



**T.C.
KAHRAMANMARAŞ SÜTÇÜ İMAM ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ
İŞLETME ANA BİLİM DALI**

**HİSSE SENEDİ FİYAT
TAHMİNLERİNDE BİLGİ İŞLEMSEL
ZEKA YÖNTEMLERİ: UZMAN BİR
SİSTEM ARACILIĞIYLA BİST
UYGULAMASI**

Mehmet ÖZÇALICI

DOKTORA TEZİ

**KAHRAMANMARAŞ
OCAK - 2015**



**T.C.
KAHRAMANMARAŞ ST İMAM NİVERSİTESİ
SOSYAL BİLİMLER ENSTİTS
İŞLETME ANA BİLİM DALI**

**HİSSE SENEDİ FİYAT
TAHMİNLERİNDE BİLGİ İŞLEMSEL
ZEKA YNTEMLERİ: UZMAN BİR
SİSTEM ARACILIĞIYLA BİST
UYGULAMASI**

DANIŞMAN: Do. Dr. Ycel AYRIAY

Mehmet ZALICI

DOKTORA TEZİ

**KAHRAMANMARAŞ
Ocak - 2015**

KAHRAMANMARAŞ SÜTÇÜ İMAM ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ
İŞLETME ANA BİLİM DALI

HİSSE SENEDİ FİYAT TAHMİNLERİNDE
BİLGİ İŞLEMSEL ZEKA YÖNTEMLERİ:
UZMAN BİR SİSTEM ARACILIĞIYLA
BİST UYGULAMASI

Mehmet ÖZÇALICI

DOKTORA TEZİ

Kod No :

Bu Tez/...../..... Tarihinde Aşağıdaki Jüri Üyeleri Tarafından
Oy Birliği ile Kabul Edilmiştir.

Doç. Dr. Yücel AYRIÇAY
BAŞKAN

Prof. Dr. Cengiz TORAMAN
ÜYE

Doç. Dr. Mahmut
YARDIMCIOĞLU
ÜYE

Doç. Dr. Haluk DUMAN
ÜYE

Yrd. Doç. Dr. Orhan ERCAN
ÜYE

Yukarıdaki imzaların adı geçen öğretim üyelerine ait olduğunu onaylarım.

Doç. Dr. Abdullah SOYSAL
Enstitü Müdürü

Bu çalışma.....tarafından desteklenmiştir.
Proje No:

Not: Bu tezde kullanılan özgün ve başka kaynaktan yapılan bildirişlerin, çizelge, şekil ve fotoğrafların kaynak gösterilmeden kullanımı, 5846 sayılı Fikir ve Sanat Eserleri Kanunundaki hükümlere tabidir.

KAHRAMANMARAŞ SÜTÇÜ İMAM ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ
İŞLETME ANA BİLİM DALI

ÖZET

DOKTORA TEZİ

**HİSSE SENEDİ FİYAT TAHMİNLERİNDE
BİLGİ İŞLEMSEL ZEKA YÖNTEMLERİ:
UZMAN BİR SİSTEM ARACILIĞIYLA BİST
UYGULAMASI**

Mehmet ÖZÇALICI

Danışman : Doç. Dr. Yücel AYRIÇAY
Yıl : 2015, Sayfa: 144+10
Jüri : Doç. Dr. Yücel AYRIÇAY (Başkan)
: Prof. Dr. Cengiz TORAMAN (Üye)
: Doç. Dr. Mahmut YARDIMCIOĞLU (Üye)
: Doç. Dr. Haluk DUMAN (Üye)
: Yrd. Doç. Dr. Orhan ERCAN (Üye)

Araştırmacılar hisse senedi fiyatlarının teknik analiz değişkenleri ile birlikte önceden tahmin edilmesi ile ilgili çalışmalar yapmışlardır. Yapay sinir ağları hisse senedi fiyat tahmininde başarıyla kullanılan bilgi işlemsel zeka yöntemlerinden bir tanesidir. Yapay sinir ağları ile fiyat tahmini gerçekleştirilirken, hangi değişkenlerin seçileceğine ve ağ mimarisine kullanıcının karar vermesi gerekmektedir. Bu tezde söz konusu parametreleri belirleyecek genetik algoritma tabanlı uzman bir sistem tasarlanmıştır. T gününe ilişkin fiyat ve hacim bilgileri kullanmak suretiyle teknik göstergeler hesaplanmıştır. Özellik seçimi ve parametre optimizasyonu genetik algoritma ile eşzamanlı gerçekleştirilmiştir. Uzman sistem t+1 gününe ilişkin fiyat tahminlerini gerçekleştirmek için kullanılmıştır. Önerilen uzman sistemin, optimize edilmeyen modele göre hem istatistiksel başarı ölçülerine göre hem de alım satım simülasyonu sonucuna göre daha iyi sonuçlar ortaya çıkardığı belirlenmiştir.

Anahtar Kelimeler: Bilgi işlemsel zeka, hisse senedi fiyat tahmini, genetik algoritmalar, yapay sinir ağları, teknik analiz, özellik seçimi

**DEPARTMENT OF BUSINESS AND ADMINISTRATION
INSTITUTE OF SOCIAL SCIENCES
KAHRAMANMARAŞ SÜTÇÜ İMAM UNIVERSITY**

ABSTRACT

PhD Thesis

**COMPUTATIONAL INTELLIGENCE
TECHNIQUES IN FORECASTING STOCK
PRICES: ISE APPLICATION WITH AN EXPERT
SYSTEM**

Mehmet ÖZÇALICI

Supervisor : Assoc. Prof. Dr. Yücel AYRIÇAY
Year : 2015, Pages: 144+10
Jury : Assoc. Prof. Dr. Yücel AYRIÇAY (Chairperson)
: Prof. Dr. Cengiz TORAMAN (Member)
: Assoc. Prof. Dr. Mahmut YARDIMCIOĞLU (Member)
: Assoc. Prof. Dr. Haluk DUMAN (Member)
: Assist. Prof. Dr. Orhan ERCAN (Member)

Researchers are interested with forecasting stock prices using technical indicators. Artificial neural networks are one of the soft computing techniques that is used for forecasting stock prices. The user of the neural network must decide the size of the hidden layer and must select the optimal feature subset to obtain the best forecasting performance from network. In this study an expert system which is based on genetic algorithms is designed to optimize the parameters of the network. Technical indicators are calculated using price and volume information of day t . Feature selection and parameter optimization is handled simultaneously by using genetic algorithms. Expert system is used to forecast closing prices of day $t+1$. The results indicate that optimized model outperformed the alternative model in terms of both statistical and financial performance.

Keywords: Soft computing, stock price forecasting, genetic algorithms, artificial neural networks, technical analysis, feature selection

ÖNSÖZ

Bu tezin hazırlanmasında yardımlarını esirgemeyen danışmanım ve değerli hocam Sayın Yücel AYRIÇAY'a ve ayrıca değerli hocam Mahmut YARDIMCIOĞLU'na teşekkürlerimi sunarım.

Mehmet ÖZÇALICI

Ocak, 2015

İÇİNDEKİLER TABLOSU

ÖZET	I
ABSTRACT	II
ÖNSÖZ	III
İÇİNDEKİLER TABLOSU	IV
KISALTMALAR LİSTESİ	VII
TABLolar LİSTESİ	VIII
ŞEKİLLER LİSTESİ	IX
EKLER LİSTESİ	X
1. GİRİŞ	1
2. KONUS İLE İLGİLİ ÖNCEKİ ARAŞTIRMALAR.....	4
2.1. Hisse Senedi / İndeks Fiyat Hareketlerinin İncelendiği Çalışmalar	6
2.1.1. Eğilimin Tahmin Edildiği Çalışmalar.....	6
2.1.2. Fiyat Tahmininin Gerçekleştiği Çalışmalar	9
2.1.3. Hem Nokta, Hem Fiyat Tahmini Üzerine Çalışmalar	14
2.1.4. Türkiye’de Yapılan Çalışmalar	15
3. HİSSE SENEDİ FİYAT ANALİZ VE TAHMİN YÖNTEMLERİ.....	17
3.1. Hisse Senedi Kavramı ve Ekonomik Önemi.....	17
3.2. Hisse Senedi Türleri.....	18
3.3. Hisse Senetlerinin Sağladığı Haklar	19
3.4. Hisse Senetlerinde Fiyat ve Değer Kavramları	19
3.5. Hisse Senedi Fiyatlarına Etki Eden İki Temel Unsur: Bilgi ve Risk Kavramı.....	20
3.5.1. Bilgi Kavramı	20
3.5.2. Risk Kavramı.....	21
3.5.2.1. Sistematiik Olmayan Risk	21
3.5.2.2. Sistematiik Risk.....	22
3.6. Hisse Senedi Fiyatının Tahmin Edilebilirliğinde Bekleyişlerin Oluşumu	22
3.6.1. Bekleyişlerin Oluşumu	22
3.6.2. Rassal Yürüyüş Hipotezi	23
3.6.3. Etkin Piyasalar Hipotezi (EPH).....	24
3.6.3.1. Etkin Piyasalar Hipotezinin Tanımı	24
3.6.3.2. Etkin Piyasalar Hipotezinin Tarihi	24
3.6.3.3. Etkinlik Çeşitleri.....	25
3.6.3.3.(1). Zayıf Formda Etkinlik	25
3.6.3.3.(2). Yarı Güçlü ve Güçlü Formda Etkinlik	26
3.6.3.4. Farklı Formdaki Etkinlikleri Ölçmek İçin Kullanılan Testler	27
3.6.3.4.(1). Zayıf Formda Etkinlik Testleri:.....	28
3.6.3.4.(2). Yarı Güçlü Formda Etkinlik Testleri.....	29
3.6.3.4.(3). Güçlü Formda Etkinlik Testleri: İçeriden Öğrenenlerin Ticareti	30
3.6.3.4.(4). Borsa İstanbul ’un Etkinliği Üzerine Çalışmalar.....	30
3.6.4. Davranışsal Finans	31
3.7. Hisse Senedi Fiyatlarının Analiz Yöntemleri	31
3.7.1. Temel Analiz	31
3.7.2. Teknik Analiz	32
3.7.2.1. Teknik Analizin İlkeleri	33
3.7.3. Teknik Göstergeler	33
3.7.3.1. Salınım (Oscillators)	34
3.7.3.1.(1). Toplama/Dağıtım Salınımı (ADO).....	34
3.7.3.1.(2). Chaikin Salınımı (CO)	35
3.7.3.1.(3). Hareketli Ortalamalar (HO)	35
3.7.3.1.(4). Hareketli Ortalamaların Birleşmesi Ayrılması (MACD)	36
3.7.3.1.(5). İvme - Acceleration (İVM)	36
3.7.3.1.(6). Momentum (MOM)	36
3.7.3.2. Stokastikler	36
3.7.3.2.(1). Chaikin Dalgalanma (CV).....	37
3.7.3.2.(2). Hızlandırılmış Stokastik %K ve %D (H%K, H%D)	37
3.7.3.2.(3). Yavaşlatılmış Stokastik Y%K ve Y%D	38
3.7.3.2.(4). William's %R Değeri (W%R)	38

3.7.3.3.İndeksler	38
3.7.3.3.(1). Negatif Hacim İndeksi (NHI).....	38
3.7.3.3.(2). Pozitif Hacim İndeksi (PHI).....	39
3.7.3.3.(3). Göreli Güç İndeksi - Relative Strength Index (GGI)	39
3.7.3.4. Göstergeler	40
3.7.3.4.(1). Toplama / Dağıtım Çizgisi (ADL)	40
3.7.3.4.(2). Bollinger Bandı (BB)	41
3.7.3.4.(3). En Yüksek Yüksek Değer (HH).....	42
3.7.3.4.(4). En Düşük Düşük Değer (LL)	42
3.7.3.4.(5). Medyan Fiyat (MF).....	42
3.7.3.4.(6). Denge İşlem Hacmi (On Balance Hacmi (OBV))	42
3.7.3.4.(7). Fiyat Değişim Oranı (Price Rate of Change (PROC))	43
3.7.3.4.(8). Fiyat-Hacmi Trendi (Price-Volume Trend (PVT))	43
3.7.3.4.(9). Tipik Fiyat (TP).....	43
3.7.3.4.(10). Hacim Değişim Oranı (Volume Rate of Change (VROC))	44
3.7.3.4.(11). Ağırlıklı Kapanış Fiyatı (AKF)	44
3.7.3.4.(12). William Toplama/Dağıtım Göstergesi (WAD))	44
3.7.3.5.Teknik Göstergelere Yönelik Eleştiriler	45
3.8. Hisse Senedi Fiyat Tahmin Yöntemleri	45
3.8.1. Genel Olarak Tahmin Süreci	45
3.8.2. İstatistiksel Yöntemler	47
3.8.2.1.Otoregresif Model (AR(p)).....	47
3.8.2.1.(1). Birinci Dereceden Otoregresif Süreç	47
3.8.2.1.(2). P Dereceden Otoregresif Süreç	47
3.8.2.2.Hareketli Ortalamalar Yöntemi (MA(q)).....	47
3.8.2.2.(1). Birinci Dereceden Hareketli Ortalamalar Süreci MA(1)	47
3.8.2.2.(2). Q Dereceden Hareketli Ortalamalar Süreci	48
3.8.2.3.ARMA Modeli (ARMA(p,q))	48
3.8.2.4.ARIMA Yöntemi (ARIMA(p,q,d))	48
3.8.2.5.Regresyon Yöntemi	48
3.8.2.6.Lojistik Regresyon Yöntemi.....	49
3.8.3. Bilgi İşlemsel Zeka Yöntemleri.....	49
3.8.3.1.Yapay Zeka	49
3.8.3.2.Bilgi İşlemsel Zeka Yöntemleri Hakkında Genel Bilgiler.....	50
3.8.3.3.Uzman Sistemler (Expert Systems)	50
3.8.3.4.Yapay Sinir Ağları.....	51
3.8.3.4.(1). Giriş ve Tarihçe.....	51
3.8.3.4.(2). Biyolojik Altyapı.....	53
3.8.3.4.(3). Yapay Sinir Ağı Mimarileri	55
3.8.3.4.(4). Aktivasyon Fonksiyonu Çeşitleri	59
3.8.3.4.(5). Yapay Sinir Ağlarının Eğitimi	60
3.8.3.4.(6). Yapay Sinir Ağlarında Öğrenme Algoritmaları	62
3.8.3.4.(7). Yapay Sinir Ağının Eğitiminde Karşılaşılan Problemler	64
3.8.3.5.ANFIS Yöntemi	66
3.8.3.6.Destek Vektör Makineleri	68
3.8.3.7.Genetik Algoritma	69
3.8.3.7.(1). Genel Olarak Optimizasyon İşlemi	71
3.8.3.7.(2). Genetik Algoritma Terminolojisi	74
3.8.3.7.(3). Genetik Algoritmalarla İşlemler.....	77
3.8.3.7.(4). GA Süreci ve Örneği	84
3.8.3.7.(5). Genetik Algoritmanın Avantajları ve Kısıtları	86
3.8.4. Bilgi İşlemsel Zeka Yöntemlerinin Finansal Piyasalarda Uygulanması.....	86
3.8.4.1.Yapay Sinir Ağlarının Finansal Piyasalardaki Uygulanmaları	86
3.8.4.2.Genetik Algoritmaların Finansal Alandaki Uygulamaları	87
3.8.4.3.Destek Vektör Makinelerinin Finansal Piyasalardaki Uygulamaları	88
3.8.4.4.ANFIS Yönteminin Finansal Piyasalardaki Uygulamaları	88
4. UZMAN BİR SİSTEM ARACILIĞIYLA FİYAT TAHMİNİNDE BIST UYGULAMASI	89
4.1. Uygulamanın Amacı	89
4.2. Uygulamanın Yöntemi	89

4.3. Özellik Seçimi.....	89
4.3.1. Dönüşüm Bazlı Boyut İndirgeme	92
4.3.2. Seçim Bazlı Boyut İndirgeme.....	93
4.4. Model Tasarımı.....	96
4.4.1. Genetik Algoritma Parametreleri.....	96
4.4.1.1.Kromozom Tasarımı.....	97
4.4.1.2.Uygunluk Fonksiyonu	98
4.4.2. Model	99
4.4.3. Modelin Test Edilmesi	101
4.4.3.1.Tahmin Başarı Ölçüleri	101
4.4.3.1.(1). İstatistiksel Başarı Ölçüleri	102
4.4.3.1.(2). Yön Tahmini	103
4.4.3.1.(3). Alım Satım Simulasyonu	105
4.4.3.1.(4). Yön Tahmini ve Alım Satım Simülasyonu Arasındaki İlişki	106
4.5. Uygulama.....	106
4.5.1. Veri Seti ve Değişkenler.....	106
4.5.1.1.Veri Seti.....	106
4.5.1.2.Tahminde Kullanılacak Değişkenler	110
4.5.2. Alternatif Model	111
5. BULGULAR.....	112
5.1. Optimal Nöron Sayıları ve Değişkenler	112
5.1.1. İşlem Süresi	118
5.2. Gerçek Değerler ile Tahmin Edilen Değerlerin Karşılaştırılması	119
5.2.1. İstatistiksel Tahmin Sonuçları	123
5.2.2. Yön Tahmin Sonuçları	125
5.2.3. Alım Satım Simulasyonu Sonuçları	126
5.3. Risk ve Tahmin İlişkisi	127
5.3.1. İstatistiksel Tahmin Sonuçlarının Karşılaştırılması	128
5.3.2. Alım Satım Simulasyonu Sonuçlarının Karşılaştırması	129
6. SONUÇ VE TARTIŞMA	130
KAYNAKLAR	133
ÖZGEÇMİŞ	
EKLER	

KISALTMALAR LİSTESİ

Kısaltma	Türkçe İsim	İngilizce İsim
ADL	Toplama / Dağıtım Çizgisi	Accumulation Distribution Line
ADO	Toplama/Dağıtım Salınımı	Accumulation/Distribution Oscillator
AKF	Ağırlıklı Kapanış Fiyatı	Weighted Close
ANFIS	Sinirsel Bulanık Mantık	Adaptive Neuro-Fuzzy Interface System
AR	Otoregresif Süreç	AutoRegressive Process
ARMA	Otoregresif Hareketli Ortalama	AutoRegressive Moving Averages
ARIMA	Otogresif Bütünleşik Hareketli Ortalama Modeli	Autoregressive Integrated Moving Average
BB	Bollinger Bandı	Bollinger Band
BIST	Borsa İstanbul A.Ş.	Istanbul Stock Exchange
BIZ	Bilgi İşlemsel Zeka	Computational Intelligence
CO	Chaikin Salınımı	Chaikin's Oscillator
CV	Chaikin Dalgalanması	Chaikin Volatility
DVM - SVM	Destek Vektör Makineleri	Support Vector Machines
GA	Genetik Algoritma	Genetic Algorithm
GGI	Görelî Güç İndeksi	Relative Strength Index
HH	Enyüksek Yüksek Değer	Highest High
HO	Hareketli Ortalamalar	Moving Averages
H%K	Hızlandırılmış Stokastik %K	Fast Stochastic %K
H%D	Hızlandırılmış Stokastik %D	Fast Stochastic %D
İVM	İvme	Acceleration
LL	Endüşük Düşük Değer	Lowest Low
MA	Hareketli Ortalamalar	Moving Averages
MACD	Hareketli ortalamaların birleşmesi ayrılması	Moving Averages Converge Distribution
MAPE	Ortalama Mutlak Yüzde Hata	Mean Absolute Percentage Error
MF	Medyan Fiyat	Median Price
MOM	Momentum	Momentum
MSE	Ortalama Karesel Hata	Mean Squared Error
NHI	Negatif Hacim İndeksi	Negative Volume Index
OBV	Denge İşlem Hacmi	On Balance Volume
PCA	Temel Bileşen Analizi	Principle Component Analysis
PHI	Pozitif Hacim İndeksi	Positive Volume Index
PROC	Fiyat Değişim Oranı	Price Rate of Change
PVT	Fiyat Hacim Trendi	Price Volume Trend
RMSE	Ortalama Karesel Hatanın Kökü	Root of Mean Squared Error
SMA	Basit Hareketli Ortalama	Simple Moving Average
SOM	Özdüzenleyici Haritalar	Self Organizing Maps
SVR	Destek Vektör Regresyon	Support Vector Regression
TMA	Üçgensel Hareketli Ortalama	Triangle Moving Average
TP	Tipik Fiyat	Typical Price
VROC	Hacim Değişim Oranı	Volume Rate of Change
WAD	William Toplama/Dağıtım Göstergesi	William Accumulation Distribution
W%R	William %R Değeri	William's %R
YSA - NN	Yapay Sinir Ağları	Neural Network
Y%K	Yavaşlatılmış Stokastik %K	Slow Stochastic %K
Y%D	Yavaşlatılmış Stokastik %D	Slow Stochastic %D

TABLOLAR LİSTESİ

<u>Tablo</u>	<u>Sayfa</u>
TABLO 3.1. Fiyat ve Hacmi Bilgileri Kısaltması.....	34
TABLO 4.1. İkili Sınıflandırma Tablosu	104
TABLO 4.2. Çalışmada Kullanılan Hisse Senetlerinin Kodları Ve İsimleri.....	107
TABLO 4.3. Kapanış Fiyatlarının Tanımlayıcı İstatistikleri.....	109
TABLO 4.4. Çalışmada Kullanılan Değişkenler.....	110
TABLO 5.1. Optimal Nöron, Değişken Sayısı Ve Indisleri.....	112
TABLO 5.2. Değişkenlerin Kullanıldığı Hisse Senetleri	115
TABLO 5.3. Hesaplama Süreleri	118
TABLO 5.4. Gerçek Fiyatlar İle Tahmin Edilen Fiyatlar Arasındaki R - Kare Değerleri	122
TABLO 5.5. Optimal ve Alternatif Modele İlişkin İstatistiksel Performans Ölçüleri.....	123
TABLO 5.6. Hipotez Testi Sonuçları.....	124
TABLO 5.7. Yön Tahmin Sonuçları	125
TABLO 5.8. Getiri Oranları.....	126
TABLO 5.9. Riskli ve Risksiz Hisse Senetleri Sayısı.....	128
TABLO 5.10. Riskli ve Risksiz Grupların İstatistiksel Performansları	129
TABLO 5.11. Riskli ve Risksiz Hisse Senetlerinin Getiri Oranları	129

ŞEKİLLER LİSTESİ

<u>Sekiller</u>	<u>Sayfa</u>
ŞEKİL 3.1. Piyasa Etkinliği (Ross vd., 2003:344).....	25
ŞEKİL 3.2. Dalgalı Hisse Seneedi Fiyat Hareketi (Ross vd., 2003:345).....	26
ŞEKİL 3.3. Farklı Veri Setleri Arasındaki İlişki (Ross vd., 2003:347).....	27
ŞEKİL 3.4. Birikim ve Dağıtım Alanları (Siegel, 2000:10).....	40
ŞEKİL 3.5. Tahmin Sisteminin Kavramsal Yapısı (Abraham ve Ledolter, 2005:4).....	46
ŞEKİL 3.6. Lojistik Regresyon Fonksiyonu.....	49
ŞEKİL 3.7. Bilgi İşlemsel Zeka Yöntemleri (Konar, 2005:6).....	50
ŞEKİL 3.8. Doğrusal Bir Fonksiyon İle Adaline Yapısı (Scarborough ve Somers, 2006: 32).....	52
ŞEKİL 3.9. Biyolojik Nöron Yapısı (ARBİB, 2003:4).....	54
ŞEKİL 3.10. Sinaptik ve Somatik İşlemlerin Gösterimi.....	55
ŞEKİL 3.11. İleri Beslemeli Yapay Sinir Ağları Çeşitleri (Scarborough ve Somers, 2006:41).....	55
ŞEKİL 3.12. Tek Katmanlı ve Tek Nöronlu Yapay Sinir Ağı.....	56
ŞEKİL 3.13. Tek Katmanlı ve Çok Nöronlu Yapay Sinir Ağı Modeli.....	57
ŞEKİL 3.14. Çok Katmanlı ve Çok Nöronlu Yapay Sinir Ağı.....	58
ŞEKİL 3.15. Farklı Transfer Fonksiyonları.....	60
ŞEKİL 3.16. Bulanık Mantık İçin Üyelik Fonksiyonu Örnekleri (Jang VD., 1997:17).....	66
ŞEKİL 3.17. Bulanık Çıkarım Sistemi (Jang, 1993: 666).....	67
ŞEKİL 3.18. ANFIS Mimarisi (Jang vd., 1997:336).....	67
ŞEKİL 3.19. Doğrusal Olmayan Bir Düzlem ve Doğrusal Bir Düzlem (Nisbet vd., 2009:164).....	68
ŞEKİL 3.20. Marjın Ve Destek Vektörler (Alpaydın, 2010: 314).....	69
ŞEKİL 3.21. Genetik Algoritmaların Temel Presüdüğü (Gen ve Cheng, 2000: 1).....	70
ŞEKİL 3.22. Genetik Algoritmaların Temel Yapısı (Sakawa, 2002: 15).....	73
ŞEKİL 3.23. Genotip Ve Fenotip Kavramlarının Şema İle Gösterimi.....	74
ŞEKİL 3.24. Kromozomun Şema İle Gösterimi.....	74
ŞEKİL 3.25. Gen Kavramının Şema İle Gösterimi.....	75
ŞEKİL 3.26. Populasyon Kavramının Şema İle Gösterimi.....	76
ŞEKİL 3.27. Genetik Algoritmalarda Seçim İşlemi (Svanandam Ve Deepa, 2008: 46).....	79
ŞEKİL 3.28. Rulet Tekerleği Seçim Süreci (Sakawa, 2002: 20).....	79
ŞEKİL 3.29. Rulet Tekerleği Seçim Modeli (Sakawa, 2002: 20).....	80
ŞEKİL 3.30. Stochastic Uniform Seçim Modeli (Svanandam Ve Deepa, 2008: 50).....	80
ŞEKİL 3.31. Genetik Algoritmalarda Tek Noktalı Çaprazlama İşlemi.....	82
ŞEKİL 3.32. Genetik Algoritmalarda İki Noktalı Çaprazlama İşlemi.....	82
ŞEKİL 3.33. Genetik Algoritmalarda Mutasyon İşlemi.....	84
ŞEKİL 4.1. Boyut İndirgeme Yöntemlerinin Sınıflandırılması (Jensen ve Shen, 2008: 62).....	90
ŞEKİL 4.2. İlgili ve İlgisiz Özellikler (Kohavi ve John, 1997: 298).....	91
ŞEKİL 4.3. Genel Olarak Özellik Seçimi.....	92
ŞEKİL 4.4. Özellik Seçiminin Farklı Boyutları (Jensen ve Shen, 2008: 67).....	93
ŞEKİL 4.5. Özellik Seçim Süreci (Dash ve Liu, 1997:133).....	94
ŞEKİL 4.6. Özellik Seçiminde Wrapper Ve Filtre Yaklaşımı (Jensen ve Shen, 2008: 68).....	95
ŞEKİL 4.7. Wrapper Yaklaşımının Şematik Gösterimi (Kohavi ve John, 1997: 274).....	95
ŞEKİL 4.8. Çalışmada Kullanılan Gen Tasarımı.....	97
ŞEKİL 4.9. Çalışmada Kullanılan Uygunluk Fonksiyonunun Şema İle Gösterimi.....	98
ŞEKİL 4.10. Uzman Sistemin Ana Hattı.....	100
ŞEKİL 4.11. Uzman Sistemin Detaylı Şeması.....	101
ŞEKİL 4.12. Alım Satım Algoritmasının Sahte Kodu.....	105
ŞEKİL 4.13. Çalışmada Kullanılan Veri Setinin Elde Edilmesi.....	109
ŞEKİL 5.1. Optimal Nöron Sayıları.....	114
ŞEKİL 5.2. Optimal Değişken Sayısı.....	114
ŞEKİL 5.3. Değişkenlerin Kullanıldığı Senet Sayısı.....	117
ŞEKİL 5.4. EKGYO İsimli Hisse Senedinin Eğitim Süreci.....	120
ŞEKİL 5.5. TUPRS Hisse Senedine İlişkin Tahmin Edilen ve Gerçek Fiyatlar.....	121
ŞEKİL 5.6. YKBNK Hisse Senedi Dağılım Grafiği.....	122
ŞEKİL 5.7. Optimal ve Alternatif Modelde Kar ve Zarar Durumu.....	127

EKLER LİSTESİ

Ekler

EK 1. Eğitim Veri Seti Şekilleri

EK 2. Test Veri Seti Şekilleri

EK 3. Test Veri Seti Dağılım Grafikleri

1. GİRİŞ

Hisse senedi fiyatlarını önceden tahmin etmek spekülâtörler, yatırımcılar ve işadamları için önem taşır. Hisse senedi fiyatlarının ne olacağının önceden tahmin edilmesi sadece spekülâtif amaçlı alım satım yapan yatırımcılar için değil aynı zamanda, firma değerinin maksimizasyonunu amaç edinmiş finansal yöneticiler için ve genel olarak da bütün ekonomi için önem arz etmektedir. Ayrıca birçok farklı bilim dalında uzmanlaşan araştırmacılar, uzmanlık alanlarındaki gelişmeleri hisse senedi fiyat tahminlerindeki doğruluk oranını arttırmak için kullanılmaktadırlar. Bilgisayar teknolojisindeki gelişmeler ile birlikte yeni analizler ortaya çıkmış ve söz konusu analizler hisse senetlerinin tahmininde kullanılmaya başlanmıştır.

1970’li yıllarda ortaya çıkan Etkin Piyasalar Hipotezi sermaye piyasalarının temel hipotezlerinden biri olmuştur. Bu hipoteze göre, hisse senedi fiyatlarını önceden tahmin etmeye çalışmanın bir faydası yoktur; çünkü fiyatlar tamamen rassal bir şekilde oluşmaktadır. Başka bir ifade ile fiyatlar, önceki fiyatlardan bağımsız bir şekilde oluşmaktadır.

Hipotez literatüre tanıtıldıktan sonra, hisse senetlerinin fiyatlarının tahmin edilebilirliğini araştıran bir çok çalışma ortaya çıkmıştır. Çalışmalardan bazılarında hisse senetlerinin fiyatlarının etkin piyasa hipotezinin doğru olamayacağını ima edecek düzeyde başarılı bir şekilde tahmin edilebildiği raporlanmaktadır.

Hisse senedi fiyatlarını tahmin etmek için başlangıçta geleneksel istatistiksel yöntemler kullanılmıştır. Söz konusu yöntemlerden bazıları AR, MA ve ARIMA gibi yöntemleridir. Fakat bu yöntemler veri seti hakkında istatistiksel varsayımları şart koşturmaktadır. Başka bir ifade ile yöntemlerin kullanılabilmesi için veri setinde bazı şartların sağlanması gerekmektedir. Bu nedenle tahmin performansları kısıtlıdır (Hsieh vd, 2011).

Son zamanlarda ise; yapay sinir ağları, genetik algoritmalar, destek vektör makineleri ve bulanık tabanlı ağ çıkarım sistemi gibi bilgi işlemsel zeka yöntemleri (computational intelligence) geliştirilmiş ve bu yöntemler hisse senedi fiyat tahmininde kullanılmaya başlanmıştır. Bilgi işlemsel zeka yöntemleri, geleneksel istatistiki yöntemlerini yetersiz kılacak kadar karmaşık gerçek hayat problemlerini çözmeye çalışan ve doğadan esinlenen hesaplama yöntemleridir. Bilgi işlemsel zeka yöntemlerini kullanan çalışmalarda elde edilen başarılar etkin piyasalar hipotezi ile çelişir niteliktedir. Bu tür çalışmalarda, hisse senetlerinin başarılı bir şekilde tahmin edilebileceği ve etkin piyasalar hipotezinin geçerli olmadığı savunulmaktadır (Atsalakis ve Valavanis, 2009; Atsalakis vd., 2011; Chang vd., 2012).

Bilgi işlemsel zeka yöntemlerinden olan yapay sinir ağları hisse senedi fiyatında başarılı bir şekilde kullanılmıştır. Fakat yapay sinir ağlarının hisse senedi fiyatındaki performansı yanında, uygulanmasını zorunlu kılan bazı ayrıntıları söz konusudur. Bu ayrıntılar, özellik seçimi, yapay sinir ağı mimarisine karar verme ve ağı eğitimi gibi hususlardır. Bu ayrıntılar yapay sinir ağlarının performansı ile yakından ilgilidir.

Başarılı bir hisse senedi fiyat tahminin gerçekleştirilmesi için modelde kullanılacak özelliklerin (girdilerin) belirlenmesi yapay sinir ağları ile yapılacak tahminlerde bir diğer önemli mesele olmaktadır. Girdi olarak temel analiz veya teknik analiz değişkenleri kullanılabilir. Temel analiz değişkenlerinde, enflasyon, gayri safi milli hasıla, döviz kurları gibi makroekonomik göstergelerin yanı sıra, işletme mali tablolarından çıkarılan bilgiler de kullanılmaktadır. Teknik analizde ise geçmiş fiyat bilgilerinden bazı göstergeler elde edilmektedir. Teknik analiz, geçmiş fiyat ve işlem hacmi bilgilerini kullanmak yoluyla, ticaret ve yatırım kararlarında kullanılacak bilgilerin

ortaya çıkarılmasıdır (Kirkpatrick ve Dahlquist, 2007: 3). Teknik analiz kuralları çok fazla sayıdadır ve sıradan bir yatırımcının hangi hisse senedi için hangi teknik analiz kuralının uygulanması gerektiğini belirlemesi zordur (Lin X. vd., 2011). Hesaplanacak teknik göstergelerin bir kısmının tahmin modelinin başarısı ile ilgisi olmayabilir veya bir anlam ifade etmeyen değişkenler olabilir. Bu tür fazla (redundant) değişkenlerin kullanılması yapay sinir ağları gibi makine öğrenmesi modellerinin yanlış sonuçlar ortaya çıkarmasına neden olabilir (Huang vd., 2008). Bu nedenle en doğru değişken alt kümesinin seçilmesi gerekmektedir. Üstelik A hisse senedi fiyatının tahmininde faydalı olabilecek bir değişken, B hisse senedinin fiyatının tahmin modelinde kullanıldığında aynı başarıyı ortaya çıkarmayabilir. Dolayısıyla hisse senetlerinin fiyatlarının tahmin edilmesi çalışmasında kullanılacak girdi değişkenlerinin belirlenmesi önem arz etmektedir. Var olan değişkenler arasından en iyi alt kümenin seçilmesi işlemi tipik bir özellik alt kümesi seçim (feature selection) problemidir.

Değişken seçiminin yanı sıra, tahmin modelinin başarılı bir şekilde sonuçlanması için kullanılan analizin parametrelerine de isabetli bir şekilde önceden karar vermek gerekmektedir. Örneğin bilgi işlemsel zeka yöntemlerinden yapay sinir ağları, hisse senedi fiyat tahmininde başarılı bir şekilde kullanılmıştır (Armano vd., 2005; Charkha, 2008; Li ve Liu, 2009; Mostafa, 2010; Ok vd., 2011; Salehi vd., 2011). Literatürde yapılan çalışmalar incelendiğinde ara katmandaki nöron sayısının deney tasarımı veya deneme yanılma yoluyla belirlendiği gözlenmektedir. Başarılı bir hisse senedi tahmin performansı için nöron sayısının önceden belirlenmesi ve modelin buna uygun kullanılması önem arz etmektedir. Yapay sinir ağı mimarisi, hesaplamanın karmaşıklık düzeyini ve genelleştirme yeteneğini doğrudan etkilemektedir (Pattamavorakun ve Pattamavorakun, 2007). Parametreler belirlenirken, herkes tarafından kabul edilen ve açık bir yöntem olmadığı için, yapay sinir ağları kullanılırken parametre belirleme önemli bir problem olmaktadır (Bashiri ve Geranmayeh, 2011).

Yapay sinir ağları ile çalışırken karşılaşılan en önemli meselelerden bir diğeri de çalışmada aşırı uyum (overfitting) durumunun ortaya çıkabilmesidir. Aşırı uyum, yapay sinir ağı modelinin eğitim setine aşırı derecede iyi uyum sağlayan ağırlıkları belirlemesi ve farklı bir veri seti ile karşılaştığında çok kötü performans göstermesi durumudur. Başka bir ifade ile aşırı uyum durumunda, yapay sinir ağı modelinin genelleştirme yeteneği azalmaktadır. Yapay sinir ağı ile yapılacak bir tahmin faaliyetinde bu durumun oluşmasını engelleyecek önlemlerin alınması gerekmektedir.

Özet olarak yapay sinir ağı modeli ile başarılı bir hisse senedi fiyatı tahmin işlemi gerçekleştirmek için, kullanılacak değişkenlere, yapay sinir ağı mimarisine ve aşırı uyum olumsuzluğunu engelleyecek bir yönteme ihtiyaç duyulmaktadır. Bu olumsuzlukların hepsini ortadan kaldıracak mevcut bir yöntem söz konusu değildir. Bu çalışmanın amacı bilgi işlemsel zeka ailesinin bir üyesi olan genetik algoritmalar ile söz konusu eksiklikleri giderecek uzman bir sistem tasarlamaktır. Genetik algoritma, sezgisel bir optimizasyon yöntemidir (Svanandam ve Deepa, 2008) ve çözüm uzayında yer alan olası bütün çözümlerden en iyisinin seçilmesini sağlar. Söz konusu bu sistemde uygunluk fonksiyonu, aşırı uyum durumunu engelleyecek şekilde tasarlanmıştır. Aynı şekilde yapay sinir ağı ara katmanında yer alan nöron sayısını ve kullanılacak değişken miktarını eşzamanlı belirleyebilecek bir gen tasarlanmıştır. Tasarlanan bu sistem kullanıcının yapay sinir ağları modeline mümkün olduğunca az müdahale ettiği uzman bir sistemdir.

Çalışmada önerilen modelin ne kadar iyi performans gerçekleştirdiğini ortaya çıkarmak için ikinci bir model daha kullanılmıştır. Bu model alternatif model olarak adlandırılmıştır ve bir seçim işlemi uygulanmadan bütün değişkenler modelde girdi olarak kullanılmıştır. Ayrıca ara katmandaki nöron sayısı da 10 tanede sabit tutulmuştur.

Fiyat tahmini gerçekleştirildikten sonra, model sonuçlarının ne kadar iyi olduğu farklı açılardan incelenmiştir. Modellerin sonuçları, istatistiksel performans ölçüleri ve yön tahmin sonuçları ile incelenmiştir. Modelin ürettiği fiyat tahminlerini dikkate alan bir yatırımcının dönem sonunda elde edeceği getiri yüzde olarak da hesaplanmıştır. Böylelikle çalışmadaki sistemin finansal başarı ölçüsü de hesaplanmış olmaktadır.

Çalışma, giriş ve sonuç kısımları dahil altı kısımdan oluşmaktadır. Konu ile ilgili önceki çalışmaların incelendiği üçüncü kısmın ardından, modelin tanıtıldığı dördüncü bölüm yer almaktadır. Beşinci bölümde yapılan analizin bulgularına yer verilmiştir. Altıncı bölümde ise sonuç ve tartışma yer almaktadır.

2. KONU İLE İLGİLİ ÖNCEKİ ARAŞTIRMALAR

Bu bölümde hisse senedi fiyat tahmini üzerinde yapılmış olan çalışmalar incelenenektir.

Hisse senedi fiyatlarının rastgele oluştuğunu savunan etkin piyasa hipotezine göre hisse senedi fiyatlarının önceden tahmin edilmesi mümkün değildir. Ancak literatürde yapılan çalışmalar incelendiğinde hisse senedi fiyatının önceden tahmin edilmesi çabalarının aktif bir şekilde sürdüğü görülmektedir. Bunun nedeni bilgi işlemsel zeka ve yapay zeka alanındaki gelişmelerdir. Çok fazla sayıda işlemin hızlı bir şekilde yapılabilmesi, tarihsel hisse senetleri fiyat hareketlerinde bazı örüntülerin keşfedilebileceğine ilişkin çalışmalara ilham kaynağı olmuştur.

Hisse senedi fiyat tahmini ile ilgili çok fazla sayıda çalışma yapıldığı görülmektedir. Bu alanda henüz tatmin edici bir kesinliğe ulaşılmadığından, teknik analiz yardımıyla hesaplanabilecek değişkenlerin kullanılması ile fiyatların önceden tahmin edileceğini savunanlar tarafından yapılan çalışmalar devam etmektedir.

Hisse senedi fiyat hareketlerini önceden tahmin etmeye yönelik yapılan çalışmalar iki grupta incelenmiştir. Bu gruplar şu şekildedir:

- **Gelecekteki fiyatı/indeksi tahmin etmeye yönelik çalışmalar:** Bir sonraki tahmin periyodunda fiyatın veya indeksinin alacağı değerin tahmin edilmesine yönelik yapılan çalışmalardır. Bu gruptaki çalışmalarda kullanılan başlıca analizler Sinirsel Bulanık Mantık (ANFIS), Destek Vektör Regresyon (Support Vector Regression – SVR), Yapay Sinir Ağları (Artificial Neural Networks – NN) ve Regresyon yöntemleridir.
- **Fiyat/indeks eğiliminin tahmin edildiği çalışmalar:** Bir sonraki tahmin aralığında fiyattaki veya endeksteki hareketin yönünü tahmin etmeye yönelik çalışmalardır. Yön tahmininin gerçekleştirildiği çalışmaların esas dayanak noktası; hisse senedi fiyatlarının birebir tahmin edilmesi (nokta tahmini) nin zor olacağı buna karşılık yön tahminlerinde tahmin başarısının artabileceği düşüncesidir. Bu gruptaki çalışmalarda ise genellikle Destek Vektör Makineleri (Support Vector Machines – SVM), NN ve Lojistik Regresyon gibi sınıflandırma yöntemlerinin kullanıldığı gözlemlenmektedir.

Literatürde, hisse senetleri ile ilgili yapılan çalışmalarda ortak amaç elde edilecek başarı oranının artırılmasıdır. Bu konuda çalışan araştırmacılar, çalışmalarında dünyanın farklı ülkelerinde faaliyet gösteren hisse senedi piyasalarındaki verileri kullanmaktadırlar. Yapılan çalışmalar incelendiğinde, tahmin çalışmalarında araştırmacının karar vermesi gereken bir çok noktanın ön plana çıktığı anlaşılmaktadır. Literatürde yapılan 60'dan fazla uygulama makalesi incelendikten sonra tespit edilen ana konular aşağıda maddeler halinde sıralanmıştır:

- **Kullanılacak veri setinin boyutu:** Araştırmada kullanılan veri setinin miktarına araştırmacı karar vermelidir. NN, SVM ve ANFIS gibi yöntemlerde veri setinin genelde iki gruba ayrıldığı görülmektedir. Bu gruplar eğitim ve test aşaması olarak adlandırılmaktadır. Eğitim veri setinde yer alan veriler kullanılmak suretiyle tahmin modeli kurulmaktadır. Oluşturulan bu modelin gerçek hayatta ne kadar yüksek performans sergileyeceği ise test veri setinde, modelin uygulanması ve gerçekleşen fiyatlarla karşılaştırılması yoluyla ölçülmektedir. Bazı araştırmalarda ise doğrulama (validation) adı altında bir veri setinin daha kullanıldığı görülmektedir. Doğrulama veri seti eğitim veri setinin bir alt kümesi olarak düşünülebilir. Eğitim veri seti kullanılmak yoluyla, doğrulama veri setinde en iyi

sonucu veren parametreler belirlenir ve test veri seti ile model test edilir. Bazı araştırmalarda ise burada anlatılan veri seti gruplarından test ve doğrulama veri setinin isimlerinin karşılıklı değiştirilmek suretiyle kullanıldığı da görülmektedir. Araştırmacı, gerçekleştireceği deneyinde eğitim amacı ile kullanacağı veri setinin ne kadarlık süreyi kapsayacağını ve oluşturulan bu modelin ne kadarlık bir süreyi kapsayan bir veri seti ile test edileceğini belirlemek durumundadır. Kullandığı analizinde doğrulama veri setini kullanacaksa bu durumda ne kadar süreyi kapsayan bir veriye ihtiyaç duyacağını belirlemek durumundadır. Literatürde genellikle veri setinin eğitim ve test veri olarak %80/%20 oranında veya %70/%30 oranlarında ayrıştırıldığı görülmektedir.

- **Ön işleme (pre-processing):** Ön işleme veri setinin başka bir veri setine dönüştürülmesini kapsamaktadır. Çalışmalarda sıklıkla veri setinin, belirli aralıktaki yeni veri setine doğrusal dönüştürülme işleminin kullanıldığı görülmektedir. Ayrıca bazı çalışmalarda girdi olarak kullanılan veri setine ayrıklaştırma (discretization) işleminin uygulandığı görülmektedir (Kim ve Han, 2000). Ayrıklaştırma yönteminde sayısal olan veriler gruplara ayrıştırılmaktadır. Veri setinin wavelet transform dönüşümünün gerçekleştirildiği çalışmalar da literatürde yer almaktadır (Atsalakis vd., 2011; Wang vd., 2011; Homayouni ve Amiri, 2011; Nourani vd., 2012). Wavelet transform (dalgaçık dönüşümü) veri setinin farklı frekanslara ayrıştırılmasıdır.
- **Analiz için kullanılacak yöntem:** Çalışmada fiyat tahmininde kullanılacak analiz yönteminin önceden belirlenmesi gerekmektedir. Ekonometrik modellerden ARIMA kullanılabileceği gibi bilgi işlemsel zeka yöntemlerinden NN, SVM veya ANFIS kullanılabilir. Çalışmalarda aynı zamanda melez yöntemlerin kullanıldığı da görülmektedir. Bu tür çalışmalarda birden fazla analiz yöntemi kullanılmaktadır. Esas fiyat tahminin gerçekleştiren yöntemin yanı sıra bazı yardımcı yöntemler kullanılmaktadır. Bu tür çalışmalara (Hsu vd., 2009) örnek olarak verilebilir.
- **Tahmin aralığı:** Çalışmalarda kullanılacak zaman aralığını belirlenmesi gerekmektedir. Çalışmaların büyük çoğunluğu bir gün sonraki fiyatı tahmin etmeye yöneliktir. Ancak bir hafta veya bir aylık tahminlerin gerçekleştirildiği çalışmalara da literatürde rastlanmaktadır. Bunların yanında daha kısa periyotları kapsayan (örneğin dakikalık) tahminlerin yapılması da mümkündür.
- **Tahmini gerçekleştirecek analizin parametreleri:** Tahmini gerçekleştirecek analizin parametrelerinin belirlenmesi gerekmektedir. Parametrelerin belirlenmesinde en sık kullanılan yöntemlerden bir tanesi deneme yanılma yöntemidir. Eğer parametre deneme yanılma yolu ile belirlenecekse bu durumda amaç fonksiyonu önemli olmaktadır. Bazı çalışmalarda belirlenen aralıktaki bütün parametre bileşenleri denenmekte ve belirlenen amaca uygun olarak en iyi sonucu veren parametre bileşimi seçilmektedir.
- **Tahmini gerçekleştirecek veriler (Input Series):** Analizlerde girdi olarak kullanılacak veri setine karar verilmesi önemli olmaktadır. Yapılan çalışmalarda tahmin edilecek hisse senedi veya indeksin kapanış fiyatının a) önceki kapanış fiyatları, b) önceki kapanış, açılış, en düşük, en yüksek fiyatları, c) önceki fiyat ve işlem hacmi bilgisi kullanmak suretiyle hesaplanan teknik göstergeler d) temel göstergeler, e) firmaya ait finansal oranlar, f) makroekonomik göstergeler yardımıyla tahmin edilmeye yönelik çalışmalar yapıldığı görülmektedir.
- **Kaç tane girdi değişkeninin kullanılacağı belirlenmesi:** İncelenen çalışmalarda farklı sayılarda girdi miktarının kullanıldığı görülmektedir. Burada

bir fikir birlikteliği söz konusu değildir. Kaç tane girdi değişkeninin kullanılacağı ve tahminin buna göre yapılacağı konusuna karar verilmesi gerekmektedir.

2.1. Hisse Senedi / Indeks Fiyat Hareketlerinin İncelendiği Çalışmalar

Hisse senedi fiyatı konusunda yapılan çalışmalar incelendiğinde, çalışmaların iki grupta kutuplaştığı gözlemlenmektedir. Bunlar hisse senedi veya indeksin doğrudan tahmin edildiği ve hisse senedi veya indeksteki hareketin yönünün tahmin edilmeye çalışıldığı çalışmalardır. Hisse senedindeki yönün tahmin edildiği çalışmaların esas çıkış noktası, hisse senedi fiyatının nokta tahminin gerçekleştirilmesinin oldukça güç olması ve yönün daha kolay tahmin edilebileceğidir. Buna göre, örneğin, “hisse senedinin fiyatı yarın 5.26 TL olacaktır” tahmini yerine “hisse senedinin kapanış fiyatı yarın, bugünkünden daha yüksek düzeyde olacaktır” yönünde yapılacak tahminin doğruluğunun daha yüksek olacağına inanılmaktadır.

2.1.1. Eğilimin Tahmin Edildiği Çalışmalar

Hisse senetlerinde farklı sayılarda girdi değişkenlerinin veya teknik göstergelerin kullanılabilmesi mümkündür. Fakat, bu değişkenlerden sadece bazılarının kullanılması tahmin yeteneğini arttırabilir. Bu nedenle Kim ve Han (2000) çalışmalarında genetik algoritmalarla uygun değişkenlerin seçilmesi yoluyla tahmin performansının arttırılabileceğini önermektedir. Ocak 1989 ile Aralık 1998 arasında Korea Stock Price Index değerleri bir araya toplanmış ve toplamda 2928 adet gözlem elde edilmiştir. Veri seti [0.0, 1.0] arasında doğrusal dönüşüme tabi tutulmuştur. Genetik algoritmalar çalışmada sadece öğrenme algoritmasındaki ağırlıkların optimizasyonunda değil, aynı zamanda uygun değişkenlerin seçilmesinde de kullanılmaktadır. Ortalama %61,70 oranında doğru tahmin söz konusudur.

Kim (2003) yılında yayınladığı çalışmasında, Korea Composite Stock Price Index değerini, destek vektör makineleri ile tahmin etmeye çalışmıştır. 12 adet teknik gösterge girdi değişkeni olarak kullanılmıştır. Ocak 1989 ile Aralık 1998 arasında, 2928 gözlemi kullanmıştır. Eğitim setinde 2347 adet gözlem söz konusuyken, test aşamasında 581 adet gözlem kullanmışlardır. Veri setini [-1.0, 1.0] arasında ölçeklendirmişlerdir. Eğitim aşamasında %58,52 oranında, test aşamasında ise %54,73 oranında geri beslemeli yapay sinir ağları ile doğru tahmin gerçekleştirebilmişlerdir. Buna karşılık destek vektör makineleri ile %64,75 oranında eğitim aşamasında, %57,83 oranında ise test aşamasında doğru tahmin gerçekleştirebilmişlerdir.

Kim ve Lee (2004), çalışmalarında hisse senedi piyasasını yapay sinir ağları ile tahmin etmektedirler. Çalışmalarında genetik algoritmalar özellik dönüştürmede kullanılmıştır. Çalışmalarında günlük KOSPI indeksini kullanmışlardır ve toplamda 2348 adet veri kullanmak suretiyle çalışmalarını gerçekleştirmişlerdir. Çalışmalarında teknik göstergeleri kullanmaktadırlar. Ayrıca discretization yöntemini kullanmak suretiyle girdi veri setini kategorilere ayırmışlardır. Doğrusal ve bulanık dönüştürme yöntemlerini ayrı ayrı kullanmışlardır ve bulanık yöntemin doğrusal yöntemle göre daha iyi sonuç verdiğini bulmuşlardır. Genetik algoritma tabanlı kategorileştirme yöntemi ile birlikte veri setinin boyutu azaltılmış ve böylelikle genelleştirme özelliğinin arttığını raporlamışlardır.

Eğim tahmini yapılan çalışmalardan bir diğeri de Huang vd. (2005) ait olan çalışmadır. Nikkei 225 indeksinin haftalık tahminini destek vektör makineleri ile gerçekleştirmişlerdir. Bir gün sonraki fiyat yönündeki değişimi tahmin etmek için S&P 500 ve ABD doları ve Japon yeni arasındaki değişimi oranı girdi değişkenleri olarak

kullanılmıştır. 1 Ocak 1990 ile 31 Aralık 2012 arasındaki 676 adet haftalık gözlem kullanılmıştır. %75 oranına varan doğru tahminlerde bulunmuşlardır.

Yu vd. (2005) yaptıkları çalışmada destek vektör makineleri ile hisse senedi tahmin yönü yapılırken kullanılacak değişkenlerin genetik algoritmalar ile belirlendiği melez bir yöntem önermektedirler. S&P 500 indeksi tahmin edilmeye çalışılmıştır. 18 adet teknik gösterge başlangıç girdi kümesi olarak belirlenmiştir. Kullanılan veri seti 1 Ocak 2000 ile 31 Aralık 2004 süresini kapsamaktadır. Önerdikleri yöntem, %84 oranında doğru tahminler gerçekleştirebilmiştir.

Hisse senedi tahmininde yapay sinir ağları ve çeşitlerinin kullanıldığı çalışmalardan bir tanesi de Afolabi ve Olude (2007) 'a aittir. Çalışmalarında Backpropagation, SOM ve melez SOM adını verdikleri yöntemleri hisse senetlerinin ne zaman alınıp satılacağını belirlemek için kullanmışlardır. Melez SOM yönteminin diğer yöntemlere göre daha iyi sonuç verdiğini raporlamaktadırlar. Çalışmalarında Lucent firmasına ait günlük fiyat hareketlerini kullanmışlardır. Kasım 1998 ile Kasım 2003 periyodunda 1251 adet güne ilişkin veri setini kullanmışlardır.

Yıldız vd. (2008) çalışmalarında, yapay sinir ağlarını, BIST 100 endeksini bir gün sonraki yönünü tahmin etmede kullanmışlardır. Girdi olarak en yüksek, en düşük, kapanış fiyatı ve TL-Dolar kuru gibi değişkenler kullanılmıştır. Çıktı değişkeni ise bir gün sonraki indeks yönüdür. Eğer indeksin yönü bir gün sonra bugünkünden daha yüksek olarsa, çıktı değeri "1" olmaktadır. Eğer yarınki indeks değeri bugünkünden daha düşükse bu durumda çıktı değeri "0" olmaktadır. 1805 gözlem yapay sinir ağının eğitimi için kullanılırken, 100 adet gözlem ise modelin performansını karşılaştırmak için kullanılmıştır. Çalışmalarında %54,37 oranında doğru tahmin gerçekleştirebilmişlerdir.

Korea ve Taiwan Stock Market indekslerine ilişkin eğim tahminlerle ilgili çalışmalardan bir tanesi Huang vd. (2008) tarafından gerçekleştirilmiştir. Haziran 1990 ile Mayıs 1991 periyodu ile 365 günlük bir veri seti üzerine tahmin modeli gerçekleştirilmiştir. Gözlem veri seti 294 gün ve test veri seti 71 günden oluşmaktadır. Toplamda 23 adet teknik gösterge hesaplanmıştır ve hesaplanan bu teknik göstergeler destek vektör makineleri ile yapılan tahminde en iyi sonucu verecek wrapper değişken seçimi yöntemi ile seçime tabi tutulmuştur. %80,28 oranına kadar doğru tahmin gerçekleştirebilmişlerdir.

Atsalakis ve Valavanis (2009) yılında yaptıkları çalışmada hisse senetlerindeki fiyat değişimlerini kısa dönemli olarak önceden tahmin etmeye çalışmışlardır. Çalışmalarında, Gaussian-2 tipli üyelik fonksiyonunun yer aldığı ANFIS metodolojisini kullanmışlardır. Çalışmalarında Atina ve New York Borsalarında işlem gören beş adet hisse senedine ait veriler, kullanmışlardır. Çalışmalarında girdi olarak geçmiş fiyat hareketlerinden (15 adet farklı kombinasyon) faydalanmışlardır. Çalışmalarının sonunda, geçmiş fiyat hareketlerinin kullanılması yoluyla, gelecekteki fiyat hareketlerinin doğrulukla tahmin edebileceği ortaya çıkmıştır. Test veri setini kısa dönemli periyodlar halinde kullanmışlar ve fiyat hareketlerini %56,60 ile %68,33 oranında doğrulukla tahmin edebilmişlerdir. Çalışmalarında ayrıca alım-satım simülasyonu (trading simulation) kullanmışlardır ve benzetim sonuçları da aktif alım-satımın karlı olduğunu göstermektedir.

Değişken seçimi ile ilgili gerçekleştirilen bir diğer çalışma ise Lee (2009) 'ye aittir. Çalışmasında filter ve wrapper yöntemlerinin optimal değişken kümesinin seçimindeki avantajlarını birleştirmiştir. Tahmin metodu olarak destek vektör makineleri ve geri beslemeli yapay sinir ağları kullanılmıştır. Destek vektör makinelerinin, yapay sinir ağlarından daha iyi performans sergiledikleri ortaya çıkmıştır. NASDAQ indeksinin yönü

çalışmasında tahmin edilmeye çalışılmıştır. 29 adet teknik gösterge hesaplanmıştır. %85 oranında, destek vektör makineleri ile tahmin gerçekleştirilebilmiştir.

Tsai ve Hsiao (2010), çalışmalarında ideal bir hisse senedi fiyat tahmini için özellik seçimi üzerinde durmuşlardır. Yazarlar farklı özellik seçim yöntemlerini kullanmışlar ve modellerin performanslarını karşılaştırmışlardır. Çalışmalarında temel ve makroekonomik göstergeleri kullanmışlardır. Toplamda 85 adet gösterge belirlemişlerdir. Çalışmalarında kullanılan özellik seçim yöntemleri ise genetik algoritmalar, Temel Bileşen Analizi (PCA) ve karar ağaçlarıdır. Çalışmalarında birden fazla özellik seçim modellerinin, tek bir adet özellik seçimi uygulanan modellere göre daha iyi sonuç verdiğini raporlamaktadırlar.

Cheng ve arkadaşları (2010) yayınladıkları çalışmalarında rough set teori ve genetik algoritma tabanlı bir hisse senedi fiyat tahmin modeli geliştirmişlerdir. Çalışmalarında altı yılı kapsayan Taiwan Stock Exchange Capitalization Weighted Stock Index veri setini kullanmışlardır. Çalışmanın sonucunda, önerdikleri yöntemin, tekbaşına rough set teorisi yöntemi veya genetik algoritma yönteminin kullanımına göre elde edilen sonuçlardan daha başarılı sonuçlar üretebildiği ve bu sonuçların alım satımda kullanılması sonucu daha yüksek kar elde edilebildiğini raporlamaktadırlar.

Abolhassani ve Yaghoobi (2010) yılında yayınladıkları çalışmalarında, hisse senedi fiyatı tahmininde SVM yöntemini kullanmışlardır. Özellik seçimi için “particle swarm optimization” tekniğini kullanmışlardır. Yaptıkları çalışmada sadece tahmin etmeye çalıştıkları hisse senetlerine ilişkin teknik göstergeleri kullanmamışlardır. Aynı zamanda bu hisse senedi ile yüksek korelasyon katsayısına sahip diğer hisse senetlerine ilişkin teknik göstergeler de kullanılmıştır. Yüksek korelasyon içinde oldukları hisse senetleri ve particle swarm optimization tekniğinin birlikte kullanılması ile birlikte SVM nin başarı performansını oldukça yüksek bir şekilde arttığını bulmuşlardır.

Kara, Boyacıoğlu ve Baykan (2011) yılında yayınladıkları çalışmada BIST100 endeksini destek vektör makineleri ve yapay sinir ağları ile tahmin etmişlerdir. Çalışmalarında 2 Ocak 1997 ile 31 Aralık 2007 zaman aralığında yer alan 2733 gözlem kullanılmıştır. Çalışmalarında ilk olarak %20 oranındaki gözlemi parametre belirlemede kullanmışlardır. Kalan gözlemler iki gruba ayrılmıştır, bu gruplardan bir tanesi eğitim amacıyla kullanılmış ve diğeri de test amacıyla kullanılmıştır. 10 adet teknik gösterge kullanılmıştır. Veri seti [-1.0, 1.0] arasında ölçeklendirilmiştir. Çalışmaları sonucunda yapay sinir ağları ortalama %75.74 oranında doğru tahmin gerçekleştirirken, destek vektör makineleri ile %71.52 oranında doğru tahmin gerçekleştirebilmişlerdir.

Hisse senedi fiyat tahmininde bilgi işlemsel zeka yöntemleri kullanılırken, yönteme ilişkin parametrelerin doğru belirlenmesi gerekmektedir. Hsieh vd. (2011) yapay sinir ağları ile gerçekleştirilecek tahminlerde parametrelerin, deney tasarımı ile belirlenmesini önermektedirler. Deney tasarımı, sistematik deneyler için istatistiksel analitik araçların uygulanmasını içermektedir. Çalışmalarında, 1 Ocak - 30 Haziran 2009 Taiwan Stock Exchange verilerini kullanmışlardır. 7 adet teknik gösterge hazırlamışlardır. Çalışmalarında, geri beslemeli yapay sinir ağına ait; gizli katmandaki nöron sayısı, öğrenme oranı, momentum ve yineleme sayısını, deney tasarımı uygulaması sonucu belirledikleri sistematik değerler ile test etmişlerdir. Çalışmalarının sonucunda %84' e kadar doğru tahmin gerçekleştirebilmişlerdir.

Ni vd. (2011), fractal değişken seçiminin kullanılmasını önermektedirler. Fractal değişken seçiminin diğer değişken seçimlerinden daha iyi olduğu bir nokta var, o da hem kullanılacak değişkenlerin hem de kullanılacak değişken sayısının yöntemde belirlenebilmesidir. Önerdikleri yöntemi; Ocak 2000 - Aralık 2008 dönemleri arasındaki 2171 gözlemin kullanıldığı bir veri setinde denemişlerdir. Veri seti Shanghai Stock

Exchange Composite Index gözlemleri oluşturmaktadır. Tahmin yöntemi için ise destek vektör makinelerini kullanmışlardır. Çalışma sonucunda %64,05'e kadar doğru tahmin gerçekleştirebilmişlerdir. 19 adet teknik gösterge başlangıç veri seti olarak hesaplanmıştır.

Elliot Wave teorisinin hisse senetlerinin fiyatlarının tahmininde kullanıldığı çalışma Atsalakis vd. (2011)' na aittir. Çalışmalarının sonucunda %64'lere varan doğru tahminde bulunabilmişlerdir. Çalışmalarında tahminlere ilişkin tahmin istatistiklerini dörtlü sınıflandırmaya tabi tutmuşlardır. Sinyal analizinde kullanılan dört bölümü finans alanındaki tahminde kullanmışlardır.

Hisse senetlerindeki fiyat değişiminin tahmininde evrim geçiren kısmi bağlantılı yapay sinir ağları adında yeni bir yöntem Chang vd. (2012) çalışmalarında kullanılmıştır. Çalışmalarında yapay sinir ağı içindeki nöronların rastgele belirlenmesi, birden fazla gizli katmanın olabilmesi ve öğrenme algoritmasının geliştirilmesi ve eğitim ağırlıklarının belirlenmesinin evrimsel algoritmalarla belirlenmesi söz konusudur. Çalışmalarında iki adet hisse senedinin fiyatındaki değişimin yönünün, önerdikleri algoritma ile tahmin edilmesine ilişkin deneyler mevcuttur. Girdi olarak 24 adet teknik gösterge kullanmışlardır. Bunlardan 12 tanesi bir gün önceki değerler, diğer 12 tanesi ise bir gün daha önceki göstergeler arasındaki fark değişkenleridir. Citigroup ve MotorsLiquidation şirketlerine ilişkin fiyat hareketleri kullanılmıştır. 2008 yılına ait değerler eğitim veri setinde, 2009 yılının ilk yarısına ait değerler ise test amacıyla kullanılmıştır. Belirli bir hata oranı dahilinde hisse senetlerinin, test veri setindeki fiyatlarındaki değişiklikleri Citigroup için %97,58 ve MotorsLiquidation için %97,58 oranında doğru tahmin edebilmişlerdir.

