

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

**ZAMAN SERİSİ VERİLERİNİN DERİN YAPAY SİNİR AĞLARI İLE  
ANALİZİ VE ENİYİLEMESİ: FİNANSAL TAHMİN ALGORİTMALARI**

**DOKTORA TEZİ**  
**Ömer Berat SEZER**

**Bilgisayar Mühendisliği Anabilim Dalı**

**Tez Danışmanı Dr. Öğr. Üyesi Ahmet Murat ÖZBAYOĞLU**

**MAYIS 2018**



Fen Bilimleri Enstitüsü Onayı

.....  
**Prof. Dr. Osman EROĞUL**  
Müdür

Bu tezin Doktora derecesinin tüm gereksinimlerini sağladığını onaylarım.

.....  
**Prof. Dr. Oğuz ERGİN**  
Anabilimdalı Başkanı

TOBB ETÜ, Fen Bilimleri Enstitüsü'nün 131117012 numaralı Doktora Öğrencisi **Ömer Berat SEZER**'in ilgili yönetmeliklerin belirlediği gerekli tüm şartları yerine getirdikten sonra hazırladığı "**ZAMAN SERİSİ VERİLERİNİN DERİN YAPAY SİNİR AĞLARI İLE ANALİZİ VE ENİYİLEMESİ: FİNANSAL TAHMİN ALGORİTMALARI**" başlıklı tezi 24.05.2018 tarihinde aşağıda imzaları olan jüri tarafından kabul edilmiştir.

**Tez Danışmanı:** **Dr. Öğr. Üyesi Ahmet Murat ÖZBAYOĞLU** .....  
TOBB Ekonomi ve Teknoloji Üniversitesi

**Jüri Üyeleri:** **Prof. Dr. Erdoğan DOĞDU (Başkan)** .....  
Çankaya Üniversitesi

**Doç. Dr. Osman ABUL** .....  
TOBB Ekonomi ve Teknoloji Üniversitesi

**Prof. Dr. İsmail Hakkı TOROSLU** .....  
Orta Doğu Teknik Üniversitesi

**Doç. Dr. Muhammed Fatih DEMİRCİ** .....  
TOBB Ekonomi ve Teknoloji Üniversitesi



## **TEZ BİLDİRİMİ**

Tez içindeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edilerek sunulduğunu, alıntı yapılan kaynaklara eksiksiz atıf yapıldığını, referansların tam olarak belirtildiğini ve ayrıca bu tezin TOBB ETÜ Fen Bilimleri Enstitüsü tez yazım kurallarına uygun olarak hazırlandığını bildiririm.

Ömer Berat SEZER



## ÖZET

Doktora Tezi

### ZAMAN SERİSİ VERİLERİNİN DERİN YAPAY SİNİR AĞLARI İLE ANALİZİ VE ENİYİLEMESİ: FİNANSAL TAHMİN ALGORİTMALARI

Ömer Berat SEZER

TOBB Ekonomi ve Teknoloji Üniversitesi  
Fen Bilimleri Enstitüsü  
Bilgisayar Mühendisliği Anabilim Dalı

Tez Danışmanı Dr. Öğr. Üyesi Ahmet Murat ÖZBAYOĞLU

Tarih: Mayıs 2018

Zaman serisi verilerinin analizi istatistiksel / matematiksel analiz, sinyal işleme, özellik çıkartma, örüntü tanıma, makine öğrenme ve derin öğrenme yöntemleriyle yapılmaktadır. Zaman serisi verilerinin analizi yapılarak, verilerin gelecek zamandaki değerlerinin tahmini yapılabilmektedir. Finansal zaman serisi verilerinin analizinde finansal teknik analiz göstergeleri kullanıldığı gibi makine öğrenme ve derin öğrenme algoritmaları da kullanılmaktadır. Ancak, literatürdeki çalışmalarda teknik analiz verilerini derin sinir ağı modelleriyle entegre eden modellere pek rastlanmamıştır. Önerilen tez ile teknik analiz verileri işlenerek, derin öğrenme yöntemleri ile birlikte kullanılmaktadır. Tezde önerilen yöntemlerin, diğer önerilen yöntemlerden farkı teknik analiz verilerinin fiyatlar üzerine uygulanarak özellik vektör ve matrislerinin (iki boyutlu resim) oluşturulması ve finansal zaman serisi verilerinin sınıflandırma problemine dönüştürülmesidir. Finansal zaman serisi verilerinde, orta ve uzun vadede finansal tahmin yapabilen, yüksek oranda kar elde edilmesi sağlayabilen, stabil kararlar alabilen yöntemler geliştirmek hedeflenmiştir. Bu hedefler doğrultusunda; finansal teknik analiz göstergeleri, genetik algoritma, derin çok katmanlı algılayıcı sinir ağı, derin konvolüsyonel sinir ağları kullanılarak yenilik içeren algoritma ve metotlar geliştirilmiştir. Tez kapsamında dört farklı öneri yapılmıştır. Önerilen algoritmalar, gerçek bir finansal değerlendirme senaryosunda gerçek verilerle koşullularak, "Al&Tut", RSI ve SMA modelleri ile, LSTM ve MLP regresyon yöntemleri ile karşılaştırılmıştır. Elde edilen sonuçlar yaygın kullanılan Al-Sat modelleri ve literatürde yer alan yapay öğrenme modelleri ile kıyaslandığında daha iyi başarımlar sağladığı gözlemlenmiştir. Geliştirilen modeller farklı zaman serilerine uygulanabilir.

**Anahtar Kelimeler:** Finansal veri analizi, Derin konvolüsyonel sinir ağı, Makine öğrenme, Alım satım stratejileri, Genetik algoritma, Teknik analiz.





## ABSTRACT

Doctor of Philosophy

ANALYSIS AND OPTIMIZATION OF THE TIME SERIES DATA WITH DEEP  
ARTIFICIAL NEURAL NETWORKS: FINANCIAL ESTIMATION ALGORITHMS

Ömer Berat SEZER

TOBB University of Economics and Technology  
Institute of Natural and Applied Sciences  
Department of Computer Engineering

Supervisor: Dr. Öğr. Üyesi Ahmet Murat ÖZBAYOĞLU

Date: May 2018

Time series data is analysed with different methods in terms of statistical / mathematical analysis, signal processing, feature extraction, pattern recognition, machine learning and deep learning methods. By analysing the time series data, future values of the data can be estimated. In the analysis of financial time series data, as financial technical analysis indicators are used, machine learning and deep learning algorithms are also used. However, models that integrate technical analysis data with deep neural networks are rarely seen in literature. With the proposed thesis, as a contribution to literature, technical analysis data and deep convolutional neural network are combined. The difference between the proposed models and the existing methods can be explained as follows: Technical analysis data is applied on the prices to create feature vectors and matrices (two-dimensional images) and the financial time series data is converted into a classification problem. In this thesis, our aim is to develop methods that can make financial forecasts in the medium and long term, making stable decisions that can provide maximum profit. In line with these objectives; financial technical analysis indicators, genetic algorithm, deep multilayer perceptron, deep convolutional neural network were used to develop novel algorithms and methods. Four different models were proposed in the thesis. The proposed algorithms were run in a real financial evaluation scenario and results were compared with Buy&Hold strategies, RSI and SMA models, LSTM and MLP regression methods. It has been observed that the obtained results provide better performance when compared to the widely used Buy&Hold models and machine learning models in the literature. Proposed models can be adapted to different time series to be utilized in various use cases.

**Keywords:** Financial data analysis, Deep convolutional neural network, Machine learning, Trading strategies, Genetic algorithm, Technical analysis.



## TEŐEKKÜR

Çalıőmalarım boyunca deęerli yardım ve katkılarıyla beni yönlendiren Hocalarım Dr. Öğr. Üyesi Murat Özbayoęlu, Doç. Dr. Osman Abul, Prof. Dr. Erdoğan Doędu'ya, kıymetli tecrübelerinden faydalandıęım TOBB Ekonomi ve Teknoloji Üniversitesi Bölümü öğretim üyelerine, eğitimim boyunca bana burs veren TOBB Ekonomi ve Teknoloji Üniversitesi'ne ve destekleriyle her zaman yanımda olan eőim Zuhâl Sezer'e, aileme ve arkadaşlarıma çok teşekkür ederim.





## İÇİNDEKİLER

	<u>Sayfa</u>
<b>ÖZET</b> . . . . .	<b>iv</b>
<b>ABSTRACT</b> . . . . .	<b>v</b>
<b>TEŞEKKÜR</b> . . . . .	<b>vi</b>
<b>İÇİNDEKİLER</b> . . . . .	<b>vii</b>
<b>ŞEKİL LİSTESİ</b> . . . . .	<b>x</b>
<b>ÇİZELGE LİSTESİ</b> . . . . .	<b>xii</b>
<b>KISALTMALAR</b> . . . . .	<b>xiv</b>
<b>1. GİRİŞ</b> . . . . .	<b>1</b>
1.1 Problem ve Motivasyon . . . . .	2
1.2 Tezin Katkıları . . . . .	3
1.2.1 Önerilen çözüm . . . . .	5
<b>2. ZAMAN SERİSİ VERİLERİNİN ANALİZİ</b> . . . . .	<b>11</b>
2.1 Zaman Serisi Verileri . . . . .	11
2.2 Zaman Serisi Verilerinin Analizi . . . . .	11
2.2.1 İstatiksel / Matematiksel analiz . . . . .	12
2.2.2 Sinyal işleme . . . . .	12
2.2.3 Özellik çıkartma . . . . .	15
2.2.4 Örüntü tanıma . . . . .	17
2.3 Zaman Serisi Verilerinin Analizinde Makine Öğrenme . . . . .	20
2.3.1 Kümeleme algoritmaları . . . . .	21
2.3.2 Yapay sinir ağları . . . . .	22
2.3.3 Destek vektör makineleri regresyonu . . . . .	27
2.3.4 Özdüzenleyici haritalar . . . . .	27
2.4 Zaman Serisi Verilerinin Analizinde Derin Öğrenme . . . . .	27
2.4.1 Çok katmanlı derin yapay sinir ağları (DMLP) . . . . .	28
2.4.2 Tekrarlamalı yapay sinir ağı (RNN) . . . . .	29
2.4.3 Uzun kısa vadeli hafıza (LSTM) . . . . .	31
2.4.4 Sınırlı Boltzmann makinesi (RBMs) . . . . .	32
2.4.5 Derin düşünce ağları (DBN) . . . . .	33
2.4.6 Otomatik kodlayıcı (Autoencoder) . . . . .	34
2.4.7 Konvolüsyonel sinir ağları . . . . .	35
<b>3. FİNANSAL ZAMAN SERİSİ VERİLERİNİN ANALİZİ</b> . . . . .	<b>37</b>
3.1 Finansal Zaman Serisi Verileri . . . . .	37
3.2 Finansal Teknik Analiz . . . . .	37
3.3 Finansal Teknik Analiz Göstergeleri . . . . .	38
3.3.1 Bağıl güç endeksi (relative strength index) . . . . .	39
3.3.2 Williams %R . . . . .	39
3.3.3 Basit hareketli ortalama (simple moving average) . . . . .	40
3.3.4 Üssel hareketli ortalama (exponential moving average) . . . . .	40
3.3.5 Ağırlıklı hareketli ortalama (weighted moving average) . . . . .	41
3.3.6 Hull hareketli ortalama (Hull moving average) . . . . .	41
3.3.7 Üçlü üssel hareketli ortalama (triple exponential moving average) . . . . .	41

3.3.8 Commodity channel index (CCI) . . . . .	42
3.3.9 Chande momentum osilatörü (CMO) . . . . .	42
3.3.10 Moving average convergence and divergence (MACD) . . . . .	42
3.3.11 Yüzde oranı osilatörü (percentage price oscillator) . . . . .	43
3.3.12 Değişim oranı (rate of change) . . . . .	43
3.3.13 Chaikin para akışı (chaikin money flow indicator) . . . . .	43
3.3.14 Yön hareket göstergesi (directional movement indicator) . . . . .	44
3.3.15 Parabolic sar . . . . .	45
3.4 Finansal Verilerin Analizinde Makine Öğrenme . . . . .	45
3.4.1 Yapay sinir ağları (YSA) . . . . .	49
3.4.2 Destek vektör makineleri (SVM) . . . . .	50
3.4.3 Hibrit çözümler . . . . .	51
3.4.4 Optimizasyon . . . . .	52
3.4.5 Bileşik çözümler (ensemble solutions) . . . . .	53
3.5 Finansal Verilerin Analizinde Derin Öğrenme . . . . .	54
<b>4. BÜYÜK VERİ ve ANALİZİ . . . . .</b>	<b>57</b>
4.1 Büyük Veri Tanımı ve Özellikleri . . . . .	57
4.2 Büyük Veri Depolama . . . . .	58
4.3 Büyük Veri Analizi ve Öğrenme . . . . .	60
<b>5. TEKNİK ANALİZ VERİLERİ KULLANARAK YAPAY SİNİR AĞI İLE FİNANSAL ANALİZ YÖNTEMİ (MLP-TA) . . . . .</b>	<b>63</b>
5.1 Motivasyon . . . . .	63
5.2 Önerilen Metot (MLP-TA) . . . . .	64
5.2.1 Önışleme (veri kümesi dönüşümü) . . . . .	64
5.2.2 Teknik analiz ve MLP . . . . .	64
5.3 Değerlendirme . . . . .	66
5.3.1 Finansal değerlendirme . . . . .	67
5.3.2 Dow30 analizi . . . . .	68
5.3.3 MLP-TA yönteminin değerlendirmesi . . . . .	71
<b>6. GENETİK ALGORİTMA İLE OPTİMİZE EDİLMİŞ TEKNİK ANALİZ PARAMETRELERİNİN KULLANILARAK DERİN ÇOKLU ALGILAYICI SİNİR AĞI MODELİ İLE FİNANSAL ANALİZ YÖNTEMİ (DMLP-GA) . . . . .</b>	<b>73</b>
6.1 Motivasyon . . . . .	73
6.2 Önerilen Metot (DMLP-GA) . . . . .	73
6.2.1 Önışleme (veri kümesi dönüşümü) . . . . .	74
6.2.2 Genetik algoritma (GA) . . . . .	75
6.2.3 DMLP . . . . .	78
6.3 Değerlendirme . . . . .	78
6.3.1 Finansal değerlendirme . . . . .	78
6.3.2 Dow30 analizi . . . . .	80
6.3.3 DMLP-GA yönteminin değerlendirmesi . . . . .	82
<b>7. FİNANSAL ZAMAN SERİSİ VERİLERİNİN İKİ BOYUTLU GRAFİK GÖRÜNTÜSÜNE DÖNÜŞTÜRÜLEREK DERİN KONVOLÜSYONEL SİNİR AĞLARI İLE FİNANSAL ANALİZ YÖNTEMİ (CNN-BI) . . . . .</b>	<b>85</b>
7.1 Motivasyon . . . . .	85
7.2 Önerilen Metot (CNN-BI) . . . . .	86
7.2.1 Önışleme (veri kümesi dönüşümü) . . . . .	86
7.2.2 Görüntü oluşturma . . . . .	86
7.2.3 CNN . . . . .	88

7.3 Değerlendirme . . . . .	90
7.3.1 Finansal değerlendirme . . . . .	90
7.3.2 Dow30 analizi . . . . .	90
7.3.3 İstatiksel anlamlılık testleri . . . . .	95
7.3.4 CNN-BI yönteminin değerlendirmesi . . . . .	95
<b>8. FİNANSAL ZAMAN SERİSİ VERİLERİNİN, TEKNİK ANALİZ VERİLERİ KULLANILARAK GÖRÜNTÜ VERİSİNE DÖNÜŞTÜRÜLMESİ ve GÖRÜNTÜLERİN DERİN KONVOLÜSYONEL SİNİR AĞI İLE FİNANSAL ANALİZ YÖNTEMİ (CNN-TA) . . . . .</b>	<b>97</b>
8.1 Motivasyon . . . . .	97
8.2 Önerilen Metot (CNN-TA) . . . . .	98
8.2.1 Önışleme (veri kümesi dönüşümü) . . . . .	98
8.2.2 Teknik analiz ve görüntü oluşturma . . . . .	99
8.2.3 CNN . . . . .	102
8.3 Değerlendirme . . . . .	104
8.3.1 Finansal değerlendirme . . . . .	104
8.3.2 Karşılaştırılan modeller . . . . .	105
8.3.3 ETF analizi . . . . .	105
8.3.4 Dow30 analizi . . . . .	108
8.3.5 Hesaplamalı model performansı . . . . .	111
8.3.6 İstatistiksel anlamlılık testleri . . . . .	113
8.3.7 CNN-TA yönteminin değerlendirmesi . . . . .	113
8.3.8 CNN-TA zaman kaydırmalı yönteminin değerlendirmesi . . . . .	115
<b>9. GENEL DEĞERLENDİRME . . . . .</b>	<b>119</b>
9.1 Önerilen Tüm Yöntemlerin Değerlendirmesi . . . . .	119
9.2 CNN-TA Zaman Kaydırmalı Yönteminin Değerlendirmesi . . . . .	124
<b>10. SONUÇ . . . . .</b>	<b>129</b>
10.1 Gelecekteki Çalışmalar . . . . .	130
<b>KAYNAKLAR . . . . .</b>	<b>132</b>
<b>ÖZGEÇMİŞ . . . . .</b>	<b>149</b>





## ŞEKİL LİSTESİ

	<u>Sayfa</u>
Şekil 1.1: Önerilen yöntemler . . . . .	6
Şekil 2.1: Sinyalin frekans bölgesindeki gösterimi . . . . .	13
Şekil 2.2: Otokorelasyon, çapraz korelasyon ve konvolüsyon işlemleri <sup>1</sup> . . . . .	14
Şekil 2.3: Parçalı kümeleme yaklaşımı ile örnekleme [8] . . . . .	15
Şekil 2.4: PIPs ile örnekleme [8] . . . . .	16
Şekil 2.5: Sembolik kümeleme yaklaşımı [43] . . . . .	16
Şekil 2.6: Modülasyonu yapılarak aktarılan sinyallerin örüntüleri [41] . . . . .	18
Şekil 2.7: Beyne gelen işitme verilerinin etiketlenmesi [9] . . . . .	19
Şekil 2.8: Kümeleme yaklaşımları [4] . . . . .	21
Şekil 2.9: Nöron yapısı [63] . . . . .	23
Şekil 2.10: Sigmoid fonksiyonu [63] . . . . .	23
Şekil 2.11: Basit çok katmanlı algılayıcı [63] . . . . .	24
Şekil 2.12: Çok katmanlı derin yapay sinir ağı [13] . . . . .	28
Şekil 2.13: Çok katmanlı derin yapay sinir ağı geri yayılımı [13] . . . . .	29
Şekil 2.14: Tekrarlamalı yapay sinir hücresinin zaman içerisindeki açılımı [13] . . . . .	30
Şekil 2.15: Tekrarlamalı yapay sinir ağları [85] . . . . .	30
Şekil 2.16: Tekrarlamalı yapay sinir hücresinde zaman içerisinde geri yayılımı <sup>2</sup> . . . . .	31
Şekil 2.17: LSTM yapısı [87] . . . . .	32
Şekil 2.18: Sınırlı Boltzmann makinesi (RBM) [88] . . . . .	33
Şekil 2.19: Derin düşünce ağları [88] . . . . .	33
Şekil 2.20: Otomatik kodlayıcı [14] . . . . .	34
Şekil 2.21: Konvolüsyonel sinir ağları (CNN) <sup>3</sup> . . . . .	35
Şekil 3.1: Yükselen eğilim [97] . . . . .	38
Şekil 3.2: Zaman serisi verilerde kullanılan yaygın tahmin yöntemi [17] . . . . .	46
Şekil 3.3: Finansal tahmin yöntemleri [17] . . . . .	47
Şekil 5.1: MLP-TA yöntemi . . . . .	64
Şekil 5.2: Etiketleme yöntemi . . . . .	66
Şekil 6.1: Genetik algoritma ve derin MLP ile hisse senedi tahmini . . . . .	74
Şekil 6.2: DMPLP-GA modelinin detaylı gösterimi . . . . .	74
Şekil 6.3: Genetik algoritma fazı . . . . .	75
Şekil 6.4: 8 genden oluşan kromozom . . . . .	75
Şekil 7.1: CNN-BI metodu . . . . .	87
Şekil 7.2: 30x30 piksel örnek görüntüler ve görüntülerin "Al", "Sat", "Tut" etiketleri . . . . .	88
Şekil 7.3: Oluşturulan CNN yapısı . . . . .	90
Şekil 7.4: CNN-BI ile "Al-Tut" yöntemi sonuçlarının karşılaştırılması . . . . .	93
Şekil 8.1: CNN-TA metodu . . . . .	99
Şekil 8.2: Etiketleme yöntemi . . . . .	99
Şekil 8.3: 15x15 piksel örnek görüntüler ve görüntülerin "Al", "Sat", "Tut" etiketleri . . . . .	101
Şekil 8.4: CNN-TA yöntemi işlem adımları . . . . .	102

Şekil 8.5: XLE ve XLF ETF'lerinde CNN-TA metodu ve "Al&Tut" stratejisinin sonuçlarının karşılaştırılması . . . . .	108
Şekil 8.6: JPM ve TRV hisselerinde CNN-TA metodu ve "Al&Tut" stratejisinin sonuçlarının karşılaştırılması . . . . .	111
Şekil 8.7: CNN-TA zaman kaydırmalı eğitim ve test yaklaşımı . . . . .	115
Şekil 9.1: Dow30 2007-2017 ortalama yıllık getiri - yöntem grafiği . . . . .	120
Şekil 9.2: Dow30 2007-2012 ortalama yıllık getiri - yöntem grafiği . . . . .	122
Şekil 9.3: ETF 2007-2017 ortalama yıllık getiri - yöntem grafiği . . . . .	125
Şekil 9.4: ETF 2007-2012 ortalama yıllık getiri - yöntem grafiği . . . . .	126



## ÇİZELGE LİSTESİ

	<u>Sayfa</u>
Çizelge 5.1: WMT (Walmart) hissesinin hata matrisi (confusion matrix) . . . . .	67
Çizelge 5.2: WMT (Walmart) hissesinin değerlendirilmesi . . . . .	67
Çizelge 5.3: JPM hissesinin örnek "Al-Sat" işlemleri . . . . .	68
Çizelge 5.4: MLP-TA metodunun Dow-30 hisseleri ile değerlendirilmesi - (2007-2017) (no-stoploss) . . . . .	69
Çizelge 5.5: MLP-TA metodunun Dow-30 hisseleri ile değerlendirilmesi - (2007-2017) (5%-Stoploss) . . . . .	70
Çizelge 5.6: MLP-TA metodunun "Al&Tut" ile kıyaslanması (2007-2017) . . . . .	71
Çizelge 6.1: MLP için eğitim verisi örneği . . . . .	77
Çizelge 6.2: DMLP-GA yönteminin Dow-30 hisseleriyle değerlendirmesi . . . . .	80
Çizelge 6.3: GA yönteminin Dow-30 hisseleriyle değerlendirilmesi . . . . .	81
Çizelge 6.4: DMLP-GA, GA, MLP, "Al&Tut" metotlarının kıyaslanması . . . . .	81
Çizelge 7.1: Finansal senaryo işlem örnekleri: JPM hissesinin işlemleri . . . . .	93
Çizelge 7.2: CNN-BI yönteminin Dow-30 hisseleri ile değerlendirilmesi - (2007 - 2012) . . . . .	93
Çizelge 7.3: CNN-BI yönteminin Dow-30 hisseleri ile değerlendirilmesi - (2012 - 2017) . . . . .	94
Çizelge 7.4: 2007-2012 ve 2012-2017 TTest performans sonuçları . . . . .	95
Çizelge 8.1: INTC hissesinin 2007-2012 yılları finansal değerlendirme sonuçları . . . . .	101
Çizelge 8.2: TRV hissesinin örnek "Al-Sat" işlemleri . . . . .	106
Çizelge 8.3: Seçilen ETF ve tanımları . . . . .	107
Çizelge 8.4: CNN-TA yönteminin ETF'lerle değerlendirilmesi - eğitim periyodu: 1997-2007, test periyodu: 2007-2012 . . . . .	107
Çizelge 8.5: CNN-TA yöntemi ile BaH, RSI, SMA, LSTM, MLP (Reg.) modellerinin karşılaştırılması (ETF'ler-test periyodu: 2007-2012) . . . . .	107
Çizelge 8.6: CNN-TA yönteminin ETF'lerle değerlendirilmesi - eğitim periyodu: 1997-2007, test periyodu: 2007-2017 . . . . .	107
Çizelge 8.7: CNN-TA yöntemi ile BaH, RSI, SMA, LSTM, MLP (Reg.) modellerinin karşılaştırılması (ETF'ler-test periyodu: 2007-2017) . . . . .	108
Çizelge 8.8: CNN-TA yönteminin Dow30 hisseleriyle değerlendirilmesi - eğitim periyodu: 1997-2007, test periyodu: 2007-2012 . . . . .	109
Çizelge 8.9: CNN-TA yöntemi ile BaH, RSI, SMA, LSTM, MLP (Reg.) modellerinin karşılaştırılması (Dow30 - test periyodu: 2007-2012) . . . . .	110
Çizelge 8.10: CNN-TA yönteminin Dow30 hisseleriyle değerlendirilmesi - eğitim periyodu: 1997-2007, test periyodu: 2007-2017 . . . . .	110
Çizelge 8.11: CNN-TA yöntemi ile BaH, RSI, SMA, LSTM, MLP (Reg.) modellerinin karşılaştırılması (Dow30 - test periyodu: 2007-2017) . . . . .	111
Çizelge 8.12: Test verilerinin hata matrisi (confusion matrix-Dow-30) . . . . .	112
Çizelge 8.13: Test verilerinin değerlendirilmesi (Dow-30) . . . . .	112

Çizelge 8.14: Test verilerinin hata matrisi (confusion matrix-ETFs) . . . . .	112
Çizelge 8.15: Test verilerinin değerlendirilmesi (ETFs) . . . . .	112
Çizelge 8.16: Dow30 hisselerinin 2007-2012 ve 2012-2017 dönemlerindeki TTest sonuçları . . . . .	113
Çizelge 8.17: ETF'lerin 2007-2012 ve 2012-2017 dönemlerindeki TTest sonuçları .	113
Çizelge 8.18: CNN-TA yönteminin rastgele seçilmiş hisse ve ETF'ler ile testi . . .	114
Çizelge 8.19: 5 yıl eğitim, 1 yıl test ile CNN-TA yönteminin değerlendirilmesi (ETF)	116
Çizelge 8.20: CNN-TA zaman kaydırmalı yöntemin diğer yöntemlerle kıyaslanması (ETF) . . . . .	116
Çizelge 8.21: 5 yıl eğitim, 1 yıl test ile CNN-TA yönteminin değerlendirilmesi (Dow30) . . . . .	116
Çizelge 8.22: CNN-TA zaman kaydırmalı yöntemin diğer yöntemlerle kıyaslanması (Dow30) . . . . .	117
Çizelge 9.1: Önerilen tüm yöntemlerin yıllık kazançlarının kıyaslanması (2007-2017)	120
Çizelge 9.2: Önerilen tüm yöntemlerin toplam sermaye kıyaslanması (2007-2017) .	121
Çizelge 9.3: Önerilen tüm yöntemlerin yıllık kazançlarının kıyaslanması (2007-2012)	122
Çizelge 9.4: Önerilen tüm yöntemlerin toplam sermaye kıyaslanması (2007-2012) .	123
Çizelge 9.5: CNN-TA zaman kaydırmalı yönteminin BaH, RSI, SMA, LSTM, MLP Reg. modelleri ile kıyaslanması (ETFs - test periyodu: 2007 - 2017) . . . . .	125
Çizelge 9.6: CNN-TA zaman kaydırmalı yönteminin BaH, RSI, SMA, LSTM, MLP Reg. modelleri ile kıyaslanması (ETFs - test periyodu: 2007 - 2012) . . . . .	126
Çizelge 9.7: Yıllık kazançların TTest sonuçları (Dow30) . . . . .	126
Çizelge 9.8: Yıllık kazançların TTest sonuçları (ETF) . . . . .	127

## KISALTMALAR

<b>ANN - YSA</b>	: Artificial Neural Network - Yapay Sinir Ađı
<b>ARMA</b>	: Autoregressive Moving Average - Otoregresyon Hareketli Ortalama
<b>ARIMA</b>	: Autoregressive Integrated Moving Average
<b>BaH</b>	: Buy and Hold - Al&Tut Stratejisi
<b>CCI</b>	: Commodity Channel Index
<b>CMFI</b>	: Chaikin Money Flow Indicator
<b>CMO</b>	: Chande Momentum Osilatörü
<b>CNN</b>	: Convolutional Neural Network - Konvolüsyonel Sinir Ađı
<b>CNN-BI</b>	: Convolutional Neural Network using Bar Image
<b>CNN-TA</b>	: Convolutional Neural Network using Technical Analysis
<b>DBN</b>	: Deep Belief Network
<b>DFT</b>	: Discrete Fourier Transform
<b>DMI</b>	: Directional Movement Indicator - Yön Hareket Göstergesi
<b>DMLP</b>	: Deep Multilayer Perceptron - Derin Çok Katmanlı Algılayıcı
<b>DMLP-GA</b>	: Deep Multilayer Perceptron with Genetic Algorithm
<b>DTW</b>	: Dynamic Time Wrapping
<b>EMA</b>	: Exponential Moving Average - Üssel Hareketli Ortalama
<b>ETF</b>	: Exchange Trading Fund
<b>GA</b>	: Genetic Algorithm - Genetik Algoritma
<b>HDFS</b>	: Hadoop Dynamic File System
<b>IoT</b>	: Internet Of Things - Nesnelerin İnterneti
<b>LSTM</b>	: Long Short Term Memory - Uzun Kısa Dönemli Hafıza
<b>MACD</b>	: Moving Average Convergence and Divergence
<b>MLP</b>	: Multilayer Perceptron - Çok Katmanlı Algılayıcı
<b>MLP-TA</b>	: Multilayer Perceptron with Technical Analysis
<b>PAA</b>	: Piecewise Aggregate Approximation - Parçalı Kümeleme Yaklaşımı
<b>PIP</b>	: Perceptually Important Points
<b>RBF</b>	: Radial Basis Function
<b>RBM</b>	: Restricted Boltzmann Machine
<b>RNN</b>	: Recurrent Neural Network - Tekrarlamalı Sinir Ađı
<b>RoC</b>	: Rate Of Change - Deđişim Oranı
<b>RRL</b>	: Recurrent Reinforcement Learning
<b>RSI</b>	: Relative Strength Index - Bağıl Güç Endeksi
<b>SAX</b>	: Symbolic Aggregate Approximation - Sembolik Kümeleme Yaklaşımı
<b>SDA</b>	: Stochastic Gradient Descent
<b>SMA</b>	: Simple Moving Average - Basit Hareketli Ortalama
<b>SOM</b>	: Self Organizing Maps - Özdüzenleyici Haritalar
<b>SVM</b>	: Support Vector Machine - Destek Vektör Makineleri
<b>TA4J</b>	: Technical Analysis For Java
<b>TDNN</b>	: Time Delay Neural Network
<b>WMA</b>	: Weighted Moving Average - Ađırlıklı Hareketli Ortalama



## 1. GİRİŞ

Teknolojinin gelişmesiyle birlikte etrafımızdaki elektronik cihazların (mobil cihazlar, bilgisayarlar, sensörler) veriler ürettiğini ve bu verilerin gündelik hayatta daha çok yer edindiğini görmekteyiz. Elektronik cihazlar tarafından bu verilerin zamanla birlikte anlam kazandığı ve belirli bir zaman periyotunda gelen verilerin anlamlı olduğu görülmektedir. Zamana bağlı, zaman sıralı olarak gelen verilerinin analizi, zaman serisi verilerinin analizi olarak adlandırılmaktadır. Bir çok zaman serisi verilerin eşit zaman aralıklı olarak geldiği görülmektedir.

İstatistik, kontrol, astronomi, haberleşme, biyomedikal, meteoroloji, jeofizik, sismoloji, ekonometri, matematiksel finans gibi uygulamalı bilimler ve mühendislik alanlarında ve hava ve deprem tahmini, nesnelerin interneti, örüntü tanıma, sinyal işleme, finansal verilerin analizi gibi uygulama alanlarında zaman serisi verilerinin incelenmesi ve analizi yapılır [1], [2], [3], [4], [5], [6]. Zaman serisi verilerinin analizinde amaç verilerden anlamlı ve karakteristik bilginin çıkarılmasıdır. Zaman serisi verilerinin tahmininde ise önceki verilere bakılarak gelecek verilerin tahmini yapılır.

Zaman serisi verilerinin analizi istatistiksel/matematiksel analiz, sinyal işleme, özellik çıkartma, örüntü tanıma, makine öğrenme ve derin öğrenme yöntemleriyle yapılmakta, gelecek verilerin tahmini yapılabilmektedir [7],[8],[9]. Zaman serisi verilerinin analizinde ayrıca makine öğrenme algoritmaları da kullanılmaktadır. Kümeleme algoritmaları (Clustering algorithms), yapay sinir ağları (Artificial Neural Network), destek vektör regresyonu (Support Vector Regression), özdüzenleyici haritalar (Self Organizing Maps) zaman serisi verilerinin analizinde kullanılan başlıca makine öğrenme yöntemlerindedir [10],[11]. Ayrıca, son yıllarda önerilen derin öğrenme algoritmalarıyla da zaman serisi verilerinin tahmini yapılabilmektedir. Derin öğrenme (Deep Learning) algoritmaları, çok katmanlı derin yapay sinir ağları (Multi Layer Deep Neural Network), tekrarlamalı yapay sinir ağları (Recurrent Neural Network), uzun kısa vadeli hafıza (Long Short Term Memory), sınırlı Boltzmann makinesi (Restricted Boltzmann Machine), derin düşünce ağları (Deep Belief Networks), otomatik kodlayıcı (Autoencoders) ve konvolüsyonel sinir ağlarından (Convolutional Neural Network) oluşmaktadır [12],[13],[14], [15]. Ancak, literatürde çoğunlukla tekrarlamalı yapay sinir ağları, uzun kısa vadeli hafıza zaman serisi verilerinin analizinde kullanılmaktadır [16].

Zaman serisi verileri bir çok alanda olduğu gibi finans alanında da bulunmaktadır. Finansal alanda kullanılan zaman serisi verileri hisse senedi fiyatları, endeks değerleri, ETF fiyatları, döviz fiyatları olabilmektedir. Zaman serisi verilerinin analizinde finansal teknik analiz göstergeleri kullanıldığı gibi makine öğrenme ve derin öğrenme algoritmaları da kullanılmaktadır. Finansal verilerin analizinde yapay sinir ağları, destek vektör makineleri, hibrit çözümler ve makine öğrenme algoritmaları olarak kullanılmaktadır. Ayrıca, derin öğrenme algoritmalarının gelişmesiyle, finansal verilerin analizinde derin öğrenme yöntemleri kullanılmaya başlanmıştır. Finansal verilerin analizinde çok katmanlı derin yapay sinir ağları, tekrarlamalı yapay sinir ağları, uzun kısa vadeli hafıza, sınırlı Boltzmann makinesi, derin düşünce ağları ve hibrit çözümler, derin öğrenme algoritmaları olarak kullanılmaktadır [17],[18].

## 1.1 Problem ve Motivasyon

Son zamanlardaki gelişmeler ile, finansal alanda, borsa ve piyasa işlemlerinde makine öğrenme, yapay zeka uygulamaları kullanılmaya başlanmıştır. Aynı zamanda, finansal enstrümanların (ETF ve opsiyon işlemleri ve kaldıraçlı sistemler) sayısı da yıllar içerisinde artmıştır. Finansal enstrümanların artmasıyla birlikte, piyasalarda karar verebilen, otonom ve akıllı uzman sistemlerin geliştirilmesi amaçlanmıştır. Bu amaçla çeşitli algoritma ve yöntemler geliştirilmiş ve geliştirilmeye devam etmektedir. Son yıllarda derin öğrenme algoritmalarına dayanan tahmin ve sınıflandırma modellerinin, çeşitli alanlarda kullanılarak iyi performans verdiği görülmektedir. Görüntü, video ve ses işleme alanlarında derin öğrenme algoritmalarının kullanıldığı görülmektedir.

Literatürde derin öğrenme yöntemlerinin finansal alanda da kullanılmaya başlandığı görülmektedir. Tekrarlamalı sinir ağları (RNN) [19] ve uzun kısa dönemli hafıza (LSTM) [20] ağlarının finansal alanda uygulama örnekleri bulunmaktadır. Ayrıca, çalışılan yöntemlerde (RNN, LSTM) kısa zaman içerisinde finansal tahminlerin yapılması sağlanmaya çalışılmıştır. Ancak, literatürde önerilen yöntemlerdeki eksikleri şu şekilde sıralanabiliriz:

- Finansal teknik analiz verilerini yetersiz kullanılması [21] ve/veya hiç kullanılmaması [20], [22], [23], [24],
- Önerilen yöntemlerin her zaman aralığında aynı oranda stabil sonuçları verememesi [20],
- Geleneksel yaklaşımların her zaman kullanılması ve iyileştirilme çalışmaları (SVM [25], [26], SVM-KNN [27], SVR-ANN [28], Fuzzy [21]),



- Derin öğrenme yöntemlerinin sınırlı kullanımı [20], [19] veya hiç kullanılmaması,
- Tahmin performansının iyileştirmelere açık olması,
- Alanın yeni yaklaşımları açık olması.

Özellikle, finansal tahmin modellerinde derin sinir ağlarının uygulanması hala çok sınırlıdır. Bu amaç doğrultusunda, finansal zaman serisi verilerinde, orta ve uzun vadede finansal tahmin yapabilen, yüksek oranda kar elde edilmesi sağlayabilen, stabil kararlar alabilen metot ve modeller geliştirmek hedeflenmiştir. Ayrıca farklı bir bakış açısıyla resim sınıflandırma için kullanılan derin konvolüsyonel ağları kullanılarak literatüre farklı bir bakış açısı kazandırmak amaçlanmıştır. Bu hedefler doğrultusunda, yapay sinir ağları, finansal teknik analiz göstergeleri, genetik algoritma, derin çok katmanlı algılayıcı sinir ağı, derin konvolüsyonel sinir ağları kullanılarak yenilik içeren model ve metotlar geliştirilmiştir.

## **1.2 Tezin Katkıları**

"Problem ve Motivasyon" bölümünde bahsedilen literatürdeki eksiklikler göz önüne alınarak, bu tez kapsamında yapılan çalışmalar ile finansal zaman serisi verilerinde, orta ve uzun vadede finansal tahmin yapabilen, yüksek oranda kar elde etmeyi amaçlayan, stabil kararlar almayı hedefleyen, teknik analiz verileri ile yapay ve derin sinir ağlarını kullanabilen, derin öğrenme yöntemlerini kullanarak yenilikçi yöntemlerin geliştirilmesi hedeflenmiştir. Tez kapsamında, finansal zaman serisi verilerinin analizi için teknik analiz göstergeleri, yapay ve derin sinir ağları, ve evrimsel optimizasyon yaklaşımları kullanılarak, yeni model ve metotlar geliştirilmiştir.

Literatürde finansal analiz ve alım-satım modelleri geliştirilmesine yönelik makine öğrenmesi [24],[22] ve teknik / temel analiz [29] yöntemlerini kullanan çalışmalar mevcuttur. Bu çalışmaların genel yaklaşımları zaman serisi analizini bir regresyon problemi olarak ele alıp sonraki değer tahmini yapmak veya zaman serisindeki tepe ve dip noktalarını belirleyerek alım-satım stratejileri oluşturmak şeklindedir [30]. Bu konuda belirli bir başarımlar sağlanmıştır. Fakat genellikle bu çalışmalar belirli bir hisse senedi / endeks veya varlık için tasarlanmış olup, her durumda işlevini koruyabilecek şekilde genel bir model sonucuna ulaşamamıştır. Bu tez kapsamında bu amaca yönelik olarak hem genel kabul görmüş al-sat stratejilerinden ve hesaplamalı zeka modellerinden daha iyi bir getiri sağlanması amaçlanmak da, hem de geliştirilen modelin genel kullanımı mümkün olabilecek ve daha kontrollü (daha az riskli) çalışması hedeflenmektedir.

Literatürde, parametre eniyilenmesi için çeşitli eniyileme metotları (Genetik Algoritma [31], [21], [32], "Particle Swarm Optimization" [23], "Firework", "Improved Bacterial Chemotaxis Optimization"[33] vs.) kullanılmaktadır. Literatürde çoğunlukla yapay sinir ağı yapısının eniyilenme yaklaşımı önerilmektedir [32]. Tez kapsamında yapılan bu çalışmada, derin çoklu algılayıcı sinir ağı modelinde kullanılacak olan teknik analiz parametrelerinin eğitim verisi için eniyilenmesi hedeflenmektedir. Eniyilenen değerlerle DMLP modeli eğitilerek, tahmin performansının iyileştirilmesi öngörülmektedir. Literatürde, zaman serisi verilerinin analizinde derin öğrenme yöntemleri (RNN [19], LSTM [20]), derin konvolüsyonel sinir ağlarını kullanılma çalışmaları mevcuttur [34], [35], [36]. Ancak, önerilen LSTM çalışmalarında teknik analiz verileri kullanılmadan sadece zaman serisi veriler kullanılmıştır [20]. Ayrıca, önerilen derin konvolüsyonel sinir ağı çalışmalarında, zaman serisi verileri tek boyutlu olarak ya birden fazla kandan alınmaya çalışılmış [35], ya da iki boyutlu verilere çevrilirken sadece zaman serisi verileri kullanılmaya çalışarak sınıflandırma yapılmaya çalışılmıştır [37]. Tez kapsamında bu konuda iki yaklaşım önerilmektedir. İlk yöntem ile, zaman serisi verileri 2 boyutlu çubuk grafik görüntü verisine çevirilmekte ve gelecekteki trend yönü bilgisi hesaplanarak, oluşturulan çubuk grafik görüntüleri etiketlenmektedir. İkinci yöntem ile teknik analiz verileri kullanılarak zaman serisi verileri uygun bir şekilde resim haline getirilmekte, zaman içerisinde değişen fiyatlar üzerine uygulanan etiketleme algoritması ile resimler etiketlenmekte ve etiketlenen resimler derin konvolüsyonel sinir ağı modeline girdi olarak verilmektedir. Önerilen yöntemlerde MNIST algoritmasında kullanılan derin konvolüsyonel sinir ağına benzeyen yapıda konvolüsyonel sinir ağı yapısı kullanılmaktadır [15]. Finansal zaman serisi verilerinin MNIST veri seti gibi resim halinde oluşturulup, derin konvolüsyonel sinir ağı uygulanmasıyla iyi sonuçların elde edilmesi hedeflenmiştir.

Tez kapsamında, dört öneri yapılmıştır. Sunulan yöntemlerin başlıklarını şu şekilde sıralayabiliriz:

- ***Teknik Analiz Verileri Kullanarak Yapay Sinir Ağı ile Finansal Analiz Yöntemi (MLP-TA)***
- ***Genetik Algoritma ile Optimize Edilmiş Teknik Analiz Parametrelerinin Kullanılarak Derin Çoklu Algılayıcı Sinir Ağı Modeli ile Finansal Analiz Yöntemi (DMLP-GA)***
- ***Finansal Zaman Serisi Verilerinin İki Boyutlu Grafik Görüntüsüne Dönüştürülerek Derin Konvolüsyonel Sinir Ağları ile Finansal Analiz Yöntemi (CNN-BI)***

- *Zaman Serisi Verilerinin, Teknik Analiz Verileri Kullanılarak Görüntü Verisine Dönüştürülmesi ve Görüntülerin Derin Konvolüsyonel Sinir Ağları ile Finansal Analiz Yöntemi (CNN-TA)*

Önerilen yöntemler ile;

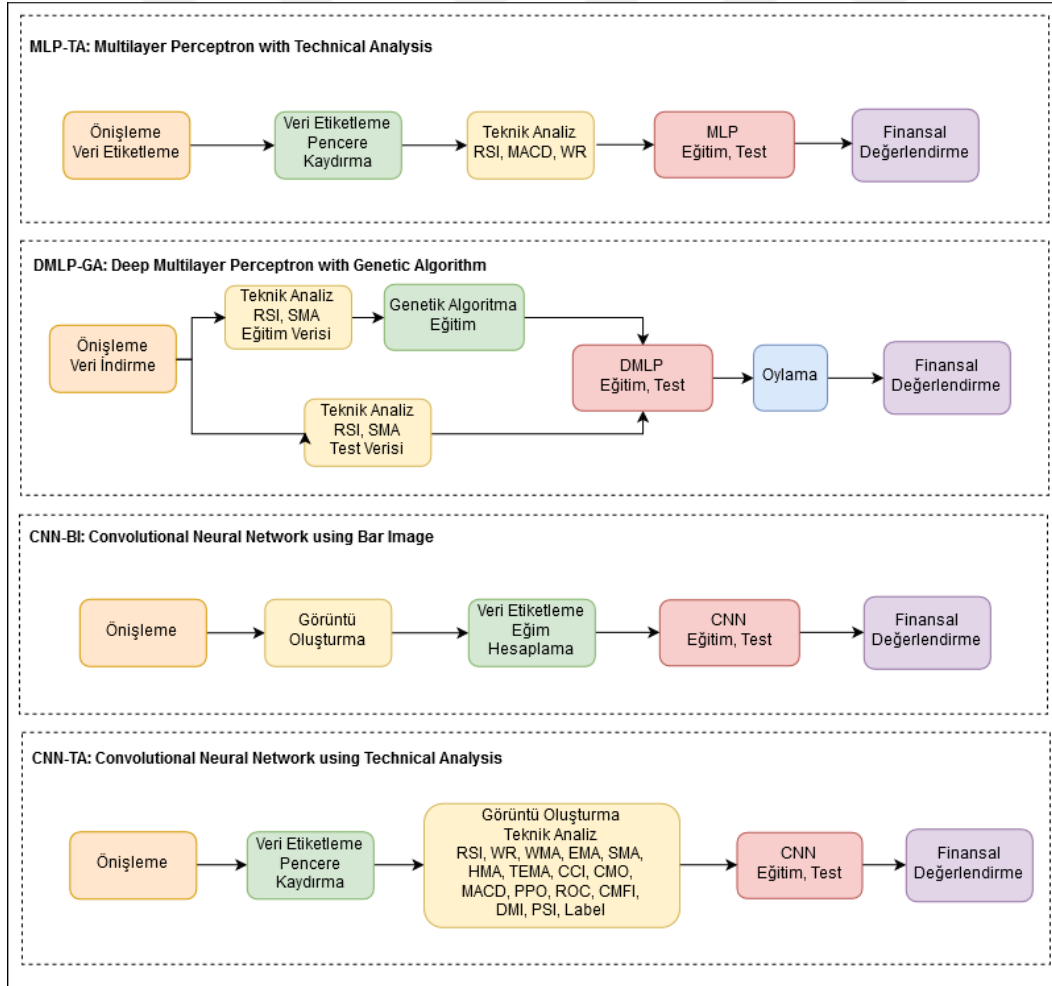
- Finansal zaman serisi verilerinin analizinde derin konvolüsyonel sinir ağları kullanıldı.
- Uzun ve orta vadede tahmin yapabilen, stabil kararlar alabilen yöntem ve algoritmalar geliştirildi.
- Finansal teknik analiz verileriyle derin sinir ağları entegre edilerek yenilikçi algoritma ve modeller önerildi ve geliştirildi.
- Finansal kriz zamanlarında diğer yöntemlere göre daha iyi performans gösterebilen, stabil yöntemler geliştirildi.

### 1.2.1 Önerilen çözüm

Tez kapsamında, "Problem ve Motivasyon" bölümünde bahsedilen literatürdeki eksiklikler ve "Tezin Katkıları" bölümünde bahsedilen literatüre olan katkı göz önüne alınarak, yeni model ve yöntemler geliştirilmiştir. Şekil 1.1'de tüm önerilen model ve yöntemlerin aşamaları gösterilmektedir. Önerilen model ve yöntemler, finansal değerlendirme aşamasında piyasa derinliğine sahip olan Dow-30 ve ETF hisseleri ile değerlendirilmiştir. Yeterli hacime (piyasa derinliğine) sahip olmayan hisseler manipülatif ve spekülatif hareketlere açık olan hisseler olduğundan yeterli piyasa hacmine sahip olan Dow-30 ve ETF hisseleri seçilmiştir.

Birinci modelde (*MLP-TA: "Multilayer Perceptron with Technical Analysis"*), teknik analiz göstergelerini kullanarak yapay sinir ağı tabanlı hisse senedi fiyatı tahmin metodu sunulmaktadır. Önerilen yöntem, finansal zaman serisi verilerini, en çok tercih edilen teknik analiz göstergelerini kullanarak (MACD, RSI, William%R) bir dizi "Al", "Sat", "Tut" sinyallerine dönüştürmektir. Önerilen yöntem ile, Çok Katmanlı Perceptron (MLP) yapay sinir ağı modeli kullanılarak, 1997 ve 2007 yılları arasındaki günlük Dow-30 hisselerinin fiyatları eğitilmektedir. Önerilen modelin sonuçları finansal değerlendirme senaryosundan geçirilerek, "Al&Tut" stratejisinin sonuçları ile kıyaslanmaktadır. "Al&Tut" stratejisi uzun bir zaman diliminde, özellikle hisse senedi piyasasında çoğu stratejiden daha iyi sonuçlara sahip olmaktadır. Bunun sebebi, şirketlerin uzun zaman dilimlerinde kar elde etmeleri, kar fiyatlarının hisse senedi fiyatlarına

yansıması ve uzun zaman dilimlerinde manipülatif hareketlerin sürdürülememesidir. Önerilen MLP-TA modeli, "Al&Tut" stratejisi ile karşılaştırıldığında karışık sonuçlar vermektedir (bazen daha iyi, bazen daha kötü). Bunun nedeni, tüm hisse senetlerinde seçilen teknik indikatörlerin aynı standart değerleri kullanmasıdır. Teknik analizde kullanılan indikatörler ve parametreler için optimizasyon kullanılması hisse senedinde daha iyi tahminlerin yapılmasını sağlamaktadır. Bu çalışmada belirli bir başarı seviyesine ulaşılmasına rağmen MLP'ye girdi olarak seçilen teknik analiz çıktı değerleri RSI (14) ve William%R (10) ve MACD (12,28) değerleri sabit tutularak elde edilmiştir. Teknik analiz parametre değerlerinin dip ve tepe noktalarını en iyi yansıtacak değerler olup olmadığı konusu incelenmemiştir. Bu değerlerin seçilmesinin sebebi piyasa yatırımcıları tarafından en yaygın kullanılan parametreler olmasıdır. Halbuki, bu indikatör parametreleri eniyilenip buna bağlı bir öğrenme modeli oluşturulsa, daha iyi sonuçlar elde etme imkanı ortaya çıkabilecektir. İkinci önerilen yöntemde, bu şekilde bir model üzerinde durulmaktadır.



Şekil 1.1: Önerilen yöntemler

İkinci modelde (**DMLP-GA: "Deep Multilayer Perceptron with Genetic Algorithm"**), genetik algoritma kullanarak "Al-Sat" noktalarını oluşturmak için optimize edilmiş teknik analiz parametrelerine dayanan bir hisse "Al-Sat" sistemi önerilmektedir. Optimize edilmiş parametreler daha sonraki adımda, "Al", "Sat", "Tut" noktalarının belirlenmesi için derin çok katmanlı bir algılayıcı (DMLP) sinir ağından geçirilmektedir. Bu çalışmada belirli bir başarı seviyesine ulaşılmasına rağmen derin çoklu algılayıcı modelinin genetik algoritma ile birlikte çalışması ekstra performans artışı sağlamamıştır. Bunun en önemli sebebi genetik algoritmanın toplam kar kriterine göre eniyileme yapmasıdır. Bu durumda, yerel tepe ve dip noktaları eski önemliliğini yitirmiş olmaktadır. Genetik algoritma toplam karı maksimize ederken ortaya çıkan teknik analiz indikatör parametre çıktıları kısa vadede oluşan "Al-Sat" noktalarını göz ardı edebilmektedir. Halbuki DMLP modeli eğitimi, kısa vade tepe, dip noktalarının sağlıklı bir şekilde tespitine bağlıdır. Bunun sonucunda genetik algoritma ile eniyilenmiş parametrelerden oluşan bir eğitim veri seti DMLP için yetersiz kalmaktadır. Bunun yanısıra, genetik algoritma hem çalışma zamanı olarak (tek bir veriyi bulması gözönüne alındığında) uzun sürmekte hem de elde edilen eniyilenmiş çıktı değerleri (genellikle) birbirlerine çok yakın değerler almaktadır. Bu durum, DMLP için gerekli farklı verilerden oluşan eğitim setinin oluşturulmasına engel olmaktadır. Bu da DMLP'nin genetik algoritma çıktıları yeterli kadar öğrenememesi neden olmuş olabilir. Yine de elde edilen sonuçlar, belirli bir başarıyı sağlamıştır. Ayrıca, elde edilen sonuçlara göre genetik algoritma, DMLP olmadan daha iyi sonuç vermektedir. Bu durum, bize toplam karın maksimize edilmesi sırasında yerel dip ve tepe noktalarının öğrenilmesinin nispeten daha arka planda kalabildiğini göstermektedir. Bu aşamada, DMLP ve genetik algoritma yaklaşımları ile elde edilebilecek sonuçların belirli bir başarıyı aşamadığı gözlemlenmiştir. Son yıllarda, derin yapay sinir ağları içinde sürekli başarıyı artan şekilde ön plana çıkan derin konvolüsyonel sinir ağı şu anda en iyi başarıyı sağlayan derin yapay sinir ağı modeli olarak görülmektedir. Fakat derin konvolüsyonel sinir ağı ağırlıklı olarak 2 boyutlu görüntü sınıflandırma problemlerinde bu başarıyı sağlamıştır. Elde ettiğimiz sonuçları daha da geliştirebilmek amacıyla derin konvolüsyonel sinir ağının 2 boyutlu modellerde elde ettiği başarıyı finansal verilere uyarlamamızın oldukça yenilikçi bir fikir olabileceği söylenebilir. Üçüncü önerilen yöntemde, bu hedefe yönelik geliştirilen bir model üzerinde durulmaktadır.

Üçüncü modelde (**CNN-BI: "Convolutional Neural Network using Bar Image"**), zaman serisi verilerinin 2 boyutlu çubuk grafik görüntülerine dönüştürülmesi ve görüntülerin derin konvolüsyonel sinir ağı kullanılarak tahmin edilme metodu önerilmektedir. Finansal zaman serisi verilerinin 2 boyutlu görüntülere dönüştürmek için, her bir fiyat çubuk grafik olarak gösterilmektedir, sonrasında 30 günlük çubuk grafikler birleştirilerek resim elde edilmektedir. Finansal verilerden 30x30 piksel görüntü dosyaları

oluşturulmaktadır. Her görüntü için gelecekteki trend bilgisi kullanılarak görüntüler "Al", "Sat", "Tut" olarak etiketlenmektedir. Önerilen modelin sonuçları finansal değerlendirme senaryosundan geçirilerek, "Al&Tut" stratejisinin sonuçları ile kıyaslanmaktadır. Önerilen CNN-BI modeli, temel piyasa koşullarından bağımsız olarak (kriz durumu olması ve olmaması durumunda) tutarlı performans sonuçları göstermektedir. Dolayısıyla, pazar koşulları oldukça farklı olsa da, her iki durumda da model neredeyse aynı performans göstermektedir. Bu aşamada elde edilen sonuçlar genetik algoritma ve MLP'nin gerisinde kalmıştır. Bunun muhtemel başlıca sebebi elde edilen görüntülerin "Al-Sat-Tut" kararını verebilecek ayırtıcılığa sahip olmaması olarak düşünülebilir. Bunun en önemli göstergesi işlem başarımlarında kayda değer düşüşten de anlaşılabilir. Fakat yine de elde edilen sonuçlar belirli bir performans istikrarı içermektedir. Nispeten daha az fiyat oynaklığı ile belirli bir başarımlar sağlanmıştır. Elde edilen kısıtlı başarımların sebebi CNN'nin iki boyutlu görüntü olarak kullandığı çubuk görüntülerindeki finansal zaman serisine göre veri kaybıdır. Buna bağlı olarak hem finansal verilerdeki kaybın en düşük şekilde tutulup, hem de iki boyutlu yapının CNN ile kullanılabilir şekilde modellenmesi, istenilen performans başarımlarını getirebileceği öngörülmektedir. Dördüncü önerilen yöntemde, bu amaca yönelik bir model üzerinde durulmaktadır.

Dördüncü modelde (*CNN-TA: "Convolutional Neural Network using Technical Analysis"*), görüntü işleme özelliklerine göre öğrenme yapabilen 2 Boyutlu derin konvülsiyonel sinir ağı kullanan yeni bir algoritmik model önerilmektedir. Finansal zaman serisi verilerinin 2 boyutlu görüntülere dönüştürmek için, her biri 15 farklı parametre seçimi (farklı zaman aralıklarında) olan 15 farklı teknik gösterge kullanılmaktadır. Finansal verilerden 15x15 piksel görüntü dosyaları oluşturulmaktadır. Oluşturulan her görüntü, "Al", "Sat", "Tut" olarak etiketlenerek sınıflandırılmaktadır. Önerilen modelin sonuçları finansal değerlendirme senaryosundan geçirilerek, "Al&Tut" stratejisi, RSI, SMA, LSTM [20], MLP [20] modeli sonuçları ile kıyaslanmaktadır. CNN-TA metodu tarafından üretilen işlem sinyalleri ("Al", "Sat", "Tut") çoğu zaman başarılı (karlı) durumdadır. Test verisi (2007-2017 yılları arası) incelendiğinde, dönem boyunca farklı piyasa koşullarının (yükselen, alçalan, durağan) olduğu gözlemlenmektedir. Ancak, piyasa koşullarındaki bu dalgalanmalar, CNN-TA modelinin genel işlem performansını etkilememektedir. Sonuç olarak, model kötüleşen piyasa koşullarında dahi iyi kazançlar elde etmeyi başarmaktadır. CNN-TA yönteminin performansının daha iyi ölçülmesi için, zaman içerisinde kaydırmalı olarak eğitilip, daha sonrasında testler uygulanmıştır. Uygulanan yöntemde beş yıllık veriler eğitim için kullanılırken, daha sonrasında gelen bir yıllık veriler test için kullanılmıştır. Diğer tüm modellerden daha iyi performans sonuçları elde edilmiştir. Zaman kaydırmalı olarak CNN modelinin eğitilmesiyle zaman içerisinde değişen koşullar modele yansıtılmıştır. Böylelikle kısa ve orta vadede değişen koşullar ile daha iyi tahmin sonuçları elde edilmiştir.

Tez kapsamında yapılan çalışmalar şu şekilde düzenlenmiştir: **Bölüm 2**'de literatürde çalışılan zaman serisi verilerinin analiz yöntemleri, zaman serisi verilerinin analizinde makine ve derin öğrenme yöntemleri anlatılmaktadır. **Bölüm 3**'te finansal zaman serilerinin analizi, finansal teknik analiz göstergeleri, finansal verilerin analizinde makine öğrenme ve derin öğrenme yöntemleri anlatılmaktadır. **Bölüm 4**'te büyük veri tanımı, özellikleri, analizi, depolama ve öğrenme yöntemleri anlatılmaktadır. **Bölüm 5**'te teknik analiz verileri kullanarak yapay sinir ağı ile finansal analiz yöntemi önerilmektedir. Önerilen metot detaylı bir şekilde anlatılmış ve değerlendirilmiştir. **Bölüm 6**'da genetik algoritma ile eniyelenmiş teknik analiz parametreleri kullanılarak, derin çoklu algılayıcı sinir ağı modeli ile finansal analiz yöntemi önerilmektedir. Önerilen metot detaylı bir şekilde ilgili bölümde anlatılmaktadır. **Bölüm 7**'de zaman serisi finansal verilerin iki boyutlu grafik görüntüsüne dönüştürülerek derin konvolüsyonel sinir ağları ile finansal analiz yöntemi önerilmektedir. **Bölüm 8**'de zaman serisi finansal verilerin teknik analiz verileri kullanılarak görüntü verisine dönüştürülmesi ve görüntülerin derin konvolüsyonel sinir ağları ile finansal analiz yöntemi önerilmektedir. Önerilen metot detaylı bir şekilde anlatılmış ve değerlendirilmiştir. **Bölüm 9**'da tüm önerilen yöntemler birbirleriyle kıyaslanmış ve genel olarak değerlendirilmiştir. **Bölüm 10**'da konuyla ilgili çalışmalar ve önerilen yöntemler özetlenmekte ve gelecekte yapılabilecek çalışmalar hakkında fikirler verilmektedir.





## 2. ZAMAN SERİSİ VERİLERİNİN ANALİZİ

### 2.1 Zaman Serisi Verileri

*Zaman serisi verileri*, zaman sıralamalı, belirli bir değeri gösteren verilerdir. Literatürde bir çok alanda zaman serisi verilerinin çalışıldığı görülmektedir. İstatistik [1], sinyal işleme [38], finans [2], [3], [4], ekonometri [5], [4], işletme [6], [4] alanlarında zaman serisi verilerinin analizi yapılmakta ve gelecekteki değerleri tahmin edilmektedir. Bilgisayar ve sensör ağlarının (network, sensor network) verileri, nesnelerin interneti (Internet of Things) verileri, finans (menkul kıymet ve kur fiyatları) verileri zaman serisi verilerine örnektir.

### 2.2 Zaman Serisi Verilerinin Analizi

Zaman serisi verileri bir çok alanda kullanıldığı gibi, farklı yaklaşımlar ile de analiz edilebilmektedir. Zaman serisi verilerinin analizi, alan bağımlı (domain dependent) ve alan bağımsız (domain independent) olarak yapılmaktadır.

*Alan bağımlı (domain dependent)* zaman serisi verilerinin analizinde, farklı alanlardaki zaman serisi verilerinin olmasından dolayı alana bağımlı modellerin ve bu modellerden özelliklerin çıkarılması gerekmektedir. Alan bağımlı zaman serisi verilerinin incelenmesi sırasında alan uzmanı (domain expert) kişilerin modeli oluşturması, çıkarılacak özelliklerin ne olduğuna karar vermesi, çıkarılan özelliklerin verilerin analizinde nasıl kullanacağı hakkında veri analizi yapan sisteme girdi yapması beklenir.

*Alan bağımsız (domain independent)* zaman serisi verilerinin incelenmesinde verilerin yapısına, istatistiksel ve matematiksel analizine bakılarak analiz yapılır. Alan uzmanına ihtiyaç duyulmadan zaman serisi verilerinin analizi yapılabilmektedir. Literatürde, alan bağımsız zaman serisi verilerin incelenmesi konusunda araştırmalar ve çalışmalar şu alt başlıklar altında toplanarak incelenmiştir: İstatistiksel/Matematiksel analiz, sinyal işleme, özellik çıkartma, örüntü tanıma.

