

**DESTEK VEKTÖR MAKİNELERİ YÖNTEMİ İLE İMKB 100 ENDEKSİ
HAREKET YÖNÜ TAHMİNİ**

Selin TEKİN

Yüksek Lisans Tezi

Danışman: Yrd. Doç. Dr. Nezh TAYYAR

Uşak

Şubat, 2013

**DESTEK VEKTÖR MAKİNELERİ YÖNTEMİ İLE İMKB 100 ENDEKSİ
HAREKET YÖNÜ TAHMİNİ**

Selin TEKİN

YÜKSEK LİSANS TEZİ

İşletme Anabilim Dalı

Danışman: Yrd. Doç. Dr. Nezih TAYYAR

Uşak

Uşak Üniversitesi Sosyal Bilimler Enstitüsü

Şubat, 2013

YÜKSEK LİSANS TEZ ÖZETİ

DESTEK VEKTÖR MAKİNELERİ YÖNTEMİ İLE İMKB 100 ENDEKSİ HAREKET YÖNÜ TAHMİNİ

Selin TEKİN

İşletme Anabilim Dalı

Uşak Üniversitesi Sosyal Bilimler Enstitüsü, Şubat 2013

Danışman: Yrd. Doç. Dr. Nezih TAYYAR

Bu çalışmada İstanbul Menkul Kıymetler Borsası Ulusal 100 Endeksi (İMKB 100) hareket yönü tahmini amacıyla veri madenciliğinde sınıflama metodu olarak kullanılan Destek Vektör Makineleri (DVM) yöntemi kullanılmıştır. İMKB 100 endeksi hareket yönünün tahmini için istatistiksel veri analizleri yapan, açık kaynak kodlu programlama dili "R" kullanılmış, DVM'lerin sınıflandırma başarısı çalışmada kullanılan ikinci bir yöntem olan Lojistik Regresyon (LR) yöntemi ile karşılaştırılmıştır. Çalışmada hisse senedi analizinde teknik analizin yararlandığı araçlardan biri olan teknik göstergelerden (indikatörler) yararlanılmıştır. Modellere dahil edilen teknik göstergeler LR analizi ile incelenmiş ve LR analizinde anlamlı olan göstergeler bağımsız değişken olarak kullanılmıştır. Analiz, 03.04.1995-19.03.2012 arası dönemi kapsamaktadır. Toplam 4226 adet veri günlük, haftalık ve aylık veri setleri şeklinde düzenlenmiştir. Her veri seti için 4 model oluşturulmuş ve her model için farklı değerlendirme kriterleri uygulanarak yöntemlerin endeks hareket yönü tahmin performansları değerlendirilmiştir.

Yapılan değerlendirmeler sonucunda DVM'nin oluşturulan 12 model içerisinde İMKB 100 endeksi hareket yönünü en iyi tahminlediği modelin Haftalık Model-1 olduğu (%70.0) gözlenmiştir. Bu model aynı zamanda İMKB 100 endeksi artış (%82.89) ve azalış yönünü (%54.68) birbirine en yakın ve yüksek oranda tahminleyen model olarak bulunmuştur.

Bu çalışma ile elde edilen bulgular ışığında İMKB 100 endeksi hareket yönü tahmininde Haftalık Model-1'in gerek yatırımcılar tarafından, gerekse akademik arařtırmalarda başarı ile kullanılabilceęi sonucuna ulařılmıřtır.

Anahtar Kelimeler: *Destek Vektör Makineleri, Endeks Hareket Yönü Tahmini, Teknik Analiz Göstergeleri, Lojistik Regresyon, Sınıflandırma, İMKB 100.*

ABSTRACT

FORECASTING MOVEMENT DIRECTION OF ISE 100 INDEX USING SUPPORT VECTOR MACHINES METHOD

Selin TEKİN

Department of Business Administration

Social Sciences Institute Uşak University, February 2013

Advisor: Assistant Professor Nezh TAYYAR

This study aims to forecast the movement direction of Istanbul Stock Exchange National 100 Index (ISE 100) using Support Vector Machines (SVM), one of the classification methods in data mining. Open source programming language "R" was used to analyse statistical data, and SVMs' classification performance was compared with Logistic Regression (LR), the other method used in this study, in order to forecast the movement direction of ISE 100 Index. Technical indicators that are among the devices useful for technical analysis in stock prediction were used. These indicators included in models were analysed with LR analysis and then, significant ones were used as independent variables. The analysis includes the data from 03.04.1995 to 19.03.2012. 4226 data were established as daily, weekly and monthly data sets. 4 models were organized for each dataset and index movement direction forecasting performance of these methods was evaluated by applying different criteria for each model.

The results of this study show that SVMs estimate the movement of ISE 100 Index best with Weekly Model-1 (70.0%) among 12 models. Additionally, it is observed that this model has a high level of estimation and the closest increase (82.89%) and decrease (54.68%) direction of ISE 100 Index.

In consideration of the results obtained with this study, it is obvious that in estimating the movement direction of ISE 100 Index, Weekly Model-1 will be useful for investors and academic studies.

Key Words: *Support Vector Machines, Index Movement Direction Forecast, Technical Indicators, Logistic Regression, Classification, ISE 100.*

JÜRİ VE ENSTİTÜ ONAYI

İşletme Anabilim Dalı yüksek lisans öğrencisi Selin TEKİN'in "Destek Vektör Makineleri Yöntemi ile İMKB 100 Endeksi Hareket Yönü Tahmini" başlıklı tezi15.02.2013.. tarihinde, aşağıdaki jüri tarafından Lisansüstü Eğitim ve Sınav Yönetmeliğinin ilgili maddeleri uyarınca, Yüksek Lisans tezi olarak değerlendirilerek kabul edilmiştir.

JÜRİ ÜYELERİ

Üye (Tez Danışmanı) : Yrd. Doç. Dr. Nezir TAYYAR

Üye : Yrd. Doç. Dr. Ufuk SELEN

Üye : Yrd. Doç. Dr. Yılmaz AKYÜZ

İmza**Enstitü Müdürü**

Doç. Dr. Musa ÇİFCİ



ÖNSÖZ

Yüksek Lisans öğrenimim boyunca benden sabrını ve emeğini esirgemeyen, karamsarlığa kapıldığım çoğu zaman beni cesaretlendiren, öğrencisi olmaktan onur duyduğum değerli hocam Sayın Yrd. Doç. Dr. Nezih Tayyar'a sonsuz teşekkürlerimi sunarım.

Ayrıca çalışmam süresince değerli bilgilerini benimle paylaşan, bana güvenen Sayın Dr. Ahmet Coşkun ve sevgili arkadaşım Okt. Rabia Önder'e teşekkürü bir borç bilirim.

Hayatımın her anında benden maddi ve manevi desteğini esirgemeyen, varoluş sebebim annem ve babam'a, canım kardeşim Mert Tekin'e, beni asla yalnız bırakmayan, huzur kaynağım Bella ve Nefes'e yürek dolusu teşekkürlerimi sunarım...

Selin TEKİN

ÖZGEÇMİŞ

Kişisel Bilgiler

Adı Soyadı : Selin TEKİN
Doğum Yeri ve Tarihi : UŞAK / 09.08.1987
Lisans Öğretimi : Maliye Bölümü
Bildiği Yabancı Diller : İngilizce
Bilimsel Faaliyetleri : İMKB'ye Kote Edilmiş Sigorta Şirketlerinin Mali Analizinin Analitik Hiyerarşi Yöntemi ve Topsis ile Değerlendirilmesi (12. Uluslararası Ekonometri, Yöneylem Araştırması ve İstatistik Sempozyumu-Bildiri)

İş Deneyimi

Çalıştığı Kurumlar : 2009/2012 Uşak Üniversitesi Döner Sermaye İşletme Müdürlüğü

İletişim

E-posta Adresi : selintkn@gmail.com

İÇİNDEKİLER

Sayfa

ÖZET.....	iii
ABSTRACT.....	v
JÜRİ VE ENSTİTÜ ONAYI.....	vii
ÖNSÖZ.....	viii
ÖZGEÇMİŞ.....	ix
İÇİNDEKİLER.....	x
TABLolar LİSTESİ.....	xiv
ŞEKİLLER LİSTESİ.....	xvi
KISALTMALAR.....	xvii
GİRİŞ.....	1
1. BÖLÜM: HİSSE SENEDİ TAHMİNİ ÇALIŞMALARI.....	4
1.1. DESTEK VEKTÖR MAKİNELERİ YÖNTEMİ KULLANILARAK YAPILMIŞ HİSSE SENEDİ TAHMİNİ ÇALIŞMALARI	4
1.2. İMKB'DE HİSSE SENEDİ TAHMİNİNE YÖNELİK YAPILAN ÇALIŞMALAR.....	12
2. BÖLÜM: DESTEK VEKTÖR MAKİNELERİ VE LOJİSTİK REGRESYON ANALİZİ.....	23
2.1. DESTEK VEKTÖR MAKİNELERİ	23

2.2. DESTEK VEKTÖR MAKİNELERİ İLE SINIFLAMA.....	24
2.2.1. Doğrusal Destek Vektör Makineleri.....	24
2.2.1.1. Doğrusal Ayrılabilen Veriler İçin Destek Vektör	
Makineleri.....	24
2.2.1.2. Doğrusal Ayrılamayan Veriler İçin Destek Vektör	
Makineleri.....	28
2.2.2. Doğrusal Olmayan Destek Vektör Makineleri.....	31
2.2.2.1. Çekirdek Düzenlemesi ve Çekirdek Fonksiyonları.....	33
2.2.2.2. Çapraz Geçerli Kılma ve Hücre Arama.....	34
2.3. LOJİSTİK REGRESYON ANALİZİ.....	35
3. BÖLÜM: TEKNİK ANALİZ YÖNTEMİ İLE HİSSE SENEDİ	
ANALİZİ.....	39
3.1. GENEL AÇIKLAMA.....	39
3.2. TEKNİK ANALİZ VARSAYIMLARI VE DOW TEORİSİ.....	40
3.3. TEKNİK ANALİZDE KULLANILAN YÖNTEMLER.....	43
3.4. TEKNİK GÖSTERGELER (İNDİKATÖRLER, OSİLATÖRLER).....	44
3.4.1. Hareketli Ortalamalar (Moving Averages - MA).....	44
3.4.1.1. Basit Hareketli Ortalama (Simple Moving Average -	
SMA).....	45
3.4.1.2. Üssel Hareketli Ortalama (Exponential Moving Average -	
EMA).....	46
3.4.1.3. Ağırlıklı Hareketli Ortalama (Weighted Moving Average -	
WMA).....	46
3.4.2. Aroon Osilatörü (Aroon Oscillator).....	47
3.4.3. Yönel Hareket Göstergesi (Directional Movement Indicator -	
DMD).....	49
3.4.4. Parabolik SAR (Parabolic SAR).....	51
3.4.5. Hareketli Ortalamaların Birleşmesi-Ayrılması Göstergesi (Moving	
Average Convergence-Divergence - MACD).....	53
3.4.6. Momentum Göstergesi (Momentum Indicator).....	54
3.4.7. Göreceli Güç Göstergesi (Relative Strenght Index - RSI).....	55
3.4.8. Stokastik Osilatörü (Stochastic Oscillator - SO).....	56