2.1.2. Fiyat Tahmininin Gerçekleştiği Çalışmalar

Hisse senetlerinin fiyatlarının tahmin edilmesinde gri tahmin sisteminin kullanıldığı çalışmaların da yapıldığı görülmektedir. Wang (2002), Taiwan hisse senetleri piyasasında işlem gören hisse senetlerine ilişkin verileri kullanmıştır. Eylül 2000 ile Şubat 2001 arası eğitim amaçlı, Mart 2001 ile Nisan 2001 arası ise kurulan modelin ne kadar iyi performans sergilediğini test etmek için kullanmıştır. Gri tahmin sisteminde tahminler yapılırken, daha az sayıda veriye ihtiyaç duyulur. Çalışmaları sonucunda tahmin edilen fiyatlar, gerçek fiyatlardan %9 oranında sapma göstermekte olduğu ortaya çıkmıştır.

Egeli vd. (2003) yılında yayınladıkları çalışmalarında hisse senedi getirilerini tahmin etmeye çalışmışlardır. Çalışmalarında İstanbul Stock Exchange piyasa endeksini kullanmışlardır. Çalışmalarında girdi olarak bir gün önceki endeks değeri, bir gün önceki TL/Dolara kuru bir gün önceki gecelik faiz oranı ve 5 kukla değişken kullanmışlardır. Kukla değişkenler işgünlerini temsil etmektedir. Çalışmalarında MSE değerini performans ölçüsü olarak kullanmışlardır. Yapay sinir ağlarının performansını hareketli ortalamalar yöntemi ile elde edilen sonuçlarla karşılaştırmışlardır ve yapay sinir ağlarının daha iyi sonuç verdiğini bulmuşlardır.

Fiyatların tahmin edilmeye çalışıldığı başka bir çalışma ise Pai ve Lin (2005)' e aittir. Çalışmalarında ARIMA ve Destek Vektör Makineleri birlikte kullanılmıştır. Yazarlar ARIMA modellerinin doğrusal ilişkileri başarılı bir şekilde modelleyebildiğini, destek vektör makinelerinin de doğrusal olmayan ilişkileri başarılı bir şekilde modelleyebildiklerini savunmaktadırlar ve fiyat tahmininde doğrusal olan ve olmayan şeklinde iki grup belirlemektedirler. Doğrusal bölümde ARIMA modelleri kullanılmak yoluyla tahmin gerçekleştirilirken, doğrusal olmayan bölümde ise destek vektör makineleri ile tahmin gerçekleştirilmektedir. New York Stock Exchange 'e kayıtlı 10 adet

farklı firmaya ilişkin fiyat verileri kullanılmıştır. Ekim 2002 ile Aralık 2002 arasındaki 50 gözlem eğitim veri seti olarak kullanılırken, Ocak 2003 doğrulama (validation) veri seti olarak kullanılmış ve Şubat ayı test veri seti olarak kullanılmıştır. MAE, MAPE, RMSE ve MSE performans ölçütü olarak seçilmiştir. Çalışmaları sonucunda önerdikleri melez modelin, sadece ARIMA veya sadece destek vektör makinelerinin kullanıldığı modellere göre daha iyi sonuç verdiği ortaya çıkmıştır.

Hisse senetlerinin fiyatlarının tahmin edildiği bir diğer çalışma Yang (2007) 'a aittir. Çalışmasında bulanık mantık temelli bir tahmin söz konusudur. Çalışmasında bir ve iki gün önceki açılış, en yüksek, en düşük, kapanış fiyatları girdi değişkenleri olarak kullanılmıştır. 1.02.2004 ile 31.01.2005 arasındaki gözlemler eğitim veri seti olarak kullanılırken, 1.02.2004 ile 30.05.2005 test amacı ile kullanılmıştır. Performans göstergesi olarak RMSE kullanılmıştır.

Armona vd. (2005) yılında yayınladıkları çalışmalarında hisse senedi fiyat tahminin için melez bir yöntem kullanmışlardır. Kullandıkları melez yöntemde yapay sinir ağları ve genetik algoritmalar kullanılmaktadır. Çalışmalarında hisse senedi fiyat tahmini için teknik göstergeler kullanılmaktadır. S&P 500 veri setini kullanmışlardır.

Ince ve Trafalis (2007) yayınladıkları çalışmalarında, hisse senetleri tahmin çalışmasında değişken seçimi üzerinde durmuşlardır. NASDAQ borsasında işlem gören 10 hisse senedi fiyatı yapay sinir ağları ve support vector regression ile tahmin edilmeye çalışılmıştır. 100'den fazla teknik değişken hesaplamışlardır. Çalışmalarında farklı değişken seçimi tekniklerini karşılaştırmışlardır. Çalışmaları sonucunda, uzman bilgisine dayalı sezgisel değişken seçimi yönteminin, PCA ve faktör analizine göre daha iyi sonuç verdiği ortaya çıkmıştır.

Hisse senetlerinin fiyatlarının ANFIS tekniği ile tahmin edildiği bir çalışmada, İran'daki bir firmanın, Tehran Borsasındaki fiyat hareketleri önceden tahmin edilmeye çalışılmıştır. İşlem hacmi, fiyat-kazanç oranı ve kapanış fiyatı girdi olarak belirlenmiştir (Abbasi ve Abouec, 2009).

Li ve Liu (2009), üç katmanlı, ileri beslemeli yapay sinir ağları yapısını kullanmıştır ve çalışmalarında, Shangai stock exchange kapanış fiyatının önceden tahmin edilmesinde kullanmışlardır. Çıktı olarak endeksin kapanış fiyatı, girdi olarak ise bir hafta önceki kapanış fiyatı ve hacim değeri, aylık perakende mal fiyatları, fiyat indeksi ve endüstri katma değeri kullanılmıştır. Çalışmalarında ilk yirmi hafta için iyi tahminler gerçekleştirilirken, süre uzadığında tahmin değerlerinin de bozulmaya başladığı belirlenmiştir. Bu nedenle yazarlar, kısa dönemli tahminde çalışmalarında sundukları modelin kullanılmasını önermektedirler.

Esfahanipour ve Aghamiri (2010) yılında yayınladıkları çalışmalarında ANFIS yöntemi ile hisse senedi fiyat tahmini gerçekleştirmişlerdir. Çalışmalarında İran'da faaliyet gösteren Tehran Stock Exchange'e ilişkin farklı endeks verilerini kullanmışlardır. Çalışmalarında değişken seçimi için stepwise regression yöntemini kullanmışlardır. Çalışmalarında önerdikleri yöntemle elde ettikleri sonuçların, yapay sinir ağı ve çoklu regresyondan daha iyi olduğunu raporlamaktadırlar.

Hao (2010), kısa dönemli hisse senedi tahminini genetik algoritmalar ve yapay sinir ağları kullanmak suretiyle gerçekleştirmiştir. Ara katmanda 16 adet nöron kullanmışlardır. Tahmin edilen fiyatlar ile gerçek fiyatlar arasındaki korelasyon katsayısı ile tahmin performansı değerlendirilmiştir.

Hisse senedi fiyat tahmini konusunda melez yöntemin kullanıldığı çalışmalardan bir tanesi de Zhai vd. (2010) aittir. Kullandıkları melez yöntem üç adet farklı alt yöntemden oluşmaktadır. Bu yöntemler geri beslemeli yapay sinir ağları, anfis ve support vector machine dir. İlk önce yöntemler bağımsız olarak çalıştırılmakta daha sonra elde

edilen değerler nihai bir tahminle sonuçlandırılmaktadır. Sonuçlandırılma aşamasında ilk önce doğrusal bir yöntem daha sonra yapay sinir ağları denenmiştir. S&P 500 veri setini kullanmışlardır. Çalışmalarında üç yöntemin uygun bir şekilde bir arada kullanılmasının daha iyi sonuçlar verdiğini raporlamaktadırlar.

Nair vd. (2010) çalışmalarında özellik seçiminin tahmin sisteminin performansını geliştirmesi üzerinde durmuşlardır. Teknik analiz değişkenleri hesaplanmış ve onbeş farklı değişken seçim tekniği kullanılmak suretiyle veri setinin boyutu azaltılmıştır. En iyi sonucu veren teknik belirlenmiş ve veri setinin boyutu azaltılmıştır. Bu veri seti anfis metodolojisinde girdi olarak kullanılmıştır ve Bombay Stock Exchange Sensitive Index tahmin edilmiştir. Değişken sayısı azaltılmadan kullanılan ANFIS yöntemine göre daha iyi sonuçların elde edildiği görülmüştür. Günlük tahmin gerçekleştirilmiştir. Şubat 2006 ile Mart 2010 arasındaki 1097 gözlemden, 1040'ı eğitim amacı ile kullanılmıştır. Geri kalan 57 gözlem ise modelin doğruluğunu ölçmek amacı ile kullanılmıştır. Sonuçta karar ağacı tekniği ile değişken sayısının azaltıldığı model, diğerlerine göre daha başarılı tahminde bulunmuştur.

Pan (2010) yılında yaptığı çalışmada hisse senedi fiyatının daha doğru tahmin edilmesi için melez bir yöntem önermektedir. Öncelikle 2006 yılında Taiwan şirketlerinin mali tablolarından hesaplanan oranlar kullanılmış ve daha sonra gri ilişkisel analiz yardımıyla firmalar performanslarına göre sıralanmışlardır. En yüksek performansa sahip firmalar tahmin için seçilmiştir. Daha sonra 3 Ağustos 2004 ile 26 Mart 2008 periyodunda firmaların günlük fiyat ve işlem hacmi bilgileri kullanılmıştır. Toplam veri seti 800 gözlem eğitim, 100 gözlem test olmak üzere iki farklı gruba ayrılmıştır. Herbir gözlem için teknik göstergeler hesaplanmıştır. Yapay Sinir Ağlarını kullanmışlardır. Girdi değişkenleri faktör analizi (temel bileşenler analizi)ne tabi tutulmuştur. Böylelikle girdi değişkenleri arasında korelasyon durumunu temsil eden multicollinearity problemi, birbirleri ile ilişkisi olmayan faktörlere çevrilmek yoluyla ortadan kaldırılmış olmaktadır. Önerdikleri melez yöntemin performansı diğer yöntemlerle karşılaştırılmıştır. RMSE, MAE ve MAPE gibi göstergelerle performanslar karşılaştırılmıştır ve önerilen yöntemin diğer yöntemlere göre daha iyi sonuç verdiğini raporlamışlardır.

ANFIS yöntemi ile hisse senedi fiyat tahmininde daha iyi sonuçlar almak için Hadavandi vd. (2010) yılında yayınladıkları çalışmalarında, yöntemde kullanılacak kuralları genetik algoritma ile seçilmesini önermektedirler. 10 Şubat 2003 ile 10 Eylül 2004 tarihleri arasındaki IBM şirketine ait hisse senetleri fiyat hareketlerini eğitim amacı ile, 13 Eylül 2004 - 21 Ocak 2005 tarihleri arasındaki fiyatları ise test amacı ile kullanmışlardır. Girdi değişkenleri olarak açılış, kapanış, en yüksek ve en düşük fiyatlar kullanılmıştır ve çıktı olarak bir sonraki günün kapanış fiyatı seçilmiştir. Önerdikleri yöntem ile tahmin edildiğinde ortaya çıkan MAPE değeri, benzer diğer çalışmalardaki değerlerle kıyaslanmış ve daha iyi sonuçlar elde edildiği görülmüştür.

Kuwait Stock Exchange kapanış fiyatının tahmin edildiği bir çalışma söz konusudur ve Mohamed M. Mostafa (2010) tarafından 2010 yılında yayınlanmıştır. Çalışmasında Multi-layer perceptron ve genelleştirilmiş regresyon ağları (generalized regression neural networks). Veri seti olarak 17 Haziran 2001 ile 30 Kasım 2003 tarihleri arasındaki hareketler kullanılmıştır. AE ve ARE adı verilen performans ölçümleri kullanılmıştır ve sonuçlar gelişmekte olan Kuveyt Menkul Değerler Borsasında fiyatların tahmin edilmesinde yapay zeka yöntemlerinin faydalı olabileceğini göstermektedir.

Salehi vd. (2011) yılında yayınladıkları çalışmalarında hisse senedi fiyatını yapay sinir ağları ile tahmin etmişlerdir. İran'da faaliyet gösteren metal üretim işletmelerine ait verileri kullanmışlardır. Çalışmalarında başarı oranı olarak RMSE değerini

kullanmışlardır. Çalışmalarında ara katmanda 1 ile 15 arasında nöronu denemişler ve en ideal sonucu veren yapıyı tespit etmişlerdir.

Chang P.C. vd. (2011) ise teknik göstergeler kullanmak suretiyle kapanış fiyatını tahmin etmeye çalışmışlardır. Çalışmalarında gruplandırma (discretization) yöntemini, genetik algoritmalar yardımıyla uygulamışlardır. Taiwan ve Amerika’da faaliyet gösteren 3’er adet firmaya ilişkin verileri kullanmak suretiyle bir deney gerçekleştirmişlerdir. Çalışmada tahminler alım satım amacıyla kullanılmış ve elde edilen karlar raporlanmıştır.

Omidi vd. (2011) yapay sinir ağlarını kullanmak suretiyle hisse senedi fiyatı tahmini gerçekleştirmişlerdir. İran’da faaliyet gösteren traktör üretim firmasına ilişkin veri setini kullanmışlardır. Çalışmalarında yapay sinir ağlarının uygun sonuçlar verdiğini raporlamaktadırlar.

Wang vd. (2011) yılında yayınladıkları çalışmalarında hisse senedi fiyatı yapay sinir ağları ile tahmin edilmiştir. Çalışmalarında ilk önce wavelet transform (dalgaçık dönüşümü) yöntemi ile birlikte orjinal veri seti farklı katmanlara ayrılmıştır. Her bir katman düşük ve yüksek frekanslı sinyallere sahiptir. Daha sonra ayrıştırılan katmanlardaki düşük frekanslı sinyaller kullanılarak gelecekteki değerler, geri beslemeli yapay sinir ağları ile tahmin edilmiştir. Çalışmalarında yer alan deneyde Shanghai Stock Exchange’ e ilişkin veri setini kullanmışlardır. Çalışmalarının sonucunda dalgaçık dönüşümünün iyi bir veri ön işleme yöntemi olduğunu raporlamaktadırlar.

BIST100 endeksinin tahmin edildiği çalışmalardan bir diğeri Ok vd. (2011) e aittir. Çalışmalarında BIST100 endeksini tahmin etmek için dolar kuru ve gecelik faiz oranını girdi olarak kullanmışlardır. Çalışmalarında kullandıkları ikinci modelde bu iki değişkene ek olarak, işlem hacmi, üçüncü değişken olarak eklenmiş ve endeks tahmin edilmeye çalışılmıştır. R-kare değerleri ve MAPE değerleri performans ölçütü olarak kullanılmıştır. Çalışmalarında ayrıca regresyon analizi kullanılmış ve iki yöntemin performansı karşılaştırılmıştır. İki girdili ve üç girdili modellerde, her iki performans ölçütüne göre ANFIS yöntemi, regresyon yöntemine göre daha iyi sonuçlar vermiştir. Bunun nedeni olarak borsa endeksinin doğrusal olmayan karmaşık yapısına vurgu yapılmıştır.

Geleneksel yöntemler ve yapay sinir ağlarının çeşitli olumsuz taraflarını eleyecek melez bir yöntem Chang J.R. vd. (2011) tarafından önerilmiştir. Yazarlara göre geleneksel zaman serileri sadece bir adet girdi değişkeni ile tahmin yapmaya izin verirken, yapay sinir ağları ile oluşturulan kurallar kullanıcılar tarafından kolay anlaşılır olmamaktadır. Bu iki olumsuz özelliği ortadan kaldıracak yeni bir yöntem önermektedirler. Önerdikleri yöntemde ilk olarak autoregressive yöntemle t+1 gününe ilişkin volatilité hesaplanmakta daha sonra da anfis yöntemi için parametreler optimize edilmektedir. Çalışmalarında 1997 ile 2003 yılları arasındaki veri seti kullanılmıştır ve her farklı yılda ilk 10 ay eğitim için sonraki iki ay ise test için kullanılmıştır. RMSE ve karlılıklar, performans ölçütü olarak kullanılmıştır.

Hisse senedi fiyatlarının veya indekslerin daha iyi tahmin edilebilmesi için farklı yöntemlerin bir arada kullanılması da literatürde önerilen konuladandır. Bu tür çalışmalardan bir tanesi Hsu (2011) 'ya aittir. Yazar öz-düzenleyici haritalar ve genetik programlamayı bir arada kullanmıştır. Taiwan stock exchange capitalization weighted stock indeksine ait fiyat bilgileri kullanılmıştır. Ocak 1996 ile Eylül 2009 periyodunda 3540 güne ait fiyat ve hacim bilgileri kullanılmıştır. 16 adet teknik gösterge girdi veri seti olarak kullanılmıştır. Çalışmalarında nokta tahmin gerçekleştirilmiştir ve performans RMSE, MAE ve MAPE ile ölçülmüştür. Veri seti öncelikle öz-düzenleyici haritalar kullanılmak yoluyla kümeler ayrıştırılmıştır. Böylelikle aynı özellikteki fiyat hareketleri aynı grup altında toplanmıştır. Daha sonra genetik programlama kullanılmak yoluyla,

tahmin modeli kurulmuştur. Farklı periyodlar kullanılmıştır ve ortalama olarak MAPE değeri 0,0144 olarak hesaplanmıştır.

Güresen vd. (2011) yapay sinir ağları ile NASDAQ index tahminini gerçekleştirmişlerdir. 7 Ekim 2008 ile 26 Haziran 2009 tarihleri arasındaki değerleri kullanmışlardır ve ilk 146 gözlem eğitim için diğer 36 gözlem ise test için kullanılmıştır. MSE ve MAD değerleri performans ölçütü olarak kullanılmıştır.

Aghababaeyan vd. (2011) yapay sinir ağları ile İran'da faaliyet gösteren bir firmanın hisse senedi fiyatlarını tahmin etmişlerdir. Sum squared error ölçüsünü performans ölçüsü olarak kullanmaktadırlar. İki farklı öğrenme algoritmasının performansını karşılaştırmışlardır. Standart feed-forward backprop algoritması ile eğitilen yapay sinir ağı modelinin daha iyi sonuç ortaya çıkardığını raporlamaktadırlar.

Adebiyi vd. (2012) yayınladıkları çalışmalarında melezleştirilmiş piyasa göstergeleri ve yapay sinir ağları yardımıyla hisse senedi fiyat tahmini gerçekleştirmişlerdir. Çalışmalarında temel ve teknik analiz göstergelerini kullanmaktadırlar. Farklı yapay sinir ağı mimarilerini denemişlerdir. Melezleştirilmiş yaklaşımın, sadece teknik analiz göstergelerinin kullanıldığı duruma göre daha iyi sonuç verdiğini raporlamaktadırlar.

Yang vd. (2012) melez bir yöntemle hisse senedi fiyat tahmini gerçekleştirmişlerdir. Çalışmalarında kullanılan esas yöntem bulanık yapay sinir ağlarıdır ve genetik algoritma tabanlı kural keşfi gerçekleştirilmektedir. Kullandıkları girdi değişkenleri şu şekildedir; bir gün önceki dalgalanma, bugünkü dalgalanma, bugünkü 10 günlük hareketli ortalama, bugüne ilişkin 30 günlük hareketli ortalama ve bugüne ilişkin MACD değeridir.

Wu ve Lu (2012) yılında yayınladıkları çalışmalarında, Computational Intelligence yaklaşımlarını bir araya getirmişlerdir. Bu yaklaşımlar self-organizing polynomial neural network based on statistical learning algorithm, cerebellar model articulation controller NN, standard back propagation NN with the steepest descent method, BPNN with scaled conjugate gradient method, artificial immune algorithm based BPNN, advanced simulated annealing based BPNN and adaptive network based fuzzy inference system yöntemleridir. Çalışmalarında kullandıkları veri seti Taiwan Stock Exchange Capitalization Weighted Stock Index (TAIEX) den oluşmaktadır. Çalışmaları sonucunda melez yöntemlerin daha iyi sonuçlar verdiğini ortaya çıkarmışlardır.

Liu vd. (2012) çalışmalarında temel olarak Taiwan stock exchange capitalization weighted stock indeksini (TAIEX) seçilmekle beraber, Dow Jones Endeksi ve NASDAQ stock exchange indeksi de farklı deneyler için kullanılmıştır. Çalışmada tip 2 neuro fuzzy modeli kullanılmıştır. Önerilen modelin performansı geleneksel regresyon, yapay sinir ağları, bulanık zaman serileri ve destek vektör regresyon modelleri ile karşılaştırılmıştır. 10 ay eğitim için 2 ay ise test için kullanılmıştır ve farklı yıllarda hep bu şekilde veri setinin bölünmesi yoluna gidilmiştir. Modellerin performansı RMSE performans ölçütüne göre değerlendirilmiştir. Çalışmalarında beş adet farklı deney gerçekleştirmişlerdir. Deneylerin çoğunda girdi olarak bir gün önceki kapanış fiyatını kullanmışlardır. Deneylerin sonucunda tip 2 neuro-fuzzy yöntemi diğer yöntemlere göre görece iyi sonuçlar verdiğini raporlanmaktadır.

Huang (2012) yılında yayınladığı çalışmasında melez bir yöntem kullanmıştır. Bu yöntemde support vector regresyon ve genetik algoritmaları kullanmıştır. Çalışmalarında genetik algoritma özellik seçimi ve parametre optimizasyonunda kullanılmıştır. SVR yöntemi ise bir dizi hisse senetlerinin getirilerinin hesaplanmasında kullanılmıştır. Çalışmalarında portföy seçimine vurgu yapılmış ve önerdikleri yöntemin, kıyaslamada kullanılan yöntemden daha iyi sonuçlar verdiğini raporlamaktadır.

Kao vd. (2013) yılında yayınladıkları çalışmada, Shanghai Stock Exchange Composite ve Nikkei 225 stock indeksini tahmin etmeye çalışmışlardır. Değişkenlerin seçiminde Nonlinear independent component analysis adında bir yöntemi kullanmışlardır. Bu yöntem, gözlemlerin görünmeyen (latent) sinyallerin doğrusal olmayan bir kombinasyonu olduğunu varsaymaktadır. Bu yöntemle belirledikleri değişkenleri (independent components), Destek Vektör Regresyon (SVR) modelinde girdi olarak kullanmışlardır. Ayrıca çalışmalarında geleneksel faktör analizi ve SVR, doğrusal independent component analysis ve SVR ve son olarak da sadece SVR ile gerçekleştirdikleri deney sonuçlarını karşılaştırmışlardır. 26 Ekim 2007 ile 30 Kasım 2011 tarihleri arasında Nikkei 25 indeksine ait 1000 adet gözlem belirlenmiştir ve bu gözlemlerin %80'i eğitim amacıyla, geri kalan %20 si ise test amacı ile kullanmışlardır. Eğitim ve test aşamasında hareketli pencereler yöntemini kullanmışlardır. SSEC indeksinde de 1000 adet gözlem kullanmışlardır. Bu gözlemler 6 Kasım 2007 ile 30 Kasım 2011 arasındaki gözlemlerden oluşmaktadır. Çalışmalarında performans ölçütü olarak RMSE, Mean Absolute Deviation, MAPE, Root of Mean Squared Percentage Error ve directional symmetry değerlerini kullanmışlardır. Her iki veri seti için de girdi değişkenleri seçildikten sonra parametreleri ayarlamak için grid search algoritmasını kullanmışlardır. Parametreler belirlendikten sonra hesaplanan performans değerleri diğer yöntemlerin performans değerleri ile karşılaştırılmıştır. Bu karşılaştırmada Wilcoxon signed-rank testini kullanmışlardır. Sonuç olarak NICA in diğer yöntemlerden istatistiksel olarak daha iyi sonuç verdiğini ortaya koymuşlardır.

2.1.3. Hem Nokta, Hem Fiyat Tahmini Üzerine Çalışmalar

İndeks fiyatı Cao ve Tay (2001) 'ın çalışmasında destek vektör makineleri ile tahmin edilmiştir ve sonuçlar geri beslemeli yapay sinir ağı ile karşılaştırılmıştır. Çalışmalarında S&P 500 Chicago Mercantile günlük endeksi fiyatı tahmin edilmeye çalışılmıştır. Eğitim periyodu olarak 01.04.1993 ile 31.12.1994 arası günler seçilmiştir. 01.03.1995 ile 31.12.1995 ise test veri seti olarak kullanılmıştır. Veri seti beş günlük yüzde görelî fark hesaplanmak yoluyla dönüşüme tabi tutulmuştur. Bu dönüşüm yöntemi ile birlikte dağılım normale daha da yakın olmaktadır. Performans yöntemleri olarak normalleştirilmiş MSE, MAE, Directional Symmetry, doğru tahmin edilen fiyat artışları ve doğru tahmin edilen fiyat azalışları performans göstergesi olarak kullanılmıştır. Geri beslemeli yapay sinir ağının öğrenme parametresini 0.005 momentum değerini 0.9 olarak belirlemişlerdir. Çalışmalarının sonucunda SVM nin, yapay sinir ağına göre daha iyi sonuç verdiği bulunmuştur.

Yümlü vd. (2005) yılında gerçekleştirdikleri çalışmalarında BIST endeksini tahmin etmeye çalışmışlardır. Çalışmalarında global, recurrent ve smoothed-piecewise sinir ağları modellerini kullanmışlardır. EGARCH yöntemini ise kıyaslama amacıyla kullanmışlardır. Çalışmalarında performans ölçüsü olarak doğru tahmin oranı, MSE, MAE ve korelasyon katsayısını kullanmışlardır. Çalışmalarında smoothed-piecewise yapay sinir ağları modelinin geri dönüşü daha doğru tahmin edebildiği ortaya çıkmıştır. Çalışmalarında 12 yılı kapsayan BIST veri setinde %62 oranında yönü doğru tahmin edebildiklerini raporlamaktadırlar.

Radyal temelli yapay sinir ağı ile geri beslemeli yapay sinir ağı performansı Charkha (2008) 'nın çalışmasında kullanılmıştır. Delhi National Stock Exchange veri seti olarak kullanılmıştır. Çıktı değişkeni olarak eğer fiyat bir sonraki gün yükseliyorsa, 1 aksi durumda 0 olarak kodlanmıştır. Veri seti [-1, 1] aralığında ölçeklendirilmiştir.

Çalışmalarının sonucunda İleri beslemeli ağı eğim tahmininde, radyal bazlı ağı ise fiyat tahmininde daha iyi sonuçlar verdiği saptanmıştır.

Hsu vd. (2009) yılında yayınladıkları çalışmalarında self-organizing map ve support vector regression yöntemini kullanmak suretiyle hisse senedi fiyat tahmini gerçekleştirmişlerdir. Önerdikleri melez yöntemde ilk olarak girdi seti özdüzenleyici haritalar yardımıyla kümelere ayrılmakta ve böylelikle girdi veri setlerinde benzer özellikleri taşıyan kümeler oluşturulmaktadır. Daha sonra support vector regression yöntemi uygulanmakta ve tahmin gerçekleştirilmektedir. Çalışmalarında elde ettikleri performansı sadece Destek Vektör Regresyon yöntemi ile kullanıldığında gerçekleştirilecek performansla kıyaslamışlardır. Çalışmalarında 7 büyük ülkedeki hisse senedi piyasası indeks verilerini kullanmışlardır. Sonuçta melez yöntemin, sadece SVR yöntemi kullanıldığında elde edilecek sonuca göre daha iyi performans sergilediğini raporlamaktadırlar.

Hem nokta tahmin hem de eğim tahmininin gerçekleştiği çalışmalardan bir tanesi Adebıy vd. (2012) 'ye aittir. Çalışmalarında hisse senedi fiyat tahmini için melez göstergeler kullanmışlardır. Melez göstergeler, teknik, temel ve uzman görüşlerinden oluşmaktadır. Ve bu melez göstergeler yapay sinir ağlarında girdi olarak kullanılmaktadır. Çalışmalarında New York Stock Exchange piyasasında işlem gören Dell ve Nokia hisse senetlerine ilişkin veri setini kullanmışlardır. Çalışmalarında yapay sinir ağlarına ilişkin optimal yapıyı belirlemek için deneme yanılma yolunu tercih etmişlerdir. Ara katmanında farklı sayıda nöron bulunan ve farklı sürelerde eğitilen yapay sinir ağlarından en iyi sonucu veren yapı belirlenmiştir. Bu yapının belirlenmesinde yol gösterici gösterge ise MSE değeridir.

2.1.4. Türkiye’de Yapılan Çalışmalar

Özalp ve Anagün (2001), Borsa İstanbul’da işlem gören hisse senetlerinin fiyatlarını önceden tahmin etmek için yapay sinir ağlarını kullanmışlardır. En iyi parametre değerleri ve ağ mimarisini Taguci yöntemleri ile belirlemişlerdir. Parametre optimizasyonu ile tahmin başarısının arttığı raporlanmıştır.

Diler (2003) ise yaptığı çalışmada BIST 100 endeksi getirilerinin yönünü bir gün önceden tahmin etmeye çalışmıştır ve bu amaçla yapay sinir ağları modeli kullanmıştır. Çalışmasında %60,81 oranında yönü doğru bir şekilde tahmin edebilmiştir.

Tektaş ve Karataş (2004) çimento ve gıda sektörlerinde faaliyet gösteren işletmelerin hisse senedi fiyatları, yapay sinir ağları ile tahmin edilmiştir. Çalışmalarında tahmin performansı olarak korelasyon katsayısı kullanılmıştır. Çalışma sonunda yapay sinir ağlarının performansının regresyon yöntemine göre daha yüksek olduğu belirlenmiştir.

Karaatlı vd. (2005) yaptıkları çalışmada BIST endeksinin kapanış fiyatını tahmin etmeye çalışmışlardır. Yapay sinir ağları ve regresyon yöntemi ile tahminler gerçekleştirilmiştir ve yapay sinir ağlarının regresyon yöntemine göre daha iyi sonuç verdiği ortaya çıkmıştır. Girdi olarak faiz oranları, altın fiyatı, enflasyon oranı, sanayi üretim endeksi, tasarruf mevduatı faiz oranı, Dolar kurunu kullanmışlardır ve aylık tahminler gerçekleştirilmiştir. Performans ölçüsü olarak RMSE kullanılmıştır.

Altay ve Satman (2005) BIST endeksinin nokta tahmini ve yön tahminini gerçekleştirmişlerdir. Çalışmada yöntem olarak yapay sinir ağlarını ve regresyonu kullanmışlardır. Regresyon sonuçları nokta tahmininde yapay sinir ağlarından çok da farklı çıkmamıştır. Fakat yön tahmininde ve alım satımda yapay sinir ağları, regresyon analizine göre daha iyi sonuç vermiştir.

Kalaycı ve Karataş (2005) çalışmalarında hisse senetlerinin getirilerini borsa performans ve verimlilik değerleri ile açıklanmıştır. Hisse getirileri ile ilgili olan finansal oranlar belirlenmeye çalışılmıştır. Çalışmada girdi olarak 17 adet oran kullanılmıştır.

Güngör ve Tortu (2007) ise çalışmalarında esnek hesaplama yöntemlerini tanıtmışlardır. Doğrusal regresyon ve esnek hesaplama yöntemleri ile bazı hisse senetlerinin fiyatlarını ve BIST 100 endeksini tahmin etmişlerdir. Döviz kuru, faiz oranları ve altın fiyatları gibi temel analiz değişkenleri kullanılmıştır. Çalışmanın sonucunda yüksek belirlilik katsayısı elde ettiklerini raporlamaktadırlar.

Altan (2008) ise finansal bir zaman serisi olan döviz kurlarının yapay sinir ağı ile tahmin etmişlerdir. Çalışmada hem otoregresif hem de yapay sinir ağları kullanılmıştır ve her iki yöntemin birleştirilmesi ile daha iyi sonucun elde edildiği ortaya çıkmıştır.

Toraman ise (2008) çalışmasında demir-çelik sektöründe faaliyet gösteren iki adet firmaya ilişkin hisse senetleri fiyatlarını tahmin etmiştir. Çalışmada girdi değişkenlerinden bazıları; faiz oranları, enflasyon oranı ve firmaların mali tablolarından yola çıkmak suretiyle hesaplanan finansal oranlardır. Çalışmada başarı ölçüsü olarak, OMH ve OMHY kullanılmıştır. Çalışmada az hata ile hisse senedi fiyatı doğru bir şekilde tahmin edilmiştir.

Türkiye’de hisse senedi fiyat tahmini üzerinde çalışmalar şu şekildedir: Öz, Ayırcay ve Kalkan (2011) çalışmalarında BIST 30 endeksine dahil olan hisse senetlerinin getirilerini önceden tahmin etmişlerdir. Bir ve iki yıl öncesine ait finansal oranlar kullanılmıştır ve diskriminant analizi yardımıyla hisse senetlerinin getirileri tahmin edilmiştir. Analiz sonuçlarına göre iki yıl öncesine ait oranların kullanıldığı modeldeki başarı oranı daha yüksek çıkmıştır.

Özdemir vd. (2011) ise hisse senedindeki yönü lojistik regresyon ve destek vektör makineleri ile tahmin etmişlerdir. Çalışmalarında BIST 100 endeksine ait veriler kullanılmıştır. Destek vektör makinelerinin (%86), lojistik regresyon yöntemine (%75) göre daha yüksek oranda doğru tahminlerde bulunduğunu raporlamışlardır.

Karaca ve Başdemir (2012) ise çalışmalarında 20 adet şirkete ait hisse senetlerinin getirilerini yapay sinir ağları ile önceden tahmin etmeye çalışmışlardır. 21 adet girdi değişkeni kullanmışlardır ve modelin performansı için MSE değerini kullanmışlardır. Girdi olarak firmalara ait finansal oranlar kullanılmıştır.

Tosunoğlu ve Benli (2012) ise Morgan Stanley Capital International Türkiye endeksinin aylık değerlerini yapay sinir ağları ile öngörmüşlerdir. Çalışmada 12 adet girdi kullanmışlardır. Verileri normalizasyona tabi tutmuşlardır ve $[0, 1]$ aralığına dönüştürmüşlerdir. Deneme yanılma yoluyla ara katmandaki nöron sayısı belirlenmiştir. Çalışmalarında RMSE değerini kullanmışlardır. Hata değeri düşük bulunmuştur.

Aygören vd. (2012) BIST 100 endeksinin tahmininde yapay sinir ağları ve Newton nümerik arama modellerinin kullanmışlardır. MSE ve R^2 ile modellerin performansı karşılaştırılmış ve yapay sinir ağlarının daha iyi performans gösterdiği ortaya çıkmıştır.

Erdoğan ve Özyürek (2012) BIST 100 endeksinde bulunan beyaz eşya firmalarının günlük fiyatları, yapay sinir ağları kullanmak suretiyle tahmin edilmiştir. Dolar kuru, BIST endeksi ve diğer günlere ait kapanış fiyatları kullanmak suretiyle Cuma gününe ait kapanış fiyatı tahmini gerçekleştirilmiştir.

3. HİSSE SENEDİ FİYAT ANALİZ VE TAHMİN YÖNTEMLERİ

Bu bölümde hisse senedi kavramından ve tahmin yöntemlerinden bahsedilecektir. Çalışmada yapay sinir ağları tahmin modeli olarak seçilmiştir. Bu nedenle yapay sinir ağları hakkında detaylı bilgi verilecek, diğer tahmin yöntemleri ise genel hatları ile tanıtılmaya çalışılacaktır.

3.1. Hisse Senedi Kavramı ve Ekonomik Önemi

Hisse senetleri anonim ortaklıklar tarafından ihraç edilen ortaklık belgeleridir. Hisse senedinin satın alan yatırımcı şirketin ortağı olur. Eğer şirket kar elde ederse bunu ortaklarına kar payı olarak dağıtır ve hisse senedi sahibi bu kar payından payına düşen miktarı alma hakkı elde eder. Zarar durumunda ise hisse sahibi zarara ortak olmaktadır. Hisse senedi sahibi, hisseleri ikincil piyasada satabilir ve bundan bir kazanç elde edebilir.

Hisse senetleri piyasaları ülke ekonomisine önemli katkılarda bulunmaktadır. Şirketler, faaliyetlerini sürdürmek için ihtiyaç duydukları fonların bir kısmını hisse senedi piyasalarından sağlamaktadırlar. Yabancı yatırımcıların hisse senetlerine yatırım yapması ülke için döviz girişi sağlayacaktır. Özkaynak yolu ile sermaye sağlayan bir şirket yabancı kaynağa göre daha az riskli bir finansman yolunu tercih etmiştir. Bunun nedeni öz sermaye ile sağlanan finansmanda şirketin ödemesi gereken sabit bir faiz veya yükümlülüğün olmamasıdır. Bilançosunda yabancı kaynakların fazla olduğu bir şirketin daha riskli olduğu kabul edilir. Hisse senetlerinin ekonomiye diğer katkılarını aşağıdaki gibi sıralamak mümkündür (Karan, 2011):

- Hisse senetleri küçük tasarrufların bir araya gelmesini sağlar ve kalkınma için gerekli sermaye birikiminin oluşmasına yardım eder.
- Üretim araçları ve iktisadi işletmelerin mülkiyeti geniş halk topluluklarına dağıtılır ve iktisadi refah geniş bir tabana yayılır, daha dengeli bir gelir dağılımı sağlanır. Böylelikle, halk ekonomik kararlarda az da olsa söz sahibi olur ve demokrasi tabana yayılır.
- Hisse senetleri ile birlikte tasarruflara ek gelir sağlanır. Söz konusu ek gelir faiz yoluyla değil, enflasyon ile birlikte değerlendirilen bir yatırım yoluyla sağlanır. Bu nedenle gelir enflasyona karşı korunmuş olur.

Hisse senetleri, hamiline veya nama yazılı olmak zorundadır. SPK Kanununa göre bedelleri tamamen ödenmemiş olan paylar için hamiline yazılı pay senetlerinin çıkarılması mümkün değildir.

Yatırım deyince çoğu insanın aklına hisse senetlerinin alınıp satılması gelmektedir. Her ne kadar alternatifler söz konusu olsa da hisse senetleri birincil yatırım aracı olarak işlem görmektedirler. Hisse senetleri ile ilgili bilgiler gazetelerde her gün yer almaktadır. Sahiplerine sabit bir miktar ödemeyi garanti eden tahvillerden farklı olarak hisse senetlerinde kar payı ödemesi ve büyüme potansiyeli bulunmaktadır. Bu nedenle hisse senetleri yatırımcılar tarafından tercih edilmektedir (Mayo, 2008: 269).

Hisse senetlerinin çok önemli iki özelliği bulunmaktadır. Bunlar ikinci derecedeki alacaklar ve sınırlı sorumluluk özellikleridir (Bodie vd., 2003: 40).

- İkinci derecedeki alacaklar, bir şirketin varlık ve gelirleri üzerinde, şirket ortaklarının hak sıralamasında en son sırada yer almalarını temsil etmektedir. Bir firma iflas halinde ortaklar, vergiler, işçiler, arz edenler, tahvil ve borç sahiplerinden sonra hak iddia edebilirler.

- Sınırlı sorumluluk ise, şirket ortaklarının sadece taahhüt ettikleri sermaye miktarınca sorumlu olmalarını ifade etmektedir. İflas durumunda şirket ortakları sadece koymuş oldukları sermaye miktarınca sorumlu olmaktadır. Kişisel olarak bütün malvarlıkları ile sorumlu değildir.

Hisse senetleri ile ilgili çeşitli özellikler söz konusudur. Bunlar (Moyer vd., 2006: 267):

- Hisse senedi bölünmesi (stock split): Hisse senedi fiyatları düştüğü zaman, yatırımcıların daha fazla hisse senedine yöneleceği düşünülüyorsa hisse senedi bölünmesi gerçekleştirilebilir. Hisse senetleri için kabul edilebilir bir aralık söz konusudur. Bu aralığın üst sınırından daha yüksek fiyata işlem görmeye başladığında, hisse senedi bölünmendirilmesi yoluyla, daha fazla satın alınması söz konusu olabilir.
- Nominal değerleri arttırarak hisse senetlerini birleştirme (Reverse stock splits): Kabul edilebilir fiyat aralığından daha düşük miktarda hisse senetleri işlem görmeye başladığında, yöneticiler piyasadaki hisse senedi miktarını azaltabilir. Böyle bir durumda hisse senetleri daha yüksek fiyattan işlem görmeye başlayacaktır.
- Hisse senetlerinin geri satın alımı (Stock repurchases): Zaman zaman firmalar hisse senetlerini piyasadaki satın alırlar. Kar payı ödemeye alternatif olarak düşünülebilir. Bunun yanında şu gibi faydaları söz konusudur:
 - Fazla nakdin değerlendirilmesi (Disposition of excess cash): Firmalar fazla nakitlerini, firmanın hisse senetlerini satın almak suretiyle değerlendirebilirler. Yakın bir gelecekte firma için, fazla olan nakdini değerlendirecek daha iyi bir yatırım fırsatı söz konusu değilse, firma hisse senetlerini satın alabilir.
 - Mali durumun yeniden yapılandırılması (Financial restructuring): Firma, hisse senedi satın almak yoluyla, mali yapısını değiştirebilir ve finansal kaldıraçtan daha fazla yararlanabilir.
 - Gelecekteki mali durum (Future corporate needs): Yöneticiler için stok opsiyon sözleşmelerinin olduğu durumda, firma hisse senetlerini satın alabilir. Hisse senedi ile değiştirilebilir tahvil söz konusu olduğunda da firma, satın aldığı hisse senetlerini kullanabilir.
 - Devralma riskinin azaltılması (Reduction of takeover risk): Firma piyasadaki kendi hisse senedini satın aldığı zaman, hisse senedinin piyasa fiyatı artacaktır. Böylelikle pasif yapıdaki borç oranı artacaktır. Bu durumda firmayı devralmak isteyenler için uzaklaştırıcı bir etki olacaktır.

3.2. Hisse Senedi Türleri

Hisse senetlerini farklı açılardan sınıflandırmaya tabi tutmak mümkündür (Ceylan, 2004: 65)

- Hisse senetleri hamiline veya nama yazılı olarak düzenlenmiş olabilir. Nama yazılı senetler, şirket defterinde yazılı kimseler adına düzenlenmiştir. Hamiline yazılı senetlerde ise mülkiyet, hisse senedini satın alana teslim etmek ile gerçekleşir.
- Hisse senetleri aynı zamanda bedellerinin ödenme durumuna göre de ayrıma tabi tutulabilir. Bedellerinin tamamı ödenen senetler olabileceği gibi bedellerinin tamamen ödenmediği senetler de olabilir.

- Hisse senetleri sermaye artış durumlarına göre de ayrıma tabi tutulabilir. Karşılığında şirkete nakit girişinin sağlandığı senetler, bedelli hisse senetleri olarak adlandırılmaktadır. Bunun yanında dağıtılmayan karlar, yeniden değerlendirme değer artış fonu, sabit varlıkların satışından elde edilen kazançlar veya iştiraklerdeki değer artışlarının sermayeye eklenmesi nedeni ile çıkarılan ve işletmeye fon girişi sağlamayan hisse senetleri ise bedelsiz hisse senetleri olarak adlandırılmaktadır.
- Hisse senetleri ayrıca sahiplerine sağladıkları çıkar açısından da ayrıma tabi tutulabilir. Adi hisse senetleri, sahiplerine genel kurulda eşit oy hakkı ve kar dağıtım ve tasfiyede eşit pay alma hakkı sağlamaktadır. Buna karşın, imtiyazlı hisse senetleri sahiplerine, ana sözleşmeyle bir takım öncelikler ve imtiyazlar sağlanmıştır. Bunun yanında imtiyazlı hisse senetlerinin getirileri belirlidir.

Bunların yanında hisse senetleri aşağıdaki gibi sınıflara ayrılabilir (Karan, 2011):

- Üzerinde yazılı değer ile ihraç edilen (primsiz) ve nominal değerinden yüksek bir bedelle ihraç edilen hisse senetleri (primli) olarak ayrıma tabi tutulabilir.
- Belli bir sermaye payını temsil etmeyen, şirketin yönetimine katılma hakkı vermeyen kurucu hisse senetleri ve şirket genel kurulunun alacağı kararla bazı kimselere çeşitli hizmetler ve alacak karşılığı olarak kuruluştan sonra verilen ve sermaye payını temsil etmeyen hisse senetleri olan intifa senetleri mevcuttur.

3.3. Hisse Senetlerinin Sağladığı Haklar

Hisse senedinin satın alan yatırımcı firmanın ortağı olur. Eğer firma kar elde ederse bunu ortaklarına kar payı olarak dağıtır ve hisse senedi sahibi bu kar payından payına düşen miktarı alma hakkı elde eder. Hisse senedi sahibi, hisseleri ikincil piyasada satabilir ve bundan bir kazanç elde edebilir. Hisse senedi sahibi ayrıca ortaklığın verdiği seçme ve seçilme haklarını kullanır.

Hisse senedi sahiplerinin sahip oldukları haklar şu şekilde özetlenebilir (Moyer vd., 2006: 266):

- Kar payı hakları: Kurum kazancı üzerinden dağıtılacak kar paylarından, sahip olunan hisse senedi oranında elde etme hakkı söz konusudur.
- Varlık hakları (asset rights): Tasfiye durumunda, hükümete, işçilere ve borçlulara hakları ödendikten sonra, geriye kalan miktar üzerinde hak sahibidirler.
- Ön alım (rüçhan) hakkı: Yeni hisse senedi satımı durumunda öncelikli alım hakkına sahiptirler. Örneğin bir yatırımcı, şirketin yüzde yirmi hissesine sahipse, bu durumda yeni yayınlanacak hisse senetlerinden yüzde yirmi oranında öncelikli alım hakkına sahip olacaktır.
- Oy hakkı: yönetim kurulunun seçimi gibi durumlarda, oy hakkına sahiptirler.

3.4. Hisse Senetlerinde Fiyat ve Değer Kavramları

Çalışmada hisse senedi fiyatı tahmin edilmeye çalışılacaktır. Bu nedenle hisse senedi fiyat ve değer kavramlarının açıklanması gerekmektedir.

Hisse senedinin nominal (itibari) fiyatı, pay senedinin üzerinde yazılı olan fiyattır. İhraç fiyatı ise hisse senetlerinin şirket tarafından çıkarılış aşamasında satışa sunulan fiyattır. İhraç fiyatının nominal fiyatın altında olması mümkün değildir. Bunun yanında

hisse senetlerinin sermaye piyasasında alınıp satıldığı fiyat o hisse senedinin gerçek fiyatı (piyasa veya borsa fiyatı) dır (Karan, 2011:313).

Hisse senedi fiyatı, hisse senedinin piyasada arz ve talebe göre oluşan fiyattır. Sermaye piyasasının tam rekabet şartlarına uyduğu ve geleceğin tam bir belirlilikle tahmin edilebildiği durumlarda bir hisse senedinin değeri, gelecek yıllarda oluşacak gelirler üzerinden dağıtılacak temettülerin belirli bir kapitilazson oranı ile iskonto edilmiş şimdiki değerine eşit olacaktır (Ataman ve Kibar, 1999:74).

Nominal değer hisse senedinin üzerinde yazılı olan değerdir. Defter değeri ise, işletmenin öz sermaye toplamının hisse senedi sayısına bölünmesiyle bulunan değerdir. Tasfiye (likiditasyon) değeri ise, şirketin tüm varlığının satılıp, elde edilen değerden, borçların ödenmesi sonucu bulunan değer, hisse senedi sayısına bölünmesiyle bulunan değerdir. İşleyen Teşebbüs (Ongoing Concern) değeri ise şirketin gelecekte sağlayacağı faiz ve vergi öncesi gelirlerinin bugünkü değreinden borçlarının düşülmesiyle bulunan değerdir. Bu değer kavramlarından farklı olarak işletmenin varlıkları, karlılık durumu, dağıtılan kar payı, sermaye yapısı gibi faktörlere göre belirlenen hisse senedinin değeri gerçek değer olarak adlandırılmaktadır (Ceylan, 2004:77).

3.5. Hisse Senedi Fiyatlarına Etki Eden İki Temel Unsur: Bilgi ve Risk Kavramı

3.5.1. Bilgi Kavramı

Hisse senedi yatırımlarında bilgi; veri ya da haberlerden oluşmaktadır. Bu veri ve haberler, hisse senedi fiyatını etkileyebilecek, makro, mikro, olumlu, olumsuz açıklanmış veya açıklanacak nitelikte olabilir. Makro verilere örnek olarak, enflasyon, faiz oranları, vergi oranları verilebilir. Mikro verilere ise işletmenin açıklamış olduğu kar dağıtımları, yeni yatırım kararları, birleşmeler gibi haberlerdir. Piyasaya açıklanan bu bilgilerin hisse senedi fiyatını etkileme potansiyeli olduğu için büyük öneme sahiptir (Barak, 2008:12).

Finansal piyasalara yatırım yapmak isteyen tasarruf sahipleri için finansal bilginin tam olarak temin edilmesi, finansal bilginin toplanması ve dağıtımının maliyetli olması nedeniyle, rekabetçi olmayan finans piyasalarında oldukça güçtür.

Finansal piyasalarda iki türlü bilgiden bahsedilir bunlar simetrik ve asimetrik bilgilerdir. Simetrik bilgide alacaklı ve borçlu taraflar karşılıklı olarak söz konusu işlemle ilgili aynı düzeyde bilgiye sahiptirler.

Asimetrik bilgi durumunda ise taraflardan biri finansal işlemle ilgili diğerinden daha fazla bilgiye haizdir. Asimetrik bilgi özellikle rekabetin aksadığı finans piyasalarında söz konusu olmaktadır (Erdem, 2012). Asimetriyi işletmeyi yönetenlerle yatırımcılar arasındaki bilgi eşitsizliği olarakda tanımlamak mümkündür (Barak, 2008:13). Örneğin firma yöneticileri genellikle, firmanın işleyişi hakkında paydaşlardan daha detaylı bilgiye sahiptir. Ayrıca firmanın raporlanan mali durumları hakkında firma yöneticileri daha detaylı bilgiye sahiptir. Fakat paydaşlar yöneticilerin dürüst olup olmadıklarını anında ortaya çıkaracak bir bilgiye sahip değildirler (Kirkpatrick ve Dahlquist, 2007: 41).

Hisse senedi piyasalarında bilgi çok önemli bir yere sahiptir ve yatırımcılar sahip oldukları bilgi yardımıyla yatırımlarını gerçekleştirirler. Hisse senedi piyasalarında bilgi üç grupta toplanabilir. Bunlar teknik, temel ve diğer bilgilerdir (Şenol, 2008). Teknik bilgi, hisse senetlerine ilişkin kısa veya uzun dönemli açılış ve kapanış fiyatı ve hacim gibi değerlerdir. Temel bilgi ise firmaya ait olan ve makroekonomik etkileri de içeren, net kar, aktifler ve gelecekteki fon hareketlerini kapsar. Diğer bilgi ise yukarıdaki iki çeşit bilgi grubunda yer almayan bilgilerdir.

Yatırımcı kamuya açıklanan bilgileri kullanmak suretiyle menkul kıymetin gerçek değerini saptamakta ve piyasada buna göre işlem yapmaktadır. Kamuya açıklanan bilgiler; şirketlerin yıllık satış ciroları, dönem karları, finansal yapılarına ilişkin gelişmeler, sermaye arttırımı eğilimleri gibi yatırımcının menkul kıymeti değerlemesinde anahtar girdileri oluşturan bilgilerdir (Kıyılar, 1997; 41).

Hisse senedi piyasasında bilgi kavramı üzerinde durulurken, aynı zamanda, bilginin yatırımcıya ne kadar sürede ulaştığı da göz önüne alınmalıdır. Bilginin her yatırımcıya eşit sürede ulaştığı durumlarda herkesin eşit şartlar altında olduğunu söylemek mümkündür. Fakat bazı kesimlerin bilgiye erken ulaşabilmesi durumunda, avantaj sağlayacakları göz önünde bulundurulmalıdır (Kıyılar, 1997: 41).

Gerçek dünyada, bütün bilgiler, piyasa oyuncularının hepsine aynı anda ulaşamaz. Bu nedenle, bilginin yayılması sürecinde bazı problemler ortaya çıkmaktadır. İlk olarak bilgi aktarımında, bilgi dönüşüme uğrayabilir. İkinci olarak kasıtlı yanlış bilgi sızdırılması söz konusu olabilir. Üçüncü olarak, acil aktarılması gereken bilgiler geciktirilebilir. Dördüncü olarak da bilginin kaynaktan son alıcıya ulaşmasında zaman geçebilir ve bu da bilgide değişiklik olması anlamına gelir.

Bilgi yayıldıktan sonra, piyasa oyuncularının bilgiyi doğru bir şekilde yorumlanmasına sıra gelmektedir. Bu yorumlama ise zor ve problemli olabilir. Bilgi fazla sayıda olabilir, karmaşık ve bu gibi nedenlerle de kolay yorumlanamaz olabilir. Genellikle bilgi muğlaktır ve sonuçları anlaşılır değildir. Söz konusu bilginin ne tür sonuçlara yol açacağına önceden karar verebilecek insan sayısı çok az olabilir. Kısacası, bilginin kendisi güvenilir değildir ve yorumlanması öznel hatalara açıktır (Kirkpatrick ve Dahlquist, 2007: 42).

3.5.2. Risk Kavramı

Risk en temel kavramıyla getirilerdeki dalgalanmaları ifade etmektedir. Gerçek nakit akışlarının, tahmin edilen nakit akışlarından farklı olmasını da ifade etmektedir (Moyer vd., 2006: 182).

Beklenen nakit girişlerinin kesin bir şekilde bilindiği yatırımlar risksiz yatırımlar olarak değerlendirilmektedirler.

Standard sapma olası getirilerin, beklenen değerden ne kadar sapma gösterdiğinin istatistiksel bir ölçüsüdür.

Hisse senetlerine yatırım kısa dönemli (spekülatif) amaçlar doğrultusunda yatırımlar yapılabilir. Bu tür yatırımlar hisse fiyatlarındaki kısa dönemlerde meydana gelen fiyat farklılıklarından kar elde etmeyi amaçlamaktadır. Başka bir ifade ile hisse senetlerini fiyatları daha düşükken satın alıp daha yüksek olduğunda satmak ön plana çıkmaktadır. Uzun vadeli yatırımlarda ise hisse senedinin fiyatının uzun vadede bugünkünden daha fazla olacağı öngörülür ve hisse senedine yatırım yapılır. Uzun dönemde firma performansı dikkate alınır ve buna bağlı olarak yatırım kararı verilir.

3.5.2.1. Sistemik Olmayan Risk

Çeşitlendirme yoluyla elenebilen riskler sistemik olmayan risk olarak adlandırılmaktadır. Sistemik olmayan risk aynı zamanda (unique, residual, specific veya diversifiable) risk olarak da adlandırılmaktadır (Mishkin, 2004: 168). Bireysel firmayı etkileyen olumsuzlukları içeren risklerdir.

İşletmenin yönetim kapasitesi ve kararlarındaki değişiklikler, grevler, ham madde miktarlarındaki değişiklikler, yabancı rakipler, firmanın uyguladığı finansal ve faaliyet

kaldıraç seviyeleri sistematik olmayan risklerin önemli tetikleyicileridir (Moyer, 2006: 205).

3.5.2.2. Sistematik Risk

Çeşitlendirme yoluna gitmek suretiyle elenemeyecek riskler de bulunmaktadır ve bu riskler piyasa riski, sistematik veya undiversifiable risk olarak da bilinmektedirler (Mishkin, 2004: 168). Piyasadaki bütün işletmeleri aynı yönde etkileyen riskler sistematik risk kapsamında değerlendirilmektedirler.

Sistematik riskler herhangi bir hisse senedinin toplam riskinin %25 ile %50'si arasındadır. Faiz oranlarındaki değişimler, enflasyonda (satınalma gücündeki) değişimler, yatırımcıların ekonominin bütünü hakkında sahip oldukları beklentilerdeki değişimler sistematik riski değiştirebilir (Moyer vd., 2006: 205).

3.6. Hisse Senedi Fiyatının Tahmin Edilebilirliğinde Bekleyişlerin Oluşumu

Hisse senedi fiyatları iktisadi arz ve talep göz önünde bulundurulmak suretiyle açıklanabilmektedir. Başka bir ifade ile hisse senedi piyasalarında, diğer piyasalarda olduğu gibi fiyat, arz ve talebin kesiştiği yerde gerçekleşmektedir denilebilir. Hisse senedi piyasalarında talebi belirleyen önemli bir etken ise bekleyişlerdir.

Hisse senedi fiyatlarının davranışları üzerine bir dizi çalışma yapılmıştır. Bu çalışmalarda, geçmiş fiyat hareketlerinden yola çıkmak suretiyle, gelecekteki fiyatların ne dereceye kadar başarılı bir şekilde tahmin edilebileceği araştırılmaktadır (Fama, 1965). Bir tarafta rassal yürüyüş hipotezi söz konusudur ve fiyatların, sadece geçmiş fiyat hareketlerini incelemek suretiyle öngörülemediğini savunur ve diğer tarafta, geçmiş fiyat bilgilerinin faydalı olduğunu teknik analiz taraftarları ortaya koymaktadır.

Hisse senedi fiyatının önceden tahmin edilemediğini öne süren çalışmalar etkin piyasa hipotezine dayanmaktadır. Bu bölümde ilk önce hisse senedi piyasalarında bekleyişlerin oluşumundan daha sonra hisse senedi fiyatının öngörülemediğini öne süren etkin piyasalar hipotezi ve bu hipotez ile yakından ilgili diğer hipotezlere de yer verilecektir.

3.6.1. Bekleyişlerin Oluşumu

Hisse senetlerinin fiyatları (değerleri) belirlenirken, yatırımcıların nakit akımları ile ilgili beklentileri belirleyici bir rol oynamaktadır.

Literatürde bekleyişlerin oluşumu ile ilgili üç farklı model ortaya çıkarılmıştır. Bu yaklaşımlar: Markow bekleyişleri, uyumlu bekleyişler ve rasyonel bekleyişlerdir.

En basit süreç, Markow bekleyişleri olarak adlandırılmaktadır. Bu yaklaşıma göre, ekonomik birimler beklentilerini en yakın gözlemi göz önüne almak suretiyle gerçekleştirmektedirler. Örneğin geçen dönem enflasyon %8 olarak gerçekleşmişse, bir sonraki dönem için de beklenti %8 olacaktır. Daha genel bir ifade ile Markow bekleyişler modeline göre, ekonomik birimler geleceğin bugünkünün aynısı olduğunu beklemektedirler ve geçmişten ders çıkarılmamaktadır.

1950 ve 1960 larda ise geçmiş birkaç ayın ortalaması dikkate alınmaya başlandı. Bu tür beklentilere uyumlu bekleyişler (adaptive expectations) denilmektedir ve beklentilerin yavaş bir şekilde değişeceğini savunmaktadır. Bu teoriye göre eğer faiz oranları birden bire yükselirse, insanların faiz oranı beklentileri yavaş yavaş yükselecektir (Mishkin, 2004: 147).

İnsanların beklentilerini şekillendirebilmek için, sadece geçmiş fiyatlardan daha fazla bilgiye ulaşabilmesi uyumcu bekleyişlerin aksamasına yol açmıştır. Örneğin faiz oranı beklentisi, gelecekte uygulanması beklenen mali politikalarından, şu anda uygulanan mali politikalarından ve geçmişte uygulanmış mali politikalarından etkilenecektir. Ayrıca beklentiler yeni bilgi ile çabucak değişebilmektedir. Bu nedenle John Muth rasyonel beklentiler adı verilen bir teori geliştirmiştir (Muth, 1961). Bu teoriye göre beklentiler, mevcut bütün bilgiyi kullanmak yoluyla en uygun (optimal) tahminlere eşit olacaktır. Bu teoremin finansal piyasalardaki karşılığı etkin piyasalar hipotezi olarak adlandırılır (Mishkin, 2004: 147).

3.6.2. Rassal Yürüyüş Hipotezi

Hipotezin temel dayandığı nokta, hisse senedi fiyat hareketlerinin birbirlerinden bağımsız olmasıdır. (Fama ve Blume, 1966: 226).

Teknik analizin karşıtları geçmiş fiyat ve hacim hareketlerine bakmak yoluyla hisse senedi fiyatlarının tahmin edilmesinin mümkün olmadığı görüşündedirler. Teknik analiz karşıtlarına göre hisse senetleri fiyatlarında gizli olan bir örüntü yoktur. Karşıtlar fiyatların rastgele hareket ettiklerini ve hafızalarının olmadığını savunurlar. Bu varsayım teknik analizin geçersiz olduğu çünkü hisse fiyatlarının rastgele hareket ettiği düşüncesine yol açmaktadır.

Rassal yürüyüş, geçmiş fiyat hareketleri ile gelecekteki fiyat hareketlerinin tahmin edilemediği durumlarda oluşur. Örneğin madeni bir para atılması rassal yürüyüş kavramına bir örnek olarak verilebilir. Madeni para bir kere atıldığında ve yazı geldiğinde, bu bilgi, bir sonraki atışta hangi tarafın geleceğini kestirmemize yardım etmez. Paranın her atışı bağımsız bir olaydır ve bir sonucun bir diğer atışın sonucuna hiçbir etkisi yoktur. Eğer hisse senetleri piyasası rassal yürüyüş sergiliyorsa, gelecek hisse fiyatları geçmiş fiyat hareketlerine bakmak suretiyle tahmin edilemezler (Kirkpatrick ve Dahlquist, 2007: 33).

Hisse senetleri piyasasında rassal yürüyüşün olmadığına ilişkin bazı çalışmalar da söz konusudur. Olağandışı uç değerlerin varlığı, serbest alım-satımın yapıldığı piyasalarda farklı tür dinamiklerin rol oynadığına işaret etmektedir. Hisse senedi getirilerindeki rastgele hareketlerin aksi yöndeki bulgular olsa da bu bulgular, teknik analizin geçerli olduğunu kanıtlamak için yeterli değildir. Rastgele yürüyüşün reddedilmesi sadece hisse senedi getirilerinin saf rastgele dağılmadığına işaret etmektedir. Fiyatlar birbirleriyle ilişkili olabilir başka bir ifadeyle hafızaları olabilir ve bir dereceye kadar tahmin etmekte kullanılabilir. Hisse senetleri fiyatları bazı çalışmaların önerdiği gibi bir şekilde bağımlıysa teknik analizin gelecekteki fiyatları tahmin etmekte yararlı olabileceği savunulabilir (Kirkpatrick ve Dahlquist, 2007: 38).

Bazı araştırmacılara göreyse hisse fiyatlarının rastgele hareket etmiyor olması teknik analizi geçerli kılmaz. Bu yazarlara göre hisse senedi fiyatlarında bazı örüntüler söz konusu olabilir fakat bu örüntüler gelecekteki fiyatları tahmin etmekte yetersiz olacaktır. Başka bir deyişle, geçmiş örüntüler ortalamanın üzerinde getiri elde etmek için kullanılamazlar. Çünkü geçmişte keşfedilen örüntüler olsa da, piyasaya yeni gelen bilgiler hisse fiyatını etkileyecektir. Bu da eski örüntülerin tahmin gücünü zayıflatacaktır (Kirkpatrick ve Dahlquist, 2007: 39).

3.6.3. Etkin Piyasalar Hipotezi (EPH)

3.6.3.1. Etkin Piyasalar Hipotezinin Tanımı

Etkin piyasalar hipotezi (EPH) 1960larda Eugene Fama'nın tezinden ortaya çıkmıştır ve herhangi bir zamanda hisse senedi fiyatlarının bütün mevcut bilgileri yansıttığını ifade etmektedir. Bu hipoteze göre eğer hisse senetlerinin fiyatları bütün mevcut bilgileri yansıtıyorsa, bir hisse senedinin fiyatı, gerçekte sahip olduğu değeri iyi bir şekilde yansıtır ve hiçbir yatırım stratejisi pazarın üzerinde geri dönüş oranı sağlayamaz (Kirkpatrick ve Dahlquist, 2007: 40).

Hipoteze göre piyasa etkinliği, fiyat uyarlamasının, yeni bilgi girişi karşısında hangi hızda ve hangi doğrulukta gerçekleştiğine bağlıdır. Diğer bir ifadeyle piyasaya giren bilgi sonucunda, fiyatlar yeni bilgiye doğru ve hızlı bir biçimde uyarlanıyorsa o piyasa etkindir. Bu teoriye göre etkin bir piyasada bir yatırımcının anormal getiri sağlaması mümkün değildir.