### 2.2.1 İstatiksel / Matematiksel analiz

*İstatiksel / Matematiksel analiz* ile zaman serisi verilerde belirli bir pencere içerisinde en küçük, en büyük, ortalama, hareketli ortalama, variance, covariance, standart sapma, otokorelasyon değerlerinin hesaplanmasıdır. Bu analiz zaman serisi verilere ilk aşamada yapılan ön işleme (preprocessing) işlemleridir [7]. Bu işlemler ile orjinal veriler filtrelenir, sinyal hakkında öncelikli bilgiler sağlanabilir (ör: trend)

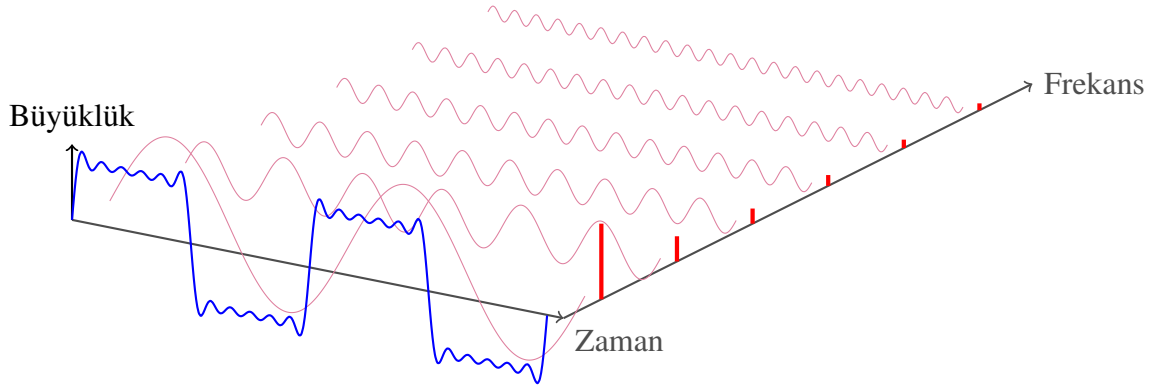
İstatistikte kullanılan yaklaşımlar zaman serisi verilerinin analizinde de kullanılabilir. *Parametrik* (olasılık dağılımının belirli parametrelere bağlı olma durumu) ve *parametrik olmayan* (olasılık dağılımının belirli parametrelere bağlı olmama durumu) yaklaşımlar, zaman serisi verilerinin analizinde kullanılır. Örneğin otoregresyon, hareketli ortalama modelleri kullanılarak zaman serisi verilerindeki parametrik değerlerin bulunması sağlanarak, analizi yapılır. Zaman serisi verilerinde kovaryans ve spektrum tahmini yapılarak, parametrik olmayan yaklaşımlar kullanılır.

Ayrıca matematiksel analiz olarak gelen zaman serisi verileri üzerinde, "curve fitting", regresyon analizi, fonksiyon tahmini uygulanır. "*Curve fitting*" ile matematiksel fonksiyonu tahmin edilen (periyodik olarak kendini tekrar eden zaman serisi verileri sinüs/cosinüs ile ifade edilir) ifadelerin katsayıları geçmiş veriler ile bulunur, gelecekte olabilecek verilerin değerleri tahmin edilir. *Fonksiyon yaklaşımı* ile bilinen matematiksel fonksiyonlar kullanılarak, tahmin edilecek olan matematiksel fonksiyon ifade edilmeye çalışılır. *Regresyon analizi* ile gelen verilerin birbirleriyle olan ilişkisi ölçülür, var olan ilişki matematiksel bir fonksiyonla ifade edilir.

*Otoregresyon hareketli ortalama (autoregressive moving average -ARMA)* ve *otoregresyon entegreli hareketli ortalama (autoregressive integrated moving average -ARIMA)* modelleri ile zaman serisi verilerinin gelecekteki değerleri tahmin edilir. ARIMA, Box-Jenkins metodu olarak da isimlendirilen, George Box, Gwilym Jenkins tarafından 1971'de bulunan, sadece verinin geçmiş zamanındaki değerlerine ve olasılıksal hata terimine bakılarak gelecekteki verinin tahmin edilmesini sağlayabilen matematiksel modeldir [39]. Literatürde ARIMA/ARMA modellerinden elde edilen zaman serisi verilerinin, k-means ve k-medoid algoritmaları ile kümeleme çalışmaları mevcuttur [40].

### 2.2.2 Sinyal işleme

Zaman serisi verilerinden özellik çıkartmanın yöntemlerinden bir tanesi de, zaman serisi verilerine sinyal işleme metotlarının uygulanmasıdır. Fourier dönüşümü (Fourier



Şekil 2.1: Sinyalin frekans bölgesindeki gösterimi

transform) ve dalgacık dönüşümü (wavelet transformation) bu metotların örneklerindedir. Ayrıca sinyal işleme metotlarıyla da orjinal sinyale boyut azaltma yöntemi uygulanır [7]. Fourier ve dalgacık dönüşümü sonrası oluşturulan katsayıların sayısı azaltılarak, sinyal yeniden inşa edilir.

**Fourier serisi**, zaman serisi periodik sinyalin sinusoidal fonksiyonlarla ifade edilmesidir. **Fourier dönüşüm** ise periyodik sinyalin sinüs ve cosinüs fonksiyonlarıyla ifade edilmesidir [41]. Yani Fourier dönüşüm ile ana sinyal birden fazla farklı frekanslı sinusoidal sinyalden oluştuğu kabul edilir, zaman alanından frekans alanına geçilir. Ana sinyalden varolan farklı frekanslar frekans alanında rahatlıkla gözlemlenir. Şekil 2.1 gösterildiği gibi zaman alanındaki sinyalin farklı sinusoidal parçalara bölümünü ve onların frekans alanında sahip oldukları frekans büyüklükleri gözlemlenir.


Sinyalin genel Fourier serisi ile gösterimi Denklem 2.1’de gösterilmektedir.

$$\sum_{j \in B} (a_j \cos(jt) + b_j \sin(jt)) \quad (2.1)$$

Sinyalin Fourier dönüşümü, Denklem 2.2 ile gösterilmektedir. Fourier dönüşümü ile Fourier katsayıları elde edilir. Bu katsayılar özellik vektörüne eklenerek, sinyalin özellikleri çıkartılmış olur. Fourier dönüşüm ile özellik çıkartmanın zaman karmaşıklığı  $O(n \log n)$ ’dir [41].

$$F\{x(t)\} = \int_{-\infty}^{\infty} x(t) e^{-j\omega t} dt \quad (2.2)$$

Diğer zaman serisi verileri işleme adımlarından bir tanesi de dalgacık dönüşümüdür (Wavelet Transformation). **Dalgacık dönüşümüyle** ana sinyal alt sinyaller ile ifade edilir. Denklem 2.3 ile ana sinyalin alt sinyalleri ile ifade edilişi gösterilmektedir. B




Şekil 2.2: Otokorelasyon, çapraz korelasyon ve konvolüsyon işlemleri <sup>4</sup>

kümesi, Dalgacık  $\psi$  dönüşümündeki dalgaların alt kümesidir.  $\phi$  ise bu alt dalgacıkların katsayılarını göstermektedir. Bu katsayılar özellik vektörüne eklenerek, sinyalin özellikleri çıkartılmış olur. Dalgacık dönüşüm ile özellik çıkartmanın zaman karmaşıklığı  $O(n \log n)$ 'dir [41].

$$\sum_{j \in B} (\phi_j \psi_j) \quad (2.3)$$

Zaman serisi verilerinin analizinde diğer metotlar ise sinyalin zaman alanında analizini sağlayan *otokorelasyon (Autocorrelation)*, *çapraz korelasyon (Cross-Correlation)* ve *konvolüsyon'dur (Convolution)*. *Otokorelasyon* sinyalin farklı zamanlarındaki değerlerinin birbirleriyle olan korelasyonudur. Bir sinyalde tekrar edilen örüntülerin bulunması için kullanılır. *Çapraz korelasyon ve konvolüsyon* işlemleri iki farklı sinyalin birbirleriyle olan korelasyonunun bulunması için kullanılan işlemlerdir. Şekil 2.2'de otokorelasyon, çapraz korelasyon ve konvolüsyon işlemleri gösterilmiştir.

<sup>4</sup>[https://upload.wikimedia.org/wikipedia/commons/4/46/Comparison\\_convolution\\_james.png](https://upload.wikimedia.org/wikipedia/commons/4/46/Comparison_convolution_james.png)



Şekil 2.3: Parçalı kümeleme yaklaşımı ile örnekleme [8]

### 2.2.3 Özellik çıkartma


Literatürde, zaman serisi verilerinden özellik çıkartmayı sağlayabilen ve bu özelliklerden analiz yapabilmeyi sağlayan birçok metot bulunmaktadır. Bu metotların başlıcalarını şu şekilde sıralayabiliriz: Ayrık Fourier dönüşümü (Discrete Fourier Transform - DFT), ayrık dalgacık dönüşümü (Discrete Wavelet Transform - DWT) ve parçalı kümeleme yaklaşımı (Piecewise Aggregate Approximation - PAA). Ayrıca verilerin analizi sırasında boyut azaltma (dimensionality reduction), benzerlik ölçümü (similarity measure) metotları da bulunmaktadır [8].

Ayrık Fourier dönüşümü ve ayrık dalgacık dönüşümü metotları bir önceki "Sinyal İşleme" bölümünde de anlatıldığı gibi, sinyalin frekanslarının bulunup, özellik kümesine eklenmesiyle, zaman serisi verilerinin özelliklerinin çıkarılmasıdır.


**Parçalı kümeleme yaklaşımı (Piecewise Aggregate Approximation - PAA)** [42] ise bir diğer özellik çıkartma metotlarından biridir. Bu metotta zaman serisi verileri belirli büyüklükte parçalara bölünür. Her bir parçadaki zaman serisi verisinin ortalaması o parçanın parçalı kümeleme yaklaşım değerini verir [43]. Parçalı kümeleme yaklaşımında,  $n$  uzunluğunda zaman serisi  $T$  verisi  $w$ -boyutlu uzayda  $C$  vektörüyle gösterilir.  $C$  vektörünün  $i$ . elemanı Denklem 2.4'te gösterilmektedir. Bu metot ile örnekleme yapılarak boyut azaltma sağlanır. Şekil 2.3'de gösterildiği gibi verilerden belirli aralıklarda örnekleme yapılarak verinin boyutunda azalma sağlanır.

$$c_i = \frac{w}{n} \sum_{j=\frac{n}{w}(i-1)+1}^{\frac{n}{w}i} c_j \quad (2.4)$$

Veri azaltma yöntemi olarak, ayrıca doğrusal enterpolasyon (linear interpolation) ve algısal açıdan önemli nokta (perceptually important points -PIPs) metotları da vardır. **PIPs** metodu ile finansal uygulamalarda teknik örüntülerin eşleştirmesi sağlanır [44]. Şekil 2.4'de gösterildiği verilerdeki önemli noktalarda örnekleme yapılarak verinin boyutunda azaltmaya gidilir.



Şekil 2.4: PIPs ile örnekleme [8]



Şekil 2.5: Sembolik kümeleme yaklaşımı [43]

**Sembolik kümeleme yaklaşımı** (*Symbolic Aggregate approxImation - SAX*) ise Parçalı kümeleme yaklaşımından esinlenilmiş bir yöntemdir. Bu yöntemde, parçalı kümeleme yaklaşımından elde edilen parçalara kullanıcı tarafından tanımlanmış harfler uygulanır. Böylelikle her bir parça harf karşılığı ile kodlanmış olur. Şekil 2.5 gösterildiği gibi, sinyalden elde edilen parçalı küme değerleri belirli harfler ile etiketlenir [43]. Ayrıca, PAA ve SAX yöntemleriyle verilerde boyut azaltılması uygulanır [7].

Sembolik kümeleme yaklaşımı daha sonra geliştirilerek, Kamath tarafından **Sembolik Kümeleme Yaklaşımı Evrimsel Özellik Üretimi** (*SAX-EFG*) algoritması sunulmaktadır [43]. Bu yöntemde, eğitim verisinden kullanılacak özellikler genetik programlama (GP) algoritmasıyla seçilir. Özellikler, GP ağacında tutulur ve zaman içerisinde GP özelliklerini kullanarak evrimleşir (mutasyon, çaprazlama). EFG, filtre tabanlı uygunluk (fitness) fonksiyonu kullanarak, GP özelliklerinin kullanılabilirliğini tahmin eder. "Hall of fame" yöntemiyle daha sonra kullanılacak olan en iyi tahmin edilmiş özellikler toplanır. Literatürde farklı parçalı yaklaşım temelli çözümler de sunulmaktadır. Bu yaklaşımlardan başlıca olanları şunlardır: Parçalı linear yaklaşım (piecewise linear approximation -PLA), uyarlanabilir parçalı sabit yaklaşım (adaptive piecewise constant approximation - APCA) ve çok çözünürlüklü parçalı kümeleme yaklaşımı (multi-resolution piecewise aggregate approximation - MPAA) [9].

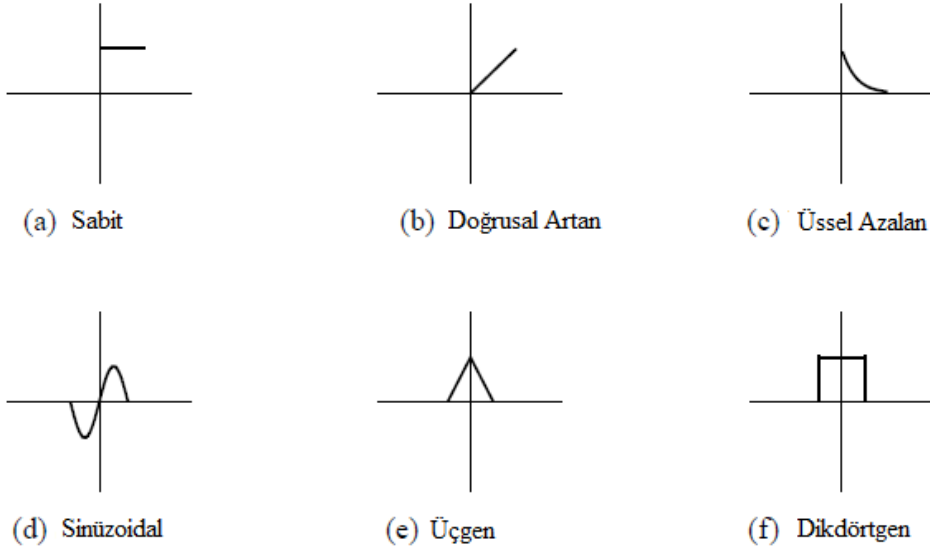
Diğer metotlardan bir tanesi de benzerlik ölçümü yapılmasıdır. **Benzerlik ölçümü** iki şekilde yapılır: Bütün dizinin eşleştirilmesi, alt dizinin eşleştirilmesi. Benzerlik ölçümü sırasında sinyal işlemede çıkan DFT, DWT sonuçlarının katsayılarının birbirlerine olan öklit uzaklığı ile benzerlik ölçümü yapılır. Ayrıca, diğer uzaklık ölçüm metotlarıyla da benzerlik ölçümü literatürde mevcuttur (Constrained-based, Geometrik uzaklık) [8]. Bir diğer popüler benzerlik ölçümü metodu ise "**Dynamic Time Warping (DTW)**" dir [45]. İki zaman serisinin birbirleriyle olan benzerlik ölçümü DTW ile yapılır.

Literatürde, özellik çıkartma; boyut azaltma, kümeleme analizi (Clustering Analysis), ve özellik seçme (Feature Selection) ile eşanlı olarak görülmektedir. Görüntü işlemede aslında belirli özelliklere göre verinin azaltılması ve benzer örüntülerin bulunması amaçlanmaktadır. Benzer durum zaman serisi verilerinde de geçerlidir. Bu tip verilerde aykırı noktaların tespiti için, benzer durumları bulmak için özellik çıkartımı yapılır [7]. Belirli işlemlerden geçen zaman serisi verilerinde aykırı noktalar kümeleme işlemleri (Clustering, Markov Chains, Hidden Markov Model) bulunur. **Kümeleme (Clustering)** algoritmasıyla benzer noktalar gruplanır. "K-Means" algoritmasıyla zaman serisi verileri gruplanarak aykırı veriler ortaya çıkarılır. **Markov zinciri** ile zaman serisi verilerinde aykırı verilere gelme olasılığı düşük olacağından dolayı bu noktalar kolay tespit edilir (Markov zinciri zaman serisi verilerin, frekanslarına göre oluşturulur). "Hidden Markov Model" ile "K-Means" algoritmasındaki gibi sinyal farklı gruplara ayrılır [7].

#### 2.2.4 Örüntü tanıma

Literatürde, zaman serisi verilerinden örüntü tanıma çalışmaları da yapılmaktadır. Literatürde çalışılan alanlar şu şekilde sıralanır: Yapısal analiz [41], [9], [46], sıklıkla oluşan örüntülerin tespiti [47], ilginç örüntülerin bulunması [48], anomali durumlarının tespiti [49], [50] ve motif tespiti [51]. Literatürdeki zaman serisi verilerinden örüntü bulma çalışmaları [8]'de araştırılmış ve özetlenmiştir.

Zaman serisi verilerinin analizinde yapısal analiz de uygulanmaktadır. **Yapısal analiz** uygulanırken zaman serisi verilerinin yapısal özelliklerine dikkat edilir. Zaman serisi verileri, özellikle modülasyonu yapılarak aktarılan sinyallerde (ör: elektrik akımı), sabit (zamana göre değişmeyen), sabit hızlı artan veya azalan, exponensiyel hızda artan veya azalan, sinüzoidal değişen, üçgen veya dikdörtgen yapıya sahip olabilir. Bu özelliklerin tespiti için yöntemler geliştirilmiştir. Zaman serisi verileri parçalara ayrılarak, incelenir. Şekil 2.6'da gösterildiği gibi zaman serisi verileri "sabit", "doğrusal artan", "üssel azalan", "sinüzoidal", "üçgen" ve "dikdörtgen" sınıflandırılır [41].



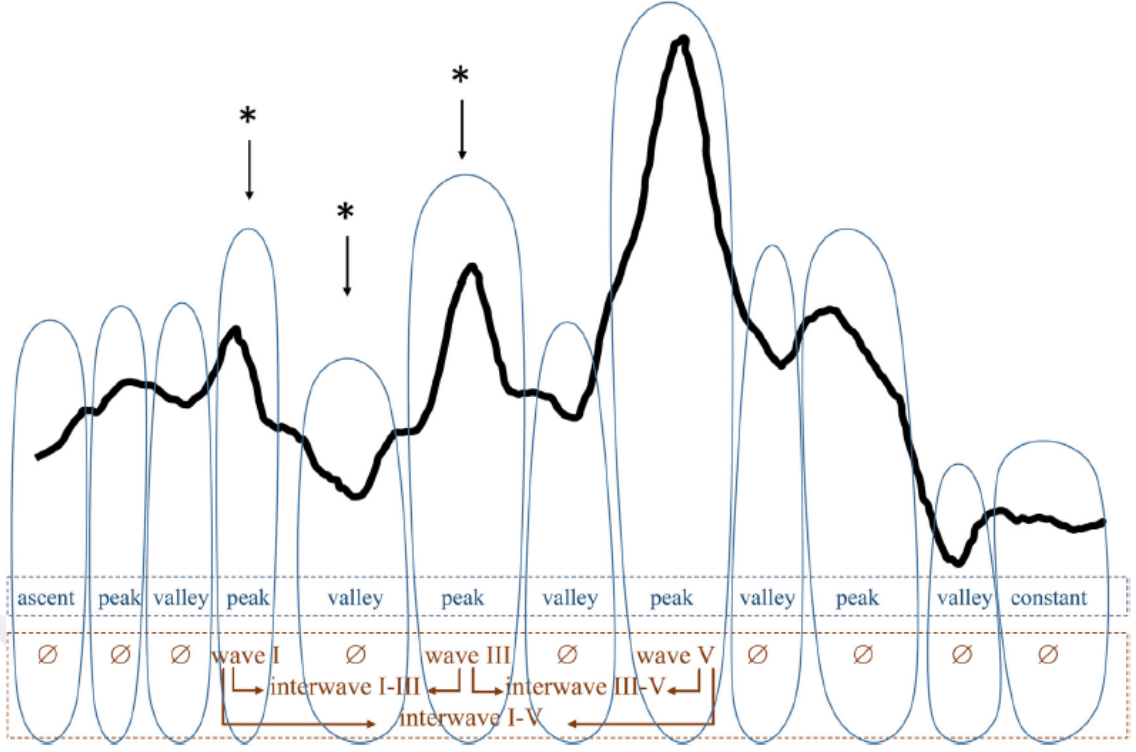
Şekil 2.6: Modülasyonu yapılarak aktarılan sinyallerin örüntüleri [41]

Sinyalin yapısal durumuna bakılarak, sinyaldeki yapısal değişimler iki farklı şekilde etiketlenir. Sinyal alan-bağımsız olarak değerlendirildiğinde, sinyaldeki değişimler "zirve", "vadi", "çıkan", "düşen", "sabit", "dalga tepesi" olarak etiketlenebilir. Sinyal alan-bağımlı değerlendirildiğinde ise alana bağlı olarak farklı etiketlendirmeler yapılır. Molina [9], çalışmasında beyine gelen işitme verilerini alan-bağımlı ve alan-bağımsız olarak etiketlenmiştir. Şekil 2.7'de gösterildiği gibi zaman serisi verileri "zirve", "vadi", "çıkan", "düşen" olarak alan-bağımsız etiketlenirken, "dalga1", "dalga3", "dalga5" olarak alan-bağımlı olarak etiketlenmiştir.

Zaman serisi verilerinden örüntü tanımlama işlemi sırasında ayrıca istatistiksel analiz ve sinyal işlemeden de faydalanılmaktadır. **Özdeşlik Dönüşümü (Identity Transformation)** ile sinyal özellik sayısı kadar birim vektörlere (unit vector) dönüştürülerek ifade edilir. Fourier dönüşüm ile sinyal sinüs ve cosinüs sinyaller olarak ifade edilir, sinüzoidal değişen sinyal, farklı frekans içeren sinyallere ayrılır. **Dalgacık dönüşümü (Wavelet Transformation)** ile de sinyal farklı frekanslara ayrılır. Farklı frekanslı zaman serisi verileri ana sinyalin özellikleri olarak kullanılır. Böylelikle sinyalin örüntüsü belirlenir [41]. Ayrıca, farklı frekanslara ayrılan sinyaller yapay sinir ağına girdi olarak verilerek, sınıflandırılır [52].

Olszewski [41] tarafından önerilen algoritma (Structure Detector) zaman serisi verilerinin alt bölümlere bölündükten sonra daha önce tanımlanmış sinyal örüntüleriyle (sabit, doğrusal, üssel, sinüzoidal, üçgen ve dikdörtgen değişen) sınıflandırılması ve bu alt bölgelerdeki sinyallerin birleştirilmesiyle örüntünün anlamlandırma işlemidir.





Şekil 2.7: Beyne gelen işitme verilerinin etiketlenmesi [9]

Önerilen algoritma (Structure Detector), özdeşlik, Fourier, dalgacık dönüşümleriyle zaman karmaşıklığı, güçlü ve zayıf yönlerinden kıyaslanmıştır. Önerilen algoritma zaman karmaşıklığı yönünden diğerlerinden zayıf kalmaktadır (Algoritmanın zaman karmaşıklığı  $O(n^3)$ , fourier ve wavelet dönüşümlerinin zaman karmaşıklığı  $O(n \log n)$ , özdeşlik dönüşümünün ise  $O(n)$ 'dir <sup>5</sup>), ancak diğer istatistiksel, sinyal işleme yöntemlerine göre genel amaçlı bir yöntem sunmaktadır. Diğer yöntemlerde sinyalin genel özellikleri çıkarılırken, önerilen yöntemde sinyalin yapısına göre inceleme yapılır, önceden tanımlanmış sinyal örüntüleriyle sinyalin örüntüsü tanımlanır.

Xue tarafından sensör ağlarında örüntü tabanlı olay tespiti yaklaşımı sunulmaktadır. Bu yaklaşımda sensör verilerinin örüntüleri matematiksel olarak önceden tanımlanır (yatay, eğimli, osile eden, atlama yapan, keskin değişen). Tanımlanan duruma göre anlık veriler kıyaslanarak, o anki durumun hangi örüntüye uyup uymadığı analiz edilir. Böylelikle sensör verilerinin belirli bir örüntüye uygun olup olmadığı belirli sorgularla sorgulanabilir [46].

<sup>5</sup>Algoritmanın zaman karmaşıklığı girdi sayısı ile orantılıdır, yani zaman karmaşıklığında kullanılan "n" ifadesi girdi sayısını belirtmektedir.

### 2.3 Zaman Serisi Verilerinin Analizinde Makine Öğrenme

Zaman serisi verilerinin analizinde geleneksel yaklaşımlardan farklı olarak makine öğrenme yöntemi yaklaşımları da kullanılmaktadır. **Makine öğrenme algoritmaları** sayesinde geleneksel modellere bağlı kalmadan yeni modeller, gelen verilerle oluşturulur. Yeni oluşturulan modeller kullanılarak, verilerde ikili, çoklu sınıflandırmalar yapılabilir gibi gelecek verilerin tahmini yapılır. Makine öğrenme algoritmaları, gözetimli öğrenme (supervised learning), gözetimsiz öğrenme (unsupervised learning) ve destekli öğrenme (reinforcement learning) olarak üç ana daldan oluşur.

**Gözetimli öğrenme** yönteminde, gelen veriler kullanılarak model oluşturulur. Oluşturulan model sayesinde gelen veriler sınıflandırılır. Gözetimli yöntemde, model oluşturma aşamasında eğitim verisi kullanılır. Modelin başarısı ise test verisi kullanılarak test edilir. Zaman içerisinde çeşitli gözetimli öğrenme yöntemleri geliştirilmiştir. Yapay sinir ağları, Bayesian ağlar, karar ağaçları, gizli Markov modelleri, destek vektör makineleri başlıca kullanılan gözetimli öğrenme algoritmalarındandır.

**Gözetimsiz öğrenme** yönteminde, gelen veriler kümelenecek, gruplanarak verilerin sınıflandırması sağlanır. Gözetimli öğrenmeden farklı olarak bu yöntemde gelen veriler etiketlenmemiştir. Veriler etiketlenmeden belirli özelliklere göre gruplanırlar. K-Means, özdüzenleyici haritalar (self organizing maps - SOM) başlıca kullanılan gözetimsiz öğrenme algoritmalarındandır.

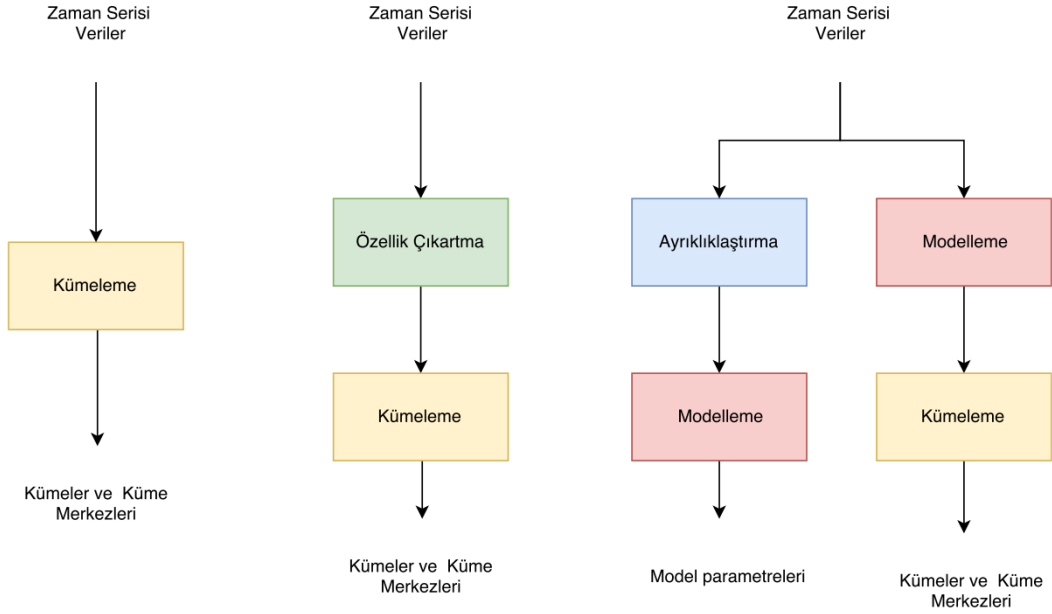
**Destekli öğrenme**, çıkan sonuçlardan maksimum verimin alınması için uygulanan makine öğrenme algoritmasıdır. Oyun teorisi, kontrol teorisi, bilgi teorisi, simülasyon-tabanlı optimizasyon, istatistik, genetik algoritma gibi bir çok alanda kullanılır.

Zaman serisi verilerinin analizinde bir ya da birden fazla makine öğrenme algoritmaları kullanılmaktadır. Literatürde başlıca kullanılan makine öğrenme algoritmaları aşağıdaki başlıklar altında incelenmiştir. Birden çok makine öğrenme metodu içeren çalışmalar ise bu bölümde anlatılmıştır. Ahmed, çalışmasında [11] zaman serisi verilerinin analizi için olan makine öğrenmelerin bir çoğunu aralarında kıyaslamıştır. Çalışmasında zaman serisi verilerinin tahmini için çok katmanlı algılayıcı (Multi layer perceptron), Bayesian sinir ağı, radyal tabanlı fonksiyonel sinir ağı (radial basis function neural network), genelleştirilmiş regresyon sinir ağı (generalized regression neural network), k en yakın komşu regresyonu, sınıflandırma ve regresyon ağaçları, destek vektör makine regresyonu, gaussian (gaussian process) modellerini kullanmış ve birbirleriyle kıyaslamıştır. Bu modellere, verileri girdi olarak vermeden önce belirli önışlemlerden (Lagged-Val, Diff, Moving-Average) geçirmektedir. "Lagged-Val" önışleme sonucunda, makine öğrenme modelindeki girdi değişkenleri gecikmiş zaman

serisi deęerleri oluřturmaktadır. "Diff" ile geriye doęru zaman serisi verilerinde ilk fark alınmakta ve tahmin modeli bu farklı zaman serisi verilerine uygulanmaktadır. "Moving-Average" ile zaman serisi verilerinde farklı boyutlu pencerelerden hareketli ortalamalar hesaplanmaktadır.

### 2.3.1 Kmeleme algoritmaları

Zaman serisi verilerinin analizinde *kmeleme (clustering)* algoritmalarından da yararlanılır. Őekil 2.8'de gsterildięi gibi zaman serisi verilerinde kmeleme algoritmaları ç yaklařım ile uygulanır: Ham veri temelli, zellik temelli, model temelli yaklařımlar. Ham veri temelli yaklařım ile zaman serisi verileri herhangi bir niřleme tutulmadan kmeleme algoritmaları (K-means, similarity measures, etc.) uygulanmaktadır. zellik temelli yaklařımda verilerden zellikler ıkarılır, ıkarılan zelliklere kmeleme algoritmaları uygulanmaktadır. Model temelli yaklařımda ise zaman serisi verilerine modelleme uygulanır, modelleme sonrasında ıkan katsayılar ve parametrelere kmeleme algoritması uygulanmaktadır. Literatrde, model temelli yaklařımlarda, ARMA, AR, Hidden Markov Model, Markov Chain modellerinin parametre ve katsayıları kullanılmaktadır. [4].



Őekil 2.8: Kmeleme yaklařımları [4]

Genellikle, kümeleme algoritmalarını kullanırken *uzaklık-temelli (distance-based) kümeleme yaklaşımı* kullanılmaktadır [53]. Bu genel yaklaşımda, önce kümeleme merkezlerinin sayısı ve yerleri tanımlanmaktadır. Her iterasyonda gelen verinin hangi merkez noktaya yakınlığı bulunur ve merkez noktanın yeri güncellenmektedir. Kümeleme yaklaşımında, ilk küme merkezleri farklı şekillerde seçilebilmektedir: Rastgele seçim veya belirli sırada seçim. Ayrıca küme merkezlerinin sayısı ve yerlerinin güncellenmesi de yaklaşımın çeşitlendirilmesi için kullanabilmektedir [8].

Literatürde farklı zaman serisi verilerine, farklı kümeleme algoritmaları uygulanmaktadır. Ham veri temelli yaklaşımlar farklı çalışmalarda [54], [55], [56], [57], [58] uygulanmıştır. Golay [54], MRI beyin aktivite ham verisine öklit temelli uzaklık ölçümü, "fuzzy c-means" kümeleme algoritması uygulamıştır. Möller-Levet [55], DNA mikrodizi verilerine kısa zaman serisi uzaklık ölçümü, fuzzy c-means algoritması uygulamıştır. Shumway [56] ve Kakizawa [57], deprem ve maden patlama ham verisi üzerine "agglomerative" hiyerarşik kümeleme algoritması uygulamışlardır. Liao [58], savaş simülasyonu verilerine üzerine "k-means" ve "fuzzy c-means" algoritmaları uygulamıştır.

Özellik temelli yaklaşımlar da farklı çalışmalarda [47], [59] uygulanmıştır. Fu [47], Hong Kong borsa verilerinden PIP (perceptually important points) noktalarını özellik olarak çıkartmıştır. Daha sonra verilere mesafe ölçümü ve SOM kümeleme algoritmaları uygulanmıştır. Goutte [59], MRI beyin aktiviteleri verilerinden çapraz korelasyon özelliklerini çıkartarak, çıkan özelliklere (agglomerative) hiyerarşik kümeleme algoritması uygulamıştır.

Literatürde model temelli yaklaşımlı [60], [61], [62] çalışmalarını verir. Baragona [60], Xiong ve Yeung [61] zaman serisi verilerinin üzerine ARMA modeli uygulamış, çıkan katsayıları genetik algoritma, "simulated annealing", "expectation maximization learning" algoritmalarıyla kümelemiştir. Ramoni [62], robot sensor verileri üzerinde Markov zinciri modeli uygulamış, modelden çıkan geçiş ihtimallerine (transition probabilities) "agglomerative" hiyerarşik kümeleme algoritması uygulamıştır.

### 2.3.2 Yapay sinir ağları

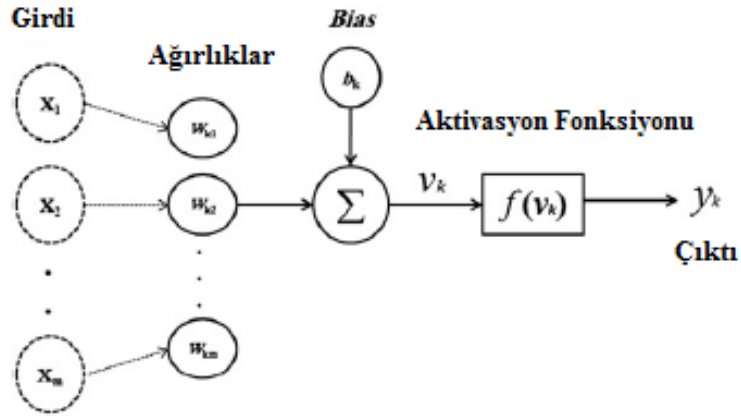
*Yapay sinir ağları*, beyindeki nöronların çalışma prensibini taklit eden matematiksel modellerdir. Şekil 2.9'da gösterildiği gibi bir nörona gelen girdiler belirli ağırlıklarla çarpılarak toplanır, daha sonra belirli bir aktivasyon fonksiyonundan geçirildikten sonra çıktı olarak sistemden çıkmaktadır. Denklem 2.5'te gösterildiği gibi tüm nöronların girdi değerleri ( $x$ ) ağırlık değerleriyle çarpılarak ( $w$ ), eşik (bias) değeri ( $b$ ) ek-

lenmektedir. Çıkan değer Denklem 2.6'da gösterildiği gibi aktivasyon denkleminde geçirmektedir. Aktivasyon fonksiyonu olarak genellikle sigmoid fonksiyonu kullanılmaktadır. Şekil 2.10'da ve Denklem 2.7'de sigmoid fonksiyonları gösterilmiştir.


$$v_k = \sum_{j=1}^m x_j w_{kj} + b_k \quad (2.5)$$

$$y_k = f(v_k) \quad (2.6)$$

$$y(v_i) = \tanh(v_i) \text{ veya } y(v_i) = (1 + e^{-v_i})^{-1} \quad (2.7)$$




Şekil 2.9: Nöron yapısı [63]



Şekil 2.10: Sigmoid fonksiyonu [63]

Şekil 2.11'de gösterildiği gibi katmanlarda bulunan sinir hücreleri diğer katmanlardaki

sinir hücreleri ile bağlantılar kurmaktadır. Şekil 2.11'deki gibi sinir ağları genellikle üç katmandan oluşmaktadır: Girdi katmanı, gizli katman ve çıktı katmanı. Literatürde farklı yapay sinir ağ çeşitleri bulunmaktadır. Genel olarak yapay sinir ağları ikiye ayrılır: İleri beslemeli yapay sinir ağları (feedforward neural network), tekrarlayan sinir ağları (recurrent neural network).



Şekil 2.11: Basit çok katmanlı algılayıcı [63]

İleri beslemeli sinir ağlarında sinirler arasındaki bağlantılarda çevrim (cycle) veya döngü (loop) bulunmamaktadır. İleri beslemeli sinir ağlarında bilgi ileri katmanda bulunan sinir ağlarına aktarılmaktadır. **Çok katmanlı algılayıcı (multilayer perceptron - MLP)** bir çeşit ileri beslemeli bir sinir ağıdır. Çok katmanlı sinir ağında sinirler bir-biriyle tamamen bağlıdır (fully connected), yani bir katmandaki sinir hücresinden diğer katmandaki bütün sinir hücrelerine bağlantılar bulunmaktadır. Çok katmanlı sinir ağında en popüler öğrenme yöntemi geriye yayılımdır (back propagation). Çıktı katmanındaki hata değerlerini minimize etmek için geride bulunan katmanlar arasındaki nöronların ağırlıklıkları, her bir geri yayılım iterasyonu ile güncellenmektedir. Yani, öğrenme sırasında bağlantılardaki ağırlıklar zamanla değişmektedir. Belirli bir tekrarlama sonra ağırlıkların değişmesi azalır, artık o andan itibaren sistem öğrenmiş olmaktadır.

Denklem 2.8'de gösterildiği gibi çıktı düğümü  $j$ 'deki hatanın hesaplanması ( $e_j(n)$ ) için, hedeflenen değer  $d_j(n)$ 'den, o anki nöronun ürettiği  $y_j(n)$  değeri çıkarılmaktadır.

$$e_j(n) = d_j(n) - y_j(n) \quad (2.8)$$

Daha sonra, tüm çıktındaki hatayı en aza indirmek için düğümlerin ağırlıklarında düzeltmeler yapılmaktadır. Denklem 2.9'da tüm düğümlerdeki hatalar bulunur.

$$\varepsilon(n) = \frac{1}{2} \sum_j e_j^2(n) \quad (2.9)$$

Denklem 2.10'da "gradient descent" (gradient descent; yerel minimumu bulmak için kullanılan birinci derece tekrarlamalı optimizasyon algoritmasıdır) algoritması kullanılarak, her ağırlıklandırmadaki değişiklikler güncellenmektedir. Denklem 2.10'daki  $y_i$  bir önceki nöronun çıktısını oluştururken,  $\eta$  ise öğrenme oranıdır.

$$\Delta w_{ji}(n) = -\eta \frac{\partial \varepsilon(n)}{\partial v_j(n)} y_i(n) \quad (2.10)$$

**Tekrarlayan sinir ağları (recurrent neural network)** bir çeşit yapay sinir ağı olup, sinir bağlantıları arasında yönlü çevrimler (directed cycle) içermektedir. Böylelikle tekrarlayan sinir ağları dinamik bir hafızaya kavuşmuş olur. Farklı tekrarlayan sinir ağları bulunmaktadır. Tekrarlayan sinir ağları, Bölüm 2.4'de detaylı olarak incelenecektir.

Yapay sinir ağları zaman serisi verilerinin tahmini için bir çok alanda kullanılmaktadır. Literatürde 1990'dan beri önemli çalışmalar yer almaktadır. Arizmendi [64], zaman serisi verilerinde yapay sinir ağlarını kullanarak havadaki polen konsantrasyonlarında belirli tahmin çalışmaları yapmıştır. Yapay sinir ağları ile yaptığı tahminler, geleneksel yaklaşımlardan daha iyi sonuç vermiştir. Srinivasan [65], güç sistemindeki saatlik elektrik yükünü tahmin edebilmek için dört katmanlı ileri beslemeli yapay sinir ağı kullanmıştır. Yapay sinir ağı ile tahminlerinde %1.80 hata oranıyla başarı olmuştur. Kaastra ve Boyd [66], finansal ve ekonomik zaman serisi verilerinin tahmininde yapay sinir ağı modeli içeren sekiz basamaklı bir prosedür geliştirmişlerdir. Ansu [67], ARIMA modeli ile yapay sinir ağı modelini Brezilya'daki satışların tahmini için kıyaslamıştır. Yapay sinir ağı modelinin daha iyi sonuçlar verdiği görülmüştür. Zhang ve Hu [68], Pound/Dolar kurunun tahmininde yapay sinir ağlarını uygulamışlardır. Yapay sinir ağındaki girdi ve gizli katmandaki nöronların sayısının ve veri büyüklüğünün model performansına olan etkilerini değerlendirmişlerdir. Girdi katmanındaki nöron sayısının, model performansına olan etkisinin diğer parametrelerden daha etkili olduğu görülmüştür. Bezerianos [69], radyal tabanlı fonksiyon sinir ağı (RBF) ile nabız değişikliğinin tahmini ve değerlendirmesini yapmıştır. Li [70], cihazlarla ölçülmekte

zorlanılan, yüksek binalarda oluşan titreşimlerin en yüksek değerlerinin tahmini için geri yayımlı yapay sinir ağı (BPANN) ve otoregresif (AR) modellerini oluşturmuştur. Nguyen ve Chan [71], benzin istasyonundaki saatlik müşteri tahminini yapabilmek için çoklu yapay sinir ağı yaklaşımı kullanmıştır. Aynı veri üzerine çoklu sinir ağı uygulaması, tekli sinir ağının uygulamasından daha iyi sonuç vermiştir. Hansen ve Nelson [72], gelir verilerini kullanarak ekonomik bir tahmin yapabilmek için yapay sinir ağı ile geleneksel zaman serisi tahmin metotlarını daha iyi sonuç almak için birlikte kullanmışlardır. Yapay sinir ağları ve geleneksel metotların birlikte kullanımı, tek tek kullanımdan daha iyi sonuçlar vermiştir. Kalaitzakis [73], kısa vadeli elektrik yük tahmini için, radyal tabanlı fonksiyon sinir ağı (RBF), Gaussian kodlama geri yayımlı sinir ağı ve tekrarlayan sinir ağı (RNN) yaklaşımlarını içeren birden fazla yöntemi araştırmış ve uygulamıştır. Sundukları yöntem, otoregresif ve geri yayımlı yapay sinir ağlarına göre daha iyi sonuçlar vermiştir. Ayrıca, 24 saatlik elektrik yükünü tahmin edebilmek için paralel işlem yaklaşımını sunmuşlardır. Zhang [74], ARIMA ve yapay sinir ağı modellerinin avantajlarını kullanarak gerçek veri kümelerinin analizi için hibrit bir model sunmuştur. Sunduğu hibrit model, iki modelin ayrı ayrı kullanılmasından daha verimli bir tahmin geliştirme sonucu elde etmiştir. Gao ve Er [75], doğrusal olmayan dışsal girdili otoregresif hareketli ortalama modeli (non-linear autoregressive moving average with exogenous inputs - NARMAX) ile ileri beslemeli ve tekrarlayan metotları kullanan bulanık yapay sinir (fuzzy neural networks -FNNs) ağı modelini oluşturmuşlardır.

Ayrıca, yapay sinir ağları zaman serisi verilerinin analizi için nesnelerin interneti (Internet of Things - IoT), insanların aktiviteleri tanımı (human activity recognition) alanlarında da kullanılmaktadır. Guan [76], 40 adet hareket sensörünü insanın bacaklarına yerleştirerek, gelen verileri geri yayımlı yapay sinir ağında analiz etmiştir. İnsanın aktivitelerinin (koşma, yürüme, yatma, zıplama, vs.) tahmini için kullanılan bu mekанизmada %97'lere ulaşan oranla yapılan aktivite doğru olarak tahmin edilmiştir. Saeedi [77], akıllı telefondaki sensörleri (dönüölçer, ivmeölçer, manyetometre, sıcaklık ve GPS (küresel konumlama sistemi)) kullanarak, kişinin hareketlerini ve gün içerisinde aktivitelerini geri yayımlı yapay sinir ağı ile analiz etmiştir. Choi [78], ise yapay sinir ağlarını akıllı ev sisteminin öğrenme kısmında kullanmıştır. Mishra [79], IoT büyük verilerinin işlenmesi için çok katmanlı algılayıcı ve bulanık nöro genetik algoritma uygulamıştır. Görüldüğü gibi birçok alanda yapay sinir ağları, zaman serisi verilerinin analizi için kullanılmıştır.



### 2.3.3 Destek vektör makineleri regresyonu

*Destek Vektör Makineleri (Support Vector Machines - SVM)* bir çeşit gözetimli öğrenme, doğrusal sınıflandırma algoritmasıdır. Sınıflandırma ve regresyon için kullanılmaktadır. Literatürde, zaman serisi verilerinin analizinde diğer makine öğrenme yöntemleri ile birlikte kullanılmaktadır. Cao [80], çalışmasında zaman serisi verilerinin gelecek tahminini yaparken iki kademeli bir yöntem kullanmıştır. İlk kademe verileri özdüzenleyici harita algoritmasıyla (SOM) gruplandırarak ağaç yapısını oluşturmuş, ikinci aşamada ise verilere SVM yöntemini uygulamıştır. Ahmed [11], zaman serisi verilerinin analizi için SVM algoritmasını diğer algoritmalarla karşılaştırmak için kullanmıştır. Mohandes [81], çalışmasında zamanla değişen rüzgar hızı verilerine, SVM ve MLP yöntemlerini uygulamış ve elde ettiği sonuçları birbirleriyle kıyaslamıştır. Elde ettiği sonuçlarda SVM yönteminin belirli durumlarda daha iyi sonuç verdiğini göstermiştir.

### 2.3.4 Özdüzenleyici haritalar

Literatürde zaman serisi verilerinin analizinde *özdüzenleyici harita (self-organizing map - SOM)* algoritmaları kullanılmaktadır. Özdüzenleyici haritalar bir çeşit yapay sinir ağlarıdır, gözetimsiz eğitilmektedir [10]. Özdüzenleyici haritaların eğitimi sırasında rekabetçi öğrenme (competitive learning) kullanılır. Eğitim sonrasında yeni gelen verilerin sınıflandırılması yani haritalandırma metodu kullanılır. Literatürde özdüzenleyici haritalar, tıp ve finans alanlarındaki zaman serisi verilerinin üzerinde uygulanmıştır. Tıp alanında, kas aktivitelerinin örüntülerinin çıkarılması ve çıkarılan örüntülerin anlamlandırılması için özdüzenleyici haritalar kullanılmıştır [82]. Finans alanında, finansal verilerin tahmini için veriler (açılış, kapanış, yüksek ve düşük fiyatlar) girdi olarak özdüzenleyici haritalara verilmiş, çıkan sonuçlara göre tahminler yapılmıştır [83].

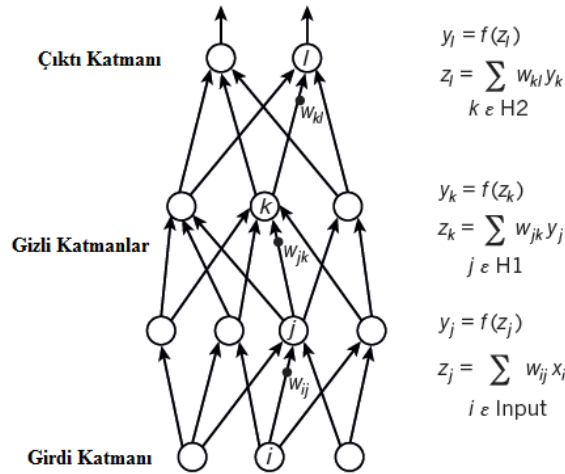
## 2.4 Zaman Serisi Verilerinin Analizinde Derin Öğrenme

*Derin öğrenme* bir makine öğrenme yöntemidir. Derin sinir ağları, klasik, sıg yapay sinir ağları yerine, çok fazla katmandan oluşan bir yapıya sahiptir. Katmanlar, özellik çıkartma ve dönüştürme işlemleri için birçok doğrusal olmayan işlem birimi içerir ve her ardışık katman, bir önceki katmandaki çıktıyı girdi olarak kullanmaktadır. Derin öğrenme ile önceden belirli özellikler çıkartılmadan katmanlar üzerinde alt seviye özellikler çıkartılır ve üst düzey özellikler, alt düzey özelliklerden türetilerek hiyerarşik bir temsil oluşturur. Derin sinir ağları ile görüntü, video, konuşma, ses, metin işleme

işlemleri gerçekleştirilir. Derin sinir ağları tipik bir ileri beslemeli ağları gibi tasarlanmıştır. Zaman içerisinde farklı problemlerin çözümleri için farklı yapıda derin sinir ağları geliştirilmiştir. Çok katmanlı derin yapay sinir ağları , tekrarlamalı sinir ağları (Recurrent neural networks -RNN), uzun kısa vadeli hafıza (Long Short Term Memory -LSTM), sınırlı Boltzmann makinesi (Restricted Boltzmann Machine - RBMs), otomatik kodlayıcı (Autoencoder), konvolüsyonel derin sinir ağları (Convolutional deep neural networks - CNNs) literatürde geliştirilen derin sinir ağları modelleridir. Bu bölümde geliştirilen derin sinir ağları alt başlıklar halinde incelenecektir.

#### 2.4.1 Çok katmanlı derin yapay sinir ağları (DMLP)


**Çok katmanlı derin yapay sinir ağları (Deep multilayer perceptron - DMLP)**, ilk geliştirilen yapay sinir ağlarından farklıdır. Sığ çok katmanlı yapay sinir ağlarından farklı daha fazla katman içermesidir. Derin ağlar ile klasik yapay sinir ağı ile yapılamayan kompleks işlemler yapılır. Nesne tespiti, tanıma, ayırma işlemleri derin sinir ağları ile yapılır. Çok katmanlı derin yapay sinir ağları ile çok daha verimli sınıflandırma ve regresyon işlemleri yapılır. Şekil 2.12'de gösterildiği gibi bir çok katmanlı derin yapay sinir ağı modeli, katmanları, katmanlardaki sinir hücreleri, hücreler arasındaki ağırlıklandırmalar gösterilmiştir.



Şekil 2.12: Çok katmanlı derin yapay sinir ağı [13]

Çok katmanlı derin yapay sinir ağları öğrenme aşaması, klasik yapay sinir ağları gibi geri yayılım işlemi ile yapılmaktadır. Çıktı katmanındaki sinir hücrelerinin çıktılarındaki hata miktarı geri yayımlı bir şekilde diğer katmanlardaki sinir ağlarına da yansıtılır. "**Stochastic gradient descent (SDA)**" algoritması da kullanılarak katmanlar arasındaki bağlantıların ağırlıklarının güncellenmesi yapılır. Şekil 2.13'te gösterildiği gibi

geri yayılımın etkisi önceki katmanlara aktarılır. Geri yayılım sırasında en baştaki katmanlara geldikçe SDA'nın etkisi kaybolur, bu probleme literatürde "**Vanishing gradient**" denir. Bu durumda en baştaki katmanlar arasındaki güncellemeler yapılamaz hale gelir, öğrenme durur. Sinir ağındaki katman sayısının fazla olması ve karmaşıklığın artması "Vanishing gradient" problemine neden olur.



Şekil 2.13: Çok katmanlı derin yapay sinir ağı geri yayılımı [13]


Literatürde, zaman serisi verilerinin analizi için derin sinir ağları kullanılmıştır. De Coninck [84] çalışmasında IoT verilerinin analizi için "The Big-Little Approach" yaklaşımını sunmuştur. Yaklaşımında, IoT cihazlar sınıflandırma yapmak için kendilerinde daha önce uygulanmış olan derin öğrenme modeli kullanır. Sınıflandırmada başarısızlık olursa, veriler bulutta bulunan daha kapsamlı derin sinir ağına sınıflandırma yapılması için aktarılır.

#### 2.4.2 Tekrarlamalı yapay sinir ağı (RNN)


**Tekrarlamalı yapay sinir ağı (Recurrent Neural Network - RNN)** bir çeşit yapay sinir ağı olup, sıralı, zaman serisi verilerinin gelecekteki durumlarını tahmin etmeyi sağlayabilen yapay sinir ağlarıdır. Yapay sinir ağlarında sinirler birbirlerine yönlü olarak bağlıdır, bağlar yönlü çevrimler (directed cycle) oluşturur. İleri beslemeli ağlardan farklı olarak, tekrarlamalı yapay sinir ağları sıralı gelen girdilerin işlenmesi için dahili hafızalarını kullanırlar. Tekrarlamalı yapay sinir ağları çeşitli alanlarda (el yazısı tanıma, konuşma tanıma, vs) zaman serisi verilerinin analizinde kullanılmaktadır.

RNN'ler çalışma sırasında bir girdi dizisini birer birer işlemektedir. Gizli katmandaki birimlerde, girdinin geçmiş hakkında bilgiyi "durum vektörü" içinde tutarlar. Gizli

katmandaki birimlerin çıktıları farklı ayırık zaman adımlarına ayrıldığında, RNN'ler derin çok katmanlı bir ağa dönüşür [13]. Şekil 2.14'te RNN'nin gizli katmanındaki bilgi akışı ayırık zamanlara ayrılmıştır.  $s$  düğümünün farklı  $t$  zamanlarındaki durumu  $s_t$ , girdi değeri  $x$ 'in farklı zamanlardaki değeri  $x_t$ , çıktı değeri  $o$ 'nun farklı zamanlardaki değeri  $o_t$  şeklinde gösterilmiştir. Parametre değerleri ( $U, W, V$ ) her zaman adımında aynı olarak kullanılmıştır. Şekil 2.15'te ise tek katmanlı ve üç katmanlı RNN ağları gösterilmiştir.




Şekil 2.14: Tekrarlamalı yapay sinir hücresinin zaman içerisindeki açılımı [13]



Şekil 2.15: Tekrarlamalı yapay sinir ağları [85]

RNN ağları zaman içerisinde geri yayılım metodu kullanılarak eğitilebilirler. RNN'de geri yayılım metodu (Back propagation through time - BPTT) Şekil 2.16'da gösterilmektedir. Geri yayılım metodu ile herhangi bir  $t$  zamanındaki hata değişimi önceki  $t$  zamanlarındaki girdi ve ağırlıklara yansıtılmaktadır. RNN'inin eğitilmesinin zorluğu, RNN yapısının zaman içinde geriye doğru bağıllığının olmasıdır. Bundan dolayı RNN ağları eğitim açısından çok karmaşık hale gelir. RNN kullanılmasının temel amacı, uzun vadeli bağımlılıkları öğrenmek olsa da, literatürde çalışmalar bilginin çok uzun süre depolanıp RNN ile öğrenmenin zor olduğunu göstermektedir. Bu durumdaki problemlerin çözümü için farklı yapıdaki yapay sinir ağı olan LSTM'ler geliştirilmiştir [13].



Şekil 2.16: Tekrarlamalı yapay sinir hücresinde zaman içerisinde geri yayılımı <sup>6</sup>


Literatürde zaman serisi verilerinin analizi için RNN ağları kullanılmıştır. Ma [86], Çin'deki trafik yoğunluğunu tahmin edebilmek için GPS (küresel konumlama sistemi) verilerini kullanmıştır. Elde ettiği verileri RNN ve derin RBM ağlarından geçirmiştir.

### 2.4.3 Uzun kısa vadeli hafıza (LSTM)

*Uzun Kısa Vadeli Hafıza (Long Short Term Memory - LSTM)* bir çeşit yapay sinir ağı olup, geleneksel sinir ağlarından farklı bir yapıya sahiptir. Geleneksel RNN'lerin aksine, bir LSTM ağı, belirsiz boyutta zaman gecikmesi olduğunda zaman serilerini sınıflandırma, işleme ve tahmin etme işlemleri için daha uygun bir çözümdür. LSTM'nin doğal davranışı, girdileri uzun süre hatırlamaktır. Bellek hücresi olarak adlandırılan özel bir birim, bir akümülatör gibi davranır. RNN'ler gibi sıralı, zaman serisi verilerinin analizinde, el yazısı tanıma, metin sıkıştırma, konuşma tanıma alanlarında kullanılırlar. RNN'den farklı olarak eğitim sırasında oluşabilecek olan "Vanishing gradient" problemi, LSTM ile çözülür.

LSTM ağları, RNN ağları gibi sıralı, zaman serisi verilerini işlerken farklı zamanlardaki verilerden de yararlanır. RNN'lerden farkı, içerdiği LSTM düğümlerinin farklı bir yapıdan oluşmasıdır. RNN ve LSTM ağ yapıları aynıdır, sadece tek bir düğümün içeriği farklıdır. Bir LSTM bloğu girdi ve çıktı bağlantılarından farklı olarak üç farklı kapı içermektedir: girdi (input gate), çıktı (output gate) ve unut kapıları (forget gate) (Şekil 2.17). Kapılardan gelen veriler belirli bir aktivasyon fonksiyonundan (tanh veya sigmoid) geçer. Daha sonra gelen değerler, girdi içeriğiyle belirli işlemlerden (çarpma, toplama vs.) geçerek, çıktı olarak düğümden çıkar [87].

<sup>6</sup><http://www.wildml.com>




Şekil 2.17: LSTM yapısı [87]

Kısacası, bir LSTM yapısı, bir RNN hücresinin hafızayla birlikte çalışma durumudur. Bu hafıza ile bir önceki zamandan gelen bilgi alınır, bir sonraki zamana iletilir. Hangi bilginin değerlendirilip değerlendirilmeyeceğine eğitim ile karar verilir. Literatürde, zaman serisi verilerinin analizinde LSTM sinir ağları kullanılmıştır. Graves [16], konuşma tanıma alanında derin LSTM sinir ağları kullanarak TIMIT veri seti üzerinde %17.7 sınıflandırma hatasıyla başarılı olmuştur.

#### 2.4.4 Sınırlı Boltzmann makinesi (RBMs)

**Sınırlı Boltzmann makinesi (Restricted Boltzmann machine -RBM)**, girdi seti üzerinde olasılık dağılımı öğrenebilen üretken bir stokastik yapay sinir ağıdır [88]. RBM'ler boyut azaltma, sınıflandırma, özellik öğrenme gibi uygulamalarda kullanılır. RBM'ler sıg yapay sinir ağlarıdır, ancak RBM'lerin birleştirilmesiyle DBN'ler oluşturulur.

Bir RBM yapay sinir ağı iki katmandan oluşur; görünen ve gizli katman (Şekil 2.18). Katmanlar kendi arasında bağlı değildir. Her sinir düğümü, girdiyi işleyen bir hesaplama noktasıdır ve bu sinir düğümü girdiyi iletip iletmeyeceğine ilişkin stokastik kararlar verir. Girdiler belirli ağırlıklarla çarpılır, belirli eşik değerler (bias) eklenir, aktivasyon fonksiyonundan geçerek çıktıyı oluşturur. Yeniden yapılandırma (Reconstruction) aşamasında, çıktılardaki sonuçlar girdi olarak ağa tekrar girer. Aynı işlemlerden geçerek çıktı olarak görünen katmandan çıkar. Önceki girdi ile işlemde çıkan değerler karşılaştırılır. Karşılaştırılma yapılmasındaki amaç aradaki farkın azaltılmasıdır. Ağ üzerinde birden fazla tekrarlama yapılarak öğrenme gerçekleşir [88]. Yeniden yapılandırma, regresyondan farklı bir etki oluşturur. Birçok girdiye dayanan değerlerin sınıflandırma yapmadan farklı olarak tahmin edilmesidir.




Şekil 2.18: Sınırlı Boltzmann makinesi (RBM) [88]

Zaman serisi verilerinin analizinde RBM ağları da kullanılmaktadır. Jaitly ve Hinton [89] tarafından konuşma tanıma verisi üzerinde RBM ağları kullanılmıştır. Çalışmalarında TIMIT verisini kullanarak %21.8 sınıflandırma hatasıyla başarılı olmuşlardır. Benzer bir çalışma, Mohamed [90] tarafından yapılmıştır. RBM ağları kullanılarak TIMIT veri seti üzerinde %20.7 sınıflandırma hatasıyla sınıflandırma başarısı yakalamıştır.

#### 2.4.5 Derin düşünce ağları (DBN)

**Derin Düşünce Ağları (Deep Belief Network - DBN)** bir çeşit derin yapay sinir ağıdır ve RBM ağlarının yığından oluşmaktadır (Şekil 2.19). DBN’de her katmanda birimler arası bağlantı yoktur. Girdideki ayırıcı özellikleri, gözetimsiz bir şekilde bulmak için DBN’ler kullanılır. DBN, gözetimsiz (unsupervised) bir şekilde eğitim seti üzerinde eğitim gördüğünde, ağa giren girdi setini olasılıksal olarak yeniden yapılandırmayı öğrenebilir. Daha sonra ağıdaki katmanlar girdiler üzerinde özellikleri tespit etmeye başlar. Bu öğrenme adımından sonra, sınıflandırmayı gerçekleştirmek için gözetimli (supervised) eğitim alınır [12].




Şekil 2.19: Derin düşünce ağları [88]

Literatürdeki çalışmalarda, DBN'ler resimlerdeki ve videolardaki nesnelerin tanınması, videolardaki hareketlerin yakalanması için kullanılmıştır. Hamel ve Eck [91], müzik tanıma çalışmalarında GTZAN veri seti üzerinde konvolüsyonel DBN uygulamışlar, %84.3 tanıma başarısını yakalamışlardır. Lee [92], çalışmasında konvolüsyonel DBN kullanmış, bu çalışma ile müzik ve konuşma spektrogramlarından özelliklerin çıkarılmasını sağlamıştır.

#### 2.4.6 Otomatik kodlayıcı (Autoencoder)

**Otomatik Kodlayıcı (Autoencoder)** etkin kodlamaların gözetimsiz (unsupervised) öğrenimi için kullanılan bir yapay sinir ağıdır. Bir otomatik kodlayıcı ile boyutsallığın azaltılmasıyla, bir veri seti için bir gösterim (kodlama) öğrenilir. Otomatik kodlayıcılar, mimari olarak ileri beslemeleri ağlara benzerler. Bir girdi, bir çıktı katmanı ve bunları birbirine bağlayan bir veya daha fazla gizli katmana sahiptirler. Otomatik kodlayıcılarda girdi katmanındaki düğüm sayısı ile çıktı katmanındaki düğüm sayısı birbirine eşittir ve simetrik bir yapıya sahiptir. Otomatik kodlayıcılar gözetimsiz (unsupervised) öğrenme modelleridir.



Şekil 2.20: Otomatik kodlayıcı [14]


Otomatik kodlayıcılar iki bileşenden oluşur; kodlayıcı (encoder), kod çözücü (decoder) (Şekil 2.20). Kodlayıcı ile girdi  $x$ , sistem içi gösterim  $h$ 'ye fonksiyon  $f$  ile dönüştürülür. Daha sonra, kod çözücü ile iç gösterim  $h$ , çıktı  $r$ 'ye fonksiyon  $g$  ile dönüştürülür. Literatürde, otomatik kodlayıcılar, özellik çıkartma ve boyut azaltma işlemleri için kullanılmıştır [14].

Zhang [93], trafik örüntüsünü ve hava kirliliğinin tahmini için derin otokodlayıcıları kullanmıştır. Önerdiği çözümle, bir çok kaynaktan gelen veriyi (sosyal medya, sensörler, arkaplan bilgisi) otokodlayıcılar kullanarak anlamlı hale getirmiştir.



## 2.4.7 Konvolüsyonel sinir ağları

**Konvolüsyonel Sinir Ağları (Convolutional Neural Network - CNN)** bir çeşit ileri beslemeli yapay sinir ağı olup, katmanlar arası bağlantı modeli, görsel korteksin organizasyonuna benzetilmektedir. Genel olarak iki çeşit katmandan oluşur: konvolüsyonel katman (convolutional layer), örnekleme katmanı (sub-sampling layer). CNN yapısal olarak, arka arkaya gelen konvolüsyonel ve örnekleme katmanından oluşmaktadır. Son olarak katmanlar tamamen bağlı çok katmanlı algılayıcıya (fully connected MLP) bağlanır. CNN'ler görüntü ve video tanıma, tavsiye sistemleri ve doğal dil işleme alanlarında geniş uygulamalara sahiptirler. Genel CNN yapısı, Şekil 2.21'de gösterilmektedir. Şekilde de gösterildiği gibi girdi verisi arka arkaya konvolüsyonel ve örnekleme katmanlarından geçer, son olarak MLP'ye bağlanır.



