŞ olması, dinamik programlama formülasyonu ile belirlenir. Dinamik Programlama yaklaşımı, bir ticari enstrümanın optimal kâr sağlayacak şekilde yatırım yapmasını sağlayan optimal yatırım örüntüsünü çıkarır. Bunun sonucunda, Dinamik Programlamadan elde edilen optimal yatırım örüntüsündeki veriler DOĞRU önerici olarak kabul edilirken, optimal yatırım örüntüsü dışında kalan veriler YANLIŞ önerici olarak kabul edilir.

Lineer zamanlı Dinamik Programlama formülasyonu, hisse senedi fiyat verisi ve seçilen öneri şemasına bağlı AL/SAT önerileri altında optimal yatırım örüntüsünü bulabilmektedir. Çeşitli öneri şemalarını (Şema 1-10) uygulayarak, en kârlı olan iki şema (Şema 8 ve 9) tercih edilmiştir.

DOĞRU ve YANLIŞ Al/Sat önerileri, sınıflandırma aşamasında tahmin edici öznelik olarak kullanılan finansal teknik göstergeler ile güçlendirilir. Bu finansal göstergeler özellikle normalize edilmiş ve fiyat ölçeğinden bağımsız göstergelerden tercih edilmiştir. Bunun nedeni, daha iyi bir sınıflandırma modeli için ayrı ayrı her bir hisse senedi verilerinden daha büyük veri setleri oluşturulmak istenmesidir.

Bu çalışma, iki farklı veri setinde uygulanmış ve %70'in üzerinde başarımlı sonuçları alınmıştır. İlkinde, BIST-100'deki 10 hisse senedinin 10 yıllık zaman serisi kullanılarak %70'e varan doğruluk oranı elde edilmiştir.(Çizelge 4.6) Diğer veri setinde, DOW-30'daki 27 hisse senedi, Altın, Dolar ve Euro döviz çiftleri, toplamda 30 ticari enstrümanın 20 yıllık zaman serisi kullanılarak %70'in üzerinde doğruluk oranı elde edilmiştir. (Çizelge 4.7)

Bunun dışında, Dow-30 veri seti üzerinde her bir hisse senedinin başlangıç sermayesi \$100 ile başlayarak, ilk olarak, dinamik programlama ile optimal yatırım modeli kullanılarak 20 yıl boyunca elde edilebilecek maksimum getiri hesaplanmıştır. Daha sonra, önerilen model olmadan, sadece birincil öneri şemasının ilk önerileri seçilerek 20 yıllık yatırım yapıldığında (AL, SAT) elde edilen getiri hesaplanmıştır. Son olarak, önerilen model kullanılarak, 20 yıllık yatırım işlemiyle (AL, SAT) elde edilen getiri hesaplanmıştır. Bu üç farklı işlem DOW-30'daki her bir hisse senedi için ayrı ayrı uygulanmıştır. (Çizelge 4.9 - 4.14)

Son olarak, tek günün teknik göstergelerini öznelik olarak kullanmanın yanı sıra, bir önceki günün teknik göstergelerinde öznelik uzayına dahil ederek (Çizelge 3.7) daha geniş bir öznelik uzayı oluşturulmuştur. Bunun sonuçları da Çizelge 4.8 paylaşılmıştır. Tek günün sonuçlarına göre daha iyi bir sonuç elde edilmiştir. Bu deneyde ardışık günlerin özneliklerinin birlikte sistemin öğrenmesinde anlamlı bir bilgi taşıdığı göz-



lemlemiştir.