3.4.9. Stokastik Momentum Endeksi (Stochastic Momentum Index - SMI).....	58
3.4.10. Williams'ın %R Göstergesi (Williams' %R)	58
3.4.11. Mal Kanal Endeksi (Commodity Channel Index - CCI).....	59
3.4.12. Chande Momentum Osilatörü (Chande Momentum Oscillator - CMO)	60
3.4.13. Bollinger Bantları (Bollinger Bands - BB).....	61
3.4.14. Ortalama Doğruluk Aralığı (Average True Range - ATR)	62
3.4.15. Chaikin'in Dalgalanma Göstergesi (Volatility, Chaikin's)	62
3.4.16. Toplama/Dağıtım Endeksi (Accumulation/Distribution Index - A/D).....	64
3.4.17. Denge İşlem Hacmi Göstergesi (On Balance Volume - OBV).....	65
3.4.18. Para Akışı Endeksi (Money Flow Index - MFI).....	65
3.4.19. Chaikin Osilatörü (Chaikin Oscillator - CO).....	66
3.4.20. Chaikin Para Akım Göstergesi (Chaikin Money Flow - CMF).....	67
4. BÖLÜM: DESTEK VEKTÖR MAKİNELERİ VE LOJİSTİK REGRESYON YÖNTEMLERİ İLE İMKB 100 ENDEKSİ HAREKET YÖNÜ TAHMİNİ UYGULAMASI.....	69
4.1. UYGULAMANIN KAPSAMI.....	69
4.2. VERİ SETİ VE ANALİZ.....	70
4.2.1. Veri Seti.....	70
4.2.2. Analiz	70
4.2.2.1. Günlük Veriler Kullanılarak Uygulanan Analiz.....	71
4.2.2.2. Haftalık Veriler Kullanılarak Uygulanan Analiz.....	80
4.2.2.3. Aylık Veriler Kullanılarak Uygulanan Analiz.....	89
4.3. ANALİZ SONUÇLARININ GENEL DEĞERLENDİRİLMESİ	99
5. BÖLÜM: SONUÇ VE TARTIŞMA.....	104
EK: KISALTMALAR.....	111

KAYNAKÇA.....115

TABLOLAR LİSTESİ

Tablo 1.	Günlük Model-1'de LR Yöntemi Sınıflandırma Başarısı.....72
Tablo 2.	Günlük Model-1'de DVM Yöntemi Sınıflandırma Başarısı.....73
Tablo 3.	Günlük Model-2'de LR Yöntemi Sınıflandırma Başarısı.....74
Tablo 4.	Günlük Model-2'de DVM Yöntemi Sınıflandırma Başarısı.....75
Tablo 5.	Günlük Model-3'de LR Yöntemi Sınıflandırma Başarısı.....76
Tablo 6.	Günlük Model-3'de DVM Yöntemi Sınıflandırma Başarısı.....77
Tablo 7.	Günlük Model-4'de LR Yöntemi Sınıflandırma Başarısı.....78
Tablo 8.	Günlük Model-4'de DVM Yöntemi Sınıflandırma Başarısı.....79
Tablo 9.	Haftalık Model-1'de LR Yöntemi Sınıflandırma Başarısı.....81
Tablo 10.	Haftalık Model-1'de DVM Yöntemi Sınıflandırma Başarısı.....82
Tablo 11.	Haftalık Model-2'de LR Yöntemi Sınıflandırma Başarısı.....83
Tablo 12.	Haftalık Model-2'de DVM Yöntemi Sınıflandırma Başarısı.....84
Tablo 13.	Haftalık Model-3'de LR Yöntemi Sınıflandırma Başarısı.....85
Tablo 14.	Haftalık Model-3'de DVM Yöntemi Sınıflandırma Başarısı.....86
Tablo 15.	Haftalık Model-4'de LR Yöntemi Sınıflandırma Başarısı.....87
Tablo 16.	Haftalık Model-4'de DVM Yöntemi Sınıflandırma Başarısı.....88

Tablo 17.	Aylık Model-1'de LR Yöntemi Sınıflandırma Başarısı.....90
Tablo 18.	Aylık Model-1'de DVM Yöntemi Sınıflandırma Başarısı.....91
Tablo 19.	Aylık Model-2'de LR Yöntemi Sınıflandırma Başarısı.....92
Tablo 20.	Aylık Model-2'de DVM Yöntemi Sınıflandırma Başarısı.....93
Tablo 21.	Aylık Model-3'de LR Yöntemi Sınıflandırma Başarısı.....94
Tablo 22.	Aylık Model-3'de DVM Yöntemi Sınıflandırma Başarısı.....95
Tablo 23.	Aylık Model-4'de LR Yöntemi Sınıflandırma Başarısı.....96
Tablo 24.	Aylık Model-4'de DVM Yöntemi Sınıflandırma Başarısı.....97

ŞEKİLLER LİSTESİ

Şekil 1.	Optimum Hiperdüzlem ve Destek Vektörleri.....25
Şekil 2.	Doğrusal Ayrılabilen Veriler İçin Optimum Ayırıcı Hiperdüzlem.....26
Şekil 3.	Doğrusal Ayrılamayan Veri Setleri İçin Hiperdüzlemin Belirlenmesi.....29
Şekil 4.	Kernel Fonksiyonu ile Verinin Daha Yüksek Bir Boyuta Dönüştürülmesi.....32
Şekil 5.	Günlük Modeller için LR ve DVM'nin Artış "1", Azalış "0" Yön Tahminleri.....80
Şekil 6.	Haftalık Modeller için LR ve DVM'nin Artış "1", Azalış "0" Yön Tahminleri.....89
Şekil 7.	Aylık Modeller İçin LR ve DVM'nin Artış "1", Azalış "0" Yön Tahminleri.....98
Şekil 8.	LR ve DVM Yöntemlerinin Günlük Modellere Göre Doğru Sınıflandırma Yüzdeleri.....99
Şekil 9.	LR ve DVM Yöntemlerinin Haftalık Modellere Göre Doğru Sınıflandırma Yüzdeleri.....100
Şekil 10.	LR ve DVM Yöntemlerinin Aylık Modellere Göre Doğru Sınıflandırma Yüzdeleri.....102
Şekil 11.	LR ve DVM Yöntemlerinin Artış "1", Azalış "0" Yön Tahminleri ve Genel Sınıflandırma Tahmin Sonuçları.....105

KISALTMALAR

Bu tez çalışmasında Türkçe kısaltması bulunmayan teknik yöntemlerin kısaltmaları literatürde kabul gördüğü hali ile kullanılmıştır. Bu nedenle bu türdeki kısaltmalar için kısaltmalar sözlüğü oluşturulması uygun görülmüştür (Bkz. EK).

Türkçe literatüre geçmiş yabancı türdeki kısaltmalar ise herhangi bir değişikliğe uğratılmadan aynen kullanılmıştır.

DVM	Destek Vektör Makineleri
DVR	Destek Vektör Regresyonu
İMKB 100	İstanbul Menkul Kıymetler Borsası Ulusal 100 Endeksi
LR	Lojistik Regresyon
VM	Veri Madenciliği
YSA	Yapay Sinir Ağları

GİRİŞ

Hisse senedi, anonim ortaklıklar ile sermayesi paylara bölünmüş komandit ortaklıklarda, payları temsil ve ifade eden bir sermaye piyasası yatırım aracıdır. Hisse senetleri, fiyatlardaki yüksek belirsizlik ve volatilité nedeni ile riski en yüksek ancak getirisi en fazla olan menkul kıymet niteliđi taşır. Bu nedenle hisse senedi getirilerinin tahmin edilebilirliđi, gerek yatırımcılar gerekse arařtırmacılar için büyük önem arz etmektedir. Bu durum, hisse senedi tahminine yönelik, geçmişten günümüze, farklı deđerleme yöntemleri ve pek çok farklı teknik kullanılarak çok sayıda tahmin çalışması yapılmasına sebep olmuştur.

Son zamanlarda bilgisayar teknolojilerindeki hızlı ilerleme ile İstanbul Menkul Kıymetler Borsası (İMKB)'na yönelik yapılan çalışmalarda kullanılan klasik yöntemlerin yanı sıra yeni nesil yöntemler olarak bilinen veri madenciliđi yöntemlerinin başarılı sonuçlar vermesi bu alana olan ilgiyi artırmıştır.

Veri Madenciliđi (VM); büyük miktarda veri içinden, gelecek ile ilgili tahmin yapmamızı sağlayacak bađıntı ve kuralların bilgisayar programları kullanılarak aranmasıdır (Timor ve Şimşek, 2008, s. 5). VM'de kullanılan modeller, tahmin edici ve tanımlayıcı olmak üzere iki ana başlık altında incelenmektedir. VM modellerini gördükleri işlemlere göre sınıflama ve regresyon modelleri, kümeleme modelleri ve birliktelik kuralları ve ardışık zamanlı örüntüler olmak üzere üç ana başlık altında incelemek de mümkündür. Sınıflama ve regresyon modelleri tahmin edici, kümeleme, birliktelik kuralları ve ardışık zamanlı örüntü modelleri tanımlayıcı modellerdir (Albayrak ve Yılmaz, 2009, s. 33). Tahmin edici modellerde, sonuçları bilinen verilerden hareket edilerek bir model geliştirilmesi ve kurulan bu modelden yararlanılarak sonuçları bilinmeyen veri kümeleri için sonuç deđerlerin tahmin edilmesi amaçlanmaktadır. Tanımlayıcı modellerde ise karar vermeye rehberlik etmede kullanılabilecek mevcut verilerdeki örüntülerin tanımlanması sağlanmaktadır. VM'de tahmin edici modeller olarak bilinen başlıca sınıflama ve regresyon modelleri; karar ağaçları, genetik algoritmalar, K-En yakın komşu, bellek temelli

nedenleme, lojistik regresyon (Akpınar, 2000, s. 4); bayes sınıflandırması, zaman serisi analizi, yapay sinir ağları ve destek vektör makineleridir (Kaya ve Köymen, 2008, s. 161). Bu modellerden hisse senedi fiyat öngörüsünde sıklıkla kullanılanlar ise lojistik regresyon (LR) ve yapay sinir ağları (YSA)'dır.

VM, veri tabanı teknolojileri, istatistik, makine öğrenmesi gibi birçok farklı disiplini içeren bir alandır (Kaya ve Köymen, 2008, s. 159). Bu çalışmada VM'de sınıflama ve regresyon problemlerinde başarı ile kullanılan bir makine öğrenmesi yöntemi olan destek vektör makineleri (DVM) ve DVM sonuçlarını karşılaştırmak amacıyla hisse senedi fiyat öngörüsünde sıklıkla kullanılan LR yöntemi kullanılarak İMKB 100 endeksinin hareket yönü tahmini yapılmıştır.

Çalışma beş ana bölümden oluşmaktadır. Birinci bölüm, hisse senedi tahminine yönelik DVM ile yapılmış çalışmalar ve tezde kullanılan yöntemler ile doğrudan bir bağlantısı olmasa da farklı tahmin yöntemleriyle İMKB'ye yönelik yapılan çalışmalara ait literatür araştırmasını içermektedir.

İkinci bölümde, öncelikle DVM kavramından bahsedilmiş, ardından, DVM sınıflandırıcıları, doğrusal DVM sınıflandırıcıları ve doğrusal olmayan DVM'ler olarak iki kategoride değerlendirilmiştir. Doğrusal olmayan durumlarda modelin çözümünü kolaylaştıran ve DVM'nin önemli bir parçası olan çekirdek düzenlemesi ve çekirdek fonksiyonları çeşitlerinden bahsedilerek, çapraz geçirme uygulamasına değinilmiştir. Bu bölümün sonunda, ikinci bir yöntem olarak tez çalışmasında kullanılan LR analizi anlatılmıştır.

Üçüncü bölümde, ilk olarak hisse senedi analizi yapılırken yatırımcıların kullandıkları iki önemli analiz türü olan temel ve teknik analiz kavramları hakkında genel bir açıklama yapılmıştır. Daha sonra teknik analizin temel varsayımlarından ve teknik analizin temeli kabul edilen Dow Teoris'i'nin temel ilkelerinden bahsedilmiştir. Ardından, teknik analiz uygulamalarında kullanılan yöntemlere kısaca değinilmiştir. Ayrıca, teknik analizde göstergeler kullanırken, göz ardı edilmemesi gereken uyumsuzluk kavramına da değinilmiştir. Bu yöntemler arasından, uygulama bölümünde yararlandığımız göstergeler (indikatörler) ayrıntılı olarak anlatılmıştır. Göstergelerin dayandığı temel mantık, nasıl hesaplandıkları ve yorumlanması hakkında açıklama yapılmıştır.

Dördüncü bölüm tezin uygulama kısmını kapsamaktadır. VM modellerinden ikili sınıflandırmaya imkan tanıyan DVM ve DVM'nin performansını karşılaştırmak amacıyla ikinci bir yöntem olarak kullanılan LR yöntemlerine dayalı tahmin

modelleri oluşturularak, İMKB 100 endeksi hareket yönü tahmini yapılmıştır. Uygulamada günlük, haftalık ve aylık olarak kullanılan üç veri setinin her biri için ayrı ayrı dört model oluşturulmuştur. Oluşturulan modeller ile elde edilen analiz sonuçları tablolar ve grafikler kullanılarak yorumlanmıştır.