Piyasa etkinliği üç bölümde incelenebilir. Bu etkinliklerden ilki faaliyet etkinliğidir (operational efficiency). Bu piyasada, fon arz ve talep edenler, minimum maliyette işlemlerini gerçekleştirirler. İkincisi ise piyasa etkinlik türü kaynak dağıtım etkinliğidir (capital allocational efficiency). Bu piyasada kaynakların optimum dağıtım hedeflenir. Üçüncü piyasa etkinlik türü ise fiyatların mevcut tüm bilgiyi yansıttığını kabul eden bilgi etkinliğidir (informational efficiency). Etkin piyasalar hipotezindeki etkin kavramı bilgi etkinliğidir (Karan, 2011:276).

Etkin piyasalar, yanlış değer biçilmiş hisse senetlerini bulmak için var olan rekabetin çok yoğun olduğu piyasalar anlamına gelmektedir. Bu tür piyasalara yeni bir bilgi geldiğinde, yatırımcılar bu bilgiden faydalanmak isteyeceklerdir ve herhangi bir kar fırsatını saf dışı bırakacaklardır (Brealey vd., 2012: 211).

Etkin piyasalar hipotezine göre bir piyasa etkin ise, hisse senedi fiyatını tahmin etmeye gerek yoktur çünkü bir sonraki gün hisse senedi fiyatı tamamen rastgele gerçekleşecektir (Fama, 1969). Bu rastgelelik nedeniyle, araştırmacılar teknik indikatörlerle fiyat tahminin geçersiz olacağını savunmaktadırlar.

Etkin Piyasalar Hipotezi 'nin temeli ekonomide yer alan tam rekabetçi piyasa teorisidir. Temel ekonomi teorisi öğretilerine göre arbitraj rekabeti, etkin piyasaların oluşmasına neden olacaktır. Piyasaya her yeni giren bilgi, anında hisse senedinin fiyatına yansiyacaktır ve hisse senedinin fiyatı ile gerçek değeri birbirine eşit olacaktır. Eğer herhangi bir şekilde fiyat, gerçek değerden saparsa, yani gürültü oluşursa, bu durumda arbitrajcılar devreye girecek, birbirleriyle rekabet halinde olacaklar ve hisse senedi fiyatının gerçek değerine ulaşmasına neden olacaklardır. Buna rağmen, Grossman ve Stiglitz (1980) bilginin maliyetli olduğunu ve hisse senedi fiyatlarının mevcut bütün bilgiyi mükemmel bir şekilde yansıtamayacağını savunmaktadırlar.

3.6.3.2. Etkin Piyasalar Hipotezinin Tarihi

Etkin piyasalar hipotezi hakkında yapılan çalışmalar 1900 yılında Fransız matematikçi Louis Bachelier'in doktora tezine kadar dayandırılmaktadır. Théorie de la Spéculation isimli tezinde bir spekülâtörün matematiksel beklentisinin sıfır olduğu sonucuna varmıştır (Lee vd., 2010). Cowles ise yatırım fonu yöneticilerinin performanslarını incelemiştir ve çalışmasının sonucunda hisse senedi tahmin çalışmalarının başarısızlıkla sonlandığı sonucuna varmıştır. 1965 yılında Fama etkin piyasa kavramını çalışmalarında ilk kez kullanmıştır ve etkin piyasalar kavramını üne

kavuşturan isim olmuştur (Lee ve Lee, 2009). 1980 yılında Grossman ve Stiglitz ise bilgi açısından etkin piyasaların gerçekleşmesinin imkansız olduğunu ifade etmişlerdir. Malkiel ise 2003 yılındaki çalışmasında etkin piyasalar hipotezi ve eleştirilerine detaylı bir şekilde yer vermiştir (Malkiel, 2003).


Etkin piyasalar hipotezi ile ilgili geniş çapta literatür taramaları mevcuttur. Dimson ve Mussavian (1998) yılında piyasa etkinliğinin tarihçesine değinmiştir. Çalışmalarında piyasa anomalilerinin şans eseri ortaya çıktığını ve gelecekte de devam etmeyeceğini ifade emektedirler. Bu nedenle kârlı yatırım fırsatlarının aslında anomali olarak adlandırıldığını ifade etmektedirler. Beechey ve diğerleri ise çalışmalarında etkin piyasalar hipotezi ile ilgili literatür taraması gerçekleştirmişlerdir (Beechey vd., 2000). Çalışmalarında etkin piyasalar hipotezinin, fiyat hareketleri ile ilgili bazı önemli meseleleri açıklayamadığını ifade etmektedirler. Bunlardan bir tanesi de Sewell'e aittir. 2011 yılında yayınladığı çalışmasında etkin piyasalar hipotezinin tarihine yer vermiştir. Çalışmasının sonucunda hiçbir piyasanın gerçek anlamda bilgileri tam olarak yansıtmayacağını ve EPH nin geçersiz olduğu yargısına varmıştır (Sewell, 2011).

3.6.3.3. Etkinlik Çeşitleri

Üç çeşit piyasa etkinliğinden söz edilmektedir. Bunlar zayıf formda, yarı güçlü formda ve güçlü formda etkinliktir. Şekil 3.1 'de piyasa etkinliği grafik yardımıyla ifade edilmeye çalışılmıştır.

3.6.3.3.(1). Zayıf Formda Etkinlik

Geçmiş fiyat hareketlerinin cari fiyat hareketleri ile tam uyum içinde olduğu piyasalar zayıf formda etkin piyasalardır.




Şekil 3.1. Piyasa Etkinliği (Ross vd., 2003:344).

Zayıf formda etkin piyasalar matematiksel olarak şu şekilde ifade edilir:

$$P_t = P_{t-1} + \text{Beklenen getiri} + \text{hata}_t$$

Bu eşitliğe göre bugünkü fiyat, en son gözlemlenen fiyat, beklenen getiri ve rastgele hatanın toplamına eşittir. En son gözlemlenen fiyat dünkü, geçen haftaki veya

geçen ayki gözlem gibi örneklem aralığına bağlıdır. Beklenen getiri ise bir hisse senedinin riskinin bir fonksiyonudur. Rastgele hata ise piyasadaki yeni bilgi nedeniyle oluşur. Artı yönlü veya eksi yönlü olabilir. Bir dönemdeki rastgele hata terimi bir önceki dönemden bağımsızdır. Dolayısıyla hata terimi geçmiş fiyatlardan yola çıkarak tahmin edilemez. Yukarıdaki denklemin geçerli olduğu piyasaların rassal yürüyüş (random walk) gerçekleştirdikleri kabul edilir (Ross vd., 2003: 344).



Şekil 3.2. Dalgalı Hisse Seneedi Fiyat Hareketi (Ross vd., 2003:345).

Bu etkinlik çeşidinin zayıf formda etkinlik olarak adlandırılmasının nedeni, geçmiş fiyat hareketlerinin en kolay ulaşılabilen bilgi olmasıdır. Eğer sadece geçmiş fiyat hareketlerinin tahmin edilmesi ile birlikte fiyatlardaki hareketler belirlenebilseydi, bu herkes tarafından yapılırdı ve herhangi bir kar olasılığı anında değerlendirilirdi.

Şekil 3.2 deki gibi mevsimsel bir dalgalanmanın izlendiği hisse senedinde, yatırımcılar fiyatın yüksek olduğu anda hisse senetlerini satmaya çalışacaklar (böylelikle fiyatların düşmesini sağlayacaklar), tam aksine fiyatın en düşük olduğu yerde ise hisse senetlerini almak isteyecekler ve fiyatların yükselmesini sağlayacaklar.


Zayıf formda etkin bir piyasada, hisse senetleri fiyatları geçmiş fiyat bilgilerinden hareketle tahmin edilemezler. Bu nedenle teknik analizin geçerliliği söz konusu değildir (Ross vd., 2003: 345).

3.6.3.3.(2). Yarı Güçlü ve Güçlü Formda Etkinlik

Bir piyasa, halka açıklanan bütün bilgileri içeriyorsa, yarı güçlü formda etkindir. Halka açıklanan bilgiler finansal tablolar ve geçmiş fiyat bilgileri gibi bilgilerdir.

Eğer bir piyasa, halka açıklanan ve açıklanmayan bütün bilgileri yansıtıyorsa bu durumda piyasa güçlü formda etkin piyasadır.

Farklı veri setleri arasındaki ilişki



Şekil 3.3. Farklı Veri Setleri Arasındaki İlişki (Ross vd., 2003:347).

Şekil 3.3 de farklı veri setleri bir arada gösterilmiştir. Şekilden de görüldüğü üzere geçmiş fiyat hareketleri, halka açıklanan bilgilerin bir alt kümesidir. Halka açıklanan bilgiler de hisse senetleri ile ilgili bütün bilgilerin bir alt kümesidir. Zayıf formda etkinlikle yarı güçlü formda etkinlik arasındaki fark, yarı güçlü formda etkinliğin sadece geçmiş fiyat hareketlerini değil, halka açıklanan bütün bilgileri yansıttığı varsayımdır (Ross vd., 2003: 347).

3.6.3.4. Farklı Formdaki Etkinlikleri Ölçmek İçin Kullanılan Testler

Bu bölümde farklı formdaki etkinlikleri ölçmek için geliştirilen testlere değinilecektir.

Etkin piyasalar hipotezi Wall Street’te geniş kitleler tarafından kabul edilmemiştir ve hisse senedi analizlerinin hangi dereceye kadar yatırımların performansını geliştireceği konusunda tartışmalar sürmektedir. Bu tartışmaların sürmesine neden olan bazı meseleler söz konusudur (Bodie vd., 2003: 270):

- **Büyüklik (The Magnitude Issue).** Hisse senetlerinin gerçek fiyatları ile değeri lenmediği herkes tarafından kabul edilen bir gerçektir. Ancak çok büyük portföylerin sahipleri bu küçük hisse senedi yanlış fiyatlamalarından kazanç sağlayabilir. Bu görüşe göre, yatırımcıların rasyonel hareketleri, piyasa fiyatlarının ideal seviyeye gelmesinde etkin rol oynamaktadır. “Piyasaların etkin midir?” sorusu yerine “Piyasalar ne kadar etkindir?” sorusunu sormak gerekmektedir.
- **Yayınlama eğilimi (The selection bias issue).** Gerçekten para kazandıracak yöntemler var olabilir. Böyle yöntemler varsa, bunların bütün dünyaya açıklanması beklenmez. Ortalamanın üzerinde kar sağlamayan yatırım yöntemlerinin raporlanması söz konusudur. Bu nedenle etkin piyasa

hipotezinin karşısında olan kişiler, dünyayı sadece kar sağlamayan yöntemlerin yayınlandığı bir yer olarak görmektedirler. Bu selection bias olarak bilinmektedir. Doğru bir şekilde oluşturulamayan yöntemlerin raporlanacağını söylemek mümkündür. Bu nedenle portföy yöneticilerinin gerçekte portföyleri nasıl yönettiğini hiçbir zaman tam doğrulukla bilmek mümkün olmayacaktır.

- **Şans (The lucky event issue).** Bu konuyu açıklamak için hayali bir yarışmadan bahsedelim. Hilesiz bir paranın atıldığı ve en çok yazı atan yatırımcının kazandığı bir yarışma olsun. Bir kişi için kazanma olasılığı yüzde ellidir. Çünkü %50 yazı ve %50 tura gelme olasılığı söz konusudur. Fakat 10000 kişi bu oyunu oynarsa, en az bir veya iki katılımcı %75 yazı atmış olacaktır. Fakat bu durumda bu kişilerin yatırım uzmanı olduğunu söylemek doğru olmaz çünkü sadece yazı-tura oynayan kişilerdir. Bu hayali yarışma, etkin piyasalar hipotezini canlandırmaktadır. Etkin piyasalar hipotezine göre var olan bilgiler altında adil bir şekilde fiyatlanmış bir hisse senedinin gelecekte fiyatının ne olacağını tahmin etmek yazı tura oynamakla eşdeğerdir. Birçok yatırımcının olduğu bir piyasada bazı yatırımcılar tesadüf eseri olağandışı karlar elde ederler, buna karşılık bazı yatırımcılar da zarar ederler.

3.6.3.4.(1). Zayıf Formda Etkinlik Testleri:

Zayıf formda etkinlikte genellikle bir hisse senedinin fiyatının önceden tahmin edilip edilemeyeceği üzerinde durulmaktadır. Bir piyasanın zayıf formda etkin olup olmadığını belirlerken aşağıdaki hususların dikkate alınması gerekmektedir (Bodie vd., 2003:271):

- **Kısa dönemli getiriler.** Hisse senedi piyasalarının etkin olup olmadığını test eden ilk çalışmalar zayıf formda etkinlik üzerinde durmuşlardır. Sorulan soru yatırımcıların geçmiş fiyat hareketlerine bakarak, gelecekte kendilerine olağandışı karlar sağlayacak eğilimler bulabilirler mi? olmaktadır. Hisse senedi fiyatlarında eğilimlerin keşfedilmesinin bir yolu korelasyon analizi yapmaktır. Bu analizde hisse senedi getiri eğiliminin geçmişteki getiri oranları ile ilişkili olup olmadığı incelenmektedir. Pozitif korelasyon, pozitif getirilerin, pozitif getirileri takip edeceği anlamına gelmektedir. Negatif korelasyon ise, pozitif getirilerin, negatif getiri durumlarının ardından ortaya çıktığı anlamına gelmektedir.
- **Uzun dönemli getiriler.** Kısa dönemi kapsayan çalışmalar düşük düzeyde pozitif korelasyon bulsalar da, uzun dönemli verilerin kullanıldığı çalışmalarda negatif korelasyonun bulunduğu raporlanmaktadır.
- **Geri Sarma (Reversals).** Uzun dönemde, aşırı uçtaki piyasa performanslarının tersi yönde performansın oluşacağına ilişkin çalışmalar söz konusudur. Yakın zamanda çok iyi performans sergileyen bir firmanın gelecek dönemlerde ortalamanın altında performans sergilemesi beklenmektedir. Bu etkinin varlığı, hisse senedi piyasalarının ilgili haberlere aşırı tepki verdiğini önermektedir.

Zayıf formda etkinliği ölçmek için aşağıdaki testler uygulanmaktadır (Karan, 2011: 278):

- Serisel korelasyon testi: Zaman aralıklarında korelasyon yoksa fiyat değişimleri rassaldır.
- Zaman serileri testleri: Doğrusal regresyon, ARCH ve GARCH modelleri, logit ve probit modelleri bu tür analizlerde kullanılmaktadır.
- Koşu testi: Değerler arasındaki farkın pozitif veya negatif olması dikkate alınır.
- Filtre testi: Menkul kıymetin değeri %X artarsa, o menkul değer alınır ve gördüğü en yüksek seviyeden aynı oranda düşünce satılır. Eğer bu kural uygulamak suretiyle piyasa getirisinin aşılması durumunda zayıf form etkinliğinin varlığından söz edilir.

3.6.3.4.(2). Yarı Güçlü Formda Etkinlik Testleri

Yarı güçlü formdaki etkinlik testlerinde ise piyasa anomalileri dikkate alınmaktadır. Temel analiz teknik analizden daha geniş çaptaki bilgileri kullanmaktadır. Hisse senedinin sadece geçmiş fiyat hareketlerinin ötesinde ve halka açıklanmış bilgileri kullanmakla daha yüksek karın elde edilip edilemeyeceği araştırılmaktadır. Bu aynı zamanda yarı güçlü piyasa yapısının test edilmesi anlamına gelmektedir. Fiyaz kazanç oranı veya piyasa kapitalizasyonu gibi kolay erişilebilen bilgiler yardımıyla ortalamanın üzerinde kar elde edilebildiğine rastlanmaktadır. Bu tür bulgular, etkin piyasalar hipotezini reddetmektedir ve piyasa anomalileri olarak adlandırılmaktadır. Aşağıdaki bazı anomalilere yer verilmiştir (Bodie vd., 2003: 275):

- **Mevsimsel etkiler (The small-firm-in-January effect).** Etkin piyasalar hipotezi ile ilgili en sık anılan anomalilerden bir tanesi küçük firma etkisidir. Buna göre küçük firmalardan oluşan bir portföyün getirisi, büyük firmaların hisselerinden oluşan bir portföyün getirisinden daha yüksek olacaktır. Bu etkinin özellikle Ocak'ın ilk iki haftasında gözle görülür derecede olduğuna ilişkin çalışmalar söz konusudur.
- **Likidite etkisi (The neglected-firm effect and liquidity effects).** Küçük firmalar büyük kurumlar tarafından göz ardı edildiğinden bu tür firmalara ilişkin bilgiler pek fazla piyasada yer almaz. Bilginin olmaması dezavantaj yaratmaktadır ve küçük firmaları daha riskli hale getirmektedir. Bunun yanında marka yapmış büyük firmalar, kurumların denetimi altındadır ve piyasaya yüksek kaliteli bilgiler sunulmaktadır. Göz ardı edilen bilgiler için ocak etkisi daha belirgin olmaktadır.
- **Piyasa değeri defter değeri oranı (Book-to-market ratios).** Getiriyi tahmin etmekte en başarılı olan oranın defter değeri bölü piyasa değeri olduğu söylenmektedir. Bu değer yüksek olduğu firmaların, bu oranın küçük olduğu firmalara oranla daha yüksek getiri sağlaması beklenmektedir.
- **Kazanç ilanı sonrası fiyat hareketleri (Postearnings announcement price drift).** Etkin piyasalar hipotezinin temel prensibi, yeni bilginin hisse senedi fiyatlarına çok hızlı bir şekilde yansıtacağıdır. Örneğin iyi bir bilgi piyasaya çıkınca, hisse senedi fiyatlarının anında yükselmesi beklenmektedir. Söz konusu etkide, bir firma getiri elde ettiğini piyasaya açıkladıktan sonra, hisse senedinin birkaç ay boyunca normal üstü kazanç sağlama durumu.

Bir piyasanın yarı güçlü formda etkin olup olmadığını öğrenmek için bazı testler yapılır. Bu testler (Karan, 2011: 282):

- Hisse senedi bölünmeleri testi: Bir şirket, hisse senetlerinin bölünme haberni ilan etmesi ile yatırımcı normal-üstü getiri sağlayabiliyorsa, o piyasanın güçlü formda etkin olduğu reddedilir.
- Yıllık kazanç duyuruları testi: Şirketin yıllık kazancını açıklamasından sonraki dönemde, duyuruyu yapan şirketin hisse senetlerini alan bir yatırımcı, normal-üstü kar elde edebiliyorsa, o piyasanın yarı-güçlü formda etkinliği reddedilebilir.
- Aracı kurum önerileri testi: Aracı kurumlarının önerdikleri senetlerin normal-üstü getiri sağlaması durumunda, yarı-güçlü formdaki piyasa etkinliği reddedilebilir.

3.6.3.4.(3). Güçlü Formda Etkinlik Testleri: İçeriden Öğrenenlerin Ticareti

İçeriden öğrenenlerin ticareti ile normal üzeri kar elde edilmesi durumunda, hisse senedi piyasasının güçlü formda etkin olması beklenir (Bodie vd., 2003: 278). Eğer gizli bilgilere ulaşabilen kişiler mevcutsa ve bu bilgilerini aşırı getiri elde etmek için kullanabiliyorlarsa, şirkete ait gizli bilgiler de anında hisse senedi fiyatlarına yansiyacaktır ve güçlü formda etkin bir piyasa söz konusu olacaktır.

Bir piyasanın kuvvetli formda etkin olup olmadığını değerlendirebilmek için kullanılan etkinlik testleri aşağıdaki gibidir (Karan, 2011: 283):

- İçeriden öğrenenlerin ticaretine yönelik testler: Kamuya açıklanmamış, özel bilgiye ulaşan yönetici veya çalışanlar, firmaların hisse senetlerinde normal-üstü getiri sağlayabiliyorlarsa, o piyasanın güçlü form etkinliği reddedilmiş olur.
- Yatırım fonları ve büyük portföylerin yöneticilerine yönelik testler: Yatırım fonlarının normal-üstü getiri sağlaması, güçlü form etkinliğini reddetmek için gerekli ancak yeterli değildir.

3.6.3.4.(4). Borsa İstanbul 'un Etkinliği Üzerine Çalışmalar

Borsa İstanbul piyasasının etkin olup olmadığını ölçmek için yapılmış çalışmalar söz konusudur. Bu çalışmalardan bazıları şu şekildedir.

Emin Feridun Yalvaç, 2011 yılında yayınladığı doktora tezinde Borsa İstanbul 'un etkin bir piyasa olup olmadığına dair kanıtlar bulmaya çalışmıştır. Çalışmasında örnek olay gerçekleştirmiş ve hisse senetleri satış duyurularının hisse senedi fiyatları üzerinde önemli bir etki oluşturduğunu raporlamıştır. Hisse fiyatlarının piyasaya yeni ulaşan habere Etkin Piyasalar Hipotezi 'nin orta düzey formuna uygun olarak tepki verdiği hakkında kanıt sağlamıştır (Yalvaç, 2011).

Çelik ise 2007 yılında yayınladığı doktora tezinde Türkiye 'nin de aralarında olduğu gelişmekte olan piyasaların zayıf formda etkinliğini test etmiştir. Türkiye menkul kıymet piyasasının zayıf formda etkin olduğunu raporlamıştır (Çelik, 2007).

Özçalıcı vd. (2014) yaptıkları çalışmada hareketli ortalamalar kullanmak suretiyle BIST indeksinde alım satımlar gerçekleştirmişler ve piyasa getirisinin üzerinde getiri elde edebildiklerini raporlamaktadırlar.

3.6.4. Davranışsal Finans

Fiyatların temel değerlerden ayrılması bazı yazarlar tarafından davranışsal psikolojiye bağlanmıştır. İnsanlar, her zaman yüzde yüz rasyonel davranmazlar. Bu sonuç, riske karşı tutum ve olasılıkları değerlendirme olmak üzere iki temel alanda ortaya çıkmaktadır (Brealey vd., 2012: 215):

(1) Riske karşı tutum. Psikologlar, insanların özellikle riskli kararlar verirken zarara uğramaktan kaçındıklarını gözlemlemişlerdir. Daha önceki kararlarda zarar olması durumunda yatırımcılar, sonraki kararlarında, başka zararları önlemek adına daha da dikkatli davranmaktadırlar. Bunun tam tersi olarak, belirli bir dönem kar elde etmiş bir yatırımcı, sonraki dönemlerde daha fazla risk üstlenebilmektedir.

(2) Olasılıklar hakkında inançlar. Birçok yatırımcı olasılık teorisi alanında doktora derecesine sahip değildir. Bu nedenle de kesin olmayan olasılıkları değerlendirirken genel hatalar yapabilmektedirler. Psikologlar bireylerin genel olarak, bir olayın gelecekteki değerini tahmin ederken, geçmişteki olaylara bakıp, gelecekte de bu eğilimin devam edeceği yönünde değerlendirmede bulunduklarını keşfetmişlerdir. Örneğin yakın bir gelecekte büyüme sergileyen bir firmanın bu eğilimi devam ettireceği düşünülür. Gerçekte ise çok uzun süre devam edebilen büyüme oranlarını gerçekleştirmek zordur. İkinci yaygın olan eğim ise aşırı güvendir. Birçok yatırımcı hisse senetlerini ortalama bir yatırımcıdan daha iyi değerlendirebildiğini düşünmektedirler. Birbirleriyle alım satım anlaşması gerçekleştiren iki spekülâtörden birisi kazanacak ve birisi kaybedecektir. Fakat insanlar alım satım yapmaya devam ederler çünkü kaybedecek kişinin karşıdaki olduğunu düşünmektedirler.

İstatistikçiler geçmişte yaşanan anomalileri ortaya çıkarabilmekte ve psikologlar da bunlar için bir açıklama sağlayabilmektedirler. Fakat piyasalarda işlem yapan gerçek yatırımcılar için, o andaki olayları açıklayabilmek çok zordur ve bu da etkin piyasalar hipotezinin temel mesajıdır (Brealey vd., 2012: 215).

Barak (2008) yapmış olduğu çalışmasında, fiyat anomalilerinin BIST’de var olup olmadığını araştırmış ve elde ettiği bulguları davranışsal finans modelleri kapsamında incelemiştir.

3.7. Hisse Senedi Fiyatlarının Analiz Yöntemleri

3.7.1. Temel Analiz

Temel analiz, ihracat ve ithalat, para arzı, faiz oranları, enflasyon oranları, döviz kurları, işsizlik oranları ve firmaya özgü finansal özellikler (kar dağıtım oranı, kazanç oranı, nakit akış oranı, defter değeri-piyasa değeri oranı, fiyat kazanç oranı, nakit döngüsü ve boyut gibi) kullanılmak suretiyle yapılır (Atsalakis ve Valavanis 2009).

Temel analizde, denetim raporları, finansal durum ve finansal performans tabloları, kar payı ödeme kayıtları ve politikalar incelenmektedir. Satışlar, yönetimin kabiliyeti, üretim miktarları, fiyat istatistikleri analiz edilmekte ve günlük gazete haberleri detaylı bir şekilde takip edilmektedir. Temel analiz taraftarı bütün bunları dikkate alır ve değerinden daha düşük bir fiyattan işlem gördüğüne kanaat getirirse, hisse senedine yatırım yapar (Edwards vd., 2007: 3). Temel analiz yöntemi bu çalışmanın kapsamı dışındadır bu nedenle temel analizin detaylarından bahsedilmeyecektir

3.7.2. Teknik Analiz

Teknik analizin günümüz finans yazınına kazandıran kişinin köşe yazarı Charles Dow (1851-1902) dur ve modern teknik analizin kurucusu olarak kabul edilir. 1884 yılında ilk piyasa endeksi Dow tarafından hesaplanmıştır. Endeksin fiyatı, endekse dâhil olan hisse senetlerinin fiyatlarının toplanması ve endekste ki hisse senedi sayısına bölünmesi neticesinde hesaplanmıştır. Söz konusu analizler “Dow Teorisi” olarak adlandırılmaktadır ve modern teknik analizin temellerini oluşturmaktadır.

Teknik analizin farklı tanımları yapılmıştır. Bu tanımlardan bazıları şu şekildedir: Teknik analiz temel tanım olarak hisse senedi fiyatının gelecekteki değerinin, geçmiş fiyat hareketlerinden yola çıkmak suretiyle tahmin edilmeye çalışılmasıdır. Teknik analiz, geçmiş fiyat ve işlem hacmi bilgilerini kullanmak yoluyla, ticaret ve yatırım kararlarında kullanılacak bilgilerin ortaya çıkarılmasıdır (Kirkpatrick ve Dahlquist, 2007: 3).

Teknik analiz, hisse senedinin geçmiş fiyatlarının (genellikle grafik şeklinde) kaydedilmesi ve bu kayda alınan geçmiş bilgilere bakmak suretiyle, gelecekte olması muhtemel karlı eğilimlerin tahmin edilmesi ile uğraşan bir bilimdir (Edwards vd., 2007: 4).

Geçmiş hisse senedi fiyat hareketlerini araştırmak suretiyle az değer biçilmiş (undervalued) hisse senetlerini belirlemek, bu hisse senetlerine yatırım yapmak ve olağandışı kar elde etmeye çalışmak teknik analiz olarak tanımlanmaktadır (Brealey vd., 2012: 206).

Teknik analiz, gelecekteki fiyat eğilimlerini tahmin etmek amacıyla geçmiş fiyat ve işlem hacimlerini incelenmesidir (Abolhassani ve Yaghoobi, 2010).

Teknik analiz, temel ekonomi teorisine dayanmaktadır. Teknik analizin temel varsayımlarını göz önüne aldığımızda bu gerçek daha anlaşılır olacaktır (Edwards, 2007):

- Hisse senedi fiyatları arz ve talebe göre belirlenir
- Hisse senedi fiyatları eğilimlerle hareket etme eğilimindedir
- Arz ve talepteki değişim eğilimlerin tersine çevrilmesine neden olur
- Arz ve talepteki değişimler grafikler yardımıyla tespit edilebilir
- Grafiklerdeki desenler kendini tekrar etme eğilimindedir.

Teknik analize ilişkin birçok gösterge hesaplanmaktadır. Bu göstergeler ilerleyen bölümlerde teker teker açıklanacaktır. Fakat burada değinilmesi gereken bir kavram söz konusudur. O da evrensel düzeyde geçerli gösterge gibi bir kavramın söz konusu olmamasıdır. Farklı durumlarda farklı göstergelerin kullanılması gerekmektedir (Thorp, 2000: 24). Hangi durumlarda hangi göstergenin kullanılacağına ilişkin kesin bir cevap söz konusu değildir.

Uzun dönemli tahminler hatırı sayılır derecede risk içermektedir ve hisse senedi piyasasındaki pozisyonu yönetmek için uygun olmayan bir yöntem olmaktadır (Kaufman, 1998: 1). Bu nedenle de bu tezde kısa dönemli fiyat tahminleri gerçekleştirilmiştir.

Hisse senedi arz ve talebini etkileyen bir çok faktör söz konusudur. Bunlar, yatırımcıların umutları, korkuları, tahminleri, ruh halleri, rasyonel veya irrasyonel yüzlerce olası yatırımcı ve onların ihtiyaç ve kaynakları şeklinde sıralanabilir (Edwards vd., 2007: 5). Fiyat hareketlerinin birçoğunu yönlendiren, beklentiler olmaktadır. Beklentiler hiç farkedilmeden değişikliğe uğrayabilir (Kaufman, 1998: 2).

Fiyatların birbirleriyle ilişkili olmadığı iddia edilmektedir. Bu fikri savunanlara göre fiyatlar arz ve talebe göre dengeye gelecektir fakat bu denge var olan bilgilerden tamamen bağımsız ve farkedilemeyen bir şekilde gerçekleştirilecektir. Eğer rassal yürüyüş teorisi doğrusya, bugün mevcut olan, matematik ve pattern recognition tabanlı birçok alım satım yöntemi geçerliliğini yitirecektir (Kaufman, 1998:3). Rassal yürüyüş

teorisini savunanlara yöneltilen en büyük eleştiri fiyat beklentileridir. Yatırımcıların kararları büyük oranda beklentilere bağlıdır. Fiyatlar çoğunluğun beklentisini yansıtacaktır. Yeni çıkan haberlerle birlikte piyasa dalgalanmaya başlayacaktır. Bu hareketler rassal gibi görünse de gerçekte rassal değildir (Kaufman, 1998: 3).

3.7.2.1. Teknik Analizin İlkeleri

Teknik analiz eğilim diye adlandırılan bir ana ilke üzerine kurulmuştur (Kirkpatrick ve Dahlquist, 2007).

Teknik analizin ilkeleri Colby (2003) tarafından şu şekilde açıklanmaktadır:

- Piyasa fiyatları eğilimler (trendler) halinde hareket etmektedir. Birçok faktör bu trenleri etkileyebilir. Trendlerin arz ve talepte değişiklik meydana gelinceye kadar devam ettiği bilinmektedir. Yeni bir bilgi açığa çıktığında, bu bilgiye ilk karşılık en çok bilgilendirilen kullanıcılar tarafından verilir. Daha sonra daha az bilgi sahibi olan kullanıcılar tepki verir ve bu süreç devam eder. En az bilgiye sahip kullanıcı da tepki verdikten sonra trend sona erer ve yeni bir trend başlar. Alım ve satım dalgaları bu şekilde işlemektedir. Bir finansal ürüne olan arz veya talepte bir değişiklik meydana gelene kadar eğilimler devam edecektir.
- Hisse senedi alım satımları insanlar tarafından gerçekleştirilmektedir ve insanlar duyguları ile hareket etmektedirler. Yatırımcıların karar verme süreçlerini ve dolayısıyla gerçek piyasa hareketlerini rasyonel olarak nitelendirilen temel göstergelerden ziyade sürü psikolojisi ve yatırımcı psikolojisi etkilemektedir.
- Bazı eğilimler yıllar boyunca sürerken diğerleri dakikalarda sürebilir. Üç temel eğilim söz konusudur. Yukarı doğru eğilim, aşağı doğru eğilim veya aynı kalma. Bu trendler yıllarca sürebilir veya birkaç haftadan birkaç aya kadar süren önemli ortda düzey eğilimler şeklinde olabilir ya da günlerce süren ve kısa-dönem yatırımcıları ilgilendiren gürültülü hareketlerden oluşabilir. Getiri maximizasyonu için farklı zaman dilimleri ve farklı eğilimler farklı teknik göstergelerin kullanılması gerekmektedir.

3.7.3. Teknik Göstergeler

Hisse senetleri fiyat ve hacim bilgilerinden hareketle hesaplanan göstergeler beş ayrı grupta incelenebilir. Bu gruplar şu şekildedir:

- Osilatörler (Salıngaçlar)
- Stokastikler
- İndeksler
- Göstergeler

Teknik göstergeler hesaplanırken kullanılacak kısaltmalar Tablo 3.1 de yer almaktadır.

Tablo 3.1. Fiyat ve Hacmi Bilgileri Kısaltması

Kısaltma	Uzun İsim
A	Açılış Fiyatı
K	Kapanış Fiyatı
Y	Seans içi en yüksek fiyat
D	Seans içi en düşük fiyat
H	İşlem hacmi

3.7.3.1. Salınımlar (Oscillators)

Osilatörler bir hisse senedinin olması gerekenden fazla alınıp veya olması gerekenden fazla satılıp satılmadığını belirleyen göstergelerdir. Osilatörler kelimesi Türkçe'ye salınımlar olarak çevrilir ve adından da anlaşılacağı üzere belirli bir aralıkta hareket etmektedirler. Piyasanın aşırı alım veya aşırı satım bölgesinde olup olmadıklarını belirlemeye yararlar.

Çalışmaya konu olan salınımlar şu şekildedir:

- Toplama/Dağıtım Salınımı (Accumulation/Distribution Oscillator)
- Chaikin Salınımı
- Hareketli ortalamaların birleşmesi ayrılması (MACD)
- İvme (Acceleration)
- Momentum

Salınımların hepsinin temelinde momentum kavramı yatmaktadır. Momentum kavramı da temel olarak fiyatların hangi oranda (veya hızda) değiştiğini ölçmektedir (Schwager, 1999: 110).

Bir uçtan, diğer uca sahip olduğu momentum sayesinde gidebilen bir sarkaç modeli piyasalar için de geçerlidir (Siegel, 2000: 6).

3.7.3.1.(1). Toplama/Dağıtım Salınımı (ADO)

1972 yılında, Jim Waters ve Larry Williams tarafından geliştirilmiştir. Alış gücü ve satış gücü kavramlarını tanımlamışlardır. Bu kavramlar şu şekildedir (Kaufman, 1998: 140)

$$\text{Alış Gücü (AG)} = Y - A$$

$$\text{Satış gücü (SG)} = K - D$$

O güne ilişkin alım satım yönünü temsil etmek için alış gücü (açılış fiyatına göre) ve satış gücü (kapanış fiyatına göre) hesaplanmaktadır.

$$ADO_t = \frac{(Y_t - A_t) + (K_t - D_t)}{2 * (Y_t - D_t)} \times 100$$

Formülün alabileceği en yüksek değer 100 olmaktadır. Bu değere açılış fiyatının en düşük fiyata ve kapanış fiyatının da en yüksek fiyata eşit olduğu günde ulaşmaktadır. Formülün alabileceği en düşük değer sıfırdır ve bu değere en yüksek fiyattan açılır ve en düşük fiyattan kapanırsa ulaşmaktadır (Kaufman, 1998: 140).

3.7.3.1.(2). Chaikin Salınımı (CO)

MACD göstergesinin accumulation distribution line ını ölçer. Chaikin salınımı amacı MACD hareketli momentum seviyelerinin tespit edilmesidir

Chaikin salınımı, Marc Chaikin tarafından Accumulation/Distribution taban alınmak yoluyla geliştirilmiştir (Achelis, 2001: 100).

Chaikin salınımı, Accumulation/Distribution Line'ın 3-günlük üssel hareketli ortalamasından, Accumulation/Distribution Line'ın 10-günlük üssel hareketli ortalamasının çıkartılması sonucu hesaplanır.

$$CO_t = MA_{ADL(3)} - MA_{ADL(10)}$$

3.7.3.1.(3). Hareketli Ortalamalar (HO)

9 Günlük hareketli ortalama sinyal veya (Trigger - tetik) değeri olarak bilinir (Achelis, 2001). Bir hisse senedinin belirli bir dönem boyunca aldığı ortalama değeri göstermektedir. Hareketli ortalamalar genellikle momentumu ölçmek için ve olası destek-direnç noktalarının belirlenmesinde kullanılırlar.

3.7.3.1.(3).(a). Basit Hareketli Ortalama (BHO)

Basit hareketli ortalamanın formülü şeklindeki gibidir.

$$SMA_t = \frac{P_m + P_{m-1} + \dots + P_{M-(n-1)}}{n}$$

3.7.3.1.(3).(b). Üssel Hareketli Ortalama (SHO)

Hareketli ortalamanın farklı türleri söz konusudur. Bu türlerden bir tanesi de son fiyata diğerlerinden daha fazla ağırlık yükleyen üssel hareketli ortalamadır.

SHO şu şekilde hesaplanmaktadır:

$$\begin{aligned} S_1 &= Y_1 \\ \text{for } t &> 2, \\ S_t &= \alpha * Y_{t-1} + (1 - \alpha) * S_{t-1} \end{aligned}$$

Bu formülde α ifadesi ağırlığı temsil etmektedir ve 0 ile 1 arasında değer almaktadır. Y_t ifadesi t dönemi sonundaki değeri temsil etmektedir. Formülde S_1 tanımlanmamıştır. Genelde $S_1 = Y_1$ olarak tanımlanmaktadır.

3.7.3.1.(3).(c). Üçgensel Hareketli Ortalama (ÜHO)

Üçgen hareketli ortalama ağırlığın büyük kısmı fiyat serisinin orta bölümüne verilmektedir. Temel anlamda basit hareketli ortalamanın iki kere hesaplanması ile ortaya çıkmaktadır (Achelis, 2001: 198).

$$TMA_t = \frac{SMA_1 + SMA_2 + SMA_3 + \dots + SMA_t}{t}$$

3.7.3.1.(4). Hareketli Ortalamaların Birleşmesi Ayrılması (MACD)

MACD osilatörü bir hareketli ortalamanın bir diğer hareketli ortalama bölünmesi yoluyla hesaplanır.

Fiyatların hareketli ortalamaları arasındaki ilişkiyi gösteren bir momentumdur. 26 günlük hareketli ortalama ile 12 günlük hareketli ortalama arasındaki fark MACD değerini vermektedir. Buna ek olarak MACD değerinin 9 günlük düzeltilmiş ortalaması alınmak suretiyle yavaş çizgi (slower line) hesaplanır (Murphy, 1999: 253).

Al ve sat sinyalleri iki çizginin birleştiği noktalarda verilir. MACD çizgisi, yavaş çizginin üzerinde seyrettikten sonra kesişme gerçekleşiyorsa al sinyali veriliyor demektir. Çizginin altında ise sat sinyali veriliyor demektir (Murphy, 1999).

MACD değerleri aynı zamanda sıfır çizgisi etrafında da dolanmaktadır. Sıfır çizgisinin çok yukarılarındaysa bu durumda fazla satın alınma durumu (overbought) söz konusudur (Boğa piyasası (Edwards vd., 2007: 650)). Çizgiler sıfır değerinin altında seyreliyorsa bu durumda fazla satılma durumu söz konusudur (oversold) (Ayı piyasası (Edwards vd., 2007: 650)) ve hisse senedine yatırım yapılabilir (Murphy, 1999):

$$MACD_t = MA_{t-26} - MA_{t-12}$$

3.7.3.1.(5). İvme - Acceleration (İVM)

Kapanış fiyatı için İvme (acceleration) formülü şu şekildedir:

$$İvme = M_t - M_{t-n}$$

Formülde M_t kapanış fiyatına ait momentumu M_{t-n} ise n gün önceki kapanış fiyatı momentumunu ifade etmektedir. Bu çalışmada $n = 12$ olarak belirlenmiştir. Bu formülle sadece kapanış fiyatına ait ivme hesaplanabilir. Açılış fiyatı, en yüksek fiyat ve en düşük fiyat için de acceleration değerinin hesaplanması mümkündür. Formülde ilgili fiyatın momentumu alınmak suretiyle diğer fiyat çeşitleri için de ivme değeri hesaplanabilmektedir.

En yüksek fiyat, en düşük fiyat, açılış fiyatı ve kapanış fiyatı için ayrı ayrı ivme değerinin hesaplanması mümkündür. Çalışmada her dört fiyat çeşidi için ivme değeri hesaplanmıştır.

3.7.3.1.(6). Momentum (MOM)

Kapanış fiyatı için momentum formülü şu şekildedir:

$$M_t = K_t - K_{t-n}$$

Formülde M_t kapanış fiyatına ait momentumu, K_t kapanış fiyatını ve K_{t-n} , n gün önceki kapanış fiyatını ifade etmektedir. Bu çalışma için $n = 12$ olarak belirlenmiştir. Bu formülle sadece kapanış fiyatına ait momentum hesaplanabilir. Açılış fiyatı, en yüksek fiyat ve en düşük fiyata ilişkin momentum değerlerinin de hesaplanabilmesi mümkündür. Formülde kapanış fiyatı değerleri yerine, diğer fiyat çeşitlerine ilişkin değerler yazılması yoluyla ilgili hesaplara ilişkin momentum değerleri hesaplanabilir.

3.7.3.2. Stokastikler

Stokastik, Yunanca kökenli tahmin etmek kelimesinden türetilmiş bir kelimedir ve davranışları önceden belirlenemeyen, rastgele gerçekleşen sistemler için kullanılan bir sıfattır.

Çalışmada kullanılan stokastikler şu şekildedir:

- Chaikin Volatility
- Hızlandırılmış Stokastik %K ve %D
- Yavaşlatılmış Stokastik %K ve %D
- William's %R değeri

3.7.3.2.(1). Chaikin Dalgalanma (CV)

Chaikin Dalgalanması (Chaikin Volatility) bir hisse senedinin en yüksek fiyat değeri ve en düşük fiyat değeri arasındaki yayılımı ölçer.

İlk önce aşağıdaki gibi en yüksek fiyat ile en düşük fiyat arasındaki farkın üssel hareketli ortalaması hesaplanır.

$$Y - D_{ortalama} = SHO(Yüksek - Düşük)$$

Daha sonra belirli bir dönem boyunca bu ortalamanın nasıl değiştiği aşağıdaki formül yardımıyla ölçülür;

$$CV = \frac{Y - D_{ortalama} - (Y - D_{ortalama}_{t-n})}{Y - D_{ortalama}_{t-n}} * 100$$

3.7.3.2.(2). Hızlandırılmış Stokastik %K ve %D (H%K, H%D)

Stokastikler, yakın zamanda belirgin bir aralıkta alınıp satılan hisse senetleri için ve alım satım noktalarının belirlenmesinde kullanılabilecek iyi bir göstergedir. Fakat hisse senetlerinin güçlü artış veya azalış eğiliminde olduğu dönemlerde yanlış sinyaller verebilir (Thorp, 2000: 24).

Fiyatlar yükseldikçe, kapanış fiyatlarının, fiyat aralığının yüksek olan kısmına yakın olduğu gözlemine dayanmaktadır.

Stokastik osilatörü, bir hisse senedinin fiyatının, belirli bir zaman periyodundaki fiyatına göre değerini vermektedir (Achelis, 2001).

Stokastik osilatör iki çizgi halinde gösterilir. Esas çizgi %K olarak gösterilir. İkinci çizgi ise %D olarak adlandırılır ve gerçekte %K'nın hareketli ortalamasıdır.

Osilatörler farklı şekillerde yorumlanmaktadır. En yaygın yorumlanmaları şu şekildedir (Achelis, 2001): (i) Osilatörler belirli bir miktarın altına düşer (örneğin 20) ve sonra bu seviyeden yükselirse satın alınması uygundur. Eğer osilatör 80'in üzerine çıkar ve daha sonra düşerse de satılması gerekir (ii) %K çizgisi, %D çizgisinin üzerine çıkarsa satın alınmalı, eğer %K çizgisi, %D çizgisinin altına düşerse satılması gerekir.

%K 'nın hesaplama formülü şu şekildedir;

$$\%K_t = \frac{K_t - LLP_{t-n}}{HHP_{t-n} - LLP_{t-n}} * 100$$

%D'nin ise hesaplama formülü şu şekildedir;

$$\%D_t = EMA_{\%K-n}$$

%D , %K değerinin n günlük üssel hareketli ortalamasının hesaplanması ile hesaplanmaktadır. Formüldeki n değeri genellikle 3 olarak kabul edilmektedir. Bu çalışmada da %K 'nın 3 günlük üssel hareketli ortalamasının hesaplanması ile %D değeri elde edilmiştir.

Stokastik osilatörler her zaman için %0 ile %100 arasında değişir. Osilatörün %0 çıkması, hissenin kapanış fiyatının geçmiş n gün boyunca bütün kapanış fiyatlarının en

düşüğü olduğunu ifade etmektedir. Aynı şekilde, eğer osilatör %100 çıkarsa bu durumda, hissenin kapanış fiyatı geçmiş n günün en yükseği olduğunu ifade etmektedir.

3.7.3.2.(3). Yavaşlatılmış Stokastik Y%K ve Y%D

Hızlandırılmış stokastiklere hızlandırılmış denmesinin esas nedeni, yukarıda yer alan formülün oynak bir seri ortaya çıkarmasıdır (Thorp, 2000: 25). Bu serinin oynaklığı nedeniyle, alım satım kararlarının alınmasında çok kullanışlı olmamaktadır. Bu olumsuz tarafın giderilmesi için yavaş stokastik kavramı ortaya çıkarılmıştır (Thorp, 2000: 25).

Yavaşlatılmış stokastik değerleri ise hızlı stokastik değerlerinin üssel hareketli ortalamalarından oluşmaktadır.

$$Slow \%K = EMA_{\%K-n}$$

$$Slow \%D = EMA_{\%D-n}$$

Formülde de ifade edildiği gibi slow %K değeri Fast %K değerinin n günlük üssel hareketli ortalamasından oluşmaktadır. Slow %D değeri ise slow %K değerinin n günlük üssel hareketli ortalamasından oluşmaktadır. Bu çalışmada n değerleri 3 olarak kabul edilmiştir.

3.7.3.2.(4). William's %R Değeri (W%R)

Bu değer aşırı alım/satım seviyelerini ölçmeye yarayan bir momentum göstergesidir. Larry Williams tarafından geliştirildiği için bu adı almıştır (Achelis, 2001).

William's %R değerinin yorumlanması, stokastik osilatörün içsel düzenleme özelliği dışında, stokastik osilatörle aynı şekildedir. William's %R değeri aşağı ve yukarı yönlü çizilmektedir.

Değerin 80-100 arasında yer alması hissenin aşırı satıldığını (oversold), 0-20 arasında bir değer alması ise hissenin aşırı alındığını (overbought) ifade etmektedir (Achelis, 2001).

Örneğin William's %R değeri aşırı alım (overbought) durumunu gösteriyorsa, bu durumda hisse senedini satmak için bir müddet beklemek yerinde olacaktır.

$$W_t = \frac{HH_{t-n} - K_t}{HH_{t-n} - LL_{t-n}} * 100$$

Formüldeki n değeri 14 olarak kabul edilmiştir.

3.7.3.3. İndeksler

Çalışmada kullanılan indeksler şu şekildedir:

- Negatif Hacim İndeksi
- Pozitif Hacim İndeksi
- Göreli Güç İndeksi

3.7.3.3.(1). Negatif Hacim İndeksi (NHI)

İşlem hacminin bir gün önceki işlem hacminden düşük olduğu durumlardaki fiyat değişikliği birikimli toplama eklenmektedir. NHI, genel anlamda piyasa için uygun bir

araçken, PHI bireysel hisse senetleri için uygun bir araç olarak değerlendirilmektedir (Bollinger, 2002: 6).

Negatif hacim indeksinde, işlem hacminin bir önceki güne göre daha az olduğu günler üzerinde durulur.

Hesaplanması

İlk NHI değerine 100 değeri atanır.

Eğer bu günün işlem hacmi dünün işlem hacminden daha düşükse;

$$NHI_t = NHI_{t-1} + \left(\frac{K_t - K_{t-1}}{K_{t-1}} \right) * NHI_{t-1}$$

Eğer bu güne ait işlem hacmi güne ait işlem hacminden daha büyük veya eşitse;

$$NHI_t = NHI_{t-1}$$

İşlem hacmi arttığında, kalabalığın yeterince bilgilendirilmeyen yatırımcıları takip ettiği varsayımına dayanmaktadır. İşlem hacmi azaldığında ise akıllı yatırımcıların iş başında olduğu varsayılmaktadır.

3.7.3.3.(2). Pozitif Hacim İndeksi (PHI)

İşlem hacminin bir gün önceki güne göre daha fazla olduğu günlere odaklanan bir indekstir.

İlk PHI değerine 100 değeri atanır.

Eğer bugünün hacmi dünün hacminden daha büyükse;

$$PHI_t = PHI_{t-1} + \left(\frac{K_t - K_{t-1}}{K_{t-1}} \right) * PHI_{t-1}$$

Eğer bugünün işlem hacmi güne ait işlem hacminden daha küçük veya eşitse bu durumda;

$$PHI_t = PHI_{t-1}$$

3.7.3.3.(3). Göreli Güç İndeksi - Relative Strength Index (GGI)

Göreli güç endeksi aynı zamanda nisbi güç endeksi olarak da bilinir. Endüstri veya piyasayla karşılaştırıldığında hisse senedi fiyatlarının yükselen piyasada daha hızlı, alçalan piyasada ise daha yavaş hareket etmesi söz konusu ise hisse senetlerinin göreli güce sahip olduğu yönünde algılanır (Dağlı, 2012: 279)

Göreli güç endeksi yanlış isimlendirilmiş bir indekstir. İsmi im ettiği gibi farklı finansal varlıkların birbirlerine karşı olan gücünü ölçmez (Colby, 2003). Göreli güç endeksi fazla alım veya fazla satım durumlarının tespit etmesinde sıklıkla kullanılan indekslerden bir tanesidir (Kaufman, 1998: 133). Verileri, 0 ile 100 arasında ölçeklendirmesi momentum indeksinden farklı olmasını sağlamaktadır. Farklılık ayrıca, momentum göstergesindeki gibi ilk ve son değerleri değil bütün değerleri dikkate aldığı için daha istikrarlı olmasından kaynaklanmaktadır (Kaufman, 1998).

U = Son 14 gün boyunca yüksek kapanan gün sayısı

D = Son 14 gün boyunca düşük kapanan gün sayısı

olmak üzere

$$RSI_t = \frac{100}{1 + \frac{U}{D}}$$

Genel olarak 14 gün için göreli güç endeksi hesaplanır, çünkü 14 gün doğal bir çevrimin yarısını temsil etmektedir (Kaufman, 1998).

3.7.3.4. Göstergeler

Çalışmada kullanılan göstergeler şu şekildedir:


- Toplama/Dağıtım çizgisi (Accumulation/Distribution Line)s
- Bollinger Bandı
- Highest High
- Lowest Low
- Medyan Fiyat
- Denge işlem hacmi (On Balance Hacmi)
- Fiyat Değişim Oranı (Price Rate of Change)
- Fiyat-Hacmi Eğilimi (Price-Volume trend)
- Tipik fiyat (Typical Price)
- Hacmi Değişim Oranı (Volume rate of change)
- Ağırlıklı kapanış fiyatı
- William Toplama/Dağıtım göstergesi (William's Accumulation/Distribution)

3.7.3.4.(1). Toplama / Dağıtım Çizgisi (ADL)

Özellikle hisse senedinin düşük değerlendirildiğini düşünen yatırımcılar tarafından büyük miktarlarda hisse senedi satın alınması durumu toplama (accumulation) olarak tanımlanmaktadır (Siegel, 2000: 9). Toplama aşaması hisse senedi fiyatlarının yükselmeden önceki aşamadır. Toplama, bir hisse senedine olan talebin, hisse senedine olan arzı aştığı durumda gerçekleşmektedir. Şekil 3.4 ‘deki toplama (accumulation) bölgesi yatırımcıların hisse senedini biriktirdiği bir fiyat aralığını göstermektedir. Hisse senedi fiyatının belirli bir fiyattan daha fazla düşmediği alan toplama bölgesi olarak tanımlanmaktadır.

Hisse senedinin fiyatında önemli oranda düşme bekleniyorsa, birikim söz konusudur. Hisse senedinin fazla değerlendirildiği düşünüldüğünde söz konusu olur.

Toplama /Dağıtım (Accumulation/Distribution) hisse senedi işlem hacmi ve fiyatındaki değişiklikleri karşılaştıran bir momentum ölçüsüdür. İşlem hacmi arttığında, fiyatın daha fazla hareket edeceği varsayılmaktadır. A/D değerindeki artış hisse senedinin toplanma durumunda (bought) olduğuna işaret etmektedir çünkü hacim fiyattaki yukarı yönlü harekete bağlanmıştır. A/D değerindeki azalış hisse senedinin dağıtım durumunda (sold) olduğuna işaret etmektedir çünkü hacim fiyattaki aşağı yönlü hareketle ilgilidir (Şekil 3.4).



Şekil 3.4. Birikim ve Dağıtım Alanları (Siegel, 2000:10).

Söz konusu gösterge, fiyat ile hacim arasında bir ilişkinin kurulduğu bir göstergedir. Hacimde meydana gelen değişim arttıkça, fiyatta da önemli miktarda değişikliklerin meydana geleceğini tahmin etmektedir (Achelis, 2001).

Aşağıdaki formül yardımıyla hesaplanmaktadır:

$$AD_{line} = \sum \left[\frac{(K - D) - (Y - K)}{(Y - D)} * H \right]$$

Günlük kapanış fiyatının, günlük fiyat aralığının neresinde olduğunu ölçen bir göstergedir. Bu oran günlük hacimle çarpılmaktadır ve günlük net toplanma durumunu veya dağıtım durumunu sayısallaştırmaktadır (Colby, 2003: 51).

3.7.3.4.(2). Bollinger Bandı (BB)

Bollinger bandları çok yönlüdür ve herhangi zaman aralığındaki veriler için (örneğin dakika bazlı veriler veya ay bazlı veriler için) hesaplanabilir. Piyasadaki büyük hareketlere tepki vermek ve fiyatların normal alım satım aralığından daha yüksek veya daha düşük olup olmadığını tespit etmek için tasarlanmışlardır.

Bollinger bantları hareketli bir ortalamanın bir standart sapma altında ve üstünde çizilir. Standart sapma esnekliğin bir ölçüsü olduğu için, bantlar kendi kendilerini, piyasanın hareketli olduğu zamanlar genişletmek ve piyasanın durgun olduğu zamanlar daraltmak yoluyla düzeltirler.

Fiyatlar genelde, düşük Bollinger bandı ile yüksek Bollinger bandı arasında hareket edecektir. Fiyatların hareketli olduğu zamanlar bantlar arası aralık açılır. Fiyatların nispeten durgun olduğu zamanlarda ise bantların, fiyatları içermek için kasıldığı görülür.

Hesaplanması şu şekildedir:

Orta Band:

$$Orta\ Band = \frac{\sum_{j=1}^n K_j}{n}$$

Formülde $n = 20$ olarak kabul edilmiştir.

Üst Band:

Orta band ile aynıdır fakat D standart sapma sayısı kadar yukarı taşınmıştır.

$$Üst\ Band = Orta\ Band + \left(D * \sqrt{\frac{\sum_{j=1}^n (K_j - Orta\ Band)^2}{n}} \right)$$

Alt band:

Orta bandın belirlenen D sayısı standart sapma kadar aşağı taşınması ile elde edilen seridir.

$$Alt\ Band = Orta\ Band - \left(D * \sqrt{\frac{\sum_{j=1}^n (K_j - Orta\ Band)^2}{n}} \right)$$

Alt Bollinger bandı destek formunu oluştururken, üst bollinger bandı ise direnç formu oluşturmaktadır. Bollinger bantları ile istatistikteki güven aralığı kavramı birbirleriyle yakın ilişki içindedir. İstatistiksel ifade ile, Bollinger bandları, hareketli ortalamanın %95 güven aralığını temsil etmektedirler ve hareketli ortalamanın normal

dağıldığı durumlarda, artı ve eksi iki standart sapma uzaklıkta bulunmaktadırlar. Fiyatlar aşağı doğru hareket ettiği ve alt banda çarptığı noktada al sinyali verilmektedir. Aynı şekilde fiyatlar yukarı doğru hareket edip, üst banda çarptığı noktada sat sinyali verilmektedir. Bollinger bandları ile bilinmesi gereken en önemli şey, bollinger bandlarının yorumu hisse fiyatlarının normal seyrettiği durumda geçerlidir. Fakat hisse senedi fiyatlarının normal dağılmadığına ilişkin birçok kanıt bulunmaktadır. Hisse fiyatlarının çarpık ve şişman kuyruklu dağılım gösterdiği kanıtlanmıştır. Bu nedenle hareketli ortalamanın etrafındaki simetrik bantlar çarpıklık ve basıklığı tam olarak yansıtamayacaktır (Fong, 2013: 20).

3.7.3.4.(3). En Yüksek Yüksek Değer (HH)

Belirli bir zaman dilimi boyunca, hisse senedi en yüksek fiyatının aldığı en yüksek değer en yüksek yüksek değer (highest high değeri)dir. Farklı zaman dilimleri için HH değerinin hesaplanması mümkün olsa da bu çalışma için, en çok kullanılan 14 değeri kullanılmıştır. Dolayısıyla son 14 gün boyunca bir hisse senedinin en yüksek değerinin aldığı en yüksek değer HH değerini oluşturmaktadır.

3.7.3.4.(4). En Düşük Düşük Değer (LL)

Belirli bir zaman dilimi boyunca, hisse senedi en düşük fiyatının aldığı en düşük değer en düşük düşük değer (lowest low değeri)dir. Bu çalışmada son 14 gün boyunca hisse senedi en düşük fiyatları içindeki en düşük fiyat, lowest low değeri olarak hesaplanmıştır. Dolayısıyla son 14 gün içinde en düşük fiyatlar içindeki en düşük fiyat LL değerini oluşturmaktadır.

3.7.3.4.(5). Medyan Fiyat (MF)

Bir gün için medyan fiyat, o günkü en yüksek ve en düşük fiyatın ortalaması alınmak yoluyla hesaplanır.

$$MF_t = \frac{Y_t + D_t}{2}$$

3.7.3.4.(6). Denge İşlem Hacmi (On Balance Hacmi (OBV))

Joe Granville tarafından 1963 yılında tanıtılan bir indekstir. Hacim çarpı fiyat değişikliğindeki işaretin birikimli toplamından oluşmaktadır. Fiyatın yükseldiği günlerdeki hacim birikimli toplama eklenirken, fiyatın düştüğü günlerdeki hacim birikimli toplamdan çıkarılmaktadır. Buradaki temel fikir, fiyat değişikliğinin ardında yatan gücün hacim olduğudur. Bu nedenle, fiyatın yükseldiği günlerdeki hacim olumlu gösterge olarak göz önünde bulundurulurken, fiyatın düştüğü günlerdeki hacim ise olumsuz olarak değerlendirilmektedir. Fiyat ve OBV, farklı ölçeklerde de olsa aynı grafik üzerinde gösterilir. Eğer fiyat yükseliyorsa ve gösterge yükselmiyorsa satış gerçekleştirilir. Eğer fiyat düşüyorsa fakat gösterge düşmüyorsa bu durumda alış gerçekleşir. Bir çok teknik analizciye göre OBV iyi bir teknik göstergedir (Bollinger, 2002: 5).

Denge işlem hacmi, hisse senedinin hacmini, fiyattaki değişikle ilişkilendiren bir momentumdur.

Hesaplanması şu şekildedir. Eğer bugünün kapanış fiyatı, dünün kapanış fiyatından daha büyükse bütün günün hacmine artı işareti atanır. Fakat bugünün kapanış fiyatı dünün kapanış fiyatından daha düşükse bütün günün hacmine eksi işaret atanır. Fiyatların ne kadar farklı olduğu önemli değildir. Önemli olan fiyat değişiminin yönüdür. Daha sonra kümülatif toplamlar alınır (Colby, 2003: 766).

Eğer bugünün kapanış fiyatı dünün kapanış fiyatından daha yüksekse; ($K_t > K_{t-1}$)

$$OBV_t = OBV_{t-1} + H_t$$

Eğer bugünün kapanışı dünün kapanışından daha düşükse; ($K_t < K_{t-1}$)

$$OBV_t = OBV_{t-1} - H_t$$

Eğer bugünün kapanış fiyatı dünün kapanış fiyatına eşitse; ($K_t = K_{t-1}$)

$$OBV_t = OBV_{t-1}$$

Matematiksel olarak;

$$OBV = \frac{K_t - K_{t-1}}{|K_t - K_{t-1}|} * H$$

3.7.3.4.(7). Fiyat Değişim Oranı (Price Rate of Change (PROC))

PROC göstergesi, hisse senedinin bugünkü fiyatı ile n gün önceki fiyatı arasındaki farka eşittir. Değer olarak hesaplanabileceği gibi yüzde olarak da hesaplanması mümkündür.

$$PROC_t = \frac{K_t - K_{t-n}}{K_{t-n}} * 100$$

Formüldeki n değeri varsayılan olarak 12 değerini almaktadır.

PROC değeri sıfırdan büyük olduğunda, fiyatların ileride yükselebileceğini göstermektedir. Bu değer sıfırın altına düştüğünde ise fiyatların ileride gerileyebileceğini göstermektedir (Colby, 2003: 596).

3.7.3.4.(8). Fiyat-Hacmi Trendi (Price-Volume Trend (PVT))

On Balance Volume değerine benzemektedir. Fakat burada kümülatif toplam söz konusudur. PVT'de sadece günlük hacmin belirli bir kısmı eklenir veya çıkarılır.

PVT, hisse senedindeki bir günlük fiyat değişiminin (yüzde olarak) hacimle çarpılması ve bulunan değer, çünkü PVT değerine eklenmesi yoluyla hesaplanır. Fiyatta bir azalma söz konusu olduğunda ise, kümülatif toplamdan değer düşülmesi gerekecektir.

İlk PVT değeri gözlemlerdeki ilk hacim olarak atanmıştır.

$$PVT_t = \frac{K_t - K_{t-1}}{K_{t-1}} * H + PVT_{t-1}$$

3.7.3.4.(9). Tipik Fiyat (TP)

Bir hisse senedinin o gün için aldığı en yüksek fiyat, en düşük fiyat ve kapanış fiyat değerlerinin aritmetik ortalamasıdır.

$$TP_t = \frac{Y_t + D_t + K_t}{3}$$

3.7.3.4.(10). Hacim Değişim Oranı (Volume Rate of Change (VROC))

Hisse senetleri grafiklerindeki oluşumların (formasyonların) neredeyse hepsi (zirveler, dippler, breakoutlar vb) hacimde keskin bir yükselmeye neden olur. VROC, hacimdeki değişimin hızını ölçmeye yarar (Achelis, 2001).

Son n gündeki hacim değişikliğinin, n gün önceki hacime bölünmesi yoluyla hesaplanır. Sonuçta elde edilen değer son n günde hacimdeki yüzde değişikliktir.

Eğer bu günkü işlem hacmi, n gün önceki işlem hacminden daha yüksekse, VROC değeri pozitif olacaktır. Eğer bugünkü işlem hacmi, n gün önceki işlem hacminden daha düşükse, bu durumda VROC değeri negatif olacaktır.

$$VROC_t = \frac{H_t - H_{t-n}}{H_{t-n}} * 100$$

Bu çalışmada formüldeki n değeri 12 olarak seçilmiştir.

3.7.3.4.(11). Ağırlıklı Kapanış Fiyatı (AKF)

Her günün kapanış fiyatının belirli bir oranla ağırlıklandırılmış bir şekilde ortalamasının alınması yoluyla hesaplanır.

Kapanış fiyatının iki ile çarpılması ve bu değere en yüksek ve en düşük fiyatların eklenmesi ve sonucun dörde bölünmesi yoluyla hesaplanır (Achelis, 2001).

$$AKF_t = \frac{K_t * 2 + Y_t + D_t}{4}$$

3.7.3.4.(12). William Toplama/Dağıtım Göstergesi (WAD))

Toplama, hisse senedi piyasasının alıcılar tarafından, dağıtım ise satıcılar tarafından kontrol edildiğini ifade eden kelimelerdir.