Özetle ifade etmek gerekirse,

- Önerilen model ve sadece birincil öneri şemasını kullanan model arasındaki fark, her bir hisse senedi için gösterilmiştir (Çizelge 4.9.)  
Bu farklar bazı hisse senetlerinde pozitif, bazı hisse senetlerinde negatif olsa da, hisse senetlerinin toplam kârının önerilen model tercih edildiğinde belirgin bir farkla yüksek olduğu gözlemlenmiştir.
- Önerilen modelin, farklı komisyon oranları (%0, %0.1, %0.2) alındığında ve iki öneri şemasında (Şema 8 - 9) da temel modelden belirgin bir şekilde daha kârlı olduğu gözlemlenmiştir. Çizelge 4.2’te kârlılık sonuçları gösterilmiştir. DOW-30’daki 3 farklı hisse senedinin (AXP, NKE, UNH) karşılaştırmalı sonuçları komisyon oranı %0 için Şekil 4.3, 4.4 ve 4.5’de gösterilmiştir. Bunların devamı olan, Komisyon oranı %0.1 ve %0.2 grafikleri Şekil EK3.1, EK3.2, EK3.3, EK3.4, EK3.5 ve EK3.6 eklerde paylaşılmıştır.
- Dinamik programlama modelinin verdiği getirilerin, ideal durumu temsil ettiğinden dolayı çok yüksek getirilere sahip olduğu görülmüştür. Örneğin AAPL Apple hisse senedi için 20 yıllık optimal yatırım örüntüsü (DP) uygulandığında (Şema 8 C=%0 için)  $\$1.22 \times 10^{12}$  getiri elde edilirken, önerilen model ile  $\$1645$  getiri elde edilir. Bu farkın yüksek olması modelin daha geliştirilebileceğini göstermektedir.
- Bu uygulamalar sonucunda, Dinamik programlama modelinin ürettiği optimal yatırım örüntüsünün anlamlı sonuçlar getirdiği sonucuna varılmıştır.
- Bir önceki günün teknik gösterge özniteliklerinin birleştirilmesi ile son iki günün özniteliklerinin tahmin edici olarak kullanılmasının sistemin başarımının arttırdığı gözlemlenmiştir. (Çizelge 4.8)
- Veri setinin daha büyük boyutta olmasının doğruluk oranını pozitif olarak etkilediği görülmüştür. Elde edilen sonuçlar, ileriki çalışmalarda, daha büyük ölçekte finansal veri kullanılması (BIST-100’deki tüm hisse senetleri, farklı ülkelerin indeksleri), daha farklı öneri şemaları uygulanması fikrini ortaya koymuştur.

## KAYNAKLAR

- Abu-Mostafa, Y. and Atiya, Amir F. (1996)** Introduction to financial forecasting. In *Applied Intelligence*, 72, Nr. 6, 205–213
- Abul, Osman and Tufekci, Zeynep (2020)** Veri seti. 2020 (URL: <https://github.com/z-tufekci/DeepLearning/DOW30/&/Bist100>)
- Achelis, Steven B. (2014)** Technical analysis from A to Z: covers every trading tool ... from the absolute breadth index to the zig zag. McGraw-Hill Education
- Arik, Oğuzhan (2018)** Dynamic Programming Approach to Selling and Buying of Stocks in XU030 Index of BIST by Forecasting Stock Prices for Next Five Years.
- Barak, Sasan, Arjmand, Azadeh and Ortobelli, Sergio (2017)** Fusion of multiple diverse predictors in stock market. In *Information Fusion*, 36, 90–102
- Bollinger, John (1980s)** BOLLINGER BANDS. 1980s (URL: <https://www.bollingerbands.com/bollinger-band-rules>)
- Boser, Bernhard E., Guyon, Isabelle M. and Vapnik, Vladimir N. (1992)** A Training Algorithm for Optimal Margin Classifiers. In *Proceedings of the Fifth Annual Workshop on Computational Learning Theory*. New York, NY, USA: Association for Computing Machinery, COLT '92, 144–152
- Box, George Edward Pelham and Jenkins, Gwilym (1990)** Time Series Analysis, Forecasting and Control. USA: Holden-Day, Inc.
- Burges, Christopher (1998)** A Tutorial on Support Vector Machines for Pattern Recognition. No address in
- Cavalcante, Rodolfo C. et al. (2016)** Computational Intelligence and Financial Markets: A Survey and Future Directions. In *Expert Systems with Applications*, 55, 194–211
- Chang, Pei-Chann et al. (2009)** A neural network with a case based dynamic window for stock trading prediction. In *Expert Systems with Applications*, 36, Nr. 3, Part 2, 6889–6898