Şekil 2.21: Konvolüsyonel sinir ağları (CNN) <sup>7</sup>

Literatürde, CNN genelde resim ve video tanıma alanında kullanılmıştır. Ayrıca CNN zaman serisi verilerinin analizinde kullanılan bir yöntemdir. Humphrey [94], çalışmasında konvolüsyonel ağları kullanarak, sesin zaman-frekans gösterimlerinde iyi sonuçlar vermesini sağlamıştır. Mirowski [95], çalışmasında kafa içi EEG (elektroensefalografi) sinyallerinden epileptik nöbet tahmini yapabilmek için konvolüsyonel ağları kullanmış, sonuçları lojistik regresyon ve SVM ile karşılaştırmıştır.

Zheng [35], çalışmasında zaman serisi verilerinin analizinde çok kanallı derin konvolüsyonel sinir ağı yapısı önermiştir. Önerdiği "Multi-Channels Deep Convolutional Neural Networks" (MC-DCNN) yapısı ile birden fazla kanaldan gelen zaman serisi veriler ham veri olarak modele alınmaktadır. Önerilen model 2 ana yapıdan oluşmaktadır. İlk aşamada, ham veriler "feature-extractor" yapısından geçirilerek özellikleri çıkartılmakta, ikinci aşamada tamamen bağlı MLP'den geçirilerek sınıflandırılmaktadır. Önerilen yapı gerçek "electrocardiograph" (ECG) verileri test edilmiştir. Önerilen modelin sınıflandırma başarısı yaklaşık olarak 94% olarak ölçülmüştür [35].

Le [36], çalışmasında CNN kullanarak zaman serisi verilerinin sınıflandırılması üzerine çalışmıştır. Önerilen model, zaman serisi verisini ham olarak almakta ve sınıflan-

<sup>7</sup><http://deeplearning.net/tutorial/deeplearning.pdf>

dırmaktadır. Önerilen modelde Le-Net CNN yapısı kullanılmaktadır: İki konvolüsyon, bir "max pooling" katmanı ve tamamen bağlı MLP. "Window Wrapping" ve "Window Slicing" yöntemleri ile CNN'e girecek olan veriler etiketlenmektedir. UCR veri tabanındaki 7 farklı zaman serisi verisi kullanılmıştır (ECG, Sensor, vs.) [36].

Hatami [37], önerdiği yöntemde zaman serisi verilerini 2 boyutlu verilere çevirerek, CNN modeli kullanarak sınıflandırmaya çalışmaktadır. Önerilen model, "Recurrence Plots" aracı kullanılarak tek boyutlu ham veriyi iki boyutlu hale getirmektedir. UCR veri setindeki <sup>8</sup> 85 farklı zaman serisi verisi kullanılarak önerilen model test edilmiştir. Daha sonra literatürdeki diğer yöntemlerle (SIFT, Gabor) kıyaslanmıştır.

---

<sup>8</sup>[http://www.cs.ucr.edu/~eamonn/time\\_series\\_data/](http://www.cs.ucr.edu/~eamonn/time_series_data/)

### 3. FİNANSAL ZAMAN SERİSİ VERİLERİNİN ANALİZİ

#### 3.1 Finansal Zaman Serisi Verileri

Finansal zaman serisi verileri, zaman içerisindeki finansal verilerin değişimini gösteren verilerdir. Finansal veriler, menkul kıymetlerin (hisse ve tahvil senedi, fon, hazine bonosu) fiyatları, para piyasalarındaki paraların birbiri cinsinden dönüşüm değerleri (USD/TR, USD/EUR, EUR/TR) olabilir. Finansal zaman serisi verileri, zaman serisi verileri gibi zaman sıralamalıdır. Zaman serisi verilerinin analizi gibi analiz edilir. Ancak, literatürde çoğunlukla finansal zaman serisi verilerinin analizinde *eğilim (trend)* analizi ve finansal teknik analiz göstergeleri kullanılmaktadır. Finansal zaman serisi verilerinin analizinde amaç fiyatların değişim yönünün ve zamanının, fiyatların gelecekteki yerlerinin tahmin edilmesidir. Bu konuda araştırmacılar da, yapay sinir ağlarını, makine öğrenme algoritmalarını kullanarak yeni finansal veri analiz yöntemleri geliştirme çabası içerisinde.

#### 3.2 Finansal Teknik Analiz

*Finansal teknik analiz*, bir menkul kıymetin (hisse, fon, vs) geçmiş verilerinin analiz edilerek, gelecekteki eğiliminin (trend), olabilecek fiyat hareketlerinin tahmin edilebilir, belirme bilimidir [96]. Menkul kıymetin gerçek değeri ölçülmez, menkul kıymetin ait olduğu şirketin finansal verilerine (bilanço, gelir gider tablolarına, finansal raporlara, vs.) bakılmaz. Sadece fiyat değişimlerine, finansal teknik analiz göstergelerine bakılarak gelecek fiyatların eğilim yönü tahmin edilerek alım, satım noktaları belirlenir.

Teknik analizde, fiyatların belirli bir eğilim (trend) içerisinde ilerleyeceği kabul edilir. Menkul kıymetin gelecekteki fiyatlarının, eğilimin yönünde ilerlemesinin, eğilimin tersine doğru ilerlemesinden daha yüksek ihtimal olduğu öngörülür. Bu yüzden eğilimin yönünün ve eğilim yönünün değişeceği noktanın önceden tahmin edilmesi önemli olarak görülmektedir.

*Eğilim (trend) çizgisi* çizilerek, fiyatların eğilim yönü belirlenir. Eğilim çizgisi, fiyatlar üzerindeki tepe veya dip noktalar arasında çizilir. Yani, fiyatlar yükselirken, fiyatlarda



Şekil 3.1: Yükselen eğilim [97]

oluşan tepe ve dip noktalar gittikçe yükseliyorsa, eğilim çizgisi yükselmeyi gösterir. Bu eğilime **yükselen eğilim** denir. Fiyatlar düşerken, fiyatlarda oluşan tepe ve dip noktalar gittikçe alçalıyorsa, eğilim çizgisi alçalmayı gösterir. Bu eğilime **alçalan eğilim** denir. Yükselen eğilimde, yatırımcılar satmaktan çok, almak eğilimindedir. Alçalan eğilimde ise, yatırımcılar almaktan çok, satma eğilimindedir. Her zaman belirli bir eğilim olmayabilir. Bu durumlara da eğilimsiz veya eğilim içermeyen durumlar denir. Şekil 3.1’de yükselen bir eğilim ve dip noktalar birleştirilerek çizilen eğilim çizgisi görülmektedir.

### 3.3 Finansal Teknik Analiz Göstergeleri

**Teknik analiz göstergeleri**, menkul kıymetlerin (hisse senedi ve fonların) fiyat değerleri, işlem hacmi ve zaman içerisindeki değişimleri temel alınarak geliştirilen matematiksel ve istatistiksel hesaplamalardır. Teknik analiz göstergeleri finans alanında analistler tarafından tahmin yapılırken kullanılan araçlardır. Teknik analiz göstergeleri kullanılarak zaman içerisinde değişen menkul kıymetlerin alım, satım noktaları, eğilim yönü belirlenir.

Literatürde geliştirilen birçok teknik analiz göstergesi mevcuttur. Analistler bu veriler hakkında tahmin yaparken göstergeleri birlikte kullanarak tahminlerinin doğruluk oranlarını arttırmaya çalışmaktadır. Her bir teknik analiz göstergesi farklı parametreyi girdi olarak alarak, farklı göstergeler oluştururlar. Örneğin bir gösterge girdi olarak kapanış fiyatı alırken bir diğeri en yüksek değeri, en düşük değeri, kapanış değerini ve işlem hacmini girdi olarak almaktadır. Bu bölümde, finansal teknik analizde sıklıkla kullanılan teknik göstergeler incelenmiştir.

### 3.3.1 Bağıl güç endeksi (relative strength index)

**Bağıl güç endeksi (RSI)**, Welles Wilder tarafından 1978’de geliştirilmiştir. Teknik göstergenin hesaplanması ve yorumlanması Wilder’in kitabında, "New Concepts in Technical Trading System", detaylı olarak incelenmiştir [98].

RSI, 0 ile 100 arasında değer alan, bir menkul kıymete ait aşırı-alım ve aşırı-satım noktalarının belirlenmesinde kullanılan teknik analiz göstergesidir. 0 değeri menkul kıymetin aşırı-satım (oversold) noktasını, 100 değeri ise menkul kıymetin aşırı-alım (overbought) noktasını belirtir. RSI momentum göstergesi, menkul kıymet fiyatının o anki değerinin daha önceki fiyatlara göre kıyaslayarak pahalı veya ucuz olma durumunu belirtme imkanı sağlar. Yatırımcılar RSI değerlerinin yükselme ve düşme durumuna göre alım, satım konusunda karar verirler. Standart RSI hesaplanması 14 günlük dönem içerisinde yapılır. Genel literatürde aşırı-alım çizgisi RSI göstergesinde 70 değerinde çizilirken, aşırı-satım çizgisi ise 30 değerine çizilir. Örneğin, eğer N günlük RSI değeri 70 değerinin üzerine çıktığı zaman, o menkul kıymetin aşırı alındığı yorumlanır. Eğer N günlük RSI değeri 30 değerinin altına indiği zaman, o menkul kıymetin aşırı satıldığı yorumlanır. N günlük RSI hesaplanması Denklemler 3.1, 3.2 ile gösterilmiştir. RS değeri hesaplanırken, "TP" (TP:time period) gün içerisindeki kazanç sağlayan kapanış fiyatlarının ortalaması ve "TP" gün içerisindeki kayba sebep olan kapanış fiyatlarının ortalaması kullanılır.

$$RS(TP) = \frac{\text{Average of Upward Price Change}}{\text{Average of Downward Price Change}} \quad (3.1)$$

$$RSI(TP) = 100 - \frac{100}{(1 + RS(TP))} \quad (3.2)$$

### 3.3.2 Williams %R

**Williams %R**, hisse senedi fiyatları için aşırı alım ve aşırı satım koşullarını da belirleyen momentum temelli bir teknik göstergedir. -100 ve 0 değerleri arasında değer alır. Williams %R için karşılık gelen mantık RSI ile aynıdır. Değer -80’in altında ise, hisse senedi fiyatlarının "aşırı satış" bölgesinde olduğu yorumlanmaktadır. Aksine, değer -20’nin üstünde ise, hisse senedi fiyatı "aşırı alım" bölgesinde olduğu kabul edilir. Denklem 3.3 Williams %R değerinin nasıl hesaplandığını gösterir. "max(High)" geçmiş periyottaki en yüksek değeri verirken, "min(Low)" geçmişteki en düşük değeri vermektedir. "Close" değeri ise son günkü kapanış fiyatıdır.

$$Williams\%R(TP) = \frac{\max(High) - Close}{\max(High) - \min(Low)} * -100 \quad (3.3)$$

### 3.3.3 Basit hareketli ortalama (simple moving average)

**Basit hareketli ortalama (SMA)**, belirli bir dönemdeki fiyatların hareketli ortalamasını gösterir. Eğilim yönünü belirlemek için SMA değerlerinin farklı aralık değerleri ile kesişimi kullanılır. SMA değerleri birlikte ve tek olarak kullanılabilir. Hisse senedi fiyatları SMA'dan (örneğin 50 günlük SMA verisinden) yüksekse, hisse senedi fiyatlarının artmaya devam edeceği öngörülür. Hisse senedi fiyatları SMA'dan düşükse, hisse senedi fiyatlarının düşeceği öngörülmektedir. SMA'nın 50 günlük değeri 200 günlük değerini yukarıya doğru kesiyorsa, eğilimin yükselen yönde olduğu; SMA'nın 50 günlük değeri 200 günlük değerini aşağıya doğru kesiyorsa eğilimin alçalan yönde olduğu yorumlanır. SMA'nın hesaplanması, Denklem 3.4'de gösterilmiştir. Günlük hareketli kapanış değerleri toplanarak ("Close(k)"), istenilen gün sayısına ("TP:timePeriod") bölünür ve "TP" günlük SMA hesaplanmış olur.

$$SMA(TP) = \sum_{k=a+1}^{a+TP} \frac{Close(k)}{TP} \quad (3.4)$$

### 3.3.4 Üssel hareketli ortalama (exponential moving average)

**Üssel hareketli ortalama (EMA)**, fiyatların hareketli ortalamasını gösteren ve son günler için daha fazla önem veren hareketli bir ortalama gösterge türüdür. Üssel hareketli ortalama hesaplanırken, son zamanlardaki verilerin ağırlığının daha önceki verilerin ağırlığına göre daha fazla olduğu kabul edilir. EMA hesaplamalarında son zamanlardaki verilerin önemi katlanarak artmaktadır. Denklem 3.5, hisse senedi fiyatlarının EMA'sının hesaplanmasını göstermektedir. Denklem 3.5, "TP" (time period) değeri hesaplanacak olan zaman periyotunu gösterirken, "close" değeri kapanış fiyatını göstermektedir.

$$EMA(TP) = (Close - EMA(previousDay)) * \frac{2}{(TP + 1)} + EMA(previousDay) \quad (3.5)$$

### 3.3.5 Ağırlıklı hareketli ortalama (weighted moving average)

*Ağırlıklı hareketli ortalama (WMA)*, üssel hareketli ortalamaya benzeyen başka bir hareketli ortalama göstergesidir. Yakın zamandaki fiyattan, geçmiş verilere doğru önemlilik doğrusal olarak azalmaktadır. Öte yandan, EMA'da fiyatın önemi katlanarak azalmaktadır. Denklem 3.6, WMA'nın nasıl hesaplandığını göstermektedir. Kapanış değerlerinin ağırlıklı ortalamaları toplanarak, toplam ağırlığa bölünür ve "TP" günlük WMA hesaplanmış olur.

$$WMA(TP) = \frac{\text{Sum of Weighted Averages Close Values}}{\text{Sum of Weight}} \quad (3.6)$$

### 3.3.6 Hull hareketli ortalama (Hull moving average)

*Hull hareketli ortalama (HMA)*, SMA ile ilişkili gecikmeyi azaltan bir hareketli ortalama göstergesi türüdür. EMA ve WMA, son verilere daha fazla ağırlık verilerek gecikmenin azaltılmasına çalışır. HMA bu gecikmeyi daha da azaltır ve EMA, WMA'ya kıyasla daha iyi sonuçlar alır. Denklem 3.7, HMA'nın nasıl hesaplandığını göstermektedir. İlk aşamada, "TP"/2 günlük periyotta WMA hesaplanarak 2 ile çarpılır, "TP" günlük WMA hesaplanarak, ilk aşamadaki WMA'dan çıkartılır. Üçüncü aşamada,  $\sqrt{(TP)}$  günlük periyotta WMA, ikinci aşamadaki veriler kullanılarak hesaplanır.

$$WMA(TP) = (WMA(2 * WMA(\frac{TP}{2}) - WMA(TP)), \sqrt{(TP)}) \quad (3.7)$$

### 3.3.7 Üçlü üssel hareketli ortalama (triple exponential moving average)

*Üçlü üssel hareketli ortalama (TEMA)*, küçük fiyat dalgalanmalarının azalmasını sağlayan ve fiyat oynaklığını filtreleyen bir EMA göstergesi türüdür. Denklem 3.8, TEMA'nın nasıl hesaplandığını göstermektedir. "TP" günlük TEMA hesaplanırken, "TP" günlük EMA değerleri kullanılır.

$$TEMA(TP) = (3 * EMA(TP)) - (3 * EMA(EMA(TP))) + EMA(EMA(EMA(TP))) \quad (3.8)$$

### 3.3.8 Commodity channel index (CCI)

*Commodity channel index (CCI)*, bir süre boyunca mevcut fiyatları ve ortalama fiyatı karşılaştıran bir göstergedir. Çoğunlukla, -100 ve 100 değerleri arasında değer almaktadır. Gösterge, aralık değerlerini de geçebilmektedir. Denklem 3.9 ve Denklem 3.10, CCI hesaplamalarını göstermektedir. "Price" değeri gün içerisindeki en yüksek ("high"), en düşük ("low") ve kapanış ("close") değerlerinin ortalama değeridir. "TP" günlük CCI hesaplanırken, "TP" günlük SMA değeri ve "mean deviation" (ortalama sapma) değerleri hesaplanır.

$$CCI(TP) = \frac{Price - TP \text{ Period SMA of Price}}{0.015 * Mean Deviation} \quad (3.9)$$

$$Price = \frac{High + Low + Close}{3} \quad (3.10)$$

### 3.3.9 Chande momentum osilatörü (CMO)

*Chande momentum osilatörü (CMO)*, RSI'e benzer bir momentum göstergesi türüdür. -100 ile 100 arasında salınım gösterir. Eğer gösterge değeri 50'nin üzerindeyse, hisse senedi fiyatlarının "aşırı alım" bölgesinde olduğu yorumlanmaktadır. Değer -50'nin altında ise, genelde hisse senedi fiyatlarının "aşırı satış" bölgesinde olduğu kabul edilir. Göstergenin formülü Denklem 3.11'de gösterilmektedir.  $S_u$ , fiyatların yukarı doğru olan günlerin toplamıdır ve  $S_d$ , fiyatların aşağı doğru olan günlerin toplamıdır.

$$CMO(TP) = 100 * \frac{(S_u(TP) - S_d(TP))}{(S_u(TP) + S_d(TP))} \quad (3.11)$$

### 3.3.10 Moving average convergence and divergence (MACD)

*Moving average convergence and divergence (MACD)*, hisse senedi fiyatlarının eğilimini gösteren teknik bir göstergedir. MACD hattı sinyal hatlarını yukarı yönde kesiyorsa, hisse senedi fiyatlarının artacağı öngörülür. Buna karşılık, eğer MACD hattı sinyal hatlarını aşağı yönde kesiyorsa, hisse senedi fiyatlarının düşeceği yorumlanmaktadır. Denklem 3.12 ve Denklem 3.13, MACD ve Sinyal hatlarının hesaplamalarını gösterir. 12 günlük EMA değerinden 26 günlük EMA değeri çıkartılarak "MACD" değeri bulunur. "Signal Line" değeri MACD değerinin 9 günlük EMA değerinin hesaplanmasıyla bulunur.



$$MACD\ Line = EMA(12) - EMA(26) \quad (3.12)$$

$$Signal\ Line = EMA(9)\ of\ MACD\ Line \quad (3.13)$$

### 3.3.11 Yüzde oranı osilatörü (percentage price oscillator)

**Yüzde oranı osilatörü (PPO)** MACD'ye indikatörü benzemektedir. PPO'nun ve PPO'nun sinyal hattının hesaplanması Denklem 3.14 ve Denklem 3.15'de gösterilmiştir. 12 günlük EMA değerinden 26 günlük EMA değeri çıkartılır, çıkan sonuç 26 günlük EMA değerine bölünür. "Signal Line" değeri MACD değerinin 9 günlük PPO değerinin hesaplanmasıyla bulunur.

$$PPO = \frac{EMA(12) - EMA(26)}{EMA(26)} * 100 \quad (3.14)$$

$$Signal\ Line = EMA(9)\ of\ PPO \quad (3.15)$$

### 3.3.12 Değişim oranı (rate of change)

**Değişim oranı (ROC)**, belirli bir süre boyunca fiyat değişim hızını gösteren teknik bir göstergedir. Denklem 3.16, ROC formülünü göstermektedir. ROC değeri hesaplanırken, "Latest Close" (en son kapanış) ve "previous close" (bir önceki kapanış) değerleri kullanılır.

$$RoC = \frac{(Latest\ Close - Previous\ Close)}{(Previous\ Close)} * 100 \quad (3.16)$$

### 3.3.13 Chaikin para akışı (chaikin money flow indicator)

**Chaikin para akışı göstergesi (CMFI)**, belirli bir süre boyunca para akışı hacmini ölçmek için kullanılan teknik bir göstergedir. Gösterge değeri 1 ile -1 arasında salınım yapar. Değer 1'e yaklaşırsa, satın alma baskısının daha yüksek olduğu yorumlanır. Aksine, değer -1'e yakınsa, satış baskısının daha yüksek olduğu yorumlanmaktadır. Denklem 3.17, Denklem 3.18 ve Denklem 3.19 CMFI'nın hesaplanmasını göstermektedir. "TP" günlük CMFI değeri hesaplanırken, "multiplier" (katsayı), "volume" (işlem

hacmi) değerleri kullanılır. Katsayı değeri hesaplanırken ise, o günkü "close" (kapanış), "high" (en yüksek) ve "low" (en düşük) değerler kullanılır.

$$Multiplier = \frac{(Close - Low) - (High - Close)}{(High - Low)} \quad (3.17)$$

$$Money Flow Volume (MFV) = Volume * Multiplier \quad (3.18)$$

$$CMFI(TP) = \frac{TP \text{ Period Sum of MFV}}{TP \text{ Period Sum of Volume}} \quad (3.19)$$

### 3.3.14 Yön hareket göstergesi (directional movement indicator)

**Yön hareket göstergesi (DMI)**, eğilimin gücünü ve yönünü gösteren teknik bir göstergedir. Üç ayrı göstergeden oluşur: Ortalama Yön Endeksi (ADX), Artı Yön Göstergesi (+DI) ve Eksi Yön Göstergesi (-DI). DMI 0 ve 100 değerleri arasında değişmektedir. Algoritma 1, Denklem 3.20, Denklem 3.21, Denklem 3.22 ve Denklem 3.23 DMI hesaplamasını göstermektedir. DM değeri hesaplanırken, "currentHigh" (anlık en yüksek değer), "currentLow" (anlık en düşük değer), "previousHigh" (önceki en yüksek değer), "previousLow" (önceki en düşük değer) değerleri kullanılır. "True Range" hesaplanırken, "High-Low", "High-PreviousClose", "PreviousClose-Low" değerlerinden en büyüğü seçilir. "True Range" değeri "+DI" ve "-DI" hesaplamalarında kullanılır.

---

#### Algoritma 1 DM Hesaplanması

---

```

1: function DM()
2:   Input: CurrentHigh, CurrentLow, PreviousHigh, PreviousLow
3:   Output: +DM, -DM
4:   UpMove = CurrentHigh - PreviousHigh
5:   DownMove = CurrentLow - PreviousLow
6:   If (UpMove > DownMove and UpMove > 0)
7:     then return (+DM) = UpMove,
8:     else return (+DM) = 0
9:   If (DownMove > Upmove and DownMove > 0)
10:    then return (-DM) = DownMove,
11:    else return (-DM) = 0

```

---

$$True\ Range = \max(High - Low, High - PreviousClose, PreviousClose - Low) \quad (3.20)$$

$$+DI = 100 * EMA\left(\frac{+DM}{Average\ True\ Range}\right) \quad (3.21)$$

$$-DI = 100 * EMA\left(\frac{-DM}{Average\ True\ Range}\right) \quad (3.22)$$

$$ADX = 100 * EMA\left(\left|\frac{(+DI) - (-DI)}{(+DI) + (-DI)}\right|\right) \quad (3.23)$$

### 3.3.15 Parabolic sar

**Parabolik sar**, potansiyel eğilim değişimini belirlemek için kullanılan teknik analiz göstergesidir. Mevcut SAR üç unsurla hesaplanır: Önceki SAR (PSAR, Prior SAR), Aşırı Nokta (EP) ve Hızlanma Faktörü (AF). Önceki SAR, önceki dönem için bir SAR değeridir. EP, mevcut yükseliş eğiliminin en yüksek seviyesi veya mevcut düşüş eğiliminin en düşük seviyesidir. AF, SAR'ın hassasiyetini açıklar. AF, 0.02'den başlar ve yükselen SAR'da yükseldiğinde her zaman 0.02 oranında artar. AF, düşen bir SAR'a düştüğünde her seferinde 0.02 oranında azalır. Denklem 3.24, Yükselen Parabolik SAR ("RisingSAR") hesaplamasını gösterir. Düşen Parabolik SAR ("FallingSAR"), Denklem 3.25'deki gibi hesaplanır.

$$RisingSAR = PSAR + Prior\ AF(Prior\ EP + PSAR) \quad (3.24)$$

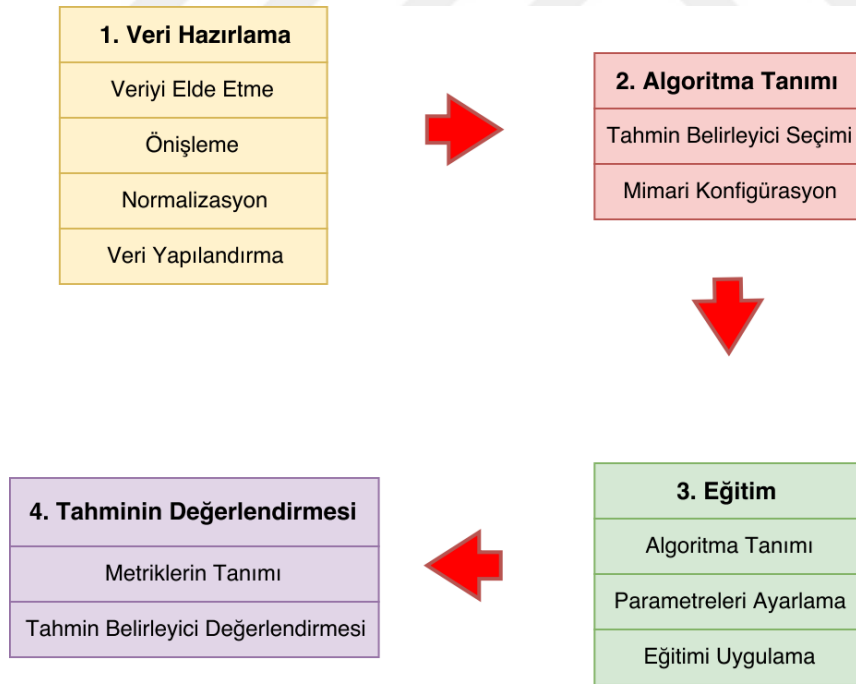
$$FallingSAR = PSAR - Prior\ AF(PSAR - Prior\ EP) \quad (3.25)$$

## 3.4 Finansal Verilerin Analizinde Makine Öğrenme

Literatürde, finansal verilerin analizi ile ilgili çok sayıda araştırma bulunmaktadır. Son yıllarda, finansal zaman serisi verilerinin tahmini ve karar destek sistemleri ilgili çalışmalar olmuştur. Finansal zaman serisi verilerinin tahmininde istatistiksel modeller ve makine öğrenme yaklaşımları kullanılmıştır. Geleneksel istatistiksel metotlar, doğrusal çalışan sistemlerin tahminin de kullanılmaktadır. Ancak finansal zaman serisi veriler

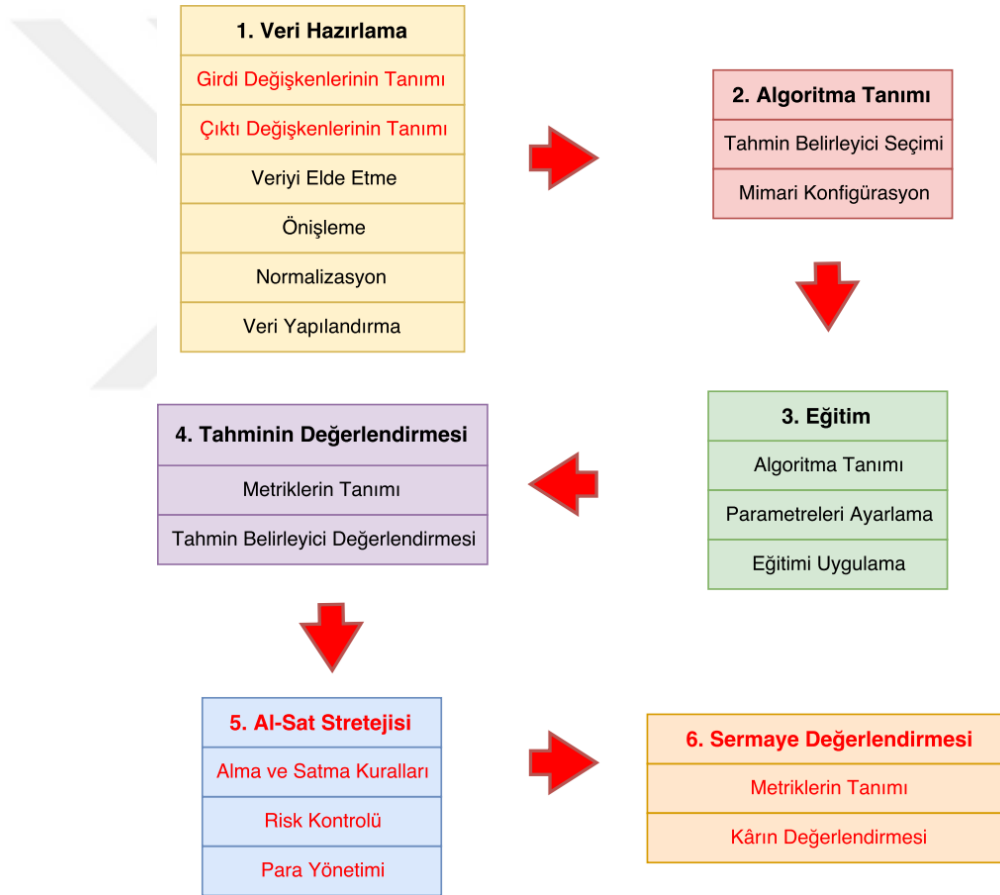
doğası gereği genellikle kompleks, yüksek gürültü içeren, dinamik, doğrusal ve parametrik olmayan, kaotik verilerdir [17]. Bu yüzden finansal verilerin analizinde teknik ve temel analizinde dışında, son yıllarda makine öğrenme, hesaplamalı akıllı yöntemler kullanılmaya başlanmıştır. Önişleme ve kümeleme teknikleri, finansal verilerin hareketlerini tahmin etme yöntemleri, finansal metinlerin işlenmesi konularında çalışmalar bulunmaktadır. Bu tezde finansal verilerin hareketlerini tahmin etmek ve alım/satım noktalarını bulmak için çalışma yaptığımız için, daha çok finansal verilerin hareketlerini tahmin etme yöntemleri hakkında araştırma yapılmıştır. Bu yöntemler, şu başlıklar altında incelenmiştir: Yapay sinir ağları, destek vektör makineleri, hibrit mekanizmalar, optimizasyon ve birleşik ağlar.

Genellikle, zaman serisi verilerinin tahmininde kullanılan hesaplama zekası sistematik olarak belirli adımları içermektedir; *verinin hazırlanması (önişlem)*, *algoritma tanımı*, *eğitim ve tahminin değerlendirilmesi*. Şekil 3.2’de de gösterildiği gibi, veri hazırlama fazında, verinin elde edilmesi sağlanır, elde edilen veri belirli önişlemlerden geçirilir, normalize edilir ve veri tekrar yapılandırılır (eğitim ve test verisi için). İkinci fazda, uygulanacak algoritma seçilir, konfigüre edilir. Eğitim fazında, eğitim seti eğitilir, öğrenilmiş model oluşturulup, son fazda, test verisi ile sonuçlar değerlendirilir [17].



Şekil 3.2: Zaman serisi verilerde kullanılan yaygın tahmin yöntemi [17]

Finansal zaman serisi verilerinin tahmini için, bu sistematik adımlara iki faz daha eklenmiştir; "*Al-Sat*" stratejisi ve sermaye değerlendirmesi. Şekil 3.3'de de gösterildiği, beşinci faz olan "*Al-Sat*" stratejisinde, "*Al-Sat*" kuralları oluşturulur, risk kontrolü ve para yönetimi yapılır. "*Al-Sat*" kuralları oluşturulurken maksimum kar hedeflenir. Risk kontrolünde belirli kurallar (ör:stop-loss) oluşturulur ve o kurallar ile risk dengelenir. Sermaye yönetimiyle de pozisyonun büyüklüğü belirlenir, "*Al-Sat*" sırasında kullanılacak olan sermaye miktarı, mevcut toplam sermaye ve "*Al-Sat*"a dahil risk dikkate alınarak hesaplanır. Bu üç stratejinin uygulanmasında, işlem maliyetleri, hacim gibi kısıtlamalarının hesaba katılması gerekir. Son faz, sermaye değerlendirmesinde, uygulanan yöntemin gerçekte olan uygulaması değerlendirilir. Bu adım önemli bir fazı oluşturur. Çünkü önerilen uzman "*Al-Sat*" yönteminin gerçek hayatta uygulandığında nasıl bir kazanç elde edeceği değerlendirilmektedir [17].



Şekil 3.3: Finansal tahmin yöntemleri [17]

Finansal zaman serisi verilerinin analizi sırasında belirli makine öğrenme metotları kullanılmadan önce verilerin analizi için çeşitli önişlemler uygulanır. Özellik seçimi ve çıkarımı, zaman serilerinin segmentasyonu ve kümeleme, literatürde uygulanan önişlem metotlarıdır. Finansal verilerin analizinde kullanılan özellikler yapılan analizin çe-

şidine göre değişmektedir. Temel analiz sırasında firmanın büyüklüğü, nakit akışı, fiyat/kazanç oranı, karlılık, piyasa/defter değeri gibi özelliklere bakılırken, teknik analiz sırasında ortalama, bağıl güç endeksi, hacim, momentum gibi özellikler değerlendirilir.

Özelliklerin hepsinin kullanılması tahmin başarısını ve hesaplama performansını düşürdüğü için özellik çıkarılması, seçilmesi ve azaltılması gerekmektedir. Analiz sırasında hangi özelliğin hangi parametrelerle seçilmesi gerektiği konusunda literatürde kesin bir kanı mevcut değildir. Bu yüzden özelliklerin seçilmesi ve kullanılması hakkında metotlar geliştirilmiştir. Lee [99], özelliklerin seçilimi için hibrit bir yöntem önermiştir. Yöntemde, en iyi alt küme özelliklerinin belirlenmesi için f-skoru kullanılmaktadır. Daha sonra, bir destek vektör makinesi (SVM) sınıflandırıcısı ile azaltılmış özellik kümesi oluşturulur. Tsai ve Hsiao [100], özellik seçimi için hibrit bir yöntem oluşturmuştur. Bu yöntemde, temel bileşenler analizi (principal component analysis), genetik algoritma, sınıflandırma ve regresyon karar ağaçları çeşitli kombinasyonlar halinde (üç stratejinin kesişimi, bileşimi) kullanılmıştır. Lin [101], uzman bilgisini genetik algoritma tabanlı yöntemle birleştirerek, SVM sınıflandırıcısı da kullanarak en iyi özellikleri seçmeye çalışmıştır.

Diğer bir önışlem metodu finansal zaman serisi verilerinin segmentasyonudur. Bu metotla, tüm verilerin analiz için kullanılması yerine verilerin azaltılması amaçlanır. Finansal verilerde kullanılan yaygın segmentasyon metotları, algısal açıdan önemli noktalar (perceptually important points -PIP) ve dönüş noktası (turning point -TP) belirleme metotlarıdır. Tsinaslanidis ve Kugiumtzis [102], PIP ve DTW (dynamic time wrapping) temelli tahmin metodu sunmuşlardır. PIP ile seriyi farklı alt bölümlerine bölen önemli noktalar tespit etmişler, DTW ile de benzer tarihsel alt dizileri bularak gelecekte benzer davranışların gerçekleşeceğine tahmin etmeye çalışmışlardır. Li [103], çalışmasında Dow Jones Endüstri Endeksindeki (Dow Jones Industrial Average - DIJA) dönüş noktalarını tahmin etmek için geriye yayımlı olarak eğitilmiş bir yapay sinir ağı kullanmıştır. Yin [104], farklı zaman dilimleri düzeyinde finansal zaman serilerini ayırtmak için dönüş noktası (TP) segmentasyon yöntemini kullanmıştır. Önerdiği yaklaşımı eğri uydurma (curve fitting) ve orijinal zaman serilerinin korunması açısından PIP stratejisi ile karşılaştırmıştır. Si ve Yin [105], her bir TP'nin önem derecesini değerlendiren TP'leri belirlemeye yönelik bir yöntem önermiştir.

Finansal zaman serisi verilerinde kullanılan bir diğer önışlem metodu kümeleme (clustering) işlemidir. Bu yöntem ile benzer finansal hareketleri yapan endeksler ve hisseler gruplanır. Bir ülkedeki bir borsa veya endeksin hareketinin, başka bir ülkedeki hisse senetlerinin hareketlerinden etkilenebilir. Bu, aynı zamanda, farklı ancak ilgili pazar sektörlerinde de olabilir. Benzer finansal zaman serisi verilerin gruplanması, hisse senedi fiyatlarını tahmin etmede ve kârlı yatırımlar yapmak için faydalıdır. Zhou, Li, ve

Ma [106], finansal açıdan çok değişkenli zaman serisi verilerini kümelemek için araştırma yapmışlardır. Local Linear Embedding (LLE) yöntemini önermişlerdir. Önerdikleri yöntem ile zaman serisi verilerde varolan teknik gösterge verileri (yüksek, düşük, açılış, kapanış değerleri, hacim) azaltılmıştır. K-means kümeleme algoritması ile de, LLE tarafından modifiye edilen zaman serisi verileri kümelemiştir. Huang ve Tsai [107], çalışmalarında yüksek doğruluk ile tahmin etmeye sağlayacak bir gösterge geliştirmeye çalışmışlardır. Çalışmaları, filtre tabanlı özellik seçimi yöntemi ile SOM tekniğini birleştirmektedir. Önerilen metot ile özellik seçici önemsiz özellikleri filtreler, SOM ile eğitim verileri gruplanır, her bir grubu öğrenmek ve tahmin etmek için SVR modeli uygulanır.

### 3.4.1 Yapay sinir ağları (YSA)

Literatürde, finansal verilerinin analizi ve tahmini için, yapay sinir ağlarının kullanıldığı çalışmalar bulunmaktadır. Martinez [18], çalışmasında geri yayılım algoritması ile eğitilmiş çok katmanlı bir ileri beslemeli sinir ağı (MLP) kullanmıştır. Bu çalışmada, teknik göstergeler arasındaki ilişkiyi bulmak ve günlük maksimum, minimum fiyatları tahmin etmek amaçlanmıştır. Tahmin edilen sonuçlar gerçek piyasa verilerinde kullanılmıştır. Dhar, Mukherjee ve Ghoshal [30], çalışmalarında Hint Menkul Kıymetler Borsasındaki hisselerin bir sonraki adımdaki kapanış değerlerini tahmin etmek için MLP kullanmışlardır. Çalışmada kullanılan YSA, geri yayılım algoritması ile eğitilmiş klasik üç katmanlı bir MLP ağıdır. Yazarlar, en iyi MLP konfigürasyonunu bulmak için, ağ parametrelerinin çeşitli kombinasyonlarını (giriş ve gizli katmanlardaki nöron sayıları, öğrenme oranı) araştırmışlardır. Oliveira [108], bir Brezilya Petrol Şirketinin hisse senedi fiyatlarını tahmin etmek için üç katmanlı bir MLP kullanmıştır. YSA'yı eğitmek için geleneksel geri yayılım algoritmasının farklı versiyonu olan esnek geri yayılım algoritması (resilient backpropagation) kullanmışlardır. Jasemi, Kimiagari ve Memariani [109], japon mum çubuklarındaki (candlesticks) gizli örüntüleri bulmak için MLP kullanmışlardır. Kayal [110], çalışmasında basit ve üstel hareketli ortalamalar, RSI gibi teknik göstergeleri kullanarak döviz piyasasının (FOREX) tahmininde MLP kullanımını araştırmıştır. Vanstone, Finnie ve Hahn [29], Avustralya borsasında kullanılmak üzere otomatik alım/satım yapabilen bir sistem oluşturmak için MLP kullanmışlardır. Fiyat kazanç oranı (price earning ratio), defter değeri, özkaynak kârlılığı (ROE) ve temettü ödeme oranı gibi temel analiz verileri, MLP'de girdi olarak kullanılmıştır [17].

MLP'nin finansal zaman serisi verilerini tahmin etme başarısı, ağ modelindeki hiper parametrelerin değişimlerinden (sinirsel mimari, gizli katmanların sayısı, gizli nöronların sayısı, öğrenme oranı, eğitim algoritması gibi) etkilenmektedir. En iyi parametre-

lere göre MLP yapısının kullanılması için Lasfer [111], tarafından arařtırmalar yapılmıřtır. Arařtırmasında sayısız deneyler yaparak, parametrelerin birbirleriyle ve sonuçla olan iliřkisini arařtırmıřtır [17].

MLP dıřında, literatürde farklı YSA'lar da kullanılmıřtır. Majhi, Panda ve Sahoo [112], döviz kurlarını tahmin etmek için iki farklı YSA önermiřtir; "functional link" yapay sinir ađı (FLANN) ve "the cascaded functional link" yapay sinir ađı (CFLANN). Mahdi, Hussain ve Al-Jumeily [113], çalıřmalarında iki farklı yapıda olan kendi kendini düzenleyen MLP (SOMLP) ile FLANN'ı karřılařtırmıřlardır. Çalıřmalarında, FOREX piyasasında FLANN ve SOMLP'yi kullanarak en yüksek kazancı elde ettiklerini göstermiřlerdir. Ghazali [114], FOREX piyasalarının analizinde kullanılmak üzere, "dynamic ridge polynomial" yapay sinir ađını (DRPNN) önermiřtir. Deneylerinde DRPNN'inin "ridge polynomial" yapay sinir ađlarına (RPNN) göre daha iyi sonuç verdiđini göstermiřtir. Shahpazov, Veleve ve Doukowska [115], Bulgaristan hisse senedi piyasasındaki endeksleri tahmin edebilmek için üç sinir ađı modelini arařtırmıřlardır; MLP, RBF (radial basis function) ve genel regresyon sinir ađı (GRNN). González [116], çalıřmasında İspanyol Borsasındaki hisselerin alım/satım fiyatlarının tahmini için RSI deđerleriyle eđitilmiş genelleřtirilmiř bir ileri beslemeli sinir ađının (GFNN) kullanılmasını önermiřtir. Liu ve Wang [117], hisse senedi endekslerinin tahmini için Legendre sinir ađı kullanımını önermiřlerdir. Bu yaklařımda, tarihsel verilerin yeni deđerlerin tahmininde farklı bir etkisi olduđunu göstermiřtir. Ticknor [118], hisse senedi fiyatlarını öngörmek için Bayes ađlarının kullanılmasını önermiřtir. Çalıřmasında, hisse senedi fiyat hareketlerini öngörmek için üç katmanlı bir ileri beslemeli sinir ađı kullanılmıřtır. Dokuz farklı teknik gösterge girdi olarak kullanılmıřtır. Wang [119], çalıřmasında PCA ile stokastik zaman etkili fonksiyonel sinir ađlarının (STNN) kullanılmasını önermiřlerdir. Önerilen yöntem, giriř verisindeki ana bileřenleri (principal components) çıkarmak için PCA (principal component analysis) kullanılmaktadır. Daha sonra ortaya çıkarılan ana bileřenler, MLP'de tahmin etmek için kullanılır. Önerilen metodun performansı geleneksel MLP, PCA-MLP ve STNN'e göre daha iyi sonuç vermiřtir [17].

### **3.4.2 Destek vektör makineleri (SVM)**

Finansal verilerin analizinde, YSA'lar ile birlikte yaygın olarak kullanılmaktadırlar. YSA'lar ile analizleri sırasında, verilerin son derece gürültülü ve yüksek boyutluluđa sahip olmasından dolayı örüntünün öđrenimi sırasında belirli kısıtlar oluřmaktadır [26], [17]. SVM'ler YSA'lar gibi verilerdeki örüntü tanıma iřlemlerinde kullanılmaktadır. SVM'ler hem sınıflandırma (support vector classifier -SVC) hem de regresyon problemleri (support vector regression -SVR) için kullanılmaktadır. Chen [25], çalıř-



masında teknik göstergeler ve endeks fiyatı verilerine SVR kullanmıştır. SVR model parametrelerini optimize etmek için "grid search" yöntemini kullanmıştır. Guo-Qiang [26], hisse senedi fiyatlarını tahmin etmek için SVR kullanmıştır. SVR parametrelerini optimize etmek için de parçacık sürü eniyilemesi (Particle Swarm Optimization) kullanmıştır. Luo, Wu, ve Yan [120], SVR'yi hisse senedi endekslerini tahmin etmek için geleneksel regresyon modelleri ve sinir ağı modelleri ile birlikte kullanmışlardır. Bao, Yang, Xiong ve Zhang [121], SVR'yi ham petrol fiyatlarının tahmininde kullanmışlardır. Kara [122], çalışmasında farklı MLP mimarilerini SVR ile karşılaştırarak, hisse senedi fiyatlarının tahmininde kullanmıştır. Chao, Li-li ve Ting-ting [123], finansal zaman serisi verilerinin tahmini için dalgacık analizi ile SVR birleştirmişlerdir. Diğer çalışmaların aksine bu çalışmada, verilerin önışleme sırasında kullanılan dalgacık mekanizması, SVR çekirdeğini oluşturmak için kullanılmıştır.

Kim [124], SVM kullanarak hisse senedi piyasasındaki hisse hareketlerinin tahmini yapmaya çalışmıştır. SVM modelini YSA ile karşılaştırmıştır. Huang [125] da benzer şekilde SVM kullanarak NIKKEI 225 endeksinde haftalık hareketlerini tahmin etmek için araştırma yapmıştır. Çalışmasını, doğrusal ayrımcılık analizi (Linear Discriminant Analysis), ikinci dereceden ayrımcılık analizi (Quadratic Discriminant Analysis) ve Elman geri yayılım yapay sinir ağları (Elman Backpropagation Neural Networks) yöntemleri ile kıyaslamıştır. Cao ve Tay [126],[127], çalışmalarında SVM'i hisse senedi hareketlerini tahmin etmek için kullanmışlar ve önerdikleri çözümü, çok katmanlı YSA'lar ve RBF'ler ile kıyaslamışlardır. Pai [128], hisse senedi fiyatlarının zaman içerisindeki hareketlerinin tahmini için ARIMA ile SVM hibrit çözümünü önermiştir. Önerdiği hibrit çözümü 10 farklı hisse senedinin zaman serisi içerisindeki fiyat değişimlerine uygulamıştır.

### 3.4.3 Hibrit çözümler

Hibrit çözümler, birden fazla çözümün birleşiminden oluşmakla birlikte, tek bir çözümün dezavantajlarını gidermeyi sağlayan çözümler olmaktadır. Bireysel yaklaşımlarda yerel uygunluk (local optima), gereğinden fazla uyma (overfitting), birçok parametrenin seçiminde zorluk gibi bazı dezavantajlar bulunmaktadır. Hibrit çözümler ile bu sorunların giderilmesi için çalışmalar yapılmıştır. Liang [129], çalışmasında opsiyon fiyatlarının etkin bir şekilde tahmin edilmesi için hibrit bir yaklaşım önermiştir. Önerilen yaklaşım, parametrik ve parametrik olmayan yaklaşımlardan oluşan kademeli bir yapıdır. Parametrik yaklaşım (Binom ağacı, sonlu fark yöntemi ve Monte Carlo) ile fiyat hareketlerinin modellenmesi sağlanır. Daha sonra, parametrik olmayan yaklaşım (lineer sinir ağı, MLP ve SVR) ile de, parametrik yaklaşımın uygulanmasından elde

edilen verilerin öğrenilmesi sağlanır. Wu ve Shahidehpour [130], çalışmasında üç yaklaşımdan oluşan hibrid bir mekanizma kullanarak gün öncesi elektrik fiyatlarını nasıl tahmin edebileceklerini araştırmışlardır. Kullanılan ilk yöntem, tarihsel fiyat değişiklikleri ile diğer veriler arasındaki doğrusal ilişkiyi modellemek için uygulanan otoregresif hareketli ortalamadır (ARMAX). Ardından, ARMAX modelinden gelen verilerin karakteristik özelliklerini tanımlamak için GARCH (Generalized autoregressive conditional heteroscedasticity) modeli kullanılır. Son olarak, uyarlamalı dalgacık sinir ağı (adaptif wavelet neural network -AWNN) uygulanmışlardır. Zhu ve Wei [131], karbon fiyatlarını tahmin etmek için karma bir yaklaşım kullanmışlardır. Karbon fiyatları doğrusal ve doğrusal olmayan bileşenlere ayrılmış ve sırasıyla bu bileşenleri öğrenmek ve tahmin etmek için ARIMA, en küçük kareli destek vektör makinesi (LSSVM) modelleri kullanılmıştır. Nayak, Mishra ve Rath [27], çalışmalarında SVM ve K-en yakın komşusu (KNN) yaklaşımını kullanarak borsa endeks verilerinin tahmini için hibrit bir yöntem sunmuşlardır. Çalışmalarında, sadece kapanış fiyatını tahmin etmekle kalmayıp, aynı zamanda eğilimi, volatilitiyi ve momentumu da tahmin etmeye çalışmışlardır. Patel [28], borsa endekslerinin gelecekteki değerlerini öngörmek için iki aşamalı bir yöntem önermiştir. Önerilen yöntemin birinci aşamasında, SVR kullanılırken, ikinci aşamada ise YSA, "random forest" ve SVR yöntemleri kullanılmıştır. Kim [132], çalışmasında optimum özellik dönüşümü (feature transformation) için YSA ve GA'nın birlikte çalıştığı melez bir modeli önermiştir. Önerilen model, Kore bileşik hisse senedi fiyat endeksi değişiminin (KOSPI) gelecekteki yönünü tahmin etmek için kullanılmaktadır. Hassan [133], Hidden Markov Model (HMM), YSA ve GA algoritmalarını birleştirerek hisse senedi fiyatının bir sonraki gündeki değerini tahmin eden bir model geliştirmiştir. Çıkan sonuçları ARIMA ile kıyaslamıştır.

#### 3.4.4 Optimizasyon

Literatürde, finansal verilerin analizinde kullanılan akıllı mekanizmaların tahmin doğruluğunu iyileştirmek için optimizasyon algoritmalarının kullanımı araştırılmıştır. Brasileiro [134], çalışmasında yapay arı koloni (artificial bee colony-ABC) optimizasyon algoritması ve KNN algoritması ile oluşturulan hibrid bir metot önermiştir. KNN, hisse senedi alıp satmak için en uygun zamanın seçilmesi için kullanılmıştır. ABC algoritması ise, en iyi zaman gecikmelerini seçmek ve KNN parametrelerini ayarlamak için kullanılmıştır. Hsieh [135], çalışmasında finansal verilerin analizinde ceza rehberli destek vektör makinesi (penalty guided support vector machine -PGSVM) ile evrimsel ABC'yi (EABC) birlikte kullanmıştır. Bu yaklaşımda EABC, PGSVM parametrelerini optimize etmek için kullanılmıştır. Elde edilen sonuçlar, EABC-PGSVM'nin MLP ve klasik SVM göre üstün olduğunu göstermiştir.

Evans [136], çalışmasında FOREX verilerinde tahmin hatalarını düzeltmek ve MLP'nin en iyi ağ topolojisini bulmak için genetik algoritma (GA) kullanmıştır. Huang [31], çalışmasında SVR parametrelerini optimize etmek ve modele giren verileri seçmek için GA kullanmıştır. Pulido [23], önerdiği çalışmada MLP ağ yapısı parametrelerinin (gizli katmanların sayısı ve katmanlardaki nöronların sayısı ve bağlantısı) ve bileşik (ensemble) MLP mimarisinin bulunması için parçacık sürüsü optimizasyonunu (particle swarm optimization - PSO) kullanmıştır. Ayrıca çalışmada kullanılan bulanık mantık, topluluğu oluşturan bireysel MLP modellerinin bireysel çıktılarını birleştirmek için kullanılmıştır. Abdual-Salam [137], önerdiği yöntemde hisse senedi fiyatlarının tahmini için kullanılacak olan MLP mimarisinin oluşturulması için diferansiyel evrim algoritması (DE) ve PSO'yu karşılaştırmıştır. Pinto [138], çalışmasında çok amaçlı evrimsel sistemi önermiştir. Bu çalışmada, alım/satım stratejilerini ve borsa eğilimlerini optimize etmek için çok amaçlı genetik algoritma kullanılmıştır. Lai [21], Tayvan borsasındaki hisseler için bulanık karar ağacı mekanizması oluşturmuştur. Karar ağacının optimizasyonu için GA (genetik algoritma) kullanılmıştır. Önerilen model ile %82'lik performans başarısına ulaşmıştır. Kim ve Han [32], çalışmalarında GA kullanmışlar ve YSA'ya girecek olan özelliklerin (teknik analiz verilerin) optimizasyonu ile YSA ağ topolojisinin (gizli katmanlardaki nöron sayısı, nöronlar arasındaki ağırlıkların değerleri) optimizasyonunu yapmışlardır. YSA ile ortalama %58.5 olan isabet oranını, GA ile optimizasyon ile ortalama %65.8 oranına kadar çıkarmışlardır. Zhang [33], Standard's & Poor's 500 hisse senedi endeks değerlerini tahmin etmek için YSA'yı IBCO (improved bacterial chemotaxis optimization) ile optimize etmiştir. Önerilen çözüm ile YSA'nın ağırlıkları optimize edilmiştir. Zhu [139], çalışmasında daha önce önerilmiş olan PPO (price percentage oscillator) teknik göstergesini kullanarak Hong Kong Hang Seng endeksindeki değerleri GA ile optimize edilmiş SVM ve GA ile optimize edilmiş YSA yöntemleriyle tahmin etmeye çalışmıştır.

### 3.4.5 Bileşik çözümler (ensemble solutions)

Literatürde, tek bir öğrenme modeli kullanmak yerine bileşik öğrenme modellerinin bir kombinasyonunu kullanılmıştır. Bu stratejiye bileşik öğrenme denir. Bileşik öğrenme modellerinin kullanılması tek bir öğrenme yöntemiyle karşılaştırıldığında genel çözüm performansını artırmak amacıyla kullanılmıştır. Finansal piyasa sorunlarını çözmek için çeşitli bileşik ağ çözümleri bulunmaktadır. Cavalcante [140], çalışmasında ELM ve OS-ELM (online sequential extreme learning machine) bileşik çözümlerini karşılaştırarak hisse senedi piyasalarında alım/satım yapabilen akıllı bir sistem geliştirmiştir. Mabu, Obayashi ve Kuremoto [141], hisse senedi piyasalarında alım/satım kararlarını verebilmek için kural tabanlı bir evrimsel algoritma ile MLP'yi birleştiren

bileşik öğrenme mekanizmasının kullanımını önermişlerdir. Bu yaklaşımda, genetik ağ programlaması hisse senedi kuralları oluştururken, MLP ise borsada işlem yapan için en iyi kuralları seçmektedir. Ballings [142], hisse senedi piyasalarındaki hisselerin hareketlerini tahmin edebilmek için bileşik çözümlerin (random forest, adaboost ve kernel factory) performanslarını sınıflandırıcı modeller (ANN, logistic regression, SVM ve KNN) ile karşılaştırmıştır. Elde edilen sonuçlar bileşik çözümlerinin tek sınıflandırıcılardan daha iyi performans gösterdiğini ortaya koymuştur.

### 3.5 Finansal Verilerin Analizinde Derin Öğrenme

Derin öğrenme metotlarını kullanılarak büyük veriden hiyerarşik bir şekilde anlamlı özellikler çıkartılması, örüntülerin tanımlanması ve makine öğrenme algoritmalarından daha iyi sonuçlar elde edilmesi amaçlanmıştır. Bu amaç doğrultusunda finansal verilerin analizinde de derin öğrenme algoritmaları son yıllarda kullanılmaya başlanmıştır. Ancak derin öğrenme yöntemlerinin kullanarak finansal verilerin tahmin edilmesi hala keşfedilmemiş alanlar olarak kabul edilmektedir. Buradaki zorluk, derin mimari yapılarının, alım/satım modellerine uyarlanmasının araştırılması ve alım/satım işlemleri sırasında oluşan riskin azaltılma yöntemlerinin araştırılmasıdır [17]. Yoshihara [143], uzun vadeli etkilere sahip haber olaylarını ve RBM, DBN derin öğrenme metotlarını kullanarak Nikkei Menkul Kıymetler Borsası'ndaki hisse senedi fiyatlarının eğilimini tahmin etmek için bir yaklaşım önermiştir. Çalışmasında, RBM ve DBN kullanarak piyasa verilerindeki kısa vadeli etkilerden etkilenmemiştir. On adet hisse senedinde önerdiği yaklaşımı uygulamış, hisse senedi tahminindeki hata oranını SVM, DBN yöntemleri ile kıyaslamıştır. Ding [144], tensör ve derin konvolüsyonel sinir ağı hibrit çözümü kullanarak haberlerdeki olayların kısa ve uzun vadeli etkilerinin hisse senedi fiyatları üzerindeki etkisini araştırmıştır. Shen [145], gelişmiş bir derin inanç ağı ve eşlenik gradyan yöntemini (conjugate gradient method) birleştirerek döviz kuralarını tahmin etmek için yeni bir yöntem önermiştir. Önerdiği yöntemi, geleneksel ileri beslemeli sinir ağı ile karşılaştırmış ve derin öğrenme yaklaşımının geleneksel yöntemlerden daha iyi olduğunu göstermiştir (GBD/USD Direct Accuracy YSA ile %41, DBN ile %63). Fischer [20], çalışmasında LSTM, MLP kullanarak 1992-2015 yılları arasındaki S&P 500 endeksinin trend yönünü tahmin etmeye çalışmıştır. Krauss [19], çalışmasında derin ağları, "gradient-boosted-trees" ve "random forest" yöntemlerini birbirleriyle kıyaslamıştır. Chen [146], çalışmasında finansal zaman serisi verilerini "Gramian Angular Field" yöntemiyle iki boyutlu resim haline getirerek CNN ağına girdi olarak kullanmıştır. Gunduz [147], çalışmasında saatlik BIST verilerinin tahmini için CNN yapısı önermiştir. Çalışmasındaki tahmin başarımını f-measure ile ölçmüştür. Kuremoto [148], çalışmasında iki adet RBM'den oluşan DBN modeli kul-

lanarak kaotik zaman serisi verilerinin modellenmesi ve tahmin edilebilmesini sağlamıştır. Önerdiği yöntemin, MLP ve ARIMA'ya göre daha yüksek öngörü hassaslığına sahip olduğunu göstermiştir. Qiu [88], çalışmasında bileşik (ensemble) DBN ve SVR hibrit çözümü önermiştir. Önerdiği çözümü Mackey-Glass zaman serisi, elektrik yükü ve regresyon veri setleri üzerinde denemiş, SVN, DBN, FNN ile kıyaslamıştır.

Tino [149], Alman DAX ve İngiliz FTSE endekslerinin hareketlerini (volatiliy, etc.) tahmin edebilmek için Markov model (MM) ve RNN metotlarını farklı parametreler ile kıyaslamıştır. Elde ettiği sonuçlara göre RNN, MM'den daha iyi sonuçlar verememiştir. Saad [150], 1998'deki çalışmasında hisse senetlerinin tahminindeki yanlış kararları (false alarms) azaltmak için, RNN, TDNN ve PNN, yapay sinir ağlarını kullanmış ve modelleri birbirleriyle kıyaslamıştır. Ribeiro [151], DBN yaklaşımı kullanarak Fransız firmalarının finansal verilerini inceleyip, firmaların iflas tahmin modellerini çıkartmıştır. Önerdiği yöntemi SVM ve RBM ile kıyaslamıştır, DBN ile başarılı sonuçlar aldığı göstermiştir. Deng [152], önerdiği yöntemde DDR (Deep direct reinforcement) yöntemi ve FDDR (Fuzzy deep direct reinforcement) yöntemini, RDNN (Recurrent DNN) ile beraber kullanmıştır. Önerdiği metodu, Çin vadeli işlem piyasası ve emtia vadeli piyasasında (gümüş ve şeker fiyatlarında) uygulamıştır. Wang [153], önerdiği çözümde, derin Q-öğrenme (deep Q-learning; bir reinforcement learning) yöntemini uygulamış, Hong Kong (HSI) ve SP500 endesklerinde önerdiği çözümü test etmiştir. Wang, önerdiği yöntemi, B&H (buy and hold) stratejisi ve RRL (recurrent reinforcement learning) ile kıyaslamıştır. Derin Q-öğrenme yönetimiyle başarılı sonuçlar elde etmiştir. Dixon[154], çalışmasında Intel Xeon Phi işlemcisini (61 çekirdeğe sahip) kullanarak DNN (tamamen bağlı ileri beslemeli derin sinir ağı) uygulamış ve 45 CME (Chicago Mercantile Exchange) vadeli emtia fiyatının yönünü tahmin etmeye çalışmıştır. Önerdiği çözüm (5 katmanlı tamamen bağlı derin sinir ağı) ile %73 doğruluk oranıyla fiyatların yönünü tahmin etmiştir.



#### 4. BÜYÜK VERİ ve ANALİZİ

Tez kapsamında finansal zaman serisi verilerinin analizi yapılırken büyük veri analizi için geliştirilen yazılımlar (Apache Spark) kullanılmıştır. Bunun sebebi, üzerinde çalışılan zaman serisi verilerinin<sup>9</sup>, sensör verileri gibi gerek yapılandırılmamış (unstructured), gerek de büyük veri özelliklerini taşımasından dolayıdır. Veri analizi yapılırken veriler "dataframe" yapısına çevrilmiş ve ilgili çatı yazılımı kullanılmıştır.

**Büyük veri**, diğer veri kümelerine göre çok büyük yapılandırılmamış (unstructured) verileri ifade etmektedir. Büyük veri analizi sırasında keşfedilmemiş bilgiler ortaya çıkabilmektedir. Bu durum, araştırmacıların büyük veri analizine olan ilgisini arttırmaktadır. Büyük veri analizi, internet şirketlerinin büyümesiyle başlamıştır. Google, yüzlerce petabaytlık veriyi işleyip, analiz ederken (her dakikada 72 saatlik videolar YouTube'a yüklenmektedir), Facebook, ayda 10 PB log verisi üretmektedir. Facebook'a günde 750 milyon resim yüklenirken, AliBaba ise günde 10 terabaytlık veri üretmektedir. 2011'de dünyada iki günde üretilen verinin büyüklüğü 1.8 ZettaByte'tır. Bu veri miktarı, insanlığın insanlık tarihinin başlangıcından 2003 yılına kadar ürettiği veriden bile büyüktür. Üretilen verinin büyüklüğü gün geçtikçe hızla artacaktır [155].

##### 4.1 Büyük Veri Tanımı ve Özellikleri

Literatürde, büyük veri, geleneksel verilerden farklı olarak tanımlanmaktadır. Büyük veri, "*hacim*" (*volume*), "*çeşitlilik*" (*variety*), "*hız*" (*velocity*), "*değer*" (*value*), "*değişkenlik*" (*variability*), "*gerçeklik*" (*veracity*) açısından geleneksel verilerden farklı değerlendirilmektedir. Geleneksel bilgisayarlar ve sistemler, Google, Yahoo ve Facebook gibi İnternet şirketleri 2000'li yılların başında büyük miktarda veri toplamaya başladığında büyük verileri işlemek, analiz etmek ve yönetmek için yeterli değildi. Böylece, büyük verileri işlemek için yeni sistemler, yeni yaklaşımlar ve çözümler geliştirmek zorunda kaldılar. Google, büyük verilerin paralel işlenmesi için MapReduce algoritmasını önerdi. Yahoo, MapReduce algoritmasını geliştirerek, Apache Hadoop olarak çatı yazılımını açık kaynak olarak kodladı. Apache daha sonra Apache Spark'ı (*Apache Spark*, verileri önbelleğe almasından dolayı Hadoop'dan daha hızlı bir ya-

<sup>9</sup><https://www.datamation.com/big-data/structured-vs-unstructured-data.html>

zılım platformu) geliřtirdi. Ancak büyük veri uygulamalarının geliřtirilmesi için hala engeller bulunmaktadır (veri yařam döngüsü yönetimi, veri gizliliđi, veri temsili, enerji yönetimi, tükenebilirlik, artıklık ve ölçeklenebilirlik). Engelleri ařmak için geliřtirmelere ve arařtırmalara devam edilmektedir [155], [156].