Beşinci bölümde ise uygulama sonucu elde edilen araştırma sonuçları değerlendirilmiş ve bazı önerilerde bulunulmuştur.

1. BÖLÜM: HİSSE SENEDİ TAHMİNİ ÇALIŞMALARI

Yapılan literatür araştırmasında, DVM'lerin Uluslararası finans literatüründe hisse senedi tahmininde yaygın olarak kullanıldığı gözlenmiştir. Yapılan bu çalışmalarda, DVM'lerin tahmin performansı, farklı istatistiksel yöntemler ya da VM yöntemleri ile birleştirilerek değerlendirilmiştir.

İMKB'ye yönelik yapılan tahminlerde ise hisse senedi tahminine yönelik DVM kullanılarak yapılan iki çalışmaya (Kara vd., 2011) ve (Özdemir vd., 2011) rastlanmıştır. Bu çalışmalar haricinde, İMKB'ye yönelik yapılan çalışmaların neredeyse tamamında bilgisayar temelli öğrenme algoritmalarından YSA modellerinin kullanıldığı gözlenmiştir.

Bu bölümde öncelikle DVM yöntemi ile hisse senedi tahmini yapan çalışmalardan bahsedilecektir. Ardından İMKB'de hisse senedi tahminine yönelik yapılan çalışmalara yer verilecektir.

1.1. DESTEK VEKTÖR MAKİNELERİ YÖNTEMİ KULLANILARAK YAPILMIŞ HİSSE SENEDİ TAHMİNİ ÇALIŞMALARI

Kim (2003), KOSPI endeksinin günlük yönünü tahmin etmek amacıyla 12 teknik gösterge ile DVM yöntemini kullanmıştır. Analiz dönemi Ocak 1989 - Aralık 1998 olarak belirlenmiştir. Toplam 2928 verinin %80'si (2347 tanesi) eğitim verisi, %20'si (581 tanesi) test verisi olarak kullanılmıştır. KOSPI endeksinin tahmini amacıyla ikili sınıflandırma yapılmıştır; endeks getirileri bir gün önceki gün sonu değerine göre arttığında "1", azaldığında "0" olarak sınıflandırılmıştır. DVM yöntemi, geri yayılım sinir ağları (BPNN) ve durum tabanlı çıkarsama (CBR) yöntemleri ile karşılaştırılmıştır. DVM'nin, BPNN ve CBR yöntemlerine nazaran daha iyi performans gösterdiğini ve finansal zaman serileri tahmini için gelecek vadeden bir yöntem olduğunu belirtmiştir.

DVM'ler, bir taraftan diğer yöntemlerden daha avantajlı özelliklere sahipken diğer taraftan bir takım dezavantajlara da sahiptir. Örneğin; veri sayısının çok fazla ve yüksek boyutlu olduğu durumlarda, DVM eğitimi zaman maliyetine yol açmaktadır. Böyle durumlarda DVM yönteminin daha çok diğer yeni nesil yöntemlerle geliştirilerek tahminlerde bulunulduğu gözlenmiştir. İncelenen bu çalışmalarda DVM'ler ile diğer yöntemlerin hibrid kullanımının sınıflama performansını ve tahmin doğruluğunu artırdığı gözlenmiştir. Pai ve Lin (2005), on şirkete ait hisse senedinin fiyat yönünü tahmin etmek amacıyla, doğrusal zaman serisi tahmininde yaygın olarak kullanılan bütünleştirilmiş otoregresif hareketli ortalama (ARIMA) ve DVM modellerini entegre eden bir tahmin modeli geliştirmişlerdir. Eğitim, doğrulama ve test veri seti için, 2002 - 2003 dönemi günlük kapanış fiyatları kullanılmıştır. Çalışmada modellerin tahmin doğruluğu ortalama mutlak hata (MAE), ortalama karesel hata (MSE), ortalama mutlak hata yüzdesi (MAPE), hata kareler ortalamasının karekökü (RMSE) ile değerlendirilmiştir. ARIMA ve DVM modellerini entegre eden bu hibrid modelin, ARIMA ve DVM modelleri ile kıyaslandığında, tüm tahmin hatalarını anlamlı bir biçimde azalttığı gözlenmiştir.

Huang vd. (2005), NIKKEI 225 endeksinin haftalık hareket yönünü tahmin etmek için DVM yöntemini kullanmışlardır. DVM'nin performansını dört farklı sınıflandırma yöntemi (rasgele yürüyüş (RW) modeli, doğrusal diskriminant analizi (LDA), kuadratik diskriminant analizi (QDA) ve Elman geri yayılım sinir ağları (EBNN)) ile karşılaştırmışlardır. Aynı zamanda çalışmada bu sınıflandırma yöntemleri ile DVM'yi kombine eden bir model geliştirmişlerdir. Çalışmada S&P 500 endeksi ve Japon Yeni (JPY) girdi değişkenleri olarak belirlenmiştir. 1 Ocak 1990 - 31 Aralık 2002 dönemine ait toplam 676 verinin 640'ı model ve parametre özelliklerini belirlemek amacıyla, geriye kalan 36 veri performans karşılaştırması için kullanılmıştır. RW, LDA, QDA, EBNN ve DVM yöntemlerinin bireysel tahmin performansları ile tüm bu sınıflandırma yöntemlerinin entegre edilmesiyle oluşturulan kombine modelin tahmin performansları karşılaştırılmıştır. Çalışma sonucunda, NIKKEI endeksinin haftalık hareket yönü için en iyi tahmin performansının, DVM ile diğer sınıflandırma yöntemlerini entegre eden modele (%75) ait olduğu sonucuna ulaşmışlardır. Ayrıca, bireysel performanslara bakıldığında DVM yönteminin (%73), çalışmada kullanılan diğer sınıflandırma yöntemlerinden daha başarılı performans gösterdiği, RW'nin (%50) ise en kötü performansa sahip olduğu gözlenmiştir.

Huang ve Wu (2008), çeşitli hisse senedi endekslerinin gelecekteki değerlerini tahmin etmek amacıyla genetik algoritma (GA) ve DVM yöntemlerini entegre edecek bir model geliştirmişlerdir. Çalışmada endeks tahmini için 2 ayrı veri seti oluşturulmuştur. İlk veri seti Büyük Asya endeksleri; NASDAQ, NK225, TWSE, KOSPI endeksleridir. İlk veri seti için tüm endeks verileri Ocak 2003 - Aralık 2004 dönemi için 435 gözlem içermektedir. Bu borsa endeksleri daha sonra günlük getirilere dönüştürülmüştür. İkinci veri seti ise, G7 günlük hisse senedi endeksleri; CAC40, FTSE100, DAX30, MIB40, TSX60, S&P500 ve NK225'den oluşmaktadır. İkinci veri seti için endeks getirileri Ocak 2004 - Aralık 2005 dönemine ait 435 gözlem içerir. Bu 435 verinin 300'ü DVM eğitimi için, geri kalan 135'i test için kullanılmıştır. Çalışmada, önerilen GA-DVM modelinin haricinde, genelleştirilmiş otoregresif koşullu değişen varyans analizi (GARCH), YSA ve DVM'nin bireysel performansları da değerlendirilmiştir. Bu değerlendirmede GARCH modeli ile DVM yöntemi karşılaştırıldığında GARCH daha iyi tahmin performansı gösterirken, DVM ile YSA karşılaştırıldığında DVM'nin daha başarılı olduğu gözlenmiştir. Her iki veri seti içinde GA-DVM modeli ile bireysel tahmin yöntemlerinin performansları karşılaştırıldığında ise önerilen GA-DVM modelinin diğer yöntemlerden daha iyi sonuçlar verdiği bulunmuştur.

Chiu ve Chen (2009), Tayvan borsa dinamizmini değerlendirmek için bulanık teori, GA ve DVM yöntemlerini entegre eden bir model geliştirmişlerdir. Çalışmada borsa teknik göstergeleri, vadeli işlemler piyasası teknik göstergeleri ve makroekonomik değişkenler de dahil olmak üzere toplam 61 tane bağımsız (girdi) değişken; 20 borsa teknik göstergesi, 21 makroekonomik değişken, 20 vadeli işlemler piyasası teknik göstergesi kullanılmıştır. Analiz dönemi Ocak 2003 - Aralık 2004 olarak belirlenmiş ve toplam 714 günlük veri kullanılmıştır. Çalışmada, bulanık model ile DVM, yalnızca DVM, bulanık model ile YSA, bulanık model ile GA, yalnızca YSA ve diskriminant analizi (DA) gibi farklı modellerin iki dönem ve çok dönemli performansları çeşitli girdi değişkenleri kullanılarak değerlendirilmiştir. Bulanık model ile DVM'nin çok dönemli ve iki dönemli tahmin sonuçları sırasıyla; %71 ve %70.25 iken bulanık model ile GA'nın tahmin sonuçları %75 ile %70.75 olarak bulunmuştur. Çalışmada önerilen entegre modelde, üç çeşit girdi değişkeninin kullanılmasının, bir ya da iki çeşit girdi değişkeni kullanılarak oluşturulan analizlere göre daha yüksek tahmin doğruluğu sağladığı gözlenmiştir. Ayrıca DVM'nin tahmin performansı YSA ve DA yöntemlerinden daha başarılı bulunmuştur.

Hsu vd. (2009), yedi önemli endeksi incelemek üzere destek vektör regresyonu (DVR) yöntemi ve YSA'nın özel bir çeşidi olan ön düzenleyici haritalar (SOM) modellerini entegre eden iki aşamalı bir tahmin modeli geliştirmişlerdir. 1 Temmuz 1997 - 31 Mayıs 2002 dönemi için günlük kapanış değerlerini kullanmışlardır. Verilerin %80'i eğitim için %20'si test amaçlı kullanılmıştır. Çalışmada, 15 günlük üssel hareketli ortalama (EMA15), dört periyot gecikmeli fiyatın göreceli oransal farkı (RDP); RDP-5, RDP-10, RDP-15 ve RDP-20 değişkenleri girdi değişkeni, RDP+5 ise çıktı değişkeni olarak kullanılmıştır. Önerilen model DVR+SOM ve tek başına DVR tahmin performansları her bir borsa endeksi için ayrı ayrı olmak üzere, normalize edilmiş ortalama karesel hata (NMSE), MAE, yönlü simetri ve ağırlıklı yönlü simetri kullanılarak değerlendirilmiştir. Çalışma sonucunda geliştirilen bu iki aşamalı tahmin modelinin, tek başına DVM'lerin gösterdiği performansa göre daha başarılı olduğu ve finansal zaman serileri tahmininde kullanılabilecek alternatif bir yöntem olduğu sonucuna ulaşılmıştır.

Perez-Cruz vd. (2003), GARCH modellerinde yaygın olarak kullanılan maksimum olabilirlik (ML) uygulaması yerine DVM'leri kullanıp daha iyi tahminlere ulaşılabileceğini göstermek amacıyla Uluslararası dört borsa endeksi (S&P 100, FTSE100, IBEX35, NIKKEI) üzerinde bir çalışma yapmışlardır. Analiz dönemleri, S&P 100 endeksi için, Ocak 1996 - Ekim 2000; FTSE100 endeksi için, Ocak 1995 - Aralık 2000; IBEX35 için, Ocak 1990 - Aralık 1999 ve NIKKEI endeksi için, Ocak 1995 - Kasım 1999 olarak seçilmiştir. Ayrıca General Motors ve Hewlett Packard hisse senetleri analize dahil edilmiş ve Ocak 1996 - Ekim 2000 dönemi için analiz edilmiştir. Çalışma sonucunda DVM'nin ML tahminlerine oranla daha iyi tahmin doğruluğu sağladığı saptanmıştır.