- Chen, Wei et al. (2021)** Machine learning model for Bitcoin exchange rate prediction using economic and technology determinants. In *International Journal of Forecasting*, 37, Nr. 1, 28–43
- Cheung, Wee and Kaymak, Uzay (2007)** A fuzzy logic based trading system. In *Personality and Individual Differences - PERS INDIV DIFFER*
- Choudhry, Rohit and Garg, Kumkum (2008)** A Hybrid Machine Learning System for Stock Market Forecasting. In *World Academy of Science, Engineering and Technology* 39
- Cover, T.M. and Ordentlich, E. (1996)** Universal portfolios with side information. In *IEEE Transactions on Information Theory*, 42, Nr. 2, 348–363
- Cristianini, Nello and Shawe-Taylor, John (2000)** An Introduction to Support Vector Machines and Other Kernel-based Learning Methods: Pattern recognition and machine learning. No address in
- Di Persio, Luca and Honchar, Oleksandr (2016)** Artificial neural networks architectures for stock price prediction: Comparisons and applications. In *International journal of circuits, systems and signal processing*, 10, Nr. 2016, 403–413
- Ding, Qianggang et al. (2020)** Hierarchical Multi-Scale Gaussian Transformer for Stock Movement Prediction. In **Bessiere, Christian, editor: Proceedings of the Twenty-Ninth International Joint Conference on Artificial Intelligence, IJCAI-20**. International Joint Conferences on Artificial Intelligence Organization, 4640–4646
- Evgeniou, Theodoros, Pontil, Massimiliano and Poggio, Tomaso (1999)** Regularization Networks and Support Vector Machines. No address in
- Goumatianos, Nikitas, Christou, Ioannis T and Lindgren, Peter (2013)** Useful pattern mining on time series: Applications in the stock market. In *Proceedings of the 2nd International Conference on Pattern Recognition Applications and Methods (ICPRAM 2013)*. International Conference on Pattern Recognition Applications and Methods, 608–612
- Greaves, Alex and Au, Benjamin (2015)** Using the bitcoin transaction graph to predict the price of bitcoin.
- Gunduz, Hakan, Yaslan, Yusuf and Cataltepe, Zehra (2017)** Intraday prediction of Borsa Istanbul using convolutional neural networks and feature correlations. In *Knowledge-Based Systems*, 137, 138–148
- Guo, Tian and Antulov-Fantulin, Nino (2018)** Predicting short-term Bitcoin price fluctuations from buy and sell orders.
- Guo, Zhiqiang, Huaiqing, Wang and Quan, Liu (2012)** Financial time series forecasting using LPP and SVM optimized by PSO. In *Soft Computing* 17

- Hegazy, Osman, Soliman, Omar S. and Abdul Salam, Mustafa (2013)** A Machine Learning Model for Stock Market Prediction. In *International Journal of Computer Science and Telecommunications*, 4, 17–23
- Henrique, Bruno Miranda, Sobreiro, Vinicius Amorim and Kimura, Herbert (2019)** Literature review: Machine learning techniques applied to financial market prediction. In *Expert Systems with Applications*, 124, 226–251
- Hoseinzade, Ehsan and Haratizadeh, Saman (2019)** CNNpred: CNN-based stock market prediction using a diverse set of variables. In *Expert Systems with Applications*, 129, 273–285
- Kim, Kyoung-Jae (2003)** Financial time series forecasting using support vector machines. In *Neurocomputing*, 55, Nr. 1, 307 – 319, Support Vector Machines
- Kwon, Yung-Keun and Moon, Byung-Ro (2007)** A Hybrid Neurogenetic Approach for Stock Forecasting. In *IEEE Transactions on Neural Networks*, 18, Nr. 3, 851–864
- Lin, Y., Guo, H. and Hu, J. (2013)** An SVM-based approach for stock market trend prediction. In *The 2013 International Joint Conference on Neural Networks (IJCNN)*., 1–7
- Madan, Isaac (2014)** Automated Bitcoin Trading via Machine Learning Algorithms.
- Naeini, Mahdi Pakdaman, Taremiyan, Hamidreza and Hashemi, Homa Baradaran (2010)** Stock market value prediction using neural networks. In *2010 International Conference on Computer Information Systems and Industrial Management Applications (CISIM)*., 132–136
- Pai, Ping-Feng and Lin, Chih-Sheng (2005)** A hybrid ARIMA and support vector machines model in stock price forecasting. In *Omega*, 33, Nr. 6, 497–505
- Qiu, Mingyue and Song, Yu (2016)** Predicting the direction of stock market index movement using an optimized artificial neural network model. In *PLoS one*, 11, Nr. 5, e0155133
- Roman, Jovina and Jameel, Akhtar (1996)** Backpropagation and recurrent neural networks in financial analysis of multiple stock market returns. In *Proceedings of HICSS-29: 29th Hawaii international conference on system sciences*. Volume 2, IEEE, 454–460
- Sahin, Ugur and Ozbayoglu, A. Murat (2014)** TN-RSI: Trend-normalized RSI Indicator for Stock Trading Systems with Evolutionary Computation. In *Procedia Computer Science*, 36, 240 – 245, Complex Adaptive Systems Philadelphia, PA November 3-5, 2014