## 4.2 Büyük Veri Depolama

Büyük veri depolama yöntemleri, geniş depolama gereksinimleri, verilerin yönetilme ve analiz edilme sorunları nedeniyle geleneksel veri depolama yöntemlerinden farklıdır. Geleneksel büyük veri depolama sistemleri DAS (direct attached storage), NAS (network attached storage) ve SAN (storage area network) olarak sınıflandırılabilir. Ancak, bu yöntemler büyük veri depolamaya uygun değildirler. Buna ek olarak, literatürde çok miktarda veriyi depolamak için dağıtık depolama sistemleri önerilmiştir. Ancak, bu dağıtık depolama sistemleri için dikkate alınması gereken kritik faktörler vardır [155], [157]:

- **Tutarlılık (Consistency):** Çoklu dağıtık depolama sistemlerinin sürekli çalışması gereklidir. Sunucu hatasını önlemek için de aynı verinin birden fazla kopyasının sistemde olması gerekir.
- **Kullanılabilirlik (Availability):** Sistemde daha fazla sunucunun olması, daha fazla sorun ve arızanın oluşmasına neden olabilir.
- **Bölme Toleransı (Partition Tolerance):** Sistemde birden çok sunucu, ağ yoluyla birbirine bağlıdır. Ağda bir arızanın olması, tüm sistemin düzgün çalışmasına engel olabilir. Dağıtık tüm sistemlerin bağlantı, düğüm ve ağ sorunları için belirli toleranslara sahip olması gerekir.

Dağıtık sistemler, CA (tutarlılık ve kullanılabilirlik özelliklerine sahip sistemler), CP (tutarlılık ve bölme toleransı özelliklerine sahip sistemler) ve AP (kullanılabilirlik ve bölme toleransı özelliklerine sahip sistemler) olarak sınıflandırılır [158]. Bu kritik faktörlerin aynı anda, aynı sistemde yerine getirilmesi mümkün değildir [159]. Bundan dolayı, büyük veri depolama mekanizmaları yıllar içinde geliřtirilmiştir.

Geliřtirilen büyük veri depolama mekanizmaları, dosya sistemleri, veritabanları ve programlama modelleri olarak sınıflandırılırlar. Dosya sistemleri, büyük veri depolama sistemleri uygulamaları için temel oluşturmaktadır. Büyük veri sistemleri için farklı dosya sistemleri geliřtirilmiştir. Hadoop dağıtık dosya sistemi (HDFS) [160], "Cosmos" (Microsoft'un geliřtirdiđi) [161], Haystack (Facebook'un geliřtirdiđi) [162] ve



Google Dosya Sistemi (GFS) [163] büyük veri sistemleri için geliştirilen dosya sistemlerinden bazılarıdır.

Büyük veri depolama alanı için başka bir gelişme de büyük veriler için veritabanlarının geliştirilmesidir. Büyük veriler için veritabanlarının geliştirilmesinin nedeni, geleneksel ilişkisel veritabanlarının, büyük verilerin depolanma gereksinimlerini karşılamıyor olmasıdır. Büyük verilerin depolanması için son zamanlarda NoSQL veritabanları geliştirilmeye başlanmıştır. NoSQL veritabanları özelliklerine göre dört farklı türe ayrılır: Anahtar-değer (Key-value), Sütun-tabanlı (column-oriented), Döküman-tabanlı (document-oriented) ve Grafik-tabanlı (graph-based) veritabanları [155].

- **Anahtar-değer (Key-value) Veritabanları:** Veri, anahtar-değer modelinde saklanır. Modeldeki anahtarlar benzersizdir ve değerler bu anahtarlarla bağlantılıdır. Dynamo (Amazon) [164], Voldemort (Linkedin) [165], Azure Table Storage (Microsoft), MemcacheDB, Redis, Riak, Scalaris (Apache) ve Berkeley DB anahtar-değer veritabanlarına örnektir [155],[166].
- **Sütün-tabanlı (Column-oriented) Veritabanları:** Sütun yönelimli veritabanlarında, sütunlar veriyi bölmek ve depolamak için kullanılır. BigTable [167], Cassandra (Facebook) [168], HBase (Apache)<sup>10</sup>, HyperTable<sup>11</sup>, ve C-Store<sup>12</sup> sütun yönelimli veritabanlarına örnektir [169]. Sütun yönelimli veritabanları, okuma için optimize edilmiş sistemler olmasına karşın, geleneksel ilişkisel veritabanı yönetim sistemleri (RDBMS) yazma için optimize edilmiş sistemlerdir.
- **Döküman-tabanlı (Document-oriented) Veritabanları:** Döküman-tabanlı veritabanlarında her kayıt, aslında bir dökümandır. Dökümanlar, JSON benzeri Binary JSON (BSON) formatında saklanır. Her bir eleman, bir alan adı ve belirli tipte bir değerden oluşur. İlişkisel veritabanındaki tablolar, koleksiyon (collection); satırlar, döküman (document); sütunlar, alan (field) olarak adlandırılır. Anahtar-değer veritabanlarına benzemekle beraber, daha karmaşık yapıya sahiptir. Buna ek olarak, anahtar-değer model özelliklerini de korur. MongoDB [170], SimpleDB (Amazon'un web servisi) [171], CouchDB (Apache, JSON format) [172] döküman-tabanlı veritabanlarına örnektir.
- **Grafik-tabanlı (Graph-based) Veritabanları:** Grafik tabanlı veritabanlarında satırlar ve tablolar yoktur. Veriler, grafik olarak gösterilir (OrientDB<sup>13</sup>, Neo4J<sup>14</sup>).

<sup>10</sup><https://hbase.apache.org>

<sup>11</sup><http://www.hypertable.com>

<sup>12</sup><http://db.csail.mit.edu/projects/cstore/>

<sup>13</sup><http://orientdb.com/>

<sup>14</sup><http://neo4j.com/>

### 4.3 Büyük Veri Analizi ve Öğrenme

Geleneksel paralel işleme modellerinin yetersizliğinden dolayı, büyük verilerin işlenmesi ve analizi için bazı paralel işleme modelleri ve motorları geliştirilmiştir. **Map-Reduce**, önemli ve popüler bir paralel işleme programlama modelidir ve iki ana işlevden oluşur: haritalandırma (map) ve azaltma (reduce) [173]. **Haritalandırma işlevi**, girdi anahtar-değer çiftlerini işleyerek, ara anahtar-değer çiftlerini üretir. **Azaltma işlevi**, düğüm değerlerini birleştirir ve toplar. Bu işlevler paralel olarak yapıldığında büyük veriler hızlı ve başarılı şekilde işlenmiş olur. Hadoop yazılımı [174], MapReduce programlama modelini uygulayan büyük veri işleme çerçeve yazılımlarından biridir. Diğer önemli paralel işlem yapabilen model ve yazılımlar ise şunlardır: Dryad (genel amaçlı dağıtık çalışan paralel işlem motoru) [175], All-Pairs (biyo-informatik veri madenciliği için kullanılan yazılım) [155], Pregel (büyük boyutlu grafikleri işleyen yazılım) [176], Spark (hafıza önbellekleme nedeniyle Hadoop'tan daha hızlı çalışan çerçeve yazılımı) [166], Storm (gerçek zamanlı akış verilerini işleyen yazılım) [166], Flink [166], H2O (matematik ve makine öğrenme kütüphanelerini içeren paralel işlem motoru) [177],[166],[155].

Büyük veri analiz işlemlerinden birisi de veri öğrenmesidir (data learning). Veri öğrenmesi ile gelen verilerden modeller çıkartılır. Literatürde, paralel olarak çalışabilen, büyük veriyi işleyebilen, birçok makine öğrenme algoritmasını içerisinde barındıran çeşitli araç, geliştirme ortamı ve yazılımlar bulunmaktadır. Apache Mahout [178], Apache Spark MLlib<sup>15</sup> [179], H2O [166], SAMOA(Scalable Advanced Massive Online Analysis) [180], Flink-ML [166], Weka [181], Oryx<sup>16</sup> ve Vowpal Wabbit, geliştirme ortam ve araçlarına örnektir [166].

Ayrıca, Spark ve diğer derin öğrenme kütüphaneleri ile derin öğrenme uygulanabilir. "SparkNet"<sup>17</sup>, "CaffeOnSpark"<sup>18</sup>, "SparklingWater"<sup>19</sup>, "Deeplearning4J"<sup>20</sup> ve "TensorFlow on Spark"<sup>21</sup> derin öğrenme algoritmalarının büyük verilere uygulanmasını sağlayan kütüphane ve araçlardır. "SparkNet" ve "CaffeOnSpark", "Apache Spark" ve "Caffe" ile çalışabilen ve derin öğrenimin uygulanmasını sağlayan projelerdir. "SparklingWater", "H2O" ile "Apache Spark"ın birlikte çalıştığı derin öğrenme kütüphanesidir. "Deeplearning4J", "Apache Spark" ve "Hadoop" ile çalışan, derin öğrenme ağlarının uygulanmasını sağlayan java tabanlı bir kütüphanedir. "TensorFlow on Spark",

<sup>15</sup><http://spark.apache.org/mllib/>

<sup>16</sup><https://github.com/cloudera/oryx>

<sup>17</sup><https://github.com/amplab/SparkNet>

<sup>18</sup><https://github.com/yahoo/CaffeOnSpark>

<sup>19</sup><https://databricks.com/blog/2014/06/30/sparkling-water-h2o-spark.html>

<sup>20</sup><https://deeplearning4j.org/>

<sup>21</sup><https://github.com/adatao/tensorspark>

"Apache Spark" ile "TensorFlow"un birlikte çalıştığı, derin öğrenme uygulamalarının yapılmasını olanak sağlayan kütüphanedir.





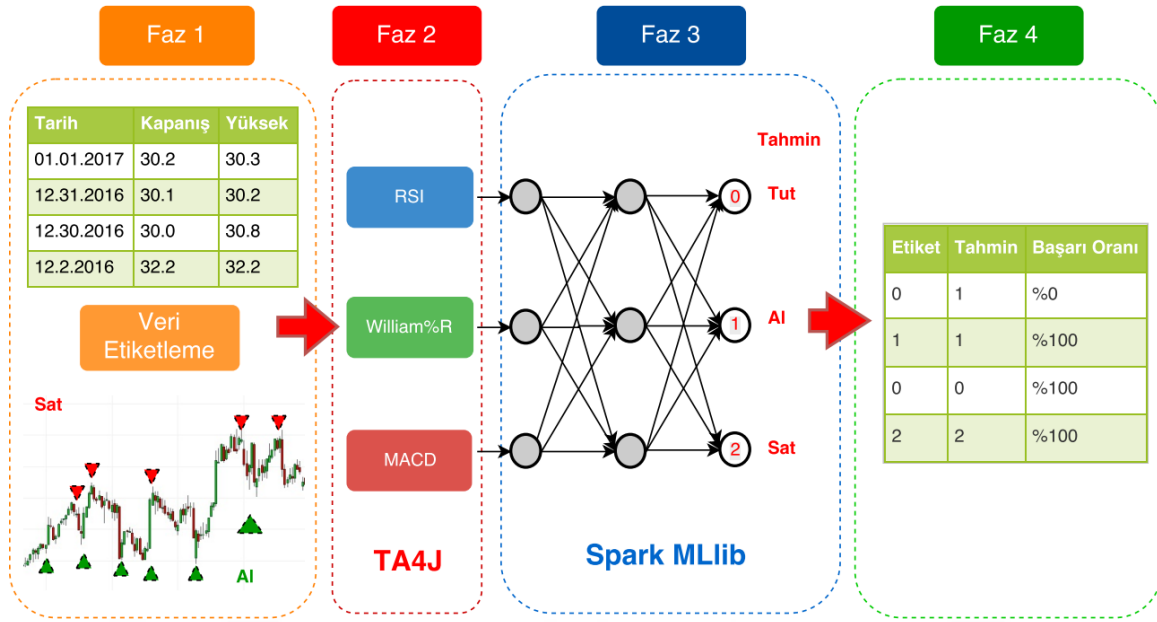
## 5. TEKNİK ANALİZ VERİLERİ KULLANARAK YAPAY SİNİR AĞI İLE FİNANSAL ANALİZ YÖNTEMİ (MLP-TA)

### 5.1 Motivasyon

Literatürde finansal analiz ve alım-satım modelleri geliştirilmesine yönelik makine öğrenmesi ve teknik / temel analiz yöntemlerini kullanan çok sayıda çalışma mevcuttur. Bu çalışmaların genel yaklaşımları finansal zaman serisi verilerinin analizini bir regresyon problemi olarak ele alıp, değer tahmini yapmak veya zaman serisi verilerindeki en yüksek ve en düşük noktaları belirleyerek alım-satım stratejileri oluşturmaktır. Bu konuda belirli bir başarımlar sağlanmıştır. Fakat genellikle bu çalışmalar belirli bir hisse senedi / endeks veya varlık için tasarlanmış olup, her durumda işlevini koruyabilecek şekilde genel bir modele ulaşılamamıştır. Bu tez kapsamında bu amaca yönelik olarak hem genel kabul görmüş al-sat stratejilerinden ve hesaplamalı zeka modellerinden daha iyi bir getiri sağlanması amaçlanmaktadır, hem de geliştirilen modelin genel kullanımı mümkün olabilecek ve daha kontrollü (daha az riskli) çalışması hedeflenmektedir.

Önerilen çalışmayla [182], teknik analiz verileri ile yapay sinir ağı modelinin birleştirilmesinde yenilikçi bir yaklaşım sunulmuştur. Çalışmada, gerçek finansal veriler kullanılarak her fiyat noktasında "Al", "Sat", "Tut" noktaları belirlenmektedir. Önerilen yöntemde teknik analiz verilerinin fiyatlar üzerine uygulanması, özellik vektörünün oluşturulması ve finansal zaman serisi verilerinin sınıflandırma problemine dönüştürülmesi hedeflenmektedir. Son olarak, belirlenen noktalara göre gerçek bir alım-satım senaryosu oluşturularak sonuçlar değerlendirilmektedir.

Tez kapsamında önerilen metot ile, finansal zaman serisi verileri, en çok tercih edilen teknik analiz göstergelerini kullanarak (MACD, RSI, William%R) bir dizi "Al", "Sat", "Tut" sinyallerine dönüştürülmektedir. Önerilen yöntemde, çok katmanlı algılayıcı (MLP) yapay sinir ağı modeli, 1997 ve 2007 yılları arasındaki günlük Dow-30 hisselerinin fiyatları ile eğitilmektedir. Eğitim aşamasında "Apache Spark" büyük veri kütüphanesi kullanılmaktadır. Eğitilmiş model daha sonra 2007-2017 yılları arasındaki verilerle test edilmektedir.



Şekil 5.1: MLP-TA yöntemi

## 5.2 Önerilen Metot (MLP-TA)

### 5.2.1 Önişleme (veri kümesi dönüşümü)

Önerilen yöntem (*MLP-TA: "Multilayer Perceptron with Technical Analysis"*), Şekil 5.1 'de de gösterildiği gibi 4 ana fazdan oluşmaktadır. İlk fazda hisse senedi verileri (açılış fiyatı-"open", gün içerisindeki en yüksek fiyat-"high", gün içerisindeki en düşük fiyat-"low", kapanış fiyatı-"close", hacim-"volume", düzeltilmiş kapanış fiyatı-"adjusted close") CSV dosyasından okunduktan sonra, tüm verilerdeki değerler (açılış fiyatı, gün içerisindeki en yüksek fiyat, gün içerisindeki en düşük fiyat, kapanış fiyatı) "kapanış fiyatı/düzeltilmiş kapanış fiyatı" oranı kullanarak normalize edilir. Daha sonra, 11 günlük pencere içerisinde hisse verileri kaydırılarak, pencere içerisindeki en yüksek noktalar "Sat", en düşük noktalar "AI", geri kalan noktalar "Tut" olarak etiketlenir. Şekil 5.2'de gösterildiği gibi pencere kaydırılarak etiketleme işlemi uygulanmaktadır. Algoritma 2 ile etiketleme algoritması özetlenmektedir.

### 5.2.2 Teknik analiz ve MLP

İkinci fazda, TA4J<sup>22</sup> (*Technical Analysis For Java*) çatı yazılımını kullanarak, RSI (Relative Strength Index), MACD (Moving Average Convergence and Divergence) ve William %R değerleri tüm değerler için hesaplanarak, bir dosyaya yazılır. MLP-TA

<sup>22</sup><https://github.com/mdeverdelhan/ta4j>

---

**Algoritma 2** Etiketleme Algoritması

---

```
1: function LABELLING()
2:   Input: Financial time series data (stock prices)
3:   Output: Labels with stock prices ("Buy", "Sell", "Hold")
4:   windowSize = 11 days
5:   while(counterRow < numberOfDaysInFile)
6:     counterRow ++
7:     If (counterRow > windowSize)
8:       windowBeginIndex = counterRow - windowSize
9:       windowEndIndex = windowBeginIndex + windowSize - 1
10:      windowMiddleIndex = (windowBeginIndex + windowEndIndex)/2
11:      for (i = windowBeginIndex; i <= windowEndIndex; i ++)
12:        number = closePriceList.get(i)
13:        if(number < min)
14:          min = number
15:          minIndex = closePriceList.indexOf(min)
16:        if(number > max)
17:          max = number
18:          maxIndex = closePriceList.indexOf(max)
19:        if(maxIndex == windowMiddleIndex)
20:          result = "SELL"
21:        elif(minIndex == windowMiddleIndex)
22:          result = "BUY"
23:        else
24:          result = "HOLD"
```

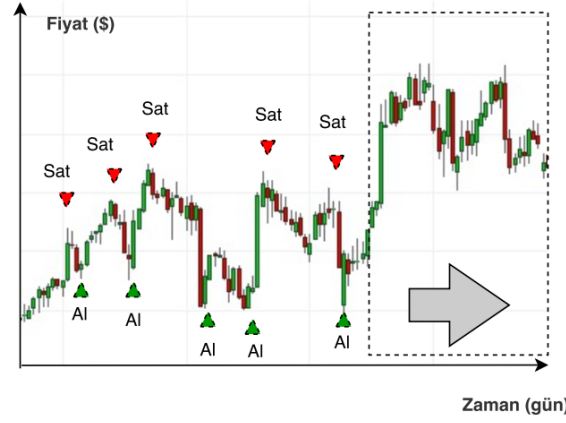
---

yönteminde RSI 14 günlük periyot ile hesaplanmaktadır. MACD değeri için hızlı hareketli ortalama periyodu olarak 12 günlük, yavaş hareketli ortalama metodu 28 günlük kullanılmaktadır. William %R için 10 günlük periyot kullanılmaktadır.

"Data imbalance" problemini çözmek için "Al" ve "Sat" etiketindeki değerler, "Tut" verisinin sayısı kadar yeniden örneklenir. "Data Imbalance" problemini çözmek için literatürde farklı yaklaşımlar bulunmaktadır. MLP-TA yönteminde uygulanan metod "oversampling" sınıfında bulunan "random oversampling of minority class" ıdır [183]. Üçüncü fazda, Apache Spark MLlib çatı yazılımındaki MLP yapay sinir ağı eğitilir. Çok katmanlı yapay sinir ağının girdi katmanında 4 nöron bulunmakta iken, gizli katmanlarda sırasıyla 5 ve 4 adet nöron bulunmaktadır. Eğitilen yapay sinir ağı çıkış katmanındaki 3 nöronuyla, değer tahmini yapmaktadır ("Al", "Sat", "Tut"). Böylelikle, MLP kullanılarak, test verilerindeki al/sat noktaları tahmin edilir. Dördüncü fazda geliştirilen finansal analiz yöntemiyle tahmin edilen sonuçlar ile alım/satım işlemleri yapılır. Algoritma 3 ile MLP-TA yöntemindeki prosedür özetlenmektedir. Ayrıca, bu yöntem için geliştirilen kodlara GitHub<sup>23</sup> üzerinden erişilebilir.

---

<sup>23</sup><https://github.com/omerbsezer/SparkMlpDow30>



Şekil 5.2: Etiketleme yöntemi

---

### Algoritma 3 Önerilen Metod (MLP-TA)

---

- 1: **procedure** ALLPHASES
  - 2:     **Phase 1:**
  - 3:     *dataset = read(open, close, high, low, adjustedClose, volume)*
  - 4:     *dataset.adjustRatio = dataset.close / dataset.adjustedClose*
  - 5:     *adjusted(dataset.open, dataset.close, dataset.high, dataset.low) with adjustRatio*
  - 6:     *calculate Label (Buy/Sell/Hold)*
  - 7:     **Phase 2:**
  - 8:     *calculate RSI, WilliamR, MACD for each line in dataset*
  - 9:     *trainingDataset = dataset.split(dates = 1997 – 2006)*
  - 10:    *testDataset = dataset.split(dates = 2007 – 2016)*
  - 11:    *trainingDataset = resample(trainingDataset)*
  - 12:    **Phase 3:**
  - 13:    *model = MLP(layers = [4, 5, 4, 3], epochs = 200, blocksize = 128)*
  - 14:    *model.train(trainingDataset)*
  - 15:    *model.test(testDataset)*
  - 16:    **Phase 4:**
  - 17:    *evaluateResults()*
- 

### 5.3 Değerlendirme

Önerilen çözüm (MLP-TA), istatistiksel ve finansal olarak değerlendirilmektedir. Dow-30 endeksindeki hisselerin her biri, eğitim ve test verisi için iki sete ayrılmaktadır. 1/1/1997 ve 12/31/2006 arasındaki günlük hisse fiyatları eğitim verisi olarak, 1/1/2007 ve 1/1/2017 arasındaki günlük hisse fiyatları test verisi olarak kullanılmaktadır. Test verisinden çıkan tahmin sonuçları ile daha önce etiketlenen sonuçlar karşılaştırılmakta ve istatistiksel olarak değerlendirilmektedir. Walmart (WMT) hissesi değerlendirme örneği için seçilmiştir. Çizelge 5.1'de WMT'nin hata matrisi (confusion matrix) gösterilmektedir. Çizelge 5.2'de ise, WMT'nin hata matrisi değerlerinin değerlendirmesi ("precision", "recall" ve "F1" değerleri) gösterilmektedir. WMT hissesindeki toplam tahmin başarı oranı (overall prediction rate accuracy) %65.52'dir.



Çizelge 5.1: WMT (Walmart) hissesinin hata matrisi (confusion matrix)

		Predicted		
		0	1	2
Actual	0	889	429	868
	1	41	110	4
	2	21	0	139

Çizelge 5.2: WMT (Walmart) hissesinin değerlendirilmesi

	Class 0	Class 1	Class 2
Precision	0.93	0.20	0.14
Recall	0.41	0.71	0.87
F1 Score	0.57	0.32	0.24

### 5.3.1 Finansal değerlendirme

Ayrıca, MLP-TA metodu, finansal açıdan da değerlendirilmektedir. Finansal değerlendirme aşamasında, hisse tahmin edilen etiket sonucuna göre alınır, satılır veya tutulur. Örneğin, eğer tahmin edilen değer "1" (Al) ise, tüm sermaye ile hisse senedi alımı yapılır. Başlangıç anındaki toplam sermaye \$10000'dır. Mevcut tüm sermaye, her işlem sırasında kullanılır. Eğer tahmin edilen değer "2" (Sat) ise, elde tüm hisse senetleri satılır. Eğer tahmin edilen değer "0" (tut) ise, sistemde hiçbir alım/satım işlemi yapılmaz. Ayrıca, alım/satım işlemleri sırasında, aynı etiket birbiri ardına tekrarlanırsa, yalnızca ilk etiket sinyali ile işlem tetiklenir; sistem, etiket değişinceye kadar tekrar eden sinyalleri dikkate almamaktadır. Senaryomuzda gerçekliliği sağlamak için alım/satım komisyonları ve "stop loss" durumları da kullanılmaktadır (İşlem başına \$1 işlem ücreti ve %5 stop loss kullanılmıştır). "Stop loss" ile, eğer alım işlemi yapıldıysa, hisse fiyatı alınan fiyatın %5 altına inince, eldeki tüm hisseler satılmaktadır. MLP-TA değerlendirilirken, %5 "stop loss" (Çizelge 5.5) ve "stop loss" olmayan (Çizelge 5.4) finansal değerlendirme senaryoları kullanılmıştır.

Çizelge 5.3'de JPM (J.P. Morgan) hissesinin alım/satım örneğinin bir kısmı gösterilmektedir. 2007-2017 arasında toplam 168 işlem (transaction) yapıldığı gözlemlenmektedir. Şekilde de gösterildiği gibi başlangıç sermayesi \$10,000, yapılan işlemler sonunda \$49,181.78 'a ulaşılmaktadır. Senaryoda "Al" sinyali geldiğinde eldeki tüm sermaye ile alım yapılmak da, "Sat" sinyaline kadar işlem yapılmamakta, "Sat" sinyali gelince eldeki tüm hisseler satılmaktadır. Böylelikle "işlem aralıkları" oluşmaktadır. Çizelge 5.3'de gösterildiği gibi 21. günde alım yapılmış, 25.günde satım yapılmıştır. Bu işlem 1. işlemi (transaction) oluştururken, \$516.19 zarar edilmiştir.

Çizelge 5.3: JPM hissesinin örnek "Al-Sat" işlemleri

İşlem Numarası	İşlem Aralığı (Gün)	Kazanç	Anlık Sermaye
1	21-25	-\$516.19	\$9481.81
62	831-836	-\$1532.45	\$19428.23
117	1729-1738	\$819.77	\$33060.87
168	2463-2465	\$1061.5	\$49181.78

MLP-TA metodunu kıyaslayabilmek için, ayrıca aynı test dönemi içinde "Al&Tut" (Buy and Hold - BaH) stratejisi de uygulanmaktadır. "Al&Tut" stratejisinde, hisse test döneminin başında satın alınıp, test döneminin sonunda satılmaktadır. Bu yöntem daha çok, uzun vadeli yatırımcılar tarafından kullanılan stratejidir. "Al&Tut" stratejisi yükselen piyasalarda çok iyi çalışırken, durağan ve alçalan piyasalarda aynı başarılı sonuç alınamamaktadır.

### 5.3.2 Dow30 analizi

MLP-TA yöntemi, 2007-2017 yıllarında Dow-30 hisseleriyle değerlendirilmektedir. Çizelge 5.4 ve Çizelge 5.5'te MLP-TA yönteminin Dow-30 hisseleriyle değerlendirilmesi gösterilmektedir. Çizelge 5.4 ve Çizelge 5.5'teki varlıkların finansal değerlendirme sonuçları aşağıdaki kriterlere göre değerlendirilmektedir: MLP-TA metodunun zaman içerisindeki toplam sermayesi (MLP-TA), MLP-TA metodunun yıllık getirisi (AR), yıllık ortalama işlem sayısı (AnT: Tüm işlem sayısının toplam işlem yılına oranı), başarı oranı (PoS: Başarılı işlemlerin sayısının tüm işlem sayısına oranı), işlemler başına ortalama kâr yüzdesi (ApT: Toplam karın toplam işlemlere oranı), ortalama işlem uzunluğu (L), işlemdeki maksimum kar yüzdesi (MpT: Bir işlemdeki en yüksek kar yüzdesi), işlemdeki maksimum kayıp yüzdesi (MLT: Bir işlemdeki en yüksek zarar yüzdesi), maksimum sermaye (MxC: Ulaşılan en yüksek toplam sermaye), minimum sermaye (MinC: Ulaşılan en düşük toplam sermaye), sistemin boş kalma oranı (IdleR: İşlem yapılan gün sayısının toplam gün sayısına oranı). Değerlendirme metriklerinin formülleri Denklemler 5.1, 5.2, 5.3, 5.4, 5.5, 5.6'da gösterilmektedir.

$$AR = \left( \left( \frac{\text{totalCapital}}{\text{initialCapital}} \right)^{\frac{1}{\text{numberOfYears}}} - 1 \right) * 100 \quad (5.1)$$

$$AnT = \frac{\text{transactionCount}}{\text{numberOfYears}} \quad (5.2)$$

$$PoS = \frac{\text{successTransactionCount}}{\text{transactionCount}} * 100 \quad (5.3)$$

$$ApT = \frac{totalPercentProfit}{transactionCount} * 100 \quad (5.4)$$

$$L = \frac{totalTransactionLength}{transactionCount} * 100 \quad (5.5)$$

$$IdleR = \frac{numberOfDaysInTestData - totalTransLength}{numberOfDaysInTestData} * 100 \quad (5.6)$$

Çizelge 5.4: MLP-TA metodunun Dow-30 hisseleri ile değerlendirilmesi - (2007-2017) (no-stoploss)

Hisse	MLP-TA(NoStop)	AR (NoStop)	AnT	PoS	ApT	L	MpT	MIT	MaxC	MinC	IdleR
MMM	\$15,023.39	4.15%	10.6	68.49%	0.66%	6.0	9.69%	-10.04%	\$15,290.74	\$7,706.45	80.26%
AXP	\$18,130.56	6.13%	10.9	64.00%	1.21%	20.0	43.09%	-31.39%	\$26,111.01	\$8,320.25	39.48%
APPL	\$14,809.34	4.00%	4.5	74.19%	1.92%	29.0	23.28%	-35.64%	\$14,809.34	\$6,913.63	63.43%
BA	\$14,917.73	4.08%	16.0	68.18%	0.49%	7.0	3.20%	-15.12%	\$15,014.40	\$6,221.13	66.77%
CAT	\$10,706.97	0.69%	27.0	65.95%	0.18%	6.0	5.98%	-32.83%	\$12,658.49	\$5,537.86	52.55%
CVX	\$17,976.03	6.04%	19.8	68.38%	0.50%	3.0	12.53%	-9.26%	\$18,129.33	\$9,765.46	78.71%
CSCO	\$28,313.10	10.97%	17.8	71.31%	0.97%	9.0	8.96%	-14.61%	\$28,862.36	\$8,379.60	51.56%
KO	\$23,803.13	9.06%	7.4	82.35%	1.77%	12.0	4.53%	-8.56%	\$23,803.13	\$9,935.43	75.54%
DIS	\$44,811.07	16.18%	18.9	75.38%	1.29%	10.0	11.85%	-9.19%	\$46,897.41	\$7,756.73	45.47%
DD	\$19,977.31	7.17%	15.0	71.84%	0.80%	7.0	12.99%	-26.79%	\$20,854.17	\$7,897.39	70.06%
XOM	\$26,377.36	10.19%	21.0	66.67%	0.76%	7.0	20.27%	-8.05%	\$27,173.96	\$9,484.16	59.30%
GE	\$11,096.69	1.05%	17.8	68.03%	0.24%	9.0	5.58%	-12.63%	\$11,365.43	\$4,529.31	53.82%
GS	\$20,138.67	7.25%	18.4	65.87%	0.69%	8.0	8.60%	-12.49%	\$20,138.67	\$8,432.05	59.03%
HD	\$27,095.16	10.48%	19.8	75.74%	0.86%	8.0	2.89%	-8.28%	\$30,230.11	\$8,901.75	53.40%
IBM	\$20,804.81	7.60%	16.1	70.91%	0.74%	6.0	5.66%	-10.42%	\$22,150.06	\$8,781.07	71.94%
INTC	\$26,368.01	10.18%	18.5	68.50%	0.89%	8.0	7.05%	-21.18%	\$28,220.05	\$8,509.00	59.12%
JNJ	\$16,926.28	5.40%	16.5	74.34%	0.52%	7.0	6.72%	-11.22%	\$17,137.12	\$8,609.93	67.41%
JPM	\$33,715.50	12.92%	18.4	72.22%	1.16%	8.0	27.14%	-20.78%	\$33,715.50	\$9,614.38	56.16%
MCD	\$16,734.63	5.28%	15.2	70.19%	0.53%	2.0	3.79%	-4.01%	\$17,619.43	\$10,000.00	87.76%
MRK	\$33,674.18	12.91%	19.8	71.32%	0.99%	8.0	8.86%	-20.03%	\$34,030.89	\$9,774.58	56.00%
MSFT	\$51,552.19	17.82%	19.8	69.85%	1.29%	8.0	6.28%	-4.58%	\$51,552.19	\$9,430.54	53.08%
NKE	\$50,017.85	17.47%	13.4	73.91%	1.98%	18.0	28.39%	-8.56%	\$61,644.58	\$10,000.00	32.79%
PFE	\$16,625.96	5.22%	19.7	63.70%	0.44%	8.0	4.98%	-8.52%	\$17,048.77	\$7,516.21	54.42%
PG	\$20,909.98	7.66%	17.4	68.91%	0.69%	11.0	10.23%	-14.61%	\$20,909.98	\$9,640.59	45.88%
TRV	\$58,259.75	19.27%	21.0	76.39%	1.32%	8.0	15.18%	-19.24%	\$58,259.75	\$10,000.00	49.76%
UTX	\$15,783.33	4.67%	19.8	68.38%	0.42%	8.0	6.44%	-17.87%	\$18,408.55	\$9,868.25	54.16%
UNH	\$12,639.95	2.37%	11.1	68.42%	0.71%	15.0	8.55%	-30.55%	\$12,639.95	\$3,262.65	54.38%
VZ	\$14,599.98	3.86%	15.3	61.90%	0.41%	7.0	3.59%	-8.58%	\$15,163.80	\$10,000.00	67.13%
WMT	\$31,761.72	12.25%	17.5	72.50%	1.01%	8.0	11.07%	-6.65%	\$31,761.72	\$9,821.49	61.34%
Ortalama	\$24,605.19	9.42%	16.7	70.27%	0.88%	9.3	11.29%	-15.23%	\$25,917.27	\$8,434.82	59.33%
S.Sapma	\$12,641.22	5.03%	4.5	4.35%	0.47%	5.3	9.15%	8.89%	\$13,487.87	\$1,738.80	12.29%

Çizelge 5.4'te MLP-TA modelinin 2007-2017 yılları arasındaki, Dow-30 hisseleriyle (No Stoploss) performansı gösterilmektedir. MLP-TA modelinde yıllık ortalama getiri oranı 9.42% olurken, ortalama toplam sermaye \$24605.19 olmuştur. MLP-TA modelinin finansal işlemlerdeki ortalama başarı oranı 70.27%'dir. Çizelge 5.5'te MLP-TA modelinin 2007-2017 yılları arasındaki, Dow-30 hisseleriyle (5% Stop) performansı gösterilmektedir. MLP-TA çözümünde yıllık ortalama getiri oranı 7.97% olurken, ortalama toplam sermaye \$21520.94 olmuştur. Modelin, finansal işlemlerdeki ortalama başarı oranı 67.33%'tür.

Çizelge 5.6'da MLP-TA modelinin Dow-30 hisseleri kullanılarak "Al&Tut" stratejisi ile karşılaştırmalı performansı gösterilmektedir. MLP-TA modelinde yıllık ortalama

Çizelge 5.5: MLP-TA metodunun Dow-30 hisseleri ile değerlendirilmesi - (2007-2017) (5%-Stoploss)

Hisse	MLP-TA(5%Stp)	AR(5%Stp)	AnT	PoS	ApT	L	MpT	MIT	MaxC	MinC	IdleR
MMM	\$15,234.16	4.30%	12	67.07%	0.63%	5	12.54%	-8.20%	\$15,505.23	\$7,636.83	82.50%
AXP	\$14,727.15	3.95%	15.6	57.01%	0.68%	13	43.09%	-13.75%	\$21,180.43	\$5,952.00	40.84%
AAPL	\$14,742.93	3.96%	5.8	60.00%	1.26%	20	23.28%	-7.33%	\$17,804.25	\$8,653.71	67.15%
BA	\$17,010.05	5.46%	20.3	66.91%	0.50%	5	6.17%	-8.90%	\$18,302.59	\$5,986.53	69.33%
CAT	\$10,252.42	0.25%	31	62.91%	0.12%	4	11.54%	-8.31%	\$12,895.92	\$6,058.70	58.58%
CVX	\$17,907.21	6.00%	20.6	67.38%	0.48%	3	12.53%	-9.98%	\$18,349.65	\$9,765.46	79.39%
CSCO	\$21,182.93	7.79%	22	66.89%	0.64%	7	8.96%	-9.39%	\$21,594.89	\$8,373.11	56.63%
KO	\$17,258.98	5.61%	8.6	76.27%	1.03%	9	4.53%	-12.17%	\$17,258.98	\$7,806.29	76.78%
DIS	\$28,859.03	11.18%	22.3	70.59%	0.82%	8	11.85%	-5.41%	\$30,457.32	\$5,722.72	51.14%
DD	\$17,750.91	5.91%	18	66.67%	0.60%	5	19.97%	-6.65%	\$19,297.54	\$7,294.32	73.98%
XOM	\$18,385.49	6.28%	23.7	66.67%	0.47%	5	20.27%	-5.78%	\$18,868.03	\$18,868.03	62.22%
GE	\$12,663.52	2.39%	21.9	65.33%	0.31%	6	15.30%	-14.68%	\$13,237.47	\$5,146.29	58.21%
GS	\$14,230.22	3.59%	23.2	64.78%	0.39%	5	24.93%	-15.50%	\$14,230.22	\$4,952.86	63.50%
HD	\$15,088.71	4.20%	24.7	68.64%	0.36%	6	2.89%	-7.65%	\$18,299.88	\$8,110.89	57.67%
IBM	\$17,151.82	5.54%	17.2	70.34%	0.54%	5	5.66%	-7.86%	\$19,265.33	\$8,947.69	74.86%
INTC	\$27,965.75	10.83%	22.2	68.42%	0.80%	6	7.05%	-7.18%	\$31,877.34	\$8,904.41	62.20%
JNJ	\$19,043.10	6.65%	17.8	73.77%	0.58%	6	8.85%	-6.99%	\$19,279.80	\$8,484.34	68.17%
JPM	\$49,181.78	17.27%	24.5	67.26%	1.21%	5	27.14%	-8.62%	\$49,181.78	\$7,553.60	59.99%
MCD	\$17,519.35	5.77%	15.5	70.75%	0.56%	2	3.79%	-4.01%	\$18,445.34	\$10,000.00	88.00%
MRK	\$29,081.32	11.27%	22.5	69.48%	0.79%	6	8.86%	-6.71%	\$29,389.65	\$8,781.02	58.79%
MSFT	\$37,923.78	14.26%	22.6	69.03%	0.97%	6	6.28%	-5.77%	\$37,923.78	\$9,366.55	57.23%
NKE	\$22,940.48	8.66%	16.9	67.24%	0.93%	13	28.39%	-8.50%	\$28,257.09	\$7,136.90	36.79%
PFE	\$11,094.86	1.04%	22.9	64.33%	0.16%	6	7.07%	-8.52%	\$11,653.85	\$5,086.75	56.90%
PG	\$20,278.23	7.33%	18.8	68.99%	0.62%	9	10.23%	-5.48%	\$20,278.23	\$9,481.75	48.44%
TRV	\$64,371.78	20.47%	24.1	75.15%	1.26%	7	33.97%	-6.54%	\$64,371.78	\$10,000.00	52.12%
UTX	\$18,540.16	6.37%	24.1	68.48%	0.47%	5	21.00%	-10.23%	\$19,360.46	\$9,530.15	60.75%
UNH	\$9,343.90	-0.68%	15.2	57.69%	0.25%	9	10.67%	-17.73%	\$12,030.98	\$3,293.30	61.42%
VZ	\$12,147.37	1.96%	16.2	61.26%	0.26%	6	22.05%	-5.97%	\$13,267.72	\$9,984.12	69.85%
WMT	\$32,230.01	12.42%	18.5	73.23%	0.98%	7	11.07%	-8.07%	\$32,230.01	\$9,619.12	62.81%
Ortalama	\$21,520.94	7.97%	19.61	67.33%	0.64%	6.86	14.83%	-8.69%	\$22,899.85	\$8,155.08	62.63%
S.Sapma	\$12,017.01	4.88%	5.21	4.60%	0.32%	3.50	9.88%	3.25%	\$11,669.34	\$2,748.50	11.52%

getiri oranı 9.42% olurken, "Al&Tut" stratejisinin yıllık ortalama getiri oranı 10.41% olmuştur. Modelin getirisi, 29 hissenin 15'inde "Al&Tut" stratejisinden daha iyi sonuç getirmektedir (Visa [V] hissesi aynı dönemde yeterli veriye sahip değildir). Sistemimizdeki tüm işlemlerin ortalama başarı yüzdesi (al/sat işlemleri) 70.27% olup, her üç işlemin ikisinde kar elde edilmektedir.

MLP-TA yönteminin performansının daha iyi ölçülmesi için, zaman içerisinde kaydırmalı olarak eğitilip, daha sonrasında testler uygulanmıştır. Uygulanan yöntemde beş yıllık veriler eğitim için kullanılırken, daha sonrasında gelen bir yıllık veriler test için kullanılmıştır. 2007-2017 yılları arasında MLP-TA modelinin yıllık ortalama getirisi 9.42%'dir. MLP-TA modelinin zaman kaydırmalı testi için "KO" hissesi seçilmiştir. "KO" hissesinin seçilmesinin nedeni, "KO" hissesinin ortalama yıllık getirisinin tüm hisselerin ortalama yıllık getirisine olan yakınlığıdır ("KO" hissesinin MLP-TA modeli uygulanarak 2007-2017 yılları arasındaki yıllık ortalama getirisi 9.06%'dır). "KO" hissesine 2007-2017 yılları arasında zaman kaydırmalı MLP-TA yöntemi uygulanmıştır. Zaman kaydırmalı yöntem ile "KO" 2007-2017 yılları arasındaki ortalama yıllık getirisi 10.10% olmaktadır. Zaman kaydırmalı yöntem uygulanarak, "KO" hissesinin getirisi yaklaşık olarak 11% artmıştır. Zaman kaydırmalı yöntem kullanılarak, ortalama yıllık getiri yaklaşık olarak 10% artırılabilir.

Çizelge 5.6: MLP-TA metodunun "Al&Tut" ile kıyaslanması (2007-2017)

Hisse	MLP-TA(NoStop)	AR (NoStop)	MLP-TA (%5Stp)	AR (%5Stp)	BaH	BaH_R
MMM	\$15,023.39	4.15%	\$15,234.16	4.30%	<b>\$29,324.88</b>	<b>11.36%</b>
AXP	<b>\$18,130.56</b>	<b>6.13%</b>	\$14,727.15	3.95%	\$15,157.78	4.25%
APPL	\$14,809.34	4.00%	\$14,742.93	3.96%	<b>\$104,256.20</b>	<b>26.42%</b>
BA	\$14,917.73	4.08%	\$17,010.05	5.46%	<b>\$22,809.31</b>	<b>8.60%</b>
CAT	\$10,706.97	0.69%	\$10,252.42	0.25%	<b>\$21,030.51</b>	<b>7.72%</b>
CVX	\$17,976.03	6.04%	\$17,907.21	6.00%	<b>\$22,968.13</b>	<b>8.67%</b>
CSCO	<b>\$28,313.10</b>	<b>10.97%</b>	\$21,182.93	7.79%	\$13,126.52	2.76%
KO	<b>\$23,803.13</b>	<b>9.06%</b>	\$17,258.98	5.61%	\$23,354.41	8.85%
DIS	<b>\$44,811.07</b>	<b>16.18%</b>	\$28,859.03	11.18%	\$34,368.91	13.14%
DD	\$19,977.31	7.17%	\$17,750.91	5.91%	<b>\$22,197.39</b>	<b>8.30%</b>
XOM	<b>\$26,377.36</b>	<b>10.19%</b>	\$18,385.49	6.28%	\$15,946.05	4.78%
GE	\$11,096.69	1.05%	<b>\$12,663.52</b>	<b>2.39%</b>	\$12,399.64	2.17%
GS	<b>\$20,138.67</b>	<b>7.25%</b>	\$14,230.22	3.59%	\$12,238.97	2.04%
HD	\$27,095.16	10.48%	\$15,088.71	4.20%	<b>\$43,768.70</b>	<b>15.91%</b>
IBM	\$20,804.81	7.60%	\$17,151.82	5.54%	<b>\$21,143.52</b>	<b>7.77%</b>
INTC	\$26,368.01	10.18%	<b>\$27,965.75</b>	<b>10.83%</b>	\$23,656.29	8.99%
JNJ	\$16,926.28	5.40%	\$19,043.10	6.65%	<b>\$23,687.770</b>	<b>9.01%</b>
JPM	\$33,715.50	12.92%	<b>\$49,181.78</b>	<b>17.27%</b>	\$22,092.57	8.25%
MCD	\$16,734.63	5.28%	\$17,519.35	5.77%	<b>\$38,489.77</b>	<b>14.43%</b>
MRK	<b>\$33,674.18</b>	<b>12.91%</b>	\$29,081.32	11.27%	\$18,865.70	6.55%
MSFT	<b>\$51,552.19</b>	<b>17.82%</b>	\$37,923.78	14.26%	\$25,820.00	9.95%
NKE	<b>\$50,017.85</b>	<b>17.47%</b>	\$22,940.48	8.66%	\$48,496.06	17.10%
PFE	\$16,625.96	5.22%	\$11,094.86	1.04%	<b>\$18,953.47</b>	<b>6.60%</b>
PG	<b>\$20,909.98</b>	<b>7.66%</b>	\$20,278.23	7.33%	\$17,434.55	5.72%
TRV	\$58,259.75	19.27%	<b>\$64,371.78</b>	<b>20.47%</b>	\$31,098.53	12.01%
UTX	\$15,783.33	4.67%	\$18,540.16	6.37%	<b>\$20,932.55</b>	<b>7.67%</b>
UNH	\$12,639.95	2.37%	\$9,343.90	-0.68%	<b>\$34,464.65</b>	<b>13.17%</b>
VZ	\$14,599.98	3.86%	\$12,147.37	1.96%	<b>\$24,315.17</b>	<b>9.29%</b>
WMT	\$31,761.72	12.25%	<b>\$32,230.01</b>	<b>12.42%</b>	\$18,389.92	6.28%
Ortalama	\$24,605.19	9.42%	\$21,520.94	7.97%	<b>\$26,923.72</b>	<b>10.41%</b>
S.Sapma	\$12,641.22	5.03%	<b>\$12,017.01</b>	<b>4.88%</b>	\$17,310.32	5.02%

### 5.3.3 MLP-TA yönteminin değerlendirilmesi

Genellikle, böyle uzun bir zaman diliminde (2007-2017) "Al&Tut" stratejisini geçmek çok zordur. Bununla birlikte, MLP-TA modeli, "Al&Tut" stratejisi ile karşılaştırıldığında karışık sonuçlar vermektedir (bazen daha iyi, bazen daha kötü). Bunun nedeni, tüm hisse senetlerinde seçilen teknik indikatörlerin aynı standart değerleri kullanmasıdır. Teknik analizde kullanılan indikatörler ve indikatörlerin parametreleri için eniyileme kullanılması, hisse senedi fiyatlarında daha iyi tahminlerin yapılmasını sağlayacaktır. Bununla birlikte, daha önceki çalışmalarda da görüldüğü gibi, eniyileme tekniklerinin uygulanması toplam "Al-Sat" performansını önemli ölçüde arttırmaktadır. Teknik gösterge parametrelerini her hisse senedi için ayrı ayrı hassas (fine tuning) bir şekilde ayarlanması, "Al-Sat" modelinin genel performansını iyileştirecektir.

Bu çalışmada belirli bir başarı seviyesine ulaşılmasına rağmen MLP'ye girdi olarak seçilen teknik analiz çıktı değerleri RSI (14) ve William%R (10) ve MACD (12,28) değerleri sabit tutularak elde edilmiştir. Bu değerlerin dip ve tepe noktalarını en iyi

yansıtacak deęerler olup olmadıęı konusu incelenmemiřtir. Bu deęerlerin seęilmesinin sebebi, indikatör parametrelerinin piyasa yatırımcıları tarafından en yaygın kullanılan parametreler olmasıdır. Halbuki, bu indikatör parametreleri eniyilenip buna baęlı bir öğrenme modeli oluşturulsa, daha iyi sonuçlar elde etme imkanı ortaya çıkabilecektir. Bir sonraki bölümde bu şekilde bir model üzerinde durulacaktır.



## 6. GENETİK ALGORİTMA İLE OPTİMİZE EDİLMİŞ TEKNİK ANALİZ PARAMETRELERİNİN KULLANILARAK DERİN ÇOKLU ALGILAYICI SİNİR AĞI MODELİ İLE FİNANSAL ANALİZ YÖNTEMİ (DMLP-GA)

### 6.1 Motivasyon

Literatürde, parametre eniyilenmesi için çeşitli eniyileme metotları (Genetik Algoritma [31], [21], [32], "Particle Swarm Optimization" [23], "Firework", "Improved Bacterial Chemotaxis Optimization"[33] vs.) kullanılmaktadır. Literatürde çoğunlukla yapay sinir ağı yapısının eniyilenme yaklaşımları bulunmaktadır [32]. Tez kapsamında yapılan bu çalışmada, daha önceki bölümde (Bölüm 5) önerilen yöntemden farklı olarak derin çoklu algılayıcı sinir ağı modelinde kullanılacak olan eğitim verileri için tepe, dip noktaları al-sat noktaları olarak belirlenmemiştir. Bunun yerine, al-sat noktaları (eğitim verileri), eniyilenmiş indikatör parametrelerinin oluşturduğu çıktılardan alınmıştır. Yani, eniyilenen değerlerle DMLP modeli eğitilerek, tahmin performansının iyileştirilmesi öngörülmektedir.


Bu aşamada, genetik algoritma kullanarak "Al-Sat" noktalarını oluşturmak için optimize edilmiş teknik analiz parametrelerine dayanan bir yöntem önerilmektedir [184]. Model, Apache Spark büyük veri platformu kullanılarak geliştirilmiştir. Optimize edilmiş parametreler daha sonraki adımda, "Al", "Sat", "Tut" noktalarının belirlenmesi için derin çok katmanlı bir algılayıcı (MLP) sinir ağından geçirilmektedir. Modelin doğrulanması için Dow-30 hisse senetleri seçilmiştir. Her bir Dow-30 hissesi için, 1997-2007 yılları arasındaki gün sonu fiyatları eğitim verisi, 2007-2017 yılları arasındaki gün sonu fiyatları test verisi olarak kullanılmıştır.

### 6.2 Önerilen Metot (DMLP-GA)


Bu çalışmada, genetik algoritmayı ve derin çok katmanlı algılayıcıyı (Deep-MLP) kullanan yeni bir yöntem önerilmektedir. Önerilen yaklaşımda (*DMLP-GA: "Deep Multilayer Perceptron with Genetic Algorithm"*), hisse senedi fiyatlarının RSI (Bağlı Güç Endeksi) değerlerini kullanarak hisse senedi alım satım noktaları belirlenmektedir. Literatürde, RSI değerleri yaygın olarak 14 günlük zaman aralığında, 30-70 eşik değerlerinde kullanılmaktadır [185]. RSI değeri 30 değerinin altına düşünce alım, RSI değeri

70 değerinin üstüne çıkınca satım stratejisi uygulanmaktadır. Bu değerler, genetik algoritma ile eniyilenerek daha iyi alım/satım değerlerine ulaşılır [186]. Daha önceki çalışmalardan farklı olarak genetik algoritma ile eniyilenmiş RSI değerleri eğitim verisi olarak kullanılarak DMLP'nin eğitilmesi amaçlanmıştır.

Şekil 6.1'de görüldüğü gibi, DMLP-GA metodu altı faza ayrılmaktadır. İlgili hisse senedi fiyatlarının zaman serilerindeki "Al", "Sat" ve "Tut" noktalarına en uygun olanının belirlenmesi amaçlanmaktadır. Şekil 6.2'de fazlardaki işlemler ayrıntılı bir şekilde gösterilmektedir.



Şekil 6.1: Genetik algoritma ve derin MLP ile hisse senedi tahmini



Şekil 6.2: DMLP-GA modelinin detaylı gösterimi

### 6.2.1 Önişleme (veri kümesi dönüşümü)

Faz 0'da, hisse senedi fiyatları düzeltilmiş kapanış fiyatlarına göre normalleştirilmektedir. Faz 1'de, farklı aralıklardaki (1 ila 20 gün) bağıl güç endeksi (RSI) değerleri ve farklı aralıklardaki (50 ve 200 gün) basit hareketli ortalama (SMA) değerleri TA4J (Java için Teknik Analiz) kütüphanesi kullanılarak hesaplanmaktadır. Trend yönünün "Yukarı" veya "Aşağı" olup olmadığını belirlemek için SMA değerleri hesaplanmaktadır. GA Fazında (Genetik Algoritma Fazında - Faz 2), alçalan ve yükselen eğilimdeki (trend) alım satım noktalarındaki en iyi RSI değerleri, rastgele başlatılmış gen po-




pülasyondan aratılarak, bulunmaktadır. En iyi RSI kromozomları, eğitim verilerinde kullanılmak üzere bir havuzda biriktirilmektedir.

## 6.2.2 Genetik algoritma (GA)

Genetik algoritma fazı farklı aşamalardan oluşmaktadır. Şekil 6.3'te Genetik Algoritma fazının aşamaları gösterilmektedir. İlk olarak, 8 gen den oluşan kromozom popülasyonu (rastgele) oluşturulmaktadır. Şekil 6.4'te kromozomlardaki genlerin yapısı gösterilmektedir. Populasyondaki kromozomları oluşturma metodu şu şekilde yapılmaktadır:

- RSI "Al" değerleri 5 ile 40 arasında rastgele seçilir.
- RSI "Al" zaman aralığı, 5 ile 20 gün arasında rastgele seçilir.
- RSI "Sat" değerleri 60 ile 95 arasında rastgele seçilir.
- RSI "Sat" zaman aralığı 5 ile 20 gün arasında rastgele seçilir.
- Aynı prosedür, hem "Yükselen" hem de "Azalan" trend için takip edilir. Bir kromozomda toplam 8 gen den oluşur.



Şekil 6.3: Genetik algoritma fazı



Şekil 6.4: 8 gen den oluşan kromozom

DMLP-GA yönteminde oluşturulan ilk kromozom popülasyonu 50 kromozomdan oluşmaktadır. Başlangıç popülasyonunun oluşturulmasından sonra, her kromozom için uygunluk değeri (fitness value) hesaplanır. Uygunluk değeri hesaplanırken, RSI (5-20 günlük aralığındaki) ve SMA (50 ve 200 günlük) değerlerini içeren eğitim verileri kullanılmaktadır. Her bir kromozom için uygunluk değeri bulunurken, fitness fonksiyonu kullanılır. Algoritma 4'te genetik algoritma da kullanılan fitness fonksiyonu gösterilmektedir. Fitness fonksiyonunda SMA değerlerine göre eğilim belirlenmekte, daha sonra kromozomdaki genlerdeki değerlere alım/satım yapılarak, o kromozomdaki değerler kullanılarak elde edilebilecek toplam para belirlenmektedir. Uygunluk değeri fitness fonksiyonundan çıkan toplam para olmaktadır.

---

#### Algoritma 4 Fitness Fonksiyonu

---

```

1: function FITNESSFUNCTION()
2:   Input: data[2500][22]
3:   Output: totalCapital
4:   while(k < data.length - 1)
5:     sma50 = Double.valueOf(data[k][21])
6:     sma200 = Double.valueOf(data[k][22])
7:     trend = sma50 - sma200
8:     if(trend > 0) // upTrend
9:       if(data[k][chromosome.getGene(5)] <= chromosome.getGene(4))
10:        buyPoint = Double.valueOf(data[k][0])
11:        shareNumber = (totalCapital - 1.0) / buyPoint
12:        for(int j = k; j < data.length - 1; j++)
13:          if(data[j][chromosome.getGene(7)] >= chromosome.getGene(6))
14:            sellPoint = Double.valueOf(data[j][0])
15:            totalCapital = (shareNumber * sellPoint) - 1.0
16:            transactionCount ++
17:            k = j + 1
18:            break
19:        else // downTrend
20:          if(data[k][chromosome.getGene(1)] <= chromosome.getGene(0))
21:            buyPoint = Double.valueOf(data[k][0]);
22:            shareNumber = (totalCapital - 1.0) / buyPoint;
23:            for(int j = k; j < data.length - 1; j++)
24:              if(data[j][chromosome.getGene(3)] >= chromosome.getGene(2))
25:                sellPoint = Double.valueOf(data[j][0])
26:                totalCapital = (shareNumber * sellPoint) - 1.0
27:                transactionCount ++
28:                k = j + 1
29:                break
30:          k ++
31:    return totalCapital

```

---

En uygun kromozom (en kârlı kromozom), ilk nesil için bulunur. Daha sonra standart GA fonksiyonları, çaprazlama (çaprazlama oranı 0.7) ve mutasyon (mutasyon oranı

Çizelge 6.1: MLP için eğitim verisi örneği

Etiket	RSI Değeri	RSI Aralığı (Gün)	Trend Yönü
1 (Al)	26.0	10.0	0.0 (Aşağı trend)
2 (Sat)	62.0	8.0	0.0 (Aşağı trend)
1 (Al)	29.0	6.0	1.0 (Yukarı trend)
2 (Sat)	79.0	15.0	1.0 (Yukarı trend)
0 (Tut)	50.0	18.0	0.0
0 (Tut)	45.0	7.0	0.0

0.001) kromozom popülasyonuna uygulanır. Birkaç nesilden sonra en uygun kromozom bulunur ve genetik havuz listesine "Al", "Sat" ve "Trend Yönü" bilgileriyle etiketlenerek eklenir. Ayrıca, tutulan etiketli değerler veri havuzuna eklenir. Çizelge 6.1'de popülasyondan seçilen en uygun kromozom ve kromozomun genleri tablo halinde gösterilmektedir.

---

### Algoritma 5 DMLP-GA Yöntemi

---

```

1: procedure ALLPHASES
2:   Phase 0:
3:     dataset = read(open, close, high, low, adjustedClose, volume)
4:     dataset.adjustRatio = dataset.close/dataset.adjustedClose
5:     adjust(dataset.open, dataset.close, dataset.high, dataset.low) with adjustRatio
6:   Phase 1:
7:     calculate RSI Values for 1,2,3,...,20 days intervals foreach line in dataset
8:     trainingDataset = dataset.split(dates = 1997 – 2006)
9:     testDataset = dataset.split(dates = 2007 – 2016)
10:  Phase GA:
11:    create chromosomes population with 8 genes
12:    calculate fitness value for each chromosome with trainingDataset
13:    create fittest chromosome list with trainingDataset
14:  Phase 2:
15:    prepare testDataset for input of deep MLP
16:  Phase 3:
17:    model = MLP(layers = [3, 20, 10, 8, 6, 5, 3], maxEpochs = 200, blockSize = 128)
18:    model.train(trainingDataset)
19:    model.test(testDataset)
20:  Phase 4:
21:    apply to voting mechanism for testDataset
22:  Phase 5:
23:    evaluateResults()

```

---

Önerilen modeldeki genetik algoritmanın kullanılmasının sebebi, kromozomdaki tüm değerlerin ve ihtimallerin değerlendirmeleri durumunda yani tam arama (exhaustive search) durumunun çok uzun süreler almasıdır. Tam arama (exhaustive search) durumunda kromozomdaki hem alçalan hem de yükselen trenddeki genler gözönüne alındığında,  $525^4$  ( $(35 \times 15)^4$ ) durum yaklaşık 75969140625 saniye (~2407 yıl) zaman almaktadır (fitness değeri hesabı ~1sn sürmektedir). Tam arama (exhaustive search) durumunun sadece bir trend yönünde hesaplanmasında  $525^2$  durum yaklaşık 275625 sa-

niye (~3.19 gün) zaman alacaktır. Sadece bir trend yönünün ayrı ayrı hesaplanması (x2), tüm Dow30 hisseleri için ayrı hesaplanma durumu (x30) ve DMLP eğitim seti için 100'lük kromozom seti oluşturma durumunda (x100) tüm testler yaklaşık olarak 19140 günde ( 52.4 yılda) yapılabilecektir. Daha kısa sürelerde etkin sonuçlar alabilmek için genetik algoritma yöntemi kullanılmıştır.

### 6.2.3 DMLP

Önerilen yöntemde, eğitim verileri (1/1/1997 ile 12/31/2006) için Faz 0, 1 ve GA, test verileri (1/1/2007 ile 1/1/2017) için Faz 0 ve 1 uygulanmaktadır. Faz 2'de, test veri seti DMLP'ye girdi olarak verilmeden önce hazırlanır (RSI değerleri, RSI aralık değerleri ve trend yönü etiketleri, test veri kümesi için oluşturulur). Faz 3'te, eğitim ve test veri setleri DMLP'ye aktarılır. DMLP, 7 katmandan oluşur ve katmanlardaki nöron sayıları şu şekilde seçilmiştir: (3, 20, 10, 8, 6, 5, 3). Öğrenme aşamasında, maksimum eğitim sayısı (maximum epoch) 200'dür.

DMLP'den çıkan sonuçlar, hisse senedinin her bir gün için "Al", "Sat", ve "Tut" noktalarının tahminini gösteren bir listedir. Sonuç listesi, tüm test veri setleri için olası tüm RSI aralık (5,6,...,20 gün aralık değerleri) tahminlerini içermektedir. Faz 4'te, olası bir RSI aralığı (5 ile 20) tahminleri bir oylama mekanizması (voting) kullanarak bir değere azaltılmaktadır. Oylama mekanizmasında (voting) tahmini sonuçların sayısı ("Al", "Sat" ve "Tut") sayılır ve sonuçların sayısı 14'ü aşarsa, bu tahmin gerçek tahmin olarak kullanılmaktadır. Algoritma 5 DMLP-GA yönteminin prosedürünü özetlemektedir. Ayrıca, bu metot için geliştirilen kodlara GitHub<sup>24</sup> üzerinden erişilebilir.

## 6.3 Değerlendirme

### 6.3.1 Finansal değerlendirme

Derin çok katmanlı algılayıcıdan çıkan tahmin sonuçlarındaki "Al", "Sat" ve "Tut" etiketleri belirlendikten sonra, sonuçlar 5. Fazda finansal değerlendirme yöntemi kullanılarak değerlendirilmektedir. Finansal değerlendirme yönteminde, her hisse, öngörülen etikete göre alınır, satılır veya tutulur. Hisse alım-satım işlemleri gerçek bir senaryo gibi uygulanmaktadır. Tahmin etiketi "Al" ise, hisse senedi cari fiyatla satın alınır. Tahmin etiketi "Sat" ise, hisse senedi cari fiyatla satılır. Tahmin etiketi "Tut" ise, o noktada herhangi bir işlem gerçekleştirilmez. Senaryonun başlangıç anındaki ana sermaye \$10.000'dir. Her alım satım işlemi mevcut sermayenin tamamı ile yapılır. İşlem

<sup>24</sup><https://github.com/omerbsezer/SparkDeepMlpGADow30>

sırasında, aynı tahmin etiketi ardışık olarak sırayla tekrarlanırsa, yalnızca ilk etiket ile işlem gerçekleştirilmektedir. Etiket değişinceye kadar, tekrarlanan etiketler yoksayılr. Finansal değerlendirmede, gerçek bir senaryo uygulanmaktadır. Senaryoda işlem komisyonları (işlem başına ücret \$1) ve kaybı durdurma durumları (stop loss 10%) uygulanmaktadır. "Stop loss" ile, eğer alım işlemi yapıldıysa, hisse fiyatı alınan fiyatın %10 altına inince, elde tüm hisseler satılmaktadır.

DMLP-GA metodunda, teknik analiz parametresindeki değerler kullanılarak "Al-Sat" noktaları belirlenmeye çalışılmaktadır. Bundan dolayı, model optimize edilmiş teknik analiz verilerini kullanarak "tahmini Al-Sat" noktalarını bulmaya çalışır. Ancak, en iyi "Al-Sat" noktalarının, teknik göstergelerin sonuçlarındaki değerlerle aynı değerleri almadığı gözlemlenmektedir. Bununla birlikte, DMLP-GA metodunun genetik algoritma (GA) fazı test verilerinde uygulanmadığından dolayı, "Al-Sat-Tut" etiketleri belirli bir veri ile ilişkilendirilememektedir. Yani, DMLP-GA modelinin etkinliğini ölçmek için sinir ağı performansı yerine performans karşılaştırmasında yalnızca finansal değerlendirme kullanılmaktadır. DMLP-GA yönteminin değerlendirme sonuçları Çizelge 6.2'de gösterilmektedir.