William's Accumulation/Distribution (WAD) göstergesini üç adımda hesaplamak mümkündür. İlk adım olarak Gerçek Yüksek Aralık (GYA veya ingilizce isimleri ile True Range High - TRH) ve Gerçek Düşük Aralık (GDA veya ingilizce isimleri ile True Range Low - TRL) değerlerinin hesaplanması gerekir (Achelis, 2001).

- GYA = Dünkü kapanış fiyatı veya bugünkü en yüksek fiyattan yüksek olan fiyat
- GDA = Dünkü kapanış fiyatı veya bugünkü en düşük fiyattan düşük olan fiyat

İkinci adımda, A/D değeri, bugünün kapanış fiyatı ve dünün kapanış fiyatının karşılaştırılması yoluyla belirlenir.

- Eğer bugünün kapanış fiyatı dünün kapanış fiyatından büyükse;
Bugünün A/D değeri = Bugünkü Kapanış Fiyatı - GDA
- Eğer bugünün kapanış fiyatı dünün kapanış fiyatından düşükse;
Bugünün A/D değeri = Bugünün Kapanış Fiyatı - GYA
- Eğer bugünün kapanış fiyatı dünün kapanış fiyatına eşitse;
Bugünün A/D değeri = 0

Üçüncü adımda A/D değerlerinin birikimli toplamaları alınır ve William's A/D değeri hesaplanmış olur.

$$William's A/D = Bugünkü A/D + Dünkü A/D$$

3.7.3.5. Teknik Göstergelere Yönelik Eleştiriler

Teknik analize yönelik eleştiriler (Caginalp ve Balenovich, 2003: 8) :

- Tarafsız bir şekilde karmaşık desenlerin tespit edilmesi zordur.
- Bazı akademik çalışmalarda, kolay bir şekilde kar elde edilemeyeceği ifade edilmektedir.
- Sadece teknik analizin kullanılması ile büyük karlar elde edilemeyeceğine yönelik bir algı söz konusudur.

Bu eleştirilere rağmen teknik analizde bilgisayarların sıklıkla kullanılması yanlış olma problemini ortadan kaldırmaktadır. Başka bir ifade ile teknik analizde insan müdahalesi asgari düzeye indirildiğinden, kişilerin kişisel duyguları ile karar vermesi gibi bir problem söz konusu değildir. Üstelik teknik analizin günümüzde kullandığı yöntemler, analizi eleştiren makalelerin yayınlandığı dönemlerdekinden çok daha gelişmiştir. Son olarak, saf teknik analizin karlı olduğunu iddia etmek zor olsa da, teknik analizin göz ardı edilmesinin yanlış olduğunu söyleyebiliriz. Fiyat deseni şu anki zamana kadar varolan arz ve talebin dinamiklerini yansıtmaktadır (Caginalp ve Balenovich, 2003: 8).

Teknik analizin eleştirildiği en önemli noktalardan birisi de teknik analizin kullanıldığı kuralların son derece keyfi ve bu nedenle de bilimsellikten uzak olduğu yönündedir (Caginalp ve Balenovich, 2003: 19).

3.8. Hisse Senedi Fiyat Tahmin Yöntemleri

3.8.1. Genel Olarak Tahmin Süreci

Gelecekteki belirsizliği önceden tahmin etmeye çalışmak neredeyse insanlık tarihi kadar eskidir. Bilimsel tahminler önceden belirlenen örüntülere ve düzenlere dayanmaktadır (Floudas ve Pardalos, 2008: 1068).

Geleceğin tahmin edilebilir veya rastgele olduğunu araştırmaya başladığımızda doğanın davranışlarında bazı düzenleri keşfetmeye başlarız. Bu düzenler fizik ve astronomi gibi alanlarda çok belirgindir ve gelecekle ilgili tahminler yapmamıza olanak sağlar (Floudas ve Pardalos, 2008: 1069).


Yirminci yüzyılın başlarında psikoloji disiplini insan oğlunun ve diğer organizmaların davranışlarını incelemek için deneysel metodlar geliştirmeye başladılar. Böylelikle, psikologlar davranışları tahmin edebilmeye başladılar ve gelecekle ilgili belirsizliği mümkün olduğunca azalttılar. Yirminci yüzyıl boyunca tahmin etmek özellikle sayısal yöntemlerin gelişmesi ile birlikte önemli olmaya başladı. Ekonomi alanında da farklı tahmin yöntemleri kullanılmaya başladı. Konjonktürlerin ve kriz yönetimi alanları, ilk ekonomik tahminlerin geliştirildiği alanlardır (Floudas ve Pardalos, 2008: 1069).

Tahmin etme (forecasting) en temel anlamda, birçok değişkenin birbirleriyle etkileşim halinde olduğu istikrarsız piyasalarda, bazı değişkenlerin alacağı değerleri öngörmekte kullanılabilecek değişkenlerin tespit edilmesidir. Bu da geçmiş fiyat hareketlerine bakarak tahmin edilmek istenen değişkenlerin davranışına öncülük eden değişkenleri anlamayı gerektirmektedir. Piyasada gözlemlediğimiz veri setinin altında yatan modeli kavrayabilirsek, belirli bir hata oranıyla, en iyi tahminleri gerçekleştirebiliriz. Gerçek model çok karmaşık ve tespit edilmesi zor olabilir. Bu durumda gerçek modele en yakın modelin oluşturulması gerekir (McNelis, 2005: 2).

Tahmin konusunda kullanılan yöntemlerin fazla olması nedeniyle, çeşitli sınıflandırmalar yapmak mümkündür. En temel anlamda, kalitatif ve kantitatif yöntemler olarak iki gruba ayrılabilir (Floudas ve Pardalos, 2008: 1069).

Bir başka belirgin sınıflandırma ise (Floudas ve Pardalos, 2008: 1069) ;

- Veri bazlı (genellikle zaman serileri). Gelecekte de tarihin kendisini tekrar edeceği çalışmalar bu gruba örnek olarak verilebilir. Bu çalışma da yapısı itibarıyla bu grupta yer almaktadır.
- Teori bazlı, dışsal faktörlerin gelecekteki olayları belirleyeceği varsayılmaktadır.



Şekil 3.5. Tahmin Sisteminin Kavramsal Yapısı (Abraham ve Ledolter, 2005:4).

Şekil 3.5 bir tahmin sisteminin genel hatları ile işleyişini içermektedir. Tahmin sistemi genel olarak iki aşamadan oluşmaktadır. İlk aşamada var olan teori ve veri seti dikkate alınmak suretiyle bir model oluşturulur. Söz konusu model toplanan veri seti ile denenmektedir. Bu aşamada modelin yeterli olmadığına kanaat getirilirse, modeldeki parametreler değiştirilir ve yeni modeller kurulur. Modelin yeterli tahminler ürettiğine kanaat edildiği durumda ise model oluşturma aşaması sona ermektedir. Tahmin süreci (aşaması) başlamaktadır. Tahmin aşamasında yeterli olduğuna kanaat getirilen model yeni gözlemlerle tekrar denemeye tabi tutulur. Modelin ürettiği sonuçlar ile gerçek veriler karşılaştırılır ve modelin ne kadar hatalı tahminde bulunduğu belirlenir. Eğer istikrarlı bir tahmin söz konusu ise bu durumda model olduğu gibi kabul edilir. Aksi durumda modelin yeniden belirlenmesi gerekmektedir (Abraham ve Ledolter, 2005: 4).

Bir zaman serisinin tahmininde var olan $(x_1, x_2, x_3, \dots, x_n)$ değerlerinden yola çıkmak suretiyle, geleceğe ilişkin (x_{n+1}, x_{n+2}) değerler tahmin edilmeye çalışılır.

Tahmin yaklaşımları üç grup altında toplanabilir (Palit ve Popovic, 2005: 50):

- Kişisel yargılar, sezgisel ve ilgili diğer bilgilerden yola çıkmak suretiyle hesaplanan tahminler,
- Tek boyutlu zaman serisinden yola çıkmak suretiyle hesaplanan univariate tahminler,
- İki ya da daha fazla boyuta sahip veri setinden yola çıkmak suretiyle gerçekleştirilen multivariate tahminlerdir.

Yukarıdaki tahminler yaklaşımları birleşik şekilde kullanılabilir. Örneğin univariate tahmin gerçekleştirildikten sonra kişisel yargılarla düzenlemeler yapılabilir.

Tahmin yöntemi belirlenmeden önce, tahminin nasıl kullanılacağı, hangi kesinlikte tahminlerin beklendiği, hesaplama gücünün varlığı, kaç adet değişkene ilişkin tahminin gerçekleştirileceği, var olan veri setinin büyüklüğü ve kaç dönem sonraya ilişkin tahminlerin gerçekleştirileceğinin belirlenmesi önem arz etmektedir (Palit ve Popovic, 2005: 50).

3.8.2. İstatistiksel Yöntemler

İstatistiksel yöntemlerle hisse senedi fiyat tahmininde, hisse senedi fiyat hareketleri zaman serileri olarak görülmektedir. Zaman serileri ve zaman serilerinin tahmin edilmesi bilimde, mühendislikte ve işletme disiplinde önemli bir hale gelmiştir ve sahip olduğu önem giderek artmaktadır. Bir zaman serisi belirli aralıklarla gözlenen fiziksel veya finansal değişken olarak tanımlanabilir (Palit ve Popovic, 2005: 17).

Hisse senedi fiyatları da zaman serisi olarak adlandırılabilir çünkü belirli aralıklarla ölçülmekte olan sayısal değişkenlerdir.

Geleneksel yöntemlerle hisse senedi fiyat tahminleri hakkında yapılan çalışmalar (Atsalakis ve Valavanis, 2010) makalesinde detaylı bir şekilde incelenmiştir. Bu bölümde söz konusu yöntemler tanıtılacaktır.

3.8.2.1. Otoregresif Model (AR(p))

Otoregresif modelde, bir zaman serisinin şimdiki değeri, daha önceki değerlerin doğrusal bir birleşimine ve bir hata terimine bağlıdır (Palit ve Popovic, 2005: 27).

3.8.2.1.(1). Birinci Dereceden Otoregresif Süreç

$$y_t = c + \phi y_{t-1} + \varepsilon_t$$

3.8.2.1.(2). P Dereceden Otoregresif Süreç

$$y_t = c + \phi_1 y_{t-1} + \phi_2 y_{t-2} + \dots + \phi_p y_{t-p} + \varepsilon_t$$

Daha kısa olarak aşağıdaki gibi ifade edilebilir.

$$y_t = c + \varepsilon_t + \sum_{i=1}^p \phi_i y_{t-i}$$

Formüldeki p değeri modelin derecesini içermektedir. Otoregresif modelin geçerli olabilmesi için zaman serisini doğrusal olması gerekmektedir (Hamilton, 1994).

3.8.2.2. Hareketli Ortalamalar Yöntemi (MA(q))

3.8.2.2.(1). Birinci Dereceden Hareketli Ortalamalar Süreci MA(1)

$$y_t = \mu + \varepsilon_t + \theta \varepsilon_{t-1}$$

Formülde μ ve θ katsayılarıdır. Bu zaman serisi modeli, birinci dereceden hareketli ortalamalar süreci olarak adlandırılmaktadır ve MA(1) ile gösterilir. ε ifadesi son iki değer hareketli ortalamasıdır (Hamilton, 1994).

3.8.2.2.(2). Q Dereceden Hareketli Ortalamalar Süreci

$$y_t = \mu + \varepsilon_t + \theta \varepsilon_{t-1} + \theta \varepsilon_{t-2} + \dots + \theta_q \varepsilon_{t-q}$$

Yukarıdaki formül daha kısa olmak üzere aşağıdaki gibi ifade edilebilir.

$$y_{t+1} = \mu + u_t + \sum_{i=1}^q \theta_i \varepsilon_{t-i}$$

3.8.2.3. ARMA Modeli (ARMA(p,q))

Otoregresif yöntem ile hareketli ortalamalar yönteminin birleşimi ARMA modelini oluşturmaktadır (Hamilton, 1994).

$$y_t = c + \phi_1 y_{t-1} + \phi_2 y_{t-2} + \dots + \phi_p y_{t-p} + e_t + \theta_1 e_{t-1} + \theta_2 e_{t-2} + \dots + \theta_q e_{t-q}$$

Yukarıdaki formülde p dereceden otoregresif model söz konusu iken, q dereceden hareketli ortalamalar süreci söz konusudur.

3.8.2.4. ARIMA Yöntemi (ARIMA(p,q,d))

ARIMA (Autoregressive Integrated Moving Average) yöntemi Box-Jenkins yöntemi olarak da adlandırılmaktadır. Doğrusal olmayan fakat farkı alındığında doğrusal olan zaman serilerinin tahmininde kullanılmaktadır. Fark alma işleminde ardışık değerlerin ardışık farkları alınır. Örneğin $X_t - X_{t-1}$ gibi.

ARIMA yöntemi ARIMA(p,q,d) ile ifade edilmektedir. İfadedeki p değeri otoregresif modelin parametresini, q değeri ise hareketli ortalamanın derecesini ifade etmektedir. D derecesi ise farkın derecesini temsil etmektedir. Örneğin ARIMA(2,3,1) modelinde iki adet otoregresif parametre, üç adet hareketli ortalama parametresi söz konusudur ve bu değerler orjinal zaman serisinin ilk farkı alındıktan sonra uygulanır. ARIMA yönteminde model parametrelerinin belirlenmesinde otokorelasyon ve kısmi otokorelasyon değerleri kullanılmaktadır.

3.8.2.5. Regresyon Yöntemi

Gözlenen değişkenler arasındaki ilişkiyi modelleyen regresyon analizi yardımıyla tahminler gerçekleştirilebilir. Buradaki amaç, bir değişkenin gelecekteki değerini, ilgili olduğu ve gözlenebilen diğer değişkeni dikkate almak suretiyle tahmin gerçekleştirilmektedir. Basit, çoklu ve doğrusal olmayan regresyon yöntemleri mevcuttur (Palit ve Popovic, 2005).

Basit regresyonun denklemi aşağıdaki gibidir.

$$Y_i = a_0 + a_1 X_i + \varepsilon_i$$

Formülde yer alan ε_i ifadesi hata terimini göstermektedir ve hatalarının ortalamasının sıfır olması beklenmektedir. Ayrıca hata teriminin dağılımının varyansının bir olması beklenmektedir. Formüldeki bilinmeyen a_0 ve a_1 değerleri $\sum_{i=1}^n (y_i - a_0 - a_1 x_i)^2$ ifadesinin en küçük kılacak şekilde belirlenmelidir.

Çoklu regresyon yönteminde ise sadece bir adet x değeri söz konusu değildir. Buna karşın birden fazla x değeri denklemde yer almaktadır.


$$y = a_0 + a_1 x_1 + a_2 x_2 + \dots + a_n x_n$$

3.8.2.6. Lojistik Regresyon Yöntemi

Hisse senedi fiyatının değil de yönünün tahmin edilmesinde kullanılacak bir yöntemdir. Bir önceki bölümde anlatılan regresyon modeli sayısal x ve y değişkenleri için uygundur. Fakat y değişkeninin 0 ile 1 değerlerinden oluşan ikili bir değişken olması durumunda yukarıdaki model geçerli olmayacaktır. Aşağıdaki model uygun olacaktır (Devore ve Berk, 2007: 600).

$$p(x) = \frac{e^{\beta_0 + \beta_1 x}}{e^{\beta_0 + \beta_1 x} + 1}$$

Aşağıdaki şekilde p(x) fonksiyonun grafiği yer almaktadır (Şekil 3.6).



Şekil 3.6. Lojistik Regresyon Fonksiyonu

Lojistik regresyon yöntemi hisse senedi fiyatlarındaki yönü tahmin etmek için uygun bir araçtır.

3.8.3. Bilgi İşlemsel Zeka Yöntemleri

3.8.3.1. Yapay Zeka

Yapay zeka yönteminde esas olarak problemler için çözüm yollarının araştırılması söz konusudur. Örnek olarak satranç algoritmaları verilebilir. Satranç algoritmalarında insan zihninin satranç oynarken düşünme şekli algoritma halinde ifade edilmeye çalışılmaktadır. Bir başka örnek ise yabancı dilden çevirilerdir.

Öğrenmek hayvanların içgüdülerinde vardır. Öğrenme sayesinde daha önce karşılaşılmamış durumlarla başa çıkmak mümkün hale gelmektedir. Makinelerin de öğrenmesi sağlanabilmektedir. Bu amaçla ya önceden bilinen çiftler sayesinde makine eğitilmektedir veya makinenin parametreleri kendi kendine uyumlaştırması sağlanmaktadır (Chen vd, 2007).

Geleneksel yapay zeka yöntemlerinde problemler sembollerle ifade edilir ve problemin farklı boyutları için kurallar tanımlanır. Geleneksel yapay zeka yöntemleri analogi tabanlı öğrenmede ve tümevarımsal problemlerde oldukça başarılıdır. Fakat denetimli öğrenmede yetersiz kalmaktadır.

3.8.3.2. Bilgi İşlemsel Zeka Yöntemleri Hakkında Genel Bilgiler

Klasik yapay zeka yöntemlerinin yetersiz olduğu noktalar, geleneksel olmayan mühendislik modellerinin yaratılmasını sağlamıştır. Bu yeni yöntemlere bilgi işlemsel zeka yöntemleri adı verilmektedir.

Bir yöntemin bilgi işlemsel zeka yöntemi olarak adlandırılabilmesi için, parametrelerini ya önceden belirlenmiş kriterlere göre veya girdi ve çıktı örneklerindeki değişimlere bağlı olarak değiştirebilmesi gerekmektedir. Birçok yapay sinir ağı modeli bu özellikleri taşımaktadır.

Bilgi işlemsel zeka yöntemi ham veriyi alabilmeli ve işleyebilmelidir. İkinci olarak paralel işlem yapabilme özelliğine sahip olmalıdır ve son olarak da güvenilir ve makul bir zamanda yanıt verebilmelidir (Konar, 2005). Şekil 3.7 de bilgi işlemsel zeka yöntemleri familyası görülmektedir.



Şekil 3.7. Bilgi İşlemsel Zeka Yöntemleri (Konar, 2005:6).

Bilgi işlemsel zeka yöntemleri (Computational Intelligence), geleneksel istatistiksel ve mühendislik yöntemlerinin çözmekte başarılı olamayacakları işletmecilik ve ekonomi problemlerini ele almaktadır. Geleneksel yöntemlerde çözüme ulaşabilmek için problemin teorik temellere dayandırılması gerekmektedir. Teorik temellere dayanan çözümler ise çoğunlukla doğrusal ve gerçekçi olmayan varsayımları şart koşmaktadır. Bilgi işlemsel zeka yöntemleri ise insan zihninin bir uzantısı gibi çalışan bilgisayarlaştırılmış sistemlerdir. Bu yöntemler insanın düşünme şeklini, biyolojik sistemleri veya diğer doğal sistemleri taklit etme ve karmaşık hesaplamaları insan zihninden çok daha hızlı gerçekleştirebilme yeteneğine sahiptir. Bu gibi avantajları bilgi işlemsel zeka yöntemlerini karar verme sürecinde tercih edilebilir hale getirmektedir (Chen vd., 2007).

3.8.3.3. Uzman Sistemler (Expert Systems)

Uzman sistemler 1960 lı yılların ortalarında ortaya çıkmıştır ve bilgi işlemsel zeka araştırma alanının ilk ticari uygulamaları olarak kabul edilmektedir (Voges ve Pope, 2006:3).

Uzman bir sistem, çözümü için belirli bir alanda yıllarca çalışmış bir insanın deneyimlerini gerektiren bir problemi çözmeye çalışan bilgisayar programları olarak tanımlanabilmektedir (Rutkowski, 2005: 10). Uzman sistemlerin temelinde yatan mantık, belirli bir alandaki uzmanlık bilgisini bir bilgi tabanına çevirmek ve kullanıcılarla bilgi alışverişini sağlayan bir arayüz oluşturmaktır.

3.8.3.4. Yapay Sinir Ağları

3.8.3.4.(1). Giriş ve Tarihçe

Bu bölümde yapay sinir ağlarının tarihçesinin bir özeti sunulacaktır. Daha detaylı tarihçe bilgisi için, Palit ve Popovic (2005:80)' e başvurulmalıdır.

Warren McCulloch ve Walter Pitts (1943), sinirsel davranışın matematiksel teorisini yayınlamışlardır ve bu yayın ile birlikte gelecekteki dijital hesaplama, uzman sistemler, sinirsel hesaplamalar ve nöronfizyoloji çalışmalarını önemli ölçüde etkilemişlerdir. McCulloch-Pitts nöronu, biyolojik nöronun basitleştirilmiş bir modelidir. Bu teoriye göre, nöronun içsel faaliyetleri şu beş prensipten etkilenmektedir:

1. Sinirsel faaliyet ikili sistemdedir (başka bir ifade ile nöronun çıktısı açık veya kapalı olmak üzere sadece iki değer alabilmektedir)
2. Nöronların sabit bir aktivasyon fonksiyonu vardır. Böylelikle aynı girdi deseni aynı çıktının alınmasına yol açacaktır.
3. Nöronunu tepkisi anidir. Girdilerin etkilemesi ile birlikte çıktı anında alınmaktadır.
4. Nörona ait olan girdi engellendiğinde nöron aktive olmaz.
5. Nöronlara ait olan bağlantılar değişmemektedir.

Her ne kadar problem çözme yeteneği az da olsa, yapay sinir ağları tasarımlarında temel olarak kullanılmıştır. McCulloch-Pitts nöronu girdilerden, ağırlıklardan, toplama fonksiyonundan, kesin sınırlı veya adımli transfer fonksiyonundan oluşmaktadır.

Dış dünyadaki değişkenlerden oluşan bir girdi vektörü ($i_1, \dots, i_n$), nörondaki ağırlık vektörü ($w_1, \dots, w_n$) ile çarpılmaktadır. Ağırlıklandırılmış girdiler toplanmaktadır. Eğer bu toplam belirli bir eşik değerinden daha büyükse, çıktı bir (1) olmaktadır. Eğer eşik değeri sağlanmadıysa, çıktı sıfır (0) olmaktadır. Bu aktivasyon fonksiyonu şu şekilde ifade edilebilir:

$$net_i = \sum_{j=1}^n (w_{ij} * o_j)$$

Formüldeki net_i ifadesi i nöronuna ait olan çıktı sinyalini; w_{ij} ise nöron i ve nöron j 'ye ait olan sinaptik bağlantıyı; o_j ise nöron j 'ye ait olan çıktıyı ifade etmektedir.

Nöron i ye ait olan çıktı, nöron j 'den nöron i 'ye gelen sinyallerin ağırlıklar ile çarpılması ve bütün çarpımların toplamına eşittir.

McCulloch ve Pitts (1943) bu nöronların ikili mantıksal hesaplamalarda kullanılabileceğini ve bir ağ oluşturdukları zaman daha karmaşık problemleri çözebileceğini göstermişlerdir. McCulloch-Pitts nöronunu temel noksanlığı, bir problemi çözmek için ağırlıkların önceden hesaplanmış olması gerektiğidir. Nöronlar arasındaki ağırlıkların düzeltilmesi için bir prosedür söz konusu değildir. Kısacası McCulloch-Pitts nöronunda öğrenme kuralı mevcut değildir.


Fizyolojist Donald Hebb (1949) öğrenme sürecinde nöronların nasıl fiziksel olarak değişikliğe uğradığını araştırmıştır. Çok sık uyarılan nöronal patikadaki bağlantıların daha güçlü olacağı yönündeki kural Hebb'in öğrenme kuralı olarak bilinmektedir. Bu kuralın matematiksel nöron modeline uyarlanması Frank Rosenblatt tarafından gerçekleştirilmiştir.

Rosenblatt (1958), McCulloch-Pitts ve Hebb'in çalışmalarını temel almak suretiyle sanal nöron (perceptron) adı verilen yapıları geliştirmiştir. Rosenblatt, Hebb'in kuralının bir varyasyonunu kullanmak suretiyle, mantıksal işlemleri

gerçekleştirebilmiştir ayrıca, eğitim sürecinin bir sonucu olarak sistemin kendi kendisini ayarlayabildiğini ve bilgileri saklayabildiğini göstermiştir.

Rosenblatt öğrenme teoremine göre, sanal nörona sunulan her şey öğrenilebilecektir. Sunulmaktan kasıt, örnek veri setine bir fonksiyonun bulunmasıdır. Öğrenme ise sinir ağındaki ağırlıkların sistematik bir şekilde düzeltilmesini gerektirmektedir. McCulloch ve Pitts'in 1943 yılında sundukları sinirsel davranışın beşinci kuralı nöronlar arasındaki bağlantıların değişmediğidir. Rosenblatt bu beşinci kurala Hebbian öğrenme teorisi yoluyla karşı çıkmıştır.

Rosenblatt'ın yayınından iki yıl sonra elektrik mühendisi olan Bernard Widrow ve Ted Hoff ADELİNE (Adaptive Linear Element) in patentini almışlardır (Palit ve Popovic, 2005:80). ADELİNE tek bir nörondan oluşmaktadır ve bu nöronda toplam fonksiyonu, doğrusal bir transfer fonksiyonu ve her bir girdi elemanı için değiştirilebilir sinaps bulunmaktadır (Şekil 3.8).



Şekil 3.8. Doğrusal Bir Fonksiyon ile ADALINE Yapısı (Scarborough ve Somers, 2006: 32).

ADELİNE ve ADELİNE ağı (Multiple Adaptive Linear Elements MADELINE) sinir ağı teknolojisinde önemli bir adım olarak nitelendirilmektedir. Uzun mesafeli telefon sistemlerinde ekonun ortadan kaldırılması için, medikal ve endüstriyel uygulamalarda gerçek zamanlı süreç kontrolü için ve bilgisayar model teknolojisi için uygulanmıştır.

Widrow ve Hoff 'un geliştirdiği ADALINE modeli önemli bir gelişmedir çünkü sanal nöron eğitim algoritmasına delta kuralı olarak da bilinen ve sürekli girdi ve çıktı değişkenleri ile işlem görebilen least mean square kavramı eklenmiştir.

ADALINE, LMS regresyon presdürünü, ağıın ürettiği çıktılar ile gerçekleşmesi arzu edilen çıktılar arasındaki farkı minimum kılacak şekilde ağırlık matrisini değiştirmek için kullanılmaktadır. Delta kuralı toplamdaki MSE değerini aşağıdaki formüle göre minimum yapmaya çalışmaktadır:

$$\Delta w_{ij} = \eta (T_i(t) - a_i(t)) o_j(t)$$

Formüldeki Δw_{ij} nöron j 'den nöron i 'ye olan ağırlığındaki değişmeyi, T_i gerçek cevabı; t zamanı, a_i nöron i nin aktivasyonunu, o_j ise nöron j 'nin çıktısını ve η öğrenme katsayısını temsil etmektedir (Scarborough and Somers, 2006: 35).

Delta kuralı T_i değişkeninin (gerçek çıktı değerlerinin) bilinmesini gerekli kılmaktadır. Bu nedenle doğru çıktılarının bilinmediği durumlarda (denetimin olmadığı durumlarda) uygulanamaz.

1960 lı yılların ortalarında Massachusetts Institute of Technology (MIT) profesörlerinden Marvin Minsky ve Seymour Papert, tek katmanlı sanal nöron ağı ile

çözülemez bir problem tanımlamışlardır (Palit ve Popovic, 2005). Perceptrons adı verilen kitaplarında sanal nöronun yapısının, verisetinin doğrusal bir çizgi veya doğrusal bir düzlem ile ayrılabilen problemler için geçerli olduğunu kanıtlamışlardır. Doğrusal ayrılabilirlik kısıtı, tek katmanlı sanal nöron ağına doğrusal olmayan problemleri çözmesini engellemektedir. Bu bulgu ile birlikte, yapay sinir ağları çalışmaları yaklaşık bir yıl boyunca durma noktasına gelmiştir. Yine de söz konusu zaman diliminde öz düzenleyici haritaların (self-organizing maps) temelleri atılmıştır. Sinirsel hücreler belirli bir aralıktaki sinyaller almaktadır ve işlem görmektedir. İşlemler devam ettikçe, sinir hücreleri daha sık aktive olduğu aralıktaki sinyalleri almak üzere kendini ayarlamaktadır ve sonuçta girdi frekanslarının dağılımı veya topolojik haritası oluşmaktadır. Sonuçta ortaya çıkan harita gelen sinyalin karmaşıklığını azaltmaktadır. Denetimli öğrenmenin aksine özdüzenleyici haritalar geometrik yakınlığı dikkate almaktadır.

Özdüzenleyici haritalar Teuvo Kohonen'in 1982 yılında yayınladığı kitap ile bugünkü halini almıştır (Kohonen, 2001). Özdüzenleyici haritalar denetimsiz öğrenme kuralını uygulamaktadır bu nedenle de kümeleme analizleri için uygundur.

Geri beslemeli eğitim algoritması (backpropagation training algorithm) genelleştirilmiş delta kuralı olarak da bilinmektedir ve LMS algoritmasının doğrusal olmayan bir uzantısıdır. Sanal nöron ve ADELİNE-MADELİNE teknolojisinin kısıtlarını ortadan kaldırmak için çok katmanlı ağların eğitiminde hesaplama açısından etkin bir yöntemdir ve bu yöntemde doğrusal olarak ayrılamayan fonksiyonların çözümü amaçlanmaktadır.

Yapay sinir ağları sinyal analizinde, değişken seçiminde, verilerin sınıflandırılmasında ve desenlerin keşfedilmesinde başarılı bir şekilde kullanılmaktadır. Gözlem yapılan veri setinden öğrenme yeteneği kullanılarak, genelleştirilmeler yapılabildiği için mühendisler ve araştırmacılar tarafından sıklıkla kullanılmışlardır. Bu kadar popüler olmalarının sebebi, problem çözmek için gereken hesaplama gücünü oldukça düşürebilmeleridir.

Yapay sinir ağlarının aşağıda sıralanan özellikleri, çok pratik bir araç olmalarını sağlamıştır (Palit ve Popovic, 2005: 80).


- zaman serisinin geçmişteki değerleri ile gelecekteki değerleri arasındaki doğrusal olmayan ilişkileri ortaya çıkarabilmesi
- veri setindeki ilişkinin bilinmediği zamanlarda veya matematiksel olarak ifade edilmesinin zor olduğu zamanlarda veya toplanan verilerin gürültülü olduğu zamanlarda bile esas fonksiyonel ilişkiyi ortaya çıkarabilme yeteneği
- keyfi olarak belirlenen doğrusal olmayan sürekli fonksiyonları yüksek doğrulukla modelleyebilme yeteneğine sahiptir
- verilerin denetiminde öz düzenleyici bir şekilde, örneklerden öğrenebilme ve genelleştirebilme yeteneği

3.8.3.4.(2). Biyolojik Altyapı

İnsan beynindeki nöronların farklı çeşitlerde olduğu belirlenmiştir. Gerçek nöronların karmaşık yapıları basitleştirme yoluna gitmek suretiyle daha kolay anlaşılır hale getirilmektedir. Tipik nöron diye bir kavram olmamasına rağmen, yapay sinir ağlarındaki temel kavramların anlaşılması için gerçek bir nöron basit bir şekilde sunulacaktır (Arbib, 2003: 3).

İnsan beyni nöron adı verilen sinir ağlarından oluşmaktadır. Bu biyolojik hücreler bilgiyi almakta ve insan vücudunun farklı parçaları ile iletişime geçmektedir (Gupta vd., 2003: 22). İç ve dış çevredeki değişiklikleri sürekli gözlemleyen ve algılayıcı (receptors)

adı verilen yapılar, sinir ağına girdiyi sağlamaktadır. Kasların hareketini sağlayan ve sinir ağının faaliyetleri ile yönetilen hücreler motor nöronlar olarak adlandırılmaktadır. Bu iki çeşit hücre arasında ise algılayıcılar ile motor nöronlar arasındaki sinyalleri ileten karmaşık bir sinir ağı mevcuttur (Arbib, 2003: 3).



Şekil 3.9. Biyolojik Nöron Yapısı (Arbib, 2003:4).

Temel nöron yapısı Şekil 3.9 'da şematize edilmiştir. Hücre gövdesi (soma) 'dan dışarıya doğru dendrit adı verilen uzantılar yer almaktadır. Soma ve dendritler nöron için girdiyi sağlayan birimlerdir. Akson tepecikçi adı verilen noktadan, akson adı verilen uzun bir lif çıkmaktadır. Aksonların uzantısı ise aksonal arborizasyon denilen yapıları oluşturmaktadır. Aksonun dalları sinir terminalleri olarak adlandırılmaktadır. Sinir terminalleri ile bir sonraki hücre arasındaki etkileşim sinaps (synapse) olarak bilinir. Bilgi akışı şekildeki oklarla gösterilebilir. Hücrede her iki yönde de bilgi akışı olabilir. Buna rağmen çoğu sinapslar dendrit, soma, axon hillock, axonal arborizasyon ve sinir terminalleri yordamını izlemektedirler (Arbib, 2003: 4).

Biyolojik sinirsel süreçte dendritler sinir hücreleri için girdi sağlamaktadır. Bu sinyaller pasif bir şekilde hiçbir değişikliğe uğramadan somaya iletilmektedir. Bu sinaptik sinyaller somada işlenmektedir ve ulaşılan sonuç axona iletilmektedir. Aksonlardaki dallar se bu sinyali, diğer nöronlar, kaslar ve alıcılara iletmektedirler (Gupta vd., 2003: 25).


İnsan beyni 10 milyardan daha fazla nöron içermektedir. Bu nöronlar birbirleriyle karmaşık bir şekilde bağlanmışlardır ve büyük ölçekte sinyal işleme görevi görmektedirler. Her bir nöronda 1000 ile 10000 arasında dendrit bulunmaktadır. Bir nöron komşusu olan diğer nöronlardan sinyaller almaktadır ve kendisinin etkileyebileceği diğer komşuları için bu sinyalleri işlemekte ve yeni sinyaller yaratmaktadır (Gupta vd., 2003: 27).

3.8.3.4.(2).(a). Sinirsel İşlemler

İki ayrı matematiksel işlem söz konusudur (Gupta vd., 2003: 29):

- (i) Sinaptik işlemler. Sinapsın gücü (ağırlığı) bilginin saklanma durumunu temsil etmektedir. Sinapik işlem her bir gelen sinyale göreli bir ağırlık (önem) atamaktadır. Bu ağırlık geçmiş deneyimlerden yola çıkarak atanmaktadır.


- (ii) Somatik işlemler. Bu işlemler toplama, doğrusal olmayan aktivasyon, eşikleme ve dinamik işleme gibi işlemlerden oluşmaktadır.



Şekil 3.10. Sinaptik ve Somatik İşlemlerin Gösterimi

Şekil 3.10 'de sinaptik ve somatik işlemlerin gösterimi yer almaktadır. Geri plandaki yapay sinir ağı modeli ise tek katmanlı bir nöronal modeldir ve ileride detaylı olarak incelenecektir.

3.8.3.4.(3). Yapay Sinir Ağı Mimarileri



Şekil 3.11. İleri Beslemeli Yapay Sinir Ağları Çeşitleri (Scarborough ve Somers, 2006:41).

Şekil 3.11 'de ileri beslemeli yapay sinir ağı çeşitleri yer almaktadır. İlerleyen sayfalarda da açıklanacağı üzere bu çalışma doğrusal olmayan ve denetimli bir ileri beslemeli yapay sinir ağını kullanmaktadır.


3.8.3.4.(3).(a). Temel Yapay Sinir Ağı Yapısı

Yapay sinir ağlarının en temel ve basit bilgi işleme birimi nöronlardır. Şekil 3.12 'de temel bir nöron modeli görülmektedir.

Basit bir nöronal modelin üç adet özelliği söz konusudur (Haykin, 1999: 32).

- Bir dizi ağırlıklar vardır. Örneğin girdi sinyali p_j nöron k ile w_{kj} ağırlığı ile bağlanmıştır. Başka bir ifade ile girdi sinyali ilgili ağırlıkla çarpılacaktır. Ağırlıkların isimlendirilmesi önemli olmaktadır. Bir ağırlığın indisindeki ilk gösterge nöronu ifade ederken, ikinci gösterge girdiyi ifade etmektedir. Ağırlıklar pozitif olabileceği gibi negatif de olabilmektedir.
- Toplama birimi. Bu birim kendisine gelen sinyallerin toplanmasını sağlar.
- Aktivasyon fonksiyonu. Bir nöronun çıktısının genişliğini sınırlayan fonksiyondur.

Şekilde ayrıca eğim b de görülmektedir. Bu eğim aktivasyon fonksiyonunun net girdisini azaltabilme veya arttırabilme özelliğine sahiptir. Pozitif veya negatif olabilmektedir.



Şekil 3.12. Tek Katmanlı ve Tek Nöronlu Yapay Sinir Ağı

Matematiksel olarak bir nöron iki adımda, şu şekilde ifade edilebilir.

$$n = w_{1,1}p_1 + w_{1,2}p_2 + \dots + w_{1,R}p_R + b$$

yukarıdaki denklem matris notasyonu ile daha kısa bir şekilde ifade edilebilir. Matris notasyonunda çarpımı ifade etmek için koyu font kullanılmaktadır. Yukarıdaki denklem şu şekilde de ifade edilebilir:

$$n = \mathbf{W}_p$$

ve

$$a = f(\mathbf{W}_p + b)$$

Bu denklemlerde $p_1, p_2, \dots, p_n$ girdi sinyallerini; $w_1, w_2, \dots, w_m$ ise nöronun ağırlıklarını; n girdi sinyallerinin toplamını; b eğimi; f aktivasyon fonksiyonunu ve a nöronun çıktısını temsil etmektedir.

Çok katmanlı sanal nöronlar öğrenme, sınıflandırma, recognition, ve tahmin gibi görevleri gerçekleştirmek için kullanılmaktadırlar ve insan beyninin çalışma biçimini taklit eden yapay sinir ağlarının özel bir çeşididir. Yapay Sinir ağı modeli neuron olarak adlandırılan işlem birimlerinin bir araya gelmesi ile oluşmaktadır. Her bir nöron diğer nöronlara ağırlıkları içeren bağlantılarla bağlanmış durumdadır. Girdi bağlantısı olmayan nöronlar girdi nöronları olarak adlandırılırken, çıktı bağlantısı olmayan nöronlar çıktı nöronları olarak adlandırılmaktadır. Yapay sinir ağlarında paralel işlem görmek esastır.


Girdi nöronları, çıktı nöronları ve bunlar arasındaki ağırlıkları içeren bağlantılar multilayer sanal nöronun mimari yapısını oluşturmaktadır.

3.8.3.4.(3).(b). Çok Nöronlu Tek Katmanlı Yapay Sinir Ağı Modeli

Buraya kadar ifade edilen çok girdili yapay sinir ağı modelinde, ara katmanda bir tane nöron bulunmaktadır. Nöron sayısı daha da fazla arttırılabilir. Bir katmanda birden fazla nöronun kullanılması ile Şekil 3.13 elde edilmektedir. Şekildeki gibi katmanda ağırlık matrisi, toplama fonksiyonları, eğim vektörü, transfer fonksiyonları ve çıktı vektörü bulunmaktadır.

Tek katmanlı yapay sinir ağlarında nöronlar katman adı verilen formlarda dizilirler. En basit katmanlı nörona ise bir girdi katmanı ve bir çıktı katmanı söz konusudur. Bu tür ağları tek katmanlı ağlar adı verilmektedir.

Tek katmanlı ileri beslemeli yapay sinir ağlarında nöronlar arasındaki bilgiler sadece ileri yönlü akmaktadır. Başka bir deyişle bilgi girdilerden çıktılara doğrudur.



Şekil 3.13. Tek Katmanlı ve Çok Nöronlu Yapay Sinir Ağı Modeli

Girdi vektörünün her bir elemanı (b), her bir nörona ağırlık vektörü (W) ile bağlıdır. Her bir nöronun eğimi (b), bir adet toplama fonksiyonu, bir adet transfer fonksiyonu (f) ve bir adet de çıktısı (a) söz konusudur.

Nöron sayısı ile girdi sayısının birbirine eşit olması gerekmez (başka bir ifade ile $R \neq S$). Ayrıca her bir nöronun aynı transfer fonksiyonuna da sahip olması gerekmez.

3.8.3.4.(3).(c). Çok Katmanlı Yapay Sinir Ağı Modeli

Bir önceki bölümde girdi katmanı ve çıktı katmanı arasında bir tek ara katmanı olan nöronlardan bahsedilmişti. Bu bölümde ise ara katman sayısı birden fazla olan yapay sinir ağları anlatılmaya çalışılacaktır.

Çok katmanlı yapay sinir ağları, birden fazla ara katmanın olabildiği yapay sinir ağları çeşididir. Birden fazla katmanın eklenmesi ile birlikte ağ, daha karmaşık ilişkileri modelleyebilme özelliğine sahip olabilmektedir.

İlk ara katmanın girdilerini, girdi sinyallerinin işlem görmesi sonucu ortaya çıkan değerler oluşturmaktadır. İlk katmanın çıktıları ise ikinci katmanın girdileri olmaktadır


ve bu bütün katmanlarda devam etmektedir. En son katmandan çıkan değerler ise bütün ağın tepkisi olmaktadır.

Eğer çok katmanlı yapay sinir ağında bazı nöronların diğer nöronlarla bağlantısı eksikse bu durumda kısmi bağlantılı yapay sinir ağlarından bahsedilir (partially connected neural networks).

Çok katmanlı ileri beslemeli yapay sinir ağı modelinde ağırlık matrisi (W) şu şekildedir:

$$W = \begin{bmatrix} w_{1,1} & w_{1,2} & \dots & w_{1,R} \\ w_{2,1} & w_{2,2} & \dots & w_{2,R} \\ \dots & \dots & \dots & \dots \\ w_{S,1} & w_{S,2} & \dots & w_{S,R} \end{bmatrix}$$

W matrisinde her bir satır hedef nörona ilişkindir. Sütunlar ise girdileri temsil etmektedir. Dolayısıyla daha önce de ifade edildiği gibi $w_{3,2}$ ağırlığı, ikinci girdiden üçüncü nörona olan ağırlığı ifade etmektedir.



Şekil 3.14. Çok Katmanlı ve Çok Nöronlu Yapay Sinir Ağı

Şekil 3.14 'de çok katmanlı ve çok nöronlu yapay sinir ağı mimarisi yer almaktadır. Şekilde görüldüğü gibi R adet girdi söz konusudur ve birinci katmanda S^1 adet nöron, ikinci katmanda S^2 adet nöron ve üçüncü katmanda S^3 adet nöron bulunmaktadır. Farklı katmanlarda farklı sayıda nöron söz konusu olabilir.

Bir nolu katmanın çıktıları iki nolu katmanın girdilerini oluşturmaktadır. İki nolu katmanın çıktıları ise üç nolu katmanın çıktıları oluşturmaktadır. Başka bir açıdan bakıldığında ise, iki nolu katman $R = S^1$ adet girdisi olan, $S = S^2$ adet nöronu olan ve ağırlık matrisi (W) $S^1 \times S^2$ boyutunda, tek katmanlı bir yapay sinir ağı gibi düşünülebilir. İkinci katmanın girdileri a^1 ve çıktısı a^2 olmaktadır.

Yapay sinir ağının çıktısını oluşturan katman çıktı katmanı olarak adlandırılır. Diğer nöronlar ise gizli nöron olarak adlandırılmaktadır. Şekilde çıktı katmanı üç numaralı katman olmaktadır ve (bir ve iki) numaralı katmanlar ise gizli katman olarak adlandırılmaktadır.

Çok katmanlı yapay sinir ağları, tek katmanlı yapay sinir ağları mimarisinden daha güçlüdür. Örneğin ilk katmanında aktivasyon fonksiyonları sigmoid olan ve ikinci katmandaki aktivasyon fonksiyonun doğrusal olduğu yapay sinir ağları birçok fonksiyonu tahmin etmekte başarılı bir şekilde kullanılabilir (Hagan vd., 1996)

3.8.3.4.(3).(d). Devirli Ağlar

Zamanla desenlerin keşfi için yapılan araştırmalar, zamana bağlı doğrusal olmayan yapay sinir ağları modellerine olan ihtiyacı ortaya çıkarmıştır. Zaman boyutunun, yapay sinir ağı topolojisine eklenmesi, zamana bağlı modelleme yapmayı mümkün hale getirmiştir. Elman 1990, context nodes kavramı ile global açıdan ileri beslemeli, yerel açıdan devirli kavramını önermiştir. Bu node lar yapay sinir ağlarına dinamik bir hafıza sunmaktadır (Palit ve Popovic, 2005: 87).

Devirli bir yapay sinir ağında bazı çıktıları girdilere bağlayan geri beslemeler vardır.

Söz konusu model aynı zamanda dinamik yapay sinir ağı olarak da bilinmektedir. Özçalıcı ve Ayırcay (2013) dinamik bir yapay sinir ağı kullanmak suretiyle döviz kuru tahmini gerçekleştirmişlerdir. Çalışmaları sonucunda dinamik modelin statik modele göre döviz kurlarını tahmin etmekte hem istatistiksel hem de finansal açıdan daha iyi sonuç verdiğini raporlamaktadırlar.

3.8.3.4.(4). Aktivasyon Fonksiyonu Çeşitleri

En sık kullanılan transfer fonksiyonları şu şekilde sıralanabilir

- *hardlim – adım fonksiyonu* . Step Transfer fonksiyonu olarak da bilinmektedir. Aktivasyon fonksiyonunun girdisi sıfıra eşit veya sıfırdan büyükse bu durumda çıktının 1 değerini aldığı, girdinin sıfırdan küçük olduğu durumlarda ise çıktı değerinin sıfır olduğu aktivasyon fonksiyonudur. Şu şekilde ifade edilebilir

$$y_k = \begin{cases} 1, & \text{Eğer } v_k \geq 0 \\ 0, & \text{Eğer } v_k < 0 \end{cases}$$

Bu tür nöronlar McCulloch-Pitts modeli olarak da tanınmaktadır.

- *Signum (İşaret Transfer Fonksiyonu)*: Step transfer fonksiyonuna benzemektedir. Sıfırdan küçük değerlerde -1, ve sıfırdan büyük değerlerde 1 değerini alacaktır.

$$y_k = \begin{cases} 1, & \text{Eğer } v_k \geq 0 \\ -1, & \text{Eğer } v_k < 0 \end{cases}$$

- *Doğrusal aktivasyon fonksiyonu*. Doğrusal nitelikteki problemlerin çözümünde kullanılan aktivasyon fonksiyonudur. İhtiyaç duyulan durumlarda kısmi doğrusal aktivasyon fonksiyonu da kullanılabilir. Kısmi doğrusal fonksiyonda belirli aralıkta doğrusal çıktı alınırken, belirlenen limitten düşük olduğu her durumda çıktı değeri sıfır değerini alır. Aynı şekilde belirlenen bir değerden büyük olduğu durumda çıktı değeri sürekli bir değerini almaktadır.

$$\varphi(v) = v$$

- *log sigmoid aktivasyon fonksiyonu.* Sigmoid aktivasyon fonksiyonu s şeklindedir. Bu fonksiyonda çıktı değerleri sıfır ile bir arasında olmaktadır.


$$\varphi(v) = \frac{1}{1 + e^{(-av)}}$$

Bu denklemde a eğim parametresini ifade etmektedir. Bu değer değiştiğinde sigmoid fonksiyonun şekli de değişmektedir.

- Hiperbolik tanjant sigmoid transfer fonksiyonu. Log sigmoide benzemektedir. Fakat bu fonksiyonda y değerleri -1 ile 1 aralığında yer alacaktır.

$$\varphi(v) = \frac{2}{1 + e^{-2v}} - 1$$

Yukarıda anlatılan transfer fonksiyonlarının grafiği Şekil 3.15 'da bir arada gösterilmiştir.



Şekil 3.15. Farklı Transfer Fonksiyonları

3.8.3.4.(5). Yapay Sinir Ağlarının Eğitimi

Yapay sinir ağları yapısı belirlendikten sonra, eğitim sürecine geçilir. Eğitim sürecinde ağırlıklar rastgele belirlenir. Daha sonra öğrenme sürecine geçilir. Denetimli eğitimde yapay sinir ağlarından üretmesi beklenen sonuçlar bilinmektedir ve yapay sinir ağları bu istenen sonuçları veya bu sonuçlara en yakın değerleri verecek şekilde ağırlıklarında değişiklikler meydana getirilir. Bu süreç öğrenme olarak adlandırılır.

Yapay sinir ağlarındaki eğitim tek bir adımda gerçekleşemez. Ağırlıklar, yenilemeler dahilinde belirlenir. Eğitim veri seti yapay sinir ağlarına sunulur ve ağın verdiği tepkiler takip edilir. Ağırlıklar, yapay sinir ağının verdiği bu tepkilere bağlı olarak yenilenir (Sumathi ve Surekha, 2010: 41).

Eğitim sürecinde öğrenme oranına ihtiyaç duyulur. Bu oran, öğrenmenin gerçekleştirilmesi için ağırlıkların ne kadar değiştirilmesi gerektiğini ifade etmektedir. Bir önceki ağırlık bütün olarak sistemden dışlanmaz. Bunun yerine şimdiki ağırlık ile bir önceki ağırlık arasındaki fark (delta değeri) hesaplanır ve orijinal ağırlıkla değişiklik

meydana getirilir. Yapay sinir ağındaki ağırlıklar değiştirildikten sonra eğitim veri seti tekrar girdi olarak yapay sinir ağlarına sunulur ve ağına verdiği sonuç dikkate alınır. Bu yenilemelere kabul edilen seviyenin altında değişiklik meydana gelene kadar devam edilir (Sumathi ve Surekha, 2010: 41).

Öğrenme kuralında hata paylarının da dikkate alınması gerekir. Hata, yapay sinir ağlarının ürettiği çıktı ile gerçek çıktı arasındaki farktır. Eğer böyle bir hata eğitim fonksiyonuna sunulabiliyorsa bu durumda denetimli eğitimden bahsedilir. Denetimli eğitimde yapay sinir ağları gerçek değerleri üretene kadar sürekli ağırlıklarını değiştirir.

3.8.3.4.(5).(a). Eğitim Çeşitleri

3.8.3.4.(5).(a).i. Denetimli Eğitim

Girdi ve çıktı değerleri yapay sinir ağlarına sunulmuşsa, denetimli öğrenmekten bahsedilir. Ağ, kendi ürettiği sonuçlarla gerçek sonuçları karşılaştırır. Bu karşılaştırmada açığa çıkan hatalar tekrar sisteme sunulur ve sistem ağırlıklarını yeniler. Eğitimin gerçekleştiği veri seti eğitim veri seti olarak adlandırılır. Eğitim süreci boyunca, eğitim veri seti birkaç kez yapay sinir ağlarında işlem görür ve yapay sinir ağının verdiği tepkiler (ağın çıktıları) ölçülür.

Denetimli eğitimde bazen yapay sinir ağları istenilen sonuçları vermez. Böyle bir duruma eğitim veri setindeki girdilerin, istenilen çıktıyı sağlayacak bilgiyi içermemesi neden olabilir (Sumathi ve Surekha, 2010: 41).

Denetimli eğitimde bazı veya bütün çıktı değişkenleri önceden bilinmektedir ve bu değerler "öğretmen" gibi davranır.

Denetimli eğitim şu şekilde özetlenecektir. İlk olarak şu verilerin var olması gerekmektedir.

- Girdi verileri, $X_1, \dots, X_n$
- Hedef (çıkı verileri), $Y_1, \dots, Y_k$
- Girdi verileri ve çıktı verileri örneklerini içeren eğitim seti
- Sadece girdi veri seti olan test seti

Buradaki amaç, henüz gözlemlenemeyen test veri setindeki girdilerin kullanılması ile çıktıların tahmin edilmesidir. Yeni girdi veri setindeki değerlerin kullanılması ile tahmin gerçekleştirebilecek bir modelin oluşturulması hedeflenmektedir (Poole ve Mackworth, 2010: 288).

3.8.3.4.(5).(a).ii. Denetimsiz Eğitim

Bu eğitim çeşidi genellikle sınıflandırma algoritmalarında kullanılmaktadır. Yapay sinir ağlarının ağırlıklarının belirlenmesinde yol gösterecek bir öğretmen olmadığı için ağırlıklar farklı şekillerde belirlenmektedir. Denetimsiz Eğitim, Kohonen Ağları olarak da bilinen, özdüzenleyici haritalarda kullanılmaktadır. Özdüzenleyici haritalar hakkında daha detaylı bilgi ve banka müşterilerinin bölümlendirilmesi hakkında örnek bir çalışma için (Özçalıcı, 2011) kaynağına başvurulabilir.

3.8.3.4.(5).(b). Sanal Nöron Eğitimi

Sanal nöronun eğitim süreci örnek olarak toplanmış veri seti ile gerçekleşir. Eğitim süreci boyunca, sanal nörona sunulan girdi ve çıktı değerlerine uygun olarak

ağırlıklar düzeltilir. Ağırlık vektörünün değiştirilmesi için ilk olarak Widrow ve Hoff (1960) tarafından delta kuralı (recursive gradient-type of learning algorithm veya α –LMC algoritması) önerilmiştir. Bu kuralda bir sonraki ağırlık, şimdiki ağırlıklara bir tazmin ifadesi eklenmek yoluyla hesaplanır.

$$w(k + 1) = w(k) + \eta \varepsilon(k) x(k)$$

bu ifadede η orantılılık ifadesini, $\varepsilon(k)$ hata ifadesini ve $x(k)$ girdi sinyalini ifade etmektedir. k ise adımı ifade etmektedir.

Oldukça basit olmasına rağmen, delta öğrenme kuralı birçok durumda yüksek başarı ve eğitimde yüksek hız sergilemiştir. Böyle olmasına rağmen, sadece tek bir sanal nöron bütün problemleri çözebilecek yeterlilikte değildir. Sanal nöronun sadece doğrusal olarak ayrılabilen (linearly seperable problems) problemleri çözebildiği görülmüştür. Bu nedenle genel amaç için kullanılamaz. Girdi katmanı ve çıktı katmanına ek olarak bunların arasına yerleştirilmiş saklı katmanların yer aldığı çok katmanlı sanal nöronlarla birlikte, daha karmaşık problemlerin çözülebilmesi mümkün hale gelmiştir. Birden fazla saklı katmanın kullanılması mümkün olsa da gerçekte çok nadir durumlarda fazladan gizli katmana ihtiyaç duyulur (Palit ve Popovic, 2005: 82).

3.8.3.4.(6). Yapay Sinir Ağlarında Öğrenme Algoritmaları

Bu bölümde farklı öğrenme yöntemleri açıklanacaktır. Yapay sinir ağlarında öğrenme ve eğitim ile farklı kavramlar ifade edilmektedir. Öğrenme yerel bir durumdur ve belirli bir ağırlığın bir sonraki durumun ortaya çıkarmaktadır. Eğitim kavramı ile bütün ağırlık eğitiminden bahsedilmektedir.

Yapay sinir ağlarının en önemli özelliği çevresinden öğrenebiliyor olması ve öğrenme yoluyla da performansını geliştirebiliyor olmasıdır (Haykin, 1999: 72). Öğrenme süreci zaman ile gerçekleşmektedir. Yapay sinir ağları, ağırlıklarını ve bias değerlerini çevresi ile etkileşim halinde düzenlemek suretiyle öğrenir. Temelde, yapay sinir ağları öğrenme sürecindeki her bir yenileme adımı ile birlikte, çevresi hakkında daha fazla bilgiye sahip olur.

Bu çalışmada yapay sinir ağlarındaki öğrenme şu şekilde tanımlanmaktadır:

Öğrenme, yapay sinir ağlarındaki serbest parametrelerin, ağırlıkların bulunduğu çevreden gelen uyarı süreci ile uyumlaştırılması bir süreçtir.

Bu tanımda öğrenme sürecindeki işlemler şu sıra ile gerçekleştirilmektedir (Haykin, 1999: 72):

- Yapay sinir ağları çevresinden uyarı almaktadır (girdiler)
- Bu uyarılara bağlı olarak yapay sinir ağları değişebilen parametrelerini değiştirme yoluna gitmektedir.
- Yapay sinir ağları çevresinde farklı bir şekilde tepki vermektedir, çünkü öğrenme ile birlikte içsel yapısı değişmiştir.

3.8.3.4.(6).(a). Hata Düzeltme Öğrenmesi (Error Correction Learning)

Bu öğrenme algoritmasını açıklamak için tek katmanlı ileri beslemeli basit bir yapay sinir ağı mimarisini göz önünde bulundurulacaktır. Nöron K'ya $x(n)$ gibi bir girdi sunulmaktadır. Çıktı sinyali ise $y_k(n)$ ile gösterilmektedir. Çıktı sinyali, hedef çıktı ($d_k(n)$) ile karşılaştırılmaktadır ve sonuçta bir hata sinyali ($e_k(n)$) ortaya çıkmaktadır.

$$e_k(n) = d_k(n) - y_k(n)$$

Denklemdaki hata sinyali, kontrol mekanizmasını harekete geçirmektedir. Bu kontrol mekanizması yapay sinir ağındaki nöron k 'nın ağırlıklarının düzeltilmesidir. Bu düzeltme işlemi ile birlikte, yapay sinir ağıının çıktısının $y_k(n)$, gerçek değer olan $d_k(n)$ değerine yaklaşması hedeflenmektedir. Hata sinyali kullanılmak suretiyle hesaplanan maliyet fonksiyonu minimum yapıldığında, bu hedef gerçekleştirilmiş olacaktır.

$$\xi(n) = \frac{e_k^2(n)}{2}$$

Bu denklemdaki $\xi(n)$ değeri hata enerjisinin ani değeri (instantaneous value of the error energy) ni temsil etmektedir. Sistem durağan bir hale gelinceye kadar (sinaptik ağırlıklar stabil bir hale gelinceye kadar) bu düzenleme işlemi adım adım devam eder. Stabil bir sistem oluşturulduğunda ise öğrenme süreci sona erdirilir.

Burada tanıtilan süreç hata düzeltme öğrenmesi olarak adlandırılır. Maliyet fonksiyonunun minimizasyonu delta kuralı olarak bilinen bir öğrenme kuralının ortaya çıkmasına neden olur. Bu kural kurucularına ithafen Widrow-Hoff kuralı olarak da isimlendirilir. $w_{kj}(n)$ ifadesinin, n . adımda $x_j(n)$ nöronu tarafından etkilenen (ateşlenen) nöron k nın w_{kj} ağırlığını temsil ettiği durum göz önünde bulundursun. Delta kuralına göre, düzeltme işlemi $\Delta w_{kj}(n)$ şu şekilde hesaplanacaktır.

$$w_{kj}(n) = \eta e_k(n) x_j(n)$$

Bu denklemda η pozitif bir sabittir ve bir adımdan diğerine geçilirken kullanılacak öğrenme oranını temsil etmektedir. Bu nedenle öğrenme oranı parametresi olarak adlandırılır. Ağırlıkta yapılan değişme girdi sinyali ile hata sinyaline bağlıdır (Haykin, 1999: 75).

Burada ifade edildiği gibi, delta kuralı hata sinyalinin doğrudan ölçülebildiğini varsaymaktadır. Bu öğrenme kuralının uygulanabilmesi için istenilen çıktıları temsil eden $d(n)$ serisini biliyor olmamız gerekmektedir. Şekilden de görülebileceği gibi, hata düzeltme öğrenmesi yerel bir yapıya sahiptir. Başka bir ifade ile delta kuralı nöron k nın çevresinde yerleşmiştir (Haykin, 1999: 75).

Nöronun ağırlığında meydana getirilecek değişme $\Delta w_{kj}(n)$ hesaplandığında, nöronun ağırlığı şu işlemle birlikte güncellenir:

$$w_{kj}(n+1) = w_{kj}(n) + \Delta w_{kj}(n)$$

Bu denklemdaki $w_{kj}(n)$ ile $w_{kj}(n+1)$ ağırlığın eski ve yeni değerleri olmaktadır. Denklem şu şekilde de ifade edilebilir:

$$w_{kj}(n) = z^{-1}[w_{kj}(n+1)]$$

Denklemdaki z^{-1} birim gecikme operatörü (unit-delay operator) olarak adlandırılır ve saklama elemanı (storage element) temsil etmektedir (Haykin, 1999: 75).

η parametresinin dikkatli bir şekilde belirlenmesi sistemin stabilitesi ve kesinliği üzerinde oldukça önemli olmaktadır (Haykin, 1999: 75).

3.8.3.4.(6).(b). Hafıza Bazlı Öğrenme - Memory Based Learning

Hafıza baslı öğrenme yönteminde, geçmiş deneyimlerin hepsi (veya büyük bir kısmı), doğru bir şekilde sınıflandırılan girdi-çıkı örnekleri hafızasında saklanmaktadır: $\{(\mathbf{x}_i, d_i)\}_{i=1}^N$. Burada $\mathbf{x}_i$ girdi vektörünü temsil ederken, d_i beklenen çıktıları temsil etmektedir.

Bütün hafıza bazlı öğrenme algoritmaları iki temel bileşeni içermektedir

- Test vektör ($\mathbf{x}_{test}$) ün yerel komşuluğunu tanımlamak için kullanılacak kriter
- Test vektörünün ($\mathbf{x}_{test}$) yerel komşuluğundaki eğitim örneklerinin eğitimi için kullanılacak öğrenme kuralı

Algoritmalar bu iki bileşenin tanımlanma biçimiyle birbirlerinden farklılaşmaktadır.

Basit fakat etkili bir yöntem olan en yakın komşuluk kuralında, yerel komşuluk test vektöründeki en yakın gözlemler olarak tanımlanmaktadır. Vektör

$$\mathbf{x}'_N \in \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N\}$$

eğer şu koşulu sağlarsa $\mathbf{x}_{test}$ in en yakın komşusu olarak tanımlanır.

$$\min_i d(\mathbf{x}_i, \mathbf{x}_{test}) = d(\mathbf{x}'_N, \mathbf{x}_{test})$$

Koşuldaki $d(\mathbf{x}_i, \mathbf{x}_{test})$ ifadesi $\mathbf{x}_i$ vektörü ile $\mathbf{x}_{test}$ vektörü arasındaki öklit uzaklığını temsil etmektedir (Michalewicz, 1996: 76).

3.8.3.4.(6).(c). Hebb Öğrenme Kuralı

Bütün öğrenme kuralları içinde en meşhuru ve en eskisi Hebb'in öğrenme kuralıdır. Bu kuralda, ağdaki ağırlıklar, ağın uyarılmadan önceki ve sonraki durumlarının bir fonksiyonudur.

$$\Delta W_{ij}(t) = \gamma x_j x_i$$

Formülde x_j nöronun uyarılmadan önceki çıktısını, x_i ise nöronun uyarıldıktan sonraki çıktısını ifade etmektedir. w_{ij} ise ağırlığı ve γ öğrenme oranını temsil etmektedir.

3.8.3.4.(6).(d). Rekabete Dayalı Öğrenme

Rekabete dayalı öğrenmede nöronlar birbirleriyle kazanan nöron (aktif nöron) olmak için sürekli rekabet etmektedirler. Hebb öğrenme yönteminde birden fazla nöron aktif olabilirken, bu öğrenme çeşidinde her bir yenilemede sadece bir tek nöron aktif olabilmektedir. Bu nedenle bu öğrenme kuralı kümeleme problemlerinin çözümünde oldukça başarılı olabilmektedir (Haykin, 1999).

3.8.3.4.(7). Yapay Sinir Ağının Eğitiminde Karşılaşılan Problemler

Bu bölümde yapay sinir ağları kullanılırken karşılaşılan problemlere değinilecektir. Söz konusu problemler yapay sinir ağı performansını etkileyebilmektedir. Bu nedenle kullanıcıların bu konular hakkında bilgi sahibi olması gerekmektedir.

3.8.3.4.(7).(a). Overfitting - Aşırı Uyum

Aşırı Uyum (overfitting) yapay sinir ağlarının eğitim veri setine %100'e varan oranlarda uyum sağlaması fakat doğrulama veya test veri setinde çok kötü performans göstermesidir.

Overfitting problemini engellemek için önerilen temel yöntem eğitimi erken durdurmaktır (early stopping). Bu yöntemde yapay sinir ağlarının eğitime, eğitim veri setine mükemmel bir şekilde uyum sağlamadan önce son verilmesi söz konusudur (Hastie vd., 2009: 398.)