- Sezer, Omer (2018)** Analysis and Optimization of the Time Series Data with Deep Artificial Neural Networks: Financial Estimation Algorithms. Ph. D thesis
- Sezer, Omer Berat, Gudelek, Mehmet Ugur and Ozbayoglu, Ahmet Murat (2020)** Financial time series forecasting with deep learning : A systematic literature review: 2005–2019. In *Applied Soft Computing*, 90, 106181
- Tay, Francis E.H and Cao, Lijuan (2001)** Application of support vector machines in financial time series forecasting. In *Omega*, 29, Nr. 4, 309 – 317
- Teixeira, Lamartine Almeida and de Oliveira, Adriano Lorena Inácio (2010)** A method for automatic stock trading combining technical analysis and nearest neighbor classification. In *Expert Systems with Applications*, 37, Nr. 10, 6885–6890
- Tsai, Chih-Fong and Hsiao, Yu-Chieh (2010)** Combining multiple feature selection methods for stock prediction: Union, intersection, and multi-intersection approaches. In *Decision Support Systems*, 50, Nr. 1, 258–269
- Tsay, Ruey S. (2005)** Analysis of Financial Time Series. John Wiley Sons
- Udagawa, Yoshihisa (2017)** Approach for Retrieving Similar Stock Price Patterns Using Dynamic Programming Method. In *Proceedings of the 19th International Conference on Information Integration and Web-Based Applications & Services*. New York, NY, USA: Association for Computing Machinery, iiWAS '17, 126–130
- Udagawa, Yoshihisa (2018)** Dynamic Programming Approach to Retrieving Similar Candlestick Charts for Short-Term Stock Price Prediction. In *International Journal on Advances in Software* 11, Nr. 3-4
- Vapnik, Vladimir N. (2000)** The Nature of Statistical Learning Theory. Springer New York
- Xiao, Yufan et al. (2022)** Research on Financial Trading Strategies Based on Dynamic Programming Theory. In *2022 7th International Conference on Image, Vision and Computing (ICIVC)*., 946–951
- Xie, Guo-qiang (2011)** The Optimization of Share Price Prediction Model Based on Support Vector Machine. In *2011 International Conference on Control, Automation and Systems Engineering (CASE)*., 1–4
- Yu, L. et al. (2009)** Evolving Least Squares Support Vector Machines for Stock Market Trend Mining. In *IEEE Transactions on Evolutionary Computation*, 13, Nr. 1, 87–102
- Zou, Jinan et al. (2023)** Stock Market Prediction via Deep Learning Techniques: A Survey. No address in

## **EKLER**

**EK 1 :** BIST-100 ve DOW-30 hisse senetleri kapanış fiyatı zaman serisi veri örneği

**EK 2 :** Tek gün ve ardışık gün verilerinden oluşan DOĞRU ve YANLIŞ olarak etiketlenmiş DA matrisi.

**EK 3 :** En yüksek getiri elde edilen AXP, NKE ve UNH hisse senetlerinin, komisyon oranı %0.1 ve %0.2 için önerilen modelin temel model ile karşılaştırılması.