Lee (2009), NASDAQ endeksinin günlük yönünü tahmin etmek amacıyla, F değeri ile desteklenen sıralı ileri arama (F_SSFS) hibrid özellik seçimi yöntemi ile DVM'ye dayalı bir tahmin modeli geliştirmiştir. Geliştirilen bu modelin performansı, BPNN, bilgi kazanç, simetrik belirsizlik ve korelasyon tabanlı özellik seçimi (CFS) yöntemleri ile kıyaslanmıştır. Çalışmada, 20 vadeli işlem sözleşmesi (dokuz mal, on bir yabancı para), dokuz spot endeks ve bir gün gecikmeli NASDAQ endeksi olmak üzere toplam 30 değişken kullanılmıştır. Analiz dönemi, 8 Kasım 2001 - 8 Kasım 2007 dönemini kapsayan 1065 veri (her bir değişken için) içermektedir. Verilerin %80'i eğitim için, %20'si test amaçlı kullanılmıştır. Orijinal veri seti (0,1) aralığında

ölçeklendirilmiştir. NASDAQ endeksinin tahmini amacıyla ikili sınıflama kullanılmıştır; endeks değerleri bir gün önceki değerine göre arttığında ya da azaldığında sırasıyla +1 ve -1 değerlerini alacak şekilde sınıflandırılmıştır. Çalışmada öncelikle önerilen F_SSFS modeli ile özellik seçimi yapılmış ardından DVM çekirdek fonksiyonunun en iyi parametre değerlerini bulmak için beş kat çapraz geçirme yapılmıştır. Daha sonra, DVM ve BPNN'nin performansları dört özellik seçimi yöntemine (F_SSFS, bilgi kazanç, simetrik belirsizlik ve korelasyon tabanlı özellik seçimi (CFS)) göre değerlendirilmiştir. Daha sonra önce DVM ile DVM'nin bu dört özellik seçim yöntemi ile hibrid sonuçları, ardından BPNN ile BPNN'nin bu dört özellik seçimi yöntemleri ile hibrid sonuçları ayrı ayrı değerlendirilmiştir. BPNN ve DVM modellerinin tahmin doğruluğu t testi ve Mann-Whitney U testi kullanılarak karşılaştırılmıştır. Çalışma sonucunda DVM %85.4, BPNN %71.5 iken, DVM ve F_SSFS hibrid kullanımının %87.3 ile hisse senedi yönünü tahmin etmede daha iyi performans gösterdiği sonucuna ulaşılmıştır.

Bu tezin konusunu oluşturan hisse senedi analizinde kullanılan teknik analiz göstergelerin hisse senedi tahminindeki başarısı ve DVM'nin tahminleme performansındaki etkisini araştıran çalışmalarda da DVM yönteminin diğer yöntemler ile hibrid kullanımının yaygın olduğu gözlenmiştir. Yu vd. (2005), S&P 500 endeksinin günlük değişim yönü tahminine yönelik genetik algoritma tabanlı DVM (GADVM) modelini kullanarak yaptıkları çalışmada, literatürde yaygın olarak kullanılan 18 teknik gösterge; fiyat, stokastik osilatör (SO), hareketli stokastik osilatör (MSO), yavaş stokastik osilatör (SSO), değişim oranı (ROC), momentum, hareketli ortalama (MA), varyans hareketi, varyans hareket oranı, üssel hareketli ortalama (EMA), hareketli ortalamaların birleşmesi ayrılması göstergesi (MACD), toplama/dağıtım osilatörü (A/D), kapanış fiyatının beş günlük hareketli ortalamaya oranı (D5), kapanış fiyatının on günlük hareketli ortalamaya oranı (D10), fiyat osilatörü, mal kanal endeksi (CCI), göreceli güç endeksi (RSI), lineer regresyon çizgisi kullanılmıştır. Tüm veri seti 1 Ocak 2000 - 31 Aralık 2004 dönemini kapsamaktadır. 1 Ocak 2000 – 31 Aralık 2003 dönemi verileri eğitim amaçlı, 1 Ocak 2004 – 31 Aralık 2004 verileri ise test amaçlı kullanılmıştır. S&P 500 hisse senedi günlük fiyat endeksinin tahmini için ikili sınıflama kullanılmıştır; endeks getirileri bir gün önceki gün sonu değerine göre yüksek olduğunda "1", düşük olduğunda "0" olarak sınıflandırılmıştır. Çalışmada, DVM ile RW, ARIMA, BPNN ve önerilen model GADVM'nin tahmin performansları değerlendirilmiştir. Bulunan sonuçlar

DVM'nin tahmin performansı üzerinde GA tabanlı değişken seçiminin önemli olduğunu gösterir niteliktedir. Buna göre DVM %78.65 tahmin performansı sergilerken, önerilen model GADVM'nin diğer yöntemlerden (%84.57) daha iyi tahmin performansına sahip olduğu sonucuna ulaşılmıştır.

Huang ve Tsai (2009), borsa tahmini üzerine yaptıkları çalışmalarında kendini örgütleyen özellik haritaları (SOFM), DVR ve filtre tabanlı özellik seçimi yöntemlerinden oluşan bir hibrid model geliştirmişlerdir. Analizde kullanılan veriler 4 Ocak 2000 - 20 Şubat 2006 dönemini kapsamaktadır. Veri seti beş ayrı dilime ayrılmış ve ilk beş yıl ayrı dönemler için eğitim verisi, son bir yılı da yaklaşık ikişer aylık dönemler itibarıyla ayrılarak test verisi için kullanılmıştır. Çalışmada on üç bağımsız (girdi) değişken; RSI, MACD, MA, Williams'ın %R göstergesi (%R), psikolojik sınır (PSY), stokastik %K, stokastik %D, yukarı yönsel gösterge (+DI), aşağı yönsel gösterge (-DI), BIAS, hacim oranı (VR), A oranı ve B oranı kullanılmıştır. Çalışmada önerilen SOFM-DVR modelinin tahmin doğruluğu MSE, MAE ve MAPE ile değerlendirilmiştir. SOFM-DVR ile özellik seçimi yöntemlerinden oluşan modelin, özellik seçimi içermeyen SOFM-DVR modeline nazaran daha kesin tahmin doğruluğu sağladığı gözlenmiştir. Ardından DVR ortalama tahmin hataları, önce seçilen özellikler daha sonra tüm özellikler kullanılarak değerlendirilmiştir. Çalışmada, SOFM-DVR hibrid modelinin, DVR'nin yalnız başına gösterdiğini performanstan daha iyi sonuçlar verdiği sonucuna ulaşılmıştır.

Ni vd. (2011), SSECI'nin günlük hisse senedi hareketlerini (Ocak 2000 - Aralık 2008) tahmin etmek amacıyla altı farklı fraktal özellik seçimi yöntemi ve DVM'ni hibrit olarak kullanmışlardır. Çalışmada, hisse senedi fiyatını etkileyen pek çok faktör olmasına rağmen sadece 19 teknik gösterge; MACD, bollinger bantları (BB), stokastik %K, stokastik %D, momentum, Williams'ın aşırı alım/aşırı satım göstergesi (WR), PSY, VR, C oranı, para akım endeksi (MFI), A oranı, B oranı, +DI, -DI, RSI, TRIX göstergesi, CCI, ROC, hacim göreceli güç endeksi kullanılmıştır. SSECI tahmini için ikili sınıflama yapılmıştır; endeks getirileri bir önceki gün sonu değerine göre arttığında "+1", azaldığında "-1" olarak sınıflandırılmıştır. Çalışmada kullanılan veriler iki ayrı set halinde ayrılmış ve 4 Ocak 2000 - 29 Aralık 2006 ile 2 Ocak 2001 - 23 Aralık 2007 verileri eğitim verisi olarak, 4 Ocak 2007 - 28 Aralık 2007 ile 2 Ocak 2008 - 23 Aralık 2008 verileri ise test verisi olarak kullanılmıştır. Çalışmada her iki veri seti için DVM'nin tek başına performansı ve DVM ile diğer

altı özellik seçimi yöntemlerinin; bilgi kazanç, simetrik belirsizlik, Relief-F, CFS, OneR method ve geliştirilmiş fraktal özellik seçimi yöntemi hibrid performansları, seçilen alt özellik göstergeleri kullanılarak değerlendirilmiştir. İki ayrı veri seti için ortalama tahmin doğruluğu; bilgi kazanç %52.87, simetrik belirsizlik %52.87, Relief-F %46.32, CFS %56.60, OneR %57.44 ve geliştirilmiş özellik seçimi %58.86 olarak bulunmuştur. Geliştirilmiş fraktal özellik seçimi metodu, diğer özellik seçimi metodları ile karşılaştırıldığında, geliştirilmiş özellik seçimi yöntemi ve DVM'nin hibrid kullanımının (%58.86) diğer beş özellik seçimi yöntemi ile birlikte kullanımından daha başarılı olduğu sonucuna ulaşılmıştır.

Yapılan literatür incelemesinde, DVM'lerin diğer yöntemler ile hibrid kullanımının yanı sıra modifiye versiyonları kullanılarak hisse senedi tahminindeki başarı performansının arttığını gösteren çalışmalar da dikkat çekmektedir. Tay ve Cao (2002), durağan olmayan finansal zaman serilerini modellemek amacıyla yaptıkları çalışmalarında, DVM'lerin modifiye edilmiş bir versiyonu; C-artan destek vektör makinelerini kullanmışlardır. Modifiye DVM'lerin performansı, Chicago Ticaret Borsası'nda bulunan üç gerçek vadeli işlem sözleşmesi [S&P 500 borsa endeksi (CME-SP), ABD 30 yıllık devlet tahvili (CBOT-ABD) ve Alman 10 yıllık devlet tahvili (EUREX-BUND)]'nin günlük kapanış fiyatları kullanılarak değerlendirilmiştir. Çalışmada beş günlük periyotlarla, dört periyot gecikmeli RDP değeri (RDP-5, RDP-10, RDP-15, RDP-20) ve EMA15 girdi değişkeni olarak kullanılmıştır. Çıktı değişkeni olarak kullanılan RDP+5, üç günlük üssel hareketli ortalama ile düzeltilen kapanış fiyatlarından elde edilmiştir. Çalışmada öncelikle, ± 2 standart sapma limitinin ötesindeki RDP değerleri aykırı değerler olarak seçilmiştir ve bunlar en yakın sınır (marjin) değerleri ile değiştirilmiştir. Ardından veri ölçeklendirilmesi yapılmıştır. Veri noktaları [-0.9, 0.9] aralığında ölçeklendirilmiştir. Kapanış fiyatlarından oluşan üç veri kümesi, zaman aralıklarına göre üç ayrı parçaya ayrılmıştır. DVM'ye optimum parametreler seçmek için ilk parça eğitim, ikinci parça doğrulama amacıyla kullanılmıştır. Son parça ise test verisi olarak kullanılmıştır. Eğitim seti için 907 veri örneği, doğrulama ve test setinin her biri için 200 veri örneği kullanılmıştır. DVM çekirdek fonksiyonu olarak Gaussian fonksiyonu tercih edilmiştir. Çalışmada DVM'lerin birçok farklı modellenmesi birbiriyle karşılaştırılmıştır. Modellerin tahmin performansları NMSE kullanılarak değerlendirilmiştir. Çalışma sonucunda, C-artan destek vektör makinelerinin, standart DVM'lere nazaran daha küçük NMSE değerlerine sahip olduğu ve finansal

zaman serilerinin yapısal deęişiklięini tahmin etmede daha iyi performans gösterdięi gözlenmiştir.

Yeh vd. (2011), TAIEX fiyat tahminine yönelik geliřtirdikleri çoklu çekirdek destek vektör regresyonu (MKSVR) yöntemine dayalı çalışmada, Ekim 2002 - Aralık 2005 dönemi günlük kapanış deęerlerini kullanmışlardır. Çalışma üç aşamada gerçekleştirilmiştir; ilk iki aşamada dört ayrı veri seti (belirli dönemlere ait kapanış deęerlerinden) hazırlanmış, üçüncü aşamada ise ikinci aşamada oluşturulan veri seti kullanılmıştır. Bu veri setlerinden hareketle önce MKSVR'nin, tek çekirdek destek vektör regresyonu (SKSVR) modeli ile performanslarını deęerlendirmişler, daha sonra MKSVR ve SKSVR, ARIMA ile, ardından bulanık sinir aęları (FNN) yöntemleri ile karşılaştırılmıştır. Çalışma sonucunda önerilen model MKSVR'nin dięer yöntemlerden daha başarılı olduęu sonucuna ulaşmışlardır.