Dow-30 hisselerinde, aşağıdaki kriterlere göre finansal değerlendirme yapılmaktadır: Önerilen metot ile kazanılan toplam sermaye (DMLP-GA), önerilen modelin yıllık ortalama getirisi (AR), yıllık ortalama işlem sayısı (AnT), işlem başarı oranı (PoS), işlemler başına ortalama kâr yüzdesi (ApT), ortalama işlem uzunluğu (L), işlemdeki maksimum kar yüzdesi (MpT), işlemdeki maksimum kayıp yüzdesi (MLT), maksimum sermaye (MxC), minimum sermaye (MinC), sistemin boş kalma oranı (IR). Değerlendirme metriklerinin formülleri Denklemler 6.1, 6.2, 6.3, 6.4, 6.5, 6.6'da gösterilmektedir.

$$AR = \left( \left( \frac{totalCapital}{initialCapital} \right)^{\frac{1}{numberOfYears}} - 1 \right) * 100 \quad (6.1)$$

$$AnT = \frac{transactionCount}{numberOfYears} \quad (6.2)$$

$$PoS = \frac{successTransactionCount}{transactionCount} * 100 \quad (6.3)$$

$$ApT = \frac{totalPercentProfit}{transactionCount} * 100 \quad (6.4)$$

Çizelge 6.2: DMLP-GA yönteminin Dow-30 hisseleriyle değerlendirmesi

Hisse	DMLP-GA	AR	AnT	PoS	ApT	L	MpT	MLT	MxC	MinC	IR
MMM	\$17,085.05	5.50%	5.5	76.32%	1.68%	24	22.64%	-11.16%	\$18,554.58	\$8,995.87	62.71%
AXP	\$13,908.78	3.35%	7.1	67.35%	1.26%	23	9.99%	-11.25%	\$16,208.65	\$4,046.03	55.08%
APPL	\$37,852.92	14.24%	7.1	75.51%	3.32%	21	9.67%	-12.42%	\$39,870.99	\$7,834.22	58.94%
BA	\$23,533.31	8.94%	5.4	59.46%	3.33%	56	25.50%	-12.88%	\$24,534.32	\$4,388.37	16.96%
CAT	\$19,394.75	6.85%	8.7	61.67%	1.69%	18	11.54%	-10.60%	\$20,437.10	\$6,002.75	55.76%
CVX	\$31,565.85	12.18%	5.9	78.05%	3.12%	21	22.17%	-11.67%	\$31,565.85	\$9,403.57	65.57%
CSCO	\$20,922.80	7.66%	6.5	73.33%	2.03%	22	12.36%	-11.95%	\$20,922.80	\$7,778.66	60.60%
KO	\$26,958.24	10.43%	6.1	85.71%	2.48%	27	9.63%	-11.53%	\$26,958.24	\$9,358.99	54.57%
DIS	\$29,958.82	11.60%	8.7	68.33%	2.26%	29	12.51%	-11.80%	\$33,943.53	\$5,171.40	30.06%
DD	\$15,304.38	4.35%	7.4	66.67%	1.31%	17	11.92%	-13.06%	\$17,146.90	\$6,584.94	64.73%
XOM	\$22,259.96	8.33%	9.4	73.85%	1.39%	23	13.42%	-10.45%	\$22,259.96	\$10,000.00	39.91%
GE	\$19,261.81	6.78%	4.5	51.61%	3.91%	47	104.33%	-10.83%	\$19,281.78	\$3,107.62	42.14%
GS	\$16,090.25	4.87%	7.3	60.00%	1.89%	23	56.84%	-12.06%	\$19,008.11	\$4,541.75	53.93%
HD	\$19,323.46	6.81%	6.1	66.67%	2.05%	21	8.51%	-10.81%	\$20,686.15	\$8,632.65	63.94%
IBM	\$31,134.92	12.03%	5.9	75.61%	3.12%	26	28.14%	-12.79%	\$31,483.38	\$7,977.44	56.99%
INTC	\$17,854.13	5.97%	6.5	64.44%	1.74%	19	8.30%	-11.95%	\$19,951.53	\$7,835.27	65.97%
JNJ	\$19,588.34	6.95%	7.0	81.25%	1.51%	23	11.73%	-12.50%	\$19,954.21	\$9,181.42	55.60%
JPM	\$18,136.83	6.13%	4.8	57.58%	3.16%	70	43.68%	-11.95%	\$18,136.83	\$4,577.41	7.19%
MCD	\$25,295.64	9.72%	6.1	80.95%	2.40%	29	7.19%	-10.83%	\$26,071.86	\$10,000.00	51.55%
MRK	\$23,467.98	8.90%	7.0	72.92%	2.12%	21	10.77%	-10.30%	\$23,467.98	\$7,337.60	58.42%
MSFT	\$33,313.59	12.79%	6.2	76.74%	3.15%	26	9.34%	-11.74%	\$33,313.59	\$8,933.32	54.13%
NKE	\$40,307.46	14.96%	6.5	77.78%	3.50%	21	17.89%	-11.24%	\$49,084.06	\$9,979.20	61.72%
PFE	\$23,219.50	8.79%	8.3	71.93%	1.81%	21	10.24%	-10.80%	\$24,496.08	\$6,611.99	51.95%
PG	\$16,713.78	5.27%	2.2	80.00%	4.20%	150	23.87%	-16.55%	\$16,713.78	\$7,554.79	10.29%
TRV	\$22,120.65	8.26%	4.4	76.67%	2.95%	22	23.51%	-12.47%	\$22,120.65	\$9,833.68	72.80%
UTX	\$14,407.36	3.72%	6.5	73.33%	1.06%	19	7.18%	-11.59%	\$17,906.82	\$9,495.03	65.45%
UNH	\$19,295.40	6.79%	5.2	75.00%	2.07%	11	9.16%	-8.35%	\$19,295.45	\$5,767.37	82.96%
VZ	\$15,455.29	4.45%	7.3	70.00%	1.01%	20	8.53%	-11.06%	\$17,572.32	\$9,585.46	59.13%
WMT	\$20,406.24	7.39%	6.1	78.57%	1.84%	23	8.53%	-11.73%	\$21,107.52	\$10,000.00	60.21%
Ortalama	\$22,556.47	8.47%	5.4	71.63%	2.32%	30	19.28%	-11.67%	\$23,863.97	\$7,604.03	53.08%
S.Sapma	\$6,952.67	3.12%	14.3	8.05%	0.88%	26	19.91%	1.34%	\$7,668.71	\$2,111.94	17.41%

$$L = \frac{\text{totalTransactionLength}}{\text{transactionCount}} * 100 \quad (6.5)$$

$$IR = \frac{\text{numberOfDayInTestData} - \text{totalTransLength}}{\text{numberOfDayInTestData}} * 100 \quad (6.6)$$

### 6.3.2 Dow30 analizi

DMLP-GA yönteminin (Çizelge 6.2) yıllık getiri oranı 8.47% ve başarı yüzdesi 71.63% 'tür. Ayrıca, genetik algoritma modeli de finansal analiz yöntemiyle değerlendirilmektedir. Sadece genetik algoritma kullanılarak elde edilen optimize edilmiş teknik analiz verileriyle yapılan finansal değerlendirme Çizelge 6.3'te gösterilmektedir. Önerilen yöntemin (GA) yıllık ortalama getirisi 11.41%, yapılan işlemlerin başarı oranı 70.88% 'dir.

Çizelge 6.4'de, önerilen yöntemlerin (DMLP-GA), (GA) ve "Al&Tut" (BaH) stratejisinin performanslarının kıyaslanmaları gösterilmektedir. Önerilen yöntemin (GA) yıllık ortalama getirisi 11.41% iken, "Al&Tut" (BaH) yönteminin yıllık ortalama getirisi

Çizelge 6.3: GA yönteminin Dow-30 hisseleriyle değerlendirilmesi

Hisse	GA	AR	AnT	PoS	ApT	L	MpT	MLT	MxC	MinC	IR
MMM	\$22,136.47	8.27%	13.3	72.83%	1.13%	11.0	67.43%	-18.62%	\$22,482.69	\$6,583.49	58.34%
AXP	\$17,849.60	5.97%	8.1	62.50%	2.98%	27.0	191.68%	-15.33%	\$24,143.35	\$3,686.78	39.56%
APPL	\$91,402.33	24.77%	5.1	74.29%	7.87%	56.0	22.56%	-20.79%	\$119,272.44	\$10,000.00	21.92%
BA	\$33,257.97	12.77%	2.3	68.75%	11.97%	82.0	153.63%	-10.13%	\$33,257.97	\$7,005.03	47.70%
CAT	\$20,488.00	7.44%	4.4	60.00%	4.21%	55.0	36.73%	-25.19%	\$31,909.77	\$8,366.15	33.88%
CVX	\$19,312.81	6.80%	12.0	62.65%	1.04%	17.0	22.90%	-15.13%	\$19,313.21	\$7,882.83	41.38%
CSCO	\$25,693.83	9.90%	6.2	74.42%	2.45%	20.0	16.08%	-16.86%	\$26,053.04	\$9,627.76	64.77%
KO	\$19,330.74	6.81%	2.6	94.44%	3.85%	35.0	7.42%	-10.18%	\$19,330.74	\$10,000.00	74.46%
DIS	\$22,435.75	8.42%	6.4	68.18%	2.26%	27.0	28.32%	-13.09%	\$23,248.16	\$7,939.69	52.38%
DD	\$22,700.53	8.54%	7.8	74.07%	1.81%	15.0	12.47%	-15.01%	\$22,700.53	\$8,306.12	67.83%
XOM	\$25,710.99	9.90%	19.3	64.66%	0.81%	8.0	18.86%	-17.28%	\$25,710.99	\$9,862.75	52.62%
GE	\$30,446.40	11.78%	6.5	64.44%	3.27%	31.0	37.15%	-15.56%	\$30,501.84	\$8,144.14	43.84%
GS	\$14,806.92	4.00%	13.8	65.26%	0.93%	15.0	18.45%	-13.28%	\$14,806.92	\$4,316.05	42.53%
HD	\$56,318.78	18.87%	8.3	71.93%	3.52%	31.0	17.50%	-11.43%	\$57,164.64	\$8,697.29	29.63%
IBM	\$29,817.61	11.54%	3.2	77.27%	5.67%	46.0	45.68%	-11.13%	\$29,817.61	\$10,000.00	59.73%
INTC	\$32,661.97	12.57%	6.2	69.77%	3.28%	36.0	12.02%	-12.34%	\$35,200.68	\$10,000.00	37.85%
JNJ	\$22,428.83	8.41%	2.6	88.89%	4.74%	58.0	9.44%	-11.72%	\$22,428.83	\$10,000.00	58.10%
JPM	\$34,587.38	13.21%	16.1	70.27%	1.61%	10.0	79.62%	-15.16%	\$34,587.38	\$9,647.69	52.90%
MCD	\$35,502.32	13.51%	3.8	76.92%	5.36%	61.0	19.46%	-10.83%	\$35,502.32	\$9,983.75	36.34%
MRK	\$23,901.33	9.10%	5.2	72.22%	2.91%	30.0	10.77%	-11.68%	\$23,901.33	\$6,688.97	55.80%
MSFT	\$32,670.76	12.57%	3.5	70.83%	5.82%	48.0	16.41%	-17.65%	\$32,670.76	\$9,175.42	53.61%
NKE	\$32,914.74	12.65%	8.4	74.14%	2.36%	23.0	8.51%	-10.63%	\$36,727.31	\$9,595.73	45.63%
PFE	\$24,422.03	9.34%	4.6	78.13%	3.16%	39.0	20.30%	-21.13%	\$24,422.03	\$8,938.18	49.36%
PG	\$16,512.78	5.14%	26.1	58.33%	0.36%	5.0	28.50%	-15.23%	\$16,514.78	\$7,424.48	58.94%
TRV	\$26,815.77	10.37%	2.8	89.47%	5.63%	83.0	11.81%	-15.90%	\$26,815.77	\$8,608.88	36.70%
UTX	\$28,678.10	11.11%	11.5	67.09%	1.55%	20.0	8.84%	-12.12%	\$32,050.85	\$7,763.67	36.14%
UNH	\$39,884.30	14.84%	12.2	59.52%	2.01%	19.0	11.56%	-20.22%	\$39,891.12	\$3,851.79	35.98%
VZ	\$20,960.35	7.68%	13.1	51.11%	0.91%	13.0	14.37%	-11.06%	\$22,786.66	\$8,921.09	52.18%
WMT	\$31,000.88	11.98%	16.8	73.28%	1.06%	13.0	9.10%	-10.77%	\$31,000.88	\$10,000.00	37.13%
<b>Ortalama</b>	<b>\$29,470.70</b>	<b>11.41%</b>	<b>8.7</b>	<b>70.88%</b>	<b>3.26%</b>	<b>32.2</b>	<b>33.02%</b>	<b>-14.67%</b>	<b>\$31,524.64</b>	<b>\$8,310.96</b>	<b>47.49%</b>
<b>S.Sapma</b>	<b>\$14,572.21</b>	<b>4.18%</b>	<b>5.8</b>	<b>9.42%</b>	<b>2.50%</b>	<b>21.2</b>	<b>42.54%</b>	<b>3.86%</b>	<b>\$18,842.01</b>	<b>\$1,844.20</b>	<b>12.20%</b>

Çizelge 6.4: DMLP-GA, GA, MLP, "Al&Tut" metodlarının kıyaslanması

Hisse	DMLP-GA%10Stp	DMLP-GA_AR	GA%10Stp	GA_AR	Best Chromosome	BAH	BAH_AR
MMM	\$17,085.05	5.50%	\$22,136.47	8.27%	30 19 81 19 25 5 61 5	<b>\$29,324.88</b>	<b>11.36%</b>
AXP	\$13,908.78	3.35%	<b>\$17,849.60</b>	<b>5.97%</b>	21 7 78 16 34 9 65 12	\$15,157.78	4.25%
APPL	\$37,852.92	14.24%	\$91,402.33	24.77%	14 9 98 6 7 2 87 14	<b>\$104,256.20</b>	<b>26.42%</b>
BA	\$23,533.31	8.94%	<b>\$33,257.97</b>	<b>12.77%</b>	11 11 83 16 25 12 77 19	\$22,809.31	8.60%
CAT	\$19,394.75	6.85%	\$20,488.00	7.44%	26 9 83 18 11 6 63 18	<b>\$21,030.51</b>	<b>7.72%</b>
CVX	<b>\$31,565.85</b>	<b>12.18%</b>	\$19,312.81	6.80%	25 12 78 15 38 5 67 12	\$22,968.13	8.67%
CSCO	\$20,922.80	7.66%	<b>\$25,693.83</b>	<b>9.90%</b>	16 19 81 10 22 6 71 12	\$13,126.52	2.76%
KO	<b>\$26,958.24</b>	<b>10.43%</b>	\$19,330.74	6.81%	16 13 85 14 12 9 74 13	\$23,354.41	8.85%
DIS	\$29,958.82	11.60%	\$22,435.75	8.42%	20 5 63 13 39 19 86 9	<b>\$34,368.91</b>	<b>13.14%</b>
DD	\$15,304.38	4.35%	<b>\$22,700.53</b>	<b>8.54%</b>	29 5 68 11 6 6 75 7	\$22,197.39	8.30%
XOM	\$22,259.96	8.33%	<b>\$25,710.99</b>	<b>9.90%</b>	32 5 67 7 35 5 60 6	\$15,946.05	4.78%
GE	\$19,261.81	6.78%	<b>\$30,446.40</b>	<b>11.78%</b>	32 17 65 8 11 6 80 15	\$12,399.64	2.17%
GS	<b>\$16,090.00</b>	<b>4.87%</b>	\$14,806.92	4.00%	38 6 69 5 29 7 83 11	\$12,238.97	2.04%
HD	\$19,323.00	6.81%	<b>\$56,318.78</b>	<b>18.87%</b>	29 7 78 7 26 5 81 14	\$43,768.70	15.91%
IBM	<b>\$31,134.92</b>	<b>12.03%</b>	\$29,817.61	11.54%	31 18 80 15 12 8 81 10	\$21,143.52	7.77%
INTC	\$17,854.00	5.97%	<b>\$32,661.97</b>	<b>12.57%</b>	8 6 71 10 24 6 76 16	\$23,656.29	8.99%
JNJ	\$19,588.34	6.95%	\$22,428.83	8.41%	21 9 79 17 15 9 76 18	<b>\$23,687.77</b>	<b>9.01%</b>
JPM	\$18,136.83	6.13%	<b>\$34,587.38</b>	<b>13.21%</b>	14 5 70 13 31 5 63 5	\$22,092.57	8.25%
MCD	\$25,295.64	9.72%	\$35,502.32	13.51%	21 14 93 8 14 5 82 12	<b>\$38,489.77</b>	<b>14.43%</b>
MRK	\$23,467.98	8.90%	<b>\$23,901.33</b>	<b>9.10%</b>	14 7 71 11 31 16 71 18	\$18,865.70	6.55%
MSFT	<b>\$33,313.59</b>	<b>12.79%</b>	\$32,670.76	12.57%	21 10 81 13 5 6 88 9	\$25,820.00	9.95%
NKE	\$40,307.46	14.96%	\$32,914.74	12.65%	9 5 72 9 21 5 76 11	<b>\$48,496.06</b>	<b>17.10%</b>
PFE	\$23,219.50	8.79%	<b>\$24,422.03</b>	<b>9.34%</b>	15 10 88 8 13 5 69 19	\$18,953.47	6.60%
PG	\$16,713.78	5.27%	\$16,512.78	5.14%	39 7 76 15 33 5 84 1	<b>\$17,434.55</b>	<b>5.72%</b>
TRV	\$22,120.65	8.26%	\$26,815.77	10.37%	31 13 76 15 28 14 92 8	<b>\$31,098.53</b>	<b>12.01%</b>
UTX	\$14,407.36	3.72%	<b>\$28,678.10</b>	<b>11.11%</b>	39 5 91 6 30 6 67 11	\$20,932.55	7.67%
UNH	\$19,295.40	6.79%	<b>\$39,884.30</b>	<b>14.84%</b>	34 9 84 13 36 6 65 15	\$18,464.65	13.17%
VZ	\$15,455.29	4.45%	\$20,960.35	7.68%	13 10 72 16 37 6 60 19	<b>\$24,315.17</b>	<b>9.29%</b>
WMT	\$20,406.24	7.39%	<b>\$31,000.88</b>	<b>11.98%</b>	34 5 66 7 39 5 76 7	\$18,389.92	6.28%
<b>Ortalama</b>	<b>\$22,556.44</b>	<b>8.47%</b>	<b>\$29,470.70</b>	<b>11.41%</b>	-	\$26,923.72	10.41%
<b>S.Sapma</b>	<b>\$6,952.69</b>	<b>3.12%</b>	\$14,572.21	4.18%	-	\$17,310.32	5.02%

10.41%'dir. Genel olarak, literatürde belirtildiği gibi, "Al&Tut" stratejisini böylesine uzun bir zaman periyodunda geçmek çok zordur. İlk önerilen stratejinin (DMLP-GA) ortalama yıllık getirisi, 29 hisse senedinin 12'sinde "Al&Tut" stratejisinin ortalama yıllık getirisine göre daha iyi performans göstermektedir (Visa [V] hissesinin aynı dönemde yeterli veri noktası olmadığı için değerlendirilmeye alınmadı). Önerilen GA stratejisinin ortalama yıllık getirisi, 29 hisse senedinin 16'sında "Al&Tut" stratejisinin ortalama yıllık getirisine göre daha iyi performans göstermektedir.

DMLP-GA yönteminin performansının daha iyi ölçülmesi için, daha önce oluşturulan eniyilenmiş teknik indikatör parametreleri eğitim seti olarak kullanılıp, test verisi bir yıllık veriler olarak ele alınmış ve test verileri zaman içerisinde kaydırılmıştır (Ör; Test Verisi: 1/1/2015-31/12/2015). 2007-2017 yılları arasında DMLP-GA modelinin yıllık ortalama getirisi 8.47%'dir. DMLP-GA modelinin zaman kaydırmalı testi için "TRV" hissesi seçilmiştir. "TRV" hissesinin seçilmesinin nedeni, "TRV" hissesinin ortalama yıllık getirisinin tüm hisselerin ortalama yıllık getirisine olan yakınlığıdır ("TRV" hissesinin 2007-2017 yılları arasındaki ortalama yıllık getirisi 8.26%'dır). Test verisinin zaman kaydırmalı olarak uygulanmasıyla "TRV" hissesinin, 2007-2017 yılları arasındaki ortalama yıllık getirisi 6.53% olmaktadır. Zaman kaydırmalı yöntem uygulanarak, "TRV" hissesinin getirisi 2007-2017 yılları arasında bir miktar düşmüştür. Zaman kaydırmalı yöntem kullanılarak, ortalama yıllık getiri üzerinde önemli bir iyileştirme yapılamamıştır.

### 6.3.3 DMLP-GA yönteminin değerlendirmesi

Bu çalışmada belirli bir başarı seviyesine ulaşılmasına rağmen derin çoklu algılayıcı modelinin genetik algoritma ile birlikte çalışması ekstra performans artışı sağlamamıştır. Bunun en önemli sebebi genetik algoritmanın toplam kar kriterine göre eniyileme yapmasıdır. Bu durumda, yerel tepe ve dip noktaları eski önemliliğini yitirmiş olmaktadır. Genetik algoritma toplam karı maksimize ederken ortaya çıkan teknik analiz indikatör parametre çıktıları kısa vadede oluşan "Al-Sat" noktalarını göz ardı edebilmektedir. Halbuki DMLP modeli eğitimi, kısa vade tepe, dip noktalarının sağlıklı bir şekilde tespitine bağlıdır. Bunun sonucunda genetik algoritma ile eniyilenmiş parametrelere oluşan bir eğitim veri seti DMLP için yetersiz kalmaktadır.

Bunun yanı sıra, genetik algoritma hem çalışma zamanı olarak (tek bir veriyi bulması gözönüne alındığında) uzun sürmekte hem de elde edilen eniyilenmiş çıktı değerleri (genellikle) birbirlerine çok yakın değerler almaktadır. Bu durum, DMLP için gerekli farklı verilerden oluşan eğitim setinin oluşturulmasına engel olmaktadır. Bu da DMLP'nin genetik algoritma çıktıları yeteri kadar öğrenememesi neden olmuş ola-



bilir. Yine de elde edilen sonuçlar, belirli bir başarıyı sağlamıştır. Ayrıca, elde edilen sonuçlara göre genetik algoritma, DMLP olmadan daha iyi sonuç vermektedir. Bu durum, bize toplam karın maksimize edilmesi sırasında yerel dip ve tepe noktalarının öğrenilmesinin nispeten daha arka planda kalabildiğini göstermektedir. Bu aşamada, DMLP ve genetik algoritma yaklaşımları ile elde edilebilecek sonuçların belirli bir başarıyı aşmadığı gözlemlenmiştir. Son yıllarda, derin yapay sinir ağları içinde sürekli başarıyı artan şekilde ön plana çıkan derin konvolüsyonel sinir ağı şu anda en iyi başarıyı sağlayan derin yapay sinir ağı modeli olarak görülmektedir. Fakat derin konvolüsyonel sinir ağı ağırlıklı olarak 2 boyutlu görüntü sınıflandırma problemlerinde bu başarıyı sağlamıştır. Elde ettiğimiz sonuçları daha da geliştirebilmek amacıyla derin konvolüsyonel sinir ağının 2 boyutlu modellerde elde ettiği başarıyı finansal verilere uyarlamamız oldukça yenilikçi bir fikir olabileceği söylenebilir. Bir sonraki bölümde bu hedefe yönelik geliştirilen bir model tanıtılacaktır.





## 7. FİNANSAL ZAMAN SERİSİ VERİLERİNİN İKİ BOYUTLU GRAFİK GÖRÜNTÜSÜNE DÖNÜŞTÜRÜLEREK DERİN KONVOLÜSYONEL SİNİR AĞLARI İLE FİNANSAL ANALİZ YÖNTEMİ (CNN-Bİ)

### 7.1 Motivasyon

Derin konvolüsyonel sinir ağları bir çeşit derin yapay sinir ağıdır. Literatürde, derin konvolüsyonel sinir ağları çoğunlukla görüntü ve video alanlarında kullanılmakta olup, iyi başarı oranlarına sahiptir (AlexNet 50-55% başarı oranı, Inception ve ResNet 75-80% başarı oranı) [187]. Ayrıca, literatürde, ilk başarılı sonucu veren derin konvolüsyonel sinir ağı modeli, Yan Lecun'ın önerdiği derin sinir ağı modelidir [15]. Önerdiği LeNet derin konvolüsyonel sinir ağını, MNIST (Modified National Institute of Standards and Technology) veri seti üzerinde el yazısı tanıma için kullanmıştır.

Tez kapsamında önerilen çalışmada, zaman serisi verileri görüntü verisine dönüştürülüp, derin konvolüsyonel sinir ağı kullanılarak finansal zaman serisi verilerinin tahmini yapılmaktadır. Literatürde, zaman serisi verilerinin analizinde derin konvolüsyonel sinir ağlarının kullanımı mevcuttur [34], [35], [36]. Zheng [35], çalışmasında zaman serisi verilerinin analizinde çok kanallı derin konvolüsyonel sinir ağı yapısı önermiştir. Le [36], çalışmasında CNN kullanarak zaman serisi verilerinin sınıflandırılması üzerine çalışmıştır. Hatami [37], önerdiği yöntemde zaman serisi verilerini 2 boyutlu verilere çevirerek, CNN modeli kullanarak sınıflandırmaya çalışmıştır. Ayrıca, literatürde zaman serisi olmayan verilerin de 2 boyutlu görüntü verisine çevrilerek, CNN modelinde kullanılması ile ilgili çalışmalar da bulunmaktadır: Kötü amaçlı yazılım sınıflandırması [188], [189], radar sinyalleriyle yürüyüşü tanıma [190]. Tez kapsamında önerilen yöntem, finansal zaman serisi verilerini 2 boyutlu görüntü verisine çevirmekte ve etiketlemektedir. Önerilen yöntemde MNIST algoritmasında kullanılan derin konvolüsyonel sinir ağına benzeyen yapıda konvolüsyonel sinir ağı yapısı kullanılmaktadır. Finansal zaman serisi verilerinin MNIST veri seti gibi resim halinde oluşturulup, derin konvolüsyonel sinir ağı uygulanmasıyla iyi sonuçların elde edilmesi hedeflenmiştir.

Bu aşamada, zaman serisi verilerinin 2 boyutlu çubuk grafik görüntülerine dönüştürülmesi ve görüntülerin derin konvolüsyonel sinir ağı kullanılarak tahmin edilme metodu önerilmektedir. Finansal zaman serisi verilerini 2 boyutlu görüntülere dönüştürmek

için, her bir fiyat çubuk grafik olarak gösterilmektedir, sonrasında 30 günlük çubuk grafikler birleştirilerek resim elde edilmektedir. Finansal verilerden 30x30 piksel görüntü dosyaları oluşturulmaktadır. Her görüntü için gelecekteki eğilim (trend) bilgisi kullanılarak görüntüler "Al", "Sat", "Tut" olarak etiketlenmektedir. Önerilen yöntemin farklı piyasa koşullarında test edebilmek için 2007-2012 ve 2012-2017 yılları arasında ayrı ayrı testler yapılmıştır. Sonuçlar, daha sonra "Al&Tut" stratejisi ile karşılaştırılmıştır.

## 7.2 Önerilen Metot (CNN-BI)

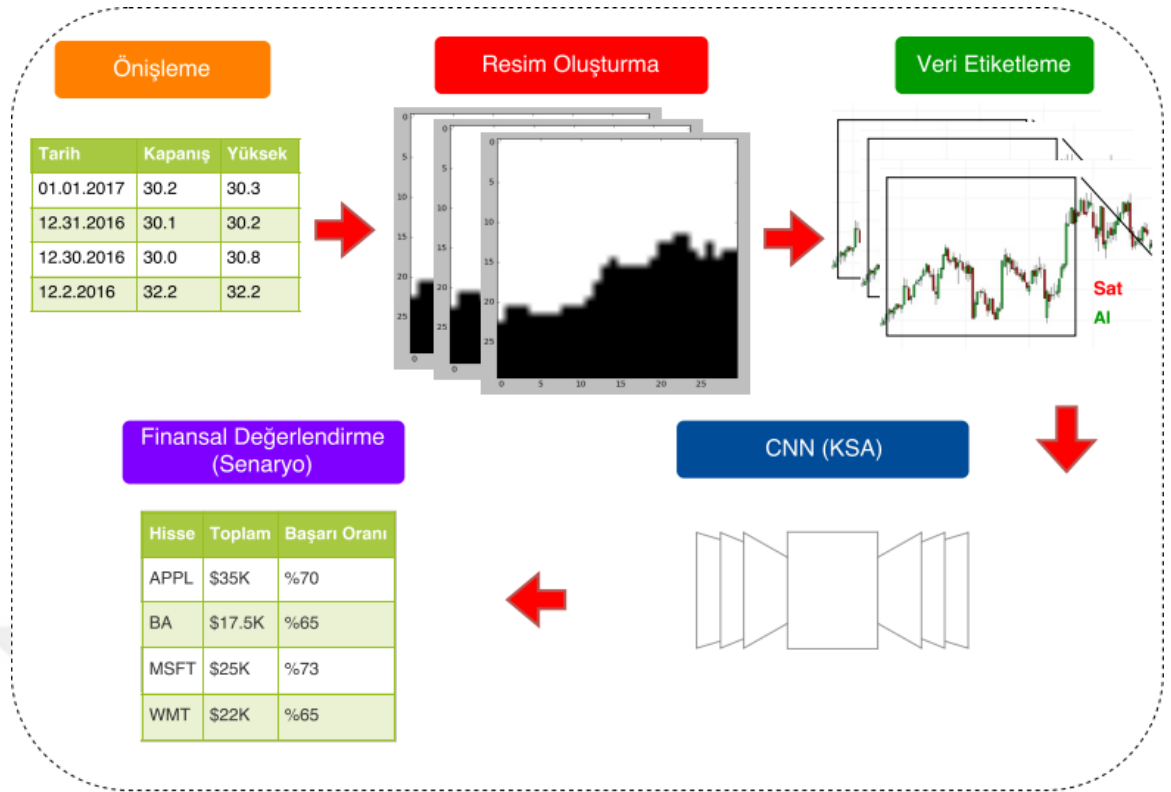
Bu aşamada, "Al", "Sat" ve "Tut" noktalarını hisse senedi verilerinden belirleyen, zaman serisi verilerinden görüntü dosyaları oluşturabilen, derin konvansiyonel sinir ağını farklı bir yaklaşım olarak kullanarak öğrenebilen ve yeni verilen zaman serisi verilerini sınıflandırabilen bir metot önerilmektedir. Önerilen metotta (*CNN-BI: "Convolutional Neural Network using Bar Image"*), zaman serisi verileri, hisse senedi fiyatlarının çubuk grafiklerinden oluşan görüntü dizilerine dönüştürülmektedir. Dönüştürülen her resim hisse senedi fiyatlarını (y eksenini) ve zamanı (x eksenini) içerir. Ayrıca, her 30x30 piksellik görüntü 30 günlük hisse senedi fiyatlarını içermektedir. Şekil-7.1 'de görülebileceği gibi, CNN-BI yöntemi beş ana faza ayrılmıştır: Veriler çıkarılması /dönüştürülmesi, görüntülerin oluşturulması, görüntülerin etiketlenmesi, konvolüsyonel sinir ağı (CNN) analizi ve finansal değerlendirme aşamaları. Amacımız algoritmik al-sat işlemlerinde maksimum kar elde etmek için hisse senedi fiyatlarındaki en uygun al-sat noktalarını bulmaktır.

### 7.2.1 Ön işleme (veri kümesi dönüşümü)

Çalışmamızda, Dow 30 hisse senetleri, "finance.yahoo.com" adresinden indirilmektedir. Eğitim verisi olarak, 1/1/1997 ile 12/31/2006 tarihleri arasındaki hisse senedi fiyatları ve 1/1/1997 ile 12/31/2011 tarihleri arasındaki hisse senedi fiyatları, test verisi olarak da, 1/1/2007 ile 12/31/2011 tarihleri arasındaki hisse senedi fiyatları ve 1/1/2012 ile 1/1/2017 tarihleri arasındaki hisse senedi fiyatları kullanılmaktadır. İlk adımda, verilerin çıkarılma/dönüştürme fazında, fiyatlar normalize edilir.

### 7.2.2 Görüntü oluşturma


Görüntü oluşturma fazında, siyah-beyaz çubuk grafiklerin elde edilmesi için zaman serisi verileri kullanılır. İlk adımda, 30 günlük pencereye karşılık gelen zaman aralığının



Şekil 7.1: CNN-BI metodu

daki hisse senedinin günlük kapanış fiyatları normalleştirilir. Her günlük hisse senedi fiyatı, bir fiyat çubuğu grafiği olarak gösterilir. 30x30 piksellik görüntü oluşturmak için 30 günlük değerler birleştirilir. Metot uygulanırken, 1/1/1997 - 12/31/2006 zaman aralığında her bir hisse için yaklaşık 2500 görüntü, 1/1/1997 - 12/31/2012 zaman aralığında her bir hisse için yaklaşık 3750 görüntü eğitim verisi olmak üzere üretilmiştir. Ayrıca, 1/1/2007 - 1/1/2017 zaman aralığında her bir hisse için yaklaşık 2500 görüntü, 1/1/2012 - 12/31/2016 zaman aralığında her bir hisse için yaklaşık 1250 görüntü test verisi olmak üzere üretilmiştir. Her hissenin farklı karakteristik özelliği olmasından dolayı her bir hisse için ayrı ayrı eğitim ve test görüntüleri oluşturulmuştur.

Verilerin etiketleme fazında, fiyatların gelecekteki eğilimini (trendi) göstermek için her resim etiketlenir. Denklem 7.1'de gösterildiği gibi, her referans trend eğimi hesaplanarak ve her görüntü için bir listede saklanır. Listede saklanan referans eğimler daha sonra kendi içinde sıralanır. Sıralanan eğimlerden (etiketleme aşamasında kullanılması için) iki eğim değeri elde edilir. Her bir görüntü "Al", "Tut" ve "Sat" olarak etiketlenirilirken, her resmin anlık trend eğimi de hesaplanır (Denklem 7.2). Anlık eğilimin daha uzun (15 günlük eğilim) vadede hesaplanmasının sebebi, kısa vadedeki olabilecek anlık eğilim değişiminden (noise elimination) etkilenmemek içindir. "TrendLabel", Denklem 7.3 gibi her resim için tanımlanır. Verilerin etiketlenmesinden sonra, her bir etiket ve ilgili görüntü, öğrenme aşaması için bir dosyada birleştirilir. Bu yöntemin



Şekil 7.2: 30x30 piksel örnek görüntüler ve görüntülerin "Al", "Sat", "Tut" etiketleri

amacı, al-sat kararlarının etiketli görüntülerini girdi olarak kullanıp derin konvolüsyonel sinir ağının tahmin yapabilmesini sağlamaktır. Şekil 7.2, örnek resimleri ve oluşturulan resimleri etiketlerini göstermektedir.

$$slopeRef[1..n] = \frac{value34 - value30}{day34 - day30} \quad (7.1)$$

$$slopeCurrent = \frac{value45 - value30}{day45 - day30} \quad (7.2)$$

$$trendLabel = \begin{cases} 1 = ('Buy'), & \text{if } slopeCurrent > if \text{ slopeRef}[3n/5] \\ 0 = ('Hold'), & \text{if } (slopeRef[2n/5] < slopeCurrent) \\ & \text{and } (slopeRef[3n/5] > slopeCurrent) \\ 2 = ('Sell'), & \text{if } slopeCurrent < if \text{ slopeRef}[2n/5] \end{cases} \quad (7.3)$$

### 7.2.3 CNN

Öğrenme fazında, oluşturan görüntüleri eğitmek ve test etmek için bir konvolüsyonel sinir ağı (CNN) oluşturulur. Konvolüsyonel sinir ağı (CNN) (Şekil 7.3) sekiz katmandan oluşur: Girdi katmanı, iki konvolüsyonel katman, bir maksimum havuz (max-pooling) katmanı, iki "dropout" katmanı, tam bağlı katman ve çıktı katmanı. "Dropout" katmanları ile verilerin eğitilmesi sırasında "overfit" olması engellenmeye çalışılır. Ayrıca hiper parametreler ("epoch" sayısı, "kernel" büyüklüğü, vs), farklı denemelerdeki sonuçlar gözlemlenerek ince ayarlanmıştır.

Önerilen CNN-BI modelinde, uygulanan CNN yapısı, MNIST algoritmasında kullanılan derin CNN yapısına benzemektedir. MNIST yönteminde kullanılan LeNet CNN

yapısı, girdi olarak 28 x 28 görüntüler kullanmakta ve altı katmandan oluşmaktadır [15]. Ayrıca, daha fazla katman ekleyerek algoritmanın karmaşıklığı artmaktadır. Çok büyük bir eğitim seti olmadan giderek daha da karmaşıklaşan bir ağ yapısı, "overfit"e neden olurken, test verilerinden elde edilen doğruluğu da (accuracy) azaltabilmektedir. Gelecekteki çalışmalarda, daha fazla eğitim verisi kullanılarak, daha fazla katmanı bulunan daha derin modeller uygulanabilir. Önerilen model ile "proof of concept" bir tasarım önerilmektedir. Gelecekteki çalışmalarda farklı CNN yapıları önerilerek sonuçlar daha da iyileştirilebilir.

Konvolüsyon katmanları konvolüsyon işlemini yapma yeteneğine sahiptir. Denklem 7.4 bir ekseninde konvolüsyon işlemini göstermektedir (t zaman gösterir). Derin konvolüsyonel sinir ağlarında, konvolüsyon işlemi iki boyutlu görüntülere uygulanır. Denklem 7.5 iki boyutlu bir görüntünün konvolüsyon işlemini göstermektedir (I girdi görüntüsünü, K "kernel" gösterir). Ek olarak Denklem 7.6, sinir ağı mimarisini açıklamaktadır (W ağırlıkları, x girdi, b ise "bias"i belirtir). Sinir ağının son aşamasından, çıktı almak için "softmax" işlevi kullanılır. Denklem 7.7, softmax fonksiyonunu (y, çıktısını gösterir) göstermektedir [14].

$$s(t) = (x * w)(t) = \sum_{a=-\infty}^{\infty} x(a)w(t-a) \quad (7.4)$$

$$S(i, j) = (I * K)(i, j) = \sum_m \sum_n I(m, n)K(i-m, j-n). \quad (7.5)$$

$$e_i = \sum_j W_{i,j} x_j + b_i. \quad (7.6)$$

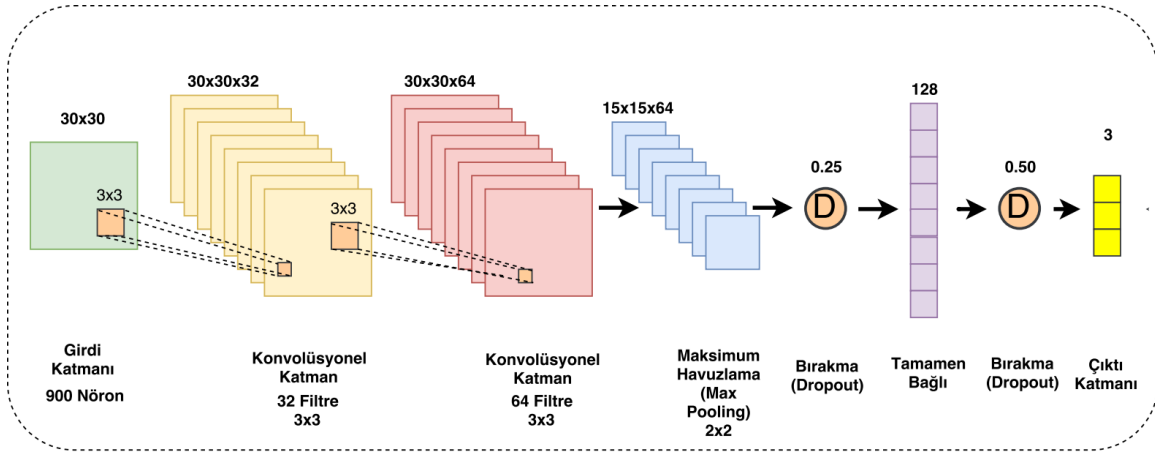
$$y = \text{softmax}(e) \quad (7.7)$$

CNN fazı, Keras<sup>25</sup>, Tensorflow<sup>26</sup> altyapısı kullanılarak gerçekleştirilmiştir. Algoritma 6 CNN-BI yönteminin prosedürünü göstermektedir. Ayrıca, bu metot için geliştirilen kodlara GitHub<sup>27</sup> üzerinden erişilebilir.

<sup>25</sup><https://keras.io/>

<sup>26</sup><https://github.com/tensorflow>

<sup>27</sup><https://github.com/omerbsezer/TimeSeries2DBarChartImageCNN>



Şekil 7.3: Oluşturulan CNN yapısı

## 7.3 Değerlendirme

### 7.3.1 Finansal değerlendirme

Son fazda, al-sat işlemleri sonuçlarının performansı, finansal değerlendirme yöntemi kullanılarak değerlendirilir. Her bir hisse, tahmin edilen etikete göre alınır, satılır veya tutulur. Finansal değerlendirme senaryosu, Denklem 7.8’de gösterilmektedir.

$$FinancialEvaluation = \begin{cases} numberOfStocks = \frac{totalCapital}{price}, & \text{if label='Buy'} \\ no\ action, & \text{if label='Hold'} \\ totalCapital = price * numberOfStocks & \text{if label='Sell'} \end{cases} \quad (7.8)$$

Eğer, hisse senedinin o anki fiyatının etiketi "Al" ise, hisse bu noktada mevcut sermayenin tamamı ile satın alınır, eğer hisse senedinin o anki fiyatının etiketi "Sat" ise, hisse bu fiyata satılır. Eğer, tahmin edilen etiket "Tut" ise, o anda herhangi bir işlem yapılmaz. Ayrıca, aynı etiket ardışık olarak gelirse, işlem yalnızca ilk etiket göre yapılır. Tekrarlanan etiketler ilişkili etiket değişinceye kadar dikkate alınmaz. Finansal değerlendirme için başlangıç sermayesi \$10,000, işlem komisyonu işlem başına (transaction) \$1’dir.

### 7.3.2 Dow30 analizi

CNN-BI yöntemi ile Dow-30 hisse senetleri farklı zaman periyotlarında (2007-2012 ve 2012-2017) değerlendirilmektedir. Aşağıdaki değerlendirme metrikleriyle her bir hisse



---

**Algoritma 6 CNN-BI Yöntemi**

---

```
1: procedure ALLPHASES
2:   Phase DataSet E/T:
3:   dataset = read(open, close, high, low, adjustedClose, volume)
4:   Phase Image Creation:
5:   create 30x30 pixels images
6:   trainingDataset = dataset.split(dates = 1997 – 2006)
7:   testDataset = dataset.split(dates = 2007 – 2017)
8:   testDataset1 = testDataset.split(dates = 2007 – 2012)
9:   testDataset2 = testDataset.split(dates = 2012 – 2017)
10:  Phase Labelling Data:
11:  slopeRef[1..n] = calculate slop references using time series data
12:  calculate distribution of the class(Buy, Sell, Hold) to find seperation values
13:  firstSepPoint, secondSepPoint = find the seperation values(slopeRef[1..n])
14:  slopeCurrent = calculate the slope for each images using time series data()
15:  if(slopeCurrent >= secondSepPoint) :
16:    label = 1 ("Buy")
17:  elif(slopeCurrent > firstSepPoint and slopeCurrent < secondSepPoint) :
18:    label = 0 ("Hold")
19:  elif(slopeCurrent <= secondSepPoint) :
20:    label = 2 ("Sell")
21:  merge labels and images
22:  create images file
23:  Phase Predicting Label:
24:  trainingDataset = resample(trainingDataset) to solve data imbalance problem
25:  model = CNN(epochs = 100, blocksize = 1028)
26:  model.train(trainingDataset)
27:  model.test(testDataset1)
28:  model.test(testDataset2)
29:  Phase Financial Evaluation:
30:  financialEvaluationScenario()
31:  calculateEvaluationConstraints()
```

---

senedinin işlem (transaction) performansları ölçülmüştür (Çizelge 7.2 ve Çizelge 7.3): CNN-BI metodunun toplam sermayesi (CNN-BI), CNN-BI metodunun yıllık getirisi (AR) (Denklem 7.9), "Al&Tut" stratejisi toplam sermayesi (BaH), "Al&Tut" stratejisi yıllık getirisi (AR) (Denklem 7.9), yıllık ortalama işlem sayısı (AnT) (Denklem 7.10), başarı oranı (PoS) (Denklem 7.11), işlemler başına ortalama kâr yüzdesi (APT) (Denklem 7.12), ortalama işlem uzunluğu (L) (Denklem 7.13), işlemdeki maksimum kar yüzdesi (MpT), işlemdeki maksimum kayıp yüzdesi (MLT), maksimum sermaye (MxC), minimum sermaye (MinC), sistemin boş kalma oranı (IR) (Denklem 7.14). İlgili değerlendirme metrikleri için formüller Denklem 7.9, 7.10, 7.11, 7.12, 7.13, 7.14'de gösterilmiştir.

$$AR = \left( \left( \frac{totalCapital}{initialCapital} \right)^{\frac{1}{numberOfYears}} - 1 \right) * 100 \quad (7.9)$$

$$AnT = \frac{transactionCount}{numberOfYears} \quad (7.10)$$

$$PoS = \frac{successTransactionCount}{transactionCount} * 100 \quad (7.11)$$


$$ApT = \frac{totalPercentProfit}{transactionCount} * 100 \quad (7.12)$$

$$L = \frac{totalTransactionLength}{transactionCount} * 100 \quad (7.13)$$

$$IdleR = \frac{numberOfDaysInTestData - totalTransLength}{numberOfDaysInTestData} * 100 \quad (7.14)$$

Farklı piyasa koşullarını test edebilmek için iki farklı eğitim ve test periyodu seçilmiştir. İlk örnekte, model 1997-2007 arasındaki hisse senedi verileri kullanarak eğitilmektedir, sonrasında 2007-2012 yılları arasındaki hisse senedi verileri ile test edilmektedir. 2007-2012 yıllarının seçilmesinin sebebi 2008 finansal krizini içermesindedir. Bu zaman aralığında, hisse senetlerinin fiyatları şiddetli fiyat dalgalanmalarına uğradı. İkinci örnekte, model 1997-2012 yılları verileri ile eğitilirken, 2012-2017 yılları arasındaki dönem ile de test edilmektedir. Bu dönemde hisse senetlerinde fiyatlar yükselişte olduğu gibi, fiyat dalgalanmaları da azdır. Her iki durumdaki modelde, eğitilmiş modelin güvenilirliğini ve sağlamlığını test etmek ve uzun bir süre başarıyla uygulayabildiğini görmek için takip eden verilerle model tekrar eğitime alınmamıştır. Şekil 7.4 CNN-BI yönteminin ve "Al&Tut" sonuçlarının karşılaştırmasını göstermektedir. Çizelge 7.1, JPM hissesinin al-sat işlemlerinin (transactions) örneğini göstermektedir.

Elde edilen sonuçlar analiz edildiğinde (Çizelge 7.2 ve Çizelge 7.3) bazı ilginç sonuçlar gözlemlenebilir. Her şeyden önce, model ilk durumda "Al&Tut" stratejisinden (Çizelge 7.2) daha iyi performans gösterirken, ikinci durumda daha kötü performans göstermiştir (Çizelge 7.3). 2007 ile 2012 yılları arasında, CNN-BI yönteminin ortalama yıllık getirisi 7.20%, ortalama başarılı işlemlerin oranı 52.35% ve bir hissesin yıllık en yüksek getirisi 37.46%'dır. Bu zaman aralığında "Al&Tut" stratejisinin ortalama yıllık getirisi ise 5.86%'dır. Her iki model karşılaştırıldığında CNN-BI yönteminin daha iyi performans gösterdiği görülmüştür. Ancak 2012-2017 arasındaki test



Şekil 7.4: CNN-BI ile "Al-Tut" yöntemi sonuçlarının karşılaştırılması

Çizelge 7.1: Finansal senaryo işlem örnekleri: JPM hissesinin işlemleri

İşlem Numarası	Aralık (Gün)	Kazanç	Anlık Sermaye
1	21-25	-\$561,19	\$9.481,81
16	117-117	\$60,62	\$9.120,70
40	300-301	\$415,05	\$10.747,49
60	402-403	\$1.666,47	\$14.833,34
80	537-543	\$2.545,37	\$17.889,30
100	680-683	\$1.385,12	\$23.095,23
120	806-807	\$558,66	\$23.167,22
140	892-893	-\$442,64	\$21.281,64
160	1029-1030	-\$364,75	\$19.875,25
180	1168-1177	\$1.099,83	\$19.840,19
187	1211-1213	\$2.351,19	\$25.871,19

Çizelge 7.2: CNN-BI yönteminin Dow-30 hisseleri ile değerlendirilmesi - (2007 - 2012)

Hisse	CNN-BI	CNN-BI_AR	BAH	BAH_AR	AnT	PoS	ApT	L	MpT	MIT	MaxC	MinC	IdleR
MMM	\$14,677.55	7.98%	\$12,272.92	4.18%	56.80	53.44%	0.26%	3.00	13.50%	-7.97%	\$15,063.87	\$8,412.55	52.43%
AXP	\$9,132.83	-1.80%	\$9,188.87	-1.68%	50.20	55.09%	0.19%	3.00	62.86%	-29.26%	\$11,324.66	\$3,915.74	45.93%
APPL	\$49,074.25	37.46%	\$45,624.00	35.47%	39.10	62.31%	1.41%	6.00	18.11%	-19.18%	\$51,382.90	\$10,000.00	31.44%
BA	\$9,217.19	-1.62%	\$8,855.67	-2.40%	51.70	48.26%	0.08%	4.00	10.22%	-17.76%	\$11,627.13	\$4,974.52	42.39%
CAT	\$7,480.28	-5.64%	\$9,841.64	-0.32%	52.40	47.13%	-0.10%	3.00	8.28%	-6.54%	\$10,943.23	\$6,995.81	46.17%
CVX	\$21,727.81	16.79%	\$16,923.79	11.10%	47.80	58.49%	0.58%	4.00	15.31%	-15.90%	\$21,727.81	\$9,998.89	41.48%
CSCO	\$11,419.68	2.69%	\$6,992.57	-6.90%	49.90	51.20%	0.19%	4.00	20.52%	-15.86%	\$12,401.31	\$6,534.86	42.55%
KO	\$16,589.11	10.65%	\$16,156.55	10.07%	55.60	56.22%	0.31%	3.00	6.85%	-4.55%	\$18,499.11	\$9,582.82	50.86%
DIS	\$13,549.50	6.26%	\$11,518.77	2.87%	52.00	49.71%	0.27%	3.00	12.43%	-19.44%	\$14,033.63	\$7,598.25	46.75%
XOM	\$9,999.40	0.00%	\$11,908.08	3.55%	53.50	50.00%	0.05%	4.00	5.95%	-7.26%	\$10,621.46	\$7,768.85	41.07%
GE	\$10,415.37	0.82%	\$5,520.29	-11.20%	50.50	52.38%	0.19%	3.00	11.97%	-23.02%	\$13,278.95	\$4,249.75	46.42%
GS	\$3,518.10	-18.86%	\$5,066.41	-12.71%	54.40	48.07%	-0.40%	3.00	29.57%	-21.68%	\$9,875.97	\$2,486.94	51.44%
HD	\$9,696.71	-0.61%	\$11,460.96	2.76%	57.10	49.47%	0.07%	3.00	24.72%	-11.16%	\$11,326.26	\$7,593.35	52.59%
IBM	\$15,928.39	9.76%	\$21,268.53	16.29%	54.70	53.30%	0.32%	3.00	16.25%	-7.95%	\$17,413.69	\$9,812.50	46.01%
INTC	\$14,606.30	7.87%	\$13,959.50	6.90%	55.90	55.38%	0.28%	2.00	19.40%	-14.18%	\$14,606.30	\$8,196.52	57.94%
JNJ	\$9,655.38	-0.70%	\$11,449.30	2.74%	56.50	53.19%	0.02%	3.00	5.98%	-7.87%	\$11,592.25	\$8,503.19	52.43%
JPM	\$25,871.19	20.94%	\$7,317.93	-6.05%	56.20	51.34%	0.69%	2.00	31.54%	-19.53%	\$25,871.19	\$8,378.84	56.46%
MCD	\$18,700.61	13.34%	\$24,911.34	20.03%	54.40	53.59%	0.39%	3.00	4.73%	-8.19%	\$19,394.66	\$9,624.34	41.32%
MRK	\$11,555.51	2.93%	\$9,905.70	-0.19%	51.10	48.82%	0.16%	3.00	14.29%	-13.46%	\$13,261.31	\$7,133.17	52.67%
MSFT	\$5,445.01	-11.45%	\$9,607.69	-0.80%	51.70	49.42%	-0.26%	4.00	17.73%	-9.63%	\$10,364.50	\$4,248.14	41.98%
NKE	\$15,550.75	9.23%	\$19,642.43	14.46%	54.10	53.33%	0.32%	3.00	21.44%	-18.98%	\$16,472.34	\$7,270.36	55.06%
PFE	\$9,844.37	-0.31%	\$9,718.14	-0.57%	49.30	43.90%	0.04%	2.00	8.25%	-5.48%	\$10,397.50	\$7,711.61	61.56%
PG	\$8,669.59	-2.81%	\$11,479.26	2.80%	54.40	53.59%	-0.03%	3.00	6.29%	-7.28%	\$10,612.15	\$7,298.68	42.14%
TRV	\$11,286.49	2.45%	\$12,040.33	3.78%	50.50	52.98%	0.14%	3.00	10.33%	-6.97%	\$14,783.66	\$8,943.55	47.49%
UTX	\$17,254.59	11.53%	\$12,469.62	4.51%	54.40	55.80%	0.37%	3.00	17.48%	-8.70%	\$17,398.13	\$8,030.55	40.58%
UNH	\$16,898.48	11.06%	\$9,823.38	-0.36%	48.40	54.04%	0.49%	4.00	45.86%	-11.95%	\$17,079.56	\$4,895.88	37.61%
VZ	\$17,876.97	12.32%	\$13,702.90	6.50%	56.20	52.94%	0.36%	2.00	17.20%	-5.98%	\$17,876.97	\$8,191.40	55.72%
WMT	\$10,670.31	1.31%	\$13,610.18	6.36%	56.80	52.38%	0.07%	1.00	7.34%	-6.65%	\$12,260.25	\$8,730.42	68.97%
Ortalama	\$14,153.99	7.20%	\$13,294.17	5.86%	52.70	52.35%	0.23%	3.11	17.30%	-12.59%	\$15,767.53	\$7,395.77	48.20%
S. Sapma	\$8,422.42	10.56%	\$7,761.50	9.67%	3.83	3.70%	0.33%	0.92	12.79%	6.47%	\$7,990.17	\$1,996.92	7.99%

döneminde, CNN-BI modeli yükselen piyasanın olması nedeniyle "Al&Tut" stratejisinin performansının üzerine çıkamamıştır. Yükselen piyasalarda genellikle "Al&Tut" stratejisinden daha iyi performans elde edilememektedir. 2012-2017 yılları arasında

Çizelge 7.3: CNN-BI yönteminin Dow-30 hisseleri ile değerlendirilmesi - (2012 - 2017)

Hisse	CNN-BI	CNN-BI_AR	BAH	BAH_AR	AnT	PoS	ApT	L	MpT	MIT	MaxC	MinC	IdleR
MMM	\$19,593.71	14.40%	<b>\$22,675.47</b>	<b>17.79%</b>	\$58.70	58.97%	0.38%	3.00	10.03%	-4.87%	\$19,652.35	\$9,510.52	47.65%
AXP	\$9,671.69	-0.67%	<b>\$15,279.66</b>	<b>8.85%</b>	\$50.30	46.71%	0.04%	4.00	10.73%	-18.41%	\$11,663.10	\$8,092.34	36.85%
APPL	\$9,071.01	-1.93%	<b>\$16,745.95</b>	<b>10.86%</b>	\$43.40	47.22%	0.03%	5.00	6.34%	-13.58%	\$12,077.68	\$6,252.66	33.14%
BA	\$16,501.81	10.54%	<b>\$22,976.43</b>	<b>18.10%</b>	\$53.00	56.82%	0.33%	4.00	10.43%	-7.28%	\$16,509.36	\$9,506.38	38.50%
CAT	\$6,885.79	-7.19%	<b>\$9,841.64</b>	<b>-0.32%</b>	\$53.30	48.59%	-0.14%	3.00	9.65%	-8.12%	\$9,634.53	\$5,800.79	45.09%
CVX	\$9,355.38	-1.32%	<b>\$12,973.64</b>	<b>5.34%</b>	\$55.70	52.97%	0.01%	3.00	5.73%	-8.96%	\$11,898.61	\$7,567.87	41.38%
CSCO	<b>\$19,268.69</b>	<b>14.02%</b>	\$17,180.88	11.43%	\$52.10	53.18%	0.43%	3.00	13.50%	-8.73%	\$20,202.86	\$9,207.90	54.33%
KO	\$10,549.27	1.08%	<b>\$13,927.04</b>	<b>6.85%</b>	\$55.40	47.83%	0.06%	3.00	6.36%	-8.12%	\$14,027.25	\$9,867.86	49.13%
DIS	\$18,770.40	13.42%	<b>\$26,015.56</b>	<b>21.07%</b>	\$53.00	53.98%	0.40%	3.00	11.41%	-11.17%	\$21,941.61	\$9,817.04	43.36%
XOM	\$9,556.35	-0.90%	<b>\$11,997.52</b>	<b>3.71%</b>	\$59.90	46.73%	0.01%	3.00	7.63%	-7.85%	\$10,763.24	\$8,412.71	49.22%
GE	\$16,502.79	10.54%	<b>\$19,592.94</b>	<b>14.40%</b>	\$50.00	56.02%	0.35%	3.00	10.80%	-7.73%	\$16,652.93	\$9,785.36	48.15%
GS	\$12,774.49	5.02%	<b>\$22,405.06</b>	<b>17.51%</b>	\$56.90	52.91%	0.17%	3.00	5.14%	-5.13%	\$12,774.49	\$8,245.10	51.77%
HD	\$18,205.08	12.73%	<b>\$31,921.72</b>	<b>26.13%</b>	\$53.30	54.80%	0.37%	2.00	7.88%	-4.19%	\$19,578.14	\$9,666.73	59.44%
IBM	\$6,378.56	-8.60%	<b>\$9,717.76</b>	<b>-0.57%</b>	\$57.20	46.32%	-0.19%	3.00	5.59%	-11.13%	\$10,194.67	\$5,581.03	49.96%
INTC	\$9,881.14	-0.24%	<b>\$15,536.60</b>	<b>9.21%</b>	\$56.60	50.53%	0.05%	3.00	12.48%	-9.37%	\$10,285.90	\$7,490.77	51.61%
JNJ	\$15,339.45	8.93%	<b>\$19,987.83</b>	<b>14.86%</b>	\$58.10	58.03%	0.25%	2.00	6.69%	-7.71%	\$15,531.77	\$10,000.00	55.81%
JPM	\$15,206.33	8.74%	<b>\$25,301.27</b>	<b>20.40%</b>	\$53.60	56.18%	0.28%	3.00	7.05%	-7.70%	\$15,206.33	\$9,541.54	48.27%
MCD	\$12,551.20	4.65%	<b>\$14,159.43</b>	<b>7.20%</b>	\$43.10	58.74%	0.20%	6.00	8.13%	-6.92%	\$13,687.24	\$8,786.74	28.11%
MRK	\$13,063.48	5.49%	<b>\$18,529.08</b>	<b>13.13%</b>	\$53.00	54.55%	0.19%	2.00	9.07%	-8.91%	\$13,358.03	\$9,811.65	59.27%
MSFT	\$14,498.43	7.71%	<b>\$23,147.11</b>	<b>18.28%</b>	\$51.50	49.12%	0.26%	2.00	10.08%	-10.96%	\$14,759.53	\$9,111.40	62.24%
NKE	\$11,795.50	3.36%	<b>\$20,921.86</b>	<b>15.91%</b>	\$47.60	54.43%	0.15%	4.00	7.31%	-8.51%	\$14,570.15	\$9,013.55	45.18%
PFE	\$11,607.28	3.03%	<b>\$17,250.84</b>	<b>11.52%</b>	\$43.70	55.17%	0.13%	1.00	3.41%	-4.79%	\$12,061.23	\$9,897.65	76.42%
PG	\$14,675.91	7.97%	<b>\$15,190.11</b>	<b>8.72%</b>	\$53.90	56.42%	0.24%	3.00	8.38%	-4.95%	\$14,860.58	\$10,000.00	45.26%
TRV	\$18,802.11	13.46%	<b>\$22,493.84</b>	<b>17.60%</b>	\$54.80	63.74%	0.38%	3.00	6.45%	-5.77%	\$18,802.11	\$9,826.82	45.26%
UTX	\$11,447.68	2.74%	<b>\$14,597.92</b>	<b>7.86%</b>	\$54.50	51.93%	0.11%	3.00	6.33%	-5.80%	\$11,568.65	\$8,429.40	45.09%
UNH	\$16,998.61	11.19%	<b>\$31,710.80</b>	<b>25.96%</b>	\$56.30	60.43%	0.32%	3.00	5.42%	-3.62%	\$16,998.61	\$8,322.55	45.09%
VZ	\$11,885.35	3.51%	<b>\$16,726.59</b>	<b>10.84%</b>	\$58.70	51.28%	0.12%	2.00	9.72%	-5.69%	\$13,007.59	\$9,776.43	59.60%
WMT	\$11,065.42	2.05%	<b>\$12,911.65</b>	<b>5.24%</b>	\$58.70	51.79%	0.09%	2.00	10.96%	-10.04%	\$12,226.53	\$8,480.34	53.59%
Ortalama	\$13,282.25	5.84%	<b>\$18,632.72</b>	<b>13.25%</b>	\$53.44	53.41%	0.18%	3.00	8.31%	-8.07%	\$14,446.25	\$8,778.68	48.88%
S. Sapma	<b>\$3,801.42</b>	<b>6.30%</b>	\$5,796.60	6.97%	\$4.58	4.51%	0.16%	0.98	2.47%	3.13%	\$3,316.95	\$1,267.36	9.61%

CNN-BI modelinin yıllık ortalama kazancı 5.84% olurken, "Al&Tut" stratejisinin yıllık ortalama kazancı ise 13.25%'dir. Aynı dönemde bir hissesin yıllık en yüksek getirisi 14.40%'dır. 2007-2012 döneminde CNN-BI modelinin, 28 hissenin 9'unda ortalama yıllık getirisi negatif olurken, "Al&Tut" stratejisinde aynı dönemde 28 hissenin 10'unda ortalama yıllık getiri negatif olmuştur. 2012-2017 döneminde CNN-BI modelinin, 28 hissenin 7'sinde ortalama yıllık getirisi negatif olurken, "Al&Tut" stratejisinin aynı dönemde 28 hissenin 2'sinde ortalama yıllık getirisi negatif olmuştur. Bu durum 2012-2017 döneminde yükselen piyasanın olduğunu göstermektedir. CNN-BI modelinin tahmin etme istatistiksel genel doğruluğu (accuracy), 44% ile 52% arasında değişmektedir. Bu istatistiksel genel doğruluk oranı üç-sınıflı sistemde 33%'tür ve CNN-BI modelinin istatistiksel genel doğruluk oranı bu değerden yüksektir.

CNN-BI yönteminin performansının daha iyi ölçümlenmesi için, zaman içerisinde kaydırmalı olarak eğitilip, daha sonrasında testler uygulanmıştır. Böylelikle zaman içerisinde değişen özellikler güncellenmektedir. Uygulanan yöntemde beş yıllık veriler eğitim için kullanılırken, daha sonrasında gelen bir yıllık veriler test için kullanılmıştır (Ör; Eğitim Verisi: 1/1/2010-31/12/2014, Test Verisi: 1/1/2015-31/12/2015). 2007-2012 yılları arasında CNN-BI modelinin yıllık ortalama getirisi 7.20% iken, 2012-2017 yılları arasında CNN-BI modelinin yıllık ortalama getirisi 5.84%'tür. CNN-BI modelinin zaman kaydırmalı testi için "MCD" hissesi seçilmiştir. "MCD" hissesinin 2007-2012 yılları arasındaki ortalama yıllık getirisi 13.34% iken 2012-2017 yılları arasındaki ortalama yıllık getirisi 4.65%'dir. "MCD" hissesine 2007-2017 yılları ara-

sında zaman kaydırmalı CNN-BI yöntemi uygulanmıştır. Zaman kaydırmalı yöntem ile "MCD" hissesinin, 2007-2012 yılları arasındaki ortalama yıllık getirisi 16.27% iken 2012-2017 yılları arasındaki ortalama yıllık getirisi 4.55% olmaktadır. Zaman kaydırmalı yöntem uygulanarak, "MCD" hissesinin getirisi 2007-2012 yılları arasında artarken, 2012-2017 yılları arasında bir miktar düşmüştür. Zaman kaydırmalı yöntem kullanılarak, ortalama yıllık getiri üzerinde önemli bir iyileştirme yapılamamıştır.

