



**BORSA ENDEKSİ HAREKET YÖNÜNÜN TAHMİNİNDE
SINIFLANDIRMA YÖNTEMLERİNİN PERFORMANSLARININ
KARŞILAŞTIRILMASI: BİST 100 ÖRNEĞİ**

İsmail KARA

Doktora Tezi

Danışman: Doç. Dr. FATİH ECER

Mart, 2019

Afyonkarahisar

T.C.
AFYON KOCATEPE ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ
İŞLETME ANABİLİM DALI
DOKTORA TEZİ

BORSA ENDEKSİ HAREKET YÖNÜNÜN
TAHMİNİNDE SINIFLANDIRMA YÖNTEMLERİNİN
PERFORMANSLARININ KARŞILAŞTIRILMASI: BİST
100 ÖRNEĞİ

Hazırlayan
İsmail KARA

Danışman
Doç. Dr. FATİH ECER

AFYONKARAHİSAR, 2019

YEMİN METNİ

Doktora tezi olarak sunduđum “**Borsa Endeksi Hareket Yönünün Tahmininde Sınıflandırma Yöntemlerinin Performanslarının Karşılaştırılması: Bist 100 Örneđi**” adlı çalışmanın, tarafımdan bilimsel ahlak ve geleneklere aykırı düşecek bir yardıma başvurmaksızın yazıldığını ve yararlandığım eserlerin Kaynakça’da gösterilen eserlerden oluştuđunu, bunlara atıf yapılarak yararlanmış olduğumu belirtir ve bunu onurumla doğrularım.


19.03.2019

İsmail KARA

TEZ JÜRİSİ KARARI VE ENSTİTÜ ONAYI

JÜRİ ÜYELERİ

Tez Danışmanı : Doç. Dr. Fatih ECER
Jüri Üyeleri : Prof. Dr. Veysel KULA
: Prof. Dr. Nuri ÖMÜRBEK
: Prof. Dr. Mahmut ZORTUK
: Doç. Dr. Gökhan DEMİRTAŞ

İmza






İşletme Anabilim Dalı Doktora programı öğrencisi İsmail KARA 'nın "**Borsa Endeksi Hareket Yönünün Tahmininde Sınıflandırma Yöntemlerinin Performanslarının Karşılaştırılması: BİST 100 Örneği**" başlıklı tezini değerlendirmek üzere 19.03.2019 günü saat 10:30' de Lisansüstü Eğitim ve Öğretim Sınav Yönetmeliğinin ilgili maddeleri uyarınca yukarıda isim ve imzaları bulunan jüri üyeleri tarafından değerlendirilerek kabul edilmiştir.

Prof. Dr. Celal DEMİR
MÜDÜR

ÖZET

BORSA ENDEKSİ HAREKET YÖNÜNÜN TAHMİNİNDE SINIFLANDIRMA YÖNTEMLERİNİN PERFORMANSLARININ KARŞILAŞTIRILMASI: BİST 100 ÖRNEĞİ

İsmail KARA

AFYON KOCATEPE ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ
İŞLETME ANABİLİM DALI

Mart 2019

Danışman: Doç. Dr. FATİH ECER

Bu çalışmanın amacı, teknik göstergeleri girdi verisi olarak kullanarak borsa endeksi hareket yönünün tahmin edilebilir olduğunu ortaya koymak ve sınıflandırma yöntemlerinin performanslarını karşılaştırmaktır. 1995:3-2018:3 dönemine ait 10 adet teknik göstergenin Borsa İstanbul 100 Endeksi (BİST 100) günlük kapanış verileri kullanılarak BİST 100 endeks yönü tahmin edilmiştir. Makine öğrenmesi yöntemlerinden Yapay Sinir Ağları (YSA), Destek Vektör Makineleri (DVM), Karar Ağaçları (KA), Naive Bayes (NB), k-En Yakın Komşuluk (k-EYK) yöntemleri ile Lojistik Regresyon (LogR) ve Doğrusal Diskriminant Analizi (DDA) gibi istatistiksel yöntemler kullanılarak analizler yapılmıştır. Sınıflandırma yöntemlerinin doğru sınıflandırma oranları sırasıyla %83.83, %78.43, %65.04, %61.74, %55.48, %76.70 ve %76.87 olduğu görülmüştür. Sonuçlara göre, BİST 100 endeksi hareket yönünün tahmininde kullanılabilecek en iyi sınıflandırma yöntemi YSA'dır.

Anahtar Kelimeler: Makine Öğrenmesi, Yapay Zeka, Sınıflandırma, Teknik Göstergeler, BİST 100.

ABSTRACT

PERFORMANCE COMPARISON OF CLASSIFICATION TECHNIQUES IN STOCK EXCHANGE INDEX DIRECTION MOVEMENT PREDICTION: THE CASE OF BIST 100

İsmail KARA

**AFYON KOCATEPE UNIVERSITY
THE INSTITUTE OF SOCIAL SCIENCES
DEPARTMENT OF BUSINESS ADMINISTRATION**

March 2019

Advisor: Asist. Prof. Dr. FATİH ECER

The aim of this study is to show that the direction of movement of stock market index is predictable by using technical indicators as input data and to compare performances of classification methods. The BIST 100 index direction was estimated by using the daily closing data of Borsa Istanbul 100 Index (BIST 100) of 10 technical indicators belong to the period of 1995:3-2018:3. By using the Machine learning methods such as Artificial Neural Networks (ANN), Support Vector Machines (SVM), Decision Trees (DT), Naive Bayes (NB), k-Nearest Neighborhood (k-NN) methods and the statistical methods of Logistic Regression (LogR) and Linear Discriminant Analysis (LDA) were analyzed. The correct classification rates of classification methods were 83.83%, 78.43%, 65.04%, 61.74%, 55.48%, 76.70% and 76.87% respectively. According to the results, ANN is the best classification method that can be used to predict the direction of movement of the BIST 100 index.

Key Words: Machine Learning, Artificial Intelligence, Classification, Technical Indicators, BIST 100.

TEŐEKKÜR

Bu tez alıŐmamdaki katkılarından dolayı danışmanım Sayın Do. Dr. Fatih ECER'e, Tez İzleme Komitesinde ve tez savunmamda yer alan Sayın Prof. Dr. Veysel KULA'ya, Sayın Do. Dr. Gökhan DEMİRTAŐ'a, tez savunmamda sağladığı katkıları nedeniyle Sayın Prof. Dr. Mahmut ZORTUK ve Sayın Prof. Dr. Nuri ÖMÜRBEK'e, tezin uygulama kısmındaki yapıcı eleŐtirileri ve katkıları nedeniyle Sayın Dr. Öğr. Üyesi Ender BAYKUT'a ve Öğr. Gör. Dr. M. Ozan KARAHAN'a, manevi olarak destek sağlayan eşime, anneme ve aileme sonsuz teşekkürlerimi sunarım.

İsmail KARA

İÇİNDEKİLER

YEMİN METNİ	iii
TEZ JÜRİSİ KARARI VE ENSTİTÜ MÜDÜRLÜĞÜ ONAYI...Hata! Yer işareti tanımlanmamış.	
ÖZET.....	v
ABSTRACT	vi
TEŞEKKÜR	vii
İÇİNDEKİLER	viii
TABLolar LİSTESİ.....	xvi
ŞEKİLLER LİSTESİ.....	xviii
KISALTMALAR DİZİNİ	xx
GİRİŞ	1

BİRİNCİ BÖLÜM

YAPAY ZEKA VE MAKİNE ÖĞRENMESİ

1. YAPAY ZEKA	4
1.1. YAPAY ZEKA KAVRAMI	4
1.2. YAPAY ZEKANIN AMAÇLARI.....	6
1.3. YAPAY ZEKANIN TARİHSEL GELİŞİM SÜRECİ	6
1.4. YAPAY ZEKA TEKNOLOJİLERİ.....	10
1.4.1. Geleneksel Yapay Zeka Teknolojileri	10
1.4.2. Hesaplamaya Dayalı Yapay Zeka Teknolojileri.....	10
1.5. YAPAY ZEKA YAKLAŞIMLARI.....	11
1.5.1. İnsan Gibi Düşünme (Bilişsel Modelleme) Yaklaşımı.....	12
1.5.2. İnsan Gibi Davranma (Turing Testi) Yaklaşımı	12
1.5.3. Rasyonel Düşünme (Düşünce Kanunları) Yaklaşımı	13
1.5.4. Rasyonel Davranma (Zeki Ajan) Yaklaşımı.....	13
2. MAKİNE ÖĞRENMESİ.....	14
2.1. MAKİNE ÖĞRENMESİNİN AMACI VE ÖNEMİ.....	16
2.2. MAKİNE ÖĞRENMESİNİN AVANTAJLARI.....	17
2.3. TEMEL ÖĞRENME PROBLEMLERİ.....	18
2.3.1. Sınıflandırma	18
2.3.2. Sayısal Tahmin	19
2.3.3. Kümeleme	20
2.3.4. Birliktelik Kuralı.....	22
2.4. MAKİNE ÖĞRENMESİ TÜRLERİ.....	22

2.4.1. Danışmanlı Öğrenme	23
2.4.2. Danışmansız Öğrenme	24
2.4.3. Yarı-Danışmanlı Öğrenme	25
2.4.4. Pekiştirmeli Öğrenme	25
2.4.5. Aktif Öğrenme	27
2.4.6. Çevrimiçi Öğrenme	27
2.5. MAKİNE ÖĞRENMESİ SÜRECİ	27
2.5.1. Veri toplama	29
2.5.2. Veri Hazırlama	29
2.5.2.1. Veri Temizleme	29
2.5.2.2. Veri Entegrasyonu	29
2.5.2.3. Veri İndirgeme	30
2.5.2.4. Veri Dönüşümü	30
2.5.3. Model	30
2.5.4. Algoritma Eğitimi	31
2.5.5. Algoritmayı Test Etme	31
2.5.6. Uygulama	32
2.6. MAKİNE ÖĞRENMESİNDE MODEL DEĞERLENDİRME VE SEÇİMİ	32
2.6.1. Model Performans Değerlendirme Yöntemleri	33
2.6.1.1. Dışarıda Tutma	33
2.6.1.2. Çapraz Geçerleme	34
2.6.1.3. Bootstrap	35
2.6.2. Model Seçimi	36
2.6.3. Model Tahmini	36
2.6.4. Model Performansını Optimize Etme	37

İKİNCİ BÖLÜM

BORSA ENDEKSİ HAREKET YÖNÜNÜN TAHMİNİNDE KULLANILAN YÖNTEMLER

1. BORSA ENDEKSİ HAREKET YÖNÜNÜN TAHMİNİNDE KULLANILAN YÖNTEMLER	39
1.1. YAPAY SİNİR AĞLARI (YSA)	39
1.1.1. YSA'nın Sunduğu Faydalı Özellik ve Kabiliyetler	41
1.1.2. Biyolojik Sinir Hücreleri	42
1.1.3. Yapay Sinir Hücresi	43

1.1.3.1. Girdiler	44
1.1.3.2. Ağırlıklar	44
1.1.3.3. Toplama Fonksiyonu.....	45
1.1.3.4. Aktivasyon Fonksiyonu	45
1.1.3.5. Hücrenin Çıktısı	46
1.1.4. Yapay Sinir Ağlarının Bileşenleri.....	46
1.1.4.1. Girdi Katmanı.....	46
1.1.4.2. Gizli Katman	46
1.1.4.3. Çıktı Katmanı.....	46
1.1.4.4. Bağlantılar	47
1.1.5. Yapay Sinir Ağlarında Öğrenme Kuralları.....	47
1.1.5.1. Hebb Kuralı.....	47
1.1.5.2. Hopfield Kuralı	48
1.1.5.3. Perseptron (Geri Yayılım Algoritması).....	48
1.1.5.4. Delta Kuralı.....	49
1.1.5.5. Kohonen Kuralı.....	49
1.1.6. Yapay Sinir Ağlarının Model Yapısı.....	50
1.1.6.1. Tek Gizli Katmanlı Yapay Sinir Ağları	50
1.1.6.2. İki Gizli Katmanlı Yapay Sinir Ağları	51
1.1.7. Yapay Sinir Ağı Model Yapısına Karar Verilmesi	52
1.1.7.1. Girdi Nöronu Sayısının Belirlenmesi.....	52
1.1.7.2. Gizli Katman Sayısının Belirlenmesi.....	52
1.1.7.3. Gizli Katman Nöron Sayısının Belirlenmesi	53
1.1.7.4. Çıktı Nöron Sayısının Belirlenmesi	53
1.1.7.5. Katmanlar Arası İletişim.....	53
1.1.8. Yapay Sinir Ağlarının Eğitimi ve Testi.....	53
1.1.9. Hata Fonksiyonları	54
1.1.10. Yapay Sinir Ağları Mimarisi	55
1.1.10.1. Geri Yayılım (Backpropagation) Yapay Sinir Ağları	55
1.1.10.2. İleri Beslemeli Yapay Sinir Ağları.....	57
1.1.10.3. Çok Katmanlı Yapay Sinir Ağı.....	58
1.1.11. Araştırma ve Uygulamalarda Yapay Sinir Ağları	59
1.2. DESTEK VEKTÖR MAKİNELERİ	60
1.2.1. Destek Vektör Makinesine Genel Bir Bakış	60
1.2.2. Doğrusal Sınıflandırıcı.....	61
1.2.3. Dört Farklı Konseptin Birleşimi DVM	62

1.2.4. Doğrusal Destek Vektör Makineleri.....	63
1.2.5. Marj.....	65
1.2.6. Doğrusal Olmayan Destek Vektör Makineleri.....	66
1.2.7. Çekirdek Fonksiyonları.....	66
1.2.8. Çekirdek Fonksiyonlarının Seçiminin Önemi ve Tasarımı.....	68
1.2.9. Çekirdek Hilesi.....	68
1.2.10. Mercer teoremi.....	69
1.2.11. Sınıflandırma için DVM.....	70
1.2.12. DVM Uygulamaları.....	70
1.3. KARAR AĞAÇLARI.....	71
1.3.1. Karar Ağacının Yapısı.....	72
1.3.2. Karar Ağacı İle Sınıflandırma.....	72
1.3.3. Karar Ağacı Oluşturma.....	73
1.3.4. Ayırma – Budama.....	74
1.3.5. Karar Ağacı Algoritmaları.....	74
1.3.5.1. ID3.....	74
1.3.5.2. C4.5.....	75
1.3.5.3. CART (C&RT).....	76
1.3.6. Karar Ağacı Uygulamaları.....	76
1.4. NAİVE BAYES.....	76
1.4.1. Bayes Teoremi.....	77
1.4.2. Naive Bayes Sınıflandırma.....	77
1.4.3. Naive Bayes Sınıflandırma Adımları.....	78
1.4.4. Araştırma ve Uygulamalarda Naive Bayes.....	79
1.5. K-EN YAKIN KOMŞULUK.....	79
1.5.1. K-Katlı Çapraz Doğrulama.....	81
1.5.2. Uzaklık Ölçüsü ve En Yakın Komşu Sınıflaması.....	81
1.5.3. K-EYK Algoritması Uygulama Adımları.....	82
1.5.4. K seçimi.....	83
1.5.5. K-EYK Uygulamaları.....	83
1.6. LOJİSTİK REGRESYON.....	83
1.6.1. Lojistik Regresyona Genel Yaklaşım.....	84
1.6.2. Lojistik Regresyon Modeli.....	85
1.6.3. Birimlerin Sınıflandırılması.....	85
1.6.4. Katsayıların Önemi Testi.....	85
1.6.5. LogR Uygulamaları.....	86

1.7. DOĞRUSAL DİSKRİMİNANT ANALİZİ	86
1.7.1. Doğrusal Diskriminant Analizi Metodu.....	86
1.7.2. Doğrusal Diskriminant Analizinin Amaçları	87
1.7.3. Doğrusal Diskriminant Analizi Uygulama Teknikleri	87
1.7.4. DDA Uygulamaları.....	88
2. YARARLANILAN YÖNTEMLERE İLİŞKİN LİTERATÜR	
ARAŞTIRMASI	88
2.1. SINIFLANDIRMA YÖNTEMLERİ İLE İLGİLİ YAPILAN	
ÇALIŞMALAR.....	89
2.1.1. Yapay Sinir Ağları ile İlgili Yapılan Çalışmalar	91
2.1.2. Destek Vektör Makineleri ile İlgili Yapılan Çalışmalar	98
2.1.3. Karar Ağaçları ile İlgili Yapılan Çalışmalar	101
2.1.4. Naive Bayes ile İlgili Yapılan Çalışmalar	104
2.1.5. K-En Yakın Komşuluk ile İlgili Yapılan Çalışmalar	105
2.1.6. Lojistik Regresyon ile İlgili Yapılan Çalışmalar	107
2.1.7. Doğrusal Diskriminant Analizi ile İlgili Yapılan Çalışmalar.....	109
2.1.8. Sınıflandırmaya Yönelik Çalışmalara İlişkin Genel Değerlendirme	
.....	110
2.2. ENDEKS YÖN TAHMİNİNDE TEKNİK GÖSTERGELERİN	
KULLANILDIĞI ÇALIŞMALAR	111
2.2.1. Endeks Yön Tahmininde Teknik Göstergeler Kullanılarak	
Yurtdışında Yapılan Çalışmalar.....	112
2.2.2. Endeks Yön Tahmininde Teknik Göstergeler Kullanılarak	
Türkiye’de Yapılan Çalışmalar	121
2.2.3. Endeks Yön Tahmininde Teknik Göstergelerin Kullanıldığı	
Çalışmalara İlişkin Genel Değerlendirme	123

ÜÇÜNCÜ BÖLÜM

FİNANSAL PİYASALAR VE BORSA İSTANBUL

1. FİNANSAL PİYASALAR.....	125
1.1. FİNANSAL PİYASA KAVRAMI	125
1.2. FİNANSAL PİYASALARIN ÖZELLİKLERİ	127
1.3. FİNANSAL PİYASALARIN SINIFLANDIRILMASI	128
1.3.1. Para ve Sermaye Piyasaları.....	128
1.3.1.1. Para Piyasaları	128
1.3.1.2. Sermaye Piyasaları	129
1.3.1.3. Para ve Sermaye Piyasaları Arasındaki İlişki	129

1.3.2. Spot ve Vadeli Piyasalar	129
1.3.2.1. Spot Piyasalar	129
1.3.2.2. Vadeli Piyasalar	130
1.3.3. Organize ve Organize Olmayan Piyasalar.....	130
1.3.3.1. Organize Piyasalar	130
1.3.3.2. Organize Olmayan (Tezgahestü) Piyasalar.....	131
1.3.4. Birincil ve İkincil Piyasalar	131
1.3.4.1. Birincil Piyasalar	131
1.3.4.2. İkincil Piyasalar.....	131
1.3.5. Üçüncül ve Dördüncül Piyasalar	131
1.3.5.1. Üçüncül Piyasalar.....	132
1.3.5.2. Dördüncül Piyasalar	132
1.4. FİNANSAL PİYASA ENSTRÜMANLARI	132
1.4.1. Hisse Senetleri.....	133
1.4.2. Tahviller	133
1.4.3. Devlet Tahvilleri ve Hazine Bonoları	134
1.4.4. Gelir Ortaklığı Senetleri.....	134
1.4.5. Banka Bonoları ve Banka Garantili Bonolar	134
1.4.6. Varlığa Dayalı Menkul Kıymetler	135
1.4.7. Vadeli İşlem ve Opsiyon Sözleşmeleri	135
2. BORSA İSTANBUL VE ENDEKSLER	135
2.1. BORSA İSTANBUL'A GENEL BAKIŞ	136
2.2. BİST'İN YAPISI.....	136
2.3. BİST ENDEKSLERİ VE HESAPLAMALARI	138
2.3.1. BİST 100 Endeksi.....	139
2.4. BİST ANALİZLERİ VE KULLANILAN ALTERNATİF GÖSTERGELER	139
2.4.1. Temel Analiz	139
2.4.2. Teknik Analiz	141
2.4.3. Analizde Kullanılan Diğer Yöntemler.....	143
2.4.3.1. Hareketli Ortalamalar (10 Günlük)	144
2.4.3.2. Ağırlıklı Hareketli Ortalamalar (10 Günlük)	145
2.4.3.3. MACD (Hareketli Ortalama Yakınsama İraksama).....	145
2.4.3.4. CCI (Emtia Kanalı Endeksi)	146
2.4.3.5. RSI (Göreceli Güç Endeksi).....	147
2.4.3.6. Stokastik %K.....	148

2.4.3.7. Stokastik %D.....	149
2.4.3.8. William's %R.....	149
2.4.3.9. Momentum	150
2.4.3.10. A/D (Alım/Dağıtım Göstergesi).....	151

DÖRDÜNCÜ BÖLÜM

BORSA ENDEKSİ HAREKET YÖNÜNÜN TAHMİNİ UYGULAMASI

1. UYGULAMANIN AMACI	152
2. UYGULAMANIN YÖNTEMİ.....	152
3. HİSSE SENEDİ PİYASALARININ TAHMİN EDİLEBİLİRLİĞİ	153
4. BİST 100 ENDEKSİNİN YÖN TAHMİNİ	154
5. MODEL TASARIMI	155
5.1. MODEL PARAMETRELERİNİN TESPİT EDİLMESİ	156
5.1.1. YSA Parametreleri.....	157
5.1.2. DVM Parametreleri	158
5.1.3. K-EYK Parametreleri.....	159
5.2. MODEL	159
5.3. MODELİN TEST EDİLMESİ	160
5.3.1. Sınıflandırıcı Performansını Değerlendirme Metrikleri	160
5.3.1.1. Doğruluk	161
5.3.1.2. Hata Oranları.....	163
5.3.1.2.1. Ortalama Karesel Hata (MSE)	163
5.3.1.2.2. Ortalama Mutlak Hata (MAE)	163
5.3.1.2.3. Kök Ortalama Karesel Hata (RMSE).....	163
5.3.1.2.4. Ortalama Mutlak Yüzde Hata (MAPE)	164
6. UYGULAMA.....	164
6.1. ANALİZDE KULLANILAN BORSA ENDEKS VERİLERİ	165
6.2. VERİLERİN TOPLANMASI VE HAZIRLANMASI.....	166
6.3. ENDEKS YÖN TAHMİNDE KULLANILACAK GİRDİ DEĞİŞKENLERİ.....	167
6.4. TEKNİK GÖSTERGELER İLE GERÇEK FİYAT ARASINDAKİ KORELASYON.....	170
7. BULGULAR	171
7.1. MAKİNE ÖĞRENMESİ YÖNTEMLERİYLE ENDEKS YÖNÜ TAHMİNİ	171
7.1.1. Yapay Sinir Ağları Yöntemi İle Endeks Yönü Tahmini	171

7.1.1.1. Test Edilen YSA Parametre Seviyeleri	171
7.1.1.2. YSA Genel Değerlendirme	174
7.1.2. Destek Vektör Makineleri Yöntemi İle Endeks Yönü Tahmini... 177	
7.1.2.1. Test Edilen DVM Parametre Seviyeleri.....	178
7.1.2.2. DVM Genel Değerlendirme	180
7.1.3. Karar Ağaçları Yöntemi İle Endeks Yönü Tahmini..... 183	
7.1.4. Naive Bayes Yöntemi İle Endeks Yönü Tahmini	187
7.1.5. K-En Yakın Komşuluk Yöntemi İle Endeks Yönü Tahmini	190
7.1.5.1. Test Edilen k-EYK Parametre Seviyeleri	190
7.1.5.2. K-EYK Yöntemi Genel Değerlendirme.....	191
7.2. İSTATİSTİKSEL YÖNTEMLERLE ENDEKS YÖNÜ TAHMİNİ.....	194
7.2.1. Lojistik Regresyon Yöntemi İle Endeks Yönü Tahmini.....	194
7.2.2. Doğrusal Diskriminant Analizi Yöntemi İle Endeks Yönü Tahmini	197
8. ANALİZ SONUÇLARININ KARŞILAŞTIRILMASI.....	200
SONUÇ VE DEĞERLENDİRME	204
KAYNAKÇA	208

TABLolar LİSTESİ

Sayfa

Tablo 1. Aktivasyon Fonksiyonları.....	45
Tablo 2. Endeks Yön Tahmininde Yapay Sinir Ağları Yöntemi ile İlgili Yapılan Çalışmalar.....	92
Tablo 3. Endeks Yön Tahmininde Destek Vektör Makineleri Yöntemi ile İlgili Yapılan Çalışmalar	98
Tablo 4. Endeks Yön Tahmininde Karar Ağacı Yöntemi ile İlgili Yapılan Çalışmalar.....	102
Tablo 5. Endeks Yön Tahmininde Naive Bayes Yöntemi ile İlgili Yapılan Çalışmalar.....	104
Tablo 6. Endeks Yön Tahmininde k-En Yakın Komşuluk Yöntemi ile İlgili Yapılan Çalışmalar	106
Tablo 7. Endeks Yön Tahmininde Lojistik Regresyon Yöntemi ile İlgili Yapılan Çalışmalar.....	107
Tablo 8. Endeks Yön Tahmininde Doğrusal Diskriminant Analizi Yöntemi ile İlgili Yapılan Çalışmalar	109
Tablo 9. Teknik Göstergelerin Kullanıldığı Sınıflandırma Yöntemleri ile Yurtdışında Yapılan Çalışmalar.....	113
Tablo 10. Teknik Göstergeler Kullanılarak Sınıflandırma Yöntemleri ile Türkiye'de Yapılan Çalışmalar	122
Tablo 11. BİST 100'ün parametre ayar veri setindeki her yıl artış ve azalış sayısı.	156
Tablo 12. Test Edilen YSA Parametre Seviyeleri.	158
Tablo 13. Test Edilen DVM Parametre Seviyeleri.....	158
Tablo 14. Sınıflandırma Performansını Değerlendirme Metrikleri.....	161
Tablo 15. Karışıklık Matrisi.....	162
Tablo 16. BİST XU 100'ün Tüm Veri Setindeki Her Yıl İçin.....	166
Artan ve Azalan Veri Sayısı.	166
Tablo 17. BİST XU100 Karşılaştırmalı Veri Setindeki Her Yıl Artış ve Azalış Sayıları.	167
Tablo 18. Çalışmada Kullanılan Girdi Değişkenleri.....	168
Tablo 19. Seçilen Teknik Göstergeler ve Formülleri	169
Tablo 20. Seçilen Göstergeler İçin Özet İstatistikler.	169
Tablo 22. Teknik Göstergeler ile Gerçek Fiyat Arasındaki Korelasyon Katsayıları.....	170
Tablo 23. Yapay Sinir Ağları Parametre Seviyeleri	172
Tablo 24. Test edilen YSA parametre seviyeleri.	173

Tablo 25. YSA Karışıklık Matrisi.....	173
Tablo 26. YSA Test Sonuçları.....	173
Tablo 27. Yapay Sinir Ağları Test Sonuçları	174
Tablo 28. Destek Vektör Makineleri Parametre Seviyeleri	178
Tablo 29. Test Edilen DVM Parametre Seviyeleri.....	179
Tablo 30. DVM Karışıklık Matrisi	179
Tablo 31. DVM Test Sonuçları	179
Tablo 32. Destek Vektör Makineleri Test Sonuçları	180
Tablo 33. Karar Ağacı Karışıklık Matrisi	185
Tablo 34. Karar Ağacı Test Sonuçları	185
Tablo 35. Naive Bayes Karışıklık Matrisi.....	188
Tablo 36. Naive Bayes Test Sonuçları	188
Tablo 37. k-EYK Karışıklık Matrisi	191
Tablo 38. k-EYK Test Sonuçları.....	191
Tablo 39. k-En Yakın Komşuluk Test Sonuçları	191
Tablo 40. LogR Karışıklık Matrisi	195
Tablo 41. LogR Test Sonuçları	195
Tablo 42. DDA Karışıklık Matrisi	198
Tablo 43. DDA Test Sonuçları	198
Tablo 44. Tüm Analizler En İyi Test Sonuçları	201

ŞEKİLLER LİSTESİ

Sayfa

Şekil 1. Yapay Zeka Teknolojilerinin Sınıflandırılması (Lin ve Lee, 1996: 498).	11
Şekil 2. Regresyon (Brink, Richards ve Fetherolf, 2016: 69)	20
Şekil 3. Makine Öğrenme Türleri (Ramasubramanian ve Singh, 2017: 222). ...	22
Şekil 4. Holdout (Bramer, 2016: 80).	33
Şekil 5. K-katlı Çapraz Geçerleme (Bramer, 2016: 83).	35
Şekil 6. Biyolojik Nöron (Ertel, 2011: 222).	42
Şekil 7. Yapay Sinir Hücresi (Ertel, 2011: 222).	43
Şekil 8. Yapay Sinir Hücresi Elemanları (Akdağ, 2010: 37).	44
Şekil 9. Tek Gizli Katman Sinir Ağı Modeli (Chen,2015: 2).	50
Şekil 10. İki Gizli Katman Sinir Ağı Modelleri (Chen,2015: 5).	51
Şekil 11. Geri Yayılım Yapay Sinir Ağları (Akdağ, 2010: 50).	56
Şekil 12. İleri Beslemeli YSA (Hamzaçebi ve Kutay, 2004: 229).	57
Şekil 13. Çok Katmanlı Yapay Sinir Ağı (Kılıç, Özbacı ve Özçalık, 2012: 695)	58
Şekil 14. Doğrusal Sınıflandırıcı (hiperdüzlem) (Olson ve Delen, 2008: 111). ...	62
Şekil 15. DVM Haritası (Cherkassky, 2007: 407).	62
Şekil 16. Maksimum Ayırma Hiperdüzlemleri (Olson ve Delen, 2008: 113).	64
Şekil 17. Karar Ağacı Yapısı (Ramasubramanian ve Singh, 2017: 298).	72
Şekil 18. On-katlı Çapraz Doğrulama Yöntemi (Olson ve Delen, 2008:142).	81
Şekil 19. K-EYK (Barber, 2012: 324)	82
Şekil 20. Finansal Piyasaların İşleyişi (Şıklar, 2004: 46).	126
Şekil 22. YSA Model Mimarisi (Patel, 2015: 264).	157
Şekil 23. Tahmin Modeli	160
Şekil 24. BİST 100 Endeksi Kapanış Verileri.	165
Şekil 25. Rapid Miner Yapay Sinir Ağları Yöntemi Süreci.	171
Şekil 26. YSA Endeks Tahmini	176
Şekil 27. YSA Endeks Yön Tahmininde Karışıklık Matrisi Verileri.	176
Şekil 28. YSA Yön Tahmininde Yükselen ve Düşen Kapanış Verileri.	177
Şekil 29. YSA Tahmini ile Borsa Endeksi Korelasyonu	177
Şekil 30. Rapid Miner Destek Vektör Makineleri Yöntemi Süreci.	178
Şekil 31. DVM Endeks Tahmini	181
Şekil 32. DVM Endeks Yön Tahmini Karışıklık Matrisi Verileri.	181
Şekil 33. DVM Modeli Yön Tahmininde Yükselen ve Düşen Kapanış Verileri.	182

Şekil 34. DVM Tahmini ile Borsa Endeksi Korelasyonu	182
Şekil 35. Rapid Miner Karar Ağacı Süreci.....	183
Şekil 37. Karar Ağacı Endeks Tahmini	185
Şekil 38. Karar Ağacı Endeks Yön Tahmini Karışıklık Matrisi Verileri.	186
Şekil 39. Karar Ağacı Modeli Yön Tahmininde Yükselen ve Düşen Kapanış Verileri	186
Şekil 40. Karar Ağacı Tahmini ile Borsa Endeksi Korelasyonu.....	187
Şekil 41. Rapid Miner Naive Bayes Süreci.	187
Şekil 42. Naive Bayes Endeks Tahmini.	188
Şekil 43. Naive Bayes Endeks Yön Tahmini Karışıklık Matrisi Verileri.....	189
Şekil 44. Naive Bayes Modeli Yön Tahmininde Yükselen Ve Düşen Kapanış Verileri	189
Şekil 45. Naive Bayes Tahmini ile Borsa Endeksi Korelasyonu.	190
Şekil 46. Rapid Miner k-En Yakın Komşuluk Yöntemi Süreci.	190
Şekil 47. k-EYK Endeks Tahmini.....	192
Şekil 48. k- EYK Endeks Yön Tahmini Karışıklık Matrisi Verileri.	193
Şekil 49. k-EYK Modeli Yön Tahmininde Yükselen ve Düşen Kapanış Verileri.	194
Şekil 50. k-EYK Tahmini ile Borsa Endeksi Korelasyonu.....	194
Şekil 51. Rapid Miner LogR Yöntemi Süreci.	195
Şekil 52. LogR Endeks Tahmini.	196
Şekil 53. LogR Endeks Yön Tahmini Karışıklık Matrisi Verileri.	196
Şekil 54. Lojistik Regresyon Modeli Yön Tahmininde Yükselen ve Düşen Kapanış Verileri.	197
Şekil 55. LogR Tahmini ile Borsa Endeksi Korelasyonu.	197
Şekil 56. Rapid Miner DDA Yöntemi Süreci.	198
Şekil 57. DDA Endeks Tahmini.	199
Şekil 58. DDA Endeks Yön Tahmini Karışıklık Matrisi Verileri.....	199
Şekil 59. DDA Modeli Yön Tahmininde Yükselen Ve Düşen Kapanış Verileri.	200
Şekil 60. DDA Tahmini ile Borsa Endeksi Korelasyonu.	200
Şekil 61. Birden Fazla Sınıflandırma Algoritmasının Aynı Anda Doğruluk Tahmini Karşılaştırılması.	202

KISALTMALAR DİZİNİ

A/D	:Alım/Dağıtım Göstergesi
AHO	:Ağırlıklı Hareketli Ortalamalar
ANFIS	:Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi
AÖM	:Aşırı Öğrenme Makinesi
ARIMA	:Otoregresif Entegre Hareketli Ortalama
BİST	:Borsa İstanbul
BİST-100	:Borsa İstanbul 100 Endeksi
BPNN	:Geri Yayımlı Sinir Ağı
CART	:Sınıflandırma ve Regresyon Ağaçları
CBR	:Vaka Temelli Akıl Yürütme
CCI	:Emtia Kanalı Endeksi
CEFLANN	:Hesaplamalı Verimli Fonksiyonel Bağlantı Yapay Sinir Ağı
CNN	:Evrşimsel Sinir Ağı
C4.5	:Karar Ağacı Eğitim Algoritması
ÇKA	:Çok Katmanlı Algılayıcılar
DAN2	:Yapay Sinir Ağları Dinamik Mimari
DDA	:Doğrusal Diskriminant Analizi
DM	:Dinamik Mimari
DR	:Doğrusal Regresyon
DVM	:Destek Vektör Makineleri
DVR	:Destek Vektör Regresyon
DWT	:Ayrık Wavelet Dönüşümü
EYK	:En Yakın Komşuluk
FM	:Bulanık Metagraf
GA	:Genetik Algoritmalar
GARCH	:Genelleştirilmiş Autoregressive Koşullu Heteroskedastisite
GD	:Dereceli Alçalma
GMM	:Gaussian Karışım Modeli
GRNN	:Genelleştirilmiş Regresyon Sinir Ağı
FLANN	:İşlevsel Bağlantı Yapay Sinir Ağı
HO	:Hareketli Ortalamalar
HS	:Uyum Arayışı
ICA	:Entegre Bağımsız Bileşen Analizi
IDTW	:Artımlı Dinamik Zaman Eğrisi
ID3	:Yinelemeli Dikotomiser
KA	:Karar Ağacı
KK	:Kaba Küme
LogR	:Lojistik Regresyon
LS	:En Küçük Kareler
LSTM	:Uzun-Kısa Süreli Hafıza
MACD	:Hareketli Ortalama Yakınsama İraksama
MAE	:Ortalama Mutlak Hata
MANN	:Çok Değişkenli Yapay Sinir Ağları
MAPE	:Ortalama Mutlak Yüzde Hata
MDVM	:Çoklu Çıkış Desteği Vektör Makinesi
MLV	:Çok Değişkenli Doğrusal Model

MOM	:Momentum
MSE	:Ortalama Karesel Hata
NB	:Naive Bayes
PCA	:Temel Bileşenler Analizi
PLSR	:Kısmi En Küçük Karesel Regresyon
PNN	:Olasılıksal Sinir Ağları
PSO	:Parçacık Sürü Optimizasyonu
QDA	:Kuadratik Diskriminant Analizi
RBFNN	:Radyal Tabanlı Fonksiyon Sinir Ağları
RF	:Rastgele Orman
RMSE	:Kök Ortalama Karesel Hata
RSI	:Göreceli Güç Endeksi
RT	:Rastgele Ağaç
RW	:Rastgele Yürüyüş
SA	:Benzetimli Tavlama
STOD%	:Stokastik %D
STOK%	:Stokastik %K
UANN	:Tek Değişkenli Yapay Sinir Ağları
ULN	:Tek Değişkenli Doğrusal Model
UMIDAS	:Sınırsız Karışık Veri Örnekleme
WILLR%	:William's %R
YSA	:Yapay Sinir Ağları
YZ	:Yapay Zeka

GİRİŞ

Belirsizlikler nedeniyle endeks ve hisse senedi fiyat yönünü tahmin etmek zordur. Bu nedenle hisse senedi fiyat değişimlerinin yönünü tahmin etmek önemli bir konudur, çünkü borsa işlemleri için etkili stratejilerin geliştirilmesine katkıda bulunur (Oliveira, Nobre ve Zárate, 2013: 7596). Endeks yönünün önceden tahmini yatırımcılar, şirket yöneticileri ve araştırmacılar için büyük önem arz etmektedir. Endeks ve hisse senedi fiyat yönünün önceden tahmin edilmesi yatırımcılar için işlem maliyetlerinden kaçınma ve fırsatları yakalama olanağı sağlarken şirket yöneticileri için de şirket değerlerini maksimize etme fırsatları sunar. Ayrıca araştırmacılar çalışmalarına yön vermek için önceden yapılacak tahminlerin doğruluğunu test etme fırsatı bulurlar.

İnsanoğlunun zekasını ve davranışlarını taklit edebilecek makineler yapma düşüncesiyle yapay zeka kavramı ortaya çıkmıştır. Yapay zeka, insanların yapabildiği zeki davranışların ve düşünme faaliyetlerinin makineler tarafından da yapılabilmesi ve insan zekasının taklit edilmesidir. Bilgisayarların öğrenme kabiliyetinin insandan daha düşük olduğunu düşünürsek, öğrenme mekanizmalarına yönelik araştırmalar yapılması ve makine öğrenme algoritmalarının geliştirilmesi yapay zekanın en önemli konularını oluşturmaktadır (Ertel, 2011:161). Öğrenme işini insanlar yerine bir makine için düşündüğümüzde bu durumun bir hayli zor ve sancılı bir süreç olduğu görülmektedir. Yapay zeka ve istatistik bilimlerinin ortak çalışması ile makine öğrenmesi alanında çeşitli yazılımlar ve algoritmalar üretilerek bu problem aşmaya çalışılmıştır (Kantardzic, 2011: 89). Geliştirilen algoritmalarla endeks veya hisse senedi fiyatı yön tahmini yapılması kolaylaştığı gibi tahmin doğruluk oranları yükselmiştir.

Endeks ve hisse senedi fiyatı yönünü tahmin edebilmek için ilk önceleri geleneksel istatistik yöntemleri kullanılmış daha sonraları ise problemlerin karmaşıklaşmasıyla birlikte yeni yöntemler geliştirilmiştir. İstatistiksel tahmin teknikleri olarak Doğrusal Regresyon (DR), Lojistik Regresyon (LogR), Doğrusal Diskriminant Analizi (DDA), Random Walk (RW) ve ARIMA gibi yöntemleri sayabiliriz. İstatistiksel yöntemlerle ilgili katı kurallarının olması, veri setleri için

bazı şartları sağlama gereklilikleri ve problemlerin çözümü için esnek olamamaları tahmin başarılarını düşüren etkenler olmuştur.

Bu çalışmada, endeks hareket yönünün tahmin edilmesi hedeflenmiştir. Endeks hareket ve hisse senedi fiyat yönü tahmini, piyasalardaki fiyat hareketlerini öngörebilen bir teknik geliştirilemediğinden, finans dünyasında en fazla tartışılan ve araştırılan konulardan birisidir. Klasik istatistiksel yöntemler her ne kadar bu konuda kısmen başarılı olsa da son zamanlarda insan zekasını taklit ederek örnek verilerden öğrenebilen, sonuçları genelleyeabilen ve geleneksel istatistiksel tekniklere göre daha az kuralları olan makine öğrenmesi yöntemlerinin kullanımı yaygınlaşmakta ve artmaktadır. Makine öğrenmesi algoritmalarından olan Yapay Sinir Ağları (YSA), Aşırı Öğrenme Makineleri (AÖM), Destek Vektör Makineleri (DVM), Genetik Algoritmalar (GA), Karar Ağaçları (KA), Naive Bayes (NB) ve k-En Yakın Komşuluk (k-EYK) gibi yöntemler, borsa endeksi tahmininde kullanılan yöntemlerin başında gelmektedir. Yapılan tahmin uygulamalarında; esnek yapısı ve doğrusal olmayan ilişkileri modelleme gücü sayesinde makine öğrenmesi modellerinin, diğer ilgili uygulamalara göre araştırmacılar ve yatırımcılar tarafından daha etkin bir şekilde kullanıldığı görülmüştür. Bu tez çalışmasında endeks yön tahmini yapılması, teknik göstergelerin ele alınması ve performans karşılaştırması için makine öğrenmesi yöntemlerinin seçilmesi çalışmanın özgünlüğünü arttırmaktadır. Ayrıca çalışma, bilindiği kadarıyla literatürde ilk kez 7 yöntemin bir arada kullanıldığı çalışma olması özelliği taşımaktadır. Literatüre göre, makine öğrenmesi tekniklerinin geleneksel tekniklere göre daha yüksek tahmin doğruluğu sonuçları ürettiği tespit edilmiştir (Çalışkan ve Deniz, 2015: 192). Özellikle teknolojide meydana gelen hızlı gelişim ve değişimler bilgisayar temelli uygulamaların önemini arttırmıştır. Bu uygulamalar daha güncel, hızlı ve doğru tahminlerin yapılabilmesine katkı sağlamıştır.

Türkiye finansal piyasalarındaki belirsizliğin sonucunda piyasada oluşan düzensiz fiyat hareketleri finansal krizlerin yaşanmasına sebep olabilmektedir. Bu nedenle Türkiye ekonomisi durağan olsa da BİST, yatırımcıların edindikleri tecrübelerle olumsuz piyasa koşullarına çok duyarlı olduğu, çabuk tepki verdiği ve aldıkları riski yüksek miktarda getiriler ile telafi edebildikleri bir piyasa yapısına

sahiptir. Bu da Borsa İstanbul'u güçlü kılmakta ve yatırımcılar için cazip hale getirmektedir.

Kurulduğundan bu yana İstanbul Menkul Kıymetler Borsası (İMKB), sürekli olarak gelişerek büyümektedir. Günümüzde yeni adı ve yapısıyla BİST, kote olmuş 514 şirket, hesaplanan 324 endeks, 14 sektör ve 55 alt sektör, 10 pazar ve yükselen işlem hacmi ile gelişen borsalar arasında yer almaktadır. Dolayısıyla BİST üzerine yapılan çalışmaların literatüre anlamlı bir katkı yapması beklenmektedir.

Başarılı bir endeks hareket yönü tahminin yapılabilmesi için modelde kullanılan girdi değişkenleri olarak teknik göstergeler seçilmiştir. On teknik göstergenin yer aldığı eğitim veri seti için öznitelik seçimi yapılmıştır. Böylece boyut azaltımı yapılarak tahmin doğruluğunun artırılması hedeflemiştir. Ayrıca bağımsız değişken olarak kullanılan teknik göstergelere korelasyon analizi yapılarak değişkenler arasında doğrusal bir ilişkinin var olup olmadığı araştırılmıştır.

Modellerin endeks hareket yönü tahmin performansları iki boyutlu olarak değerlendirilmiştir. Sonuçlar ilk olarak istatistiksel ölçüm tekniklerinden olan hata oranları ile ikinci olarak da yön tahmin tekniklerinden doğruluk oranı ile karşılaştırılmıştır. Böylece tez çalışmasının sonuçları iki yönlü olarak değerlendirilerek çalışmanın güvenilirliği artırılmıştır.

Bu tez çalışması, dört bölümden oluşmaktadır. Birinci bölümde yapay zeka ve makine öğrenmesi konuları ele alınmıştır. İkinci bölümde sınıflandırma yöntemleri tanıtımı ve konu ile ilgili literatür araştırılmıştır. Üçüncü bölümde ise sermaye piyasaları ve Borsa İstanbul'un tanıtımı yapılmıştır. En son olarak da dördüncü bölümde çalışmanın uygulama kısmı yer almaktadır.

BİRİNCİ BÖLÜM

YAPAY ZEKA VE MAKİNE ÖĞRENMESİ

Bu bölümde makine öğrenmesini incelerken kullanılacak olan genel kavramlar ele alınacaktır. Makine öğrenmesi, yapay zeka alanının içinde incelendiğinden bu bölümde öncelikle yapay zeka kavramı, yapay zekanın amaçları, yapay zekanın gelişim süreci ve yapay zeka yaklaşımları konularına yer verilmiştir. Sonrasında makinaların öğrenme sürecine ilişkin temel kavramlar açıklanarak, öğrenme probleminin genel çerçevesi çizilmeye çalışılmıştır.

1. YAPAY ZEKA

Yapay zeka ile ilgili kavramlara ve literatürdeki tanımlara yer verilerek bu kısma başlanmıştır. Yapay zeka kullanımı sayesinde nelerin amaçlandığından bahsedildikten sonra yapay zekanın tarihsel süreçte geçirdiği evrim anlatılmıştır. En son olarak güncel yapay zeka yaklaşımları detaylı olarak ifade edilerek kısım tamamlanmıştır.

1.1. YAPAY ZEKA KAVRAMI

İnsanoğlu zekasını ve davranışlarını taklit edebilecek makineler yapma düşüncesiyle yapay zeka kavramı ortaya çıkmıştır. İlk defa yapay zeka kavramsal olarak McCarthy (1956) tarafından zeki makineler yapma bilimi olarak tanımlanmıştır.

Zeka kavramı, Altuntaş ve Çelik (1998: 18) tarafından bilginin beyin aracılığı ile idrak edilip, en kısa sürede ve doğru olarak çözümlemesi biçiminde açıklanmıştır. Başka bir tanımda McCarthy (1956) zekayı, hayattaki amaçlara ulaşma olanağının hesapsal yanı olarak ifade etmiştir. Emir'e (2013: 4) göre ilk karşılaşılan veya aniden gelişen bir duruma adapte olma, anlama, öğrenme, analiz etme zeka ile yapılır.

Yapay zeka, insanların ve makinelerin sergilediği akıllı davranışın ne olduğunu araştıran ve insanların yaptığı aygıtların akıllı davranışları nasıl sergileyebileceğini keşfetmeye çalışan bilimsel bir alandır (Göksungur, 2008: 84).

Yapay zeka, kendimiz ve dünyamız hakkında en zor sorulardan bazılarını bilimsel cevaplar sunar. Bu nedenle, yapay zeka her zaman sanat, bilim ve psikoloji alanlarında araştırma konusu olagelmıştır (Whitby, 2005: 17-19). Yapay zeka sadece anlamak için değil, aynı zamanda akıllı sistemler kurmak için çalışır (Russell ve Norvig, 2010:1).

Yapay zeka, insanların yapabildiği zeki davranışların ve düşünme faaliyetlerinin makineler tarafından da yapılabilmesi ve insan zekasının taklit edilmesidir (Negnevitsky, 2004: 18).

Literatüre "Yapay Zeka" olarak giren ifade insanların zihninde farklı algılar oluşturmaktadır. Kimilerine göre hayatı kolaylaştıran bir bilgisayar programı, kimilerine göre de bir insanın yaptığı işleri yapabilen bir robotu ifade etmektedir. Yapay zeka araştırmalarının konuları zamanla gelişim göstererek yapay zeka yaklaşımlarına dönüşmüştür. Bu yaklaşımlar; insan gibi karar veren sistemler ve rasyonel karar veren sistemlerdir. Dolayısıyla yapay zeka, insan gibi düşünen ve davranan sistemler geliştirmeyi amaçlar. Bilgisayarın veya kontrol ettiği bir makinenin, anlama, fikir yürütme, deneyimlerden öğrenme ve genelleme gibi yüksek performanslı beyin faaliyetlerinin yerine getirilmesi genellikle insan benzeri özellikler olarak varsayılır (Negnevitsky, 2004: 18).

Yapay zekaya sahip makineler şuan ki teknoloji ile insanda var olan duygu, mimik, karakter ve yaratıcılığı taklit edebilme becerisini gösterememektedir. Ancak basit fiziksel insan davranışlarını taklit eden robotların geliştirilmesi, yüksek veri işleme kapasitesine sahip bilgisayarların yapılması, veri analizi üzerinden tıbbi teşhis yapabilme yeteneği olan uzman sistemler ve insan düşünme sürecini taklit eden yeni sistemler üretilmektedir (Ertel, 2011: 1). Bu ürünlerin ekonomik bir değer ifade etmesi ise ticarileştirilebilmelerine bağlıdır.

Yapay zekanın temel kaynağı insan zekasıdır. Fakat, insan zekası tamamıyla araştırılıp keşfedilemediği için çalışma sistemi anlaşılammıştır. Yapay zeka araştırmalarının önemli amaçlarından biri, insan zekasının işleyişini anlamaktır. Böylece insan zekasını taklit eden sistemler geliştirilmesi mümkün olacaktır (Ertel, 2011: 1).

Yapay zeka alanında her yapılan çalışma, hayatımıza katkı sağlayan yenilikler içerirken aynı zamanda yapay zekanın sınırlarını genişletmektedir. Yapay zeka çalışmaları, sorularımıza cevap aramaktan çok ortaya yeni soruların, yeni araştırma konularının çıktığı bir hale evrilmiştir. Öyle ki araştırmacılar yapay zekayı hareket eden bir ufuk olarak tanımlamışlardır.

1.2. YAPAY ZEKANIN AMAÇLARI

Genel olarak yapay zekanın amaçları üç ana başlıkta ifade edebilir; makineleri daha zeki hale getirmek, zeka kavramını anlamak, makineleri insanlığa daha faydalı hale getirmek.

Yapay zekanın amacı insan gibi düşünen veya akıllı davranış sergileyebilen robot ve zeki sistemler üretmektir. Zekanın işaretleri ve zeki davranış olarak kabul edilen davranış türlerine örnek olarak; sorunları çözebilmek için muhakeme etme, ani gelişen durumlara adapte olma, karışık mesajları anlamlı hale getirme ve deneyimlerden öğrenme verilebilir (Steels, 1993: 2).

Yapay zekanın bir başka amacı da insanların sergilediği yüksek beyin fonksiyonları ile otonom davranışları sergileyen işletim sistemi olmasıdır. Bu yapay işletim sistemi insan gibi düşünebilmeli ve bu düşünceler sonucunda ortaya tepkilerini koymalı, fiziksel dışa vurumlar yapabilmelidir (Negnevitsky, 2004: 21).

Yapay zeka araştırmaları büyük ölçüde teoriktir. Çünkü insan beyninin çalışır bir versiyonunun anlaşılması, somut bir örneği yoktur. İnsan zekasının işleyişini anlamak, kendimiz ve dünya hakkında bilimsel cevaplar sunabilmek, hayatımıza yenilikler katmak yapay zekanın amaçları arasında yer alır.

1.3. YAPAY ZEKANIN TARİHSEL GELİŞİM SÜRECİ

Yapay zeka kavramının tarihsel gelişimi modern bilgisayarlara dayanmaktadır. II. Dünya Savaşında İngiliz matematikçi Alan M. Turing'in dile getirdiği "Makineler düşünebilir mi?" sorusu yapay zeka konusu ile ilgili ilk fitili ateşlemiştir. Alan M. Turing, savaş döneminde karşı tarafın şifrelerini çözmek maksatıyla başlatılan çalışmalarda yer almıştır. Bu çalışmalarda bilgisayarları işleme mantığı geliştirmiştir. Böylece makine zekası kavramı oluşmuştur.

Bu alanda yapılan önemli çalışmalar şu şekilde özetlenebilir.

1930: İngiliz matematikçi Alan M. Turing, hesaplama otomatı geliştirerek bunu ilk İngiliz elektronik bilgisayar yapımında kullanıldı.

1943: Biyolojik sinir hücresini modelleme fikrinden yola çıkan Warren McCulloch ve Walter Pitts yapay sinir ağ teknolojisini geliştirerek yapay sinir ağlarının problemleri öğrenebileceğini ve çözüm geliştireceğini iddia etmişlerdir.

1948: Neumann, bilgisayar programlarının kendi kendini kopyalayabileceği düşüncesini ileri sürmüştür.

1950: Shannon tarafından satranç programı yazılmıştır.

1950: Alan M. Turing, Turing Testini geliştirmiştir.

1951: Minsky ve Edmonds, yapay sinir ağı temelli ilk bilgisayar olan SNARC'ı yapmışlardır.

1951: Manchester Üniversitesinde Ferranti Mark 1 adlı aygıt için ilk yapay zeka programları yazılmıştır.

1952-1962: Samuel tarafından satranç oynayabilen bilgisayar geliştirilmiştir.

1956: McCarthy bir yaz çalışma kampında “yapay zeka” kavramı ilk kez ortaya atmıştır.

1956: İnsanın problem çözme yeteneğini taklit eden ve “Mantık Kuramcısı (Logic Theorist)” adı verilen ilk yapay zeka programı Allen Newell, Herbert Simon ve J.C. Shaw tarafından yapılmıştır.

1958: Cambridge Üniversitesi'nde Masterman ve arkadaşları tarafından semantik ağlar geliştirilmiştir.

1958: McCarthy, MIT'de yaptığı çalışmalarda LISP yapay zeka programlama dilini geliştirmiştir.

1960: Licklider, insan-makine simbiyozu* konusunu bir makalesinde anlatmıştır.

1961: James Slagle, matematik problemlerini çözebilen LISP tabanlı Saint (Aziz) programını geliştirmiştir.

* Simbiyoz: İki organizmanın yardımlaşarak tek bir organizma gibi birlikte yaşamaları.

1962: Unimation isimli ilk endüstriyel robot şirketi kurulmuştur.

1963: Thomas Evans MIT çatısı altında IQ testi sorunlarını çözebilen Analogy (Benzeşim) programını geliştirmiştir.

1963: Yapay zeka hakkındaki ilk makale olan Bilgisayarlar ve Düşünce, Edward A. Feigenbaum ve Julian Feldman tarafından yayımlanmıştır.

1965: Lotfi A. Zadeh “Bulanık Mantığı (Fuzzy Logic)” geliştirerek yapay zeka alanında büyük bir ilerleme sağlamıştır.

1965: Ingo Rechenberg ve Hans-Paul Schwefel, popülasyon genetiğinin optimizasyon ve öğrenme problemlerine uygulanmasını içeren “Evrimsel Hesaplama (Evolutionary Computation)” teknolojisini geliştirmişlerdir.

1965: Sohbet edebilen yapay zeka programı ELİZA geliştirmiştir.

1966: Hareket edebilen ilk robot "Shakey" Stanford Üniversitesi'nde yapılmıştır.

1974: Vint Cerf ve Bob Kahn tarafından “İnternet” kelimesi ilk kez telaffuz edilmiştir.

1975: John Henry Holland’ın genetik bilimini bilgisayar programlarına aktarmasıyla “Genetik Algoritmalar (Genetic Algorithms)” adı verilen yapay zeka teknolojisi ortaya çıkmıştır.

1978: Yapay zekada sınırlı rasyonalite teorisini kuran Herbet Simon, Nobel ödülü almıştır.

1981: İlk kişisel bilgisayar IBM tarafından satışa sunulmuştur.

1993: İnsana benzeyen “Cog” ismi verilen robot MIT’de yapılmaya başlanmıştır.

1997: Tarihte ilk kez bir bilgisayar (Deep Blue), dünya satranç şampiyonu Gary Kasparov'u yenmiştir.

1998: İlk yapay zeka oyuncuğu olan Furby'yi Tiger Electronics firması üretmiştir.

2000: Mimik ve yüz hareketlerini kullanabilen insansı robot Kismet, Braezeal tarafından tanıtılmıştır.

2005: İnsan gibi yürüyebilen, en becerikli robot Asimo'yu Honda firması tanıtmıştır.

2010: Asimo zihin gücüyle hareket ettirilmiştir.

2011: IBM tarafından geliştirilen yapay zeka programı Watson, Jeopardy adlı bilgi yarışmasını önceki şampiyonları yenerek kazanmıştır.

2011: iPhone 4S ile birlikte akıllı kişisel asistan Siri kullanılmaya başlanmıştır.

2012: Google tarafından geliştirilen yapay zeka, YouTube'da ilk olarak kedi videolarını keşfetmiştir.

2014: Turing testi, Chatbot 'Eugene Goostman' tarafından geçilmiştir.

2015: Otonom sürüş yapabilen arabalar tanıtılmıştır.

2016: Mikro yüz ifadelerini yansıtabilen ve insan gibi hissedebilen insansı robot Jia Jia tanıtılmıştır.

2017: Hanson Robotics tarafından insana en çok benzeyen robot Sophia geliştirilmiştir.

2018: Massachuseyts Teknoloji Enstitüsü tarafından SoFi adlı uzaktan kumandalı robot balık geliştirilmiştir.

Son yıllarda tüm bilim çevrelerinde yapay zeka uygulamalarına yönelik büyük bir ilgi artışı gözlenmiştir. Akademi dünyasında bu konuyla ilgili olarak birçok makale yayınlanmış, dergiler özel ekler basmış, yapay zeka kitapları basılmıştır. Uluslararası düzeyde konferanslar düzenlenmiş ve araştırma kuruluşları raporlar yayınlamıştır.

Ticari uygulamaları geliştirilen uzman sistem teknolojilerinin yakaladığı başarı, yapay zekayı önemli bir endüstri kolu haline getirmiştir. Yapay zeka araştırmalarında büyük bir artış yaşanarak Ar-Ge çalışmalarına ayrılan kaynak miktarları artmıştır. İlerleyen yıllarda bilgisayar teknolojisindeki gelişmelere paralel

olarak üretilen güçlü bilgisayarlar ile yapay zeka çalışmalarında büyük projeleri yapabilmek olanaklı hale gelecektir.

Yapay zekanın düşünce gelişimi ve yenilik olarak daima insana ihtiyacı olacaktır. Araştırmacılar, insanların yapay zeka teknolojilerini geliştirirken iyimser düşüncelerle hareket ediyor olsalar bile sonuçlarını iyice düşünerek hareket etmelerini salık veriyorlar. Endüstri 4.0 ile birlikte işsizliğin artacağını ve sosyal patlamalar yaşanabileceğini ifade ediyorlar.

1.4. YAPAY ZEKA TEKNOLOJİLERİ

Beynin çalışma mekanizmalarını anlamaya yönelik araştırmalar, farklı yaklaşımlara ve dolayısıyla farklı yöntemlere yol açmıştır. Yapay zeka teknolojileri, geleneksel ve hesaplama dayalı yapay zeka teknolojileri olarak ikiye ayrılabilir.

1.4.1. Geleneksel Yapay Zeka Teknolojileri

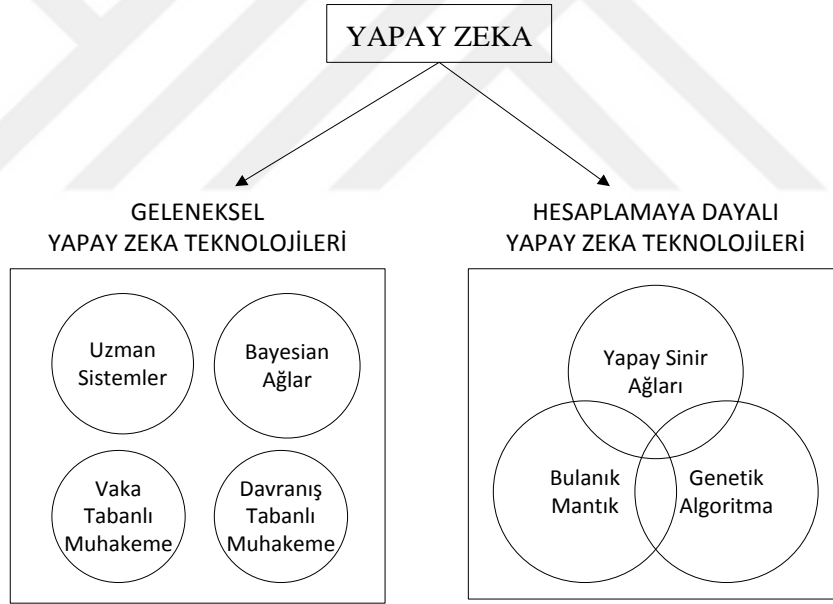
Geleneksel yapay zeka teknolojileri yüksek maliyetli bellek kaynaklarından oluşan derin noral ağları kullanır. Bayesian Ağlar ve uzman sistemler bu grubun örneklerindedir. Naive Bayes Ağları modeli, bir problem için yaratılan olasılık ilişkileri barındıran rastgele değişkenlerden oluşan grafiksel bir yaklaşımdır (Bakar ve Hamid, 2012: 166). Bu yapı içerisinde, tüm rastgele değişkenler tek bir ebeveyn düğüme bağlıdır ve daha çok bir sınıflandırma yaklaşımı olarak kullanılmaktadır (Aghaie ve Saeedi, 2009: 452). Daha fazla miktarda bilgi işlenmesi gerektiğinde uzman sistemlere ihtiyaç duyulmaktadır. Uzman sistemler, uzmanlık konularında danışılan ve karmaşık işlerin yapılmasında yol gösteren bilgisayar programlarıdır. Sistemi kullanan kişiye bir problemin çözülmesinde uzman görüşü sunar (Tekin vd., 2005: 387). Uzman Sistemler, problemin çözümüne ilişkin kural üreten sistemlerdir (Akgöbek ve Çakır, 2009: 804). Böylece, üretilen bu kurallarla problemlerin çözümünde uzman bilgisi kullanmış olurlar (Özkan ve Gülesin, 2001: 171).

1.4.2. Hesaplama Dayalı Yapay Zeka Teknolojileri

Hesaplama dayalı yapay zeka teknolojileri öğrenme verilerini ve yüksek düzeyli algoritmaları kullanarak her sistemin özel ihtiyaçlarına uyum sağlar. Bulanık mantık, genetik algoritma ve yapay sinir ağları bu gruba örnek verilebilir.

Yapay sinir ağıları, eğitim setindeki bilgileri öğrenme sürecine dahil olan ağılar sayesinde öğrenerek gelecekteki bilgileri tahmin etmek için kullanılmaktadır. Bulanık mantık, tam verinin bulunmadığı durumlarda problemlere insan gibi düşünüp davranabilen bir yaklaşım geliştirmektedir (Lin ve Lee, 1996: 498). Genetik algoritma, eniyileme problemlerini çözmek için uygulanan bir yöntemdir. Önce yapılması gereken şey, rasgele seçilmiş değerlerin oluşturduğu bir sonuç bulmaktır. Çözümler eşleştirilerek en iyi sonuçlar elde edilir. Tekrarlama yöntemiyle optimum sonuç bulununcaya kadar devam edilir. Yapay zeka teknolojileri problemlerin özelliklerine bağlı olarak ayrı ayrı veya birlikte kullanılabilir. Yapay sinir ağıları ile girdi-çıkı arasında ilişkilere ve genetik algoritma ile gizli katman ve nöron sayısı belirlenebilir. Problemlerde belirsiz durumlar varsa, bu yaklaşımlara bulanık mantık eklenebilir. Yapay zeka teknolojilerinin sınıflandırılması Şekil 1’de gösterilmektedir.

Şekil 1. Yapay Zeka Teknolojilerinin Sınıflandırılması (Lin ve Lee, 1996: 498).



1.5. YAPAY ZEKA YAKLAŞIMLARI

Yapay zeka araştırmacıları ilk önceleri “insan gibi düşünme” yaklaşımına göre çalışan programlar geliştirmişlerdir. Daha sonraki yıllarda mantık temelli çalışmalar egemen olmuş “rasyonel karar veren sistemleri” yapmayı hedeflemişlerdir. Yapay zeka konusunda karşımıza çıkan dört temel yaklaşım vardır (Russell ve Norvig, 2010: 2).

- İnsan gibi karar veren sistemler → İnsan gibi düşünen sistemler
→ İnsan gibi davranan sistemler
- Rasyonel karar veren sistemler → Rasyonel düşünen sistemler
→ Rasyonel davranan sistemler

Yapay zeka yaklaşımları aşağıdaki gibi özetlenebilir.

1.5.1. İnsan Gibi Düşünme (Bilişsel Modelleme) Yaklaşımı

Belli bir bilgisayar programının insana benzer düşünebildiği söylenecekse, düşünme olayının nasıl gerçekleştiğinin bilinmesi gerekir. İnsan zihninin gerçek işleyişi psikolojik deneylerle saptanabilir. Zihin işleyişi ile ilgili yapılan deneyler daha sonra bir teoriye dönüştürülür ve bu teoriyi bilgisayar programı olarak ifade etmek mümkün hale gelir. Programın girdi ve çıktılarına karşılık gelen davranış insan davranışıyla eşleşirse, bu da programın bazı mekanizmalarının insan beyni gibi çalışabileceğinin kanıtı olmaktadır. İnsan gibi düşünen sistemler bilişsel bilim alanında yapılan çalışmalar ile üretilmiştir. Bilişsel bilim, insan zihninin kesin ve test edilebilir teorilerini oluşturmak için yapay zekadaki bilgisayar modellerini ve psikolojik deneysel teknikleri bir araya getirir (Russell ve Norvig, 2010: 3).

1.5.2. İnsan Gibi Davranma (Turing Testi) Yaklaşımı

Turing testi, Alan M. Turing (1950) tarafından insanın diğer tarafı göremeyecek veya duyamayacak şekilde kapalı bir odada bulunup, metin mesajı benzeri program kullanarak iletişim kurması ve konuşmanın sonunda diğer tarafın insan ya da makine olduğunu düşünüp düşünmediğini ifade etmesi üzerine kurulan testtir (Berglas, 2015: 42). Birçok yapay zeka yazılımı bu teste gerek duyulmayacak ölçüde sınırlı ve basit düzeydedir (Negnevitsky, 2004: 4). İnsan gibi davranışı üreten bir bilgisayarın, insan beynindeki süreçlerin modellenmesiyle olabileceği gibi başka prensiplerle çalışması da mümkün olabilir. Turing testi, 2014 yılında gerçekleştirilen denemelerde Eugene Goostman programı tarafından ilk kez geçilmiştir (Berglas, 2015: 42).

1.5.3. Rasyonel Düşünme (Düşünce Kanunları) Yaklaşımı

Yunan düşünür Aristoteles, “doğru düşünceyi” kodlamak isteyen ilk kişilerden biriydi. Aristo’ya göre düşünce bir süreçten oluşmaktaydı. Bu akıl yürütme sürecine göre: “Sokrates bir insandır; bütün insanlar ölümlüdür; bu nedenle Sokrates ölümlüdür”. Bu düşünce yasaları zihnin işleyişini gösteren sistematiklerdi. Bu çalışmalar “mantık” adı verilen yeni bir alanı başlattı. Yapay zeka içerisindeki mantıkçı gelenek, akıllı sistemler yaratmak için bu tür programları geliştirmeyi amaçlamaktadır (Russell ve Norvig, 2010: 4).

Bu yaklaşımın iki ana engeli vardır. Birincisi, mantık formel bir dil kullanır. Günlük hayattaki belirsizlik içeren bilgileri mantığın kullandığı dille ifade etmek kolay değildir. İkincisi, "prensipl olarak" bir problemi çözmekle pratikte çözmek arasında büyük bir fark vardır.

1.5.4. Rasyonel Davranma (Zeki Ajan) Yaklaşımı

Zeki ajan, en iyi sonuca ulaşmak veya belirsizlik olduğunda en iyi beklenen sonucu elde edecek şekilde davranan bir aracıdır. Tüm bilgisayar programları bir şeyler yapar, ancak zeki ajanların daha fazlasını yapmaları beklenir. Çevreyi algılayabilir, uzun süre devam edebilir, rasyonel davranma değişimine uyum sağlayabilir ve hedefler yaratabilir ve takip edebilir (Steels, 1993: 13).

Yapay zeka düşüncesinin "düşünce kanunları" yaklaşımında, vurgu doğru çıkarımlar üzerine yapıldı. Doğru çıkarımları yapmak rasyonel bir ajan olmanın önemli bir göstergesidir. Rasyonel davranmak mantık çerçevesinde belirli bir eylem yapılırsa bir hedefe ulaşacağı biliniyorsa bu sonuca varacak şekilde davranmaktır. Turing Testi için gerekli tüm beceriler bir ajanın rasyonel olarak hareket etmesine izin verir. Bilgi keşfi ve akıl yürütme, ajanların iyi kararlara ulaşmasını sağlar (Russell ve Norvig, 2010:4).

Rasyonel davranış yaklaşımı, diğer yaklaşımlara göre iki avantaja sahiptir. İlk olarak, "düşünce yasaları" yaklaşımına göre rasyonelliği sağlamak için daha genel mekanizmalar sunar. İkinci olarak, insan davranışına veya insan düşüncesine dayanan yaklaşımlardan daha çok bilimsel gelişime uygundur (Russell ve Norvig, 2010:4).

2. MAKİNE ÖĞRENMESİ

İnsanođlu çevreye uyum sađlama konusunda yüzyıllardır çalışmaktadır. Bu süreçte davranışlarda meydana gelen sürekli deđişimler öğrenme olarak ifade edilmektedir (Kantardzic, 2011: 89). Bilgisayarların öğrenme kabiliyetinin insandan daha düşük olduđu düşünülürse, öğrenme mekanizmalarına yönelik araştırmalar yapılması ve makine öğrenme algoritmalarının geliştirilmesi yapay zekanın en önemli konularını oluşturmaktadır (Ertel, 2011:161).

Yapay zeka, zeki makineler ile ilgili olduğuna göre “makine nedir?” sorusu gündeme gelmektedir. Birçok insana göre, bir makine oldukça sağlam bir şeydir; dişlileri olan ve çelik kısımlardan oluşan bir aleti çağırıştırır. Ancak günümüzde bilgisayar, bir makinenin ne olabileceđi konusundaki düşünceleri büyük ölçüde yeniden tanımlamıştır. Bir bilgisayar sistemi, hem donanım hem de yazılımdan oluşur ve sıklıkla yazılımın kendisi bir makine olarak düşünülmektedir. Örneđin, satranç oynayan makinelere veya akıllı ev aletlerine atf yapıldığında bu işleri yapan programları “makine” olarak ifade etmiş olunur (Nilsson, 2010: 14). Öğrenen makine kavramındaki makineler; televizyon, cep telefonu veya bir fırın gibi donanımlar olabilir ama makinelerin öğrenmesini sađlayan esas şey bu öğrenme işlerini gerçekleştiren bilgisayar programları ve yazılımlarıdır (Alpaydın, 2014: 2). Öğrenme işini insanlar yerine bir makine için düşündüğümüzde bu durumun bir hayli zor ve sancılı bir süreç olduğu görülmektedir. Yapay zeka ve istatistik bilimlerinin ortak çalışması ile makine öğrenmesi alanında çeşitli yazılımlar ve algoritmalar üretilerek bu problem aşılmaya çalışılmıştır (Kantardzic, 2011: 89).

Makine öğrenmesi, bilgisayar programlarının yazılmasının yanı sıra, insan öğrenme davranışını taklit edebilen somut algoritmaların tasarımı ve gerçekleştirilmesi ile ilgilenmektedir. Bilim insanlarının temel amacı makineleri insan gibi düşünüp davranabilen sistemler haline getirebilmektir. Makine öğrenmesi örüntü tanıma, veri madenciliđi ve sinir ađları gibi birçok ilgili disiplini içerir. Son yıllarda tanık olduğumuz gibi, satranç oynayan bilgisayarlar, hedef izleme füzeleri, görev robotları ve otonom uçabilen uçaklar bu alanlarda yapılmış çalışmaların günlük hayatta kullanıma sunulmuş bazı ürünleri olarak sıralanabilir.

Teknolojinin gelişmesi ve yaygınlaşmasıyla dijital cihaz sayısındaki patlama ile bu cihazlardan üretilen veri miktarı geometrik bir artış göstermiştir. Büyük miktardaki veri ön-işleme yapılarak bilgiye dönüştürülür. Bilgi, yeni veriler üretildikçe sürekli olarak güncellenebilir veya düzeltilebilir bir model olarak tanımlanır. Modeller, müşterilerin çevrimiçi davranışlarına ve satın alma geçmişlerine, kredi risk değerlendirmesi, yüz tanıma, hizmet kalitesinin en üst düzeye çıkarılması, hastalığın patolojik belirtilerinin sınıflandırılması, bilgisayar ağlarının optimizasyonu ve güvenlik saldırı tespiti gibi alanlara özgüdür (Bugnion, Nicolas ve Kozlov, 2017: 518).

Büyük veri setleri ile çalışmak makine öğrenmesinin sağladığı otomatik veri analiz yöntemlerini kullanmayı gerekli kılar. Özellikle, makine öğrenimi veri içindeki kalıpları otomatik olarak algılayabilen ve daha sonra ortaya çıkacak verileri tahmin etmede veya belirsizlik altında diğer karar verme türlerini yerine getirmek için kullanan bir dizi yöntem olarak tanımlanır (Murphy, 2012: 1).

Bir makine öğrenmesinin davranışı nasıl değiştireceği şu şekilde ifade edilebilir (Mitchell, 1997: 2):

“Eğer bir bilgisayar programının T görevlerindeki, E deneyimi ile ölçülen P performansı yükseliyorsa, T görevlerinin sınıf doğruluğu ve ölçülen P performansına göre o bilgisayar programı E deneyimini öğrendiği söylenir.”

Bahsedilen durum örnek olay halinde incelenirse:

- T görevi, borsa yatırımcılarının hisse senedi seçiminin doğru sınıflandırılması
- P performansı, hisse getirisi doğru olarak belirlenmiş müşteri oranı
- E deneyimi, portföy yönetim şirketinin bugüne kadar yaptığı müşteri portföylerinin kayıtlarını içeren veri tabanı

Bir müşteriye hangi hisselerin seçilip seçilmemesi işlemini yapacak brokerin, deneyimli ve bilgili bir portföy yöneticisi olması beklenir. İşlemi yapacak broker varsayılan niteliklere haiz olsa bile, hangi hisselerin seçilip seçilmemesi olayının arkasındaki gerçek faktörleri bir insanın inceleyip karar vermesi kolay bir iş değildir. Bir veya iki hisse için analiz yapmak kolay olmasına karşın pekçok müşteri için

pekçok analiz gerekli olacağından doğru kararı vermek zor, hata olasılığı fazla olacaktır. Hisse seçme işlemini yapan bir bilgisayar programı olsaydı önce bilgisayarın hisse analizinin nasıl yapılacağını öğrendiği bir süreç geçirmeliydi. Bu durumda bilgisayar programı borsa yatırım şirketine ait veri tabanını öğrenerek birçok hisse analizini ve teknik bilgiyi içeren bu veri tabanında, daha önce hisse seçilen müşterilerin portföylerine etki eden faktörleri inceleyerek buradan aldığı bilgilerle sonraki müşterilere daha etkin bir hisse analizi yapar. Bilgisayar programının doğru hisse seçimi yapıp yapmadığı, müşterilerin portföy başarısına yani hisse getirisi doğru olarak belirlenmiş müşteri oranına bakılarak bulunabilir.

Bu örnek olaydan hareketle literatürde makine öğrenmesi ile ilgili yapılmış tanımlara bakıldığında; Makine öğrenmesi, veriden ilginç ve faydalı örüntüleri ortaya çıkarmak için algoritma ve programları kullanan, performansını deneyimler ile arttırdığında öğrenmiş olduğu kabul edilen bir öğrenen sistemdir (Harrington, 2012: 5, Domingos, 2012: 78, Blum, 2007: 1). Diğer bir ifadeyle makine öğrenmesi, geçmiş deneyimleri kullanarak performans optimizasyonu yapabilen bilgisayar programları geliştirmektir (Mitchell, 1997: 4, Alpaydın, 2014: 3, Mohri ve diğ., 2012: 1, Hal Daumé III, 2012: 113).

2.1. MAKİNE ÖĞRENMESİNİN AMACI VE ÖNEMİ

İçinde yaşadığımız dünyada davranışlarını gözlemlediğimiz olaylar süre gelmektedir. Makine öğrenmesindeki temel soru, çevremizde gelişen bu olaylara, davranışlara veya düşüncelere dayalı kalıpları keşfetmek ve tarif etmek için bilgisayarlar kullanabilir mi? sorusudur. Makine öğrenmesi bu amaçla çeşitli bilgisayar algoritmaları üreterek davranış ve düşünceleri öğrenebilen ve çözümler sunan sistemler geliştirmektedir (Hamel, 2009: 4). Makine öğrenmesinin amacı doğru sınıflandırılmış verilerden örüntüyü öğrenerek daha sonrasında tahmin kümesindeki veriler için orijinal örüntüye mümkün olduğunca yakın olan bir sınıflandırma işlemi için uygun bir model tasarlamaktır (Hamel, 2009: 4-5).

Makine öğrenmesi, birtakım algoritmalara bağlı olarak oluşturulmuş bir model ve bu modelin performansının ölçüldüğü bir veri setinden oluşan bir sistemdir. Makine öğrenmesinin amacı, kullanılan modelin en iyi performansı sağladığı parametre değerlerinin bulunması, tahmin özelliği güçlü ve karar vermeye yardımcı

bir model olup olmadığı ve veriden bilgiye ulaşmakta kullanılabilmesidir (Alpaydın, 2014: 4).