## EK 1

DATE	ADEL	ARCLK	ASELS	EGEEN	FENER	GOLTS	GOODY	THYAO	TTRAK	XU100
2.01.2006	3.08	4.82	1.47	7.88	15.89	38.68	13.20	1.01	3.74	39790.72
3.01.2006	3.17	4.82	1.43	8.08	17.02	38.11	13.11	1.03	3.76	40665.44
4.01.2006	3.11	4.92	1.45	8.08	16.87	38.11	13.37	1.03	3.86	41362.47
5.01.2006	3.45	5.02	1.47	8.08	16.80	38.11	13.37	1.03	4.02	41722.4
6.01.2006	3.51	5.07	1.50	8.01	16.65	38.11	13.11	1.05	4.13	41905.41
16.01.2006	3.45	5.76	1.58	7.68	16.72	37.53	12.77	1.02	4.21	43628.83
17.01.2006	3.59	5.66	1.58	7.61	16.49	36.38	12.60	0.98	4.41	44076.91
18.01.2006	3.37	5.51	1.57	7.07	16.57	35.62	12.08	0.94	4.21	42622.9
19.01.2006	3.42	5.71	1.59	7.14	16.87	35.81	12.34	0.95	4.33	43645.23
20.01.2006	3.45	5.61	1.66	7.00	16.72	38.49	12.34	0.96	4.52	44465.68
23.01.2006	3.48	5.61	1.71	7.00	16.72	39.45	12.17	0.95	4.60	43851.42
24.01.2006	3.65	5.71	1.80	7.14	16.49	43.28	12.25	0.94	4.84	44434.54
25.01.2006	3.74	6.02	1.77	7.21	16.57	50.55	12.34	0.99	4.95	45746.17
26.01.2006	3.62	5.86	1.79	7.14	16.49	54.38	12.34	1.02	4.68	45784.09
27.01.2006	3.68	5.91	1.73	7.00	16.42	52.85	12.17	0.99	4.68	45315.15
30.01.2006	3.88	6.12	1.72	7.00	16.49	53.23	11.91	0.96	4.68	44891.25
31.01.2006	4.19	6.32	1.74	7.21	16.42	57.83	11.99	0.96	4.84	44590.22
1.02.2006	4.56	6.37	1.80	7.27	16.34	58.59	12.08	0.97	4.95	45250.66
2.02.2006	4.73	6.22	1.85	7.21	16.42	57.83	11.99	0.98	4.99	44841.03
3.02.2006	4.54	6.42	1.78	7.14	16.65	57.83	11.82	0.96	4.95	44228.02
6.02.2006	4.45	6.42	1.90	7.88	16.49	58.59	11.99	0.96	5.23	44855.61

Şekil EK1.1: Orijinal Veri seti. BIST-100 hisse senetleri kapanış fiyatı zaman serisi

Date	AAPL	AMGN	AXP	BA	CAT	CSCO	CVX	DIS
20.10.2000	0.348214	68.75	49.07151	60	15.34375	57.3125	41.71875	35.88394
23.10.2000	0.363839	70.9375	47.59444	61.25	15.71875	55.875	41.28125	35.69897
24.10.2000	0.337054	71.375	50.00151	61	15.9375	54.875	41.125	35.69897
25.10.2000	0.330357	68.625	50.22034	62.5625	15.65625	50.625	40.75	34.34253
26.10.2000	0.330357	68.5	47.64914	63.0625	15.90625	53.5625	41	34.65081
27.10.2000	0.331473	59.3125	48.85268	63.75	16.4375	50.6875	40.15625	33.84928
30.10.2000	0.344866	54.125	51.15035	64.6875	17.46875	48.0625	40.8125	34.40419
31.10.2000	0.34933	57.9375	52.518	67.8125	17.53125	53.875	41.0625	35.32903
1.11.2000	0.366071	60.35938	51.09564	65.75	17.375	52.125	41.40625	36.13056
2.11.2000	0.398438	61.4375	50.43916	66.125	17.40625	55.75	40.25	36.80878
3.11.2000	0.397321	59.8125	52.18976	66.0625	17.40625	56.75	40.53125	37.54866
6.11.2000	0.382813	59.875	53.06506	66.0625	18.09375	55.125	41.28125	36.80878
7.11.2000	0.38058	61.8125	53.33859	65.1875	18.0625	56.75	41.03125	36.62381
8.11.2000	0.358259	61.625	50.7674	65	18.21875	52.125	41.5	36.37719
9.11.2000	0.360491	62.75	50.98623	65.6875	18.28125	53.25	41.6875	30.70481
10.11.2000	0.340402	64.5625	49.94681	63.5	17.875	50.0625	42.0625	31.25972
13.11.2000	0.345982	62.625	48.90739	62.8125	18.09375	50.375	41.5625	30.02659
14.11.2000	0.361607	64.125	50.16563	64.375	18.03125	53.125	42.125	30.51984
15.11.2000	0.354911	67.375	50.49387	63.5625	18.34375	53.5625	41.96875	31.38303
16.11.2000	0.339286	65.875	50.54858	65.8125	18.15625	51.0625	41.9375	30.45819
17.11.2000	0.330357	65.125	49.07151	65.375	18.46875	52.75	41.875	29.77997

Şekil EK1.2: Orijinal Veri seti. DOW-30 hisse senetleri kapanış fiyatı zaman serisi