### 7.3.3 İstatiksel anlamlılık testleri

Çizelge 7.2 ve Çizelge 7.3'deki karşılaştırılabilir metriklere *istatiksel anlamlılık testleri (statistical significance test)* uygulanmıştır. T-Testi sonuçlarına göre (Çizelge 7.4), maksimum işlem karı, kayıp yüzdeleri ve minimum sermaye değerleri haricinde 2007-2012 ve 2012-2017 dönemleri arasında model metrikleri arasında önemli bir fark olmadığı gözlemlenmektedir. Bununla birlikte, "Al&Tut" performansı her iki dönemde de belirgin olarak farklıdır. Dolayısıyla, CNN-BI yönteminin performansı, yükselen piyasada geride kalmasına rağmen daha sağlam ve tutarlı bir model sunmaktadır.

Çizelge 7.4: 2007-2012 ve 2012-2017 TTest performans sonuçları

Performance Metrics	TTest Results
Total Capital with Our Proposed Strategy (CNN-BI)	0.620
Proposed CNN Strategy Annualized Return (CNN-BI_AR),	0.974
Total Capital with "Buy and Hold" Strategy (BaH)	0.005
Proposed "Buy and Hold" Strategy Annualized Return (BAH_AR)	0.001
Annualized Number of Transaction (AnT)	0.515
Percent of Success (PoS)	0.341
Average Percent Profit Per Transactions (ApT)	0.460
Average Transaction Length (L)	0.675
Maximum Profit Percentage in Transaction (MpT)	0.001
Maximum Loss Percentage in Transaction (MIT)	0.002
Maximum Capital (MaxC)	0.423
Minimum Capital (MinC)	0.003
Idle Ratio (IdleR)	0.771

### 7.3.4 CNN-BI yönteminin değerlendirilmesi

CNN-BI modeli, temel piyasa koşullarından bağımsız olarak tutarlı performans sonuçları göstermektedir. Her iki dönemdeki yıllık getiri oranları benzerlik göstermektedir (2007-2012 yılları için yıllık ortalama getiri 7.20%, 2012-2017 yılları için yıllık ortalama getiri 5.84%). Dolayısıyla, pazar koşulları oldukça farklı olsa da, her iki durumda da model neredeyse aynı performans göstermektedir. Performans başarımlarının yüzdesinin de (PoS) gösterdiği gibi al-sat kararları rastgele karar verme durumuna göre 2007-2012

döneminde 28 hissenin 19'unda, 2012-2017 döneminde 28 hissenin 21'inde daha iyi performans göstermektedir. Yıllık ortalama işlem sayısı, her iki test döneminde 40 ila 60 arasında değişmekte ve eğilimin yönü ne olursa olsun, modelin haftada bir kez al-sat işlemi yaptığı gözükmemektedir. Her bir al-sat işleminin ortalama süresi, her iki test döneminde de 3 gündür. Ayrıca, Çizelge 7.2 ve Çizelge 7.3'deki diğer metrikler de benzerlikler göstermektedir.

Çizelge 7.2 ve Çizelge 7.3'dan görüldüğü gibi, CNN-BI modelinin finansal değerlendirme aşamasında ortalama olarak boşa kalma oranı (idle ratio) 50%'dir. Alçalan ve durağan olan piyasa koşullarında bu durum sorun oluşturmazken (nakitte kalmak hatta alçalan piyasa koşullarında en iyi stratejilerden biridir), yükselen piyasa koşullarında potansiyel karların elde edilememesine, fırsatlardan yararlanmamaya neden olmakta ve genel getirilerin azalmasına yol açmaktadır. CNN-BI modelinin 2012-2017 yılları arasında "Al%Tut" stratejisine göre performansının kötü olmasının nedenlerinden biri modelin test edilen zamanın yaklaşık 50%'sinde nakitte kalması ve herhangi bir işlem yapmamasıdır. Dolayısıyla, daha yüksek işlem yapma süresi sağlanır ve boşa kalma (idle ratio) oranını düşürebilirse, performans sonuçları daha da geliştirilebilir. Farklı şekillerde performansın iyileştirilmesi sağlanabilir. Sadece bir hisse senedi ile işlem yapmak yerine birden fazla hisse senedi ile işlem yapılabilir. Böylelikle bir hisse de işlem yapılmayan zamanda diğer hisseler ile işlem yapılarak kâr maksimize edilebilir, yıllık ortalama işlemlerin sayısını artırabilir. Ayrıca, piyasa eğilimi gözlemlenerek, durağan ve alçalan piyasalarda başarılı olacak şekilde model ayarlanabilir. Son olarak, kârı artırmak için kaldıraçlı modeller de eklenebilir. Genel olarak başarı oranı pazar koşullarına ve sürelerine bakılmaksızın 50%'nin üzerinde olduğundan dolayı kaldıraçlı modellerle kâr maksimize edilebilir. Tüm bu stratejiler, modelin daha iyi toplam performans elde etmesine yardımcı olabilir.

Bu aşamada elde edilen sonuçlar genetik algoritma ve MLP'nin gerisinde kalmıştır. Bunun muhtemel başlıca sebebi elde edilen görüntülerin "Al-Sat-Tut" kararını verebilecek ayırcılığa sahip olmaması olarak düşünülebilir. Bunun en önemli göstergesi işlem başarımlarında kayda değer düşüşten de anlaşılabilir (Önceki modellerde gözlemlenen başarımlar oranında 70-80%'den 50-60%'a düşmüştür). Fakat yine de elde edilen sonuçlar belirli bir performans istikrarı içermektedir. Nispeten daha az fiyat oynaklığı ile belirli bir başarımlar sağlanmıştır. Elde edilen kısıtlı başarımların sebebi CNN'nin iki boyutlu görüntü olarak kullandığı çubuk görüntülerindeki finansal zaman serisine göre veri kaybıdır. Buna bağlı olarak hem finansal verilerdeki kaybın en düşük şekilde tutulup, hem de iki boyutlu yapının CNN ile kullanılabilir şekilde modellenmesi, istenilen performans başarımlarını getirebileceği öngörülmektedir. Bir sonraki bölümde bu amaca yönelik bir model tanıtılacaktır.

## **8. FİNANSAL ZAMAN SERİSİ VERİLERİNİN, TEKNİK ANALİZ VERİLERİ KULLANILARAK GÖRÜNTÜ VERİSİNE DÖNÜŞTÜRÜLMESİ ve GÖRÜNTÜLERİN DERİN KONVOLÜSYONEL SİNİR AĞI İLE FİNANSAL ANALİZ YÖNTEMİ (CNN-TA)**

### **8.1 Motivasyon**

Daha önceki bölümde (Bölüm 7) de anlatıldığı gibi derin konvolüsyonel sinir ağları finansal zaman serisi verilerinin analizinde sıklıkla kullanılmamaktadır. Literatürde, zaman serisi verilerinin analizinde derin konvolüsyonel sinir ağlarının kullanımı mevcuttur [34], [35], [36]. Zheng [35], çalışmasında zaman serisi verilerinin analizinde çok kanallı derin konvolüsyonel sinir ağı yapısı önermiştir. Le [36], çalışmasında CNN kullanılarak zaman serisi verilerinin sınıflandırılması üzerine çalışmıştır. Hatami [37], önerdiği yöntemde zaman serisi verilerini 2 boyutlu verilere çevirerek CNN modeli kullanarak sınıflandırmaya çalışmıştır. Gunduz [147], çalışmasında saatlik BIST verilerinin tahmini için CNN yapısı önermiştir. Çalışmasındaki tahmin başarımını f-measure ile ölçmüştür. Ancak, önerilen çalışmalarda zaman serisi verileri tek boyutlu olarak ya birden fazla kanaldan alınmaya çalışılmış, ya da iki boyutlu verilere çevrilirken sadece zaman serisi verileri kullanılmaya çalışarak sınıflandırma yapılmaya çalışılmıştır. Önerilen çalışmayla teknik analiz verileri kullanılarak zaman serisi verileri uygun bir şekilde resim haline getirilmekte, zaman içerisinde değişen fiyatlar üzerine uygulanan etiketleme algoritması ile resimler etiketlenmekte ve etiketlenen resimler derin konvolüsyonel sinir ağı modeline girdi olarak verilmektedir.

Finansal zaman serisi verilerinin analizinde teknik analiz göstergeleri önemli yer teşkil etmektedir. Ancak, teknik analiz verilerini derin sinir ağlarıyla birlikte modelleyen yöntemler, literatürde çok yaygın değildir. Derin konvolüsyonel sinir ağları ve teknik analiz verilerinin birlikte kullanılarak, 2 boyutlu matris yapının oluşturulması ve önerilen yaklaşımın algoritmik alım/satım modelleri için kullanılması yenilikçi bir yaklaşımdır. Derin konvolüsyonel sinir ağlarındaki "konvolüsyon" ve "maxpooling" işlemlerinin resim dışında matris yapıda oluşturulan özellik kümesine de uygulanabileceği hipotezi üzerine, yaklaşım önerilmiştir. Önerilen modelde, teknik analiz verileri kullanılarak oluşturulan özellikler 2 boyutlu matris yapıya dönüştürülmektedir. Sonrasında derin konvolüsyonel sinir ağı kullanılarak finansal matris yapıda olan özellikler, sınıflandırılmaktadır. Önerilen yöntemde MNIST algoritmasında kullanılan derin konvo-

lüksyonel sinir ađına benzeyen yapıda konvolüsyonel sinir ađı yapısı kullanılmaktadır. En sonunda, belirlenen noktalara göre gerçek bir alım-satım senaryosu kořturularak sonuçlar deđerlendirilmektedir.

Bu aşamada, görüntü işleme özelliklerine göre öğrenme yapabilen 2 boyutlu derin konvolüsyonel sinir ađı (Convolutional Neural Network - CNN) kullanan yeni bir algoritmik model önerilmektedir [191]. Finansal zaman serisi verilerini 2 boyutlu görüntülere dönüřtürmek için, her biri 15 farklı parametre seçimi (farklı zaman aralıklarında) olan 15 farklı teknik gösterge kullanılmaktadır. Finansal verilerden 15x15 görüntü dosyaları oluşturulmaktadır. Tutarlı ve anlamlı bir görüntü elde edebilmek için, teknik göstergelerde benzer davranış gösterenler birlikte (osilatör veya eğilim) ve yakın yerlerde konumlandırılmıştır. Her görüntü, orijinal zaman serilerininin tepe ve vadi noktalarına bađlı olarak "Al", "Sat", "Tut" olarak etiketlenmektedir. Önerilen metodun farklı piyasa kořullarında test edebilmek için 2007-2012 ve 2007-2017 yılları arasında ayrı ayrı testler yapılmıştır. Sonuçlar, daha sonra BaH (Al-Tut) stratejisi, RSI ve SMA modelleri, LSTM ve MLP regresyon yöntemleri ile karşılaştırılmış, ETF'ler ve hisse senetlerinde iyi sonuçlar sağladığı görülmüřtür.

## 8.2 Önerilen Metot (CNN-TA)


Bu çalışmada (*CNN-TA: "Convolutional Neural Network using Technical Analysis"*), konvansiyonel sinir ađı kullanan ve hisse senedi fiyatlarındaki "Al" ve "Sat" noktalarını belirlemek için yeni bir yöntem önerilmektedir. Yaklaşımında, her bir günlük hisse senedi fiyatı için farklı zaman aralıklarıyla 15 farklı teknik gösterge kullanılıp görüntüler oluşturulmaktadır. Şekil 8.1'de görüldüğü gibi, CNN-TA yöntemi beş ana faza ayrılmıştır.

### 8.2.1 Önişleme (veri kümesi dönüřümü)


Çalışmamızda, Dow 30 hisse senetleri ve günlük Borsa Yatırım Fonu (ETF: Exchange Traded Fund) fiyatları, "finance.yahoo.com" adresinden indirilmektedir. Eğitim verisi olarak, 1/1/1997 ile 12/31/2006 tarihleri arasındaki hisse senedi ve ETF fiyatları, test verisi olarak da, 1/1/2007 ile 1/1/2012 tarihleri ve 1/1/2007 ile 1/1/2017 tarihleri arasındaki hisse senedi ve ETF fiyatları kullanılmaktadır. İlk adımda, verilerin çıkarılma/dönüřtürme fazında, fiyatlar normalize edilir. Daha sonra, etiketleme aşamasında, günlük tüm kapanış fiyatları, zaman içerisinde kayan bir pencerede üst ve alt noktaları belirlenerek "Al", "Sat", "Tut" olarak işaretlenir. Şekil 8.2'de etiketleme senaryosu gösterilmektedir. Algoritma 7'de etiketleme algoritması gösterilmektedir. Önerilen mode-



lin gerçekleşmesinde, "Apache Spark" <sup>28</sup>, "Keras" <sup>29</sup> ve "Tensorflow" <sup>30</sup> çatı yazılımları kullanılmıştır.



Şekil 8.1: CNN-TA metodu



Şekil 8.2: Etiketleme yöntemi

## 8.2.2 Teknik analiz ve görüntü oluşturma

Görüntü oluşturma fazında, her bir günlük kapanış fiyatı için farklı zaman aralıklarında (6 ila 20 gün) RSI, Williams % R, WMA, EMA, SMA, HMA, Üçlü EMA, CCI,

<sup>28</sup><https://spark.apache.org/>

<sup>29</sup><https://keras.io/>

<sup>30</sup><https://www.tensorflow.org/>

---

### Algoritma 7 Etiketleme Algoritması

---

```
1: function LABELLING()
2:   Input: Financial time series data (stock prices)
3:   Output: Labels with stock prices ("Buy", "Sell", "Hold")
4:   windowSize = 11 days
5:   while(counterRow < numberOfDaysInFile)
6:     counterRow ++
7:     If (counterRow > windowSize)
8:       windowBeginIndex = counterRow - windowSize
9:       windowEndIndex = windowBeginIndex + windowSize - 1
10:      windowMiddleIndex = (windowBeginIndex + windowEndIndex)/2
11:      for (i = windowBeginIndex; i <= windowEndIndex; i ++)
12:        number = closePriceList.get(i)
13:        if(number < min)
14:          min = number
15:          minIndex = closePriceList.indexOf(min)
16:        if(number > max)
17:          max = number
18:          maxIndex = closePriceList.indexOf(max)
19:        if(maxIndex == windowMiddleIndex)
20:          result = "SELL"
21:        elif(minIndex == windowMiddleIndex)
22:          result = "BUY"
23:        else
24:          result = "HOLD"
```

---

CMO, MACD, PPO, ROC, CMFI, DMI ve PSI değerleri TA4J (Technical Analysis For Java)<sup>31</sup> kütüphanesi kullanılarak hesaplanmaktadır. Teknik göstergelerde, benzer formüllere ve benzer çıktı oluşturanlar indikatörler kendi içlerinde gruplanarak, ilgili sırada görüntüler oluşturulmaktadır. (RSI, William%R bir grup; WMA, EMA, SMA, HMA, TEMA bir grup; CCI, CMO, MACD bir grup; PPO, ROC bir grup; CMFI, DMI, PSI bir grup). 15 teknik gösterge ve 15 farklı zaman aralığı kullanılarak 15x15 piksel görüntüler oluşturulur. Tutarlı ve anlamlı bir görüntü elde edebilmek için, teknik göstergelerde benzer davranış gösterenler birlikte (osilatör veya eğilim) ve yakın yerlerde konumlandırılmıştır. Finansal teknik analiz verilerinin değerleri farklı zaman aralıklarındaki dağılımı matris yapıda yatay eksen üzerinde sıralanırken, farklı teknik analiz verilerinin değerleri matris yapıda dikey eksen üzerinde sıralanmaktadır.

Farklı teknik analiz gruplarının farklı sıralarda sıralanması, farklı matris yapılarının oluşmasına neden olabilmektedir. Farklı teknik analiz gruplarının farklı sıralarda sıralanması ile ilgili testler yapılmıştır. Test için "INTC" hissesi seçilmiştir. 1997-2007 eğitim verisi, 2007-2012 test verisi olarak kullanılmıştır. Testler sırasında, PSI yerine

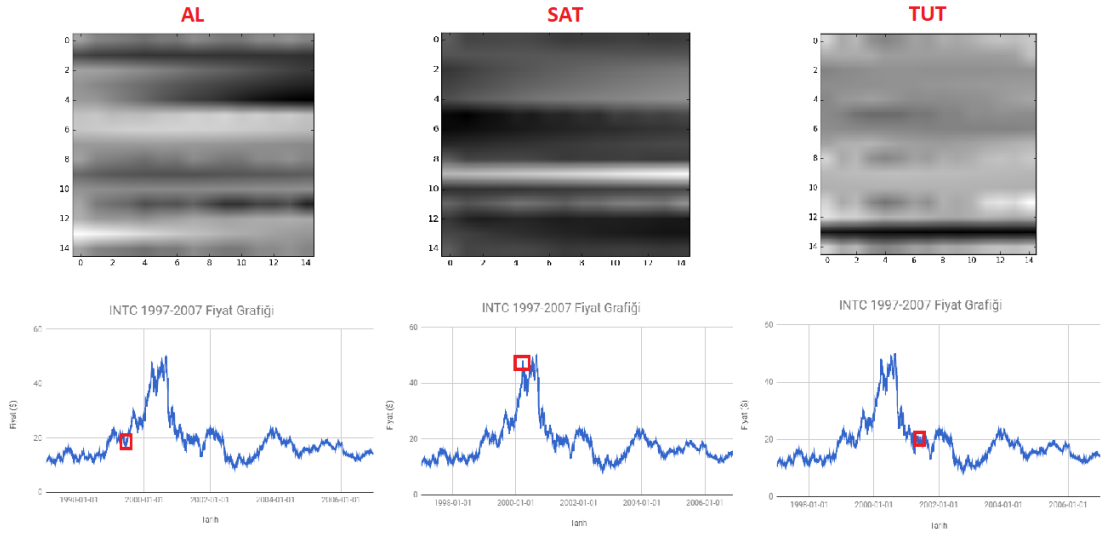
---

<sup>31</sup><https://github.com/mdeverdelhan/ta4j>

RSI teknik indikatörü ayrıca kullanılmıştır. İlgili testler Çizelge 8.1’de gösterilmektedir. Farklı teknik analiz parametrelerinin farklı sırada sıralanmasıyla birbirine yakın, farklı sonuçlar elde edilebilmektedir. Teknik analiz parametre sırasının değiştirilmesi, sonuçlar üzerinde önemli bir değişikliğe neden olmamıştır. Teknik analiz verilerinin normalize edilmesi (değerlerin -1/1 arasında değer alınması), sıralamanın değişmesinin hem eğitim hem de test verilerine aynı şekilde etkilenmesinden dolayı (CNN her defasında benzer eğitim ve test verileriyle eğitilmektedir) teknik indikatörlerin farklı sıralanması performans sonuçlarını büyük ölçüde etkilememiştir. Bu çalışma kapsamında yaptığımız çalışmayla, teknik analiz verilerinin CNN ile birlikte kullanılmasının kavram ispatı yapılmıştır. Gelecek çalışmalarda, farklı teknik analiz parametre sırası kullanılabilir.

Çizelge 8.1: INTC hissesinin 2007-2012 yılları finansal değerlendirme sonuçları

Teknik Analiz Sıralaması	Ort. Yıllık Getiri
1 RSI, WR, WMA, EMA, SMA, HMA, TEMA, CCI, CMO, MACD, PPO, ROC, CMFI, DMI, RSI	18.73%
2 WMA, EMA, SMA, HMA, TEMA, CCI, CMO, MACD, RSI, WR, CMFI, DMI, RSI, PPO, ROC	16.40%
3 PPO, ROC, RSI, WR, CCI, CMO, MACD, WMA, EMA, SMA, HMA, TEMA, CMFI, DMI, RSI	18.68%
4 CCI, CMO, MACD, RSI, WR, CMFI, DMI, RSI, PPO, ROC, WMA, EMA, SMA, HMA, TEMA	15.34%
5 CMFI, DMI, RSI, PPO, ROC, WMA, EMA, SMA, HMA, TEMA, RSI, WR, CCI, CMO, MACD	21.97%
6 WR, RSI, HMA, TEMA, SMA, WMA, EMA, MACD, CMO, CCI, ROC, PPO, RSI, DMI, CMFI	16.93%
7 SMA, EMA, TEMA, HMA, WMA, CCI, MACD, CMO, WR, RSI, DMI, CMFI, RSI, ROC, PPO	16.24 %




Şekil 8.3: 15x15 piksel örnek görüntüler ve görüntülerin "Al", "Sat", "Tut" etiketleri

Daha önce "Al", "Sat", "Tut" şeklinde etiketlenen veriler ilgili görüntüler ile eşleştirilir. Eğitim verisi olarak 1/1/1997 - 12/31/2006 tarihleri arasında her bir hisse senedi için yaklaşık 2500 görüntü, test verisi olarak 1/1/2007 - 12/31/2017 tarihleri arasında her bir hisse senedi için yaklaşık 2500 görüntü ve 1/1/2007 - 12/31/2011 tarihleri arasında

her bir hisse senedi için yaklaşık 1250 görüntü oluşturulur. Her bir hisse senedi ve ETF'in farklı karakteristik özellikleri olmasından dolayı, farklı eğitim ve test verileri hazırlanmaktadır. Şekil 8.3, oluşturulan örnek görüntüleri ve oluşturulan görüntülerin etiketlerini göstermektedir.

### 8.2.3 CNN

Önerilen CNN analiz fazında, Şekil 8.4'de görüldüğü gibi, analiz için dokuz katman kullanılmaktadır: Giriş katmanı (15x15), iki konvolüsyonel katman (15x15x32, 15x15x64), maksimum "pooling" (7x7x64), iki "dropout" (0.25, 0.50), tamamen bağlı (fully connected) katman (128) ve bir çıktı katmanı'dır. "**Dropout**" katmanları ile verilerin eğitilmesi sırasında "**overfit**" olması engellenmeye çalışılır. Önerilen CNN-TA modelinde, CNN filtresi için 3x3 filtre boyutu kullanılmaktadır. Literatürde farklı boyutlarda CNN filtreleri kullanılmaktadır: 3x3, 5x5 ve 7x7. Filtre boyutunun düşürülmesi ile genellikle resimlerin ayrıntıları yakalanabilmektedir. 3x3, görüntü işleme uygulamasında (AlexNet) en küçük ve en çok kullanılan filtre boyutudur. 3x3'lük bir filtre boyutu kullanılarak, en yakın komşuların (üst, alt, sağ, sol, üst sol, sağ üst, alt sol, sağ alt bilgi) bilgileri de göz önüne alınarak görüntü içindeki keskin değişimler de yakalanabilir. Önerilen yöntemde, küçük görüntüler (15x15 piksel) oluşturulduğundan ve görüntülerde önemli yoğunluk değişimleri olduğundan, 3x3 filtre boyutu tercih edilmiştir. Ayrıca hiper parametreler ("epoch" sayısı, "kernel" büyüklüğü, vs), farklı denemelerdeki sonuçlar gözlemlenerek ince ayarlanmıştır.



Şekil 8.4: CNN-TA yöntemi işlem adımları

Önerilen CNN-TA modelinde, uygulanan CNN yapısı, MNIST algoritmasında kullanılan derin CNN yapısına benzemektedir. MNIST yönteminde kullanılan LeNet CNN yapısı, girdi olarak 28 x 28 görüntüler kullanmakta ve altı katmandan oluşmaktadır [15]. Ayrıca, daha fazla katman ekleyerek algoritmanın karmaşıklığı artmaktadır. Çok büyük bir eğitim seti olmadan giderek daha da karmaşıklaşan bir ağ yapısı, "overfit"e

neden olurken, test verilerinden elde edilen doğruluğu da (accuracy) azaltabilmektedir. Gelecekteki çalışmalarda, daha fazla eğitim verisi kullanılarak, daha fazla katmanı bulunan daha derin modeller uygulanabilir. Önerilen model ile kavramsal ispat için ("proof of concept") bir tasarım önerilmektedir. Gelecekteki çalışmalarda farklı CNN yapıları önerilerek sonuçlar daha da iyileştirilebilir.

Konvolüsyon katmanları konvolüsyon işlemini yapma yeteneğine sahiptir. Denklem 8.1 bir ekseninde konvolüsyon işlemini göstermektedir (t zaman gösterir). Derin konvolüsyonel sinir ağlarında, konvolüsyon işlemi iki boyutlu görüntülere uygulanır. Denklem 8.2 iki boyutlu bir görüntünün konvolüsyon işlemini göstermektedir (I girdi görüntüsünü, K "kernel" gösterir). Ek olarak Denklem 8.3, sinir ağı mimarisini açıklamaktadır (W ağırlıkları, x girdi, b ise "bias"i belirtir). Sinir ağının son aşamasından, çıktı almak için "softmax" işlevi kullanılır. Denklem 8.4, softmax fonksiyonunu (y, çıktısını gösterir) göstermektedir [14].

$$s(t) = (x * w)(t) = \sum_{a=-\infty}^{\infty} x(a)w(t-a) \quad (8.1)$$

$$S(i, j) = (I * K)(i, j) = \sum_m \sum_n I(m, n)K(i-m, j-n). \quad (8.2)$$

$$e_i = \sum_j W_{i,j}x_j + b_i. \quad (8.3)$$

$$y = \text{softmax}(e) \quad (8.4)$$

CNN analizi, "Keras", "Tensorflow" altyapısı kullanılarak gerçekleştirilmiş ve eğitim 200 defa tekrarlanmıştır. Görüntü oluşturma ve Etiketleme fazlarında hisse senedi fiyatlarının etiketlenmesinde "Tut" olarak etiketlenmiş görüntülerin sayısı, "Al" ve "Sat" olarak etiketlenmiş görüntülerin sayısından çok daha fazladır. Bu durum veri dengesizliğine (data imbalance problem) neden olmaktadır. Veri dengesizliği sorunu "Tut" etiketli görüntülerin örneklenmesiyle çözülmektedir. Veri dengesizliğini problemini çözmek için literatürde farklı yaklaşımlar bulunmaktadır. CNN-TA yönteminde uygulanan metod "oversampling" sınıfında bulunan "random oversampling of minority class"tır [183]. Bu sorunu çözmek için öncelikle etiketli görüntülerden "Tut/Al" ve "Tut/Sat" oranları hesaplanır. Daha sonra "Tut" etiketi sayısı kadar "Tut" görüntüleri yeniden örneklenir. Son adımda, tahmin edilen her etiket finansal senaryoda değerlendirilir. Algoritma 8, CNN-TA yönteminin prosedürünü göstermektedir.

---

## Algoritma 8 Genelleştirilmiş CNN-TA Yöntemi

---

```
1: procedure ALLPHASES
2:   Phase DataSet E/T:
3:   dataset = read(open, close, high, low, adjustedClose, volume)
4:   dataset.adjustRatio = dataset.close / dataset.adjustedClose
5:   adjust(dataset.open, dataset.close, dataset.high, dataset.low) with adjustRatio
6:   Phase Data Labelling:
7:   calculate Label (Buy/Sell/Hold) using sliding window
8:   Phase Image Creation:
9:   calculate technical analysis values (RSI, EMA, MACD..) for each line in dataset
10:  create 15x15 images
11:  merge label and technical analysis values
12:  normalize technical analysis values between [1, -1]
13:  trainingDataset = dataset.split(dates = 1997 - 2006)
14:  testDataset = dataset.split(dates = 2007 - 2016)
15:  Phase CNN:
16:  trainingDataset = resample(trainingDataset) to solve data imbalance problem
17:  model = CNN(epochs = 200, blocksize = 1028)
18:  model.train(trainingDataset)
19:  model.test(testDataset)
20:  Phase Financial Evaluation:
21:  evaluateResults()
```

---

## 8.3 Değerlendirme

### 8.3.1 Finansal değerlendirme

Finansal değerlendirme fazında, sonuçlar finansal değerlendirme metodu kullanılarak değerlendirilir. Finansal değerlendirme senaryosu, Denklem 8.5’de gösterilmektedir. Eğer, hisse senedinin o anki fiyatının etiketi "Al" ise, hisse bu noktada mevcut sermayenin tamamı ile alınır, eğer hisse senedinin o anki fiyatının etiketi "Sat" ise, hisse bu fiyata satılır. Eğer, tahmin edilen etiket "Tut" ise, o anda herhangi bir işlem yapılmaz. Ayrıca, aynı etiket ardışık olarak gelirse, işlem yalnızca ilk etiket göre yapılır. Tekrarlanan etiketler ilişkili etiket değişinceye kadar dikkate alınmaz. Finansal değerlendirme için başlangıç sermayesi \$10,000, işlem komisyonu işlem başına (transaction) \$1’dir.

$$\text{FinansalDeğerlendirme} = \begin{cases} \text{numberOfStocks} = \frac{\text{totalCapital}}{\text{price}}, & \text{if label='Buy'} \\ \text{no action}, & \text{if label='Hold'} \\ \text{totalCapital} = \text{price} * \text{numberOfStocks} & \text{if label='Sell'} \end{cases} \quad (8.5)$$

### 8.3.2 Karşılaştırılan modeller

Önerdiğimiz yöntem (CNN-TA), Dow 30 hisse senetleri ve ETF'ler ile farklı zaman aralıklarında (2008 finansal krizinin etkilerini analiz etmek için 2007-2012 yılları, son 10 yılın performansını değerlendirmek için 2007-2017 yılları) değerlendirilmektedir. CNN-TA yöntemi "Al&Tut" Stratejisi (BAH), RSI (14 günlük aralıkta, 70-30), SMA (50 günlük) modelleriyle, LSTM ve MLP regresyon yöntemleriyle de karşılaştırılmaktadır. Her bir yöntem, model ve strateji için implementasyon yapılmış ve ilgili finansal hesaplama senaryoları koşturulmuştur.

"Al&Tut" stratejisinde hisse senedi test verisinin başındaki fiyattan alınır, test verisinin sonundaki fiyattan satılır. Böylelikle test aralığındaki finansal kazancı hesaplanır. RSI modelinde test verisindeki her bir veri için RSI değeri hesaplanır. İlgili test verisinin o anki RSI değeri 30 değerinin altında ise, alım sinyali oluşturulur; ilgili test verisinin o anki RSI değeri 70 değerinin üstünde ise, satım sinyali oluşturulur. SMA modelinde test verisindeki her bir veri için 50 günlük SMA değeri hesaplanır. İlgili test verisinin o anki SMA değeri 50 günlük değerinin üzerine çıktıysa alım sinyali oluşturulur. Çünkü fiyatların, 50 günlük verilerin üzerine çıkması, eğilimin yukarıya doğru çıkmaya başlayacağını göstergesidir. Diğer durumda satım sinyali oluşturulur. LSTM ve MLP regresyon modelleri zaman serisi verilerinin analizinde çoğunlukla kullanılan bir yöntemlerdendir. Ayrıca literatürdeki çalışmalarda da LSTM [20] ve MLP regresyon [24], [192] modelleri finansal zaman serisi verilerinin analizinde de kullanılmaktadır. Karşılaştırılan LSTM modeli, [20] çalışmasında da kullanılan, 240 zaman basamağına sahip, 25 nöronluk LSTM yapısından ( girdi katmanı: 1 nöron, gizli katman: 25 nöron, çıktı katmanı: 1 nöron, "dropout:" 0.5, "epoch:" 1000) oluşan bir modeldir. Karşılaştırılan MLP modeli, [20] çalışmasında da kullanılan, 100 zaman basamağına sahip, 4 katmandan (katmanlar: 31,10,5,1, "dropout:" 0.5, "epoch:" 200) oluşan bir modeldir.

### 8.3.3 ETF analizi

Seçilen ETF'ler ve açıklamaları Çizelge 8.3'de gösterilmektedir. Seçilen ETF'ler, yüksek işlem hacmine sahip oldukları için eğitim için yeterlidir. Çizelge 8.4, Çizelge 8.6, Çizelge 8.8, Çizelge 8.10'daki varlıkların finansal değerlendirme sonuçları aşağıdaki kriterlere göre değerlendirilmektedir: CNN-TA metodunun toplam sermayesi (CNN-TA), CNN-TA metodunun yıllık getirisi (CNN-TA\_AR) , "Al&Tut" stratejisi toplam sermaye(BaH), "Al&Tut" stratejisi yıllık getirisi (BaH\_AR), yıllık ortalama işlem sayısı (AnT), başarı oranı (PoS), işlemler başına ortalama kâr yüzdesi (APT), ortalama işlem uzunluğu (L), işlemdeki maksimum kar yüzdesi (MpT), işlemdeki maksimum

Çizelge 8.2: TRV hissesinin örnek "Al-Sat" işlemleri

İşlem Numarası	İşlem Aralığı (Gün)	Kazanç	Anlık Sermaye
1	1-3	\$185.45	\$10183.45
10	167-172	\$497.25	\$11430.10
20	302-309	\$224.51	\$13503.91
30	418-424	-\$464.52	\$15728.26
40	544-549	\$690.32	\$19705.69
50	662-674	\$345.10	\$26649.55
60	818-841	-\$1310.31	\$29696.90
70	1029-1038	\$227.44	\$31644.05
80	1174-1178	\$711.39	\$33143.69
90	1311-1314	\$726.67	\$41231.66
100	1489-1495	\$27.38	\$45470.46
110	1644-1661	-\$1312.99	\$49852.26
120	1917-1924	-\$10.75	\$47846.05
130	2088-2090	\$565.91	\$54205.05
140	2251-2267	-\$3.562.69	\$55261.75
153	2453-2466	-\$898.75	\$64343.49

kayıp yüzdesi (MLT), maksimum sermaye (MxC), minimum sermaye (MinC), sistemin boş kalma oranı (IR). Değerlendirme metriklerinin formülleri Denklemler 8.6, 8.7, 8.8, 8.9, 8.10, 8.11'de gösterilmektedir. Çizelge 8.2, TRV hissesinin finansal işlemlerini göstermektedir.

$$AR = \left( \left( \frac{totalCapital}{initialCapital} \right)^{\frac{1}{numberOfYears}} - 1 \right) * 100 \quad (8.6)$$

$$AnT = \frac{transactionCount}{numberOfYears} \quad (8.7)$$

$$PoS = \frac{successTransactionCount}{transactionCount} * 100 \quad (8.8)$$

$$ApT = \frac{totalPercentProfit}{transactionCount} * 100 \quad (8.9)$$

$$L = \frac{totalTransactionLength}{transactionCount} * 100 \quad (8.10)$$

$$IdleR = \frac{numberOfDaysInTestData - totalTransLength}{numberOfDaysInTestData} * 100 \quad (8.11)$$

CNN-TA metodu ile ETF'lerde 2007-2012 döneminde ortalama yıllık getiri 8.30% ve işlem başarı oranı 71.44%'tür. Aynı dönemde ETF'lerde "Al&Tut" stratejisinin ortalama yıllık getirisi 2.60%, RSI modelinin ortalama yıllık getirisi -0.01%, SMA mo-



Çizelge 8.3: Seçilen ETF ve tanımları

İsim	Tanım	Başlangıç Tarihi	Hacim
XLF	Financial Select Sector SPDR ETF	12/16/1998	71,886,065
XLU	Utilities Select Sector SPDR ETF	12/16/1998	11,342,530
QQQ	PowerShares QQQ ETF	10/03/1999	33,918,165
SPY	SPDR S&P 500 ETF	1/22/1993	68,675,793
XLP	Consumer Staples Select Sector SPDR ETF	12/16/1998	9,721,714
EWZ	iShares MSCI Brazil Capped ETF	7/10/2000	19,613,073
EWH	iShares MSCI Hong Kong ETF	3/12/1996	2,586,985
XLY	Consumer Discret Sel Sect SPDR ETF	12/16/1998	4,257,841
XLE	Energy Select Sector SPDR ETF	12/16/1998	16,494,257

Çizelge 8.4: CNN-TA yönteminin ETF'lerle değerlendirilmesi - eğitim periyodu: 1997-2007, test periyodu: 2007-2012

ETF	CNN	CNNr	AnT	PoS	ApT	L	MpT	MIT	MaxC	MinC	IdleR	Sharpe Ratio
SPY	\$11,223.33	2.34%	20.0	66.18%	0.28%	8.0	10.82%	-18.78%	\$11,834.68	\$8,405.94	53.62%	0.05
QQQ	\$17,344.15	11.64%	21.1	72.22%	0.87%	7.0	5.87%	-11.89%	\$17,456.37	\$9,938.15	54.50%	0.13
XLU	\$14,801.43	8.16%	18.2	79.03%	0.74%	9.0	9.99%	-19.42%	\$14,801.43	\$9,406.22	54.34%	0.10
XLE	\$25,243.48	20.35%	18.5	76.19%	1.62%	8.0	11.75%	-9.97%	\$25,243.48	\$10,000.00	55.14%	0.15
XLP	\$15,288.75	8.86%	17.3	77.97%	0.77%	10.0	2.92%	-11.60%	\$15,288.75	\$10,000.00	49.28%	0.18
XLY	\$11,954.73	3.64%	20.6	71.43%	0.42%	8.0	17.36%	-26.49%	\$12,254.06	\$8,265.56	53.70%	0.05
EWZ	\$11,171.55	2.24%	15.6	69.81%	0.57%	11.0	10.25%	-28.44%	\$16,324.28	\$8,309.26	51.37%	0.05
EWH	\$14,774.90	8.12%	17.0	72.41%	0.90%	9.0	9.53%	-30.85%	\$15,830.15	\$9,514.67	53.70%	0.09
XLF	\$12,272.32	4.18%	20.8	57.75%	0.51%	9.0	11.34%	-21.09%	\$12,363.30	\$6,607.69	48.15%	0.04
Ortalama	\$14,897.18	8.30%	18.8	71.44%	0.74%	8.8	9.98%	-19.84%	\$15,710.72	\$8,938.61	52.64%	0.09
S.Sapma	\$4,417.81	5.75%	1.9	6.54%	0.39%	1.2	3.99%	7.67%	\$4,084.94	\$1,138.46	2.47%	0.05

Çizelge 8.5: CNN-TA yöntemi ile BaH, RSI, SMA, LSTM, MLP (Reg.) modellerinin karşılaştırılması (ETF'ler-test periyodu: 2007-2012)

ETF	CNN-TA	CNN-TAr	BaH	BaHr	RSI	RSIr	SMA	SMAr	LSTM[20]	LSTMr[20]	MLP[20]	MLPr[20]
SPY	\$11,223.33	2.34%	\$9,807.33	-0.39%	\$9,204.64	-1.64%	\$9,246.29	-1.56%	\$16,891.51	11.05%	\$16,566.71	10.62%
QQQ	\$17,344.15	11.64%	\$13,210.34	5.73%	\$11,368.36	2.60%	\$13,606.42	6.35%	\$12,998.23	5.38%	\$11,507.81	2.85%
XLU	\$14,801.43	8.16%	\$12,001.08	3.72%	\$10,426.38	0.84%	\$10,065.29	0.13%	\$13,953.37	6.89%	\$12,036.95	3.78%
XLE	\$25,243.48	20.35%	\$13,138.92	5.61%	\$9,839.31	-0.32%	\$14,323.20	7.45%	\$12,027.02	3.76%	\$18,370.02	12.93%
XLP	\$15,288.75	8.86%	\$14,002.61	6.97%	\$12,096.31	3.88%	\$12,207.19	4.07%	\$10,612.21	1.20%	\$12,384.29	4.37%
XLY	\$11,954.73	3.64%	\$10,854.97	1.65%	\$11,042.48	2.00%	\$8,288.89	-3.68%	\$12,096.52	3.88%	\$14,295.19	7.41%
EWZ	\$11,171.55	2.24%	\$14,446.88	7.64%	\$9,252.38	-1.54%	\$14,392.72	7.55%	\$10,874.25	1.69%	\$11,898.28	3.54%
EWH	\$14,774.90	8.12%	\$10,907.00	1.75%	\$9,996.86	-0.01%	\$9,691.01	-0.63%	\$31,843.35	26.07%	\$22,531.71	17.64%
XLF	\$12,272.32	4.18%	\$3,960.25	-16.91%	\$6,706.04	-7.68%	\$4,166.04	-16.06%	\$13,630.79	6.39%	\$14,036.21	7.02%
Ortalama	\$14,897.18	8.30%	\$11,369.93	2.60%	\$9,992.53	-0.01%	\$10,665.23	1.30%	\$14,991.92	8.44%	\$14,847.46	8.23%
Standart Sapma	\$4,417.81	5.75%	\$3,184.69	7.49%	\$1,565.35	3.36%	\$3,345.00	7.44%	\$6,593.52	7.61%	\$3,694.46	5.03%

Çizelge 8.6: CNN-TA yönteminin ETF'lerle değerlendirilmesi - eğitim periyodu: 1997-2007, test periyodu: 2007-2017


ETF	CNN	CNNr	AnT	PoS	ApT	L	MpT	MIT	MaxC	MinC	IdleR	Sharpe Ratio
SPY	\$25,127.56	9.65%	23.1	76.58%	0.65%	7.0	11.90%	-18.77%	\$25,127.56	\$8,949.72	54.44%	0.15
QQQ	\$29,767.18	11.53%	16.9	75.86%	1.03%	8.0	6.49%	-7.23%	\$29,767.18	\$8,895.42	61.67%	0.15
XLU	\$16,141.40	4.90%	16.5	70.80%	0.50%	10.0	10.00%	-14.30%	\$16,141.40	\$8,943.48	51.20%	0.08
XLE	\$18,386.23	6.28%	15.3	70.48%	0.72%	12.0	5.37%	-13.31%	\$21,607.02	\$10,000.00	48.16%	0.09
XLP	\$24,444.45	9.35%	11.2	80.52%	1.21%	11.0	3.86%	-8.96%	\$24,652.31	\$10,000.00	64.63%	0.22
XLY	\$18,270.32	6.21%	15.9	69.72%	0.73%	12.0	4.40%	-37.98%	\$18,270.32	\$7,360.96	44.64%	0.10
EWZ	\$9,431.61	-0.58%	18.1	62.90%	0.16%	8.0	10.26%	-23.99%	\$22,029.75	\$5,978.44	57.07%	0.02
EWH	\$11,244.26	1.18%	16.1	70.91%	0.24%	10.0	9.55%	-24.69%	\$12,896.52	\$7,829.66	53.60%	0.04
XLF	\$41,353.49	15.25%	22.6	65.81%	1.06%	7.0	29.27%	-17.33%	\$41,353.49	\$8,192.29	50.96%	0.10
Ortalama	\$21,574.06	7.99%	17.3	71.51%	0.70%	9.4	10.12%	-18.51%	\$23,538.39	\$8,461.11	54.04%	0.11
S.Sapma	\$9,899.21	4.97%	3.7	5.45%	0.36%	2.0	7.73%	9.43%	\$8,379.03	\$1,286.54	6.33%	0.06

delinin ortalama yıllık getirisi 1.30%, LSTM yönteminin ortalama getirisi 8.44% ve MLP yönteminin ortalama yıllık getirisi 8.23%'dir. Çizelge 8.4 ve Çizelge 8.5'de sonuçlar gösterilmektedir. CNN-TA yönteminin ortalama yıllık getirisi, söz konusu dönemde "Al&Tut" stratejisinin ortalama yıllık getirisinin yaklaşık olarak dört katıdır. Ayrıca, CNN-TA metodu ile ETF'lerde 2007-2017 döneminde ortalama yıllık getiri

Çizelge 8.7: CNN-TA yöntemi ile BaH, RSI, SMA, LSTM, MLP (Reg.) modellerinin karşılaştırılması (ETF'ler-test periyodu: 2007-2017)

ETF	CNN-TA	CNN-TAr	BaH	BaHr	RSI	RSIr	SMA	SMAr	LSTM[20]	LSTMr[20]	MLP[20]	MLPr[20]
SPY	\$25,127.56	9.65%	\$15,724.58	4.63%	\$18,153.76	6.14%	\$10,551.40	0.54%	\$13,907.21	3.35%	\$20,177.33	7.27%
QQQ	\$29,767.18	11.53%	\$27,189.30	10.52%	\$18,693.21	6.46%	\$16,867.35	5.37%	\$8,749.55	-1.33%	\$14,683.41	3.92%
XLU	\$16,141.40	4.90%	\$13,396.28	2.97%	\$16,145.16	4.91%	\$10,933.75	0.90%	\$11,364.95	1.29%	\$11,175.91	1.12%
XLE	\$18,386.23	6.28%	\$13,246.58	2.85%	\$14,296.43	3.64%	\$17,705.66	5.88%	\$14,818.25	4.01%	\$16,941.51	5.41%
XLP	\$24,444.45	9.35%	\$19,517.62	6.92%	\$16,747.92	5.29%	\$16,555.43	5.17%	\$17,859.49	5.97%	\$10,873.28	0.84%
XLY	\$18,270.32	6.21%	\$20,960.08	7.68%	\$17,478.94	5.74%	\$11,949.99	1.80%	\$12,346.93	2.13%	\$11,386.48	1.31%
EWZ	\$9,431.61	-0.58%	\$7,091.91	-3.38%	\$7,188.06	-3.25%	\$15,014.87	4.15%	\$8,769.09	-1.30%	\$16,945.79	5.42%
EWJ	\$11,244.26	1.18%	\$11,875.86	1.73%	\$12,579.60	2.32%	\$13,542.91	3.08%	\$31,906.14	12.30%	\$18,100.82	6.11%
XLF	\$41,353.49	15.25%	\$12,568.55	2.31%	\$11,287.83	1.22%	\$5,619.67	-5.60%	\$44,787.43	16.18%	\$13,028.10	2.68%
Ortalama	\$21,574.06	7.99%	\$15,730.08	4.63%	\$14,730.10	3.95%	\$13,193.45	2.81%	\$18,278.78	6.22%	\$14,812.51	4.01%
S.Sapma	\$9,899.21	4.97%	\$5,959.18	4.03%	\$3,784.87	3.12%	\$3,866.45	3.57%	\$12,165.03	5.96%	\$3,397.77	2.40%

7.99% ve işlem başarı oranı 71.51%'dir. Aynı dönemde ETF'lerde "Al&Tut" stratejisinin ortalama yıllık getirisi 4.63%, RSI modelinin ortalama yıllık getirisi 3.95%, SMA modelinin ortalama yıllık getirisi 2.81%, LSTM yönteminin ortalama getirisi 6.22% ve MLP yönteminin ortalama yıllık getirisi 4.01%'dir. Çizelge 8.6 ve Çizelge 8.7'de sonuçlar gösterilmektedir. CNN-TA yönteminin ortalama yıllık getirisi, "Al&Tut", RSI ve SMA'nın ortalama yıllık getirilerinin neredeyse iki katıdır.



Şekil 8.5: XLE ve XLF ETF'lerinde CNN-TA metodu ve "Al&Tut" stratejisinin sonuçlarının karşılaştırılması

Şekil 8.5, CNN-TA metodunun farklı ETF'ler için farklı zamanlardaki toplam sermaye değişimini göstermektedir. CNN-TA metodunun toplam sermaye değişimi, "Al&Tut" stratejisinin toplam sermaye değişimiyle kıyaslanmaktadır. CNN-TA metodunun performansı şekillerde gösterdiği gibi daha iyi sonuç vermektedir. Diğer ETF'lerin performans sonuçları da benzer özellikler göstermektedir.

### 8.3.4 Dow30 analizi

Ayrıca, CNN-TA metodu Dow-30 hisse senetleri ile de farklı zaman periyotlarında (2007-2012 ve 2007-2017) değerlendirilmiştir. CNN-TA metodunun finansal krizde performansını gözlemlemek için Dow-30 hisseleriyle 2007-2012 yılları arasında da işlem yapılmıştır. CNN-TA yönteminin Dow-30 hisseleri ile 2007-2012 yılları arasında ortalama yıllık getiri oranı 9.54%, finansal değerlendirme de yapılan işlemleri

başarı oranı ise 70.63%'tür. Aynı dönemde Dow-30 hisselerinde "Al&Tut" stratejisinin ortalama yıllık getirisi 6.98%, RSI modelinin ortalama yıllık getirisi 1.92%, SMA modelinin ortalama yıllık getirisi 0.75%, LSTM yönteminin ortalama getirisi 10.82% ve MLP yönteminin ortalama yıllık getirisi 9.98%'dir. Çizelge 8.8 ve Çizelge 8.9'de sonuçlar gösterilmektedir. CNN-TA yönteminin ortalama yıllık getirisi, söz konusu dönemde "Al&Tut" stratejisinin ortalama yıllık getirisine göre yaklaşık olarak 1.5 katıdır. CNN-TA yönteminin Dow-30 hisseleri ile 2007-2017 yılları arasında ortalama yıllık getiri oranı 11.47%, finansal değerlendirme de yapılan işlemleri başarı oranı ise 71.32%'dir. Aynı dönemde Dow-30 hisselerinde "Al&Tut" stratejisinin ortalama yıllık getirisi 10.47%, RSI modelinin ortalama yıllık getirisi 5.01%, SMA modelinin ortalama yıllık getirisi 3.78%, LSTM yönteminin ortalama getirisi 6.48% ve MLP yönteminin ortalama yıllık getirisi 5.45%'dir. Çizelge 8.10 ve Çizelge 8.11'da sonuçlar gösterilmektedir.

Literatürde belirtildiği gibi, CNN-TA metodu ile "Al&Tut" stratejisinin performansını geçmek uzun bir süre için zordur. CNN-TA metodunun Dow-30 hisselerinde (28 hissenin 15'inde) 2007-2012 yılların arasında ortalama yıllık getirisi, aynı dönemde "Al&Tut" stratejisinin ortalama yıllık getirisine göre daha iyi performans göstermektedir (Aynı dönemde, Visa [V] hissesinin yeterli verisi olmadığından, değerlendirmeye alınmadı).

Çizelge 8.8: CNN-TA yönteminin Dow30 hisseleriyle değerlendirilmesi - eğitim periyodu: 1997-2007, test periyodu: 2007-2012

Hisse	CNN	CNNr	AnT	PoS	ApT	L	MpT	MIT	MaxC	MinC	IdleR	Sharpe Ratio
MMM	\$12,798.44	5.06%	18.8	71.88%	0.49%	8	5.67%	-16.59%	\$13,498.57	\$8,911.81	53.94%	0.08
AXP	\$22,138.93	17.23%	22.0	70.67%	1.28%	7	11.42%	-19.54%	\$24,040.39	\$9,985.30	56.83%	0.09
APPL	\$14,185.36	7.24%	13.2	73.33%	1.46%	14	15.31%	-46.15%	\$15,423.52	\$5,777.91	47.35%	0.12
BA	\$9,806.99	-0.39%	20.8	70.42%	0.25%	8	15.47%	-26.38%	\$11,077.43	\$6,245.37	54.34%	0.02
CAT	\$7,908.68	-4.58%	22.3	69.74%	-0.03%	7	15.96%	-14.59%	\$11,084.32	\$5,639.93	51.29%	0.01
CVX	\$20,262.68	15.17%	22.6	75.32%	1.10%	8	22.68%	-10.88%	\$21,229.73	\$9,548.31	48.31%	0.10
CSCO	\$14,094.10	7.10%	15.3	63.46%	0.81%	10	8.02%	-15.94%	\$14,771.29	\$8,781.20	55.47%	0.08
KO	\$18,840.50	13.51%	17.9	75.41%	1.10%	9	11.44%	-6.31%	\$18,840.50	\$9,853.67	53.78%	0.16
DIS	\$11,473.60	2.79%	17.9	63.93%	0.40%	9	10.69%	-16.08%	\$12,447.02	\$8,080.56	54.10%	0.05
XOM	\$15,857.48	9.66%	20.0	69.12%	0.77%	8	9.39%	-10.24%	\$15,857.48	\$9,494.48	54.10%	0.08
GE	\$5,056.33	-12.75%	18.8	62.50%	-0.71%	10	10.22%	-30.94%	\$11,676.91	\$4,260.51	45.18%	-0.08
GS	\$8,575.09	-3.03%	26.1	65.17%	0.09%	7	10.74%	-37.91%	\$11,864.06	\$6,331.60	48.39%	0.01
HD	\$12,863.96	5.17%	17.6	71.67%	0.57%	8	6.92%	-18.46%	\$14,060.22	\$7,783.18	58.04%	0.07
IBM	\$14,469.14	7.67%	24.7	69.05%	0.53%	6	5.84%	-23.74%	\$15,206.31	\$7,896.61	58.44%	0.10
INTC	\$18,312.09	12.86%	19.1	70.77%	1.13%	7	8.60%	-27.98%	\$20,256.45	\$9,726.06	58.92%	0.12
JNJ	\$15,077.47	8.56%	18.5	76.19%	0.73%	9	8.61%	-11.21%	\$15,077.47	\$8,775.29	53.86%	0.11
JPM	\$37,153.71	30.02%	19.4	74.24%	2.36%	9	20.55%	-20.08%	\$40,996.53	\$9,697.90	47.83%	0.11
MCD	\$26,172.43	21.22%	14.1	83.33%	2.09%	10	5.48%	-8.96%	\$26,172.43	\$10,000.00	61.33%	0.21
MRK	\$11,202.43	2.30%	20.6	68.57%	0.31%	8	9.78%	-20.03%	\$12,573.89	\$8,762.44	54.34%	0.04
MSFT	\$12,991.83	5.37%	18.5	65.08%	0.57%	9	9.61%	-20.68%	\$15,619.06	\$8,417.03	51.13%	0.06
NKE	\$20,103.52	14.99%	20.3	73.91%	1.13%	7	10.74%	-10.81%	\$20,103.52	\$10,000.00	58.60%	0.12
PFE	\$17,102.18	11.33%	16.7	66.67%	1.02%	12	5.11%	-8.19%	\$17,102.18	\$8,741.92	43.81%	0.15
PG	\$13,734.96	6.55%	17.0	70.69%	0.68%	10	9.02%	-24.52%	\$13,734.96	\$9,153.55	52.01%	0.09
TRV	\$25,875.86	20.94%	23.2	73.42%	1.38%	7	17.26%	-26.85%	\$25,875.86	\$9,767.76	53.62%	0.14
UTX	\$13,751.18	6.58%	17.3	69.49%	0.68%	8	6.42%	-15.93%	\$13,751.18	\$9,440.58	60.93%	0.08
UNH	\$8,035.23	-4.28%	15.3	69.23%	-0.11%	11	9.29%	-21.94%	\$12,186.88	\$4,849.97	53.70%	-0.01
VZ	\$14,321.99	7.45%	18.2	66.13%	0.70%	10	22.91%	-14.57%	\$15,012.91	\$9,644.48	47.51%	0.08
WMT	\$19,349.39	14.11%	17.6	78.33%	1.15%	9	5.83%	-5.67%	\$19,349.39	\$10,000.00	55.79%	0.25
Ortalama	\$15,768.41	9.54%	19.1	70.63%	0.78%	9	11.04%	-18.97%	\$17,103.23	\$8,413.12	53.32%	0.08
S. Sapma	\$6,620.58	8.90%	3.0	4.75%	0.64%	2	5.06%	9.43%	\$6,344.95	\$1,699.85	4.61%	-

Çizelge 8.9: CNN-TA yöntemi ile BaH, RSI, SMA, LSTM, MLP (Reg.) modellerinin karşılaştırılması (Dow30 - test periyodu: 2007-2012)

Hisse	CNN-TA	CNN-Tar	BaH	BaHr	RSI	RSIr	SMA	SMAr	LSTM[20]	LSTMr[20]	MLP[20]	MLPr[20]
MMM	\$12,798.44	5.06%	\$11,888.66	3.52%	\$9,235.66	-1.58%	\$7,096.84	-6.63%	\$20,345.92	15.26%	\$11,729.82	3.24%
AXP	\$22,138.93	17.23%	\$8,943.51	-2.21%	\$5,482.32	-11.33%	\$7,477.11	-5.65%	\$33,659.87	27.47%	\$30,126.62	24.68%
APPL	\$14,185.36	7.24%	\$47,450.80	36.54%	\$14,382.02	7.54%	\$41,188.98	32.73%	\$25,849.19	20.92%	\$10,247.97	0.49%
BA	\$9,806.99	-0.39%	\$9,724.67	-0.56%	\$10,151.55	0.30%	\$10,941.36	1.82%	\$18,858.76	13.53%	\$12,134.23	3.94%
CAT	\$7,908.68	-4.58%	\$16,827.13	10.97%	\$6,301.61	-8.82%	\$22,506.23	17.61%	\$12,612.59	4.75%	\$12,498.18	4.56%
CVX	\$20,262.68	15.17%	\$17,518.44	11.87%	\$11,307.00	2.49%	\$9,990.36	-0.02%	\$21,286.98	16.31%	\$19,327.05	14.09%
CSCO	\$14,094.10	7.10%	\$6,939.05	-7.05%	\$10,066.51	0.13%	\$4,339.33	-15.38%	\$10,406.13	0.80%	\$25,744.33	20.82%
KO	\$18,840.50	13.51%	\$16,948.81	11.13%	\$12,564.34	4.67%	\$12,839.80	5.13%	\$13,275.68	5.83%	\$14,864.74	8.25%
DIS	\$11,473.60	2.79%	\$11,907.46	3.55%	\$9,077.48	-1.92%	\$8,035.01	-4.28%	\$15,017.44	8.47%	\$11,657.07	3.11%
XOM	\$15,857.48	9.66%	\$12,837.92	5.12%	\$12,429.67	4.45%	\$7,667.46	-5.17%	\$11,966.52	3.66%	\$15,493.71	9.15%
GE	\$5,056.33	-12.75%	\$6,031.12	-9.62%	\$3,826.46	-17.51%	\$8,578.03	-3.02%	\$12,008.42	3.73%	\$11,707.89	3.20%
GS	\$8,575.09	-3.03%	\$4,437.56	-15.00%	\$4,801.86	-13.65%	\$7,944.55	-4.50%	\$5,507.34	-11.25%	\$13,645.63	6.41%
HD	\$12,863.96	5.17%	\$12,356.57	4.32%	\$11,461.36	2.77%	\$6,739.70	-7.59%	\$12,900.92	5.23%	\$13,516.03	6.21%
IBM	\$14,469.14	7.67%	\$20,576.54	15.52%	\$12,439.42	4.46%	\$13,734.41	6.55%	\$10,689.04	1.34%	\$9,443.76	-1.14%
INTC	\$18,312.09	12.86%	\$13,650.17	6.42%	\$12,210.66	4.08%	\$10,344.53	0.68%	\$14,571.12	7.82%	\$20,848.47	15.83%
JNJ	\$15,077.47	8.56%	\$11,612.37	3.03%	\$12,646.89	4.81%	\$8,548.53	-3.09%	\$14,369.22	7.52%	\$11,388.52	2.63%
JPM	\$37,153.71	30.02%	\$7,403.34	-5.84%	\$13,339.47	5.93%	\$3,400.61	-19.40%	\$42,790.03	33.74%	\$35,895.10	29.12%
MCD	\$26,172.43	21.22%	\$27,177.18	22.14%	\$15,736.58	9.49%	\$10,461.10	0.91%	\$8,955.81	-2.18%	\$11,288.48	2.45%
MRK	\$11,202.43	2.30%	\$10,168.31	0.33%	\$8,202.52	-3.89%	\$9,408.96	-1.21%	\$13,993.70	6.95%	\$17,392.93	11.71%
MSFT	\$12,991.83	5.37%	\$9,394.58	-1.24%	\$8,809.79	-2.50%	\$10,313.04	0.62%	\$18,085.36	12.58%	\$21,023.00	16.02%
NKE	\$20,103.52	14.99%	\$21,861.39	16.93%	\$18,262.45	12.80%	\$7,336.84	-6.01%	\$17,470.30	11.80%	\$13,573.38	6.30%
PFE	\$17,102.18	11.33%	\$10,503.06	0.99%	\$7,403.32	-5.84%	\$9,594.55	-0.82%	\$11,548.34	2.92%	\$14,676.03	7.97%
PG	\$13,734.96	6.55%	\$11,741.86	3.26%	\$11,330.49	2.53%	\$8,888.68	-2.33%	\$18,360.02	12.92%	\$10,574.07	1.12%
TRV	\$25,875.86	20.94%	\$13,324.97	5.91%	\$13,235.25	5.77%	\$3,508.34	-18.90%	\$26,790.39	21.79%	\$20,141.74	15.03%
UTX	\$13,751.18	6.58%	\$12,386.81	4.37%	\$11,891.70	3.53%	\$11,252.19	2.39%	\$13,017.00	5.41%	\$11,818.87	3.40%
UNH	\$8,035.23	-4.28%	\$10,109.54	0.22%	\$9,109.76	-1.85%	\$14,419.23	7.59%	\$6,458.90	-8.37%	\$9,954.43	-0.09%
VZ	\$14,321.99	7.45%	\$14,656.19	7.95%	\$15,804.16	9.59%	\$8,516.92	-3.16%	\$18,800.76	13.46%	\$21,278.94	16.30%
WMT	\$19,349.39	14.11%	\$13,955.82	6.89%	\$16,374.40	10.37%	\$5,621.17	-10.88%	\$18,348.79	12.91%	\$18,497.10	13.09%
Ortalama	\$15,768.41	9.54%	\$14,011.92	6.98%	\$10,995.67	1.92%	\$10,381.92	0.75%	\$16,712.31	10.82%	\$16,088.86	9.98%
Standart Sapma	\$6,620.58	8.90%	\$8,186.32	10.09%	\$3,553.91	7.33%	\$7,098.58	10.21%	\$7,978.25	9.74%	\$6,411.05	7.77%

Çizelge 8.10: CNN-TA yönteminin Dow30 hisseleriyle değerlendirilmesi - eğitim periyodu: 1997-2007, test periyodu: 2007-2017

Hisse	CNN	CNNr	AnT	PoS	ApT	L	MpT	MIT	MaxC	MinC	IdleR	Sharpe Ratio
MMM	\$29,661.39	11.49%	26.0	75.84%	0.67%	6.0	6.41%	-12.98%	\$30,009.41	\$7,807.65	55.88%	0.14
AXP	\$27,720.98	10.73%	21.6	69.59%	0.85%	7.0	4.57%	-19.54%	\$34,928.18	\$9,301.29	54.84%	0.08
APPL	\$25,015.36	9.60%	17.1	69.23%	1.02%	9.0	5.76%	-12.78%	\$28,978.02	\$6,282.05	55.44%	0.11
BA	\$23,063.36	8.72%	21.7	74.50%	0.72%	6.0	5.57%	-25.89%	\$23,063.36	\$6,181.32	59.55%	0.07
CAT	\$14,005.45	3.43%	19.8	61.76%	0.46%	9.0	9.36%	-14.59%	\$14,005.45	\$7,350.62	48.64%	0.04
CVX	\$21,435.73	7.92%	27.6	69.84%	0.50%	5.0	15.37%	-12.55%	\$28,630.72	\$9,472.46	54.72%	0.06
CSCO	\$26,997.92	10.44%	14.3	71.43%	1.17%	11.0	9.53%	-18.02%	\$27,081.73	\$8,488.42	53.40%	0.12
KO	\$33,256.00	12.77%	21.5	70.75%	0.86%	6.0	5.68%	-5.14%	\$33,256.00	\$9,979.00	59.71%	0.15
DIS	\$22,406.60	8.40%	25.8	72.88%	0.55%	6.0	3.56%	-11.34%	\$25,033.39	\$8,256.17	51.56%	0.09
XOM	\$43,812.44	15.92%	26.0	73.03%	0.90%	5.0	20.27%	-13.00%	\$44,068.29	\$9,675.61	60.03%	0.10
GE	\$16,275.45	4.99%	20.1	64.49%	0.48%	7.0	10.43%	-12.26%	\$16,401.42	\$6,382.09	59.87%	0.06
GS	\$17,871.14	5.98%	23.9	65.24%	0.55%	7.0	16.26%	-37.91%	\$17,871.14	\$7,251.89	51.32%	0.06
HD	\$22,081.72	8.24%	17.1	75.21%	0.77%	8.0	5.15%	-4.99%	\$22,081.72	\$7,954.16	58.99%	0.10
IBM	\$16,417.62	5.08%	20.3	69.06%	0.45%	7.0	5.84%	-14.10%	\$18,360.55	\$7,457.81	58.35%	0.08
INTC	\$37,074.54	14.00%	20.3	69.06%	1.04%	7.0	7.05%	-15.01%	\$38,646.53	\$9,366.48	59.19%	0.13
JNJ	\$20,612.37	7.50%	20.3	77.70%	0.57%	7.0	8.60%	-6.29%	\$21,177.93	\$9,205.00	58.03%	0.13
JPM	\$117,462.09	27.94%	19.7	78.52%	2.09%	8.0	27.14%	-21.94%	\$117,462.09	\$9,611.88	53.12%	0.12
MCD	\$30,024.99	11.62%	17.4	72.27%	0.97%	7.0	4.56%	-4.49%	\$30,867.50	\$10,000.00	65.95%	0.16
MRK	\$30,233.72	11.70%	24.7	72.78%	0.74%	6.0	8.20%	-20.03%	\$31,935.89	\$9,726.01	54.84%	0.11
MSFT	\$32,387.89	12.47%	21.0	71.53%	0.91%	7.0	10.71%	-18.65%	\$32,387.89	\$8,697.04	58.11%	0.12
NKE	\$40,070.47	14.89%	22.9	75.16%	0.97%	7.0	8.89%	-10.32%	\$47,657.32	\$10,000.00	54.28%	0.13
PFE	\$20,315.90	7.35%	22.8	68.59%	0.51%	5.0	3.67%	-5.82%	\$20,315.90	\$7,836.71	63.95%	0.08
PG	\$17,450.07	5.73%	23.1	69.62%	0.40%	6.0	7.62%	-10.44%	\$17,450.07	\$9,753.98	59.43%	0.09
TRV	\$64,343.49	20.46%	22.3	75.16%	1.29%	6.0	16.57%	-7.82%	\$65,456.54	\$10,000.00	59.39%	0.16
UTX	\$21,852.57	8.13%	20.7	71.13%	0.65%	8.0	5.50%	-17.49%	\$25,631.54	\$10,000.00	53.32%	0.09
UNH	\$16,183.84	4.93%	20.6	70.92%	0.54%	7.0	5.75%	-30.61%	\$16,183.84	\$3,785.13	59.07%	0.06
VZ	\$22,343.95	8.37%	20.9	67.13%	0.62%	7.0	5.47%	-4.66%	\$23,210.13	\$10,000.00	55.04%	0.10
WMT	\$19,322.03	6.81%	17.8	74.59%	0.59%	7.0	3.57%	-12.57%	\$19,322.03	\$10,000.00	62.99%	0.12
Ortalama	\$29,632.11	11.47%	21.3	71.32%	0.78%	6.9	8.82%	-14.33%	\$31,124.09	\$8,565.10	57.11%	0.10
S.Sapma	\$20,193.50	5.17%	3.1	3.90%	0.35%	1.3	5.59%	7.97%	\$20,248.83	\$1,568.08	3.98%	0.03

Şekil 8.6, CNN-TA metodunun farklı hisse senetleri için farklı zamanlardaki toplam sermaye değişimini göstermektedir. Ayrıca, CNN-TA metodunun toplam sermaye değişimi, "Al&Tut" stratejisinin toplam sermaye değişimiyle kıyaslanmaktadır. CNN-TA metodunun performansı şekillerde gösterdiği gibi daha iyi sonuç vermektedir. Diğer hisselerin performans sonuçları da benzer özellikler göstermektedir.