Makine Öğrenmesi, öğrenmenin temel ilkelerini bir hesaplama süreci olarak anlamayı amaçlar. Bu alan, hassas matematiksel düzeyde, farklı görev türlerini başarılı bir şekilde öğrenmek için yetenekler ve bilgilerin ne olduğunu ve bilgisayarlardan veri öğrenmeye ve geribildirimle performansı artırmaya yönelik temel algoritmik ilkeleri anlamayı amaçlamaktadır. Makine öğrenmesinin hedefleri hem daha iyi otomatik öğrenme yöntemleri tasarlamaya yardımcı olmak hem de öğrenme sürecindeki temel konuları anlamaktır (Blum, 2007: 1).

2.2. MAKİNE ÖĞRENMESİNİN AVANTAJLARI

Makine öğrenmesinin avantajları şunlardır (Brink, Richards ve Fetherolf, 2016: 16):

- **Doğruluk:** Makine öğrenimi, problemin çözümünde en iyi sınıflandırma modelini seçmek için verileri kullanır. Daha fazla veri toplandığında doğruluk otomatik olarak artabilir.
- **Otomatiklik:** Veriler sisteme yüklendiğinde, makine öğrenme modeli otomatik olarak yeni örüntüler öğrenebilir. Bu durum, kullanıcılar için makine öğrenmesi modelleri ile çalışırken otomatik bir iş akışına doğrudan sahip olmalarını sağlar.
- **Hızlılık:** Sistemlerin gerçek zamanlı tepki vermesine olanak tanıyan makine öğrenimi, yeni veri akışları geldiğinde milisaniye içerisinde cevaplar üretebilir.
- **Özelleştirilebilirlik:** Veriden kaynaklanan birçok sorun makine öğrenimi ile giderilebilir. Makine öğrenme modelleri, sisteme yüklenen verilerden özel olarak oluşturulmuştur ve problem ne olursa olsun çözümü optimize etmek için yapılandırılabilir.
- **Ölçeklenebilirlik:** Problem büyüdükçe, makine öğrenimi artan veri oranlarını işlemek üzere kolaylıkla ölçeklenir. Bazı makine öğrenme algoritmaları, sistemdeki büyük miktarda veriyi işlemek üzere birçok makineye ölçeklendirebilir.

2.3. TEMEL ÖĞRENME PROBLEMLERİ

Öğrenme algoritmaları gerçek hayatta birçok probleme uygulanmaktadır. Bu uygulamalar çok çeşitli öğrenme problemlerine karşılık gelmektedirler. Genel olarak öğrenme problemi, sınıflandırma, regresyon, kümeleme ve birliktelik kuralı olarak dört alt başlıkta incelenebilir. Bu problemlerin her biri için hata değerleri ve çıktı değerleri birbirinden farklıdır. Bununla birlikte, yalnızca eğitim kümesindeki verilerin hata değerinin minimize edilmesi tüm öğrenme problemleri için ortak amaçtır (Cherkassky & Mulier, 2007: 25).

2.3.1. Sınıflandırma (Classification)

Sonlu sayıda ayrık sınıfın bulunduğu bir sistemde her bir girdi verisini, bir sınıfa etiketlemeyi hedefleyen işlemler sınıflandırma olarak ifade edilmektedir (Bishop, 2007: 181). Bir sınıflandırma modeli örneklerden tahmin edilen sınıfların oluşturduğu bir doğrulama haritasıdır (Fawcett, 2006: 861).

Sınıflandırma işlemlerinde görüntü kümesindeki elemanlara sınıf, sınıflandırmayı yapan hesaplama modeline de sınıflandırıcı denilmektedir (Camastra ve Vinciarelli, 2015: 171). İkili sınıflandırma probleminde çıktı değerleri sadece sınıflara karşılık gelen değerler olabilir. Bu etiketlerden oluşan kümeye görüntü kümesi denir. Sınıf etiketleri farklı değerler olabilir. İkili sınıflandırma probleminde görüntü kümesi yani sistemin çıktısı $\{0,1\}$ değerlerini alabilir. Burada 1 değeri sınıfa üye olma durumunu, 0 diğeri ise sınıfa üye olmama durumunu gösteren iki farklı etiketi ifade eder.

İkili sınıflandırma problemlerinde geniş ölçüde kullanım alanı bulan kayıp fonksiyonu sınıflandırmada oluşabilecek hatayı ölçer (Cherkassky & Mulier, 2007: 26). Bu durumda öğrenme, yalnızca eldeki eğitim verisini kullanarak, yanlış sınıflandırma olasılığını minimize eden gösterge fonksiyonunun tahmini problemi haline gelir (Kantardzic, 2011: 92).

Bir sınıflandırıcı, $\hat{c}:X\rightarrow C$, $C=\{C_1, C_2, \dots, C_n\}$ şeklinde ifade edilebilir (Flach, 2012: 52). Sınıflandırıcının $\hat{c}(x)$ biçiminde gösterilmesinin sebebi, varlığı bilinen ama sınıfı belli olmayan $c(x)$ fonksiyonunun tahmini olmasıdır. Sınıflandırıcının etiketleri $(x, c(x))$ şeklinde gösterilir, $c(x)$ ise gerçek sınıf değerini vermektedir.

Sınıflandırma sonuçları ölçülürken her bir girdi verisi için alınan her bir sınıflandırma kararının birbirinden bağımsız olduğu kabul edilir. Veriden kaynaklanan bağımlı durumlar ihmal edilebilir (Murphy, 2012: 3).

Sınıflandırma, makine öğrenmesinin popüler konularındandır ve bilmediğimiz bir verinin bildiğimiz bir sınıfa atanması işlemidir (Harrington, 2012: 7). Sınıflandırmada yani diğer adıyla örneklerden çıkarımda amaç, algoritmaya girmemiş örnekleri en yüksek doğrulukla etiketleyebilen sınıflandırıcıyı bulmaktır (Çakır, 2005: 47). Ana hedef sistemin daha önce görmediği yeni girdiler hakkında tahminler yapmaktır (Murphy, 2012: 3).


Sınıflandırma, veri sınıflarını açıklayan modelleri çıkaran bir veri analizi biçimidir. Sınıflandırıcılar adı verilen bu tür modeller, kategorik (ayrık, sırasız) sınıf etiketlerini öngörür. Örneğin, banka kredisi uygulamalarını güvenli veya riskli olarak sınıflandırmak için bir sınıf modeli oluşturabiliriz. Bu tür analiz, geniş kapsamlı verilerin daha iyi anlaşılmasına yardımcı olabilir. Araştırmacılar tarafından makine öğrenmesi, kalıp tanıma ve istatistik konularında birçok sınıflandırma yöntemi önerilmiştir. Son zamanlarda veri madenciliği araştırmaları, büyük miktarda veriyi işleme kapasitesine sahip ölçeklenebilir sınıflandırma ve tahmin tekniklerinin geliştirildiği çalışmalar üzerine kurulmuştur. Sınıflandırma, dolandırıcılık tespiti, hedef pazarlama, performans tahmini, imalat ve tıbbi teşhis dahil olmak üzere sayısız uygulamaya sahiptir (Han, Kamber ve Pei, 2011: 327).

Literatürde makine öğrenmesinde kullanılan sınıflandırma, ayrıca örüntü tanıma diye isimlendirilmektedir (Alpaydın, 2014: 9). Makine öğrenmesinde geleceği tahmin etmede sınıflandırma başlığı altında kullanılan YSA, DVM, Karar Ağaçları, Naive Bayes ve k-EYK gibi çok sayıda model vardır.

2.3.2. Sayısal Tahmin (Regresyon)

Her makine öğrenme problemi, verileri sınıflara atama ile ilgili değildir. Bazen hedef değişken sürekli değerler alır. Örneğin bir finansal modelde dolar değerlerini tahmin etme sayısal tahmindir. Şekil 2 sayısal tahminin şekil olarak özetlenmiş halini gösterir (Brink, Richards ve Fetherolf, 2016: 69).

Şekil 2. Regresyon (Brink, Richards ve Fetherolf, 2016: 69)



Sürekli değerlerin tahmini, regresyon analizi adı verilen istatistiksel bir teknikle modellenebilir. Regresyon analizinin amacı, çıktı değişkenini çeşitli girdi değişkenleriyle ilişkilendirebilecek en iyi modelin belirlenmesidir. Daha kavramsal olarak, regresyon analizi, bir y değişkeninin bir veya daha fazla diğer değişken x_1, x_2, \dots, x_n ile nasıl ilişkili olduğunu belirleme sürecidir. Genellikle y 'ye, tepki çıktısı veya bağımlı değişken denir ve x_{i-s} ise girdiler, regresörler, açıklayıcı değişkenler veya bağımsız değişkenler adını alır (Kantardzic, 2012: 149). Regresyon analizinin yapılmasına ilişkin genel nedenler şunları içerir:

- Çıktı ölçmek pahalıdır ancak girdiler değildir ve dolayısıyla çıktı için ucuz bir tahmin aranır,
- Girişlerin değerleri, çıktı bilinmeden önce bilinir ve çıktı için bir çalışma tahmini gereklidir,
- Giriş değerlerini kontrol ederek, karşılık gelen çıktıların davranışını öngörebiliriz,
- Bazı girdiler ve çıktı arasında bir bağlantı olabilir ve bağlantıları tanımlamak isteriz.

2.3.3. Kümeleme (Clustering)

Kümeleme, bir takım veri nesnelerinin alt gruplara bölünmesi işlemidir (Likas, Vlassis ve Verbeek, 2003: 1). Her bir alt küme, bir kümedir; böylece, kümedeki nesnelere birbirine benzemektedir, ancak diğer kümelerdeki nesnelere benzer değildir. Bir küme analizinden kaynaklanan kümeler, kümeleme olarak adlandırılabilir. Bu bağlamda, farklı kümeleme yöntemleri, aynı veri kümesinde farklı kümeler oluşturabilir (Fayyad, Piatetsky-Shapiro ve Smyth, 1996: 45).

Kümeleme, insanlar tarafından değil kümeleme algoritması tarafından gerçekleştirilir. Bu nedenle, kümeleme, veri içindeki daha önce bilinmeyen grupların keşfedilmesine yol açabilmesi açısından yararlıdır.

Kümeleme analizi, iş zekası, görüntü kalıbı tanıma ve güvenlik gibi birçok uygulamada yaygın şekilde kullanılmaktadır. İş zekasında kümeleme, çok sayıda müşteriyi bir grup içindeki müşterilerin güçlü benzer özelliklere sahip olduğu gruplar halinde organize etmek için kullanılabilir. Bu, gelişmiş müşteri ilişkileri yönetimi iş stratejilerinin geliştirilmesini kolaylaştırır. Ayrıca, çok sayıda projeye sahip bir danışman şirketin proje yönetimini iyileştirmek için, kümeleme, bölünme projelerini benzerliğe dayalı kategorilere dönüştürülebilir böylece proje denetimi ve teşhisi etkin bir şekilde yönetilebilir.

Bir veri madenciliği işlevi olarak, kümeleme analizi, verilerin dağılımı hakkında fikir edinmek, her kümenin özelliklerini gözlemlemek ve daha ileri analiz yapabilmek için belirli kümeler odaklanmayı bağımsız bir araç olarak kullanılabilir (Chatterjee, Das ve Turgut, 2002: 194). Alternatif olarak, tespit edilen kümeler ve seçilen özellikler veya özellikler üzerinde çalışacak olan karakterizasyon, nitelik altkümüesi seçimi ve sınıflandırma gibi diğer algoritmalar için bir ön işlem basamağı görevi görebilir.

Bir küme, küme içinde birbirine benzeyen ve diğer kümelerdeki nesnelere benzer olmayan bir veri nesnelere topluluğudur, veri nesnelere kümesi örtük bir sınıf olarak değerlendirilebilir. Bu anlamda, kümeleme bazen otomatik sınıflandırma olarak adlandırılır. Yine, buradaki önemli husus kümelemenin gruplamaları otomatik olarak bulabildiğidir. Bu, küme analizinin belirgin bir avantajıdır (Berkhin, 2006: 25).

Veri kümelemesi güçlü bir gelişme göstermektedir. Kümeleme analizinin katkıda bulunduğu alanlar arasında veri madenciliği, istatistik, makine öğrenimi, mekansal veri tabanı teknolojisi, bilgi alımı, web araması, biyoloji, pazarlama ve diğer pek çok uygulama alanı bulunmaktadır. Veri tabanlarında toplanan büyük miktarda veriden dolayı, kümeleme analizi son zamanlarda veri madenciliği araştırmasında son derece aktif bir konu haline gelmiştir.

İstatistik dalında kümeleme analizi, esas olarak mesafe tabanlı küme analizine odaklanarak kapsamlı olarak incelenmiştir. K-ortalamlar ve diğer birçok yöntem temelli kümeleme analiz modelleri, S-Plus, SPSS ve SAS gibi birçok istatistiksel analiz yazılım paketinde veya sisteminde kurulmuştur. Makine öğrenmesinde, sınıftaki etiket bilgisi verildiğinden sınıflandırmanın danışmanlı öğrenme olarak bilinir oysaki kümeleme de, sınıf etiketi bilgisi mevcut olmadığından danışmansız öğrenme olarak bilinir.

2.3.4. Birliktelik Kuralı (Association Rule)


Araştırma modelindeki veriler ile eğitim kümesindeki değişkenlerin değerleri arasında bulunan herhangi bir ilişkiyi bulmak için kullanılan kurallara birliktelik kuralları denilir. Verilen herhangi bir veri kümesinden türetilen olası pek çok ilişkilendirme kuralı vardır. Bunların çoğunun değeri çok az veya hiç yoktur, bu nedenle birliktelik kurallarının ne kadar güvenilir olduklarını gösteren ek bilgilerle belirtilmesi gereklidir (Bramer, 2016: 8).

Örneğin "Pazar Sepeti Analizi" olarak adlandırılan analizde bir mağazadaki tüm müşteriler tarafından bir haftalık yapılan alımlar biliniyorsa, mağazanın ürünlerini gelecekte daha etkili bir şekilde pazarlamasına yardımcı olacak ilişkiler bulunabilir.

2.4. MAKİNE ÖĞRENMESİ TÜRLERİ

Belirli bir probleme birçok makine öğrenmesi algoritmalarının uygulandığı bir sürü örtüşme var. Sonuç olarak, aynı problem için birçok farklı makine öğrenmesi modeli olabilir. En iyi makine öğrenme modelinin ortaya çıkması sabır ve deneme yanılma gerektiren bir sanattır (Marshland, 2011: 5). Ramasubramanian ve Singh (2017: 222) makine öğrenme türlerini Şekil 3'teki gibi incelemiştir.

Şekil 3. Makine Öğrenme Türleri (Ramasubramanian ve Singh, 2017: 222).



Camasta ve Vinciarelli (20015: 101), öğrenme stratejilerini;

- Danışmanlı öğrenme
- Danışmansız öğrenme
- Yarı-danışmanlı öğrenme
- Pekiştirmeli öğrenme
- Çevrimiçi öğrenme
- Aktif öğrenme olarak incelemiştir.

Brownlee (2013-internet), öğrenme türlerini;

- Danışmanlı öğrenme,
- Danışmansız öğrenme,
- Yarı-danışmanlı öğrenme,
- Pekiştirmeli öğrenme olarak ifade etmiştir.

Öğrenme stratejilerinin literatürdeki farklı sınıflandırılmalarına karşın genel olarak, makine öğrenmesinin ana iki alt alanı, danışmanlı öğrenme ve danışmansız öğrenme olduğu görülmüştür. Bizim çalışmamızda makine öğrenmesi türleri sınıflandırmasında Camasta ve Vinciarelli (2008: 101) tarafından önerilen öğrenme stratejileri kullanılmıştır.

2.4.1. Danışmanlı Öğrenme (Supervised Learning)

Danışmanlı öğrenme, öğrenme algoritmasının etiketlenmiş eğitim verisini aldığı ve iterasyonla öğrenme işlemini gerçekleştirdiği test verisindeki noktaları tahmin etmeye çalıştığı bir öğrenme stratejisidir (Mohri vd., 2012: 2).

Danışmanlı öğrenmede öğrenme olayı isminden de anlaşılacağı gibi bir danışman (veya öğretmen) aracılığıyla gerçekleştirilir. Danışman (veya öğretmen), makine öğrenmesinde eğitim verisini veya kazanılmış deneyimi ifade etmektedir (Kotsiantis, 2007: 249). Danışmanlı öğrenmede (veya öğretmenle öğrenirken) veriler, girdi-çıkı modellerinin bir örneğidir. Bu durumda, verinin kısa bir açıklaması, girdi verildiğinde çıktı üretebilen işlemdir (Camasta ve Vinciarelli, 2015: 102). Danışmanlı öğrenme probleminde, eğitim seti olarak adlandırılan bir girdi-çıkı setine verilen görev, herhangi bir girdiyi gelecekteki girdi-çıkı gözlemlerini tahmin

edebilecek bir çıktıya eşleyen deterministik bir fonksiyon bulmaktır (Camastra ve Vinciarelli, 2015: 102).

Algoritma, verilen tahmin edici değişkenler kümesine karşı çıktı değişkenini öğrenmeye dayanır. Örneğin, veri seti bir hasta grubuna aitse, her bir örneğin bir hastanın kanser olup olmadığını belirten bir çıktı değişkeni olacaktır (kategorik). Ayrıca, çıktı değişkeni kategorik ise bir sınıflandırma görevi, sürekli ise bir regresyon görevi olacaktır (Ramasubramanian ve Singh, 2017: 222).

Danışmanlı öğrenmenin bazı uygulamaları konuşma tanıma, kredi puanlama, tıbbi görüntüleme ve arama motorları (Ramasubramanian ve Singh, 2017: 222) olarak ifade edilirken ayrıca el yazısı harflerin ve rakamların tanınması, borsa endekslerinin tahmini (Camastra ve Vinciarelli, 2015: 102) olarak da ifade edilmiştir.

2.4.2. Danışmansız Öğrenme (Unsupervised Learning)

Veriler, ilişkili hedef değerleri olmayan nesnelere sadece bir örneğiye yani etiketler mevcut değilse problem danışmansız öğrenme olarak bilinir. Danışmansız öğrenmede öğretmen yoktur. Bu nedenle, verilerin kısa bir açıklaması, gelecekte belli bir nesneyi gözlemleme olasılığını belirten bir grup küme veya olasılık yoğunluğu olabilir (Camastra ve Vinciarelli, 2015: 103).

Danışmansız öğrenmede sistem giriş kalıplarının kümelerini oluşturmaktadır. Kümeleme sisteminde belirli bir desen seti veya maliyet fonksiyonu göz önüne alındığında, farklı kümeleme algoritmaları farklı kümeler oluşturur (Duda, 2001: 29). Buna göre, kümelemeyi yapan algoritma gelen verileri birbirine benzemelerine göre aynı kümeye atama işlemini yapar (Alpaydın, 2011: 9).

Öğrenme, veri kümesindeki her satır arasındaki benzerlik veya uzaklık ölçüsüne dayanır (Ramasubramanian ve Singh, 2017: 223). Öğrenen, eğitim verisine göre tahminlerde bulunur (Mohri vd., 2012: 3).

Literatürde danışmansız öğrenme örnekleri olarak kümeleme ve boyut azaltma gösterilebilir (Mohri vd., 2012: 33). Danışmansız öğrenmenin bazı uygulamaları pazarlama, sosyal ağ analizi, imge bölümlenme, iklimbilim ve müşteri segmentasyonudur (Ramasubramanian ve Singh, 2017: 223) ve ayrıca görüntü

kontrolü ve metin parçalanması ve süreç denetiminde yenilik algılaması görevini içerir (Camastra ve Vinciarelli, 2015: 103).

2.4.3. Yarı-Danışmanlı Öğrenme (Semi-Supervised Learning)

Yarı-danışmanlı öğrenme, danışmanlı ve danışmansız öğrenmeyi birleştirir (Chapelle, 2010: 2). Yarı-danışmanlı öğrenmede makine öğrenme algoritması hem etiketli hem etiketsiz verilerden oluşan eğitim kümesini alır ve bu kümede yer almayan yeni veriler için tahminlerde bulunur (Witten vd., 2016: 468). Etiketsiz gözlemlerin de kullanılmasının sadece danışmanlı öğrenmenin kullanılmasına göre daha iyi neticeler vereceği düşünülür (Mohri vd., 2012: 7).

Yarı-Danışmanlı öğrenmede öğrenme problemi, daha iyi bir öğrenme sistemi oluşturmak için küçük miktarda etiketli veriyle etiketlenmemiş büyük miktarda veri kullanılarak ele alınmaktadır (Camastra ve Vinciarelli, 2015: 104). Yarı-danışmanlı öğrenmede, etiketli verilere dayalı olarak yapılanlardan daha iyi bir sınıflandırıcı oluşturmak için etiketsiz verileri kullanmaya çalışır. Birçok örnekte bu yaygın bir sorundur çünkü etiketlenmemiş verilerin toplanması ucuzdur (Barber, 2012: 308).

Yarı-danışmanlı öğrenme yöntemi etiketsiz verilerin kolayca ulaşılabildiği fakat veriyi etiketlemenin oldukça güç olduğu durumlar için kullanılmaktadır. Birçok durumda, etiketleme maliyeti oldukça yüksektir çünkü bunu yapmak için nitelikli uzmanlar gerekir (Ramasubramanian ve Singh, 2017: 223).

Yarı-danışmanlı öğrenme, üçe ayrılır: yarı denetimli sınıflandırma, yarı denetimli regresyon ve yarı denetimli kümeleme (Camastra ve Vinciarelli, 2015: 104). Sınıflandırma, regresyon türündeki bazı problemler de yarı-danışmanlı öğrenme algoritmaları ile çözülmektedir (Mohri vd., 2012: 7).

2.4.4. Pekiştirmeli Öğrenme (Reinforcement Learning)

Pekiştirmeli öğrenme, başarmak için hedeflerin verildiği ve bu hedeflerin denenerek nasıl başarılacağına görüldüğü bir öğrenme stratejisidir. Bu öğrenme, dinamik programlama ve danışmanlı öğrenme alanlarını birleştirir (Harmon ve Harmon, 1997: 3). Pekiştirmeli öğrenmede, veriler kategorilere ayrılmaz. Geçici kategori oluşturulur ve bunlar doğru veya yanlış olarak ayrılır. Ancak kategorinin yanlış olduğu özellikle söylenmez (Duda, 2001: 29). Eğitim ve test aşamaları iç içe

girmiş durumdadır. Pekiştirmeli öğrenme algoritması sürekli çevreyle yinelemeli bir şekilde öğrenir. Öğrenen, mümkün olan tüm durumları keşfedinceye kadar çevre deneyimlerini öğrenir (Ramasubramanian ve Singh, 2017: 224). Her bir deneyimden sonra hemen bir ödül alır. Öğrenme makinesinin hedefi bir deneyimler dizisinden sonra aldığı ödülü maksimize etmektir (Engelbrecht, 2007: 83).

Pekiştirmeli öğrenmenin kökleri kontrol teorisindedir. Durum-eylem-ödül üçlüsünü veri olarak veren dinamik bir ortamın senaryosunu dikkate alır. Pekiştirmeli ve danışmanlı öğrenme arasındaki fark, pekiştirmeli öğrenmede belirli bir süreçte optimal bir eylem bulunmadığı, ancak öğrenme algoritmasının beklenen ödülü zaman içinde en üst düzeye çıkarmak için bir eylem belirlemesi gerektiğidir (Camastra ve Vinciarelli, 2015: 103).

Pekiştirmeli öğrenme problemi, verilen bir ödülü en üst düzeye çıkarmak için ne yapılacağını, diğer bir deyişle durumların hareketlerle nasıl eşleştirileceğini öğrenmektir. Danışmanlı öğrenme görevinden farklı olarak, belirli bir durumda hangi eylemlerin gerçekleştirileceği öğrenme algoritmasına bildirilmemektedir. Bunun yerine öğrenen, bazı ödülleri aldığı eylemler hakkında, eylemin gerçekleşmesinden hemen sonra gelmeyerek bilgi edinmeyi kabul eder. Böyle bir probleme örnek satranç oynamayı öğrenmektir. Her tahta konfigürasyonu, yani satranç taşlarının satranç tahtasındaki konumu verilen bir durumdur; Eylemler belirli bir yapılandırılmada olası hamlelerdir. Belli bir eylemin ödülü oyunu kazanmaktır (Camastra ve Vinciarelli, 2015: 103).

Görünmeyen örnekler üzerinde çalışabilmek için verilerin kapsamlı olması gerekir. Örneğin, hastaların tıbbi geçmişi temelinde kanser öngörme problemi belirli bir kanser türü için veri bulunmuyorsa, algoritma gerçek zamanlı konuşlandırıldığında birçok yanlış alarm üretir. Bu nedenle, şu anda öğrenme verilerinin mevcut olmadığı veya zamanla hızla güncellendiği durumlarda, pekiştirmeli öğrenme ideal bir seçimdir (Ramasubramanian ve Singh, 2017: 224).

Pekiştirmeli öğrenme, kontrol teorisi, markov karar süreçleri ve oyun kuramı ile bağlantılıdır. (Barber, 2012: 308). Pekiştirmeli öğrenme algoritmasının bazı uygulamaları bilgisayarla oynanan tahta oyunları (Satranç, Go), robotik eller ve kendi kendine sürülen otomobillerdir (Ramasubramanian ve Singh, 2017: 224). Yeni

doğmuş bir ceylan yavrusunun kısa sürede ayağa kalkması ve hızla koşabilmesi, temizlik yapmak için bir robotun odalar arasında dolaşması pekiştirmeli öğrenmeyi kavramamızı sağlayan örneklerdir (Sutton ve Barto, 1998: 1).

2.4.5. Aktif Öğrenme (Active Learning)

Aktif öğrenmede öğrenme makinesi yeni verilerin etiketini bir uzmanı sorgulayarak öğrenmeye çalışır. Amaç, öğrenme için gerekli etiketlenmiş verilerin sayısını azaltabilmektir (Zhang, 2011). Genellikle maliyetlerin yüksek olduğu etiketlerin elde etme durumlarında kullanılır (Mohri vd., 2012: 8). Aktif öğrenme etiketleme problemi yaşanan resim, ses, video, doküman sınıflandırma ve konuşma tanıma problemlerinde etiketlenmemiş örneklerin sorgulama sistemi ile uzman kişinin etiketleyebilmesini sağlamaktadır. Bu sayede aktif öğrenmede en az etiketlenmiş veri ile en yüksek doğruluk elde edilmiş olur (Settles, 2010: 3). Aktif öğrenme, öğrenenin şu anda bilgi sahibi olmadığı bölgelerdeki bilgileri talep edebileceği danışmansız öğrenme bağlamında da düşünülebilir (Barber, 2012: 308).

2.4.6. Çevrimiçi Öğrenme (Online Learning)

Çevrimiçi öğrenmede veriler sıralı olarak gelir ve yeni veriler elde edildiğinde tur tamamlanmış olur ve model sürekli güncellenir (Barber, 2012: 307). Öğrenene her turda soru sorulur ve öğrenenin verdiği cevap ile doğru cevap karşılaştırılır. Öğrenme başarısı, doğru cevap ile verilen cevap arasındaki fark ölçülerek ortaya çıkartılmaktadır (Shalev-Shwartz, 2007: 1). Çevrimiçi öğrenme, danışmanlı veya danışmansız öğrenme türleriyle ilişkilidir (Barber, 2012: 308).

2.5. MAKİNE ÖĞRENMESİ SÜRECİ

Literatürde makine öğrenmesi algoritmaları kullanılarak çözülebilecek bir problem için bazı yaklaşımlar mevcuttur. Shearer (2000: 14) tarafından, veri madenciliği görevlerine çerçeve geliştirmek için Avrupa Birliği tarafından finanse edilen çalışmalarda kullanılmak üzere makine öğrenmesine uygulanabilir bir süreç geliştirmiştir:

1. Problemi Anlama
2. Veriyi Anlama
3. Veri Hazırlama

4. Modelleme
5. Deęerlendirme
6. Uygulama

Brink, Richards ve Fetherolf (2016: 17), makine öğrenmesi iş akışı şöyledir:

1. Veri Hazırlama
2. Model Oluşturma
3. Model Performansını Deęerlendirme
4. Model Performansını Optimize etme ve Yeni Tahminler

Ramasubramanian ve Singh (2017: 426), makine öğrenmesi süreci akışı dört ana başlıkta incelemiştir:

1. Plan
 - 1.1. Veri Toplama
 - 1.2. Veri Hazırlama
2. Keşfet
 - 2.1. Veri Analizi
 - 2.2. Ayrıntılı Veri Araştırması
3. Yapı
 - 3.1. Model Oluşturma
 - 3.2. Model oluşturma Ürünü
4. Deęerlendirme
 - 4.1. Model Deęerlendirmesi
 - 4.2. Model Revize Etme

Harrington (2012: 12) ise bir makine öğrenmesi uygulama geliştirme adımlarını şu şekilde incelemiştir:

1. Veri toplanma
2. Veri hazırlama
3. Model
4. Algoritma eğitimi
5. Algoritmayı test etme
6. Uygulama

Tez çalışmasında makine öğrenmesi uygulama geliştirme adımları olarak Harrington (2012: 12) modeli baz alınmıştır.

2.5.1. Veri toplama

Veri toplama aşamasında farklı kaynaklardan yararlanılabilmektedir. Bunlardan biri bir web sitesini kazıyarak ve veri çıkararak örnekleri toplamak ya da bir cihazın verileri toplamasını sağlamaktır. Biraz zaman ve emekten tasarruf etmek için ise herkese açık veriler kullanılabilir (Harrington, 2012: 13). Bir diğeri hazır veri setleridir. Bu hazır veri setleri, erişimi ve kullanımı kolay olması sebebiyle makine öğrenmesi çalışmalarında avantaj sağlamaktadır (Kartal, 2015: 15).

2.5.2. Veri Hazırlama

Verinin analizlerden önce hazır hale getirilmesi önemlidir. Burada algoritmaya özgü bazı biçimlendirmelerin yapılması gerekebilir. Bazı algoritmalar bir formattaki özelliklere ihtiyaç duyar, bazı algoritmalar hedef değişkenleri ve özellikleri dizeler olarak ele alabilir ve bazıları tamsayı olmaya ihtiyaç duyarlar (Harrington, 2012: 14). Veri hazırlama sürecindeki işlemlerin standardı yoktur, kullanılacak veri setine göre değişiklik göstermektedir (Kartal, 2015: 16).

Veri hazırlama, literatürde Han, Kamber ve Pei (2011: 83) tarafından veri temizleme, veri entegrasyonu, veri indirgeme ve veri dönüşümü olarak detaylı şekilde incelenmiştir:

2.5.2.1. Veri Temizleme

Gerçek dünya verileri eksik, gürültülü ve tutarsız olma eğilimindedir. Veri temizleme işlemi, eksik değerleri doldurmaya, farklıları tanımlarken gürültüyü düzeltmeye ve verilerin tutarsızlıklarını düzeltmeye çalışır (Han, Kamber ve Pei, 2011: 83).

2.5.2.2. Veri Entegrasyonu

Veri madenciliği, çoğu zaman birden fazla veri deposundan veri birleştirilmesi için veri bütünleştirmesini gerektirir. Dikkatli yapılan entegrasyon, ortaya çıkan veri kümesindeki fazlalıkları ve tutarsızlıkları azaltmaya ve önlemeye yardımcı olabilir. Bu, sonraki veri madenciliği işleminin doğruluğunu ve hızını

arttırılmasına yardımcı olabilir. Verilerin anlamsal heterojenliği ve yapısı, veri entegrasyonunda büyük zorluklar oluşturmaktadır (Han, Kamber ve Pei, 2011: 83).

2.5.2.3. Veri İndirgeme

Karmaşık veri analizi ve büyük miktarlarda veri madenciliği, bu tür bir analizin pratik olmaması veya uygulanabilir hale getirilmesi uzun zaman alabilir. Veri azaltma metotları, boyut olarak küçültülmüş fakat içerik olarak orijinaliği koruyarak verilerin daha alt boyutta gösterimini sağlamak için kullanılabilir. Böylece küçültülmüş veri boyutu işlem verimliliğini artırırken önceki çıktılara benzer sonuçlar bulunmalıdır (Han, Kamber ve Pei, 2011: 83).

2.5.2.4. Veri Dönüşümü

Bu ön işleme aşamasında veriler, verimli olacak şekilde dönüştürülür ve örneklerin daha kolay anlaşılması amaçlanır. Veri dönüşümünde, veriler modele uygun biçime dönüştürülür veya birleştirilir. Veri dönüşümü stratejileri şunları içerir: düzeltme, özellik oluşturma, birleştirme, normalizasyon, ayırma, nominal veriler için kavramsal hiyerarşi üretimi (Han, Kamber ve Pei, 2011: 83).

2.5.3. Model

Model geliştirme başlamadan önce, genellikle veriler iki kategoriye bölünür:

Eğitim veri seti: Bu veri seti, makineyi eğitmek için kullanılır. Literatürde eğitim için tüm veri setinin 1:1, %70, %80 ve %90 oranlarında kısımları kullanılır. Eğitim veri seti kullanılarak makine öğrenme algoritması ile modele uyumu yansıtan bazı iyi tanımlanmış performans ölçütleri optimize edilir.

Test veri seti: Test veri seti, makine öğrenmesi algoritmasının daha önce görmediği veri noktalarını içerir. Modelin yeni verilere nasıl performans gösterdiğini görmek için bu veri kümesini kullanılır. Model performansı ve değerlendirmesi bu aşamada önceden belirlenmiş parametrelere göre hesaplanır ve değerlendirilir. Burada modelleyici, modelin iyileştirme gerektirip gerektirmediğine karar verebilir ve değişiklikleri yapabilir ve model buna göre uyarlanabilir.

Makine öğrenmesi alanında çalışanlar, karmaşık ve büyük miktarda olan veri kümesini çeşitli yöntemlerle modellerler. Veri kümesinin içindeki gömülü olan örüntüyü keşfedebilmek için seçilen makine öğrenmesi modeli kullanılır (Vellido

vd., 2012: 164). Her makine öğrenme sistemi, model oluşturmak ve tahminler yapmak için modelleri kullanmakla ilgilenir (Brink, Richards ve Fetherolf, 2016: 20).

Makine öğrenmesinde model, bir görevin niteliklerle tanımlanan veriyi çıktılara uygun ihtiyaç duyulan haritalamadır. Görevler modeller tarafından yönlendirilirken, öğrenme problemleri modelleri üreten öğrenme algoritmaları tarafından çözülmektedir (Flach, 2012: 20). Bu noktada, makine öğrenmesi algoritması girdi özelliklerinden çıktı verisine eşlemeyi gerçekleştiren büyülü bir kutu olarak düşünülebilir. Makine öğrenme algoritmalarının diğer yaygın olarak kullanılan yöntemlerle karşılaştırıldığında sağladığı avantajlardan birisi, birçok özelliği barındırabilmesi açısından esnek olmasıdır (Brink, Richards ve Fetherolf, 2016: 19).

Bu tez çalışmasında kullanılmış olan YSA, DVM, K-EYK, Naive Bayes, Karar Ağaçları, Doğrusal Diskriminant Analizi ve Lojistik Regresyon model algoritmaları Bölüm 2’de ayrıntılı bir şekilde anlatılmıştır.

2.5.4. Algoritma Eğitimi

Makine öğrenimi burada yapılır. Bu adım ve bir sonraki adım, algoritmaya bağlı olarak "çekirdek" algoritmalarının bulunduğu yerlerdir. Algoritmayı ilk iki adımdan itibaren iyi verilerle beslersek bilgi ya da bilgileri sistemden öğrenebilir. Bu bilgi sıklıkla bir sonraki iki adım için bir makine tarafından kolaylıkla kullanılacak bir biçimde saklanır. Danışmansız öğrenme durumunda, bir eğitim adımı yoktur, çünkü hedef bir değer yoktur. Her şey bir sonraki adımda kullanılır (Harrington, 2012: 12).

2.5.5. Algoritmayı Test Etme

Bu, önceki adımda öğrendiği bilgilerin kullanıma sunulduğu yerdir. Bir algoritmayı değerlendirirken, algoritmanın ne kadar iyi olduğunu görmek için test edilir. Test verileri kullanılarak yapılan işlem ile algoritmanın tahmin sonuçları bulunur. Danışmanlı öğrenme durumunda, algoritmayı değerlendirmek için kullanabilen bazı bilinen değerler vardır. Danışmansız öğrenmede başarıyı değerlendirmek için başka metrikler kullanmak zorunluluğu ortaya çıkar (Han, Kamber ve Pei, 2011: 112).

2.5.6. Uygulama

Sınıflandırma probleminin çözümünde kullanılan veri kümesi probleme uygun hazırlanır. Veri kümesindeki ön-işleme adımları yapılarak veri seti öğrenme stratejileri ile eğitime ve test etmeye uygun olarak düzenlenir. Veriyi değerlendiren performans metotları ile öğrenme algoritmalarının optimal başarıyı yakalayan tahmin yöntemi seçilir. Makine öğrenmesi süreci adımları sırayla tamamlandıktan sonra model uygulamaya geçirilir (Han, Kamber ve Pei, 2011: 112).

2.6. MAKİNE ÖĞRENMESİNDE MODEL DEĞERLENDİRME VE SEÇİMİ

Model performansı ve değerlendirmesi, modeli geliştirdikten sonra ve modelin test verilerinden elde edilen tahminler ile gerçek değerler arasında nasıl performans gösterdiğini ölçmek için gerçekleştirilir (Han, Kamber ve Pei, 2011: 364).

Model değerlendirmesinin temel fikri, hatanın birçok yönden tanımlanabildiği test verileri üzerindeki hatayı en aza indirmektir. Sezgisel anlamda hata, verilerdeki tahmin ettirici değişkeninin gerçek değeri ile makine öğrenmesi modelinin tahmin ettiği değer arasındaki farktır. Hata oranları her zaman evrensel değildir ve bazı belirli problemler veya problem bilgisine uygun hata oranları gerektirir (Ramasubramanian ve Singh, 2017: 431). Model performansı test verileri kullanılarak ölçülür ve modelleyici, modelin geçerliliğini sağlamak için hangi eşik değerlerin kabul edilebilir olduğuna karar verir. Performans metrikleri, genel olarak, model uyumu için temel ölçütler kullanılarak üretilir; diğer bir deyişle, model çıktısının gerçek değerinden ne kadar farklı olduğu belirlenir. Gerçek ve tahmin edilenler arasındaki bu hata, iyi bir performans için en aza indirgenmesi gereken hata olacaktır (Ramasubramanian ve Singh, 2017: 431).

Geri bildirim döngüsünün başa dönmesi, taşıdığı karmaşıklığın veya verilerin bazı sorulara cevap vermesinin yetersiz olması nedeniyle birçok tahmin probleminde bazen kaçınılmazdır. Süreç akışındaki tüm adımlar özenle uygulanırsa, sıfırdan başlamak için başa dönmek yerine modelin ayarlaması yeterli olacaktır. Tek bir iterasyonda güçlü bir makine öğrenmesi modeli oluşturabilme ihtimali çok düşüktür

bu sebeple modele göre değişiklik gösteren iterasyonlar uygulanabilir (Ramasubramanian ve Singh, 2017: 27).

Birçok iterasyonun ardından veriler üzerinde bir model oluşturur ve tahminler yapmak için dışarıda bırakılmış verileri (test verileri) kullanılır. Artık modelin doğruluğunu test etmek için tahmin edilen sonuçları bilinen “gerçek” değerlerle karşılaştırabilir (Brink, Richards ve Fetherolf, 2016: 21).

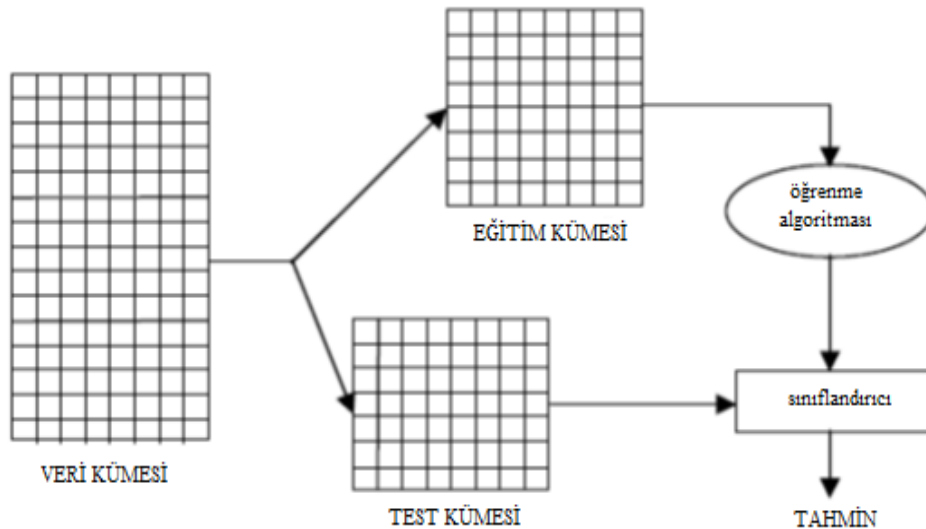
2.6.1. Model Performans Değerlendirme Yöntemleri

2.6.1.1. Dışarıda Tutma (Holdout)

Dışarıda tutma yönteminde, veriler rastgele iki bağımsız sete, bir eğitim seti ve bir test setine bölünür. Tipik olarak, verilerin üçte ikisi eğitim setine, kalan üçte biri test grubuna ayrılır (Şekil 4). Eğitim seti, modeli türetmek için kullanılır (Han, Kamber ve Pei, 2011: 364).

İlk olarak, eğitim seti bir sınıflandırıcı oluşturmak için kullanılır. Daha sonra sınıflandırıcı, test setindeki örneklerin sınıflandırılmasını öngörmek için kullanılır. Test seti, C'nin doğru olarak sınıflandırıldığı N örneğini içeriyorsa, test seti için sınıflandırıcının tahmin doğruluğu $p=C/N$ dir. Bu, görünmeyen herhangi bir veri kümesindeki performansının bir tahmini olarak kullanılabilir (Bramer, 2016: 80). Modelin doğruluğu daha sonra test setiyle tahmin edilir (Şekil 4). Tahminlerin doğruluğu yetersiz olabilir çünkü başlangıç verisinin yalnızca bir kısmı modelin türetilmesi için kullanılır (Han, Kamber ve Pei, 2011: 364).

Şekil 4. Holdout (Bramer, 2016: 80).



Hazır veri setleri için, veriler, eğitim seti ve test seti olarak belirtilen iki ayrı dosya olarak sağlanmaktadır. Veri kümesinin yalnızca tek bir dosya olduğu durumlarda onu bir eğitim kümesine ve bir test kümesine bölünür. Bu, çeşitli şekillerde yapılabilir, ancak rasgele bölünme, orantılı olarak iki parçaya ayrılabilir: 1:1, 2:1, 60:40, 70:30, 80:20 ya da 90:10 literatürde en çok kullanılanlardır (Bramer, 2016: 80).

2.6.1.2. Çapraz Geçerleme (Cross-Validation)

Çapraz geçerleme, model değerlendirmesi için en çok kullanılan yöntemlerden biridir. Veri sayısı ne kadar büyük olursa, yorumlama o kadar iyi olur (Büyük Sayılar Kanunu). K-katlı çapraz geçerleme yöntemi adımları şunları içerir (Ramasubramanian ve Singh, 2017: 431):

Adım 1: Veri kümesini k alt kümeye bölün.

Adım 2: k-1 alt kümeleri üzerinde bir model eğitin.

Adım 3: Modeli kalan bir alt kümede test edin ve hatayı hesaplayın.

Adım 4: Testler için tüm alt gruplar tam olarak bir kez kullanılacaktır. 1-3 arasındaki adımları tekrarlayın.

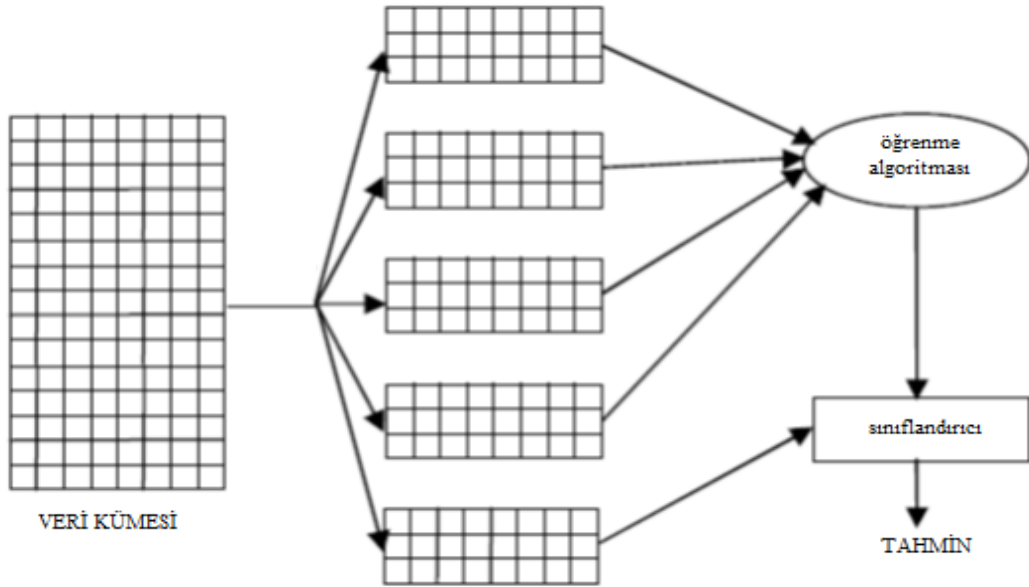
Adım 5: Geçiş hatasını almak için bu tahmini simülasyon (benzetim) sonuçlarındaki hataların ortalamasını alın.

K-katlı çapraz geçerlemede, başlangıç verileri, birbirine rastgele seçilen k kümelerine, D_1, D_2, \dots, D_k 'ya rasgele bölünür ve her biri yaklaşık eşit boyuttadır (Şekil 5). Eğitim ve test k kez yapılır. Yineleme i 'de, bölüm D_i test kümesi olarak ayrılmıştır ve geri kalan bölümler, modeli eğitmek için birlikte kullanılır. Yani, birinci iterasyonda, D_2, D_3, \dots, D_k alt kümeleri, D_1 üzerinde test edilen bir ilk modeli elde etmek için eğitim seti olarak hizmet eder; ikinci iterasyon, D_1, D_3, \dots, D_k alt grupları üzerinde eğitilir ve D_2 üzerinde test edilir. Bekletme ve rasgele alt örnekleme yöntemlerinin aksine, burada her örnek, eğitim için aynı defada ve test için bir kez kullanılır. Sınıflandırma için, doğruluk tahmini, k tekrarlamalardan doğru sınıflandırmaların toplam sayısının, başlangıç verisindeki toplam sınıf sayısı ile bölünmesiyle bulunur (Ramasubramanian ve Singh, 2017: 431).

Veri seti N örnek içeriyorsa, bunlar k eşit parçaya bölünür, bu k tipik olarak 2, 5 ya da 10 gibi küçük bir sayıdır (N , k tarafından tam olarak bölünemezse, son bölüm diğer $k-1$ parçalardan daha az örneğe sahip olacaktır). Veri seti k eşit parçaya bölündüğünde sırayla k parçaların herbiri test seti olarak kullanılırken diğer $k-1$ parçaları bir eğitim seti olarak kullanılır (Bramer, 2016: 83). Genelde, varyansa bağlı olarak doğruluğu tahmin etmek için 10 kat çapraz geçişleme önerilir.

Bu yöntem, herbir veri noktasının bir defa test kümesine girmesini ve $k-1$ defa eğitim setinde olmasını sağlar. Dolayısıyla k arttıkça tahmin varyansı azalır. Çapraz geçişlemede dezavantaj, modelin tahmini k -kez olması ve sonra k -kez yapılması için test yapılmasıdır, bu da daha yüksek bir hesaplama maliyeti anlamına gelir (Ramasubramanian ve Singh, 2017: 431). Şekil 5’de k -katlı çapraz geçişleme gösterilmiştir.

Şekil 5. k -katlı Çapraz Geçişleme (Bramer, 2016: 83).



2.6.1.3. Bootstrap (Yerine Koyarak Rastgele Örnekleme)

Yerine koyma yöntemi, verilen eğitim setlerini yerine koyarak eşit olarak örnekler. Yani, bir etiket her seçildiğinde, tekrar seçilmesi ve eğitim setine tekrar eklenmesi eşit derecede olasıdır (Bramer, 2016: 84).

Birkaç yerine koyma yöntemi vardır. Sık kullanılan yerine koyma yönteminde, bir veri kümesi ele alınır. Veri kümesi, yerine getirilmek üzere d kez

örneklenir ve bir yerine koyma örneği veya d örneklerinin eğitim setine girerse bu örnekteki bazı orijinal veri etiketlerinin birden çok kez oluşacağı muhtemeldir. Eğitim setine girmeyen veriler test setini oluşturur (Ramasubramanian ve Singh, 2017: 432).

2.6.2. Model Seçimi

Danışmanlı makine öğrenmesi yöntemleri parametrelerin ayarlanması ile en iyi performansı elde eder. Farklı parametrelerin konfigürasyonları kullanılarak farklı makinesi öğrenme yöntemleri ile aynı problemin çözümü yapılabilir. Farklı öğrenme makineleri arasından en iyisini seçme sorunu, model seçimi olarak adlandırılır (Camastra ve Vinciarelli, 2015: 169).

Bir öğrenme algoritmasının başarısı ve doğru modeli seçebilmesi için sınırlı bir ampirik veri seti, altında yatan düzensizliklerin öğrenilebileceği ve buna karşılık gelen bir modelle temsil edilebileceği kadar yeterli bilgiyi içermelidir (Kantardzic, 2011: 125).

Veri kümelerinin boyutunun ve hızının her zamankinden daha hızlı arttığı bilinmektedir. Hedef cevapların eğitim setinde olduğu danışmanlı yöntemler için veri setleri geleneksel olarak nispeten küçük olmuştur çünkü cevapları elde etmek için insanlara ihtiyaç duyulmaktadır. Bugün ise, çok sayıda veri doğrudan sensörler, makineler veya bilgisayarlar tarafından üretilmektedir ve bu veri hacimlerini ele almak için ölçeklenebilir makine öğrenmesi algoritmaları gereklidir (Brink, Richards ve Fetherolf, 2016: 25).

Daha büyük bir model hatası olan daha az karmaşık bir model ile daha küçük bir model hatası olan daha karmaşık bir model karşılaştırıldığında iki modelin performansları öne çıkar. Model performansları için güven aralıkları kullanılabilir, her iki model için de %95 hata güven aralığında model performansları önemli ölçüde farklı kabul edilir ve en iyi performans gösteren model kullanılmalıdır (Hamel, 2009: 162).

2.6.3. Model Tahmini

Farklı öğrenme teknikleri kullanılarak makine öğrenmesi işlemi ile gerçekleştirilen bir model, performansının ölçüsü olarak standart hata oranı

parametresini kullanarak tahmin edilebilir. Hata oranı, uygulanan yeniden örnekleme tekniklerinden biriyle elde edilen bir test veri seti kullanılarak hesaplanır. Hata oranı ile ölçülen doğruluğa ek olarak veri madenciliği modelleri, hızları, sağlamlıkları, ölçeklenebilirlikleri ve yorumlanabilirlikleri açısından karşılaştırılabilir; tüm bu parametrelerin, modelin nihai doğrulama ve geçerliliği üzerinde etkisi olabilir (Kantardzic, 2011:126).

Hata oranının hesaplanması, bir test sürecindeki hataların sayımına dayanır. Bu hatalar, bir sınıflandırma problemi için basitçe yanlış sınıflandırma olarak tanımlanır. Tüm hatalar eşit önemde ise, bir hata oranı R , test setinde bulunan numunelerin S sayısına bölünen E hata sayısıdır (Kantardzic, 2011: 126):

$$R = E/S$$

Bir modelin doğruluğu AC , test verilerinin doğru sınıflandırılmış bir parçasıdır ve bir eksi hata oranı olarak hesaplanmıştır:

$$AC = 1 - R = (S - E)/S$$

2.6.4. Model Performansını Optimize Etme

Makine öğrenmesi modellerinin optimize edilmesi üç yol ile yapılabilir (Brink, Richards ve Fetherolf, 2016: 22):

Model parametrelerinin ayarlanması: Makine öğrenmesi algoritmaları temel alınan algoritmaya özgü parametrelerle yapılandırılır ve bu parametrelerin en uygun değeri genellikle verilerin türüne ve yapısına bağlıdır. Deneme yanılma metoduyla optimize edilmiş parametreler bulunabilir.

Özelliklerin alt kümesini seçme: Pek çok makine öğrenmesi problemi birçok özellik içerir ve bu özelliklerden kaynaklanan karmaşıklık bazen kendi başına bilgi verici olsalar bile, algoritmanın verilerin gerçek sinyalini bulmasını zorlaştırabilir. Öznitelik seçimi yapılarak uygun özellikler seçilebilir.

Verilerin ön işleme tabi tutulması: Gerçek dünya veri setlerinin çoğu temiz bir durumda değildir ve temizleme ve ön işleme işlemi gerçekleştirilmesi gerekir (Brink, Richards ve Fetherolf, 2016: 22).

Çalışmanın bir sonraki bölümünde önce uygulamada kullanılan sınıflandırma yöntemleri tanıtılmış olup daha sonra bu yöntemlerin kullanıldığı ilgili literatür kısmına yer verilmiştir.



İKİNCİ BÖLÜM

BORSA ENDEKSİ HAREKET YÖNÜNÜN TAHMİNİNDE KULLANILAN YÖNTEMLER

Çalışmanın bu bölümünde, analizde kullanılan yedi sınıflandırma yöntemi tanıtılacak ve daha sonraki kısımda ilk olarak bu sınıflandırma yöntemleri ile ilgili literatürde yapılmış endeks yön tahmini çalışmaları sunulurken ikinci olarak da teknik göstergelerin girdi veri seti olarak kullanıldığı sınıflandırma yöntemleri ile endeks yön tahmini yapılan çalışmalar sunulacaktır.

1. BORSA ENDEKSİ HAREKET YÖNÜNÜN TAHMİNİNDE KULLANILAN YÖNTEMLER

Sınıflandırma yöntemlerinden olan makine öğrenmesi yöntemleri olarak Yapay Sinir Ağları, Destek Vektör Makineleri, Karar Ağacı, Naive Bayes ve k-En Yakın Komşuluk yöntemleri ile geleneksel istatistiki yöntemlerden Lojistik Regresyon ve Doğrusal Diskriminant Analizi yöntemleri tanıtılacaktır.

1.1. YAPAY SİNİR AĞLARI (YSA)

Sinir ağları, insanların ve hayvanların beyinlerinde var olan sinir hücrelerinin oluşturduğu ağlardır. İnsan beyinde yaklaşık 100 milyar sinir hücresi vardır. İnsanlar zeka ve yeteneklerini beyne ait karmaşık sinir ağlarına uyarlanmış çeşitli zihinsel motor yeteneklere borçludur. Yüzyıllar boyunca doktorlar, psikologlar ve biyologlar beynin nasıl çalıştığını anlamaya çalıştılar. 1900'lü yılların başında beyindeki sinir hücrelerinin farkındalık, işbirliği, düşünce, bilinç ve öğrenme kabiliyetinden sorumlu olduğunun ortaya çıkması bilimde yeni bir çığır açmıştır (Ertel, 2011: 221).

Yapay sinir ağları (YSA) ilk olarak 1943'te McCulloch ve Pitts tarafından beyin fonksiyonlarını taklit etmek için basitleştirilmiş bir matematiksel model olarak önerildi. Yazarlar, sinir ağlarındaki nöronlar için farklı eşik değerleri ile neredeyse

tüm aritmetik fonksiyonları modelleyebildiklerini göstermişlerdir. Bu makale, YZ'nin bu çok önemli dalı olan YSA'nın inşası için temel oluşturmuştur (Ertel, 2011: 221). Daha sonra aynı yazarlar 1947 yılında, sinir ağları tarafından model tanıma konusunda pratik bir uygulama alanına yönelmişlerdir. Ancak bundan sonra YSA üzerine yapılan araştırmalar, bilinmeyen parametrelerin tahmin edilmesinde yaşanan zorluklar nedeniyle uzun süre ilerleme kaydedememiştir. 1986 yılında Rumelhart vd. sinir ağlarının parametre tahminleri için etkili bir geri yayılım algoritması tasarlamışlardır. Bu algoritma sinir ağlarının gelişiminde yeniden bir canlanma oluşturmuştur.

Hornik ve Jones, 1990'ların başında sinir ağlarının teorik temellerini daha ileri götürmüşlerdir. Standart çok katmanlı ileri beslemeli ağların, herhangi bir ölçülebilir fonksiyona tatmin edici bir doğruluk derecesiyle benzeme yeteneğine sahip olduğunu kanıtlamışlardır. Aynı zamanda, Yann LeCun'un el yazısı posta kodu tanıma araştırmaları, sinir ağları model tanıma alanında büyük başarı göstermiştir.

Sinir ağı modelleri esas olarak, doğrusal olmayan regresyon veya sınıflandırma modelleridir. 2000 yılı ve sonrasında yapılan birçok araştırma, basit sinir ağı modellerinin diğer makine öğrenme modelleri olan Rastgele Orman (RF) ve Destek Vektör Makinelerine (DVM) kıyasla daha iyi performans sağlayamadığını ortaya koymuştur. Bu da sinir ağlarının pratik kullanımında şüphelere yol açmıştır. Bu nedenle araştırmacılar, basit sinir ağı modelleri yerine analiz edilecek problemlere ve veri setlerine göre özellikli yeni yapılar geliştirerek sinir ağlarının daha iyi performans göstermelerini sağlamışlardır (Chen, 2015: 1).

YSA'nın modellenmesi, YZ içerisinde biyonik dal olarak düşünülebilir. YZ'nin neredeyse tüm alanları, mantıksal veya olasılıksal akıl yürütme gibi bilişsel süreçleri yeniden yaratmaya çalışmaktadır. Ancak modelleme için kullanılan araçlar insan beyniyle çok az benzerlik göstermektedir. YSA ise farklı yaklaşım göstermekte ve doğal sinir ağlarının işleyişi hakkındaki bilgilerden yola çıkarak, onları modellemeye, benzetmeye ve hatta donanım içinde yeniden yapılandırmaya çalışmaktadır (Ertel,2011: 221).

Sinir ağı, adından da anlaşılacağı gibi, yönlü bağlantılar üzerinden bağlanan bir takım düğümlerden oluşan bir ağ yapısıdır. Her düğüm bir işleme birimini temsil

eder ve düğümler arasındaki bağlantılar, bağlı düğümler arasındaki nedensel ilişkiyi belirtir. Tüm düğümlerin uyarlanabilir olması, bu düğümlerin çıktılarının modifiye edilebilir parametrelere bağlı olduğu anlamına gelir. YSA kavramı ile ilgili çeşitli yaklaşımlar olmasına rağmen, YSA biçimlendirilmiş uyarlanmış bir makine olarak kabul edilebilir. YSA, basit işlem ünitelerinden oluşan paralel dağıtılmış devasa bir işlemcidir. Birimler arası bağlantı gücü sayesinde ifade edilen deneysel bilgiyi öğrenme kabiliyetine sahiptir ve bu bilgiyi kullanıma hazır hale getirebilir (Kantardzic, 2011: 200).

1.1.1. YSA'nın Sunduğu Faydalı Özellik ve Kabiliyetler

Bir YSA bilgi işlem gücünü, öncelikle paralel dağıtılan büyük yapıyla ve ikinci olarak da öğrenme ve genelleme yeteneği yoluyla elde etmektedir. Genelleme, bir öğrenme işlemi sırasında karşılaşılmayan yeni girdiler için makul çıktılar üreten YSA'yı ifade eder. YSA'ların sunduğu faydalı özellik ve kabiliyetler şunlardır (Kantardzic, 2011: 201):

1. Doğrusal Olmama: YSA'nın temel birimi doğrusal veya doğrusal olmayan işlem elemanı olabilir, ancak YSA'nın tamamı büyük ölçüde doğrusal değildir. Ağ boyunca dağılmış olması, doğrusal olmamanın özel bir türüdür. YSA modellerinin doğasında varolan doğrusal olmama özelliği, öğrenme için veri üreten gerçek dünya mekanizmaları için özellikle önemlidir.

2. Örneklerden Öğrenme: YSA, bir dizi eğitim veya öğrenme örneği uygulayarak ara bağlantı ağırlıklarını modifiye eder. Öğrenme sürecinin nihai etkileri, bir ağı ayarlanmış parametreleridir ve eldeki probleme ilişkin dolaylı olarak depolanan bilgiyi temsil eder.

3. Uyumluluk: YSA, ara bağlantı ağırlıklarını çevredeki değişikliklere uyarlamak için dahili bir kabiliyete sahiptir. Özellikle, belirli bir ortamda çalışacak şekilde eğitilmiş YSA, çevresel koşullarındaki değişikliklere uyum sağlamak için kolayca yeniden eğitilebilir. Dahası, durağan olmayan ortamda çalışırken YSA, parametrelerini gerçek zamanlı olarak alacak şekilde tasarlanabilir.

4. Kanıtlı Cevap: Veri sınıflandırması bağlamında YSA, yalnızca belirli bir örnek için hangi sınıfın seçileceği hakkında değil, aynı zamanda alınan karar hakkında da bilgi sağlamak üzere tasarlanabilir. Bu bilgiler, belirsiz verilerin ortaya çıkması

durumunda reddedilmesi ve böylece sınıflandırma performansını veya ağ tarafından modellenen diğer görevlerin performanslarını iyileştirmek için kullanılabilir.


5. Hata Toleransı: YSA potansiyel olarak hataya dayanıklı olma veya sağlam hesaplama kapasitesine sahiptir. Performansı, nöronların ayrılması ve gürültülü veya eksik veriler gibi olumsuz çalışma koşulları altında önemli ölçüde bozulmaz.

6. Analiz ve Tasarım Eşitliği: YSA'ların uygulanmasını içeren tüm alanlarda aynı ilkeler, gösterim ve metodolojideki adımlar kullanılır. Farklı YSA türleri ve temel ilkelerinden bir sınıflandırmayı açıklamak için her YSA'nın temel bir bileşenini tanıtmak gereklidir. Bu basit işleme birimine yapay nöron denir.

1.1.2. Biyolojik Sinir Hücreleri

İnsan beynindeki yaklaşık 100 milyar nöronun her biri, Şekil 6'daki basitleştirilmiş bir sunumda gösterilen yapı ve fonksiyona sahiptir. Hücre gövdesinin (çekirdek) yanı sıra, nöron dendritler üzerinden diğer nöronlara lokal bağlantılar yapabilen bir aksona sahiptir. Akson, vücutta bir sinir lifi şeklinde bir metre uzunluğa kadar büyüyebilir (Ertel,2011: 222).

Şekil 6. Biyolojik Nöron (Ertel, 2011: 222).




Çekirdek, sinaps denilen temas noktalarındaki dendritleri aracılığıyla uyarıları (girdileri) alır, bu uyarıları özetler ve toplar, zar eşik potansiyelinin üstündeyse, bir potansiyel uyarı üretir ve aksonları boyunca diğer sinir hücrelerine gönderir ve sinapslar yoluyla tekrar sinirler yoluyla bağlanır. Oluşturulan sinyallerin sıklığı uyarıların gücüne bağlıdır. Nöronlar arasındaki sinapslar, gelen sinyallerin nöronun “ateşlenmesi” üzerindeki etkisini belirler (Cios vd., 2007: 421).

İnsan beynindeki tahminen 10^{11} nöronun her biri aşağı yukarı 1000 ila 10000 civarında diğer nöronlara bağlanır, bu da toplamda 10^{14} 'ün üzerinde bağlantı sağlar. Eğer aşırı derecede devasa bağlantıların bu devasa sayısının yumuşak, üç boyutlu dokudan oluştuğunu ve insan beynindeki deneylerin gerçekleştirilmesinin kolay olmadığını düşünürsek, o zaman neden beynin detaylı bir devre şemasına sahip olmadığını anlarız. (Ertel, 2011: 222).

1.1.3. Yapay Sinir Hücresi

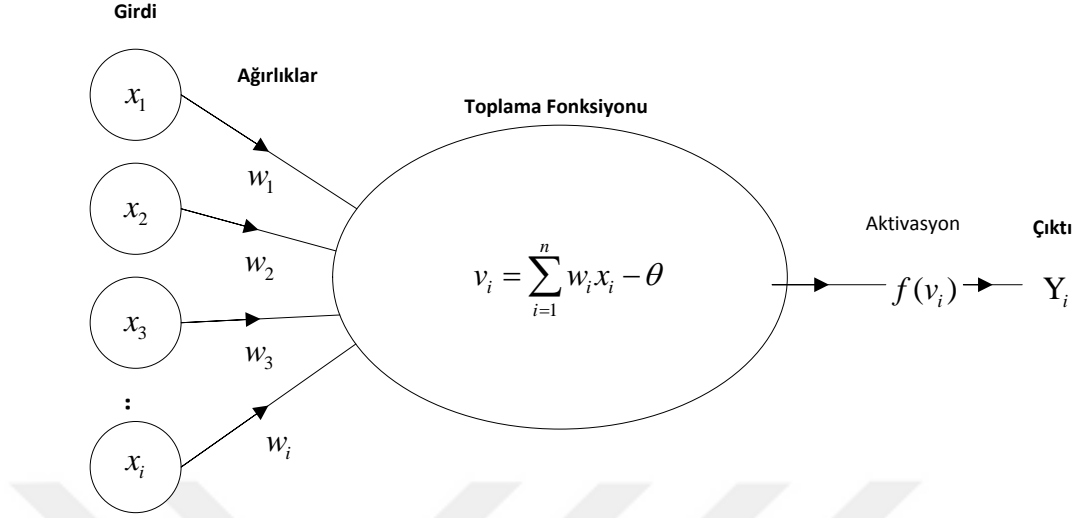
İlk olarak yapay sinir hücrelerinde, biyolojik sinir hücrelerinin sinapsları ağırlık olarak modellenmiştir. Biyolojik sinir hücresinin sinapsı sinir ağlarını birbirine bağlar ve sinapsın ana görevi bağlantının gücünü vermektir. Yapay sinir hücrelerinde ağırlıklar sayısal ifadelerdir. Negatif ağırlık, engelleyici bir bağlantıyı temsil eder; öte yandan, pozitif bir ağırlık uyarıcı bağlantıyı temsil eder. İkincisi, tüm girdiler bir araya toplanır ve ağırlıklar kullanılarak yeniden şekillendirilir. Son olarak, bir aktivasyon fonksiyonu çıktının genişliğini kontrol eder. Çıkış aralığı genellikle 0 ile 1 arasında veya -1 ve 1 olabilir (Ertel, 2011: 222). Bu süreç Şekil 7'de gösterilmiştir:

Şekil 7. Yapay Sinir Hücresi (Ertel, 2011: 222).



Yapay sinir hücresi biçimsel tanımı McCulloch ve Pits (1943: 117) tarafından biyolojik sinir hücresi örnek alınarak formüle edilmiştir. Yapay sinir hücresinin 5 temel elemanı bulunmaktadır. Bu elemanlar; giriş değerleri, ağırlıklar, toplama fonksiyonu, aktivasyon fonksiyonu ve çıkış değerleridir. Şekil 8, bir yapay sinir hücresinin elemanlarını vermektedir.

Şekil 8. Yapay Sinir Hücresi Elemanları (Akdağ, 2010: 37).



1.1.3.1. Girdiler

Nörona, dışarıdan ya da diğer bir sinir hücresinden iletilen (x_1, x_2, \dots, x_n) bilgilerdir. Yapay sinir hücrelerine çok sayıda bilgi girdi olarak verilebilir (Akdağ, 2010: 37).

1.1.3.2. Ağırlıklar

Ağırlıklar, YSA modellerinde bilginin gösterimi için kullanılır. Ağın tasarımı ve performansı bilginin gösterim şekline göre değişir. Bu amaçla kullanılan dört temel kural vardır (Haykin, 1994: 48):

Kural 1: Benzer sınıflardan gelen benzer girdiler, aynı kategoride yer alacak şekilde sınıflandırılmalıdır. Girdilerin benzerlikleri Öklid uzaklığı veya Mahalanobis uzaklığı gibi benzerlik ölçüleri kullanılarak ölçülür.

Kural 2: Ayrı sınıflardan gelen benzer girdiler, ayrı kategorilerde sınıflandırılmalıdır.

Kural 3: Önemli bir özneliliğin temsilinde daha fazla sayıda birim yer almalıdır. Karar verilirken birim sayısının fazla olması yüksek kesinlik sağlar ve hatayı azaltır.

Kural 4: Ağ tasarımında parametrelerle ilgili ön bilgiler kullanılarak daha basit bir ağ oluşturulabilir.

1.1.3.3. Toplama Fonksiyonu

Sinir hücrelerine gelen net giriş değerlerini hesaplayan fonksiyona toplama fonksiyonu denir. Ağırlıklı toplam fonksiyonu bu işte kullanılan en popüler fonksiyondur. Bu fonksiyonda girdi değerleri ağırlıkları ile çarpılır daha sonra da toplanır. Bu durumda net giriş değeri bulunmuş olur. Seçilen ağ mimarisine bağlı olarak bazı durumlarda kullanılan toplama fonksiyonları daha karmaşık olabilir. Bu fonksiyonlar farklı şekilde değerler üretebilir. Nöronlardan gelen değerlerin ağırlıklı toplamı ile eşik değerinin toplamı bir nöronun toplam girdisine eşittir (Kamruzzman, 2006: 63). En iyi toplama fonksiyonu genellikle deneme yanılma yolu ile belirlenmektedir. Bu da tamamen ağ mimarisini tasarlayanın kendi öngörüsüne bağlıdır.

1.1.3.4. Aktivasyon Fonksiyonu

YSA'da bilginin işlenmesini sağlayan eleman aktivasyon fonksiyonlarıdır. Bilginin işlendiği yer gizli katmandaki nöronlardır. Her bir nörona bir aktivasyon fonksiyonu karşılık gelecek şekilde eşleştirme yapılır. Nörona gelen bilgiler aktivasyon fonksiyonunun giriş değerlerini oluşturur. Aktivasyon fonksiyonunun giriş değerlerini işleyerek ürettiği yeni veriler ise ilgili gizli nöronun çıktı değerlerini oluşturur. Literatürde kullanılan YSA aktivasyon fonksiyonlarından bazıları Tablo 1'de gösterilmiştir.

Tablo 1. Aktivasyon Fonksiyonları

Fonksiyon	Kısa adı	Formül
Eşik Değer	-	$\phi(x) = \begin{cases} 1 & x \geq 0 \\ 0 & x < 0 \end{cases}$
Logaritmik Sigmoid	logsis	$\phi(x) = \frac{1}{1 + e^{-x}}$
Tanjant Hiperbolik	tanh	$\phi(x) = \frac{2}{1 + e^{-2x}} - 1$
Sekant Hiperbolik	sech	$\phi(x) = \frac{2}{e^x + e^{-x}}$
Radyal Tabanlı Fonksiyonlar	RBF	$\phi\left(\frac{x-c}{r}\right)$

1.1.3.5. Hücrenin Çıktısı

Çıktı değeri aktivasyon fonksiyonu tarafından belirlenir. Bir nöronun üretilen tek bir çıktı değeri vardır ve bu değer dış dünyaya veya birden fazla nörona girdi olarak gönderilebilir.

1.1.4. Yapay Sinir Ağlarının Bileşenleri

Genel bir YSA modeli, nöron adı verilen basit birimlerin farklı görevlere sahip girdi katmanı, gizli katman ve çıktı katmanından oluşmaktadır (Elmas, 2011: 126; Ecer, 2013a: 103; Ecer, 2013b: 106). Bu nedenle YSA modeli bileşenleri, nöronlar ve nöronlar arasındaki bilgi akışını sağlayan bağlantılardan oluşur. Birimler arasındaki bağlantıların herbirinin bir ağırlığı (W_i) vardır (Larose, 2005: 132).

1.1.4.1. Girdi Katmanı

Girdi katmanı var olduğu kabul edilen bir katmandır. Bu katman verinin ağa ilk tanıtıldığı bölüm olup giriş değerlerini herhangi bir işleme tabi tutmadan gizli katmana iletir. Detaylı bir yapıya sahip değildir. Girdi katmanında bağımsız değişken sayısı kadar nöron sayısı bulunur (Elmas, 2011: 126).

1.1.4.2. Gizli Katman

YSA'nın kara kutusu gizli katmandır. Girdi katmanından gelen bilgiler burada işlenir. Gizli katman nöronlarında bulunan aktivasyon fonksiyonları bilgiyi işler ve çıktı olarak iletirler. YSA'ya doğrusal olmayan ilişkileri modelleme gücünü kazandıran gizli katmandır (Alpaydın, 2011: 208). Uygulamalarda kullanılacak gizli katman sayısı ihtiyacı karşılayacak en az sayıda olmalıdır (Kriesel, 2007: 93).

1.1.4.3. Çıktı Katmanı

Sinir hücre yapısında aksona karşılık gelir. Çıktı katmanı, gizli katmandan bağlantılar ile kendisine gelen bilgiyi YSA'nın çıktısı olarak iletir. İkili sınıflandırma problemlerinde sınıfları ayıracak bir eşik değeri için çıktı katmanının kullanılması yaygındır. Birçok ağda, bilgi işlem birimleri Denklem 1'i kullanarak çıktı üretirler (Reed ve Marks, 1999: 1):

$$y = f\left(\sum_i w_i x_i\right) \quad (1)$$

Burada,

x_i : diğer birimlerin çıktılarını veya dışarıdan gelen girdi değerlerini,

w_i : bağlantı ağırlıklarını,

$f(.)$: doğrusal olmayan bir fonksiyonu,

göstermektedir.

1.1.4.4. Bağlantılar

YSA'da bağlantılar, katmanlar arasındaki bilgi akışını gerçekleştirir. Her katmandaki bir nöron kendisine gelen bilgiyi işleyerek ya da doğrudan bağlanmış olduğu diğer katmandaki nörona aktarır. Bu bağlantıların herbiri W ile gösterilen bir ağırlık değerine sahiptir. Bir nörondan diğer bir nörona iletilen bilgi bu ağırlık değeri ile çarpılarak iletilmiş olur. Bu durumda bir nörona gelen net bilgi, bir önceki katmandan kendisine bağlı olan nöronların çıktı değerlerinin skaler bir katıdır.

YSA'da katmanlarda bulunan nöron sayısı bağlantı sayısını belirler. YSA modellerindeki her bir bağlantıya ait bağlantı ağırlık değeri modelin tasarımcısı tarafından belirlenir. YSA'nın çıktı değerleri ile hedeflenen değer arasındaki farkı optimize etmek için bağlantı ağırlık değerleri değiştirilir. Bu ağırlık değerlerinin değiştirilerek optimize edilmesi, YSA'nın öğrenme süreci olarak ifade edilir.

1.1.5. Yapay Sinir Ağlarında Öğrenme Kuralları

YSA'nın temel problemi öğrenmenin nasıl olacağıdır. En önemli öğrenme kuralları şunlardır:

1.1.5.1. Hebb Kuralı

Öğrenme problemine, 1949 yılında yayınlanan kitabı ile literatürde Hebb kuralı olarak geçen Donald Hebb çözüm getirmiştir. Hebb kuralı daha sonra geliştirilen diğer birçok öğrenme kuralının temelini oluşturmuştur. Bu kurala göre; iki nöron arasında bilgi iletimi varsa nöronlar aktiftir ve nöronlar arasındaki bağlantı ağırlıkları kuvvetlendirilmelidir. Nöronlar aktif değilse, bağlantı ağırlıklarının zayıflatılması gerekmektedir. Aktiviteleri arasında pozitif yönlü korelasyon olan nöronlar arasındaki bağlantı ağırlıkları da artar (MacKay, 2003: 505):

$$\frac{dw_{ij}}{dt} \approx \text{Korelasyon}(x_i, x_j) \quad (2)$$

1.1.5.2. Hopfield Kuralı

Hopfield ağının etkinlik kuralı, her nöronun durumunu Denklem 3'te eşik aktivasyon fonksiyonuna sahip tek bir nöronmuş gibi güncellemesidir (MacKay, 2003: 506):

$$x(\alpha) = \theta(\alpha) \equiv \begin{cases} 1 & , \alpha \geq 0 \text{ ise} \\ -1 & , \alpha < 0 \text{ ise} \end{cases} \quad (3)$$

Bir Hopfield ağında geri bildirim bulunduğundan, güncellemelerin gerçekleşmesi için ağa bir geri bildirim verilmelidir. Hebb kuralına bakıldığında, 0 ile 1 arasındaki değerlere sahip nöronlar için ağırlıkların ancak zamanla büyüyebileceği görülür. Bir nöronun bu kurala göre zayıflaması, hatta ölmesi mümkün değildir. Bu problem 1982'de Hopfield tarafından sunulan modele göre oldukça farklı bir şekilde çözülmüştür. Hopfield Kuralı ikili nöronlar kullanır, fakat iki değer için -1 inaktif ve 1 aktiftir. Hebb kuralına göre, iki nöron aynı anda aktif olduğunda bağlantı ağırlıkları pozitifdir. Hopfield modelinde ise iki nörondan sadece biri aktif ise, bağlantı ağırlıkları negatiftir (Ertel, 2011: 226).

1.1.5.3. Perseptron (Geri Yayılım Algoritması)

Perseptron yapay sinir ağının temel birimidir, bu ağ çoklu girdiler alır ve ikili çıkışlar üretir. Makine öğrenme terminolojisinde, danışmanlı öğrenme algoritması girdileri 0 veya 1 ikili sınıfı olarak sınıflandırabilir. Daha basit bir ifadeyle perseptron, özellik vektörünün ağırlıklarını birleştiren bir doğrusal tahmin işlevine dayalı sınıflandırma yapabilen bir sınıflandırma algoritmasıdır.