DVM eğitiminde çekirdek fonksiyonlarının seçimi ve seçilen çekirdek fonksiyonu için belirlenecek parametre seçimi önemli bir rol oynamaktadır. Yapılan çalışmalarda çekirdek fonksiyonları için seçilecek parametre deęerlerinin seçiminin DVM'nin sınıflandırma performansına doğrudan etki ettięi gözlenmiştir. Ding vd. (2008), borsaya kote edilmiş Çin şirketlerinin finansal durumunu belirlemeye yönelik DVM'ye dayalı bir tahmin modeli kullandıkları çalışmalarında, analiz dönemi olarak 2001 - 2006 dönemi verilerinden yararlanmışlardır. Çalışmada öncelikle 10 kat çapraz geçерleme kullanılarak en iyi parametre seçimi yapılmıştır. Ardından DVM'nin dört çekirdek fonksiyonunun tahmin performansı deęerlendirilmiştir ve radyal tabanlı çekirdek fonksiyonu (RBF) dięer çekirdeklerden başarılı bulunmuştur. Daha sonra DVM'nin tahmin performansı üç katmanlı BPNN, çoklu diskiriminant analizi (MDA) ve LR ile istatistiksel olarak karşılaştırılmıştır. Çalışma sonucunda, RBF DVM'nin, BPNN, MDA ve LR yöntemlerinden daha iyi sonuçlar verdięi sonucuna ulaşılmıştır.

Sap ve Awan (2005), KLSE üzerine yaptıkları çalışmalarında 1 Nisan 2002 - Aralık 2004 sonuna kadar günlük kapanış deęerlerini kullanmışlardır. Eğitim veri seti; 1 Nisan 2002 - 31 Aralık 2003, 1 Mart 2004 - 31 Aralık 2004 dönemi de test veri seti olarak seçilmiştir. İlk eğitim veri seti KLSE endeksinden seçilen bir şirketin 100 günlük kapanış deęerlerinden oluşmaktadır. Bu 100 gün gelecek günün endeksini tahmin etmek için kullanılmıştır. Bu çalışmada Gaussian fonksiyonu DVM'nin çekirdek fonksiyonu olarak kullanılmıştır çünkü Gaussian çekirdekleri eldeki verilere ek bir bilgi olmasa da iyi performans gösterebilmektedirler. Deneyde

kullanılan DVR algoritması LibSVM'den modifiye edilmiştir. Algoritmayı uygulamadan önce bazı parametreler seçilmiştir. Bunlar; hata maliyeti, çekirdek fonksiyon parametresi ve marjinlerdir. İlk eğitim setinde çapraz geçerleme uyguladıktan sonra parametre değerlerini oluşturmuşlardır. Modellerin tahmin performansı MSE kullanılarak değerlendirilmiştir. Çalışma sonucunda DVM'nin zaman serisi tahminine iyi bir alternatif oluşturduğu ve şu avantajları sağladığı saptanmıştır; bunlardan ilki, daha küçük bir MSE sağladığı için DVM'ler daha iyi tahmin yapar. Bunun nedeni DVM'nin yapısal risk minimizasyonu prensibini benimsemesi ve böylece geleneksel tekniklerden daha iyi genelleme yapabilmesidir. İkincisi ise, DVM'nin çalışmasının daha hızlı oluşudur. DVM'deki regresyon fonksiyonu yalnızca destek vektörleri tarafından oluşturulur ve çalışma örneklerinin sayısına oranla destek vektörlerinin sayısı çok daha azdır.

Yapılan literatür incelemesinde, hisse senedi fiyatlarındaki aşırı dalgalanma nedeniyle oluşan gürültü probleminin de DVM performansını etkilediği gözlenmiştir. Gürültü içeren veriler söz konusu olduğunda kullanılan yöntemler ile ulaşılan sonuç doğru tahminleme oranını azaltmaktadır. DVM tekniğinin değerlendirildiği çalışmalarda, gürültüden arındırılmış veriler ile DVM performansının daha iyi sonuçlar verdiği gözlenmiştir. Sui vd. (2007), SSECI tahminine yönelik olarak yaptıkları çalışmalarında, 28 Nisan 1997 - 12 Eylül 2006 dönemi için toplam 2261 veriden yararlanmışlardır. Verilerin 1920'si çalışma verisi olarak 341'i test verisi olarak kullanılmıştır. Finansal veriler gürültü içerdiği için veriler dalgacık sıkıştırma yöntemi ile gürültüden arındırılmıştır. Çalışmada 12 teknik gösterge; Alexander filtresi (ALF), göreceli güç, RSI, MFI, BB, volatilité, volatilité bantları, Chaikin osilatörü (CO), MACD, stokastik %K, A/D osilatörü, %R kullanılmıştır. DVM hem gürültü içeren hem de gürültüden arındırılmış modellere ayrı ayrı uygulanmıştır. Gürültüden arındırılmış veri setinde (%60.12), gürültü içeren veri setine göre (%54.25) daha iyi sonuçlar alınmıştır.

1.2. İMKB'DE HİSSE SENEDİ TAHMİNİNE YÖNELİK YAPILAN ÇALIŞMALAR

Son zamanlarda hisse senedi piyasalarına olan ilginin artış göstermesi, gerek yatırımcıları gerekse Akademik çevreyi, hisse senetlerinin gelecek değerlerini tahmin etme konusunda çalışmalar yapmaya yöneltmiştir. Türkiye'nin tek hisse senedi

piyasası olan İMKB'de hisse senedi getiri tahminine yönelik özellikle son on yıllık süreçte çok sayıda çalışma yapıldığı, bu çalışmaların çoğunluğunda ise VM yöntemi olan YSA yönteminin tercih edildiği gözlenmiştir. Yapılan incelemede, İMKB'de hisse senedi tahminine yönelik DVM'lerinin kullanıldığı iki çalışmaya rastlanmıştır. Bu kısımda öncelikle DVM yöntemi ile hisse senedi tahmini çalışmaları, ardından İMKB'de farklı teknikler ile hisse senedi getiri tahmini yapan çalışmalar özetlenmiştir.

Hisse senedi tahmini için DVM yönteminin kullanıldığı çalışmalarda, DVM'nin diğer sınıflandırma yöntemlerine göre gösterdiği performansın değerlendirildiği gözlenmiştir. Kara vd. (2011), İMKB 100 endeksinin tahmini amacıyla yaptıkları çalışmalarında VM'de yaygın kullanım alanı bulan YSA ve DVM'nin performanslarını karşılaştırmışlardır. Analiz için, 2 Ocak 1997 - 31 Aralık 2007 günlük kapanış fiyatlarını kullanmışlardır. Toplam 2733 iş gününün 1440'ı artan, 1293'ü azalan yönlüdür. Çalışmada 10 teknik gösterge; basit hareketli ortalama (SMA), ağırlıklı hareketli ortalama (WMA), momentum, stokastik %K, stokastik %D, RSI, MACD, %R, A/D osilatörü, CCI bağımsız değişken olarak kullanılmıştır. İMKB 100 endeksi tahmini için ikili sınıflandırma kullanılmış; hisse senedi fiyat endeksi günlük değişim yönü (0,1) olarak sınıflandırılmıştır. Çalışma sonucunda her iki yöntemde başarılı sonuçlar vermiş olmasına rağmen YSA'nın %75.74, DVM'nin %71.52 tahmin performansına sahip olduğu sonucuna ulaşmışlardır.

Özdemir vd. (2011) ise, yaptıkları çalışmalarında, hisse senedi getirilerine etki edeceği düşünülen bağımsız değişkenler kullanarak İMKB 100 endeksinin getiri yönünü tahmin ettikleri çalışmalarında, ikili sınıflandırmaya imkan tanıyan LR ve DVM yöntemlerini kullanmışlardır. Çalışmada, Şubat 1997 - Aralık 2010 dönemini kapsayan aylık verileri kullanmışlardır. Toplam 167 aylık veri setinin, modellerin kurulduğu 138 veri eğitim kümesine ve modellerin geçerliliğinin test edildiği 29 veri tahmin kümesine ayrılmıştır. Çalışmada, sekiz tane makroekonomik gösterge; tüketici fiyatları endeksine dayalı enflasyon oranları, TCMB tarafından gösterge niteliğinde açıklanan TL/Dolar döviz satış kuru, reel efektif döviz kuru endeksi, TCMB döviz rezervleri, bankalararası para piyasası bir gecelik faiz oranları ile ABD Federal Funds Rate farkı, imalat sanayi kapasite kullanım oranı, İstanbul altın borsası endeksi ve West Texas Intermediate spot petrol fiyatı ile MSCI European Index (16 Avrupa ülkesinin hisse senedi piyasasının performansını gösteren piyasa değeri ağırlıklı bir endeks), MSCI Emerging Markets Index (21 yükselen piyasa

ekonomisinin hisse senedi piyasa performansını gösteren piyasa değeri ağırlıklı bir endeks) ve S&P 500 endeksleri olmak üzere toplamda 11 tane değişken kullanılmıştır. İMKB 100 endeksinin tahmini amacıyla ikili sınıflandırma yapılmıştır; endeks getirisi bir önceki ay sonundaki değerine göre pozitif yönlü olduğunda "1", negatif yönlü olduğunda ise "0" olarak sınıflandırılmıştır. LR ve DVM'nin modelleme ve tahmin kümeleri için doğru sınıflandırma performansları ayrı ayrı değerlendirilmiştir. LR yönteminin modelleme ve tahmin kümesi için doğru sınıflandırma oranları sırasıyla %75.4 ve %86.2'dir. DVM yönteminin ise tüm değişkenlerle oluşturulan modelde doğru sınıflandırma sonuçları eğitim kümesinde %73.9, test kümesinde %79.3 iken değişken seçimi ile kurulan modelde sırasıyla %76.1 ve %86.2 olarak gözlenmiştir. Çalışmada, yöntemlerin tahmin güçleri incelendiğinde LR'nin endeksin negatif getiri yönünü daha iyi tahminlerken, DVM yöntemiyle kurulan her iki modelde de endeksin pozitif getiri yönünü daha iyi tahmin ettiği görülmüştür.

Diler (2003), YSA hata geriye yayma yöntemi ve bu yöntemin momentumla güçlendirilmiş halini kullanarak İMKB 100 endeksinin günlük hareket yönünü tahmin etmiştir. Model, girdi katman-gizli katman-çıkı katman şeklinde iki tabakalı bir YSA olarak tasarlanmıştır. Çalışmada yedi teknik gösterge bağımsız (girdi) değişken (bir gün gecikmeli) olarak kullanılmıştır; SMA, 5 ve 10 günlük WMA, momentum, stokastik %K, RSI, MACD ve bağımlı (çıkı) değişken olarak ise, İMKB 100 endeksinin günlük değişim oranı kullanılmıştır. Çalışmada kullanılan değişkenlerin aynı cinsten olmalarını sağlamak amacıyla günlük değişim oranları bulunmuş, veriler (-1,+1) arasında değer alacak şekilde düzeltilmiştir. 1 Ocak 1990 - 11 Kasım 2003 dönemini kapsayan 3418 verinin 2700'ü eğitim verisi, 718'i test verisi olarak kullanılmıştır. Modelin performansı önce gizli nöron sayısı, daha sonra momentum katsayısı ile öğrenme katsayısı değiştirilerek ölçülmüştür. Ayrıca bir gösterge olması açısından RMSE hesaplanmıştır. 7-10-1 ağ yapısında, öğrenme oranı 0.08, momentum katsayısı 0.1 olduğu, RMSE'nin de diğer denemelere nazaran daha düşük olduğu, test verilerinin de başarı oranının en yüksek olduğu saptanmıştır. Çalışma sonucunda, modelin İMKB 100 endeksinin ertesi günü yönünü %60.81 oranında tahmin ettiği sonucuna ulaşılmıştır.