Çizelge 8.11: CNN-TA yöntemi ile BaH, RSI, SMA, LSTM, MLP (Reg.) modellerinin karşılaştırılması (Dow30 - test periyodu: 2007-2017)

Hisse	CNN-TA	CNN-TAr	BaH	BaHr	RSI	RSIr	SMA	SMAr	LSTM[20]	LSTMr[20]	MLP[20]	MLPr[20]
MMM	\$29,661.39	11.49%	\$29,324.88	11.36%	\$15,738.61	4.64%	\$12,495.92	2.25%	\$18,649.18	6.43%	\$12,534.43	2.28%
AXP	\$27,720.98	10.73%	\$15,157.78	4.25%	\$9,184.33	-0.85%	\$9,076.55	-0.96%	\$20,096.20	7.23%	\$24,923.76	9.56%
APPL	\$25,015.36	9.60%	\$104,256.20	26.42%	\$26,188.52	10.11%	\$59,639.43	19.55%	\$16,340.82	5.03%	\$12,882.29	2.57%
BA	\$23,063.36	8.72%	\$22,809.31	8.60%	\$12,552.96	2.30%	\$12,277.65	2.07%	\$14,821.54	4.01%	\$12,914.35	2.59%
CAT	\$14,005.45	3.43%	\$20,025.92	7.19%	\$7,358.97	-3.02%	\$27,696.31	10.72%	\$8,572.18	-1.53%	\$10,675.91	0.66%
CVX	\$21,435.73	7.92%	\$22,968.13	8.67%	\$15,672.01	4.60%	\$11,121.03	1.07%	\$20,863.59	7.63%	\$17,500.35	5.76%
CSCO	\$26,997.92	10.44%	\$13,126.52	2.76%	\$17,200.28	5.57%	\$5,813.56	-5.28%	\$23,777.76	9.05%	\$24,008.09	9.15%
KO	\$33,256.00	12.77%	\$23,354.41	8.85%	\$21,145.34	7.78%	\$13,551.51	3.09%	\$14,386.45	3.70%	\$13,068.56	2.71%
DIS	\$22,406.60	8.40%	\$34,368.91	13.14%	\$10,999.14	0.96%	\$18,524.60	6.36%	\$15,790.96	4.67%	\$16,861.57	5.36%
XOM	\$43,812.44	15.92%	\$15,946.05	4.78%	\$15,996.92	4.81%	\$7,892.89	-2.34%	\$19,067.38	6.67%	\$14,055.06	3.46%
GE	\$16,275.45	4.99%	\$12,399.64	2.17%	\$4,659.37	-7.35%	\$14,693.50	3.92%	\$15,887.46	4.74%	\$17,481.97	5.74%
GS	\$17,871.14	5.98%	\$12,617.30	2.35%	\$6,036.53	-4.92%	\$13,213.57	2.83%	\$16,672.30	5.24%	\$30,017.96	11.62%
HD	\$22,081.72	8.24%	\$43,768.70	15.91%	\$19,808.24	7.07%	\$16,824.76	5.34%	\$18,372.69	6.27%	\$12,335.55	2.12%
IBM	\$16,417.62	5.08%	\$21,143.52	7.77%	\$16,839.63	5.35%	\$12,645.37	2.37%	\$10,951.53	0.91%	\$8,576.67	-1.52%
INTC	\$37,074.54	14.00%	\$23,656.29	8.99%	\$16,576.08	5.18%	\$17,742.69	5.90%	\$18,212.64	6.18%	\$15,840.55	4.71%
JNJ	\$20,612.37	7.50%	\$23,687.77	9.01%	\$20,666.97	7.53%	\$11,964.91	1.81%	\$14,460.00	3.76%	\$10,428.55	0.42%
JPM	\$117,462.09	27.94%	\$22,092.57	8.25%	\$22,942.07	8.66%	\$6,130.76	-4.77%	\$43,048.07	15.72%	\$45,157.07	16.27%
MCD	\$30,024.99	11.62%	\$38,489.77	14.43%	\$22,339.34	8.37%	\$12,239.25	2.04%	\$14,932.11	4.09%	\$10,239.87	0.24%
MRK	\$30,233.72	11.70%	\$18,865.70	6.55%	\$14,249.12	3.60%	\$10,950.68	0.91%	\$13,281.94	2.88%	\$17,021.21	5.46%
MSFT	\$32,387.89	12.47%	\$25,820.00	9.95%	\$19,804.70	7.07%	\$17,207.44	5.58%	\$16,744.16	5.29%	\$15,449.97	4.45%
NKE	\$40,070.47	14.89%	\$48,496.06	17.10%	\$24,411.78	9.34%	\$10,591.00	0.58%	\$11,654.47	1.54%	\$15,802.58	4.68%
PFE	\$20,315.90	7.35%	\$18,788.46	6.51%	\$9,659.66	-0.35%	\$11,986.56	1.83%	\$19,796.16	7.07%	\$11,427.59	1.34%
PG	\$17,450.07	5.73%	\$17,434.55	5.72%	\$13,846.43	3.31%	\$10,919.47	0.88%	\$16,272.69	4.99%	\$14,707.07	3.93%
TRV	\$64,343.49	20.46%	\$31,098.53	12.01%	\$18,314.80	6.24%	\$4,528.97	-7.62%	\$61,819.78	19.98%	\$28,327.02	10.97%
UTX	\$21,852.57	8.13%	\$20,932.55	7.67%	\$13,133.92	2.76%	\$13,681.38	3.18%	\$18,804.62	6.52%	\$11,780.28	1.65%
UNH	\$16,183.84	4.93%	\$34,595.28	13.21%	\$20,242.05	7.31%	\$24,792.91	9.50%	\$9,032.76	-1.01%	\$12,341.19	2.13%
VZ	\$22,343.95	8.37%	\$24,315.17	9.29%	\$24,497.50	9.37%	\$10,286.78	0.28%	\$15,516.30	4.49%	\$17,291.27	5.63%
WMT	\$19,322.03	6.81%	\$18,389.92	6.28%	\$16,629.06	5.22%	\$7,465.02	-2.88%	\$16,766.05	5.30%	\$22,256.72	8.33%
Ortalama	\$29,632.11	11.47%	\$27,068.92	10.47%	\$16,310.51	5.01%	\$14,498.37	3.78%	\$18,735.42	6.48%	\$16,996.70	5.45%
Standart Sapma	\$20,193.50	5.17%	\$17,610.73	5.10%	\$5,702.82	4.38%	\$10,234.22	5.28%	\$10,429.21	4.26%	\$7,747.05	3.99%



Şekil 8.6: JPM ve TRV hisselerinde CNN-TA metodu ve "Al&Tut" stratejisinin sonuçlarının karşılaştırılması

### 8.3.5 Hesaplamalı model performansı

Ayrıca, CNN-TA modelinde kullanılan derin konvolüsyonel ağının tahmin performansı değerlendirilmektedir. Çizelge 8.12, Dow-30 hisselerindeki test verilerinin hata matrisini (confusion matrisi) göstermektedir. Çizelge 8.13, hata matrisinin performans değerlendirilmesini göstermektedir. Sınıf 1 ("Al") ve Sınıf 2 ("Sat") değerlerinin "recall" değerleri sınıf 0'a ("Tut") göre daha iyi performans göstermektedir. Bununla birlikte, sınıf 1 ve 2, sınıf 0'a göre daha kötü "precision" değerine sahiptir. Genel olarak, CNN-TA modelinin genel başarısı, "Al-Sat" noktalarının (sınıf 1 ve 2) doğru bir şekilde önerilmesine bağlıdır. Önerdiğimiz metot ile "Al-Sat" noktalarının çoğu doğru bir şekilde elde edilmektedir. Bununla birlikte, birçok yanlış "Al-Sat" noktası da üretilmektedir. Bunun nedeni, "Al" ve "Sat" noktalarının "Tut" noktalarından çok daha az sıklıkla görüldüğü gerçeğidir. Yapay sinir ağı ile genel dağılımı bozmadan "Nadir" oluşan "Al-

"Sat" noktalarını yakalamak kolay değildir. Başka bir deyişle, "Al", "Sat" noktalarının çoğunu yakalayabilmek için model, mevcut olmayan "Al-Sat" noktaları için yanlış sinyaller üretmektedir. Ayrıca, "Tut" noktaları "Al" ve "Sat" (tepeler ve vadiler) kadar net değildir. Sınır ağı, "Al" ve "Sat" noktalarına yakın olan "Tut" noktalarını (özellikle de en yüksek ve en düşük noktalara) karıştırabilmektedir. Çizelge 8.14, ETF test verilerinin hata matrisini ve Çizelge 8.15, ETF verilerinin hata matrisinin değerlendirilmesini göstermektedir. ETF'lerin performans değerlendirme sonuçları, Dow30 hisse senetlerinin performans değerlendirme sonuçlarına göre daha iyi olduğunu göstermektedir. Bu, ETF'lerin olaylara, ekonomik krizlere ve siyasi kararlara hisse senetlerine kıyasla daha az hassas olmalarından dolayıdır. ETF'ler ile CNN-TA modelinin daha kararlı olduğu gösterilmektedir.

Çizelge 8.12: Test verilerinin hata matrisi (confusion matrix-Dow-30)

		Predicted		
		0	1	2
Actual	0	52364	18684	23592
	1	1268	5175	3
	2	1217	8	5059

Çizelge 8.13: Test verilerinin değerlendirilmesi (Dow-30)

Total Accuracy: 0.58			
	Class 0	Class 1	Class 2
Recall	0.55	0.80	0.81
Precision	0.95	0.22	0.18
F1 Score	0.70	0.34	0.29

Çizelge 8.14: Test verilerinin hata matrisi (confusion matrix-ETFs)

		Predicted		
		0	1	2
Actual	0	18629	5180	6498
	1	478	1215	0
	2	587	0	1127

Çizelge 8.15: Test verilerinin değerlendirilmesi (ETFs)

Total Accuracy: 0.62			
	Class 0	Class 1	Class 2
Recall	0.61	0.72	0.66
Precision	0.95	0.19	0.15
F1 Score	0.75	0.30	0.24

Çizelge 8.16: Dow30 hisselerinin 2007-2012 ve 2012-2017 dönemlerindeki TTest sonuçları

Performans Metrikleri	TTest Sonuçları
Total Capital with Proposed Strategy (CNN-TA)	0.001
Proposed Strategy Annualized Return (CNN-TAR),	0.337
Annualized Number of Transaction (AnT)	0.007
Percent of Success (PoS)	0.556
Average Percent Profit Per Transactions (ApT)	0.981
Average Transaction Length (L)	0.000
Maximum Profit Percentage in Transaction (MpT)	0.127
Maximum Loss Percentage in Transaction (MIT)	0.052
Maximum Capital (MaxC)	0.001
Minimum Capital (MinC)	0.729
Idle Ratio (IdleR)	0.002

Çizelge 8.17: ETF'lerin 2007-2012 ve 2012-2017 dönemlerindeki TTest sonuçları

Performans Metrikleri	TTest Sonuçları
Total Capital with Proposed Strategy (CNN-TA)	0.083
Proposed Strategy Annualized Return (CNN-TAR),	0.787
Annualized Number of Transaction (AnT)	0.298
Percent of Success (PoS)	0.982
Average Percent Profit Per Transactions (ApT)	0.815
Average Transaction Length (L)	0.405
Maximum Profit Percentage in Transaction (MpT)	0.962
Maximum Loss Percentage in Transaction (MIT)	0.747
Maximum Capital (MaxC)	0.023
Minimum Capital (MinC)	0.417
Idle Ratio (IdleR)	0.546

### 8.3.6 İstatistiksel anlamlılık testleri

Çizelge 8.4, Çizelge 8.8, Çizelge 8.6, ve Çizelge 8.10'da oluşturulan metriklere istatistiksel anlamlılık testleri (statistical significance) uygulanmıştır. Elde edilen istatistiksel anlamlılık test sonuçları Çizelge 8.16 ve Çizelge 8.17'da gösterilmektedir. İstatistiksel anlamlılık test sonuçlarına göre CNN-TA metodunun farklı zamanlarda (2007-2012 ve 2007-2017 dönemleri) ve farklı piyasa koşullarına göre farklı davranmadığı gözlemlenmiştir. Değerlendirilen metrikler incelendiğinde, CNN-TA modelinin istikrarlı ve sağlam çalıştığı söylenebilir.

### 8.3.7 CNN-TA yönteminin değerlendirilmesi

Çizelge 8.4, Çizelge 8.8, Çizelge 8.6, ve Çizelge 8.10 incelendiğinde, yapılan işlemlerdeki başarı oranının %70-80 olduğu görülmektedir. Dolayısıyla, CNN-TA metodu tarafından üretilen işlem sinyalleri ("Al", "Sat", "Tut") çoğu zaman başarılı (karlı) durumdadır. Test verisi (2007-2017 yılları arası) incelendiğinde, dönem boyunca farklı piyasa koşullarının (yükselen, alçalan, durağan) olduğu gözlemlenmektedir. Ancak, piyasa koşullarındaki bu dalgalanmalar, CNN-TA modelinin genel işlem performansını etkilememektedir. Sonuç olarak, model kötüleşen piyasa koşullarında dahi iyi kazanç-

lar elde etmeyi başarmaktadır. CNN-TA modeli, en çok işlem gören ETF'ler içinden 9 ETF'in 8'inde "Al&Tut" stratejisinden daha iyi bir performans göstermektedir. Benzer durum Dow-30 hisse için de geçerlidir. CNN-TA metodu, 10 yıllık bir süre boyunca 29 hisseden 19'unda "Al&Tut" stratejisinden daha iyi bir performans göstermektedir.

Çizelge 8.18: CNN-TA yönteminin rastgele seçilmiş hisse ve ETF'ler ile testi

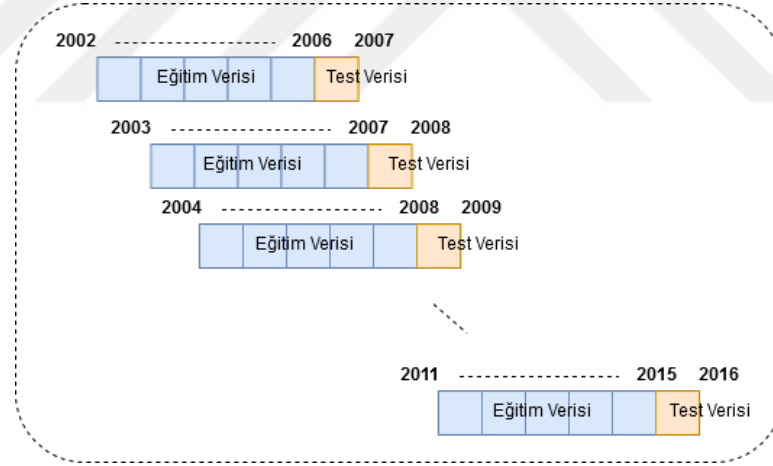
Tarih - Test	EWB	XLP	UNH	VZ	MSFT	MRK
2014 - 1	7.69%	16.77%	22.12%	9.85%	20.87%	18.31%
2014 - 2	4.82%	14.60%	11.89%	11.89%	13.14%	17.28%
2014 - 3	3.77%	13.05%	17.50%	8.79%	15.69%	27.57%
2014 - 4	5.29%	11.44%	8.62%	11.24%	18.37%	19.33%
2014 - 5	6.25%	14.62%	20.70%	9.78%	12.96%	16.13%
2014 - 6	6.39%	12.89%	23.45%	9.28%	18.96%	18.25%
2014 - 7	7.34%	17.23%	22.44%	6.44%	19.04%	20.02%
2014 - 8	3.74%	8.50%	18.84%	13.52%	20.68%	21.37%
2014 - 9	0.16%	9.22%	20.51%	9.58%	17.26%	28.21%
2014 - 10	-0.17%	10.02%	9.70%	10.24%	20.96%	19.43%
2014 - Ortalama	4.53%	12.83%	17.58%	10.06%	17.79%	20.59%
2014 - S.Sapma	2.60%	2.88%	5.23%	1.80%	2.84%	3.90%
2014 - Güven Aralığı	1.61%	1.78%	3.24%	1.12%	1.76%	2.42%
2015 - 1	8.73%	13.84%	18.59%	8.85%	28.50%	6.70%
2015 - 2	11.19%	12.10%	11.30%	5.09%	31.09%	3.90%
2015 - 3	11.65%	14.18%	18.98%	2.11%	27.02%	9.03%
2015 - 4	10.33%	9.31%	18.24%	6.72%	30.23%	4.65%
2015 - 5	8.80%	10.44%	23.32%	7.60%	32.50%	11.43%
2015 - 6	11.99%	10.13%	16.05%	3.12%	28.48%	5.31%
2015 - 7	10.00%	14.05%	13.92%	5.63%	26.28%	4.30%
2015 - 8	10.96%	11.59%	22.15%	6.99%	34.80%	3.94%
2015 - 9	8.57%	12.36%	17.40%	4.33%	34.00%	9.48%
2015 - 10	11.86%	13.07%	22.07%	4.14%	30.53%	6.67%
2015 - Ortalama	10.41%	12.11%	18.20%	5.46%	30.34%	6.54%
2015 - S.Sapma	1.27%	1.64%	3.59%	2.00%	2.70%	2.50%
2015 - Güven Aralığı	0.78%	1.02%	2.22%	1.24%	1.67%	1.55%
2016 - 1	14.57%	3.57%	17.97%	6.44%	27.91%	30.99%
2016 - 2	15.74%	3.77%	22.18%	5.88%	23.78%	27.54%
2016 - 3	15.35%	4.81%	16.52%	9.43%	30.35%	28.29%
2016 - 4	14.84%	3.41%	18.85%	4.75%	22.78%	29.91%
2016 - 5	15.30%	3.58%	20.56%	2.97%	27.50%	31.11%
2016 - 6	22.02%	3.00%	21.53%	5.65%	27.08%	32.22%
2016 - 7	16.72%	2.18%	23.97%	1.64%	33.40%	30.20%
2016 - 8	18.34%	2.98%	21.14%	3.25%	25.95%	28.29%
2016 - 9	22.33%	1.26%	23.55%	4.20%	19.10%	34.23%
2016 - 10	21.17%	0.83%	20.48%	7.27%	27.01%	28.24%
2016 - Ortalama	17.64%	2.94%	20.68%	5.15%	26.49%	30.10%
2016 - S.Sapma	2.94%	1.14%	2.24%	2.17%	3.77%	2.00%
2016 - Güven Aralığı	1.82%	0.71%	1.39%	1.34%	2.34%	1.24%

CNN-TA yöntemi rastgele seçilmiş olan hisse ve ETF ler ile aynı dönemdeki verilerle 10'ar defa test edilerek elde edilen sonuçların ortalamaları ve standart sapmaları hesaplanmıştır. Çizelge 8.18'de testlerin sonuçları, ortalama, standart sapma, güven aralığı (confidence interval-%95) değerleri gösterilmektedir. Standart sapma değerleri minimum 1.14% olurken, maksimum değer 5.23% olmuştur. Standart sapma ve güven aralığı hesaplamaları göz önüne alındığında CNN-TA modelinin istikrarlı sonuç verdiği gözlemlenmektedir. Diğer hisselerle de benzer sonuçlara ulaşılabileceği varsayılmaktadır.



### 8.3.8 CNN-TA zaman kaydırmalı yönteminin değerlendirilmesi

CNN-TA yönteminin performansının daha iyi ölçülmesi için, zaman içerisinde kaydırmalı olarak eğitilip, daha sonrasında testler uygulanmıştır. Uygulanan yöntemde beş yıllık veriler eğitim için kullanılırken, daha sonrasında gelen bir yıllık veriler test için kullanılmıştır (Şekil 8.7) (Ör; Eğitim Verisi: 1/1/2010-31/12/2014, Test Verisi: 1/1/2015-31/12/2015). Daha önce seçilmiş ETF'lere 2003-2016 yılları arasında zaman kaydırmalı CNN yöntemi uygulanmıştır ve Çizelge 8.19'de sonuçları gösterilmektedir. Ayrıca, Çizelge 8.20'de de gösterildiği gibi CNN-TA yönteminin, "Al&Tut", LSTM ve MLP regresyon yöntemleri ile kıyaslanmıştır. CNN-TA yönteminin 2007-2017 yılları arasındaki ortalama yıllık getirisi 13.01% iken, "Al&Tut" modelinin 2007-2017 yılları arasındaki ortalama yıllık getirisi 4.63%, LSTM yönteminin 2007-2017 yılları arasındaki ortalama yıllık getirisi 6.22%, MLP regresyon (literatürde önerilen) yönteminin 2007-2017 yılları arasındaki ortalama yıllık getirisi 4.01%'dir. Ayrıca, CNN-TA yönteminin 2007-2012 yılları arasındaki ortalama yıllık getirisi 13.17% iken, "Al&Tut" modelinin 2007-2012 yılları arasındaki ortalama yıllık getirisi 2.60%, LSTM yönteminin 2007-2012 yılları arasındaki ortalama yıllık getirisi 8.44%, MLP regresyon (literatürde önerilen) yönteminin 2007-2012 yılları arasındaki ortalama yıllık getirisi 8.23%'dir.



Şekil 8.7: CNN-TA zaman kaydırmalı eğitim ve test yaklaşımı

Ayrıca, önerilen zaman kaydırmalı CNN-TA yöntemi, Dow30 hisse senedi verilerine de uygulanmıştır. Çizelge 8.21'de sonuçları gösterilmektedir. Ayrıca, Çizelge 8.22'de de gösterildiği gibi CNN-TA yöntemi, "Al&Tut", LSTM ve MLP regresyon yöntemleri ile kıyaslanmıştır. CNN-TA yönteminin 2007-2017 yılları arasındaki ortalama yıllık getirisi 12.59% iken, "Al&Tut" modelinin 2007-2017 yılları arasındaki ortalama yıllık getirisi 10.47%, LSTM yönteminin 2007-2017 yılları arasındaki ortalama yıllık getirisi 6.48%, MLP regresyon (literatürde önerilen) yönteminin 2007-2017 yılları arasındaki ortalama yıllık getirisi 5.45%'dir. Ayrıca, CNN-TA yönteminin 2007-2012 yılları ara-

sındaki ortalama yıllık getirisi 12.83% iken, "Al&Tut" modelinin 2007-2012 yılları arasındaki ortalama yıllık getirisi 6.98%, LSTM yönteminin 2007-2012 yılları arasındaki ortalama yıllık getirisi 10.82%, MLP regresyon (literatürde önerilen) yönteminin 2007-2012 yılları arasındaki ortalama yıllık getirisi 9.98%'dir. Elde edilen sonuçlar şu ana kadar literatürdeki sonuçlarla karşılaştırıldığında daha başarılı olduğu söylenebilir. Geliştirilen tüm modellerin kendi aralarında ve literatürde bazı modeller ile gerçekleştirilen karşılaştırmalı analizi bir sonraki bölümde detaylı bir şekilde gösterilmiştir.

Çizelge 8.19: 5 yıl eğitim, 1 yıl test ile CNN-TA yönteminin değerlendirilmesi (ETF)

ETF	2003	2004	2005	2006	2007	2008	2009	2010	2011	2012	2013	2014	2015	2016
SPY	18.45%	1.72%	3.57%	10.72%	5.74%	-11.01%	29.11%	6.82%	15.90%	8.92%	11.34%	13.21%	8.86%	18.80%
QQQ	10.28%	-0.52%	5.53%	1.83%	15.52%	-7.06%	19.54%	5.59%	12.42%	6.51%	15.81%	21.60%	13.36%	12.36%
XLU	-6.15%	8.89%	21.12%	9.84%	16.47%	22.58%	-4.30%	12.53%	20.77%	6.50%	4.51%	16.75%	-1.50%	6.94%
XLE	15.74%	17.88%	22.47%	11.95%	31.19%	76.20%	30.42%	12.38%	-13.78%	4.03%	19.84%	-11.71%	-7.10%	16.55%
XLP	7.14%	7.41%	11.97%	13.54%	14.20%	19.44%	14.48%	4.30%	15.21%	7.91%	2.85%	16.66%	13.61%	2.30%
XLY	24.14%	0.67%	-0.97%	5.13%	-1.16%	-16.99%	18.12%	4.54%	7.08%	20.98%	14.22%	1.71%	22.28%	24.74%
EWZ	21.31%	10.84%	38.56%	8.80%	84.94%	2.68%	55.99%	15.48%	-8.43%	-0.24%	-8.31%	-0.09%	-29.77%	91.73%
EWJ	37.86%	4.11%	6.77%	6.64%	42.69%	-8.36%	28.09%	4.12%	-5.87%	13.22%	6.81%	2.97%	12.54%	20.70%
XLF	20.75%	3.52%	6.03%	13.63%	12.95%	-8.63%	23.01%	11.79%	2.83%	14.07%	14.30%	15.78%	12.99%	61.43%
<b>Ortalama</b>	<b>16.61%</b>	<b>6.06%</b>	<b>12.78%</b>	<b>9.12%</b>	<b>24.73%</b>	<b>7.65%</b>	<b>23.83%</b>	<b>8.62%</b>	<b>5.13%</b>	<b>9.10%</b>	<b>9.04%</b>	<b>8.54%</b>	<b>5.03%</b>	<b>28.39%</b>

Çizelge 8.20: CNN-TA zaman kaydırmalı yöntemin diğer yöntemlerle kıyaslanması (ETF)

ETF	CNN-TA Kay.(07-17)	CNN-TA Kay.(07-12)	BaH (07-17)	BaH (07-12)	LSTM (07-17)[20]	LSTM (07-12)[20]	MLP (07-17)[20]	MLP (07-12)[20]
SPY	10.77%	9.25%	4.63%	-0.39%	3.35%	11.05%	7.27%	10.62%
QQQ	11.57%	8.75%	10.52%	5.73%	-1.33%	5.38%	3.92%	2.85%
XLU	10.13%	12.43%	2.97%	3.72%	1.29%	6.89%	1.12%	3.78%
XLE	15.80%	23.41%	2.85%	5.61%	4.01%	3.76%	5.41%	12.93%
XLP	11.10%	12.59%	6.92%	6.97%	5.97%	1.20%	0.84%	4.37%
XLY	9.55%	5.43%	7.68%	1.65%	2.13%	3.88%	1.31%	7.41%
EWZ	20.40%	25.07%	-3.38%	7.64%	-1.30%	1.69%	5.42%	3.54%
EWJ	11.69%	12.32%	1.73%	1.75%	12.30%	26.07%	6.11%	17.64%
XLF	16.05%	9.34%	2.31%	-16.91%	16.18%	6.39%	2.68%	7.02%
<b>Ortalama</b>	<b>13.01%</b>	<b>13.17%</b>	<b>4.63%</b>	<b>2.60%</b>	<b>6.22%</b>	<b>8.44%</b>	<b>4.01%</b>	<b>8.23%</b>

Çizelge 8.21: 5 yıl eğitim, 1 yıl test ile CNN-TA yönteminin değerlendirilmesi (Dow30)

Hisse	2003	2004	2005	2006	2007	2008	2009	2010	2011	2012	2013	2014	2015	2016
MMM	14.25%	-8.09%	8.48%	2.74%	-0.88%	-9.84%	27.97%	22.17%	34.39%	6.73%	17.57%	10.69%	-4.90%	4.94%
AXP	21.82%	-3.81%	13.09%	17.46%	15.00%	43.23%	93.22%	22.00%	-2.81%	19.18%	22.47%	3.91%	3.29%	30.98%
APPL	21.73%	34.09%	28.22%	5.83%	50.90%	-40.49%	29.89%	13.28%	17.89%	-11.29%	15.61%	22.54%	11.88%	3.52%
BA	15.12%	-2.21%	24.54%	24.17%	0.24%	2.86%	-13.50%	-1.66%	11.18%	17.26%	24.24%	-6.27%	12.48%	23.49%
CAT	34.95%	15.20%	20.72%	27.87%	15.96%	-9.98%	10.95%	11.81%	-12.18%	-15.23%	-2.36%	-2.20%	11.03%	35.51%
CVX	26.38%	37.18%	7.14%	8.61%	33.52%	56.03%	-2.69%	15.46%	17.33%	-1.05%	-2.42%	1.50%	3.08%	28.35%
CSCO	59.72%	-18.92%	2.12%	47.10%	9.34%	18.58%	32.93%	-7.70%	8.23%	-11.36%	12.44%	10.75%	1.35%	25.66%
KO	3.21%	-12.80%	2.21%	7.71%	13.53%	2.16%	26.19%	15.29%	25.72%	2.02%	7.43%	1.52%	2.74%	14.70%
DIS	49.78%	-14.07%	-8.90%	23.62%	26.29%	-18.63%	23.83%	17.80%	-1.76%	32.45%	19.78%	21.52%	14.14%	4.27%
XOM	2.10%	29.38%	6.01%	22.50%	36.33%	35.29%	2.08%	25.71%	-1.31%	15.43%	2.24%	4.02%	15.89%	9.40%
GE	16.32%	7.69%	9.36%	12.66%	17.88%	-3.55%	4.27%	2.35%	16.03%	5.69%	12.61%	13.57%	18.29%	16.33%
GS	14.84%	-3.90%	5.43%	2.72%	5.35%	-19.64%	20.95%	13.72%	-16.83%	5.24%	7.65%	3.72%	5.65%	35.97%
HD	35.37%	10.77%	0.19%	-0.50%	-23.04%	19.95%	10.46%	17.33%	17.63%	29.72%	13.06%	14.19%	40.16%	12.56%
IBM	38.28%	-1.28%	-11.12%	12.59%	4.41%	-5.28%	22.11%	10.08%	30.29%	8.05%	0.65%	-9.94%	-1.74%	22.87%
INTC	57.70%	6.97%	7.15%	11.33%	33.86%	38.39%	36.29%	-10.03%	9.28%	3.57%	22.84%	11.44%	17.39%	19.24%
JNJ	18.87%	7.26%	6.11%	12.04%	-6.93%	66.72%	1.25%	8.94%	15.52%	14.25%	0.87%	5.02%	22.70%	6.13%
JPM	19.77%	1.61%	9.90%	7.59%	2.02%	5.18%	25.08%	5.44%	1.94%	15.50%	10.15%	4.09%	20.53%	38.00%
MCD	15.68%	9.11%	4.90%	34.49%	29.18%	45.86%	18.99%	16.17%	18.19%	2.75%	3.80%	3.29%	37.28%	3.92%
MRK	-10.83%	-7.54%	11.41%	30.10%	17.60%	41.65%	-6.80%	7.11%	5.53%	13.78%	16.72%	22.27%	8.70%	32.76%
MSFT	9.88%	19.31%	4.57%	-6.45%	3.76%	9.58%	36.96%	-19.71%	-11.08%	7.11%	34.02%	15.87%	33.68%	24.09%
NKE	33.02%	3.01%	5.32%	9.21%	28.42%	4.00%	28.48%	21.97%	21.75%	10.10%	28.35%	25.17%	28.90%	-17.14%
PFE	11.60%	2.86%	-2.34%	10.05%	6.85%	13.11%	8.52%	-3.62%	19.75%	6.74%	2.26%	3.58%	20.53%	2.98%
PG	5.11%	8.38%	5.96%	6.61%	13.71%	10.58%	18.47%	15.08%	-0.44%	5.42%	11.24%	12.11%	-8.80%	20.52%
TRV	14.01%	-3.02%	10.36%	-3.64%	27.95%	60.27%	14.28%	7.71%	7.02%	20.81%	10.77%	7.73%	8.38%	8.44%
UTX	17.67%	7.87%	25.31%	8.32%	7.85%	14.48%	25.37%	1.01%	10.45%	4.72%	7.61%	-4.00%	-1.77%	27.89%
UNH	30.35%	17.58%	24.20%	-14.26%	8.99%	-57.04%	8.45%	8.30%	27.37%	18.20%	29.88%	12.35%	19.68%	21.26%
VZ	19.90%	4.08%	2.04%	1.30%	15.04%	59.49%	1.78%	-3.64%	9.06%	5.62%	-3.25%	8.78%	4.97%	4.40%
WMT	20.84%	1.26%	0.23%	5.83%	30.03%	33.34%	28.88%	19.49%	6.08%	13.10%	1.12%	9.14%	-5.67%	16.51%
<b>Ortalama</b>	<b>22.05%</b>	<b>5.28%</b>	<b>7.95%</b>	<b>11.70%</b>	<b>15.11%</b>	<b>14.87%</b>	<b>19.10%</b>	<b>9.00%</b>	<b>10.15%</b>	<b>8.73%</b>	<b>11.69%</b>	<b>8.08%</b>	<b>12.14%</b>	<b>17.06%</b>

Çizelge 8.22: CNN-TA zaman kaydırmalı yöntemin diğer yöntemlerle kıyaslanması (Dow30)

Hisse	CNN-TA Kay.(07-17)	CNN-TA Kay.(07-12)	BaH (07-17)	BaH (07-12)	LSTM (07-17)[20]	LSTM (07-12)[20]	MLP (07-17)[20]	MLP (07-12)[20]
MMM	10.88%	<b>13.42%</b>	11.36%	3.52%	6.43%	15.26%	2.28%	3.24%
AXP	25.05%	<b>31.64%</b>	4.25%	-2.21%	7.23%	27.47%	9.56%	24.68%
APPL	11.37%	10.03%	26.42%	<b>36.54%</b>	5.03%	20.92%	2.57%	0.49%
BA	7.03%	2.73%	8.60%	-0.56%	4.01%	<b>13.53%</b>	2.59%	3.94%
CAT	4.33%	0.22%	7.19%	<b>10.97%</b>	-1.53%	4.75%	0.66%	4.56%
CVX	14.91%	<b>19.77%</b>	8.67%	11.87%	7.63%	16.31%	5.76%	14.09%
CSCO	10.02%	8.34%	2.76%	-7.05%	9.05%	0.80%	9.15%	<b>20.82%</b>
KO	11.13%	<b>14.15%</b>	8.85%	11.13%	3.70%	5.83%	2.71%	8.25%
DIS	<b>13.97%</b>	13.33%	13.14%	3.55%	4.67%	8.47%	5.36%	3.11%
XOM	14.51%	<b>18.92%</b>	4.78%	5.12%	6.67%	3.66%	3.46%	9.15%
GE	<b>10.35%</b>	7.11%	2.17%	-9.62%	4.74%	3.73%	5.74%	3.20%
GS	6.18%	1.47%	2.35%	-15.00%	5.24%	-11.25%	<b>11.62%</b>	6.41%
HD	15.20%	12.01%	<b>15.91%</b>	4.32%	6.27%	5.23%	2.12%	6.21%
IBM	8.15%	11.61%	7.77%	<b>15.52%</b>	0.91%	1.34%	-1.52%	-1.14%
INTC	18.23%	<b>18.56%</b>	8.99%	6.42%	6.18%	7.82%	4.71%	15.83%
JNJ	13.45%	<b>16.63%</b>	9.01%	3.03%	3.76%	7.52%	0.42%	2.63%
JPM	12.79%	9.19%	8.25%	-5.84%	15.72%	<b>33.74%</b>	16.27%	29.12%
MCD	17.94%	<b>21.86%</b>	14.43%	22.14%	4.09%	-2.18%	0.24%	2.45%
MRK	<b>15.93%</b>	13.15%	6.55%	0.33%	2.88%	6.95%	5.46%	11.71%
MSFT	13.43%	4.44%	9.95%	-1.24%	5.29%	12.58%	4.45%	<b>16.02%</b>
NKE	18.00%	<b>19.12%</b>	17.10%	16.93%	1.54%	11.80%	4.68%	6.30%
PFE	8.07%	<b>8.56%</b>	6.51%	0.99%	7.07%	2.92%	1.34%	7.97%
PG	9.79%	10.47%	5.72%	3.26%	4.99%	<b>12.92%</b>	3.93%	1.12%
TRV	17.34%	<b>23.01%</b>	12.01%	5.91%	19.98%	21.79%	10.97%	15.03%
UTX	9.36%	<b>10.65%</b>	7.67%	4.37%	6.52%	5.41%	1.65%	3.40%
UNH	9.74%	2.38%	<b>13.21%</b>	0.22%	-1.01%	-8.37%	2.13%	-0.09%
VZ	10.23%	14.56%	9.29%	7.95%	4.49%	13.46%	5.63%	<b>16.30%</b>
WMT	15.20%	<b>21.82%</b>	6.28%	6.89%	5.30%	12.91%	8.33%	13.09%
Ortalama	12.59%	<b>12.83%</b>	10.47%	6.98%	6.48%	10.82%	5.45%	9.98%



## 9. GENEL DEĞERLENDİRME

Bu tez kapsamında yapılan çalışmalar ile finansal zaman serisi verilerde, finansal tahmin yapabilen, maksimum oranda kar elde etmeyi amaçlayan, stabil kararlar almayı hedefleyen, literatürden farklı olarak teknik analiz veriler ile yapay ve derin sinir ağlarını kullanabilen yöntemler geliştirilmiştir. Bu kapsamda, dört öneri yapılmıştır. Önerilen metotlar:

- Teknik Analiz Verileri Kullanarak Yapay Sinir Ağı ile Finansal Analiz Yöntemi (MLP-TA)
- Genetik Algoritma ile Optimize Edilmiş Teknik Analiz Parametrelerinin Kullanılarak Derin Çoklu Algılayıcı Sinir Ağı Modeli ile Finansal Analiz Yöntemi (DMLP-GA ve GA)
- Finansal Zaman Serisi Verilerinin İki Boyutlu Grafik Görüntüsüne Dönüştürülerek Derin Konvolüsyonel Sinir Ağları ile Finansal Analiz Yöntemi (CNN-BI)
- Finansal Zaman Serisi Verilerinin, Teknik Analiz Verileri Kullanılarak Görüntü Verisine Dönüştürülmesi ve Görüntülerin Derin Konvolüsyonel Sinir Ağları ile Finansal Analiz Yöntemi (CNN-TA)


### 9.1 Önerilen Tüm Yöntemlerin Değerlendirmesi

Önerilen tüm yöntemler birbirleriyle ve "Al&Tut", RSI ve SMA modelleri ile, LSTM ve MLP regresyon yöntemleri ile karşılaştırılmıştır. Çizelge 9.1'de önerilen yöntemlerin 2007-2017 yılları arasındaki yıllık kazançlarının kıyaslanması gösterilmektedir. Önerilen modellerin Dow-30 hisseleriyle 2007-2017 yılları arasındaki ortalama yıllık getirileri şu şekilde özetlenebilir; CNN-TA modelinin zaman kaydırmalı olarak (5 yıl eğitim, 1 yıl test olarak) uygulanmasının ortalama yıllık getirisi 12.59%, CNN-TA modelinin ortalama yıllık getirisi 11.47%, genetik algoritmayla iyileştirilmiş teknik verilerin derin çoklu algılayıcı (DMLP-GA) ile tahmin modelinin ortalama yıllık getirisi 8.51%, sadece genetik algoritma ile iyileştirilmiş teknik analiz verisinin (GA) modelinin ortalama yıllık getirisi 11.39%, önerdiğimiz çoklu algılayıcı (MLP-TA) modelinin ortalama yıllık getirisi 9.42%, "Al&Tut" modelinin ortalama yıllık ge-

tirisi 10.54%, RSI modelinin ortalama yıllık getirisi 5.01%, SMA modelinin ortalama yıllık getirisi 3.78%, LSTM yönteminin ortalama getirisi 6.48% ve MLP regresyon (literatürde önerilen) yönteminin ortalama yıllık getirisi 5.45%'dir. Önerilen CNN-TA ve GA modellerinin performanslarının, "Al&Tut" modellinden, LSTM ve MLP regresyon (literatürde önerilen) yöntemlerinden ortalama olarak daha iyi olduğu gözlemlenmiştir. Tüm önerilen modeller ayrıca RSI ve SMA modellerinden daha iyi performans göstermektedir. Önerilen tüm yöntemlerin Dow-30 hisseleriyle 2007-2017 yılları arasındaki yıllık ortalama getiri oranları Şekil 9.1'de gösterilmektedir.

Çizelge 9.1: Önerilen tüm yöntemlerin yıllık kazançlarının kıyaslanması (2007-2017)

Hisse	CNN-TA Kayd.	CNN-TA	DMLP-GA	GA	MLP-TA	BaH	RSI	SMA	LSTM[20]	MLP[20]
MMM	10.88%	<b>11.49%</b>	5.50%	8.27%	4.15%	11.36%	4.64%	2.25%	6.43%	2.28%
AXP	<b>25.05%</b>	10.73%	3.35%	5.97%	6.13%	4.25%	-0.85%	-0.96%	7.23%	9.56%
APPL	11.37%	9.60%	14.24%	24.77%	4.00%	<b>26.42%</b>	10.11%	19.55%	5.03%	2.57%
BA	7.03%	8.72%	8.94%	<b>12.77%</b>	4.08%	8.60%	2.30%	2.07%	4.01%	2.59%
CAT	4.33%	3.43%	6.85%	7.44%	0.69%	7.72%	-3.02%	<b>10.72%</b>	-1.53%	0.66%
CVX	<b>14.91%</b>	7.92%	12.18%	6.80%	6.04%	8.67%	4.60%	1.07%	7.63%	5.76%
CSCO	10.02%	<b>10.44%</b>	7.66%	9.90%	10.97%	2.76%	5.57%	-5.28%	9.05%	9.15%
KO	11.13%	<b>12.77%</b>	10.43%	6.81%	9.06%	8.85%	7.78%	3.09%	3.70%	2.71%
DIS	<b>13.97%</b>	8.40%	11.60%	8.42%	16.18%	13.14%	0.96%	6.36%	4.67%	5.36%
XOM	14.51%	<b>15.92%</b>	4.35%	8.54%	10.19%	8.30%	4.81%	-2.34%	6.67%	3.46%
GE	<b>10.35%</b>	4.99%	8.33%	9.90%	1.05%	4.78%	-7.35%	3.92%	4.74%	5.74%
GS	6.18%	5.98%	6.78%	<b>11.78%</b>	7.25%	2.17%	-4.92%	2.83%	5.24%	11.62%
HD	<b>15.20%</b>	8.24%	4.87%	4.00%	10.48%	2.04%	7.07%	5.34%	6.27%	2.12%
IBM	8.15%	5.08%	6.81%	18.87%	7.60%	<b>15.91%</b>	5.35%	2.37%	0.91%	-1.52%
INTC	<b>18.23%</b>	14.00%	12.03%	11.54%	10.18%	7.77%	5.18%	5.90%	6.18%	4.71%
JNJ	<b>13.45%</b>	7.50%	5.97%	12.57%	5.40%	8.99%	7.53%	1.81%	3.76%	0.42%
JPM	12.79%	<b>27.94%</b>	6.95%	8.41%	12.92%	9.01%	8.66%	-4.77%	15.72%	16.27%
MCD	<b>17.94%</b>	11.62%	6.13%	13.21%	5.28%	8.25%	8.37%	2.04%	4.09%	0.24%
MRK	<b>15.93%</b>	11.70%	9.72%	13.51%	12.91%	14.43%	3.60%	0.91%	2.88%	5.46%
MSFT	13.43%	12.47%	8.90%	9.10%	<b>17.82%</b>	6.55%	7.07%	5.58%	5.29%	4.45%
NKE	<b>18.00%</b>	14.89%	12.79%	12.57%	17.47%	9.95%	9.34%	0.58%	1.54%	4.68%
PFE	8.07%	7.35%	14.96%	12.65%	5.22%	<b>17.10%</b>	-0.35%	1.83%	7.07%	1.34%
PG	<b>9.79%</b>	5.73%	8.79%	9.34%	7.66%	6.60%	3.31%	0.88%	4.99%	3.93%
TRV	17.34%	<b>20.46%</b>	5.27%	5.14%	19.27%	5.72%	6.24%	-7.62%	19.98%	10.97%
UTX	9.36%	8.13%	8.26%	<b>10.37%</b>	4.67%	12.01%	2.76%	3.18%	6.52%	1.65%
UNH	9.74%	4.93%	3.72%	<b>11.11%</b>	2.37%	7.67%	7.31%	9.50%	-1.01%	2.13%
VZ	10.23%	8.37%	6.79%	<b>14.84%</b>	3.86%	13.17%	9.37%	0.28%	4.49%	5.63%
WMT	<b>15.20%</b>	6.81%	4.45%	7.68%	12.25%	9.29%	5.22%	-2.88%	5.30%	8.33%
Ortalama	<b>12.59%</b>	11.47%	8.51%	11.39%	9.42%	10.54%	5.01%	3.78%	6.48%	5.45%
S.Sapma	4.45%	5.17%	<b>3.17%</b>	4.25%	5.03%	5.08%	4.38%	5.28%	4.26%	3.99%



Şekil 9.1: Dow30 2007-2017 ortalama yıllık getiri - yöntem grafiği

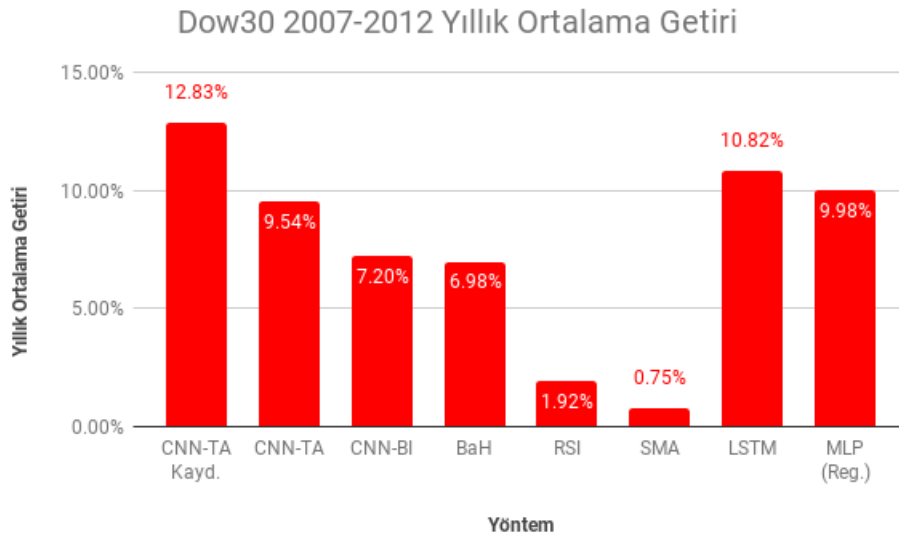
Çizelge 9.2: Önerilen tüm yöntemlerin toplam sermaye kıyaslanması (2007-2017)

Hisse	CNN-TA	DMLP-GA	GA	MLP-TA	BaH	RSI	SMA	LSTM[20]	MLP[20]
MMM	\$29,661.39	\$17,085.05	\$22,136.47	\$15,234.16	\$29,324.88	\$15,738.61	\$12,495.92	\$18,649.18	\$12,534.43
AXP	\$27,720.98	\$13,908.78	\$17,849.60	\$14,727.15	\$15,157.78	\$9,184.33	\$9,076.55	\$20,096.20	\$24,923.76
APPL	\$25,015.36	\$37,852.92	\$91,402.33	\$14,742.93	\$104,256.20	\$26,188.52	\$59,639.43	\$16,340.82	\$12,882.29
BA	\$23,063.36	\$23,533.31	\$33,257.97	\$17,010.05	\$22,809.31	\$12,552.96	\$12,277.65	\$14,821.54	\$12,914.35
CAT	\$14,005.45	\$19,394.75	\$20,488.00	\$10,252.42	\$21,030.51	\$7,358.97	\$27,696.31	\$8,572.18	\$10,675.91
CVX	\$21,435.73	\$31,565.85	\$19,312.81	\$17,907.21	\$22,968.13	\$15,672.01	\$11,121.03	\$20,863.59	\$17,500.35
CSCO	\$26,997.92	\$20,922.80	\$25,693.83	\$21,182.93	\$13,126.52	\$17,200.28	\$5,813.56	\$23,777.76	\$24,008.09
KO	\$33,256.00	\$26,958.24	\$19,330.74	\$17,258.98	\$23,354.41	\$21,145.34	\$13,551.51	\$14,386.45	\$13,068.56
DIS	\$22,406.60	\$29,958.82	\$22,435.75	\$28,859.03	\$34,368.91	\$10,999.14	\$18,524.60	\$15,790.96	\$16,861.57
XOM	\$43,812.44	\$15,304.38	\$22,700.53	\$17,750.91	\$22,197.39	\$15,996.92	\$7,892.89	\$19,067.38	\$14,055.06
GE	\$16,275.45	\$22,259.96	\$25,710.99	\$18,385.49	\$15,946.05	\$4,659.37	\$14,693.50	\$15,887.46	\$17,481.97
GS	\$17,871.14	\$19,261.81	\$30,446.40	\$12,663.52	\$12,399.64	\$6,036.53	\$13,213.57	\$16,672.30	\$30,017.96
HD	\$22,081.72	\$16,090.00	\$14,806.92	\$14,230.22	\$12,238.97	\$19,808.24	\$16,824.76	\$18,372.69	\$12,335.55
IBM	\$16,417.62	\$19,323.00	\$56,318.78	\$15,088.71	\$43,768.70	\$16,839.63	\$12,645.37	\$10,951.53	\$8,576.67
INTC	\$37,074.54	\$31,134.92	\$29,817.61	\$17,151.82	\$21,143.52	\$16,576.08	\$17,742.69	\$18,212.64	\$15,840.55
JNJ	\$20,612.37	\$17,854.00	\$32,661.97	\$27,965.75	\$23,656.29	\$20,666.97	\$11,964.91	\$14,460.00	\$10,428.55
JPM	\$117,462.09	\$19,588.34	\$22,428.83	\$19,043.10	\$23,687.77	\$22,942.07	\$6,130.76	\$43,048.07	\$45,157.07
MCD	\$30,024.99	\$18,136.83	\$34,587.38	\$49,181.78	\$22,092.57	\$22,339.34	\$12,239.25	\$14,932.11	\$10,239.87
MRK	\$30,233.72	\$25,295.64	\$35,502.32	\$17,519.35	\$38,489.77	\$14,249.12	\$10,950.68	\$13,281.94	\$17,021.21
MSFT	\$32,387.89	\$23,467.98	\$23,901.33	\$29,081.32	\$18,865.70	\$19,804.70	\$17,207.44	\$16,744.16	\$15,449.97
NKE	\$40,070.47	\$33,313.59	\$32,670.76	\$37,923.78	\$25,820.00	\$24,411.78	\$10,591.00	\$11,654.47	\$15,802.58
PFE	\$20,315.90	\$40,307.46	\$32,914.74	\$22,940.48	\$48,496.06	\$9,659.66	\$11,986.56	\$19,796.16	\$11,427.59
PG	\$17,450.07	\$23,219.50	\$24,422.03	\$11,094.86	\$18,953.47	\$13,846.43	\$10,919.47	\$16,272.69	\$14,707.07
TRV	\$64,343.49	\$16,713.78	\$16,512.78	\$20,278.23	\$17,434.55	\$18,314.80	\$4,528.97	\$61,819.78	\$28,327.02
UTX	\$21,852.57	\$22,120.65	\$26,815.77	\$64,371.78	\$31,098.53	\$13,133.92	\$13,681.38	\$18,804.62	\$11,780.28
UNH	\$16,183.84	\$14,407.36	\$28,678.10	\$18,540.16	\$20,932.55	\$20,242.05	\$24,792.91	\$9,032.76	\$12,341.19
VZ	\$22,343.95	\$19,295.40	\$39,884.30	\$9,343.90	\$34,464.65	\$24,497.50	\$10,286.78	\$15,516.30	\$17,291.27
WMT	\$19,322.03	\$15,455.29	\$20,960.35	\$12,147.37	\$24,315.17	\$16,629.06	\$7,465.02	\$16,766.05	\$22,256.72
Ortalama	\$29,632.11	\$22,633.23	\$29,416.05	\$21,138.48	\$27,228.50	\$16,310.51	\$14,498.37	\$18,735.42	\$16,996.70
S.Sapma	\$20,193.50	\$7,067.74	\$14,836.59	\$12,056.44	\$17,548.55	\$5,702.82	\$10,234.22	\$10,429.21	\$7,747.05

Çizelge 9.2’de önerilen yöntemlerin 2007-2017 yılları arasındaki toplam sermaye kıyaslanması gösterilmektedir. Önerilen modellerin Dow-30 hisseleriyle 2007-2017 yılları arasındaki toplam sermayeleri şu şekilde özetlenebilir; CNN-TA modelinin toplam sermayesi ortalama \$29632.11, genetik algoritmayla ile iyileştirilmiş teknik verilerin derin çoklu algılayıcı (DMLP-GA) ile tahmin modelinin toplam sermayesi ortalama \$22633.23, sadece genetik algoritma ile iyileştirilmiş teknik analiz verisinin (GA) modelinin toplam sermayesi ortalama \$29416.05, çoklu algılayıcı (MLP-TA) modelinin toplam sermayesi ortalama \$21138.48, "Al&Tut" (BaH) modelinin toplam sermayesi ortalama \$27228.50, RSI modelinin toplam sermayesi ortalama \$16310.51, SMA modelinin toplam sermayesi ortalama \$14498.37, LSTM yönteminin toplam sermayesi ortalama \$18735.42 ve MLP regresyon yönteminin toplam sermayesi ortalama \$16996.70’dir.

Çizelge 9.3: Önerilen tüm yöntemlerin yıllık kazançlarının kıyaslanması (2007-2012)

Hisse	CNN-TA Kayd.	CNN-TA	CNN-BI	BaH	RSI	SMA	LSTM[20]	MLP[20]
MMM	13.42%	5.06%	7.98%	3.52%	-1.58%	-6.63%	<b>15.26%</b>	3.24%
AXP	<b>31.64%</b>	17.23%	-1.80%	-2.21%	-11.33%	-5.65%	27.47%	24.68%
APPL	10.03%	7.24%	<b>37.46%</b>	36.54%	7.54%	32.73%	20.92%	0.49%
BA	2.73%	-0.39%	-1.62%	-0.56%	0.30%	1.82%	<b>13.53%</b>	3.94%
CAT	0.22%	-4.58%	-5.64%	10.97%	-8.82%	<b>17.61%</b>	4.75%	4.56%
CVX	<b>19.77%</b>	15.17%	16.79%	11.87%	2.49%	-0.02%	16.31%	14.09%
CSCO	8.34%	7.10%	2.69%	-7.05%	0.13%	-15.38%	0.80%	<b>20.82%</b>
KO	<b>14.15%</b>	13.51%	10.65%	11.13%	4.67%	5.13%	5.83%	8.25%
DIS	<b>13.33%</b>	2.79%	6.26%	3.55%	-1.92%	-4.28%	8.47%	3.11%
XOM	<b>18.92%</b>	9.66%	0.00%	5.12%	4.45%	-5.17%	3.66%	9.15%
GE	<b>7.11%</b>	-12.75%	0.82%	-9.62%	-17.51%	-3.02%	3.73%	3.20%
GS	1.47%	-3.03%	-18.86%	-15.00%	-13.65%	-4.50%	-11.25%	<b>6.41%</b>
HD	<b>12.01%</b>	5.17%	-0.61%	4.32%	2.77%	-7.59%	5.23%	6.21%
IBM	11.61%	7.67%	9.76%	<b>15.52%</b>	4.46%	6.55%	1.34%	-1.14%
INTC	<b>18.56%</b>	12.86%	7.87%	6.42%	4.08%	0.68%	7.82%	15.83%
JNJ	<b>16.63%</b>	8.56%	-0.70%	3.03%	4.81%	-3.09%	7.52%	2.63%
JPM	9.19%	<b>30.02%</b>	20.94%	-5.84%	5.93%	-19.40%	33.74%	29.12%
MCD	21.86%	21.22%	13.34%	<b>22.14%</b>	9.49%	0.91%	-2.18%	2.45%
MRK	<b>13.15%</b>	2.30%	2.93%	0.33%	-3.89%	-1.21%	6.95%	11.71%
MSFT	4.44%	5.37%	-11.45%	-1.24%	-2.50%	0.62%	12.58%	<b>16.02%</b>
NKE	<b>19.12%</b>	14.99%	9.23%	16.93%	12.80%	-6.01%	11.80%	6.30%
PFE	<b>8.56%</b>	11.33%	-0.31%	0.99%	-5.84%	-0.82%	2.92%	7.97%
PG	10.47%	6.55%	-2.81%	3.26%	2.53%	-2.33%	<b>12.92%</b>	1.12%
TRV	<b>23.01%</b>	20.94%	2.45%	5.91%	5.77%	-18.90%	21.79%	15.03%
UTX	10.65%	6.58%	<b>11.53%</b>	4.37%	3.53%	2.39%	5.41%	3.40%
UNH	2.38%	-4.28%	<b>11.06%</b>	0.22%	-1.85%	7.59%	-8.37%	-0.09%
VZ	14.56%	7.45%	12.32%	7.95%	9.59%	-3.16%	13.46%	<b>16.30%</b>
WMT	<b>21.82%</b>	14.11%	1.31%	6.89%	10.37%	-10.88%	12.91%	13.09%
<b>Ortalama</b>	<b>12.83%</b>	9.54%	7.20%	6.98%	1.92%	0.75%	10.82%	9.98%
<b>S.Sapma</b>	7.38%	8.90%	10.56%	10.09%	<b>7.33%</b>	10.21%	9.74%	7.77%



Şekil 9.2: Dow30 2007-2012 ortalama yıllık getiri - yöntem grafiği



Çizelge 9.4: Önerilen tüm yöntemlerin toplam sermaye kıyaslanması (2007-2012)

Hisse	CNN-TA	CNN-BI	BaH	RSI	SMA	LSTM[20]	MLP[20]
MMM	\$12,798.44	\$14,677.55	\$11,888.66	\$9,235.66	\$7,096.84	<b>\$20,345.92</b>	\$11,729.82
AXP	\$22,138.93	\$9,132.83	\$8,943.51	\$5,482.32	\$7,477.11	<b>\$33,659.87</b>	\$30,126.62
APPL	\$14,185.36	<b>\$49,074.25</b>	\$47,450.80	\$14,382.02	\$41,188.98	\$25,849.19	\$10,247.97
BA	\$9,806.99	\$9,217.19	\$9,724.67	\$10,151.55	\$10,941.36	<b>\$18,858.76</b>	\$12,134.23
CAT	\$7,908.68	\$7,480.28	\$16,827.13	\$6,301.61	<b>\$22,506.23</b>	\$12,612.59	\$12,498.18
CVX	\$20,262.68	<b>\$21,727.81</b>	\$17,518.44	\$11,307.00	\$9,990.36	\$21,286.98	\$19,327.05
CSCO	\$14,094.10	\$11,419.68	\$6,939.05	\$10,066.51	\$4,339.33	\$10,406.13	<b>\$25,744.33</b>
KO	<b>\$18,840.50</b>	\$16,589.11	\$16,948.81	\$12,564.34	\$12,839.80	\$13,275.68	\$14,864.74
DIS	\$11,473.60	\$13,549.50	\$11,907.46	\$9,077.48	\$8,035.01	<b>\$15,017.44</b>	\$11,657.07
XOM	<b>\$15,857.48</b>	\$9,999.40	\$12,837.92	\$12,429.67	\$7,667.46	\$11,966.52	\$15,493.71
GE	\$5,056.33	\$10,415.37	\$6,031.12	\$3,820.46	\$8,578.03	<b>\$12,008.42</b>	\$11,707.89
GS	\$8,575.09	\$3,518.10	\$4,437.56	\$4,801.86	\$7,944.55	\$5,507.34	<b>\$13,645.63</b>
HD	\$12,863.96	\$9,696.71	\$12,356.57	\$11,461.36	\$6,739.70	\$12,900.92	<b>\$13,516.03</b>
IBM	\$14,469.14	\$15,928.39	<b>\$20,576.54</b>	\$12,439.42	\$13,734.41	\$10,689.04	\$9,443.76
INTC	\$18,312.09	\$14,606.30	\$13,650.17	\$12,210.66	\$10,344.53	\$14,571.12	<b>\$20,848.47</b>
JNJ	<b>\$15,077.47</b>	\$9,655.38	\$11,612.37	\$12,646.89	\$8,548.53	\$14,369.22	\$11,388.52
JPM	\$37,153.71	\$25,871.19	\$7,403.34	\$13,339.47	\$3,400.61	<b>\$42,790.03</b>	\$35,895.10
MCD	\$26,172.43	\$18,700.61	<b>\$27,177.18</b>	\$15,736.58	\$10,461.10	\$8,955.81	\$11,288.48
MRK	\$11,202.43	\$11,555.51	\$10,168.31	\$8,202.52	\$9,408.96	\$13,993.70	<b>\$17,392.93</b>
MSFT	\$12,991.83	\$5,445.01	\$9,394.58	\$8,809.79	\$10,313.04	\$18,085.36	<b>\$21,023.00</b>
NKE	\$20,103.52	\$15,550.75	<b>\$21,861.39</b>	\$18,262.45	\$7,336.84	\$17,470.30	\$13,573.38
PFE	<b>\$17,102.18</b>	\$9,844.37	\$10,503.06	\$7,403.32	\$9,594.55	\$11,548.34	\$14,676.03
PG	\$13,734.96	\$8,669.59	\$11,741.86	\$11,330.49	\$8,888.68	<b>\$18,360.02</b>	\$10,574.07
TRV	\$25,875.86	\$11,286.49	\$13,324.97	\$13,235.25	\$3,508.34	<b>\$26,790.39</b>	\$20,141.74
UTX	\$13,751.18	<b>\$17,254.59</b>	\$12,386.81	\$11,891.70	\$11,252.19	\$13,017.00	\$11,818.87
UNH	\$8,035.23	<b>\$16,898.48</b>	\$10,109.54	\$9,109.76	\$14,419.23	\$6,458.90	\$9,954.43
VZ	\$14,321.99	\$17,876.97	\$14,656.19	\$15,804.16	\$8,516.92	\$18,800.76	<b>\$21,278.94</b>
WMT	<b>\$19,349.39</b>	\$10,670.31	\$13,955.82	\$16,374.40	\$5,621.17	\$18,348.79	\$18,497.10
Ortalama	\$15,768.41	\$14,153.99	\$14,011.92	\$10,995.67	\$10,381.92	<b>\$16,712.31</b>	\$16,088.86
S.Sapma	\$6,620.58	\$8,422.42	\$8,186.32	<b>\$3,553.91</b>	\$7,098.58	\$7,978.25	\$6,411.05

Çizelge 9.3 ve Çizelge 9.4’de önerilen yöntemlerin 2007-2012 yılları arasındaki toplam sermaye ve ortalama yıllık getirilerinin kıyaslanması gösterilmektedir. 2007-2012 yılları arasında değerlendirme yapılmasıyla önerilen modelin kriz zamanında olan performansının belirlenmesi amaçlanmıştır. Önerilen modellerin Dow-30 hisseleriyle 2007-2012 yılları arasındaki toplam sermaye ve ortalama yıllık getirileri şu şekilde özetlenebilir; CNN-BI modelinin toplam sermayesi ortalama \$14153.99, CNN-BI modelinin ortalama yıllık getirisi 7.20%, CNN-TA modelinin zaman kaydırmalı olarak (5 yıl eğitim, 1 yıl test olarak) uygulanmasının ortalama yıllık getirisi 12.83%, CNN-TA modelinin toplam sermayesi ortalama \$15768.41, CNN-TA modelinin ortalama yıllık getirisi 9.54%, "Al&Tut" modelinin toplam sermayesi ortalama \$14011.92, "Al&Tut" modelinin ortalama yıllık getirisi 6.98%, RSI modelinin toplam sermayesi ortalama \$10995.67, RSI modelinin ortalama yıllık getirisi 1.92%, SMA modelinin toplam sermayesi ortalama \$10381.92, SMA modelinin ortalama yıllık getirisi 0.75%, LSTM yönteminin toplam sermayesi ortalama \$16712.31, LSTM yönteminin ortalama yıllık getirisi 10.82%, MLP regresyon (literatürde önerilen) yönteminin toplam sermayesi ortalama \$16088.86, MLP regresyon (literatürde önerilen) yönteminin ortalama yıllık

getirisi 9.98%'dir. Önerilen tüm yöntemlerin Dow-30 hisseleriyle 2007-2012 yılları arasındaki yıllık ortalama getiri oranları Şekil 9.2'de gösterilmektedir.