## EK 2

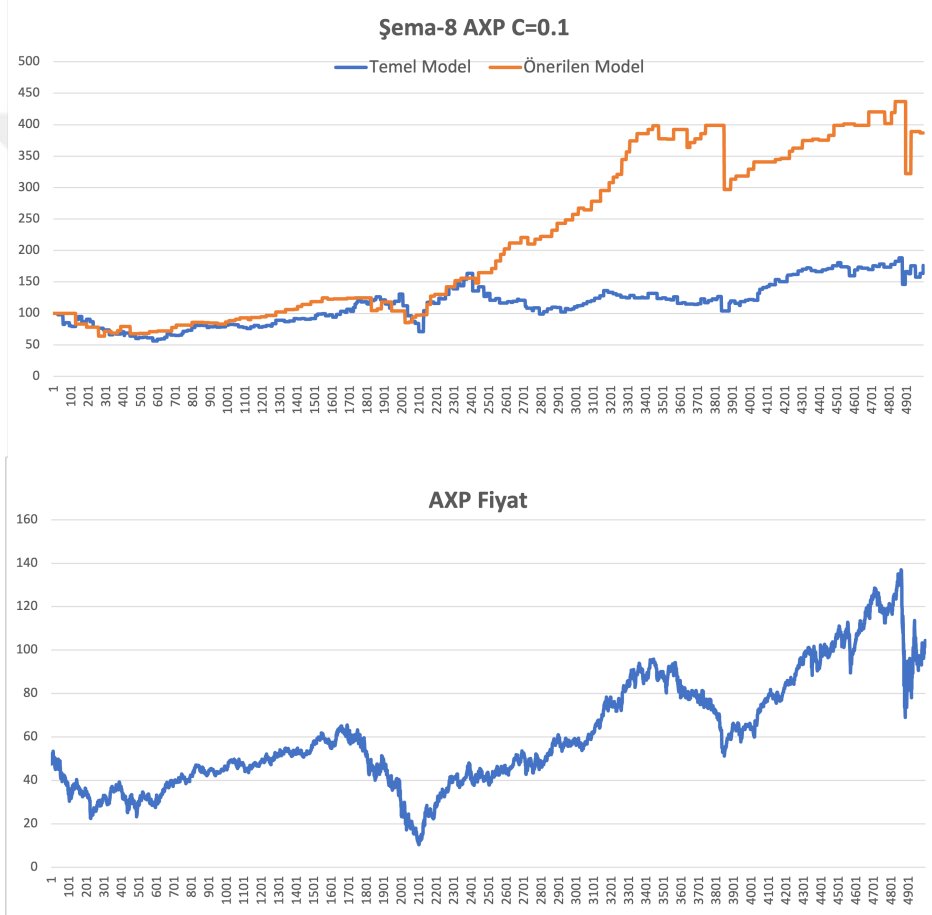
	1 Rsi	2 Tnrsi	3 BBPercent	4 Roc	5 So	6 CCI	7 PPO	8 Response
1	51.2197	21.7300	93.7462	1.1333	107.0200	150.0900	-23.8500	0
2	40.4259	35.7200	29.7839	-8.2315	8.2000	-67.7900	-12.7000	0
3	21.6562	41.3500	-18.2948	-27.9876	-64.8200	-287.9700	-11.4200	1
4	64.9119	35.5000	71.6787	14.4679	64.1500	60.1300	0.5400	1
5	66.6665	43.8000	64.0964	17.8830	68.3500	40.3200	5.9800	0
6	45.0385	36.1100	44.5330	-3.9632	21.4300	-20.2500	3.7900	0
7	50.6250	41.2700	52.5670	0.6410	42.3100	6.0800	0.8200	1
8	49.1907	41.5300	24.0899	-0.9526	-3.7000	-81.6700	1.6800	1
9	37.8563	39.3400	27.4408	-10.8001	26.7100	-73.1200	1.2100	0
10	42.6930	27.7900	26.5624	-5.7732	-4.1800	-85.4900	2.1500	1
11	46.2245	38.1200	30.4239	-3.0794	11.7600	-71.5900	1.6800	0
12	41.6484	41.0100	19.6752	-6.2298	8.8200	-104.1300	1.2500	0
13	58.4464	44.1500	85.0965	8.3148	112.9800	112.6700	1.3000	0
14	41.6611	38.1100	-0.1368	-10.9255	-8.8400	-184.4300	1.3900	0
15	34.9968	43.9400	3.0873	-19.9244	-8.0900	-166.7400	-2.5700	1
16	25.6488	28.5100	4.9133	-8.6665	-6.9600	-166.7700	-3.8900	1
17	30.1788	36.4900	-14.8038	-15.5627	-22.7300	-276.9700	-4.1500	1
18	27.1823	37.4800	-2.0552	-16.8604	1.5400	-205.2700	-4.5600	0
19	64.5671	44.4000	69.2222	9.5424	66.3400	60.5700	0.3100	1
20	47.6189	43.6000	60.2924	-1.6299	56.6500	29.9800	2.5400	1
21	57.1213	44.4800	82.3136	4.7985	68.4200	116.9500	3.5800	1
22	43.9951	30.1600	35.8586	-4.5859	-0.9000	-48.3200	3.0800	1
23	47.6308	37.3700	37.8367	-1.8096	6.8200	-41.4600	2.5500	0
24	45.2476	40.2200	21.3194	-3.3040	-10.2300	-95.4100	0.3600	1
25	64.4857	38.6500	65.3595	8.3896	60.8800	47.1200	3.2900	0
26	64.5161	36.8200	75.9852	7.7553	81.5100	80.6000	3.2400	0
27	31.7458	27.3500	-12.1710	-13.0259	-39.5800	-236.1100	0.5000	1
28	48.0599	17.6000	30.6611	-0.7652	-11.7700	-72.6900	0.7900	1