Makine öğrenmesinde, perseptron giriş değeri x 'i çıkış değeri $f(x)$ 'e eşleyen ikili sınıflandırıcı fonksiyonu olarak Denklem 4 tanımlanır (Ramasubramanian ve Singh, 2017: 375):

$$f(x) = \begin{cases} 1 & , w \cdot x + b > 0 \text{ ise} \\ 0 & , w \cdot x + b \leq 0 \text{ ise} \end{cases} \quad (4)$$

Tek bir perseptron için öğrenme algoritması şu şekilde ifade edilebilir (Ramasubramanian ve Singh, 2017: 375):

1. Bazı olası değerlere ağırlıklar verilir.
2. Bir eğitim setindeki her veri noktası için Adım 3 ve 4'ü yapılır.
3. Önceki adım ağırlıkları ile çıktıyı hesaplanır.

$$y_j(t) = f[w(t) \cdot x_j] = f[w_0(t) \cdot x_{j,0} + w_1(t) \cdot x_{j,1} + w_2(t) \cdot x_{j,2} + \dots + w_n(t) \cdot x_{j,n}] \quad (5)$$

Bu, perseptron'daki mevcut ağırlıklarla alınacak çıktıdır.

4. Ağırlıklar güncellenir:

$$w_i(t+1) = w_i(t) + (d_j - y_j(t))x_{j,i} \quad (6)$$

bütün özellikler için $0 \leq i \leq n$.

5. Genel olarak, üç durdurma kriteri olabilir:

- Eğitim setindeki tüm noktalar bittiğinde
- Önceden belirlenmiş sayıda tekrarlama
- Tekrarlama hatası kullanıcı tarafından belirlenen hata eşliğinden az olduğunda.

1.1.5.4. Delta Kuralı

En küçük kareler yöntemi olarak da bilinen Delta kuralı 1960 yılında Bernard Widrow ve Ted Hoff tarafından geliştirilmiştir. Gerçekleşen çıktı ile beklenen çıktı arasındaki hataların kareleri ortalamasının optimum yapılması ile bağlantı ağırlıkları sabitlenir.

1.1.5.5. Kohonen Kuralı

Sinir hücrelerinin öğrenme kuralları taklit edilerek geliştirilmiştir. Kohonen kuralına göre YSA'da gizli katmandaki işlem birimleri ağırlıklarını değiştirmek için yarışır. Kazanan birim, en büyük çıktıya sahip işlem birimidir. Bağlantı ağırlıklarını yenileyen işlem birimleri böylece öğrenme sürecine katılırlar.


1.1.6. Yapay Sinir Ağlarının Model Yapısı

YSA'nın model yapısı, yaygın kullanımda doğrusal olmayan problemlerle başa çıkmak için oldukça farklı şekilde değişebilir. Çalışmanın bu bölümünde, genellikle tek veya iki gizli katmanlı en çok kullanılan yapılar ele alınacaktır.

1.1.6.1. Tek Gizli Katmanlı Yapay Sinir Ağları

Tek gizli katman sinir ağı, iki aşamalı regresyon veya sınıflandırma modelidir. Şekil 9'daki gibi tipik bir ağ diyagramı ile temsil edilir. Üç katmandan oluşur: girdi katmanı X s, gizli katman W s ve çıktı katmanı Y s.

Şekil 9. Tek Gizli Katman Sinir Ağı Modeli (Chen,2015: 2).



Grafikteki her daire içindeki düğüm, modeldeki bağıl konumlarını ayırt eden farklı renklere sahip değişkenlerdir (nöronlar); her bir çizgi, iki komşu katmandan bir çift düğüm bağlar ve bilinmeyen parametreyi (ağırlığı) gösterir. Alt katman, model girdileri olarak hizmet eden açıklayıcı değişkenler olan P düğümlerinden oluşur. Doğrusal regresyona benzer şekilde, eğer gerekirse kategorik faktörler kukla değişkenlere dönüştürülebilir. Üstteki K düğümleri, çıktı değişkenlerine karşılık gelir. Tek değişkenli regresyon için, K basitçe bir eştir ve üstte sadece bir birim Y_1 vardır. Genellemek amacıyla aşağıda, K 'nın çıktıları rasgele boyutlandırılır. Gizli katman yapının en önemli parçasıdır; doğrudan gözlemlenemeyen N düğümlerden oluşur. Bu değişkenler bu nedenle gizlidir ve sadece kavramsal olarak vardır. Bu gizli değişkenlerdeki varyasyon sinir ağlarının tahmin gücünü artırır. Komşu katmanlar arasındaki ilişkiler, Denklem 7 ve 8 ile açıklanabilir (Chen, 2015: 3):

$$W_n = \sigma \left(\sum_{p=1}^P \alpha_{np} * X_p \right), \text{ için } n=1, \dots, N \quad (7)$$

$$Y_k = g_k \left(\sum_{n=1}^N \theta_{kn} * W_n \right), \text{ için } k=1, \dots, K \quad (8)$$

α_s, θ_s ağırlık olarak adlandırılan model parametreleridir. σ_s doğrusal olmayan modeli denetleyen aktivasyon fonksiyonudur ve $g_k(\cdot)$ genelleştirilmiş doğrusal modellerin bağlantı fonksiyonlarıdır.


Temel olarak, her W, X 'in doğrusal kombinasyonunun doğrusal olmaya dönüşümüdür ve her Y, W doğrusal kombinasyonunun diğer doğrusal olmaya dönüşümüdür. Eğer $\sigma(\cdot)$ tanım fonksiyonu ise model standart doğrusal modele dönüşür.

1.1.6.2. İki Gizli Katmanlı Yapay Sinir Ağları

Birden fazla gizli katman olduğunda, Z nöronları tek katman ağına eklenir. Bu tip ağlar Şekil 10'da gösterildiği gibi daha karmaşıktır ve girdiler arasındaki ilişkileri daha iyi belirleyebilir.

Eğer modele daha fazla gizli katman ağı eklendiyse, daha karmaşık çok katmanlı yapı oluşturulur. Ayrıca, sinir ağları bazı parametrelerin önceden belirtilmesi gereken ve bazılarının ayarlanması gereken büyük bir model sınıfıdır.

Şekil 10. İki Gizli Katmanlı Sinir Ağı Modelleri (Chen,2015: 5).



Şekil 10’da üst katmandaki Y nöronları çıktı değişkenleridir, alt katmandaki X nöronları girdi değişkenleridir. Aradaki W ve Z nöronları ile belirtilen yapılar ise sırasıyla birinci ve ikinci gizli katmanlardır.

Değişkenler arasındaki ilişkiler Denklem 9, 10 ve 11 ile açıklanabilir (Chen,2015: 4):

$$W_n = \sigma \left(\sum_{p=1}^P \alpha_{np} * X_p \right), \text{ için } n = 1, \dots, N \quad (9)$$

$$Z_m = \sigma \left(\sum_{n=1}^N \beta_{mn} * W_n \right), \text{ için } m = 1, \dots, M \quad (10)$$

$$Y_k = g_k \left(\sum_{m=1}^M \theta_{km} * Z_m \right), \text{ için } k = 1, \dots, K \quad (11)$$

1.1.7. Yapay Sinir Ağı Model Yapısına Karar Verilmesi

YSA’nın başarısı veri setine uygun ağ model yapısının kurulmasına bağlıdır. Esas olan model yapısı oluşturulurken katman sayısı ve kullanılacak hücre sayısının belirlenmesidir. Modelde kullanılacak katman ve hücre sayısını belirlemek için uygulanacak kesin ve açık bir kural yoktur. Bundan dolayı Zhang (1998: 42), YSA tasarımını bir sanata benzetmiştir. Bu konunun uzmanlarının görüşleri alınarak katman ve hücre sayısı belirlenerek ağ model yapısı oluşturulabilir. Çalışmanın bu bölümünde konunun önemi nedeniyle ağ model yapısını oluşturan katman ve nöron sayıları hakkında detaylı bilgiler verilecektir.

1.1.7.1. Girdi Nöronu Sayısının Belirlenmesi

YSA’da basit düzeyli tahmin problemlerinin girdi nöron sayısı, girdi vektöründeki değişken sayısına eşittir. Zaman serilerinde ise gecikme sayısına bağlıdır. Ancak yine de kesin bir yol yoktur, deneme yoluyla bulunabilir (Zhang, 1998: 44).

1.1.7.2. Gizli Katman Sayısının Belirlenmesi

YSA, gizli katmandaki işlem birimleri sayesinde genelleme yeteneği kazanmaktadır. YSA modelinin başarısında gizli katman ve nöron sayısı büyük önem arz eder (Zhang, 1998: 42). Gizli katmandaki işlem birimleri, verideki örüntüleri

öğrenmeyi ve girdi ile çıktı arasındaki doğrusal olmayan eşleşmeleri sağlar. Gizli katman sayısı literatüre göre tek gizli katman veya en çok iki gizli katman olarak belirlenmektedir (Zhang, 1998: 44; Kaastra ve Boyd, 1996: 225). Çünkü katman sayısı gereğinden fazla olduğunda model öğrenmeden ziyade ezberlemeye yönelmektedir.

1.1.7.3. Gizli Katman Nöron Sayısının Belirlenmesi

Gizli katman nöron sayısı genellikle deneme-yanılma yoluyla bulunur. Kullanılacak nöron sayısı ağın büyütülmesi veya budanması ile belirlenir. Ağın büyütülmesi yönteminde, nöron sayısı en küçükten başlatılarak artırılır ve ağın hata oranı yükseldiği noktada gizli katmanda kullanılacak nöron sayısı tespit edilmiş olur (Öztemel, 2003: 120; Kaastra ve Boyd, 1996: 225). Budama yönteminde ise bu durumun tersi adımlar takip edilir.

1.1.7.4. Çıktı Nöron Sayısının Belirlenmesi

Çıktı nöron sayısı diğer tabakalara göre daha kolay belirlenir. Zaman serisi tahmin problemlerinde çıktı nöron sayısı tahmin dönemi sayısına eşittir. Yani tek dönemlik tahminde çıktı nöron sayısı bire eşit iken çok dönemli tahminde dönem sayısına eşittir. Sınıflandırma problemlerinde ise sınıf sayısına göre değişir (Zhang, 1998, 46). Örneğin değişken ikili şekilde sınıflandırılacaksa çıktı katmanında 2, üçlü olarak sınıflandırılacaksa çıktı katmanında 3 nöron bulunur.

1.1.7.5. Katmanlar Arası İletişim

Katmanlar arasında bağlantı kuran başlıca üç tür kalıp vardır: tam bağlantı, yerel bağlantı ve doğrudan bağlantı. Tam bağlantı, üst katmandaki tüm düğümlerin alt katmandaki tüm düğümlere bağlandığı anlamına gelir. Alt tabakadaki tüm bilgiler üst tabakayı elde etmek için gerekli olduğunda veya alt tabakadaki herhangi bir nöron seti birbirleriyle etkileşime girebildiğinde, bu kalıp doğru bir seçim olur ancak bunun için çok fazla parametreye ihtiyaç duyulur (Chen,2015: 7).

1.1.8. Yapay Sinir Ağlarının Eğitimi ve Testi

YSA'da ağın eğitilmesi, nöronlar arasındaki bağlantı ağırlıklarının belirlenmesi ile olur. Bağlantı ağırlık değerleri başlangıçta rastgele verilir. Sinir

ağları eğitim setindeki değerleri öğrendikçe bağlantı ağırlıkları optimal değerini alır (Öztemel, 2003: 55).

YSA'da makine öğrenmesinde olduğu gibi veri seti, eğitim ve test seti olarak ikiye ayrılır. Literatürde eğitim ve test setlerinin belirlenmesinde genel olarak verinin sırasıyla %90-%10, %80-%20, %70-%30 ya da %50-%50 olarak eğitim seti ve test setine ayrıldığı görülmektedir (Zhang, 1998: 50). Eğitim seti YSA'da öğrenmeyi hedeflerken, test seti öğrenmesi sağlanmış YSA'nın yeni verileri tahmin etme becerisinin belirlenmesinde kullanılır.

Öğrenme gerçekleşirken nöronlar arasındaki bağlantı ağırlıkları rastgele atanır. Eğitim seti iteratif (döngüsel) olarak tekrarlandıkça bağlantı ağırlıkları değişir. Doğru çıktıları üreten optimal ağırlık değerleri bulununca ağ öğrenmeyi tamamlar ve test setindeki yeni veriler için tahminlerde bulunmaya hazır hale gelir.

1.1.9. Hata Fonksiyonları

Sinir ağı modellerinde bilinmeyen parametreleri veya ağırlıkları tahmin etmek için, hata fonksiyonlarını en aza indirmek gerekir. Çıktı değişkeninin niteliğine bağlı olarak amaç, regresyon veya sınıflandırma problemlerinin çözümü olabilir. Ayrıca, aşırı öğrenme sorununu önlemek için hata fonksiyonlarına normalleştirme koşulları eklenebilir.

Çift katmanlı bir sinir ağında, tüm parametreleri (ağırlık) Ω ile gösterilir. Regresyon modelleri için hata fonksiyonu basitçe toplam kareleri alınmış hatalar olarak Denklem 12 ile ayarlanabilir (Chen, 2015: 9-11):

$$R(\Omega) = \sum_{k=1}^K \sum_{i=1}^N (y_{ik} - \hat{y}_{ik})^2 \quad (12)$$

Sınıflandırma modelleri için, hata fonksiyonu çaprazlama (sapma) Denklem 13 ile bulunabilir:

$$R(\Omega) = -\sum_{k=1}^K \sum_{i=1}^N y_{ik} \log(\hat{y}_{ik}) \quad (13)$$

ve karşılık gelen sınıflandırıcı Denklem 14 ile bulunabilir:

$$G(x) = \arg \max_k \{ \hat{y}_k(x) \} \quad (14)$$

1.1.10. Yapay Sinir Ağları Mimarisi

Yapay sinir ağları mimarisinin yapısal tasarımı, ağın topolojik yapısı ve katman sayıları birimler arasındaki ağırlıklı ilişkiler ve her katmandaki düğüm sayıları ile elde edilir. YSA topolojisi, düğümler ve bunların bağlantıları aracılığıyla açıklanmaktadır (Xin, 1999: 1424).

Verilen bir problem için ağ mimarisinin amacı, bir modelin geliştirilmesi için asıl gerekli adımlardan biridir. Ağın mimarisi birkaç nöron ile başlar, artırılarak devam eder, bu ilerleme, ağın aktivitesi kabul edilebilir bir seviyeye ulaşmaya kadar, eğitim boyunca nöron sayısını artırır ve optimal nöron sayısı tespit edilir (Nelson, 2011: 207).

YSA topolojisi, gizli nöronların sayısının sabitlenmesi ve her bir düğümün bağlantı ağırlıklarının seçilmesi yoluyla elde edilebilir. Küçük ve büyük ağların özellikleri, ağı seçerken olduğu gibi dikkate alınmalıdır. Küçük ağlar daha küçük miktarlarda depolamaya ihtiyaç duyarlar ve test ve eğitim yoluyla yüksek hızda işlem görürler, ancak hata şeması daha da zorlaşır ve bu tür ağlar hatalar daha az minimum seviyeye ulaşır (Nidhi ve Kumar, 2013: 4429). Daha büyük ağlar ise gereksinim duyulan bir dizi eğitim dizisinin süratle öğrenilmesi ve hata yayılımında sınırlı asgari seviyeye ulaşılması için geliştirilmiş bir kapasiteye sahip olma eğiliminde olmasına rağmen, doğru tahmin başarısını elde etmek için çok sayıda eğitim örneğine ihtiyaç duyarlar.

1.1.10.1. Geri Yayılım (Backpropagation) Yapay Sinir Ağları

Geri yayılım YSA, ağda döngüler oluşturarak sinyalleri her iki yönde de iletebilir. Geri bildirim ağları çok güçlü ve son derece karmaşık olabilir (Mujeed, 2012: 3). Geriye dönük ilerleme, kuvvet faktörünü ve öğrenme oranını değiştirir (Sonam ve Rakesh, 2013: 94).

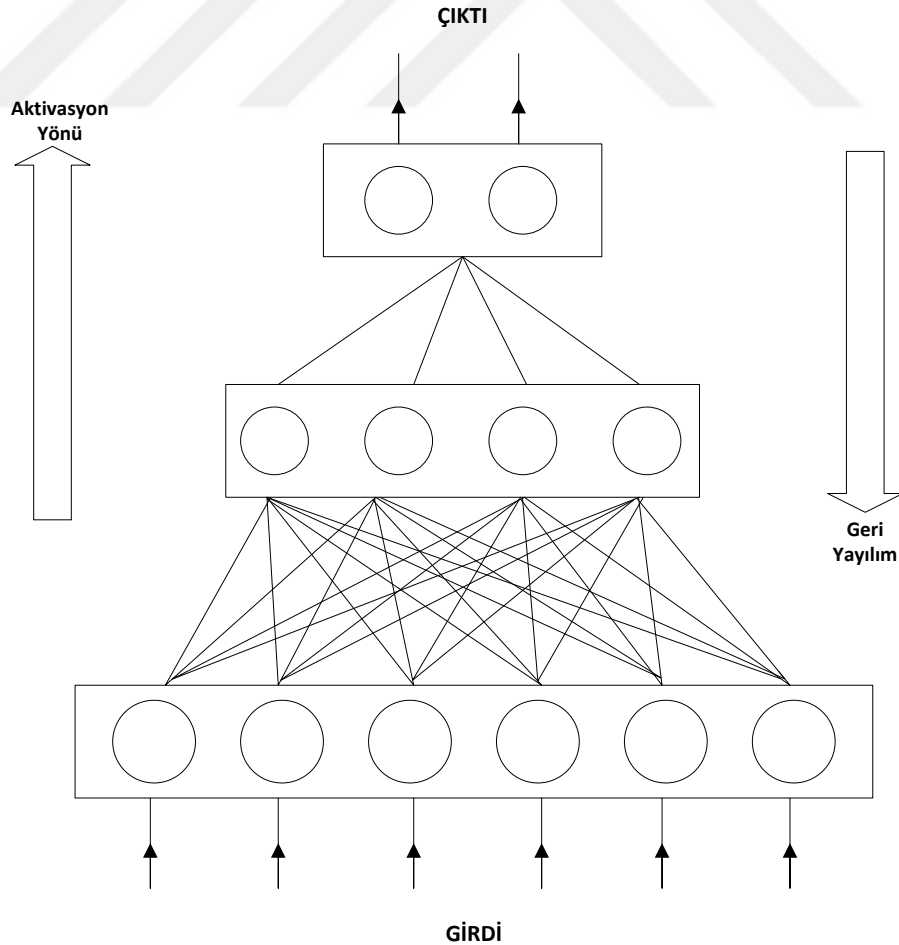
Geri yayılım algoritması, öğrenme algoritmalarından en yaygın olarak kullanılanlarındandır. Kolay anlaşılabilir ve matematiksel olarak ispatlanabilir olması popüler yapmaktadır. Geri yayılım algoritması adını hataları çıkıştan girişe doğru azaltmaya çalışması nedeniyle almıştır. Çıkıştan başlayarak geriye doğru her tabakada hataları azaltarak ağırlıkları yeniden hesaplar.

Geri yayılım öğrenme algoritması uygulama adımları şunlardır:

- Girdi parametrelerinin ilerlemesi
- İlişkilendirilmiş hataların geriye yayılımı
- Ağırlıkların ayarlanması

İlk etapta ağ, sunulan bilgiyi girdi tabakasından hiç bir işleme tabi tutmadan gizli katmana iletir. Gizli katmana gelen bilgiler, toplama fonksiyonu ile değerlendirildikten sonra, aktivasyon fonksiyonu ile işlenerek çıktı tabakasındaki sinir hücrelerine gönderilir. Çıktı katmanında yukarıdaki işlem tekrar edildikten sonra ağın çıktısı elde edilir. İkinci aşamada elde edilen ağ çıktısı, gerçek çıktı ile karşılaştırılır ve iki değer arasında oluşan hata, ağa geri sunulur. Son aşamada ise, mevcut hata miktarı ağa tekrar sunularak, daha düşük hata oranını veren ağırlık değerlerinin belirlenmesi sağlanır. Şekil 11’de anlatılan bu süreç verilmiştir.

Şekil 11. Geri Yayılım Yapay Sinir Ağları (Akdağ, 2010: 50).

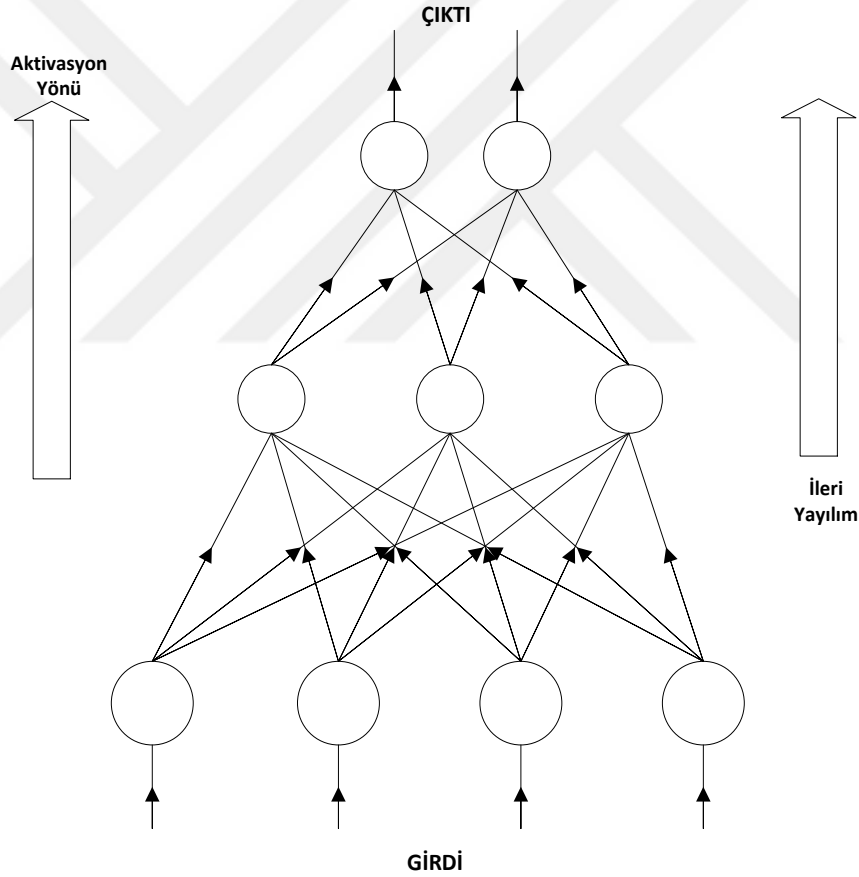


1.1.10.2. İleri Beslemeli Yapay Sinir Ağları

İleri beslemeli ağlarda sinyaller girdi katmanından çıktı katmanına sadece bir yoldan geçer. YSA'da ileri beslemeli öğrenme algoritması, benzer bağlantı ağırlıklarının değiştirilmesi işleminin çok hızlı bir şekilde yapılmasını sağlar (Sagar, Venkata ve Manoj, 2011: 335).

İleri beslemeli öğrenme algoritmaları, girdiler ile çıktıları doğrudan ilişkilendirir. Tüm birimleri sonraki katmandaki birimlerle tek bir yönde bağlar. Bu ağlar örüntü tanımda yaygın şekilde kullanılır. Şekil 12 ileri beslemeli YSA'ları göstermektedir.

Şekil 12. İleri Beslemeli YSA (Hamzaçebi ve Kutay, 2004: 229).



İleri beslemeli ağlarda, sinyaller girdi katmanından çıktı katmanına doğru yalnız bir yönde iletilmektedir. Ağı oluşturan sinir hücreleri arka arkaya beslenmektedir. Bu ağlarda, işlem elemanları, önceki veya aynı tabakadaki işlem elemanları ile bağlantı oluşturmazlar. Bilgi bir önceki katmanda bulunan işlem

elemanından alınır, sonraki katmanda bulunan işlem elemanına veya dış dünyaya iletilir.

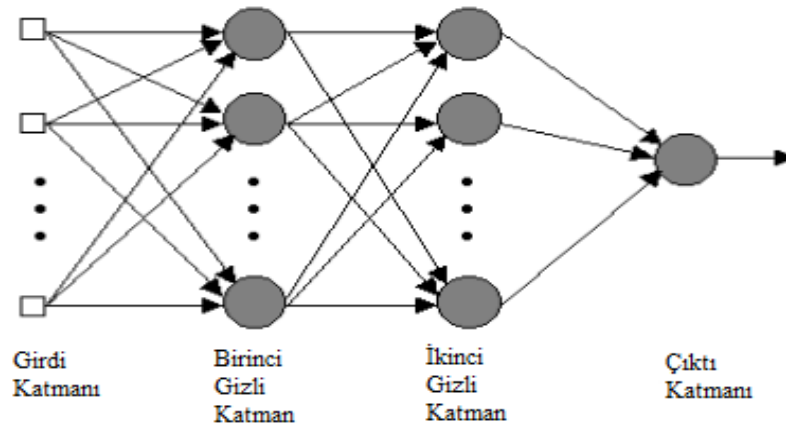
İleri beslemeli ağlar için Çok Katmanlı Algılayıcılar (ÇKA) örnek olarak verilebilir. Geriye yayılım algoritmasının kullanılması ile birlikte, özellikle çok katmanlı yapay sinir ağına olan ilgi artmıştır.

1.1.10.3. Çok Katmanlı Yapay Sinir Ağı

Çok katmanlı YSA'lar danışmanlı öğrenme yöntemi ile eğitilmektedir. Yani geriye yayılım algoritması kullanılarak yapılan eğitim işleminde, ağa girdi ve çıktı değerlerinden oluşan veri seti birlikte verilmektedir. Danışmanlı öğrenme yönteminin kullanıldığı çok katmanlı ağ modeli, sınıflandırma, tanıma ve genelleme yapmayı gerektiren problemlerin çözümünde kullanılmaktadır.

ÇKA'da, en az bir gizli katman olmak üzere, çözülen problemin karmaşıklığına göre birden fazla gizli katman da kullanılabilir (Şekil 13). ÇKA ağında, danışmanlı öğrenme stratejisi kullanılır. Bu ağ türünde, ağa girdi kümesi ile birlikte, bu girdi kümesi için üretmesi gereken çıktı kümesi de birlikte sunulur. Böylece, ağ kendisine sunulan örnek girdilerle, ürettiği çıktı değerlerini karşılaştırır. İteratif bir yöntemle hata oranını en aza indirmeye çalışır. Araştırmacının belirleyeceği hata seviyesine ulaşıldığında, ağırlık katsayıları sabitlenir. Ağ, verilen örnek seti için genelleştirme yeteneğini, belirlenen hata payı ile kazanmış olur.

Şekil 13. Çok Katmanlı Yapay Sinir Ağı (Kılıç, Özbalcı ve Özçalık, 2012: 695)



Çok katmanlı YSA uygulamada sağladığı kolaylık nedeniyle yaygın olarak kullanılır.

1.1.11. Arařtırma ve Uygulamalarda Yapay Sinir Ađları

YSA'larının arařtırma alanı zaman içinde arpıcı deđiřiklikler geirmiş ve havaalanındaki patlayıcı madde tespit sisteminden (Shea ve Lin, 1989: 33) fotođraflama, kanser hücresi algılama (Zhou vd., 2002: 32) ve yapay zekada el yazısı tanımayaya (Cun vd., 1990: 27) kadar birçok alanda modeller ve öğrenme yöntemleri geniş bir yelpazeyi kapsayacak şekilde ilerlemiřtir.

Güçlü bir öngörü aracı olarak sinir ađı, bazı uygulamalar için mükemmel bir seçenek olabilir. Örneđin, internetteki tarama gemişine, gemişte satın alınan mallara ve diđer demografik bilgilere dayalı olarak potansiyel müşterileri ve onların belli ihtiyaçları için tercihlerini belirlemeye yardımcı olmak için pazarlama analizlerinde uygulanabilir. Bu bilgilerle yatırımcılar, potansiyel müşterilerinin kim olduklarını ve neye ihtiyaç duyacaklarını bilir ve sonra onları hedef alan reklamlar tasarlayabilirler. Bu tür analiz yatırımcıların reklam maliyetlerini önemli ölçüde (Widrow, Rumelhart ve Lehr, 1994: 101) azaltmalarına yardımcı olmakla kalmaz müşterilerin ilgili bilgileri daha etkin bir şekilde almalarına yardımcı olabilir.

YSA, kümeleme ve doğrusal olmayan ana bileřen analizi gibi danışmansız öğrenmeye de katkıda bulunabilir (Herrero, Valencia ve Dopazo, 2001: 130). Sinir ađlarını kullanarak doğrusal olmayan ana bileřen analizi gerçekleştirme fikri, çıktı sinir hücrelerindeki giriş nöronlarını çođaltmaya alışmaktadır, böylece gizli nöronlar girdi nöronları için iyi bir temsilci kümesi olarak hizmet edecektir. Sinir ađı modellerinin kaynađı insan beyninin işlevselliđini taklit etmek olduğundan, yapay zekada sinir ađları umut verici bir uygulamaya sahiptir. Yapay zekanın birçok yönü öğrenme, doğal dil işleme ve manipölasyon gibi güçlü makine öğrenme modellerine gerçekten ihtiyaç duyar.

Sinir ađları için en geniş uygulama alanı sınıflandırma, tahmin modelleme, model tanıma ve yenilik algılama alanlarıdır. Daha yakın zamanlarda, finansal endüstride sinir ađlarının uygulamaları önerilmiştir. Pek çok yayın, finansal pazardaki başarısını kanıtlamıştır. Otomatik ticaret sistemlerinin bazıları da sinir ađı modelleri üzerine kurulmuřtur.

1.2. DESTEK VEKTÖR MAKİNELERİ

Destek vektör makinesi, istatistiğin öğrenme teoremlerine dayanan bir evrensel yapıcı öğrenme stratejisidir (Cortes ve Vapnik, 1995: 273). Destek vektör makinesi (DVM) yaklaşımı standart tahmin edici öğrenme algoritmalarının nasıl kullanılabileceğini açıklamaktadır. Bununla birlikte DVM, fonksiyonların parametreleştirilmesinde yeni bir yaklaşım sunar ve dolayısıyla danışmansız öğrenme algoritmaları ve öngörücü öğrenmenin dışında da uygulanabilir.

1.2.1. Destek Vektör Makinesine Genel Bir Bakış

Temel marj kavramı ilk olarak 1960'ların başlarında ayrılabilir verilerle problemleri sınıflandırmak için geliştirilmiştir (Vapnik ve Lerner, 1963: 776; Vapnik ve Chervonenkis, 1964: 112). Çekirdek seçimi ve eşsiz verilerle başa çıkma yeteneği DVM yöntemine dahil edilmiştir (Boser, Guyon ve Vapnik 1992: 144; Cortes ve Vapnik 1995: 273). DVM metodolojisi diğer öğrenme problemlerini çözmek için uyarlanmış ve çok sayıda uygulama için başarıyla kullanılmıştır.

DVM yaklaşımı birkaç ana fikri (marj, kernel temsili ve dualite) birleştirir. Çekirdek kullanma fikri 1960'ların ortalarında kullanılmıştır (Aizerman, Braverman ve Rozonoer, 1964: 921). Çekirdek seçimi, aynı zamanda, Mercer teoreminde karesel kayıp ile standart bir düzenleyici çerçevede altında tanıtılmıştır (Kimeldorf ve Wahba, 1971: 84). Matematiksel programlamada, DVM'ye benzer sınıflandırma için doğrusal optimizasyon formülasyonu Mangasarian (1965) tarafından önerilmiştir. Bununla birlikte, bu gelişmeler istatistiksel öğrenme kuramının sağladığı sağlam temellerden yoksun olduğu için pratik öğrenme algoritmaları ile sonuçlanmamıştır (Cherkassky, 2007: 408).

DVM, eğitim verisi kümesinden girdi-çıkı haritalama fonksiyonları üreten danışmanlı öğrenme metodlarıdır (Ecer, 2013c: 86). Haritalama işlevi aynı zamanda sınıflandırma işlevi veya regresyon işlevi için kullanılır. Sınıflandırma için, doğrusal olmayan kernel fonksiyonları genellikle girdi verisinin orijinal girdi alanına kıyasla daha ayrılabilir hale getirdiği yüksek boyutlu bir özellik alanına dönüştürmek için kullanılır. Daha sonra, eğitim verisindeki sınıfları optimal olarak ayırmak için maksimum marjlı hiperdüzlemler oluşturulur. Hiperdüzlemin her iki tarafında yer alan iki paralel hiperdüzlem, iki paralel hiperdüzlem arasındaki mesafeyi

maksimuma çıkararak verileri ayıran yapılardır. Bu paralel hiperdüzlemler arasındaki marj veya mesafe ne kadar büyük olursa, sınıflandırıcının genelleme performansının o kadar iyi olacağı söylenebilir.

DVM'ler, bir sınıflandırma veya regresyon kararı alan bir genelleştirilmiş doğrusal model ailesine aittir. Ayrıca "çekirdek fonksiyonlarına" ait oldukları söylenebilir.


İstatistiksel öğrenme teorisinde sağlam matematiksel temelini yanı sıra, bilgi keşfi ve veri madenciliği için en popüler, en yeni araçlardan biri olarak geliştirilen DVM'ler, tıbbi tanı, bioinformatik, yüz tanıma, destek vektörü parametreleştirilmesi, büyük doğrusal operatör denklemleri, bilgisayarlı tomografi, sinyal/görüntü sıkıştırması, görüntü işleme ve metin madenciliği gibi sayısız gerçek dünya uygulamalarında son derece rekabetçi bir performans sergilemiştir. Yapay sinir ağlarına benzer şekilde, DVM'ler herhangi bir doğruluk derecesine sahip çok değişkenli fonksiyonun evrensel tahmin edicilerin yeteneklerine sahiptir. Bu nedenle, büyük ölçüde doğrusal olmayan, karmaşık sistemler ve süreçlerin modellenmesi özellikle önemlidir.

1.2.2. Doğrusal Sınıflandırıcı

Genellikle birçok doğrusal sınıflandırıcı (hiperdüzlem), verileri birden fazla sınıfa ayırabilir. Bununla birlikte sadece bir hiperdüzlem maksimum ayırma sağlar. DVM'ler veriyi, veri noktası olarak temsil edilen "öğrenen" bir makine öğrenme sürecinin parçası olarak sınıflandırır. Bu veri noktalarının ikiden fazla boyutu olabilir. Nihayetinde, verileri $n-1$ boyutlu bir hiperdüzlem ile ayırabilir.

Bu, doğrusal sınıflandırıcının tipik bir formu olarak görülebilir. Öncelikle iki (veya daha fazla) sınıf arasında maksimum ayırma (marj) elde edilip edilemeyeceği bulunur. Bu şekilde hiperdüzlem seçilir ve hiperdüzlemden en yakın veri noktasına olan mesafe maksimuma çıkarılır. Böyle bir hiper düzlem, maksimum marjlı hiperdüzlem olarak bilinir. Böyle bir doğrusal sınıflandırıcı ise bir maksimum marj sınıflandırıcısı olarak bilinir. Şekil 14'te doğrusal sınıflandırıcı (hiperdüzlem) gösterilmiştir.

Şekil 14. Doğrusal Sınıflandırıcı (hiperdüzlem) (Olson ve Delen, 2008: 111).




1.2.3. Dört Farklı Konseptin Birleşimi DVM

1. DVM bir dizi eşdeğerlik sınıfında özel bir yapı tanımlar. Bu yapıda, her bir eleman, marjın boyutu (sınıflandırma problemleri için) ve daha genel olarak, uyarlanabilir marjın temelli bir kayıp fonksiyonunun hiperparametresi ile indekslenir (Cherkassky, 2007: 407).

2. Girişlerin doğrusal olmayan temel fonksiyonlar kullanılarak yüksek boyutlu bir alan üzerine eşlenmesi Şekil 15'teki gibidir. Örüntü tanıma uygulamalarında, girdi vektörlerini, öğrenme problemine ilişkin bir önyargı varsayımına göre seçilen bir dizi yeni değişkene (özelliklere) eşlemek yaygındır. Bu özellikler orijinal girişlerden ziyade öğrenme algoritması tarafından kullanılır. Bu tip özellik seçimi genellikle karmaşıklığın giriş boyutuna bağlı olduğu durumlarda, yakınlık şemaları için karmaşıklığı kontrol etme amacına sahiptir. Özellik seçimi sorunun karmaşıklığını azaltmak için, verilerdeki fazlalıktan yararlanır. Bu, girdi değişkenlerinin yüksek boyutlu bir haritalamasını oluşturmak için kullanılan temel fonksiyonların (özellikler) sayısına hiçbir kısıtlama getirmeyen DVM yaklaşımının tersidir (Cherkassky, 2007: 407).

Şekil 15. DVM Haritası (Cherkassky, 2007: 407).



3. Karmaşıklık kısıtlı lineer fonksiyonlar, yüksek boyutlu uzay giriş örneklerini tahmin etmek veya ayırmak için kullanılır. DVM, amacı gerçekleştirmek için doğrusal tahmin ediciler kullanır. Sinir ağları gibi diğer birçok öğrenme yaklaşımı, doğrudan girdi uzayında doğrusal olmayan yaklaşımlara bağlıdır. Doğrusal olmayan tahmin ediciler potansiyel olarak yaklaşma fonksiyonunun daha optimal bir temsilini sağlayabilir. Bununla birlikte DVM'ler, iki ciddi dezavantaja sahiptirler: optimal bir çözüm sağlayan karmaşıklık önlemlerinin eksikliği ve optimizasyon yaklaşımlarının eksikliği. Model karmaşıklığı için doğru tahminler, doğrusal tahmin ediciler ile elde edilebilir. Doğrusal fonksiyonlar için asgari ampirik risk sağlayan optimizasyon yaklaşımları mevcuttur. Bu nedenlerden dolayı DVM, yüksek boyutlu özellik alanında doğrusal tahmin kullanır (Cherkassky, 2007: 407).


4. İkili optimizasyon teorisi, sayısal olarak hesaplanabilir bir yüksek boyutlu özellik uzayında model parametrelerinin tahminini yapmak için kullanılır. Optimizasyon teorisinde, eğer maliyet ve kısıtlama işlevleri tamamen ayrık ise, bu optimizasyon probleminin ikili bir formu vardır. İkili problemin çözümü, orijinal problemin çözülmesine eşdeğerdir (Strang, 1986: 28). DVM için, bir doğrusal temel fonksiyon açılımının parametrelerini belirlemek için ikinci dereceden bir optimizasyon problemi çözümlenmelidir. Yüksek boyutlu özellik alanları için, çok sayıda parametre bu sorunu zorlaştırabilir. Bununla birlikte, ikili formda bu problem, eğitim örneklerinin sayısı ile arttığı için çözülmesi pratiktir. İkilinin çözümüne karşılık gelen doğrusal yaklaşma fonksiyonu, tipik temel işlev gösterimi yerine, çekirdek seçiminde verilir (Cherkassky, 2007: 406-407).

1.2.4. Doğrusal Destek Vektör Makineleri

Eğitim veri kümesindeki veri noktalarının $\{(x_1, c_1), (x_2, c_2), \dots, (x_n, c_n)\}$ c_i 'nin 1 (yani, "evet") veya 0 olduğu (yani "hayır") olduğu durumlarda, bu sabit sayılar veri noktasının ait olduğu sınıfı belirtir. Her veri noktası, genellikle ölçeklenmiş $[0, 1]$ veya $[-1, 1]$ değerlerine sahip, n boyutlu bir gerçek vektördür. Ölçekleme, sınıflandırmaya başka türlü hakim olabilecek büyük varyanslı değişkenlere karşı korunmak için önemlidir. Bölünen hiperdüzlem ile DVM'nin nihayetinde ayrılmasını istediğimiz doğru sınıflandırmayı gösteren eğitim verisi Denklem 15 ile bulunabilir:

$$w \bullet x - b = 0 \quad (15)$$

Şekil 16. Maksimum Ayırma Hiperdüzlemleri (Olson ve Delen, 2008: 113).



Vektör w , ayırıcı hiperdüzleme dik olarak gösterilir. Hata parametresini b eklemek, marjı arttırılmasına izin verir. Onun yokluğunda, hiper düzlem, kaynağı sınırlandırarak orijinden geçmek zorunda kalır.

Maksimum marjla ilgilenildiği için, her iki sınıftaki bu destek vektörlerine en yakın paralel hiperdüzlemler aranır. Bu paralel hiperdüzlemler Denklem 16 ve 17 ile açıklanabilir.

$$w \bullet x - b = 1 \quad (16)$$

$$w \bullet x - b = -1 \quad (17)$$

Eğitim verileri doğrusal olarak ayrılabilirse, bu hiperdüzlemleri seçebilir, böylece aralarında hiçbir nokta bulunmaz ve sonra mesafelerini en üst düzeye çıkarmaya çalışılır. Hiperdüzlemler arasındaki mesafe $2/|w|$ olarak bulunur. Veri noktalarını hariç tutmak için, her ikisi için de Denklem 18 ve 19 kullanılabilir (Min ve Lee, 2005: 605).

$$w \bullet x_i - b \geq 1 \quad (18)$$

$$w \bullet x_i - b \leq -1 \quad (19)$$

Denklem 20'deki gibi yeniden yazılırsa:

$$c_i(w \bullet x_i - b) \geq 1, \quad 1 \leq i \leq n \quad (20)$$

1.2.4.1. Ön Form

Minimize $|w|$ kısıtlamaya tabi olduğundan bu bir kuadratik programlama optimizasyon problemidir. Daha açık bir şekilde, minimize olması ve matematiksel kolaylık için Denklem 21’de $1/2$ faktörü kullanılır.

$$(1/2)\|w\|^2 \quad (21)$$

1.2.4.2. İkili Form

Sınıflandırma kuralını ikili biçimde yazmak, sınıflandırmanın sadece destek vektörlerinin bir işlevi olduğunu, yani marjda yer alan eğitim verilerinin olduğunu ortaya koymaktadır. DVM'nin ikili formu Denklem 22 ile gösterilebilir:

$$\max \sum_{i=1}^n \alpha_i - \sum_{i,j} \alpha_i \alpha_j c_i c_j x_i^T x_j \quad (22)$$

α terimleri, eğitim veri setinde ağırlık vektörü için ikili bir temsil oluşturduğunda Denklem 23 şeklinde yazılır.

$$w = \sum_i \alpha_i c_i x_i \quad (23)$$

1.2.5. Marj

1995 yılında Cortes ve Vapnik, yanlış etiketlenmiş örneklere izin veren değiştirilmiş bir maksimum marj fikri önermişlerdir (Cortes ve Vapnik, 1995: 20). “Evet” ve “hayır” örneklerini ayırabilen bir hiperdüzlem yoksa, en yakın doğru bölünmüş örneklere olan mesafeyi maksimize eden Yumuşak Marj yöntemi örnekleri mümkün olduğunca doğru bir şekilde dağıtan bir hiperdüzlem seçer. Bu çalışma DVM yöntemini popülerleştirmiştir. Yöntem, referans noktasının yanlış sınıflandırılma derecesini ölçen gevşek değişkenleri ξ_i , Denklem 24 ile hesaplar (Min ve Lee, 2005: 605).

$$c_i(w \bullet x_i - b) \geq 1 - \xi_i \quad 1 \leq i \leq n \quad (24)$$

Fonksiyon daha sonra sıfır olmayan ξ_i hata fonksiyonuyla artırılır ve optimizasyon büyük bir marj ile küçük bir hata arasında bir değişime dönüşür. Hata

fonksiyonu doğrusal ise, nesnel fonksiyonun ilk şekli Denklem 25'teki gibidir (Olson ve Delen, 2008: 111-115).

$$\min \|w\|^2 + C \sum_i \xi_i \quad \text{öyle ki} \quad c_i (w \bullet x_i - b) \geq 1 - \xi_i \quad 1 \leq i \leq n \quad (25)$$

Bu kısıtlama küçültme hedefi ile birlikte $\|w\|$ Lagrange çarpanları kullanılarak çözülebilir. Doğrusal bir hata fonksiyonunun en önemli avantajı, gevşek değişkenlerin ikili problemde yoksun olması ve sabit c 'nin sadece Lagrange çarpanları üzerinde ek bir kısıtlama olarak ortaya çıkmasıdır. Doğrusal olmayan hata fonksiyonları, sınıflandırıcı üzerindeki etkisini azaltmak için kullanılmıştır (Olson ve Delen, 2008: 111-115).

1.2.6. Doğrusal Olmayan Destek Vektör Makineleri

Vladimir Vapnik tarafından 1963'te önerilen orijinal optimal hiperdüzlem algoritması, doğrusal bir sınıflandırıcıydı. Bununla birlikte, 1992'de Boser, Guyon ve Vapnik, maksimum marjlı hiperdüzlemlere çekirdek hilesinin uygulanmasıyla doğrusal olmayan sınıflandırıcılar elde etmenin bir yolunu önermişlerdir. Çekirdek hilesi ile elde edilen algoritma benzerdir, ancak doğrusal her nokta doğrusal olmayan bir çekirdek fonksiyonu ile değiştirilir. Böylelikle algoritmanın dönüştürülmüş özellik alanında maksimum marjlı hiperdüzleme uyması sağlanır. Doğrusal olmayan ve dönüştürülmüş alan yüksek boyutlu olabilir. Dolayısıyla, sınıflandırıcı yüksek boyutlu özellik alanında bir hiperdüzlem olsa da, orijinal giriş alanında doğrusal olmayabilir (Boser, Guyon ve Vapnik 1992: 144).

1.2.7. Çekirdek Fonksiyonları

Çekirdek fonksiyonu bir benzerlik fonksiyonudur. Makine öğrenme algoritmasına dayanan alan uzmanlığı gerektiren fonksiyondur. Çekirdek fonksiyonları bir alternatif sunar. Bir dizi özelliği tanımlamak yerine, örnekler arasındaki benzerliği hesaplamak için tek bir çekirdek fonksiyonu tanımlanır. Bu çekirdek fonksiyonu, örnekler ve etiketlerle birlikte öğrenme algoritması sayesinde sınıflandırmayı yapar. Bazı koşullar altında, her çekirdek fonksiyonu sorun çözücü bir fonksiyon olarak ifade edilebilir (Min ve Lee, 2005: 605). Literatürde kullanılan birçok çekirdek fonksiyonu vardır. En yaygın olanlar aşağıda tanımlanmıştır:

Doğrusal Kernel Fonksiyonu: Çekirdek fonksiyonlarının en basit şeklidir. Çıktı (x, y) tarafından ek bir sabit c ile Denklem 26'daki gibi temsil edilebilir (Min ve Lee, 2005: 605);

$$K(x, y) = (x^T y) + c \quad (26)$$

Polinom Çekirdek Fonksiyonu: Doğrusal olmayan problemler arasında popüler bir çekirdek işlevidir. Denklem 27'deki gibi temsil edilebilir (Min ve Lee, 2005: 605);

$$K(x, y) = [(x^T y) + c]^d \quad (27)$$

Sigmoid fonksiyonu: Sigmoid fonksiyonu, aynı zamanda sigmoidal eğri veya lojistik fonksiyon olarak da Denklem 28'deki gibi adlandırılır (Min ve Lee, 2005: 605).

$$f(x) = 1 / (1 + e^{-x}) \quad (28)$$

Gauss Radyal Tabanlı Fonksiyonu: Literatürde en yaygın kullanılan çekirdek fonksiyonudur. DVM'nin en iyi ara değer bulma yeteneğine sahip olmasını Denklem 29 ile sağlar (Min ve Lee, 2005: 605).

$$K(x, y) = \exp\left(-\frac{\|x - y\|^2}{2\sigma^2}\right) = \exp(-\gamma\|x - y\|^2) \quad (29)$$

Bir çekirdek fonksiyonu kullanıldığında, genellikle eşleme özelliklerinin ve özellik alanının ne olduğu açık değildir. Potansiyel olarak çok yüksek boyutlu bir mekana haritalama yapmak ve eğitim setinde sınıflandırma hataları olmayan bir sınıflandırıcı üretmek her zaman mümkündür. Ancak, sınıflandırıcının performansı zayıf olabilir. Öte yandan, sonsuz boyutlu özellik alanı olan bir sınıflandırıcının iyi performans göstermesi mümkündür. Böylece, doğru alanın seçiminde özellik alanının boyutu önemli değildir (Lee vd., 2004: 225).

Çekirdek fonksiyonunun seçimi; veri miktarına ve sınıfına, gürültü oranına, hesaplama becerileri ve deneyimine dolayısıyla kullanıcıya ve problem tipine bağlıdır. Genel bir cevap olmadığı için, farklı fonksiyonlar denenmeli ve modele uygun olanı seçilmelidir (Schölkopf, 2001: 302).

1.2.8. Çekirdek Fonksiyonlarının Seçiminin Önemi ve Tasarımı

Çekirdek, DVM sınıflandırıcılarının yapımında önemli rol oynar. Steinwart (2001), çekirdeğin DVM'lerin genelleme yetenekleri ve ilgili tekniklerdeki merkezi rolü olduğunu söylemektedir. Genton (2001) özellikle istatistiksel bir perspektiften, alanın geometrisinin yönleri hakkında detaylar içeren çekirdek seçimi ve tasarımının önemine dikkat çekmiştir.

Genel anlamda, kısmen bir çekirdeğin kullanımı nedeniyle, DVM'ler genellikle boyut sorunundan kurtulurlar. Bununla birlikte, çekirdeğin kendisinin seçilmesi önemli bir konudur ve bir SVM çözümünü uygulamak için gerekli olan hesaplama muazzam olabilir (Suykens vd., 2003: 447).

Öte yandan, kavramsal olarak, DVM'ler zariftir ve Vapnik Chervonenkis-boyutu ile karakterize edilen olasılık özelliklerine sahip deterministik bir yöntem olarak kabul edilebilir (Suykens vd., 2003: 447).

Regresyon veya sınıflandırma bağlamında, çekirdeğin seçilmesi, tam bir model alanı veya tanımlanacak bir model sınıfının seçilmesidir. K 'nın sabitlenmesi, geleneksel istatistiksel anlamda belirli bir model seçim problemine benzetilebilir. Başka bir deyişle, farklı K 'lar, bir alandaki bireysel modellere değil, farklı model uzay koordinasyonlarına karşılık gelir (Clarke, Fokoue, ve Zhang, 2009: 290).

1.2.9. Çekirdek Hilesi

Çekirdek hilesi teriminin kökeni bilinmemekle birlikte, ilk olarak Aizerman, Braverman ve Rozonoer (1994: 922) tarafından yayınlanmıştır. Makine öğrenmesinde çekirdek hilesi, orijinal gözlemleri daha yüksek boyutlu bir alana eşlemek için doğrusal olmayan bir işlev kullanarak doğrusal bir sınıflandırıcı algoritmasının doğrusal olmayan bir işleve dönüştürülmesi için kullanılan bir yöntemdir. Böylece orijinal uzayda doğrusal olmayan sınıflandırmaya eşdeğer yeni bir lineer sınıflandırma yapılıır. Çekirdek hilesi; sürekli, simetrik, pozitif yarı-kesin çekirdek fonksiyonunun yüksek boyutlu bir alanda bir nokta olarak ifade edilebileceğini belirtir (Schölkopf, 2001: 301).

Daha spesifik olarak, eğer çekirdeğin argümanları ölçülebilir bir alan X ise ve eğer çekirdek pozitif yarı-kesin ise Denklem 30 ile gösterilir (Schölkopf, 2001: 302).

$$\sum_{i,j} K(x_i, x_j) c_i c_j \geq 0 \quad (30)$$

X 'in herhangi bir sonlu alt kümesi için $\{x_1, x_2, \dots, x_n\}$ ve nesnelerin $\{c_1, c_2, \dots, c_n\}$ alt kümeleri için, o zaman aralığı muhtemelen yüksek boyutta bir çıktı alanında olan bir fonksiyon ise Denklem 31 ile gösterilir (Schölkopf, 2001: 302).

$$K(x, y) = \varphi(x) \cdot \varphi(y) \quad (31)$$

Çekirdek hilesi, yalnızca iki vektör arasındaki nokta ürününe bağlı olan herhangi bir algoritmayı dönüştürür. Bir nokta ürünü kullanıldığında, çekirdek fonksiyonu ile değiştirilir. Böylece, bir doğrusal algoritma doğrusal olmayan bir algoritmaya kolayca dönüştürülebilir. Bu doğrusal olmayan algoritma, φ 'nin aralık alanında çalışan doğrusal algoritmaya eşdeğerdir. Ancak, çekirdekler kullanıldığından, φ işlevi hiçbir zaman açık bir şekilde hesaplanmaz. Çünkü yüksek boyutlu boşluk sonsuz boyutlu olabilir (Schölkopf, 2001: 302).

Yöntem makine öğrenimi ve istatistikte aşağıda belirtilen çeşitli algoritma türlerine uygulanmıştır:

- Algılayıcılar
- DVM
- Temel bileşenler analizi
- Fisher'in doğrusal diskriminant analizi
- Kümeleme

1.2.10. Mercer teoremi

$K(x,y)$ fonksiyonu, Mercer Teoremini sağlarsa çekirdek fonksiyonu olabilmektedir.

Teorem (Mercer koşulları): $K(x,y)$, çift değişkenli sürekli simetrik gerçek değerli çekirdek fonksiyonunu alalım (Sun, 2005: 338):

$$K(x, y) = \sum_{i=1}^{\infty} \lambda_i \varphi_i(x) \varphi_i(y) \quad (32)$$

Doğrusal kombinasyonu olarak yazılabilir. Burada $\lambda_i > 0$ ve $\varphi_i(\cdot)$ sırasıyla özdeğerler ve $K(x,y)$ 'nin öz fonksiyonlarıdır.

$$K(x,y)=\varphi(x)\varphi(y) \text{ eşitliğinin yazılabilmesi için,} \quad (33)$$

$$\int g(x)^2 dx < \infty \Rightarrow \int K(x,y)g(x)g(y)dxdy \geq 0 \quad (34)$$

Koşulunun sağlanması zorundadır.

Teorem: $K(x,y)$, çift değişkenli sürekli simetrik gerçekteğerli çekirdek fonksiyonunu alalım. $\varphi: X \rightarrow F$ öyle ki $\varphi(x)$ fonksiyonunun $K(x,y)$ 'nin bir öz fonksiyonu olabilmesi için (Sun, 2005: 342):

$$\int K(x,y)\varphi_i(y)dy = \lambda_i\varphi_i(x) \quad (35)$$

Mercer koşulunun yerine getirilmesi gerekir.

Belirli bir iki değişkenli fonksiyon K için, yukarıdaki koşulların doğrulanması kolay olmayabilir. Pratikte, geçerli çekirdek fonksiyonları için çoğu gerçek dünyadaki veriler üzerinde iyi bir performans sunar (Clarke, Fokoue ve Zhang, 2009: 285-286).

1.2.11. Sınıflandırma için DVM

DVM'nin amacı, sadece öznitelikleri verilen test kümesindeki veri örneğinin hedef değerini tahmin eden bir model üretmektir. DVM'deki sınıflandırma, danışmanlı öğrenimin bir örneğidir. Bilinen etiketler, sistemin doğru bir şekilde performans gösterip göstermediğini gösterir. Bu bilgi, sistemin doğruluğunu onaylayan veya sistemin doğru bir şekilde hareket etmesini öğrenmeye yardımcı olmak için kullanılması istenen bir çıktıyı gösterir. DVM sınıflandırmasındaki bir adım, bilinen sınıflara yakından bağlı olan tanımlamayı içerir. Buna özellik seçimi veya özellik çıkarımı denir. Özellik seçimi ve DVM sınıflandırması, bilinmeyen örneklerin tahmini gerekli olmadığında bile bir kullanıma sahiptir. Sınıfları ayırt eden süreçlerde yer alan kilit kümeleri tanımlamak için kullanılabilirler (Cristianini ve Shawe-Taylor, 2000: 93).

1.2.12. DVM Uygulamaları

Varsayımsal seçenekler olan bir Gauss veya polinom çekirdeği gibi standart seçimler vardır, ancak eğer bunlar etkisiz olursa ya da girdiler ayrı yapılırsa, daha ayrıntılı çekirdek fonksiyonları gerekir. Özellik boşluğunu örtük olarak tanımlayarak,

çekirdek, verileri görüntülemek için makinenin kullandığı tanımlama dilini sağlar. Çekirdek ve optimizasyon kriteri seçildikten sonra, sistemin ana bileşenleri yer almaktadır (Cristianini ve Shawe-Taylor, 2000: 93). DVM'nin test edildiği ilk gerçek dünya görevi, elle yazılmış karakter tanımadır. Ayrıca, çok sınıflı DVM'ler bu veriler üzerinde test edilmiştir. Görüntü tanıma, nitelik indirgeme, bilişim teknolojileri, endeks hareket yönü tahmini, volatilitate tahmini, banka başarısızlığı tahmini, doküman sınıflandırma, imalat sektörü ve tıbbi test sonucu doğrulama alanlarında uygulamalar yapılmıştır.

1.3. KARAR AĞAÇLARI

Karar Ağacı (KA), ayırma ve budama stratejisini uygulayan hiyerarşik bir veri yapısıdır. Hem sınıflandırma hem de regresyon için kullanılacak etkin bir parametrik olmayan yöntemdir.

1979 yılında Quinlan tarafından KA algoritması olarak bilinen ID3 algoritması geliştirildi. Daha sonra Quinlan ID3'ün devamı olan ve birçok başka algoritma ile performans karşılaştırmalarında kullanılan C4.5'i önermiştir. 1984 yılında ise Friedman, Olshen ve Stone tarafından "Classification and Regression Trees (CART)" isimli yeni bir karar ağacı algoritmasını tanımlayan kitap yayınlanmıştır. KA oluşumu için benzer yaklaşımlar izleyen ID3 ve CART algoritmaları aynı dönemde birbirlerinden bağımsız olarak yazılımları yapılmıştır. Bu algoritmalar karar ağaçları çalışmalarında yeni bir ivme kazandırmıştır. ID3, C4.5 ve CART, KA'nın yukarıdan aşağıya tekrar eden ayırma ve budama şeklinde oluşturulan bir yaklaşımı benimsemektedir (Han, Kamber ve Pei, 2011: 332).

İstatistik tekniklerine dayanan diğer makine öğrenmesi algoritmalarından farklı olarak, KA varsayımları olmayan bir modeldir. Parametrik tahminlerde, tüm giriş alanı üzerinde bir model tanımlar ve tüm eğitim verilerinden parametrelerinin öğrenilmesini sağlar. Daha sonra aynı model ve herhangi bir test girişi için aynı parametre seti kullanılır. Parametrik olmayan tahminlerde ise giriş uzayı, Öklid uzaklığı gibi bir mesafe ölçüsü ile tanımlanan yerel bölgelere ayrılır ve her bir girdi için, o bölgedeki eğitim verisinden hesaplanan ilgili yerel model kullanılır.

KA, danışmanlı öğrenme için hiyerarşik bir model olup, daha az adımda tekrarlayan bölünmeler dizisi şeklinde tanımlanır. KA'nın yorumlama ve anlama

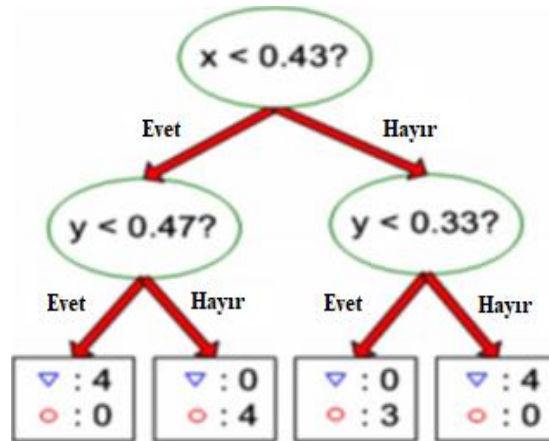
kolaylığı, tarımdan, çeşitli çevresel değişkenler ve yağmur olasılığını tahmin edebildiğimiz pek çok uygulamada kullanım alanı bulmuştur (Ramasubramanian ve Singh, 2017: 297). Yıllar boyunca, ağaç temelli yaklaşımlar, uygulanabilirliğin yanı sıra gelişmişlik konusunda daha geniş bir alana dönüşmüştür. Hem sınıflandırma hem de regresyon problemleri için uygun bir çözüm haline getiren, hem ayrı hem de sürekli cevap değişkenleri durumunda kullanılabilirler. Bu nedenlerle KA en yaygın kullanılan sınıflandırma tekniklerinden biridir (Harrington, 2012: 38).

1.3.1. Karar Ağacının Yapısı

KA bir dizi düğüm ve dal oluşturmak için farklı durumlara bağlı bir ağaç yapısına sahiptir. Ağaç yapısı düğüm ve dallardan oluşur. Kullanılan her özellik bir düğüm, düğümler arasındaki olaylar ise dal ile temsil edilir (Öztürk, 2015: 215). Her düğüm bir çıktı/hedef sınıfı sunar ve her dal sınıflandırma için bir süreç/karar sunar. Uç düğüm, bir tahmin sonucunu verir (Tsai ve Wang, 2009: 60).

Her düğüm, dalları etiketleyen ayrık sonuçlarla $f(x)$ test fonksiyonunu uygular. Bir girdi verildiğinde, her düğümde, bir test uygulanır ve sonuca bağlı olarak dallardan biri alınır. Bu işlem kökte başlar ve bir yaprak düğümü kalana kadar ardı ardına tekrarlanır, bu noktada yaprakta yazılan değer çıkışı oluşturur (Alpaydın, 2014: 213). Şekil 17’de bir KA gösterilmiştir.

Şekil 17. Karar Ağacı Yapısı (Ramasubramanian ve Singh, 2017: 298).



1.3.2. Karar Ağacı İle Sınıflandırma

Karar ağaçları, makine öğrenimi algoritmalarının bir alt kümesi olan sınıflandırma ve tahmin için kullanılan en güçlü, iyi bilinen ve yaygın araçlardan

biridir. KA, geniş bir veri kümesini özelliklerini koruyarak daha küçük veri kümelerine bölmek için kullanılacak bir makine öğrenimi algoritmasıdır (Rostami vd., 2015: 164).

Sınıflandırma ağacı kategorik veya ayrık cevap değişkenleri için daha uygundur. Sınıflandırma ağaçları ve regresyon ağaçları arasındaki temel farklar şunlardır (Ramasubramanian ve Singh, 2017: 300):

- Sınıflandırma ağaçlarındaki bölünmeleri yapmak için sınıflandırma hata oranı kullanılır.
- Belirli bir bölgedeki tepki değişkeninin ortalamasını tahmin için almak yerine, burada en yaygın olarak ortaya çıkan eğitim gözlemi sınıfı bir tahmin yöntemi olarak kullanılır.

Yine, gözlemleri farklı sınıflara ayırmanın en iyi özelliğini veya niteliğini seçmek için Gini indeksi veya Entropi bir ölçü olarak kullanılabilir (Flach, 2012: 134).

KA mimarisi oluşturulurken aşağıda verilen birçok teknik kullanılmaktadır.

1.3.3. Karar Ağacı Oluşturma

Algoritma tarafından karar ağaçları oluşturulurken, eğitim veri setindeki sınıf etiketlerini yukarıdan başlayarak aşağıya doğru dağıtan bir strateji izlenir. Eğitim veri seti karar ağacı inşa edilirken, daha küçük alt kümelere tekrar tekrar bölümlendirilir (Han, Kamber ve Pei, 2011: 332). Ağaç iki aşamada inşa edilir. Bu iki aşama ağaç yapımı ve budamadır (Lavanya ve Rani, 2011: 2). Karar ağaçları, bunu yapmak için bir dizi soru ve çok basit karar kuralları kullanır (Rostami vd., 2015: 164).

KA iki tip düğümden oluşur (Ramasubramanian ve Singh, 2017: 298):

- Yanıt değişkeni tarafından tanımlanan sınıf/bölgeyi gösteren bir yaprak düğümü,
- Testin olası her bir sonucu için tek bir öznitelik ve bir alt ağacı olan tek bir öznitelik üzerinde bazı testleri belirten bir karar düğümü.

KA, üst karar düğümünden başlayarak ve bir özdeş ayırma ve budama yaklaşımı kullanılarak bir yaprak düğümü kalana kadar diğer karar düğümlerinden

aşağı doğru hareket ederek bir gözlemi sınıflandırmak için kullanılabilir (Ramasubramanian ve Singh, 2017: 298).

1.3.4. Ayırma – Budama

Maksimum ağaçlar çok yüksek karmaşıklığa sahip olabilir ve yüzlerce seviyeden oluşabilir. Bu nedenle, yeni verilerin sınıflandırılması için kullanılmadan önce optimize edilmeleri gerekmektedir. Ağaç optimizasyonu, önemsiz düğümleri ayırma ve hatta alt dalları budayarak doğru ağacın boyutunu seçmeyi gerektirir (Timofeev, 2004: 16).

Ayırma: Ağaç inşa edilirken hangi özelliklerin kullanılacağıın saptanması işlemidir. Özellik seçimi ve sıralaması uzman görüşü alınarak yapılan ayırma işlemi algoritmanın performansını artırır.

Budama: Veriyi ağaç algoritmasına yerleştirme problemini ele alır. Budama aşaması, gürültüyü ve aykırı değerleri çıkararak ağacı genelleştirir. Sınıflandırma doğruluğu budama aşamasında artar. Budama aşaması sadece tamamen inşa edilmiş ağaçlara uygulanır. Eğitim verileri üzerinde birden fazla geçiş gerektirir. KA'yı budamak için gereken süre KA'yı inşa etmekten çok daha azdır (Lavanya ve Rani, 2011: 2).

1.3.5. Karar Ağacı Algoritmaları

1.3.5.1. ID3

Yinelemeli Dikotomiser-3 (ID3), karar ağacı oluşturmak için kullanılan bir algoritmadır. Bununla birlikte, her zaman en küçük ağacı üretmez ve bu nedenle bir sezgiseldir (Vasudevan, 2014: 1152).

ID3, bölme özneliğini seçmek için bilgi kazancı ölçüsünü kullanır. Bir ağaç modeli oluştururken sadece kategorik nitelikler kabul eder. Gürültü olduğunda doğru sonuç vermez. Gürültülü durumları algoritmadan çıkarmak için ön işleme tekniğini kullanılmalıdır. Sürekli öznelikler, öznelik değerleri üzerinde bir eşik olarak en iyi ayırma noktası t değerini bulmak için ID3 algoritması doğrudan veya ayrıştırılarak kullanılabilir (Lavanya ve Rani, 2011: 2).

Bilgiyi nitelemek ve veri setindeki rassallığı ölçmek için entropi kavramı kullanılır. Bilgi teorisinde Shannon entropisi ya da bilgi entropisi, rastgele bir değişkenle ilişkili belirsizliğin bir ölçütüdür (Ankerst vd., 1999: 393).

ID3, entropiyi düğümleri ayırma işlemi için kullanır. Burada t düğümünün i sınıfı olasılığı p_i ile ifade edilir. Olası değer aralığını alabilen ayrı bir rasgele değişken S 'nin bilgi entropisi şöyle Denklem 36 ve 37'deki gibi tanımlanır (Shannon, 1948: 386):

$$Entropi = H(S) = -\sum_{i=1}^n p_i \log_2(p_i) \quad (36)$$

$$H(X, T) = \sum_{i=1}^n \frac{|T_i|}{|T|} H(T_i) \quad (37)$$

Burada T_i hedef niteliği olmakla beraber T_i 'nin sınıfının belirlenmesinde ağırlıklı ortalama $H(X, T)$ kullanılır. En iyi kazancı veren T_i seçilirken maksimum $Kazanç(X, T)$ amaçlanır ve Denklem 38 ile bulunur.

$$Kazanç(X, T) = H(T) - H(X, T) \quad (38)$$

1.3.5.2. C4.5

Bu algoritma, Quinlan tarafından geliştirilen ID3'ün bir uzantısıdır. C4.5 (Karar Ağacı Eğitim Algoritması) karar ağacını oluşturmak için kategorik ve sürekli öznitelikleri ele alır. Sürekli özniteliklerin üstesinden gelmek için C4.5 öznitelik değerlerini seçilen eşige göre iki bölüme ayırır, böylece eşğin üzerindeki tüm değerler bir grup ve diğer grup olarak kalır. Ayrıca eksik özellik değerlerini de işler. C4.5 bir karar ağacı oluşturmak için bir özellik seçim ölçüsü olarak Kazanç Oranını kullanır. Bir özelliğin birçok sonuç değeri olduğunda bilgi kazancıyla ilgili önyargıyı ortadan kaldırır (Quinlan, 1992: 28).

C4.5 algoritması tarafından oluşturulan karar ağaçları, sınıflandırma için kullanılabilir ve bu nedenle, C4.5 ayrıca bir istatistiksel sınıflandırıcı olarak adlandırılır (Adhatrao, 2013: 42). C4.5 algoritması, ID3 algoritmasını geliştirmek için bir dizi değişiklik yapmıştır (Dunham, 2003: 126).

- Eğitim verilerinin özniteliklerin eksik değerleri ile ele alınmıştır.
- Farklı maliyet özelliklerini ele almıştır.
- Karar ağacını oluşturduktan sonra budama yapılmıştır.
- Ayrık ve sürekli değerler ile öznitelikleri işleme gerçekleştirilmiştir.

Budama işleminde ilk olarak, her bir özelliğin kazanç oranı hesaplanır. Kök ile düğüm için kazanma oranı maksimum olan özellik olur. C4.5 sınıflandırma doğruluğunu artırmak için karar ağacındaki gereksiz dalları kaldırmak için kötümser budama kullanır (Lavanya ve Rani, 2011: 2).

1.3.5.3. CART (C&RT)

1984 yılında CART (Sınıflandırma ve Regresyon Ağaçları) algoritması Breiman vd. tarafından önerilmiştir. Sınıflandırma ve regresyon ağaçları, veriden tahmin modelleri oluşturmak için kullanılan makine öğrenmesi yöntemidir. Modeller, veri alanının yinelenen bölümlenmesi ve her bölüm içinde basit bir tahmin modelinin yerleştirilmesiyle elde edilir (Loh, 2011: 14).

CART algoritmasında sınıflandırma ağaçları, bağımlı değişkenin kategorik olduğu modelleri içerirken regresyon ağaçları sürekli olanları içerir (Wilkinson, 2004: 35). CART parametrik olmayan bir algoritmadır. Bu nedenle, bu yöntem herhangi bir fonksiyonel formun spesifikasyonunu gerektirmez. CART önceden seçilecek değişkenler gerektirmez (Timofeev, 2004: 20). Bölünme işlemi CART algoritmasında bir kriter uygulanarak düğümde yapılır. Bu nedenle tüm özellikler dikkate alınarak eşleşmeler yapılır ve iki bölümlenme gerçekleştirilir. Seçme işlemi için ise Gini Endeksi ve Twoing Algoritması yapılandırılır (Timofeev, 2004: 10).

1.3.6. Karar Ağacı Uygulamaları

KA yöntemi sınıflandırma, tahmin, yorumlama ve veri işleme gibi çeşitli potansiyel uygulamalar için güçlü bir makine öğrenmesi yöntemidir. Uydu görüntülerinin sınıflandırılması, medikal veri işleme, bilişim altyapı tasarımı, imalat sektöründe veri sınıflandırma gibi alanlarda KA yönteminin pratik uygulamaları yapılmıştır.

1.4. NAİVE BAYES

Bayes sınıflandırıcılar, istatistiksel sınıflandırıcılardır. Bilinen bir örneğin bir gruba atanma ihtimali gibi sınıf üyelik ihtimallerini öngörebilirler (Leung, 2007: 3). Naive Bayes (NB) algoritması bize, önceki olasılık ve koşullu olasılıkları tek bir formülde birleştirerek, olası sınıflandırmaların her birinin olasılığını hesaplamak için kullanabileceğimiz bir yöntem sunmaktadır (Bramer, 2016: 26).

Bayes sınıflayıcısı, Bayes teoremini temel alır. NB yöntemi, bir öznitelik değerinin belirli bir sınıflandırma olasılığına etkisinin, diğer özniteliklerin değerlerinden bağımsız olduğunu varsayar (Han, Kamber ve Pei, 2011: 350; Bramer, 2016: 26). Bu varsayım, sınıfın koşullu bağımsızlığıdır. Söz konusu hesaplamayı basitleştirmek için yapılır ve bu anlamda “naive” olarak kabul edilir. NB yöntemi pratik kullanımda genellikle iyi sonuçlar vermektedir (Han, Kamber ve Pei, 2011: 350).

1.4.1. Bayes Teoremi

Bayes teoremi adını, 18. yüzyılda olasılık ve karar teorisinde çalışma yapan bir İngiliz matematikçi olan Thomas Bayes'den almıştır. $X = \{x_1, x_2, \dots, x_n\}$ bileşenleri, bir dizi n özniteliği üzerinde değerleri temsil eden bir örneklem olsun. Bayes terimlerinde X , “çıktı” olarak adlandırılır. $P(H/X)$, H 'nin X 'in belirli bir sınıfa ait olma olasılığı hipotezidir. Sınıflandırma problemleri için amaç, $P(H/X)$, H hipotezinin “çıktı” (yani gözlemlenen veri örneği X) olasılığının belirlenmesidir. Başka bir deyişle, X 'in öznitelik tanımı bilindiği için X sınıfının C sınıfına ait olma olasılığı aranır. $P(H/X)$, X üzerinde H 'nin bir koşullu olasılığıdır (Han, Kamber ve Pei, 2011: 351).

Bayes teoremine göre, $P(H/X)$ hesaplamak istenen koşullu olasılık $P(H)$, $P(X/H)$ ve $P(X)$ olasılıkları cinsinden Denklem 39 ile ifade edilebilir.

$$P(H / X) = P(X / H)P(H) / P(X) \quad (39)$$

1.4.2. Naive Bayes Sınıflandırma

NB sınıflandırıcılar, Bayes ağının özel bir formudur ve bilgilendirici sınıflandırma kategorisine girer (Langley ve John, 1995: 338; Langley ve Sage, 1994: 399). NB sınıflandırıcısının arkasındaki ana varsayımı, özniteliklerin geri kalanından bağımsız olmasıdır (Friedman, Geiger ve Goldszmidt, 1997: 132). NB algoritmasının popüler olması hesaplama hızının yüksek olması, basit bir yapıya sahip olması ve eksik verilerle çalışabilir olmasından kaynaklanmaktadır (Rubinstein ve Hastie, 1997: 52). NB yöntemi, bir dizi görünmeyen örneği sınıflandırmak için kullanırken, önceki tüm olasılıkları ve bir özelliği içeren tüm koşullu olasılıkları hesaplamaktadır (Bramer, 2016: 28).

1.4.3. Naive Bayes Sınıflandırma Adımları

NB sınıflandırıcı şöyle çalışır (Han, Kamber ve Pei, 2011: 351):

1. Adım: D , bir eğitim seti ve ilgili sınıf etiketleri olsun. Her bir sınıf etiketi n -boyutlu öznitelik vektörü $X=\{x_1, x_2, \dots, x_n\}$ ile temsil edilir ve sınıf etiketleri üzerinde yapılan n öznitelik ölçümleri sırasıyla A_1, A_2, \dots, A_n ile gösterilir.

2. Adım: m sınıf sayısı iken, C_1, C_2, \dots, C_m olsun. X , bir gözlem verildiğinde sınıflandırıcı X 'in X üzerinde koşullandırılmış en yüksek koşullu olasılığa sahip olan sınıfa ait olduğunu tahmin edecektir. Yani, Bayesian sınıflandırıcı, gözlem X 'in C 'nin sınıfına ait olduğu tahmin ediliyor ise

$$P(C_i|X) > P(C_j|X) \quad \text{için } 1 \leq j \leq m, \quad j \neq i \quad (40)$$

Böylece maksimize eden sınıfı buluruz. $P(C_i|X)$. $P(C_i|X)$ 'un maksimize edildiği C_i sınıfı, maksimum koşullu olasılığı olarak adlandırılır. Bayes teoremi ile

$$P(C_i|X) = P(X|C_i)P(C_i)P(X) \quad (41)$$

3. Adım: $P(X)$ bütün sınıflar için aynı olduğundan, sadece $P(X|C_i)P(C_i)$ maksimum düzeye çıkarılmalıdır. Eğer sınıf koşullu olasılıkları $P(C_i)$ bilinmiyorsa, yaygın olarak sınıfların eşit derecede muhtemel olduğu varsayılır, yani $P(C_1)=P(C_2)=\dots=P(C_k)$ ve bu yüzden $P(X|C_i)$ 'yi maksimize edilir. Aksi takdirde $P(X|C_i)P(C_i)$ 'yi maksimize edilir. Sınıfın koşullu olasılıklarının $P(C_i)=\text{frek}(C_i,T)/|T|$ ile tahmin edilebilir.

4. Adım: Birçok öznitelikli veri kümeleri verildiğinde, $P(X|C_i)$ hesaplaması için hesaplama açısından çok fazla sayıda olur. $P(X|C_i)P(C_i)$ 'nin değerlendirilmesinde hesaplamayı azaltmak için, sınıf koşullu bağımsızlığın naive varsayımı yapılır. Bu, özniteliklerin değerlerinin, örneğin sınıfın etiketine göre, koşullu olarak birbirinden bağımsız olduğunu varsayar. Matematiksel olarak bunun anlamı

$$P(X|C_i) \approx Y_{nk} = 1P(x_k|C_i) \quad (42)$$

şeklindedir. $P(X_1|C_i), P(X_2|C_i), \dots, P(X_n|C_i)$ olasılıkları eğitim veri setinden kolaylıkla öngörülebilir. Burada x_k 'nin, örnek X için olan A_k öznitelik değerine atıfta bulunur.