Aşırı uyum durumu olduğunda, yapay sinir ağı modeli eğitim veri setine mükemmel uyum sağlamaktadır fakat bunun yanında genelleştirilme yeteneğini kaybetmektedir.

Bu çalışmada ise yapay sinir ağlarının, eğitim setindeki örüntüleri ezberlemesi ve başka bir veri setinde kötü performans göstermesinin önüne geçmek için farklı bir yöntem izlenecektir. Eğitim seti sıralı alt gruplara ayrılacak, her bir alt grup kendi içinde eğitim

ve test diye yine iki gruba ayrılacaktır. Belirlenen girdi ve nöron sayıları, alt grupların eğitim setinde kullanılacak ve daha sonra test bölümünde test edilecektir. Test aşamasında ortalama olarak en düşük hatayı belirleyen bileşenler seçilmiş olacaktır.

3.8.3.4.(7).(b). Girdilerin Ölçeklendirilmesi

Girdilerin sıfır ortalama ve bir standart sapmaya sahip olacak şekilde ölçeklendirilmesi, yapay sinir ağlarının son performansına olumlu katkı sağlayabilir (Hastie vd., 2009: 398).

3.8.3.4.(7).(c). Ara Katman Sayısı ve Katmanlardaki Nöron Sayısı

Yapay sinir ağlarındaki nöron ve katman sayılarının belirlenmesi konusunda bazı durumların göz önünde bulundurulması gerekir. Girdi katmanında yer alması gereken nöron sayısı ve çıktı katmanında yer alması gereken nöron sayısı problemin özelliklerine göre belirlenmektedir. Üstelik çıktı katmanındaki aktivasyon fonksiyonu ise yine problemin özelliklerine göre belirlenecektir. Eğer problemin çıktısı ikili değişkenlerden oluşmakta ise çıktı katmanındaki aktivasyon fonksiyonu adım fonksiyonu (hardlim) olacaktır. Gizli katmanlardaki nöron sayısının belirlenmesi konusunda ise henüz herkes tarafından kabul edilmiş bir yöntem bulunmamaktadır. Genellikle 5 ile 100 arasındaki nöron sayısı literatürde kabul edilmektedir ve deneme yanılma yoluyla optimal sayının bulunması önerilmektedir (Hastie vd., 2009: 400).

Genellikle yapay sinir ağlarında, gizli katmanda yer alması gereken nöron sayısının bağlı olduğu bazı faktörler şu şekildedir (Sumathi ve Surekha, 2010: 90):

- Girdi ve çıktı birimleri (değişken sayıları)
- eğitimde kullanılacak gözlem sayısı
- çıktılardaki gürültünün derecesi
- öğrenilmesi gereken fonksiyonun karmaşıklığı
- mimari
- gizli katman aktivasyon fonksiyonu çeşidi
- eğitim algoritması

Ara katmanda yer alması planlanan nöron sayısının kaç olacağını belirleyecek belirli bir metod yoktur. Ara katmanda az sayıda nöron yer alması durumunda, underfitting nedeniyle eğitim hatası çok yüksek olur ve istatistiksel sapmalar meydana gelir. Eğer çok fazla sayıda nöron kullanılırsa bu durumda overfitting ve yüksek varyans nedeniyle, eğitim veri setinde hata en az olsa da, genelleştirme hatası çok yüksek olur (Sumathi ve Surekha, 2010: 90).

Gerçek hayatta kullanılan birçok problemde iki ya da üç katman bulunmaktadır. Üç veya daha fazla sayıda katmanın kullanıldığı problem sayısı az olmaktadır.

3.8.3.4.(7).(d). Yapay Sinir Ağlarının Avantajları ve Dezavantajları

Yapay sinir ağlarının bazı avantaj ve dezavantajlarına Kecman (2001: 12) değinmiştir ve aşağıdaki gibi özetlenebilir:

Yapay sinir ağlarının bazı avantajları;

- İnsanların öğrenme şeklini taklit edebilirler ve veri setinden öğrenme sağlanmaktadır.

- Birçok doğrusal olmayan çok değişkenli problemi çözebilirler.
- Üzerinde çalışılan problem veya süreç hakkında detaylı bilgiye gereksinim duyulmaz.
- Gürültülü veri setinden çok etkilenmezler.
- Paralel yapıdadırlar ve donanımlarda kolaylıkla kullanılabilirler.
- Farklı nitelikteki problemler aynı yapay sinir ağı modeli ile çözülebilir.


Yapay sinir ağlarının bazı dezavantajları;

- Birçok gerçek hayat probleminin çözümü için aşırı uzun eğitim ve öğrenme zamanına ihtiyaç duyulur.
- Değişkenler arasındaki ilişkiyi açığa çıkarmaz ve süreç hakkındaki bilgimizi arttırmamızı sağlamazlar.
- Kötü genelleştirmelere eğilimleri vardır (aşırı uyum gibi).
- Yapay sinir ağları yapısı veya optimizasyon prosedürü hakkında hiç yok denecek kadar az rehberlik söz konusudur (belirli bir problem için hangi yapının kullanılması gerektiği gibi).

3.8.3.5. ANFIS Yöntemi

ANFIS (Adaptive Neuro Fuzzy Inference System) ile birlikte hisse senedi kapanış fiyatlarını önceden tahmin etmek mümkündür. Yöntem, yapay sinir ağları ile bulanık mantığın bileşiminden oluşmaktadır.

Bulanık mantık verilerin alternatif bir şekilde ifade edilmesini sağlamaktadır ve Zadeh (1965) tarafından ortaya çıkarılmıştır (Zadeh, 1965). Bulanık mantığın anlaşılması yaş örneği ile anlaşılabilir (Atsalakis vd., 2011). Bulanık mantıkta yaş; genç, orta yaşlı ve yaşlı olmak üzere üç gruba ayrılabilir. Herhangi bir yaş değerinin hangi gruba ait olacağı üyelik fonksiyonu (membership function) ile belirlenmektedir. Üyelik fonksiyonu, yaş değerinin hangi kategoriye ait olduğuna bağlı olarak $[0, 1]$ aralığında değerler alabilir. Klasik mantık ile bulanık mantık arasındaki temel fark burada yer almaktadır. Bulanık mantıkta bir değer birden fazla kategoriye ait olabilirken, klasik mantıkta ya bir grubun üyesidir veya değildir.




Şekil 3.16. Bulanık Mantık için Üyelik Fonksiyonu Örnekleri (Jang vd., 1997:17).

Şekil 3.16 'de bulanık mantığın üyelik fonksiyonları görülmektedir. Şekile göre, 30 yaş hem genç kategorisine hem de orta yaşlı kategorisine aittir. Üyelik dereceleri ise 0.5 'tir. Buna karşın 80 yaş grubu, yaşlı kategorisine 1 üyelik değeri ile aittir. Bulanık

- İkinci katmanda ise bir önceki katmanın çıktıların çarpımı hesaplanmaktadır.
- Üçüncü katmanda üyelik fonksiyonlarının normalleştirme işlemi gerçekleştirilmektedir.
- Dördüncü katmanda özel bir fonksiyon kullanılmaktadır.
- Beşinci katmandaki nöron ise kendisine gelen sinyalleri toplamaktadır.


3.8.3.6. Destek Vektör Makineleri

Destek vektör makineleri Vapnik tarafından 1995 yılında geliştirilmiştir (Vapnik, 2000). En yakın eğitim gözlemlerinin arasındaki uzaklıkları maksimum kılacak bir hiperdüzlem bulunmaya çalışılmaktadır (Abolhassani ve Yaghoobi, 2010). Yapay sinir ağlarında ampirik risk minimizasyonu gerçekleştirilirken, destek vektör makinelerinde yapısal risk minimizasyonuna dayalı bir sistem söz konusudur. Yapay sinir ağlarında yanlış sınıflandırma hatası minimum kılınmaya çalışılırken, destek vektör makinelerinde ise hatayı minimum kılacak bir üst sınır bulunmaya çalışılmaktadır.



Şekil 3.19. Doğrusal Olmayan Bir Düzlem ve Doğrusal Bir Düzlem (Nisbet vd., 2009:164).

Veri setindeki gözlemler doğrusal olarak ayrılabilen bir durumdaysa, grupları ayırıştırıcı hiperdüzlem doğrusal bir şekilde ifade edilebilir. Fakat gözlemler doğrusal bir şekilde ayrılmaya müsait değilse, bu durumda, girdi seti öncelikle yüksek boyutlu başka bir düzleme dönüştürülür (Şekil 3.19). Bu yeni düzlemde gözlemlerin optimal bir hiper düzlem ile doğrusal bir şekilde ayırıştırılmaya çalışılmaktadır. Bu optimal hiper düzlem destek vektörleri adı verilen parametreler ile belirlenmektedir. Destek vektörler ise hiper düzleme en yakın olan gözlemlerdir. Bu dönüştürülme işlemi kernel adı verilen fonksiyonlarla yapılmaktadır. Kernel fonksiyonlarının, doğrusal, Gaussian Radyal bazlı fonksiyon ve polinomal kernel fonksiyon çeşitleri mevcuttur. Şekil 3.20 'de destek vektör makinelerinin çalışma prensibi görülmektedir (Ertel, 2011: 253).



Şekil 3.20. Marjin ve Destek Vektörler (Alpaydın, 2010: 314).

3.8.3.7. Genetik Algoritma

Genetik algoritma doğal evrimden esinlenmek suretiyle geliştirilmiş sezgisel optimizasyon yöntemidir. Daha geniş bir kapsamda, genetik algoritma, seçim ve çaprazlama yöntemlerini uygulamak suretiyle arama uzayında yeni noktalar yaratan, anakütle tabanlı optimizasyon algoritmasıdır (Armano vd., 2005).

1960'lardan beri, zor olan optimizasyon problemlerinin çözümü için güçlü algoritma geliştirme çabaları söz konusudur. Bu çabaları ifade etmek için *evrimsel hesaplama* terimi kullanılmaktadır. Bu sınıfın içinde yer alan en çok tanınan algoritmalarından birisi de Holland tarafından literatüre tanıtılan genetik algoritmalarıdır. Genetik algoritmalar, günümüzün en çok bilinen evrimsel hesaplama çeşididir (Gen ve Cheng, 2000: 1).

Genetik algoritmalar John Holland'ın 1975 yılındaki "Adaptation in Natural and Artificial Systems" adlı kitabında ilk kez tanıtılmıştır (Holland, 1992). Holland kitabında GA'ı "güçlü olan hayatta kalır" anlayışına dayalı sezgisel bir metod olarak tanıtmıştır ve ilk tanıtıldığı günden bu güne arama ve optimizasyon problemlerinde faydalı bir şekilde kullanılmaktadır.

Genetik Algoritmalar evrim teorisinden esinlenmektedir. Darwin'in geliştirdiği evrim teorisinde yer alan doğal seçim teorisine göre bugünkü bitki ve hayvanlar milyonlarca yıl devam eden uyum sürecinin bir sonucudur. Herhangi bir zaman diliminde ekosistemde yer alan aynı kaynaklar için bir dizi farklı organizma rekabet halinde olabilir. En fazla kaynağı elde eden organizmaların nesilleri daha fazla olacaktır. Sebebi ne olursa olsun daha az rekabet gücüne sahip organizmaların ise ileride daha az nesil yaratması veya hiç nesil yaratmaması beklenmektedir. İlkinin, sonrakinden daha uyumlu olduğu söylenmektedir. Başka bir ifade ile ilki (uyum sağlayan), ikincisine (uyum sağlayamayana) tercih edilmiştir. Zamanla, ekosistemin toplam popülasyonu en uyumlu ve hayatta kalmaya yatkın bireylerden oluşacaktır (Svanandam ve Deepa, 2008: 1).

Evrimsel hesaplama (evolutionary computation) teknikleri bu doğal evrim sürecini, bazı problemleri çözebilecek algoritmalar halinde soyutlamaktadır. Arama algoritması kısa süre içinde, bir problem için tanımlanmış olası çözümleri taramakta ve en iyi çözümü belirlemeye çalışmaktadır. Küçük ölçekli problemlerde, mümkün olan bütün çözümlerin tek tek denenmesi ve optimal çözümün belirlenmesi mümkün olabilir. Bu yöntem problemin ölçeği büyüdükçe imkansız bir hal almaktadır. Geleneksel arama

algoritmaları her defasında rastgele veya sezgisel örnekler içinden, tek bir bireyi değerlendirmekte ve optimal çözümü bulması beklenmektedir. Evrimsel arama algoritmasının belirleyici özelliği ise popülasyon tabanlı olmasıdır. Evrimsel arama algoritmasında bir dizi yeni nesil kullanılmakta ve arama yönlendirilmektedir. Evrimsel arama genellikle rastgele aramadan daha iyidir (Svanandam ve Deepa, 2008: 1).

Genetik algoritma temelde beş temel bileşenden oluşmaktadır (Michalewicz, 1996):

1. Çözümlerin genetik temsili
2. Başlangıç popülasyonunun oluşturulması
3. Uygunluk fonksiyonun belirlenmesi
4. Yeniden üretim sürecinde genetik bileşenlerin değiştirilmesi
5. Genetik algoritma problemlerinin değerleri

Genetik algoritma prosedüründe bir grup bireyden oluşan popülasyon söz konusudur. Bu popülasyon, t nesili için $P(t)$ ile temsil edilmektedir. Her bir birey, üzerinde çalışılan problem için aday çözümü temsil etmektedir. Her bir birey uygunluk değeri ile değerlendirilmektedir. Bazı bireyler, genetik işlemler (operasyonlar) yardımıyla yeni bireyler oluşturmak üzere değişikliğe uğramaktadırlar. İki çeşit değişiklik söz konusudur. Bu değişiklikler, tek birey üzerinde değişiklik yapan mutasyon ve iki farklı bireyin farklı parçalarını bir araya getiren çaprazlamadır. $C(t)$ ile isimlendirilen yeni bireyler değerlendirmeye alınmaktadır. Ana popülasyon ve yavruların yer aldığı yeni popülasyondan en iyi bireyler bir araya getirilmek yoluyla yeni bir popülasyon oluşturulmaktadır. Birkaç nesil (yenileme) sonucunda, algoritmanın optimal veya optimale yakın en iyi bireyi tespit etmesi beklenmektedir. Genetik algoritmaların genel yapısı Şekil 3.21 'deki gibidir (Gen ve Cheng, 2000: 1):

Prosedür: Genetik Algoritmalar

Başla

$t = 0$;

Başlangıç $P(t)$ anakütlesinin oluşturulması;

$P(t)$ nin değerlendirilmesi;

while bitirme şartı sağlanmadığı müddetçe **do**

başla

$C(t)$ 'yi elde etmek için $P(t)$ 'nin çaprazlanması

$C(t)$ 'nin değerlendirilmesi;

$P(t)$ ve $C(t)$ anakütlelerinden $P(t + 1)$ 'in oluşturulması

$t = t + 1$;

bitir

bitir

Şekil 3.21. Genetik Algoritmaların Temel Prosedürü (Gen ve Cheng, 2000: 1).

Genetik algoritmalar karmaşık çözüm uzayında yönlendirilmiş rastgele arama gerçekleştirmektedir. Seçim operatörlerinin genetik aramayı, istenilen çözüm uzayına yönlendirmesi beklenmektedir. Bu bağlamda kör bir arama sürecinden bahsedilmektedir. Gerçek bir problemin genetik algoritma yoluyla çözülebilmesi için çözüm uzayının araştırılması ve kullanılması arasında iyi bir dengenin sağlanması gerekmektedir. Bu hedefin gerçekleştirilmesi için de genetik algoritmanın bütün bileşenlerinin dikkatli bir şekilde irdelenmesi gerekmektedir. Algoritmanın performansı ek sezgisel yöntemler kullanmak suretiyle geliştirilebilir (Gen ve Cheng, 2000: 2).

Genetik algoritaların temel fikri şu şekildedir: genetik havuzu verilmiş bir popülasyonda, çözüm veya daha iyi bir çözüm bulunmaktadır. Bu çözüm "aktif" değildir çünkü çözümü oluşturan genetik kombinasyon birkaç bireye yayılmış durumdadır. Sadece farklı genomların birleşimi çözümü barındırabilir. Mevcut olan hiçbir çözüm böyle bir genomu barındırmaz, fakat yeniden üretim ve çaprazlama yardımıyla yeni genetik kombinasyonlar oluşturulur ve sonuçta ebeveynlerden gelen genlerle "iyi bir gen" yaratılmış olur.

Holland'ın yönteminin etkinliği, sadece mutasyonu göz önünde bulundurmasından değil aynı zamanda genetik çaprazlamayı barındırmasından kaynaklanmaktadır. Kısmi çözümlerin yeniden kombinasyonları, algoritmanın optimuma yaklaşmasını ve sonunda optimum çözümü bulmasına katkı sağlamaktadır. Çaprazlama doğal evrim için anahtar rol oynayan bir işlemdir. Teknik olarak, iki genotip alınır ve bu genotiplerde bulunan genlerin karıştırılması yoluyla yeni bir genotip yaratılır. Biyolojide, en çok kullanılan çaprazlama formu, iki kromozomun bir noktadan kesilmesi ve iki yarım kısmın yer değiştirilmesi şeklinde tanımlanan çaprazlamadır. Çaprazlamanın etkisi oldukça önemlidir çünkü farklı ebeveynlerin farklı özellikleri bir araya getirilmektedir. Eğer anne ve babanın iyi özellikleri varsa, çocuğa da bütün bu iyi özelliklerin geçmesini bekleyebiliriz. Böylelikle, yenidoğanın sadece anne ve babasından iyi özellikleri alması yoluyla, atalarından daha iyi konumda olacağını söyleyebiliriz. Bu karışım yoluyla yeni bireylerin oluşturulabilmesi, genetik algoritaların en önemli özelliğidir. Yeni genomlar oluşturmada kullanılan bir diğer yöntem ise mutasyondur. Mutasyon genlerin değerinin değiştirilmesini kapsamaktadır. Doğal evrimde, mutasyon genelde cansız genomların oluşmasına neden olur. Aslında, doğal evrimde mutasyon, çok sık kullanılan bir işlem değildir. Yine de, optimizasyonda, birkaç rastgele değişiklik arama uzayının taranmasında hızlı bir yol olabilir (Svanandam ve Deepa, 2008: 23).

3.8.3.7.(1). Genel Olarak Optimizasyon İşlemi

Bir optimizasyon probleminde amaç fonksiyonunda en uygun değeri verecek çözüm uzayı tanımlanmaktadır. Birçok problemde çözüm uzayı kesikli şekildedir (discrete) bu nedenle de kombinatorial optimizasyon problemlerinden bahsedilir (combinatorial optimization problems - COPs). Çözüm uzayı elemanları sürekli olduğunda başka yaklaşımlara ihtiyaç duyulmaktadır.

Çözüm uzayı kesikli olduğunda dahi bütün kombinasyonların tek tek değerlendirilmesi günümüz teknolojisinde bile imkansız olabilmektedir. Bu durum NP – hard ile ifade edilmektedir. Burada sezgisel optimizasyon algoritmaları devreye girmektedir.

Algoritma, bir problemi çözmek için gereken bir dizi adım olarak tanımlanır. Genetik algoritma ise, problem çözümünde genetiği kullanan problem çözme yöntemidir. Optimizasyonun çözümüne ve arama problemine yaklaşık değerler bulan bir tekniktir. (Svanandam ve Deepa, 2008: 29-33).

Temel olarak, optimizasyon problemi çok basitmiş gibi görünebilir. Mevcut bir problem için bütün olası çözümler kümesi bilinmektedir. Bütün çözümler kümesi, arama uzayını oluşturmaktadır. Problem, bütün çözümler kümesinden en iyi uyum sağlayan çözümün bulunmasıdır. Bütün çözümlerin denenmesi durumunda, optimal çözüm bulunabilir. Buna rağmen arama uzayı genişlediğinde, her çözümün denenmesi, çok fazla zaman alacağından imkansız hale gelir. Bu durumda, optimum çözümün bulunabilmesi için özel bir tekniğin kullanılması gerekmektedir.

Çözüme ulaştıran adımların önceden bilinmediği durumlarda, problemin çözümü, çözüm uzayının aranması yoluyla gerçekleştirilmektedir. Genel olarak iki çeşit arama davranışı söz konusu olmaktadır. Bunlardan birincisi rastgele arama, bir diğeri ise yerel aramadır. Rastgele aramada çözüm uzayı bütünüyle aranmaktadır ve böylelikle yerel optimumdan uzaklaşılması mümkün olmaktadır. Yerel aramada ise en iyi çözüm sömürülmektedir ve yerel optimuma yakalanmak daha mümkün görünmektedir. İdeal bir arama süreci her iki çeşit aramayı da eş zamanlı olarak kullanmalıdır. Geleneksel yöntemlerle böyle bir arama sürecinin kurulması imkansızdır. Genetik algoritmalar ise yönlendirilmiş ve stokastik aramanın bileşenlerini içermektedir ve böylelikle arama ve sömürme arasında iyi bir denge kurabilmektedir. Genetik algoritmalarda biriken bilgi, seçim mekanizması yardımıyla sömürülürken, yeni arama uzaylarının taranması genetik operasyonlar yardımıyla gerçekleştirilmektedir (Gen ve Cheng, 2000: 2).

3.8.3.7.(1).(a). Evrimsel Hesaplamalar ile Klasik Optimizasyon Yöntemleri

Doğrusal, kareli, konveks, unimodal ve diğer özelleştirilmiş problemlerde klasik optimizasyon algoritmaları daha etkindir. Buna rağmen daha karmaşık problemlerde evrimsel hesaplamaların daha etkin olduğunu söylemek mümkündür.

Klasik optimizasyon ve evrimsel hesaplama süreci ve arama alanı bilgisi açısından önemli farklılıklar göstermektedir. Bu farklılıklar (Engelbrecht, 2007: 141):

- **Arama Süreci.** Klasik optimizasyonda, arama uzayında bir noktadan diğer bir noktaya hareket deterministik kurallara bağlıdır. Bu işlem ise evrimsel hesaplamalarda olasılıklıdır. Ayrıca evrimsel hesaplamalarda arama uzayının paralel aranması gerçekleştirilebilirken, klasik optimizasyon yöntemlerinde sıraya bağlı arama söz konusudur. Evrimsel bir optimizasyon yönteminde bir dizi başlangıç noktaları vardır ve arama uzayı bu noktalardan başlamak suretiyle paralel bir şekilde aranabilir. Klasik optimizasyon yönteminde ise bir noktadan başlanır ve optimal noktaya doğru ilerlenir.
- **Arama alanı bilgisi.** Klasik optimizasyon yönteminde optimum nokta bulunurken genellikle birinci dereceden veya ikinci dereceden türev bilgileri kullanılır. Evrimsel hesaplamalarda ise türev bilgileri kullanılmaz. Bireylerin uygunluk değerleri aramaya rehberlik eder.

3.8.3.7.(1).(b). Genetik Algoritmanın Özellikleri


Genetik algoritmaların bazı özellikleri söz konusudur. Bunlardan ilki, genetik algoritmaların stokastik bir algoritma olmasıdır. Rastgelelik, genetik algoritmalarda önemli bir rol oynamaktadır. Bireylerin seçimi ve yeniden üretilmesinde tesadüfi süreçlere ihtiyaç vardır. İkinci çok önemli nokta ise genetik algoritmalarda bir "çözüm popülasyonu" göz önünde bulundurulur. Her bir iterasyonda sadece tek bir çözüm yerine, genetik algoritmadaki gibi, birden fazla çözümün göz önünde bulundurulmasının bir çok avantajı vardır. Algoritma farklı çözümleri, daha iyilerini bulmak için birleştirir ve sıralamanın sağlayacağı avantajlardan faydalanır. Popülasyon tabanlı bir algoritmanın paralelleştirmeye uygun olduğunu da ifade etmekte fayda vardır. Algoritmanın dayanıklılığından (robustness) da bahsetmek gerekir. Dayanıklılık, geniş problem çeşitleri içinde istikrarlı bir şekilde iyi sonuçlar vermeyi ifade eder. Ayrıca genetik algoritmaları uygulamadan önce problemde yapılması gereken özel işlemler söz konusu değildir, bu özelliğiyle de herhangi bir problemin çözümüne uygulanabilir. Bütün bu

özellikleri GA'yı güçlü bir optimizasyon aracı yapmaktadır (Svanandam ve Deepa, 2008: 20-21).

Goldberg'in özetlediği gibi genetik algoritmalar geleneksel optimizasyon yöntemlerinden ve arama prosedürlerinden şu dört şekilde ayrılmaktadır (Sakawa, 2002: 12).;

1. Genetik algoritmalar çözüm üzerinde çalışmak yerine, çözüm setinin kodlanmış hali ile çalışmaktadır.
2. Genetik algoritmalar, tek çözüm yerine, bir dizi bireyden oluşan anakütle üzerinde arama yapmaktadır.
3. Genetik algoritmalar türev veya yardımcı bilgileri kullanmaz, uygunluk değerlerini dikkate alır.
4. Genetik algoritmalar, deterministik değil, olasılıklı dönüşüm kurallarını kullanmaktadırlar.

Şekil 3.22 'de genetik algoritmaların temel yapısı özetlenmektedir. Fenotip kodlamaya sahip aday çözümler, genotip şeklinde kodlanmakta ve başlangıç popülasyonunu oluşturmaktadır. Anakütledeki her bir birey uygunluk fonksiyonu ile değerlendirilmektedir. Bir sonraki yineleme için anakütleden değişikliğe gidilmektedir. Değişiklik seçim, çaprazlama ve mutasyon yöntemleri ile oluşturulmaktadır. Bu süreç bu şekilde devam etmektedir ve sonlandırma şartı sağlandığında elde edilen en iyi birey optimal veya optimele yakın sonuç olarak değerlendirilmektedir.



Şekil 3.22. Genetik Algoritmaların Temel Yapısı (Sakawa, 2002: 15).

Genetik algoritmaların sonuçları elde edebilmesi için çözümlerin genetik temsiliinin gerçekleştirilmesi, başlangıç popülasyonunun nasıl oluşturulacağına karar

verilmesi, uygunluk değerleri ile değerlendirme süreçleri, genetik işlemler, kısıtlar varsa dikkate alınması ve popülasyon büyüklüğü, çaprazlama ve mutasyon oranları, sonlandırma şartları ve benzeri parametrelerin de belirlenmesi gerekmektedir (Sakawa, 2002: 14).

3.8.3.7.(2). Genetik Algoritma Terminolojisi


Bu bölümde genetik algoritmalarda kullanılan terminolojiye değinilecektir. Genetik algoritmaların tam olarak anlaşılabilmesi için bazı yapı taşlarının bilinmesi gerekmektedir.

3.8.3.7.(2).(a). Birey

Genetik algoritmalarındaki her bir birey bir adet aday çözümü temsil etmektedir. İki çeşit birey söz konusudur. Bunlar:

- Ham genetik bilginin (genotip) saklandığı ve Genetik İşlemlerin yapıldığı kromozom
- Modelin kurulduğu fenotip.

Bir kromozom genlerden oluşmaktadır. Gen ise tek bir faktörün genetik temsilidir. Çözüm setindeki her bir faktör, kromozomdaki bir gene karşılık gelmektedir ve bu durum Şekil 3.23 ‘de grafik halinde gösterilmiştir (Svanandam ve Deepa, 2008: 39).



Şekil 3.23. Genotip ve Fenotip Kavramlarının Şema ile Gösterimi

İkili gösterimle ifade edilen kromozom ise Şekil 3.24 ‘deki gibidir.


1 0 1 0 0 1 0 0 1 0 1 0 1 0 1 0

Şekil 3.24. Kromozomun Şema ile Gösterimi

3.8.3.7.(2).(b). Genler

Genler bir problem için çözüm adayıdır. Kromozom bir dizi genlerden oluşmaktadır. Her zaman için çözümün kendisi olmak zorunda değildir. Bir gen problemin niteliğine göre uzunluğu değişebilen ikili karakterlerden oluşmaktadır. (Svanandam ve Deepa, 2008: 39)

Her bir genin yapısı fenotip parametrelerinde kodlanmıştır. Fenotip parametreleri genotip ve fenotip arasındaki değişimi sağlayacak talimatları içermektedir. Genotip ve fenotip dönüşümü, modelin parametrelerinin genetik algoritmanın işlem yapabilmesini sağlayacak şekle dönüştürülmesi ve oluşturulan yeni bireylerin uygunluk değerlerinin belirlenmesi için gereklidir. Bir kromozomda yer alan genler Şekil 3.25 ‘de gösterilmiştir:



Şekil 3.25. Gen Kavramının Şema ile Gösterimi

3.8.3.7.(2).(c). Uygunluk

Genetik algoritmada bireyin uygunluğu fenotipi kullanmak suretiyle hesaplanan uygunluk fonksiyonu değeridir. Uygunluk değerinin hesaplanabilmesi için, kromozomun fenotipe çevrilmesi ve uygunluk fonksiyonun değerlendirilmesi gerekmektedir. Uygunluk değeri çözümün ne kadar iyi olduğunun yanında optimal çözüme ne kadar yakın olduğunu da ölçmektedir (Svanandam ve Deepa, 2008: 39).

Minimizasyon probleminde uygunluk fonksiyonunun mümkün olan en düşük değer alması istenmektedir. Problem maximizasyon problemi ise uygunluk fonksiyonunun en yüksek değeri alması beklenmektedir.

3.8.3.7.(2).(d). Başlangıç Popülasyonu (Initial Population)

Genetik algoritma popülasyon tabanlı arama algoritmasıdır. Popülasyonda bir dizi aday çözüm bulunmaktadır. Genetik algoritmaların uygulanmasındaki ilk adım, başlangıç popülasyonun oluşturulmasıdır. Başlangıç popülasyonunun oluşturulmasındaki genleneksel yöntem ise her kromozomun her genine kabul edilebilir sınırlar dahilinde rastgele değerler atamaktır. Rastgele değer atamaktaki amaç, başlangıç popülasyonunun arama uzayını iyi bir şekilde temsil etmesini sağlamaktır. Eğer arama uzayının bazı bölgeleri başlangıç popülasyonunda yer almazsa, bu bölgelerin arama süreci tarafından, gelecek iterasyonlarda ihmal edilmesi (dikkate alınmaması) olasılığı mevcuttur.

Başlangıç popülasyonunun büyüklüğü belirlenirken şu hususlar gözönüne alınmalıdır. Popülasyonda çok sayıda birey yer alırsa, popülasyonun arama kabiliyeti artacaktır. Fakat ne kadar çok sayıda birey yer alırsa, her bir popülasyon için gerekecek hesaplama miktarı da artacaktır. Aynı şekilde her bir popülasyona ilişkin hesaplamalar uzun sürse de, kabul edilebilir bir çözüme ulaşmak daha az sayıda nesil ile mümkün olabilecektir. Az sayıda popülasyon ise arama uzayının küçük bir parçasını temsil edecektir. Her bir popülasyona ilişkin hesaplamalar kısa sürse de, çözüm için daha fazla sayıda nesile ihtiyaç duyulacaktır.

Küçük popülasyonun seçilmesi durumunda, mutasyon oranı artırılarak genetik algoritmaların arama uzayının daha büyük kısmını araması sağlanabilir (Engelbrecht, 2007: 132).

3.8.3.7.(2).(e). Popülasyon

Popülasyon bir grup bireyden oluşmaktadır. Bir popülasyonda, test edilen bir grup birey ve fenotip parametreleri yer almaktadır.

Popülasyon (Anakütle)	Kromozom 1	1	1	1	0	0	0	1	0
	Kromozom 2	0	1	1	1	1	0	1	1
	Kromozom 3	1	0	1	0	1	0	1	0
	Kromozom 4	1	1	0	0	1	1	0	0

Şekil 3.26. Populasyon Kavramının Şema ile Gösterimi

Popülasyon büyüklüğü, problemin yapısına bağlıdır. Genellikle başlangıç popülasyonu rastgele değerlerden oluşmaktadır. Eğer yapılabiliyorsa, başlangıç popülasyonu bilinen iyi bireylerden oluşturulabilir. Dört adet bireyden oluşan anakütle Şekil 3.26 ‘de temsili olarak gösterilmiştir.

Arama uzayını iyi tarayabilmek için başlangıç popülasyonunun mümkün olduğu kadar büyük seçilmesi gerekir. Bütün mümkün alellerin popülasyonda yer alması gerekmektedir. Bunu sağlamak için başlangıç anakütlesi rastgele seçilmektedir. Bazı sezgisel yöntemler kullanmak yoluyla başlangıç popülasyonu oluşturulabilir. Bu durumda popülasyonda iyi bireyler olacağından, genetik algoritma çözüme daha hızlı yaklaşabilir. Bu durumda da anakütlenin yeterince büyük olması gerekmektedir. Popülasyonun bütün olası çözümleri iyi temsil edemediği durumda, algoritma, arama uzayının sadece küçük bir kısmını arayacaktır ve hiçbir zaman optimal sonucu bulamayacaktır (Svanandam ve Deepa, 2008: 42).

3.8.3.7.(2).(f). Temsil (Representation) - The chromosome (kromozom)

Genetik algoritmalarda, her birey, optimizasyon problemine bir çözüm adayını temsil eder. Bireyin karakteristikleri ise kromozom veya genom ile temsil edilir. Karakteristikler ise optimizasyon probleminin değişkenlerini ifade etmektedir. Optimize edilmek istenen her bir değişken ise gen ile gösterilir ki genler en küçük bilgi birimidir. Değişkene kabul edilebilir sınırlar dahilinde bir değer atama işlemi allele olarak bilinmektedir. Bireyin karakteristikleri genotipler ve fenotipler olmak üzere iki grupta incelenmektedir. Genotipler bireyin ebeveynlerinden aldığı genetik bilgileri içerir. Başka bir ifadeyle bireyin sahip olduğu aleller genotipi oluşturmaktadırlar. Fenotip ise bireyin nasıl görüldüğünü temsil etmektedir (Engelbrecht, 2007: 8).

Genetik algoritmalarda aday çözümlerin (kromozomların) uygun gösterimi önemli bir yer tutmaktadır. Arama algoritmasının performansı temsil şemasına bağlıdır. Genetik algoritmaların klasik temsil şeması ikili vektörlerden oluşmaktadır. n_x boyutlu arama uzayında, her birey her değişkenin bit string olarak kodlandığı n_x adet değişkenden oluşmaktadır.

3.8.3.7.(2).(g). Uygunluk Fonksiyonu (Fitness Function)

Kromozomun temsil ettiği çözümün ne kadar iyi olduğunun matematiksel bir fonksiyon ile belirlenmesidir. Uygunluk fonksiyonu ne kadar iyi ise, kromozomun bir sonraki nesile aktarılma olasılığı o kadar fazla olmaktadır (Engelbrecht, 2008: 133). Genetik algoritmadaki amaç uygunluk fonksiyonunu minimum kılacak genin belirlenmesini sağlamaktır.

3.8.3.7.(2).(h). Genetik Algoritmelerde Kodlama

Genetik algoritmelerde çözümün kromozomlar şeklinde nasıl kodlanacağı, genetik algoritmelerde önemli olmaktadır.

Genetik algoritmelerde kodlamalar şu şekilde gruplandırılabilir:

- İkili kodlama (Binary encoding)
- Gerçek sayılı kodlama (Real number encoding)
- Tamsayılı kodlama (Integer or literal permutation)
- Genel veri yapılı kodlama (General data structure encoding)

Genetik algoritmalar, dizi yapıları arasında en iyinin hayatta kalmasına dayalı bir arama algoritmasıdır.

3.8.3.7.(2).(i). Arama Uzayı

Bütün mümkün çözümlerin yer aldığı uzay arama uzayı olarak adlandırılmaktadır. arama uzayındaki her bir nokta, mümkün olan bir çözümü temsil etmektedir. Bu nedenle, her bir çözümün, problemdeki tanımına göre bir adet uygunluk değeri söz konusudur. Genetik Algoritmalar, arama uzayındaki mümkün olan çözümlerden en iyisini bulmaya çalışır. Genetik algoritmalar genelde, çözüm uzayı içindeki en küçük değeri aramak üzere programlanırlar. Buradaki en büyük zorluklar, yerel minimum çözümlerinin varlığı ve aramaya başlanması gereken noktanın seçimidir (Svanandam ve Deepa, 2008: 20).

3.8.3.7.(2).(j). Elitist Strateji

Her yeni nesilde Genetik algoritmanın belirli sayıda en iyi bireyleri içermesinin garanti edilmesidir. Gelecek nesiller için en iyi bireyler seçilmediği veya çaprazlama veya mutasyon yolu ile iyi olan genetik yapının bozulduğu takdirde bu iyi bireylerin kaybolma ihtimali söz konusudur. Genetik algoritmanın performansının önemli ölçüde elitist strateji ile artırıldığı kanıtlanmıştır (Mitchell, 1999: 126).

Elit count parametresi ile bir sonraki nesile geçmesi garanti edilen birey sayısı belirlenmektedir. Bazı durumlarda en iyi bireylerin bir sonraki nesil için seçilmeme durumu olabilir. Bu durumun engellenmesi için elit sayısının belirlenmesi gerekmektedir.

3.8.3.7.(3). Genetik Algoritmelerde İşlemler

Darwin 'e göre türler içindeki en güçlü veya en akıllı birey hayatta kalmaz. Hayatta kalan birey değişime en çok ayak uydurabilen bireydir. Evrimin temelinde en uygun olan bireyin hayatta kalması yatmaktadır. Evrimsel hesaplamanın (Evolutionary computation) en önemli özelliği tek seferde bir birey yerine bir grup birey ile hesaplama yapıyor olmasıdır (Kordon, 2010: 115). Daha iyi çözümlerden genetik operasyonlar yoluyla yeni bireyler elde edilir ve kötü çözüm veren bireyler elenir. Yeni oluşturulan çözümler bir dereceye kadar anne-babalarının özelliklerini taşımaktadır.

Genetik algoritmaların anahtar özelliklerinden birisi iki ayrı uzay kullanıyor olmasıdır. Bunlar belirli bir problem için kodlanmış çözümlerin yer aldığı çözüm uzayı ve gerçek çözümlerin yer aldığı çözüm uzayıdır. Kodlanmış çözümler veya genotipler, her bir çözümün uygunluğunun veya kalitesinin değerlendirilmesi için gerçek çözümler veya fenotiplere dönüştürülmelidir. Genotipler bir veya sıfır değerlerinden oluşan bir dizidir (Kordon, 2010: 119).

3.8.3.7.(3).(a). GA'da Seçim

Genetik algoritmanın arkasında yatan ilke temel olarak Darwinci yaklaşımdır. Seçim işlemi, genetik algoritmayı yönlendirici güç olmaktadır. Bu gücün fazla olması arama işleminin olması gerektiğinden daha kısa sürede sona ermesine neden olabilir, çok az güç kullanılması ise gereğinden daha uzun sürede evrim sürecinin tamamlanmasına neden olabilir. Başlangıç aşamasında arama baskısının az olması, daha geniş bir alanı taramak için önerilmektedir. Aramanın sonlarına doğru ise arama baskısının artırılması gerekmektedir. Seçim işlemi genetik aramayı optimal alana doğru yönlendirmektedir. Farklı türde seçim işlemleri söz konusudur (Gen ve Cheng, 2000: 9)


Seçim işlemi bazı kaynaklarda yeniden üretim (reproduction) kelimesi ile ifade edilmektedir.

Genetik algoritmalarda seçim önemli bir yer tutmaktadır ve en iyi olanın hayatta kalması şeklindeki darwinci görüş ile yakından ilgilidir. Seçim operatörlerinin esas amacı iyi çözümlerin vurgulanmasıdır. Bu ise, iki adımda gerçekleştirilecektir (Engelbrecht, 2007: 134).

- **Yeni popülasyonun seçimi.** Genetik algoritmalarda, her bir neslin sonunda yeni bir popülasyon oluşturulur ve bu popülasyon bir sonraki nesil için temel alınacak popülasyonu oluşturmaktadır. Yeni popülasyon, sadece yavrulardan seçilebileceği gibi hem anne-baba hem de yavrulardan seçilebilir. Seçim işlemi iyi bireylerin bir sonraki nesile gitmesini sağlamalıdır.
- **Yeniden Üretim (Reproduction).** Yavrular, çaprazlama ve/veya mutasyon işleminin uygulanması ile oluşturulur. Çaprazlama işleminde yavruların en iyi bireylerden genetik bilgi alabilmesi için üstün bireylerin yeniden üretime daha fazla katılması gereklidir. Mutasyonda ise seçim mekanizması zayıf bireyler üzerine odaklanmalıdır. Bu işlemde mutasyon ile birlikte zayıf bireylerin daha iyi özellikler kazanabileceği umut edilmektedir.

Genetik Algoritmalarda seçim, çaprazlama yapmak için popülasyondan iki adet bireyin (ebeveyn)in seçilmesi sürecini ifade etmektedir. Hangi seçim yönteminin kullanılacağı ve kaç adet yeni bireyin yaratılacağına karar verilmelidir. Seçimde en iyi uygunluğa sahip bireyler bir araya getirilir ve bunlardan oluşturulacak yeni bireyin uygunluğunun daha iyi olacağını beklenir. Genetik algoritmalarındaki seçim süreci Şekil 3.27 'de yer almaktadır.

Seçim, anakütleden kromozomların uygunluk değerleri dikkate alınmak suretiyle rastgele seçilmesi sürecidir. Uygunluk değerinin yüksek olması, bireyin seçilme şansını arttırmaktadır. Seçim baskısı, iyi bireylerin hangi dereceye kadar ayrıcalıklı olacağını içermektedir. Baskının yüksek olması, iyi bireylerin daha ayrıcalıklı seçilmesine neden olur. Bu seçim baskısı genetik algoritmayı, bir sonraki neslin daha iyi bireylerden oluşmasına neden olacak şekilde yönlendirmektedir. Genetik algoritmanın çözüme ulaşma başarısı büyük oranda seçim baskısının büyüklüğü ile belirlenmektedir. Seçim baskısının yüksek olması, çözüme ulaşmayı kolaylaştırmaktadır. Seçim baskısının düşük belirlendiği durumlarda, genetik algoritmanın optimal çözüme ulaşması gereğinden fazla zaman alacaktır. Seçim baskısının gereğinden fazla olduğu durumlarda ise, genetik algoritmanın doğru olmayan (sub-optimal) sonuçlara ulaşmasına neden olmaktadır (Svanandam ve Deepa, 2008: 46-47).



Şekil 3.27. Genetik Algoritmalarda Seçim İşlemi (Svanandam ve Deepa, 2008: 46).

Genetik algoritma literatüründe sıklıkla kullanılan seçim algoritmaları aşağıdaki gibidir:

3.8.3.7.(3).(a).i. Rulet Tekerleği Seçimi

Rulet seçim geleneksel GA seçim tekniklerinden bir tanesidir. Rulet seçimin ilkesi, bireyin uygunluk değeri ile orantılı bir tekerlek modeli yardımıyla doğrusal bir arama gerçekleştirmektir. En uygun bireylerin seçilmesinin garantisi yoktur. Sadece seçilme olasılıkları daha yüksektir. Uygun bireyin, hedef değere katkıda bulunması beklenmektedir fakat uygun bireyin seçilmediği durumda bir sonraki kromozomun zayıf olma ihtimali vardır. Popülasyonun uygunluk değerlerine göre sıralanmaması gerekmektedir çünkü bu durumda seçim işlemi yanıltıcı olacaktır.

Rulet seçim süreci şu şekilde de açıklanabilir (Şekil 3.28). Her bir birey için rulet tekerleği modelinde bir dilim ayrılmaktadır (Şekil 3.29) ve bu dilimin kalınlığı bireyin uygunluk değeri tarafından belirlenmektedir. Tekerlek popülasyondaki birey sayısı kadar dönderilir. Her bir dönderilişte tekerleğin işaret ettiği birey bir sonraki nesil için seçilmektedir (Svanandam ve Deepa, 2008: 47-48).

Rulet tekerleği seçimi algoritması


Adım 1: t popülasyonundaki bütün bireylerin uygunluğu $f_i, i = 1, \dots, N$ ve toplam uygunluk $f_{sum} = \sum_{i=1}^N f_i$ hesaplanır.

Adım 2: $[0,1]$ aralığında bir rastgele sayı üretilir ve $s = rand() * f_{sum}$ hesaplanır.

Adım 3: $\sum_{i=1}^k f_i \geq s$ şartını sağlayan en küçük k sayısı belirlenir ve t+1 nesili için k sırasında bulunan birey seçilir.

Adım 4: istenilen sayıda birey seçilenen kadar yukarıdaki işlem devam eder.

Şekil 3.28. Rulet Tekerleği Seçim Süreci (Sakawa, 2002: 20).




Şekil 3.29. Rulet Tekerleği Seçim Modeli (Sakawa, 2002: 20).

3.8.3.7.(3).(a).ii. Stochastic Uniform Seçim

Stochastic Uniform seçim birçok açıdan rulet tekerleği seçimine benzemektedir. Rulet tekerleğinde tekerlek popülasyondaki birey sayısı olan N defa çevrilmektedir. Bu modelde ise rulet tekerleğinde eşit aralıklarla yerleştirilmiş N adet işaretçi bulunmaktadır ve tekerlek bir kere çevrilir. Tekerleğin çevrilmesi sonucunda N adet birey seçilmiş olmaktadır (Mitchell, 1999

: 125).

Örneğin, 10 adet bireyden oluşan bir popülasyondan, 6 adet birey seçilmek istensin. Bu nedenle 6 adet iğne yerleştirilecektir. Her bir iğne arasındaki mesafe $1/6 = 0.167$ birim olmak durumundadır. Bu durumda ilk iğnenin nereden başlayacağı $[0,0.167]$ aralığında rastgele sayı üretmekle bulunur. Diyelim ki bu aralıkta 0.1 değeri üretilmiş olsun. İlk iğne 0.1 den başlar ve diğer iğneler eşit aralıklarla yerleştirilir. İğnelerin denk geldiği bireyler seçilmiş olur. Örneğimizde 1,2,3,4,6 ve 8 numaralı bireyler bir sonraki popülasyon için seçilmişlerdir. Şekil 3.30 'de stochastic uniform seçim modeli görülmektedir (Svanandam ve Deepa, 2008: 50).



Şekil 3.30. Stochastic Uniform Seçim Modeli (Svanandam ve Deepa, 2008: 50).

3.8.3.7.(3).(a).iii. Rastgele Seçim

Bu yöntemde popülasyondan rastgele ebeveynler seçilir. Rastgele seçim yöntemi en basit seçim işlemidir ve bu yöntemde her bir bireyin seçilme olasılığı $\frac{1}{n_s}$ dir. Hiçbir uygunluk (fitness) bilgisi kullanılmaz bu nedenle de en iyi birey ve en kötü bireyin seçilme şansı aynıdır (Engelbrecht, 2007: 135).

3.8.3.7.(3).(a).iv. Sıralama Seçimi (Rank Selection)

Sıralama seçiminde, bireylerin seçilme ihtimali sıralamaya göre belirlenmektedir. Bu seçim yönteminde, popülasyondaki bireyler en iyiden en kötüye göre sıralanmaktadır. Her bir bireyin beklenen değeri, mutlak uygunluk fonksiyonundan ziyade sıralamasına bağlı olmaktadır. Seçilme olasılıkları belirlenirken de uygunluk fonksiyonları yerine, popülasyondaki sıralama dikkate alınmaktadır. Uygunluğun ölçeklendirilmesine gerek yoktur çünkü uygunluk değerleri arasındaki fark göz ardı edilmiştir (Sakawa, 2002: 22).

3.8.3.7.(3).(a).v. Turnuva Seçimi

Bu seçim sürecinde anakütleden rastgele iki birey seçilir. $[0,1]$ aralığında rastgele bir sayı belirlenir. Ayrıca k ile belirlenen bir turnuva seçim parametresi belirlenir. Eğer belirlenen rastgele sayı k parametresinden küçükse bu durumda iki bireyden en iyi uyum sağlayan seçilir. Aksi durumda daha az uyum sağlayan seçilir. Seçim yapılan iki birey tekrar anakütleye bırakılır. Böylelikle bir sonraki turnuva için yeniden seçilme durumları söz konusu olabilmektedir (Mitchell, 1999: 128).

Turnuva sayısının çok büyük seçilmesi en iyi bireylerin baskın olmasına yol açar ve bu şekilde seçim baskısını azaltır. Eğer turnuva sayısı çok az seçilirse bu durumda kötü bireylerin seçilme şansı söz konusu olmaktadır (Engelbrecht, 2007: 137).

3.8.3.7.(3).(b). Çaprazlama

İki adet ebeveyn çözümün alınması ve bunlardan yavru çözüm oluşturma işlemi çaprazlama olarak adlandırılmaktadır. Seçim işleminden sonra, anakütlenin daha iyi bireylerden oluşmasına katkı sağlamaktadır. Seçim işleminde iyi bireyler kopyalanır, yeni bireyler oluşturulmaz. Çaprazlama işlemi eşleşme havuzundaki bireylere uygulanır ve daha iyi bireyleri oluşturması beklenir. Çaprazlama işlemi üç adımda gerçekleştirilmektedir:

- Eşleşme için iki birey seçilir.
- Kromozomun uzunluğunda rastgele bir nokta seçilir.
- Bu noktanın böldüğü parçalar, ebeveynler arasında değiştirilir.


Böylelikle ilk ebeveynde noktanın öncesinde yer alan bilgiler bir araya getirilir. İkinci ebeveynden ise noktanın ilerisinde yer alan bilgiler bir araya getirilir ve yeni bir birey oluşturulmuş olur (Svanandam ve Deepa, 2008: 51).

Geleneksel genetik algoritmaların performansı ağırlıklı olarak çaprazlama işlemine bağlıdır ve temel operatör olarak görev almaktadır. Bireyde rastgele değişikliklerin gerçekleştirildiği mutasyon işlemi ise geri planda kalan bir işlemdir. Esasında genetik işlemler aramayı rastgele gerçekleştirmektedir ve iyileştirilmiş çözümü garanti etmezler. Çok kombinasyonlu optimizasyon problemlerinde genetik algoritmanın çözüme yakınsamasının zaman aldığı tespit edilmiştir. Çaprazlama ve mutasyonun karşılaştırıldığı çalışmalar yapılmıştır ve mutasyonun bazen çaprazlamadan daha önemli bir rol oynadığı ortaya konulmuştur (Gen ve Cheng, 2000: 2).

3.8.3.7.(3).(b).i. Tek Noktalı Çaprazlama

En sık kullanılan tek noktalı genetik değişimdir. İki kromozom belirlenen noktalardan kesilir ve kalan kısımlar karşılıklı değiştirilir. Bu işlem Şekil 3.31 'de görülmektedir. Kesimin yapılacağı noktanın belirlenmesi çok önemlidir. Doğru yerden

kesilme durumunda yeni oluşturulan bireyler ebeveynlerden daha iyi uygunluğa sahip olacaklardır. Doğru noktadan kesimin yapılmaması halinde dizilimin kalitesi bozulur.




Şekil 3.31. Genetik Algoritmelerde Tek Noktalı Çaprazlama İşlemi

3.8.3.7.(3).(b).ii. İki noktalı çaprazlama

Farklı nitelikte çaprazlama algoritmaları geliştirilmiştir. Bu algoritmaların ortak noktası birden fazla kesim noktası içermeleridir. Fazla sayıda kesim noktası kullanmanın genetik algoritmanın performansını azaltacağı unutulmamalıdır. Yine de birden fazla çaprazlama noktasının kullanılması arama uzayının daha etkin bir şekilde aranmasını sağlamaktadır.

İki noktalı çaprazlamada, iki adet çaprazlama noktası seçilmekte ve bu noktalar arasında kalanlar ebeveynler arasında karşılıklı değiştirilmektedir (Şekil 3.32).



Şekil 3.32. Genetik Algoritmelerde İki Noktalı Çaprazlama İşlemi

Genetik algoritmalar tek noktalı çaprazlama işlemini uygulamaktadır. Tek noktalı çaprazlamada, bir kromozomun ilk ve son kısmının yeni bireylere geçmesi mümkün değildir. Böylelikle eğer bir kromozomun ilk ve son kısımlarında iyi genetik bilgiler varsa, bu durumda tek noktalı çaprazlama ile bu iki bilginin yeni bireylere geçmesi sağlanamayacaktır. Bu nedenle iki noktalı çaprazlama bu olumsuz duruma maruz kalmamaktadır ve genel olarak tek noktalı çaprazlamadan daha iyi sonuçlar ürettiği düşünülmektedir (Svanandam ve Deepa, 2008: 56).

3.8.3.7.(3).(b).iii. Intermediate Çaprazlama

Doğrusal kısıtlamaların olduğu durumlarda kullanılacak çaprazlama yöntemidir. Bu yöntemde ebeveynlerin ağırlıklı ortalaması alınmaktadır. Ağırlıklar bu çalışmada 1 olarak belirlenmiştir. Bu yöntemde seçilen ebeveynlerden yavru şu formüle göre belirlenmektedir

$$child = parent1 + rand * Ratio * (parent2 - parent1)$$

3.8.3.7.(3).(b).iv. Çaprazlama oranı


Çaprazlama tekniğinde çaprazlama olasılığının kullanıcı tarafından belirlenmesi gerekmektedir. Bu olasılık değeri, çaprazlamanın hangi sıklıkta meydana geleceğini ifade etmektedir. Çaprazlamanın gerçekleşmediği durumlarda yavrular, ebeveynlerinin aynı özelliklere sahip olacaklardır. Fakat çaprazlama gerçekleşirse bu durumda, ebeveynlerin bazı özellikleri, yavrulara geçecektir. Bu oranın %100 olarak belirlendiği durumda, yeni oluşan anakütledeki bütün yavrular çaprazlama sonucunda belirlenmiş olur. Bu oranın %0 olarak belirlendiği durumda ise, yeni anakütle, eski popülasyondaki bireylerin kromozomlarından oluşmaktadır. Çaprazlamanın yapılmasının esas nedeni, eski kromozomlardaki iyi bilgilerin bir araya getirilmesidir. Böyle bir işlem sonucunda oluşan yavruların ebeveynlerinden daha iyi uyum sağlayan bireyler olması beklenmektedir. Fakat eski popülasyondaki bazı bireylerin çaprazlama işlemine uğramadan yeni popülasyona aktarılması işleminde de faydalar söz konusudur (Svanandam ve Deepa, 2008: 56).

3.8.3.7.(3).(c). Mutasyon

Mutasyon işleminin amacı, anakütledeki bireylerin genetik özelliklerine çeşitlilik eklemektir. Mutasyon işlemi çaprazlamayı desteklemek için kullanılmaktadır. Mutasyon bir olasılık dahilinde gerçekleştirilmektedir. Mutasyon olasılığı aynı zamanda mutasyon oranı olarak da adlandırılmaktadır ve $[0,1]$ aralığında küçük bir oran olarak seçilmektedir. Küçük bir oran olarak seçilmesinin esas nedeni ise iyi çözümlerin yapısının çok fazla bozulmamasıdır (Engelbrecht, 2007: 153).

Çaprazlama işleminden sonra, bireyler mutasyon işlemine tabi tutulmaktadır. Mutasyon algoritmanın yerel minimum noktasında takılı kalmasını önlemektedir. Mutasyon ile birlikte kaybolan genetik materyallerin ve rastgele dağıtılan genetik bilgilerin geri kazanılmasında önemli bir rol oynamaktadır. Mutasyon basit bir arama operatörü olarak göz önünde bulundurulmaktadır. Çaprazlama yönteminden varolan çözümlerden daha iyi çözümlerin üretilmesi beklenirken, mutasyonun da bütün arama uzayını taraması beklenmektedir. Mutasyon, anakütledeki genetik çeşitliliğin sürdürülmesini sağlayan ve geri planda yer alan bir operatör olarak görülmüştü. Rassal bir şekilde seçilen noktalardaki genetik yapılar değiştirilmek suretiyle yeni genetik yapılar kullanılmaya başlanmaktadır. Mutasyon, yerel minimum noktasına düşme tehlikesinden kurtulmaya ve anakütledeki çeşitliliği sağlamaya yardım etmektedir. Mutasyonun farklı çeşitleri söz konusu olmaktadır. İkili gösterimde basit bir mutasyon gendeki bilginin küçük bir olasılıkla değiştirilmesini içermektedir (Svanandam ve Deepa, 2008: 56).

Tek noktalı basit bir mutasyon işlemi Şekil 3.33 'de görülmektedir.



Şekil 3.33. Genetik Algoritmalarda Mutasyon İşlemi

Bir başka mutasyon yöntemi ise adaptation feasible olarak adlandırılmaktadır ve bu çalışmada da kullanılan mutasyon yöntemidir. En son nesil dikkate alınmak suretiyle rassal yönler yaratılır. Bu mutasyon yönteminde, doğrusal kısıtlar, alt ve üst sınırlar ve yön dikkate alınmak suretiyle mutasyon gerçekleştirilir.

3.8.3.7.(4). GA Süreci ve Örneği

Bu alt bölümde, daha önceden anlatılan konular genel hatları ile özetlenecek ve basit bir genetik algoritma çalışma örneği sunulacaktır.

Genetik algoritmalarındaki seçim süreci ile birlikte popülasyondaki her bireyin karşılaştırılması sağlanmaktadır. Seçim işlemi, uygunluk fonksiyonu ile gerçekleştirilir. Her bir kromozom için, temsil ettiği çözümün uygunluk değeri hesaplanır. Uygunluk fonksiyonu, aday çözümün ne kadar iyi olduğunun değerlendirilmesinde kullanılır. Optimzal çözüm amaç fonksiyonunu minimum yapan çözümdür. Genetik algoritmalarda, en küçük değer gözönünde bulundurulur. Eğer çözümü istenen problem maksimizasyon problemi ise, uygunluk fonksiyonu ters çevrilmek suretiyle maksimizasyon gerçekleştirilebilir. (Svanandam ve Deepa, 2008: 29-33).

Yeniden üretim ve uygunluk fonksiyonu, problemin ihtiyacına göre belirlendikten sonra, Genetik Algoritma evrimleşmeye başlar. Öncelikle başlangıç popülasyonunun yaratılması gerekmektedir. İlk popülasyonda geniş genetik materyallerin olmasına dikkat etmek gerekir. Gen havuzu, çözüm uzayındaki çözümün belirlenmesi için mümkün olduğunca geniş tutulmalıdır. Genellikle, başlangıç popülasyonu rastgele belirlenmektedir.

Daha sonra, genetik algoritma, popülasyonu evrimleştirmek için iterasyonlara başlar. Her bir iterasyon şu adımlardan oluşur:

- **Seçim.** İlk adım yeniden üretim için bireylerin seçiminden oluşur. Bu seçim, uygunluk fonksiyonu dikkate alınmak yoluyla gerçekleştirilir.
- **Yeniden Üretim.** İkinci adımda, seçilen bireylerden yeni bireyler meydana getirilir. Yeni kromozomların oluşturulmasında, yeniden kombinasyon veya mutasyon kullanılabilir.
- **Evrım.** Yeni kromozomun uygunluğunun değerlendiriliği adımdır.
- **Yerine Koyma.** Son adımdaki, eski popülasyondaki bireylerin ortadan kaldırılıp, yerine yenilerinin konulduğu adımdır.

Bir ya da daha fazla ebeveynden, bir ya da daha fazla yavru elde etme işlemi yeniden üretim olarak adlandırılır. Uygunluğun değerlendirildiği aşamada, bireyin kalitesi ölçülür. Mutasyonda, bir bireyin bazı genetik özelliklerinin rastgele değiştirilmek yoluyla yeni versiyonu oluşturulur. Seçim sürecinde, yeni arama noktaları üretime için

mutasyon ve yeniden üretimin uygulanacağı bireylerin belirlenmesi söz konusudur (Svanandam ve Deepa, 2008: 29-33).

Genetik Algoritma prosedürü yukarıdaki şekilde gösterilmiştir. Genetik algoritma çalışması sona erdiğinde genellikle anakütlede, en iyi uyum sağlayan bir veya birkaç bireyin olması beklenmektedir.

Genetik algoritmaların çalışma mantığı bir örnek yardımıyla açıklanabilir. Bu örnek (Mitchell, 1999: 9) çalışmasında yer almaktadır. Örneğin kromozom uzunluğunun 8 olduğu bir örnek düşünelim. Uygunluk fonksiyonu kromozom dizilimindeki toplam “1” sayısı olsun. Uygunluk fonksiyonunun en yüksek olmasını isteyelim (başka bir ifade ile maksimizasyon problemi olsun). Bu durumda kromozom diziliminde en fazla sayıda 1 yer alan kromozom en iyi (uygun) çözümü temsil edecektir. Anakütlede yer alan birey sayısı 4 olarak belirlensin ve çaprazlama oranı 0.7 ayrıca mutasyon oranı 0.001 olarak belirlensin.

Başlangıçta rastgele yaratılan anakülte şu şekilde olsun:

Kromozom etiketi	Kromozom dizilimi	Uygunluk
A	00000110	2
B	11101110	6
C	00100000	1
D	00110100	3

Rulet tekerleği seçim kurallarına göre seçim işleminin tercih edildiği varsayalım. Anakütlede dört adet birey söz konusu olduğu için rulet tekerleği dört adet çevrilir ve ilk iki döndermede B ve D, üçüncü ve dördüncü döndermede ise B ve C seçilmiş olsun.

Anakütleden bireyler seçildikten sonra çaprazlama oranı ile yeni yavrular oluşturulur. Eğer çaprazlama uygulanmazsa yeni bireyler ebeveynlerin birebir kopyası olacaktır. Örneğin B ve D bireyleri, ilk karakterden sonra çaprazlama işlemine tabi tutulsun ve E = 10110100 ve F = 01101110 bireylerini oluştursun. Buna rağmen B ve C bireyleri için çaprazlama işlemi uygulanmasın ve birebir kopyaları yeni anakütlede yer alsın. Daha sonra her bir birey mutasyon olasılığı ile mutasyona tabi tutulsun. Ve bu durumda diyelim ki E bireyi altıncı karakterde mutasyon geçirerek E' = 10110000 bireyini oluştursun. F ve C bireyleri mutasyona uğramazken B bireyinin de ilk karakterde mutasyona uğradığını kabul edelim. Bu durumda yeni oluşacak B' = 01101110 olacaktır. Yeni anakütlenin görünümü şu şekilde olacaktır.

Kromozom etiketi	Kromozom dizilimi	Uygunluk
E'	10110000	3
F	01101110	5
C	00100000	1
B'	01101110	5

Burada dikkate edilmesi gereken husus, başlangıç anakütlesinde, kromozomunda en fazla 1 değerinin yer aldığı birey (uygunluk değeri 6 olan birey), yeni anakütlede yer almıyor olmasına rağmen, ortalama uygunluk değeri 12/4 'ten 14/4'e yükselmiş oldu. Bu adımların tekrarlanması bütün dizilimlerin bir olduğu bir bireyi oluşturacaktır (Mitchell, 1999: 9).

3.8.3.7.(5). Genetik Algoritmanın Avantajları ve Kısıtları

Genetik Algoritmanın bazı avantajları ve kısıtları şu şekilde sıralanabilir (Svanandam ve Deepa, 2008: 34):

Genetik Algoritmanın avantajları;

- Paralellik
- Güvenilirlik (liability)
- Çözüm uzayının geniş olması
- Global optimumun keşfedilmesinin kolay olması
- Büyük ve az anlaşılmış çözüm uzaylarında işlem yapmanın kolay olması
- Uygunluk fonksiyonunun değerlendirilmesinde yaşanan zorluklara karşı dayanıklı (robust) olması
- Yerel optimuma yakalanmaya karşı dirençli olması
- Büyük çaptaki optimizasyon problemlerinde iyi performans sergilemesi
- Geniş optimizasyon problemleri için kullanılabilirler.

Genetik Algoritmaların kısıtları (dezavantajları) ise şu şekildedir:

- Uygunluk fonksiyonunun belirlenme problemi
- Popülasyon büyüklüğü, mutasyon oranı, çaprazlama oranı, seçim oranı ve gücü gibi parametrelerin belirlenmesinin zorluğu
- Probleme özel bilgilerin kolaylıkla yönetilmesinin mümkün olmaması
- Etkin sonlandırıcının olmaması (Ne zaman durulacağını tam olarak bilinmemesi)
- Uygunluk fonksiyonun çok sayıda değerlendirilmesine ihtiyaç duyulması
- Yapılandırmanın basit olmaması

3.8.4. Bilgi İşlemsel Zeka Yöntemlerinin Finansal Piyasalarda Uygulanması

Nedovic ve Devedzic (2002) uzman sistemlerin finans alanındaki uygulamalarını analiz etmişlerdir. Çalışmalarında finans alanında uzman sistemleri inceleyen çalışmalar bir araya getirilmiştir ve çalışmaların firmaların finansal analizi, firmaların başarı ya da başarısızlık nedenleri, piyasa analizi ve pazarlama eğitimi olmak üzere dört alanda yoğunlaştıklarını raporlamaktadırlar.