**Şekil EK2.1:** SVM ile eğitilmeden önceki DA matrisi, 7 Teknik analiz göstergesinden oluşan öznitelikler ile DOĞRU ya da YANLIŞ olarak etiketlenmiş matrisi.


	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
	Rsi	Trns1	BBPercent	Roc	So	CCI	PPD	Rsi2	Trns2	BBPercent2	Roc2	So2	CCI2	PPD2	Response
1	52.3808	33.6200	57.8315	2.4998	56.1400	22.5600	-26.0200	51.2197	21.7300	93.7462	1.1333	107.0200	150.0900	-23.8500	0
2	52.2582	41.3500	30.1439	2.3571	11.6700	-67.8800	-14.0500	45.6953	36.2400	21.3641	-4.2071	-15.1000	-97.7200	-13.7500	0
3	40.4259	35.7200	29.7839	-8.2315	8.2000	-67.7900	-12.7000	23.9315	26.1300	23.2854	-17.0870	0	-90.2400	-12.2900	0
4	28.3335	54.5300	16.8004	-16.0495	13.3300	-120.7900	-10.5400	21.6562	41.3500	-18.2948	-27.9876	-64.8200	-287.9700	-11.4200	1
5	64.9124	35.0200	79.9636	14.1669	73.5900	86.6900	0.4500	64.9119	35.5000	71.6787	14.4679	64.1500	60.1300	0.5400	1
6	71.4282	44.4200	97.4488	25.1906	100	175.3000	5.0500	65.1315	40	85.8663	16.8497	86.3600	124.5800	5.3000	0
7	65.1315	40	85.8663	16.8497	86.3600	124.5800	5.3000	67.3467	41.7300	78.0913	19.4654	77.2700	89.4100	5.2700	0
8	54.1177	46.3500	53.6357	4.6512	44.2300	9.2500	0.9900	50.6250	41.2700	52.5670	0.6410	42.3100	6.0800	0.8200	1
9	49.1487	40.5100	36.6363	-0.9661	18.2200	-42.3800	2.5800	49.1907	41.5300	24.0899	-0.9526	-3.7000	-81.6700	1.6800	0
10	48.3364	46.9800	52.2759	-1.5612	57.5700	4.8400	1.7000	37.8563	39.3400	27.4408	-10.8001	26.7100	-73.1200	1.2100	0
11	40.0194	20.9100	29.6017	-8.1471	-37.5500	-73.4400	2.9100	42.6930	27.7900	26.5624	-5.7732	-4.1800	-85.4900	2.1500	1
12	72.4367	45.2600	83.4012	16.4629	96.3500	100.7000	2.1700	71.8628	43.4000	70.5150	16.6499	80.5300	58.3600	2.1000	0
13	35.8808	42.2900	1.4931	-18.2426	-8.1700	-177.7800	-1.6900	34.9968	43.9400	3.0873	-19.9244	-8.0900	-166.7400	-2.5700	1
14	41.4754	41.1100	5.0272	-3.5659	2.8500	-176.0300	-3.8500	35.2334	34.5700	2.0721	-5.9811	-8.5700	-183.7900	-3.9400	0
15	26.2538	28.7200	19.2534	-8.1231	15.2600	-110.8900	-3.8400	25.6488	28.5100	4.9133	-8.6665	-6.9600	-166.7700	-3.8900	1
16	36.9654	36.9600	13.1585	-6.4043	1.5600	-125.3400	-3.0400	37.2040	39.8700	15.1712	-6.2566	1.5600	-113.8000	-3.0700	0
17	44.1134	50.9400	16.4419	-4.4357	28.0300	-122.2300	-3.5700	30.1788	36.4900	-14.8038	-15.5627	-22.7300	-276.9700	-4.1500	1
18	82.3525	62.8900	94.6068	18.8777	100	156.1900	0.3300	64.5671	44.4000	69.2222	9.5424	66.3400	60.5700	0.3100	1
19	70.9988	41.3500	88.9961	19.3327	97.7700	119.0100	2.4600	70.9193	40.1300	88.7511	18.8974	105.6300	118.6600	2.8600	0
20	70.9193	40.1300	88.7511	18.8974	105.6300	118.6600	2.8600	65.9354	37.0200	76.5072	15.2468	83.7000	78.0500	2.9100	0
21	48.6991	28.1900	48.5920	-1.0149	25.9100	-6.5700	1.7100	53.7760	38.6600	72.4246	3.2204	72.7300	74.1700	1.8700	0
22	53.7760	38.6600	72.4246	3.2204	72.7300	74.1700	1.8700	53.7760	41.0900	70.0244	3.2240	71.8200	66.7200	1.9600	0
23	52.8352	45.8400	61.5043	2.2403	56.6500	33.6100	2.7200	47.6189	43.6000	60.2924	-1.6299	56.6500	29.9800	2.5400	1
24	61.6261	48.0600	97.4020	7.3072	86.0900	177.5300	3.6000	57.1213	44.4800	82.3136	4.7985	68.4200	116.9500	3.5800	1
25	56.3876	40.5400	49.2415	5.8467	29.5900	-4.4000	3.8200	43.9951	30.1600	35.8586	-4.5859	-0.9000	-48.3200	3.0800	1
26	52.5447	45.0200	46.5715	1.5916	24.6200	-12.6200	0.8100	45.2476	40.2200	21.3194	-3.3040	-10.2300	-95.4100	0.3600	1
27	74.9678	54.7500	80.4400	18.7201	83.3000	96.1000	3.7700	64.0866	38.3100	71.8739	8.0961	68.3200	67.8800	3.5700	0
28	43.8618	32.5400	22.3988	-3.9851	18.0200	-89.3600	1.4300	31.7458	27.3500	-12.1710	-13.0259	-39.5800	-236.1100	0.5000	1