Karaatlı (2003), YSA yöntemi kullanarak İMKB 100 endeksinin (Ocak 1990 - Aralık 2002 dönemi için) tahmini amacıyla yaptığı çalışmada aylık veriler ve endeks kapanış fiyatlarını kullanmıştır. Çalışmada kullanılan bağımsız değişkenler;

hazine bonusu faiz oranları, cumhuriyet altını fiyatı, enflasyon oranı (TÜFE), sanayi üretim endeksi, tasarruf mevduatı faiz oranı, döviz kuru (Amerikan Doları) ve zaman değişkenleridir. Bağımlı değişken ise; İMKB 100 endeksi kapanış fiyatlarıdır. 1990 - 2002 yılları arasında yer alan toplam 156 verinin 125 tanesi eğitim amaçlı, 31 tanesi test amaçlı kullanılmıştır. Veriler (-1,+1) aralığına normalize edilmiştir. Çalışmada önce YSA kullanılarak tahmini değerler elde edilmiş daha sonra aynı çalışma için regresyon yöntemi kullanılarak elde edilecek tahmini değerler ve gerçek değerlerin analiz yapılmıştır. Ardından her iki yöntemin standart hataları karşılaştırılmıştır. Karşılaştırma sonuçları, YSA yönteminin hatasının daha küçük olduğunu göstermektedir. İMKB 100 endeksinin tahmini için yapılan bu çalışmada YSA yönteminin tahmin performansının daha iyi olduğu saptanmıştır.

Tektaş ve Karataş (2004), ileri beslemeli çok katmanlı pörseptron (MLP)'ni kullanarak, 2002 - 2003 dönemi için İMKB'de işlem gören yedi şirketin (üç çimento, dört gıda şirketi) hisse senedi fiyat tahminlemesini yaptıkları çalışmalarında, günlük ve haftalık verilerden oluşan iki veri seti kullanmışlardır. Haftalık analizlerde kullanılan bağımsız (girdi) değişkenler; aylık enflasyon endeksi, TCMB tarafından ağırlıklandırılmış bir aylık mevduat faiz oranı, İMKB 100 Endeksi, İMKB Sınai Endeksi ve TCMB Amerikan Doları satış kuru, bağımlı (çıkıtı) değişken ise; analiz edilen şirketlerin Cuma günü kapanış fiyatlarıdır. Günlük analizlerde ise bağımlı değişken; hisse senedi kapanış fiyatı, bağımsız değişkenler ise; TCMB Amerikan Doları satış kuru, İMKB 100 Endeksi, İMKB Sınai Endeksi olarak kullanılmıştır. Çalışmada günlük veri kullanımının performansı artırdığı sonucuna varmışlardır. İkinci aşamada, günlük verilerin kullanıldığı YSA ve aynı verilere uygulanan çoklu doğrusal regresyon modellerini karşılaştırmışlardır. Karşılaştırma kriteri olarak, her iki modelde de performans ölçütü olarak kullanılan korelasyon katsayısı alınmıştır. YSA kullanılarak elde edilen korelasyon katsayılarının daha anlamlı olduğu ve YSA'nın hisse senedi fiyat tahminlemesinde, çoklu doğrusal regresyon modellerinden daha başarılı olduğu sonucuna ulaşılmıştır.

Akel ve Bayramoğlu (2008), kriz dönemlerinin, İMKB 100 endeksinde meydana getirebileceği değişmelerin öngörüsünde bulunabilmek için yaptıkları çalışmalarında 4 Ocak 1999 - 28 Şubat 2001 dönemini analiz dönemi olarak belirlenmiştir. Çalışmada kullanılan YSA modeli, 5 girdi işlem elemanı-8 gizli işlem elemanı-1 çıkıtı işlem elemanından oluşan (5-8-1) çok katmanlı ve geri besleme algoritmasına sahip bir YSA şeklinde tasarlanmıştır. Çalışmada, bağımsız değişken

olarak; ABD doları, Merkez Bankası döviz rezervleri, İMKB işlem hacmi, Merkez Bankası bir aylık mevduat faiz oranı ve altın borsası kapanış fiyatları kullanılmıştır. Bağımlı değişken ise İMKB 100 endeksidir. Modelin geliştirilmesi sırasında çıktı değişkeninin t zamandaki değerinin, girdi değişkenlerinin t-1 zamandaki değerlerinden etkileneceği göz önüne alınarak, girdi değişkenlerinin 4 Ocak 1999 - 27 Şubat 2001 tarihleri arasındaki değerleri, çıktı değişkeninin ise 5 Ocak 1999 - 28 Şubat 2001 tarihleri arasındaki değerleri analiz kapsamına alınmıştır. Tüm değişkenler iş günü frekansında alınmış ve logaritmik dönüşüme uğratarak analize dahil edilmiştir. Veri setinin uzunluğu 521 iş günü olarak belirlenmiş ve 1-502 aralığındaki veriler modelin geliştirilmesi için kullanılmıştır. 503-521 aralığındaki veriler ise geliştirilen modelin öngörü aşamasında kullanılmıştır. Çalışmada kullanılan veri seti (öngörü dönemi haricinde) eğitim, doğrulama ve test olmak üzere üç gruba ayrılmıştır. Veriler, İMKB 100 endeksinin o dönem içinde volatilitenin yüksek olması nedeniyle üçer gün atlanarak (1, 4, 7,..., 502 aralığındaki veriler eğitim grubu; 2, 5, 8,..., 502 aralığındaki veriler doğrulama grubuna ve 3, 6, 9,..., 502 aralığındaki veriler test grubu) modele dahil edilmiştir. Eğitim, doğrulama ve test aşamalarına ilişkin sonuçlar MAPE kullanılarak değerlendirilmiş ve her aşamanın MAPE'ye göre sonuçlarının birbirine yakınlığı göz önüne alınarak geliştirilen YSA modelinin öngörü için kullanılabilir olduğu sonucuna ulaşılmıştır. Çalışmada, YSA modelinin Şubat 2001 krizinden önceki ve sonraki başarılı bir şekilde öngörebilme kabiliyetine sahip olduğunu test etmişler ayrıca kriz dönemlerinde görülen volatilitenin yüksek olması nedeniyle modelin bu volatiliteniyi kriz öncesi döneme kıyasla daha düşük bir başarıyla öngördüğünü sonucuna ulaşımlardır. Modelin endeksin bir sonraki gün yönünü %73.68'lik bir doğrulukla öngörebildiği sonucuna ulaşımlardır.

Akay (2009), İMKB 100 endeksinin aylık gelecek değer tahmini için yaptığı çalışmasında iki farklı YSA modeli kullanmıştır. Analiz, Şubat 1991 - Mayıs 2009 tarihleri arasındaki aylık 220 veri kullanılarak yapılmıştır. Eylül 2006 - Ekim 2007 dönemi ve Kasım 2007 - Mayıs 2009 dönemleri kriz öncesi ve kriz sonrası dönemler olarak ikiye ayrılmış, gecikmeli ve gecikmesiz modeller uygulanarak, modellerin endeks yönü tahmin performansları değerlendirilmiştir. Çalışmada girdi değişkenlerinin belirlenmesi için adimsal regresyon yöntemi uygulanmıştır. Birinci modelde altı ay vadeli mevduat faiz oranının aylık yüzdesel reel değeri, aylık ortalama altın fiyatları, dar para arzı ve dolar kuru bağımsız değişkenler olarak seçilmiştir. İkinci modelde ise bağımlı değişken olan İMKB 100 endeksi aylık

kapanış değerlerinin bir gecikmesi, birinci modelde kullanılan değişkenlere ek olarak modele eklenmiştir. Gecikmeli ve gecikmesiz modelde de toplam 220 veri setinden 187 veri eğitim için, kalan 33 veri ise tahmin için kullanılmıştır. Eğitim, 20000 döngü ile her döngüde tüm veriler kullanılarak yapılmıştır. Modellerden elde edilen verilere göre, modellerin kriz öncesi endeks hareket yönü tahminlerinin kriz dönemine göre oldukça yüksek olduğu yani bağımlı değişkenin bir gecikmesinin, özellikle volatilitenin yüksek olduğu dönemlerde yanıltıcı olduğu ve tahmin performansını olumsuz olarak etkilediği gözlenmiştir. Çalışma sonucunda, gecikmesiz model endeks hareket yönü tahmini başarı oranı, kriz öncesi dönem ve kriz dönemi için %92.3 ve %84.2 iken gecikmeli model tahmin sonuçları %61.5 ve %52.6 olarak bulunmuştur. Ayrıca her iki modelin endeks yönü tahminlerine bağlı al-tut-sat sinyalleri üretilmiş ve üretilen sinyallere göre de getiri endeksleri hesaplanmıştır.

Kutlu ve Badur (2009), ileri beslemeli YSA kullanarak İMKB 100 endeksi tahminine yönelik yaptıkları çalışmalarında, 2 Temmuz 2001 - 13 Temmuz 2006 dönemine ait verilerden yararlanmışlardır. Toplam 1270 veriden 1143 günlük veri öğrenme, son 127 günlük veri ise test örnekleri olarak alınmıştır. Çalışmada kullanılan bağımsız değişkenler; önceki günün endeks değeri, önceki günün Amerikan Doları değeri, önceki günün gecelik faiz değeri, haftanın günlerini belirten beş kukla değişken, önceki günün Fransa, Almanya, İngiltere, NASDAQ, DOW JONES, S&P500, Brezilya ve Japonya borsa endeks değerleridir. İlk olarak bu değişkenler kullanılarak üç değişik model (M1, M2, M3) tanımlaması yapılmış ve modeller için ileri beslemeli yapay sinir ağı tek gizli katman ile uygulanmıştır. Modellerin performansı test veri kümesinin R^2 değeri ile ölçülmüştür. Bir önceki günün endeks, Amerikan Doları ve gecelik faiz değerlerini girdi olarak alan M1 modelinin belirlenen dönem için en iyi (0.96) R^2 değerine ulaşılmıştır. Daha sonra YSA modelinin fiyat hareketinin yönünü doğru tahmin performansı, basit hareketli ortalamalar yönteminin tahmin performansı ile karşılaştırılmış ve endeks yönünü tahmin etmekte YSA'nın (%55.1) basit hareketli ortalamalar yöntemine (%50.4) göre daha iyi performans gösterdiği, İMKB endeks değerinin ileri beslemeli YSA ile başarıyla modellenebileceği sonucuna ulaşılmıştır. Ayrıca, haftanın günlerinin endeks tahmini üzerindeki etkisinin belirgin olmadığı, dış borsaların endeks tahmini üzerinde olumlu bir etkisinin görülmediği sonucuna ulaşılmıştır.

Gür (2009), 04 Ocak 1999 - 31 Aralık 2008 dönemi için İMKB 30'da yer alan dokuz hisse senedindeki fiyat değişimlerinin YSA ile öngörüsünü yapmayı amaçladığı çalışmada, girdi (bağımsız) değişkenleri olarak; önceki kapanış, seans minimum, seans maksimum, seans kapanış, işlem hacmi, İMKB 100 endeksi, ABD doları, TÜFE, Merkez Bankası bir aylık vadeli mevduat faiz oranı, Cumhuriyet Altını ve para arzı, çıktı (bağımlı) değişkeni olarak ise hisse senedi fiyatlarını kullanmıştır. Modelin geliştirilmesi sırasında çıktı değişkeninin t zamandaki değerinin, girdi değişkenlerinin ise t-1 zamandaki değerlerinden etkileneceği göz önüne alınarak, girdi değişkenlerinin 4 Ocak 1999 - 28 Kasım 2008 tarihleri arasındaki değerleri, çıktı değişkeninin ise 5 Ocak 1999 - 1 Aralık 2008 tarihleri arasındaki değerleri analiz kapsamına alınmıştır. Modelin öngörü kümesine ise girdi değişkenlerinin 1 Aralık 2008 - 30 Aralık 2008 tarihleri arasındaki değerleri, çıktı değişkeninin ise 2 Aralık 2008 - 31 Aralık 2008 tarihleri arasındaki değerleri alınmıştır. Analiz kapsamındaki veriler seans bazında ayrılmış (1. seans, 2. seans) sonra her bir grup kendi arasında eğitim, test ve öngörü olmak üzere üç kümeye ayrılmıştır. Eğitim ve test kümelerinde yer alacak veriler belirlenirken, değişkenlerin günlük değerleri birer gün atlanarak (1, 3, 5,..., 2461 aralığındaki veriler eğitim kümesi; 2, 4, 6,..., 2461 aralığındaki veriler test kümesi), 2461 - 2491 aralığındaki veriler ise öngörü için modele dahil edilmiştir. Her bir hisse senedine ait 1. seans ve 2. seans sonuçlarının değerlendirilmesinde, ortalama mutlak hata yüzdesi ölçütü kullanılmıştır. YSA modeli ile yapılan seanslık öngörü sonuçları gerçek değerlerle karşılaştırıldığında analiz kapsamındaki dokuz hisse senedine ait 1. seans fiyatları ortalama olarak %2.84, 2. seans fiyatları ise ortalama olarak %3.50 mutlak hata oranı ile tahmin edilmiştir. Ardından, Akbank hisse senedine ait 1. seans verileri kullanılarak, deneme yanılma yoluyla minimum hata oranının elde edildiği YSA modeli kullanılarak, dokuz farklı hisse senedine ait seans bazlı fiyat öngörüsü yapılmıştır (bir önceki güne göre artış mı yoksa azalış mı gösterdiği gerçek değerlerle kıyaslanarak analiz edilmiştir). Ancak ele alınan hisse senetleri Akbank hisse senedi ile benzer özellikler göstermesi nedeniyle İMKB 30'da yer almasına rağmen kurgulanan modelin sadece Akbank hisse senedini yansıttığı, bu nedenle her bir hisse senedine özgü bir model geliştirilmesinin daha başarılı sonuçlar vereceği sonucuna ulaşılmıştır.