Bahrammirzaee (2010) ise çalışmasında yapay sinir ağları, uzman sistemler ve melez zeki sistemlerin finans literatüründeki uygulamalarını karşılaştırmışlardır. Çalışmalarında finansal piyasalardaki uygulamalar; kredi değerlendirme, portföy yönetimi ve finansal tahmin-planlama olmak üzere üç ana bölümde incelenmiştir.

3.8.4.1. Yapay Sinir Ağlarının Finansal Piyasalardaki Uygulanmaları

Bu bölümde yapay sinir ağlarının finansal piyasalardaki uygulamalarını bir araya getiren çalışmalara değinilecektir.

Burrell ve Folarin (1997) ise çalışmasında yapay sinir ağlarının finans alanına etkisini incelemek amacıyla birçok çalışmayı bir araya getirmiştir. Çalışmalarının sonucunda yapay sinir ağlarının farklı finansal problemlerin çözümünde başarılı bir şekilde kullanıldığı sonucuna varmışlardır.

Wong ve Selvi (1998) finans yazınında yapay sinir ağlarını kullanan çalışmaları bir araya getirmişlerdir. Çalışmalarında finansal yazında yapay sinir ağlarının genellikle, iflas tahmininde, ticari kredi başvurularının analizinde, mali başarısızlığın tahmininde,

kredi değerlendirmede, fiyat tahmininde, ilk halka arz fiyatlarının tahmininde, index tahmininde, çek limitinin aşp aşmadığının tahmininde, mali tablo analizi ve yorumlamasında, opsiyon fiyatlama ve hedge edilmesinde, faiz oranı tahmin edilmesinde, kredi değerlemede, optimal portföy oluşturulmasında, risk tahmininde, hazine bonosu piyasa tahmininde, portföy yönetiminde, sigorta problemlerinin incelenmesinde ve daha birçok finansal amaç için kullandıklarını raporlamaktadırlar. Çalışmalarında ayrıca yapay sinir ağlarında, aralarında yüksek ilişki olsa bile çok fazla sayıda değişkenin incelenebildiğini ifade etmektedirler.

Li ve Ma (2010) yaptıkları çalışmada, yapay sinir ağlarının finansal piyasalardaki uygulamalarını bir araya getirmişlerdir. Çalışmalarının sonucunda yapay sinir ağlarının öğrenme, genelleştirme ve doğrusal olmayan modelleme özellikleri sayesinde yapay sinir ağlarının finansal ekonomi alanında değerli bir araç olduğu sonucuna varmışlardır.

3.8.4.2. Genetik Algoritmaların Finansal Alandaki Uygulamaları

Genetik algoritmaların finansal alandaki uygulamaları aşağıdaki gibi özetlenebilir:

Allen ve Karjalainen (1999) teknik alım satım kurallarını bulmak için genetik algoritmaları kullanmışlardır. Lawrenz ve Westerhoff (2003) ise döviz kuru davranışlarını genetik algoritma ile modellemişlerdir. Mirmirani ve Li (2004) ise altın fiyatlarını genetik algoritma ve yapay sinir ağları ile modellemişlerdir. Nunez-Letamendia (2007) ise teknik alım satım sistemi tasarımı için genetik algoritmaları uygulamışlardır. Strabburg vd. (2012) ise çalışmalarında hisse senedi piyasalarında alım satım kurallarının belirlenmesinde paralel genetik algoritmaları kullanmışlardır. Deng vd (2012) ise genetik algoritmaları döviz kuru alım satımında kural oluşturmak için kullanmışlardır. Evans vd. (2013) ise döviz piyasasında gün içi alım satımları gerçekleştirecek bir sistemi genetik algoritmalar ve yapay sinir ağları ile inşa etmişlerdir. Chen ve Zhang (2013) ise döviz kurunun belirlenmesinde genetik algoritmaları kullanmışlardır.

Pereira (2000) ise finansal optimizasyon için genetik algoritmaları kullanmışlardır. Genetik algoritmaların alım satım kuralların keşfi, alım-satım kurallarının optimizasyonu, portfolyo optimizasyonu ve getiri tahmini için kullanıldığını ifade etmektedirler.

Jackson (1997) ise genetik algoritmaları, portföydeki varlıkların ağırlıklarının optimizasyonu için kullanmışlardır. Yang (2006) ise portföy etkinliğini arttırmak için genetik algoritmaları kullanmışlardır. Bermudez vd. (2012) ise çalışmada bulanık portföy seçimi için çok amaçlı genetik algoritmaları kullanmışlardır. Huang (2012) ise çalışmada genetik algoritma ve support vector regresyon ile birlikte melez bir hisse senedi seçim modeli oluşturmuşlardır. Fu vd. (2013) ise genetik algoritmaları teknik analiz ve portföy yönetimi için kullanmışlardır.

Oreski ve Oreski (2014) ise çalışmada kredi risk değerlendirme modelleri için özellik seçimini genetik algoritma ile gerçekleştirmişlerdir. Çalışmada genetik algoritmalar kredi risk değerlendirmesinde kullanmışlardır.

Varetto (1998) iflas tahmini ve sınıflandırılmasında geleneksel istatistiksel yöntemlerle genetik algoritmaların performansını karşılaştırmışlardır. Rafiei vd. (2011) ise İran'da faaliyet gösteren firmaların finansal sağlık durumlarını tahmin eden bir modeli, yapay sinir ağları, genetik algoritmalar ve çok değişkenli diskriminant analizi ile gerçekleştirmişlerdir. Kim ve Kang (2012), iflas tahmininde genetik algoritmaları kullanmışlardır.

3.8.4.3. Destek Vektör Makinelerinin Finansal Piyasalardaki Uygulamaları

Destek Vektör Makinelerinin (DVM) finansal alandaki uygulamalarından bazıları ise şu şekilde sıralanabilir:

Kim (2003) ise SVM' yi finansal zaman serisinin tahmininde kullanmışlardır.

Finansal başarısızlık ve iflas tahmininde DVM sıklıkla kullanılmıştır (Shin vd., 2005; Min vd., 2006; Wu vd., 2007; Yeh vd., 2010; Chaudhuri ve De, 2011; Lin F. vd., 2011; Li ve Sun, 2011; Hsieh vd., 2012; Sun ve Li, 2012; Li vd., 2014).

Kredi risk değerlendirme amacıyla destek vektör makinelerinin kullanılması söz konusudur (Huang vd., 2004; Chen ve Shih, 2006; Li vd., 2006; Xu vd., 2009; Yu vd., 2010; Kim ve Ahn, 2012; Li vd., 2012; Harris, 2013; Han vd., 2013).

Chen vd. (2009) DVM'yi takipteki kredilerin öngörüsü için kullanmışlardır. Kim ve Sohn (2010) ise destek vektör makinelerini zamanında ödenemeyecek teknoloji kredisi tabanlı borçların, önceden tahmin edilmesinde kullanmışlardır.

Öğüt vd. (2009) ise finansal bilgi manipülasyonunun öngörüsünde DVM yöntemini kullanmışlardır. Chen ve Roy (2011) ise destek vektör makinelerini nakit akımı tahmini için kullanmışlardır. Benhayoun vd. (2013) destek vektör makinelerini, işletmelerin finansal sağlık durumlarını ölçmekte kullanmışlardır. Firmaların kredi değerlerini tahmin edecek bir model geliştirmişlerdir. Zhu ve Wei (2013) ise karbon fiyatının tahmininde DVM metodolojisini kullanmışlardır.

3.8.4.4. ANFIS Yönteminin Finansal Piyasalardaki Uygulamaları

Kar vd. (2014) anfis yöntemi ile farklı disiplinlerde yapılan çalışmaları bir araya getirmişlerdir. Çalışmada ekonomik sistem alt başlığı altında finansal alandaki anfis uygulamalarına değinmişlerdir. Genel olarak anfis yönteminin hisse senedi piyasası, tedarik zinciri yönetimi, elektrik tüketim tahmini, turizm endüstrisi ve finansal krizler gibi alanlarda kullanıldığını raporlamışlardır.

Keles vd. (2008) ise anfis yöntemini yurtiçi borç miktarının tahmin edilmesinde kullanmışlardır. Tan vd. (2011) anfis yöntemini hisse senedi alım satımını gerçekleştirmek için bir model oluşturmada kullanmışlardır. Chen (2013) ise anfis yöntemini işletme başarısızlıklarını tahmin etmek için kullanmışlardır.

Malhotra ve Malhotra (2002) anfis yöntemini iyi ve kötü kredilerin ayrıştırılmasında kullanmışlardır. Moayer ve Bahri (2009) ise anfis yöntemini işletme için stratejik planlama senaryo yaratım sürecinde kullanmışlardır. Akkoç (2012) ise anfis yöntemini kredi değerlemede kullanmışlardır. Shekarian ve Gholizadeh (2013) ise anfis yöntemini ekonomik refahın analizinde kullanmışlardır.

Bilgi işlemsel zeka yöntemlerinden olan bulanık mantığın ayrıca, hisse senedi fiyat tahmininde (Atsalakis ve Valavanis, 2010), portföy seçiminde (Inuiguchi ve Ramik, 2000), kredi derecelemede (Baetge ve Heitmann, 2000) kullanıldığı görülmektedir.

Sonuç olarak bilgi işlemsel zeka yöntemlerinin finansal problemlerin çözümünde başarıyla kullanıldığı ve söz konusu yöntemlerin işletme literatüründe daha detaylı bir şekilde kullanılmaya devam edeceğini söylemek mümkündür.

4. UZMAN BİR SİSTEM ARACILIĞIYLA FİYAT TAHMİNİNDE BİST UYGULAMASI

4.1. Uygulamanın Amacı

Hisse senedi fiyatlarını önceden tahmin etmek araştırmacıların ilgisini çeken bir konudur. Etkin piyasalar hipotezini savunanlara göre hisse senedi fiyatlarını önceden tahmin etmek mümkün değildir. Buna rağmen birçok araştırmacı, önceki çalışmalar bölümünde anlatıldığı üzere hisse senedi fiyatlarını tahmin etmeye çalışmış ve belirli düzeyde başarı elde etmişlerdir.

Hisse senedi fiyat tahmini için literatürde, istatistiksel yöntemlerin yanı sıra, bilgisayarların işlem gücünün artmasına paralel olarak gelişen bilgi işlemsel zeka yöntemlerinin de kullanıldığı görülmektedir. Bu yöntemlerden bir tanesi yapay sinir ağlarıdır. Yapay sinir ağları ile hisse senedi tahmininde başlıca iki önemli mesele hakkında karar verilmesi gerektiği anlaşılmaktadır. Bu meseleler yapay sinir ağı mimarisi ve kullanılacak değişkenlerin seçimidir. Söz konusu parametrelere konu hakkında uzman olan kişiler karar verebilir. Fakat uzman kişilere erişmek her zaman için mümkün olmayabilir.

Genetik algoritmalar bilgi işlemsel zeka yöntemlerinden bir tanesidir ve sezgisel bir optimizasyon yöntemidir. Genetik algoritmalar yapay sinir ağları için mimari optimizasyonu ve değişken seçimini gerçekleştirecek şekilde tasarlanabilir.

Uygulamanın amacı hisse senedi fiyat tahmininde kullanıcı yerine karar veren uzman bir sistem oluşturmaktır. Tahmini gerçekleştirecek yöntem yapay sinir ağlarıdır. Söz konusu uzman sistemde yapay sinir ağları için değişken seçimi ve ara katmandaki nöron sayısı genetik algoritmalar ile eş zamanlı optimize edilmektedir. Böylelikle kullanıcı yerine tahmin modelini optimize eden uzman bir sistem ortaya çıkmıştır.

4.2. Uygulamanın Yöntemi

Bu bölümde uzman sistem detaylı bir şekilde tanıtılmaya çalışılacaktır. Çalışma temelde tahmin çalışmasıdır. Hisse senedi fiyatlarını tahmin edecek değişkenler geçmiş fiyat ve işlem hacmi verilerini kullanmak suretiyle hesaplanan teknik göstergelerdir. Çalışmada özellik seçimi parametre optimizasyonu ile eş zamanlı gerçekleştirileceğinden, özellik seçimi hakkında bilgilere de yer verilecektir. Daha sonra yapay sinir ağları, genetik algoritmaların işleyişi ve model tasarımı hakkında bilgi verilecektir. Çalışmada kullanılacak modelin özelliklerine de değinilecektir.

Bilgi işlemsel zeka (BIZ) çalışmalarında, zeki-inovatif uygulamalar geliştirmek için; öğrenme, adaptasyon ve evrimsel hesaplamalar bir arada kullanılır. BIZ çalışmaları istatistiksel modelleri tamamen dışlamış değildir. Çoğunlukla bu yöntemleri tamamlayıcı niteliktedir. BIZ, esnek hesaplama (yapay zeka ile hesaplama – soft computing) kavramı ile yakından ilgilidir ve etkin bir çözüm algoritması olmayan problemler üzerinde çalışan bir bilgisayar bilimi dalıdır (Sumathi ve Surekha, 2010). Hisse senedi fiyatlarını önceden tahmin etmekte kullanılacak değişken seçimi için hazır bir algoritma geliştirilemediğinden, BIZ yöntemleri değişken seçimi için kullanılabilir.

4.3. Özellik Seçimi

Özellik seçimi (Feature Selection) etkin bir tahmin performansı için veri setinde bulunan faydasız değişkenlerin elenmesini sağlamaktadır. Genetik algoritma özellik


seçiminde kullanılabilecek yöntemlerden bir tanesidir. Daha iyi tahmin performansı elde etmek için bir grup değişkenin seçilmesi önem arz etmektedir. Eğer başlangıç veri setinde yer alan ilgisiz ve fazla değişkenler listeden çıkartılırsa, öğrenme algoritmasının çalışma süresi de azalacaktır (Tsai ve Hsiao, 2010).

Özellik seçiminin belli başlı üç adet amacı vardır: değişkenlerin tahmin performansını güçlendirmek, daha hızlı ve etkili tahminleyiciler bulmak ve veri setini etkileyen esas süreçleri anlamayı sağlamak (Guyon ve Elisseeff, 2003: 1157).

Özellik seçiminin birçok faydası söz konusudur. Bunlar, veri setinin görselleştirilmesinin ve anlaşılmasının kolaylaştırılması, saklama boyutunun azaltılması, eğitim zamanının azaltılması, tahmin performansının artırılmasıdır (Guyon ve Elisseeff, 2003: 1157).

Özellik seçiminde değişkenler arasındaki ilişkilerin göz önünde bulundurulması gerekmektedir. Bazı değişkenler arasında mükemmel korelasyon olabilir. Böyle bir durumda hepsinin aynı anda kullanılması ek bir fayda sağlamayacaktır. Tek başına faydasız olan bir değişken diğerleri ile birlikte kullanıldığında önemli performans artışı sağlayabilir. Tek başlarına faydasız olan iki değişken, birlikte kullanıldığında ise faydalı olabilir (Guyon ve Elisseeff, 2003: 1165).

Gerçek hayat problemlerinde bir araya getirilen veriler bilgisayarların işlem kapasitesini zorlayacak boyutlarda olabilir. Bu nedenle, mümkün olan en az kayıpla veri setinin daha yönetilebilir boyuta indirgenmesi, çoğu zaman faydalıdır ve bazen de gereklidir. Genellikle, toplanan bilgilerin önemli bir kısmı ya gereksizdir ya da yanıltıcı unsurlar barındırmaktadır. Bu nedenle analizlerin ileri safhalarına geçilmeden önce bu tür bilgilerin, veri setinden çıkarılması gerekmektedir. Bu tür temizleme işlemi sadece analizin daha hızlı gerçekleşmesini sağlamaz aynı zamanda elde edilen sonuçların daha anlaşılır olmasını sağlar ve sonuçların kalitesini arttırabilir (Jensen ve Shen, 2008: 62).




Şekil 4.1. Boyut İndirgeme Yöntemlerinin Sınıflandırılması (Jensen ve Shen, 2008: 62).

Boyut indirgeme teknikleri bazen veri setinin altında yatan önemli özelliklerin yapısını bozmaktadır ve bu birçok uygulama için istenmeyen bir özelliktir. Boyut indirgeme teknikleri Şekil 4.1 de gösterilmiştir. Şekilde boyut azaltma yöntemleri; veri setinin tamamen yeni bir sete dönüştüğü ve veri setinden bir alt kümenin seçildiği yöntemler olmak üzere ikiye ayrılmıştır. Hangi boyut azaltma tekniğinin kullanılacağı, üzerinde çalışılan problemin özelliklerine göre değişmektedir (Jensen ve Shen, 2008: 63).


Özellik seçimi, ilgisiz (irrelevant) ve/veya gereksiz (redundant) özelliklerin elenmesini sağlayan bir görevdir (Liu ve Motoda, 2008: 4). İlgisiz değişkenler, öğrenme algoritmasının performansını etkilemeden ortadan kaldırılabilir (Yu ve Liu, 2004). Gereksiz özellikler ise ilgisiz özelliklerin bir çeşidir (John vd., 1994). Bir veya daha fazla ilgili değişkenin olduğu durumda gereksiz değişkenden bahsedilmektedir. Bu durumda her değişken ilgilidir fakat bir tanesinin kaldırılması öğrenme performansını etkilemeyecektir (Liu ve Motoda, 2008: 5).

İlgili ilgisiz değişkenlerin şematik gösterimi Şekil 4.2 deki gibidir. Bir değişken alt kümeden çıkarıldığında performansta düşme oluyorsa güçlü ilgili (strongly relevant) olarak adlandırılır. Bir değişken eğer güçlü ilgili değilse ve değişkenin kümeye eklendiği durumda, kümenin performansını arttırabildiği bir S alt kümesi varsa zayıf ilgili (weakly relevant) olarak nitelendirilir. Bir değişken eğer güçlü ilgili (strongly relevant) veya düşük ilgili (weakly relevant) değilse ilgisiz olarak tanımlanmaktadır.



Şekil 4.2. İlgili ve İlgisiz Özellikler (Kohavi ve John, 1997: 298).

Şekil 4.3 'de seçim bazlı boyut indirgeme yer almaktadır. Şekildeki matriste m adet gözlem yer almaktadır. Ayrıca dönüşümden önceki veri setinde n adet değişken (özellik) yer almaktadır. Söz konusu veri setine seçim bazlı boyut indirgeme yöntemi uygulandığında alt kısımda yer alan matris elde edilmektedir. İkinci matriste k adet değişken yer almaktadır. Boyut azaltıldıktan sonra elde edilen matriste ilk matristekinden daha az sayıda veya en fazla orjinal boyuttaki kadar değişken olması beklenmektedir.



Şekil 4.3. Genel Olarak Özellik Seçimi

Bu çalışmada girdi veri setinin özelliklerinin korunması tercih edilmiştir. Bir sonraki güne ilişkin tahminler girdi veri seti üzerinden gerçekleştirilecektir. Veri setinin dönüştürülmesi (dönüşüm bazlı boyut indirgeme seçeneğinin tercih edilmesi), tahmin performansını ölçen ve günlük tahminleri girdi olarak kullanmayı şart koşan, alım satım algoritmasının işlemlerini bozacaktır. Bir sonraki güne ilişkin yapılan tahminlerin ne kadar başarılı olduğunu ortaya koyabilmek için, tahmin sonuçlarını alım satım işlemlerini günlük bazda yönlendirmesi beklenmektedir. Günlük bazda tahminler seçim bazlı veri dönüştürme işleminde oldukça kolay bir şekilde kullanılabilir. Bu nedenle dönüşüm bazlı boyut indirgeme teknikleri sadece özetlenecek, fakat seçim bazlı boyut indirgeme modelleri daha detaylı incelenecektir.

4.3.1. Dönüşüm Bazlı Boyut İndirgeme

Bu yöntemde veri seti tamamen yeni bir veri setine dönüştürülmektedir. Veri setinin orijinal halindeki anlam (semantic) ilerleyen süreçlerde kullanılmayacaksa, bu yöntem tercih edilmektedir. Doğrusal dönüşüm ve doğrusal olmayan dönüşüm olmak üzere iki grupta incelenebilmektedirler. Doğrusal bazlı boyut indirgemenin en çok bilinen örneği temel bileşen analizi (principal component analysis PCA) dir. PCA çok boyutlu olan orijinal girdi setini genelde daha az boyutlu ve birbirleriyle ilişkisi olmayan veri setine dönüştürmektedir (Jensen ve Shen, 2008: 63).

Boyut indirgeme suretiyle hisse senedi fiyat tahmini gerçekleştiren çalışmalardan bir tanesi Ince ve Trafalis (2007) 'e aittir. Yazarlar makalelerinde PCA yöntemini kullanmak suretiyle veri setlerini dönüşüme tabi tutmuşlar ve daha az sayıda olan dönüştürülmüş veri seti ile hisse senedi fiyat tahmini gerçekleştirmişlerdir.

Doğrusal olmayan dönüşüm bazlı boyut indirgeme teknikleri ise bu çalışmanın kapsamı dışındadır.


4.3.2. Seçim Bazlı Boyut İndirgeme

Dönüşüm bazlı boyut indirgeme tekniklerinde, orijinal veri setindeki anlam (semantic) geri dönüşü olmayan biçimde bozulmaktadır. Buna karşılık özellik seçimi olarak da adlandırılan (semantic-preserving Dimension Reduction) teknikler, orijinal veri setindeki anlamı korumaya çalışmaktadır. Özellik seçiminin esas amacı, orijinal özellik setindeki önemli özellikler korunurken, problemi çözebilecek en az sayıdaki özellik alt kümesinin belirlenmesidir. Birçok gerçek hayat problemlerinde özellik seçimine ihtiyaç duyulmaktadır, çünkü veri setlerinde, gürültülü (noisy), ilgisiz (irrelevant) veya yanıltıcı (misleading) özellikler bulunmaktadır. Bu faktörlerden arınmış bir veri seti kullanmak suretiyle yüksek doğruluklu öğrenme (veya tahmin) gerçekleştirilebilir (Jensen ve Shen, 2008: 66).

Bir özellik veya özellik alt kümesinin faydası, ilgililik (relevancy) ve gereğinden fazla (redundancy) olma kavramları ile belirlenmektedir. Bir özelliğin ilgili olabilmesi için karar değişkenini tahmin edebilecek durumda olması gerekir. Aksi takdirde ilgisizdir. Eğer bir özellik, diğer özelliklerle aşırı derecede ilişkiliyse (correlation) gereksiz olarak nitelendirilmektedir. Bu nedenle iyi bir özellik alt kümesi seçimi, karar değişkeni veya değişkenleri ile yüksek derecede koreli fakat birbirleriyle ilişkili olmayan değişkenlerin belirlenmesini içermektedir.

Özellik seçim yaklaşımlarının sınıflandırılması Şekil 4.4 'deki gibidir. Başlangıç özellik sayısı n olarak belirlensin. Bu durumda özellik seçiminin görevi 2^n adet aday alt küme içerisinde optimal olanın belirlenmesidir. (Çalışmada 53 adet özellik belirlenmiştir. Bu özelliklerin oluşturduğu bütün alt kümelerin sayısı ise $2^{53} = 9.0071993 \times 10^{15}$ adettir. Bütün olası alt kümeleri denemek çok uzun zaman alacaktır. Üstelik seçilecek değişken sayısı arttıkça bilgisayarın daha fazla kaynağa ihtiyaç duyacağı da göz önünde bulundurulmalıdır.)

Optimal altkümenin ne olduğu, çözülmeye çalışılan problemin özelliklerine bağlıdır. Tek tek bütün alt kümeleri denemek kesin sonuç verecektir. Buna rağmen gerçek hayatta bütün alt kümeleri denemek mümkün olmayabilir. Bu karmaşıklıktan uzaklaşmak için genellikle sezgisel (heuristic) yöntemler veya rastgele arama stratejileri izlenmektedir.




Şekil 4.4. Özellik Seçiminin Farklı Boyutları (Jensen ve Shen, 2008: 67).

Tipik bir özellik seçim yönteminde şu adımlar söz konusudur (Şekil 4.4).

- **Yaratım prosedürü:** bu prosedürle birlikte bir sonraki aday alt küme yaratılmaktadır.
- **Değerlendirme fonksiyonu:** göz önünde bulundurulan alt kümeyi değerlendiren bir fonksiyondur.
- **Durma kriteri:** özellik seçim prosedürünün ne zaman sona ereceğini belirler.
- **Değerlendirme prosedürü:** yaratılan altkümenin geçerli olup olmadığı belirlenmektedir.

Yaratım prosedürünün bir arama prosedürü olduğunu söylemek mümkündür (Lengley, 1994). Temel görevi, değerlendirme için yeni alt kümelerin yaratılmasını sağlamaktır. Yaratım prosedürü (i) hiç özellik olmadan, (ii) bütün özelliklerle veya (iii) rastgele seçilen bir alt küme ile başlayabilir. İlk iki durumda, özellikler yineleme sürecinde eklenir veya çıkarılır, son durumda ise yinelemeli bir şekilde eklenebilir, çıkarılabilir veya rastgele yeniden üretilebilir (Lengley, 1994). Değerlendirme fonksiyonu ise yaratım prosedürü ile yaratılan alt kümenin uygunluğunu değerlendirmektedir ve önceki en iyi performans ile karşılaştırmaktadır. Daha önceki en iyiden daha iyi bir sonuç bulunduyorsa, yer değiştirilir. Durdurma kriteri her bir yenilemede özellik seçim sürecinin devam edip etmeyeceğini kontrol eder. Durdurma kriteri olmadan özellik seçim süreci sonsuza kadar devam eder. Yaratım prosedürü ve değerlendirme fonksiyonları durdurma kriterinin seçimini etkileyebilir. Durdurma kriteri yaratım prosedürüne bağlı olabilir ve şu şartlardan biri sağlandığında işlem sona erer (i) önceden tanımlanmış sayıda özellik seçimi ve (ii) önceden belirlenmiş yineleme sayısına ulaşılması. Durdurma kriteri aynı zamanda değerlendirme fonksiyonuna da bağlı olabilir ve (i) yeni bir özelliğin eklenip silinmesinin daha iyi alt küme yaratmadığı veya (ii) belirlenen değerlendirme fonksiyonuna göre uygun bir değer elde edildiği durumda sona erebilir. Döngü durma kriterindeki olumlu koşul sağlanana kadar devam eder. Özellik seçim süreci, bir dizi girdi setinden oluşan bir alt küme ile sona erer. Değerlendirme süreci ise, özellik seçim sürecinin bir parçası değildir fakat özellik seçim yönteminin pratikte mutlaka doğrulanması gerekmektedir (Dash ve Liu, 1997: 133).




Şekil 4.5. Özellik Seçim Süreci (Dash ve Liu, 1997:133).


Özellik seçim algoritmaları, değerlendirme prosedürüne göre iki kategoriye ayrılabilir. Eğer seçim süreci bir öğrenme algoritmasından tamamen bağımsızsa filitre yaklaşımı söz konusudur. Bu yöntemde ilgisiz değişkenler filitrelenmektedir. Herhangi bir öğrenme algoritmasına bağlı olmadıklarından dolayı birçok alanda kullanılabilirler (Jensen ve Shen, 2008: 69).

Eğer değerlendirme süreci bir göreve bağlıysa, bu durumda wrapper yaklaşımdan bahsedilmektedir. Bu yöntemde alt kümenin uygunluğu bir öğrenme algoritmasına bağlıdır.

Flitre Yaklaşımı



Wrapper Yaklaşımı




Şekil 4.6. Özellik Seçiminde Wrapper ve Filtre Yaklaşımı (Jensen ve Shen, 2008: 68).

Özellik seçiminde filtre ve wrapper yaklaşımları arasındaki fark Şekil 4.6 ‘deki gibidir.

Bu çalışmada özellik seçimi için wrapper yaklaşımı tercih edilmiştir.

Wrapper yaklaşımında alt kümelere, tahmin etme gücü ile ilişkili bir skor atanmaktadır ve bu işlem kara kutu özelliği taşımaktadır (Şekil 4.7). Filtre metodunda ise değişkenler önileme adımı olarak, seçilen tahminleyiciden tamamen bağımsız bir şekilde seçilmektedir (Kohavi ve John, 1997).



Şekil 4.7. Wrapper Yaklaşımının Şematik Gösterimi (Kohavi ve John, 1997: 274).

Denetimli makine öğrenme yönteminde, hedef değişkenlerin ve tahmin değişkenlerinin işlendiği bir endüksiyon algoritması söz konusudur. Özellik altkütmesi seçim probleminde ise, bir grup değişkenin seçimi üzerinde odaklanılır ve geri kalan değişkenler göz ardı edilir. Wrapper yaklaşımında ise özellik seçim algoritması, endüksiyon algoritmasının çevresini sarmaktadır. Özellik seçim algoritması, seçilen alt kümenin uygunluğunu ölçmek için endüksiyon algoritmasını kullanmaktadır. Şekil 4.7 ‘de wrapper yaklaşımı gösterilmektedir. Endüksiyon algoritması kara kutu olarak göz önünde bulundurulmaktadır. Değerlendirmede en başarılı olan alt küme, nihai alt küme

olarak seçilir ve endüksiyon algoritmasına gönderilir. Arama sırasında kullanılmayan bir veri setinde tahmin gerçekleştirilir (Kohavi ve John, 1997: 275).

4.4. Model Tasarımı

Hisse senetlerinin fiyatlarını doğru bir şekilde tahmin etmesi beklenen uzman yöntem açıklanacaktır. Bu uzman sistem genetik algoritmalar ve yapay sinir ağlarından oluşmaktadır ve yapay sinir ağları kullanımında insan müdahalesini mümkün olduğunca en düşük düzeye indirmektedir.

Daha önce yapılan araştırmalar incelendiğinde, yapay sinir ağları ile hisse senedi fiyatı tahmini gerçekleştirmek için iki çok önemli kararın verilmesi gerektiği anlaşılmaktadır. Bunlardan birincisi, tahmin için kullanılacak değişkenlerin belirlenmesidir. Çok fazla sayıda teknik göstergenin hesaplanması mümkündür. Fakat bu değişken havuzundan en başarılı tahmini gerçekleştirecek değişkenlerin seçimi için mevcut bir yöntem söz konusu değildir. İkinci önemli husus ise ara katmanda yer alacak nöron sayısının belirlenmesidir. Literatürdeki çalışmalarda deneme yanılma yoluyla veya bazı kurallara göre ara katmandaki nöron sayısının belirlendiği görülmektedir. Bu çalışmada ise melez bir yöntem sayesinde ara katmanda yer alması gereken nöron sayısı ile birlikte kullanılacak değişkenler genetik algoritmalar yardımıyla belirlenecektir. Bu amaçla özel bir uygunluk fonksiyonu ve özel bir gen tasarlanmıştır.

Yapay sinir ağları ile tahmin gerçekleştirmek için öncelikle yapay sinir ağlarının yapısının belirlenmesi gerekir. Ayrıca yapay sinir ağlarının, çıktıyı başarılı bir şekilde tahmin etmesini sağlayacak girdi bileşiminin de belirlenmesi gerekir. Bu iki özellik rastgele belirlenebilir. Fakat böyle bir durumda başarı şansının düşük olması beklenir. Bir başka seçenek ise söz konusu özelliklerin, hisse senedi fiyatı tahmini konusunda deneyimli uzmanlar tarafından gerçekleştirilmesidir. Uzmanlar hangi teknik göstergenin, hangi hisse senedi için al veya sat sinyali verdiğini, deneyimlerine ve bilgilerine dayanarak suretiyle belirleyebilirler. Fakat uzman bilgisine başvurmanın zor, imkansız veya maliyetli olduğu durumlar söz konusu olabilir. Uzman bilgisinin her zaman kullanıcının hizmetinde olmadığı durumlar da söz konusu olabilir.

Yukarıda yer alan problemlerin çözümü için belirgin bir sayısal yöntem söz konusu değildir. Bu nedenle bu gerçek problemlerin çözülebilmesi için sezgisel optimizasyon yöntemleri kullanılabilir. Sezgisel optimizasyon yöntemleri çözümü zor olan problemler için olası en iyi çözümü bulmayı amaçlayan bilgisayar programlarıdır.

Bu çalışmada önerilen melez yöntemde genetik algoritma, yapay sinir ağının ara katmanında yer alan nöron sayısını ve girdi bileşimini eş zamanlı optimize etmek için kullanılacaktır. Genetik algoritmalarda her bir aday birey bir gen ile temsil edilmektedir. Çalışma için tasarlanan özel gen yardımıyla farklı nitelikte olmasına rağmen her iki özelliğin de eş zamanlı optimizasyonu gerçekleştirilebilmektedir. Değişken seçimi problemlerinde kaç adet değişkenin seçileceğine karar vermek gerekmektedir. Farklı sayılarda değişken tercih edilmesi farklı sonuçların alınmasına neden olabilir. Bu çalışma için tasarlanan özel gen, optimal değişken sayısını da belirleyebilmektedir.

4.4.1. Genetik Algoritma Parametreleri

Çalışmada genetik algoritmalar, yapay sinir ağlarının yapısını optimize etmek ve değişken seçimini gerçekleştirmek için eş zamanlı kullanılacaktır. Genetik algoritma özel bir problem çeşidi olan hisse senedi fiyatı tahmin problemine uygulanacaktır. Genetik algoritmanın söz konusu problemi çözebilmesi için uygun bir gen tasarımının ve

uygunluk fonksiyonunun varolması gerekmektedir. Ayrıca bazı parametrelerin belirlenmesi gerekmektedir.

Çalışmada MATLAB yazılımı kullanılmıştır. Çalışmada kullanılan genetik algoritmaya ilişkin parametreler ise şu şekildedir:

- Başlangıç popülasyonu : gacreationlinearfeasible. Çalışmanın genetik algoritmaları açıklayan bölümünde genetik algoritmaların rastgele değerlerden oluşan bir başlangıç anakütlesi ile başladığı açıklanmıştır. Bu çalışmada bazı alt ve üst sınırlar söz konusudur. Bu nedenle bu sınırlar dahilinde bir anakütle oluşturmak için farklı bir yerleşik fonksiyon olan gacreationlinear feasible tercih edilmiştir.
- Çaprazlama fonksiyonu : crossoverintermediate
- Çaprazlama oranı : 0.8
- Elit Değeri : 2
- Mutasyon fonksiyonu = mutationadaptfeasible
- Seçim fonksiyonu = selectionstochunif.
- Nesil (Generation) sayısı = 100. Diğer koşullar nedeniyle genetik algoritmanın çalışması durdurulmadığı müddetçe 100 nesil çalışmaya devam edecektir.
- Fonksiyon toleransı : 1e-6. Bu değerden daha iyi bir değer elde edilemediğinde genetik algoritma durmaktadır.

4.4.1.1. Kromozom Tasarımı

Bu çalışmada hisse senedi fiyatının önceden tahmin edilebilmesi için yapay sinir ağlarından faydalanılacaktır. Tek katmanlı bir yapay sinir ağında gizli katmanda yer alması gereken nöron sayısının ve seçilecek değişkenlerin belirlenmesi gerekmektedir. Bu çalışmada bu iki özellik genetik algoritma yardımıyla eş zamanlı optimize edilecektir.

Çalışmada kullanılan kromozom iki kısımdan oluşmaktadır. İlk kısım yapay sinir ağının ara katmanında yer alması gereken nöron sayısını temsil ederken, kromozomun geri kalan kısmı başlangıçtaki değişken kümesinde değişkenlerin seçilme durumunu temsil edecektir.

n		f_1		f_2		f_3		f_4		f_5
-----	--	-------	--	-------	--	-------	--	-------	--	-------

n : Ara katmanda kullanılması gereken değişken sayısı

f_n : seçilen değişkenlerin indisleri

Şekil 4.8. Çalışmada Kullanılan Gen Tasarımı


Şekil 4.8 'de çalışmada kullanılacak kromozom tasarımı görülmektedir. Kromozomun ilk kısmı olan ve n sembolüyle gösterilen kısım ara katmanda yer alacak nöron sayısını temsil etmektedir. Ara katmanda yer alan nöron sayısının belirli bir sınır dahilinde olması gerekmektedir. Fazla sayıda nöronun kullanılması veya az sayıda nöronun kullanılması, iyi sonuçların alınmasını engelleyebileceği gibi, bilgisayarı cevap vermeyecek bir durumda bırakabilir. Bu nedenle de ara katmandaki nöron sayısının en az 2 en fazla 30 değerinin alınmasını sağlayacak kısıtlama getirilmiştir. Kromozomun geri kalan kısmında yer alan ve f_k ile gösterilen kısım ise 1 veya 0 değerini almaktadır. f_k değerinin bir olması durumunda aday değişken sıralamasında k . sırada yer alan değişken

modelde kullanılacaktır. Değerin sıfır olması durumunda ise k . sırada yer alan değişken analizde kullanılmayacaktır.

Değişken seçimi problemi kaç adet değişkenin seçilmesi gerektiği önem arz etmektedir. Araştırmacı kaç adet değişken kullanacağını belirlemesi gerekmektedir. Örneğin, bir problem çözülürken, biraraya getirilen değişken havuzundan en iyi sonucu verecek X adet değişkenin seçilmesi gerekir gibi bir noktaya varılmış olabilir. Fakat söz konusu X değerinin neye göre belirleneceği problemi ortaya çıkmaktadır. Her ne kadar genetik algoritma, X adet en iyi değişkeni seçecek şekilde programlanabilse de, X değerinin belirlenmesi önemli problemleri de beraberinde getirmektedir. Örneğin $X+2$ veya $X-2$ adet değişken seçilmesi durumunda sistemin performansı nasıl değişecektir? Performans artabiliyorsa, X 'den farklı sayıdaki değişkenlerin kullanılmasında fayda olacaktır. Önerilen modelde yer alan gen tasarımı bu problemi ortadan kaldırmaktadır. Özel olarak bu çalışma için tasarlanan gen yardımıyla, kaç adet hangi değişkenin kullanılması gerektiği genetik algoritma tarafından belirlenebilmektedir. Başka bir ifadeyle en iyi değişkenler seçilirken, değişken sayısı da genetik algoritma ile optimize edilmektedir. Değişken seçimi serbest bırakıldığı için, uygun olduğu durumda bütün değişkenler de hiçbir özellik seçimine maruz kalmadan girdi olarak kullanılabilir.

4.4.1.2. Uygunluk Fonksiyonu

Çalışmanın uygunluk fonksiyonun tasarımı önem arz etmektedir. Çeşitli uygunluk fonksiyonları denenmiştir ve bu denemelerde doğru bir şekilde tasarlanmamış uygunluk fonksiyonlarının oldukça kötü/hatalı/yanlış değerler ortaya çıkarabildiği anlaşılmıştır. Bu nedenle genetik algoritmalarda uygunluk fonksiyonun doğru bir şekilde tanımlanması gerekmektedir. Çalışma için tasarlanan uygunluk fonksiyonunun şematik gösterimi Şekil 4.9 ‘da yer almaktadır.



Şekil 4.9. Çalışmada Kullanılan Uygunluk Fonksiyonunun Şema ile Gösterimi

Eğitim amacı ile kullanılacak veri seti 800'ün katları olacak şekilde belirlenmiştir. Çünkü söz konusu 800 adet gözlemden ilk 640 adedi yapay sinir ağının eğitimi için kalan

160 adedi ise test amacıyla kullanılacaktır. Uygunluk fonksiyonu ilk önce veri setini 800'ün katlarına ayırmaktadır. Her bir katmandaki ilk 640 adet gözlemi eğitim için kullanmakta ve kalan 160 adet gözlemden model test edilmektedir. Test aşamasındaki mse değeri hata oranını oluşturmaktadır. Sadece bir tek eğitim setinin değil de birden fazla alt grubun kullanılmasının sebebi, yapay sinir ağları anlatılırken değinilen aşırı uyum probleminin engellenmeye çalışılmasıdır.

Uygunluk fonksiyonu ilk önce eğitim için gelen eğitim setini 800'er gözlemden oluşacak şekilde sıralı setlere ayırmaktadır. Genetik algoritmalar önceden tasarlanmış genin uygun kurallar çerçevesinde değişikliğe uğratmak suretiyle uygunluk fonksiyonunu minimum yapmaya çalışır.

Çalışmada eğitim amacı ile kullanılacak veri ayrı alt kümelere ayrıldıktan sonra her bir küme yeni bir ayrıma tabi tutulmaktadır. Bu ayrımda ilk 640 adet gözlem eğitim amacı ile son 160 gözlem ise test amacı ile kullanılmaktadır. O iterasyondaki gen ile yapay sinir ağı modeli her bir set için ayrı ayrı oluşturulmaktadır. Her bir setteki model, setteki test veri setinde denenmektedir. Erişilen hata oranı bir toplama eklenmektedir. Sonuçta elde edilen toplam hata oranı set sayısına bölünmektedir. Başka bir ifade ile erişilen test hatalarının aritmetik ortalaması alınmaktadır.

Uygunluk fonksiyonunda MSE değeri çıktı olarak kullanılmaktadır. Bu değer ne kadar küçük hesaplanırsa, yapılan tahminlerin gerçeğe o kadar yakın olduğunu söyleyebiliriz. MSE değerinin en küçük olması istendiği için bir minimizasyon problemi söz konusudur.

MSE nin uygunluk fonksiyonunda kullanılmasının esas nedeni ise yapay sinir ağlarında Levenberg-Marquardt algoritmasının kullanılması ve bu algoritmanın da Jacobian hesaplamaları kullanmasıdır. Jacobian hesaplamalarında performansın mean veya sum of squared errors olduğu varsayılmaktadır. Levenberg-Marquardt eğitim algoritması sonuca ulaşma özellikleri diğer eğitim algoritmalarına göre daha iyidir (Ngia ve Sjöberg, 2000). Bu nedenle bu çalışmada Levenberg-Marquardt algoritması kullanılmıştır.


4.4.2. Model

Önerilen model birkaç aşamadan oluşmaktadır.

- Adım 1 Hisse senetleri geçmiş fiyat bilgilerinin elde edilmesi
- Adım 2 Geçmiş fiyat hareketlerine ilişkin aday değişkenlerin hesaplanması
- Adım 3 Tahmin modelinin oluşturulması
- Adım 4 Tahmin modelinin test veri setine uygulanması ve sonuçların karşılaştırılması

Teorik bölümde anlatılanlar çerçevesinde bu çalışmada teknik göstergeler potansiyel tahmin edici olarak kullanılacaktır. 47 tanesi teknik gösterge olmak üzere toplam 53 adet aday değişken hesaplanmıştır. Hesaplanan bu 53 adet aday değişken bu çalışmada kullanılacak modelin girdi veri setini oluşturmaktadır. Çıktı veri setini ise bir gün sonraki kapanış fiyatının yer aldığı veri seti oluşturmaktadır (Şekil 4.10). Bu iki veri seti toplam veri setini oluşturmaktadır. Toplam veri seti; eğitim, doğrulama ve test veri seti olmak üzere üç bölüme ayrılmaktadır. Eğitim ve doğrulama veri seti modelin oluşturulmasında ve optimizasyonunda kullanılırken, test veri seti modelin ne kadar iyi performans sergilediğini ve ne kadar karlı yatırım fırsatı sunabildiğini ortaya çıkarmakta kullanılacaktır. Test veri seti hiçbir şekilde modelde kullanılmayacak ve modelden tamamen bağımsız olacaktır. Böylelikle modelin gerçek hayatta uygulanması durumunda

göstereceği performans, model oluşturulurken kullanılan veri setlerinden bağımsız olarak belirlenmiş olacaktır.



Şekil 4.10. Uzman Sistemin Ana Hattı


İlk olarak veri setinin bir araya getirilmesi gerekmektedir. Çalışmada kullanılacak değişken seti hesaplanıp, eğitim ve test aşamasında kullanılacak gözlemler belirlenir.

Önerilen yöntemde eğitim veri setinde genetik algoritma işlemleri uygulanır ve belirlenen uygunluk fonksiyonuna göre en iyi sonucu veren gen belirlenir.

Genetik algoritmalar yapay sinir ağındaki nöron sayısını ve kullanılacak değişkenleri belirlemektedir. Genetik algoritmanın uygunluk fonksiyonunda en iyi değeri (en küçük hatayı) veren bileşen optimal bileşen olarak adlandırılmaktadır.

Şekil 4.11 'de ise genetik algoritmaların, yapay sinir ağları ile nasıl entegre olduğu görülmektedir. Şekil ilk olarak genetik algoritmanın başlangıç anakütlesi ile başlamaktadır. Bu anakütle bir dizi genden oluşmaktadır. Her gende ara katmanda yer alması planlanan nöron sayısı ve 53 adet değişkenin kullanılıp kullanılmama durumunda ilişkin rastgele atanan başlangıç değerleri yer almaktadır. Anakütlerde değişkenler indeks olarak tanımlanmaktadır. Örneğin anakütlerdeki 5 değeri, 53 adet aday değişken sıralamasın 5. sırasında yer alacak değişkeni temsil etmektedir.

Rastgele olarak atanan başlangıç değerlerini içeren genler kullanılır ve popülasyondaki her bir birey için uygunluk fonksiyonu değeri hesaplanır. Anakütlerdeki genler, genetik operasyonlar yardımıyla değişikliğe tabi tutulur ve yeni bireyler oluşturulur ve yeni oluşturulan her bir yeni birey için uygunluk değeri de hesaplanır. Eğer bitirme şartı sağlanıyorsa bu durumda yeni genetik işlemlere başvurulmaz ve en iyi sonuçları veren değişkenler ve ara katmandaki nöron sayısı belirlenmiş olur. Eğer bitirme şartı sağlanmıyorsa bu döngü yeniden ve yeniden optimal değerler belirlenene kadar tekrar edilir.



Şekil 4.11. Uzman Sistemin Detaylı Şeması

4.4.3. Modelin Test Edilmesi

Model oluşturulduktan sonra modelin eğitim aşamasında kullanılmayan veri seti ile test edilmesi gerekmektedir. Bu amaçla genetik algoritmanın tespit ettiği ve en iyi gendeki bilgiler test aşamasındaki gözlemler için kullanılır ve bir model oluşturulur. Oluşturulan bu model daha önce hiç kullanılmayan test aşamasındaki gözlemler için kullanılır.

Test aşamasındaki gözlemler için seçilen değişkenler hesaplanır. Hesaplanan bu değişkenler, eğitilen nihai modele girdi olarak sunulur ve modelin bir sonraki güne ilişkin tahmin ettiği fiyatlar, gerçek fiyatlarla karşılaştırılır. Çalışmanın pratik hayattaki önemini ortaya koyan kısım tam olarak burasıdır.

4.4.3.1. Tahmin Başarı Ölçüleri

Çalışmada bir sonraki güne ilişkin kapanış fiyatlarının ne derecede doğru öngörülebildiği üç farklı açıdan incelenmiştir. Bu farklı açılar aşağıdaki gibidir.

- İstatistiksel Performans Ölçüleri. Bu bölümde modelin tahmin ettiği değerler, gerçek değerlerle karşılaştırılır. İstatistiksel performans ölçülerinden MAE, MAPE ve RMSE değerleri hesaplanmıştır.
- Yön Tahmini. Bu yöntemde ise modelin tahmin ettiği fiyatlar 1 ve 0 dan oluşan yeni bir seriye çevrilir. Bu yeni seride, modelin önceki gün için tahmin ettiği fiyat

bugün için tahmin ettiği fiyattan daha düşükse bu durumda 1 değeri alır. Modelin önceki gün için tahmin ettiği fiyat bugün için tahmin ettiği fiyattan daha yüksekse bu durumda 0 değerini alır. Aynı dönüşüm gerçek fiyat hareketleri için de gerçekleştirilir. Modelin fiyat değişimlerini yüzde kaç oranında doğru tahmin edebildiği hesaplanır.

- Alım Satım Simülasyonu. Bu bölümde ise modelin tahmin ettiği fiyatlar gerçek fiyatlar üzerinden alım satıma tabi tutulur. Böylelikle modelin pratik açıdan ne ölçüde kar getirebildiği ortaya çıkarılmış olur. Literatürde tanıtılan çeşitli alım satım algoritmaları vardır. Algoritmanın yüksek kar getirebilmesi gerçek fiyat hareketlerini veya fiyatları mümkün olduğunca doğru tahmin edebilmesine bağlıdır.

4.4.3.1.(1). İstatistiksel Başarı Ölçüleri

Kullanılan tahmin modelinin gerçek değerlere ne kadar yakın sonuçlar ürettiğini ortaya çıkarmak için bazı analizlerin yapılması gerekmektedir. Sadece bir tek sonuca bakmak suretiyle tahmin modelinin gerçek değerlere yakın değerler üretebildiğini söylemek doğru olmayacaktır. Bu nedenle pratikte model test periodu için çalıştırılır ve elde edilen tahminler gerçek değerlerden çıkarılır ve sonuçlar değerlendirilir.

Y_t nin t günündeki gözlemi ifade ettiği ve F_t nin Y_t nin tahmini değerini ifade ettiğini varsayalım. Bu durumda tahmin hatası $e_t = Y_t - F_t$ olmaktadır. Eğer tahmin edilen fiyat gerçek fiyattan düşükse (yüksekse), hata terimi pozitif (negatif) olacaktır. Bu nedenle hataları olduğu gibi toplamak doğru olmayacaktır. Çünkü toplamda hata terimleri sıfırlanabilir. Bu nedenle, tahmin hataları toplanırken, genellikle ya kareleri alınır ya da mutlak değerleri hesaplanır (Brooks, 2008: 252).

Çalışmanın en önemli amacı hisse senetlerinin bir gün önceden büyük bir doğrulukla tahmin edilebilmesidir. Bu hedefin gerçekleşip gerçekleşmediğini tespit etmek için, modelin tahmin ettiği değerlerle, o gün gerçekleşen hisse senedi kapanış fiyatı bilgilerinin karşılaştırılması gerekmektedir. Başarılı bir tahmin modelinde gerçek fiyatlarla, tahmin edilen fiyatlar arasındaki farkın en az olması beklenir. Literatürde en sık kullanılan istatistiksel tahmin başarı ölçeklerinden dört adedi aşağıdaki gibidir.

4.4.3.1.(1).(a). Ortalama Mutlak Yüzde Hata - Mean Absolute Percentage Error

Ortalama mutlak yüzde hata performansı ölçüsünün formülü aşağıdaki gibidir.

$$MAPE = \frac{100}{n} \sum_{i=1}^n \frac{|TF_i - GF_i|}{GF_i}$$

Gerçek fiyatlarla tahmin edilen fiyatlar arasındaki farkın mutlak değerinin gerçek fiyata bölünmesi ve bu değerın toplanması daha sonra ortalamasının alınması ve yüz ile çarpılması yoluyla hesaplanır.

4.4.3.1.(1).(b). Ortalama Hataların Karesi - Mean Square Error

Gerçek fiyatlarla tahmini fiyatlar arasındaki farkın ortalamasının alınması yoluyla hesaplanır ve formülü aşağıdaki gibidir.

$$MSE = \frac{1}{n} \sum_{i=1}^n (TF_i - GF_i)^2$$

4.4.3.1.(1).(c). Ortalama Hataların Karesi Karekökü - Root Mean Square Error

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (TF_i - GF_i)^2}$$

Ortalama hataların karesi ifadesinin karekökünün alınması yoluyla hesaplanır. Yukarıdaki formülleri aşağıdaki gibi kısa şekilde göstermek mümkündür.

MSE	MAPE	RMSE
$\frac{1}{n} \sum_{i=1}^n e_i^2$	$\frac{1}{n} \sum_{i=1}^n \left \frac{e_i}{GF_i} \right \times 100$	$\sqrt{\frac{1}{n} \sum_{i=1}^n e_i^2}$

4.4.3.1.(2). Yön Tahmini

Çalışmada önerilen modelin performansı, fiyat tahminlerinin eğilim tahminlerine dönüştürülmesi yoluyla daha detaylı bir şekilde incelenmesi mümkündür.

Literatür bölümünde değinildiği gibi sadece hisse senedi fiyatındaki yönün tahmin edildiği çalışmalar da söz konusudur. Bu tür çalışmaların temel aldıkları nokta, bir gün sonraki hisse senedi fiyatının tahminin gerçekleştirilmesinin zorluğudur. Bir gün sonra hisse senedinin alacağı değerin tahmin edilmesi yerine, bir gün sonra hisse senedinin bugünkü değerinden daha düşük veya daha yüksek bir değer alıp almayacağı tahmin edilmeye çalışılmaktadır.

Yön tahminlerinde kullanılan modeller sınıflandırma modelleridir. Bu modellerde çıktı genellikle 1 ve 0 lardan oluşmaktadır ve 1 hisse senedi fiyatının yarın daha yüksek olacağını, 0 değeri ise daha düşük olacağını ifade etmektedir. Bu şekilde ikili bir çıktı değişkeni tahmin edilmeye çalışılmaktadır.

Tahmin edilen fiyatların eğilim tahminlerine çevrilmesi için, literatürdekine uygun bir sınıflandırma yapılacaktır ve tahmin edilen fiyat vektörüne benzer yeni bir vektör oluşturulacaktır. Bu yeni vektör 1 ve 0 lardan oluşmaktadır ve şu şekilde hesaplanmaktadır:

$$tahmin\ edilen\ eğilim(t) = \begin{cases} 1, & \text{eğer } TF_{t+1} > TF_t \\ 0, & \text{eğer } TF_{t+1} < TF_t \end{cases}$$

Formülde yer alan t gününe ilişkin eğilimin hesaplanabilmesi için iki tane tahmini fiyat değerinin bilinmesi gerekmektedir. Bir tanesi o güne ilişkin gerçekleştirilen fiyat tahminidir. Bu fiyat tahmini bir gün önceki veri seti kullanmak suretiyle hesaplanmaktadır. Bir diğer fiyat ise bir sonraki güne ilişkin yapılan tahmin fiyatıdır. Bu tahmin fiyatı bugünkü veriler kullanmak suretiyle hesaplanmaktadır. Bugüne ilişkin tahmin edilmiş fiyatlarla, bir sonraki güne ilişkin tahmin edilen fiyatlar belirlendikten sonra bu iki fiyatın karşılaştırılması gerekmektedir. Bu karşılaştırma işlemi sonucunda eğer bir sonraki gün için tahmin edilen fiyat, bugün için tahmin edilmiş fiyattan daha yüksek çıkarsa, ilgili gündeki eğilime 1 değeri atanmaktadır. Bir sonraki gün için tahmin edilen fiyatın, bugün için tahmin edilmiş fiyattan daha küçük olması durumunda ise, ilgili gündeki eğilime 0 değeri atanmaktadır.

Burada dikkat edilecek konu eğilimin hesaplanmasında kullanılan *tahmin edilen eğilim* vektörünün büyüklüğü her zaman için,

tahmin edilen fiyat vektöründen bir tane daha az gözlem içereceğidir. Çünkü eğimin hesaplanması iki adet fiyatın bilinmesine bağlıdır. Birgün önceki fiyat bilinmeyeceğinden eğilim ancak bir gün sonraki tahminlerden itibaren hesaplanmaya başlayacaktır.

Tahmin edilen eğilim hesaplandıktan sonra aynı süreç bir kez daha, bu sefer gerçek fiyatlar kullanmak suretiyle yenilenmektedir. Bu işlemin amacı ise gerçek fiyatlardaki eğilimin tespit edilmesidir. Bu işlem sonucunda da gerçek eğilim adında yeni bir vektör elde edilecektir. Elde edilecek bu yeni vektör de gerçek fiyat vektöründen bir tane daha az gözlemi içerecektir.

İkili sınıflandırma tabloları tahmin edilen eğilim ile gerçek eğilimi karşılaştırmak için kullanılmaktadır ve Tablo 4.1 'deki gibidir.

Tablo 4.1. İkili Sınıflandırma Tablosu

		Gerçek fiyatlar	
		Artı	Eksi
Tahmini fiyatlar	Artı	TP	FP
	Eksi	FN	TN

Tablonun sütunlarında gerçek fiyatlar yer almaktadır. Satırlarında ise tahmini fiyatlar yer almaktadır.

Tabloda dört adet farklı değer yer almaktadır. Bu değerler şu şekildedir:

- **TP. Gerçek Pozitif.** Bir sonraki gün gerçekleşen fiyat, bugün gerçekleşen fiyattan daha büyüktür. Aynı şekilde bir sonraki gün için yapılan fiyat tahmini, bugün için yapılmış fiyat tahmininden daha büyüktür. Başka bir ifadeyle tahmini ve gerçekleşen eğilim vektörleri 1 değerini almaktadır.
- **TN. Gerçek Negatif.** Tahmin edilen ve gerçekleşen eğilim vektörleri 0 değerini almaktadır.
- **FP. Yanlış Pozitif.** Hisse senedi fiyatının bir sonraki gün azalması buna karşılık modelin fiyat yükselmesini tahmin ettiği durumda gerçekleşen durumdur. Fiyat bir sonraki gün düşmektedir. Buna karşılık model fiyat artışı tahmin etmektedir.
- **FN. Yanlış Negatif.** Bir sonraki gün fiyat yükseldiği halde modelin fiyatı daha düşük tahmin ettiği durumdur. Fiyat bir sonraki gün yükselmektedir. Buna karşılık model fiyat azalması tahmin etmektedir.

Modelin fiyat azalış ve artışlarını başka bir ifade ile eğimi ne kadar doğru tahmin edebildiği aşağıdaki formül yardımıyla hesaplanmaktadır.

$$\text{Doğru oranı} = \frac{TP + TN}{TP + TN + FP + FN}$$

Formülde hesaplanan doğru oranı ifadesi sıfır ile bir arasında değer almaktadır ve bu oran bire ne kadar yakınsa, modelin fiyat eğilimlerini o kadar başarılı bir şekilde öngörebildiği anlaşılmaktadır.

Denklemden payda yer alan ifade toplam doğru tahmin sayısını belirtmektedir. s vektöründe yer alan değerler ile t vektöründe yer alan değerler karşılaştırılır. Doğru bir şekilde gerçekleştirilen tahminler toplanır. Doğru tahmin, tahmin edilen serideki eğimlerle, gerçek eğimlerin birbirlerine eşit olması olarak tanımlanmaktadır. Örneğin bir gün sonraki tahmin edilen fiyat, bir gün önceden bugün için tahmin edilen fiyattan daha yüksekse ve aynı günkü gözlem için, bir gün sonraki gerçek fiyat, bir gün önceki fiyattan daha yüksekse, bu durumda doğru tahmin sayısı bir artırılır. Aynı durum düşme eğilimleri için de hesaplanır. Kısacası t ve s vektöründe aynı yerdeki aynı elemanların

sayısı toplanır ve toplam test veri setine bölünür. Böylelikle ne kadar doğru tahmin gerçekleştirildiği belirlenmiş olur.

4.4.3.1.(3). Alım Satım Simulasyonu

Çalışmada önerilen melez yöntemin performansını değerlendirmek için basit bir alım satım stratejisi kullanılmıştır. Söz konusu strateji temel bir alım satım kuralına dayanmaktadır. Fiyatı düşüken hisse senedi satın alındığında ve daha sonra fiyatı yükseldiğinde satıldığında, bu işlem neticesinde kâr oluşmuş olur. Çünkü düşük fiyattan alınmaktadır ve daha sonra yüksek fiyattan satılmaktadır.

Çalışmada önerilen tahmin metodunun finansal performansı da bu şekilde değerlendirilecektir. İlk olarak fiyatın bir sonraki güne göre daha yüksek tahmin edildiği günler belirlenecektir. Bu günlerde alım yapılacak ve bir sonraki gündeki fiyattan satış yapılacaktır. Sonuçta elde edilecek getiri oranı hesaplanmış olacaktır.

$$getiri = \frac{f_{t+1} - f_t}{f_t}$$

Yukarıdaki formülde f_t , t zamanındaki fiyatı temsil etmektedir. f_{t+1} ise $t + 1$ ındaki fiyatı temsil etmektedir. Yukarıdaki formül ile birlikte gerçek fiyatlarla alım satım işlemi sonucu ortaya çıkan getiri hesaplanmış olur.

Aşağıda sahte kodu verilen alım satım algoritması Özçalıcı ve Ayrıçay (2013) çalışması baz alınmak suretiyle bu çalışma için özel olarak geliştirilmiştir (Şekil 4.12). Alım satım simulasyonu basit alım satım mantığına dayanmaktadır. Simulasyonda yarın için tahmin edilen fiyatın bugün için tahmin edilmiş fiyattan daha büyük olması durumunda, hisse senedine yatırım yapılmaktadır ve bir sonraki gün satış işlemi gerçekleştirilmektedir. Söz konusu işlemde elde edilecek yüzde getiri hesaplanmaktadır ve bir toplama atanmaktadır. Her yeni alım satım işlemi sonucunda elde edilecek getiri söz konusu değişkene eklenecektir.

```
function getiri = alim_satim_algoritmasi ( gercek_fiyatlar, tahmini_fiyatlar )

getiri = 0 % getiri değişkenine başlangıç değeri atanır.

for test süresinin her günü için
    if yarın için tahmin edilen fiyat bugünkü tahmin edilmiş fiyattan büyükse
        gercek_fiyat vektörü ile satın alma işlemini gerçekleştir.
        Elde edilen getiriyi getiri isimli değişkene ekle.
    end
end
end
end
```

Şekil 4.12. Alım Satım Algoritmasının Sahte Kodu

4.4.3.1.(4). Yön Tahmini ve Alım Satım Simülasyonu Arasındaki İlişki

Yukarıda yön tahmini performansı ve alım satım simülasyonu detaylı bir şekilde açıklanmıştır.

Yön tahmini ile bu çalışmada kullanılan alım satım algoritmasının performansı birbiri ile yakından ilgilidir. Modelin getiri performansı, modelin fiyat eğilimlerini ne kadar başarılı bir şekilde ölçtüğüne bağlıdır. Model fiyat artış ve azalışlarını, gerçek fiyat artış ve azalışlarına ne kadar yakın tahmin ederse, alım satım algoritması da o kadar yüksek bir getiri oranı ortaya çıkartacaktır.

Gerçek fiyat hareketleri ile tahmin edilen fiyat hareketleri arasındaki farklılıklar, algoritmanın zarar ortaya çıkarmasına veya olası bir karın engellenmesine neden olacaktır.

Gerçek fiyat hareketleri ve tahmin edilen fiyat hareketlerinin karşılaştırıldığı yukarıdaki tablodan (TP,TN,FP,FN) hareketle finansal açıdan şu yorumların yapılması mümkündür. FP bölümünde zarar oluşmaktadır. Çünkü fiyat gerçekte düşerken, model fiyat artışı tahmin etmektedir. Bu durumda alım satım yapılması zararın oluşmasına neden olmaktadır. FN bölümünde ise olası getiriler engellenmektedir. Bu bölümde gerçekte fiyat yükselirken, model fiyat azalması şeklinde tahminde bulunmaktadır. Model fiyat artışı tahmin etseydi ve alım satım gerçekleşseydi kar elde edilecekti. Fakat bu kardan mahrum olma durumu söz konusudur. TP kar oluşumuna neden olmaktadır. Bu bölümde gerçekte fiyat yükselirken model de buna paralel olarak fiyat artışı tahmin etmektedir. Böyle bir durumda alım satım yapılması karın elde edilmesine olanak sağlayacaktır. TN zararların önlenmesine neden olmaktadır. Bu bölümde gerçekte fiyat azalırken, model de buna bağlı olarak fiyat azalışı tahmin etmektedir. Buna uygun pozisyon alınırsa olası bir zarar engellenmiş olur (Atsalakis vd., 2011) .