Şekil EK2.2: SVM ile eğitilmeden önceki DA matrisi, son iki vektörün Teknik göstergeleri ile oluşan 14 teknik analiz göstergesinden oluşan öz nitelikler ve DOĞRU ya da YANLIŞ olarak etiketlenmiş matris.


### EK 3




**Şekil EK3.1:** Temel model ve Önerilen modelin AXP hisse senedinde komisyon oranı=%0.1 için oluşturduğu yatırım kazancının karşılaştırması ve AXP kapanış fiyatı ile birlikte değerlendirilmesi.




**Şekil EK3.2:** Temel model ve Önerilen modelin AXP hisse senedinde komisyon oranı=%0.2 için oluşturduğu yatırım kazancının karşılaştırması ve AXP kapanış fiyatı ile birlikte değerlendirilmesi.




**Şekil EK3.3:** Temel model ve Önerilen modelin NKE hisse senedinde komisyon oranı=%0.1 için oluşturduğu yatırım kazancının karşılaştırması.



**Şekil EK3.4:** Temel model ve Önerilen modelin NKE hisse senedinde komisyon oranı=%0.2 için oluşturduğu yatırım kazancının karşılaştırması.



**Şekil EK3.5:** Temel model ve Önerilen modelin NKE hisse senedinde komisyon oranı=%0.1 için oluşturduğu yatırım kazancının karşılaştırması ve NKE kapanış fiyatı ile birlikte değerlendirilmesi.



**Şekil EK3.6:** Temel model ve Önerilen modelin NKE hisse senedinde komisyon oranı=%0.2 için oluşturduğu yatırım kazancının karşılaştırması ve NKE kapanış fiyatı ile birlikte değerlendirilmesi.