(a) Eğer A_k kategorik ise, o zaman $P(x_k/C_i)$, öznelik A_k için x_k değerine sahip olan T cinsinden C_i sınıfının örnek sayısıdır. T cinsinden C_i sınıfının örnek sayısı $frek(C_i, T)$ tarafından bölünür.

(b) Eğer A_k sürekli değerlendirilirse, tipik olarak, değerlerin ortalama μ ve standart sapma σ ile tanımlanan bir Gauss dağılımına sahip olduğunu varsayılır.

$$g(x, \mu, \sigma) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{(x - \mu)^2}{2\sigma^2}\right) \quad (43)$$

Böylece,

$$p(x_k | C_i) = g(x_k, \mu_{C_i}, \sigma_{C_i}) \quad (44)$$

olur. Burada, C_i sınıfı örneklerini eğitmek için A_k 'in öznelik değerlerinin ortalama ve standart sapması olan μ_{C_i} ve σ_{C_i} 'nin hesaplanması gerekir.

5. Adım: X sınıf etiketini tahmin etmek için her bir C_i sınıfı için $P(X/C_i)P(C_i)$ değerlendirilir. Sınıflandırıcı, X 'in sınıf etiketinin, eğer sadece $P(X/C_i)P(C_i)$ 'yi maksimize eden sınıfsa, C_i olduğunu tahmin eder.

1.4.4. Araştırma ve Uygulamalarda Naive Bayes

NB hiyerarşik modellerinin diğer yöntemlere göre iki ana üstünlüğü vardır: i) tutarlılığı olasılık teorisi çerçevesinde tutarlı bir şekilde yönetirler; ii) modelin dayandığı varsayımları açıkça ortaya koyarlar. NB yönteminin uygulama bulduğu alanlar metin sınıflandırma, zihinsel durumların sınıflandırılması, kalp krizi tahmini, internet trafiği sınıflandırma, video gözetim uygulaması, kalp hastalığı için tahmin sistemi olarak sayılabilir.

1.5. K-EN YAKIN KOMŞULUK

İlk olarak Fix ve Hodges (1951) tarafından tanımlanan k-En Yakın Komşuluk (k-EYK), birçok uygulamada başarılı olduğu kanıtlanmış model tanımaya dayalı bir danışmanlı makine öğrenme tekniğidir (Lu ve Zhu, 2014: 276). K-EYK parametrik olmayan ayırt etme tutarlılığı özellikleri gösteren bir sınıflandırma tekniği olup örüntü tanıma ve veri madenciliğinde çok sık kullanılmaktadır (Fukunaga ve Hummels, 1987: 634). Hedef değişken kategorik ise sınıflandırma tekniklerinin en

basit parametrik olmayan karar prosedürü, en yakın komşusu kategorisinde x 'i sınıflandıran en yakın komşu kuralıdır (Cover ve Hart, 1967: 21).

K-EYK algoritması, çeşitli uygulamalarda yaygın olarak kullanılabilen en iyi ve en yaygın sınıflandırma algoritmalarından biridir. En yakın komşunun aranması algoritması bilgisayar bilimlerinde birçok uygulamaya sahiptir (Chahardoli, Yaghubi ve Esmaeilpour, 2015: 140).

Bilinen (veya kısmen bilinen) sınıflandırmaya ve uygun bir mesafe ölçüsüne sahip özellik vektörlerini içeren sonlu büyüklükteki bir eğitim seti verildiğinde, yeni bir örneğin sınıfına ait belirsizliği karakterize etmek için k-EYK kullanılır (Zouhal ve Denoeux, 1998: 263). Girdi verileri en yakın k tane komşuluğuna göre sınıflandırılır (Kermani, 2015: 348). Bir başka deyişle zaman serilerinde k-EYK ile tahmin etmenin ardındaki fikir, mevcut veriye en yakın olan geçmiş verileri tanımlamak ve mevcut verinin bir sonraki değerini tahmin etmek için gelecekteki değerlerini birleştirmektir (Arroyo ve Mate, 2009: 197). Tahmin setindeki bilinmeyen bir örnek, eğitim setindeki k-EYK'larının çoğunluğuna göre sınıflandırılır (Lu ve Zhu, 2014: 276).

Gözlemlerin ' n ' öznitelikleri varsa, bunlar n boyutlu bir uzayda bir vektör olarak düşünülür ve bu uzayda gözlemin ' k ' tane yeni komşuları aranır ve bu komşuların sınıf etiketlerine dayanarak, yeni gözlemin sınıf etiketi tahmin edilir (Arlot ve Celisse, 2010: 50).


Veri sayısı büyükse, en yakın komşu yerine en yakın k komşularının çoğunluk oyu kullanması mantıklıdır. Sınıflandırılmamış x noktası için Bayes olmayan bir kararın olasılığını en aza indirmek için k değeri büyük olmalıdır. Ancak x 'in gerçek sınıfının sonraki olasılıklarının doğru bir tahminini vermek için k noktalarının x 'e yeterince yakın olması durumunda k 'nın değeri küçük olmalıdır (Cover ve Hart, 1967: 22).

Bu algoritmanın dezavantajlarından biri, tüm özelliklerin komşularla yeni maksimum uzaklığının hesaplanmasıdır. Bu sorun, sınıflandırma sürecini yanıtla ile sonuçlanmakta ve sınıflandırma algoritmasının doğruluğunu azaltmaktadır. Birliktelik kuralları kullanılarak, k-EYK algoritmasının doğruluğunu artıracak çeşitli özelliklere ağırlık verilmiştir (Chahardoli, Yaghubi ve Esmaeilpour, 2015: 140).

1.5.1. K-Katlı Çapraz Doğrulama

Uygun bir k değeri, k -EYK modelinin doğruluğu üzerinde büyük bir etkiye sahiptir ve k -EYK model kalibrasyonunda en uygun parametre k değeri çapraz doğrulama ile belirlenir (Lu ve Zhu, 2014: 276). Sistemlerin doğruluklarının ölçülmesinde k -katlı çapraz doğrulama yöntemi kullanılır. Bu yöntemde göre toplam veri kümesi olan A , k alt kümeye bölünür. Her bir k alt kümesi k defa yenilenerek bir küme test kümesi diğer kalanlar ise eğitim kümesi olarak seçilir. Yapılan her yenilemede bulunan hata oranlarının ortalaması alınır ve böylece tahmin yönteminin hata oranı bulunur. Parametre k 'nın (3, 5, 7, vb.) değeri, en iyi modeli elde etmek için sırayla optimize edilir (Lu ve Zhu, 2014: 276). Literatürde k -katlı çapraz doğrulama modelinde optimal k değerinin 10 olduğunu gösteren bazı (Kohavi, 1995: 1139; Blockeel ve Struyf, 2002: Olson ve Delen, 2008:142; Erpolat ve Öz, 2010: 78; Aspinall vd., 2015: 273) çalışmalar vardır. On-katlı çapraz doğrulama yönteminde toplam veri kümesi 10 eşit kümeye bölünür. 10 defa yenilenen işlemde her seferinde bir küme test kümesi diğer 9 küme ise eğitim kümesi olarak seçilir (Aydoğan, Gencer ve Akbulut, 2008: 52). On-katlı çapraz doğrulama yöntemi Şekil 18'de gösterilmiştir.

Şekil 18. On-katlı Çapraz Doğrulama Yöntemi (Olson ve Delen, 2008:142).



1.5.2. Uzaklık Ölçüsü ve En Yakın Komşu Sınıflaması

En yakın komşu sınıflandırıcı, desenler arasındaki bir metrik veya “uzaklık” fonksiyonuna dayanır. Öte yandan, Öklid metriğini d boyutlarında kabul edilse de, metrik kavramı çok daha geneldir ve sınıflandırmadaki anahtar problemleri ele almak için alternatif mesafe ölçümlerini kullanılır (Duda, 2001: 215). k -EYK yönteminde parametre seçimlerinden biri de uzaklık ölçüsü seçimidir. Literatürde uzaklık ölçüsü olarak kullanılan Tanjant Uzaklığı, Mahalanobis Uzaklığı, Minkowski Uzaklığı,

Tanimoto Uzaklığı, Manhattan Uzaklığı ve Öklid Uzaklığı ölçüm teknikleri vardır. Çalışmamızda en yaygın olarak kullanılan uzaklık ölçüsü olan Öklid Uzaklığı kullanılmıştır (Malhotra, Sharma ve Nair, 1999: 7; Li ve Lu, 2009: 644; Ioannidis, Pasiouras ve Zopounidis, 2010: 350; Ying ve Li, 2012: 3; Xing vd., 2003: 522). Bu durumda iki girdi vektörü için Öklid uzaklığı Denklem 45 kullanılarak hesaplanır:


$x_1=(x_{11},x_{12},\dots,x_{1n})$ ve $x_2=(x_{21},x_{22},\dots,x_{2n})$ iken

$$D(x_1, x_2) = \sqrt{\sum_{i=1}^n (x_{1i} - x_{2i})^2} \quad (45)$$

şeklindedir. En yakın komşu algoritmasının modelini kullanabilmek için, veri toplama genellikle test ve eğitim kümesine ayrılır. Tahmin edilen konular ve fonksiyonların yakınlaştırılmasında tüm verilerin %20'si test seti olarak %80'i de eğitim için kullanılmaktadır (Chahardoli, Yaghubi ve Esmailpour, 2015: 140-141).

En yakın tek komşudan daha fazlasını dahil ederek, daha yumuşak bir karar sınırıyla daha sağlam bir sınıflandırıcı elde edilir. Uzaklık ölçüsü olarak Öklid uzaklığı kullanılırsa, k -EYK algoritması x test noktası üzerinde ortalanmış bir hiperküreyi ele alır. Hiperkürenin yarıçapı, tam olarak K eğitim girişleri içerene kadar artırılır. Sınıf etiketi $c(x)$ daha sonra hiperküre içindeki en çok sayıda sınıf tarafından verilir (Şekil 19).

Şekil 19. K-EYK (Barber, 2012: 324)



1.5.3. K-EYK Algoritması Uygulama Adımları

Problemin çözümünde k -EYK algoritması çerçevesinde yapılacak işlemler sırasıyla şöyledir (Duda, 2001: 205; Harrington, 2012: 25; Bramer, 2016: 30) :

1. Adım: K parametresi tespit edilir,
2. Adım: Verilen bir nokta ile diğer tüm noktalar arasındaki uzaklıklar tek tek hesaplanır,
3. Adım: Hesaplanan uzaklıklar arasından en küçük olan k tanesi seçilir,
4. Adım: Tahminlenen gözlem değeri, k adet gözlem değerinin aritmetik ortalaması alınarak bulunur.

1.5.4. K seçimi

K-EYK sınıflandırıcısındaki, k sayısı gözlemlenen verinin k tane komşularının (genellikle kullanıcı tarafından belirlenen bir parametre) sayısı olduğudur (Harrington, 2012: 25). $K > 1$ seçiminde bir takım anlamlılık olsa da, $K = N$ (N eğitim noktası sayısıdır) olduğunda çok az anlam vardır. K çok büyük olursa tüm sınıflandırmalar aynı olur. Bunlar en iyi genelleme performansını veren K 'nın optimal bir değeri olduğunu gösterir (Barber, 2012: 324). Deneme yanılma yolu ile optimal değere ulaşılır.

1.5.5. K-EYK Uygulamaları

Veri madenciliği tekniği olarak KNN, regresyonun yanı sıra sınıflandırmada da çok çeşitli uygulamalara sahiptir. Bu yöntemin uygulamalarından bazıları şunlardır; metin sınıflandırma, günlük yağışları ve diğer hava değişkenlerini simüle etme, borsa tahmini, piyasa trendlerini ortaya çıkarma, yatırım stratejilerini planlama, hisse senetlerini satın alma ve satma için en uygun zamanı belirleme.

1.6. LOJİSTİK REGRESYON

Lojistik Regresyon (LogR), gözlemleri gruplamak ve çeşitli bağımsız değişkenlerin kategorik bağımlı değişkenlerle ilişkisini tanımlamak için kullanılacak bir istatistiksel yöntemdir (Pregibon, 1981: 705). LogR yönteminin, kolayca yorumlanabilir ve matematiksel olarak esnek olması araştırmacılar ve kullanıcıların ilgisini çekmiştir (Le Cessie ve Van Houwelingen, 1992: 191). Biyoistatistik, sosyal bilimler ve pazarlama araştırmalarında son 20 yılda çok fazla kullanıldığı görülmektedir.

LogR, bağımlı değişkeni öngörmek için bağımsız değişkenin kullanıldığı bir regresyon sınıfıdır (Lani, 1995: 1) veya diğer bir deyişle bir olayın gerçekleşmesi veya başarılı olması olasılığını bulmaktır (Gujarati vd., 2012: 542).

Önsel gruplar tanımlı iken sınıflama amaçlı çalışmalarda, diskriminant analizi ve LogR en çok kullanılan yöntemlerdir. Bağımsız değişkenlerin dağılımına ilişkin bir varsayımının olmaması nedeniyle LogR daha çok tercih edilmektedir (Sharma, 1996: 317).

LogR, varsayımları ve çıktı sonuçlarını yorumlamadaki gücü nedeniyle araştırmacılara önemli fayda ve kolaylıklar sağlamaktadır (Gujarati vd., 2012: 555; Özdemir, Tolun ve Demirci, 2011: 49):

- LogR fonksiyonu, hata fonksiyonunun birikimli olasılık dağılımı gösterdiğini varsayar.
- Bağımsız değişkenler arasında LogR analizinde çoklu bağlantı probleminin olmadığı varsayılır.
- LogR'da, bağımlı değişkenlerin sürekli olması ve bağımsız değişkenlerin normal dağılım göstermesi koşulu aranmaz.
- LogR'da varyans-kovaryans matrislerinin eşitliği şartı aranmaz.

1.6.1. Lojistik Regresyona Genel Yaklaşım

LogR metodu genel uygulama adımları aşağıda verilmiştir (Harrington, 2012: 84):

1. *Toplama*: Veri toplanır.
2. *Hazırlama*: Uzaklık hesaplaması için sayısal değerler kullanılır.
3. *Analiz*: Herhangi bir yöntem.
4. *Eğitim*: Verileri sınıflandırmak için en uygun katsayılar bulmaya çalışılır.
5. *Test*: Eğitim adımı tamamlandıktan sonra sınıflandırma hızlı ve kolaydır.
6. *Kullanım*: Uygulama girdi ve çıktı verileri sayısal değerler alır.

Daha sonra, uygulama bu girdi verilerindeki basit regresyon hesaplamasını uygular ve girdi verilerinin hangi sınıfa ait olması gerektiğini belirler.

1.6.2. Lojistik Regresyon Modeli

LogR'nin altında yatan merkezi matematiksel kavram, odds (olasılık) oranının doğal logaritmasıdır (Peng, Lee ve Ingersoll, 2002: 3). Maksimum olabilirlik tahminini elde etmek için, bağımlı değişken logit fonksiyonuna dönüştürülür. Sıralı LogR bağımlı ve bağımsız değişken arasında doğrusal bir ilişki olmadığını varsayar (Lani, 1995: 1). Bağımlı değişken, LogR analizinde ikili değişken olarak kullanılır (Akgül ve Çevik, 2005: 390). Basit LogR model formu Denklem 46 ve 47'deki gibidir (Peng, Lee ve Ingersoll, 2002: 4);

$$L = \ln \left[\frac{P_i}{1 - P_i} \right] = Z_i = b_0 + b_1 X_i + e_i \quad (46)$$

Burada olma ihtimali P_i ile, olmama ihtimali $1 - P_i$ ile gösterilir.

$$Z = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \beta_3 X_3 + \dots + \beta_n X_n \quad (47)$$

şeklinde yazılır. β 'lar regresyon katsayısını göstermektedir (Le Cessie ve Van Houwelingen, 1992: 194).

1.6.3. Birimlerin Sınıflandırılması

LogR algoritmasında, bağımlı değişkenler kategorik değişkenlerle açıklanırken sonuçların 0 veya 1 olma olasılıkları hesaplanır. Normalizasyon işlemi için bağımlı değişkenin logaritması alınır. Dolayısıyla olası sonuçlardan birinin gerçekleşme oranının öngörüsü yapılır. Bu tahmini yapan fonksiyon signum olarak adlandırılır. Signum fonksiyonu aşağıdaki Denklem 48 ile verilir (Harrington, 2012: 85):

$$\sigma(z) = \frac{1}{1 + e^{-z}} \quad (48)$$

1.6.4. Katsayıların Önemi Testi

Modeldeki değişkenlerin katsayı kestirimleri yapıldıktan sonra, bağımsız değişkenlerin sonuç değişkeniyle anlamlı bir ilişkisinin olup olmadığı belirlenir. Değişkenle tahmin edilen değerler modelin bir anlamda daha iyi veya daha doğru olduğu durumlarda, modelde olmayan değişkene göre, söz konusu değişkenin

“önemli” olduğunu gösterir (Hosmer ve Lemeshow, 2000: 161). LogR’da ki değişkenlerin önemini belirlemek için 3 temel test vardır. Bu testler:

- Olabilirlik oranı testi,
- Wald testi,
- Puan testi.

1.6.5. LogR Uygulamaları

LogR yönteminin uygulamalarından bazıları şunlardır; haritalama, habitat seçimi, hisse senedi getiri tahmini, endeks yön tahmini, tıbbi veri sınıflandırma, kredi skorlama, obezite risk tahminleme, kredi riski model oluşturma, SPK'ya bağlı aracı kurumların değerlendirilmesi, banka karlılıklarının tahminlenmesi, banka kredi müşterilerinin sınıflandırılması.

1.7. DOĞRUSAL DİSKRİMİNANT ANALİZİ

Doğrusal Diskriminant Analiz (DDA), veri hiperdüzleminin sınıfları ayıran genel bir formu olarak görülebilir. Bireysel sınıfların yoğunluk profili bir ön bilgiyle biliniyorsa, hiper düzlem basit Bayesci karar kuralı olarak belirlenebilir (Chen vd., 2013: 124). Örneklerin bağımsız olduğu varsayılırsa, yoğunluk tahmini ile ilgili basit bir varsayımın genel Gauss karakterlerini kullanması gerektiği belirtilmelidir. Sınıf yoğunlukları bilinmiyorsa uygun ayırım fonksiyonlarının sınıfları yeterince ayırması için bir yöntem tasarlamaya ihtiyaç duyulmaktadır (Ye vd., 2004: 983).

DDA yönteminin varsayımları şunlardır:

- Veriler, normal dağılımlı ana kütlede alınmalıdır.
- Ana kütle normal dağılıma sahip değilse, dönüşümler yapılarak normal dağılıma dönüştürülmelidir.
- Gruplar arası farkın olup olmadığını belirlemek için hipotez testi yapılmalıdır.

1.7.1. Doğrusal Diskriminant Analizi Metodu

Sınıf ayırımını kullanan yönetsel bir yaklaşım, Fisher tarafından önerilmiştir (1936). Fisher’in DDA metodu, sınıfların optimal doğrusal ayrılmasını

amaçlamaktadır. DDA algoritmasını tanımlamak için Fisher tarafından önerilen dönüşüm:

$$y=Ax \quad (49)$$

şeklindedir. Burada A matris, x girdi vektörüdür.

Böylece her bir sınıftaki örnekler birbirine yaklaşırken, sınıflar birbirinden daha iyi ayrılır. Dolayısıyla DDA'nın, aynı sınıftaki veri noktaları arasındaki mesafeyi en aza indirerek ve farklı sınıfların veri noktaları arasındaki mesafeyi en üst düzeye çıkararak, veriler üzerinde en iyi projeksiyonu bulmayı amaçladığı anlaşılmaktadır.

DDA'da, sınıflar arası farklılığa neden olan diskriminant fonksiyonu değişkenlerin doğrusal bileşenleri alınarak elde edilir ve aşağıdaki Denklem 50'deki gibi ifade edilir (Hair vd., 1998: 241):

$$y = a_1x_1 + a_2x_2 + \dots + a_px_p \quad (50)$$

Burada,

a_i = i. değişkenin katsayısı

x_i = i. diskriminant değişkeni'dir.

1.7.2. Doğrusal Diskriminant Analizinin Amaçları

DDA'nın amaçlarından ilki sınıflar arası farklılığı oluşturan değişkenlerin doğrusal bileşimlerinin sınırlanarak belirlenmesidir. DDA'nın diğer bir amacı da hangi sınıftan geldiği bilinmeyen bir birimin hangi sınıfa ait olduğunun tespit edilmesidir (Ünsal, 2000: 1-2).

1.7.3. Doğrusal Diskriminant Analizi Uygulama Teknikleri

Uygulamalarda eğer DDA ile amaçlanan sınıflar arasında farklılık oluşturan değişkenin belirlenmesi ise bu analiz tekniği betimsel amaçlıdır. Eğer uygulamada hangi sınıftan geldiği bilinmeyen bir birimin hangi sınıfa ait olduğunun tespit edilmesi amaçlanıyorsa bu analiz tekniği karar amaçlıdır (Raykov ve Marcoulides, 2008: 331).

DDA, gözlem birimlerinin hangi sınıfa ait olduğunun tespit edilmesi ve sınıflar arası farklılığı oluşturan değişkenlerin belirlenmesi için yapılan işlemler olarak tanımlanabilir. Diskriminant fonksiyonları gözlem birimlerinin ait oldukları sınıfların tespitini yapar ve bu ayrımı yaparken sınıflar arası farkı maksimize eder.

1.7.4. DDA Uygulamaları

DDA yönteminin uygulamalarından bazıları şunlardır; ülke ekonomilerinin sınıflandırılması, hisse senedi getirisi tahminleme, endeks yön tahmini, bilgisayar grafik analizi, çok boyutlu veriler için grafik teknikleri, kredi riski model oluşturma, firmaların mali başarısızlıklarının tahminlenmesi, şirket tahvillerinin derecelendirilmesi.

2. YARARLANILAN YÖNTEMLERE İLİŞKİN LİTERATÜR ARAŞTIRMASI

Finansal piyasalar karmaşık ve dinamik sistemlerdir. Finansal tahmin, belirsizlik içeren yapılandırılmamış zaman serilerinin işlenmesini gerektirir (Emir, 2013:111). Siyasi olaylar, genel ekonomik koşullar ve yatırımcı beklentileri gibi birçok faktör nedeniyle, finansal piyasa fiyat hareketlerini tahmin etmek oldukça zordur (Huang, Nakamori ve Wang, 2005: 2513).

Endeks yön tahmini ile ilgili olarak literatürde birçok farklı yöntem ve farklı değerlendirme ölçüleri kullanılarak yapılan çok sayıda çalışma bulunmaktadır. Bilgisayar teknolojilerinin gelişmesi ile yeni geliştirilen makine öğrenmesi yöntemleri araştırmacıların bu alana olan ilgisini arttırmıştır.

Literatürde BİST 100 endeksi tahminine yönelik gerek istatistik teknikler ile gerek makine öğrenmesi yöntemlerinin kullanıldığı çok sayıda çalışma olmasına karşın, teknik göstergeleri girdi verisi olarak kullanan sınıflandırma yöntemlerinin kullanıldığı az sayıda çalışmaya rastlanılmıştır. Bu tez çalışmasında amaç, makine öğrenmesi yöntemlerinin, endeks yön tahmininde teknik göstergelerden yararlanarak diğer yöntemlere alternatif olarak kullanılabilirliğini göstermektir.

Mevcut çalışmada geleneksel istatistikî yöntemler ile makine öğrenmesi yöntemleri karşılaştırılacaktır. Bu amaçla literatür taraması aşamasında ilk bölümde makine öğrenmesi yöntemleri ve geleneksel istatistikî yöntemleri kullanan çalışmalar

incelenmiştir. Literatürde varolan çalışmalar yöntemlerin seçilme ve kullanılma şekillerine göre genellikle üç tipe görülmektedir. Bunlar:

1. Tek yöntemin kullanıldığı çalışmalar.
2. Hibrit yöntemler.
3. Birden çok yöntemin kullanıldığı çalışmalar.

Bu çalışmada, makine öğrenmesi yöntemlerinden YSA, DVM, KA, NB ve k-EYK yöntemleri ile geleneksel istatistiki yöntemlerden LogR ve DDA yöntemleri kullanılarak çeşitli veri setleri ile endeks getirisi yön tahmini araştırılmıştır. Literatürde YSA ve DVM yöntemlerinin kullanıldığı çok sayıda çalışmaya rastlanırken diğer makine öğrenmesi yöntemlerine daha az sayıda rastlanmıştır. Benzer şekilde endeks yön tahmininde geleneksel yöntemlerin kullanıldığı az sayıda çalışmaya rastlanmıştır.

Literatür taramasının ikinci bölümünde ise teknik göstergeleri girdi verisi olarak alan ve sınıflandırma yöntemlerini kullanarak endeks yön tahmini yapan çalışmalar ele alınmıştır. Bu çalışmanın konusuyla ilgili literatürde yurtdışında yapılan çok sayıda çalışmaya rastlanırken Türkiye’de ise az sayıda çalışmaya rastlanmıştır. Yazarlar için bu konudaki çalışmaları farklılaştıran iki nokta olduğu tespit edilmiştir. Bunlardan ilki çalışmalarda kullanılan yöntemlerin yapısı ve sayısı, ikincisi ise yöntemlerin değerlendirme ve karşılaştırma teknikleridir. Endeks yön tahmininde, tahmin doğruluğunun önemli bir kriter olması araştırmacıları daha yüksek doğruluk oranları verecek yeni yöntemler kullanmaya ve keşfetmeye yöneltmektedir. Farklı ve yeni birkaç yöntemi birlikte kullanarak ve hibrit yöntemler deneyerek daha doğru tahminler yapılmaya çalışıldığı gözlenmiştir.

Yöntemlerin tahmin güçlerinin daha iyi değerlendirilebilmesi için genellikle doğruluk oranı ve hata metrikleri kullanılmaktadır. Bu tez çalışmasında da yöntemler hem doğruluk oranı hem de hata metrikleri kullanılarak karşılaştırılmıştır.

2.1. SINIFLANDIRMA YÖNTEMLERİ İLE İLGİLİ YAPILAN ÇALIŞMALAR

Bu çalışmada, geleneksel yöntemlerin yanısıra bilgisayar teknolojilerinin gelişmesiyle birlikte büyük veriyi işleme olanağı veren makine öğrenmesi yöntemleri de kullanılmıştır. Ayrıca bu yöntemlerin geleneksel istatistiki yöntemler ile

performans karşılaştırmaları yapılmıştır. Bu bağlamda çalışmada makine öğrenmesi yöntemlerinden YSA, DVM, KA, NB ve k-EYK yöntemleri ile geleneksel istatistiki yöntemlerden LogR ve DDA yöntemleri kullanılmıştır. Literatürde bu yöntemlerden en sık kullanılan makine öğrenmesi yöntemleri YSA ve DVM olurken diğer yöntemlerle yapılan çalışma sayısı ise çok azdır. Özellikle zor ve karmaşık problemleri kolayca modelleyebilmesi ve esnek yapısı ile endeks yön tahmin problemlerinde YSA yöntemi, araştırmacılar tarafından en çok tercih edilen yöntemdir. Diğer makine öğrenmesi modelleri ise araştırmacılar tarafından daha az sayıda çalışmada kullanılmışlardır.

Endeks yön tahmini üzerine sınıflandırma yöntemlerinden makine öğrenmesi yöntemleri ile geleneksel istatistiki yöntemlerin tahmin doğruluğu performans karşılaştırması ile ilgili çalışmalar genel olarak değerlendirildiğinde, iki konu üzerine yoğunlaşıldığı gözlenmektedir. Bunlardan ilki çalışmalarda kullanılan yöntemlerin sayısı ve yapısı, ikincisi ise yöntemlerin değerlendirme ve karşılaştırma teknikleri olduğu gözlenmiştir.

YSA yöntemi ile ilgili literatürde yapılan bazı çalışmalarda (Nayak, Misra ve Behera, 2012; Zahedi ve Rounaghi, 2015; Chiang vd., 2016; Göçken vd., 2016; Qiu, Song ve Akagi, 2016) YSA'nın da dahil olduğu hibrit modeller kullanılmış iken diğer çalışmalarda (Laboissiere, Fernandes ve Lage, 2015; Kılıç, Paksoy ve Genç, 2015; Sakarya vd., 2015; Moghaddam, Moghaddam ve Esfandyari, 2016; Tripathy, 2018) ise sadece YSA modelinin kullanıldığı görülmüştür. Ayrıca YSA yönteminin endeks yön tahminlerini doğru olarak öngörebildiği tespit edilmiştir.

DVM yöntemine ilişkin literatürdeki çalışmalara bakıldığında kimi çalışmalarda (Wang ve Zhu, 2010; Fletcher ve Shawe-Taylor, 2013; Karagül, 2014; Liu vd., 2015) sadece DVM yöntemi kullanılırken son dönemlerde (Wang, 2013; Pan vd., 2017; Ren vd., 2018) ise hibrit yöntemlerin kullanılmış olduğu tespit edilmiştir. Elde edilen bulgulara göre DVM yönteminin endeks yönünü tahmin gücünün yüksek olduğu görülmüştür.

Çalışmada incelenen bir diğer yöntem olan Karar Ağaçları ile yapılan çalışmaların bazılarında (Tsai ve Wang, 2009; Qiu, Liu ve Wang, 2012) hibrit yöntemler kullanılırken, diğer çalışmalarda (Yakut, 2012; Rostami vd., 2015;

Pehlivanlı, Aşıkil ve Gülay, 2016) ise birden fazla yöntem karşılaştırılmıştır. Sonuçlara göre birden fazla yöntemin kullanıldığı çalışmalarda KA yönteminin tahmin doğruluğu oranının diğer yöntemlerin gerisinde kaldığı tespit edilmiştir.

NB yönteminin yer aldığı literatürdeki çalışmalarda (Dash ve Dash, 2016b; Filiz, Karaboğa ve Akoğul, 2017; Tekin ve Çanakoğlu, 2018) birden fazla yöntemle birlikte kullanıldığı görülmüştür ve NB yönteminin tahmin doğruluğu açısından çok başarılı sonuçlar verdiği belirlenmiştir. Çalışmada araştırılan diğer bir yöntem olan k-EYK ile yapılmış çalışmalarda ise (İlarslan, 2016; Nakagawa, Imamura ve Yoshida, 2017) k-EYK'nın tekli yöntem olarak kullanıldığı ve ortalama doğruluk oranının yüksek çıktığı tespit edilmiştir.

Geleneksel istatistiki yöntemlerden LogR yöntemi, bazı (Subha ve Nambi, 2012; Ballings vd., 2015; Gündüz, Yaslan ve Çataltepe, 2017) çalışmalarda birden fazla yöntemle birlikte kullanılmış ve yüksek doğruluk tahminine ulaşılmıştır. Diğer bir istatistiki yöntem olan DDA bazı (Huang, Nakamori ve Wang 2005; Ou ve Wang, 2009; Akyatan, 2016) çalışmalarda birden çok yöntemlere alternatif olarak birlikte kullanılmış ve diğer yöntemlere yakın doğruluk tahmininde bulunduğu belirlenmiştir.

Çalışmanın izleyen bölümünde, çalışmada yararlanılan yöntemlere ilişkin yapılmış olan çalışmalar ayrıntılı olarak ele alınmıştır.

2.1.1. Yapay Sinir Ağları ile İlgili Yapılan Çalışmalar

Endeks yön tahmininde YSA yönteminin kullanıldığı çalışmalar incelendiğinde, YSA yönteminin kullanıldığı ilk çalışmalardan biri Kimoto vd. (1990) tarafından yapıldığı belirlenmiştir. Daha sonraki yıllarda artan sayıda çalışma yapılarak, endeks getiri yönü tahmini problemine çözümler bulunmaya çalışılmıştır. Bu çalışmaların bir bölümünde (Avcı, 2009; Cao, Parry ve Leggio, 2011; Güresen, Kayakutlu ve Daim, 2011; Nayak, Misra ve Behera, 2012; Zahedi ve Rounaghi, 2015; Yavuz, Sakarya ve Özdemir, 2015; Chiang vd., 2016; Göçken vd., 2016; Qiu, Song ve Akagi, 2016) YSA tabanlı çok katmanlı algılayıcılar (ÇKA) ve hibrit modeller kullanılmıştır. Diğer çalışmalarda ise (Kimoto vd., 1990; Enke ve Thawornwong, 2005; Adebisi, Adewumi ve Ayo, 2014; Çalışkan ve Deniz, 2015; Laboissiere, Fernandes ve Lage, 2015; Kılıç, Paksoy ve Genç, 2015; Sakarya vd.,

2015; Moghaddam, Moghaddam ve Esfandyari, 2016; Tripathy, 2018) YSA modeli ve diğer modellerin birlikte kullanıldığı görülmektedir.

Tablo 2'ye bakıldığında, endeks getirisi yön tahmini üzerine YSA yönteminin kullanıldığı birçok çalışmanın olduğu görülmektedir. Tablo 2'den görüldüğü gibi yapılan çalışmaların beş tanesinde sadece YSA yönteminin kullanıldığı ve endeks tahminlerini doğru olarak öngörebildiği tespit edilmiş iken, yedi çalışmada ise YSA ile diğer bir yöntem hibrit olarak kullanılmış ve sonuçlar hibrit modelin tahmin doğruluğunu önemli ölçüde arttırdığını göstermiştir. Üç çalışmada ise birden fazla yöntem kullanılmış ve YSA diğer yöntemlere göre üstünlük sağlamıştır.

Tablo 2. Endeks Yön Tahmininde Yapay Sinir Ağları Yöntemi ile İlgili Yapılan Çalışmalar

Yazar/Yazarlar	Tahmin Modeli	Veri	Sonuç
Kimoto vd. (1990)	YSA	TOPIX, teknik ve ekonomik aylık veri, 1987-1989	YSA mükemmel bir kazanç, yüksek tahmin doğruluğu sağlamıştır.
Enke ve Thawornwong (2005)	YSA, GRNN, PNN, DR	S&P500 Finansal ve ekonomik 31 değişken, 1976-1999	Sınıflandırma yöntemlerinin sonuçları al ve tut stratejisinden daha karlıdır.
Avcı (2009)	ÇKA	İMKB 30 günlük ağırlıklı ortalama fiyatlar, 2007-2008	Borsa tahmininde nöral ağ modellerin etkinliğini desteklemektedir.
Cao vd. (2011)	ÇKA, ULN, MLV, UANN, MANN	SHSE günlük kapanış fiyatı 1999-2008	Model, hisse senedi hareketlerini tahmin etmek için güçlü ve pratiktir.
Güresen vd. (2011)	ÇKA, DAN2, GARCH-ÇKA, GARCH	NASDAQ endeksi günlük değişim oranı 2008-2009	ÇKA en iyi ve pratik YSA mimarisi olarak bulunmuştur.
Nayak vd. (2012)	YSA-GD, YSA-GA, FLANN-GA	S&P100 ve S&P500 günlük veriler, 2005-2010	YSA-GA, FLANN-GA modelinden daha iyi sonuç vermiştir.
Adebiyi vd. (2014)	ARIMA, YSA	NYSE günlük kapanış fiyatı 1988-2011	ANN, ARIMA'dan daha iyi sonuçlar bulmuştur.
Çalışkan ve Deniz (2015)	RW, DR, YSA, ARIMA, GARCH	BİST30, 27 şirketin günlük verisi, 2009-2014	Günlük bazda fiyat yönü ortalama %58 oranında doğru tahmin edilmiştir.
Laboissiere vd. (2015)	YSA	BM&F Bovespa günlük kapanış değ. 2010-2012	ANN Brezilya dağıtım şirketleri tahmin problemlerinde etkilidir.
Kılıç vd. (2015)	YSA	Haftalık döviz kuru, altın fiyatı ve faiz getirileri	ANN modellerinin kompozit kullanma haftalık olarak değerli bilgiler sağlar.
Sakarya vd. (2015)	YSA	BİST100 günlük kapanış fiyatları, 2007-2009	Tahmin için modelin değeri doğru olarak öngörebildiği görülmüştür.
Yavuz vd. (2015)	ÇKA	BİST-Sınai 'de 140 şirketin 2010 yılı aylık ortalama getirileri	YSA'nın getiri tahmini %1'in altında hata oranı ile gerçekleşmiştir.

Zahedi ve Rounaghi (2015)	YSA-PCA	Tahran Borsası muhasebe değişkenleri, 2006-2012	Karmaşık serilerin modellenmesinde yeni ve verimli olmuştur.
Güzel vd. (2016)	ANFIS	2002-2015 dönemi günlük makroekonomik faktörler	Endeks getirisi yüksek oranda tahmin edilebilmiştir.
Chiang vd. (2016)	YSA-PSO	S&P500 ve NASDAQ endeksi veriler, 2008-2010	Önerilen model ağ performansını optimize etmiştir.
Göçken vd. (2016)	YSA, YSA-HS YSA-GA	2005-2013 yılları BİST100 endeksi 45 teknik gösterge	YSA-HS modeli, endeks tahmini için hakim bir model olarak bulunmuştur.
Moghaddam vd. (2016)	YSA	NASDAQ'ın 2015 yılı günlük borsa verileri	NASDAQ endeksi tahmini ağları geliştirildi ve doğrulandı.
Qiu vd. (2016)	YSA, YSA-GA YSA-SA	2008-2013 Nikkei 225 endeksi günlük verileri	YSA-SA karma yaklaşımı, tahmin doğruluğunu önemli ölçüde geliştirir.
Nelson vd. (2017)	LSTM	BM&F Bovespa endeks günlük veri, 2008-2015	Ortalama doğruluk %55.9 olarak bulunmuştur.
Tripathy (2018)	YSA	S&P CNX Nifty borsası günlük verileri, 2008-2016	Modelin tahmin gücünün makul olarak etkilendiğini göstermektedir.

Kimoto vd. (1990) tarafından yapılan çalışmada, YSA yöntemi ile çeşitli teknik ve ekonomik endeksler arasındaki ilişkiler ve hisse senetlerinin ne zaman alınıp satılacağı belirlenmiştir. 1987-1989 yılları arası toplam 33 aylık teknik ve ekonomik veri kullanılan çalışmada, Japonya Tokyo Borsası TOPIX endeksinin yönü ve hisse senedi alım satım zamanı tahmini için YSA yöntemi kullanılmıştır. Çalışmanın sonuçlarına göre YSA tahmin sisteminin, mükemmel bir kazanç sağladığı ve tahmin doğruluğunun yüksek olduğu tespit edilmiştir.

Enke ve Thawornwong (2005) tarafından yapılan çalışmada endeks yön tahmini için YSA yönteminin doğruluk oranı araştırılmıştır. 1976-1999 yılları arasındaki aylık dönemlerde 31 finansal ve ekonomik değişkenin toplamda 286 verinin ele alındığı çalışmada, S&P 500 endeksinin ertesi günkü yönünü tahmin performanslarını karşılaştırmak için YSA, Genelleştirilmiş Regresyon Sinir Ağı (GRNN), Olasılıksal Sinir Ağı (PNN) ve Doğrusal Regresyon (DR) yöntemleri kullanılmıştır. Yazarlar, sınıflandırma problemlerinin çözümünde YSA modellerinin tahmin yeteneklerini araştırmışlardır. Çalışmadan elde edilen sonuçlara göre; sinir ağı sınıflandırma modelleri tabanlı ticaret stratejilerinin diğer modellerin kullanıldığı stratejilere göre daha fazla kar sağladığı görülmüştür.

BİST 30 endeksi'nin ertesi gnk yn tayini iin KA'nın kullanıldıđı bir bařka alıřma Avcı (2009) tarafından yapılmıřtır. alıřmada, BİST 30 endeksinin 2007-2008 dneminde gnlk ađırlıklı ortalama fiyat verileri kullanılmıřtır. Sonuta, KA algoritmalarının incelenen dnemlerde al-ve-tut stratejisine gre daha iyi sonular verdiđi grlmřtir.

řangay Menkul Kıymetler Borsası'nda (SHSE) iřlem gren A-tipi hisse senetlerinin fiyat hareketlerini tahmin etmeyi amalayan Cao, Parry ve Leggio (2011), tahmin performanslarını karřılařtırmak iin Tek Deđiřkenli Dođrusal Model (ULN), ok Deđiřkenli Dođrusal Model (MLV), Tek Deđiřkenli YSA (UANN) ve ok Deđiřkenli YSA (MANN) yntemlerini kullanmıřlardır. alıřmada SHSE endeksine ait 1 Ocak 1999 ile 31 Aralık 2008 arasındaki zaman dilimini kapsayan gnlk kapanıř fiyatlarından ve  aylık defter deđeri ile ortak paylardan oluřan veri seti kullanılmıřtır. Yazarlar tarafından SHSE endeksi yn tahmini iin en yksek dođruluk oranını veren algoritma olarak MANN algoritması tespit edilmiřtir.

Bu alıřmaya benzer bir alıřma, Gresen, Kayakutlu ve Daim (2011) tarafından yapılmıřtır. NASDAQ endeksi yn tahmini iin YSA yntemi ile yapılan alıřmada tahmin performanslarını karřılařtırmak zere hata ltleri kullanılmıřtır. NASDAQ'ın 7 Ekim 2008'den 26 Haziran 2009'a kadar gnlk verilerin kullanıldıđı alıřmada, KA, YSA Dinamik Mimari (DAN2), Genelleřtirilmiř Autoregressive Kořullu Heteroskedastisite-KA (GARCH-KA) ve GARCH-DAN2 yntemleri NASDAQ endeksinin ertesi gnk yn tahminlenmesinde kullanılmıřtır. alıřmada elde edilen bulgular, KA'nın zaman serilerinin tahmininde en iyi sonuları verdiđini gstermiřtir. Ayrıca karma yntemlerin, tahmin sonularını iyileřtirmedeđi tespit edilmiřtir.

S&P100 ve S&P500 Endekslerinin ertesi gnk yn tahminini en yksek dođrulukla tahmin eden YSA ynteminin belirlenmesine ynelik yapılan bir bařka alıřma ise Nayak, Misra ve Behera'ya (2012) aittir. S&P100 ve S&P500 Endekslerinin 2005-2010 yıllarına ait gnlk kapanıř fiyatlarının veri seti olarak kullanıldıđı alıřmada YSA-Dereceli Alalma (YSA-GD), YSA-Genetik Algoritma (YSA-GA) ve İřlevsel Bađlantı Yapay Sinir Ađı-GA (FLANN-GA) yntemleri

kullanılmıştır. Elde edilen doğruluk oranlarına göre ise en yüksek doğruluğu veren yöntemin, YSA-GA algoritması olduğu tespit edilmiştir.

YSA yönteminin endeks yön tahmininde daha yüksek doğruluk sonuçları tahmin ettiğini araştıran Adebisi, Adewumi ve Ayo (2014), yaptıkları çalışmada NYSE endeksinin yön tahminini, YSA ve Otoregresif Entegre Hareketli Ortalama (ARIMA) yöntemleri ile sınımladılar. Çalışmada, 1988-2011 dönemi günlük verileri kullanılarak NYSE endeksinin ertesi günkü yönü tahmin edilmiştir. Çalışmadan elde edilen ampirik sonuçlar, ARIMA modeline göre YSA modelinin üstünlüğünü ortaya koymaktadır. Yazarlara göre elde edilen bulgular literatürde bildirilen çelişkili görüşleri ortadan kaldıracak niteliktedir.

YSA kullanılarak endeks yönü tahmini yapılan başka bir çalışma Çalışkan ve Deniz (2015) tarafından yapılmıştır. BİST30 endeksinin ertesi günkü tahmini için en yüksek doğruluk oranını veren yöntemi bulmak üzere YSA, Rastgele Yürüyüş (RW), LR, ARIMA ve GARCH yöntemlerinin karşılaştırıldığı çalışmada, 2009-2014 arasındaki toplam 1248 adet günlük veri seti kullanılmıştır. Analizler sonucunda, endeks yönü tahmin problemi için en iyi yöntem olarak YSA bulunmuştur. Çalışmada elde edilen sonuçlara göre hisse senetleri fiyat yönü %58 oranında doğru tahmin edilmiştir.

Laboissiere, Fernandes ve Lage (2015), BM&Bovespa Endeksi'nin 2008-2013 dönemindeki günlük kapanış verilerini kullanarak, endeks yönünü tahmin etmeye çalışmışlardır. Çalışmada YSA yöntemi ile gerçekleştirilen tahminin doğruluk performansları MAE, MAPE ve RMSE hata ölçütleri ile değerlendirilmiştir. Çalışmanın sonuçlarına göre, günlük hisse senedi fiyatları tahmin problemini ele almak için önerilen YSA yönteminin etkili olduğu belirlenmiştir.

Aynı amaçla Kılıç, Paksoy ve Genç (2015), BİST-100 endeksinin 2002-2013 yılları arasındaki haftalık verilerini kullanarak endeks yönünü en doğru oranda tahmin etmeye çalışmışlardır. Toplamda 606 haftalık verinin kullanıldığı çalışmada, YSA yöntemi ile BİST-100 endeksinin haftalık getirileri tahmin edilmeye çalışılmıştır. Elde edilen bulgular, YSA yöntemi ile tahmin doğruluk oranının oldukça yüksek olduğunu göstermiştir.

BİST-100 Endeksi'nin günlük ve haftalık getirilerinin YSA kullanılarak tahmin edilebilirliğini inceleyen bir başka çalışma Sakarya vd. (2015) tarafından yapılmıştır. Yazarlar bu probleme cevap bulmak için, BİST-100 endeksinin 2007-2009 küresel kriz dönemine ilişkin günlük ve haftalık getirilerini YSA yöntemi ile analiz etmişlerdir. Çalışmadan elde edilen sonuçlar, YSA'nın bu alanda başarılı bir şekilde kullanılabileceğini ve bilinmeyen örnekler için bile %5'ten az bir hatayla gelecek gün ve gelecek hafta için doğru tahmin yapabildiğini göstermiştir.

Yavuz, Sakarya ve Özdemir (2015) tarafından yapılan çalışmada, BİST-Sınai endeksinin ÇKA yöntemi kullanılarak risk-getiri tahmini ve portföy optimizasyonu yapılmıştır. Veri seti olarak 140 hisse senedinin 2010 dönemine ait aylık ortalama getirileri kullanılmıştır. Çalışmada ileri beslemeli ÇKA ağından faydalanılarak en yüksek getirili ve en düşük riskli portföyler öngörülme çalışılmıştır. Çalışmadan elde edilen sonuçlara göre ÇKA ile getiri tahmini ve risk tahmininde hata oranları sırası ile %1'in ve %0.5'in altında gerçekleşmiştir.

Hisse senedi fiyatı öngörüsü için YSA yönteminin kullanıldığı bir başka çalışma Zahedi ve Rounaghi (2015) tarafından Tahran Menkul Kıymetler Borsası'nda yapılmıştır. YSA ve Temel Bileşenler Analizi (PCA) yöntemlerinin kullanıldığı çalışmanın veri seti ise 2006-2012 yılları arası hesaplanan 20 finansal oran verisinden oluşmuştur. Analiz sonuçlarına göre, YSA yönteminin rakiplerine göre üstünlüğe sahip olduğu, PCA yönteminin ise Tahran Borsası'nda hisse senedi fiyatını doğru bir şekilde tahmin edebildiği ve gerçek değerler kullanarak hisse senedi fiyatında etkili faktörleri belirleyebileceği bulunmuştur.

Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi (ANFIS) yönteminin endeks yön tahmininde en yüksek doğruluk oranlarını verdiğini iddia eden Güzel, Acar ve Avcı (2016), çalışmalarında BİST-100 endeksinin ertesi günkü yön tahminini yapmışlardır. Çalışmada, makroekonomik göstergelerden oluşan 2002-2015 dönemi için aylık olarak derlenen toplamda 168 veri kullanılmıştır. Çalışmada elde edilen bulgulara göre, BİST-100 endeksi ANFIS algoritması ile %98,54 doğruluk ile tahmin edilmiştir.

Hisse senedi endeks fiyatlarının yönünü tahmini için YSA yönteminin kullanıldığı benzer bir çalışma Chiang vd. (2016) tarafından yapılmıştır. S&P500 ve

NASDAQ endekslerinin 2004-2011 arası dönemde 12 deęişkenin gnlk verileri kullanarak endeks yn tahmini yapılan alıřmada, Paracık Sr Optimizasyonu (PSO) algoritmasının YSA performansını optimize etmesi ve teknik gstergeleri kullanmasının tahmin doęruluęunu arttırdığı tespit edilmiştir. Yazarlara gre hisse senedi endeksleri ile yapılan tahminler, yatırımcıların geliřmiř adaptif karar destek sistemi yntemlerini kullanarak nasıl daha yksek getiri saęlayabileceğini gstermektedir.

Gken vd. (2016) tarafından yapılan alıřmada, BİST-100 Endeksini en doęru tahminleme yntemini tespit etmeyi amalamıřlardır. YSA, YSA-Uyum Arayıřı (YSA-HS), YSA-GA yntemlerinin performans karřılařtırması yapılan alıřmada, 2005-2013 dnemi 45 teknik gstergenin gnlk deęerleri veri seti olarak kullanılmıřtır. Elde edilen sonulara gre, BİST-100 Endeksinin ertesini gnk yn tahmini problemi iin en yksek doęruluk oranına YSA-HS modelinin sahip olduęu bulunmuřtur.

NASDAQ Endeksinin yn tahmini iin YSA algoritması kullanan bir bařka alıřmada Moghaddam, Moghaddam ve Esfandyari (2016) tarafından yapılmıřtır. 28 Ocak 2015-18 Haziran 2015 tarihleri arasında gnlk NASDAQ dviz kuru oranlarının kullanıldıęı alıřmada, yazarlara gre model ıktıları, iki tip girdi veri seti (drt nceki gn ve dokuz nceki gn) iin NASDAQ endeksi tahmin kabiliyeti arasında belirgin bir fark olmadıęını belirlemiřtir.

Benzer bir sonu, Qiu, Song ve Akagi (2016) tarafından da bulunmuřtur. Yazarların, Japon Nikkei 225 Endeksinin 1993-2013 arası dnemine ait finansal gstergeler ve makroekonomik faktrleri ieren 71 deęiřkenin toplamda 237 aydan oluřan veri setini kullanarak endeksin ertesini gnk ynn tahmin ettikleri alıřmalarında YSA, YSA-GA, YSA-Benzetimli Tavlama (YSA-SA) yntemleri kullanılmıřtır. alıřmadan elde edilen sonulara gre; YSA-SA algoritması en yksek doęruluk oranına sahip tahminleyici olarak bulunmuřtur.

Hisse senedi fiyat hareketlerinin tahminlerini gerekleřtirmek iin Uzun-Kısa Sreli Hafıza (LSTM) aęlarına dayalı bir sınıflandırma modeli Nelson, Pereira ve Oliveira (2017) tarafından tasarlanmıřtır. IBovespa endeksi zerine yapılan

çalışmada, 2008'den 2015'e kadar olan günlük veriler kullanılmıştır. Elde edilen sonuçlara göre, doğruluk oranı %55,9 olarak gerçekleşmiştir.

Son olarak, Tripathy (2018) tarafından yapılan çalışmada, S&P CNX Nifty endeksinin ertesi günü yönü tahminlemesi, YSA yöntemi kullanılarak tahminlenmiştir. 1 Ocak 2008'den 8 Nisan 2016'ya kadar sekiz yıllık bir süre boyunca günlük verinin kullanıldığı çalışmada, YSA modelinden faydalanılmıştır. Çalışmada tahmin edilen çıktının gerçek verilere çok yakın olduğu tespit edilmiştir.

2.1.2. Destek Vektör Makineleri ile İlgili Yapılan Çalışmalar

Endeks yön tahmininde YSA yönteminden sonra literatürde en çok kullanılan ikinci yöntemin DVM olduğu görülmüştür. Çalışmaların bir bölümünde (Wang ve Zhu, 2010; Fletcher ve Shawe-Taylor, 2013; Karagül, 2014; Liu vd., 2015) sadece DVM yöntemi kullanılırken; diğerlerinde (Wang, 2013; Pan vd., 2017; Ren vd., 2018) hibrit yöntemler kullanılmış; bazısında ise (Özdemir, Tolun ve Demirci, 2011; Yakut, Elmas, ve Yavuz ,2014; Li vd., 2016) birden fazla yöntem karşılaştırmalı olarak kullanılmıştır.

Tablo 3'te de DVM yönteminin endeks yön tahmininde birçok çalışmada kullanıldığı görülmektedir. Çalışmaların dört tanesinde sadece DVM yönteminin kullanıldığı ve yöntemin endeks yönünü tahmin gücünün yüksek olduğu görülmüştür. Üç çalışmada ise kullanılan hibrit yöntemler diğer yöntemlere göre daha iyi performans göstermiştir. Geriye kalan çalışmalarda ise birden fazla yöntem kullanılmış, DVM diğer yöntemlere göre tahmin doğruluğunda geride kalmıştır.

Tablo 3. Endeks Yön Tahmininde Destek Vektör Makineleri Yöntemi ile İlgili Yapılan Çalışmalar

Yazar/Yazarlar	Tahmin Modeli	Veri	Sonuç
Wang ve Zhu (2010)	DVR	1997-2007, S&P500 ve NASDAQ günlük verileri	DVR yönteminin yüksek tahmin doğruluğu sonucu verdiği bulunmuştur.
Özdemir vd. (2011)	DVM, LogR	Makroekonomik gösterge, MSCI, S&P500, 1997-2010	Ortalama doğruluk %75, %86,2 olarak bulunmuştur.
Fletcher ve Shawe-Taylor (2013)	DVM	EUR-USD para birimi günlük verileri	Ortalama doğruluk %55 olarak bulunmuştur.

Wang (2013)	PCA-DVM	KOSPI 200- HSI endeks günlük veriler, 2002-2011	Endeks yön tahmininde modellerin yüksek tahmin gücü olduğu görüldü.
Karagül (2014)	DVM	2006-2011 yılları 10 adet finansal oran	Ortalama doğruluk %97.61 olarak bulunmuştur.
Yakut vd. (2014)	YSA, DVM	BIST, NIKKEI, CAC DAX, BOVESPA, FTSE Faiz, USD	YSA, DVM'ye göre daha iyi performans göstermiştir.
Liu vd. (2015)	DVR	Baidu endeks 2006-2015 günlük verileri	DVR modellerinin yüksek tahmin doğruluğuna sahip olduğu görülmüştür.
Li vd. (2016)	AÖM, DVM, BPNN	Piyasa haberleri, 5 teknik gösterge, 1 Haz-31 Tem 2001	Doğru sinyallere sahip strateji daha az riskle daha fazla kar sağlar.
Pan vd. (2017)	MDVM-UMIDAS	S&P500, 2008-2015 makroekonomik gösterge	Sonuçlar tatmin edicidir ve önerilen model daha iyi performans göstermiştir.
Ren vd. (2018)	Duygu Analizi-DVM	China SSE 50 endeks 2014-2016 günlük verileri	Ortalama doğruluk %89.93 olarak bulunmuştur.

Wang ve Zhu (2010) tarafından yapılan çalışmada DVM yöntemi kullanılarak S&P500 ve NASDAQ endekslerinin ertesi günü yönü tahmini problemi ele alınmıştır. 1997-2007 dönemine ilişkin 2500 günlük veri DVM tabanlı Destek Vektör Regresyon (DVR), satın al-tut stratejisi ve çekirdek öğrenme metodu olmak üzere üç yöntemle karşılaştırılmıştır. Çalışmanın sonuçlarına göre; DVR metodu S&P500 ve NASDAQ piyasa endekslerini yüksek doğruluk oranı ile tahmin etmiştir.

Özdemir, Tolun ve Demirci (2011) tarafından yapılan çalışmada, MSCI European Index, MSCI Gelişen Piyasalar Endeksi ve S&P500 endeksleri ile bazı makroekonomik göstergeler veri seti olarak ele alınarak endeks getirisinin yönü DVM ve LogR yöntemleri ile tahmin edilmiştir. 1997-2010 yıllarına ait aylık verilerin kullanıldığı çalışmada, endeks getirisinin yönü on bir değişken ile tahmin edilmeye çalışılmıştır. Analiz sonuçlarına göre; LogR'nin doğru sınıflandırma oranı %75 olarak gerçekleşirken, DVM için bu oran %86,2'dir.

Fletcher ve Shawe-Taylor (2013) makroekonomik değişkenlerden olan döviz kuru ile hisse senedi endeks getirisi yönünü tahmin etmeye çalışmışlardır. Veriler, 02/11/2009'da EURO-USD döviz çifti için 1 saniyelik bir frekansta örneklenen 6×10^4 'lük büyük bir veri setinden oluşmaktadır. 5, 10, 20, 50, 100 ve 200 saniyelik zaman periyodları (Δt) için tahminler oluşturulmuştur. Çalışmada elde edilen bulgulara göre endeks getiri hareketinin yönünü, 200 saniyelik tahmini zaman periyodu %55'lik ortalama doğruluk ile elde edilmiştir.

Borsa endekslerinin getiri ve hisse senedi fiyatları yönü tahminini ele alan bir başka çalışma Wang (2013) tarafından PCA-DVM hibrit yöntemi kullanılarak yapılmıştır. Kore ve Hong Kong borsalarının KOSPI 200 ve HSI endekslerinde yapılan araştırmada 2002 ile 2011 dönemi için toplanan günlük veri setleri kullanılmıştır. Çalışmada elde edilen ampirik sonuçlara göre, endeks yönü tahmini için DVM tabanlı hibrit yöntemlerin daha yüksek tahmin doğruluğu oranına sahip olduğu görülmüştür.

BİST 100 Endeksi'ndeki 42 şirketin 10 adet finansal oranını ele alan Karagül (2014) tarafından yapılmış çalışmada, 2006-2011 döneminde BİST 100 endeksinin getiri yönü araştırılmıştır. Çalışmada BİST 100 endeksinin getiri yönü DVM yöntemi kullanılarak tahmin edilmiştir. Çalışmanın sonuçlarına göre, DVM'nin endeksin ertesi günkü yönünü doğru tahminleme oranı %97,61'dir.

Makroekonomik göstergelerin kullanıldığı bir başka çalışma Yakut, Elmas ve Yavuz (2014) tarafından yapılmıştır. Çalışmada BİST 100 Endeksinin, 2005-2012 yılları arasındaki toplam 1998 günlük veri kullanılarak endeks getiri yönü tahmini DVM ve YSA yöntemleri kullanılarak tespit edilmiştir. Yazarlar gerçek endeks değerlerini tahmini değerler ile performans ölçütleri kullanılarak karşılaştırmışlardır. Çalışmadan elde edilen sonuçlara göre, %95 güven aralığında gerçek ve tahmini değerler arasında anlamlı bir fark olmadığı belirlenmiştir.

Hisse senedi endeks fiyatlarının ertesi günkü yönü tahmini için DVM yönteminin kullanıldığı benzer bir çalışma Liu vd. (2015) tarafından yapılmıştır. Çalışmada, hisse senedi endeksi yön tahmini için hata düzeltme ve DVM tabanlı DVR ile bir zaman serisi modeli (ZS) oluşturulmuş ve karşılaştırma için hibrit dört model, Arama Hacmi Endeksi-Zaman Serisi (AHE-ZS), Bileşik Lider Arama Endeksi-ZS (BLAE-ZS), AHE-DVR ve BLAE-DVR kullanılmıştır. 2006-2015 yılları arası günlük verilerin kullanıldığı çalışmada Baidu Endeksinin ertesi günkü yönü tahmininde en yüksek doğruluk oranını veren hibrit algoritma BLAE-DVR olarak tespit edilmiştir. Çalışmada ortaya çıkan bulgulara göre, tahmin modelleri olarak DVM tabanlı DVR ve ZS kullanıldığında BLAE test veri setinin çoğunluğunda AHE'den daha iyi performans elde edilmiştir.

Hang Seng Endeksi'nin Aşırı Öğrenme Makineleri (AÖM), DVM ve Geri Yayılım Sinir Ağları (BPNN) yöntemleri ile ertesi günü yönü tahminini araştıran Li vd. (2016), 1 Haziran 2001 ile 31 Temmuz 2001 arası döneme ilişkin 5 teknik gösterge ve piyasa haberlerinden elde edilen verileri kullanarak tahminleme yapmışlardır. Elde edilen bulgulara göre, Hang Seng endeksinin getiri yönünü en yüksek doğrulukla tahmin eden yöntem olarak AÖM-DVM algoritması belirlenmiştir.

Hisse senedi fiyat endeksinin ertesi günü yönünün tahmininde Pan vd. (2017) Çoklu Çıkış Desteği Vektör Makinesi-Sınırsız Karışık Veri Örneklemesi (MDVM-UMIDAS) hibrit yöntemini kullanarak Haziran 2008-Nisan 2015 dönemi verileri ile S&P500 Endeksinin yönünü tahminlemiştir. Sonuç olarak önerilen modelin pratikte daha gerçekçi ve hisse senedi fiyatı tahmininde sorunlarının çözümü için uygun bir yöntem olduğu belirlenmiştir.

Son zamanlarda Duygu Analizi-DVM hibrit yöntemi kullanılarak Ren, Wu ve Liu (2018) tarafından yapılan çalışmada, sadece finansal piyasa verileri ile değil, aynı zamanda yatırımcı psikolojisini içeren duygu özellikleriyle birleştirerek borsa hareket yönü tahmin edilmiştir. Çalışmadan elde edilen deneysel sonuçlar SSE 50 Endeksinin hareket yönünü tahmin etmenin doğruluğunun, duygu değişkenlerini tanıttıktan sonra %89.93'e kadar yükselebileceğini göstermiştir.

2.1.3. Karar Ağaçları ile İlgili Yapılan Çalışmalar

Endeks yön tahmininde KA yöntemi oldukça az sayıda çalışmada kullanılmıştır. Çalışmalardan iki tanesinde (Tsai ve Wang, 2009; Qiu, Liu ve Wang, 2012) hibrit yöntemler kullanılırken, diğer üç çalışmada (Yakut, 2012; Rostami vd., 2015; Pehlivanlı, Aşıkil ve Gülay, 2016) ise birden fazla yöntem karşılaştırılmıştır.

KA ile yapılan çalışmalar Tablo 4'te gösterilmiştir. Hibrit çalışmalarda en yüksek doğruluğa sahip algoritma KA-YSA olurken birden fazla yöntemin kullanıldığı çalışmalarda karar ağacı yöntemi tahmin doğruluğunda diğer yöntemlerin gerisinde kalmıştır.

Tablo 4. Endeks Yön Tahmininde Karar Ağacı Yöntemi ile İlgili Yapılan Çalışmalar

Yazar/Yazarlar	Tahmin Modeli	Veri	Sonuç
Tsai ve Wang (2009)	KA-YSA, KA-KA YSA, KA	2002-2007 yılı temel, makroekonomik endeksler	Ortalama doğruluk sırasıyla %77.19, %66.85, %59.01, %65.4 olarak bulunmuştur.
Qiu vd. (2012)	C-Bulanık KA, k-EYK	1997-2006 yılları Shanghai Composite endeksi verileri	Önerilen modellerin tahmin doğruluğu yüksek bulunmuştur.
Yakut (2012)	C5.0 KA algoritması, DVM, YSA	2002-2010 yılları İMKB'deki 120 işletme	YSA'nın tahmin doğruluğu sonucu diğer yöntemlere göre daha yüksek bulunmuştur.
Rostami vd. (2015)	KA, KK, LogR	Tahran Borsa 1969-1977 yılları günlük verileri	Karlılıkta makine öğrenme algoritmaları daha iyi bulunmuştur.
Pehlivanlı vd. (2016)	DVM, J48, LogR ÇKA, RO	2007-2013, İMKB100 23 Teknik gösterge Günlük veri	Ortalama doğruluk sırasıyla %79.6, %71, %79.2, %79.5, %79 olarak bulunmuştur.

Endeks yön tahmini probleminde KA yöntemini ele alan ilk çalışmalardan biri Tsai ve Wang (2009) tarafından Tayvan Borsa'sında yapılmıştır. Yatırımcılara doğru kararlar vermede yardımcı olacak iyi bir yatırım karar destek sistemi oluşturmak isteyen yazarlar, veri seti olarak 2002-2007 yılları temel, teknik ve makroekonomik endeks olarak seçilen 53 değişkenin günlük verilerini kullanmışlardır. Çalışmada yatırımcıların hisse senedi yatırımında daha doğru karar vermelerine yardımcı olmak için yaygın olarak kullanılan YSA teknikleri ve KA daha iyi bir karar destek sistemi için birleştirilmiştir. Çalışmada kullanılan yöntemler KA-YSA, KA-KA, YSA ve KA'dır. Elde edilen bulgulara göre entegre KA-YSA modelinin %77 doğruluğa sahip olduğu tespit edilmiştir. Literatürde yaygın olmayan entegre KA-YSA modelini kullanan yazarlara göre, önerilen model YSA ve KA modellerinden daha yüksek doğruluğa ulaşmıştır.

Endeks yön tahmini probleminde KA yöntemini ele alan bir başka çalışmada, belirsiz zaman serilerine dayanan yeni bir tahmin modeli ve araştırmacılar için en ilginç konulardan biri olan hisse senedi endeksini tahmin etmek için C-bulanık KA geliştirmiştir. Qiu, Liu ve Wang (2012) tarafından yapılan çalışmada, Şanghai Borsası Kompozit Endeksi 01/01/1997–12/31/2006 arası döneme ait 10 yıllık günlük verileri kullanılmış ve tahmin yöntemleri olarak Ağırlıklandırılmış C-bulanık KA ve k-EYK kullanılmıştır. Çalışmada elde edilen sonuçlara göre, önerilen modelin sadece tahmin prosedürünü ve uygun parametreleri elde etmenin yolunu göstermekle

kalmadığı, aynı zamanda diğer modellerden daha iyi performans gösterdiği belirlenmiştir.

Yatırım kararlarında finansal başarısızlığı tahmin eden çalışmaların pek sık kullanılmadığını belirten Yakut (2012) finansal başarısızlığı tahmininde KA modelinin önemine işaret etmiştir. BİST 100'deki sanayi işletmelerinin finansal başarısızlığı tahmin modellemesini YSA, KA C5.0 algoritması ve DVM yöntemlerini kullanarak tahminleyen yazar, bu yöntemlerden hangisinin daha iyi doğruluk oranıyla tahmin yaptığını belirlemeye çalışmıştır. Bulgulara göre yöntemlerin finansal başarısızlığı doğru tahmin oranları sırası ile %86, %81, %74 olarak gerçekleşmiştir.

Endeks yön tahmini problemlerinde KA yönteminin doğru sınıflandırma oranını araştıran Rostami vd. (2015) karşılaştırmak için Kaba Küme (KK) ve DR yöntemlerini kullanmışlardır. 9 yıllık bir dönemde yer alan günlük verilerini kullanan yazarlara göre endeksin yönünü en iyi tahmin eden model makine öğrenmesi algoritmalarıdır. Araştırma sonucunda elde edilen bulgulara göre makine öğrenmesi algoritması Tahran Menkul Kıymetler Borsası endeksini tahmin etmek için güvenilir bir yöntem olarak kullanılabilir. Yazarlara göre bunun nedeni makine öğrenmesi modellerinin geleneksel yöntemlere göre daha esnek ve problemlere uyarlanabilir olmasından kaynaklanmaktadır.

Pehlivanlı, Aşıkil ve Gülay (2016) tarafından yapılan çalışmada ise BİST 100 endeksinin endeks yön tahmini yapılmış ve endeksi en iyi tahmin eden makine öğrenmesi modeli araştırılmıştır. BİST 100 endeksinin 01/04/2007 ve 01/31/2013 tarihleri arasında günlük olarak verilen 90 hisse senedi için farklı teknik göstergeler uygulanarak elde edilen veri setinin kullanıldığı çalışmada, DVM, J48, LogR, ÇKA ve Rastgele Orman (RF) modelleri karşılaştırılarak, endeks yön tahmini için doğruluk oranını en yüksek hesaplayan modelin DVM olduğu tespit edilmiştir.

Son olarak Tsai ve Wang (2009) tarafından Tayvan elektronik endüstrisi üzerine yapılan çalışmada, entegre KA-YSA yönteminin endeks yön tahmininde YSA'ya karşı üstünlük sağladıkları belirlenmiştir.

2.1.4. Naive Bayes ile İlgili Yapılan Çalışmalar

Endeks yön tahmini yapılan çalışmalarda daha çok YSA ve DVM yöntemleri kullanılmış olsa da, literatür taramasında NB yönteminin kullanıldığı çalışmalara rastlamak da mümkündür. Sadece NB yönteminin (Malagrino, Roman ve Monteiro, 2018) tarafından kullanıldığı çalışmalar olduğu gibi birden fazla yöntemle birlikte NB'nin kullanıldığı çalışmalara (Dash ve Dash, 2016b; Filiz, Karaboğa ve Akoğul, 2017; Tekin ve Çanakoglu, 2018) literatürde rastlanmaktadır.

Tablo 5'e göre endeks yön tahmini amacıyla yapılan çalışmalarda, sadece NB yönteminin kullanıldığı Malagrino, Roman ve Monteiro (2018) tarafından yapılan çalışmada tahmin doğruluğu çok başarılı sonuç vermiştir. Birden fazla tahmin yönteminin kullanıldığı çalışmalarda ise NB, ortalama doğruluk oranları seviyesinde tahminlemeler yapmıştır.

Tablo 5. Endeks Yön Tahmininde Naive Bayes Yöntemi ile İlgili Yapılan Çalışmalar

Yazar/Yazarlar	Tahmin Modeli	Veri	Sonuç
Dash ve Dash (2016b)	CEFLANN, DVM, NB, k-EYK, KA	2010-2014 yılları BSE ve S&P500 6 Teknik gösterge	Önerilen model diğerlerinden daha üstün kar yüzdesi sağlar.
Filiz vd. (2017)	k-EYK, NB, C4.5, YSA	BİST 50 endeksi 2006-2016 Makroekonomik göstergeler	Ortalama doğruluk sırasıyla %90.16, %92.2, %92.7, %92.05 bulunmuştur.
Malagrino vd. (2018)	NB	2005-2012 yılları 12 borsanın günlük veri	Ortalama doğruluk %77.78 bulunmuştur.
Tekin ve Çanakoglu (2018)	DR, ÇKA, RO, RT NB, DVM	BİST, 25 şirket 2010-2017, 12 Teknik gösterge verisi	Doğruluk %53.4, %53.8, %57.3, %51.5, %53.17, %52.7 bulunmuştur.

Dash ve Dash (2016b) tarafından yapılan çalışmada, BSE SENSEX ve S&P500 endekslerinin hisse senedi alım satım karar tahmininin problemi Hesaplamalı Verimli Fonksiyonel Bağlantı YSA (CEFLANN), DVM, NB, k-EYK, KA yöntemleri ile belirlenmeye çalışılmıştır. 2010-2014 yılları BSE SENSEX ve S&P500 endeksinin beş yıllık zaman serisi hisse senedi endeksi fiyat değerleri kullanılan çalışmada, teknik göstergelere dayanan endeks fiyat tahminleri bulunmaya çalışılmıştır. Yaklaşımın yeniliği, CEFLANN sinir ağının öğrenme becerisinin teknik analiz kuralları ile entegrasyonu yoluyla karlı hisse senedi alım satım kararlarını vermektir. Çalışmanın sonuçlarına göre teknik göstergelere dayanan alım satım

kararını almak yerine, teknik göstergelerin entegre edildiği yapay zeka algoritmalarıyla birleştirilmesi yoluyla alım satım kararının alınması daha karlıdır.

BIST-50 endeksinin değişiminin yönünü inceleyen Filiz, Karaboğa ve Akoğul (2017) çalışmalarında bu etkiyi NB, k-EYK, C4.5 ve YSA yöntemleri ile belirlemeye çalışmıştır. BİST-50 endeksinin makine öğrenmesi yöntemleri ile analiz edildiği çalışmanın veri seti 2006–2016 döneminde 2591 işlem gününü kapsayan günlük makroekonomik verilerden oluşmaktadır. Makine öğrenmesi yöntemleri kullanılarak yapılan endeks yön tahmininde yazarlar, BIST-50 endeksinin değişiminin yönünü sırası ile %92.2, %90.16, %92.7, %92.05 oranları ile doğru sınıflandırıldığı sonucuna ulaşmışlardır.

Borsa endeksi hareket yönü tahminini NB yöntemi kullanarak inceleyen Malagrino, Roman ve Monteiro (2018) dünya çapındaki 12 borsa endeksinin iBOVESPA'yı ne ölçüde etkilediğini amaçlamışlardır. iBOVESPA endeksinin 2005-2012 dönemine ait 2501 günlük verisini kullanan yazarların elde ettiği sonuçlara göre, incelenen konfigürasyondaki doğruluk oranı %77.78'dir.

Borsa endeksi hareket yönü tahminini NB yöntemi kullanarak inceleyen bir başka çalışma ise Tekin ve Çanakoğlu (2018) tarafından yapılmıştır. NB, DR, ÇKA, RF, Rastgele Ağaç (RT) ve DVM yöntemlerinin kullanıldığı çalışmanın veri seti ise BİST'te işlem gören 25 şirketin 2010-2017 dönemi toplam 1928 günlük 12 teknik gösterge verisinden oluşmuştur. Borsa endeksi hareket yönü tahmini için girdi verisi olarak 3 ayrı veri seti üzerinde analizler gerçekleştirilmiştir. Elde edilen bulgulara göre %53.17 doğruluk oranı ile NB algoritmasının en yüksek sonuçlardan birini veren algoritma olduğu tespit edilmiştir.

2.1.5. K-En Yakın Komşuluk ile İlgili Yapılan Çalışmalar

Son yıllarda endeks tahmininde sınırlı sayıda çalışmada kullanılmaya başlayan k-EYK yöntemi tekli (İlarslan, 2016; Nakagawa, Imamura ve Yoshida, 2017) veya en fazla iki yöntemin (Alkhatib vd., 2013; Chahardoli, Yaghubi ve Esmaeilpour, 2015) literatürde birlikte kullanıldığı belirlenmiştir.

Tablo 6'ya göre, tekli veya en az iki yöntemin birlikte kullanıldığı çalışmalarda k-EYK'nın tahmin gücünün yüksek olduğu görülmüştür. Çalışmalardan elde edilen sonuçlara göre, sadece k-EYK ile yapılan çalışmalarda ortalama doğruluk yüksek

çıkmiştir. Birden fazla yöntemin kullanıldığı çalışmalarda ise Alkhatib vd. (2013) k-EYK'yı başarılı bulurken, Chahardoli, Yaghubi ve Esmaeilpour (2015) ise Kaba kümeleri k-EYK'ya göre daha başarılı bulmuştur.

Tablo 6. Endeks Yön Tahmininde k-En Yakın Komşuluk Yöntemi ile İlgili Yapılan Çalışmalar

Yazar/Yazarlar	Tahmin Modeli	Veri	Sonuç
Alkhatib vd. (2013)	k-EYK, Regresyon	Ürdün borsası 2009 yılı 200 günlük veri	k-EYK finansal tahminde başarılı olmuştur.
Chahardoli vd. (2015)	k-EYK, KK	2006-2015 arası Tahran Borsası Endeksi verileri	KK, k-EYK'a göre tahmin doğruluğu daha yüksektir.
İlarslan (2016)	k-EYK	2015 BİST'e kote Afyon Çimento günlük veri	Ortalama doğruluk %97 bulunmuştur.
Nakagawa vd. (2017)	k-EYK, IDTW	Nikkei 225 Endeksi günlük verileri	Önerilen yöntemin diğerlerine göre tahmin gücü yüksek bulunmuştur.

Borsa endeksi hareket yönü tahminini k-EYK yöntemini kullanarak inceleyen çalışmalardan biri Alkhatib vd. (2013) tarafından yapılmıştır. Ürdün borsasında 4 Haziran 2009-24 Aralık 2009 dönemine ait 5 şirketin günlük verilerini kullanan yazarlar, endeks tahminlerinde k-EYK'nın uygulanabilirliğini araştırmışlardır. Çalışmada elde edilen bulgulara göre k-EYK algoritması kararlı ve küçük bir hata oranıyla iyi sonuçlar vermiştir ayrıca, gerçek hisse senedi fiyatları verilerine bağlı olarak; tahmin sonuçları gerçek fiyatlara yakın bulunmuştur.

Chahardoli, Yaghubi ve Esmaeilpour (2015) yaptıkları çalışmada, Tahran Menkul Kıymetler Borsası'nda listelenen hisse senetlerinin fiyatını tahmin etmek için k-EYK yöntemi kullanılmıştır. 29 şirketin 2006-2015 yılları arası dönemi kapsayan toplam 2484 günlük verinin kullanıldığı çalışmada k-EYK ile sonuçları karşılaştırmak için KK yöntemi kullanılmıştır. Çalışmada, KK yönteminin k-EYK modelinden daha iyi bir sonuç verdiği belirlenmiştir.

Hisse senedi fiyatları ertesi gün tahmini için k-EYK algoritmasını inceleyen İlarslan (2016) yapmış olduğu çalışmasında, 2014-2015 dönemini kapsayan BİST'e kote olan Afyon Çimento şirketinin 317 günlük verileri kullanarak analizlerini yapmıştır. Tahmini fiyatların gerçek fiyatlardan sapma oranının %3 olduğunu belirten yazar, Afyon Çimento hisse senedinin ertesi gün fiyatının gerçeğe çok yakın

değerlerle tahmin edildiği sonucuna ulaşmıştır. Çalışmada, düşük hata oranı veren k-EYK algoritmasının etkili bir tahminleyici olduğu belirlenmiştir.

Nakagawa, Imamura ve Yoshida (2017) tarafından yapılan çalışmada ise hisse senedi fiyatlarını öngörmek için k-EYK yöntemi kullanılmıştır. Çalışmanın veri seti 2015-2016 dönemi günlük verilerinden oluşmuştur. Çalışmada hisse senedi fiyatlarını tahmin etmek ve kullanıcılara bilinçli yatırım kararları vermede yardımcı olmak için Artımlı Dinamik Zaman Eğrisi (IDTW) ile k-EYK algoritması kullanılmıştır. Elde edilen bulgulara göre, önerilen yöntemin aylık hisse senedi fiyat değişikliklerini diğer yöntemlere göre tahmin etmede daha etkili olduğu bulunmuştur.