Haznedaroğlu ve Taş (2010), İMKB 100 endeks hareketlerini tahmin etmede gayrisafi milli hasıla, sanayi üretim endeksi gibi makro ekonomik değişkenlerin ve

reel gösterge faiz oranı, döviz kurları gibi finansal verilerin kullanılabilirliğini araştırmak için yaptıkları çalışmada, Aralık 1997 - Şubat 2008 verilerinden yararlanmışlardır. Çalışmada kullanılan girdi değişkenleri mevsimsel ve enflasyonist etkilerden arındırılmıştır. Çalışmada ilk olarak bağımsız değişkenler ve finansal verilerin YSA'da kullanılabilirliğini sağlamak amacıyla düzenlemeler yapılmış ardından bağımsız değişkenlerin (36 bağımsız değişken) İMKB 100 endeksi ile ilişkileri regresyon kullanılarak incelenmiştir. Daha sonra iki farklı ölçeklendirmeye tabi tutulan 14 girdi parametresi için ileri beslemeli geri yayımlı YSA modeli oluşturulmuştur. Ardından YSA tutarlılığı, farklı ölçeklendirmeler kullanılarak karşılaştırılmıştır. (0,1) aralığında ölçeklendirmenin daha tutarlı sonuçlar ürettiği ve ölçeklendirme yöntemi olarak İMKB 100 endeks tahminine yönelik YSA modellerinde (0,1) aralığının uygun olduğu yargısına varılmıştır. Çalışmada İMKB 100 endeksi ile ilişkileri incelenen makroekonomik değişkenler ve finansal veriler ile ilgili ulaşılan sonuçlar şu şekilde özetlenebilir; borç göstergelerinin İMKB 100 endeksi ile pozitif ilişki içinde olduğu, bileşik öncü göstergeler endeksi ile kapanan şirket sayısının yüksek korelasyon, ithalat ve ihracat hacimlerinin yakın korelasyon içinde olduğu, parasal göstergelerden İMKB 100 endeksi ile en yüksek ilişki içinde olanın dolaşımdaki para olduğu ve çalışmada sınıanan faiz oranına ilişkin birçok gösterge arasında endekslenen göstergelerin yüksek korelasyonlu çıktığı, bunun dışında normalize edilmiş biçimi nedeniyle hazine ihale faiz oranı ve gösterge faiz oranının daha düşük korelasyon gösterdiği sonucuna ulaşılmıştır.

Akcan ve Kartal (2011), İMKB'de yer alan yedi sigorta şirketinin hisse senedi fiyat tahmini için yaptıkları çalışmada, söz konusu yedi sigorta şirketinin hisse senedi fiyatlarının 01 Mart - 30 Nisan tarihleri arasındaki değerleri; 15 günlük (11 iş günü), 1 aylık (23 iş günü), 1.5 aylık (34 iş günü) ve 2 aylık (44 iş günü) periyotlar halinde YSA modellerinden çok katmanlı algılayıcı (ÇKA) modeli ile tahmin edilmeye çalışılmıştır. Çalışmada dört makro ekonomik, sekiz mikro ekonomik değişken olmak üzere toplam 12 adet girdi değişkeni kullanılmıştır. Kullanılan makro ekonomik değişkenler her model için aynı alınmış ancak tahmin aşamasında şirketlerin kendi oranları modele dahil edilmiştir, yani mikro ekonomik değişkenler şirketlerin kendi performanslarını içermektedir. Çalışmada girdi değişkenleri, günlük frekansa indirgenerek değişkenlerin 5 Ocak 2009 - 28 Şubat 2011 tarihleri arasındaki 508 iş gününe ait gözlem değerleri modelin eğitim ve test aşamasında kullanılmak üzere ikiye ayrılmıştır. İlk 356 değer eğitim aşamasında, kalan 152 gözlem değeri ise

test aşamasında kullanılmıştır. Modelleme sırasında çıktı değişkenlerinin t zamandaki değerleri, girdi değişkenlerinin $t-1$ zamandaki değerleri ile ilişkilendirilmiştir. Modelin parametreleri deneme yanılma yoluyla belirlenmiş ve tüm şirketler için aynı parametrelere sahip yedi adet model kullanılmıştır. Kurulan ÇKA modelinin girdi işlem elemanı sayısı 12'dir. Gizli katman sayısı 1, gizli katmandaki işlem elemanı sayısı 16'dır. Gizli katmandaki işlem elemanlarında doğrusal olmayan tanjant hiperbolik fonksiyonu kullanılarak ÇKA'ya doğrusal olmayan yapı kazandırılmıştır. Çıktı katmanındaki işlem elemanı sayısı 1'dir. Bu işlem elemanında lineer tanjant hiperbolik fonksiyonu kullanılmıştır. ÇKA'nın eğitimi için ise geri yayılım algoritması tercih edilmiştir. Elde edilen tahmin sonuçları MAE ve MAPE performans ölçütleri ile hesaplanmıştır. Çalışma sonucunda, iki aya kadar yapılan tüm tahminlerin başarılı olduğunu, özellikle de bir aya kadar olan tahminlerin oldukça başarılı olduğunu ve YSA'nın, İMKB'de sigorta şirketlerinin hisse senetleri fiyat tahmininde başarılı olduğu sonucuna ulaşılmıştır.

Akbilgiç (2011), radyal tabanlı fonksiyon ağları (RTFA) entegre ederek geliştirdiği hibrit radyal tabanlı fonksiyon ağı (Hibrit RTFA) modeli ile İMKB 100 endeksinin yönünü, kendisinin ve yedi farklı uluslararası endeks değerlerinin gecikmeli değerleri ile tahminlemeye çalışmıştır. Çalışmada kullanılan veriler 5 Ocak 2009 - 22 Şubat 2011 tarihleri arasındaki İMKB'de gerçekleştirilen 536 işlem gününe aittir. Gecikmeli değişkenler oluşturulurken sadece bir ve iki gecikmeli değişkenler kullanılmış bu nedenle 536 olan gözlem sayısı 534'e düşmüştür. Gecikmeli değerler hesaplanırken saat farkları da dikkate alınmıştır. Çalışmada öncelikle farklı radyal tabanlı fonksiyonlar kullanılarak Hibrit RTFA modeli ile değişken seçimi yapılmıştır. Daha sonra seçilen değişkenlere bağlı olarak belirlenen modeller için tahminler yapıp hangi modelin daha iyi sonuç verdiği karar verilmiştir. Tahminleme yapılacak dönem 5 Mayıs 2010 - 22 Şubat 2011'dir. Tahminleme sürecinde daha önce belirlenmiş olan yedi farklı model ve bu modellerin her biri için kullanılan dört farklı radyal tabanlı fonksiyon ile 28 adet Hibrit RTFA modeli yapılandırılmıştır. Bu 28 adet modelin her birisi de yine yukarıda belirtilmiş olan altı farklı büyüklükteki eğitim veri kümeleri için ayrı ayrı oluşturulmuş dolayısıyla toplamda 168 farklı model için 200 günlük tahminler yapılmıştır. Ayrıca bu 200 günlük tahmin dönemi kendi içinde 20 günlük kısımlara ayrılarak dokuz defa tekrarlanmıştır. Yapılan tahminler için RMSE ve MAE değerleri de diğer karşılaştırma kriterleri olarak değerlendirilmiştir ve seçilen

modellerin tutarlılığı çapraz geçirme ile kontrol edilmiştir. Ayrıca her modelde ayrı ayrı her gün için al-sat kararı verilmiştir. Çalışma sonucunda oluşturulan Hibrit RTFA modelinin mevcut değişkenler kullanılarak İMKB 100 endeksinin hareket yönünü %65'in üzerinde bir doğrulukla tahmin ettiği ayrıca oluşturulan bu hibrit modele dayanarak yapılan al-sat tahminlerinin de başarılı sonuçlar verdiği gözlenmiştir.

Mayil (2011), hareketli ortalamalara göre oluşan al-sat sinyallerine göre hareket edilip edilemeyeceğini değerlendirmeyi amaçladığı çalışmada, kısa vadeli hareketli ortalama olarak 5 ve 22 günlük hareketli ortalamalar ve hareketli ortalama yöntemlerinden de üssel hareketli ortalama yöntemini kullanmıştır. İki hareketli ortalama da; 5 günlük hareketli ortalamasının, 22 günlük hareketli ortalamayı alttan kesmesi "AL", üstten kesmesini ise "SAT" sinyali şeklinde yorumlanarak analiz yapılmıştır. Çalışmada İMKB'de yer alan 311 hisse senedi ayrı ayrı değerlendirilmiş, 311 hisse senedinden 176 tanesi pozitif getiri, 135 tanesi de negatif getiri elde etmiştir. En yüksek üç getiri Şeker Piliç (%1508), Galatasaray Sportif A.Ş. (%1328), Doğan Burada Yayıncılık hisse senedine (%1250) aittir. En düşük getiri (-%97) negatif getiri ile Feniş Alüminyum'a ait olduğu gözlemlenmiştir. Daha sonra ortalama getirilerin çeşitli faktörlere göre gruplama sonuçları değerlendirilmiştir; sektörlere göre getiri sonuçlarında en fazla getiri %340 ile spor sektöründe en düşük getirinin de -%43 negatif getirisi ile savunma sektörüne ait olmuştur. Getirilerin endekslere göre dağılımında, en yüksek getiri ortalamasının İMKB 100'e ait olduğu saptanmıştır. Ayrıca İMKB 30, İMKB 50, İMKB 100 hisse senetleri ayrı ayrı değerlendirilmiştir. Bunun yanında getirilerin halka açıklık oranı, fiyat/kazanç oranı ve defter değerine göre dağılımı incelendiğinde, halka açıklık oranı arttıkça hareketli ortalama yöntemine göre getirilerin arttığı, fiyat/kazanç oranının en düşük olan hisse senetlerinin en fazla kazançta sahip olduğu, defter değeri sıfıra yaklaştıkça getirilerin arttığı gibi ortalama getirilerin çeşitli faktörlere göre gruplama sonuçları değerlendirilmiştir. Çalışma sonucunda, hareketli ortalamalar yöntemi kullanılarak hisse senetlerine yatırım yapılabiliceği kanısına varılmıştır.

Moralı (2011), İMKB 100 endeksinin tahmini için yaptığı çalışmada (27 Temmuz 1995 - 29 Temmuz 2010) bağımlı değişken olarak; İMKB 100 endeksinin günlük kapanış değerleri, bağımsız değişkenler olarak; faiz oranı, altın fiyatları, bankalar arası çift taraflı işlem miktarı ve dolar kapanış değerlerini kullanmıştır. Çalışmada öncelikle 3779 adet günlük verinin logaritması alınarak durağanlaştırma

işlemi yapılmış, ardından 3779 adet günlük veri için beş değişkene ait istatistiksel tanımlayıcı parametreler ile korelasyonları test edilmiştir. İMKB bağımlı değişken olmak üzere durağanlaştırılmış verilerde korelasyon değerlerinin oldukça iyi sonuçlar verdiği ve modelin İMKB bağımlı değişken ve faiz oranı, altın fiyatları, bankalar arası çift taraflı işlem miktarı ve dolar kapanış değeri değişkenleri olmak üzere dört açıklayıcı değişkenle kurulabileceği anlaşılmıştır. Modelleme çalışmasında kullanılan modeller; geleneksel zaman serileri için otoregresif hareketli ortalamalar (ARMA), nümerik arama modelleri için Newton yöntemi ve YSA için ise geri yayılım algoritmasıdır. Çalışmada YSA geri yayılım algoritmasının en iyi tahmin performansı gösterdiği, en düşük performansı ise ARMA yönteminin gösterdiği sonucuna ulaşılmıştır.