4.5. Uygulama

Çalışmada BIST 30 endeksine dahil olan firmaların hisse senedi fiyatları önceden tahmin edilmeye çalışılmıştır. Çalışmada kullanılan bilgisayarın fiziksel özellikleri şu şekildedir:

- **İşletim Sistemi:** Windows 7 Ultimate
- **İşlemci:** Intel(R) Core(TM) i7-2600 CPU @3.4GHz
- **RAM:** 8 GB
- **Sistem Türü:** 64 bit İşletim Sistemi
- **Matlab Versiyonu:** 8.1.0.604 (R2013a)

4.5.1. Veri Seti ve Değişkenler

4.5.1.1. Veri Seti

Çalışmada 2012 yılında BIST 30 endeksine dahil olan firmaların hisse senetlerine ilişkin veriler kullanılmıştır. Çalışmada sadece bir adet hisse senedi kullanılmamıştır. Bunun yerine BIST30 endeksine dahil olan 30 adet hisse senedi kullanılmıştır. Bir adet hisse senedi üzerinde önerilen modelin başarılı (veya başarısız) olması tesadüfi etkenler neticesinde oluşmuş olabilir. Başka bir ifade ile, modelin bir adet hisse senedi üzerinde başarılı olması sonucun genelleştirilmesini sağlamaz. Modelin başarısının

genelleştirilebilmesi için farklı endüstrilerdeki, farklı özelliklere sahip hisse senetleri üzerinde de başarılı sonuçlar vermesi gerekmektedir. 30 adet farklı hisse senedi üzerinde modelin ne kadar iyi performans sergilediğinin hesaplanması, modelin dayanıklı (robust) olduğunun bir göstergesi niteliğinde olacaktır.

BIST30 endeksi, Ulusal Pazar’da işlem gören şirketlerle, Kurumsal Ürünler Pazarı’nda işlem gören gayrimenkul yatırım ortaklıkları ve girişim sermayesi yatırım ortaklıkları arasından seçilen 30 paydan oluşur. Değerleme dönemi sonu itibarıyla Borsa İstanbul’da en az 60 gün süreyle işlem görmesi gerekmektedir. BIST30 endeksi için piyasa değeri ve günlük ortalama işlem hacmi yüksek olan senetler seçilmektedir. Günlük işlem hacminin yüksek olması hisse senedi fiyat tahminindeki başarı oranını da yükselteceği tahmin edilmektedir. Bu nedenle BIST30 endeksi seçilmiştir.

BIST endeksleri farklı zaman dilimlerinde farklı firmaları kapsamaktadır. 2012 yılı ilk çeyreğinde BIST 30 endeksine dahil olan firmalar bu çalışmada göz önünde bulundurulmuştur. 15 yıldan fazla süreyi kapsayan veri seti elde edilmiştir. Firmalara ait olan açılış fiyatı, en yüksek fiyat, en düşük fiyat, kapanış fiyatı ve işlem hacmi verileri, BIST satış ve pazarlama müdürlüğünden temin edilmiştir. Tablo 4.2 ‘de, çalışmada kullanılan 30 adet hisse senedinin ismi ve kısaltmaları yer almaktadır.

2012 yılı ilk çeyreğinde BIST 30 endeksine dahil edilen firmalara ait ulaşılabilen bütün fiyat ve hacim bilgileri kullanılmıştır. Hisse senetlerinin borsaya kote olma zamanları birbirlerinden farklılık göstermektedir. Bu nedenle her bir hisse senedi için farklı sayıda bilgiye ulaşılmıştır. Aşağıdaki tabloda, hisse senetlerine ilişkin ulaşılabilen gün sayısı da gözlemlenebilmektedir.

Borsa İstanbul ‘da tipik bir iş gününde iki farklı seans yapılmaktadır. Her bir gün için, resmi tatillerin olduğu zamanlar hariç, iki adet açılış, kapanış, en düşük, en yüksek ve işlem hacmi verisi bulunmaktadır. Her seans ayrı bir gözlem niteliğinde değerlendirilmiş ve her seansın kapanış fiyatı ayrı ayrı tahmin edilmeye çalışılmıştır.

Tablo 4.2. Çalışmada Kullanılan Hisse Senetlerinin Kodları ve İsimleri

Sıra No.	Hisse Senedi Kodları	Hisse Senedi İsimleri	Eğitim için kullanılan gözlem sayısı	Eğitim Başlangıç
01	AKBNK	Akbank A.Ş.	6400	01/07/1999
02	AKSA	AKSA Akrilik Kimya Sanayi A.Ş.	6400	15/06/1999
03	ARCLK	Arçelik A.Ş.	6400	02/07/1999
04	ASYAB	Asya Katılım Bankası A.Ş.	2400	23/07/2007
05	BIMAS	Birleşik Mağazalar A.Ş.	3200	20/12/2005
06	DOHOL	Doğan Yayın Holding A.Ş.	6400	15/07/1999
07	EKGYO	Emlak Konut Gayrimenkul Yatırım Ortaklığı A.Ş.	692	27/12/2010
08	ENKAI	Enka İnşaat ve Sanayi A.Ş.	4800	27/09/2002
09	EREGL	Ereğli Demir ve Çelik Fabrikaları T.A.Ş.	7200	26/03/1998
10	GARAN	T. Garanti Bankası A.Ş.	6400	02/07/1999
11	HALKB	Türkiye Halk Bankası A.Ş.	2400	23/07/2007
12	IHLAS	İhlas Holding A.Ş.	6400	04/12/1998
13	ISCTR	T. İş Bankası A.Ş.	6400	16/09/1999
14	KCHOL	Koç Holding A.Ş.	4000	05/08/2004
15	KOZAL	Koza Altın İşletmeleri A.Ş.	800	04/10/2010
16	KRDMD	Kardemir Karabük Demir Çelik Sanayi ve Ticaret A.Ş.	6400	13/07/1999
17	MGROS	Migros Türk T.A.Ş.	5600	15/09/1999
18	PETKM	Petkim PetroKimya Holding A.Ş.	6400	18/06/1999

19	SAHOL	Hacı Ömer Sabancı Holding A.Ş.	7200	28/07/1998
20	SISE	T. Şişe ve Cam Fabrikaları A.Ş.	7200	08/06/1998
21	SNGYO	Sinpaş Gayrimenkul Yatırım Ortaklığı A.Ş.	2400	23/07/2007
22	TCELL	Turkcell İletişim Hizmetleri A.Ş.	5600	09/02/2001
23	THYAO	Türk Hava Yolları A.O.	7200	13/03/1998
24	TKFEN	Tekfen Holding	1600	02/03/2009
25	TOASO	Tofaş Türk Otomobil Fabrikası A.Ş.	6400	01/07/1999
26	TTKOM	Türk Telekomünikasyon A.Ş.	1600	02/03/2009
27	TTRAK	Türk Traktör ve Ziraat Makineleri A.Ş.	3200	20/12/2005
28	TUPRS	Türkiye Petrol Rafineleri A.Ş.	6400	03/06/1999
29	VAKBN	Türkiye Vakıflar Bankası T.A.O.	3200	26/04/2006
30	YKBNK	Yapı ve Kredi Bankası A.Ş.	6400	18/06/1999

- Eğitim süresinin bitiş tarihi her bir hisse senedi için 08/05/2012'dir.
- Test süresinin başlangıç ve bitiş tarihleri her bir hisse senedi için sırasıyla 09/05/2012 – 31/08/2012'dir.
- EKGYO kodlu senet için yeterli sayıda gözlem bulunmadığından 640/160 kuralı geçerli olmamıştır.


Her bir hisse senedine ilişkin kullanılan tarihi bilgiler şu şekilde özetlenebilir:

- Eğitim Süresi İçin. Eğitim setinde kullanılan tarihi bilgiler yukarıda da bahsedildiği gibi her bir firmanın borsada işlem görme zamanı farklı olduğu için farklılık arz etmektedir. Hisse senetleri modelleri için toplam veri sayısı ve verilerin başlangıç günleri yukarıdaki tabloda yer almaktadır. Eğitim süresi her bir hisse senedi için 08/05/2012 tarihinde sona ermektedir. En az bilgi EKGYO isimli hisse senedinde bulunmaktadır. 692 güne ilişkin bilgiler hesaplanabilmektedir.
- Test Süresi için. Test süresi her bir hisse senedi için aynı olmaktadır. Test süresi 09/05/2012 tarihinde başlamaktadır ve 31/08/2012 tarihinde sona ermektedir. Toplamda 160 adet seans test amacıyla bir kenara ayrılmış ve eğitim sürecinde kullanılmamıştır.

Çalışmada test süresi 160 gün olarak belirlenmiştir. Söz konusu test süresini tahmin edebilmek için geçmişe yönelik 640 adet eğitim verisi kullanılmıştır. Literatürde genellikle toplam veri setinin %80'ini eğitim için, %20'sini test için kullanılmıştır. Bu çalışmada da bu kurala uyulmuştur.

Toplam veri seti belirlenirken, ilk olarak mevcut bilgiler dahilinde en güncel 160 gözlem test amacıyla bir kenara ayrılmıştır. Bütün veri seti dikkate alınmış ve yukarıda açıklanan 53 adet değişken hesaplanmıştır. Bazı değişkenlerin hesaplanabilmesi için belirli sayıda gözleme ihtiyaç vardır. Örneğin beş günlük hareketli ortalama hesaplanacağı zaman veri setinde beş güne ilişkin kapanış fiyatlarının var olması gerekmektedir. Başka bir ifade ile ilk 4 güne ilişkin kapanış fiyatının beş günlük hareketli ortalaması hesaplanamayacaktır. 53 adet değişken göz önünde bulundurulduğunda ilk 33 adet gözlem için değerlerin her bir değişken için hesaplanamayacağı ortaya çıkmıştır. Bu nedenle 33 adet gözlem çıkartılmış ve hesaplanan veri setine ulaşılmıştır.

Uygunluk fonksiyonunda birden fazla veri setindeki performans göz önünde bulundurulacaktır. Bu nedenle eğitim amacı ile kullanılacak veri setinde 800 ve katları şeklinde gözlem sayısına ihtiyaç duyulmaktadır. Hesaplanan veri setinde eğitim amacı ile kullanılacak veri seti 800 ve katlarına indirgindikten sonra kullanılabilir veri setine ulaşılmıştır. Şekil 4.13 'den de görülebileceği üzere toplanan veri seti ile kullanılabilir veri seti arasında bir farklılık söz konusudur. Bu farklılık, kullanılabilir veri setinin diğer veri setlerinden daha küçük hacme sahip olmasıdır.



Şekil 4.13. Çalışmada Kullanılan Veri Setinin Elde Edilmesi

Çalışmada tahmin edilecek değişken hisse senetlerinin kapanış fiyatı bilgisidir. Her bir hisse senedinin kapanış fiyatına ilişkin tanımlayıcı istatistikler aşağıdaki Tablo 4.3 'deki gibidir. Tabloda her bir hisse senedine ait kapanış fiyatının en küçük değeri, kapanış fiyatının en yüksek değeri, kapanış fiyatının ortalama değeri, kapanış fiyatının standart sapması yer almaktadır. Çalışmada tahmin sonuçları aynı zamanda eğilim tahmini için de kullanılacaktır. Fiyatın arttığı ve azaldığı gün sayılarının da belirlenmesi gerekmektedir. Tabloda aynı zamanda eğitim dönemi boyunca kapanış fiyatın bir önceki seansa göre artmış olduğu toplam seans sayısı ve eğitim dönemi boyunca kapanış fiyatın bir önceki seansa göre azaldığı toplam seans sayısı yer almaktadır. Tabloda istisnasız her hisse senedi için fiyatın azaldığı seans sayısının fiyatın arttığı seans sayısından daha fazla olduğu göze çarpmaktadır.

Tablo 4.3. Kapanış Fiyatlarının Tanımlayıcı İstatistikleri

Sıra No.	Hisse Senedi Kodları	En Küçük	En Büyük	Ortalama	Standart Sapma	Fiyat Artışı	Fiyat Azalışı
01	AKBNK	2,35	18,75	6,961	2,317	2644	3755
02	AKSA	1,18	45	9,89	7,407	2460	3939
03	ARCLK	1,39	54	10,131	7,313	2594	3805
04	ASYAB	0,95	11,9	3,824	2,863	996	1403
05	BIMAS	19,5	138	62,158	22,91	1301	1898
06	DOHOL	0,45	26,75	3,372	3,921	2536	3863
07	EKGYO	1,88	3,08	2,445	0,302	310	381
08	ENKAI	3,6	115	18,851	17,057	1920	2879
09	EREGL	2,09	51,5	12,437	10,022	2962	4237
10	GARAN	1,175	12,25	5,079	2,206	2747	3652
11	HALKB	3,2	16,25	9,522	2,995	1082	1317
12	IHLAS	0,11	61	4,133	8,787	2214	4185
13	ISCTR	1,4	36	7,414	4,494	2626	3773
14	KCHOL	0,7	9,35	5,648	1,615	1729	2270
15	KOZAL	16,7	38	24,09	4,97	379	420
16	KRDMD	0,3	4,65	1,034	0,634	2290	4109
17	MGROS	0,102	100	27,66	27,797	2161	3438
18	PETKM	1,25	35,5	7,025	4,095	2449	3950
19	SAHOL	2,29	38	6,454	3,947	2936	4263
20	SISE	0,105	23	3,617	2,147	2991	4208

21	SNGYO	0,95	8,5	3,106	1,957	975	1424
22	TCELL	3,45	20,25	9,519	2,623	2261	3338
23	THYAO	2,01	65	8,972	6,842	2915	4284
24	TKFEN	2,44	7,62	5,262	1,026	729	870
25	TOASO	1	13,25	4,977	2,535	2647	3752
26	TTKOM	3,78	9,38	6,131	1,385	691	908
27	TTRAK	3,48	40,9	16,515	9,789	1314	1885
28	TUPRS	6,3	82	24,748	11,445	2560	3839
29	VAKBN	1,02	8,5	3,611	1,44	1399	1800
30	YKBNK	0,35	20,5	4,131	2,863	2671	3728

4.5.1.2. Tahminde Kullanılacak Değişkenler

Bu çalışmada, tahmin sürecinde kullanıldığında en iyi sonuçları vermesi beklenen değişkenler (optimal nöron sayısı ile eş zamanlı olarak) genetik algoritmalar tarafından belirlenecektir. Bu nedenle başlangıçta mümkün olduğunca çok sayıda teknik analiz göstergesi bir araya getirilmeye çalışılmıştır.

Hisse senedi fiyatını tahmin modelinde kullanılmak için belirlenen aday değişkenler Tablo 4.4 ‘deki gibidir. Tabloda altı adet fiyat değişkeni, kapanış fiyatına ait 6 adet fiyat ve hacim bilgisi ve hesaplanabilen 47 adet teknik gösterge olmak üzere toplam 53 adet değişken görülebilmektedir.

Tablo 4.4. Çalışmada Kullanılan Değişkenler

Sıra No	Değişken İsmi	Sıra No	Değişken İsmi
01	Bugünkü kapanış – Bir gün önceki kapanış	28	Momentum en yüksek fiyat
02	Bir gün önceki kapanış	29	Momentum en düşük fiyat
03	Bir gün önceki en yüksek fiyat	30	Momentum kapanış fiyatı
04	Bir gün önceki en düşük fiyat	31	Chaikin Dalgalanma
05	Bir gün önceki açılış fiyatı	32	Hızlandırılmış stochastik %K
06	Bir gün önceki işlem hacmi	33	Hızlandırılmış stochastik %D
07	Kapanış fiyatının 5 günlük basit hareketli ortalaması	34	Yavaşlatılmış stochastik %K
08	Kapanış fiyatının 6 günlük basit hareketli ortalaması	35	Yavaşlatılmış stochastik %D
09	Kapanış fiyatının 10 günlük basit hareketli ortalaması	36	William’s %R
10	Kapanış fiyatının 20 günlük basit hareketli ortalaması	37	Negatif hacim indeksi
11	Kapanış fiyatının 5 günlük üssel hareketli ortalaması	38	Pozitif hacim indeksi
12	Kapanış fiyatının 6 günlük üssel hareketli ortalaması	39	Görelî güç indeksi
13	Kapanış fiyatının 10 günlük üssel hareketli ortalaması	40	Toplama/Dağıtım Çizgisi
14	Kapanış fiyatının 20 günlük üssel hareketli ortalaması	41	Bollinger orta band
15	Kapanış fiyatının 5 günlük üçgensel hareketli ortalaması	42	Bollinger üst band
16	Kapanış fiyatının 6 günlük üçgensel hareketli ortalaması	43	Bollinger alt band
17	Kapanış fiyatının 10 günlük üçgensel hareketli ortalaması	44	En yüksek yüksek değer

18	Kapanış fiyatının 20 günlük üçgensel hareketli ortalaması	45	En düşük düşük değer
19	Toplama/Dağıtım Salınımı	46	Medyan Fiyat
20	Chaikin Salınımı	47	Denge işlem hacmi
21	Hareketli Ortalamaların Birleşmesi	48	Fiyat değişim oranı
22	Ayrılması göstergesi		
22	21'in 9 günlük hareketli ortalaması	49	Fiyat hacim eğilimi
23	Açılış fiyatı ivme	50	Tipik fiyat
24	En yüksek fiyat ivme	51	Hacim değişim oranı
25	En düşük fiyat ivme	52	Ağırlıklı kapanış fiyatı
26	Kapanış fiyatı ivme	53	William's Toplama Dağıtım
27	Momentum açılış fiyatı		

4.5.2. Alternatif Model

Performans karşılaştırma amacıyla geliştirilen model, bir tane gizli katmanı olan ileri beslemeli yapay sinir ağından oluşmaktadır. Bu modelde ara katmanda bir adet gizli katman bulunmaktadır ve gizli katmanda 10 adet nöron kullanılmıştır. Alternatif modelde değişken seçimi gerçekleştirilmesi söz konusu değildir. Bu nedenle hesaplanabilen 53 adet değişken bu modelde girdi olarak kullanılmıştır.

5. BULGULAR

Alternatif model ile optimal yapay sinir ağı modelin eğitim ve test aşamasında aynı gözlemler kullanılmıştır. Eğitim için 640 adet gözlem ve test için 160 adet gözlem her iki model için de aynıdır. Her iki modelde arakatmanda 10 adet nöron bulunan tek katmanlı yapay sinir ağı mimarisi kullanılmıştır. İki model arasındaki fark, optimal yapay sinir ağı modelinde ara katmanda bulunması gereken nöron sayısı ve kullanılacak değişkenlerin seçiminin genetik algoritmalar ile optimize edilmiş olmasıdır.

Oluşturulan modellerin sonuçları üç farklı açıdan değerlendirmeye tabi tutulmuştur. İlk olarak istatistiksel performans ölçüleri hesaplanmıştır. Daha sonra eğitim sınıflandırma tahminlerinin ne kadar doğru yapıldığı hesaplanmış ve son olarak da alım-satım algoritması kullanılmak suretiyle erişilen kar miktarı her iki model için ayrı ayrı hesaplanmıştır.

5.1. Optimal Nöron Sayıları ve Değişkenler

Çalışmada ilk olarak her bir hisse senedi tahmin performansını en yüksek yapan gen elemanlarına yer verilmiştir. Genetik algoritmalar yardımıyla her bir hisse senedinin uygunluk fonksiyonunu minimum yapan ara katmandaki nöron sayısı ve kullanılması gereken değişken sayısı Tablo 5.1 'deki gibidir.

Aşağıdaki tabloda her bir hisse senedi için genetik algoritmalarla belirlenen nöron sayıları ve optimal değişken sayıları yer almaktadır. Buna ek olarak optimal değişken indeksleri de yer almaktadır.

Tablo 5.1. Optimal Nöron, Değişken Sayısı ve İndisleri


S No.	H.S. Kod	Opt. Nöron Sayısı	Opt. Değ. Sayısı	Optimal Değişkenlerin İndeksleri
01	AKBNK	2	19	3 4 8 9 10 11 19 20 23 24 28 29 32 39 42 44 48 50 51
02	AKSA	2	19	2 7 9 11 13 15 16 18 26 27 30 31 32 33 35 37 39 50 52
03	ARCLK	2	22	4 7 8 10 12 13 14 15 16 17 19 21 28 29 31 32 36 39 41 44 46 50
04	ASYAB	4	18	3 4 9 10 11 16 19 22 23 24 28 29 36 39 41 42 44 51
05	BIMAS	2	22	1 4 10 11 13 16 17 21 22 24 25 26 28 29 31 33 36 37 39 41 44 48
06	DOHOL	2	22	1 3 7 9 12 13 14 15 16 17 18 23 24 26 27 30 33 35 39 50 51 52
07	EKGYO	2	18	1 2 3 4 6 7 11 16 17 26 27 34 36 38 40 41 50 51
08	ENKAI	12	22	2 3 4 8 15 16 19 25 26 27 28 29 31 32 36 39 41 42 43 45 50 51
09	EREGL	2	26	4 5 6 7 11 17 18 20 21 22 23 24 25 27 29 30 31 32 34 35 36 39 41 46 48 53
10	GARAN	2	24	1 4 5 6 7 9 15 16 17 23 25 26 29 31 32 35 39 41 42 43 44 50 51 52
11	HALKB	3	22	2 4 5 7 8 9 10 12 13 14 17 18 22 23 26 27 28 30 34 35 36 46
12	IHLAS	2	14	13 15 16 25 26 28 32 35 37 39 43 50 51 53
13	ISCTR	2	21	2 4 7 8 10 12 13 15 16 20 23 24 33 34 35 36 42 43 48 51 53
14	KCHOL	2	16	1 5 10 14 19 25 26 28 30 31 35 36 37 39 42 46
15	KOZAL	17	26	2 3 5 7 8 12 15 19 21 24 25 26 27 29 31 32 33 34 35 40 41 42 46 48 51 53
16	KRDMD	21	29	4 6 8 11 13 14 15 16 18 22 23 24 26 27 28 30 31 33 35 36 37 38 39 41 44 45 51 52 53

17	MGROS	3	29	1 3 6 9 11 15 16 18 20 21 22 24 25 29 32 33 34 36 38 39 40 41 42 43 44 45 46 48 53
18	PETKM	2	25	1 4 5 6 7 11 12 13 15 16 18 20 23 28 29 30 31 33 36 39 42 46 48 51 52
19	SAHOL	8	23	1 2 9 10 12 14 15 16 17 18 21 27 31 33 35 36 41 43 44 45 48 50 51
20	SISE	3	18	1 2 5 7 14 15 16 17 18 21 22 27 29 30 32 36 41 42
21	SNGYO	8	24	1 4 5 9 12 14 15 16 18 20 23 31 32 33 34 36 39 41 42 44 46 50 51 52
22	TCELL	7	27	1 2 5 8 9 10 12 13 14 15 16 17 18 19 23 25 28 30 33 34 36 39 41 43 46 50 51
23	THYAO	2	20	1 4 5 11 13 15 16 17 21 27 28 29 31 35 41 45 46 50 52 53
24	TKFEN	2	15	4 7 9 13 16 17 29 30 32 39 43 44 46 50 51
25	TOASO	2	24	1 4 6 7 8 9 14 16 17 18 19 22 24 27 28 29 32 33 35 36 43 44 45 51
26	TTKOM	9	23	1 2 4 5 6 8 9 10 14 16 18 19 22 25 28 30 36 42 43 44 48 50 51
27	TTRAK	2	22	1 3 10 13 15 16 17 18 21 22 24 25 26 35 36 39 41 42 43 46 48 52
28	TUPRS	2	25	1 3 8 10 11 15 16 17 22 25 26 28 29 30 33 35 36 39 42 43 44 45 51 52 53
29	VAKBN	2	20	1 2 3 4 7 11 12 15 16 19 23 25 29 30 36 41 43 46 50 53
30	YKBNK	2	22	3 5 8 9 10 12 15 17 18 27 29 31 32 33 36 41 43 44 45 46 52 53

Tablodan açıkça görüldüğü üzere her bir hisse senedi için minimum uygunluk değerinin hesaplanmasına olanak sağlayan ara katmandaki nöron sayısı ve optimal değişken sayısı birbirlerinden oldukça farklıdır. Belirli bir standart söz konusu değildir.

Ara katmandaki nöron sayısı [2-21] arasında değişirken, optimal değişken sayısı [14-29] arasında değişmektedir.


Optimal Nöron sayılarının artan düzeyde sıralanması sonucu Şekil 5.1 elde edilmiştir.



Şekil 5.1. Optimal Nöron Sayıları

Birçok hisse senedinde kullanılacak ysa modeli için iki adet nöron yeterli görülse de KRDMMD isimli hisse senedi için 21 adet nöronun optimal olarak belirlenmiştir.

Optimal değişkenlerin sayısı ise Şekil 5.2’de gösterilmiştir. İhlas isimli hisse senedi için 14 adet değişkenin optimal olduğu belirlenmiştir. KRDMMD, TCELL ve MGROS için ise 29 adet değişken optimal olarak belirlenmiştir.



Şekil 5.2. Optimal Değişken Sayısı


Söz konusu bilgilere farklı açıdan bakmak da mümkündür. Tablo 5.2 ‘de her bir değişkenin kaç adet hisse senedinde kullanıldığı bilgisi yer almaktadır.

Tablo 5.2. Değişkenlerin Kullanıldığı Hisse Senetleri

Sıra No	Değişken İsmi	Değişkenin kullanıldığı hisse sayısı	Hisse senedi indeksleri
01	Bugünkü kapanış – Bir gün önceki kapanış	17	'5 6 7 10 14 17 18 19 20 21 22 23 25 26 27 28 29'
02	Bir gün önceki kapanış	11	'2 7 8 11 13 15 19 20 22 26 29'
03	Bir gün önceki en yüksek fiyat	11	'1 4 6 7 8 15 17 27 28 29 30'
04	Bir gün önceki en düşük fiyat	18	'1 3 4 5 7 8 9 10 11 13 16 18 21 23 24 25 26 29'
05	Bir gün önceki açılış fiyatı	12	'9 10 11 14 15 18 20 21 22 23 26 30'
06	Bir gün önceki işlem hacmi	8	'7 9 10 16 17 18 25 26'
07	Kapanış fiyatının 5 günlük basit hareketli ortalaması	14	'2 3 6 7 9 10 11 13 15 18 20 24 25 29'
08	Kapanış fiyatının 6 günlük basit hareketli ortalaması	12	'1 3 8 11 13 15 16 22 25 26 28 30'
09	Kapanış fiyatının 10 günlük basit hareketli ortalaması	14	'1 2 4 6 10 11 17 19 21 22 24 25 26 30'
10	Kapanış fiyatının 20 günlük basit hareketli ortalaması	13	'1 3 4 5 11 13 14 19 22 26 27 28 30'
11	Kapanış fiyatının 5 günlük üssel hareketli ortalaması	12	'1 2 4 5 7 9 16 17 18 23 28 29'
12	Kapanış fiyatının 6 günlük üssel hareketli ortalaması	11	'3 6 11 13 15 18 19 21 22 29 30'
13	Kapanış fiyatının 10 günlük üssel hareketli ortalaması	13	'2 3 5 6 11 12 13 16 18 22 23 24 27'
14	Kapanış fiyatının 20 günlük üssel hareketli ortalaması	11	'3 6 11 14 16 19 20 21 22 25 26'
15	Kapanış fiyatının 5 günlük üçgensel hareketli ortalaması	20	'2 3 6 8 10 12 13 15 16 17 18 19 20 21 22 23 27 28 29 30'
16	Kapanış fiyatının 6 günlük üçgensel hareketli ortalaması	24	'2 3 4 5 6 7 8 10 12 13 16 17 18 19 20 21 22 23 24 25 26 27 28 29'
17	Kapanış fiyatının 10 günlük üçgensel hareketli ortalaması	16	'3 5 6 7 9 10 11 19 20 22 23 24 25 27 28 30'
18	Kapanış fiyatının 20 günlük üçgensel hareketli ortalaması	15	'2 6 9 11 16 17 18 19 20 21 22 25 26 27 30'
19	Toplama/Dağıtım Salınımı	10	'1 3 4 8 14 15 22 25 26 29'
20	Chaikin Salınımı	6	'1 9 13 17 18 21'
21	Hareketli Ortalamaların Birleşmesi Ayrılması göstergesi	9	'3 5 9 15 17 19 20 23 27'
22	21'in 9 günlük hareketli ortalaması	11	'4 5 9 11 16 17 20 25 26 27 28'
23	Açılış fiyatı ivme	12	'1 4 6 9 10 11 13 16 18 21 22 29'
24	En yüksek fiyat ivme	11	'1 4 5 6 9 13 15 16 17 25 27'
25	En düşük fiyat ivme	13	'5 8 9 10 12 14 15 17 22 26 27 28 29'
26	Kapanış fiyatı ivme	13	'2 5 6 7 8 10 11 12 14 15 16 27 28'
27	Momentum açılış fiyatı	13	'2 6 7 8 9 11 15 16 19 20 23 25 30'
28	Momentum en yüksek fiyat	15	'1 3 4 5 8 11 12 14 16 18 22 23 25 26 28'
29	Momentum en düşük fiyat	17	'1 3 4 5 8 9 10 15 17 18 20 23 24 25 28 29 30'
30	Momentum kapanış fiyatı	13	'2 6 9 11 14 16 18 20 22 24 26 28 29'
31	Chaikin Dalgalanma	14	'2 3 5 8 9 10 14 15 16 18 19 21 23 30'
32	Hızlandırılmış stochastik %K	14	'1 2 3 8 9 10 12 15 17 20 21 24 25 30'
33	Hızlandırılmış stochastik %D	14	'2 5 6 13 15 16 17 18 19 21 22 25 28 30'
34	Yavaşlatılmış stochastik %K	8	'7 9 11 13 15 17 21 22'

35	Yavaşlatılmış stokastik %D	15	'2 6 9 10 11 12 13 14 15 16 19 23 25 27 28'
36	William's %R	22	'3 4 5 7 8 9 11 13 14 16 17 18 19 20 21 22 25 26 27 28 29 30'
37	Negatif hacim indeksi	5	'2 5 12 14 16'
38	Pozitif hacim indeksi	3	'7 16 17'
39	Görelî güç indeksi	19	'1 2 3 4 5 6 8 9 10 12 14 16 17 18 21 22 24 27 28'
40	Toplama/Dağıtım Çizgisi	3	'7 15 17'
41	Bollinger orta band	18	'3 4 5 7 8 9 10 15 16 17 19 20 21 22 23 27 29 30'
42	Bollinger üst band	14	'1 4 8 10 13 14 15 17 18 20 21 26 27 28'
43	Bollinger alt band	14	'8 10 12 13 17 19 22 24 25 26 27 28 29 30'
44	En yüksek yüksek değer	14	'1 3 4 5 10 16 17 19 21 24 25 26 28 30'
45	En düşük düşük değer	8	'8 16 17 19 23 25 28 30'
46	Medyan Fiyat	14	'3 9 11 14 15 17 18 21 22 23 24 27 29 30'
47	Denge işlem hacmi	0	"
48	Fiyat değişim oranı	10	'1 5 9 13 15 17 18 19 26 27'
49	Fiyat hacim eğilimi	0	"
50	Tipik fiyat	15	'1 2 3 6 7 8 10 12 19 21 22 23 24 26 29'
51	Hacim değişim oranı	18	'1 4 6 7 8 10 12 13 15 16 18 19 21 22 24 25 26 28'
52	Ağırlıklı kapanış fiyatı	10	'2 6 10 16 18 21 23 27 28 30'
53	William's Toplama Dağıtım	10	'9 12 13 15 16 17 23 28 29 30'

Tablo 5.2 'de her bir değişkenin kullanıldığı hisse senetleri sayısı ve kullanıldığı hisse senetleri indeksleri yer almaktadır. Değişkenlerin kullanılma sıklığı [0,24] arasında değişmektedir.



Şekil 5.3. Değişkenlerin Kullanıldığı Senet Sayısı

Şekil 5.3 ‘de değişkenlerin kaç adet hisse senedinde optimal değişken olarak tercih edildiğine ilişkin özet sıralama yer almaktadır. Şekilde dikkat çeken unsur price-volume trend isimli değişken ile on balance volume isimli değişkenin hiçbir hisse senedinde önerilen model tarafından tercih edilmediğidir. Söz konusu iki adet değişken başlangıç girdi havuzunda uygunluk fonksiyonlarına gönderilse de, model bu iki değişkeni hiçbir hisse senedi için iyi değişken olarak belirlememiştir.

Buna karşılık 6 günlük üçgen hareketli ortalama 24 adet hisse senedi ile en sık tercih edilen teknik gösterge olmuştur. Bunu William ‘s %R (22) ve 5 günlük üçgen hareketli ortalama (20) izlemiştir.

5.1.1. İşlem Süresi

Genetik algoritmalarla bir adet hisse senedine ilişkin optimal nöron sayısının ve kullanılması gereken değişken miktarının seçilmesi için yukarıda özellikleri belirtilen bilgisayar kullanılmıştır. Söz konusu özelliklere sahip makinada her bir hisse senedi için optimal genin bulunması süresi saniye ve dakika cinsinden aşağıdaki tabloda yer almaktadır. Toplamda 2681 dakika işlem gerçekleştirilmiştir bu da yaklaşık 45 saat (yaklaşık 2 gün) işlem yapıldığı anlamına gelmektedir.

Tablo 5.3. Hesaplama Süreleri

Sıra No.	Hisse Senedi Kodları	İşlem Süresi (sn.)	İşlem Süresi (dk.)
01	AKBNK	6389,1710	106,4862
02	AKSA	8468,249	141,1375
03	ARCLK	6674,164	111,2361
04	ASYAB	2089,284	34,8214
05	BIMAS	3888,251	64,8042
06	DOHOL	6615,7059	110,26176
07	EKGYO	610,034	10,1672
08	ENKAI	5566,865	92,7811
09	EREGL	7397,451	123,2909
10	GARAN	6456,405	107,6067
11	HALKB	2356,884	39,2814
12	IHLAS	6563,375	109,3896
13	ISCTR	6678,070	111,3012
14	KCHOL	3774,515	62,9086
15	KOZAL	1124,825	18,7471
16	KRDMD	10053,050	167,5509
17	MGROS	5862,005	97,7001
18	PETKM	5692,783	94,8797
19	SAHOL	10013,470	166,8912
20	SISE	7430,095	123,8349
21	SNGYO	2619,054	43,6509
22	TCELL	6757,759	112,6293
23	THYAO	7293,710	121,5618
24	TKFEN	1464,373	24,4062
25	TOASO	6754,787	112,5798
26	TTKOM	1712,399	28,5400
27	TTRAK	3449,611	57,4935
28	TUPRS	6736,852	112,2809
29	VAKBN	3223,918	53,7320
30	YKBNK	7130,731	118,8455
	TOPLAM	160847,8	2680,797


Çalışmada MATLAB yazılımının optimization toolbox isimli araç kutusu kullanılmıştır. Optimization toolbox, paralel işlem yapma özelliğini desteklemektedir. Başka bir ifade ile eğer bilgisayarda birden fazla çekirdek işlemci söz konusu ise optimizasyon işlemi her bir çekirdeğe dağıtılmakta ve paralel olarak işlem görmektedir. Söz konusu sistemin amacı daha hızlı bir şekilde sonuca ulaşabilmektir. Çalışmada paralel işlemler kullanılmıştır. Böylelikle kullanılmadığı duruma göre daha hızlı optimal sonuca ulaşılmıştır.

Paralel processing toolbox aracının işlemleri ne kadar hızlandığını ortaya koyabilmek için EKGYO isimli hisse senedine ilişkin deney bir kez daha gerçekleştirilmiştir. Bu ikinci gerçekleştirmede paralel işlem kullanılmamıştır. Paralel işlem ile 610 saniye süren işlem, paralel özelliğin olmadığı durumda 1571 saniye sürmüştür. Hesaplama süresi önceki süreye göre $(1571-610)/610 = \%158$ oranında artmıştır. Paralel işlem özelliğinin kullanılmadığı durumda toplam dakikanın 6917 dakika olması beklenmektedir. Bu da 115 saat (yaklaşık 5 gün) işlem yapılması gerektiği anlamına gelmektedir. Paralel işlemin kullanılması ile birlikte analizin sonuçlanma süresi (=bilgisayarın açık kalma süresi) oldukça kısaltılmıştır.

5.2. Gerçek Değerler ile Tahmin Edilen Değerlerin Karşılaştırılması

Çalışmada her bir hisse senedi için optimum ara katmandaki nöron sayısı ve optimum değişkenler belirlendikten sonra söz konusu parametreler ile tahmin modelleri kurulmuştur.


Tahmin modelleri test edilirken daha önce eğitim amacıyla kullanılmamış bir veri seti kullanılmaktadır. Bu veri seti test veri seti olarak adlandırılmaktadır. Söz konusu veri seti ile tahmin modelinin gösterdiği performans hesaplanacak ve böylelikle tahmin modelinin ne kadar başarılı olacağı ölçülecektir. Test veri setinden hemen önceki 640 adet gözlem eğitim amacıyla kullanılmıştır. Genetik algoritmalarla uygunluk fonksiyonunda 640/160 eğitim ve test veri seti kullanılmıştı. Bu durum genetik algoritma sonrası için de geçerlidir. Her bir hisse senedi için tahmin modeli 01/02/2011 ve 08/05/2012 tarihleri arasındaki gözlemler kullanmak suretiyle eğitime tabi tutulmuştur. Eğitilen yapay sinir ağları modelleri 160 gün için teste tabi tutulmuştur. Başka bir ifade ile son 160 günden önceki 640 güne ilişkin veriler kullanmak suretiyle yapay sinir ağları eğitilmekte ve son 160 gün için test işlemi gerçekleştirilmektedir.



Şekil 5.4. EKGYO isimli Hisse Senedinin Eğitim Süreci


Şekil 5.4 ‘de EKGYO adlı hisse senedinin eğitim süresi boyunca, optimal ve alternatif modelin ürettiği değerler yer almaktadır. Söz konusu şekilde açık renkli kesikli çizgi optimal modelin ürettiği değerlerdir. Siyah renkli kesikli çizgi ise alternatif modelin ürettiği değerlerdir. Düz çizgi ise hisse senedinin eğitim süreci boyunca sahip olduğu değerlerdir. Daha önce de değinildiği gibi eğitim sürecinde modellerin gösterdiği performans pratik açıdan bir fayda sağlamamaktadır. Çünkü daha önce modellerin eğitilmesi sürecinde kullanılan veri seti üzerinde tahmin yapılmaktadır. Bu değerler yerine modellerin test aşamasında gösterdikleri performans dikkate alınmalıdır. Söz konusu bütün hisse senetlerine ilişkin eğitim grafikleri Ek 1 de yer almaktadır.

Şekil 5.5 ‘de TUPRS adlı hisse senedinin test süresince tahmin ettiği fiyatlar yer almaktadır. Söz konusu hisse senedine ilişkin test aşamasındaki optimal ve alternatif modelin tahmin ettiği değerler ve gerçek fiyat ile modelin tahmin ettiği fiyat arasındaki farkın mutlak değeri arşığıdaki şekilde gösterilmiştir.



Şekil 5.5. TUPRS Hisse Senedine İlişkin Tahmin Edilen ve Gerçek Fiyatlar

Şekil iki bölümden oluşmaktadır. Yukarıdaki bölümde optimal ve alternatif modelin tahmin ettiği fiyatlar ile gerçek fiyatlar gösterilmektedir. Alt bölümdeki şekilde ise hisse senedinin gerçek fiyatı ile tahmin edilen fiyatı arasındaki farkın mutlak değeri yer almaktadır. Optimal modele ilişkin fiyatlar şekilde artı işareti ile gösterilen kesikli çizgilerdir. Alternatif model ise kesikli çizgi ile gösterilmiştir. Gerçek fiyat ise kalın ve düz bir çizgi ile gösterilmektedir. Yukarıdaki şekilde artı ile işaretlenen optimal tahminlerin, düz ve kalın çizgiye yakın olması optimal modelin gerçekleştirdiği tahminin ne kadar doğru olduğunu göstermektedir. Alternatif modelin gerçekleştirdiği tahminler ise gerçek fiyattan sapma göstermektedir. Alt tarafta yer alan hata grafiğinde ise hata çizgisinin alt taraftaki eksene yakın olması, yapılan tahminin doğruluğunu göstermektedir. Yatay eksenden uzaklaşıldıkça modelin tahmin ettiği fiyatlar ile gerçek fiyat arasındaki fark artmaktadır. Alt bölümden şekilden optimal hata ile alternatif hatanın birbirlerinden farklı olduğunu ve optimal hatanın alt tarafta yer alan eksene oldukça yakın olduğu görülmektedir. Böylelikle optimal modelin gerçekleştirdiği tahminler, alternatif modelin gerçekleştirdiği tahminlere göre gerçeğe daha yakındır yorumunun yapılması mümkündür. Ek 2 de test süresinde bütün hisse senetlerinin tahmini fiyatları ile gerçek fiyatlarının grafikleri yer almaktadır.



Şekil 5.6. YKBNK Hisse Senedi Dağılım Grafiği

Optimal model kurulduktan ve test sürecine ilişkin tahminler gerçekleştirildikten sonra test sürecindeki gerçek fiyatlar ve optimal modelin tahmin ettiği fiyatlar dağılım grafiğinde gösterilebilir ve böylelikle modelin gerçek fiyatlara ne kadar yakın tahminler gerçekleştirdiği belirlenebilir. Şekil 5.6 'da YKBNK kodlu hisse senedine ilişkin dağılım grafiği görülmektedir. Söz konusu şekil iki bölümden oluşmaktadır. Üstteki bölümde yatay ekseninde gerçek fiyatların ve dikey ekseninde tahmin edilen fiyatların yer aldığı dağılım grafiği yer almaktadır. Alttaki bölümde ise gerçek fiyat ile tahmin edilen fiyat arasındaki farka ilişkin grafik yer almaktadır. Alttaki grafikte fark değerlerinin yer aldığı band ne kadar dar ise yapılan tahminin de o derecede iyi olduğunu söylemek mümkündür. Bütün hisse senetlerine ilişkin dağılım grafikleri Ek 3 de yer almaktadır.

Tablo 5.4. Gerçek Fiyatlar ile Tahmin Edilen Fiyatlar Arasındaki r - kare Değerleri

Sıra No.	Hisse Senedi Kodları	Optimal Model		Alternatif Model	
		r^2	Düzeltilmiş r^2	r^2	Düzeltilmiş r^2
01	AKBNK	0,9573	0,95703	0,487346	0,484102
02	AKSA	0,897152	0,896501	0,757275	0,755739
03	ARCLK	0,950264	0,949949	0,65758	0,655413
04	ASYAB	0,969827	0,969636	0,882826	0,882084
05	BIMAS	0,892508	0,891828	0,076551	0,070706
06	DOHOL	0,932325	0,931897	0,772843	0,771405
07	EKGYO	0,965837	0,96562	0,96158	0,961337
08	ENKAI	0,924088	0,923608	0,048411	0,042388
09	EREGL	0,519451	0,51641	0,006836	0,00055
10	GARAN	0,979871	0,979744	0,961183	0,960937
11	HALKB	0,94712	0,946785	0,076404	0,070559
12	IHLAS	0,807264	0,806044	0,536935	0,534004
13	ISCTR	0,990156	0,990094	0,896419	0,895763
14	KCHOL	0,950978	0,950668	0,905672	0,905075

15	KOZAL	0,285281	0,280757	0,129119	0,123607
16	KRDMD	0,729393	0,72768	0,367022	0,363016
17	MGROS	0,890399	0,889706	0,138096	0,132641
18	PETKM	0,796122	0,794831	0,364467	0,360445
19	SAHOL	0,928831	0,928381	0,00063	-0,0057
20	SISE	0,931085	0,930648	0,636914	0,634616
21	SNGYO	0,880863	0,880109	0,775037	0,773613
22	TCELL	0,978285	0,978148	0,931199	0,930763
23	THYAO	0,984466	0,984368	0,949994	0,949678
24	TKFEN	0,968825	0,968628	0,909267	0,908693
25	TOASO	0,985305	0,985212	0,762309	0,760805
26	TTKOM	0,842656	0,84166	0,113474	0,107863
27	TTRAK	0,984918	0,984823	0,780075	0,778683
28	TUPRS	0,964571	0,964347	0,714103	0,712294
29	VAKBN	0,983096	0,982989	0,962038	0,961797
30	YKBNK	0,981573	0,981456	0,439028	0,435478

Tablo 5.4 ‘de hem optimal modelin hem de alternatif modelin tahmin sonuçları ile gerçek sonuçları arasındaki r^2 ve düzeltilmiş r^2 değerleri görülmektedir. Söz konusu değerlerin 1 ‘e yakın olması, modelin gerçek fiyatlara yakın değerler üretebildiğini göstermektedir.

Tablodan da görülebileceği gibi, optimal modelin tahmin ettiği fiyatlar ile gerçek fiyatlar arasında hesaplanan r^2 ve düzeltilmiş r^2 değerleri 1 ‘e daha yakındır. Alternatif modelin gerçekleştirdiği tahminler ile gerçek fiyatlar arasında hesaplanan r^2 ve düzeltilmiş r^2 değerleri ise optimal modelden daha düşük olmuştur. Bunun anlamı test veri setinde optimal modelin ürettiği sonuçlar alternatif modele göre daha iyidir.

5.2.1. İstatistiksel Tahmin Sonuçları

Tablo 5.5 ‘de modellerin test süresi boyunca gerçekleştirdikleri istatistiksel performans ölçülerine ilişkin değerler yer almaktadır. Bu değerler tahmin performansının ne kadar iyi olduğuna ilişkin ipucu sağlamaktadır. Söz konusu istatistiksel değerler MSE, MAPE ve RMSE’dir. Bu değerler ne kadar düşük olursa, tahmin performansının da o kadar yüksek olduğunu söylemek mümkündür.

Çalışmada modelin eğitim aşamasında ulaştığı MSE değeri ve test aşamasında ulaşılan MSE değerleri tablodaki gibidir. Ayrıca tahminlerin başarı oranının sergilenmesinde kullanılacak bir diğer yöntem olan MAPE değerlerine de yer verilmiştir. Böylelikle tahmin performansı istatistiksel açıdan değerlendirmeye tabi tutulmuştur.

Tablo 5.5. Optimal ve Alternatif Modele İlişkin İstatistiksel Performans Ölçüleri

S No.	H.S. Kod	Optimal Model			Alternatif Model		
		MSE	MAPE	RMSE	MSE	MAPE	RMSE
01	AKBNK	0,00997	1,240997	0,099849	0,205059	6,018329	0,452835
02	AKSA	0,00194	0,752879	0,044041	0,009388	1,902846	0,096892
03	ARCLK	0,080745	2,280142	0,284157	0,734879	8,425655	0,857251
04	ASYAB	0,000512	0,997145	0,022628	0,005943	3,808676	0,077092
05	BIMAS	11,49382	4,233498	3,390254	709,414	34,36783	26,63483
06	DOHOL	0,000171	1,334503	0,013092	0,015739	15,60186	0,125456
07	EKGYO	0,001926	1,466913	0,043885	0,001136	1,154167	0,033708
08	ENKAI	0,009767	1,449384	0,098829	1,237661	20,14124	1,112502
09	EREGL	0,720199	41,51146	0,848646	0,202517	19,56548	0,450019
10	GARAN	0,005638	0,860085	0,075085	0,03925	2,174918	0,198116
11	HALKB	0,398078	3,224232	0,630934	5,141034	12,34718	2,267385

12	IHLAS	0,000184	0,990611	0,013576	0,00178	3,147492	0,042195
13	ISCTR	0,00415	1,174479	0,064423	0,424399	13,53362	0,651459
14	KCHOL	0,008051	1,018812	0,089726	0,095958	4,348664	0,309771
15	KOZAL	43,53137	18,58276	6,597831	27,13975	13,30233	5,209583
16	KRDMD	0,00418	4,189589	0,064652	0,013909	7,51957	0,117936
17	MGROS	0,461636	2,862772	0,679438	1,946148	6,476073	1,395044
18	PETKM	0,000593	0,925029	0,024348	0,003725	2,611894	0,061031
19	SAHOL	0,011737	1,103926	0,108336	0,849044	10,62317	0,921436
20	SISE	0,00417	1,925791	0,064573	0,025628	4,724715	0,160086
21	SNGYO	0,001012	2,102722	0,031805	0,002302	3,347003	0,047981
22	TCELL	0,015873	1,020815	0,125989	0,150201	3,855795	0,387558
23	THYAO	0,005194	1,821031	0,07207	0,032241	5,39299	0,179557
24	TKFEN	0,006699	0,968037	0,081848	0,057268	2,989639	0,239307
25	TOASO	0,008523	0,98932	0,092319	0,238636	4,846484	0,488504
26	TTKOM	0,020007	1,483258	0,141447	0,268341	6,373689	0,518016
27	TTRAK	0,176715	1,071371	0,420374	5,594116	6,834706	2,365188
28	TUPRS	0,163102	0,832367	0,403859	8,074939	7,047745	2,841644
29	VAKBN	0,002254	1,07575	0,047481	0,049678	6,063567	0,222886
30	YKBNK	0,002484	1,127738	0,04984	0,145328	7,726103	0,381219

Gerçekleştirilen bu sonuçların istatistiksel açıdan anlamlı farklılık sergileyip sergilemediğini belirleyebilmek için parametrik olmayan testler uygulanmıştır. Aynı veri setine farklı modeller uygulandığı için bağımsız örneklem Mann-Whitney U-test uygulanmıştır ve sonuçlar Tablo 5.6 ‘daki gibidir.

Üç farklı istatistiksel performans ölçüsü söz konusudur ve iki modele ilişkin elde edilen değerler arasında anlamlı bir farklılık olup olmadığını test etmek için üç farklı hipotez kurulmuştur. Bu hipotezler şu şekildedir;

- H1: Optimal ve alternatif modelin mse değerleri arasında anlamlı bir farklılık yoktur
- H2: Optimal ve alternatif modelin mape değerleri arasında anlamlı bir farklılık yoktur
- H3: Optimal ve alternatif modelin rmse değerleri arasında anlamlı bir farklılık yoktur

Tablo 5.6. Hipotez Testi Sonuçları

Sıfır Hipotezi	Mean (Optimal)	Rank (Alternatif)	Test İstatistiği	Asymptotic Sig (2-sided)	Karar
H1	23,57	37,43	242	0,002	H_0 ret
H2	18,80	42,20	99	0,000	H_0 ret
H3	23,57	37,43	242	0,002	H_0 ret

MSE değerleri dikkate alındığında, optimal modele ilişkin ortalama sırası (ort_sıra = 23,57), alternatif modele ilişkin ortalama sırasından (ort_sıra=37,43) istatistiksel açıdan farklı olduğu görülmektedir (U=242, $p<0.01$). Başka bir ifade ile optimal modelin ürettiği sonuçlar, alternatif modelin ürettiği mse değerlerine göre daha düşüktür. Bu bulgu optimal modelin istatistiksel açıdan daha düşük MSE değeri ürettiğinin istatistiksel kanıtıdır.

Optimal modelin ürettiği MAPE değerlerine ilişkin ortalama sırası (ort_sıra = 18,80), alternatif modelin ürettiği ortalama sırasından (ort_sıra=42,20) istatistiksel açıdan farklıdır (U=99, $p<0.01$). Başka bir ifade ile optimal modelin ürettiği mape değerleri, alternatif modelin ürettiği MAPE değerlerine göre daha düşüktür. Bu bulgu optimal modelin istatistiksel açıdan daha düşük mape değeri ürettiğinin istatistiksel kanıtıdır.

Optimal modelin ürettiği RMSE değerlerine ilişkin ortalama sırası (ort_sıra=23,57), alternatif modelin ürettiği ortalama sırasından (ort_sıra = 37,43)

istatistiksel açıdan farklıdır ($U=242$, $p<0.02$). Başka bir ifade ile optimal modelin ürettiği rmse değerleri, alternatif modelin ürettiği RMSE değerlerine göre daha düşüktür. Bu da optimal modelin istatistiksel açıdan daha düşük RMSE değeri ürettiğinin istatistiksel kanıtıdır.

Yukarıdaki ifadelerden görüldüğü gibi istatistiksel performans ölçüleri optimal modelde, alternatif modele göre daha düşük düzeydedir ve daha iyi tahmin gerçekleştirildiğinin kanıtıdır.

5.2.2. Yön Tahmin Sonuçları

Tahmin başarı ölçüleri bölümünde değinilen formül yardımıyla her bir hisse senedi için, hareket yönünün ne derecede doğru tahmin edildiği hesaplanmıştır. Yapılan hesaplama sonuçları Tablo 5.7 'de yer almaktadır.

Tablo 5.7. Yön Tahmin Sonuçları

Sıra No.	Hisse Senedi Kodları	Optimal Model	Alternatif Model
01	AKBNK	0,477987	0,503145
02	AKSA	0,515723	0,509434
03	ARCLK	0,484277	0,566038
04	ASYAB	0,509434	0,503145
05	BIMAS	0,477987	0,484277
06	DOHOL	0,421384	0,427673
07	EKGYO	0,484277	0,471698
08	ENKAI	0,515723	0,509434
09	EREGL	0,54717	0,371069
10	GARAN	0,496855	0,534591
11	HALKB	0,496855	0,540881
12	IHLAS	0,408805	0,45283
13	ISCTR	0,591195	0,459119
14	KCHOL	0,465409	0,503145
15	KOZAL	0,459119	0,503145
16	KRDMD	0,415094	0,465409
17	MGROS	0,484277	0,477987
18	PETKM	0,402516	0,415094
19	SAHOL	0,496855	0,477987
20	SISE	0,433962	0,45283
21	SNGYO	0,484277	0,572327
22	TCELL	0,534591	0,572327
23	THYAO	0,597484	0,591195
24	TKFEN	0,465409	0,490566
25	TOASO	0,566038	0,540881
26	TTKOM	0,503145	0,471698
27	TTRAK	0,484277	0,490566
28	TUPRS	0,515723	0,484277
29	VAKBN	0,465409	0,528302
30	YKBNK	0,534591	0,477987

Optimal model %60 oranında yön tahminin gerçekleştirebilirken, alternatif model en fazla %56 oranında doğru tahmin gerçekleştirebilmiştir. Burada dikkat edilmesi gereken husus çalışmanın esas amacının yön tahminini keskinleştirmek olmadığıdır. Çalışmada gerçekte yapılması istenen şey fiyat tahminin mümkün olduğunca gerçeğe yakın gerçekleşmesini sağlamaktır. Fakat alım satım algoritması ile yakından ilgili

olduğundan yön tahminlerine de yer verilmiştir. Optimal model 17 adet hisse senedinde alternatif modelden daha yüksek doğrulukla yön tahminini gerçekleştirebilmiştir.

5.2.3. Alım Satım Simulasyonu Sonuçları

Test aşaması olan 160 seans boyunca hisse senetlerinin bir sonraki güne ilişkin değerleri bir gün önceden tahmin edilmiştir. Çalışmada daha önce detaylı bir şekilde açıklanan alım satım algoritması uygulanmış ve test aşaması boyunca hisse senetlerinin alım satımı sonucu gerçekleştirilen kar miktarları ayrı ayrı hesaplanmıştır.

Alım satım algoritması her iki model için ayrı ayrı hesaplanmıştır. Çalışmanın sonunda her hisse senedi için edinilen kar oranları toplanmış ve toplam kar değerleri karşılaştırılmıştır.

Tablo 5.8. Getiri Oranları


Sıra No.	Hisse Senedi Kodları	Optimal Model	Alternatif Model	artış/azalış
01	AKBNK	0,032573	-0,03753	0,070103
02	AKSA	0,052198	0,072937	-0,02074
03	ARCLK	0,010255	0,117618	-0,10736
04	ASYAB	0,070343	0,008695	0,061648
05	BIMAS	0,016591	-0,04898	0,065571
06	DOHOL	-0,20739	-0,20653	-0,00086
07	EKGYO	0,15429	0,151716	0,002574
08	ENKAI	0,045499	-0,0594	0,104899
09	EREGL	0,617642	-0,78718	1,404822
10	GARAN	0,108023	0,101779	0,006244
11	HALKB	0,137447	0,151494	-0,01405
12	IHLAS	-0,16386	-0,09472	-0,06914
13	ISCTR	0,277578	0,142546	0,135032
14	KCHOL	0,044512	0,152813	-0,1083
15	KOZAL	-0,01383	0,063842	-0,07767
16	KRDMD	-0,0532	-0,00744	-0,04576
17	MGROS	0,199319	0,111533	0,087786
18	PETKM	-0,06958	-0,03773	-0,03185
19	SAHOL	0,187716	-0,07098	0,258696
20	SISE	-0,12885	-0,08145	-0,0474
21	SNGYO	-0,00257	0,174533	-0,1771
22	TCELL	0,117798	0,265376	-0,14758
23	THYAO	0,333009	0,305446	0,027563
24	TKFEN	-0,03233	0,062363	-0,09469
25	TOASO	0,267107	0,130506	0,136601
26	TTKOM	0,017075	-0,01341	0,030485
27	TTRAK	0,128242	0,144852	-0,01661
28	TUPRS	0,170878	0,137628	0,03325
29	VAKBN	0,111468	0,239867	-0,1284
30	YKBNK	0,203404	0,098239	0,105165
TOPLAM:		2,631367	1,188431	1,4429338
Sıfır veya Zarar:		8	11	
Kar eden Senet Sayısı:		22	19	

Tablo 5.8 ‘de her bir hisse senedi için sadece alış pozisyonu (long position) varsayımı altında elde edilecek olan kar miktarları gösterilmiştir. Optimal modelde her bir hisse senedinden elde edilen yüzde oranındaki getiriler toplandığında 2,631 oranında kâr olduğu görülmektedir. Alternatif modelde bu toplam 1,188 oranında kalmaktadır.

Genetik algoritma ile optimizasyonun gerçekleştirilmesi getirilerde 1,443 oranında bir artış sağlamıştır.

Tablodaki sonuçlara göre optimal modeli kullanan bir yatırımcının test süresi sonucunda elde edeceği kar alternatif modele göre daha yüksek olmaktadır. Bu tablodaki sonuç optimal modelin hisse senedi fiyatındaki artış ve azalışları alternatif modele göre daha doğru tahmin edebilmesinin bir sonucu olarak gerçekleşmiştir.

Alım satım algoritması sonucu erişilen değerleri daha yakından incelemek için, kar edilen hisse senedi sayısı ve zarar edilen hisse senedi sayısı pasta grafiği şeklinde gösterilecektir.



Şekil 5.7. Optimal ve Alternatif Modelde Kar ve Zarar Durumu

Şekil 5.7 'de açık renkle gösterilen oran 30 adet hisse senedi içerisinde kar ile sonuçlanan hisse senetlerinin oranıdır. Koyu renkle gösterilen oran ise 160 günlük test periyodu boyunca zarar eden veya ne kar ne de zarar eden hisse senetlerinin oranıdır. Şekilin sol tarafı optimal modeli, sağ tarafı ise alternatif modeli temsil etmektedir. Optimal modelde 22 adet hisse senedinde (%73) kar elde edilmiştir. 8 adet hisse senedi (%27) ise zararlar veya nötr sonuçlanmıştır. Alternatif modelde ise 19 adet hisse senedi (%63) kar ile sonuçlanırken, 11 adet hisse senedi (%37) zararlar veya nötr sonuçlanmıştır. Gerek toplam kar meblağında, gerekse de kar eden hisse senedi çokluğu açısından optimal model, alternatif modele göre daha iyi sonuçlar vermiştir.

5.3. Risk ve Tahmin İlişkisi

Risk ve tahmin arasındaki ilişkiyi incelemek için çalışmada kullanılan 30 adet hisse senedi risk bilgisi göz önünde bulundurulmak suretiyle riskli ve risksiz hisse senetleri olmak üzere iki gruba ayrılmıştır.

Risk kavramı standart sapma kavramı ile ölçülmektedir. Standart sapma ise ortalamadan ne kadar uzaklaşıldığını ölçmektedir. Standart sapmanın formülü ise şu şekildedir:

$$s_N = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^2}$$

Formüldeki x_i ifadesi, i gün değerini, $\bar{x}$ ifadesi ise o güne ilişkin getiri değerini temsil etmektedir. Bir hisse senedinin getirilerinin standart sapması ne kadar büyükse, getirilerin geniş bir aralıkta dalgalandığını ve dolayısıyla daha riskli olduğunu söylemek mümkündür.

Hisse senetlerini riskli ve risksiz iki gruba ayırmak için medyan değeri kullanılabilir. İstatistik teorisinde yer alan medyan kavramı, bir serinin yüksek değerlere sahip yarısını, düşük değerlere sahip diğer yarısından ayıran sayı olarak tanımlanmaktadır. Medyan değerinin hesaplanabilmesi için, getiri serisi büyükten küçüğe doğru sıralanmıştır. Gözlem sayısı çift olduğunda (örneğimizde 30 adet hisse senedi kullanılmıştır) medyanı hesaplayan formül şu şekildedir:

$$\text{Medyan} = \frac{\frac{N}{2} \text{ numaralı gözlemin değeri} + \left(\frac{N}{2} + 1\right) \text{ numaralı gözlemin değeri}}{2}$$

Yukarıdaki formül dikkate alındığında, bu çalışma için hisse senetlerinin standart sapmalarının medyan değeri 15. ve 16. sırada yer alan gözlemlerin ortalaması şeklinde hesaplanmaktadır.

Medyan değeri (bu çalışmada olduğu gibi) çift sayıda gözlem söz konusu olduğunda seride yer alan değerlere denk gelmez. Ortadaki iki gözlemin ortalaması şeklinde hesaplanır. Bu çalışma için medyan değeri 0,030 olarak hesaplanmıştır.

Sıralanan seride, hesaplanan bu medyan değerinin yukarısında (aşağısında) kalan 15 adet hisse senedine ilişkin standart sapma değerleri, medyan değerinden daha büyük (küçük) olduğu için riskli (risksiz) hisse senetleri olarak isimlendirilmiştir. Tablo 5.9 'da riskli ve risksiz hisse senetleri bilgisi yer almaktadır.

Tablo 5.9. Riskli ve Risksiz Hisse Senetleri Sayısı

Risksiz Hisse Senetleri			Riskli Hisse Senetleri		
Kod	HS İsmi	Std_spm	Kod	HS ismi	Std_spm
1	AKBNK	0,026	5	BIMAS	0,030
2	AKSA	0,029	6	DOHOL	0,041
3	ARCLK	0,029	9	EREGL	0,045
4	ASYAB	0,028	10	GARAN	0,032
7	EKGYO	0,018	12	IHLAS	0,095
8	ENKAI	0,030	13	ISCTR	0,044
11	HALKB	0,021	14	KCHOL	0,120
15	KOZAL	0,016	16	KRDMD	0,037
21	SNGYO	0,029	17	MGROS	0,437
22	TCELL	0,028	18	PETKM	0,063
24	TKFEN	0,017	19	SAHOL	0,030
25	TOASO	0,028	20	SISE	0,086
26	TTKOM	0,014	23	THYAO	0,040
27	TTRAK	0,021	29	VAKBN	0,039
28	TUPRS	0,026	30	YKBNK	0,065

Geçmiş verilerde, kapanış fiyatları daha az dalgalanan (0 numaralı grup) ve daha fazla dalgalanan (1 numaralı grup) gruplar arasındaki performans karşılaştırması, risk ve tahmin arasındaki ilişki hakkında ipuçları verebilir.

5.3.1. İstatistiksel Tahmin Sonuçlarının Karşılaştırılması

Gruplarda yer alan gözlem sayısı az olduğundan parametrik olmayan özellikteki hipotez testlerinin kullanılması gerekmektedir. İki adet grup söz konusu olduğu için ve örnekler birbirlerinden bağımsız olduğu için bağımsız örneklem Mann-whitney U testi farklılığı test etmek için kullanılmıştır. Optimal MSE, RMSE ve MAPE değerlerini karşılaştırmak suretiyle istatistiksel farklılık olup olmadığı ortaya çıkarılacaktır.

Bu iki gruba ilişkin oluşturulan hipotez testleri şu şekildedir:

H1: Riskli ve risksiz senetlerin MSE değerleri arasında anlamlı bir farklılık yoktur
H2: Riskli ve risksiz senetlerin MAPE değerleri arasında anlamlı bir farklılık yoktur
H3: Riskli ve risksiz senetlerin RMSE değerleri arasında anlamlı bir farklılık yoktur
İstatistik değerlere ilişkin kurulan bu hipotezlere ilişkin istatistikler ve sonuçlar Tablo 5.10 ‘daki gibidir.