2.1.6. Lojistik Regresyon ile İlgili Yapılan Çalışmalar

Endeks yön tahmininde LogR yöntemini ele alan çalışmaların sınırlı sayıda olduğu literatür taramasında görülmüştür. Ege ve Bayrakdaroğlu (2009) tarafından yapılan çalışmada sadece LogR yöntemi kullanılmış iken bazı (Subha ve Nambi, 2012; Ballings vd., 2015; Gündüz, Yaslan ve Çataltepe, 2017) çalışmalarda ise birden fazla yöntemin birlikte kullanıldığı tespit edilmiştir.

Endeks yön tahmininde yöntemlerin tahmin doğruluklarının performanslarını karşılaştırılan çalışmaların sonuçlarını gösteren Tablo 7 incelendiğinde ise geleneksel bir istatistik model olan LogR genellikle makine öğrenmesi modellerinin gerisinde kaldığı gözlemlenmiştir. Ege ve Bayrakdaroğlu (2009) tarafından yapılan çalışma sonuçlarına göre LogR yönteminin %88.9 gibi yüksek bir tahmin doğruluğu bulunmuştur. Buna karşın birden çok yöntemin birlikte kullanıldığı Subha ve Nambi (2012) tarafından yapılan çalışmada LogR, k-EYK'nın çok gerisinde kalırken diğer çalışmalarda ise yakın tahmin doğruluk değerleri elde edilmiştir.

Tablo 7. Endeks Yön Tahmininde Lojistik Regresyon Yöntemi ile İlgili Yapılan Çalışmalar

Yazar/Yazarlar	Tahmin Modeli	Veri	Sonuç
Ege ve Bayrakdaroğlu (2009)	LogR	2004 yılı 30 şirketin Finansal oran değerleri	Ortalama doğruluk %88.9'dur
Subha ve Nambi (2012)	k-EYK, LogR	2010-2011 BSE-SENSEX, NSE-NIFTY Endeks verileri	Ortalama doğruluk sırasıyla %88.74, %58.87 bulunmuştur.

Ballings vd. (2015)	RO, AdaBoost, YSA, LogR, DVM, k-EYK	2009-2010 yılları Halka açık 5767 Avrupa şirket veri	Sonuçlar, RO'nin en iyi algoritma olduğunu göstermektedir
Gündüz vd. (2017)	CNN, LogR	2011-2015 yılları BİST100 25 teknik gösterge verisi	Ortalama doğruluk sırasıyla %56.3, %54.5'tir.

Ege ve Bayrakdaroğlu (2009) tarafından yapılan çalışmada, LogR yöntemiyle İMKB 30 hisse senetlerinin getiri performansı araştırılmıştır. Çalışmada veri seti olarak, 2004 yılının 12 aylık mali tablo verileri kullanılarak 30 şirketin 20 finansal oran değerleri hesaplanarak kullanılmıştır. Çalışmada elde edilen bulgulara göre LogR yönteminin hisse senetlerinin getiri performansı için doğruluk oranı %88.9 bulunmuştur.

LogR yöntemiyle hisse senedi endeks yönünü tahminlemeyi amaçlayan bir başka çalışma Subha ve Nambi (2012) tarafından yapılmıştır. BSE-SENSEX ve NSE-NIFTY endeks hareket yönünün tahminlemesi amacıyla k-EYK ve LogR yöntemlerinin kullanıldığı çalışmada, Temmuz 2010 ile Mayıs 2011 arasındaki 231 günlük veri seti analizlerde kullanılmıştır. Çalışmadan elde edilen bulgulara göre k-EYK sınıflandırıcısının sonuçları LogR modeli ile karşılaştırılmış ve k-EYK sınıflandırıcısının BSE-SENSEX ve NSE-NIFTY'nin gelecekteki hareketini daha doğru bir şekilde sınıflandırdığı için geleneksel LogR yönteminden daha üstün olduğu görülmüştür.

Endeks yönü tahminlemeyi amaçlayan bir diğer çalışma Ballings vd. (2015) tarafından yapılmıştır. Yazarlar YSA, LogR, DVM ve k-EYK'ya ile RO ve AdaBoost algoritmalarını karşılaştırmıştır. 2009-2010 arası döneme ilişkin halka açık 5767 Avrupa şirket verisinin kullanıldığı çalışmada AUC eğrisi performans ölçümü olarak kullanılmıştır. Çalışmadan elde edilen sonuçlara göre yöntemlerin doğru sınıflandırma sırası RO, DVM, AdaBoost, YSA, k-EYK ve LogR şeklinde gerçekleşmiştir.

Gündüz, Yaslan ve Çataltepe (2017) tarafından yapılan çalışmada ise BİST 100 hisselerinin gün içi yönünü öngörmek amaçlanmıştır. LogR ve Evrişimsel Sinir Ağı (CNN) modellerinin kullanıldığı çalışmanın veri seti ise 2011-2015 dönemi BİST 100'de listelenen 100 firmanın saatlik fiyat hareket ve 25 teknik gösterge verilerinden oluşmuştur. Çalışmanın sonuçları, CNN-Korelasyon rastgele sıralanan

özellikleri kullanan hem LogR hem de CNN-Rastgele'den daha üstün olduğunu göstermektedir.

2.1.7. Doğrusal Diskriminant Analizi ile İlgili Yapılan Çalışmalar

Endeks yön tahmininde geleneksel istatistiki yöntemlerden olan DDA yöntemini ele alan sınırlı sayıda çalışma bulunmaktadır. Bu çalışmalardan Öz, Ayrıçay ve Kalkan'ın (2011) yaptığı çalışmada sadece DDA yöntemini kullanırlarken, bazı (Huang, Nakamori ve Wang, 2005; Ou ve Wang, 2009; Akyatan, 2016) çalışmalarda ise birden çok yöntem birlikte karşılaştırılmıştır.

Tablo 8'e göre, endeks yön tahmininde DDA yöntemi kullanılarak yapılan çalışmalardan Öz, Ayrıçay ve Kalkan (2011) %91.7 gibi yüksek tahmin doğruluğu elde etmiştir. Birden çok yöntemin birlikte kullanıldığı diğer çalışmalarda Huang, Nakamori ve Wang (2005) ve Ou ve Wang (2009) DVM'nin daha iyi sonuçlar verdiğini bulurken Akyatan (2016) ise LogR ve DDA'nın birbirine yakın sonuçlar verdiğini bulmuştur.

Tablo 8. Endeks Yön Tahmininde Doğrusal Diskriminant Analizi Yöntemi ile İlgili Yapılan Çalışmalar

Yazar/Yazarlar	Tahmin Modeli	Veri	Sonuç
Huang vd. (2005)	DDA, DVM, RW, QDA, BPNN	1990-2002 NIKKEI 225 Endeks ve Makroekonomik günlük verileri	Sonuçlar, DVM'nin daha iyi sınıflandırma metodu olduğunu göstermiştir.
Ou ve Wang (2009)	DDA, QDA, k-EYK, NB, DVM, YSA, LS-DVM	2000-2006 yılları Hang Seng Endeksi günlük verileri	DVM ve LS-DVM diğer modellere göre daha üstün öngörüdür.
Öz vd. (2011)	DDA	2005-2007 yılları İMKB-30 Finansal oran değerleri	DDA Ortalama doğruluk %91.7 olarak bulunmuştur.
Akyatan (2016)	LogR, DDA	2008-2010 yılları İMKB-100 Finansal oranlar	LogR ve DDA birbirine yakın sonuçlar vermiştir

Huang, Nakamori ve Wang (2005) tarafından yapılan çalışmada, DDA ile Tokyo Borsası'nda işlem gören 225 yüksek sermayeli hisse senedinin bileşik fiyat performansı tahmin edilmeye çalışılmıştır. Çalışmanın veri seti NIKKEI 225 endeksinin 1990-2002 yılları arasındaki toplam 676 gözlem periyodundan oluşmaktadır. Tahmin performansları karşılaştırma için DDA, DVM, RW, Kuadratik Diskriminant Analizi (QDA) ve BPNN yöntemlerinin kullanıldığı çalışmanın sonucunda DVM'nin diğer sınıflandırma yöntemlerini geride bıraktığı belirlenmiştir.

Ayrıca yazarlar diğer sınıflandırma yöntemleri ile DVM entegre edilerek birleştirilen bir model önermişlerdir.

Hang Seng endeksinin kapanış fiyatlarının günlük değişimlerini ölçmeyi amaçlayan Ou ve Wang (2009) çalışmalarında DDA, QDA, k-EYK, NB, DVM ve En Küçük Kareler-DVM (LS-DVM) yöntemlerini kullanmışlardır. Hang Seng endeksi 2000-2006 arasındaki döneme ait 1732 günlük veri seti kullanılan çalışmada değişken olarak beş makroekonomik faktör belirlenmiştir. Elde edilen bulgulara göre DVM ve LS-DVM diğer modellere göre daha iyi performans göstermiştir. Ayrıca SVM örneklem içi tahminde LS-DVM'den daha iyi, ancak LS-DVM, doğruluk oranı ve hata oranı kriterleri açısından örnek dışı tahminler için DVM'den daha iyi performans sergilemiştir.

BİST 30 endeksindeki hisse senetlerinin getirilerinin öngörülerini yaparak karşılaştırmayı amaçlayan Öz, Ayırcay ve Kalkan (2011), DDA yöntemini kullanarak bir çalışma gerçekleştirmişlerdir. 2005-2007 yılları arası BİST 30 şirketlerinin finansal oran değerlerinin veri seti olarak kullanıldığı çalışmada, model için kanonik diskriminant fonksiyonu katsayıları kullanılmıştır. DDA sonucunda elde edilen bulgulara göre doğru sınıflandırma oranları karşılaştırıldığında iki yıl öncesi algoritmanın (%91,7) bir yıl öncesi algoritmaya (%75) göre daha üstün olduğu tespit edilmiştir.

Son olarak hisse senetlerinin getiri performansını ele alan Akyatan (2016) ise DDA ile LogR yöntemlerini karşılaştırmıştır. 2008–2010 döneminde BİST 100 endeksindeki 65 imalat işletmesinin hesaplanan finansal oranlarının veri seti olarak kullanıldığı çalışmada, hisse senetlerinin getiri performansı tahmininde en iyi yöntemin belirlenmesi amaçlanmıştır. Çalışmada, LogR analizi ve DDA'nın başarı tahmini birbirine yakın sonuçlar vermiştir.

2.1.8. Sınıflandırmaya Yönelik Çalışmalara İlişkin Genel Değerlendirme

Literatür araştırması sırasında da belirlendiği gibi, endeks yön tahmini üzerine yapılan çalışmaların genel amacı sınıflandırma yöntemlerinin tahmin doğruluk oranlarını belirlemektir. Bu durumda sınıflandırma yöntemlerinin tespit edilen sonuçlarına göre:

1. YSA yöntemi çalışmaların çoğunda diğer yöntemlere göre üstünlük sağlamıştır,
2. Endeks yön tahmininde bazı çalışmalara göre DVM güçlü bir yöntemdir,
3. Karar Ağaçlarının çok başarılı sonuçlar çıkaramadığı tespit edilmiştir,
4. Birden fazla tahmin yönteminin kullanıldığı çalışmalarda ise NB ortalama doğruluk oranlarında tahminlemeler yapmıştır,
5. Çalışmada k-EYK yönteminin bazı çalışmalarda başarılı olduğu, bazılarında ise geride kaldığı görülmüştür,
6. Lojistik Regresyonun ve Doğrusal Diskriminant Analizinin ise genellikle makine öğrenmesi modellerinin gerisinde kaldığı sonuçları ortaya çıktığı tespit edilmiştir.

Endeks yön tahmini performans karşılaştırmalarının sadece yöntemler üzerinden yapılması, araştırmacılar açısından eksik kalmış sonuçlar ortaya çıkaracaktır. Bundan dolayı performans karşılaştırmalarının kullanılan yöntemle birlikte veri seti -teknik göstergeler- üzerinden yapılması gerekliliği bu tez çalışmasının ana amacını oluşturmaktadır.

2.2. ENDEKS YÖN TAHMİNİNDE TEKNİK GÖSTERGELERİN KULLANILDIĞI ÇALIŞMALAR

Çalışmanın bir önceki bölümünde sınıflandırma yöntemlerinden makine öğrenmesi yöntemleri ile geleneksel istatistikî yöntemlerin tahmin doğruluğu performansları karşılaştırılmıştır, çalışmanın bu bölümünde ise teknik göstergelerin girdi verisi olarak kullanıldığı sınıflandırma yöntemlerinin endeks yönü tahmin performanslarının karşılaştırıldığı çalışmalara yer verilmiştir.

Endeks yön tahmininde fiyat korelasyonları kurma, borsa trend döngülerini keşif veya klasik olarak grafik analizleri yapılarak doğru tahminler yapılmaya çalışılır. Teknik analizciler, piyasadaki fiyat ve hacim dönüşümlerini temel alan fiyat eğilimlerini ve piyasa trendlerini tanımlamak için birçok veri, teknik araç ve özellikle teknik göstergeler ile çalışırlar. (Chen vd., 2014: 329).

Modellere girdi olarak sürekli değerli teknik göstergeler verdiğimizde teknik göstergelerin değerlerine göre sınıflandırılacak tahmin modelleri oluşturulur. Hisse senedi değerlerinin geçişinden elde edilen bilgiler kaybolur ve tahmin modelleri

tarafından kullanılmaz böylece verilerin mevsimsellik etkisi azaltılmış olur (Patel vd., 2015: 266).

Endeks yön tahmini veya hisse senedinin gelecekteki fiyatını tahmin etmek istendiğinde sürekli değerli teknik göstergelerin kullanılması daha doğru tahminler yapılmasını sağlar. Eğilim belirleyici verilerle yani teknik göstergelerle hareketin veya trendin yönünü tahmin etmesinin amaçlandığından teknik göstergelerin kullanılması tahmin doğruluğunu artırır (Yao, Tan ve Poh, 1999: 222).

Teknik göstergelerin girdi verisi olarak kullanıldığı sınıflandırma yöntemlerinde, yöntemlerin performansı genellikle iki şekilde değerlendirilir. Bunlardan ilki yapılan tahminler ile gerçekteki değerlerin karşılaştırılması sonucu bulunan tahmin doğruluk oranı ve ikincisi ise yapılan tahminlerin gerçek değerlerden ne kadar uzaklaştığını gösteren hata metrikleridir. Bu tez çalışmasında yöntemlerin performansını değerlendirmede her iki yol da kullanılmıştır. Böylece iki yönlü performans karşılaştırması yapılarak sonuçların doğrulanması amaçlanmıştır.

Girdi verisi olarak teknik göstergelerin kullanıldığı çalışmalarda, endeks hareket yönü tahmininde sınıflandırma yöntemlerinin tahmin doğruluklarının performans karşılaştırmaları yapılarak en yüksek doğruluğu veren yöntem bulunmaya çalışılmıştır. Bu çalışma alanı güncel literatürde öne çıkan önemli araştırma alanlarından biridir.

Bundan dolayı tez çalışmasının bu bölümünde ilk önce yurtdışında yapılan endeks hareket yönü tahmini sınıflandırma yöntemlerinin performanslarının karşılaştırmalarına yer verilmiş daha sonra ise Türkiye’de yapılan çalışmalar ele alınmıştır.

2.2.1. Endeks Yön Tahmininde Teknik Göstergeler Kullanılarak Yurtdışında Yapılan Çalışmalar

Endeks yön tahmininde teknik göstergeleri girdi verisi olarak ele alan ve sınıflandırma yapan yöntemlerin kullanıldığı çalışmalar bu tezin konusunu oluşturmaktadır. Yurtdışında yapılan çalışmalar, genel olarak iki noktaya odaklanmaktadır. Bunlardan ilki, birden fazla sınıflandırma yönteminin yani hibrit yöntemlerin kullanılması, ikincisi ise yöntem performanslarının ölçülmesinde farklı metrikler yoluyla en yüksek tahmin doğruluğunu veren yöntemin belirlenmesidir.

Tablo 9'a bakıldığında yapılan çalışmaların bazılarında yalnız YSA modeli (Aldin, Dehnavi ve Entezari, 2012; Karymshakov ve Abdykaparov, 2012; Oliveira, Nobre ve Zárate, 2013; Gurjar vd., 2018) kullanılırken, diğer çalışmalarda ise (Yu, Wang ve Lai, 2005; Lu, 2010; Nair, Mohandas ve Sakthivel, 2010; Dash ve Dash, 2016a; Santoso, Sutjiadi ve Lim, 2018) hibrit yöntemler kullanılmıştır. Ayrıca on dört çalışmada (Yao, Tan ve Poh, 1999; Kim, 2003; Lahmiri, 2011; Dastgir ve Enghiad, 2012; Dunis vd., 2013; Lahmiri, Boukadoum ve Chartier, 2013; Chen vd., 2014; Wang ve Shang, 2014; Anbalagan ve Maheswari, 2015; Patel vd., 2015; Anish ve Majhi, 2016; Jabbarzadeh vd., 2016; Dash vd., 2019; Nadh ve Prasad, 2019) ise birden fazla yöntem tahmin doğruluğu performansını karşılaştırmak için kullanılmıştır.

Tablo 9. Teknik Göstergelerin Kullanıldığı Sınıflandırma Yöntemleri ile Yurtdışında Yapılan Çalışmalar

Yazar/Yazarlar	Tahmin Modeli	Veri	Sonuç
Yao vd. (1999)	YSA, ARIMA	1984-1991, KLCI 5 Teknik gösterge	YSA, ARIMA modeline kıyasla daha iyi olduğu görülmüştür.
Kim (2003)	DVM, BPNN ve CBR	1989-1998, KOSPI 12 Teknik gösterge	Ortalama doğruluk sırasıyla %64.75, %58.52, % 51.97 olarak bulunmuştur.
Yu vd. (2005)	GA-DVM, RW, DVM, ARIMA, BPNN	2000-2004, S&P 500 18 Teknik gösterge	GA-DVM'nin diğer modelleri geride bıraktığı görülmüştür.
Lu (2010)	ICA-BPNN, BPNN, RW, Wavelet-BPNN	2003-2006, TAIEX 6 Teknik gösterge	ICA-BPNN diğer modellerden daha iyi performans göstermiştir.
Nair vd. (2010)	KA-KK, YSA, NB	2003-2010, BSE-SENSEX 25 Teknik gösterge	Önerilen sistem diğer tahmin sistemlerini geride bırakmıştır.
Lahmiri (2011)	PNN, DVM	2000-2008, S&P 500 12 Teknik gösterge	Ortalama doğruluk sırasıyla %88.84, %83.26'dır.
Aldin vd. (2012)	YSA	2002-2009, TEPIX 10 Teknik gösterge	Endeks tahminleri için yapay sinir ağları baskın araçlardır.
Dastgir ve Enghiad (2012)	YSA, GA	2000-2008, TEPIX 5 Teknik gösterge	YSA ertesı gün tahminlerinin mümkün olduğunu göstermiştir.
Karymshakov ve Abdykaparov (2012)	YSA	2002-2007, İMKB 100 5 Teknik gösterge	Ortalama doğruluk %82.7 bulunmuştur.
Dunis vd. (2013)	DVM, YSA, AI ve Tut stratejisi	1990-2010, IBEX-35 2 Teknik gösterge	DVM'ler diğer yöntemlerden daha iyi sonuçlar üretmektedir.
Lahmiri vd. (2013)	k-EYK, PNN	2003-2008, S&P 500 12 Teknik gösterge	Ortalama doğruluk sırasıyla %93.45, %92.4'dir.

Oliveira vd. (2013)	YSA	2000-2011, BOVESPA 8 Teknik gösterge	Ortalama doğruluk %93.62'dir.
Chen vd. (2014)	Bulanık küme, Physica, DVR, PLSR	1998-2006, TAIEX 13 Teknik gösterge	Önerilen model RMSE'ye göre diğer modelleri geride bırakmıştır.
Wang ve Shang (2014)	LS-DVM, PNN, QDA, DDA	2005-2012, CSI 300 10 teknik gösterge	Ortalama doğruluk sırasıyla %89.12, %80.9, %87.92, %87.3 bulunmuştur.
Anbalagan ve Maheswari (2015)	RW, YSA, DVM, FM	BSE endeksi 2011-2012 4 Teknik gösterge	Ortalama doğruluk sırasıyla %50, %69, %73, %75'dir.
Patel vd. (2015)	NB, YSA, DVM, RO	2003-2012 CNX Nifty, BSE 10 Teknik gösterge	Ortalama doğruluk sırasıyla %89.84, %86.6, %88.69, %89.5 olarak bulunmuştur.
Anish ve Majhi (2016)	DWT, FLANN, DVM-ÇKA, RBFNN	2000-2012, DJIA- S&P500 8 teknik gösterge	Önerilen model ÇKA, RBFNN ve DVM'den üstündür.
Dash ve Dash (2016a)	RSFN-LF, ANFIS CEFLANN RCEFLANN,	2012-2014, BSE- S&P500 3 teknik gösterge	Önerilen model diğer modellere kıyasla daha etkindir.
Jabbarzadeh vd. (2016)	Doğrusal Olmayan Model (Probit, Logit ve Extreme Value)	2011-2015, S&P500 11 Teknik gösterge	Ortalama doğruluk sırasıyla %64.1, %62.69, %71.91'dir.
Gurjar vd. (2018)	YSA	2018, CNX S&P Nifty 50 4 Teknik gösterge	Kısa vadede biraz, uzun vadede kesin öngörü kabiliyeti bulunmuştur.
Santoso vd. (2018)	GMM-DVM	2000-2017, ASIIJK 9 teknik gösterge	Önerilen modelin tahmin kabiliyetini geliştirildiği bulunmuştur.
Dash vd. (2019)	TOPSIS, DVM, NB KA, k-EYK	2015-2017, BSE SENSEX, S&P500, 6 teknik gösterge	DVM ve k-EYK diğer modellerden daha iyi performans gösterir.
Nadh ve Prasad (2019)	GA, DVM, YSA	BM&FBOVESPA PETR4 endeksi 4 teknik gösterge	DVM, YSA'dan daha iyi performans göstermiştir.

Borsa endeks yön tahmininde girdi verisi olarak teknik göstergelerin kullanıldığı ilk çalışmalardan biri Jingtao Yao, Chew Lim Tan ve Hean-Lee Poh (1999) tarafından yapılmıştır. Kuala Lumpur Borsasından (KLCI) elde edilen 1984-1991 yılları arasındaki 1911 günlük veri kullanarak endeks yön tayinini yapmayı amaçlayan yazarlar, çalışmalarında YSA algoritmasını kullanmışlardır. Teknik göstergelerden hareketli ortalama (HO), momentum (MOM), Relative Strength Index (RSI), stokastik (%K) ve stokastik (%D)'yi sinir ağını eğitmek için kullanmışlardır. Yeniden ölçeklendirilmiş aralık analizine dayalı olarak geriye doğru yayılan bir sinir ağı, teknik göstergeler ile zaman içinde çalışılan piyasadaki endeksin seviyeleri arasındaki ilişkiyi yakalamak için kullanılmıştır. Sonuçlar, YSA modelinin geleneksel ARIMA modellerine kıyasla daha iyi endeks yön tahmini yaptığını

göstermiştir. Araştırma ayrıca, geniş piyasa verileri veya bilgisi kullanılmadan yararlı tahminlerin yapılabileceğini de göstermiştir.

Kore bileşik hisse senedi fiyat endeksi (KOSPI) hareket yönünü tahminini ele alan Kim (2003) DVM, BPNN ve Vaka Temelli Akıl Yürütme (CBR) modellerini karşılaştırmıştır. Ocak 1989 ile Aralık 1998 arasında 2928 günlük verinin kullanıldığı çalışmada, endeks yön tahmininde uygun yöntemin bulunması hedeflenmiştir. Girdi verisi olarak 12 teknik gösterge (%K, %D, yavaş %D, Mom, fiyat değişim oranı, Will's %R, A/D, farklılık 5-günlük, farklılık 10-günlük, fiyat, CCI, RSI) kullanılmıştır. Doğruluk oranları DVM, BPNN ve CBR yöntemleri için sırasıyla %64.75, %58.52 ve % 51.97 olarak bulunmuştur.

Endeks yön tahmininde yöntemlerin performansını karşılaştıran bir başka çalışmada, Yu, Wang ve Lai (2005) S&P500 borsası ele alınmıştır. Gelişmiş bir borsa olan S&P 500 hisse senedi fiyat endeksindeki veri seti ise 1 Ocak 2000-31 Aralık 2004 arası günlük verilerden oluşmuştur. Çalışmada, analiz tekniği olarak ise entegre akıllı veri madenciliği metodolojisi, genetik algoritma tabanlı destek vektör makinesi (GA-DVM) modeli, rasgele yürüyüş (RW) modeli, otoregresif entegre hareketli ortalama (ARIMA) modeli, geri yayımlı sinir ağı (BPNN) modeli ve DVM modelleri borsa eğilimini araştırmak için kullanılmıştır. Çalışmada girdi değişkenleri olarak 18 teknik gösterge (Fiyat, stokastik, hareketli stokastik, yavaş stokastik, fiyat değişim oranı, HO, hareketli varyans, hareketli varyans oranı, üstel HO, MACD, A/D, farklılık (5-günlük), farklılık (10-günlük), fiyat osilatörü, CCI, RSI, doğrusal regresyon çizgisi) kullanılmıştır. Çalışmada GA-DVM'nin tahmin yeteneğini değerlendirmek için, performansı geleneksel yöntemlerle ve YSA ile karşılaştırılmıştır. Ampirik sonuçlar GA-DVM'nin diğer tahmin modellerini geride bıraktığını ve önerilen yaklaşımın borsa eğiliminin araştırılmasında gelecek vaat eden bir alternatif olduğunu göstermiştir.

Lu (2010) tarafından yapılan çalışmada, endeks yön tahmini için Tayvan ve Japonya borsa endeksleri ele alınmıştır. Önerilen nöral ağa sahip entegre bağımsız bileşen analizi (ICA-BPN) tahmin modelinin performansını değerlendirmek için, çalışmada günlük TAIEX kapanış nakit endeksi ve Nikkei 225 açılış nakit endeksi kullanılmıştır. TAIEX kapanış nakit endeksinin tahmininde, teknik göstergeler stok

fiyat tahmininde en çok kullanılan özellikler olduğundan, teknik göstergeler tahmin değişkenleri olarak kullanılmıştır. Çalışmada TAIEX nakit endeksinin 2 Ocak 2003 - 27 Şubat 2006 tarihleri arasındaki teknik göstergeleri ve nakit fiyatlarının günlük verileri analizlerde kullanılmıştır. Girdi verisi olarak 6 teknik göstergenin (en yüksek fiyat, en düşük fiyat, hacim, RSI (6), bugünkü açılış fiyatı ve 10 gün toplam tutarı hisse senedi fiyatı endeksi (TAPI 10)) kullanıldığı çalışmada ICA-BPN, BPNN ve Wavelet-BPN ile Rastgele Yürüyüş (RW) modellerinin endeks yön tahmin performansları karşılaştırılmıştır. Sonuçlar, önerilen modelin en düşük tahmin hatası ve en yüksek tahmin doğruluğunu üretebildiğini ve BPNN modeli ve RW modeli ile entegre Wavelet-BPNN modellerinden daha iyi performans sergilediğini göstermiştir.

Bombay Menkul Kıymetler Borsası'nda (BSE-SENSEX) sonraki günlerin eğilimini tahmin etmek için bir hibrit Karar Ağacı (KA)-Kaba Küme (KK) tabanlı sistemin tasarım ve performans değerlendirmesini amaçlayan Nair, Mohandas ve Sakhivel (2010) çalışmasında değişken olarak 25 teknik gösterge kullanmıştır. Çalışmada BSE-SENSEX'te 3 Eylül 2003'den 7 Mart 2010'a kadar olan döneme ait 1625 günlük veri seti ile KA, KK, YSA, NB yöntemleri kullanılmıştır. Bu çalışmada, BSE-SENSEX verilerinden elde edilen özelliklerin çıkarılması için teknik göstergeleri (pozitif hacim, negatif hacim, dengede hacim, fiyat hacim trendi, RSI, en yüksek fiyat, en düşük fiyat, MACD çizgi, MACD dokuz dönem, MOM, %K, %D, Chaikin's volatilité, Will's %R, tipik fiyat, fiyat değişim oranı, ortalama fiyat, ağırlıklı kapanış, A/D, Bolinger artan, Bolinger orta, Bolinger azalan, HO-25 günlük, HO-65 günlük) kullanılmıştır. İlgili özellikleri seçmek için C4.5 karar ağacı, daha sonra çıkarılan özelliklerden kurallar oluşturmak için ise kaba küme tabanlı sistem kullanılmıştır. Hibrit kaba küme tabanlı sistemin performansı yapay sinir ağı tabanlı eğilim tahmin sistemi ve NB tabanlı eğilim tahmincisi ile karşılaştırılmıştır. Sonuçlar, önerilen sistemin hem nöral ağ tabanlı sistemi hem de NB trend tahmin sistemini geride bıraktığını göstermiştir.

Lahmiri (2011) yaptığı çalışmada, makroekonomik bilgilerin ve teknik göstergelerin, sınıflandırıcıların doğruluğu üzerindeki etkisini incelemiştir. S&P500 günlük getiri ve aynı zamanda ekonomik değişkenlerden oluşan verilerin kullanıldığı çalışmada, endeks yön tahmini için Olasılıksal Sinir Ağları (PNN) ve DVM

analizlere dahil edilmiştir. 11 Ocak 2000'den 31 Ocak 2008'e kadar olan günlük veri setinin kullanıldığı çalışmada, girdi verisi olarak 12 teknik gösterge (HO, fiyat değişim oranı, MOM, %D, yön göstergesi yayılması, kaydırma oranı, çoğunluk kuralı, %K, X1, X2, X3, X4) hesaplanarak en iyi tahmin için en uygun model bulunmaya çalışılmıştır. PNN ve DVM modellerinin doğruluk oranları sırası ile %88.84 ve %83.26 bulunmuştur.

Lahmire, Boukadoum ve Chartier (2013) tarafından yapılan çalışmada k-EYK ve PNN modelleri kullanılarak yatırımcı ruh halleri ile S&P500 trendlerinin tahmini yapılmıştır. 2003-2008 yılları dönemini kapsayan on bir ekonomik faktör, on iki teknik gösterge (HO, fiyat değişim oranı, MOM, %D, yön göstergesi yayılması, kaydırma oranı, çoğunluk kuralı, %K, X1, X2, X3, X4) ve dört yatırımcı ruh hali ölçümü, potansiyel tahmin edici değişkenler olarak seçilmiştir. Araştırmada elde edilen bulgular, k-EYK ve PNN'nin ortalama algılama oranının sırasıyla %93.45 ve %92.4 olduğunu göstermiştir. Sonuçlar, k-EYK ile ekonomik, teknik ve psikolojik bilgi kategorilerini birlikte sınıflandırıcı olarak birleştirmenin, gelecekteki borsa iniş ve çıkışlarının yüksek tespit doğruluğuna yol açtığını ortaya koymuştur.

Aldin, Dehnavi ve Entezari (2012), teknik göstergelerin kullanılmasının etkinliğini ve Tahran Borsası Fiyat Endeksinin (TEPIX) hareket yönünün tahmini için YSA modelini kullanmıştır. Bu çalışmanın istatistiksel popülasyonu 31 Aralık 2002-18 Şubat 2009 tarihleri arasında TEPIX'in toplam fiyat endeksinin içeren 1430 örneklemeden oluşmaktadır. Girdi verisi olarak HO, AHO, RSI, MACD, CCI, A/D, MOM, %K, %D ve Will's %R teknik göstergeleri kullanılarak endeks yön tayini yapılmaya çalışılmıştır. Çalışma sonuçlarına göre YSA'nın, hisse senedi fiyat endeksi hareketinin yönünü tahmin etmede güçlü bir model olduğu belirlenmiştir.

Dastgir ve Enghiad (2012) çalışmalarında YSA ve GA modellerinin endeks yön tahmin performanslarını kıyaslamışlardır. Çalışma, İran hisse senedi piyasasının en önemli endeksi TEPIX tahmini üzerinde durulmuştur. Bu kapsamda 2000 yılından 2008 yılına kadar olan 9 yıllık dönem için 2000 günlük veri seti kullanılmıştır. Veriler temel ve teknik veriler olarak ikiye ayrılmıştır. Kullanılan temel veriler Dolar/Riyal döviz kuru, altın fiyatları ve petrol fiyatları gibi başlıca ekonomik değerlerdir. Teknik veriler ise HO, MACD, RSI, fiyat değişim oranı, MOM ve hisse

senetlerinin günlük işlem hacmidir. Çalışmada YSA'nın performansı MSE ile değerlendirilmiştir. Sonuçlar, YSA modelinin temel ve teknik veriler ile TEPIX arasındaki ilişkiyi ayırt edebildiğini ve ertesi gün tahminlerinin mümkün olabildiğini göstermiştir.

Hisse senedi piyasası endeksi hareketinin tahmininde YSA performansının incelenmesini amaçlayan araştırmalardan biri de Karymshakov ve Abdykaparov (2012) tarafından yapılmıştır. Tahmin BİST verilerinin iki örneğine dayanmaktadır ve her biri 150 gözlemden oluşan çalışmada, analiz için 2002-2007 seçilen zaman aralığında günlük veri kullanılmıştır. Endeks yön tahmini için girdi verisi olarak 5 teknik gösterge (en yüksek fiyat, en düşük fiyat, kapanış fiyatı, stokastik, HO-5 günlük) kullanılmıştır. Çalışmada elde edilen bulgulara göre YSA'nın tahmin doğruluğu %82,7'dir.

Dunis vd. (2013) tarafından yapılan çalışmada, DVM, YSA ile Al ve Tut stratejisi modelleri yardımıyla endeks yön tahmini yapılmıştır. Çalışmada girdi verisi olarak RSI ve MACD gibi hisse senedi piyasalarının analizinde yaygın olarak kullanılan geleneksel teknik göstergeler kullanılmıştır. Çalışmadan elde edilen bulgular, DVM'lerin başarılı tahmin sonuçları elde etmeyi başardığını göstermiştir.

Oliveira, Nobre ve Zárate, (2013) YSA yöntemini kullanarak Brezilya BM&FBOVESPA endeksinin yönünü tahmin etmeye çalışmıştır. NYSE Dow Jones Endeksi, MACD, RSI, Stokastik endeks, OBV endeks, HO, Bolinger bant, MOM, Williams %R, Brezilya Enerji Emtia Endeksi ve Dolar yüzde değişim değişkenleri girdi değişkeni olarak kullanılarak endeks yön tahmini yapılmıştır. Zaman serisi verileri, Ocak 2000'den Aralık 2011'e kadar toplamda 144 gözlemlerle birlikte, değişkenlerin aylık gözlemleri alınmıştır. En yüksek performansa ulaşan modelin doğruluk oranının %93.62, MAPE değerinin ise %5.45 olduğu bulunmuştur. Tahmin edilen değerler ve gerçek değerler tablosu, tahmin edilen serilerin gerçek değerler serisini izlediğini göstermiştir.

Chen vd. (2014) Bulanık Mantık, Physica, Destek Vektör Regresyon (DVR), kısmi en küçük karesel regresyon (PLSR) modellerini kullanarak endeks yön tahmini için en uygun modeli tespit etmeye çalışmıştır. 1998'den 2006'ya kadar olan TAIEX (Tayvan Borsası Varlıklar Ağırlıklı Stok Endeksi) ve HSI'ya (Hang Seng Endeksi)

ait günlük verileri kullanan yazarlar, model girdileri olarak 13 teknik göstergeyi (HO-5, HO-10, RSI, MACD, BIAS-5, BIAS-10, MOM1, MOM2, DIFN, DIFF, DIFE, Williams %R, PSY-12) hesaplamıştır. Bulgular, önerilen modellerin hem Tayvan hem de Hong Kong hisse senedi piyasalarında ağırlıklı bir hisse senedi endeksini tahmin etmek için diğer modelleri geride bıraktığını göstermektedir.

Wang ve Shang (2014) tarafından yapılan çalışmada Çin Güvenlik Endeksi 300'ün (CSI 300) günlük hareket yönü tahmini incelenmiştir. Modellerin giriş değişkenleri olarak HO, AHO, RSI, MACD, CCI, A/D, MOM, %K, %D, Will's %R teknik göstergeleri seçilmiştir. Veri seti, CSI 300 endeksteki toplam 1653 gözlem ile 27 Nisan 2005'ten 15 Şubat 2012'ye kadar olan dönemi kapsamaktadır. Çalışmada, yazarların elde ettikleri bulgulara göre, LS-DVM, PNN, QDA, DDA yöntemlerinin doğruluk oranları sırasıyla %89.12, %80.97, %87.92, %87.31'dir. Deneysel sonuçlar LS-DVM yönteminin, hem eğitim doğruluğu hem de test doğruluğu açısından PNN, DDA, QDA'den daha iyi performans gösterdiğini ortaya koymuştur.

Anbalagan ve Maheswari (2015), çalışmalarında Hint borsalarının kısa vadeli yatırımcılar için Bulanık Metagraf (FM) tabanlı bir borsa karar verme, sınıflandırma ve tahmin yöntemi önermişlerdir. Çalışmada Hindistan Bombay Borsası'nın (BSE) 2011-2012 yılları arasındaki günlük veriler kullanılmıştır. Sistemin performansını değerlendirmek için RW, YSA, DVM, FM yöntemleri karşılaştırılmıştır. HO, ÜHO, MACD ve RSI teknik göstergeleri FM yöntemi ile bütünleştirilmiş sistemi eğitmek için girdi olarak kullanılan teknik göstergelerden bazılarıdır. Kullanılan yöntemlerin doğruluk oranlarının sırası ile %50, %69, %73, %75 olduğu tespit edilmiştir.

Patel vd. (2015) tarafından yapılan çalışmada Hint borsaları için hisse senedi ve hisse senedi fiyat endeksinin hareket yönünü tahmin etme sorunu ele alınmıştır. Çalışmada NB, YSA, DVM, RO tahmin modelleri karşılaştırılmıştır. 2003'ten 2012'ye kadar 10 yıllık CNX Nifty ve BSE endekslerindeki zaman serisi olan 10 teknik gösterge (BHO, AHO, RSI, MACD, CCI, A/D, MOM, %K, %D, Will's %R) kullanılarak analizler yapılmıştır. Yöntemlerin tahmin doğrulukları sırası ile %89.84, %86.69, %88.69, %89.59 olarak bulunmuştur. Sonuçlar, bu teknik göstergelerin trend deterministik veriler olarak alınması durumunda, tüm tahmin modellerinin performansının arttığını göstermiştir.

Anish ve Majhi (2016) tarafından yapılan çalışmada DJIA ve S&P500 endeksinin yön tahmininde Ayrık Wavelet Dönüşümü (DWT), FLANN, DVM-ÇKA, Radyal Tabanlı Fonksiyon Sinir Ağları (RBFNN) yöntemleri kullanılmıştır. Çalışmanın veri seti Ocak 2000'den Ekim 2012'ye kadar 8 teknik göstergeyi (HO, ÜHO, A/D, stokastik, RSI, fiyat değişim oranı, kapanış fiyatı, en yüksek fiyat) kapsayan günlük veriden oluşmaktadır. Çalışmanın sonuçları, ÇKA yönteminin RBFNN ve DVM yöntemlerinden daha üstün olduğunu göstermiştir.

Dash ve Dash (2016a), çalışmalarında borsa endeks hareket yönünün tahmin edilmesi için Nöro-Bulanık Çıkarım Sistemi (ANFIS) kullanmışlardır. BSE SENSEX ve S&P500 endeksleri 2012-2014 dönemi için Basit Hareketli Ortalama, RSI ve Will's %R teknik göstergelerine ait günlük verileri ile analiz edilmiştir. Modelin iki farklı borsa endeksinde uygulanmasıyla elde edilen deneysel sonuçlar, modelin etkinliğini göstermiştir.

Jabbarzadeh vd. (2016) tarafından yapılan çalışmada S&P500 endeksinin ertesi günü yönü tahmin edebilirliği doğrusal olmayan modeller (Probit, Logit ve Extreme Value) ile test edilip karşılaştırılmıştır. Çalışmada kullanılan göstergeler HO, AHO, Momentum, %K, %D, Will's %R, göreceli güç endeksi, fiyat kanal endeksi, MACD, Hareketli ortalama göstergesi, Will's % aralığıdır. 2011-2015 yılları arası S&P500 endeksine ait 11 teknik göstergenin günlük verilerinin kullanıldığı çalışmada, yazarların elde ettikleri bulgulara göre doğruluk oranları sırası ile %64.1, %62.69, %71.91'dir.

Hindistan Bombay Borsası ve Ulusal Borsanın CNX S&P Nifty 50 endeksinin ertesi günü yönünü tahmin etmeyi amaçlayan Gurjar vd. (2018) YSA, DVM ve DR yöntemlerini kullanmıştır. Çalışmada CNX S&P Nifty 50 endeksini 12 Şubat 2018'den 26 Mart 2018'e arası dönem için HO, stokastik, standart sapma ve denge hacmi teknik göstergelerine ait günlük verileri kullanılmıştır. Çalışmanın sonuçlarına göre borsa endeks fiyatının tahmininde YSA yönteminin kısa vadede düşük öngörü kabiliyeti, uzun vadede ise kesin öngörü kabiliyeti olduğu belirlenmiştir.

Endeks yön tahmini yapan bir başka çalışma Santoso, Sutjiadi ve Lim (2018) tarafından yapılmıştır. Çalışmada, Astra International Inc. (ASII.JK) borsasının yön

tahmini Gaussian Karışım Modeli-DVM (GMM-DVM) entegre modelleri yardımıyla yapılmıştır. Bu model piyasadaki toplam dönüşüm ile karşılaştırılmıştır. Ocak 2000 ile Eylül 2017 arasında 17 yıllık döneme ait 9 teknik göstergenin (BHO, ÜHO, RSI, Will's %R, üçgen hareketli ortalama, değiştirilmiş hareketli ortalama, gerçek güç endeksi, ortalama gerçek aralık, oynaklık oranı) günlük değerleri veri seti olarak kullanıldığı çalışmada, ASILJK borsası için en uygun tahmin modeli doğruluk ölçütü ve hata metriklerinden yararlanılarak tespit edilmiştir. Çalışmadan elde edilen bulgulara göre, DVM ile eğitimi yapılan GMM-DVM tabanlı hisse analiz modelinin karşılaştırılan modellere kıyasla daha üstün olduğu ve Endonezya borsa veri setleri için tahmin kabiliyetinin arttığını göstermiştir.

Endeks yön tahmininde sınıflandırma yöntemlerini kullanan bir başka çalışma Dash vd. (2019) tarafından yapılmıştır. Çalışmalarında TOPSIS, DVM, NB, KA ve k-EYK yöntemlerini kullanan yazarlar, 2015-2017 yılları arası BHO, %K, %D, Will's %R, MACD ve RSI teknik göstergelerinin yer aldığı günlük veriler ile BSE SENSEX ve S&P500 endeks getiri yönünü tahmin etmişlerdir. Çalışmadan elde edilen sonuçlara göre; BSE SENSEX endeksinde DVM, S&P500 endeksinde ise k-EYK diğer modellerden daha iyi performans göstermiştir.

Son olarak Nadh ve Prasad (2019) tarafından yapılan çalışmada endeks getiri yönü tahmini için GA, DVM ve YSA sınıflandırma yöntemleri kullanılmıştır. Veri seti olarak PETR4 ve BM&FBOVESPA endekslerinde yer alan HO, AHO, MOM, RSI gibi bazı teknik göstergeler kullanılmıştır. Çalışmanın sonuçlarına göre DVM, YSA'dan daha iyi tahmin performansına sahiptir.

Çalışmanın izleyen bölümünde endeks yön tahmininde Türkiye'de yapılan çalışmalara yer verilmiştir.

2.2.2. Endeks Yön Tahmininde Teknik Göstergeler Kullanılarak Türkiye'de Yapılan Çalışmalar

Tez çalışmasının bu bölümünde endeks yön tahmininde teknik göstergelerin kullanıldığı Türkiye'de yapılan çalışmalara yer verilmiştir. Endeks yön tahmininde teknik göstergelerin ele alındığı çalışmaların Türkiye'de sınırlı sayıda olduğu gözlenmiştir. Bu çalışmalarda teknik göstergeler bağımsız değişken olarak sınıflandırma yöntemlerinde kullanılmıştır. Örneğin Diler (2003) tarafından yapılan

çalışmada sadece YSA yöntemi kullanılırken bazı (Kara, Boyacıoğlu ve Baykan, 2011; Emir, 2013; Tayyar ve Tekin, 2013) çalışmalarda ise birden çok yöntem endeks yön tahmininde doğruluk tahmini performans karşılaştırılması için kullanılmıştır.

Tablo 10. Teknik Göstergeler Kullanılarak Sınıflandırma Yöntemleri ile Türkiye'de Yapılan Çalışmalar

Yazar/Yazarlar	Tahmin Modeli	Veri	Sonuç
Diler (2003)	YSA	1990-2003, İMKB 100 6 teknik gösterge	Ortalama doğruluk %60.81 olarak bulunmuştur.
Kara vd. (2011)	YSA, DVM	1997-2007, İMKB 100 10 teknik gösterge	Ortalama doğruluk %75.74, %71.52 bulunmuştur.
Emir (2013)	DVR, DR	2005-2011, İMKB 100 6 teknik gösterge	DVR tüm metrikler için DR'den daha iyi bulunmuştur.
Tayyar ve Tekin (2013)	DVM, LogR	1995-2012, İMKB 100 27 teknik gösterge	DVM, LogR'ye göre daha yüksek doğru sınıflandırma başarısı göstermiştir.

Tablo 10'a göre endeks yön tahmininde teknik göstergelerin kullanıldığı sınıflandırma yöntemleri ile Türkiye'de yapılan ilk çalışma Diler tarafından 2003 yılında yapıldıktan sonra uzun bir süre bu alanda çalışılmamıştır.

Türkiye'de Diler (2003) tarafından yapılan ilk çalışmada BİST 100 endeksinin bir sonraki gün yönü tahmin edilmiştir. Çalışmanın veri seti, BİST 100 endeksinin 3 Ocak 1990'dan başlayarak 11 Kasım 2003 tarihine kadar olan döneme ait HO, AHO, MOM, RSI, MACD, %K teknik göstergelerinin günlük verisini kapsamıştır. Çalışmada, BİST 100 endeksinin yön tahminini yapmak üzere YSA'nın momentumla güçlendirilmiş hata geriye yayma algoritması kullanılmıştır. Araştırmanın sonucunda elde edilen bulgulara göre YSA yöntemi ile BİST 100 endeksinin ertesi günkü yönü doğru tahmin oranı %60,81 olarak bulunmuştur.

Kara, Boyacıoğlu ve Baykan (2011) tarafından yapılan çalışmada, BİST 100 endeksi yön tahmini, YSA ve DVM modelleri ile karşılaştırılmıştır. Çalışmanın veri seti ise 2 Ocak 1997'den 31 Aralık 2007'ye kadar olan dönemi kapsayan toplam 2733 günlük veriden oluşmuştur. HO, AHO, RSI, MACD, CCI, A/D, MOM, %K, %D ve Will's %R teknik göstergeleri önerilen modellerin girdisi olarak seçilmiştir. Her iki model için araştırmanın iki yönlü parametre tahmin performanslarını arttırmak için

yapılan analizler sonucunda elde edilen bulgulara göre %75,74 ile YSA modelinin performans ortalaması %71,52 ile DVM modelinden daha üstün bulunmuştur.

Emir (2013) tarafından yapılan çalışmada, BİST 100 endeksi günlük getiri tahmininde DVR ve DR yöntemleri kullanılmıştır. 2005-2011 dönemi için MOM, CCI, RSI, Stokastik, Will's %R ve Para Akışı Endeksi teknik göstergelerinin günlük gözlemlerinden oluşan veri seti kullanılmıştır. Çalışmada karşılaştırma ölçütleri olarak RMSE, MAE, MAPE, TIC ve MME metrikleri kullanılmıştır. Çalışmanın sonuçları ise, DVR'nin tüm metrikler için DR'den daha iyi olduğunu göstermiştir.

Tayyar ve Tekin (2013) tarafından yapılan çalışmada, ikili sınıflandırmaya imkan tanıyan DVM ve LogR modelleri BİST 100 endeksi hareket yönünü tahmini için kullanılmıştır. Çalışmada BİST 100 endeksinin 03.04.1995'den 19.03.2012'e kadar olan günlük, haftalık ve aylık veri setleri kullanılmıştır. Çalışmada 27 teknik gösterge (BHO-20, BHO-200, ÜHO-20, ÜHO-200, AHO-20, AHO-200, Aroon, ADX, SAR, MACD, ROC, RSI, hızlı %D, yavaş %D, SMI, Will's %R, CCI, CMO, Bollinger, BB-C, ATR, CO, A/D, OBV, MFI, CMF, CDG) girdi verisi olarak kullanılmıştır. Elde edilen sonuçlara göre haftalık DVM modeli, ortalama %70,0 doğruluk oranı ile endeks hareket yönünü en iyi tahminleyen model olmuştur.

2.2.3. Endeks Yön Tahmininde Teknik Göstergelerin Kullanıldığı Çalışmalara İlişkin Genel Değerlendirme

Endeks yön tahmininde teknik göstergelerin kullanıldığı sınıflandırma yöntemlerinin performanslarının karşılaştırılması genel olarak değerlendirildiğinde, teknik göstergelerle hareketin veya trendin yönünü tahmin etmesi amaçlandığından teknik göstergelerin kullanılmasının tahmin doğruluğunu arttırdığı tespit edilmiştir.

Teknik göstergelerin girdi verisi olarak kullanıldığı sınıflandırma yöntemleri ile yurtdışında yapılan çalışmaların büyük bölümünde (Yao, Tan ve Poh, 1999; Kim, 2003; Lahmiri, 2011; Dastgir ve Enghiad, 2012; Dunis vd., 2013; Lahmiri, Boukadoum ve Chartier, 2013; Chen vd., 2014; Wang ve Shang, 2014; Anbalagan ve Maheswari, 2015; Patel vd., 2015; Anish ve Majhi, 2016; Jabbarzadeh vd., 2016; Dash vd., 2019; Nadh ve Prasad, 2019) birden fazla yöntem tahmin doğruluğu performansını karşılaştırmak için kullanıldığı belirlenmiştir. Model sonuçlarına göre bazı çalışmalarda YSA, bazı çalışmalarda DVM, bazı çalışmalarda ise k-EYK'nın

diğer yöntemlerden üstün olduğu görülmüştür. Diğer çalışmalarda ise (Yu, Wang ve Lai, 2005; Lu, 2010; Nair, Mohandas ve Sakhivel, 2010; Dash ve Dash, 2016a; Santoso, Sutjiadi ve Lim, 2018) hibrit yöntemler kullanılmış ve önerilen modellerin diğer modelleri geride bıraktığı görülmüştür.

Teknik göstergelerin kullanıldığı sınıflandırma yöntemleri ile Türkiye’de yapılan bazı (Kara, Boyacıođlu ve Baykan, 2011; Emir, 2013; Tayyar ve Tekin, 2013) çalışmalarda ise birden çok yöntem endeks yön tahmininde doğruluk tahmini performans karşılaştırılması için kullanıldığı tespit edilmiştir. Çalışmaların sonuçlarına göre Kara, Boyacıođlu ve Baykan (2011) YSA’yı daha başarılı bulurken, Tayyar ve Tekin (2013) ve Emir (2013) ise yaptıkları çalışmalarda DVM’nin daha yüksek doğruluk tahminine sahip olduğunu bulmuşlardır. Diğer bir çalışma ise Diler (2003) tarafından YSA yöntemi kullanılarak yapılmış ve tahmin doğruluk oranı %60.81 ile ortalama bir değer olarak gözlenmiştir.

Bu çalışmalara yönelik genel bir değerlendirme yapıldığında ise teknik göstergelerin kullanıldığı sınıflandırma yöntemleri ile yurtdışında yapılan çalışmalarda makine öğrenmesi yöntemleri ile hibrit yöntemlerin diğer modelleri geride bıraktığı tespit edilmiştir. Türkiye’de yapılan çalışmalarda ise makine öğrenmesi yöntemlerinin daha yüksek doğruluk tahminine sahip olduğu belirlenmiştir.

Literatür taramasında da görüldüğü üzere teknik göstergeleri girdi verisi olarak kullanan Türkiye’de yapılan makine öğrenmesi ve istatistiki yöntemlerle endeks yön tahminini ele alan sınırlı sayıda çalışma bulunmaktadır. Çalışmaların birçoğunda bir ya da iki yöntemle endeks yön tahmini yapıldığı gibi, mevcut çalışmadaki gibi kapsamlı olarak sınıflandırma yöntemleriyle değerlendirme ve karşılaştırma yapılan çalışmaya rastlanmamıştır. Bu açıdan yapılan çalışma, endeks yön tahmininde sınıflandırma yapan beş makine öğrenmesi ve iki istatistiki yöntemi kullanması ve karşılaştırması nedeniyle literatürdeki boşluğu kapatmaya yardımcı olacaktır.

Çalışmanın bir sonraki bölümünde, finansal piyasalar ve BİST kavramları ele alınarak çalışmanın teorik çerçevesi çizilecektir.

ÜÇÜNCÜ BÖLÜM

FİNANSAL PİYASALAR VE BORSA İSTANBUL

Bu bölümünde çalışmanın pratik uygulamasının yapıldığı veri setinin seçildiği finansal piyasalar ve Borsa İstanbul'un tanıtımı yer almaktadır. Birinci kısımda finansal piyasalar kavramı tanıtılırken ikinci kısımda ise Borsa İstanbul (BİST) ve Borsa İstanbul'da hesaplanan endeksler kavramları incelenecektir.

1. FİNANSAL PİYASALAR

Bu kısımda önce finansal piyasa kavramı tanımlanacak daha sonra finansal piyasaların özellikleri ifade edilecektir. Bir sonraki kısımda ise finansal piyasaların sınıflandırılması yapıp, finansal piyasa araçlarının tanıtımı ile devam edilecektir.

1.1. FİNANSAL PİYASA KAVRAMI

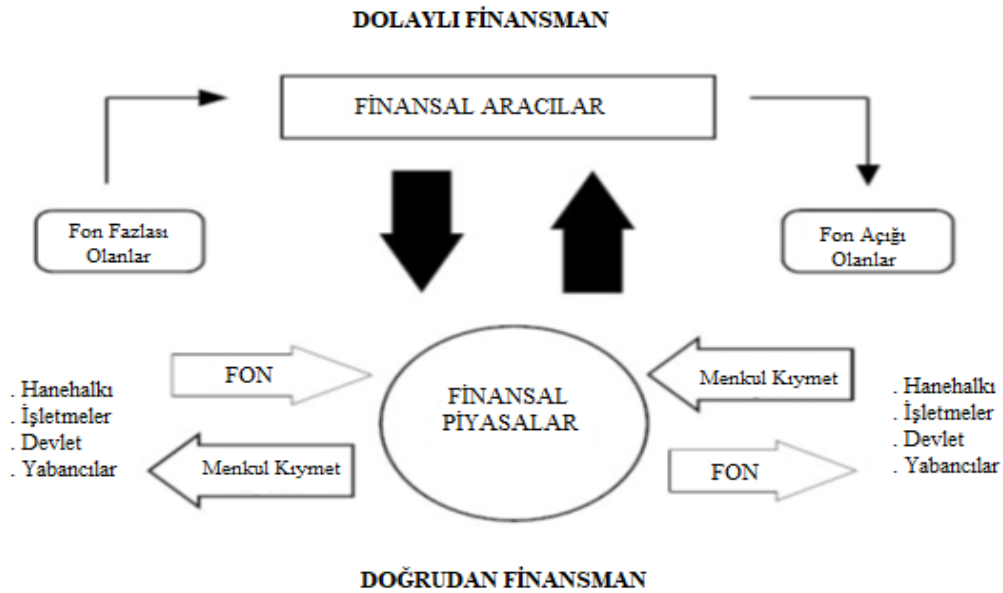
Piyasa, alıcıları ve satıcıları bir araya getiren mal veya hizmete fiyat oluşturulan ortam olarak açıklanabilir. Arz ve talebin karşılaştığı, mübadelenin yapıldığı mekanlar olarak da tanımlanabilir. Buna verilebilecek somut örnek borsalardır. Piyasaların genel tanımı; alıcıların ve satıcıların bir ihtiyacı karşılamak için bir araya gelerek iletişime geçmeleri sonucunda değişimin meydana geldiği yer olarak yapılmaktadır (Seyidoğlu, 2005: 285).

Ekonomik sistemin ayrılmaz bir parçası olan finansal piyasalar, fon fazlası olanlar ile fon ihtiyacı olanların oluşturduğu piyasalar olarak karşımıza çıkmaktadır (Mishkin, 2004: 3). Finansal piyasalar, finansal varlıkların ve yükümlülüklerin yaratılması ve bunların transfer edilmesi yoluyla oluşmaktadır (Konuralp, 2005: 3). Finansal piyasalar örgütlü veya örgütsüz olabilir (Korkmaz ve Ceylan, 2007: 478).

Finansal piyasalara fon arz eden tasarruf sahipleri, fon talebinde bulunan yatırımcılar, iki tarafın piyasaya sürdükleri finansal araçlar, aracı kurumlar, hukuki ve idari düzenin oluşturduğu bir bütündür finansal sistem (Kargı,1998: 29). Devletler, piyasanın sağlıklı bir şekilde işleyebilmesi için yasa ve yönetmelikler hazırlamakla ve piyasaları denetlemekle yükümlüdürler (Başoğlu, 2009: 126).

Bir ülke ekonomisini oluşturan finansal sistemin oyuncularını hane halkı, şirketler, devlet ve yabancılar olarak sayabiliriz (Şıklar, 2004: 46). Finansal sistem, fon fazlası olanların, ek bir gelir karşılığında fon ihtiyacı olanlara fon vermesi sonucunda ortaya çıkmıştır (Mishkin ve Stanley, 2012: 16). Birikim açığı olanlar bu piyasalardan fon sağlarken, finansal varlık oluştururlar. Şekil 20’de görüldüğü gibi fonlar, borç verenlerden borçlu harcayıcılara iki güzergâh halinde akmaktadır. Doğrudan finansmanda borç alanlar, borçlunun geleceği ile ilgili menkul kıymetleri satarak doğrudan finansal piyasalardaki borç verenlerden borç alırlar (Delice, 2000: 8). Menkul kıymetler, onları satın alan kişinin varlıklarıdır, ancak bunları satan (ihraç eden) kişi veya firma için yükümlülüklerdir. Dolaylı finansmanda ise fon fazlası olanlar ile fon açığı olanlar arasında piyasa işlemlerini yapmak için aracilar bulunur (Mishkin ve Stanley, 2012: 16).

Şekil 20. Finansal Piyasaların İşleyişi (Şıklar, 2004: 46).



Finansal piyasanın işleyişi en basit anlamda şu şekilde açıklanabilir. Literatürde bu konu ile ilgili iki tane kavram bulunmaktadır. Bunlar; fazla pozisyonda olan, ekonomik birimlere mevcut fazlayı harcayanlar ve açık pozisyonda olanlar, başka bir ifade ile açıktan harcayanlardır (Başoğlu, 2009: 126). Finansal piyasa ilişkisi içerisinde bu iki taraf bir araya gelerek; gelir fazlalıklarını ve gelir açıklarını buluşturmaktadırlar. Bu ilişki çerçevesinde fon fazlası olanlar piyasaya fon sunarlarken, fon açığı olanlar finansal varlık arz etmektedirler (Konuralp, 2005: 17).

Para ve sermaye piyasalarının, yakın bir ilişki içerisinde olan piyasalar oldukları bilinmektedir. Tasarrufların, bir piyasadan diğerine doğru kayma hareketi gösterebildiği para ve sermaye piyasalarında gerçekleşen bu hareketlenmelerin sebebi olarak faiz oranlarındaki değişiklikler gösterilebilir (Ağır, 2003: 11).

Ekonominin en önemli unsurlarından birisi finansal piyasalardır. Ülkelerin gelişmişliği finansal piyasaların gelişmişliği ile ölçülür, finansal piyasalar ise ulusal ve uluslararası tasarrufların harekete geçirilmesi veya reel sektöre aktarılma oranları ile ölçülmektedir. Finansal piyasaların etkinliği arttığı ölçüde sanayileşmenin de gelişeceğini söylemek mümkündür (Delice, 2000: 9). Finansal piyasaların etkin olmadığı, piyasaların işleyişi için ekonomik tedbirlerin ve yasal düzenlemelerin yapılmadığı ülkelerin planlı ve güçlü kalkınması zor görünmektedir. Piyasalardaki olumsuz gelişmeler sebebiyle ülkedeki birçok sektör bu durumdan etkilenip ekonomik durgunluklar ve krizler meydana getirebilmektedir (Büyüksalvarcı 2011: 227). Geniş katılımlı ve etkin bir piyasa, yatırımcıların fonlarında daha verimli bir şekilde reel varlık yatırımlarında kullanma imkanı sağlar (Kaya, Çömlekçi ve Kara, 2013: 167).

Finansal piyasa araştırmalarından da anlaşılacağı gibi tanımlar benzerlikler göstermektedir. Bu benzerlikler finansal piyasalar için ortak özelliklere işaret etmektedir. Benzer sebep ve gereklilikler finansal piyasa özelliklerinin incelenmesi düşüncesini oluşturmuştur.

1.2. FİNANSAL PİYASALARIN ÖZELLİKLERİ

Finansal piyasalara bakıldığında özelliklerini şöyle sıralayabiliriz (Kar vd., 2008: 193):

- Varlıklar için fiyatın, finansal piyasalar aracılığı ile belirlenmesi
- Piyasaya likidite sağlamak
- Finansal piyasalar sayesinde piyasalarla ilgili bilgi ve haberlere kolayca erişim

Finansal varlıklar için optimal fiyatın finansal piyasalar aracılığıyla belirlenmesi finansal piyasaların en önemli özelliklerindedir. Piyasadaki fon satışı ve fon alımı yapmak isteyen yatırımcıların isteklerine cevap verebilmek için

beklentisini karşılayacak şekilde yatırım aracı tespit edilerek, tarafların tercihine uygun olan fiyat finansal piyasalar aracılığıyla oluşturulmaktadır.

Pozisyonunu kapatmak isteyen yatırımcılar için finansal piyasalar varlığını kolay bir şekilde nakde çevirebilme kolaylığı sağlamaktadır. Finansal piyasalar bu işlemi hızlı ve minimum kayıpla gerçekleştirmektedir (Aydın, 2001: 360). Finansal piyasaların bir başka özelliği sayesinde piyasadaki işletmelerle ilgili verilere kolayca erişilerek araştırma giderleri azalmaktadır (Konuralp, 2005: 12).

1.3. FİNANSAL PİYASALARIN SINIFLANDIRILMASI

Finansal piyasaların sınıflandırılması incelendiğinde literatürde yapılmış çok sayıda çalışmaya rastlanmaktadır (Gönenli, 1988; Sarıkamış, 2000; Konuralp, 2005; Korkmaz ve Ceylan, 2007; Aksoy ve Tanrıöven, 2007; Parasız, 2007; Büker, Aşikoğlu ve Sevil, 2009; Orçun, 2010; Yalta, 2011). Literatürdeki sınıflandırmalar dikkate alındığında genel olarak finansal piyasalar:

1. Para ve Sermaye Piyasaları
2. Spot ve Vadeli Piyasalar
3. Organize ve Organize Olmayan Piyasalar
4. Birincil ve İkincil Piyasalar
5. Üçüncül ve Dördüncül Piyasalar olarak sınıflandırılır.

Çalışmamızda literatürde genel kabul görmüş olan finansal piyasa sınıflandırması kullanılacaktır ve ilerleyen kısımda tanımlarına yer verilecektir.

1.3.1. Para ve Sermaye Piyasaları

Varolan fonların süresine göre finansal piyasalar ikiye ayrılır.

1.3.1.1. Para Piyasaları

Kısa vadeli fonların işlem gördüğü piyasalardır. Vadesi genellikle bir yıldan az olan fonların oluşturduğu piyasalardır (Parasız, 2007: 95). Finansal enstrümanlardan yüksek likiditeli ve az riskli az olanlar para piyasalarında alınıp satılmaktadır. Bunlar (Karşlı, 1994: 23):

- Hazine Tahvilleri
- Finansman Bonosu

- Repo
- Mevduat Sertifikası
- Çek ve Senetler

1.3.1.2. Sermaye Piyasaları

İşlem gören fonların vadesi, orta ve uzun vadeli olan piyasalardır (Karşlı, 1994: 23). Sermaye piyasaları hisse senetleri ve bono gibi vadeleri bir yıldan uzun finansal araçların alım satımının yapıldığı piyasalardır (Parasız, 2007: 23). Şirketler orta ve uzun vadeli yatırımları için sermaye piyasası araçlarını kullanırlar. Hisse senedi ve tahviller sermaye piyasasının en önemli enstrümanlarıdır.

1.3.1.3. Para ve Sermaye Piyasaları Arasındaki İlişki

Fon arz eden yatırımcılar, uyguladıkları yatırım stratejilerine göre fonlarını bu piyasalara yönlendirirler. Fon talep eden yatırımcılar da, ihtiyaçlarına göre kullanacakları krediyi her iki piyasadaki borçlanabilirler. Şirketler dönen varlıklarının finans ihtiyacını karşılamak için kısa vadeli para piyasası enstrümanlarını kullanırlar. Sigorta ve emeklilik şirketleri ellerindeki fonlar için belirsizlikleri daha az olan uzun vadeli sermaye piyasası araçlarını tercih ederler. Bankalar, her iki piyasada da çalışabilirler böylece hem para hem de sermaye piyasası araçlarını kullanırlar (Ağır, 2003: 13).

Para piyasası ile sermaye piyasası arasındaki faiz hadleri, fon akımını ayarlayan düzenleyici bir rol oynamaktadır. Faiz hadlerinin düşük veya yüksek olmasına göre fonlar ya da kredi arz talebi, para piyasası ile sermaye piyasası arasında kolaylıkla geçişlere sahne olabilir (Yüksel ve Rodoplu, 1980: 87).

1.3.2. Spot ve Vadeli Piyasalar

Finansal varlıkların alım satım işlemlerinin yapıldığı zaman sürecine göre finansal piyasalar, spot ve vadeli piyasalar olarak ikiye ayrılır.

1.3.2.1. Spot Piyasalar

Piyasa fiyatı üzerinden ve hemen teslim şartı ile finansal varlıkların el değiştirdiği piyasalardır. “Nakit piyasa” olarak da bilinir. Vadeli işlem piyasalarından farklı olarak spot piyasalarda çok kısa sürede ödeme ve fiziksel teslim gerçekleştirilir. Fiyat işlem tarihinden en çok iki iş günü sonra belirlenir. İşlemler iki

taraf arasında yapılır. Fiyatı belirleyen ise o anki arz ve talep. Kuyumculardan altın almak spot piyasaya örnek verilebilir. Spot işlemler en yaygın yapılan işlemlerdir.

1.3.2.2. Vadeli Piyasalar

Vadeli piyasalarda anlaşma bugün yapılır, yükümlülükler ise ileri bir tarihte yerine getirilir. “Türev araçlar” olarak da bilinir. Standart bir varlığı almak veya satmak üzere ürünün kalitesi, miktarı, vadesi, teslim yeri alıcı ve satıcılar tarafından belirlenmiş piyasalara vadeli piyasalar denir. Teslim süresi haftalar hatta aylar sonra olabilir. Takas Bank, alıcı ve satıcı arasındaki muhataptır. Vadeli piyasalar aşağıdaki konuları kapsar (Örten ve Örten, 2001:287):

- Forward
- Futures
- Options
- Swap

Vadeli işlem piyasalarının kullanım amaçları:

- Koruma amaçlı
- Spekülatif amaçlı
- Arbitraj amaçlı

1.3.3. Organize ve Organize Olmayan Piyasalar

Organize ve organize olmayan piyasalar olarak kurumsal yapılarına göre finansal piyasalar ikiye ayrılabilir.

1.3.3.1. Organize Piyasalar

Organize piyasalar, belirli fiziksel mekanlarda alıcı ve satıcıların karşılaştığı, belirli kurum ve kuruluşlarca denetlenen piyasalardır. “Borsa”, organize piyasalara en iyi örnektir.

Menkul kıymet borsalarının ekonominin göstergesi olma, piyasaya likidite sağlama, mülkiyeti tabana yayma gibi fonksiyonları vardır. Gelişmiş ülkelerde borsaların en bariz özellikleri arasında çok sayıda şirketin borsaya kote olması, alım satım fiyat farklarının az olması ve yüksek işlem hacmi vardır. Bu borsaların günlük

işlemlerinde belli kurallara uyulması ve şeffaflığın fazla olması güvenilir bir piyasa yapar organize piyasaları (Konuralp, 2005: 20).

1.3.3.2. Organize Olmayan (Tezgahüstü) Piyasalar

Organize olmayan piyasalar, fiziki bir mekanı olmayan, yasal kuralları belirlenmemiş, belirli kurumlar tarafından denetlenmeyen piyasalardır. Organize olmayan piyasalara örnek serbest döviz piyasası ve serbest altın piyasası verilebilir (Ergezen, 2006: 8).

1.3.4. Birincil ve İkincil Piyasalar

Piyasada işlem gören finansal enstrümanların piyasaya ilk kez olarak sürülmüş olup olmadıklarına göre finansal piyasalar, birincil ve ikincil piyasalar olarak ikiye ayrılırlar.

1.3.4.1. Birincil Piyasalar

Hisse senedi ve tahvil gibi menkul değerleri halka arz eden şirketler veya bunların aracıları ile alıcıların doğrudan doğruya karşılaştıkları piyasalardır (Parasız, 2005: 80). Hisse senetleri ile tahvillerin halka arz ile piyasaya ilk kez sürüldüğünde alınmasına birincil piyasa denilir (Başoğlu vd., 2009: 17).

1.3.4.2. İkincil Piyasalar

Halka arzdan alınan alınan menkul kıymetlerin tekrar paraya çevrilmesini sağlayan piyasalara ikincil piyasalar denilir. İkincil piyasalara en güzel örnek menkul kıymet borsalarıdır. İkincil piyasada işlem yapıldığında işlemi yapan yatırımcılar arasında menkul kıymet ve fon takası gerçekleşir (Başoğlu vd., 2009: 19).

Birincil piyasa sermaye piyasası mantığıyla çalışırken, ikincil piyasa ise para piyasası mantığıyla çalışır (Karlı, 2004: 32). Birincil piyasaya talebin artması ve gelişmesi, ikincil piyasada menkul kıymet likiditesinin artması ile olur (Yılmaz, 2002: 6).

1.3.5. Üçüncül ve Dördüncül Piyasalar

Finansal varlıkların alım satımının aracılı veya aracısız olarak yapılmasına göre finansal piyasalar üçüncül ve dördüncül piyasalar olarak iki kısımda incelenebilir.

1.3.5.1. Üçüncül Piyasalar

Borsanın izin vermesi şartıyla halka arz edilecek olan hisse senetlerinin / finansal varlıklarının (borsaya kote edilmiş varlıkların) borsaya kaydedilmesiyle oluşan piyasalar üçüncül piyasalardır. Bir hisse senedinin (finansal varlığın) kote ettirilmemiş ise bu hisse senedinin finansal varlığın ticareti yapılamaz. Bir hisse senedinin kote ettirilmesi hisse senedinin borsaya kaydedilmesi demektir. Kote ettirilmiş bir senet borsada tanınan ve alım satımı yapılan bir senet niteliği kazanır. Borsa'nın (hisse senedi ticaretinin yapıldığı yer) kendisine özel kurallarının olduğu herkes tarafından bilinmektedir. Üçüncül piyasalarda işlemler Tezgah Üstü piyasalarda yapılır. Borsa Yönetim Kurulu'nun aldığı kararlar pazarda açılmış halde olan, göstergelere (endekse) dahil olan veya olmayan, borsa kotunun içinde bulunan her bir şirket finansal varlığı olan hisse senetlerinin alım satımının gerçekleştiği pazarlardır (Necipoğlu, 2003: 27).

1.3.5.2. Dördüncül Piyasalar

Menkul değerlerin alım satımında aracılar bulunmuyorsa bu piyasalara dördüncül piyasalar denir. Dördüncül piyasalarda, sigorta şirketleri, yatırım fonları vb. gibi kurumsal yatırımcılar alım satım işlemi gerçekleştirirler. Bu piyasalarda pazarlık ise direkt (doğrudan doğruya) pazarlık yöntemiyle oluşmaktadır. Ve buna bağlı olarak alım ve satımda harcanan maliyet miktarı çok daha fazla düşmekte ayrıca borsada fiyatların tırmanış aşamasına geçtiği blok alım satımlar da sürekli kendinden bahsettirmektedir (Tükenmez, Susmuş ve Özkan, 1999: 40).

1.4. FİNANSAL PİYASA ENSTRÜMANLARI

Menkul kıymetler; ortaklık veya alacaklılık haklarını sağlayan, belirlenmiş bir tutar söz konusu olan, bireylerin veya şirketlerin gelecekteki yatırımları için yatırım aracı olarak da kullanılabilen, getirisi yıllık veya aylık değil; dönemsel olan ve son olarak koşulları SPK'nca belirlenmiş olan kıymetli evraktır (Uludağ ve Arıcan, 1999: 128).

Menkul kıymetlere örnek verecek olursak; hisse senetleri, tahviller, hazine bonoları, banka bonoları, vadeli işlem ve opsiyon sözleşmeleri, banka garantili bonolar, hisse senedi türevleri, varlığa dayalı menkul kıymetler, finansman bonoları,

kar ve zarar ortaklığı belgeleri, gelir ortaklığı senetleri, tahvil türevleri ve gayrimenkul sertifikalarını verebiliriz.

1.4.1. Hisse Senetleri

Varlıkları pay edilerek komandit şirketlerin de çıkarabildiği, anonim şirketlerin ihraç ettiği ve sermaye payını temsil eden, literatürde esham ve pay senedi olarak da isimlendirilen kıymetli evraklara hisse senedi denir (Konuralp, 2005: 28).

Hisse senetlerinin ekonomik işlevleri (BİST, 2018a);

- Kısa süre içinde kalkınma amacıyla ihtiyaç duyulan varlık birikimini büyük işletmeler içinde geniş halk topluluğunun küçük tasarruflarını bir araya getirerek elde eder.

- İktisadi refahı sağlam bir temele dayandırmayı amaçlayan üretim araçları ve ekonomik işletmelerin sahipliğini geniş halk topluluklarına pay ederek sağlarlar.

- Enflasyona karşı dayanıklı ve bununla birlikte değeri artan bir yatırım yoluyla halkın birikimlerine faiz desteği olmadan ek getiri sağlarken yatırımların ve gelirin kıymetini enflasyona karşı muhafaza eder.

1.4.2. Tahviller

Anonim şirketlerin TTK maddelerine uygun olarak ödünç para bulmak amacıyla, kıymetleri ve her biri eşit olmak şartıyla çıkardıkları borç senetlerine “tahvil” denir (Berk, 2007: 50).

Tahvil hamili şirket yönetiminde söz sahibi değildir. Vade sonunda tahvili satın alan kişi ve şirket arasında hukuki ilişki sona erdiği gibi hamil kar-zarar ilişkisine katılmaz.

Tahvil hamilinin hakları aşağıda görüldüğü gibidir (Türk Ticaret Kanunu, 2018):

- Tahvili ihraç eden şirketin esas sermaye hakkında yanlış beyanı, vesikaların doğru olmaması, sermayeye değer biçilmesinde hile yapılması gibi hususlarda, denetçilere ve ilk idare meclisi aleyhine dava açmak.

- Ortaklık esas sermayesinin azaltılması halinde ortaklık alacaklısı sıfatlarından dolayı teminat gösterilmesini veya alacakların ödenmesini istemek.
- Genel kurulun toplanmaması, pay sahiplerinin beşten az olması, kanunen gerekli olan ortaklık organlarından birinin olmaması durumlarında düzeltilmesini istemek, düzeltilmediği halde “ortaklığın feshi” için mahkemeye başvurmak.
- Şirketin anonim ortaklıktan limitet ortaklığa çevrilmesi halinde teminat gösterilmesini veya alacaklarının ödenmesini talep etmek.

1.4.3. Devlet Tahvilleri ve Hazine Bonoları

Hazine tarafından kamunun finansman ihtiyaçlarını karşılamak üzere çıkarılan iç borçlanma senetleridir. Hazine bonoları bir yıldan kısa, devlet tahvilleri ise bir yıldan uzun vadelidir. Para politikalarının yürütülmesinde ve ekonomide önemli roller üstlenen para piyasası araçları olan devlet tahvilleri ve hazine bonoları önemli menkul kıymetlerdendir (Albeni ve Demir, 2011: 12).

1.4.4. Gelir Ortaklığı Senetleri

Gelir ortaklığı senetleri, kamu kurumlarına ait baraj, otoban, köprü, demiryolu, elektrik santrali, deniz ve hava limanlarının gelirlerine, gerçek veya tüzel kişilerin ortak olabilmesi için çıkarılan senetlere denir (Çolak ve Öçal, 1999: 33).

- Altyapı yatırımlarına yeni kaynaklar yaratarak finansman sağlamak,
- Somut varlıkları kullanarak daha kolay borçlanmak,
- Devlet tahvillerinin hazineye getirdiği faiz yükünü hafifletmektir.