Önerilen CNN-TA modelinin performansının, "Al&Tut" modelinin performansının yaklaşık olarak 1.5 katı olduğu gözlemlenmektedir. CNN-TA modelinin zaman kaydırmalı olarak uygulanmasıyla, önerilen yöntemin performansı "Al&Tut" modelinin performansının yaklaşık olarak 2 katı olmaktadır. CNN-TA modelinin zaman kaydırmalı olarak uygulanmasının performansının tüm yöntemlerin performansından daha iyi sonuç verdiği gözlemlenmektedir. Ayrıca, önerilen CNN-BI modeli "Al&Tut" modelinden daha iyi performans göstermektedir. Önerilen CNN-TA ve CNN-BI modelleri, RSI ve SMA modelleriyle karşılaştırıldığında kriz döneminde çok iyi getiri getirdiği gözlemlenmektedir. CNN-TA modelinin zaman kaydırmalı olarak uygulanmasıyla kriz döneminde hiçbir hisse senedinde zarar edilmezken, diğer metotların tümünde bazı hisselerde zarar edilmiştir. Önerilen modelin kriz zamanlarında bile daha stabil çalıştığı bu sonuçlardan söylenebilir.

## 9.2 CNN-TA Zaman Kaydırmalı Yönteminin Değerlendirmesi


Ayrıca, CNN-TA modelinin zaman kaydırmalı olarak uygulanması ETF'ler üzerinde uygulanmış ve diğer yöntemler ile kıyaslanmıştır. Çizelge 9.5'de önerilen CNN-TA modelinin zaman kaydırmalı olarak uygulanmasının diğer yöntemler ile 2007-2017 yılları arasındaki yıllık kazançlarının kıyaslanması gösterilmektedir. CNN-TA yönteminin 2007-2017 yılları arasındaki ortalama yıllık getirisi 13.01% iken, "Al&Tut" modelinin ortalama yıllık getirisi 4.63%, RSI modelinin ortalama yıllık getirisi 3.95%, SMA modelinin ortalama yıllık getirisi 2.81%, LSTM yönteminin [20] ortalama yıllık getirisi 6.22%, MLP regresyon (literatürde önerilen) yönteminin [20] ortalama yıllık getirisi 4.01%'dir. Önerilen tüm yöntemlerin ETF'lerle 2007-2017 yılları arasındaki yıllık ortalama getiri oranları Şekil 9.3'de gösterilmektedir.

Çizelge 9.6'de önerilen CNN-TA modelinin zaman kaydırmalı olarak uygulanmasının diğer yöntemler ile 2007-2012 yılları arasındaki yıllık kazançlarının kıyaslanması gösterilmektedir. CNN-TA yönteminin 2007-2012 yılları arasındaki ortalama yıllık getirisi 13.17% iken, "Al&Tut" modelinin ortalama yıllık getirisi 2.60%, RSI modelinin ortalama yıllık getirisi -0.01%, SMA modelinin ortalama yıllık getirisi 1.30%, LSTM yönteminin [20] ortalama yıllık getirisi 8.44%, MLP regresyon (literatürde önerilen) yönteminin [20] ortalama yıllık getirisi 8.23%'dir. Önerilen tüm yöntemlerin ETF'lerle 2007-2012 yılları arasındaki yıllık ortalama getiri oranları Şekil 9.4'de gösterilmektedir.

CNN-TA modelinin zaman kaydırmalı olarak uygulanmasının performansı, 2007-2017 yıllarında "Al&Tut" modelinin performansının yaklaşık olarak 3 katı olurken, kriz zamanında 2007-2012 yıllarında yaklaşık 6 katı olmaktadır. Ayrıca, CNN-TA yönteminin performansı 2007-2017 yıllarında LSTM yönteminin performansının yaklaşık olarak 1.5 katı olurken, kriz zamanında 2007-2012 yıllarında yaklaşık 2 katı olmaktadır. Tüm sonuçlar göz önüne alındığında önerilen CNN-TA modeli kriz zamanında ve diğer zaman aralıklarında yaklaşık olarak aynı performansı göstererek stabil bir model olduğunu kanıtlarken, aynı zamanda diğer model ve yöntemlerden tüm zamanlarda daha iyi performans göstermektedir.

Çizelge 9.5: CNN-TA zaman kaydırmalı yönteminin BaH, RSI, SMA, LSTM, MLP Reg. modelleri ile kıyaslanması (ETFs - test periyodu: 2007 - 2017)


ETFs	CNN-TA Kay.	BaH	RSI	SMA	LSTM[20]	MLP[20]
SPY	<b>10.77%</b>	4.63%	6.14%	0.54%	3.35%	7.27%
QQQ	<b>11.57%</b>	10.52%	6.46%	5.37%	-1.33%	3.92%
XLU	<b>10.13%</b>	2.97%	4.91%	0.90%	1.29%	1.12%
XLE	<b>15.80%</b>	2.85%	3.64%	5.88%	4.01%	5.41%
XLP	<b>11.10%</b>	6.92%	5.29%	5.17%	5.97%	0.84%
XLY	<b>9.55%</b>	7.68%	5.74%	1.80%	2.13%	1.31%
EWZ	<b>20.40%</b>	-3.38%	-3.25%	4.15%	-1.30%	5.42%
EWJ	11.69%	1.73%	2.32%	3.08%	<b>12.30%</b>	6.11%
XLK	16.05%	2.31%	1.22%	-5.60%	<b>16.18%</b>	2.68%
<b>Ortalama</b>	<b>13.01%</b>	4.63%	3.95%	2.81%	6.22%	4.01%
<b>S.Sapma</b>	3.61%	4.03%	3.12%	3.57%	5.96%	<b>2.40%</b>



Şekil 9.3: ETF 2007-2017 ortalama yıllık getiri - yöntem grafiği

Çizelge 9.6: CNN-TA zaman kaydırmalı yönteminin BaH, RSI, SMA, LSTM, MLP Reg. modelleri ile kıyaslanması (ETFs - test periyodu: 2007 - 2012)

ETFs	CNN-TA Kay.	BaH	RSI	SMA	LSTM[20]	MLP[20]
SPY	9.25%	-0.39%	-1.64%	-1.56%	<b>11.05%</b>	10.62%
QQQ	<b>8.75%</b>	5.73%	2.60%	6.35%	5.38%	2.85%
XLU	<b>12.43%</b>	3.72%	0.84%	0.13%	6.89%	3.78%
XLE	<b>23.41%</b>	5.61%	-0.32%	7.45%	3.76%	12.93%
XLP	<b>12.59%</b>	6.97%	3.88%	4.07%	1.20%	4.37%
XLY	5.43%	1.65%	2.00%	-3.68%	3.88%	<b>7.41%</b>
EWZ	<b>25.07%</b>	7.64%	-1.54%	7.55%	1.69%	3.54%
EWI	12.32%	1.75%	-0.01%	-0.63%	<b>26.07%</b>	17.64%
XLF	<b>9.34%</b>	-16.91%	-7.68%	-16.06%	6.39%	7.02%
<b>Ortalama</b>	<b>13.17%</b>	2.60%	-0.01%	1.30%	8.44%	8.23%
S.Sapma	6.69%	7.49%	<b>3.36%</b>	7.44%	7.61%	5.03%



Şekil 9.4: ETF 2007-2012 ortalama yıllık getiri - yöntem grafiği

Ayrıca, önerilen CNN-TA yönteminin sonuçları; BaH, LSTM ve MLP yöntemlerinin sonuçları ile kıyaslanarak, istatistiksel anlamlılık testleri (statistical significance test) uygulanmıştır. Çizelge 9.7 ve Çizelge 9.8’de bu sonuçlar listelenmiştir. Sonuçlara göre, CNN-TA işlem performansı, uzun vadede (2007-2017) tüm modellerden önemli ölçüde daha iyidir. 2007-2012 dönemi için de, LSTM ile sonuçları dışında benzer sonuçlar vermektedir.

Çizelge 9.7: Yıllık kazançların TTest sonuçları (Dow30)

Zaman Aralığı	Performans Metrikleri	TTest Sonuçları
2007-2017	CNN-TA - BaH	0.0100241
	CNN-TA - LSTM	0.0000001
	CNN-TA - MLP	0.0000001
2007-2012	CNN-TA - BaH	0.0012111
	CNN-TA - LSTM	0.1072803
	CNN-TA - MLP	0.0490155

Çizelge 9.8: Yıllık kazançların TTest sonuçları (ETF)

Zaman Aralığı	Performans Metrikleri	TTest Sonuçları
2007-2017	CNN-TA - BaH	0.0000302
	CNN-TA - LSTM	0.0010461
	CNN-TA - MLP	0.0000013
2007-2012	CNN-TA - BaH	0.0013547
	CNN-TA - LSTM	0.0755492
	CNN-TA - MLP	0.0463610

CNN-TA modelinde yapılan işlemlerindeki başarı oranının 70-80% olduğu görülmektedir. Dolayısıyla, CNN-TA metodu tarafından üretilen işlem sinyalleri ("Al", "Sat", "Tut") çoğu zaman başarılı (karlı) durumdadır. Ancak, "Al", "Sat", "Tut" noktaları için veri gösterimi, daha iyi al-sat sinyali üretim performansını eniyilenebilir. Test verisi (2007-2017 yılları arası) incelendiğinde, dönem boyunca farklı piyasa koşullarının (yükselen, alçalan, durağan) olduğu gözlemlenmektedir. Ancak, piyasa koşullarındaki bu dalgalanmalar, CNN-TA modelinin genel işlem performansını etkilememektedir. Sonuç olarak, model kötüleşen piyasa koşullarında dahi iyi kazançlar elde etmeyi başarmaktadır.

Önerilen CNN-TA modeli zaman içerisinde kaydırmalı olarak eğitilip, daha sonrasında test edilerek eniyilenmiştir. Zaman içerisinde kaydırmalı eğitim ile zaman içerisindeki değişimler modele yansıtılmış, toplam kar oranı ve önerilen modelin verimliliği arttırılmıştır. LSTM yönteminde yakın zaman içerisinde değişim gelecek tahmininde verimliliği arttırmaktadır. Benzer yaklaşım, zaman içerisinde kaydırmalı eğitim ile CNN-TA yöntemine de uygulanmıştır.

CNN-TA zaman kaydırmalı modelin performans sonuçları, umut verici sonuçlar vermektedir (Dow30: 2007-2017 dönemlerinde 12.59%, 2007-2012 dönemlerinde 12.83%; ETF: 2007-2017 dönemlerinde 13.01%, 2007-2012 dönemlerinde 13.17%). Ancak, CNN-TA zaman kaydırmalı modelin performansı iyileştirmeler ile artabilir. CNN-TA modelinde kullanılan CNN yapısal parametreleri eniyilenirse model daha iyi performans gösterebilir. Model eniyilenmesi için evrimsel algoritmalar kullanılarak, CNN performansı arttırılabileceği öngörülmektedir.

Tez kapsamında yapılan tüm önerilerdeki finansal değerlendirme senaryolarında, önerilen algoritmik al-sat modelleri, sadece uzun pozisyon stratejisi ile analiz edilmiştir. Uzun (long) pozisyon stratejisinde varlık, eldeki sermaye karşılığında alınmaktadır. Uzun (long) pozisyon, gelecek bir zamanda varlık fiyatlarının yükselmesi beklentisi ile varlık alımı yapılarak beklenen pozisyonudur. Kısa (short) pozisyon stratejisinde varlık, gelecek zamanda alınmak suretiyle, borçlanarak satılmaktadır. Kısa (short) pozisyon, gelecek bir zamanda varlık fiyatlarının düşmesi beklentisi ile varlık satımı yapılarak beklenen pozisyonudur.

Önerilen modellerin tümünde finansal değerlendirme senaryolarında, uzun ve kısa pozisyon stratejisinin birlikte kullanılmasıyla toplam kar artabilir. Çünkü tüm modellerde boşa kalma oranı (idle ratio) yaklaşık olarak 50%'dir. Nakitte kalınan sürede, kısa pozisyon alınması toplam karı arttırabilir. Ayrıca, boşa kalma zamanları farklı olan varlıklar tespit edilerek, portföy oluşturulursa, işlem yapılmadığı zamanlarda, portföydeki diğer varlıklardan alınarak, toplam kar artabilir.



## 10. SONUÇ

Bu tez kapsamında zaman serisi finansal verilerin analizi için yeni modeller ve metotlar önerilmiştir. Önerilen finansal modeller, diğer model ve stratejiler ile karşılaştırılmıştır. Önerilen modellerde kullanılan özellikler birer matematiksel formül olduğundan finansal veriler kullanılarak önerilen metotlar, ayrıca diğer zaman serisi verilerinin analizinde de kullanılabileceğini öngörülmektedir.

Tez kapsamında (MLP-TA), dört farklı ve yenilikçi model önerilmiştir. Birinci modelde, teknik analiz göstergeleri kullanılarak yapay sinir ağı tabanlı gelecek hisse senedi fiyatını trendini tahmin edebilen metot sunulmuştur. Önerilen model büyük veri çerçevesi yazılımı kütüphanesi "Apache Spark" kullanılarak gerçekleştirilmiştir. Modeli değerlendirmek için Dow-30 hisselerinin finansal değerleri kullanılmıştır. Finansal değerlendirme senaryosu ile elde edilen sonuçlar göstermektedir ki önerilen modelin performansı model parametreleri en iyi duruma bile getirilmeden bile "Al&Tut" stratejisine karşı iyi sonuçlar vermektedir.

İkinci öneride (DMLP-GA), genetik algoritma ile eniyilenmiş teknik analiz verileri modeli ve eniyilenmiş teknik veriler ile derin sinir ağını kullanarak tahmin yapabilen bir model sunulmuştur. Yükselen ve alçalan piyasa koşullarındaki RSI teknik analiz verilerini eniyilemek için genetik algoritma kullanılmıştır. Eniyilenmiş özellik değerleri derin sinir ağında kullanılmıştır. Sonuçlar, önerilen modelin "Al&Tut" stratejisiyle karşılaştırıldığında daha iyi sonuçlar verdiği görülmektedir. Önerilen model büyük veri çerçevesi yazılımı kütüphanesi "Apache Spark" kullanılarak gerçekleştirilmiştir.

Üçüncü modelde (CNN-BI), zaman serisi verilerin 2 boyutlu çubuk grafik görüntülerine dönüştürülmesi ve görüntülerin derin konvolüsyonel sinir ağı kullanılarak tahmin edilme metodu önerilmiştir. Literatürdeki tüm varolan stratejilerden farklı olarak zaman serisi veriler çubuk grafikler olarak ifade edilip 2 boyutlu görüntüler elde edilmiştir. Sonuçlar, önerilen modelin genel olarak tutarlı sonuçlar üretebildiğini ve piyasa koşullarına bağlı olarak "Al&Tut" stratejisini yenebildiğini göstermektedir. Genel olarak sonuçlar umut vericidir. Önerilen model, alanında yenilikçi ve farklı bir yaklaşıma sahip olduğundan dolayı iyileştirilmesi gerekebilir. İşlem sayısının artırılması ve piyasa trendinin ayrı bir özellik olarak kullanılması ile performansının daha da artırabileceği öngörülmektedir. Model ayrıca, geleneksel yöntemlere dayanan diğer modellere

de entegre edilebilir. Önerilen model "Tensorflow" kütüphanesi kullanılarak gerçekleştirilmiştir.

Dördüncü modelde (CNN-TA), görüntü işleme özelliklerine göre öğrenme yapabilen 2 Boyutlu derin konvolüsyonel sinir ağı kullanan yeni bir algoritmik model önerilmiştir. Önerilen çözümde finansal zaman serisi verilerini analiz etmek için zaman serisi veriler 2 boyutlu görüntülere dönüştürülmüştür. Dow-30 ve ETF verileri farklı zaman aralıklarında eğitilip, test edilmiştir. CNN-TA yönteminin performansının daha iyi ölçümlenmesi için, zaman içerisinde kaydırmalı olarak eğitilip, daha sonrasında testler uygulanmıştır. Elde edilen sonuçlar, bu yeni yaklaşımın, "Al&Tut", RSI, SMA, LSTM ve MLP modellerine karşı çok iyi performansa sahip olduğunu göstermektedir. Seçilen teknik analiz göstergeleri arasındaki ilişki (korelasyon) bulunup, bulunan ilişki iyileştirilerek daha farklı görüntü elde edilme yaklaşımları gelecek çalışmalara da uygulanabilir. Önerilen model "Apache Spark" ve "Tensorflow" kütüphanesi kullanılarak gerçekleştirilmiştir.

Sonuç olarak, tez kapsamında dört öneri yapılmıştır. Yapılan önerilerin yenilikçi ve farklı yaklaşımlara sahiptir. Önerilen modellerde kullanılan teknik analiz indikatörü verileri matematiksel formüllerden oluştuğundan ve teknik analiz verileri her türlü zaman serisi verisine uygulanabildiğinden dolayı hem finansal alanda hem de diğer alanlardaki zaman serisi verilerinin analizine önerilen yöntemler uygulanabilir.

## 10.1 Gelecekteki Çalışmalar

Tez kapsamında önerilen dört ana modelin performansı, gelecek çalışmalar ile daha da iyileştirilebilir. Önerilen modeller farklı alanlarda üretilen zaman serisi veriler üzerine uygulanabileceği öngörülmektedir. Gelecekte yapılabilecek çalışmaları şu şekilde sıralayabiliriz:

- Önerilen modeller, "ensemble" (adaptive boosting,vs) yöntemlerle birbirleriyle ve başka modeller ile birleştirilebilir.
- Önerilen CNN-TA ve CNN-BI modelleri için farklı CNN yapıları geliştirilebilir.
- Önerilen modeller kullanılarak, gerçek zamanlı tahmin uygulaması ile uygulanabilir.
- Kullanılan özellikler matematiksel formüllerden oluştuğundan dolayı, önerilen modeller farklı alanlarda kullanılabilir. Özellikle, trend yönü belirlenebilecek uygulamalarda önerilen modeller uygulanabilir.



- Önerilen modellerin zaman içerisinde her zaman kullanılmadığı gözlemlenmektedir. Portföy, sepet yöntemiyle birbirleriyle korelasyonu olmayan hisselerde uygulanarak daha fazla getiri elde edilebilir.
- Önerilen modeller, klasik zaman serisi tahmin yöntemleriyle (ARIMA, RNN, LSTM, vs) birlikte kullanılabilir.
- Önerilen modeller, tezde test edilmemiş finansal veriler (Foreks, Borsa İstanbul hisse seneti verileri, vs) üzerine de uygulanabilir.





## KAYNAKLAR

- [1] **Wei, William WS** (2006). “Time series analysis”. In: *The Oxford Handbook of Quantitative Methods in Psychology: Vol. 2*.
- [2] **Tsay, Ruey S** (2005). *Analysis of financial time series*. Vol. 543. John Wiley & Sons.
- [3] **Franses, Philip Hans** and **Van Dijk, Dick** (2000). *Non-linear time series models in empirical finance*. Cambridge University Press.
- [4] **Warren Liao, T.** (2005). “Clustering of time series data—a survey”. In: *Pattern Recognition* 38.11, pp. 1857–1874.
- [5] **Granger, Clive WJ** (1981). “Some properties of time series data and their use in econometric model specification”. In: *Journal of econometrics* 16.1, pp. 121–130.
- [6] **Hamilton, James D** (1989). “A new approach to the economic analysis of nonstationary time series and the business cycle”. In: *Econometrica: Journal of the Econometric Society*, pp. 357–384.
- [7] **Ganz, Frieder** et al. (2015). “A Practical Evaluation of Information Processing and Abstraction Techniques for the Internet of Things”. In: *IEEE Internet of Things Journal* 2.4, pp. 340–354.
- [8] **Fu, Tak-chung** (2011). “A review on time series data mining”. In: *Engineering Applications of Artificial Intelligence* 24.1, pp. 164–181.
- [9] **Molina, Marco E., Perez, Aurora,** and **Valente, Juan P.** (2016). “Classification of auditory brainstem responses through symbolic pattern discovery”. In: *Artificial Intelligence in Medicine* 70, pp. 12–30.
- [10] **Kohonen, Teuvo** (1998). “The self-organizing map”. In: *Neurocomputing* 21.1-3, pp. 1–6.
- [11] **Ahmed, Nesreen K.** et al. (2010). “An Empirical Comparison of Machine Learning Models for Time Series Forecasting”. In: *Econometric Reviews* 29.5-6, pp. 594–621.
- [12] **Hinton, Geoffrey E., Osindero, Simon,** and **Teh, Yee-Whye** (2006). “A Fast Learning Algorithm for Deep Belief Nets”. In: *Neural Computation* 18.7, pp. 1527–1554.
- [13] **LeCun, Yann, Bengio, Yoshua,** and **Hinton, Geoffrey** (2015). “Deep learning”. In: *Nature* 521.7553, pp. 436–444.

- [14] **Goodfellow Ian, Bengio Yoshua, and Courville Aaron** (2016). *Deep Learning*. MIT press. URL: <http://www.deeplearningbook.org/>.
- [15] **LeCun, Yann** et al. (1995). “Learning algorithms for classification: A comparison on handwritten digit recognition”. In: *Neural networks: the statistical mechanics perspective* 261, p. 276.
- [16] **Graves, Alex, Mohamed, Abdel-rahman, and Hinton, Geoffrey** (2013). “Speech recognition with deep recurrent neural networks”. In: *2013 IEEE International Conference on Acoustics, Speech and Signal Processing*, pp. 6645–6649.
- [17] **Cavalcante, Rodolfo C.** et al. (2016). “Computational Intelligence and Financial Markets: A Survey and Future Directions”. In: *Expert Systems with Applications* 55, pp. 194–211.
- [18] **Martinez, Leonardo C.** et al. (2009). “From an artificial neural network to a stock market day-trading system: A case study on the BM&F BOVESPA”. In: *2009 International Joint Conference on Neural Networks*. IEEE, pp. 2006–2013.
- [19] **Krauss, Christopher, Do, Xuan Anh, and Huck, Nicolas** (2017). “Deep neural networks, gradient-boosted trees, random forests: Statistical arbitrage on the S&P 500”. In: *European Journal of Operational Research* 259.2, pp. 689–702.
- [20] **Fischer, Thomas and Krauß, Christopher** (2017). *Deep learning with long short-term memory networks for financial market predictions*. Tech. rep. FAU Discussion Papers in Economics.
- [21] **Lai, Robert K.** et al. (2009). “Evolving and clustering fuzzy decision tree for financial time series data forecasting”. In: *Expert Systems with Applications* 36.2, pp. 3761–3773.
- [22] **Chun, Se-Hak and Kim, Steven H** (2004). “Automated generation of new knowledge to support managerial decision-making: case study in forecasting a stock market”. In: *Expert Systems* 21.4, pp. 192–207.
- [23] **Pulido, Martha, Melin, Patricia, and Castillo, Oscar** (2014). “Particle swarm optimization of ensemble neural networks with fuzzy aggregation for time series prediction of the Mexican Stock Exchange”. In: *Information Sciences* 280, pp. 188–204.
- [24] **Guresen, Erkam, Kayakutlu, Gulgun, and Daim, Tugrul U** (2011). “Using artificial neural network models in stock market index prediction”. In: *Expert Systems with Applications* 38.8, pp. 10389–10397.
- [25] **Jianxue Chen** (2010). “SVM application of financial time series forecasting using empirical technical indicators”. In: *2010 International Conference on Information, Networking and Automation (ICINA)*. IEEE, pp. V1–77–V1–81.

- [26] **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)*. IEEE, pp. 1–4.
- [27] **Nayak, Rudra Kalyan, Mishra, Debahuti, and Rath, Amiya Kumar** (2015). “A Naïve SVM-KNN based stock market trend reversal analysis for Indian benchmark indices”. In: *Applied Soft Computing* 35, pp. 670–680.
- [28] **Patel, Jigar et al.** (2015). “Predicting stock market index using fusion of machine learning techniques”. In: *Expert Systems with Applications* 42.4, pp. 2162–2172.
- [29] **Vanstone, Bruce, Finnie, Gavin, and Hahn, Tobias** (2012). “Creating trading systems with fundamental variables and neural networks: The Aby case study”. In: *Mathematics and Computers in Simulation* 86, pp. 78–91.
- [30] **Dhar, S and Mukherjee, T** (2010). “Performance evaluation of Neural Network approach in financial prediction: Evidence from Indian Market”. In: *Communication and*.
- [31] **Huang, Chien-Feng** (2012). “A hybrid stock selection model using genetic algorithms and support vector regression”. In: *Applied Soft Computing* 12.2, pp. 807–818.
- [32] **Kim, Kyoung-jae and Han, Ingoo** (2000). “Genetic algorithms approach to feature discretization in artificial neural networks for the prediction of stock price index”. In: *Expert Systems with Applications* 19.2, pp. 125–132.
- [33] **Zhang, Yudong and Wu, Lenan** (2009). “Stock market prediction of SP 500 via combination of improved BCO approach and BP neural network”. In: *Expert Systems with Applications* 36.5, pp. 8849–8854.
- [34] **Wang, Zhiguang, Yan, Weizhong, and Oates, Tim** (2017). “Time series classification from scratch with deep neural networks: A strong baseline”. In: *Neural Networks (IJCNN), 2017 International Joint Conference on*. IEEE, pp. 1578–1585.
- [35] **Zheng, Yi et al.** (2014). “Time series classification using multi-channels deep convolutional neural networks”. In: *International Conference on Web-Age Information Management*. Springer, pp. 298–310.
- [36] **Le Guennec, Arthur, Malinowski, Simon, and Tavenard, Romain** (2016). “Data augmentation for time series classification using convolutional neural networks”. In: *ECML/PKDD Workshop on Advanced Analytics and Learning on Temporal Data*.

- [37] **Hatami, Nima, Gavet, Yann, and Debayle, Johan** (2017). “Classification of Time-Series Images Using Deep Convolutional Neural Networks”. In: *arXiv preprint arXiv:1710.00886*.
- [38] **Scharf, Louis L and Demeure, Cédric** (1991). *Statistical signal processing: detection, estimation, and time series analysis*. Vol. 63. Addison-Wesley Reading, MA.
- [39] **Box, George E. P., Jenkins, Gwilym M., and Reinsel, Gregory C.** (2008). *Time Series Analysis*. Hoboken, NJ: John Wiley & Sons, Inc.
- [40] **Bagnall, Anthony and Janacek, Gareth** (2005). “Clustering Time Series with Clipped Data”. In: *Machine Learning* 58.2-3, pp. 151–178.
- [41] **Olszewski, Robert T.** (2001). “Generalized Feature Extraction for Structural Pattern Recognition in Time-Series Data”. Ph.D Thesis. Carnegie Mellon University.
- [42] **Keogh, Eamonn et al.** (2001). “Dimensionality Reduction for Fast Similarity Search in Large Time Series Databases”. In: *Knowledge and Information Systems* 3.3, pp. 263–286.
- [43] **Kamath, Uday, Lin, Jessica, and De Jong, Kenneth** (2014). “SAX-EFG”. In: *Proceedings of the 2014 conference on Genetic and evolutionary computation - GECCO '14*. ACM Press, pp. 533–540.
- [44] **Chung, FL et al.** (2001). “Flexible time series pattern matching based on perceptually important points”. In:
- [45] **Berndt, Donald J. and Clifford, James** (1994). “Using Dynamic Time Warping to Find Patterns in Time Series”. In: *AIAA*.
- [46] **Xue, Wenwei, Luo, Qiong, and Wu, Hejun** (2012). “Pattern-based event detection in sensor networks”. In: *Distributed and Parallel Databases* 30.1, pp. 27–62.
- [47] **Fu, T et al.** (2001). “Pattern discovery from stock time series using self-organizing maps”. In: *Workshop Notes of*.
- [48] **Keogh, E, Lonardi, S, and Chiu, BY** (2002). “Finding surprising patterns in a time series database in linear time and space”. In: *Proceedings of the eighth ACM SIGKDD*.
- [49] **Chan, P.K. and Mahoney, M.V.** “Modeling Multiple Time Series for Anomaly Detection”. In: *Fifth IEEE International Conference on Data Mining (ICDM'05)*. IEEE, pp. 90–97.
- [50] **Wei, L et al.** (2005). “Assumption-Free Anomaly Detection in Time Series.” In: *SSDBM*.
- [51] **Chiu, B, Keogh, E, and Lonardi, S** (2003). “Probabilistic discovery of time series motifs”. In: *Proceedings of the ninth ACM SIGKDD*.

- [52] **Sternickel, Karsten** (2002). “Automatic pattern recognition in ECG time series”. In: *Computer Methods and Programs in Biomedicine* 68.2, pp. 109–115.
- [53] **Das, Gautam** et al. (1998). “Rule discovery from time series”. In: *Aaai*.
- [54] **Golay, Xavier** et al. (1998). “A new correlation-based fuzzy logic clustering algorithm for FMRI”. In: *Magnetic Resonance in Medicine* 40.2, pp. 249–260.
- [55] **Möller-Levet, Carla S.** et al. (2003). “Fuzzy Clustering of Short Time-Series and Unevenly Distributed Sampling Points”. In: pp. 330–340.
- [56] **Shumway, Robert H.** (2003). “Time-frequency clustering and discriminant analysis”. In: *Statistics & Probability Letters* 63.3, pp. 307–314.
- [57] **Kakizawa, Yoshihide, Shumway, Robert H., and Taniguchi, Masanobu** (1998). “Discrimination and Clustering for Multivariate Time Series”. In: *Journal of the American Statistical Association* 93.441, pp. 328–340.
- [58] **Liao, TW** et al. (2002). “Understanding and projecting the battle state”. In: *23rd Army Science*.
- [59] **Goutte, Cyril** et al. (1999). “On Clustering fMRI Time Series”. In: *NeuroImage* 9.3, pp. 298–310.
- [60] **Baragona, R** (2001). “A simulation study on clustering time series with metaheuristic methods”. In: *Quaderni di Statistica*.
- [61] **Yimin Xiong and Dit-Yan Yeung**. “Mixtures of ARMA models for model-based time series clustering”. In: *2002 IEEE International Conference on Data Mining, 2002. Proceedings*. IEEE Comput. Soc, pp. 717–720.
- [62] **Ramoni, Marco, Sebastiani, Paola, and Cohen, Paul** (2002). “Bayesian Clustering by Dynamics”. In: *Machine Learning* 47.1, pp. 91–121.
- [63] **Agami, Nedaa** et al. (2009). “A neural network based dynamic forecasting model for Trend Impact Analysis”. In: *Technological Forecasting and Social Change* 76.7, pp. 952–962.
- [64] **Arizmendi, C. M.** et al. (1993). “Time series predictions with neural nets: Application to airborne pollen forecasting”. In: *International Journal of Biometeorology* 37.3, pp. 139–144.
- [65] **Srinivasan, Dipti, Liew, A.C., and Chang, C.S.** (1994). “A neural network short-term load forecaster”. In: *Electric Power Systems Research* 28.3, pp. 227–234.
- [66] **Kaastra, Iebeling and Boyd, Milton** (1996). “Designing a neural network for forecasting financial and economic time series”. In: *Neurocomputing* 10.3, pp. 215–236.

- [67] **Ansuj, Angela P.** et al. (1996). “Sales forecasting using time series and neural networks”. In: *Computers & Industrial Engineering* 31.1-2, pp. 421–424.
- [68] **Zhang, Gioqinang** and **Hu, Michael Y.** (1998). “Neural network forecasting of the British Pound/US Dollar exchange rate”. In: *Omega* 26.4, pp. 495–506.
- [69] **Bezerianos, A., Papadimitriou, S., and Alexopoulos, D.** (1999). “Radial basis function neural networks for the characterization of heart rate variability dynamics”. In: *Artificial Intelligence in Medicine* 15.3, pp. 215–234.
- [70] **Li, Q.S** et al. (2000). “Damping in buildings: its neural network model and AR model”. In: *Engineering Structures* 22.9, pp. 1216–1223.
- [71] **Nguyen, Hanh H.** and **Chan, Christine W.** (2004). “Multiple neural networks for a long term time series forecast”. In: *Neural Computing & Applications* 13.1, pp. 90–98.
- [72] **Hansen, J.V.** and **Nelson, R.D.** (1997). “Neural networks and traditional time series methods: a synergistic combination in state economic forecasts”. In: *IEEE Transactions on Neural Networks* 8.4, pp. 863–873.
- [73] **Kalaitzakis, K., Stavrakakis, G.S., and Anagnostakis, E.M.** (2002). “Short-term load forecasting based on artificial neural networks parallel implementation”. In: *Electric Power Systems Research* 63.3, pp. 185–196.
- [74] **Zhang, G.Peter** (2003). “Time series forecasting using a hybrid ARIMA and neural network model”. In: *Neurocomputing* 50, pp. 159–175.
- [75] **Gao, Yang** and **Er, Meng Joo** (2005). “NARMAX time series model prediction: feedforward and recurrent fuzzy neural network approaches”. In: *Fuzzy Sets and Systems* 150.2, pp. 331–350.
- [76] **Guan, Donghai** et al. (2007). “Devising a Context Selection-Based Reasoning Engine for Context-Aware Ubiquitous Computing Middleware”. In: *Ubiquitous Intelligence and Computing*. Berlin, Heidelberg: Springer Berlin Heidelberg, pp. 849–857.
- [77] **Saeedi, Sara, Moussa, Adel, and El-Sheimy, Naser** (2014). “Context-Aware Personal Navigation Using Embedded Sensor Fusion in Smartphones”. In: *Sensors* 14.4, pp. 5742–5767.
- [78] **Jonghwa Choi, Dongkyoo Shin, and Dongil Shin** (2005). “Research and implementation of the context-aware middleware for controlling home appliances”. In: *IEEE Transactions on Consumer Electronics* 51.1, pp. 301–306.
- [79] **Mishra, Nilamadhab, Lin, Chung-Chih, and Chang, Hsien-Tsung** (2015). “A Cognitive Adopted Framework for IoT Big-Data Management



and Knowledge Discovery Prospective”. In: *International Journal of Distributed Sensor Networks* 2015, pp. 1–12.

- [80] **Cao, Lijuan** (2003). “Support vector machines experts for time series forecasting”. In: *Neurocomputing* 51, pp. 321–339.
- [81] **Mohandes, M.A.** et al. (2004). “Support vector machines for wind speed prediction”. In: *Renewable Energy* 29.6, pp. 939–947.
- [82] **Mörchen, Fabian, Ultsch, Alfred, and Hoos, Olaf** (2005). “Extracting interpretable muscle activation patterns with time series knowledge mining”. In: *International Journal of Knowledge-based and Intelligent Engineering Systems* 9.3, pp. 197–208.
- [83] **Shu-Ching Kuo** et al. “Knowledge Discovery with SOM Networks in Financial Investment Strategy”. In: *Fourth International Conference on Hybrid Intelligent Systems (HIS’04)*. IEEE, pp. 98–103.
- [84] **De Coninck, Elias** et al. (2016). “Distributed Neural Networks for Internet of Things: The Big-Little Approach”. In: pp. 484–492.
- [85] **Hermans, Michiel and Schrauwen, Benjamin** (2013). *Training and Analysing Deep Recurrent Neural Networks*.
- [86] **Ma, Xiaolei** et al. (2015). “Large-Scale Transportation Network Congestion Evolution Prediction Using Deep Learning Theory”. In: *PLOS ONE* 10.3, e0119044.
- [87] **Greff, Klaus** et al. (2016). “LSTM: A Search Space Odyssey”. In: *IEEE Transactions on Neural Networks and Learning Systems*, pp. 1–11.
- [88] **Qiu, Xueheng** et al. (2014). “Ensemble deep learning for regression and time series forecasting”. In: *2014 IEEE Symposium on Computational Intelligence in Ensemble Learning (CIEL)*, pp. 1–6.
- [89] **Jaitly, N and Hinton, G** (2011). “Learning a better representation of speech soundwaves using restricted boltzmann machines”. In: *Acoustics, Speech and Signal Processing* (.
- [90] **Mohamed, A, Dahl, GE, and Hinton, G** (2012). “Acoustic modeling using deep belief networks”. In: *IEEE Transactions on Audio,*
- [91] **Hamel, P and Eck, D** (2010). “Learning Features from Music Audio with Deep Belief Networks.” In: *ISMIR*.
- [92] **Lee, Honglak** et al. (2009). *Unsupervised feature learning for audio classification using convolutional deep belief networks*.
- [93] **Zhang, N** et al. (2016). “Semantic framework of internet of things for smart cities: case studies”. In: *Sensors*.
- [94] **Humphrey, EJ, Bello, JP, and LeCun, Y** (2013). “Feature learning and deep architectures: New directions for music informatics”. In: *Journal of Intelligent Information*.

- [95] **Mirowski, Piotr W.** et al. (2008). “Comparing SVM and convolutional networks for epileptic seizure prediction from intracranial EEG”. In: *2008 IEEE Workshop on Machine Learning for Signal Processing*, pp. 244–249.
- [96] **Edwards, Robert D., Magee, John, and Bassetti, W.H.C.** (2007). *Technical Analysis of Stock Trends*. Ninth Edit.
- [97] **Investopedia** (2017). *Investopedia*. URL: <http://www.investopedia.com/> (visited on 03/12/2017).
- [98] **Wilder, J. Welles.** (1978). *New Concepts in Technical Trading Systems*.
- [99] **Lee, Ming-Chi** (2009). “Using support vector machine with a hybrid feature selection method to the stock trend prediction”. In: *Expert Systems with Applications* 36.8, pp. 10896–10904.
- [100] **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* 50.1, pp. 258–269.
- [101] **Lin, Fengyi** et al. (2014). “Novel feature selection methods to financial distress prediction”. In: *Expert Systems with Applications* 41.5, pp. 2472–2483.
- [102] **Tsinaslanidis, Prodromos E. and Kugiumtzis, Dimitris** (2014). “A prediction scheme using perceptually important points and dynamic time warping”. In: *Expert Systems with Applications* 41.15, pp. 6848–6860.
- [103] **Li, Xiuquan, Deng, Zhidong, and Luo, Jing** (2009). “Trading strategy design in financial investment through a turning points prediction scheme”. In: *Expert Systems with Applications* 36.4, pp. 7818–7826.
- [104] **Yin, Jiangling, Si, Yain-Whar, and Gong, Zhiguo** (2011). “Financial time series segmentation based on Turning Points”. In: *Proceedings 2011 International Conference on System Science and Engineering*. IEEE, pp. 394–399.
- [105] **Si, Yain-Whar and Yin, Jiangling** (2013). “OBST-based segmentation approach to financial time series”. In: *Engineering Applications of Artificial Intelligence* 26.10, pp. 2581–2596.
- [106] **Zhou, Dazhuo, Li, JinXia, and Ma, WenXiu** (2009). “Clustering Based on LLE For Financial Multivariate Time Series”. In: *2009 International Conference on Management and Service Science*. IEEE, pp. 1–4.
- [107] **Huang, Cheng-Lung and Tsai, Cheng-Yi** (2009). “A hybrid SOFM-SVR with a filter-based feature selection for stock market forecasting”. In: *Expert Systems with Applications* 36.2, pp. 1529–1539.
- [108] **Andrade de Oliveira, Fagner** et al. (2011). “The use of artificial neural networks in the analysis and prediction of stock prices”. In: *2011*

*IEEE International Conference on Systems, Man, and Cybernetics*. IEEE, pp. 2151–2155.

- [109] **Jasemi, Milad, Kimiagari, Ali M., and Memariani, A.** (2011). “A modern neural network model to do stock market timing on the basis of the ancient investment technique of Japanese Candlestick”. In: *Expert Systems with Applications* 38.4, pp. 3884–3890.
- [110] **Kayal, Abdulah** (2010). “A Neural Networks filtering mechanism for foreign exchange trading signals”. In: *2010 IEEE International Conference on Intelligent Computing and Intelligent Systems*. IEEE, pp. 159–167.
- [111] **Lasfer, Assia, El-Baz, Hazim, and Zualkernan, Imran** (2013). “Neural Network design parameters for forecasting financial time series”. In: *2013 5th International Conference on Modeling, Simulation and Applied Optimization (ICMSAO)*. IEEE, pp. 1–4.
- [112] **Majhi, Ritanjali, Panda, G., and Sahoo, G.** (2009). “Efficient prediction of exchange rates with low complexity artificial neural network models”. In: *Expert Systems with Applications* 36.1, pp. 181–189.
- [113] **Mahdi, A.A., Hussain, A.J., and Al-Jumeily, D.** (2009). “Adaptive Neural Network Model Using the Immune System for Financial Time Series Forecasting”. In: *2009 International Conference on Computational Intelligence, Modelling and Simulation*. IEEE, pp. 104–109.
- [114] **Ghazali, Rozaida et al.** (2009). “Non-stationary and stationary prediction of financial time series using dynamic ridge polynomial neural network”. In: *Neurocomputing* 72.10, pp. 2359–2367.
- [115] **Shahpazov, Veselin L., Velev, Vladimir B., and Doukovska, Lyubka A.** (2013). “Design and application of Artificial Neural Networks for predicting the values of indexes on the Bulgarian Stock market”. In: *2013 Signal Processing Symposium (SPS)*. IEEE, pp. 1–6.
- [116] **Rodríguez-González, Alejandro et al.** (2011). “CAST: Using neural networks to improve trading systems based on technical analysis by means of the RSI financial indicator”. In: *Expert Systems with Applications* 38.9, pp. 11489–11500.
- [117] **Liu, Fajiang and Wang, Jun** (2012). “Fluctuation prediction of stock market index by Legendre neural network with random time strength function”. In: *Neurocomputing* 83, pp. 12–21.
- [118] **Ticknor, Jonathan L.** (2013). “A Bayesian regularized artificial neural network for stock market forecasting”. In: *Expert Systems with Applications* 40.14, pp. 5501–5506.
- [119] **Wang, Jie and Wang, Jun** (2015). “Forecasting stock market indexes using principle component analysis and stochastic time effective neural networks”. In: *Neurocomputing* 156, pp. 68–78.

- [120] **Lu, Chi-Jie** and **Wu, Jui-Yu** (2011). “An efficient CMAC neural network for stock index forecasting”. In: *Expert Systems with Applications* 38.12, pp. 15194–15201.
- [121] **Bao, Yukun** et al. (2011). “A Comparative Study of Multi-step-ahead Prediction for Crude Oil Price with Support Vector Regression”. In: *2011 Fourth International Joint Conference on Computational Sciences and Optimization*. IEEE, pp. 598–602.
- [122] **Kara, Yakup, Acar Boyacioglu, Melek, and Baykan, Ömer Kaan** (2011). “Predicting direction of stock price index movement using artificial neural networks and support vector machines: The sample of the Istanbul Stock Exchange”. In: *Expert Systems with Applications* 38.5, pp. 5311–5319.
- [123] **Huang, Chao, Huang, Li-li, and Han, Ting-ting** (2012). “Financial time series forecasting based on wavelet kernel support vector machine”. In: *2012 8th International Conference on Natural Computation*. IEEE, pp. 79–83.
- [124] **Kim, Kyoung-jae** (2003). “Financial time series forecasting using support vector machines”. In: *Neurocomputing* 55.1, pp. 307–319.
- [125] **Huang, Wei, Nakamori, Yoshiteru, and Wang, Shou-Yang** (2005). “Forecasting stock market movement direction with support vector machine”. In: *Computers, Operations Research* 32.10, pp. 2513–2522.
- [126] **Cao, L.J.** and **Tay, F.E.H.** (2003). “Support vector machine with adaptive parameters in financial time series forecasting”. In: *IEEE Transactions on Neural Networks* 14.6, pp. 1506–1518.
- [127] **Cao, Lijuan** and **Tay, Francis E.H** (2001). “Financial Forecasting Using Support Vector Machines”. In: *Neural Computing, Applications* 10.2, pp. 184–192.
- [128] **Pai, Ping-Feng** and **Lin, Chih-Sheng** (2005). “A hybrid ARIMA and support vector machines model in stock price forecasting”. In: *Omega* 33.6, pp. 497–505.
- [129] **Liang, Xun** et al. (2009). “Improving option price forecasts with neural networks and support vector regressions”. In: *Neurocomputing* 72.13, pp. 3055–3065.
- [130] **Lei Wu** and **Shahidehpour, Mohammad** (2010). “A Hybrid Model for Day-Ahead Price Forecasting”. In: *IEEE Transactions on Power Systems* 25.3, pp. 1519–1530.
- [131] **Zhu, Bangzhu** and **Wei, Yiming** (2013). “Carbon price forecasting with a novel hybrid ARIMA and least squares support vector machines methodology”. In: *Omega* 41.3, pp. 517–524.

- [132] **Kim, Kyoung-jae** and **Lee, Won Boo** (2004). “Stock market prediction using artificial neural networks with optimal feature transformation”. In: *Neural Computing and Applications* 13.3, pp. 255–260.
- [133] **Hassan, Md. Rafiul, Nath, Baikunth,** and **Kirley, Michael** (2007). “A fusion model of HMM, ANN and GA for stock market forecasting”. In: *Expert Systems with Applications* 33.1, pp. 171–180.
- [134] **Brasileiro, Rodrigo C.** et al. (2013). “Automatic method for stock trading combining technical analysis and the Artificial Bee Colony Algorithm”. In: *2013 IEEE Congress on Evolutionary Computation*, pp. 1810–1817.
- [135] **Hsieh, Tsung-Jung, Hsiao, Hsiao-Fen,** and **Yeh, Wei-Chang** (2012). “Mining financial distress trend data using penalty guided support vector machines based on hybrid of particle swarm optimization and artificial bee colony algorithm”. In: *Neurocomputing* 82, pp. 196–206.
- [136] **Evans, Cain, Pappas, Konstantinos,** and **Xhafa, Fatos** (2013). “Utilizing artificial neural networks and genetic algorithms to build an algo-trading model for intra-day foreign exchange speculation”. In: *Mathematical and Computer Modelling* 58.5, pp. 1249–1266.
- [137] **Abdual-Salam, ME** and **Abdul-Kader, HM** (2010). “Comparative study between Differential Evolution and Particle Swarm Optimization algorithms in training of feed-forward neural network for stock price prediction”. In: *and Systems (INFOS ...*
- [138] **Pinto, José Matias, Neves, Rui Ferreira,** and **Horta, Nuno** (2015). “Boosting Trading Strategies performance using VIX indicator together with a dual-objective Evolutionary Computation optimizer”. In: *Expert Systems with Applications* 42.19, pp. 6699–6716.
- [139] **Zhu, Ming** and **Wang, Lipo** (2010). “Intelligent trading using support vector regression and multilayer perceptrons optimized with genetic algorithms”. In: *The 2010 International Joint Conference on Neural Networks (IJCNN)*, pp. 1–5.
- [140] **Cavalcante, Rodolfo C.** and **Oliveira, Adriano L. I.** (2014). “An autonomous trader agent for the stock market based on online sequential extreme learning machine ensemble”. In: *2014 International Joint Conference on Neural Networks (IJCNN)*. IEEE, pp. 1424–1431.
- [141] **Mabu, Shingo, Obayashi, Masanao,** and **Kuremoto, Takashi** (2015). “Ensemble learning of rule-based evolutionary algorithm using multilayer perceptron for supporting decisions in stock trading problems”. In: *Applied Soft Computing* 36, pp. 357–367.
- [142] **Ballings, Michel** et al. (2015). “Evaluating multiple classifiers for stock price direction prediction”. In: *Expert Systems with Applications* 42.20, pp. 7046–7056.

- [143] **Yoshihara, Akira** et al. (2014). “Predicting Stock Market Trends by Recurrent Deep Neural Networks”. In: pp. 759–769.
- [144] **Ding, X** et al. (2015). “Deep Learning for Event-Driven Stock Prediction.” In: *IJCAI*.
- [145] **Shen, Furoo, Chao, Jing, and Zhao, Jinxi** (2015). “Forecasting exchange rate using deep belief networks and conjugate gradient method”. In: *Neurocomputing* 167, pp. 243–253.
- [146] **Chen, Jou-Fan** et al. (2016). “Financial Time-Series Data Analysis Using Deep Convolutional Neural Networks”. In: *Cloud Computing and Big Data (CCBD), 2016 7th International Conference on*. IEEE, pp. 87–92.
- [147] **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, pp. 138–148.
- [148] **Kuremoto, Takashi** et al. (2014). “Time series forecasting using a deep belief network with restricted Boltzmann machines”. In: *Neurocomputing* 137, pp. 47–56.
- [149] **Tino, P., Schittenkopf, C., and Dorffner, G.** (2001). “Financial volatility trading using recurrent neural networks”. In: *IEEE Transactions on Neural Networks* 12.4, pp. 865–874.
- [150] **Saad, E.W., Prokhorov, D.V., and Wunsch, D.C.** (1998). “Comparative study of stock trend prediction using time delay, recurrent and probabilistic neural networks”. In: *IEEE Transactions on Neural Networks* 9.6, pp. 1456–1470.
- [151] **Ribeiro, Bernardete and Lopes, Noel** (2011). “Deep Belief Networks for Financial Prediction”. In: Springer, Berlin, Heidelberg, pp. 766–773.
- [152] **Deng, Yue** et al. (2017). “Deep Direct Reinforcement Learning for Financial Signal Representation and Trading”. In: *IEEE Transactions on Neural Networks and Learning Systems* 28.3, pp. 653–664.
- [153] **Wang, Y** et al. (2017). “Deep Q-trading”. In: *cs.lit.riit.tsinghua.edu.cn*.
- [154] **Dixon, Matthew, Klabjan, Diego, and Bang, Jin Hoon** (2015). “Implementing deep neural networks for financial market prediction on the Intel Xeon Phi”. In: *Proceedings of the 8th Workshop on High Performance Computational Finance - WHPCF '15*. ACM Press, pp. 1–6.
- [155] **Chen, Min, Mao, Shiwen, and Liu, Yunhao** (2014). “Big Data: A Survey”. In: *Mobile Networks and Applications* 19.2, pp. 171–209.
- [156] **Labrinidis, Alexandros and Jagadish, H. V.** (2012). “Challenges and opportunities with big data”. In: *Proceedings of the VLDB Endowment* 5.12, pp. 2032–2033.

- [157] **Gazal** and **Kaur, Pankaj Deep** (2015). “A survey on Big Data storage strategies”. In: *International Conference on Green Computing and Internet of Things*. IEEE, pp. 280–284.
- [158] **Qin, Yongrui** et al. (2016). “When things matter: A survey on data-centric internet of things”. In: *Journal of Network and Computer Applications* 64.4, pp. 137–153.
- [159] **Gilbert, Seth** and **Lynch, Nancy** (2002). “Brewer’s conjecture and the feasibility of consistent, available, partition-tolerant web services”. In: *ACM SIGACT News* 33.2, p. 51.
- [160] **Shvachko, Konstantin** et al. (2010). “The Hadoop Distributed File System”. In: *IEEE 26th Symposium on Mass Storage Systems and Technologies*. IEEE, pp. 1–10.
- [161] **Chaiken, Ronnie, Jenkins, Bob, and Larson, PÅ** (2008). “SCOPE: easy and efficient parallel processing of massive data sets”. In: *Proceedings of the VLDB Endowment* 1.212, pp. 1265–1276.
- [162] **Beaver, Doug** et al. (2010). “Finding a needle in Haystack : Facebook ’ s photo storage”. In: *OSDI* 10.October, pp. 1–8.
- [163] **Cattell, Rick** (2011). “Scalable SQL and NoSQL data stores”. In: *ACM SIGMOD Record* 39.4, p. 12.
- [164] **DeCandia, Giuseppe** et al. (2007). “Dynamo”. In: *ACM SIGOPS Operating Systems Review* 41.6, p. 205.
- [165] **Sumbaly, Roshan** et al. (2012). *Serving large-scale batch computed data with project Voldemort*.
- [166] **Landset, S** and **Khoshgoftaar, TM** (2015). “A survey of open source tools for machine learning with big data in the Hadoop ecosystem”. In: *Journal of Big Data*.
- [167] **Chang, Fay** et al. (2008). “Bigtable”. In: *ACM Transactions on Computer Systems* 26.2, pp. 1–26.
- [168] **Lakshman, Avinash** and **Malik, Prashant** (2010). “Cassandra”. In: *ACM SIGOPS Operating Systems Review* 44.2, p. 35.
- [169] **Stonebraker, Mike** et al. (2005). “C-store: a column-oriented DBMS”. In: *Proceedings of the 31st international conference on Very large data bases*, pp. 553–564.
- [170] **Dirolf, Kristina Chodorow & Michael** (2011). *MongoDB: The Definitive Guide*. Vol. 203, NP.
- [171] **Murty, James** (2008). *Programming Amazon Web Services: S3, EC2, SQS, FPS, and SimpleDB*. O’Reilly, p. 581.
- [172] **Anderson, JC, Lehnardt, J, and Slater, N** (2010). *CouchDB: the definitive guide*. O’Reilly.

- [173] **Dean, Jeffrey** and **Ghemawat, Sanjay** (2008). “MapReduce”. In: *Communications of the ACM* 51.1, p. 107.
- [174] **White, Tom** (2012). *Hadoop: The definitive guide*. Vol. 54, p. 258.
- [175] **Isard, Michael** et al. (2007). “Dryad”. In: *Proceedings of the 2nd ACM SIGOPS/EuroSys European Conference on Computer Systems*. Vol. 41. 3. ACM Press, p. 59.
- [176] **Malewicz, Grzegorz** et al. (2010). “Pregel”. In: *International Conf. on Management of Data*. ACM Press, p. 135.
- [177] **Alagiannis, Ioannis, Idreos, Stratos, and Ailamaki, Anastasia** (2014). “H2O”. In: *ACM Sigmod International Conference on Management of Data*. ACM Press, pp. 1103–1114.
- [178] **Owen, Sean** et al. (2011). *Mahout in Action*, p. 375.
- [179] **Consens, M P** et al. (2010). “Graphical inference for infovis”. In: *Proceedings of the International Conference on Information Visualisation* 16.6, pp. 973–979.
- [180] **De Francisci Morales, Gianmarco** and **Bifet, Albert** (2015). “SAMOA: scalable advanced massive online analysis”. In: *The Journal of Machine Learning Research* 16.1, pp. 149–153.
- [181] **Holmes, G., Donkin, A., and Witten, I.H.** (1994). “WEKA: a machine learning workbench”. In: *Proceedings of ANZIIS - Australian New Zealand Intelligent Information Systems Conference*. IEEE, pp. 357–361.
- [182] **Sezer, Omer Berat, Ozbayoglu, A Murat, and Dogdu, Erdogan** (2017a). “An Artificial Neural Network-based Stock Trading System Using Technical Analysis and Big Data Framework”. In: *Proceedings of the SouthEast Conference*. ACM, pp. 223–226.
- [183] **More, Ajinkya** (2016). “Survey of resampling techniques for improving classification performance in unbalanced datasets”. In:
- [184] **Sezer, Omer Berat, Ozbayoglu, Murat, and Dogdu, Erdogan** (2017b). “A Deep Neural-Network Based Stock Trading System Based on Evolutionary Optimized Technical Analysis Parameters”. In: *Procedia Computer Science* 114, pp. 473–480.
- [185] **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, pp. 240–245.
- [186] **Ozbayoglu, Ahmet Murat** and **Erkut, Umur** (2010). “Stock market technical indicator optimization by genetic algorithms”. In: *Intelligent Engineering Systems through Artificial Neural Networks, Volume 20*. ASME Press.



- [187] **Canziani, Alfredo, Paszke, Adam, and Culurciello, Eugenio** (2016). “An analysis of deep neural network models for practical applications”. In: *arXiv preprint arXiv:1605.07678*.
- [188] **Kabanga, Espoir K and Kim, Chang Hoon** (2017). “Malware Images Classification Using Convolutional Neural Network”. In: *Journal of Computer and Communications* 6.01, p. 153.
- [189] **Yue, Songqing** (2017). “Imbalanced Malware Images Classification: a CNN based Approach”. In: *arXiv preprint arXiv:1708.08042*.
- [190] **Seyfioglu, M. S., Ozbayoglu, A. M., and Gurbuz, S. Z.** (2018). “Deep Convolutional Autoencoder for Radar-Based Classification of Similar Aided and Unaided Human Activities”. In: *IEEE Transactions on Aerospace and Electronic Systems* PP.99, pp. 1–1.
- [191] **Sezer, Omer Berat and Ozbayoglu, Ahmet Murat** (2018). “Algorithmic Financial Trading with Deep Convolutional Neural Networks: Time Series to Image Conversion Approach”. In: *Applied Soft Computing*.
- [192] **Mostafa, Mohamed M** (2010). “Forecasting stock exchange movements using neural networks: Empirical evidence from Kuwait”. In: *Expert Systems with Applications* 37.9, pp. 6302–6309.



## ÖZGEÇMİŞ

**Ad-Soyad** : Ömer Berat SEZER  
**Uyruğu** : T.C.  
**Doğum Tarihi ve Yeri** : 24.04.1986 Tavşanlı / Kütahya  
**E-posta** : omer.b.sezer@gmail.com

### ÖĞRENİM DURUMU:

- **Yüksek Lisans** : 2013, ODTÜ / METU, Elektrik-Elektronik Müh.
- **Lisans** : 2009, ODTÜ KKK / METU NCC, Elektrik-Elektronik Müh.

### MESLEKİ DENEYİM VE ÖDÜLLER:

Yıl	Yer	Görev
2018 - Halen	TUBİTAK-UZAY	Başuzman Araştırmacı - Yazılım Müh.
2014 - 2018	TUBİTAK-UZAY	Uzman Araştırmacı - Yazılım Müh.
2014 - 2018	TOBB ETÜ	Araştırma Burslu Doktora Öğrencisi
2009 - 2013	TUBİTAK-UZAY	Araştırmacı - Gömülü Yazılım Müh.
2004 - 2009	ODTÜ KKK / METU NCC	Burslu Lisans Öğrencisi, Bölüm 1.si

**YABANCI DİL:** İngilizce

### TEZDEN TÜRETİLEN YAYINLAR, SUNUMLAR VE PATENTLER:

- **SEZER, Omer Berat; OZBAYOGLU, A. Murat.** Algorithmic Financial Trading with Deep Convolutional Neural Networks: Time Series to Image Conversion Approach. In: Applied Soft Computing, April 2018.
- **SEZER, Omer Berat; OZBAYOGLU, A. Murat.** Financial Trading Model with Stock Bar Chart Image Time Series with Deep Convolutional Neural Networks. In: Intelligent Automation & Soft Computing, Journal, submitted.

- **SEZER, Omer Berat**; OZBAYOGLU, A. Murat; DOGDU, Erdogan. Context Aware Computing, Learning and Big Data in Internet of Things: A Survey. In: IEEE Internet Of Things Journal, February, 2018.
- **SEZER, Omer Berat**; OZBAYOGLU, A. Murat; DOGDU, Erdogan. A Deep Neural-Network based Stock Trading System based on Evolutionary Optimized Technical Analysis Parameters. In: Procedia Computer Science, Complex Adaptive Systems Conference, CAS 2017, October 30 - November 1, 2017.
- **SEZER, Omer Berat**; OZBAYOGLU, Murat; DOGDU, Erdogan. An Artificial Neural Network-based Stock Trading System Using Technical Analysis and Big Data Framework. In: The Annual ACM Southeast Conference Featuring Multidisciplinary and Interdisciplinary Computing , Georgia, USA, 13-15 April, 2017.

#### **DİĞER YAYINLAR, SUNUMLAR VE PATENTLER:**

- ONAL, Aras; **SEZER, Omer Berat**; OZBAYOGLU, A. Murat; DOGDU, Erdogan. Weather Data Analysis and Sensor Fault Detection Using An Extended IoT Framework with Semantics, Big Data, and Machine Learning. In: Big Data, 2017 IEEE International Conference on IEEE, 2017.
- **SEZER, Omer Berat**; DOGDU, Erdogan; OZBAYOGLU, Murat; ONAL, Aras Can. An Extended IoT Framework with Semantics, Big Data, and Analytics. In: IEEE International Conference on Big Data, Washington, DC, USA, 5–8 December, 2016.
- **SEZER, Omer Berat**; CAN, Serdar Zafer; DOGDU, Erdogan. Development of a smart home ontology and the implementation of a semantic sensor network simulator: An Internet of Things approach. In: Collaboration Technologies and Systems (CTS), 2015 International Conference on. IEEE, 2015. p. 12-18.
- **SEZER, Omer Berat**. Implementation and Evaluation of the Dependability Plane for the Dynamic Distributed Dependable Real Time Industrial Protocol (D3RIP). 2013. Master of Science Thesis. Middle East Technical University.
- MUHTAROGLU, Ali; **SEZER, Omer Berat**. A simple self-timed implementation of a priority queue for dictionary search problems. In: Adaptive Science & Technology, 2009. ICAST 2009. 2nd International Conference on. IEEE, 2009. p. 34-39.