Tablo 5.10. Riskli ve Risksiz Grupların İstatistiksel Performansları

Hipotezler	Gruplar	Ortalama sıralama değeri	Mann-Whitney U test değeri	Exact sig	Asymptotic Sig
H1	< Medyan (0)	13,60	84,000	0,250	0,237
	> Medyan (1)	17,40			
H2	< Medyan	14,53	127,000	0,567	0,548
	> Medyan	16,47			
H3	< Medyan	13,60	84,000	0,250	0,237
	> Medyan	17,40			

Tablodan da görülebileceği gibi her bir optimal modelin sonuçlarının dikkate alınması suretiyle hesaplanan performans ölçüsünde daha az riske sahip hisse senetlerinde istatistiksel tahmin performansları birbirlerine yakın çıkmıştır. Bu farklılık, mse (U=84, p>0.05), mape (U=127, p>0.05) ve rmse (U=84, p>0.05) değerlerinde istatistiksel olarak anlamlı değildir.

5.3.2. Alım Satım Simulasyonu Sonuçlarının Karşılaştırması

Çalışmanın bu bölümünde riskli ve risksiz hisse senetlerinin getiri performansı karşılaştırılacaktır. Alım satım algoritmasının işletilmesi sonucu elde edilecek getiri oranlarının karşılaştırılması Tablo 5.11 ‘deki gibidir:

Tablo 5.11. Riskli ve Risksiz Hisse Senetlerinin Getiri Oranları

Gruplar	Getiri
Riskli	1,476
Risksiz	1,155

Tabloda riskli ve risksiz gruptaki hisse senetlerine ilişkin getiri oranlarının toplamı yer almaktadır. Tablodan da görüleceği üzere, daha düşük standart sapmaya sahip (risksiz) hisse senetlerinin getirilerinin toplamı (1,155), daha yüksek standart sapmaya sahip hisse senetlerinin (riskli) getiri oranlarının toplamından (1,476) daha düşük düzeydedir.

Tarihi getiri oranları standart sapması yüksek olan hisse senetlerinde daha yüksek kar elde edilmiştir. Başka bir ifade ile riskli hisse senetlerinde söz konusu modelin çalıştırılması daha yüksek getiri oranlarının elde edilmesine olanak sağlayabilir.

6. SONUÇ VE TARTIŞMA

Hisse senetleri bireysel ve kurumsal yatırımcıların sahip oldukları fazla fonları değerlendirmek için kullandıkları yatırım araçlarından bir tanesidir. Genel olarak hisse senedi getirilerinin, risksiz faiz oranından daha riskli olduğu kabul edilir. Daha fazla risk içermesi kayıpların ve kazançların daha yüksek olmasına yol açmaktadır. Yatırımcıların ortak bir amacı vardır ve bu amaç piyasa ortalamasının üzerinde kar elde etmektir. Hisse senedi fiyatlarının önceden tahmin edilebilmesi piyasanın üzerinde getiri sağlayabilir. Bu nedenle hisse senedi fiyatlarının önceden tahmin etmek için çalışmalar yapılmıştır.

Hisse senetleri fiyat tahmini konusunda yapılan çalışmalardan anlaşılmaktadır ki, geçmiş fiyat hareketlerinden yola çıkmak suretiyle, hisse senedi fiyatını önceden tahmin edilebilirliği konusunda henüz fikir birliği söz konusu değildir. Hisse senedi fiyatlarının önceki fiyatlardan tamamen bağımsız olduğunu savunanlar olduğu gibi, hisse senedi fiyatlarının geçmişteki fiyatlardan yola çıkarak tahmin edilebileceğini savunanlar da literatüre değerli çalışmalar sunmuşlardır. Bu araştırma ikinci gruptaki çalışmaları destekler niteliktedir. Bu çalışmaya göre de bilgi işlemsel zeka teknikleri kullanılmak suretiyle belirli bir dereceye kadar hisse senedi fiyatının bir gün sonraki fiyatını önceden tahmin etmek mümkündür. Bu tezi savunmak amacıyla BIST 30 endeksine kayıtlı firmaların hisse senedi fiyat bilgileri kullanılmış ve fiyatlar gerçekleşmeden önce tahmin edilmeye çalışılmıştır.

Çalışmanın esas amacı bilgi işlemsel zeka yöntemlerinin finansal piyasalarda uygulanmasını sağlamak yoluyla kullanıcının, karmaşık tahmin modeline daha az müdahale ettiği uzman bir sistem tasarlamaktır. Model, kullanıcının yerine karar verebildiği için uzman olarak adlandırılmaktadır. Çalışmada önerilen modelde, yapay sinir ağları için gerekli parametrelerden bazıları, bilgi işlemsel zeka yöntemlerinden biri olan genetik algoritmalar ile birlikte optimize edilmektedir. Böylelikle kullanıcı fiyatlar henüz gerçekleşmeden, bir sonraki güne ilişkin tahmin fiyatlarını elde edebilmektedir.

Çalışmada tahmin modeli olarak ileri beslemeli, tek ara katmanı olan bir yapay sinir ağı mimarisi kullanılmıştır. Yapay sinir ağları modeli ile tahmin yapılırken, kullanılacak değişkenlerin seçimi önem arz etmektedir. Eğer hisse senedi fiyatını doğru bir şekilde tahmin edemeyecek değişkenler modelde girdi olarak kullanılırsa, bu durumda tahmin performansı düşebilir. Ayrıca ara katmanda yer alması gereken nöron sayısının da tahmin gerçekleştirilmeden önce belirlenmesi ve tahmin yapılırken bu bilgilerin kullanılması gerekmektedir. Söz konusu iki karar tahmin başarısı ile yakından ilgilidir. Bu kararlar, uzmanlar tarafından belirlenebilir. Fakat uzman bilgisine erişmek maliyetli veya imkansız olabilir. Bu çalışmada söz konusu iki kararın sezgisel bir optimizasyon yöntemi olan genetik algoritmalar tarafından eş zamanlı optimize edileceği uzman bir model önerilmiştir. Kullanılan modeldeki gen tasarımı ve uygunluk fonksiyonu tasarımı eş zamanlı optimizasyonu gerçekleştiren esas unsurlardandır. Ara katmanda kullanılması gereken nöron sayısı ile kullanılacak değişkenlerin indeksleri tek bir gende bir araya getirilmiştir. Uygunluk fonksiyonu ise eğitim setini sıralı alt gruplara ayırmaktadır ve o anda değerlendirilen yapay sinir ağı mimarisinin alt gruplarda ürettiği ortalama hatayı hesaplamaktadır. Alt gruplara ayırmak, modelin eğitim setine aşırı uyum sağlamasını engellemektedir.

Veri seti olarak 2012 yılında BIST 30 endeksinde yer alan 30 adet hisse tarihi açılış, kapanış, en yüksek fiyat, en düşük fiyat ve işlem hacmi bilgileri kullanılmıştır. Bu fiyat bilgilerinden yola çıkmak suretiyle her bir hisse senedi için 53 adet aday-girdi değişken hesaplanmıştır. Oluşturulan veri seti, eğitim ve test olmak üzere iki gruba ayrılmıştır. Eğitim seti ile kurulan modeldeki ara katman sayısı ve kullanılacak

değişkenler, genetik algoritmalar yardımıyla optimizasyona tabi tutulmuştur. Optimal yapı ile tahmin modelleri oluşturulmuştur. Oluşturulan bu yeni model test veri setinde tahmin için kullanılmış ve gerçekleşen performans tespit edilmiştir. Yapay sinir ağı yapısının değişken seçimi ile eşzamanlı gerçekleştirilmesi ile birlikte, modelde kullanılacak uzman bilgisi minimum düzeye indirgenmektedir.

Önerilen yöntem tamamen bilgisayar tabanlı olduğu için tarafsız bir şekilde değerlendirme söz konusudur. Başka bir ifade ile kişilere ait yanlı olma problemi elenmiş olmaktadır. Uzman diye tabir edilen kişiler karar verirken, geçmişteki deneyimlerinin ve kişisel özelliklerinin (riskten kaçınma veya riski üstlenme gibi) etkisinde kalmak suretiyle yanlı kararlar verebilirler. Bu durum yanılmalara ve dolayısıyla yanlı kararlar da neden olabilir. Çalışmada önerilen sistemde böyle bir durum söz konusu değildir.

Deneylerin gerçekleştirilmesinde metinde özellikleri belirtilen bilgisayar kullanılmıştır. Bu bilgisayarda söz konusu uzunluktaki eğitim setinde sıralı doğrulama yönteminin uygulanması ve bir adet hisse senedi için optimal nöron sayısının ve optimal değişkenlerin seçilmesi ortalama 90 dakika sürmektedir. Çalışmada genetik algoritmaların durma şartı olarak bir tolerans belirlenmiştir. Bu toleranstan daha iyi bir iyileşme sağlanmadığı durumda genetik algoritmalar çalışmayı durdurmaktadır. Çalışmada hisse senetleri için ortalama 50 nesil sonrasında eğitim genetik algoritma işlemleri durmaktadır.

Çalışmada optimal ve alternatif modelin başarısı MSE, MAPE ve RMSE değerleri ile ölçülmüştür. Bu değerler gerçek değerden ne kadar farklı tahminlerin gerçekleştiğini göstermektedir. Başarılı modellerde bu değerler, başarısız modellere göre daha küçük olacaktır. Elde edilen sonuçlar karşılaştırıldığında, hisse senetlerinin büyük çoğunluğunda optimal modelin, alternatif modele göre gerçek değerlere daha yakın tahminlerin gerçekleştirdiği ortaya çıkmıştır. Fakat optimal modelin istikrarlı bir şekilde alternatif modele göre daha iyi sonuç verip vermediğini belirlemek için istatistiksel hipotez testleri gerçekleştirilmiştir. Optimal ve alternatif modelin ürettiği hata değerleri arasında farklılık olup olmadığını ölçmek için parametrik olmayan bir test olan Mann-Whitney U testi uygulanmıştır. Çünkü anakütle dağılımları konu dışıdır. Bu nedenle parametrik olmayan testlerin kullanılması uygundur. Söz konusu istatistiksel teste göre optimal modeldeki hata değerleri (MSE, RMSE, MAPE) alternatif modele göre istatistiksel açıdan anlamlı bir derecede farklıdır. Optimal modellerin ürettiği hata değerleri, alternatif modelin ürettiği hata değerlerinden daha küçüktür ve bu farklılık istatistiksel açıdan anlamlıdır.

Çalışma bulguları incelendiğinde başlangıçta her bir hisse senedi için hesaplanmış olan 53 adet teknik göstergenin iki tanesinin hiçbir hisse senedi tahmin modelinde tercih edilmediği görülmektedir. Bu teknik göstergeler fiyat-hacim eğilimi ve denge işlem hacmidir. En sık tercih edilen gösterge ise kapanış fiyatının 6 günlük üçgensel hareketli ortalamasıdır. Bu göstergeyi, William's %R değeri ve kapanış fiyatının 5 günlük üçgensel hareketli ortalaması takip etmektedir. Her bir hisse senedinin kendi içsel özellikleri mevcuttur.

Deneylerde nokta tahmini gerçekleştirilmiştir. Fakat çalışmada üretilen tahminler, yön tahmini haline de getirilebilir. Böylelikle çalışmada üretilen fiyat tahminlerinin başarısı başka bir yöntemle daha değerlendirilmiş olmaktadır. Çalışmada optimal yöntemle en yüksek başarı %60 oranında tahmin ile birlikte THYAO isimli hisse senedinde gerçekleştirilmiştir. Buna rağmen çalışmanın esas ağırlığı nokta tahminindedir.

Çalışmada önerilen modelin başarısını ortaya çıkarmak adına kağıt üzerinde alım satım işlemleri gerçekleştirilmiş ve tahmin modelini gerçek hayatta uygulayacak bir yatırımcının elde edeceği getiri oranı hesaplanmıştır. Alım satım simülasyonu adı verilen

bu süreç sonunda, önerilen uzman sistemi kullanan bir yatırımcının, alternatif modeli kullanan yatırımcıya göre daha yüksek oranda getiri elde edebileceği ortaya çıkmıştır. Genetik algoritma ile optimize edilen modelde dönem boyunca kağıt üzerinde alım satımlar yapılmıştır. Bu alım satımlarda vergiler ve komisyon masrafları hesaplamaları kolaylaştırmak için ihmal edilmiştir. Her bir hisse senedinden elde edilen yüzde getiriler toplandığında optimal modelde 2,631 oranında getiri elde edildiği görülmektedir. Bu işlem alternatif model için yapıldığında ise 1,188 değeri elde edilmiştir. Başka bir ifade ile genetik algoritma ile optimizasyon gerçekleştirmek getiri oranında 1,443 oranında bir artış sağlayabilmiştir. Söz konusu 30 adet hisse senedinden optimal modelde 22 adedinde kâr elde edilebilmişken, alternatif modelde bu sayı 19'da sınırlı kalmıştır. Başka bir ifade ile genetik algoritma ile optimizasyon modelinin uygulanması sadece istatistiksel performans ölçülerinde başarı sağlamakla kalmayıp aynı zamanda tahmin modelinin finansal performansını da arttırmıştır.

Çalışmada her bir hisse senedi için eğitim aşamasında ve test aşamasında modellerin gösterdiği tahmin değerleri ile gerçek değerler eklerde grafik halinde sunulmuştur. Söz konusu grafikler incelendiğinde optimal modelin, alternatif modele göre, gerçek fiyatlara daha yakın sonuçlar ürettiği anlaşılmaktadır.

Çalışmada ayrıca risk ve getiri konusu da incelenmiştir. Bu amaçla hisse senetleri iki gruba ayrılmıştır. İlk olarak her bir hisse senedi için getirilerdeki dalgalanma hesaplanmıştır. Risk, standart sapma ile ölçülmüştür. Hisse senetlerini riskli ve risksiz olmak üzere iki gruba ayırmak için standart sapmaların medyan değeri hesaplanmıştır. Bu medyan değerinin altında kalan hisse senetleri risksiz olarak adlandırılmış ve bu medyan değerinin üzerinde kalan hisse senetleri riskli olarak adlandırılmıştır. Her iki gruptaki hisse senetlerinin alım satım işlemleri sonucunda sağladıkları getiri oranları toplanmış ve riskli olarak adlandırılan gruptaki hisse senetlerinin getiri oranının daha yüksek olduğu bulunmuştur. Bunun nedeni kapanış fiyatındaki dalgalanmaların yüksek olmasına bağlı olarak işlem yapıldığında, kâr oranının da daha yüksek olması olabilir. Bu nedenle daha yüksek getiri elde etmeyi düşünen yatırımcılar, kapanış fiyatları daha dalgalı olan hisse senetlerini tercih edebilirler.

Her ne kadar sonuçlar başarılı, hisse senetlerinin fiyatlarının önceki fiyat hareketlerinin bir sonucu olduğu ortaya çıkmaz. Başka bir ifade ile hisse senedinin gelecekteki fiyatları ile geçmişteki fiyatları arasında bir neden sonuç ilişkisi aranmamıştır. Önerilen uzman sistem ile birlikte, yapay sinir ağlarının performansını etkileyecek önemli parametreleri genetik algoritmanın belirlemesi sağlanmaktadır ve hisse senedi fiyatlarının önceden belirli bir düzeye kadar doğru bir şekilde tahmin edilebileceği sonucu ortaya çıkmaktadır.

KAYNAKLAR

- ABBASI, E. ve ABOUEC, A., 2009. "Stock Price Forecast by Using Neuro-Fuzzy Inference System", *International Journal of Human and Social Sciences*, 4 (15), ss. 1136-1139.
- ABOLHASSANI, A.T. ve YAGHOUBI, M., 2010. "Stock Price Forecasting Using PSOSVM", *3rd International Conference on Advanced Computer Theory and Engineering*, 3, ss. 352-356
- ABRAHAM, B. ve LEDOLTER, J., 2005. *Statistical Methods for Forecasting*, 2.Ed., John Wiley & Sons, 459s.
- ACHELIS, S.B., 2001, *Technical Analysis From A to Z*, McGrawHill, New York, 375s.
- ADEBIYI, A., AYO, C., ADEBIYI, M. ve OTOKITI, S., 2012. "Stock Price Prediction Using Neural Network with Hybridized Market Indicators", *Journal of Emerging Trends in Computing and Information Sciences*, 3 (1), ss. 1-9.
- AFOLABI, M.O. ve OLUDE, O., 2007. "Predicting Stock Prices Using a Hybrid Kohonen Self Organizing Map (SOM)", *Preceedings of the 40th Hawaii International Conference on Systems Sciences*, ss. 1-8.
- AGHABABAEYAN, R., SIDDIQUI, T. ve AHMADKHAN, N., 2011. "Forecasting the Tehran Stock Market by Artificial Neural Networks", *International Journal of Advanced Computer Science and Applications*, ss. 13-17.
- AKKOÇ, S., 2012. "An Empirical Comparison of Conventional Techniques, Neural Networks and the Three Stage Hybrid Adaptive Neuro Fuzzy Inference System (ANFIS) Model for credit scoring analysis: The Case of Turkish Credit Card Data", *European Journal of Operational Research*, 222 (1), ss. 168-176.
- ALLEN, F. ve KARJALAINEN, R., 1999. "Using Genetic Algorithms to Find Technical Trading Rules", *Journal of Financial Economics*, 51 (2), ss.245-271.
- ALPAYDIN, E., 2010. *Introduction to Machine Learning*, MIT Press, Cambridge, 579s.
- ALTAN, Ş., 2008. "Döviz Kuru Öngörü Performansı için Alternatif Bir Yaklaşım: Yapar Sınır Ağları", *Gazi Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 10 (2), ss. 141-160.
- ALTAY, E. ve SATMAN, M.H., 2005. "Stock Market Forecasting: Artificial Neural Network and Linear Regression Compariosn in an Emergen Market", *Journal of Financial Management and Analysis*, 18(2), ss. 18-33.
- ARBIB, M.A. (Ed.), 2003. *The Handbook of Brain Theory and Neural Networks*, The MIT Press, London, 1309s.
- ARMANO, G., MARCHESİ, M. ve MURRU, A., 2005. "A Hybrid Genetic-Neural Architecture for Stock Indexes Forecasting", *Information Sciences*, 170, ss. 3-33.
- ATAMAN, Ü. Ve KİBAR, H., 1999. *Hisse Senetlerinin Gerçek Değerinin Hesaplanması*, Türkmen Kitabevi, İstanbul.
- ATSALAKIS, G.S., DİMİTRAKAKİS, E.M. ve ZOPOUNİDİS, C.D., 2011. "Elliot Wave Theory and Neuro-Fuzzy Systems, in *Stock Market Prediction: The WASP System*", *Expert Systems with Applications*, 38 (8), ss. 9196-9206.
- ATSALAKIS, G.S. ve VALAVANİS, K.P., 2010. "Surveying Stock Market Forecasting Techniques – Part I: Conventional Methods", *Journal of Computation Optimization in Economics and Finance*, 2 (2).
- ATSALAKIS, G.S. ve VALAVANİS, K.P., 2009. "Forecasting Stock Market Short-Term Trends Using a Neuro-Fuzzy Based Methodology", *Expert Systems with Applications*, 36 (7), ss. 10696-10707.

- AYGÖREN, H., SARITAŞ, H. ve MORALI, T., 2012. "İMKB100 Endeksinin Yapay Sınır Ağları ve Network Nümerik Arama Modelleri ile Tahmini", Uluslararası Alanya İşletme Fakültesi Dergisi, 4 (1), ss. 73-88.
- BAETGE, J. ve HEITMANN, C., 2000. "Creating a Fuzzy Rule-Based Indicator for the Review of Credit Standing", Schmalenbach Business Review, 52, ss. 318-343.
- BAHRAMMIRZAEI, A., 2010. "A Comparative Survey of Artificial Intelligence Applications in Finance: Artificial Neural Networks, Expert System and Hybrid Intelligent Systems", Neural Computing & Applications, 19 (8), ss.1165-1195.
- BARAK, O., 2008. Davranışsal Finans Teori ve Uygulama. Gazi Kitabevi, Ankara, 341s.
- BASHIRI, M. ve GERANMAYEH, A.F., 2011. "Tuning Parameters of an Artificial Neural Network Using Central Composite Design and Genetic Algorithm", Scientia Iranica, 18 (6), ss. 1600-1608.
- BEECHY, M., GRUEN, D. ve VICKERY, J., 2000. "The Efficient Market Hypothesis: A Survey", Economic Research Department Reserve Bank of Australia, Research Discussion Paper.
- BENHAYOUN, N., CHAIRI, I., GONNOUNI, A.E. ve LYHYAOUI, A., 2013. "Financial Intelligence in Prediction of Firm's Creditworthiness Risk: Evidence from Support Vector Machine Approach", International Conference on Applied Economics, 5, 103-112.
- BERMUDEZ, J.D., SEGURA, J.V. ve VERCHER, E., 2012. "A Multi-Objective Genetic Algorithm for Cardinality Constrained Fuzzy Portfolio Selection", 188 (1), ss.16-26.
- BODIE, Z., KANE, A. ve MARCUS, A., 2003. Essentials of Investments, 8.Ed, McGrawHill Companies, New York, 774s.
- BOLLINGER, J., 2002. "A Survey of Volume Indicators", IFTA Journal, ss. 4:8.
- BREALEY, R.A., MYERS, S.C. ve MARCUS, A.J., 2012. Fundamentals of Corporate Finance, 7.Ed., McGrawHill Companies, New York, 718s.
- BROOKS, C., 2008. Introductory Econometrics for Finance, Cambridge University Press, Cambridge, 674s.
- BURREL, P.R. ve FOLARIN, B.O., 1997. "The Impact of Neural Networks in Finance", Neural Computing & Applications, 6 (4), ss. 193-200.
- CAGINALP, G. ve BALENOVICH, D., 2003. "A Theoretical Foundation for Technical Analysis", Journal of Technical Analysis, Winter-Spring, ss. 5-21.
- CAO, L. ve TAY, F.E.H., 2001. "Financial Forecasting Using Support Vector Machines", Neural Computing & Applications, 10, ss. 184-192.
- CEYLAN, A., 2004. "Sermaye Piyasaları ve Finansal Kurumlar", Ed: Nurhan Aydın, Anadolu Üniversitesi Yayınları,
- CHANG, J.R., WEI, L.Y. ve CHENG, C.H., 2011. "A Hybrid ANFIS Model Based on AR and Volatility for TAIEX Forecasting", Applied Soft Computing, 11 (1), ss. 1388-1395.
- CHANG, P.C., WANG, D.D. ve ZHOU, C.L., 2012. "A Novel Model by Evolving Partially Connected Neural Network for Stock Price Trend Forecasting", Expert Systems with Applications, 39 (1), ss. 611-620.
- CHANG, P.C., LIAO, T.W., LIN, J.J. ve FAN, C.Y., 2011. "A Dynamic Threshold Decision System for Stock Trading Signal Detection", Applied Soft Computing, 11 (5), ss. 3998-4010.
- CHARKHA, P.R., 2008. "Stock Price Prediction and Trend Prediction Using Neural Networks", First International Conference on Emerging Trends in Engineering and Technology. ss. 592-594.

- CHAUDHURI, A. ve DE, K., 2011. "Fuzzy Support Vector Machine for Bankruptcy Prediction", *Applied Soft Computing*, 11 (2), ss. 2472-2486.
- CHEN, H., MA, Y.C, CHEN, M.Z., TANG, Y., WANG, B., CHEN, M. ve YANG, X.G., 2009. "Recovery Discrimination Based on Optimized-Variables Support Vector Machine for Nonperforming Loan, *Systems Engineering – Theory & Practice*, 29 (12), ss. 23 -30.
- CHEN, M.Y., 2013. "A Hybrid ANFIS Model for Business Failure Prediction Utilizing Particle Swarm Optimization and Subtractive Clustering", *Information Sciences*, 220, ss. 180-195.
- CHEN, M.Y. ve ROY, A.F.V., 2011. "Evolutionary Fuzzy Decision Model for Cash Flow Prediction Using Time-Dependent Support Vector Machines", *International Journal of Project Management*, 29 (1), ss. 56-65.
- CHEN, S.H., WANG, P.P. ve KUO, T.W. (Eds), 2007. *Computational Intelligence in Economics and Finance*, Springer, Berlin, 232s.
- CHEN, W.H. ve SHIH, J.Y., 2006. "A Study of Taiwan's Issuer Credit Rating Systems Using Support Vector Machines", *Expert Systems with Applications*, 20 (3), ss. 427-435.
- CHEN, Y. ve ZHANG, G., 2013. "Exchange rates Determination Based on Genetic Algorithms Using Mendel's Principles: Investigation and Estimation Under Uncertainty", 14 (3), ss. 327-333.
- CHENG, C.H., CHEN, T.L. ve WEI, L.Y., 2010. "A Hybrid Model Based on Rough Sets Theory and Genetic Algorithms for Stock Price Forecasting", *Information Sciences*, 180 (9), ss. 1610-1629.
- COLBY, R.W., 2003. *The Encyclopedia of Technical Market Indicators*, McGraw-Hill, New York, 833s.
- ÇELİK, T.T., 2007. "Etkin Piyasa Hipotezi ve Gelişmekte Olan Hisse Senedi Piyasalarında Eşhareketlilik", *Doktora Tezi, İstanbul Teknik Üniversitesi, Sosyal Bilimler Enstitüsü, İstanbul*.
- DAĞLI, H., 2012. *Sermaye Piyasası ve Portföy Analizi*, 4. Baskı, Derya Kitabevi, Trabzon, 374s.
- DASH, M. ve LIU, H., 1997. "Feature Selection for Classification", *Intelligent Data Analysis*, 1, ss. 131-156.
- DENG, S., SUN, Y. ve SAKURAI, A., 2012. "Robustness Test of Genetic Algorithm on Generating Rules for Currency Trading", *Proceedings of the International Neural Network Society Winter Conference*, 13, 86-98.
- DEVORE, J.L. ve BERK, K.N., 2007. *Mathematical Statistics with Applications*, Thomson Brooks/Cole, Davis Drive Belmont, 850s.
- DİLER, A.İ., 2003. "İMKB Ulusal-100 Endeksinin Yönünün Yapay Sinir Ağları Hata Geriye Yayıma Yöntemi ile Tahmin Edilmesi", *İstanbul Menkul Kıymetler Borsası Dergisi*, 7 (25-26), 65-82.
- DIMSON, E. ve MUSSAVIAN, M., 1998. "A Brief History of Market Efficiency", *European Financial Management*, 4(1), ss. 91-193.
- EDWARDS, R.D., MAGEE, J. ve BASSETTI, W.H.C., 2007. *Technical Analysis of Stock Trends*, 9. Bası, Taylor & Francis, New York, 835s.
- EGELİ, B., ÖZTURAN, M. ve BADUR, B., 2003. "Stock Market Prediction Using Artificial Neural Networks", *Decision Support Systems*, ss. 171-185.
- ENGELBRECHT, A.P., 2007. *Computational Intelligence: An Introduction*, John Wiley & Sons, New York, 630.

- ERDEM, E., 2012. Para Banka ve Finansal Sistem, 4. Baskı, Detay Yayıncılık, Ankara, 307s.
- ERDOĞAN, E. ve ÖZYÜREK, H., 2012. "Yapay Sinir Ağları ile Fiyat Tahminlemesi", Sosyal ve Beşeri Bilimler Dergisi, 4 (1), ss. 85-92.
- ERTEL, W., 2011. Introduction to Artificial Intelligence, Springer, London, 329s.
- ESFAHANIPOUR, A. ve AGHAMIRI, W., 2010. "Adapted Neuro-Fuzzy Inference System on Indirect Approach TSK Fuzzy Rule Base for Stock Market Analysis", Expert Systems with Applications, 37 (7), ss. 4742-4748.
- EVANS, C., PAPPAS, K. ve XHAFA, F., 2013. "Utilizing Artificial Neural Networks and Genetic Algorithms to Build an Algo-Trading Model for Intra-Day Foreign Exchange Speculation", Mathematical and Computer Modelling, 58 (5-6), ss. 1249-1266.
- FAMA, E., 1969. "Efficient Capital Markets: A Review of Theory and Empirical Work", The Journal of Finance, 25 (2), ss. 383-417.
- FAMA, E. ve BLUME, M., 1966. "Filter Rules and Stock-Market Trading", The Journal of Business, 39 (1), ss. 226-241.
- FAMA, E., 1965. "Tomorrow on the New York Stock Exchange". The Journal of Business, 38 (3), ss. 285-299.
- FLOUDAS, C.A. ve PARDALOS, P.M. (Eds), 2008. Encyclopedia of Optimization, 2.Ed, Springer, New York, 4646s.
- FONG, K.Y.T., 2013. "Regime Switching Trading Bands Using A Historical Simulation Approach", IFTA Journal, ss. 20-27.
- FU, T.C., CHUNG, C.P. ve CHUNG, F.L., 2013. "Adopting Genetic Algorithms for Technical Analysis and Portfolio Management", Computers and Mathematics with Applications, 66 (10), ss. 1743-1757.
- GEN, M. ve CHENG, R., 2000. Genetic Algorithms and Engineering Optimization, Wiley & Sons, New York, 511s.
- GROSSMAN, S.J. ve STIGLITZ, J.E., 1980. "On the Impossibility of Informationally Efficient Markets", The American Economic Review, ss. 393-408.
- GUPTA, M.M., JIN, L. ve HOMMA, N., 2003. Static and Dynamic Neural Networks from Fundamentals to Advanced Theory, IEEE Press, New Jersey, 751s.
- GURESEN, E, KAYAKUTLU, G ve DAIM, T., 2011. "Using Artificial Neural Network Models in Stock Market Index Prediction", Expert Systems with Applications, 38 (8), ss. 10389-10397.
- GUYON, I. ve ELISSEEFF, A., 2003. "An Introduction to Variable and Feature Selection", Journal of Machine Learning Research, 3, ss. 1157-1182.
- GÜNGÖR, B. ve TORTU, A., 2007. Esnek Hesaplama Teknikleri ile Hisse Senedi Fiyat Tahminleri, İmaj Yayıncılık, Ankara, 226s.
- HADAVANDI, E., SHAVANDI, H. ve GHANBARI, A., 2010. "A Genetic Fuzzy Expert System for Stock Price Forecasting", Seventh International Conference on Fuzzy Systems and Knowledge Discovery, ss. 41-44.
- HAGAN, M.T., DEMUTH, H.B. ve BEALE, M., 1996. Neural Network Design, PWS Publishing, New York, 734.
- HAMILTON, J.D., 1994. Time Series Analysis, Princeton University Press, New Jersey, 800s.
- HAN, L., HAN, L. ve ZHAO, H., 2013. "Orthogonal Support Vector Machine for Credit Scoring", Engineering Applications of Artificial Intelligence, 26 (2), ss. 848-862.

- HAO, H.N., 2010. "Short-Term Forecasting of Stock Price Based on Genetic-Neural Network", Sixth International Conference on Natural Computation, ss. 1838-1841.
- HARRIS, T., 2013. "Quantitative Credit Risk Assessment Using Support Vector Machines: Broad versus Narrow Default Definitions", Expert Systems with Applications, 40 (11), ss. 4404-4413.
- HASTIE, T., TIBSHIRANI, R. ve FRIEDMAN, J., 2009. The Elements of Statistical Learning: Data Mining, Inference, and Prediction, Springer, Berlin, 763s.
- HAYKIN, S., 1999. Neural Networks: A Comprehensive Foundation, Pearson Education, Delhi, 823s.
- HEBB, D.O., 1949. The Organization of Behavior: A Neuropsychological Theory, John Wiley & Sons, London, 365s.
- HOLLAND, J.H., 1992. Adaptation in Natural and Artificial Systems, THE MIT Press, London, 200s.
- HOMAYOUNI, N. ve AMIRI, A., 2011. "Stock Price Prediction Using a Fusion Model of Wavelet, Fuzzy Logic and ANN", International Conference on E-Business, Management and Economics, Singapore, 25, ss. 277-281.
- HSIEH, L.F., HSIEH, S.C. ve TAI, P.H., 2011. "Enhanced Stock Price Variation Prediction via DOE and BPNN-based Optimization", Expert Systems with Applications, 38 (11), ss. 14178-14184.
- HSIEH, T.J., HSIAO, H.F. ve YEH, W.C., 2012. "Mining Financial Distress Trend Data Using Penalty Guided Support Vector Machines Based on Hybrid of Particle Swarm Optimization and Artificial Bee Colony Algorithm", Neurocomputing, 82 (1), ss.196-206.
- HSU, C.M., 2011. "A Hybrid Procedure for Stock Price Prediction by Integrating Self-Organizing Map And Genetic Programming", Expert Systems with Applications, 38 (11), ss. 14026-14036.
- HSU, S.H., HSIEH, J.P.A., CHIH, T.C. ve HSU, K.C., 2009. "A two-stage architecture for stock price forecasting by integrating self-organizing map and support vector regression", Expert Systems with Applications, 36 (4), ss. 7947-7951.
- HUANG, C.F., 2012. "A Hybrid Stock Selection Model Using Genetic Algorithms and Support Vector Regression", Applied Soft Computing, 12 (2), ss. 807-818.
- HUANG, C.J., YANG, D.X. ve CHUANG, Y.T., 2008. "Application of Wrapper Approach and Composite Classifier to the Stock Trend Prediction", Expert Systems with Applications, 34 (4), ss. 2870-2878.
- HUANG, W., NAKAMORI, Y. ve WANG, S.Y., (2005). "Forecasting Stock Market Movement Direction with Support Vector Machine", Computers & Operations Research, 32, ss. 2513-2522.
- HUANG, Z., CHEN, H., HSU, C.J., CHEN, W.H. ve WU, S., 2004. "Credit Rating Analysis with Support Vector Machines and Neural Networks: A Market Comparative Study", Decision Support Systems, 37 (4), ss. 543-558.
- INCE, T. ve TRAFALIS, T.B., 2007. "Kernel Principle Component Analysis and Support Vector Machines for Stock Price Prediction", IIE Transactions, 39, ss. 629-637.
- INUIGUCHI, M. ve RAMIK, J., 2000. "Possibilistic Linear Programming: A Brief Review of Fuzzy Mathematical Programming and a Comparison with Stochastic Programming in Portfolio Selection Problem", Fuzzy Sets and Systems, 111, ss. 3-28.
- JACKSON, A., 1997. "Genetic Algorithm for Use in Financial Problems", IAA AFIR Colloquium Cairns.

- JANG, J.S.R., 1993. "ANFIS: Adaptive-Network-Based Fuzzy Inference System", IEEE Transactions on Systems, Man and Cybernetics, 23 (3), ss. 665-685.
- JANG, J.S.R., SUN, C.T. ve MIZUTANI, E., 1997. Neuro-Fuzzy and Soft Computing: A Computational Approach to Learn and Machine Intelligence, Prentice-Hall, New Jersey, 640s.
- JENSEN, R. ve SHEN, Q., 2008. Computational Intelligence and Feature Selection Rough and Fuzzy Apporaches, IEEE Press, New Jersey, 357s.
- JOHN, G.H., KOHAVI, R. ve PFLEGER, K., 1994. "Irrelevant Features and the Subset Selection Problem", Machine Learning: Proceedings of the Eleventh International Conference, ss. 121-129.
- KALAYCI, Ş. ve KARATAŞ, A., 2005. "Hisse Senedi Getirileri ve Finansal Oranlarla İlişkisi: İstanbul Menkul Kıymetler Borsasında Bir Temel Analiz Araştırması", Muhasebe ve Finansman Dergisi, 9 (27), ss. 146-157.
- KAO, L.J., CHIU, C.C., LU, C.J. ve YANG, J.L., 2013. "Integration of Nonlinear Independent Compotent Anaylsis and Support Vector Regression for Stock Price Forecasting", Neurocomputing, 99, ss. 534-542.
- KAR, S., DAS, S. ve GHOSH, P. K., 2014. "Applications of Neuro Fuzzy Systems: A Brief Review and Future Outline", Applied Soft Computing, 15, ss. 243-259.
- KARA, Y., BOYACIOĞLU, M.A. ve BAYKAN, Ö.K., 2011. "Predicting Direction of Stock Price Index Movement Using Artificial Neural Networks and Support Vector Machines: The Sample of the Istanbul Stock Exchange", Expert Systems with Applications, 38 (5), ss. 5311-5319.
- KARAATLI, M., GÜNGÖR, İ., DEMİR, Y. ve KALAYCI, Ş., 2005. "Hisse Senedi Fiyat Hareketlerinin Yapay Sinir Ağları Yöntemi ile Tahmin Edilmesi", Balıkesir Üniversitesi Bandırma İktisadi ve İdari Bilimler Fakültesi Akademik Fener Dergisi, 2 (1), ss. 22-48.
- KARACA, S.S. ve BAŞDEMİR, H.N., 2012. "The Applicability of Artificial Neural Network Method upon Prediction of Rate of Stock Return: Example of 2008 Financial Crisis", Journal of Applied Economic Sciences, 7 (2), ss.131-140.
- KARAN, M.B., 2011. Yatırım Analizi ve Portföy Yönetimi, 3. Baskı, Gazi Kitabevi, Ankara, 742s.
- KAUFMAN, P.J., 1998. Trading Systems and Methods, John Wiley & Sons, New York, 695s.
- KECMAN, V., 2001. Learning and Soft Computing, The MIT Press, London, 576.
- KELES, A., KOLCAK, M. ve KELES, A., 2008. "The Adaptive Neuro-Fuzzy Model for Forecasting the Domestic Debt", 21 (8), ss. 951-957.
- KIM, H.S. ve SOHN, S.Y., 2010. "Support Vector Machines for Default Prediction of SMEs Based on Technology Credit", European Journal of Operational Research, 201 (3), ss. 838-846.
- KIM, K.J., 2003. "Financial Time Series Forecasting Using Support Vector Machines", Neurocomputing, 55 (1-2), 307-319.
- KIM, K.J. ve AHN, H., 2012. "A Corporate Credit Rating Model Using Multi-Class Support Vector Machines with an Ordinal Pairwise Partitioning Approach", Computers & Operations Research, 39 (8), ss. 1800-1811.
- KIM, K.J. ve LEE, W.B., 2004. "Stock Market Prediction Using Artificial Neural Networks with Optimal Feature Transformation", Neural Computing & Applications, 13 (3), ss. 255-260.

- KIM, K.J. ve HAN, I., 2000, "Genetic Algorithms Approach to Feature Discretization in Artificial Neural Networks for the Prediction of Stock Price Index", *Expert Systems with Applications*, 19 (2), ss. 125-132.
- KIM, M.J. ve KANG, D.K., 2014. "Classifiers Selection in Ensembles using Genetic Algorithms for Bankruptcy Prediction", *Expert Systems with Applications*, 39 (10), ss. 9308-9314.
- KIRKPATRICK, C.D. ve DAHLQUIST, J.R., 2007. *Technical Analysis: The Complete Resource for Financial Market Technicians*, FT Press, New Jersey, 656s.
- KIYILAR, M., 1997. *Etkin Pazar Kuramı ve Etkin Pazar Kuramının İMKB'de İrdelenmesi*. Sermaye Piyasası Kurulu. Yayın No: 86.
- KOHAVI, R. ve JOHN, G.H., 1997. "Wrappers for Feature Subset Selection", *Artificial Intelligence*, 97, ss. 273-324.
- KOHONEN, T., 2001. *Self-Organizing Maps*, 3rd Ed., Springer, Berlin, 260s.
- KONAR, A., 2005. *Computational Intelligence: Principles, Techniques and Applications*, Springer, Berlin, 713s.
- KORDON, A.K., 2010. *Applying Computational Intelligence How to Create Value*, Springer, Berlin, 470s.
- LANGLEY, P. 1994. "Selection of Relevant Features in Machine Learning", *AAAI Technical Report*, FS-94-02. ss.127-131.
- LAWRENZ, C. ve WESTERHOFF, F., 2003. "Modeling Exchange Rate Behavior with a Genetic Algorithm", *Computational Economics*, 21 (3), ss. 209-229.
- LEE, C.C. ve LEE, J.D., 2009. "Energy Prices, Multiple Structural Breaks, and Efficient Market Hypothesis", *Applied Energy*, 86 (4), ss. 466-479.
- LEE, C.C., LEE, J.D. ve LEE, C.C., 2010. "Stock Prices and the Efficient Market Hypothesis: Evidence From A Panel Stationary Test with Structural Breaks", *Japan and the World Economy*, 22 (1), ss. 49-58.
- LEE, M.C., 2009. "Using Support Vector Machine with a Hybrid Feature Selection Method to the Stock Trend Prediction", *Expert Systems with Applications*, 36 (8), ss.10896-10904.
- LI, F. ve LIU, C., 2009. "Application Study of BP Neural Network on Stock Market Prediction", *Ninth International Conference on Hybrid Intelligent Systems*. ss. 174-178.
- LI, H., LI, C.J., WU, X.J. ve SUN, J., 2014. "Statistics-Based Wrapper for Future Selection: An Implementation on Financial Distress Identification with Support Vector Machine", *Applied Soft Computing*, 19, ss. 57-67.
- LI, H. ve SUN, J., 2011. "Predicting Business Failure Using Support Vector Machines with Straightforward Wrapper: A Re-Sampling Study", *Expert Systems with Applications*, 38 (10), ss. 12747-12756.
- LI, J., LI, G., SUN, D. ve LEE, C.F., 2012. "Evolution Strategy Based Adaptive Lp Penalty Support Vector Machines with Gauss Kernel for Credit Risk Analysis", *Applied Soft Computing*, 12 (8), ss.2675-2682.
- LI, S.T., SHIUE, W. ve HUANG, M.H., 2006. "The Evaluation of Consumer Loans Using Support Vector Machines", *Expert Systems with Applications*, 30 (4), ss. 772-782.
- LI, Y. ve MA, W., 2010, "Applications of Artificial Neural Networks in Financial Economics: A Survey", *International Symposium on Computational Intelligence and Design*, ss. 211-214.

- LIN, F., YEH, C.C. ve LEE, M.Y., 2011. "The Use of Hybrid Manifold Learning and Support Vector Machines in the Prediction of Business Failure", *Knowledge-Based Systems*, 24 (1), ss. 95-101.
- LIN, X., YANG, Z. ve SONG, Y., 2011. "Intelligent Stock Trading System Based on Improved Technical Analysis and Echo State Network", *Expert Systems with Applications*, 38 (9), ss. 11347-11354.
- LIU, C.F., YEH, C.Y. ve LEE, S.J., 2012. "Application of Type-2 Neuro-Fuzzy Modeling in Stock Price Prediction", *Applied Soft Computing*, 12 (4), ss. 1348-1358.
- LIU, H. ve MOTODA, H. (Eds.), 2008. *Computational Methods of Feature Selection*, Taylor & Francis Group, New York, 411s.
- MALHOTRA, R. ve MALHOTRA, D.K., 2002. "Differentiating Between Good Credits and Bad Credits Using Neuro-Fuzzy Systems", *European Journal of Operational Research*, 136, ss. 190-211.
- MALKIEL, B.G., 2003. "The Efficient Market Hypothesis and Its Critics", *Journal of Economic Perspectives*, 17 (1), ss. 59-82.
- MAYO, H.B., 2008. *Investments: An Introduction*, 9.Ed., Thomson South-Western, Natorp Boulevard Mason, 929s.
- MCCULLOCH, W.S. ve PITTS, W.H., 1943., "A Logical Calculus of the Ideas Immanent in Nervous Activity", *Bulletin of Mathematical Biophysics*, 5, ss.115-133.
- MCNELIS, P.D., 2005. *Neural Networks in Finance: Gaining Predictive Edge in the Market*, Elsevier Academic Press, 261s.
- MICHALEWICZ, Z., 1996. *Genetic Algorithms + Data Structures = Evolution Programs*. Springer, Berlin, 388s.
- MIN, S.H., LEE, J. ve HAN, I., 2006. "Hybrid Genetic Algorithms and Support Vector Machines for Bankruptcy Prediction", *Expert Systems with Applications*, 31 (3), ss. 652-660.
- MIRMIRANI, S. ve LI, H.C., 2004. "Gold Price, Neural Networks and Genetic Algorithm", *Computational Economics*, 23 (2), ss. 193-200.
- MISHKIN, F.S., 2004. *The Economics of Money, Banking and Financial Markets*, 7.Ed., Pearson, New York, 850s.
- MITCHELL, M., 1999. *An Introduction to Genetic Algorithms*, The MIT Press, London, 162s.
- MOAYER, S. ve BAHRI, P.A., 2009. "Hybrid Intelligent Scenario Generator for Business Strategic Planning by Using ANFIS", *Expert Systems with Applications*, 36 (4), ss. 7729-7737.
- MOSTAFA, M.M., 2010. "Forecasting Stock Exchange Movements Using Neural Networks: Empirical Evidence From Kuwait", *Expert Systems with Applications*, 37 (9), ss. 6302-6309.
- MOYER, R.C., MCGUIGAN, J.R. ve KRETLOW, W.J., 2006. *Contemporary Financial Management*, 10.Ed., Thomson South-Western, Natorp Boulevard Mason, 901s.
- MURPHY, J.J., 1999. *Technical Analysis of the Financial Markets: A Comprehensive Guide to Trading Methods and Applications*, New York Institute of Finance, New York, ss.585.
- MUTH, J.F., 1961. "Rational Expectations and the Theory of Price Movements", *Econometrica*, 29 (3), ss. 315-335.
- NAIR, B.B., MINUVARTHINI, M., SUJITHRA, B. ve MOHANDAS, V.P., 2010. "Stock Market Prediction Using a Hybrid Neuro-Fuzzy System", *International*

- Conference on Advances in Recent Technologies in Communication and Computing, ss. 243-247.
- NEDOVIC, L. ve DEDEDZIC, V., 2002. "Expert Systems in Finance – A Cross- Section of the Field", *Expert Systems with Finance*, 23 (1), ss. 49-66.
- NGIA, L.S. ve SJÖBERG, J., 2000. "Efficient Training of Neural Nets for Nonlinear Adaptive Filtering Using a Recursive Levenberg-Marquardt Algorithm", *IEEE Transactions on Signal Processing*, 48 (7), ss. 1915-1927.
- NI, L.P., NI, Z.W. ve GAO, Y.Z., 2011. "Stock Trend Prediction Based on Fractal Feature Selection and Support Vector Machine", *Expert Systems with Applications*, 38 (5), ss. 5569-5576.
- NISBET, R., ELDER, J. ve MINER, G. 2009. *Handbook of Statistical Analysis and Data Mining, Applications*, Elsevier, London, 860s.
- NOURANI, E., RAHMANI, A.M. ve NAVIN, A.H., 2012. "Forecasting Stock Prices Using a Hybrid Artificial Bee Colony Based Neural Network", *International Conference on Innovation, Management and Technology Research*, Malaysia. ss. 486-490.
- NUNEZ-LETAMENDIA, L. 2007., "Fitting the Control Parameters of a Genetic Algorithm: An Application to Technical Trading Systems Design", *European Journal of Operational Research*, 179 (3), ss. 847-868.
- OK, Y., ATAĞ, M. ve AKÇAYOL, M.A., 2011. "Yalın Sinirsel Bulanık Bir Model ile IMKB 100 Endeksi Tahmini", *Gazi Üniversitesi Mühendislik ve Mimarlık Fakültesi Dergisi*, 26 (4), ss. 897-904.
- OMIDI, A., NOURANI, E. ve JALILI, M., 2011. "Forecasting Stock Prices Using Financial Data Mining and Neural Network", *3rd International Conference on Computer Research and Development*, 3, ss. 242-246.
- ORESKE, S. ve ORESKE, G., 2014. "Genetic Algorithm-Based Heuristic for Feature Selection in Credit Risk Assessment", *Expert Systems with Applications*, 41 (4), ss. 2052-2064.
- ÖĞÜT, H., AKTAŞ, R., ALP, A. ve DOĞANAY, M.M., 2009. "Prediction of Financial Information Manipulation by Using Support Vector Machine and Probabilistic Neural Networks", *Expert Systems with Applications*, 36 (3), ss. 5419-5423.
- ÖZ, B., AYRIÇAY, Y. ve KALKAN, G., 2011. "Finansal Oranlarla Hisse Senedi Getirilerinin Tahmini: IMKB 30 Endeksi Hisse Senetleri Üzerine Diskriminant Analizi ile Bir Uygulama", *Anadolu Üniversitesi Sosyal Bilimler Dergisi*, 11 (3), ss. 51-64.
- ÖZALP, A. ve ANAGÜN, A.S., 2001. "Sektörel Hisse Senedi Fiyat Tahmininde Yapay Sinir Ağları Yaklaşımı ve Klasik Tahminleme Yöntemleri ile Karşılaştırılması", *Endüstri Mühendisliği*, 12 (3-4), ss. 2-17.
- ÖZÇALICI, M., PAKSOY, H.M. ve PAKSOY, S., 2014. "Comparing the Performances of Different Trading Strategies Using BIST100 Index", *International Conference on Economic and Social Studies, ICESOS'14*, Sarajevo, Bosnia and Herzegovina.
- ÖZÇALICI, M. ve AYRIÇAY, Y., 2013., "Forecasting Exchange Rates Using Nonlinear Autoregressive Neural Networks", *International IIE Conference & YAEM'13*, İstanbul.
- ÖZÇALICI, M., 2011. "Özdüzenleyici Haritalarla Banka Müşterilerinin Bölümlendirilmesi", *Yüksek Lisans Tezi*, Gaziantep Üniversitesi Sosyal Bilimler Enstitüsü, Gaziantep, 2011.

- ÖZDEMİR, A.K., TOLUN, S. ve DEMİRCİ, E., 2011. “Endeks Getirisi Yönünün İkili Sınıflandırma Yöntemiyle Tahmin Edilmesi: İMKB-100 Endeksi Örneği”, Niğde Üniversitesi İİBF Dergisi, 4 (2), ss. 45-59.
- PAI, P.F. ve LIN, C.S., 2005. “A Hybrid ARIMA and Support Vector Machines Model in Stock Price Forecasting”, Omega, 33 (6), ss.497-505.
- PALIT, A.K. ve POPOVIC, D., 2005. Computational Intelligence in Time Series Forecasting: Theory and Engineering Applications, Springer, London, 382s.
- PAN, W.T., 2010. “Performing Stock Price Prediction Use of Hybrdi Model”, Chinese Management Studies, 4 (1), ss. 77-86.
- PATTAMAVORAKUN, S. ve PATTAMAVORAKUN, S., 2007. “Determination the Number of Hidden Nodes of Recurrent Neural Networks for River Flow and Stock Price Forecasting”, Fifth International Conference on Software Engineering Research, Management and Applications, ss. 184-191.
- PEREIRA, R., 2000. “Genetic Algorithm Optimisation for Finance and Investment”, La Trobe University Discussion Papers, A00.02.
- POOLE, D.L. ve MACKWORTH, A.K., 2010. Artificial Intelligence: Foundations of Computational Agents, Cambridge University Press, New York, 682s.
- RAFIEL, F.M., MANZARI, S.M. ve BOSTANIAN, S., 2011. “Financial Health Prediction Models Using Artificial Neural Networks, Genetic Algorithm and Multivariate Discriminant Analysis: Iranian Evidence”, Expert Systems with Applications, 38 (8), ss. 10210-10217.
- ROSENBLATT, F., 1958. “The Perceptron: A Probabilistic Model for Information Storage and Organization in the Brain”, Psychological Review, 65 (6), ss. 386-408.
- ROSS, S.A., WESTERFIELD, R. ve JAFFE, J., 2003. Corporate Finance, 6.Ed., New York, 971s.
- RUTKOWSKI, L., 2005. Computational Intelligence: Methods and Techniques, Wydawnictwo Naukowe, Warszawa, 519s.
- SAKAWA, M., 2002. Genetic Algorithms and Fuzzy Multiobjective Optimization, Kluwer Academic Publishers, Boston, 300s.
- SALEHI, M., KHODADADI, V. ve ABDOLKHANI, H., 2011. “Forecasting Stock Price Using Artificial Neural Networks: A Multi-layer Perception Model – Iranian Evidence”, Scientific Research and Essays, 6 (19), ss. 4029-4038.
- SCARBOROUGH, D. ve SOMERS, M.J., 2006. Neural Networks in Organizational Research: Applying Pattern Recognition to the Analysis of Organizational Behavior, American Psychological Association, Washington DC, 176s.
- SCHWAGER, J.D., 1999. Getting Started in Technical Analysis, John Wiley & Sons, New York, 333s.
- SEWELL, M., 2011. “History of the Efficient Market Hypothesis”, UCL Department of Computer Science, RN/11/04.
- SHEKARIAN, E. ve GHOLIZADEH, A.A., 2013. “Application of Adaptive Network Based Fuzzy Inference System Method in Economic Welfare”, Knowledge-Based Systems, 39, ss. 151-158.
- SHIN, K.S., LEE, T.S. ve KIM, H.J., 2005. “An Application of Support Vector Machines in Bankruptcy Prediction Model”, Expert Systems with Applications, 28 (1), ss. 127-135.
- SIEGEL, J.G., 2000. International Encyclopedia of Technical Analysis, AMACOM Books, New York, 351s.

- STRABBURG, J., MARTEL, C.G. ve ALEXANDROV, V., 2012. "Parallel Genetic Algorithms for Stock Market Trading Rules", *Procedia Computer Science*, 9, 1306-1313.
- SUMATHI, S. ve SUREKHA, P., 2010. *Computational Intelligence Paradigms: Theory and Applications Using Matlab*, CRC Press, New York, 834.
- SUN, J. ve LI, H., 2012. "Financial Distress Prediction Using Support Vector Machines: Ensemble vs. Individual", *Applied Soft Computing*, 12 (8), 2254-2265.
- SVANANDAM, S.N. ve DEEPA, S.N., 2008. *Introduction to Genetic Algorithms*, Springer, New York, 453s.
- ŞENOL, D., 2008. "Prediction of Stock Price Direction by Artificial Neural Network Network Approach", *Yüksek Lisans Tezi*, Boğaziçi Üniversitesi, İstanbul.
- TAN, Z., QUEK, C. ve CHENG, P.Y.K., 2011. "Stock Trading with Cycles: A Financial Applications of ANFIS and Reinforcement Learning", *Expert Systems with Applications*, 38 (5), ss. 4741-4755.
- TEKTAŞ, A. ve KARATAŞ, A., 2004. "Yapay Sinir Ağları ve Finans Alanına Uygulanması: Hisse Senedi Fiyat Tahminlemesi", *Atatürk Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 18 (3-4), ss. 337-349.
- THORP, W.A., 2000. "ID'ing When to Buy and Sell Using the Stockstochastic Oscillator", *American Association of Individual Investors Journal*, October, ss. 24-34.
- TORAMAN, C., 2008. "Demir-Çelik Sektöründe Yapay Sinir ağları ile Hisse Senedi Fiyat Tahmini: Erdemir A.Ş. ve Kardemir A.Ş. Üzerine Bir Tahmin", *Muhasebe ve Finansman Dergisi*, 39, ss. 44-57.
- TOSUNOĞLU, N.G. ve BENLİ, Y.K., 2012. "Morgan Stanley Capital International Türkiye Endeksinin Yapay Sinir Ağları ile Öngörüsü", *Ege Akademik Bakış*, 12 (4), ss. 541-547.
- TSAI, C.F. ve HSIAO, Y.C., 2010. "Combining Multiple Feature Selection Methods for Stock Prediction: Union, Intersection and Multi-intersection Approaches", *Decision Support Systems*, 50 (1), ss. 258-269.
- VAPNIK, V. N., 2000. *The Nature of Statistical Learning Theory*, 2nd Ed., Springer, New York, 332s.
- VARETTO, F., 1998. "Genetic Algorithms Applications in the Analysis of Insolvency Risk", *Journal of Banking & Finance*, 22 (10-11), ss. 1421-1429.
- VOGES, K.E. ve POPE, N.K., 2006. *Business Applications and Computational Intelligence*, IDEA Group Publishing, London, 499s.
- WANG, Y.F., 2002. "Predicting Stock Price Using Fuzzy Grey Prediction System", *Expert Systems with Applications*, 22, ss. 33-39.
- WANG, J.Z., WANG, J.J., ZHANG, Z.G. ve GUO, S.P., 2011. "Forecasting Stock Indices with Back Propagation Neural Network", *Expert Systems with Applications*, 38 (11), ss.14346-14355.
- WIDROW, B. ve HOFF, M.E., 1960. "Adaptive Switching Circuits", *IRE WESCON Convention Record*, New York IRE, ss. 96-104.
- WONG, B.K. ve SELVİ, Y., 1998. *Neural Network Applications in Finance: A Review and Analysis of Literature (1990-1996)*, *Information & Management*, 34 (3), ss. 129-139.
- WU, C.H., TZENG, G.H., GOO, Y.J. ve FANG, W.C., 2007. "A Real-Valued Genetic Algorithm to Optimize the Parameters of Support Vector Machine for Predicting Bankruptcy", *Expert System with Application*, 32 (2), ss. 397-408.

- WU, J.Y. ve LU, C.L., 2012. "Computational Intelligence Approaches for Stock Price Forecasting", International Symposium on Computer, Consumer and Control, ss. 52-55.
- XU, X., ZHOU, C. ve WANG, Z., 2009. "Credit Scoring Algorithm Based on Link Analysis Ranking with Support Vector Machine", Expert Systems with Applications, 36 (2), ss. 2625-2632.
- YALVAÇ, E.F., 2011. "Event Studies and the Efficient Market Hypothesis-Evidence from Turkish Merger Announcements", Doktora Tezi, Marmara Üniversitesi Sosyal Bilimler Enstitüsü, İstanbul.
- YANG, K., WI, M. ve LIN, J., 2012. "The Application of Fuzzy Neural Network in Stock Price Forecasting Basad on Genetic Algorithm Discovering Fuzzy Rules", 8th International Conference on Natural Computation, ss. 470-474.
- YANG, W., 2007. "Stock Price Prediction Based on Fuzzy Logic", Proceeding of the Sixth International Conference on Machine Learning and Cybernetics, ss. 1309-1314.
- YANG, X., 2006. "Improving Portfolio Efficiency: A Genetic Algorithm Approach", Computational Economics, 28 (1), ss. 1-14.
- YEH, C.C., CHI, D.J. ve HSU, M.F., 2010. "A Hybrid Approach of DEA, Rough Set and Support Vector Machines for Business Failure Prediction", Expert Systems with Applications, 37 (2), ss. 1535-1541.
- YILDIZ, B., YALAMA, A. ve COSKUN, M., 2008. "Forecasting the Istanbul Stock Exchange National 100 Index Using an Artificial Neural Network, World Academy of Science, Engineering and Technology, 46, ss. 36-39.
- YU, L. ve LIU, H., 2004. "Efficient Feature Selection via Analysis of Relevance and Redundancy, Journal of Machine Learning Research, 5, ss. 1205-1224.
- YU, L., YUE, W., WANG, S. ve LAI, K.K., 2010. "Support Vector Machine Based Multiagent Ensemble Learning for Credit Risk Evaluation", Expert Systems with Applications. 37 (2), ss. 1351-1360.
- YU, L., WANG, S. ve LAI, K.K., 2005. "Mining Stock Market Tendency Using GA-Based Support Vector Machines", Internet and Network Economics Lecture Notes in Computer Sciences, 3828, ss. 336-345.
- YÜMLÜ, S., GÜRGEN, F.S. ve OKAY, N., 2005. "A Comparison of Global, Recurrent and Smoothed-Piecewise Neural Models for Istanbul Stock Exchange (ISE) Prediction", Pattern Recognition Letters, 26 (13), ss. 2093-2103.
- ZADEH, L., 1965. "Fuzzy Sets", Information and Control, 8, ss. 338-353.
- ZHAI, F., WEN, Q., YANG, Z. ve SONG, Y., 2010. "Hybrid Forecasting Model Research on Stock Data Mining", 4th International Conference on New Trends in Information Science and Service Science, ss. 630-633.
- ZHU, B. ve WEI, Y., 2013. "Carbon Price Forecasting with a Novel Hybrid ARIMA and Least Squares Support Vector Machines Methodology", Omega, 41 (3), ss. 517-524.

ÖZ GEÇMİŞ

Kişisel Bilgiler

Adı – Soyadı : Mehmet ÖZÇALICI
Doğum Yeri ve Tarihi : Gaziantep – 02/01/1986

Eğitim Durumu

Lisans Öğrenimi : Gaziantep Üniversitesi - İİBF
Yüksek Lisans Öğrenimi : Gaziantep Üniversitesi – Sosyal Bilimler
Enstitüsü – İşletme Ana Bilim Dalı
Doktora Öğrenimi : Kahramanmaraş Sütçü İmam Üniversitesi –
Sosyal Bilimler Enstitüsü – İşletme Ana Bilim
Dalı
Bildiği Yabancı Diller : İngilizce
Bilimsel Faaliyetleri :

İş Deneyimi

Stajlar : -
Projeler : -
Çalıştığı Kurumlar : Kilis 7 Aralık Üniversitesi – Araştırma
Görevlisi (2009 -)

İletişim


E-Posta Adresi : mozcalici@gmail.com
mozcalici@kilis.edu.tr
Tel. : -
Tarih :

EK 1. EĞİTİM VERİ SETİ ŞEKİLLERİ


Bu ekte eğitim setindeki gerçek fiyatlar, optimal modelin tahmin ettiği fiyatlar ve alternatif modelin tahmin ettiği fiyatlar grafik halinde sunulmuştur. Hisse senetleri alfabetik halde sıralanmıştır.

Şekillerdeki;


- Gerçek fiyat; düz siyah çizgiyle;
- Optimal modelin tahmin ettiği fiyat; kesikli kırmızı çizgiyle;
- Alternatif modelin tahmin ettiği fiyat ise kesikli siyah çizgi ile gösterilmiştir.




01-)



02-)




03-)




04-)




05-)




06-)




07-)




08-)




09-)




10-)




11-)




12-)




13-)




14-)




15-)




16-)




17-)




18-)




19-)




20-)



21-)




22-)




23-)




24-)




25-)




26-)




27-)



28-)



29-)



30-)



EK 2. TEST VERİ SETİ ŞEKİLLERİ

Bu ekteki her şekil iki ana bölümden oluşmaktadır. Şekillerin üst kısımlarında test süresi boyunca tahmin edilen fiyatlar ve aynı döneme ilişkin gerçek fiyatlar yer almaktadır. Şekillerin üst kısımlarında;



- Gerçek fiyatlar; koyu kalın düz çizgiyle
- Alternatif modelin tahmin ettiği fiyatlar; kesikli çizgiyle;
- Optimal modelin tahmin ettiği fiyatlar; üzerinde artı işareti olan kesikli çizgi ile gösterilmektedir.

Şekillerin altında kalan ikinci grafikte ise hata miktarları yer almaktadır. Hata terimi, gerçek fiyat ile tahmin edilen fiyat arasındaki farkın mutlak değeri olarak tanımlanmıştır. Şekillerin alt kısımlarında;



- Alternatif hata; kesikli çizgiyle;
- Optimal modele ilişkin hata; üzerinde artı işareti olan noktalı çizgi ile gösterilmektedir.





01-)





02-)





03-)





04-)





05-)





06-)





07-)





08-)





09-)





10-)





11-)





12-)





13-)





14-)





15-)





16-)





17-)





18-)





19-)





20-)





21-)





22-)





23-)





24-)





25-)





26-)





27-)



28-)



29-)




30-)

EK 3. TEST VERİ SETİ DAĞILIM GRAFİKLERİ


Aşağıdaki şekillerde gerçek fiyatlar ile tahmin edilen fiyatlar arasındaki ilişki dağılım grafiği ile gösterilmiştir. Dağılım grafiklerinde, gerçek fiyatlar yatay ekseninde, optimal modelin tahmin ettiği fiyatlar ise dikey ekseninde gösterilmektedir. Grafiklere doğrusal regresyon doğrusu da eklenmiştir. Böylelikle optimal modelin tahmin ettiği fiyatlar ile gerçek fiyatlar arasındaki ilişki daha net gösterilmeye çalışılmıştır.

Hisse senetleri alfabetik sıraya göre sıralanmıştır. Her şekil iki ana bölümden oluşmaktadır. Şekillerin üst kısımlarında test süresi boyunca tahmin edilen fiyatlar ve aynı döneme ilişkin gerçek fiyatlar gösterilmektedir.


Şekillerin altında kalan ikinci grafikte ise hata miktarları yer almaktadır. Hata terimi, gerçek fiyat ile tahmin edilen fiyat arasındaki fark olarak tanımlanmıştır.




01-)




02-)




03-)




04-)




05-)




06-)




07-)




08-)




09-)




10-)




11-)




12-)




13-)




14-)




15-)




16-)




17-)




18-)




19-)




20-)




21-)




22-)




23-)




24-)




25-)




26-)




27-)



28-)



29-)



30-)