1.4.5. Banka Bonoları ve Banka Garantili Bonolar

Yatırım ve Kalkınma bankaları tarafından düzenlenip SPK tarafından kayda alınmasının hemen ardından ihraç edilen emre ve hamiline yazılı menkul kıymetlere banka bonoları denir. Banka bonolarında vade 60-720 gündür. Satış sırasında vade belirlenip düzenlenerek bono üzerine yazılır (Parasız, 2000: 243).

Yatırım veya Kalkınma bankasından kredi kullanmak isteyen ortaklıklar tarafından düzenlenip teminat olarak bu bankalara verdikleri emre yazılı kıymetli

evraklara banka garantili bonolar. Krediyi kullandırmış olan banka tarafından garanti altına alınır ve SPK tarafından kayda alınmasının hemen ardından ihraç edilir. Satış tarihinden itibaren banka garantili bonolarda vade 60 ile 720 gündür.

1.4.6. Varlığa Dayalı Menkul Kıymetler

Ticari faaliyetler sonucunda oluşmuş alacaklar veya temellük eden alacakları karşılığında menkul kıymet ihraç edilebilir. SPK tarafından kayda alınırlar. Varlığa dayalı menkul kıymet çıkarmaya yetkili kuruluşlar; bankalar, finansman şirketleri, gayrimenkul yatırım ortaklıkları ve finansal kiralama şirketleri olarak sıralanabilir (Özyurt, 2004: 46).

1.4.7. Vadeli İşlem ve Opsiyon Sözleşmeleri

Belirlenen ileri bir tarih için tarafların üzerinde anlaşıldığı fiyattan bir mal veya kıymeti alım ya da satım yükümlülüğü getiren sözleşmeye vadeli işlem sözleşmesi denir.

Vadeli işlem sözleşmelerine ilaveten bir mal veya kıymeti alım yada satım hakkını, belirli bir ücrete müteakbil opsiyonu satın alan kişiye veren, opsiyon satıcısını ise bu hak kullanılmak istendiğinde zorunlu kılan sözleşmeler opsiyon sözleşmeleridir (Akgüç, 1998: 651).

2. BORSA İSTANBUL VE ENDEKSLER

Menkul kıymet borsalarının ortaya çıkmasında, fon alışverişlerinde yeni bir yatırım aracı kullanma ihtiyacı ve buna müteakbil olarak bir düzen içerisinde menkul kıymet alışverişinin yapılabilmesi arayışları etkili olmuştur (Aksoy ve Tanrıöven, 2007: 164). Menkul kıymet borsaları, yoğun bir şekilde alınıp satılmasına elverişli ortamı, arz ve talep arasındaki karşılaşmayı örgütleyerek hazırlamaktadır (Budak ve Emre, 2006: 3).

Menkul kıymet borsaları, pay senedi, özel tahvil ve devlet tahvili alım-satımı yapılan finansal varlıkların fiyatlarının belirlendiği ve ilan edildiği tüzel kişiliğe haiz kurumlardır (Budak ve Emre, 2006: 5). Bir başka deyişle belli kurallarla alıcıların ve satıcıların işlem yapmak üzere bir araya geldikleri pazarlardır.

2.1. BORSA İSTANBUL'A GENEL BAKIŞ

İstanbul Menkul Kıymetler Borsası (İMKB), 26 Aralık 1985 tarihinde kurulmuş olup 3 Ocak 1986 tarihinde faaliyetlerine başlamıştır. 2013 yılında İMKB yapısına Vadeli İşlem ve Opsiyon Borsasını da katarak Borsa İstanbul (BİST) adını alarak faaliyetlerine devam etmektedir. Günümüzde BİST, kote olmuş 514 şirket, hesaplanan 324 endeks, 14 sektör ve 55 alt sektör, 10 pazar ve yükselen işlem hacmi ile gelişen borsalar arasında yer almaktadır.

Borsa İstanbul'un başlıca amacı ve faaliyet konusu (BİST, 2018c):

“Kanun hükümleri ve ilgili mevzuat çerçevesinde, sermaye piyasası araçlarının, kambiyo ve kıymetli madenler ile kıymetli taşların ve Sermaye Piyasası Kurulunca uygun görülen diğer sözleşmelerin, belgelerin ve kıymetlerin serbest rekabet şartları altında kolay ve güvenli bir şekilde, şeffaf, etkin rekabetçi, dürüst ve istikrarlı bir ortamda alınıp satılabilmesini sağlamak, bunlara ilişkin alım satım emirlerini sonuçlandırarak şekilde bir araya getirmek veya bu emirlerin bir araya gelmesini kolaylaştırmak ve oluşan fiyatları tespit ve ilan etmek üzere piyasalar, pazarlar, platformlar ve sistemler ile teşkilatlanmış diğer pazar yerleri oluşturmak, kurmak ve geliştirmek, bunları ve başka borsaları veyahut borsaların piyasalarını yönetmek ve/veya işletmek ve ana sözleşmesinde yazılı olan diğer işlerdir.”

2.2. BİST'İN YAPISI

BİST'in özerk bir yapısı vardır ve faaliyet alanlarında hukuki düzenlemeler yapabilmektedir. BİST, T.C. Merkez Bankası, ticaret bankaları, kalkınma bankaları, yatırım şirketleri, sigorta ve emeklilik şirketleri vb. kurumlar ile birlikte Türkiye finans piyasalarında faaliyette bulunmaktadır (Altınbaş, 2012: 4).

BİST'in fonksiyonları aşağıdaki gibi sıralanabilir (Parasız, 2005: 100; Akçalı, 2002: 51; Yıldırım, 1991: 14; Karşlı, 2004: 217):

- Ekonominin Göstergesi Olma
- Ekonomiye Kaynak Sağlama
- Likidite Sağlama

- Sermaye Mülkiyetini Tabana Yayma
- Güvence
- Piyasada Tek Fiyat Olma

BİST, borsaya kote olmuş şirketlerin hisse senetlerinin güvenli ve istikrarlı bir şekilde alım satımlarının yapılmasını garanti eder. Sermaye piyasası kanununa ters düşen icraatlar ile pazar ve piyasaların açık, düzenli ve dürüst çalışmasını engelleyen faaliyetlerin tespitine yönelik, başta pay piyasası olmak üzere tüm piyasalarda oluşan olağan dışı fiyat ve miktar hareketleri elektronik olarak izlenir ve raporlanır. BİST'in denetimi SPK tarafından yapılmaktadır (Kavaklıdere, 2002: 42).

Ülkelerin menkul kıymet borsalarına ihtiyacı bulunmaktadır. Bu nedenle borsaların gelişmişliği ile ülkelerin kalkınmışlığı arasında büyük paralellik bulunmaktadır. Menkul kıymet borsaları; gelişmiş borsalar ve gelişmekte olan borsalar olarak sınıflandırılır. BİST'de gelişmekte olan borsalar içerisindedir. BİST, teknolojik altyapısıyla yatırımcılara yüksek düzeyde hizmet vermektedir.

Borsa İstanbul Piyasaları (BİST, 2018b):

1. Pay Piyasası

“Çok farklı endüstriyel sektörlerden halka açık şirketlerin işlem gördüğü Borsa İstanbul Pay Piyasası, yerli ve yabancı yatırımcılar için likit, şeffaf ve güvenli yatırım ortamı sağlamaktadır.”

2. Borçlanma Araçları Piyasası

“Borçlanma Araçları Piyasası hem kesin alım-satım işlemleri hem de repo-ters repo işlemleri için tek organize piyasadır.”

3. Vadeli İşlem ve Opsiyon Piyasası

“Vadeli İşlem ve Opsiyon Piyasası'nda Pay Vadeli İşlem ve Opsiyon Sözleşmeleri, Endeks Vadeli İşlem ve Opsiyon Sözleşmeleri, Döviz Vadeli İşlem ve Opsiyon Sözleşmeleri, Kıymetli Madenler, Emtia ve Enerji Vadeli İşlem Sözleşmeleri işlem görmektedir.”

4. Kıymetli Madenler ve Kıymetli Taşlar Piyasası

“Kıymetli Madenler ve Kıymetli Taşlar Piyasası'nda Kıymetli Madenler; Kıymetli Madenler Ödünç; Elmas ve Kıymetli Taş; alt piyasaları yer almaktadır.”

2.3. BİST ENDEKSLERİ VE HESAPLAMALARI

BİST, piyasalarla ilgili yatırımcıları bilgilendirmek için farklı nitelikte endeksler hesaplar. Hisse piyasası için iki şekilde hesaplaması vardır anlık ve seans sonlarıdır. Toplamda 324 endeks hesaplanır (BİST, 2018b). Bunların 54'ünü anlık hesaplar geriye kalan 270'ini seans sonlarında hesaplar. Hisselerin endeksleri fiyat ve getiri endeksi olarak hesaplanır. Fiyat endekslerinde fiyatın değişimi yansıtılır ancak getiri endekslerinde hem fiyatın değişimi hem de kar payı ödemeleri dikkate alınarak hesaplanır.

BİST, hisse endeksleri ve piyasa verileri ile ilgili bütün fikri mülkiyet hakları elindedir. Bu yüzden, finansal ürün ihraç işlemlerinin yapılması ve endeks hesaplanabilmesi için BİST ile lisans sözleşmesi imzalamalıdır.

Endeksler hesaplanırken kayıtlanan en son fiyat sepeti ele alınır. Borsaya kote olmuş şirketlerin paylarının fiili dolaşımdaki kısımlarının piyasa değeri dikkate alınarak endeksler hesaplanır. Endekslerin hesaplanması Denklem 51 ile yapılır (BİST, 2018b):

$$E_t = \frac{\sum_{i=1}^n (F_{it} / D_t) * N_{it} * H_{it} * K_{it}}{B_t} \quad (51)$$

E_t = Endeksin t zamandaki değeri,

n = Endekse dahil olan pay şirket sayısı,

F_{it} = “i” nci payın t zamandaki fiyatı,

N_{it} = “i” nci payın t zamandaki toplam sayısı,

H_{it} = “i” nci payın t zamandaki endeks hesaplamasında kullanılan fiili dolaşımda bulunan kısmının toplam pay sayısına oranı,

K_{it} = “i” nci payın t zamandaki katsayısı,

D_t = Endeksin döviz kurunun t zamandaki değeri,

B_t = Endeksin t zamandaki bölen değeri.

2.3.1. BİST 100 Endeksi

“Borsa İstanbul Pay Piyasası için temel endeks olarak kullanılmaktadır. Yıldız Pazar ve Ana Pazar’da işlem gören şirketlerle, Kolektif Yatırım Ürünleri ve Yapılandırılmış Ürünler Pazarı’nda işlem gören gayrimenkul yatırım ortaklıkları ve girişim sermayesi yatırım ortaklıkları arasından seçilen 100 paydan oluşmakta olup, BIST 30 ve BIST 50 endekslerine dahil payları da kapsar.”

Çalışmada BİST 100 endeksi kullanıldığı için burada diğer hesaplanan endeks tanımlarına yer verilmemiştir. Daha detaylı bilgiye Pay Endeksleri ve Hesaplanan Endeksler’den (BİST, 2018b) ulaşılabilir.

2.4. BİST ANALİZLERİ VE KULLANILAN ALTERNATİF GÖSTERGELER

Piyasadaki yatırımcılar yapacağı yatırımla ilgili karar vermeden önce finansal piyasalardaki fiyat hareketleri ile gelecekteki fiyatları tahmin etmek için geliştirilen temel analiz ve teknik analiz yöntemlerini kullanmaktadırlar. Bazı yatırımcılar sadece bir yöntemi benimserken bazıları ise yatırım kararı almak için her iki analiz yöntemine de başvurumaktadırlar (Doğan, 2006: 17).

Rasyonel bir şekilde maksimum faydayı hedefleyen yatırımcıların Temel Analiz ve Teknik Analiz yöntemi kullanılarak borsa endeksi fiyatının değişim yönünü tahmin etmeleri ilgisini çekmiştir. Temel Analiz ve Teknik Analiz yöntemleri bir sonraki başlık altında incelenecektir (Özkan vd., 2004).

2.4.1. Temel Analiz

Birçok ekonomik verinin bir araya gelmesiyle oluşan, oldukça uğraş gerektiren analize temel analiz denilmektedir. Normal bir bireysel yatırımcının temel

analiz yapabilmesi için gerekli bilgiye ulaşması ve bu bilgileri yorumlaması kolay olmamaktadır. Bundan dolayı da yatırımcılar aracı kurumlardan ve uzman kişilerden yardım alırlar (Anonim, 2006: 10).

Temel analiz, mikro ve makro göstergeler ve şirketin geçmiş mali verileri ile şirketlerin ekonomik, endüstriyel, sektörel durumlarını inceleyerek gerçek değerini ölçmeye ve bu gerçek değer ile piyasa değerini karşılaştırmaya çalışmaktadır (Atsalakis ve Valavanis, 2009:).

Temel analiz dört aşamada yapılır. İlk olarak ekonomi analizi yapılır, daha sonra sektör analizi yapılır, bir sonraki aşamada şirket analizi yapılır ve son aşamada kar tahmini, nominal hisse değeri tahmin edilerek Şekil 21’de gösterildiği gibi yapılır (Anonim, 2009: 10-23).

Şekil 21. Temel Analizin Aşamaları (Anonim, 2009: 10-23).



Ülke ekonomileri her zaman aynı düzeyde değildir. Örneğin, enflasyon oranları ya da faiz oranlarının olumlu veya olumsuz bir yönde seyir izlemesi şirket değerleri ve şirketin gelecekteki kararları üzerinde etkili olmaktadır. Bu nedenle temel analizin ilk aşamasında ekonomi analizi yapılmaktadır.

Ekonomi analizinden sonra yapılan ikinci aşama sektör analizidir. Her sektörün büyüme hızı aynı değildir. Bazı sektörler hızlı büyürken bazıları daha yavaş büyüebilmektedir. Bu nedenle şirketin içinde bulunduğu sektörün durumu yatırım yapmak için önemlidir. Ayrıca her sektör ülkenin içinde bulunduğu durumdan farklı derecede etkilenmektedir (Doğan, 2006: 16).

Sektörün geçmiş dönemlerdeki satış hacmi ve karları, rekabet koşulları, hükümet politikaları, gelecek dönemlerdeki arz talep durumu sektör analizi yapılırken dikkat edilmesi gereken faktörlerden bazılarıdır.

İlk iki aşamada bilgi toplandıktan sonraki aşama şirket analizidir. Şirket analizi, şirket ile ilgili bilgi ve belgelerin araştırılması ve mali tabloların analizi olmak üzere iki aşamada yapılmaktadır. İlk aşama yönetimden ürün ya da hizmete kadar birçok alanı kapsamaktadır. İkinci aşamada ise gelir tablosu ve bilanço gibi finansal veriler yer almaktadır. Bu finansal verilerden yola çıkılarak şirketin gerçek değeri hesaplanmaya çalışılır (Edwards, Magee ve Bassetti, 2007: 3).

Bireylerin ve kurumların hisse senedi alımından iki şekilde para kazanma ihtimalleri vardır. Birincisi gelecekteki temettü dağıtımını ikincisi ise sermaye kazancıdır. Temettü dağıtımıyla birlikte şirketin hisse fiyatı dağıtılan temettü kadar düşer fakat sonrasında yatırımcıların temettü dağıtan şirkete güveni artar ve hisse fiyatları yükselmeye başlar.

Temel analiz sadece şirketle ilgili konuları değil, makroekonomik göstergeleri de kapsamaktadır. Bu da bize her şeyin hisse fiyatlarına yansıdığını gösterir. Etkin piyasa hipotezine göre fiyatlar diğer günlere göre bağımsızdır ve yatırımcıların her türlü bilgiye aynı anda ulaştığı varsayılır (Malkiel ve Fama, 1970: 387).

2.4.2. Teknik Analiz

Analiz yöntemlerinden biri olan teknik analiz, herhangi bir yatırım aracını değerlendirirken ülke, sektör ya da firmayı ilgilendiren ekonomik gelişmelerin incelenmesinin yanı sıra geçmiş fiyat bilgileri, arz ile talebin durumunu ve geleceğini modellemeye yarayan birçok grafik, matematiksel eşitlikler ve göstergeler kullanılmaktadır (Kirkpatrick ve Dahlquist, 2007: 3). Bu yaklaşıma göre, hangi zaman aralığı inceleniyorsa o zaman aralığı içerisinde alıcı ve satıcılar arasındaki denge ve oluşan fiyat bir eğilim içerisindedir. Bu nedene bağlı olarak analizin asıl amacı bu eğilimi ve yönünü belirlemeye çalışmaktır (Murphy, 1986: 71).

Teknik analiz temel analiz gibi dış etkenlerden etkilenmeyen, sadece piyasa verilerinden hareketle geçmişteki ve günümüzdeki fiyatları inceleyerek, gelecekteki fiyatları tahmin etmeye çalışan bir analiz yöntemidir. Teknik analizin gelecekte neler olacağını bilmek gibi bir iddiası yoktur. İnsan psikolojisi üzerine kurulu olan teknik

analiz, yatırımcıların hangi durumlarda hangi hataları tekrarlayacaklarını bulma eğilimindedir (Edwards, Magee ve Bassetti, 2007: 5). Bu nedenle teknik analizde önyargılara yer yoktur (Dinç, 2006).

Zaman, fiyat değişimleri, işlem miktarı, genel piyasa koşulları teknik analiz ile ilgili konulardır. Teknik analiz yöntemini kullanan yatırımcılar, çeşitli dönemlerdeki trendleri izler ve trendlerin yönüne göre alım ya da satım yapılabilir gibi yorumlarda bulunurlar (Doğan, 2006: 15). Diğer analiz yöntemlerine göre farkı ise daha kısa sürede al ya da sat sinyali verebilmeleridir.

Teknik analiz, daha çok yatırım aracını satın aldıktan kısa bir süre sonra kar elde ederek satmayı hedefleyen spekülörler tarafından tercih edilir (Brealey vd., 2012: 206). Bunun yanı sıra, uzun vadeli yatırımcılar da teknik analizi, yapmış oldukları temel analiz sonrası harekete geçmek için zamanlamayı belirlemeye yardımcı olması için kullanırlar.

Analiz yapanların gelecek beklentileri ve trend yönlerine ilişkin, Londra Borsası'nda ortaya atılmış olan “boğa” ve “ayı” piyasası terimleri ilk olarak 18. Yüzyıl başlarında kullanılmaya başlanmıştır (Güçlü, 2010: 5).

Geleceğe dair iyimser bir tutuma sahip yatırımcılar “Boğa piyasası” terimini kullanmaktadırlar. Elleriinde yeterli miktarda para olmasa dahi borçlanarak ya da kredi kullanarak yatırım araçlarını satın almayı gerçekleştirir ve daha sonra yüksek fiyattan satarak kar elde etmeyi amaçlarlar. Bu terimin kullanılma sebebi boğanın boynuzlarını kullanarak her şeyi yukarı kaldırmasından dolayıdır (Edwards, Magee ve Bassetti, 2007: 650).

Geleceğe dair karamsar bir tutuma sahip yatırımcı için ise “Ayı piyasası” terimi kullanılmaktadır. Bu düşünceye sahip yatırımcılar riski göze alarak ellerindeki yatırım araçlarını satarlar ve daha sonra düşük fiyatla geri almayı amaçlarlar. Satış ve alış arasındaki farkı kar olarak elde etmiş olurlar. Bu terimin esin kaynağı “Ayıyı yakalamadan derisini satmak” olduğu düşünülmektedir (Edwards, Magee ve Bassetti, 2007: 650).

Hisse senedinin düşeceği beklentisinde olan yatırımcılar, senedi elinde bulundurmadığı halde aracı kurumlara başvurarak açığa satış işlemi yapabilirler yani bir başka deyişle senedi kiralamış gibi olurlar. Fiyatların düşmesi halinde yatırımcı

yüksek fiyattan satıp düşük fiyattan alarak aradaki fark kadar kar elde eder. Bu işlem yükseliş yerine düşüş meydana geldiğinde de kar elde etmek amacıyla yapılmaktadır ve genelde büyük miktarlarda işlem yapan kişi ve şirketler tarafından yapılır (Güçlü, 2010: 6).

Teknik analizin en temel unsuru grafiklerdir. Piyasa fiyatlarının değişen hareketlerinin belli bir zaman aralığında ve işlem hacmi ile yansıtılmasına grafik denir. Fiyat hareketleri grafiklerden rahatlıkla görülebilir ve matematiksel işlemler yapılırken bu grafiklerden yararlanılabilir (Edwards, Magee ve Bassetti, 2007: 4). Formasyonlar, göstergeler, trendler, destek ve direnç noktaları grafik üzerinden tespit edilerek, gelecekte oluşabilecek fiyatlar tahmin edilebilir. Teknik analiz yorumlama sanatıdır. Geçmişteki fiyat grafiklerinden faydalanılarak yeni grafikler çizilebilir ve yorumlanabilir.

Teknik analiz ilk olarak ABD’de ortaya çıkmıştır ve Dow Teorisi temeline dayanır (Fama, 1969: 383). O zamanki amaç tek tek hisse senetlerini incelemek yerine birkaç ortalama ile bütün piyasanın nabzını tutmaktır. Günümüzde de bilgisayarlarında yaygınlaşmasıyla birlikte fiyatı olan her şey için teknik analiz yapılabilir.

2.4.3. Analizde Kullanılan Diğer Yöntemler

Fiyat akımlarının sayısal realitelerinden faydalanılarak sağlanan sonuçların kesin matematiksel değerlerle ifade edilen göstergelerin neden-sonuç ilişkisini sorgulamaz. Grafik üstüne temellendirildiğinde kesinliği olan sayısal hesaplamalarla grafik üzerinden oluşan sonuçlar gösterilir. Göstergeler fiyat akımlarının tarihsel sürecinde standart baskılar ile sürekli belirli sonucun çıkması yönünde olduğu realitesiyle üretilerek fiyatların kesin değerleriyle şimdiki durumu ilişkilendirir (Achelis, 2001: 26).

Bunu uygularken tesadüfi ya da hissetme temelli sonuçlar üretmez, zaman zaman fiyat üzerinde bir hareket sürekliliği, bazen alt bölümde yoğun bir gösterim, bazen de sınır ayraçları ile tümüyle net sonuçları olan sayısal değerlerin işlenmesiyle rakamlar elde eder ve grafikte gösterimi yapılır. Gösterim ayırt etmeksizin tüm göstergeler kişisel değil sayısal realiteli, dayanaklar oluşturur (Çetinyokuş ve Gökçen, 2002: 44).

Türkçedeki genel ismiyle göstergeler grubu yabancı kaynaklarda ve yer yer Türkiye’de de gösterge ismiyle anılır. Göstergeler farklı isim ve özellikte işlem yerinde kullanılacak şekilde menüde bulunmaktadır. Bir tuşa basarak istediğiniz göstergeyi çalıştığımız fiyat grafiğine yansıtılabilir. Sonuçlardan memnun olmak için zaman zaman göstergeleri sınanmalı ve yatırım tercihlerine uygun şekilde kullanılmalıdır (Wong, Manzur ve Chew, 2003: 550). Bu nedenle göstergeler kişisel değil de matematiksel verilere dayandırılınca fiyat hareketlerini tahmin etmekte başarılı sonuçlar alınabilir.

Bu tezde literatürde genel kabul görmüş göstergelerden 10 tanesi aşağıda detaylı şekilde anlatılacaktır.

2.4.3.1. Hareketli Ortalamalar (10 Günlük)

Hareketli ortalamalar teknik analizde kullanılan en önemli göstergelerden biridir. Bir hisse senedinin belirli bir zamandaki fiyat ortalamalarını gösterir. Bu gösterge fiyat değişimlerinde oluşan arz ve talebin hangi yönde olacağını göstererek yatırımcıya alım satım kararlarında yardımcı olur (Ali vd., 2015: 2).

Hareketli ortalamaların farklı türleri bulunmaktadır. Basit hareketli ortalama, ağırlıklı hareketli ortalama, üstel hareketli ortalama en çok kullanılan hesaplama yöntemidir. Basit hareketli ortalamalar fiyatları yavaş bir şekilde takip etmekte ve vadenin uzaması bu yöntemde başarılı sonuç alınmasını etkilemektedir. Ağırlıklı hareketli ortalama ise bugünkü fiyatlara önem vermektedir (Marple ve Marple, 1987: 288).

Hareketli ortalamalarda kullanılacak zaman aralığı yatırımcının kısa ya da uzun vadeli yaptığı yatırımlara göre değişmektedir. Kısa vadeli yatırım yapacak olan yatırımcıların dikkate alacağı zaman aralığı kısa olurken, uzun vadeli yatırım yapmayı düşünen yatırımcılar için ise zaman aralığı daha uzun olacaktır. Hareketli ortalamalar için 10 günlük bir periyot çok kısa vadeyi ifade ederken, 300 günlük periyot uzun vadeyi kapsamaktadır (Marple ve Marple, 1987: 289).

Hareketli ortalamaların güvenilir ve basit olması ayrıca geçmiş fiyatların şimdiki fiyatlardan ne kadar saptığını hesaplaması popüler olmasının nedenlerindedir. C_t kapanış fiyatı iken Hareketli Ortalama Denklem 52 ile hesaplanır (Kristoufek, 2014: 170):

$$HO = \frac{C_t + C_{t-1} + \dots + C_{t-9}}{n} \quad (52)$$

2.4.3.2. Ağırlıklı Hareketli Ortalamalar (10 Günlük)

Ağırlıklı Hareketli Ortalamalar; Hareketli Ortalamalar başlığı altındaki en sık kullanılan 3 yöntemden birisidir. Bu yöntem teknik analizde sıklıkla kullanılmaktadır. Ağırlıklı Hareketli ortalamalar; istenilen periyotlarda son günlerdeki kapanış fiyatlarına diğer fiyat hareketlerine nazaran daha fazla ağırlık verilerek hesaplanan ortalamalar olarak tanımlanabilir (Lucas ve Saccucci, 1990: 1).

HO diğer yöntemleri ise Basit Ağırlıklı Ortalama ve Üslü Hareketli Ortalamadır. Aslında diğer ortalamaları da incelediğimizde Ağırlıklı Hareketli Ortalamalar Basit Hareketli Ortalamaların eksik kaldığı fikriyle ortaya çıkmıştır. Çünkü Basit Hareketli Ortalamalarda geçmiş günde ki kapanış fiyatları eşit olarak dikkate alınarak değerlendirilir. Ağırlıklı Hareketli Ortalamalarda bu durum tam tersine son günlere ağırlık verilerek değerlendirilir. Örneğin beş günlük bir fiyat hareketi varsa Basit Hareketli Ortalama Ağırlıklı fiyat toplamını 5'e böler ama Ağırlıklı Hareketli Ortalama ağırlığın toplamına yani 15'e böler. Ağırlıklı Hareketli Ortalama Denklem 53 ile hesaplanır (Lowry vd., 1992: 47):

$$AHO = \frac{(10)C_t + (9)C_{t-1} + \dots + C_{t-9}}{n + (n-1) + \dots + 1} \quad (53)$$

Ağırlıklı Hareketli Ortalamalarda, belirlenmiş bir zaman dilimi vardır ve bu zaman diliminin içerisinde bulunan son günlerin fiyatları dikkate alınarak hesaplanır (Lowry vd., 1992: 47). Bu yöntemin kısa vadeli analizler için kullanılması daha uygundur.

2.4.3.3. MACD (Hareketli Ortalama Yakınsama İraksama)

MACD göstergesi trend takipçisi olan ve fiyatların iki farklı hareketli ortalaması arasındaki ilişkiyi gösteren bir momentum göstergesidir (Appel, 2003: 27). Temel olarak 26 günlük üssel hareketli ortalamasının 12 günlük üssel hareketli ortalamadan çıkartılması ile elde edilmektedir. Sıfır seviyesinde gösterge dengededir. MACD'nin hareket yönü sıfırın altına ve üstüne doğrudur. MACD'nin iki değeri alınır: 12 ve 26 günlük ortalama değerleri. 12 günlük ortalama değeri 26

günlüğün üstüne çıkarsa MACD'de sıfır seviyesinin üstüne çıkar ve bu kısa vadeli işlemlerin uzun vadeliden daha güçlendiğini gösterir. Eğer 12 günlük ortalama 26 günlüğün altında ise MACD'de sıfır seviyesinin altına düşer ve bu uzun dönemde satışların etkili olacağını gösterir (Chong ve Ng, 2008: 1112).

MACD göstergesinin 3 tane önemli ve en çok kullanılan yorumlanma methodu vardır (Fernández-Blanco vd., 2008: 1852):

1. Kesişmeler: MACD göstergesi sinyal çizgisinin altına düşerse bu aşağı yönlü bir sinyal oluşturmakta olup satış zamanının geldiğine işaret edebilmektedir. Ters durumda ise MACD göstergesi sinyal çizgisinin üzerine çıkarsa bu yukarı yönlü bir sinyal oluşturmakta ve alış seviyelerinin geldiğine işaret edebilmektedir. Çoğu yatırımcılar yanlış sinyallerin önüne geçebilmek için kesişme seviyesinin de üzerini beklemektedirler.
2. Ayırışmalar: Finansal bir ürünün fiyatı MACD göstergesinden ayrışsa bu mevcut trendin sona erdiği anlamına gelmektedir.
3. Anormal Yükselişler: MACD göstergesi anormal bir şekilde yükselirse bu kısa vadeli hareketli ortalamanın uzun vadeli ortalamayı yukarı yönlü ittiğini göstermektedir. Bu da ilgili finansal ürünün aşırı alım bölgesinde olduğu ve kısa sürede normal haline döneceğine işaret etmektedir. Yatırımcılar ayrıca sıfır çizgisinin altını ve üstünü de sinyal olarak dikkate almaktadırlar. MACD göstergesi sıfır çizgisinin üzerindeyken, kısa vadeli ortalama uzun vadeli ortalamanın üzerindedir ve yukarı yönlü hareketin devam edebileceğini göstermektedir. Sıfır çizgisinin altı ise bunun tam tersini ifade etmektedir. MACD, Denklem 54 ile hesaplanır (Fernández-Blanco vd., 2008: 1852):

$$DIFF_t = ÜHO(12)_t - ÜHO(26)_t,$$

ÜHO: Üssel Hareketli Ortalama iken

$$MACD = MACD(n)_{t-1} + \frac{2}{n+1} \times (DIFF_t - MACD(n)_{t-1}) \quad (54)$$

2.4.3.4. CCI (Emtia Kanalı Endeksi)

CCI; geçmiş dönem fiyat hareketi ortalamasının, güncel fiyat ile farkının hangi uzaklıkta olduğunu tespit etmekte ve yorumlamaya çalışmaktadır. Fiyatların 22

günlük bir periyotta 11 günlük yükseliş, 11 günlük düşüşle hareket ettiğini tespit etmekte ve bu nedenle göstergenin 11 günlük kullanılmasını uygun görmektedir (Lambert, 1983: 2).

CCI göstergesinin karmaşık ve anlaşılması zor olan hesaplama yöntemi vardır. CCI, 11 günlük periyotta her gün için kapanış, en yüksek ve en düşük fiyatların ortalamasını hesaplar. Sıfır çizgisi merkez olarak kabul edilir ve -100 ile +100 referans olarak kabul edilir (Lambert, 1983: 2).

CCI göstergesi için +100'ün üstü aşırı alım, -100'ün altı ise aşırı satış bölgesi olarak kabul edilmektedir. Fakat CCI çok hızlı değişiklik gösterdiği için küçük değişimlerde bile referans noktalarını geçebilir. Bu sebeple daha çok kısa vadeli trend değişimlerini belirlemede tercih edilmektedir. CCI, Denklem 55 ile hesaplanır (Hsu, 2011: 14035).

$$M_t = \frac{H_t + L_t + C_t}{3}, \quad SM_t = \frac{(\sum_{i=1}^n M_{t-i+1})}{n}, \quad D_t = \frac{(\sum_{i=1}^n |M_{t-i+1} - SM_t|)}{n}$$

L_t : En düşük fiyat , H_t : En yüksek fiyat

$$CCI = \frac{M_t - SM_t}{0.015D_t} \quad (55)$$

2.4.3.5. RSI (Göreceli Güç Endeksi)

Türkçe anlamı kişiye göre değişen güç endeksi olan RSI, yayımlandıktan sonra büyük ses duyuran çoğu yatırım alanında sıkça kullanılan bir gösterge olmuştur (Özari, Turan ve Demir, 2016: 100).

RSI, yatırım araçlarını ilgili dönemi eski günlerle karşılaştırarak değerlendirir. Grafiğe eklendiğinde ise alt kısımda bir histogram şeklinde görülür. Dikey ekseninde 0 ile 100 arasında bir seviyede seyir eden bir gösterge için 30 ve 70 fiyat seviyesinde iki sınır çizilmiştir. RSI'nın 30 seviyesinin altında bulunması fiyatla uyum sağlamayan aşırı satış talebini gösterirken, RSI'nın 70 seviyesi üzerine çıkması aşırı alım talebinin gösterir. Bu göstergeler fiyat hareketinin farklılık göstereceği ile ilgili ilk bilgileri verir (Klassen, 2005: 77).

RSI hesaplanırken o dönem içindeki günlerin azalışlarını ve yükselişlerini farklı farklı toplayarak ortalamalarını hesaplar ve elindeki fiyat seviyesiyle kıyaslar. Bu amaçla yatırım aracının kendi gücüyle talebi karşılayıp karşılayamayacağını görür. Eski talep karşısında oluşan fiyat değişikliği RSI için önem arz eder ve göstergenin temeli yatırım aracının kendini gücüne bağlıdır. Tahmin edileceği üzere her bir yatırım aracında meydana gelen alım veya satım taleplerinin farklı seviyede hareketle karşılık vermesi muhtemeldir. RSI'nın en temel hedefi yatırım aracının fiyat dalgalanmalarını önceki günlerin ortalamasıyla anlamak ve bugünkü taleplerin oluşturacağı etkiyi tespit etmektir. Yukarıdaki 70 sınır çizgisi ve aşağıdaki 30 sınır çizgisi taleplerin durumunu belirlemek içindir. Konulan sınırların dışına çıkan değerler kısa zamanda bir farklılık göstereceği muhtemeldir (Taran-Moroşan, 2011: 5857).

RSI, fiyat grafiklerine 14 günlük periyotta ortalaması hesaplanarak yerleştirilir ve Denklem 56 ile hesaplanır (Klassen, 2005: 77):

UP_i : Yukarı doğru fiyat değişim ortalaması , DW_i : Aşağı doğru fiyat değişim ortalaması

$$RSI = 100 - \frac{100}{1 + \left(\frac{\sum_{i=0}^{n-1} UP_{t-i}}{n} \right) / \left(\frac{\sum_{i=0}^{n-1} DW_{t-i}}{n} \right)} \quad (56)$$

2.4.3.6. Stokastik %K

Stokastik %K gelecekteki fiyatların, daha önce görülen kapanış fiyatlarına yakın seviyelerden olacağını öngörerek teknik analiz yapılmasına yardımcı olan ve Stokastik George Lane tarafından geliştirilen bir göstergedir (Lane, 1985: 37).

Fiyatlar yükseliyorsa enstrümanın kapanış fiyatı seçildiği zaman dilimi içindeki en düşük fiyata doğru yönelme eğilimi gösterecektir. Stokastik göstergesi grafik üzerine eklendiği durumlarda birbirine bağlı olarak hareket eden iki çizgi belirir. Kesiksiz düz çizgi ile çizilen %K eğrisi olarak adlandırılır. İkinci bir çizgi ise kesikli çizgi ile gösterilir ve %D olarak adlandırılır. Yavaşlatılmış değişim değerini %K çizgisi gösterirken %D çizgisi daha dinamik ve duyarlı bir hat oluşturmaktadır (Sihabuddin, Rosadi ve Wibowo, 2009: 1015).

Son beş günün en düşük değeri ile son kapanış arasındaki fark, en yüksek değer ile en düşük değer arasındaki farka bölünmektedir. Bulunan sonuç 100 ile çarpılarak yüzde değerine eşitlenir (Kim, 2003: 311).

Son gün kapanış fiyatı, son beş gün içindeki en yüksek değere daha yakın olduğu durumda fiyatların yükseleceği, tersi durumda fiyatların düşeceği öngörülür. Belirlenmiş zaman aralığı içinde takibi yapılan 80 değer üzerinde oluşan harekette aşırı alımlardan dolayı satışa dönebileceği 20'nin altındaki değerde ise aşırı satışlar nedeniyle alışı dönebileceğini göstermektedir. Stokastik %K, Denklem 57 ile hesaplanır (Hsu, 2011: 14034):

$$\text{Stokastik \%K} = \frac{C_t - LL_{t-(n-1)}}{HH_{t-(n-1)} - LL_{t-(n-1)}} \times 100 \quad (57)$$

2.4.3.7. Stokastik %D

Yavaşlatılmış %K eğrisi belli bir periyot için hesaplanan %K eğrisinin ortalamasına denir. Belli bir periyot için olan hareketli ortalamaya ise %D eğrisi adı verilmektedir (Lane, 1985: 37).

%D çizgisi kesik çizgi halinde gösterilmekte ve sinyal çizgisi olarak bilinmektedir. RSI'da görüldüğü gibi fiyat ve grafik üzerindeki uyumsuzluklar sinyal özelliği taşımaktadır. Fiyatlar yükselirken gösterge dönüş yönünde ise fiyatlar düşüş yönünde olacak anlamına gelmektedir (Sihabuddin, Rosadi ve Wibowo, 2009: 1015).

Alım-satım sinyalleri Stokastik %D'yi yukarı yönlü keserse alım, aşağı yönlü keserse satım özelliği taşımaktadır. Stokastik %D, Denklem 58 ile hesaplanır (Kim, 2003: 311):

$$\text{Stokastik \%D} = \frac{\sum_{i=0}^{n-1} K_{t-i}}{10} \% \quad (58)$$

2.4.3.8. William's %R

0 ile 100 arasında değer alan stokastikde ki şekilde serilerde bulunan kapanışları periyottaki zirve ve dip değere olan mesafesine göre değerlendiren osilatörün gelişimi L.Williams tarafından gerçekleştirilmiş ve -100 ile 0 arasında değerler alan bir göstergedir (Saffi, 2003: 959).

Will's %R'a göre stokastik yakın şekilde bir senedin değerinin -80 referans değerinden düşük olması hisse sahiplerinin büyük çoğunluğunun pozisyonunu kapatmasına ve ardından hisse fiyatının yükselerek toparlanacağı, -20 referans değerinin üzerinde olması ise yatırımcıların büyük çoğunluğunun uzun pozisyona girmesine ve ardından pozisyonların kapatılarak gevşeyeceği sinyalini verir (Achelis, 2001: 227).

Will's %R periyot ve referans değerlerinin yanı sıra değerler arasındaki uyumsuzlukları da kontrol etmektedir. Fiyatların en yüksek ve en düşük değerlerine bakılarak Will's %R açısından yükselişteki en yüksek ve en düşük değerlerle düşüşteki en yüksek ve en düşük değerler karşılaştırılarak sonuca varılmalıdır (Achelis, 2001: 227).

Ayrıca Will's %R'a göre gireceğimiz pozisyonun sinyalini alabiliriz. Hareketli ortalamasını yukarı doğru keserek üzerine çıkarsa uzun pozisyon tersi olursa kısa pozisyona girme sinyalini almış oluruz. Will's %R, Denklem 59 ile hesaplanır (Steele ve Esmahi, 2015: 4):

$$William's \%R = \frac{H_n - C_t}{H_n - L_n} \times 100 \quad (59)$$

2.4.3.9. Momentum

Momentum fiyatların vadesi içerisindeki değişiminin yüzde halinde gösterimidir. Fiyatın değişim hızının oransal görünümü için geçmiş verileri hesaplar (Ding, Fang ve Zuo, 2013: 2).

Göstergenin baz aldığı değer ortasındaki izafi doğrudur ve bu doğru %100'dür. Gösterge eğer bu değerden uzaklaşırsa ters yönde nedenler oluşmaya başlar. Göstergedeki orta seviyeden uzak yerde tepe noktası yaptıktan sonra dönen fiyatlar için al-sat sinyali oluşur. Bu değişim fiyatların olması gerektiğinden çok daha fazladır. Bu yüzden en yüksek fiyattan sat, en düşük fiyattan al mantığıyla pozisyon açılabilir. Bununla birlikte pozisyon için fiyatların tersi yönde hareketlenmesi de beklenebilir (Inghelbrecht vd., 2012: 2244).

Momentum için negatif uyumsuzluk öngörüsü aynı RSI göstergesinde olduğu gibi kullanılabilir. Fiyat ve momentum göstergesi arasında uyumsuzluk olduğunda

mevcut fiyat yönünün değişeceği düşünülebilir. Momentum, Denklem 60 ile hesaplanır (Hsu, 2011: 14035):

$$\text{Momentum} = C_t - C_{t-9} \quad (60)$$

2.4.3.10. A/D (Alım/Dağıtım Göstergesi)

A/D, fiyatlarda meydana gelen değişim ne denli yüksek işlem hacmiyle olursa o kadar güçlü bir trendin var olacağını ve bu trendin devam edip-etmeyeceğini araştırır (Achelis, 2001: 44).

A/D'nin hesaplanması çok kolaydır, kapanış fiyatıyla günün en düşük olduğu fiyat farkından günün en yüksek fiyatı ile kapanış farkının çıkarılarak, günün en yüksek fiyatı ile günün en düşük fiyat farkına bölünmesiyle elde edilen değer işlem adedine çarpılmasıyla elde edilir (Achelis, 2001: 45).

Bu hesaplama yöntemi sonucunda kapanış fiyatı günün en yüksek fiyatına yaklaştıkça A/D değeri artacak, tam tersi kapanış fiyatı günün en düşük fiyatına yaklaştıkça A/D değeri azalacaktır. Kapanış fiyatının günün en yüksek ve günün en düşük olduğu mesafelere eşit olması durumunda A/D değeri aynı kalacaktır. A/D, Denklem 61 ile hesaplanır (Steele ve Esmahi, 2015: 4):

$$A/D = \frac{H_t - C_{t-1}}{H_t - L_t} \quad (61)$$

Çalışmanın bir sonraki bölümünde BİST 100 Endeksi yön tahmini problemi çözümü için teknik göstergelerin girdi veri seti olarak kullanıldığı sınıflandırma yöntemlerinin performanslarının karşılaştırılması yapılacaktır.

DÖRDÜNCÜ BÖLÜM

BORSA ENDEKSİ HAREKET YÖNÜNÜN TAHMİNİ UYGULAMASI

Bu bölümde, makine öğrenmesi yöntemleri olan Yapay Sinir Ağları (YSA), Destek Vektör Makineleri (DVM), Karar Ağacı (KA), Naive Bayes (NB) ve k-En Yakın Komşuluk (k-EYK) yöntemleri ile geleneksel istatistiki yöntemlerden Lojistik Regresyon (LogR) ve Doğrusal Diskriminant Analizi (DDA) yöntemleri Borsa İstanbul (BİST) 100 Endeksinin yön tahmininde kullanılmıştır. Bu amaçla kullanılmak üzere 1995:3-2018:3 dönemine ait veri seti, literatürde en çok rastlanılan 10 teknik göstergenin (Hareketli Ortalama, Ağırlıklı Hareketli Ortalama, MACD, CCI, RSI, Stokastik %K, Stokastik %D, William's %R, Momentum, A/D) hesaplanmasıyla oluşturulmuştur. Bu sınıflandırma yöntemlerinden hangisinin endeksin yönünü daha yüksek doğrulukla tahmin ettiği belirlenmeye çalışılmıştır. Ayrıca, makine öğrenmesi yöntemleri ile geleneksel istatistiki yöntemlerinin bu sınıflandırma probleminde performansları karşılaştırılarak tahmin doğrulukları irdelenmiştir.

1. UYGULAMANIN AMACI

Bu çalışmada, BİST 100 endeksi yönünü tahmin etmek için teknik gösterge verilerini doğrudan kullanan sınıflandırma yöntemleri kullanılmıştır ve sınıflandırma yöntemlerinden olan makine öğrenmesi yöntemleri ile geleneksel istatistik yöntemlerinin doğruluk tahmin performansları karşılaştırılması amaçlanmıştır.

2. UYGULAMANIN YÖNTEMİ

Bu bölümde sınıflandırma yöntemleri, parametre tespiti ve kurulan modeller detaylı bir şekilde tanıtılacaktır. Çalışmanın konusu; hesaplanan teknik göstergelerin girdi verisi olarak alındığı, sınıflandırma yöntemlerinin kullanıldığı, modelleri karşılaştırmak üzere doğruluk ve hata oranlarının ölçüt olarak kullanıldığı borsa endeks hareket yönünün tahminlenmesidir. Hisse senedi piyasalarının tahmin edilebilirliğine ve BİST 100 endeksinin yön tahminine değinilecektir. Öz nitelik olarak borsa günlük verileri seçilmiştir. Daha sonra YSA, DVM ve k-EYK

yöntemlerinin parametre seçimleri hakkında bilgi verilecektir. Çalışmada kullanılacak model ifade edilecektir. Sınıflandırıcı performansını değerlendirme metriklerinden doğruluk ve hata oranları hakkında bilgi verilecektir. Bulgular ve sonuçlar kısımları ile çalışmamız son bulacaktır.

3. HİSSE SENEDİ PİYASALARININ TAHMİN EDİLEBİLİRLİĞİ

Belirsizlikler nedeniyle endeks ve hisse senedi fiyat yönünü tahmin etmek zordur. Bu nedenle hisse senedi fiyat değişimlerinin yönünü tahmin etmek önemli bir kazanımdır, çünkü borsa işlemleri için etkili stratejilerin geliştirilmesine katkıda bulunur (Oliveira, Nobre ve Zárate, 2013: 7596).

Yatırımcıların bir hisse senedine yatırım yapmadan önce yaptıkları iki tür analiz vardır. Birincisi olan temel analizde yatırımcılar, yatırım yapıp yapmayacağına karar vermek için hisse senedi, endüstri ve ekonominin performansı, politik ortam vb. kriterleri analiz etmeye çalışırlar. İkinci yöntem olan teknik analiz ise, geçmiş faaliyetler ve hacimler gibi piyasa faaliyetlerinden elde edilen istatistiklerin incelenmesi yoluyla hisselerin değerlendirilmesidir. Teknik analizciler, kalıpları ve trendleri tanımlamak için hisse senedi grafiklerini kullanırlar (Patel vd., 2015: 259). Teknik analiz, tüm dünyada genel kabul görmüş bir kavramdır ve hisse senedi fiyatlarını tahmin etmek için kullanan birçok ekonomist ve araştırmacı vardır (Aldin, Dehnavi ve Entezari, 2012: 26).

Teknik analiz fikrini oluşturan faktör, hisse senedi fiyatındaki değişim eğiliminin, yatırımcıların öngörü farklılaşmalarından etkilenmesidir. Sürekli olarak tarihin tekrarlandığını ve gelecekteki hisse senedi fiyat değişikliklerinin hisse senedinin önceki fiyatlarına göre belirlendiğine inanılmaktadır (Razmi, Julie ve Emami, 2005:).

Beklenen fiyat dalgalanmalarının tahminlerini üretmek için zaman serileri matematiksel modellerini veya bilgisayar algoritmalarını kullanma yatırımcıların ve araştırmacıların çok ilgisini çeker (Oliveira, Nobre ve Zárate, 2013: 7596). Endeks yönünün önceden tahmini yatırımcılar ve araştırmacılar için büyük önem arz etmekte ve bu konunun çözümü için çeşitli algoritmalar geliştirilmiştir. Makroekonomik ve teknik göstergeler, analizcilerin gelecekteki hisse senedi fiyat değişikliklerini tahmin etmede kullandıkları modellerin öznelikleri ve değişkenleridir (Razmi, Julie ve

Emami, 2005:). Teknik analizci, bir modelin parametrelerini belirlemek için hisse senedi fiyatıyla ilgili mevcut bilgilerin yanı sıra geçmiş performansı da araştırır. Ayrıca, uygulanabilir modelin tahmin kapasitesini de inceler. Bunlardan hareketle en iyi tahmin modelini oluşturur (Sinaee, Mortazavi ve Teimori, 2005). İstatistiksel tahmin teknikleri olan Doğrusal Regresyon, Lojistik Regresyon, Doğrusal Diskriminant Analizi, Random Walk ve ARIMA gibi modellerin yanı sıra makine öğrenmesi algoritmalarından olan YSA, DVM, KA, NB ve k-EYK yöntemleri son yıllarda daha çok kullanılmaya başlamıştır. Makine öğrenmesi tekniklerinin geleneksel tekniklere göre daha yüksek tahmin doğruluğu sonuçları ürettiği görülmüştür (Çalışkan ve Deniz, 2015: 192).

20. yüzyılın ikinci yarısında çeşitli borsalarda fiyat değişimleri arasındaki korelasyon hakkında kapsamlı çalışmalar yapılmıştır. Tüm bu çalışmalar, korelasyon ve fiyat değişimleri eğiliminin varlığını göstermeyi amaçlamıştır (Aldin, Dehnavi ve Entezari, 2012: 26). Malkiel ve Fama (1970) tarafından ortaya atılan etkin piyasa hipotezi; tüm bilginin hisse senedi fiyatlarının içinde olduğunu belirtmekte, bu da alım satım verilerine dayanarak hisse senedi fiyatlarının tahmin edilebileceği anlamına gelmektedir. Bu, ülkenin politik ortamı gibi pek çok belirsiz faktörün, şirketlerin halk arasındaki imajının hisse senedi fiyatlarına yansımaya başlayacağı kadar mantıklı bir durumdur. Bu nedenle, hisse senedi fiyatlarından elde edilen bilgiler verimli bir şekilde önceden işlenirse ve uygun algoritmalar kullanılırsa, endeks veya hisse senedi fiyatı hareket yönü tahmin edilebilir (Patel vd., 2015: 259).

4. BİST 100 ENDEKSİNİN YÖN TAHMİNİ

Borsa fiyatı, bir ülkenin ekonomik büyümesinin en önemli göstergelerinden biridir 1985 yılında (BİST) kuruluşundan bu yana, Türkiye hisse senedi piyasaları hızla genişlemiştir. Türkiye hisse senedi piyasalarının oynaklığı ve Türkiye yasal düzenleyici ortamından kaynaklanan ilave riskler göz önünde bulundurulduğunda, endeksin yön tahmininin önemi ortaya çıkmaktadır. Yapılan çok sayıdaki çalışma (Diler, 2003; Ege ve Bayrakdaroğlu, 2009; Kara, Boyacıoğlu ve Baykan, 2011; Öz vd., 2011; Karymshakov ve Abdykaparov 2012; Yakut, 2012; Emir, 2013; Tayyar ve Tekin, 2013; Akyatan, 2016; İlarıslan, 2016; Pehlivanlı, Aşıkgil ve Gülay, 2016;

Gündüz, Yaslan ve Çataltepe, 2017; Filiz, Karaboğa ve Akoğul, 2017; Tekin ve Çanakoğlu, 2018) ile endeksin yön tahmini yapılmaya çalışılmıştır.

Türkiye finansal piyasalarındaki belirsizliğin sonucunda piyasada oluşan düzensiz fiyat hareketleri finansal krizlerin yaşanmasına sebep olabilmektedir. Bu nedenle Türkiye ekonomisi, Türk yatırımcıların edindikleri tecrübelerle olumsuz piyasa haberlerine çok duyarlı olduğu, çabuk tepki verdiği ve aldıkları riski yüksek miktarda getiriler ile telafi edebildikleri bir piyasa yapısına sahiptir. Bu da bizim borsamızı güçlü kılmakta ve yatırımcılar için cazip hale getirmektedir. Bununla birlikte, borsamızdaki karmaşık ve belirsiz durumlar finansal karar verme sürecinde güçlü tahmin modellerine ihtiyaç duyulmasına neden olmaktadır (Göçken vd., 2016: 320).

Literatürde BİST 100 endeksinin çalışma alanı seçilmesindeki sebeplerden biri de Türkiye’de borsanın yeterli etkinlik ve derinliğe ulaşmamış olmasına rağmen yatırımcılar için alternatif bir yatırım aracı olma özelliği göstermesidir. Ayrıca, bazı yıllarda elde edilen aşırı getiri oranları ve Türkiye borsasının spekülasyonlara açık olması borsayı yatırımcılar için ilgi çekici hale getirmektedir (Güzel, Acar ve Avcı, 2016: 185).

5. MODEL TASARIMI

Endeks hareketi yönünü tahminini en yüksek oranda doğru tahmin edebilen model oluşturulmuştur. Oluşturulan model sınıflandırma yöntemlerinin tahmin performansını optimal seviyeye çıkaracak şekilde tasarlanmıştır.

YSA parametreleri olarak katman sayısı, nöron sayısı, aktivasyon fonksiyonu ve öğrenme oranı alınmıştır. YSA modeli 3 katmandan oluşmuş ve gizli katmandaki nöron sayısı deneme yanılma metoduyla bulunmuştur. Öğrenme algoritması olarak literatürde en çok kullanılan perseptron kullanılmıştır. Öğrenme oranı yine deneme yanılma metoduyla bulunmuştur.

DVM parametreleri ise çekirdek fonksiyon seçimi ve c parametresi olarak belirlenmiştir. Çekirdek fonksiyon seçiminde doğrusal, polinom, radyal tabanlı ve sigmoid fonksiyonların hepsi optimal sonuç bulununcaya kadar denenmiş olup c parametresi için literatür dikkate alınmıştır. K-EYK’da k sayısının seçimi problemi en iyi tahmin performansını veren k değeri bulunarak çözülmüştür.

Model tasarımından sonra test edilerek optimize edilmiştir. Doğruluk ve hata oranları metrikleri bu konuda yön göstermiştir.

5.1. MODEL PARAMETRELERİNİN TESPİT EDİLMESİ

Çalışmada, tüm verilerin %20'si parametre tespitinde kullanılmıştır. Bu veriler modellerin tasarım parametrelerini belirlemek için kullanılmıştır. Bu parametre tespit verileri ayrıca eğitim ve test setine ayrılmıştır. Setin her biri tüm verilerin %10'unu oluşturmaktadır. Model parametreleri belirlenirken veri setinde eğitim için ayrılan kümeden %10'luk kısmı parametre eğitimi için %10'luk bir kısmı da test için rastgele olarak seçilmiştir. Parametre seçim veri seti, tüm yılların her birinden eşit oranda veri alınarak oluşturulmuştur. Her yıl yüzde oranındaki artış ve düşüş oranları da korunmuştur. Bu örnekleme metodu, parametre ayar veri setinin tüm veri setinin daha iyi bir temsilcisi olmasını sağlamaktadır. BİST 100'ün parametre ayar veri seti Tablo 11'de görülmektedir.

Tablo 11. BİST 100'ün parametre ayar veri setindeki her yıl artış ve azalış sayısı.

Yıl	Eğitim			Test		
	Artan	Azalan	Toplam	Artan	Azalan	Toplam
1995	10	9	19	10	9	19
1996	14	11	25	14	11	25
1997	15	10	25	15	10	25
1998	13	12	25	13	12	25
1999	13	10	23	13	10	23
2000	11	13	24	11	13	24
2001	12	13	25	12	13	25
2002	12	13	25	12	13	25
2003	13	11	24	13	11	24
2004	14	12	26	14	12	26
2005	15	11	26	15	11	26
2006	13	12	25	13	12	25
2007	12	13	25	12	13	25
2008	10	15	25	10	15	25
2009	14	11	25	14	11	25
2010	14	11	25	14	11	25
2011	13	12	25	13	12	25
2012	14	11	25	14	11	25
2013	12	13	25	12	13	25
2014	14	11	25	14	11	25

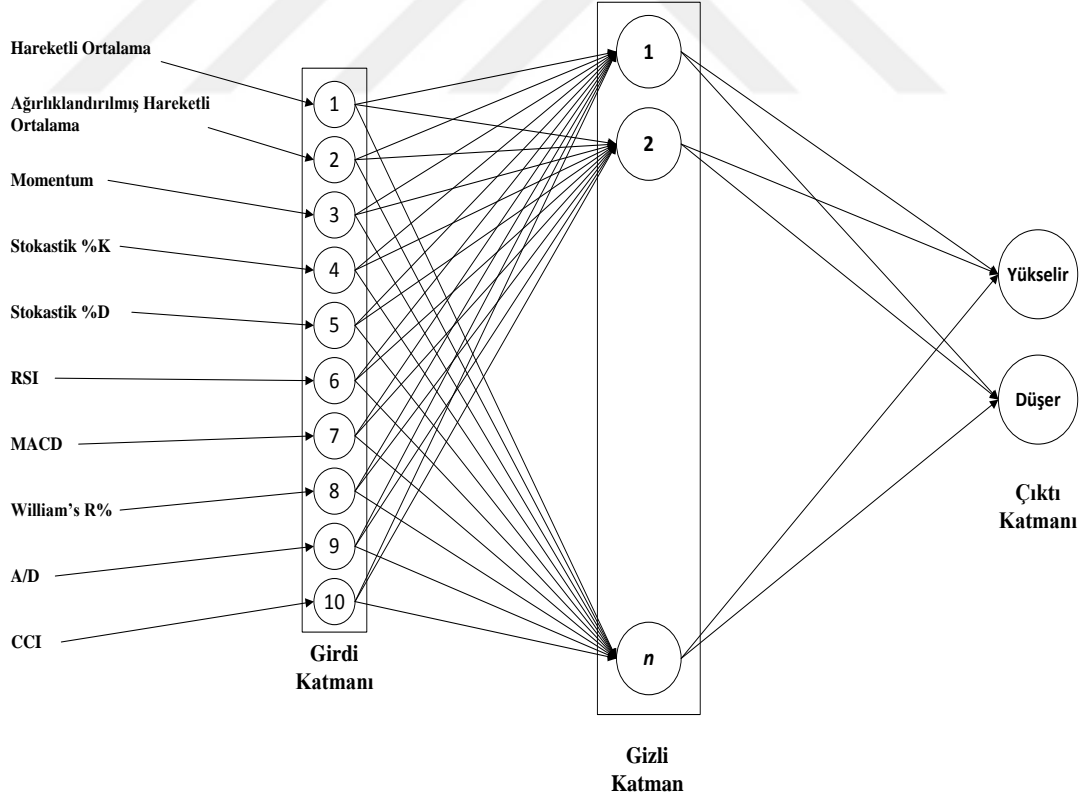
2015	12	13	25	12	13	25
2016	13	12	25	13	12	25
2017	14	12	26	14	12	26
2018	4	3	7	4	3	7
Toplam	301	274	575	301	274	575

Parametre seçim verileri üzerinde deneyler yoluyla tahmin modelleri için optimum parametreler elde edilir.

5.1.1. YSA Parametreleri

YSA modellerini oluşturan katmanlar bir girdi, çok sayıda gizli ve bir çıktı katmanıdır. Literatür çalışmalarına göre karmaşık sınıflandırma problemlerine YSA'nın bir veya iki gizli katmanlı algoritmalarının çözüm üretebildikleri belirlenmiştir (Larose, 2005: 132). Bundan dolayı bu tez çalışmasında bir girdi katmanı, bir gizli katman ve bir çıktı katmanı kullanılmıştır. YSA model mimarisi Şekil 22'de gösterilmiştir.

Şekil 22. YSA Model Mimarisi (Patel, 2015: 264).



Girdi katmanında bağımsız değişken sayısı kadar nöron bulunur. Bizim çalışmamızda 10 adet teknik gösterge girdi verisi olarak kullanıldığı için 10 nöron

kullanılmıştır. Uygulamalarda kullanılacak gizli katmandaki nöron sayısı ise optimalliği sağlayacak en az sayıda olmalıdır (Kriesel, 2007: 93). Gizli katmandaki nöron sayısını tespit edecek herhangi bir kural olmadığı için deneme yanılma yoluyla 34 nöron olarak bulunmuştur. Son olarak, çıktı katmanında çıktı değişkeninin sayısı kadar nöron bulunur. Bizim çalışmamızın çıktı değişkeni iki sonuçlu olduğu için 2 adet nöron kullanılmıştır.

Literatürde en çok kullanılan öğrenme algoritması pekçok avantajından dolayı perseptrondur (geri yayımlı öğrenme algoritması). Bu nedenle YSA’da öğrenme algoritması olarak geri yayımlı algoritma kullanılması tercih edilmiştir. Algoritma, aşırı öğrenme sorununu azaltarak ağı tahmin gücünün yüksek kalmasını sağlamaktadır. Çalışmada test edilecek YSA parametreleri Tablo 12’de gösterilmiştir.

Tablo 12. Test Edilen YSA Parametre Seviyeleri.

Parametreler	Seviyeler
Nöron sayısı (n)	1, 10, 20, ... , 100
Tekrarlama sayısı (ep)	100, 1000, ... , 100000
Momentum sabiti (mc)	0.1, 0.2, ... , 0.9
Öğrenme oranı (lr)	0.1, 0.2, 0.3, 0.4

5.1.2. DVM Parametreleri

DVM modelleri oluşturulma aşamasında çekirdek fonksiyon seçiminde doğrusal, polinom, radyal tabanlı ve sigmoid fonksiyonlarla çok sayıda analiz yapılmış ve optimal sonucu veren çekirdek fonksiyonları seçilmiştir. Çapraz geçişleme kullanılarak aşırı öğrenme problemi giderilmiştir. *C* parametresi için 1 ile 10 aralığında denemeler yapılmıştır. Çekirdek fonksiyonu gamma değerleri için 0 ile 5 değerleri arasında test edilmiştir. Tekrarlama sayısı da 100 ile 100000 arası alınmıştır. Çalışmada test edilecek DVM parametreleri Tablo 13’de gösterilmiştir.

Tablo 13. Test Edilen DVM Parametre Seviyeleri

Parametreler	Doğrusal	Sigmoid	Radyal	Polinom
Çekirdek fonksiyon	-	-	-	1, 2, 3

derecesi (d)				
Çekirdek fonksiyon Gamma (γ)	-	0, 0.1, ... , 5.0	0, 0.1, ... , 5.0	0, 0.1, ... , 5.0
Tekrarlama sayısı	100, 1000	100, 1000	100, 1000	100, 1000
Düzenleme parametresi (c)	1, 10, 100	1, 10, 100	1, 10, 100	1, 10, 100

5.1.3. K-EYK Parametreleri

K-EYK sınıflandırıcısındaki, k sayısı gözlemlenen verinin k tane komşularının (genellikle kullanıcı tarafından belirlenen bir parametre) sayısı olduğudur (Harrington, 2012: 25). K çok büyük olursa tüm sınıflandırmalar aynı olur. En iyi tahmin performansını veren k 'nın optimal bir değeri vardır (Barber, 2012: 324). Deneme yanılma yöntemi ile optimal değere ulaşılır. Bizim çalışmamızda k sabiti için 1-10 arası değerler test edilmiştir.

5.2. MODEL

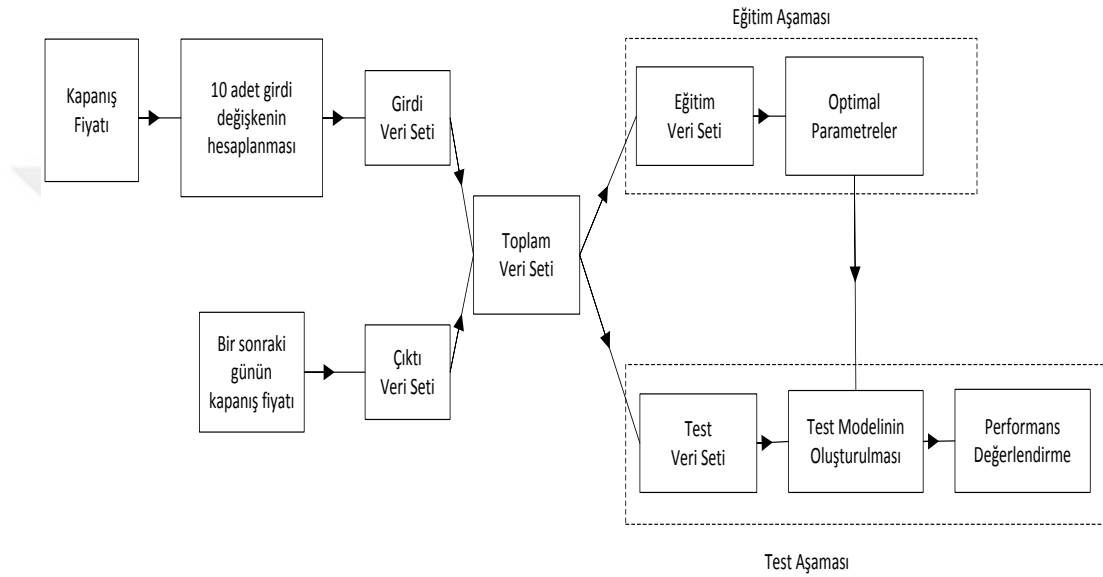
Önerilen modelin işlem adımları şöyledir:

1. Adım: BİST 100 Endeks kapanış fiyatlarının elde edilmesi,
2. Adım: Girdi değişkenlerinin hesaplanması,
3. Adım: Tahmin modeli mimarisinin kurulması,
4. Adım: Test veri setinin tahmin modelinde işleme alınması ve performans sonuçlarının değerlendirilmesi.

Çalışmada tahmin işlemi yapacak olan girdi verisi teknik göstergelerdir. Bu bağlamda literatürde en çok kullanılan 10 teknik gösterge seçilmiş ve değerleri hesaplanmıştır. Bu amaçla hesaplanan teknik göstergelerin 5750 günlük kapanış değeri kullanılmıştır. Çıktı veri seti olarak ise ertesi günkü kapanış fiyatları kullanılmıştır. Toplam veri setimiz iki bölümden oluşmaktadır; eğitim ve test veri seti. Eğitim veri seti içinden seçilmiş bir de parametre veri setimiz vardır. Eğitim ve parametre veri seti, model mimarisinde ve parametrelerin optimize edilmesinde kullanılmıştır. Test veri seti ise model performans ölçümünde ve modelin hangi oranda tahmin başarısı gösterdiğini belirlemek için kullanılmıştır. Eğitim ve test aşamasında kullanılan veri setleri birbirlerinden bağımsızdırlar. Böylece modelin gerçek performans gücünü göstermesi sağlanmaktadır.

Böylece, toplam veri seti uygulamaya hazır hale getirilir. Daha sonra eğitim aşamasına geçilerek model eğitilir ve optimal model parametreleri elde edilir. Aynı zamanda test aşamasında, eğitim aşamasından gelen optimal model parametreleri ile test model mimarisi oluşturulur (Şekil 23). Oluşturulan model mimarisi ile daha önce hiç kullanılmamış olan test veri seti kullanılarak modelin performans değerlendirmesi yapılır.

Şekil 23. Tahmin Modeli



5.3. MODELİN TEST EDİLMESİ

Model mimarisi kurulduktan sonra modelin eğitim sürecinde kullanılmayan yeni bir veri seti ile test edilmesi gerekir. Bu amaçla deneme yanılma metoduyla tespit edilen en iyi parametreler test sürecindeki veriler için kullanılır ve bir model oluşturulur. İnşa edilen bu model daha önce hiç kullanılmayan test sürecindeki veriler için kullanılır.

Test sürecindeki veriler için seçilen parametreler hesaplanır. Hesaplanan bu parametreler, eğitimi yapılmış en son modele girdi olarak verilir ve modelin ertesi güne yönelik tahmin ettiği fiyatlar, gerçek fiyatlarla karşılaştırılır.

5.3.1. Sınıflandırıcı Performansını Değerlendirme Metrikleri

Çalışmanın bu bölümünde sınıflandırıcımızın sınıf etiketini tahmin etmede ne kadar iyi ya da "doğru" olduğunu değerlendirmeye yönelik metrikler incelenmiştir.

Sınıflandırıcı değerlendirme metrikleri ve hesaplama formülleri Tablo 14’te gösterilmiştir.

Tablo 14. Sınıflandırma Performansını Değerlendirme Metrikleri

Ölçüler	Formül
Doğruluk, tanıma oranı	$\frac{DP + DN}{P + N}$
Hata oranı, yanlış sınıflandırma oranı	$\frac{YP + YN}{P + N}$
Duyarlılık, doğru pozitif oran, geri çağırma	$\frac{DP}{P}$
Özgünlük, gerçek negatif oran	$\frac{DN}{N}$
Hassasiyet	$\frac{DP}{DP + YP}$
F-skoru, hassaslık ve geri çağırma harmonik ortalaması	$\frac{2 \times \text{hassasiyet} \times \text{geri çağırma}}{\text{hassasiyet} + \text{geri çağırma}}$
F_{β} , burada β negatif olmayan bir gerçek sayıdır	$\frac{(1 + \beta^2) \times \text{hassasiyet} \times \text{geri çağırma}}{\beta^2 \times \text{hassasiyet} + \text{geri çağırma}}$

Bu tez çalışmasında ertesi gün kapanış fiyatlarının doğru tahmin edilebilirliği literatürde en sık kullanılan iki metrik kullanılarak değerlendirilmiştir. Bu metriklerden birincisi doğruluk, ikincisi ise hata oranlarıdır.

5.3.1.1. Doğruluk

Doğruluk belirli bir metrik olmasına rağmen "doğruluk" sözcüğü, sınıflandırıcının tahmin yeteneklerine atıfta bulunmak için genel bir terim olarak da kullanılmaktadır. Sınıflandırıcının doğruluğunu ölçmek, modeli eğitmek için kullanılmayan sınıf etiketli verilerden oluşan bir test kümesinin doğruluğunu ölçmek demektir. P pozitif sınıf sayısıdır ve N negatif sınıf sayısıdır. Her bir sınıf için sınıflandırıcının sınıf etiketi tahmini ile sınıfın bilinen sınıf etiketi karşılaştırılır. Karışıklık (confusion) matrisi tahmin edilen sınıf etiketi ile gerçek sınıf etiketini karşılaştırmak için kullanılmaktadır (Han, Kamber ve Pei, 2011: 364). Karışıklık matrisi Tablo 15’te gösterilmiştir.

Tablo 15. Karışıklık Matrisi

	Gerçek Değer			Toplam
		a	b	
Tahmini Değer	a	<i>DP</i> (Doğru Pozitif)	<i>YN</i> (Yanlış Negatif)	
	b	<i>YP</i> (Yanlış Pozitif)	<i>DN</i> (Doğru Negatif)	
	Toplam			

Genel tahminsel doğruluğun yanı sıra, sınıflandırıcının performansının dökümünü, yani X sınıfı örneklerinin X sınıfı olarak doğru sınıflandırıldığını veya başka sınıflar olarak yanlış sınıflandırıldığını görmek de genellikle yararlıdır (Bramer, 2016: 89). Tablo 15'in sütunlarında gerçek değerler yer alırken satırlarda ise tahmini değerler yer almaktadır. Karışıklık matrisinde aşağıdaki bilgilere yer verilmiştir (Han, Kamber ve Pei, 2011: 364):

- **Doğru pozitif (DP):** Bunlar, sınıflandırıcı tarafından doğru şekilde etiketlenmiş pozitif sınıflara işaret eder.
- **Doğru negatif (DN):** Bunlar, sınıflandırıcı tarafından doğru şekilde etiketlenmiş negatif sınıflardır.
- **Yanlış pozitif (YP):** Bunlar, yanlış pozitif olarak etiketlenmiş negatif sınıflardır.
- **Yanlış negatif (YN):** Bunlar, yanlış olarak yanlış etiketlenmiş pozitif sınıflardır.

Karışıklık matrisi, sınıflandırıcımızın farklı sınıfların etiketlerini ne kadar iyi tanıyabileceğini analiz etmek için yararlı bir araçtır. DP ve DN, sınıflandırıcının doğru olduğunu (yani, doğru etiketleme) bize bildirirken, YP ve YN sınıflandırıcının ne zaman yanlış olduğunu (yani, yanlış etiketleme) bize bildirir.

Sınıflandırıcının fiyat artışlarını ve azalışlarını ya da fiyat yönünü doğru tahmin edebilirliği doğruluk oranı Denklem 62 ile hesaplanır (Han, Kamber ve Pei, 2011: 364)

$$\text{Doğruluk Oranı} = \frac{DP + DN}{DP + DN + YP + YN} \quad (62)$$

Doğruluk oranı 0 ile 1 arasında değer almaktadır. Doğruluk oranı 1'e yakın değer aldıkça, sınıflandırıcının endeks yönünü o kadar başarılı bir şekilde tahmin edebildiği ifade edilir.

5.3.1.2. Hata Oranları

Sınıflandırma yöntemlerinde elde edilen tahmin sonuçlarını anlamlı hale getirmek için performans ölçülerine ihtiyaç vardır. Modellerin tahmin değerleri ile gerçek değerler arasındaki farkın hesaplanması ile hata oranları bulunur. Bu hata oranlarının gerçek değere ne kadar yaklaştığı tahmin performans ölçüleri ile belirlenir.

Sınıflandırma yöntemlerinde literatürde en çok kullanılan istatistiksel performans değerlendirme ölçütleri aşağıda verilmiştir.

5.3.1.2.1. Ortalama Karesel Hata (MSE)

İstatistikte, ortalama karesel hata kavramı, bir tahmin edicinin performansını ölçmek için kullanılan önemli bir ölçektir. MSE, tahmin edici ile birlikte bir tahmin veya tahmin hedefi gerektirir. MSE değerleri iki veya daha fazla istatistiksel model arasında karşılaştırma yapmak için kullanılabilir. MSE'nin ölçü birimi, tahmin edilen miktarın ölçüm birimi ile aynıdır. MSE Denklem 63 kullanılarak bulunur.

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \tilde{y}_i)^2 \quad (63)$$

5.3.1.2.2. Ortalama Mutlak Hata (MAE)

MAE, bir takım tahminlerdeki hataların ortalama büyüklüğünü, yönlerini dikkate almadan ölçer. MAE doğrusal bir puandır, bu da tüm bireysel farklılıkların ortalama olarak eşit olarak ağırlıklandırıldığı anlamına gelir. MAE Denklem 64 kullanılarak bulunur.

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (64)$$

5.3.1.2.3. Kök Ortalama Karesel Hata (RMSE)

Bir tahmin edicinin veya bir modelin tahmini değeri ile gerçek gözlemlenen değerleri arasındaki farklılıkları ölçmek için çok sık kullanılan bir ölçektir. RMSE,

tahmin edilen değerler ile gözlemlenen değerler arasındaki farkların karekökü olarak tanımlanır. RMSE Denklem 65 kullanılarak bulunur.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (65)$$

5.3.1.2.4. Ortalama Mutlak Yüzde Hata (MAPE)

Tahmin ve nihai sonuçlar için ortalama mutlak yüzde hata fonksiyonunu hesaplar. MAPE, hatanın boyutunu yüzde cinsinden ölçer. MAPE ayrıca MAPD olarak da bilinir. Birçok araştırmacı, tahmin doğruluğunu değerlendirirken öncelikle MAPE'ye odaklanır. MAPE ölçüğe duyarlıdır ve düşük hacimli verilerle çalışırken kullanılmamalıdır. MAPE Denklem 66 kullanılarak bulunur.

$$MAPE = \frac{100}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (66)$$

Tahmin performans değerlendirmeleri için literatürde en sık kullanılan ölçütler MAPE ve MSE değerleridir (Tayman ve Swanson, 1999: 300; Hyndman ve Koehler, 2006: 682). Çünkü tahmin değerlerinin gerçek değerlerden sapma davranışını en iyi gösterdiği için MAPE ölçütü kullanılır.

MAPE değerleri (Lewis, 1982: 32) tarafından;

- %10'un altında olan modelleri "çok iyi",
- %10 ile %20 arasında olan modelleri "iyi",
- %20 ile %50 arasında olan modelleri "kabul edilebilir" ve
- %50'nin altında olan modelleri ise "yanlış ve hatalı" olarak gruplanmıştır.

MAPE'nin hata sonuçları yüzde olarak elde edilirken MAE, MSE ve RMSE'nin sonuçları birim olarak değerlendirilir. Birim olarak sonuç almak yanıltıcı olabilir. Yüzde sonucuna bakılarak daha gerçekçi tahmin oranları elde edebilir.

6. UYGULAMA


Bu tez çalışmasında teknik göstergeler kullanılarak BİST 100 endeks yönü tahmin edilmeye çalışılmış ve sınıflandırma yöntemlerinin performansları karşılaştırılmıştır.

Bu çalışmada sınıflandırma yöntemlerini analiz etmek ve performans karşılaştırmalarını yapmak için Rapid Miner Studio Educational Version 9.0.003 programı kullanılmıştır. Rapid Miner yazılımı, günümüzde veri madenciliği ve makine öğrenmesi gibi büyük veri içeren zor ve karmaşık problemlerde, veriyi alıp ön işlemeden geçirip çözümünü yapabilmekte, en son raporlama ve görselleştirme işlemlerini gerçekleştirebilmektedir.

6.1. ANALİZDE KULLANILAN BORSA ENDEKS VERİLERİ

Sınıflandırma modelleriyle Borsa İstanbul 100 Endeksi hareket yönünü tahmin etmek için teknik göstergeler kullanılmıştır. Çalışmada 1995:3-2018:3 dönemine ait BİST 100 endeksi günlük kapanış verileri ve hesaplanan 10 teknik gösterge veri seti olarak alınmıştır. 1994 yılında yaşanan ekonomik krizden dolayı veri seti 1995 yılından itibaren alınmıştır. Tüm veri setimiz Matriks Bilgi Dağıtım Hizmetleri tarafından sağlanmıştır. BİST 100 Endeksi kapanış verileri Şekil 24'te gösterilmiştir.

Şekil 24. BİST 100 Endeksi Kapanış Verileri.



Bu veriler tüm veri kümemizi oluşturmaktadır. Tüm veri setinde her yıl için artan-azalan veri sayısı ve yüzde oranları Tablo 16'da gösterilmiştir.

Tablo 16. BİST XU 100'ün Tüm Veri Setindeki Her Yıl İçin Artan ve Azalan Veri Sayısı.

Yıl	Artan	%	Azalan	%	Toplam
1995	98	52,40	89	47,60	187
1996	138	55,87	109	44,13	247
1997	150	59,52	102	40,48	252
1998	127	51,21	121	48,79	248
1999	132	55,93	104	44,07	236
2000	111	44,94	136	55,06	247
2001	121	48,79	127	51,21	248
2002	124	49,19	128	50,81	252
2003	133	54,06	113	45,94	246
2004	143	57,42	106	42,58	249
2005	149	58,66	105	41,34	254
2006	132	52,81	118	47,19	250
2007	126	50,00	126	50,00	252
2008	104	41,43	147	58,57	251
2009	145	57,53	107	42,47	252
2010	143	57,19	107	42,81	250
2011	130	51,38	123	48,62	253
2012	145	57,31	108	42,69	253
2013	125	50,00	125	50,00	250
2014	141	56,17	110	43,83	251
2015	125	49,41	128	50,59	253
2016	130	51,79	121	48,21	251
2017	140	55,34	113	44,66	253
2018	35	53,84	30	46,16	65
Toplam	3047	52,99	2703	47,01	5750

Tablo 16'da gösterildiği gibi, toplam veri 5750 iş gününü kapsamaktadır. Bu verilerin 3047 tanesi yukarı yönlü ve 2703'ü aşağı yönlü pozisyona sahiptir. Verilerden %52.99'unun artan ve %47.01'inin ise azalan pozisyona sahip olduğu görülmektedir.

6.2. VERİLERİN TOPLANMASI VE HAZIRLANMASI

Veriler toplandıktan sonra YSA, DVM, KA, NB, k-EYK, LogR ve DDA modellerini karşılaştırmak için karşılaştırma veri seti tasarlanmıştır. Bu veri seti, daha önce belirtildiği gibi 5750 günlük veriden oluşmaktadır. Ayrıca bu alandaki

literatüre göre eğitim kümesine (tüm verinin %90'ı) ve test kümesine (tüm verinin %10'u) ayrılmıştır. BİST 100 Endeksi için bu veri seti Tablo 17'de gösterilmiştir.

Tablo 17. BİST XU100 Karşılaştırmalı Veri Setindeki Her Yıl Artış ve Azalış Sayıları.

Yıl	Eğitim			Test		
	Artan	Azalan	Toplam	Artan	Azalan	Toplam
1995	90	80	170	8	9	17
1996	124	98	222	14	11	25
1997	135	92	227	15	10	25
1998	114	109	223	13	12	25
1999	119	94	213	13	10	23
2000	100	123	223	11	13	24
2001	109	114	223	12	13	25
2002	112	115	227	12	13	25
2003	120	102	222	13	11	24
2004	129	94	223	14	12	26
2005	133	95	228	16	10	26
2006	119	106	225	13	12	25
2007	114	113	227	12	13	25
2008	94	132	226	10	15	25
2009	131	96	227	14	11	25
2010	129	97	226	14	10	24
2011	117	111	228	13	12	25
2012	131	97	228	14	11	25
2013	113	112	225	12	13	25
2014	127	99	226	14	11	25
2015	112	113	225	13	15	28
2016	117	109	226	13	12	25
2017	126	101	227	14	12	26
2018	31	27	58	4	3	7
Toplam	2746	2429	5175	301	274	575

Tablo 17'de gösterildiği gibi eğitim seti 5175, test seti ise 575 veriden oluşmaktadır. Eğitim setindeki verilerin 2746 tanesi artan, 2429'u azalan pozisyona sahip iken test setindeki verilerin 301 tanesi artan ve 274'ü azalan pozisyona sahiptir.

6.3. ENDEKS YÖN TAHMİNDE KULLANILACAK GİRDİ DEĞİŞKENLERİ

Endeksin gelecekteki hareketini tahmin etmek için bazı teknik göstergeler girdi değişkeni olarak kullanılmıştır. Çalışmada borsa endeks yön tahmini bağımlı

değişken olarak ele alınırken bağımsız değişkenler literatürde sıklıkla kullanılan 10 teknik göstergeden oluşmaktadır. Çalışmada kullanılan teknik gösterge seçimi; literatürdeki (Yao, Tan ve Poh, 1999; Diler, 2003; Kim, 2003; Yu vd., 2005; Lu, 2010; Nair, Mohandas ve Sakthivel, 2010; Kara, Boyacıoğlu ve Baykan, 2011; Lahmiri, 2011; Aldin, Dehnavi ve Entezari, 2012; Dastgir ve Enghiad, 2012; Karymshakov ve Abdykaparov, 2012; Dunis vd., 2013; Emir, 2013; Lahmiri, Boukadoum ve Chartier, 2013; Oliveira, Nobre ve Zárata, 2013; Tayyar ve Tekin, 2013; Chen vd., 2014; Wang ve Shang, 2014; Anbalagan ve Maheswari, 2015; Patel vd., 2015; Anish ve Majhi, 2016; Dash ve Dash, 2016a; Jabbarzadeh vd., 2016; Gurjar vd., 2018; Santoso, Sutjiadi ve Lim, 2018; Dash vd., 2019; Nadh ve Prasad, 2019) çalışmalarda kullanılmış göstergeler incelenerek yapılmıştır. Böylece dikkate alınan teknik göstergeler; Hareketli Ortalamalar (10 Günlük), Ağırlıklı Hareketli Ortalamalar (10 Günlük), MACD (Moving Average Convergence Divergence), CCI (Commodity Channel Index), RSI (Relative Strength Index), Stokastik %K, Stokastik %D, William's %R, Momentum, A/D (Accumulation / Distribution Ascillator) olmuştur. Tablo 18'de gösterilen on teknik gösterge, tahmin modellerinde girdi bağımsız değişken olarak kullanılmıştır.

Tablo 18. Çalışmada Kullanılan Girdi Değişkenleri

Sıra	Girdi Değişkenler
1	Hareketli Ortalamalar (HO) (10 Günlük)
2	Ağırlıklı Hareketli Ortalamalar (AHO) (10 Günlük)
3	Momentum (MOM)
4	Stokastik %K (STOK%)
5	Stokastik %D (STOD%)
6	RSI (Göreceli Güç Endeksi)
7	MACD (Hareketli Ortalama Yakınsama İraksama)
8	William's %R (WILLR%)
9	A/D (Alım / Dağıtım Göstergesi)
10	CCI (Emtia Kanalı Endeksi)

Tablo 19 ise seçilen on teknik göstergelyi ve hesaplama formüllerini göstermektedir.

Tablo 19. Seçilen Teknik Göstergeler ve Formülleri

Teknik Gösterge	Formüller
HO	$HO = \frac{C_t + C_{t-1} + \dots + C_{t-9}}{n}$
AHO	$AHO = \frac{(10)C_t + (9)C_{t-1} + \dots + C_{t-9}}{n + (n-1) + \dots + 1}$
MOM	Momentum = $C_t - C_{t-9}$
STOK%	Stokastik %K = $\frac{C_t - LL_{t-(n-1)}}{HH_{t-(n-1)} - LL_{t-(n-1)}} \times 100$
STOD%	Stokastik %D = $\frac{\sum_{i=0}^{n-1} K_{t-i}}{10} \%$
RSI	$RSI = 100 - \frac{100}{1 + (\sum_{i=0}^{n-1} UP_{t-i} / n) / (\sum_{i=0}^{n-1} DW_{t-i} / n)}$
MACD	$MACD = MACD(n)_{t-1} + \frac{2}{n+1} \times (DIFF_t - MACD(n)_{t-1})$
WILLR%	William 's %R = $\frac{H_n - C_t}{H_n - L_n} \times 100$
A/D	$A / D = \frac{H_t - C_{t-1}}{H_t - L_t}$
CCI	$CCI = \frac{M_t - SM_t}{0.015 D_t}$

Yukarıda belirtilen formüllere göre hesaplanan teknik göstergelerin her birinin sürekli değerli olduğu açıktır. Tüm teknik göstergeler [-1,+1] aralığında normalize edilmiştir, böylece uç değerlerin analizleri etkilemesinin önüne geçilmiştir. Çalışmadaki tüm modellerin performansı, bu girdiler kullanılarak değerlendirilmiştir. Tablo 20 ise endeks yön tahmini için seçilen teknik göstergelerin bazı tanımlayıcı istatistiklerini göstermektedir.

Tablo 20. Seçilen Göstergeler İçin Özet İstatistikler.

Teknik Gösterge	Maks.	Min.	\bar{x}	σ
HO	119.143,10	0	38.354,56	31.148,09
AHO	120.587,38	0	39.513,45	32.981,12
MOM	152,62	0	101,019	8,419
STOK%	98,173	0	55,765	21,927
STOD%	97,297	0	55,743	19,974
RSI	96,252	0	53,828	13,31
MACD	2491	-3521	141,635	809,598
WILLR%	0	-100	-42,019	30,781
A/D	2.147.483.647	169.532	1.766.795.063	761.206.642,90
CCI	333,47	-354,02	17,071	109,606

6.4. TEKNİK GÖSTERGELER İLE GERÇEK FİYAT ARASINDAKİ KORELASYON

Korelasyon, iki değişken arasında doğrusal bir ilişki var olup olmadığını araştıran, varsa bu ilişkinin yönü ve şiddetinin ne olduğunu tespit etmek için kullanılan bir istatistiksel yöntemdir (Alpar, 2003: 105). Ayrıca değişkenlerde oluşan değişimlerin birbirini etkileyip etkilemediklerini ortaya çıkarır.

Korelasyon katsayısı, değişkenler arasındaki ilişkiyi göstermek için kullanılır ve [-1,0] aralığında bir değer alır. Pearson korelasyon katsayısı Denklem 67 ile hesaplanır (Draper ve Smith, 2014: 136):

$$r = \frac{\sum(xy) - (\sum x)(\sum y) / n}{\sqrt{(\sum x^2 - (\sum x)^2 / n)(\sum y^2 - (\sum y)^2 / n)}} \quad (67)$$

Korelasyon katsayısı (Fornell ve Larcker, 1981: 44; Bülbül ve Demirer, 2008: 186; Köse, 2008: 2; Draper ve Smith, 2014: 136);

- 0.00-0.25 ise çok zayıf ilişki yada korelasyon yok,
- 0.26-0.49 ise zayıf ilişki,
- 0.50-0.69 ise orta şiddette ilişki,
- 0.70-0.89 ise yüksek ilişki,
- 0.90-1.00 ise çok yüksek ilişki yada çok yüksek korelasyon vardır şeklinde yorumlanır.

Determinasyon (belirlilik) katsayısı, korelasyon katsayısının karesi alınarak bulunur ve R^2 ile gösterilir (Başar ve Oktay, 2007: 103). Kullanılan bağımsız değişkenlerce modelin % kaç oranında açıklanabildiği R^2 ile ortaya konulur. Tablo 22’de herbir teknik gösterge ile gerçek fiyat arasındaki korelasyon gösterilmiştir.

Tablo 22. Teknik Göstergeler ile Gerçek Fiyat Arasındaki Korelasyon Katsayıları

	HO	AHO	MOM	%K	%D	RSI	MACD	WLR	A/D	CCI
GERÇEK FİYAT	0,478	0,499	-0,041	0,000	0,002	0,033	0,185	0,037	0,441	0,041

Tablo 22’ye göre gerçek fiyat ile MOM ters ilişkili iken HO, AHO ve A/D arasında zayıf ilişki vardır. Diğer teknik göstergeler ise %K, %D, RSI, MACD, WLR ve CCI ile gerçek fiyat arasında çok zayıf ilişki vardır. Gerçek fiyat ile teknik

göstergeler arasındaki korelasyon ilişkisinin zayıflığı, yapılacak tahmin işleminin doğruluğunu yükselteceğinden çalışmamızda teknik göstergelerin girdi verisi olarak kullanılabilir olduğu söylenebilir.

7. BULGULAR

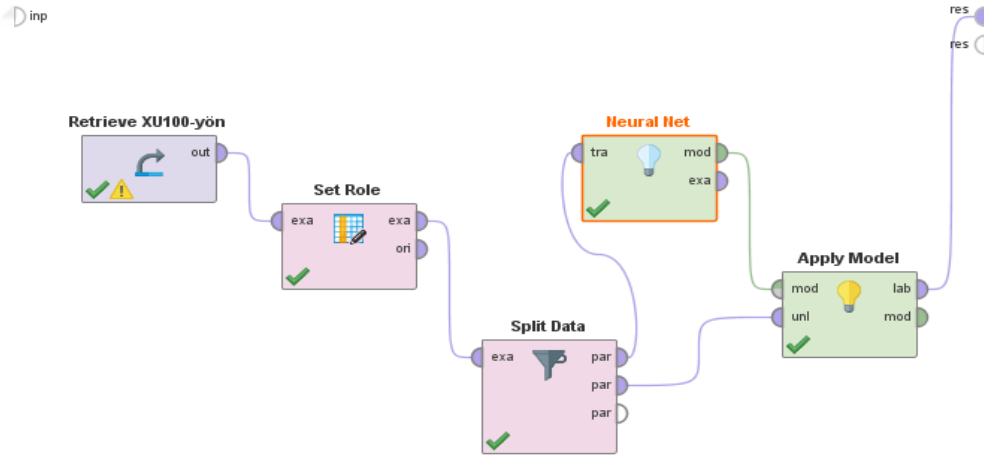
Çalışmanın bu bölümünde teknik göstergelerin girdi verisi olarak kullanıldığı sınıflandırma yöntemlerinin tahmin doğruluğu performansları karşılaştırılmıştır. Sınıflandırıcılar olarak makine öğrenmesi yöntemleri olarak YSA, DVM, KA, NB ve k-EYK yöntemleri ile geleneksel istatistikî yöntemlerden ise LogR ve DDA yöntemleri kullanılmıştır.

7.1. MAKİNE ÖĞRENMESİ YÖNTEMLERİYLE ENDEKS YÖNÜ TAHMİNİ

7.1.1. Yapay Sinir Ağları Yöntemi İle Endeks Yönü Tahmini

Yapay Sinir Ağları model süreci Rapid Miner (Şekil 25) programında dizayn edildikten sonra program çalıştırıldığında elde edilen sonuçlar aşağıda verilmiştir.

Şekil 25. Rapid Miner Yapay Sinir Ağları Yöntemi Süreci.



7.1.1.1. Test Edilen YSA Parametre Seviyeleri

YSA parametreleri kullanılarak optimum sonucu bulmak için 20 adet YSA modeli dizayn edilmiştir. YSA mimarisi kurulurken, sınıflandırma problemiyle ilişkili parametreler genellikle deneme yanılma metoduyla belirlenir (Öztemel, 2003: 34). Bu modellerin performansları ve doğru tahmin oranları Tablo 23'teki gibidir.

Tablo 23. Yapay Sinir Ağları Parametre Seviyeleri

	n	ep	mc	lr	Doğruluk
YSA-1	9	100	0.2	0.3	%80.35
YSA-2	10	100	0.2	0.2	%80.35
YSA-3	10	100	0.1	0.1	%82.61
YSA-4	9	100	0.05	0.1	%81.57
YSA-5	10	100	0.05	0.05	%82.61
YSA-6	10	500	0.9	0.5	%76.70
YSA-7	9	500	0.5	0.5	%78.78
YSA-8	11	500	0.2	0.3	%81.74
YSA-9	20	500	0.2	0.1	%83.48
YSA-10	15	500	0.1	0.1	%82.78
YSA-11	10	1000	0.2	0.2	%83.30
YSA-12	11	1000	0.2	0.1	%83.65
YSA-13	19	1000	0.1	0.1	%83.65
YSA-14	23	1000	0.1	0.05	%82.61
YSA-15	10	10000	0.2	0.2	%81.74
YSA-16	18	10000	0.2	0.1	%83.30
YSA-17	29	10000	0.1	0.1	%83.65
YSA-18	27	10000	0.1	0.05	%81.74
YSA-19	28	100000	0.1	0.1	%83.30
YSA-20	34	100000	0.2	0.1	%83.83

n: Nöron sayısı, ep: Tekrarlama sayısı, mc: Momentum sabiti, lr: Öğrenme oranı

Tablo 23'te görülen YSA parametrelerinin belirlenmesinde deneme yanılma yöntemi kullanılmış ve optimal sonucu buluncaya kadar çok sayıda analiz yapılmıştır. Bu bağlamda nöron sayısı, öğrenme oranı, momentum sabiti ve tekrarlama sayısı parametrelerinin çeşitli varyasyonları denenerek veri seti üzerinde optimal performans gösteren ağ tespit edilmiştir.

YSA'nın öğrenme performansı ile yakından ilişkili olan öğrenme oranı literatürde 0.4'e kadar yer alırken çalışmamızda 0.05'ten 0.5'e kadar dahil edilerek ağın öğrenme kabiliyeti test edilmiştir. Momentum sabiti ise 0.1'den 0.9'a kadar test edilmiştir. Gizli katmandaki nöron sayısı için 1'den başlamak suretiyle arttırılarak test edilmiş ve optimal değer olarak 34 nöron tespit edilmiştir. Yapılan çok sayıda analizden kayda değer olanları seçilerek çalışmamızda kullanılmıştır.

Çalışmada sadece optimal sonucu veren YSA modeli verilmiştir. Bu modelin özellikleri ve elde edilen sonuçlar şunlardır:

Çalışmada test edilen modelin parametre seviyeleri Tablo 24’te gösterilmiştir. Gizli katmandaki nöron sayısı 34, momentum sabiti 0.2, algoritmanın öğrenme oranı 0.1 ve veri tekrarlama (epok) sayısı 100000 seçilmiştir.

Tablo 24. Test edilen YSA parametre seviyeleri.

Parametreler	Seviyeler
Nöron sayısı (n)	34
Tekrarlama sayısı (ep)	100000
Momentum sabiti (mc)	0.2
Öğrenme oranı (lr)	0.1

Test edilen YSA model sonuçlarına göre 249 pozitif yükselir ve 233 negatif düşer veri tahmin edilmiştir. Gelecek verilerin tahmininde yükselir ve düşer olarak tespit edilen tahmin doğruluk oranı Denklem 62 kullanılarak %83.83 bulunmuştur ve Tablo 25’te gösterilmiştir.

$$D.O = \frac{249 + 233}{249 + 40 + 53 + 233} = 0,8383$$

Tablo 25. YSA Karışıklık Matrisi

Doğruluk: %83.83	gerçek YÜKSELİR	gerçek DÜŞER
tahmin YÜKSELİR	249	40
tahmin DÜŞER	53	233

Doğruluk oranı %83.83 ve MAPE değeri 0.073 ile en iyi olan YSA modeline ilişkin tüm test sonuçları Tablo 26’da görülmektedir. Hata değerlerinin 0.10’dan küçük olması sebebiyle modelin borsa hareket yönünün tespitinde oldukça başarılı olduğu söylenebilir. Ayrıca model yaklaşık %96 düzeyinde açıklama oranına da sahiptir.

Tablo 26. YSA Test Sonuçları

	Doğruluk
R ²	0.958
MSE	0.128
MAE	0.245
RMSE	0.358
MAPE	0.073
Doğruluk	%83.83

7.1.1.2. YSA Genel Değerlendirme

Tablo 27’de test edilen tüm YSA modellerinin test sonuçları birarada gösterilmiştir. Buna göre YSA modeli, hisse senedi fiyat endeksi hareketinin yönünü tahmin eden güçlü bir yöntemdir ve mevcut çalışma sonuçları, önceki çalışmaların sonuçlarıyla uyumludur (Kimoto vd., 1990; Avcı, 2009; Güresen, Kayakutlu ve Daim, 2011; Adebisi, Adewumi ve Ayo, 2014; Laboissiere, Fernandes ve Lage, 2015; Kılıç, Paksoy ve Genç, 2015; Sakarya vd., 2015; Moghaddam, Moghaddam ve Esfandyari, 2016; Tripathy, 2018).

Tablo 27. Yapay Sinir Ağları Test Sonuçları

	R ²	MSE	MAE	RMSE	MAPE	Doğruluk
YSA-1	0.868	0.135	0.278	0.367	0.098	%80.35
YSA-2	0.867	0.133	0.276	0.365	0.096	%80.35
YSA-3	0.926	0.131	0.275	0.362	0.090	%82.61
YSA-4	0.899	0.132	0.274	0.364	0.093	%81.57
YSA-5	0.927	0.130	0.279	0.361	0.090	%82.61
YSA-6	0.785	0.192	0.235	0.438	0.231	%76.70
YSA-7	0.835	0.147	0.271	0.384	0.126	%78.78
YSA-8	0.901	0.135	0.261	0.367	0.094	%81.74
YSA-9	0.949	0.127	0.260	0.356	0.081	%83.48
YSA-10	0.931	0.129	0.264	0.359	0.091	%82.78
YSA-11	0.944	0.129	0.260	0.358	0.085	%83.30
YSA-12	0.953	0.127	0.260	0.357	0.079	%83.65
YSA-13	0.954	0.127	0.260	0.357	0.079	%83.65
YSA-14	0.925	0.124	0.251	0.353	0.090	%82.61
YSA-15	0.902	0.133	0.259	0.364	0.097	%81.74
YSA-16	0.942	0.127	0.246	0.357	0.085	%83.30
YSA-17	0.953	0.128	0.256	0.358	0.079	%83.65
YSA-18	0.902	0.127	0.252	0.357	0.097	%81.74
YSA-19	0.943	0.129	0.255	0.359	0.084	%83.30
YSA-20	0.958	0.128	0.245	0.358	0.073	%83.83

Elde edilen bulgulara göre YSA parametreleri ile oluşturulan 20 farklı model için R² belirlilik katsayısının 0.785 ile 0.958 arasında değerler aldığı tespit edilmiştir. 20 farklı YSA modeli için R² düzeyinde bir karşılaştırma yapıldığında borsa endeksi ertesi günkü yönünü en iyi tahmin eden modellerin YSA-20, YSA-12, YSA-13 ve

YSA-17 modelleri olduğu belirlenmiştir. Modeller için R^2 değerleri %95-96 aralığında gerçekleştiği görülmektedir.

20 farklı YSA modeli için MAPE değerlerine bakıldığında 0.073 ile 0.231 arasında değerler aldığı görülmüştür. MAPE oranı ile YSA modelleri karşılaştırıldığında %10'nun altında hata oranı gerçekleşmesi sebebiyle YSA-20, YSA-12, YSA-13 ve YSA-17 modellerinin çok iyi modeller oldukları ifade edilebilir. Bu modellerin MAPE oranları yaklaşık %7 olarak gerçekleşmiştir. Buradan hareketle R^2 ve MAPE ölçütlerine göre YSA modellerinin benzer tahminleri yaptığını ve modellerimizin ertesi günkü endeks yönü tahminlerinin tutarlı olduğu gözlenmiştir.

Tablo 27 sonuçlarına göre MSE, MAE ve RMSE hata oranları yirmi farklı YSA modeli için sırasıyla MSE, 0.124 ile 0.192 arasında MAE, 0.245 ile 0.279 arasında ve RMSE, 0.353 ile 0.438 arasında değerler almıştır. MSE, MAE ve RMSE birim olarak değerlendirildiği için hata oranı sıfıra yaklaşan YSA-20, YSA-19, YSA-17, YSA-16, YSA-13, YSA-12, YSA-11 ve YSA-9 modelleri tahmin başarısı yüksek modeller olmuştur.


YSA parametreleri ile oluşturulan 20 farklı model birarada değerlendirildiğinde şu sonuçlara ulaşılmaktadır:

- Öğrenme oranı düştükçe tahmin gücü yükselmektedir ve optimum öğrenme oranı 0.1'dir,
- Momentum sabiti düştükçe tahmin gücü yükselmektedir ve optimum momentum sabiti 0.2'dir,
- İterasyon sayısı arttıkça tahmin gücü yükselmektedir ve optimum iterasyon sayısı 100000'dir,
- Nöron sayısı arttıkça tahmin gücü yükselmektedir ve optimum nöron sayısı 34'tür.

En yüksek başarı oranına lr: 0.1, mc: 0.2, ep:100000, n:34 parametreleri ile ulaşılmıştır. Böylece YSA yöntemi için optimal başarıya YSA-20 modeli ile ulaşıldığı tespit edilmiştir.

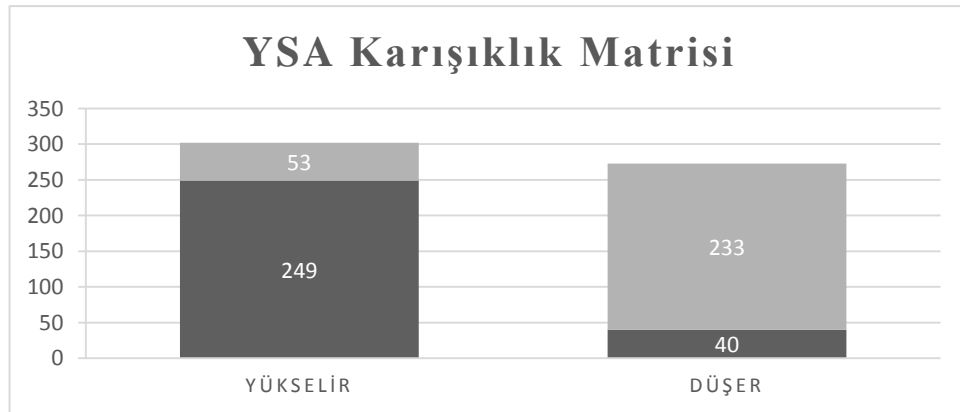
YSA modeli 575 günlük test veri setindeki tahminlere baktığımızda doğru tahmin edilen 249 gün yükselir ve 233 gün düşer gün sayısı ile %83.83'lük başarı göstermiştir. Ayrıca YSA modeli ile gerçek veri 53 gün yükselirken düşer diye tahmin edilmiş benzer şekilde gerçek veri 40 gün düşerken yükselir diye tahmin edilmiştir (Şekil 26).

Şekil 26. YSA Endeks Tahmini



En yüksek tahmin doğruluğu veren YSA modeli yön tahmininde karışıklık matrisi verileri Şekil 27'de gösterilmiştir. Şekil 27'de birinci sütündeki siyah renkli kısım gerçekte yükselen değeri doğru tahminleyen değerler kısmı, ikinci sütündeki gri renkli kısım ise gerçekte düşen değerleri doğru tahminleyen değerler kısmıdır.


Şekil 27. YSA Endeks Yön Tahmininde Karışıklık Matrisi Verileri.



Şekil 28'de mavi renkli olan noktalar yükselişleri kırmızı renkli olan noktalar ise düşüşleri sembolize etmektedir. Böylece YSA modelinin üç boyutlu piyasa ya da endeks yönündeki tahmin eğilimi görülebilir.


Şekil 28. YSA Yön Tahmininde Yükselen ve Düşen Kapanış Verileri.

prediction(YÖN) YÜKSELİR DÜŞER



Şekil 29'da gerçek borsa verileri ile YSA borsa endeks tahmin verileri arasında kuvvetli bir ilişkinin olduğu görülebilir.

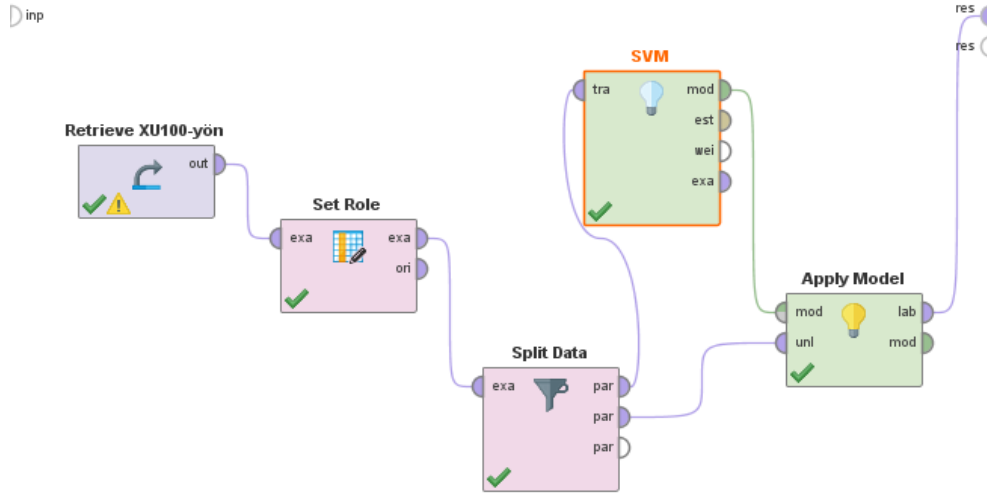
Şekil 29. YSA Tahmini ile Borsa Endeksi Korelasyonu



7.1.2. Destek Vektör Makineleri Yöntemi İle Endeks Yönü Tahmini

Destek Vektör Makineleri model süreci Rapid Miner (Şekil 30) programında dizayn edildikten sonra program çalıştırıldığında elde edilen sonuçlar aşağıda verilmiştir.

Şekil 30. Rapid Miner Destek Vektör Makineleri Yöntemi Süreci.



7.1.2.1. Test Edilen DVM Parametre Seviyeleri

DVM parametreleri kullanılarak optimum sonucu bulmak için 8 adet DVM modeli dizayn edilmiştir. DVM mimarisi kurulurken, sınıflandırma problemiyle ilişkili parametreler genellikle deneme yanılma metoduyla belirlenir (Öztemel, 2003: 34). Çalışmada çekirdek fonksiyon derecesi, çekirdek fonksiyon gamma değeri, maksimum tekrarlama ve düzenleme parametresi değerleri aşama aşama değiştirilerek optimum sonucu veren model bulunmuştur. Bu modellerin performansları ve doğru tahmin oranları irdelenmiştir. DVM parametre seviyeleri Tablo 28’de gösterilmiştir.

Tablo 28. Destek Vektör Makineleri Parametre Seviyeleri

	d	ep	γ	c	Doğruluk
DVM-D1		100000		1	%60.87
DVM-D2		10000		2	%72.87
DVM-S1		100000	1.0	1	%62.61
DVM-S2		10000	2.0	2	%60.87
DVM-R1		100000	1.0	1	%77.22
DVM-R2		100000	2.0	1	%78.43
DVM-P1	2	100000		1	%76.70
DVM-P2	3	100000		1	%76.00

d: Çekirdek fonk. Derecesi, ep: Tekrarlama sayısı, γ : Çekirdek fonk. Gamma
c: Düzenleme parametresi

Çalışmada optimal sonuçları veren DVM modeli test sonuçları şöyledir:

Çalışmada çekirdek fonksiyonu olarak radyal taban fonksiyon kullanılmış ve çalışmada test edilen DVM parametre seviyeleri Tablo 29’da gösterilmiştir. Çekirdek fonksiyon Gamma katsayısı 2.0 ve veri tekrarlama sayısı 100000 olarak seçilmiştir.

Tablo 29. Test Edilen DVM Parametre Seviyeleri

Parametreler	Seviye (radyal taban)
Çekirdek fonk. Gamma (γ)	2.0
Maksimum tekrarlama	100000
Düzenleme parametresi (c)	1

Pozitif yükselir 252 veri ile negatif düşer 199 verinin DVM modelinin Denklem 62 ile hesaplanarak toplamda %78.43 doğruluk oranı tahmin edilen karışıklık matrisi ise Tablo 30’da gösterilmiştir.

$$D.O = \frac{252 + 199}{252 + 73 + 51 + 199} = 0,7843$$

Tablo 30. DVM Karışıklık Matrisi

Doğruluk: %78.43	gerçek YÜKSELİR	gerçek DÜŞER
tahmin YÜKSELİR	252	73
tahmin DÜŞER	51	199

DVM test sonuçları Tablo 31’de gösterilmiştir. Bu sonuçlara göre determinasyon katsayısı, MSE, MAE, RMSE ve MAPE sırasıyla 0.821, 0.150, 0.350, 0.387, 0.128 çıkmıştır. Determinasyon katsayısının 0.90’a yakın bir değer çıkmış olması, DVM modelinin veriler ile uyumlu bir model olduğunu ifade etmektedir. Benzer şekilde MAPE değerinin %10’luk dilimde olması modelin çok iyi olduğunu gösterir.

Tablo 31. DVM Test Sonuçları

	Doğruluk
R^2	0.821
MSE	0.150
MAE	0.350
RMSE	0.387
MAPE	0.128
Doğruluk	%78.43

7.1.2.2. DVM Genel Değerlendirme

DVM modeli, hisse senedi fiyat endeksi hareketinin yönünü tahmin eden güçlü bir yöntemdir ve bu tez çalışma sonuçları literatürdeki (Wang ve Zhu, 2010; Fletcher ve Shawe-Taylor, 2013; Karagül, 2014; Liu vd., 2015; Li vd., 2016; Pan vd., 2017; Ren vd., 2018) çalışmalarla uyumludur. Dikkate alınan tüm DVM test sonuçları Tablo 32’de verilmiştir.

Tablo 32. Destek Vektör Makineleri Test Sonuçları

	DVM D1	DVM D2	DVM S1	DVM S2	DVM R1	DVM R2	DVM P1	DVM P2
R ²	0.549	0.719	0.591	0.565	0.794	0.821	0.784	0.769
MSE	0.247	0.175	0.227	0.213	0.161	0.150	0.171	0.182
MAE	0.461	0.380	0.433	0.420	0.352	0.350	0.385	0.404
RMSE	0.497	0.418	0.476	0.462	0.402	0.387	0.414	0.427
MAPE	0.442	0.301	0.398	0.442	0.161	0.128	0.231	0.252
Doğruluk	%60.87	%72.87	%62.61	%60.87	%77.22	%78.43	%76.70	%76.00

DVM modellerinin karşılaştırılmasında kullanılan R², MSE, MAE, RMSE ve MAPE ölçütlerine ait değerler Tablo 32’de gösterilmiştir. Sonuçlara göre DVM parametreleri ile oluşturulan 8 farklı model için R² determinasyon katsayısının 0.549 ile 0,821 arasında değerler aldığı tespit edilmiştir. 8 farklı DVM modeli için R² düzeyinde bir karşılaştırma yapıldığında borsa endeksi ertesi günkü yönünü en doğru öngören modellerin DVMR-2 ve DVMR-1 modelleri olduğu belirlenmiştir. Modeller için R² değerleri %82 ve %79 oranlarında gerçekleştiği görülmektedir.


Sekiz farklı DVM modeli için MAPE değerlerine bakıldığında 0.128 ile 0.442 arasında değerler aldığı görülmüştür. MAPE oranı ile DVM modelleri karşılaştırıldığında %10 ile %20 arasında hata oranı gerçekleşmesi sebebiyle DVMR-2 ve DVMR-1 modellerinin iyi modeller oldukları ifade edilebilir. Bu modellerin MAPE oranları %12 ve %16 olarak gerçekleştiği tespit edilmiştir. Buradan hareketle R² ve MAPE ölçütlerine göre DVM modellerinin benzer tahminleri yaptığını ve modellerimizin ertesi günkü endeks yönü tahminlerinin tutarlı olduğu gözlenmiştir.

Tablo 32 sonuçlarına göre MSE, MAE ve RMSE hata oranları sekiz farklı DVM modeli için sırasıyla MSE, 0.150 ile 0.247 arasında MAE, 0.350 ile 0.461

arasında ve RMSE, 0.387 ile 0.497 arasında değerler almıştır. MSE, MAE ve RMSE birim olarak değerlendirildiği için hata oranı sıfıra yaklaşan DVMR-2, DVMR-1 ve DVMP-1 modelleri tahmin başarısı yüksek modeller olmuştur.

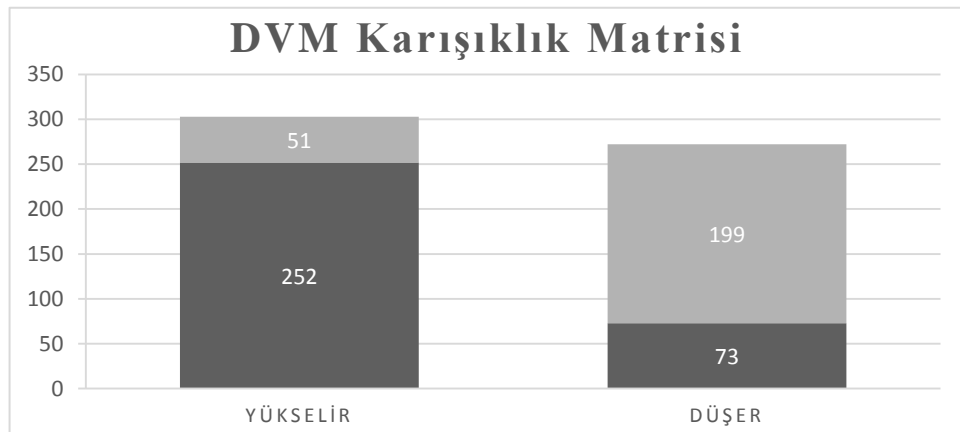
DVM modeli 575 günlük test veri setindeki tahminlere baktığımızda doğru tahmin edilen 252 gün yükselir ve 199 gün düşer gün sayısı ile %78.43'lük başarı göstermiştir. Ayrıca DVM modeli ile gerçek veri 51 gün yükselirken düşer diye tahmin edilmiş benzer şekilde gerçek veri 73 gün düşerken yükselir diye tahmin edilmiştir. DVM endeks tahmini Şekil 31'de gösterilmiştir.

Şekil 31. DVM Endeks Tahmini



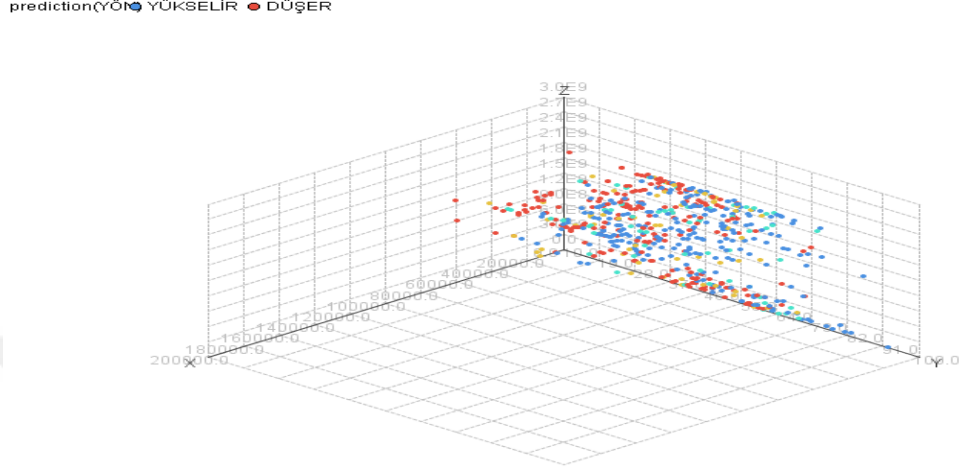
En yüksek tahmin doğruluğu veren DVM modeli yön tahmininde karışıklık matrisi verileri Şekil 32'de gösterilmiştir. Şekil 32'de birinci sütundaki siyah renkli kısım gerçekte yükselen değeri doğru tahminleyen değerler kısmı, ikinci sütundaki gri renkli kısım ise gerçekte düşen değerleri doğru tahminleyen değerler kısmıdır.

Şekil 32. DVM Endeks Yön Tahmini Karışıklık Matrisi Verileri.




En yüksek tahmin doğruluğu veren DVM modeli yön tahmininde yükselen ve düşen kapanış verileri Şekil 33'te gösterilmiştir. Şekil 33'te mavi renkli olan noktalar yükselişleri kırmızı renkli olan noktalar ise düşüşleri sembolize etmektedir.

Şekil 33. DVM Modeli Yön Tahmininde Yükselen ve Düşen Kapanış Verileri.



Şekil 34'e göre DVM endeks tahmin sonuçları ile ölçülen gerçek borsa verileri arasındaki korelasyonun $R=0.906$ bulunmuştur. Buna göre ölçülen borsa endeks verileri ile DVM tahmin verileri arasında kuvvetli bir ilişki vardır sonucuna ulaşılmıştır.

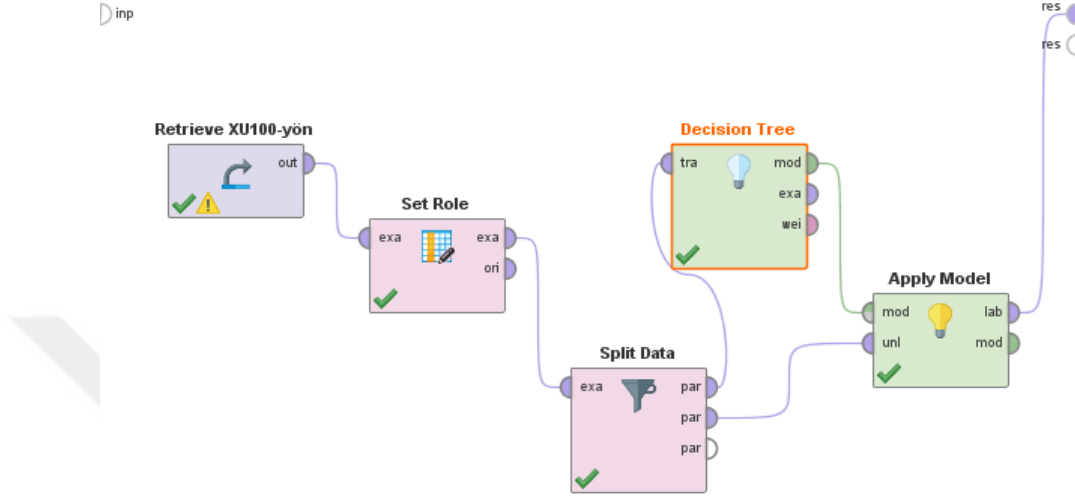
Şekil 34. DVM Tahmini ile Borsa Endeksi Korelasyonu



7.1.3. Karar Ağaçları Yöntemi İle Endeks Yönü Tahmini

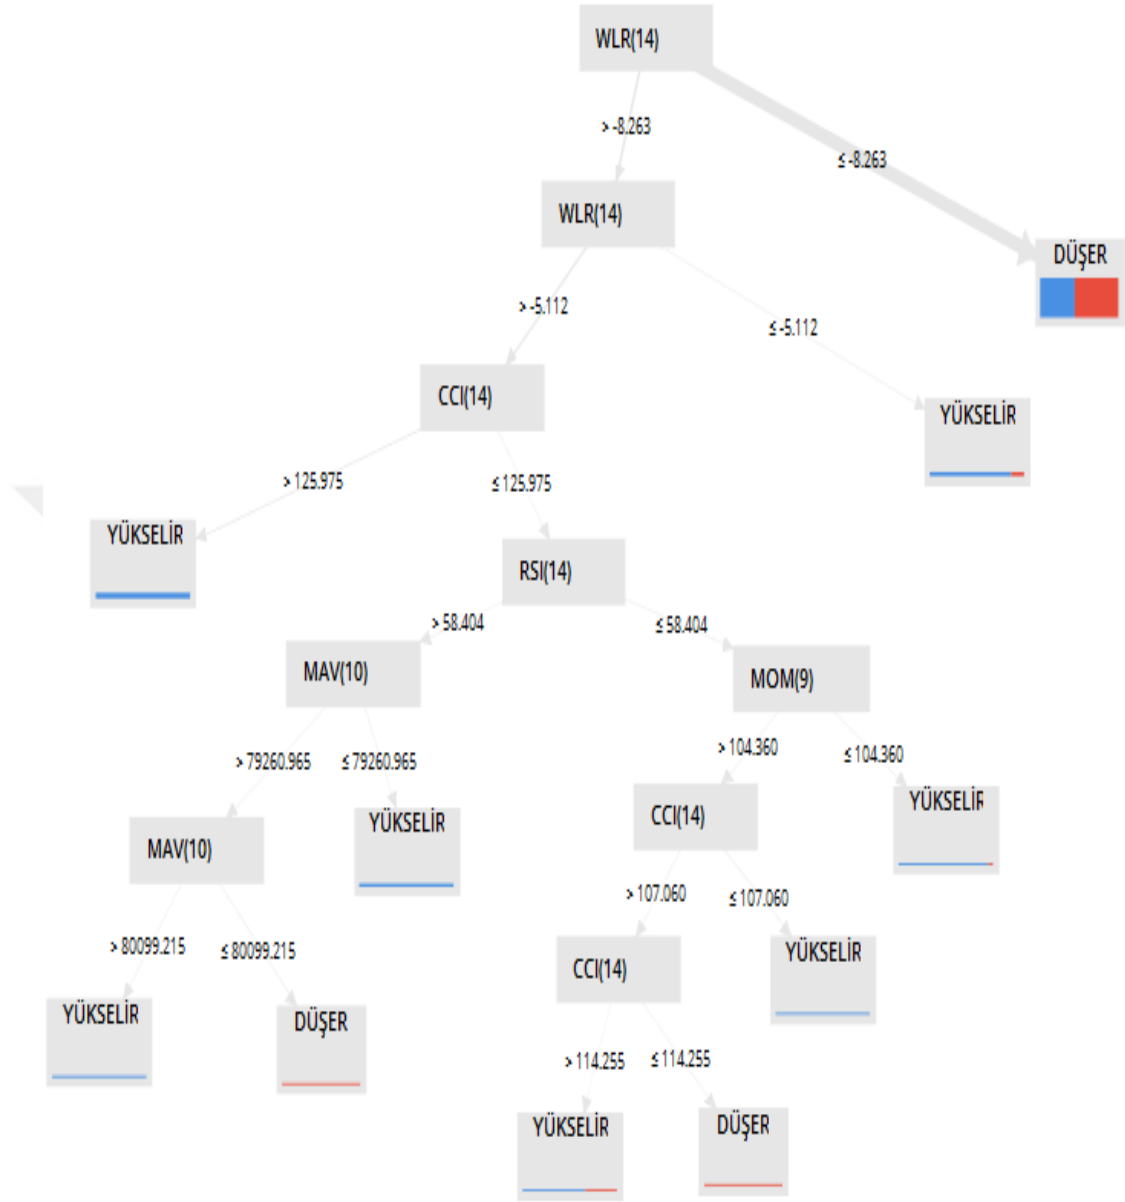
Karar Ağaçları, Rapid Miner (Şekil 35) programında dizayn edildikten sonra program çalıştırıldığında elde edilen sonuçlar aşağıda verilmiştir.

Şekil 35. Rapid Miner Karar Ağacı Süreci.



Rapid Miner programı ile karar ağacı yöntemi kullanılarak endeks yön tahmini yaptığımızda ortaya çıkan sonuçlara göre 10 teknik göstergeden 5 tanesinin karar ağacı yapısında aktif rol aldığını görülmüştür. Problemin optimal çözümünde olan teknik göstergeler WILL'R, CCI, RSI, MAV ve MOM'dir. Karar ağacı modelinde 5 teknik göstergenin yer aldığı J48 algoritmasından elde edilen karar ağacı Şekil 4.14'te gösterilmiştir.

Şekil 36. Endeks Yön Tahmini Karar Ağacı Modeli



KA sonuçlarına göre MAV (Hareketli Ortalama) ve CCI teknik göstergeleri endeks yön tahmin problemini en iyi tahminleyen göstergeler olmuştur. Karar Ağacı karışıklık matrisine göre doğruluk tahmini için 130 veri pozitif yükselir ve 244 veri yanlış düşer tahmininde bulunmuştur. Gelecek verilerin tahmininde yükselir ve düşer olarak tespit edilen tahmin doğruluk oranı Denklem 62 kullanılarak %65.04 hesaplanmıştır ve Tablo 33'te gösterilmiştir.

$$D.O = \frac{130 + 244}{130 + 28 + 173 + 244} = 0,6504$$

Tablo 33. Karar Ağacı Karışıklık Matrisi

Doğruluk: %65.04	gerçek YÜKSELİR	gerçek DÜŞER
tahmin YÜKSELİR	130	28
tahmin DÜŞER	173	244


R^2 , MSE, MAE, RMSE ve MAPE değerleri ise sırasıyla 0.633, 0.216, 0.430, 0.465 ve 0.382 bulunmuştur. R^2 'nin %60'ın üstünde çıkması verilerin modelin tahmin gücünü açıklamada uyumluluğunu göstermektedir. MAPE oranının %20 ile %50'lik dilimde olması Karar Ağacı modelinin kabul edilebilir bir model olduğu anlamına gelmektedir. Aynı şekilde diğer verilerle uyumlu olarak hata oranlarının da küçük değerler alması modelinin tahmin gücü hakkında bilgiler vermektedir (Tablo 34).

Tablo 34. Karar Ağacı Test Sonuçları

	Doğruluk
R^2	0.633
MSE	0.216
MAE	0.430
RMSE	0.465
MAPE	0.382
Doğruluk	%65.04

Karar ağacı endeks tahmini grafiği Şekil 37'de gösterilmiştir.


Şekil 37. Karar Ağacı Endeks Tahmini



Karar ağacı modeli yön tahmininde karışıklık matrisi verileri Şekil 38'de gösterilmiştir. Şekil 38'de birinci sütundaki siyah renkli kısım gerçekte yükselen

değeri doğru tahminleyen değerler kısmı, ikinci sütündeki gri renkli kısım ise gerçekte düşen değerleri doğru tahminleyen değerler kısmıdır.


Şekil 38. Karar Ağacı Endeks Yön Tahmini Karışıklık Matrisi Verileri.



Şekil 39’da mavi renkli olan noktalar yükselişleri kırmızı renkli olan noktalar ise düşüşleri sembolize etmektedir. Şekil 39 makine öğrenmesi karar ağacı modelinde üç boyutlu piyasa ya da endeks yönündeki tahmin eğilimini göstermektedir.

Şekil 39. Karar Ağacı Modeli Yön Tahmininde Yükselen ve Düşen Kapanış Verileri


predictionYÖN ● YÜKSELİR ● DÜŞER



Şekil 40’a göre Karar Ağacı endeks tahmin sonuçları ile ölçülen gerçek borsa verileri arasındaki korelasyonun $R=0,795$ olduğu görülmüştür. Ortaya çıkan bu

sonuca göre gerçek borsa verileri ile Karar Ağacı tahmin verileri arasında oldukça yüksek bir ilişki vardır sonucuna ulaşılmaktadır.

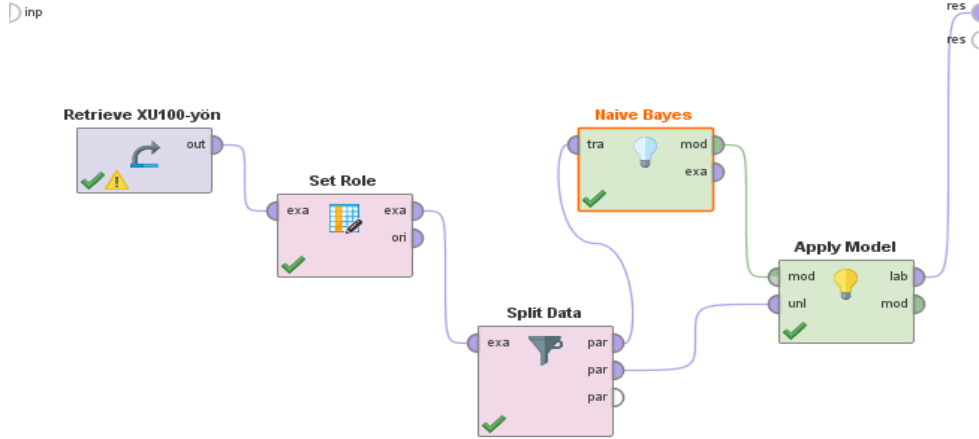
Şekil 40. Karar Ağacı Tahmini ile Borsa Endeksi Korelasyonu.



7.1.4. Naive Bayes Yöntemi İle Endeks Yönü Tahmini

Naive Bayes model süreci, Rapid Miner (Şekil 41) programında dizayn edildikten sonra program çalıştırıldığında elde edilen sonuçlar aşağıda verilmiştir.

Şekil 41. Rapid Miner Naive Bayes Süreci.



Naive Bayes karışıklık matrisine göre doğruluk tahmini için 193 veri pozitif yükselir ve 162 veri negatif düşer tahmininde bulunmuştur. Gelecek verilerin tahmininde yükselir ve düşer olarak tespit edilen tahmin doğruluk oranı %61.74 ile Tablo 35'te gösterilmiştir. Doğruluk oranı Denklem 62 ile hesaplanır.

$$D.O = \frac{193 + 162}{193 + 110 + 110 + 162} = 0,6174$$

Tablo 35. Naive Bayes Karışıklık Matrisi

Doğruluk: %61.74	gerçek YÜKSELİR	gerçek DÜŞER
tahmin YÜKSELİR	193	110
tahmin DÜŞER	110	162


R^2 ve MAPE oranları sırası ile 0.564 ve 0.436 değerleri ile kabul edilebilir değer aralığında olup Naive Bayes modelinin uygun bir model olduğunu görülmektedir. MSE, MAE ve RMSE değerleri de aynı şekilde küçük değerler almış ve doğruluk tahmin gücünün yatırımcılar için kullanılabilir seviyede olduğu Tablo 36'da görülmektedir.

Tablo 36. Naive Bayes Test Sonuçları

	Doğruluk
R^2	0.564
MSE	0.301
MAE	0.391
RMSE	0.548
MAPE	0.436
Doğruluk	%61.74


Naive Bayes endeks tahmini Şekil 42'de grafiksel olarak gösterilmiştir.

Şekil 42. Naive Bayes Endeks Tahmini.



Naive Bayes modeli yön tahmininde karışıklık matrisi verileri Şekil 43'te gösterilmiştir. Şekil 43'te birinci sütundaki siyah renkli kısım gerçekte yükselen değeri doğru tahminleyen değerler kısmı, ikinci sütundaki gri renkli kısım ise gerçekte düşen değerleri doğru tahminleyen değerler kısmıdır.


Şekil 43. Naive Bayes Endeks Yön Tahmini Karışıklık Matrisi Verileri.



Şekil 44'te mavi renkli olan noktalar yükselişleri kırmızı renkli olan noktalar ise düşüşleri sembolize etmektedir. Şekil 44 makine öğrenmesi naive bayes modelinde üç boyutlu piyasa ya da endeks yönündeki tahmin eğilimini göstermektedir.


Şekil 44. Naive Bayes Modeli Yön Tahmininde Yükselen Ve Düşen Kapanış Verileri

prediction(YÖN) ● YÜKSELİR ● DÜŞER



Şekil 45'e göre Naive Bayes endeks tahmin sonuçları ile ölçülen gerçek borsa verileri arasında korelasyonun $R=0,750$ olduğu görülmektedir. Ortaya çıkan bu sonuca göre iki grup veri arasında yüksek bir ilişki vardır sonucuna ulaşılmaktadır.

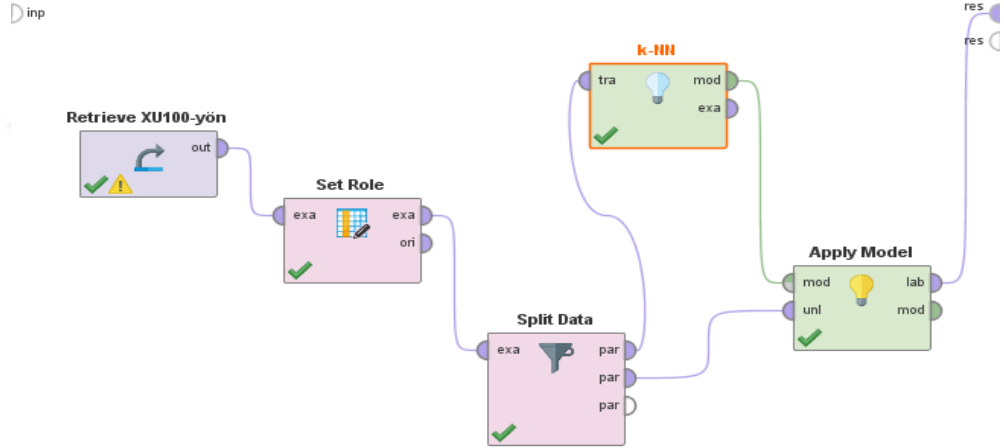
Şekil 45. Naive Bayes Tahmini ile Borsa Endeksi Korelasyonu.



7.1.5. K-En Yakın Komşuluk Yöntemi İle Endeks Yönü Tahmini

K-En Yakın Komşuluk model süreci, Rapid Miner (Şekil 46) programında dizayn edildikten sonra elde edilen sonuçlar aşağıda verilmiştir.

Şekil 46. Rapid Miner k-En Yakın Komşuluk Yöntemi Süreci.



7.1.5.1. Test Edilen k-EYK Parametre Seviyeleri

Gözlemlenen verinin k tane komşusu olduğundan en iyi tahmin performansını veren k 'nın optimal bir değeri vardır. Bu çalışmada k sabiti için 1-10 arası değerler deneme yanılma yöntemi ile test edilmiştir ve $k=4$ için optimal değere ulaşılmıştır. Çalışmada optimal sonuçları veren $k=4$ EYK modeli test sonuçları şöyledir:

EYK'da $k=4$ için test edilen model sonuçlarına göre 233 pozitif yükselir ve 86 negatif düşer veri toplamda Denklem 62 kullanılarak %55.48 tahmin doğruluğuna ulaşmıştır (Tablo 37).

$$D.O = \frac{233+86}{233+186+70+86} = 0,5548$$

Tablo 37. k-EYK Karışıklık Matrisi

Doğruluk: %55.48	gerçek YÜKSELİR	gerçek DÜŞER
tahmin YÜKSELİR	233	186
tahmin DÜŞER	70	86

Doğruluk oranı %55.48, MAPE değeri 0.507 ile yatırımcılar için kullanılabilir bir model ve yüksek bir doğruluk oranı k=4 EYK modeli ile Tablo 38’de görülmektedir.

Tablo 38. k-EYK Test Sonuçları

	Doğruluk
R ²	0.443
MSE	0.275
MAE	0.465
RMSE	0.524
MAPE	0.507
Doğruluk	%55.48

7.1.5.2. K-EYK Yöntemi Genel Değerlendirme

K-EYK modeli, hisse senedi fiyat endeksi hareketinin yönünü tahmininde kullanılan esnek bir yöntemdir ve bu çalışmanın sonuçları önceki bazı (Alkhatib vd., 2013; Chahardoli, Yaghubi ve Esmaeilpour, 2015; İlarıslan, 2016; Nakagawa, Imamura ve Yoshida, 2017) çalışmalarla uyumludur. K-EYK test sonuçları Tablo 39’deki gibidir.

Tablo 39. k-En Yakın Komşuluk Test Sonuçları

	EYK k=1	EYK k=2	EYK k=3	EYK k=4	EYK k=5	EYK k=10
R ²	0.332	0.408	0.431	0.443	0.392	0.348
MSE	0.483	0.342	0.307	0.275	0.274	0.266
MAE	0.483	0.470	0.472	0.465	0.475	0.490
RMSE	0.695	0.585	0.554	0.524	0.523	0.516
MAPE	0.694	0.586	0.538	0.507	0.602	0.653
Doğruluk	%51.65	%54.09	%55.13	%55.48	%53.91	%52.70


K-EYK modellerinin karşılaştırılmasında kullanılan R^2 , MSE, MAE, RMSE ve MAPE ölçütlerine ait değerler Tablo 39'da gösterilmiştir. Sonuçlara göre k-EYK parametreleri ile oluşturulan altı farklı model için R^2 determinasyon katsayısının 0.332 ile 0.443 arasında değerler aldığı tespit edilmiştir. Altı farklı k-EYK modeli için R^2 düzeyinde bir karşılaştırma yapıldığında borsa endeksi ertesi günü yönünü en iyi tahmin eden modellerin k=4 EYK ve k=3 EYK modelleri olduğu belirlenmiştir. Modeller için R^2 değerleri sırasıyla %44 ve %43 oranlarında gerçekleştiği görülmektedir.

Altı farklı k-EYK modeli için MAPE değerlerine bakıldığında 0.507 ile 0.694 arasında değerler aldığı görülmüştür. MAPE oranı ile k-EYK modelleri karşılaştırıldığında %50 hata oranı gerçekleşmesi sebebiyle modellerin k=4 EYK ve k=3 EYK modellerinin kabul edilebilir modeller oldukları ifade edilebilir. Bu modellerin MAPE oranları %50 olarak gerçekleştiği tespit edilmiştir. Buradan hareketle R^2 ve MAPE ölçütlerine göre k-EYK modellerinin benzer tahminleri yaptığını ve bu modellerin ertesi günü endeks yönü tahminlerinin tutarlı olduğu gözlenmiştir.

Tablo 39 sonuçlarına göre MSE, MAE ve RMSE hata oranları altı farklı k-EYK modeli için sırasıyla MSE, 0.274 ile 0.483 arasında MAE, 0.465 ile 0.490 arasında ve RMSE, 0.516 ile 0.695 arasında değerler almıştır. MSE, MAE ve RMSE birim olarak değerlendirildiği için hata oranları daha düşük olan k=4 EYK, k=3 EYK ve k=2 EYK modelleri tahmin başarısı diğer modellere göre daha yüksek modeller olmuştur.


K-EYK parametreleri ile oluşturulan altı farklı model değerlendirildiğinde; k değerleri yükseldikçe tahmin başarısının arttığı gözlenmiştir. En yüksek başarı oranı k=4 değeri ile sağlandıktan sonra başarı oranları düşmeye başlamıştır. Böylece k-EYK yöntemi için optimal başarıya k=4 değeri ile ulaşıldığı tespit edilmiştir. K-EYK endeks tahmini Şekil 47'de gösterilmiştir.

Şekil 47. k-EYK Endeks Tahmini.



En yüksek doğruluğu veren $k=4$ en yakın komşu modeli yön tahmininde karışıklık matrisi verileri Şekil 48’de gösterilmiştir. Şekil 48’de birinci sütundaki siyah renkli kısım gerçekte yükselen değeri doğru tahminleyen değerler kısmı, ikinci sütundaki gri renkli kısım ise gerçekte düşen değerleri doğru tahminleyen değerler kısmıdır.


Şekil 48. k- EYK Endeks Yön Tahmini Karışıklık Matrisi Verileri.



Şekil 49’da mavi renkli olan noktalar yükselişleri kırmızı renkli olan noktalar ise düşüşleri sembolize etmektedir. Şekil 49 makine öğrenmesi $k=4$ için en yakın komşuluk modelinde üç boyutlu piyasa ya da endeks yönündeki tahmin eğilimini göstermektedir.


Şekil 49. k-EYK Modeli Yön Tahmininde Yükselen ve Düşen Kapanış Verileri.

prediction(YÖN) YÜKSELİR DÜŞER



Şekil 50'ye göre k-EYK endeks tahmin sonuçları ile ölçülen gerçek borsa verileri arasındaki korelasyonun $R=0,665$ olduğu belirlenmiştir. Ortaya çıkan bu sonuca göre gerçek borsa değerleri ile k-EYK tahmin verileri arasında orta şiddette bir ilişki vardır sonucuna ulaşılmaktadır.

Şekil 50. k-EYK Tahmini ile Borsa Endeksi Korelasyonu.

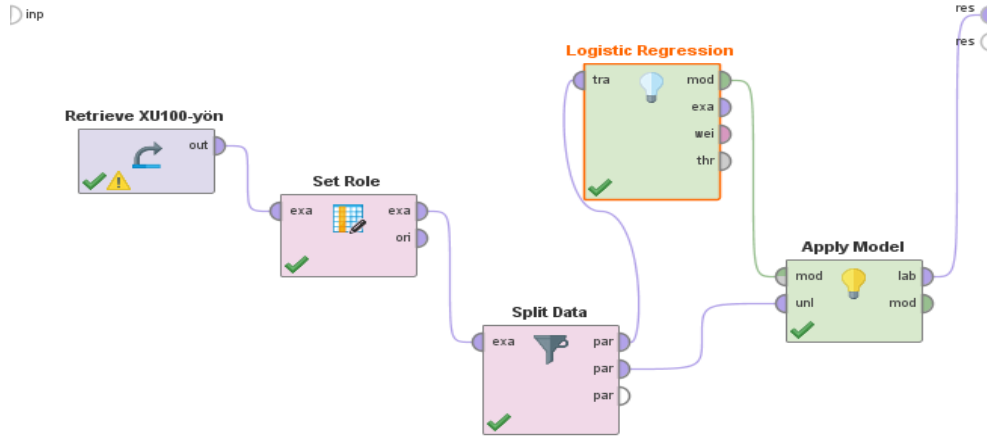


7.2. İSTATİSTİKSEL YÖNTEMLERLE ENDEKS YÖNÜ TAHMİNİ

7.2.1. Lojistik Regresyon Yöntemi İle Endeks Yönü Tahmini

LogR model süreci, Rapid Miner (Şekil 51) programında dizayn edildikten sonra program çalıştırıldığında elde edilen sonuçlar aşağıda verilmiştir.

Şekil 51. Rapid Miner LogR Yöntemi Süreci.



Pozitif yükselir veri sayısı 241, negatif düşer veri sayısı 200 ile doğru tahmin oranı Denklem 62 kullanılarak %76.70 olduğu hesaplanmıştır ve Tablo 40'da görülmektedir.

$$D.O = \frac{241 + 200}{241 + 72 + 62 + 200} = 0,7670$$

Tablo 40. LogR Karışıklık Matrisi

Doğruluk: %76.70	gerçek YÜKSELİR	gerçek DÜŞER
tahmin YÜKSELİR	241	72
tahmin DÜŞER	62	200


MSE, MAE ve RMSE'nin sıfıra yakın küçük değerler çıkması tahmin doğruluğunun %76.70 gibi yüksek bir değer olduğunu onaylar niteliktedir ve Tablo 41'de gösterilmiştir.

Tablo 41. LogR Test Sonuçları

	Doğruluk
R ²	0.783
MSE	0.153
MAE	0.301
RMSE	0.391
MAPE	0.231
Doğruluk	%76.70


LogR endeks tahmini Şekil 52'de gösterilmiştir.

Şekil 52. LogR Endeks Tahmini.



LogR modeli yön tahmininde karışıklık matrisi verileri Şekil 53'te gösterilmiştir. Şekil 53'te birinci sütundaki siyah renkli kısım gerçekte yükselen değeri doğru tahminleyen değerler kısmı, ikinci sütundaki gri renkli kısım ise gerçekte düşen değerleri doğru tahminleyen değerler kısmıdır.


Şekil 53. LogR Endeks Yön Tahmini Karışıklık Matrisi Verileri.



LogR modeli yön tahmininde yükselen ve düşen kapanış verileri Şekil 54'te gösterilmiştir. Şekil 54'te mavi renkli olan noktalar yükselişleri kırmızı renkli olan noktalar ise düşüşleri sembolize etmektedir.


Şekil 54. Lojistik Regresyon Modeli Yön Tahmininde Yükselen ve Düşen Kapanış Verileri.

predictionYÖN: YÜKSELİR (mavi), DÜŞER (kırmızı)



Şekil 55'e göre LogR endeks tahmin sonuçları ile gerçek borsa endeks değerleri arasındaki korelasyonun $R=0,884$ olduğu bulunmuştur. Ortaya çıkan bu sonuca göre iki grup arasında kuvvetli bir ilişki vardır sonucuna ulaşılmaktadır.

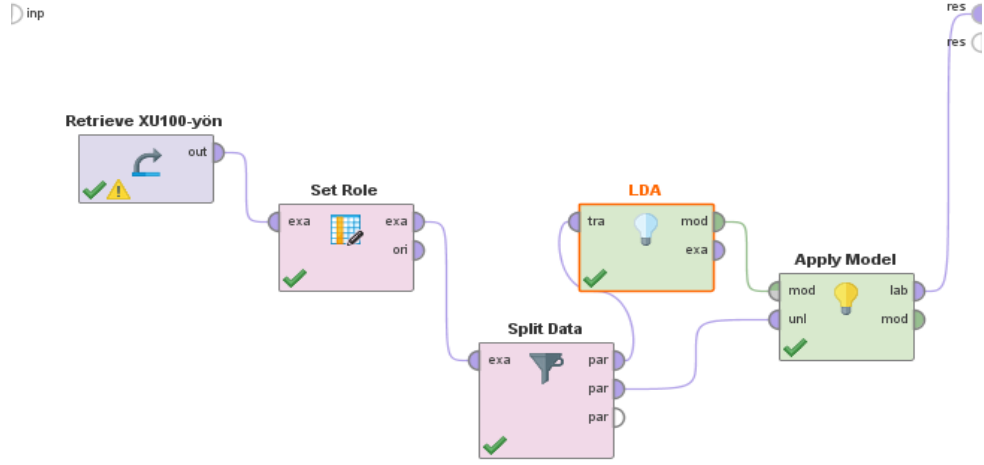
Şekil 55. LogR Tahmini ile Borsa Endeksi Korelasyonu.



7.2.2. Doğrusal Diskriminant Analizi Yöntemi İle Endeks Yönü Tahmini

DDA model süreci, Rapid Miner (Şekil 56) programında dizayn edildikten sonra program çalıştırıldığında elde edilen sonuçlar aşağıda verilmiştir.

Şekil 56. Rapid Miner DDA Yöntemi Süreci.



Denklem 62 kullanılarak hesaplanan doğruluk oranının %76.87 olduğu DDA modelinde pozitif yükselir veri sayısı 247 ve negatif düşer veri sayısı 195 olarak gerçekleştiği Tablo 42’de gösterilmiştir.

$$D.O = \frac{247 + 195}{247 + 77 + 56 + 195} = 0,7687$$

Tablo 42. DDA Karışıklık Matrisi

Doğruluk: %76.87	gerçek YÜKSELİR	gerçek DÜŞER
tahmin YÜKSELİR	247	77
tahmin DÜŞER	56	195


DDA modeli analiz sonuçlarına göre MSE, MAE ve RMSE değerleri sırasıyla 0.149, 0.289 ve 0.387’dir. R^2 ’nin 0.787 çıkması ise Doğrusal Diskriminant Analizi modelinin iyi olduğunun göstergesidir ve test sonuçları Tablo 43’de görülmektedir.

Tablo 43. DDA Test Sonuçları

	Doğruluk
R^2	0.787
MSE	0.149
MAE	0.289
RMSE	0.387
MAPE	0.184
Doğruluk	%76.87


DDA endeks tahmini Şekil 57’de gösterilmiştir.

Şekil 57. DDA Endeks Tahmini.




DDA modeli yön tahmininde karışıklık matrisi verileri Şekil 58’de gösterilmiştir. Şekil 58’de birinci sütundaki siyah renkli kısım gerçekte yükselen değeri doğru tahminleyen değerler kısmı, ikinci sütundaki gri renkli kısım ise gerçekte düşen değerleri doğru tahminleyen değerler kısmıdır.

Şekil 58. DDA Endeks Yön Tahmini Karışıklık Matrisi Verileri.




DDA modeli yön tahmininde yükselen ve düşen kapanış verileri Şekil 59’da gösterilmiştir. Şekil 59’da mavi renkli olan noktalar yükselişleri kırmızı renkli olan noktalar ise düşüşleri sembolize etmektedir.

Şekil 59. DDA Modeli Yön Tahmininde Yükselen Ve Düşen Kapanış Verileri.



Şekil 60'a göre DDA endeks tahmin sonuçları ile ölçülen gerçek borsa verileri arasındaki korelasyon katsayısının $R=0,887$ olması gerçek borsa değerleri ile DDA tahmin verileri arasında kuvvetli bir ilişki olduğunu göstermektedir.

Şekil 60. DDA Tahmini ile Borsa Endeksi Korelasyonu.



8. ANALİZ SONUÇLARININ KARŞILAŞTIRILMASI

Genel olarak bir değerlendirme yapmak gerekirse sınıflandırma modellerinin, hisse senedi fiyat endeksi hareketinin yönünü tahmin sonuçları literatürdeki bazı (Yao, Tan ve Poh, 1999; Diler, 2003; Yu vd., 2005; Kara, Boyacıoğlu ve Baykan, 2011; Lahmiri, 2011; Aldin, Dehnavi ve Entezari, 2012; Dastgir ve Enghiad, 2012;

Karymshakov ve Abdykaparov, 2012; Emir, 2013; Dunis vd., 2013; Lahmiri, Boukadoum ve Chartier, 2013; Oliveira, Nobre ve Zárate, 2013; Tayyar ve Tekin, 2013; Wang ve Shang, 2014; Anbalagan ve Maheswari, 2015; Jabbarzadeh vd., 2016; Gurjar vd., 2018; Dash vd., 2019; Nadh ve Prasad, 2019) çalışmalarla uyumludur.

Çalışmadaki modellerin karşılaştırılmasında kullanılan R^2 , MSE, MAE, RMSE ve MAPE ölçütlerine ait değerler Tablo 44'te gösterilmiştir. Sonuçlara göre YSA, DVM, KA, NB, k-EYK, LogR ve DDA modelleri için R^2 belirlilik katsayısının 0,443 ile 0,958 arasında değerler aldığı tespit edilmiştir. Yedi farklı sınıflandırma modeli için R^2 düzeyinde bir karşılaştırma yapıldığında borsa endeksinin ertesi günkü yönünü en iyi tahmin eden modellerin sırasıyla YSA, DVM, DDA ve LogR modelleri olduğu söylenebilir. Bu modellerin R^2 değerleri %95, %82, %78 ve %78 olarak gerçekleştiği görülmektedir. Çalışmada elde edilen bu sonuç literatürdeki bazı (Yao, Tan ve Poh, 1999; Diler, 2003; Yu, Wang ve Lai, 2005; Lu, 2010; Wang ve Zhu, 2010; Nair, Mohandas ve Sakthivel, 2010; Lahmiri, 2011; Dastgir ve Enghiad, 2012; Karagül, 2014; Dash ve Dash, 2016a; Li vd., 2016; Filiz, Karaboğa ve Akoğul, 2017) çalışmalar ile uyumludur.

Tablo 44. Tüm Analizler En İyi Test Sonuçları

	YSA	DVM	KA	NB	k-EYK	LogR	DDA
R^2	0.958	0.821	0.633	0.564	0.443	0.783	0.787
MSE	0.128	0.150	0.216	0.301	0.275	0.153	0.149
MAE	0.245	0.350	0.430	0.391	0.465	0.301	0.289
RMSE	0.358	0.387	0.465	0.548	0.524	0.391	0.387
MAPE	0.073	0.128	0.382	0.436	0.507	0.231	0.184
Doğruluk	%83.83	%78.43	%65.04	%61.74	%55.48	%76.70	%76.87


Yedi farklı sınıflandırma modeli için MAPE değerlerine bakıldığında 0.073 ile 0.507 arasında değerler aldığı görülmüştür. MAPE oranı ile sınıflandırma modelleri karşılaştırıldığında %10'nun altında hata oranı gerçekleşmesi sebebiyle YSA modelinin çok iyi model olduğu ifade edilirken %10 ile %20 arasında değer alan DVM ve DDA modellerinin de iyi modeller oldukları söylenebilir. Bu modellerin MAPE oranlarının sırasıyla %7, %12 ve %18 olarak gerçekleştiği tespit edilmiştir. Buradan hareketle R^2 ve MAPE ölçütlerine göre sınıflandırma

modellerinin benzer tahminleri yaptığını ve modellerimizin ertesi günü endeks yönü tahminlerinin tutarlı olduğu gözlenmiştir. Ayrıca Karymshakov ve Abdykaparov (2012), Aldin, Dehnavi ve Entezari (2012), Oliveira, Nobre ve Zárate, (2013), Chen vd. (2014) ve Gurjar vd. (2018)'nin çalışmalarıyla tutarlılık arz eden bu sonuca göre YSA modelleri, geleneksel modellere göre daha başarılıdır.

Tablo 44 sonuçlarına göre MSE, MAE ve RMSE hata oranları yedi farklı sınıflandırma modeli için sırasıyla MSE, 0.128 ile 0.301 arasında MAE, 0.245 ile 0.465 arasında ve RMSE, 0.353 ile 0.548 arasında değerler almıştır. MSE, MAE ve RMSE birim olarak değerlendirildiği için hata oranı sıfıra yaklaşan YSA, DVM, LogR ve DDA modelleri tahmin başarısı yüksek modeller olmuştur. Elde edilen bu sonuç (Aldin, Dehnavi ve Entezari, 2012; Karymshakov ve Abdykaparov, 2012) çalışmaları ile uyumlu iken, bazı (Lahmiri, Boukadoum ve Chartier, 2013; Anbalagan ve Maheswari, 2015; Patel vd., 2015; Rostami vd., 2015; Pehlivanlı, Aşıkil ve Gülay, 2016) çalışmalarla uyumlu değildir.

Birden fazla sınıflandırma algoritmasının aynı anda doğruluk tahmini karşılaştırıldığında ise en iyi tahminleri veren algoritmaların grafiğin sol üst köşesinde yer alan DDA, LogR, YSA ve DVM modelleri olduğu Şekil 61'de görülmektedir. Çalışmada tespit edilen bu sonuçlar literatür ile de uyumludur (Öz, Ayırcay ve Kalkan, 2011; Akyatan, 2016).

Şekil 61. Birden Fazla Sınıflandırma Algoritmasının Aynı Anda Doğruluk Tahmini Karşılaştırılması.



Elde edilen bulgulara göre YSA, DVM, KA, NB, k-EYK, LogR ve DDA için doğruluk oranları sırasıyla %83.83, %78.43, %65.04, %61.74, %55.48, %76.70 ve %76.87'dir. Buna göre hisse senedi piyasalarında endeks yönünün tahmininde YSA yönteminin analiz edilen dönem açısından en doğru tahmini yapan yöntem olduğu tespit edilmiştir. Endeks yön tahmininde makine öğrenmesi yöntemlerinin başarısının daha yüksek olması literatürde ki (Huang, Nakamori ve Wang, 2005; Yu vd., 2005; Avcı, 2009; Ou ve Wang, 2009; Kara, Boyacıoğlu ve Baykan, 2011; Subha ve Nambi, 2012; Yakut, 2012; Dunis vd., 2013; Emir, 2013; Tayyar ve Tekin, 2013; Adebisi, Adewumi ve Ayo, 2014; Wang ve Shang, 2014; Çalışkan ve Deniz, 2015; Gündüz, Yaslan ve Çataltepe, 2017; Santoso, Sutjiadi ve Lim, 2018; Dash vd., 2019) çalışmaların sonuçlarıyla uyumludur. Ayrıca Tablo 44'teki tahmin sonuçlarına ait hata oranlarına bakıldığında, YSA modelinin tüm hata terimleri de doğruluk sonuçlarını desteklemektedir. Tespit edilen bu sonucun Sakarya vd. (2015) ve Kılıç, Paksoy ve Genç (2015) tarafından yapılan çalışmalar ile uyumlu olduğu görülmüştür. Bu sonuçlardan hareketle, literatürde yapılan birçok çalışmayla benzer biçimde dinamik yöntemler olarak ifade edilen makine öğrenmesi yöntemlerinin daha kullanışlı ve sonuç odaklı olabileceği söylenebilir.

SONUÇ VE DEĞERLENDİRME

Günümüzde borsa endeksi hareket yönü tahmini, yatırımcılar için dinamik ve karmaşık finansal piyasalarda yatırım kararları için son derece önemli bir konudur. Hisse senedi endeks hareketinin yönünü ve fiyatlarını tahmin etmek zordur, çünkü genellikle yatırımcılar için işlem maliyetlerine ve kaçırılan fırsatlara yol açar. Yatırımcılar sadece yatırım fırsatlarını tespit etmek için değil, aynı zamanda tutarlı bir yaklaşım sağlamak için sistematik bir yöntem ihtiyacı duyarlar, böylece yatırım risklerinden kaçınmış ve maliyetler en aza indirilmiş olur.

Günümüzde gerçek riske dayanarak daha üstün genelleme kabiliyeti olan ve daha az teorik düşünce içererek esneklik sağlayan makine öğrenmesi yöntemleri borsa endeksi hareket yönü tahmini, finansal başarısızlık tahmini ya da hisse senedi fiyat tahmini gibi birçok alanda geleneksel istatistikî yöntemlere göre daha fazla kullanım alanı bulmaktadır. Bu yöntemler insan zekasını taklit ederek örneklerden öğrenme yapabilme yeteneğine sahiptirler. Çalışmada makine öğrenmesi yöntemlerinden Yapay Sinir Ağları, Destek Vektör Makineleri, Karar Ağacı, Naive Bayes ve k-En Yakın Komşuluk yöntemleri ile geleneksel istatistikî yöntemlerden Lojistik Regresyon ve Doğrusal Diskriminant Analizi yöntemleri olmak üzere 7 yöntemin borsa endeksi yönü tahmin performansları karşılaştırılmıştır. Bu yönüyle çalışma bilindiği kadarıyla literatürde ilk kez 7 yöntemin bir arada kullanıldığı çalışma olması özelliği taşımaktadır.

BİST 100 endeksinin çalışma alanı seçilmesindeki en önemli sebebi Türkiye borsasının hızlı gelişmesi ve yatırımcılara fırsatlar sunmasıdır. 1985 yılında İstanbul Menkul Kıymetler Borsası'nın kuruluşundan bu yana, Türkiye hisse senedi piyasaları hızla genişlemiştir. Bu hızlı büyüme önemli ölçüde hisse senedi fiyat hareketlerini tahmin etme yeteneğine akademik ilgi olarak yönelmiştir. Literatüre bakıldığında Türkiye borsalarının tahmini konusunda çok az çalışmanın olduğu görülmüştür. Burdan hareketle bu tez çalışmasının amacı, borsa endeksi için hareket yönünü tahmin etmektir. Tezde sınıflandırma yöntemleri teorik olarak incelendikten sonra yöntemlerin BİST 100 Endeks yönünün tahminindeki performansları karşılaştırılmıştır.

Sınıflandırma modelleriyle BİST 100 Endeksi hareket yönünü tahmin etmek için teknik göstergeler kullanılmıştır. Çalışmada 1995:3-2018:3 dönemine ait BİST 100 endeksi günlük kapanış verileri ve hesaplanan 10 teknik gösterge veri seti olarak alınmıştır. 1994 yılında yaşanan ekonomik krizden dolayı veri seti için 1995 yılı başlangıç olarak seçilmiştir. Girdi veri seti olarak hesaplanan 10 teknik göstergenin 5750 günlük kapanış değeri kullanılmıştır. Çıktı veri seti olarak da ertesi günkü kapanış fiyatları dikkate alınmıştır.

Çalışmada 10 teknik göstergenin 5750 günlük verisi sisteme girdi verisi olarak aktarılmıştır. Endeks yön tahmininde en çok kullanılan gösterge 10 günlük Ağırlıklı Hareketli Ortalamadır. Bu göstergeyi takip eden CCI, 10 günlük Hareketli Ortalama ve RSI göstergeleri olurken en az kullanılan gösterge ise A/D olmuştur. Buna göre BİST 100 Endeksinin yön tahmininde teknik göstergelerin etkili olduğu görülmüştür.

Analizlerde kurulan modeller içerisinde optimal sonuç 32 dakikada 34 nöron, 0.1 öğrenme oranı, 0.2 momentum sabiti ve 100000 tekrar ile bulunmuştur. Eğer tüm algoritmalar için aynı anda birlikte doğruluk tahmin karşılaştırılması yapılırsa benzer sonuçlar 154 dakikada bulunmaktadır. Bu durumda algoritmaların tek tek bağımsız olarak test edilmesi tahmin doğruluğunu daha güvenilir kılmakta ve zamanı optimize etmektedir.

Bu tez çalışmasında ertesi gün kapanış fiyatlarının doğru tahmin edilebilirliği literatürde en sık kullanılan iki metrik kullanılarak değerlendirilmiştir. Bu metriklerden birincisi doğruluk ve ikincisi hata oranlarıdır. YSA, DVM, DDA ve LogR modellerinin doğruluk oranı %75'in üzerinde değerler almış ve borsa hareket yönünü başarılı bir şekilde tahmin etmişlerdir. Modellerin tahmin değerleri ile gerçek değerler arasındaki fark, hata oranlarından MSE, MAE, RMSE ve MAPE değerleri ile hesaplanmış ve genellikle %10'un altında değerler almışlardır. Bu da sınıflandırma yöntemlerinin endeks yönünü küçük hatalarla tahmin ettiğini göstermektedir.

Çalışmada endeks yönü tahmininde optimize edilmiş 20 YSA, 8 DVM, 6 k-EYK ve 4 tanede diğer yöntemler olmak üzere toplam 38 model test edilmiştir. Her bir modelin; endeks tahmin grafiği, endeks ile yöntemin korelasyon grafiği,

karışıklık matris verileri ve üç boyutlu yön tahmin verileri çalışmanın anlaşılabilirliğini arttırmak ve tahmin başarısını daha açık bir şekilde ifade etmek için sunulmuştur. Bahsedilen grafikler incelendiğinde en yüksek doğruluk oranına sahip modelin diğer modellere göre ürettiği tahminlerin gerçek fiyatlara daha yakın olduğu görülmüştür.

Elde edilen bulgulara göre YSA, DVM, KA, NB, k-EYK, LogR ve DDA için doğruluk oranları sırasıyla %83.83, %78.43, %65.04, %61.74, %55.48, %76.70 ve %76.87 olarak test edilmiştir. Böylece, YSA modelinin %83.83 doğruluk ile en yüksek performansa sahip model olduğu ve k-EYK modelinin ise %55.48 doğruluk ile en düşük performans gösteren model olduğu anlaşılmaktadır. Böylece YSA'nın her 100 hisse senedinden 83'ünün ertesi gün fiyatında düşme veya yükselme olacağını doğru tahmin ettiği, bu sonuçlara göre YSA'nın tahminleme performansının çok iyi olduğu söylenebilir. Elde edilen bulgular, makine öğrenmesi modellerinden YSA'nın gerek DVM gerekse de diğer makine öğrenmesi yöntemlerine ve geleneksel istatistiki yöntemlere göre daha iyi performans sergilediğini göstermiştir. Ancak geleneksel yöntemlerin YSA ve DVM haricindeki makine öğrenmesi yöntemlerinden daha iyi performans sergilemesi çalışmanın ilginç bulgularındandır. Ayrıca çalışma, endeks yön tahmininde sınıflandırma yapan 5 makine öğrenmesi ve 2 istatistiki yöntemi kullanması ve karşılaştırması nedeniyle literatürdeki boşluğu kapatmaya yardımcı olacaktır.

İncelenen veri kümeleri üzerinde sınıflandırma yöntemlerinden en yüksek performansı her zaman YSA göstermiştir. Buna göre BİST gibi gelişmekte olan bir borsada endeks yönünü tahmin etmekte makine öğrenmesi yöntemlerinin faydalı araçlar olduğu görülmüş ve YSA yönteminin diğer yöntemlere göre daha az tahmin hatası oluşturduğu sonucuna varılmıştır.

YSA yönteminin üç boyutlu endeks değerlendirmesine göre, YSA grafiğinde homojenitenin olmadığı ve trendin var olduğu sonuçlarına ulaşılmıştır. LogR yönteminin üç boyutlu endeks değerlendirmelerine göre ise LogR grafiğinde homojenitenin var olduğu ve trendin olmadığı tespit edilmiştir. Üç boyutlu endeks grafiklerine bakılarak kolayca YSA'nın diğer yöntemlere göre daha doğru tahminler yaptığı görülebilir.

Sonuç olarak sınıflandırma yöntemlerinin endeks yönü tahminleri başarılı sonuçlar vermişlerdir. Bu da bize geçmiş endeks fiyatları ile gelecekteki fiyatların belirli bir seviyede doğru tahmin edilebileceğini göstermektedir. Bu sonuçlar yatırımcılar, araştırmacılar ve piyasa kullanıcıları için kaçırılmayacak fırsatlar sunabilir. Sınıflandırma problemlerinde her sınıfın tahmin düzeyinin yüksek ve birbirine yakın olması istenir. Bu sonuçların uzun vadede kazandıracağı düşünülür.

Çalışma, esnek yapısı ve doğrusal olmayan ilişkileri modelleme gücü sayesinde makine öğrenmesi modellerinin araştırmacılar ve yatırımcılar tarafından tahmin problemlerinde etkin bir şekilde kullanılabilceğini göstermesi yanında gelecekte yeni uygulamaların da kullanılmasını destekleyebilecektir. Ayrıca bu sonuçlar ile teknik göstergeler de olduğu gibi al/sat sinyalleri üretilerek piyasalar için dinamik alım/satım platformu oluşturulabilir.

Veri tabanını oluşturmak için 10 teknik gösterge literatür taranarak belirlenmiştir. Fakat teknik gösterge sayısı literatürde oldukça fazladır. Gelecek çalışmalarda başka teknik göstergelerin kullanılması tahmin performansını etkileyebilir. Ayrıca girdi verisi olarak döviz kuru, enflasyon, faiz oranları vb. diğer makroekonomik değişkenler kullanılabilir.

Hisse senedi fiyat endeksi hareketleri tahmini için Aşırı Öğrenme Makineleri, Genetik Algoritma, Rastgele Orman ve GARCH modeli ile parametrik olmayan testlerden MARS yöntemi gibi diğer yöntemlerin kullanılması önerilebilir. Hibrit olarak tasarlanan modellerle, tahmin başarısı arttırılabilir. Bu modellerin ve sinir ağlarının bir karşılaştırması da yapılabilir.

Çalışmanın amacı kısa vadeli tahmindir. Uzun vadeli tahminin, borsadaki performansının, gelirinin, kar getirilerinin analizini içerebilecek gelecekteki yönlerden biri olarak da düşünülebilir. Bir başka yönde farklı ülke borsalarında benzer çalışmalar yapılabilir ve sonuçları karşılaştırılabilir.

KAYNAKÇA

- Achelis, S. B. (2001). *Technical Analysis from A to Z*. New York: McGraw Hill.
- Adebiyi, A. A., Adewumi, A. O., & Ayo, C. K. (2014). Comparison of ARIMA and Artificial Neural Networks Models for Stock Price Prediction. *Journal of Applied Mathematics*, 2014.
- Adhatrao, K., Gaykar, A., Dhawan, A., Jha, R., & Honrao, V. (2013). Predicting Students Performance Using ID3 and C4.5 Classification Algorithms. *International Journal of Data Mining & Knowledge Management Process*, 3(5), 39-52.
- Aghaie, A., & Saeedi, A. (2009, April). Using Bayesian Networks for Bankruptcy Prediction: Empirical Evidence From Iranian Companies. In *Information Management and Engineering, 2009. ICIME'09. International Conference on*, 450-455. IEEE.
- Ađır, H. (2003). *İMKB'nin Ekonomik Büyüme Katkısının Ekonometrik Analizi*. (Yayınlanmamış YL Tezi). KTÜ, Kahramanmaraş.
- Aizerman, M. A., Braverman, E. M., & Rozonoer, L. I. (1964). Theoretical Foundations of Potential Function Method in Pattern Recognition. *Automation and Remote Control*, 25(6), 917-936.
- Akçalı, N. (2002). *Sermaye Piyasasının Avrupa Birliđi Sermaye Piyasaları ile Uyumlaştırılması*. (Yayınlanmamış YL Tezi). Niğde Üniversitesi, Niğde.
- Akdađ, Y. (2010). *Vadeli İşlem ve Opsiyon Borsası'nda TL-Dolar Vadeli İşlem Sözleşmelerinin Gün Sonu Uzlaşma Fiyatının Yapay Sinir Ağları ile Tahmini*. (Yayınlanmamış YL Tezi). Marmara Üniversitesi, İstanbul.
- Akgöbek, Ö. ve Çakır, F. (2009), "Veri Madenciliğinde Bir Uzman Sistem Tasarımı," Akademik Bilişim Konferansı, 11 - 13 Şubat 2009, Harran Üniversitesi, Şanlıurfa, <http://ab.org.tr/ab09/bildiri/115.doc>, [Erişim Tarihi: 25.06.2018].
- Çolak, Ö. F., ve Öçal, T. (1999). *Finansal Sistem ve Bankalar*. Ankara: Nobel Yayınları.
- Akgüç, Ö. (1998). *Finansal Yönetim (7 b.)*. İstanbul: Avcıol Basım Yayın.

- Akgül, A., ve Çevik, O. (2005). *SPSS'te İşletme Yönetimi Uygulamaları*. Ankara: Mustafa Kitabevi.
- Aksoy, A. ve Tanrıöven, C. (2007). *Sermaye Piyasası Yatırım Araçları ve Analizi*. Ankara: Gazi Kitabevi.
- Akyatan, A. (2016). Bist 100 Endeksine Kote Olan Hisse Senetlerinin Getiri Başarılarının Tahmini Üzerine Bir Çalışma. *İstanbul Üniversitesi İşletme Fakültesi Dergisi*, 45(2), 120-130.
- Albayrak, A. S. (2006). *Uygulamalı Çok Değişkenli İstatistik Teknikleri*. Ankara: Asil Yayın Dağıtım.
- Albeni, M., ve Demir, Y. (2011). Makro Ekonomik Göstergelerin Mali Sektör Hisse Senedi Fiyatlarına Etkisi (İMKB Uygulamalı). *Sosyal ve Beşeri Bilimler Araştırmaları Dergisi*, 1(14), 1-18.
- Aldin, M. M., Dehnavi, H. D., & Entezari, S. (2012). Evaluating the Employment of Technical Indicators in Predicting Stock Price Index Variations Using Artificial Neural Networks (case study: Tehran Stock Exchange). *International Journal of Business and Management*, 7(15), 25-34.
- Ali, A., Wang, Y., Li, W., & He, X. (2015, December). Implementation of Simple Moving Voltage Average Technique With Direct Control Incremental Conductance Method to Optimize the Efficiency of DC Microgrid. In *Emerging Technologies (ICET), 2015 International Conference on*, 1-5. IEEE.
- Alkhatib, K., Najadat, H., Hmeidi, I., & Shatnawi, M. K. A. (2013). Stock Price Prediction Using K-Nearest Neighbor (kNN) Algorithm. *International Journal of Business, Humanities and Technology*, 3(3), 32-44.
- Altuntaş, E. ve Çelik, T. (1998). *Yapay Zeka'nın Tarihçesi*. İstanbul: Otak Yayıncılık.
- Alpar, R. (2003). *Uygulamalı Çok Değişkenli İstatistiksel Yöntemlere Giriş 1*. Ankara: Nobel Yayın Dağıtım.
- Alpaydın, E. (2011). *Yapay Öğrenme*. İstanbul: Boğaziçi Üniversitesi Yayınevi.

- Alpaydin, E. (2014). *Introduction to Machine Learning*. Massachusetts: MIT press.
- Anbalagan, T. & Maheswari, S. U. (2015). Classification and Prediction of Stock Market Index Based on Fuzzy Metagraph. *Procedia Computer Science*, 47, 214-221.
- Anish, C. M. & Majhi, B. (2016). Hybrid Nonlinear Adaptive Scheme for Stock Market Prediction Using Feedback FLANN and Factor Analysis. *Journal of the Korean Statistical Society*, 45(1), 64-76.
- Ankerst, M., Elsen, C., Ester, M. & Kriegel, H.P. (1999). Visual Classification: An Interactive Approach to Decision Tree Construction. Proceedings of the 5th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, Aug. 15- 18, ACM Press, New York, USA., 392-396.
- Anonim, (2006). *Analiz Yöntemleri, Sermaye Piyasası Faaliyetleri İleri Düzey Lisansı Eğitimi Notları*, Türkiye Sermaye Piyasası Aracı Kurumları Birliği (TSPAKB).
- Anonim (2009). *Analiz Yöntemleri Sermaye Piyasası Faaliyetleri İleri Düzey Lisans Eğitimi Faaliyetleri*, Türkiye Sermaye Piyasası Aracı Kurumları Birliği (TSPAKB).
- Appel, G. (2003). Become Your Own Technical Analyst: How to Identify Significant Market Turning Points Using the Moving Average Convergence-Divergence Indicator or MACD. *The Journal of Wealth Management*, 6(1), 27-36.
- Arlot, S. & Celisse, A. (2010). A Survey of Cross-Validation Procedures for Model Selection. *Statistics Surveys*, 4, 40-79.
- Arroyo, J. & Maté, C. (2009). Forecasting Histogram Time Series with k-Nearest Neighbours Methods. *International Journal of Forecasting*, 25(1), 192-207.
- Aspinall, P., Mavros, P., Coyne, R. & Roe, J. (2015). The Urban Brain: Analysing Outdoor Physical Activity With Mobile EEG. *Br J Sports Med*, 49(4), 272-276.

- Atan, M., ve Çatalbaş, E. (2004). Çok Değişkenli İstatistiksel Analiz Yöntemleri ile Türk Bankacılık Sektöründe Çok Boyutlu Mali Başarısızlık Tahmin Modelleri Oluşturulması. *4. İstatistik Günleri Sempozyumu*, 19-22.
- Atsalakis, G.S. & Valavanis, K.P. (2009). Forecasting Stock Market Short-Term Trends Using a Neuro-Fuzzy Based Methodology. *Expert Systems with Applications*, 36 (7), 10696-10707.
- Avcı, E. (2009). Stock Return Forecasts with Artificial Neural Network Models. *İktisadi ve İdari Bilimler Dergisi*, 26(1), 443-461.
- Aydın, N. (2001). *Genel İşletme*. Eskişehir: Anadolu Üniversitesi Açık Öğretim Yayını.
- Aydoğan, E. K., Gencer, C. ve Akbulut, S. (2008). Veri Madenciliği Teknikleri ile bir Kozmetik Markanın Ayrılan Müşteri Analizi ve Müşteri Bölümlenmesi. *Sigma Mühendislik ve Fen Bilimleri Dergisi*, 26(1), 43-57.
- Bakar, S. & Hamid, M. Z. (2012). Validating a Bankruptcy Prediction by Using Naïve Bayesian Network Model: A Case From Malaysian Firms. *International Conference on Business Economics, Business Innovation*, vol. 38, 165-169.
- Ballings, M., Van den Poel, D., Hespeels, N. & Gryp, R. (2015). Evaluating Multiple Classifiers for Stock Price Direction Prediction. *Expert Systems with Applications*, 42(20), 7046-7056.
- Barber, D. (2012). *Bayesian Reasoning and Machine Learning*. London: Cambridge University Press.
- Başar, A. ve Oktay, E. (2007). *Uygulamalı İstatistik 2*. Ankara: Aktif Yayınevi.
- Başoğlu, U., Ceylan, A. ve Parasız, İ. (2009). *Finans: Teori, Kurum, Uygulama*. Bursa: Ekin Basım Yayın Dağıtım.
- Berglas, A. (2015). *When Computers Can Think: The Artificial Intelligence Singularity*. Seattle: Createspace Independent Publishing Platform.
- Berk, N. (2007). *Finansal Yönetim*. İstanbul: Türkmen Kitapevi.

- Berkhin, P. (2006). *A Survey of Clustering Data Mining Techniques. In Grouping Multidimensional Data (25-71)*. Berlin: Springer.
- BİST, (2018a). Hisse Senedinin Ekonomik İşlevleri http://www.borsaistanbul.com/data/kilavuzlar/Cevaplarla_Borsa_ve_Sermaye_Piyasasi.pdf [15 Şubat 2018 tarihinde erişilmiştir].
- BİST, (2018b). Pay Endeksleri ve Hesaplanan Endeksler <http://www.borsaistanbul.com/docs/default-source/endeksler/bist-pay-endeksleri-temel-kurallari-haziran-2018.pdf?sfvrsn=4> [15 Şubat 2018 tarihinde erişilmiştir].
- BİST, (2018c). Borsa İstanbul'un başlıca amacı ve faaliyet konusu <http://www.borsaistanbul.com/kurumsal/borsa-istanbul-hakkinda/hakkimizda> [15 Şubat 2018 tarihinde erişilmiştir].
- Blay, Withby; *Yapay Zeka Yeni Başlayanlar için Kılavuz*, Çev: Çiğdem K. 1. Baskı, İletişim Yayınları, İstanbul 2005, s.17-19.
- Blockeel, H. & Struyf, J. (2002). Efficient Algorithms for Decision Tree Cross-validation. *Journal of Machine Learning Research*, 3(Dec), 621-650.
- Bishop, C. M. (2007). *Pattern Recognition and Machine Learning*. London: Springer.
- Blum, A. (2007). Machine Learning Theory. *Carnegie Melon Universit, School of Computer Science*, 26.
- Blum, A., Hopcroft, J. & Kannan, R. (2016). *Foundations of Data Science*. Vorabversion Eines Lehrbuchs.
- Boser, B. E., Guyon, I. M. & Vapnik, V. N. (1992, July). A Training Algorithm for Optimal Margin Classifiers. In *Proceedings of the fifth Annual Workshop on Computational Learning Theory*, 144-152.
- Bramer, M. (2016). *Principles of Data Mining*. London: Springer.
- Brealey, R.A., Myers, S.C. & Marcus, A.J. (2012). *Fundamentals of Corporate Finance*. New York: McGrawHill.

- Bugnion, P., Nicolas, P. R. & Kozlov, A. (2017). *Scala: Applied Machine Learning*. Birmingham: Packt Publishing.
- Büker, S., Aşıkođlu, R. ve Sevil, G. (2010). *Finansal Yönetim*. Ankara: Sözkeseu Matbaacılık.
- Breiman, F. (1984). *Classification and Regression Trees*.
- Breiman, L., Friedman, J. H., Olshen, R. A., & Stone, C.J. (1984). *Classification and Regression Trees*.
- Brink, H., Richards, J. W., & Fetherolf, M. (2017). *Real-world Machine Learning*. Manning.
- Brownlee, J., 2013, *A Tour of Machine Learning Algorithms*, <http://machinelearning-mastery.com/a-tour-of-machine-learning-algorithms/>, [18 Mayıs 2017 tarihinde erişilmiştir].
- Budak, A. ve Emre, Z. (2006). *Borsa Şirketleşmeleri ve İMKB Özelleşmesi*. İstanbul: TSPAKB.
- Bülbül, H. ve Demirer, Ö. (2008). Hizmet Kalitesi Ölçüm Modelleri SERVQUAL ve SERVPERF'in Karşılaştırmalı Analizi. *Selçuk Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 20, 181-198.
- Büyükaşvarcı, A. (2011). Finansal Analizde Kullanılan Oranlar ve Hisse Senedi Getirileri Arasındaki İlişki: Ekonomik Kriz Dönemleri İçin İmkb İmalat Sanayi Şirketleri Üzerine Ampirik Bir Uygulama. *Atatürk Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 25(1), 225-240.
- Camastra, F., Vinciarelli, A (2015). *Machine Learning for Audio, Image and Video Analysis: Theory and Applications*. London: Springer.
- Cao, Q., Parry, M. E. & Leggio, K. B. (2011). The Three-Factor Model and Artificial Neural Networks: Predicting Stock Price Movement in China. *Annals of Operations Research*, 185(1), 25-44.
- Chahardoli, M., Yaghubi, M. & Esmailpour, M. (2015). Stock Price Prediction of Listed Stocks in Tehran Stock Exchange Using Intelligence and Learning

- Methods: K-Nearest Neighbors and Rough Sets. *Journal of Current Research in Science*, 3(2), 123-137.
- Chapelle, O., Scholkopf, B. & Zien, A. (2010). *Semi-Supervised Learning*. Massachusetts: MIT Press.
- Chatterjee, M., Das, S. K. & Turgut, D. (2002). WCA: A Weighted Clustering Algorithm for Mobile Ad Hoc Networks. *Cluster Computing*, 5(2), 193-204.
- Chen, H. (2015). *Development of a Novel Double Neural Network And its Applications*. (Doctoral Dissertation). Stony Brook University: Stony Brook, NY.
- Chen, S., Li, X., Yong, J., & Zhou, X. Y. (Eds.). (2013). *Control of Distributed Parameter and Stochastic Systems: Proceedings of the IFIP WG 7.2 International Conference, June 19–22, 1998 Hangzhou, China* (Vol. 13). Springer.
- Chen, Y. S., Cheng, C. H., & Tsai, W. L. (2014). Modeling Fitting-Function-Based Fuzzy Time Series Patterns for Evolving Stock Index Forecasting. *Applied Intelligence*, 41(2), 327-347.
- Cherkassky, V. & Mulier, F. M. (2007). *Learning from Data: Concepts, Theory, and Methods*. New Jersey: John Wiley & Sons.
- Chiang, W. C., Enke, D., Wu, T. & Wang, R. (2016). An Adaptive Stock Index Trading Decision Support System. *Expert Systems with Applications*, 59, 195-207.
- Cho, V. (2003). A Comparison of Three Different Approaches to Tourist Arrival Forecasting. *Tourism Management*, 24: 323-330.
- Chong, T. T. L. & Ng, W. K. (2008). Technical Analysis and the London Stock Exchange: Testing the MACD and RSI Rules Using the FT30. *Applied Economics Letters*, 15(14), 1111-1114.
- Cios, K. J., Pedrycz, W., Swiniarski, R. W. & Kurgan, L. A. (2007). *Data Mining: a Knowledge Discovery Approach*. London: Springer.

- Clarke, B., Fokoue, E. & Zhang, H. H. (2009). *Principles and Theory for Data Mining and Machine Learning*. London: Springer.
- Cortes, C. & Vapnik, V. (1995). Support-Vector Networks. *Machine Learning*, 20(3), 273-297.
- Cover, T. & Hart, P. (1967). Nearest Neighbor Pattern Classification. *IEEE Transactions on Information Theory*, 13(1), 21-27.
- Cristianini, N. & Shawe-Taylor, J. (2000). *An Introduction to Support Vector Machines and Other Kernel-Based Learning Methods*. London: Cambridge University Press.
- Çakır, M. (2005). *Firma Başarısızlığının Dinamiklerinin Belirlenmesinde Makina Öğrenmesi Teknikleri: Ampirik Uygulamalar ve Karşılaştırmalı Analiz*. (Uzmanlık Yeterlilik Tezi). Türkiye Cumhuriyet Merkez Bankası İstatistik Genel Müdürlüğü, Ankara.
- Çalışkan, M. M. T., ve Deniz, D. (2016). Yapay Sinir Ağlarıyla Hisse Senedi Fiyatları ve Yönlerinin Tahmini. *Dokuz Eylül Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 31, 177-194.
- Çetinyokuş, T. ve Gökçen, H. (2002). Borsada Göstergelerle Teknik Analiz İçin Bir Karar Destek Sistemi. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 17 (1), 43-58.
- Dağ, F. (2006), “Yapay Zeka: Temel Kavramlar”, Ören, T. (Ed.), Türkiye Bilişim Ansiklopedisi (931-939), İstanbul: Papatya Yayıncılık.
- Dash, R. & Dash, P. (2016a). Efficient Stock Price Prediction Using a Self Evolving Recurrent Neuro-Fuzzy Inference System Optimized Through a Modified Differential Harmony Search Technique. *Expert Systems with Applications*, 52, 75-90.
- Dash, R. & Dash, P. K. (2016b). A Hybrid Stock Trading Framework Integrating Technical Analysis with Machine Learning Techniques. *The Journal of Finance and Data Science*, 2(1), 42-57.

- Dash, R., Samal, S., Rautray, R. & Dash, R. (2019). A TOPSIS Approach of Ranking Classifiers for Stock Index Price Movement Prediction. In *Soft Computing in Data Analytics*, 665-674. Springer, Singapore.
- Dastgir, M. & Enghiad, M. H. (2012). Short-Term Prediction of Tehran Stock Exchange Price Index (TEPIX): Using Artificial Neural Network (ANN). *Quarterly Journal of Securities Exchange*, 4(14), 237-261.
- Delice, G. (2000). *Uluslararası Finansal Entegrasyon ve Gelişmekte Olan Ülkeler (Türkiye Üzerine Bir Uygulama)*. (Yayınlanmamış Doktora Tezi). Cumhuriyet Üniversitesi Sosyal Bilimler Enstitüsü, Sivas.
- Dietterich, T. G. (2003). "Machine Learning", Nature Encyclopedia of Cognitive Science. London: Macmillan.
- Diler, A. I. (2003). Forecasting the Direction of the ISE National-100 Index By Neural Networks Backpropagation Algorithm. *Istanbul Stock Exchange Review*, 7(25-26), 65-82.
- Dinç, A. (2006). *Sermaye Piyasası Analizleri: Teknik Analiz*, Yıldız Teknik Üniversitesi, Sosyal Bilimler Enstitüsü, İşletme Yönetimi Yüksek Lisans Programı, http://www.akademiktisat.net/makaleler/sermaye_piyasasi_teknik_analiz_abdulkadir_dinc.htm [13 Mayıs 2018 tarihinde erişilmiştir].
- Ding, T., Fang, V. & Zuo, D. (2013). Stock Market Prediction Based on Time Series Data and Market Sentiment. URL http://murphy.wot.eecs.northwestern.edu/~pzu918/EECS349/final_dZuo_tDing_vFang.pdf.
- Doğan, V. (2006). *Forecasting Stock Marker Return Using Artificial Neural Networks*. (Yayınlanmamış Yüksek Lisans Tezi). Boğaziçi Üniversitesi Fen Bilimleri Enstitüsü, İstanbul.
- Domingos, P. (2012). A Few Useful Things to Know About Machine Learning. *Communications of the ACM*, 55(10), 78-87.
- Draper, N. R. & Smith, H. (2014). *Applied Regression Analysis*. New Jersey: John Wiley & Sons.

- Duda, R. O., Hart, P. E. & Stork, D. G. (2000). *Pattern Classification*. New Jersey: Wiley-Blackwell.
- Dunham, M.H. (2003) *Data Mining: Introductory and Advanced Topics*. Singapore: Pearson Education Inc.
- Dunis, C. L., Rosillo, R., de la Fuente, D. & Pino, R. (2013). Forecasting IBEX-35 Moves Using Support Vector Machines. *Neural Computing and Applications*, 23(1), 229-236.
- Ecer, F. (2013a). Türkiye’de 2. El Otomobil Fiyatlarının Tahmini ve Fiyat Belirleyicilerinin Tespiti. *Anadolu Üniversitesi Sosyal Bilimler Dergisi*, 13(4), 101-112.
- Ecer, F. (2013b). Artificial Neural Networks in Predicting Financial Performance: An Application for Turkey's Top 500 Companies. *Economic Computation and Economic Cybernetics Studies and Research*, 47(2), 103-114.
- Ecer, F. (2013c). Comparing the Bank Failure Prediction Performance of Neural Networks and Support Vector Machines: The Turkish Case. *Economic Research-Ekonomika Istraživanja*, 26(3), 81-98.
- Edwards, R. D., Magee, J. & Bassetti, W. C. (2007). *Technical Analysis Of Stock Trends*. Florida: CRC press.
- Ege, İ. ve Bayrakdaroğlu, A. (2009). İMKB Şirketlerinin Hisse Senedi Getiri Başarılarının Lojistik Regresyon Tekniği ile Analizi. *ZKÜ Sosyal Bilimler Dergisi*, 5(10), 139-158.
- Elmas, B. (2011). Yabancı Portföy Yatırımlarının İMKB’ye Etkisi: İMKB’de Endeks Bazlı Bir Çalışma. *İMKB Dergisi*, 12(47), 1-18.
- Emir, Ş. (2013). Yapay Sinir Ağları ve Destek Vektör Makineleri Yöntemlerinin Sınıflandırma Performanslarının Karşılaştırılması: Borsa Endeks Yönünün Tahmini Üzerine Bir Uygulama. (Yayınlanmamış Doktora Tezi). İstanbul Üniversitesi, İstanbul.

- Emir, Ş. (2016). Predicting the Istanbul Stock Exchange Index Return Using Technical Indicators: A Comparative Study. *International Journal of Finance & Banking Studies*, 2(3), 111-117.
- Engelbrecht, A. P. (2007). *Computational Intelligence: An Introduction*. New Jersey: Wiley.
- Enke, D. & Thawornwong, S. (2005). The Use of Data Mining and Neural Networks for Forecasting Stock Market Returns. *Expert Systems with Applications*, 29(4), 927-940.
- Ergezen, B. (2006). *Gelişmekte Olan Ülkelerde Finansal Piyasalar ve Türkiye Örneği*. (Yayınlanmamış Yüksek Lisans Tezi). Marmara Üniversitesi Sosyal Bilimler Enstitüsü, İstanbul.
- Erpolat, S. ve Öz, E. (2010). Kanser Verilerinin Sınıflandırılmasında Yapay Sinir Ağları ile Destek Vektör Makineleri'nin Karşılaştırılması. *İstanbul Aydın Üniversitesi Fen Bilimleri Dergisi*, 2(5), 71-83.
- Ertel, W. (2011). *Introduction to Artificial Intelligence*. London: Springer.
- Eisuke, K. I. T. A., Harada, M. & Mizuno, T. (2012). Application of Bayesian Network to Stock Price Prediction. *Artificial Intelligence Research*, 1(2), 171-184.
- Fama, E. (1969). Efficient Capital Markets: A Review of Theory and Empirical Work. *The Journal of Finance*, 25 (2), 383-417.
- Fawcett, T. (2006). An Introduction to ROC Analysis, *Pattern Recognition Letters*, 27 (8), 861–874.
- Fayyad, U., Piatetsky-Shapiro, G. & Smyth, P. (1996). From Data Mining to Knowledge Discovery in Databases. *AI magazine*, 17(3), 37-54.
- Fernández-Blanco, P., Bodas-Sagi, D. J., Soltero, F. J. & Hidalgo, J. I. (2008, July). Technical Market Indicators Optimization Using Evolutionary Algorithms. In *Proceedings of the 10th Annual Conference Companion on Genetic and Evolutionary Computation*, 1851-1858, ACM.

- Flach, P. (2012). *Machine Learning: The Art and Science of Algorithms That Make Sense of Data*. London: Cambridge University Press.
- Fletcher, T. & Shawe-Taylor, J. (2013). Multiple Kernel Learning with Fisher Kernels for High Frequency Currency Prediction. *Computational Economics*, 42(2), 217-240.
- Filiz, E., Karaboğa, H. A. ve Akoğul, S. (2017). Bist-50 Endeksi Değişim Değerlerinin Sınıflandırılmasında Makine Öğrenmesi Yöntemleri ve Yapay Sinir Ağları Kullanımı. *Çukurova Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 26(1), 231-241.
- Fisher R. A. (1936). The Use of Multiple Measurements in Taxonomic Problems. *Annals of Eugenics*, 7, 179-188.
- Fix, E. & Hodges Jr, J. L. (1951). *Discriminatory Analysis-Nonparametric Discrimination: Consistency Properties*. Berkeley: California Univ.
- Fornell, C. & Larcker, D.F. (1981). Evaluating Structural Equation Models with Unobservable Variables and Measurement Error. *Journal of Marketing Research*, 18(1), 39-50.
- Forster, M. R. (2000). Key Concepts in Model Selection: Performance and Generalizability. *Journal of Mathematical Psychology*, 44(1), 205-231.
- Friedman, N., Geiger, D. & Goldszmidt, M. (1997). Bayesian Network Classifiers. *Machine Learning*, 29(2-3), 131-163.
- Friedman, J. H., Olshen, R. A. & Stone, C. J. (1984). *Classification and Regression Trees*. Belmont, CA: Wadsworth & Brooks.
- Fukunaga, K. & Hummels, D. M. (1987). Bayes Error Estimation Using Parzen and k-NN Procedures. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, (5), 634-643.
- Genton, M. G. (2001). Classes of Kernels for Machine Learning: A Statistics Perspective. *Journal of Machine Learning Research*, 2(Dec), 299-312.

- Göçken, M., Özçalıcı, M., Boru, A. & Dosdoğru, A. T. (2016). Integrating Metaheuristics and Artificial Neural Networks for Improved Stock Price Prediction. *Expert Systems with Applications*, 44, 320-331.
- Göksungur, A. E. (2008). *Stok Kontrolünde Yapay Zeka Kavramı ve Bir Uygulama*. (Yayınlanmamış Doktora Tezi). Marmara Üniversitesi, İstanbul.
- Gönenli, A. (1988). *Finansal Yönetim*. İstanbul: İstanbul Üniversitesi Yayınları.
- Gujarati, D. N., Porter, D. C., Şenesen, Ü. ve Günlük-Şenesen, G. (2012). *Temel Ekonometri*. İstanbul: Literatür Yayıncılık.
- Gurjar, M., Naik, P., Mujumdar, G. & Vaidya, T. (2018). Stock Market Prediction Using Ann. *International Research Journal of Engineering and Technology*, 5(3), 2758-2761.
- Gündüz, H., Yaslan, Y. & Cataltepe, Z. (2017). Intraday Prediction of Borsa Istanbul Using Convolutional Neural Networks and Feature Correlations. *Knowledge-Based Systems*, 137, 138-148.
- Güresen, E., Kayakutlu, G. & Daim, T. U. (2011). Using Artificial Neural Network Models in Stock Market Index Prediction. *Expert Systems with Applications*, 38(8), 10389-10397.
- Güzel, F., Acar, M. ve Avcı, D. (2016). Bulanık Sinir Ağı Yapısı İle Borsa Endeks Getirisi Tahmini: Borsa İstanbul (Bist) 100 Örneği. *Akademik Sosyal Araştırmalar Dergisi*, 4(29), 452-465.
- Hair, J.F., Andreson, R.E., Tahtam, R.L. & Black, W.C. (1998). *Multivariate Data Analysis*. New Jersey: Prentice Hall Inc.
- Hal Daumé III (2012). *A Course in Machine Learning*, http://ciml.info/dl/v0_8/ciml-v0_8-ch08.pdf, [12 Şubat 2017 tarihinde erişilmiştir].
- Hamel, L. H. (2009). *Knowledge Discovery with Support Vector Machines*. New Jersey: Wiley-Interscience.
- Hamzaçebi, C., ve Kutay, F. (2004). Yapay Sinir Ağları ile Türkiye Elektrik Enerjisi Tüketiminin 2010 Yılına Kadar Tahmini. *Gazi Üniversitesi Mühendislik-Mimarlık Fakültesi Dergisi*, 19(3).

- Han, J., Pei, J. & Kamber, M. (2011). *Data Mining: Concepts and Techniques*. Amsterdam: Elsevier.
- Harrington, P. (2012). *Machine Learning in Action*. Greenwich, CT: Manning.
- Harmon, M. E. & Harmon, S. S. (1997). *Reinforcement Learning: A Tutorial*. Wright Lab Wright-Patterson Afb Oh.
- Haykin, S. (1994). *Neural Networks*. Stuttgart: Macmillan College Publishing Company Inc.
- Hebb, D. O. (1949). *The Organization of Behavior: A Neuropsychological Theory*. New York: Wiley.
- Herrero, J., Valencia, A. & Dopazo, J. (2001). A Hierarchical Unsupervised Growing Neural Network for Clustering Gene Expression Patterns. *Bioinformatics*, 17, 126-136.
- Hopfield, J. J. (1982). Neural Networks and Physical Systems With Emergent Collective Computational Abilities. *Proc. Natl. Acad. Sci. U.S.A.*, 79, 2554–2558.
- Hosmer, D. W. & Lemeshow, S. (2000). *Applied Logistic Regression*. New York: Wiley.
- Hsieh, W. W. (2009). *Machine Learning Methods in the Environmental Sciences: Neural Networks and Kernels*. New York: Cambridge University Press.
- 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), 14026-14036.
- Huang, W., Nakamori, Y. & Wang, S. Y. (2005). Forecasting Stock Market Movement Direction with Support Vector Machine. *Computers & Operations Research*, 32(10), 2513-2522.
- Hyndman, R. J. & Koehler, A. B. (2006). Another Look at Measures of Forecast Accuracy. *International Journal of Forecasting*, 22(4), 679-688.

- Inghelbrecht, K., Heyman, D., Pauwels, S. & Marius, P. (2012). Technical Trading Rules in Emerging Stock Markets. *World Academy of Science, Engineering and Technology*, 59, 2241-2264.
- Ioannidis, C., Pasiouras, F. & Zopounidis, C. (2010). Assessing Bank Soundness with Classification Techniques. *Omega*, 38(5), 345-357.
- İlarıslan, K. (2016). k-En Yakın Komııu (k-NN) Algoritması ile Hisse Senedi Fiyatlarının Tahmin Edilmesi: BİST'den Örnek Bir Uygulama. *Asos Journal*, 4(30), 375-392.
- Jabbarzadeh, A., Shavvalpour, S., Khanjarpanah, H. & Dourvash, D. (2016). A Multiple-Criteria Approach for Forecasting Stock Price Direction: Nonlinear Probability Models with Application in S&P 500 Index. *International Journal of Applied Engineering Research*, 11(6), 3870-3878.
- Kaastra, I. & Boyd, M. (1996). Designing a Neural Network for Forecasting Financial and Economic Time Series. *Neurocomputing*, 10(3), 215-236.
- Kalaycı, Ő. (2010). *SPSS Uygulamalı Çok Deęiřkenli İstatistik Teknikleri*. Ankara: Asil Yayın Daęıtım.
- Kamruzzaman, J. (2006). *Artificial Neural Networks in Finance and Manufacturing*. Hershey: IGI Global.
- Kantardzic, M. (2011). *Data Mining: Concepts, Models, Methods, and Algorithms*. New Jersey: Wiley-Blackwell.
- Kar, Muhsin. (2008). "Finansal Sistem ve Kalkınma". S. Taban (Ed.), *Kalkınma Ekonomisi: Seçme Konular* (185-226), Bursa: Ekim Basım Yayın Daęıtım.
- Kara, Y., Boyacıođlu, M. A. & 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), 5311-5319.
- Karagöl, K. (2014). İstanbul Menkul Kıymetler Borsası'nda İşlem Gören Firmaların Destek Vektör Makineleri Kullanılarak Sınıflandırılması. *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, 20(5), 174-178.

- Kargı, N. (1998). *Ekonomik Kalkınma, Tasarruf ve Sermaye Piyasası İlişkileri: Türkiye Örneği*. Ankara: Sermaye Piyasası Kurulu.
- Karlı, M. (1994). *Sermaye Piyasası Borsa Menkul Kıymetler*. İstanbul: İrfan Yayıncılık.
- Karlı, M. (2004). *Sermaye Piyasası Borsa Menkul Kıymetler*. İstanbul: Alfa Basım Yayın Dağıtım.
- Kavaklıdere, U. A. (2002). *1995-2000 Döneminde İMKB'de İşlem Gören Hisse Senetlerinin Piyasa Değeri (Firma Büyüklüğü) ve Fiyat/Kazanç Oranına Göre Oluşturulan Portföylerinin Performanslarının İncelenmesi*. (Yayınlanmamış Y.L. Tezi). Celal Bayar Üniversitesi Sosyal Bilimler Enstitüsü, Manisa.
- Kartal, E. (2015). *Sınıflandırmaya Dayalı Makine Öğrenmesi Teknikleri ve Kardiyolojik Risk Değerlendirmesine İlişkin Bir Uygulama*. (Yayınlanmamış Doktora tezi). İstanbul Üniversitesi, İstanbul.
- Karymshakov, K. & Abdykaparov, Y. (2012). Forecasting Stock Index Movement with Artificial Neural Networks: The Case of Istanbul Stock Exchange. *Trakya University Journal of Social Science*, 14(2), 231-241.
- Kaya, V., Çömlekçi, İ. ve Kara, O. (2013). Hisse Senedi Getirilerini Etkileyen Makroekonomik Değişkenler 2002–2012 Türkiye Örneği. *Dumlupınar Üniversitesi Sosyal Bilimler Dergisi*, (35), 167-176.
- Kılıç, E., Özbacı, U. ve Özçalık, H. R. (2012). Lineer Olmayan Dinamik Sistemlerin Yapay Sinir Ağları ile Modellenmesinde MLP ve RBF Yapılarının Karşılaştırılması. *ELECO2012 Elektrik-Elektronik ve Bilgisayar Mühendisliği Sempozyumu*, (29.11. 2012-01.12. 2012).
- Kılıç, S. B., Paksoy, S. & Genç, T. (2015). Forecasting the Direction of BIST 100 Returns with Artificial Neural Network Models. *International Journal of Latest Trends in Finance and Economic Sciences*, 4(3), 759-765.
- Kim, K. J. (2003). Financial Time Series Forecasting Using Support Vector Machines. *Neurocomputing*, 55(1-2), 307-319.

- Kimeldorf, G. & Wahba, G. (1971). Some Results on Tchebycheffian Spline Functions. *Journal of Mathematical Analysis and Applications*, 33(1), 82-95.
- Kimoto, T., Asakawa, K., Yoda, M. & Takeoka, M. (1990, June). Stock Market Prediction System with Modular Neural Networks. In *Neural Networks, 1990., 1990 IJCNN International Joint Conference on*, 1-6. IEEE.
- Kirkpatrick II, C. D. & Dahlquist, J. A. (2010). *Technical Analysis: The Complete Resource for Financial Market Technicians*. New Jersey: FT press.
- Klassen, M. (2005, April). Investigation of Some Technical Indexes in Stock Forecasting Using Neural Networks. In *WEC (5)*, 75-79.
- Kohavi, R. (1995, August). A Study of Cross-Validation and Bootstrap for Accuracy Estimation and Model Selection. In *Ijcai*, 14(2), 1137-1145.
- Kohonen T., (1988). *Self-Organization and Associative Memory*. Berlin: Springer.
- Konuralp, G., (2005). *Sermaye Piyasaları: Analizler, Kuramlar ve Portföy Yönetimi*. İstanbul: Alfa Yayınları.
- Korkmaz, T. ve Ceylan, A. (2007). *Sermaye Piyasası ve Menkul Değer Analizi*, Bursa: Ekin Kitabevi.
- Kotsiantis, S. B. (2007). Supervised Machine Learning: A Review of Classification Techniques. *Informatica*, 31 (3), 249–268.
- Köse, S. K. (2008). Korelasyon ve Regresyon Analizi. <http://tr.scribd.com/doc/2066772/korelasyon-analizi>, 9.
- Kriesel, D. (2007). A Brief Introduction to Neural Networks. 2007. URL <http://www.dkriesel.com>[16 Temmuz 2018 tarihinde erişilmiştir].
- Kristoufek, L. (2014). Detrending Moving-Average Cross-Correlation Coefficient: Measuring Cross-Correlations Between Non-Stationary Series. *Physica A: Statistical Mechanics and its Applications*, 406, 169-175.
- Laboissiere, L. A., Fernandes, R. A. & Lage, G. G. (2015). Maximum and Minimum Stock Price Forecasting of Brazilian Power Distribution Companies Based on Artificial Neural Networks. *Applied Soft Computing*, 35, 66-74.

- Lahmiri, S. (2011). A Comparison of PNN and SVM for Stock Market Trend Prediction Using Economic and Technical Information. *International Journal of Computer Applications*, 29 (3), 24–30.
- Lahmiri, S. , Boukadoum, M. & Chartier, S. (2013). Information Fusion and S&P500 Trend Prediction. In *Proceedings of The 2013 ACS International Conference on Computer Systems and Applications (AICCSA)*, 1–7. Ifrane, Morocco.
- Lambert, D. R. (1983). Commodity Channel Index: Tool for Trading Cyclic Trends. *Technical Analysis of Stocks & Commodities*, 1, 47-51.
- Lane, G. C. (1985). Lane's Stochastics: The Ultimate Oscillator. *Journal of Technical Analysis*, 21, 37-42.
- Langley, P. & John, G. H. (1995, August). Estimating Continuous Distributions in Bayesian Classifiers. In *Proceedings of the Eleventh Conference on Uncertainty in Artificial Intelligence*, 338-345. Morgan Kaufmann Publishers Inc.
- Langley, P. & Sage, S. (1994). Induction of Selective Bayesian Classifiers. In *Uncertainty Proceedings 1994*, 399-406.
- Lani, J. (1995). What is Logistic Regression?
- Larose, D. (2005). *Discovering Knowledge in Data: An Introduction to Data Mining*. New Jersey: Wiley-Interscience.
- Lavanya, D. & Rani, K. U. (2011). Performance Evaluation of Decision Tree Classifiers on Medical Datasets. *International Journal of Computer Applications*, 26(4), 975-979.
- Lazar, N. (2010). Ockham's Razor. *Wiley Interdisciplinary Reviews: Computational Statistics*, 2(2), 243–246.
- Le Cessie, S. & Van Houwelingen, J. C. (1992). Ridge Estimators in Logistic Regression. *Applied Statistics*, 41(1),191-201.
- LeCun, Y., Boser, B. E., Denker, J. S., Henderson, D., Howard, R. E., Hubbard, W. E. & Jackel, L. D. (1990). Handwritten Digit Recognition With a Back-

- Propagation Network. In *Advances in Neural Information Processing Systems*, 396-404.
- Lee, J. M., Yoo, C., Choi, S. W., Vanrolleghem, P. A. & Lee, I. B. (2004). Nonlinear Process Monitoring Using Kernel Principal Component Analysis. *Chemical Engineering Science*, 59(1), 223-234.
- Leung, K. M. (2007). Naive bayesian classifier. *Polytechnic University Department of Computer Science/Finance and Risk Engineering*.
- Lewis, C.D. (1982). *Industrial and Business Forecasting Methods*. London: Butterworths Publishing.
- Li, J., & Lu, B. L. (2009). An Adaptive Image Euclidean Distance. *Pattern Recognition*, 42(3), 349-357.
- Li, X., Xie, H., Wang, R., Cai, Y., Cao, J., Wang, F., & Deng, X. (2016). Empirical Analysis: Stock Market Prediction Via Extreme Learning Machine. *Neural Computing and Applications*, 27(1), 67-78.
- Likas, A., Vlassis, N., & Verbeek, J. J. (2003). The Global k-Means Clustering Algorithm. *Pattern Recognition*, 36(2), 451-461.
- Lin, T.C. & Lee, C.S.G., (1996). *Neural Fuzzy Systems, A Neuro-Fuzzy Synergism to Intelligent Systems*. New Jersey, NY: Prentice Hall.
- Linoff, G., Berry, S. & Michael, J. (2004). *Data Mining Techniques: For Marketing, Sales, and Customer Relationship Management*. New Jersey: John Wiley & Sons.
- Liu, Y., Chen, Y., Wu, S., Peng, G., & Lv, B. (2015). Composite Leading Search Index: A Preprocessing Method of Internet Search Data for Stock Trends Prediction. *Annals of Operations Research*, 234(1), 77-94.
- Loh, W. Y. (2011). Classification and Regression Trees. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 1(1), 14-23.
- Lowry, C. A., Woodall, W. H., Champ, C. W., & Rigdon, S. E. (1992). A Multivariate Exponentially Weighted Moving Average Control Chart. *Technometrics*, 34(1), 46-53.

- Lu, C. J. (2010). Integrating Independent Component Analysis-Based Denoising Scheme with Neural Network for Stock Price Prediction. *Expert Systems with Applications*, 37(10), 7056-7064.
- Lu, L. & Zhu, Z. (2014). Prediction Model for Eating Property of Indica Rice. *Journal of Food Quality*, 37, 274-280.
- Lucas, J. M. & Saccucci, M. S. (1990). Exponentially Weighted Moving Average Control Schemes: Properties And Enhancements. *Technometrics*, 32(1), 1-12.
- MacKay, D. J. C. (2003). *Information Theory, Inference and Learning Algorithms*. London: Cambridge University Press.
- Malagrino, L. S., Roman, N. T. & Monteiro, A. M. (2018). Forecasting Stock Market Index Daily Direction: A Bayesian Network Approach. *Expert Systems with Applications*, 105, 11-22.
- Malhotra, M. K., Sharma, S. & Nair, S. S. (1999). Decision Making Using Multiple Models. *European Journal of Operational Research*, 114(1), 1-14.
- Malkiel, B. G. & Fama, E. F. (1970). Efficient Capital Markets: A Review of Theory and Empirical Work. *The Journal of Finance*, 25(2), 383-417.
- Maloof, M. A. (2005). *Machine Learning and Data Mining for Computer Security: Methods and Applications*. London: Springer.
- Mangasarian, O. L. (1965). Linear and Nonlinear Separation of Patterns by Linear Programming. *Operations Research*, 13(3), 444-452.
- Marple, S. L. & Marple, S. L. (1987). *Digital Spectral Analysis: With Applications*. Englewood Cliffs, NJ: Prentice-Hall.
- Marsland, S. (2011). *Machine Learning: An Algorithmic Perspective*. Florida: Chapman and Hall/CRC.
- McCarthy, J. (2007). *Basic Questions. What is Artificial Intelligence*, [Online], <http://www.formal.stanford.edu/jmc/whatisai/node1.html>. [16 Mayıs 2017 tarihinde erişilmiştir].
- McCulloch, W. S. & Pitts, W. (1943). A Logical Calculus of the Ideas Immanent in Nervous Activity. *The Bulletin of Mathematical Biophysics*, 5(4), 115-133.

- Min, J. H. & Lee, Y. C. (2005). Bankruptcy Prediction Using Support Vector Machine with Optimal Choice of Kernel Function Parameters. *Expert Systems with Applications*, 28(4), 603-614.
- Mishkin, F. S. (2004). *The Economics of Money Banking and Financial Markets*. USA: The Addison-Wesley.
- Mishkin, F. S. & Stanley, G. E. (2012). *Financial Markets and Institutions*. India: Pearson Education.
- Mitchell, T. (1997). *Machine Learning*, ABD: McGraw-Hill.
- Mohri, M., Rostamizadeh, A. & Talwalkar, A. (2012). *Foundations of Machine Learning*. ABD: The MIT Press.
- Moghaddam, A. H., Moghaddam, M. H. & Esfandyari, M. (2016). Stock Market Index Prediction Using Artificial Neural Network. *Journal of Economics, Finance and Administrative Science*, 21(41), 89-93.
- Murphy J. (1986). *Technical Analysis of Futures Markets*. New York: New York Institute of Finance.
- Murphy, K. P. (2012). *Machine Learning: A Probabilistic Perspective*. New York: Adaptive Computation and Machine Learning.
- Mujeed R. O., (2012). *Introduction to Artificial Neural Network and Machine Learning*. (Master of Thesis). Government Engineering College Sreekrishnapuram, Palakkad.
- Nadh, V. L. & Prasad, G. S. (2019). Stock Market Prediction Based on Machine Learning Approaches. In *Computational Intelligence and Big Data Analytics*, 75-79. Springer, Singapore.
- Nair, B. B., Mohandas, V. P. & Sakthivel, N. R. (2010). A Decision Tree-Rough Set Hybrid System for Stock Market Trend Prediction. *International Journal of Computer Applications*, 6(9), 1-6.
- Nakagawa, K., Imamura, M. & Yoshida, K. (2017, November). Stock Price Prediction with Fluctuation Patterns Using Indexing Dynamic Time Warping

- and k-Nearest Neighbors. In *JSAI International Symposium on Artificial Intelligence*, 97-111. Springer, Cham.
- Nasien, D., Yuhaniz, S. S. & Haron, H. (2010). Statistical Learning Theory and Support Vector Machines. *Proceedings of the 2010 Second International Conference on Computer Research and Development*, 760–764.
- Nayak, S. C., Misra, B. B. & Behera, H. S. (2012, February). Index Prediction with Neuro-Genetic Hybrid Network: A Comparative Analysis of Performance. In *Computing, Communication and Applications (ICCCA), 2012 International Conference on*, 1-6. IEEE.
- Negnevitsky, M. (2004). *Artificial Intelligence: A Guide to Intelligent Systems*. Essex: Addison-Wesley.
- Nelson, D. M., Pereira, A. C. & de Oliveira, R. A. (2017, May). Stock Market's Price Movement Prediction with LSTM Neural Networks. In *Neural Networks (IJCNN), 2017 International Joint Conference on*, 1419-1426. IEEE.
- Nelson F. F., (2011). An Overview on the Use of Neural Networks for Data Mining Tasks. *Journal of the Brazilian Neural Network Society*, 9(3), 202-212.
- Nidhi A. & Jatinder Kumar R. S., (2013). A Fuzzy Probabilistic Neural Network for Student's Academic Performance Prediction. *International Journal of Innovative Research in Science, Engineering and Technology*, 2(9), 4425-4432.
- Nilsson, N. J. (1998). *Introduction to Machine Learning: An Early Draft of A Proposed Textbook*. ABD: Stanford University.
- Nisbet, R., Elder IV, J. & Miner, G. (2009). *Handbook of Statistical Analysis and Data Mining Applications*. Kanada: Academic Press.
- Oliveira, F. A., Nobre, C. N. & Zárata, L. E. (2013). Applying Artificial Neural Networks to Prediction of Stock Price and Improvement of the Directional Prediction Index—Case Study of PETR4, Petrobras, Brazil. *Expert Systems with Applications*, 40(18), 7596-7606.

- Olson, D. L. & Delen, D. (2008). *Advanced Data Mining Techniques*. London: Springer Science & Business Media.
- Orçun, Ç. (2010). *Finansal Piyasalarda Alım Satım Kararlarında Teknik Analiz ve İMKB Uygulaması* (Yayınlanmamış Doktora Tezi). DEÜ Sosyal Bilimleri Enstitüsü, İzmir.
- Ou, P. & Wang, H. (2009). Prediction of Stock Market Index Movement by Ten Data Mining Techniques. *Modern Applied Science*, 3(12), 28-42.
- Örten, R. ve Örten İ. (2001). *Türev Finansal Araçlar ve Muhasebe Uygulamaları*. Ankara: Gazi Kitabevi.
- Öz, B., Ayriçay, Y. ve Kalkan, G. (2011). Finansal Oranlarla Hisse Senedi Getirilerinin Tahmini: İMKB 30 Endeksi Hisse Senetleri Üzerine Diskriminant Analizi ile bir Uygulama. *Anadolu Üniversitesi Sosyal Bilimler Dergisi*, 11(3), 51-64.
- Özarı, Ç., Turan, K. K. ve Demir, E. (2016). Teknik İndikatörlerin Etkinliği: BİST30 ve BİST100 Endeksleri Üzerine Bir Uygulama. *Nevşehir Hacı Bektaş Veli Üniversitesi SBE Dergisi*, 6(1), 94-113.
- Özdemir, A. K., Tolun, S. ve Ebru, D. (2011). Endeks Getirisi Yönünün İkili Sınıflandırma Yöntemiyle Tahmin Edilmesi: İMKB 100 Endeksi Örneği. *Ömer Halisdemir Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 4(2), 45-59.
- Özkan, A., Germen, E. , Açıkalm, S. E. ve Madellı, E., (2004), *Teknik Analiz* [online], IBS Yazılım, <http://analiz.ibsyazilim.com/egitim/teknikindex.html>, [28 Haziran 2018 tarihinde erişilmiştir].
- Özkan, M. T. ve Gülesin, M. (2001). Uzman Sistem Yaklaşımı ile Civata ve Dişli Çark Seçimi. *Turk J Engin Environ Sci*, 25, 169-177.
- Öztemel, E. (2003). *Yapay Sinir Ağları*. İstanbul: PapatyaYayıncılık.
- Öztürk, A. (2015). *Yöneylem Araştırmasına Giriş*. Bursa: Ekin Basım Yayın Dağıtım.
- Özyurt, H. (2006). *Para Teorisi ve Politikası*. Trabzon: Derya Kitabevi.

- Pan, Y., Xiao, Z., Wang, X. & Yang, D. (2017). A Multiple Support Vector Machine Approach to Stock Index Forecasting with Mixed Frequency Sampling. *Knowledge-Based Systems*, 122, 90-102.
- Parasız, İ. (2000). *Para Banka ve Finansal Piyasalar*. Ankara: Ezgi Kitabevi.
- Parasız, İ. (2005). *Para Banka ve Finansal Piyasalar*. Ankara: Ezgi Kitabevi.
- Parasız, İ. (2007). *Finansal Kurumlar ve Piyasalar*. Bursa: Ezgi Kitabevi.
- Patel, J., Shah, S., Thakkar, P. & Kotecha, K. (2015). Predicting Stock and Stock Price Index Movement Using Trend Deterministic Data Preparation and Machine Learning Techniques. *Expert Systems with Applications*, 42(1), 259-268.
- Pehlivanlı, A. Ç., Aşıkgil, B. & Gülay, G. (2016). Indicator Selection with Committee Decision of Filter Methods for Stock Market Price Trend in ISE. *Applied Soft Computing*, 49, 792-800.
- Peng, C. Y. J., Lee, K. L. & Ingersoll, G. M. (2002). An Introduction to Logistic Regression Analysis and Reporting. *The Journal of Educational Research*, 96(1), 3-14.
- Pregibon, D. (1981). Logistic Regression Diagnostics. *The Annals of Statistics*, 9(4), 705-724.
- Qiu, M., Song, Y. & Akagi, F. (2016). Application of Artificial Neural Network for the Prediction of Stock Market Returns: The Case of the Japanese Stock Market. *Chaos, Solitons & Fractals*, 85, 1-7.
- Qiu, W., Liu, X. & Wang, L. (2012). Forecasting Shanghai Composite Index Based on Fuzzy Time Series and Improved C-Fuzzy Decision Trees. *Expert Systems with Applications*, 39(9), 7680-7689.
- Quinlan, J. R. (1979). *Induction over Large Data Bases*. Californiya: Stanford Univ.
- Quinlan, J. R. (1980). *Inductive Inference as A Tool for the Construction of High-Performance Programs*. Sydney: University of Sydney.
- Quinlan, J.R. (1992). *c4.5: Programs for Machine Learning*. San Francisco: Morgan Kaufmann Publishers, Inc.

- Ramasubramanian, K. & Singh, A. (2017). *Machine Learning Using R*. London: Springer.
- Raykov, T. & Marcoulides, G. A. (2008). Exploratory Factor Analysis. *An Introduction to Applied Multivariate Analysis*, 241-76.
- Reed, R.D. & Marks II, R.J., (1999). *Neural Smothing*. Cambridge, MA: MIT Press.
- Ren, R., Wu, D. D. & Liu, T. (2018). Forecasting Stock Market Movement Direction Using Sentiment Analysis and Support Vector Machine. *IEEE Systems Journal*, 1-11.
- Rosas-Romero, R., Díaz-Torres, A. & Etcheverry, G. (2016). Forecasting of Stock Return Prices with Sparse Representation of Financial Time Series Over Redundant Dictionaries. *Expert Systems with Applications*, 57, 37-48.
- Rostami, S., Bayat, M., Javid, D. & Esmailpuor, M. (2015). Investigating The Effectiveness Of Machine Learning Algorithm On The Forecasting Of Tehran Stock Exchange Index. *Journal of Current Research in Science*, 3(2), 162-169.
- Rubinstein, Y. D. & Hastie, T. (1997, August). Discriminative vs Informative Learning. In *KDD*, 5, 49-53.
- Russell, S. & Norvig, P. (2010). *Artificial Intelligence: A Modern Approach*. New Jersey: Prentice Hall.
- Saffi, P. A. (2003). Análise Técnica: Sorte ou Realidade?. *Revista Brasileira de Economia*, 57(4), 953-974.
- Sagar G., Venkata S. & Manoj K., (2011). Evolutionary Algorithm for Optimal Connection Weights in Artificial Neural Networks. *International Journal of Engineering*, 5(5), 333-340.
- Sakarya, S., Yavuz, M., Karaoglan, A. D. & Özdemir, N. (2015). Stock Market Index Prediction with Neural Network During Financial Crises: A Review on BİST-100. *Financial Risk and Management Reviews*, 1(2), 53-67.

- Santoso, M., Sutjiadi, R. & Lim, R. (2018). Indonesian Stock Prediction Using Support Vector Machine. *In Matec Web of Conferences*, 164, 1031. EDP Sciences.
- Sarikamış, C. (2000). *Sermaye Pazarları*. İstanbul: Alfa Yayınları.
- Settles, B. (2010). *Active Learning Literature Survey*. ABD: University of Wisconsin–Madison.
- Seyidoğlu H. (2005). *Uluslararası Finans*. İstanbul: Güzem Can Yayınları.
- Schölkopf, B. (2001). The Kernel Trick for Distances. In *Advances in Neural Information Processing Systems*, 301-307.
- Shalev-Shwartz, S., (2007). *Online Learning: Theory, Algorithms, and Applications*. (Doctoral Thesis). Hebrew University, Jerusalem.
- Shannon, C.E., (1948). A Mathematical Theory of Shannon Communication. *Bell Syst. Tech. J.*, 27, 379-423.
- Sharma, S. C. (1996). *Applied Multivariate Techniques*. New York: Wiley.
- Shea, P. M. & Lin, V. (1989). Detection of Explosives in Checked Airline Baggage Using an Artificial Neural System, *Neural Networks. IJCNN., International Joint Conference on, IEEE*, 31-34.
- Shearer, C., (2000). The CRISP-DM Model: The New Blueprint for Data Mining, *Journal of Data Warehousing*, 5 (4), 13–22.
- Shin, K.-S., Lee, T. S. & Kim, H.-J. (2005). An Application of Support Vector Machines in Bankruptcy Prediction Model. *Expert Systems with Applications*, 28(1),127–135.
- Sihabuddin, A., Rosadi, D. & Wibowo, N. D. (2009). Early Warning System in Forex Market. *The First International Seminar on Science and Technology*, 1015-1022.
- Sonam T. & Rakesh K. S., (2013). An Analysis of Performance of Feed Forward Neural Network: Using Back Propagation Learning Algorithm. *International Journal of Science and Engineering*, 1, 94-98.

- Steele, R., and Esmahi, L. (2015, January). Technical Indicators as Predictors of Position Outcome for Technical trading. In *Proceedings of the International Conference on e-Learning, e-Business, Enterprise Information Systems, and e-Government (EEE)*, 3-9.
- Steels, L. (1993). The Artificial Life Roots of Artificial Intelligence. *Artificial Life*, 1(1_2), 75-110.
- Steinwart, I. (2001). On the Influence of the Kernel on the Consistency of Support Vector Machines. *Journal of Machine Learning Research*, 2(Nov), 67-93.
- Strang, G., (1986). *Linear Algebra and its Applications*. Seattle: Sounders College Publishing.
- Subha, M. V. & Nambi, S. T. (2012). Classification of Stock Index Movement Using k-Nearest Neighbours (k-NN) Algorithm. *WSEAS Transactions Information Science and Application*, 9, 261-270.
- Sun, H. (2005). Mercer Theorem for RKHS on Noncompact Sets. *Journal of Complexity*, 21(3), 337-349.
- Sutton, R. S. & Barto, A. G. (1998), *Reinforcement Learning: An Introduction*. Cambridge, MA: MIT Press.
- Suykens, J. A., Van Gestel, T., Vandewalle, J. & De Moor, B. (2003). A Support Vector Machine Formulation to PCA Analysis and its Kernel Version. *IEEE Transactions on Neural Networks*, 14(2), 447-450.
- Şıklar, İ. (2004). *Finansal Ekonomi*. Eskişehir: Anadolu Üniversitesi.
- Ŧaran-Moroşan, A. (2011). The Relative Strength Index Revisited. *African Journal of Business Management*, 5(14), 5855-5862.
- Tayman, J. & Swanson, D. A. (1999). On the Validity of MAPE as A Measure of Population Forecast Accuracy. *Population Research and Policy Review*, 18(4), 299-322.
- Tayyar, N. ve Tekin, S. (2013). İMKB-100 Endeksinin Destek Vektör Makineleri ile Günlük, Haftalık ve Aylık Veriler Kullanarak Tahmin Edilmesi. *Abant İzzet Baysal Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 26(26), 189-218.

- Tekin, M., Zerenler, M. & Bilge, A. (2005). Bilişim Teknolojileri Kullanımının İşletme Performansına Etkileri: Lojistik Sektöründe Bir Uygulama. *İstanbul Ticaret Üniversitesi Fen Bilimleri Dergisi*, 4(8), 115-129.
- Tekin, S. & Çanakoğlu, E. (2018, May). Prediction of Stock Returns in Istanbul Stock Exchange Using Machine Learning Methods. In *2018 26th Signal Processing and Communications Applications Conference*, 1-4. IEEE.
- Timofeev, R. (2004). *Classification and Regression Trees (CART) Theory and Applications*. Berlin: Humboldt University.
- Tripathy, N. (2018). Predicting Stock Market Price Using Neural Network Model. *International Journal of Strategic Decision Sciences*, 9(3), 84-94.
- Tsai, C. F. & Wang, S. P. (2009, March). Stock Price Forecasting by Hybrid Machine Learning Techniques. In *Proceedings of the International MultiConference of Engineers and Computer Scientists*, (1)755, 60.
- Turing, A. M. (1950). Computing Machinery and Intelligence. *Mind* LIX no. 2236 433-60. Reprinted in Boden M (Ed.)(1990) *The Philosophy of Artificial Intelligence*, 40-66.
- Tükenmez, M., Susmuş, T. ve Özkan, S. (1999). *Muhasebe Sistemi Uygulama Genel Tebliğine Göre Finansal Yönetim*. İzmir: Vizyon Yayınları.
- Türk Ticaret Kanunu (2018). <http://www.mevzuat.gov.tr/MevzuatMetin/1.5.6102.pdf> [3 Eylül 2018 tarihinde erişilmiştir].
- Uludağ, İ. ve Arıcan, E. (1999). *Finansal Hizmetler Ekonomisi*. İstanbul: Beta Yayınları.
- Ünsal, A. (2000). Diskriminant Analizi ve Uygulaması Üzerine Bir Örnek. *İktisadi ve İdari Bilimler Fakültesi Dergisi*, 2(3), 1-17.
- Vapnik, V. & Lerner, A. J. (1963). Generalized Portrait Method for Pattern Recognition. *Automation and Remote Control*, 24(6), 774-780.
- Vapnik, V. & Chervonenkis, A. (1964). A Note on Class of Perceptron. *Automation and Remote Control*, 19-24.

- Vasudevan, P. (2014). Iterative Dichotomiser-3 Algorithm in Data Mining Applied to Diabetes Database. *Journal of Computer Science*, 10(7), 1151.
- Vellido, A., Martín-Guerrero, J. D. & Lisboa, P. J. (2012, April). Making Machine Learning Models Interpretable. In *ESANN*, 12, 163-172.
- Vercellis, C. (2009). *Business Intelligence: Data Mining and Optimization for Decision Making*. New York: Wiley.
- Wang, L. & Zhu, J. (2010). Financial Market Forecasting Using A Two-Step Kernel Learning Method for the Support Vector Regression. *Annals of Operations Research*, 174(1), 103-120.
- Wang, S. & Shang, W. (2014). Forecasting Direction of China Security Index 300 Movement with Least Squares Support Vector Machine. *Procedia Computer Science*, 31, 869-874.
- Wang, Y. (2013). Stock Price Direction Prediction by Directly Using Prices Data: An Empirical Study on the KOSPI and HSI. *Arxiv Preprint Arxiv:1309-1325*.
- Widrow, B., Rumelhart, D. E. & Lehr, M. A. (1994). Neural Networks: Applications in Industry, Business and Science. *Communications of the ACM*, 37, 93-105.
- Widrow, B. & Hoff, M. E. (1960). Adaptive Switching Circuits. 1960 IRE Wescon Convention Record, New York: IRE Part 4 1960: 96-104.
- Wilkinson, L. (2004). Classification and Regression Trees. *Systat*, 11, 35-56.
- Witten, I. H., Frank, E., Hall, M. A. & Pal, C. J. (2016). *Data Mining: Practical Machine Learning Tools and Techniques*. San Francisco: Morgan Kaufmann.
- Wong, W. K., Manzur, M., and Chew, B. K. (2003). How Rewarding is Technical Analysis? Evidence from Singapore Stock Market. *Applied Financial Economics*, 13(7), 543-551.
- Xin Y., (1999). Evolving Artificial Neural Networks. *IEEE*, 87(9), 1423-1447.
- Xing, E. P., Jordan, M. I., Russell, S. J. & Ng, A. Y. (2003). Distance Metric Learning with Application to Clustering with Side-Information. In *Advances in Neural Information Processing Systems*, 521-528.

- Yakut, E. (2012). *Veri Madenciliği Tekniklerinden C5. 0 Algoritması, Destek Vektör Makineleri ile Yapay Sinir Ağlarının Sınıflandırma Başarılarının Karşılaştırılması: İmalat Sektöründe Bir Uygulama*. (Yayımlanmamış Doktora Tezi). Atatürk Üniversitesi Sosyal Bilimleri Enstitüsü, Erzurum.
- Yakut, E., Elmas, B. ve Yavuz, S. (2014). Yapay Sinir Ağları ve Destek Vektör Makineleri. *Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 19(1), 139-157.
- Yalta, Y. (2011). *Para Teorisi ve Politikası Ders Notları*, Türkiye Bilimler Akademisi Ulusal Açık Ders Malzemeleri Projesi, <http://www.acikders.org.tr/course/view.php?id=70>, [18 Mayıs 2018 tarihinde erişilmiştir].
- Yan, S. Y. (2002). *Number Theory for Computing*. London: Springer Science & Business Media.
- Yao, J., Tan, C. L. & Poh, H. L. (1999). Neural Networks for Technical Analysis: A Study on KLCI. *International Journal of Theoretical and Applied Finance*, 2(02), 221-241.
- Yavuz, M., Sakarya, Ş. ve Özdemir, N. (2015). Yapay Sinir Ağları ile Risk-Getiri Tahmini ve Portföy Analizi. *Ömer Halisdemir Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 8(4), 87-107.
- Ye, J., Janardan, R., Park, C. H. & Park, H. (2004). An Optimization Criterion for Generalized Discriminant Analysis on Undersampled Problems. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 26(8), 982-994.
- Yıldırım, A. (1991). *Borsa'nın ABC'si, Ayılar, Boğalar ve Paranız*. Ankara: Bilgi Yayınevi.
- Yıldız, B. (2009). *Finansal Analizde Yapay Zeka*. Ankara: Detay Yayıncılık.
- Yılmaz, M. K. (2002). *Döviz Vadeli İşlem Sözleşmeleri*. İstanbul: Der Yayınları.
- Yılmaz, İ. (2012). *Osmanlı Dönemi Mimarlık Eserleri Restorasyon İnşaat Maliyetlerinin Yapay Zeka Yöntemleri ile Tahmini*. (Yayımlanmamış Doktora Tezi). İstanbul Kültür Üniversitesi, İstanbul.

- Ying, Y. & Li, P. (2012). Distance Metric Learning with Eigenvalue Optimization. *Journal of Machine Learning Research*, 13(Jan), 1-26.
- Yu, L., Wang, S. & Lai, K. K. (2005, December). Mining Stock Market Tendency Using GA-Based Support Vector Machines. In *International Workshop on Internet and Network Economics*, 336-345. Springer, Berlin, Heidelberg.
- Yüksel, A. S. ve Rodoplu, G. (1980). *Sermaye Piyasası*. İstanbul: Filiz Kitapevi.
- Zhang, G. and Hu, M.Y. (1998). Neural Network Forecasting of the British Pound/US Dollar Exchange Rate. *Omega International Journal of Management Science*, 26(4): 495-506.
- Zhang, Y., (2011), *Active Learning*, https://www.cs.cmu.edu/~tom/10701_sp11/recitations/Recitation_13.pdf, [02 Haziran 2018 tarihinde erişilmiştir].
- Zahedi, J. & Rounaghi, M. M. (2015). Application of Artificial Neural Network Models and Principal Component Analysis Method in Predicting Stock Prices on Tehran Stock Exchange. *Physica A: Statistical Mechanics and its Applications*, 438, 178-187.
- Zhong, X. & Enke, D. (2017). Forecasting Daily Stock Market Return Using Dimensionality Reduction. *Expert Systems with Applications*, 67, 126-139.
- Zhou, Z.-H., Jiang, Y., Yang, Y.-B. & Chen, S.-F. (2002). Lung Cancer Cell Identification Based on Artificial Neural Network Ensembles. *Artificial Intelligence in Medicine*, 24, 25-36.
- Zouhal, L. M. & Denoeux, T. (1998). An Evidence-Theoretic k-NN Rule with Parameter Optimization. *IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)*, 28(2), 263-271.
- Zuo, Y. & Kita, E. (2012). Stock Price Forecast Using Bayesian Network. *Expert Systems with Applications*, 39(8), 6729-6737.