2. BÖLÜM: DESTEK VEKTÖR MAKİNELERİ VE LOJİSTİK REGRESYON ANALİZİ

Bu bölümde öncelikle DVM kavramından bahsedilecektir. Ardından, DVM sınıflandırıcıları, doğrusal DVM sınıflandırıcıları ve doğrusal olmayan DVM'ler olarak iki kategoride değerlendirilecektir. Doğrusal olmayan durumlarda modelin çözümünü kolaylaştıran ve DVM'nin önemli bir parçası olan çekirdek düzenlemesi ve çekirdek fonksiyonları çeşitlerinden bahsedilecek, çapraz geçirme uygulamasına değinilecektir. Bu bölümün sonunda, ikinci bir yöntem olarak tez çalışmasında kullanılan LR analizi anlatılacaktır.

2.1. DESTEK VEKTÖR MAKİNELERİ

DVM'lerin temelleri İstatistiksel öğrenme teorisi esas alınarak Vapnik tarafından ortaya atılmıştır (Schölkopf ve Smola, 2002). 1960'ların sonlarında Vapnik tarafından geliştirilen DVM'ler, istatistiksel öğrenme teorisi ve yapısal risk minimizasyonu ilkesine dayanan, iki sınıflı sınıflandırma ve regresyon problemlerinin çözümü amacıyla ortaya atılmış bir makine öğrenmesi yöntemidir (Vapnik 1995, 1998).

DVM'ler ikili sınıflandırma yapacak şekilde tasarlanmışlardır. Bu sınıflandırma yöntemi veriyi daha yüksek bir boyuta dönüştürerek oluşturacağı bir hiperdüzlem ile iki sınıfa birbirinden ayırma prensibini esas alır (Kavzoğlu ve Çölkesen, 2010, s. 74). DVM'nin temel esası, doğrusal olmayan örnek uzayının, örneklerin doğrusal olarak ayrılabilceği bir yüksek boyuta aktararak, örnekler arasındaki maksimum sınırın bulunmasıdır.

DVM'nin en önemli avantajı, gerçek dünya problemlerinde iyi bir performans göstermesidir ve uygulama kolaylığı sağlamasıdır. Çünkü DVM'ler doğrusal bir diskriminant fonksiyonuna dayanmaktadır ve geniş marj sınıflandırıcısı ve Vapnik-Chervonenkis teorisi tarafından ispat edilebilir durumdadır. Sahip olduğu

bu özellik sayesinde verinin hatasız ayrılabilmesi problemiyle başa çıkabilmektedir (Erastö, 2001, s. 34).

DVM'ler marjini maksimize etmek üzere eğitilmişlerdir. Bu nedenle eğitim verilerinin çok az olduğu durumlarda bile genelleme kabiliyetleri iyidir. Ayrıca, hiçbir yerel minimum içermezler. Bir DVM kuadratik programlama problemi olarak formüle edildiği için, problem kuadratik programlama teknikleri ile çözülebilir (Abe, 2005, s. 39).

Sağladığı kolaylıklardan dolayı pek çok alanda uygulanmalarına rağmen bir takım zayıf yönlerinden de söz edilebilir. Örneğin; veri sayısının çok fazla ya da yüksek boyutlu olduğu problemlerde, veri kümesi üzerinde DVM'nin eğitimi, zaman alır. Ayrıca DVM'ler doğrudan karar fonksiyonları kullanır. Bu nedenle çoklu sınıf problemleri doğrudan genişletilemez ve çok fazla formülasyonu vardır (Abe, 2005, s. 40).

DVM'ler hem doğrusal olarak ayrılabilen, hem de doğrusal olarak ayrılamayan verilere uygulanabilmekte ve bu özelliği, bu yöntemi, diğer sınıflama yöntemlerinden daha güçlü kılmaktadır. DVM'ler, banka başarısızlığının tahmini, güç kalitesindeki bozulma türlerinin sınıflandırılması, patent değerlendirme, EMG işaretlerinin tasnifi gibi pek çok farklı alanda başarı ile uygulanmıştır (Tolun, 2008; Uyar vd., 2011; Ercan, 2011; Günay ve Alkan, 2010).

Bu çalışmada İMKB 100 endeksi yönünü tahminlemek amacıyla, ikili sınıflamaya imkan tanıyan DVM kullanılmıştır. Bu nedenle veriyi doğrusal ya da doğrusal olmayan bir fonksiyon yardımıyla sınıflandırmaya imkan tanıyan DVM'ler, alt başlıklar altında ayrıntılı olarak anlatılmıştır.

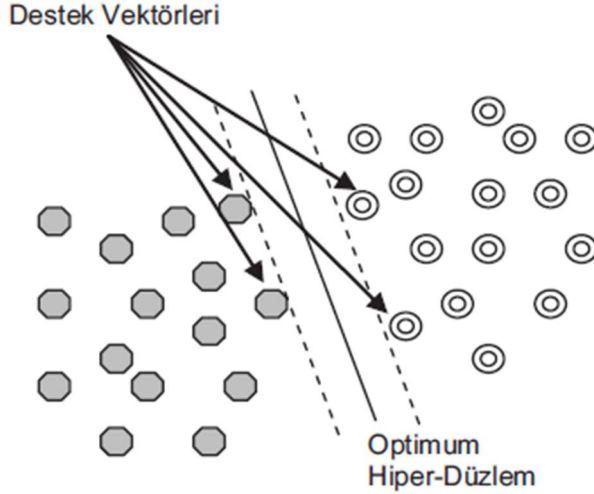
2.2. DESTEK VEKTÖR MAKİNELERİ İLE SINIFLAMA

2.2.1. Doğrusal Destek Vektör Makineleri

2.2.1.1. Doğrusal Ayrılabilen Veriler İçin Destek Vektör Makineleri

DVM ile sınıflandırmada genellikle $\{-1,1\}$ şeklinde sınıf etiketleri ile gösterilen iki sınıfa ait örneklerin, eğitim verisi ile elde edilen bir karar fonksiyonu yardımıyla birbirinden ayrılması amaçlanır. Söz konusu karar fonksiyonu kullanılarak eğitim verisini en uygun şekilde ayırabilecek hiperdüzlem bulunur. Bu

şekilde birçok hiperdüzlem çizilebilir ancak DVM'nin amacı kendisine en yakın noktalar arasındaki uzaklığı maksimum yapan hiperdüzlemi bulmaktır (Kavzoğlu ve Çölkesen, 2010, s. 75-76).



Şekil 1. Optimum Hiperdüzlem ve Destek Vektörleri

Kaynak: Kavzoğlu ve Çölkesen (2010, s. 76).

Şekil 1'de sınırı maksimuma çıkararak en uygun ayırımı yapan hiperdüzlem, optimum hiperdüzlemi ve sınır genişliğini sınırlandıran noktalar ise destek vektörlerini göstermektedir.

DVM'nin eğitimi için kullanılacak l elemandan oluşan veri kümesinin $\{x_i, y_i\}, i = 1, 2, \dots, l$ olduğunu varsayalım. Burada $y_i \in \{-1, 1\}$ etiket değerleri ve $x_i \in \mathcal{R}^d$ özellikler vektörüdür. Doğrusal olarak ayrılabilir durumda, bu iki değerli veriler doğrudan bir hiperdüzlem ile ayrılacaktır. Bu hiperdüzleme ayırıcı hiperdüzlem adı verilir. DVM'nin amacı bu hiperdüzlemin iki örnek grubuna eş uzaklıkta olmasını sağlamaktır.

Hiperdüzlem üzerindeki herhangi bir x noktası, w ağırlık vektörü (hiperdüzlemin normali), $|b|/\|w\|$ hiperdüzlemin orijine dik uzaklığı ve $\|w\|$, w 'nin öklit normu olmak üzere,

$$w \cdot x + b = 0 \quad (2.1)$$

koşulunu sağlar. d_+ ve d_- 'nin ayırıcı hiperdüzleme en yakın olan pozitif ya da negatif örneklerin hiperdüzleme olan uzaklığını gösterdiği varsayıldığında, $d_+ + d_-$ ayırıcı hiperdüzlemin sınırı (marjini) olarak tanımlanır. DVM'nin amacı, örnekler doğrusal olarak ayrılabilirse, optimum ayırıcı hiperdüzlemi bulmaktır. Bunun için tüm eğitim setinin aşağıdaki koşulları sağladığı varsayıldığında;


$$y_i = +1 \text{ için, } w \cdot x_i + b \geq +1 \quad (2.2)$$

$$y_i = -1 \text{ için, } w \cdot x_i + b \leq -1 \quad (2.3)$$

Bu eşitsizlikler bir arada ifade edilecek olursa,

$$y_i (w \cdot x_i + b) \geq +1 \quad \forall i \quad (2.4)$$

elde edilir. Optimum ayırıcı hiperdüzlem, sınırı maksimum yapan hiperdüzlemdir (Şekil 2.). Optimum ayırıcı hiperdüzlemi bulmak için uygun w ve b değerleri hesaplanacaktır.



Şekil 2. Doğrusal Ayrılabilir Veriler İçin Optimum Ayırıcı Hiperdüzlem

Kaynak: Burges (1998, s. 129).

(2.2) ve (2.3)'deki eşitsizlik durumu göz önüne alındığında, $w \cdot x_i + b = +1$ olması durumunda Şekil 2'deki H_1 hiperdüzleminin orijine dik uzaklığı $|1-b|/\|w\|$ ve $w \cdot x_i + b = -1$ olması durumunda ise H_2 hiperdüzleminin orijine uzaklığı $|-1-b|/\|w\|$ olacaktır. Dolayısıyla $d_+ = d_- = 1/\|w\|$ kadar olur. Yani H_1 ve H_2 hiperdüzlemlerinin optimum hiperdüzleme uzaklığı $1/\|w\|$ kadardır. Burada sınır değeri ise $2/\|w\|$ kadardır. H_1 ve H_2 hiperdüzlemlerinin birbirlerine paralel olmalarından dolayı aralarında hiçbir eğitim noktası bulunmamaktadır. Bu iki hiperdüzlem arasındaki maksimum uzaklık, (2.4)'deki koşula bağlı olarak, $\|w\|^2$ değerinin minimize edilmesi ile bulunabilir. Eşitsizlik (2.4)'de gösterilen ve kaldırılması, elde edilen çözümün değişmesine yol açabilen eğitim noktalarına (aralarındaki sınır maksimum olan H_1 ve H_2 hiperdüzlemlerin üzerinde yer alan noktalar) *Destek Vektörleri* (DV) adı verilmektedir.

Maksimum sınırın bulunması işlemi;

$$\text{Minimizasyon:} \quad \min \frac{1}{2} \|w\|^2 \quad (2.5)$$

$$\text{Kısıt:} \quad y_i(w \cdot x_i + b) \geq +1, \forall_i \quad (2.6)$$

ile ifade edilir (Borges, 1998, s. 128-129). Burada (2.5) eşitsizliği çözülecek problem ve (2.6) problemin çözümü sırasında kullanılan koşuldur ve bu ifade doğrusal olmayan bir optimizasyon problemidir (Özkan, 2013, s. 189). Bu optimizasyon problemi Lagrange fonksiyonu kullanarak çözülebilir. Problemin Lagrange fonksiyonu ise,

$$L_p \equiv \frac{1}{2} \|w\|^2 - \sum_{i=1}^l \alpha_i y_i (x_i \cdot w + b) + \sum_{i=1}^l \alpha_i \quad (2.7)$$

şeklindedir (Borges, 1998, s. 130). Bu formülasyonda $\alpha_i \geq 0$ değerleri Lagrange çarpanları olarak adlandırılır. Bu işlevi, w , b değerlerine göre en küçük, $\alpha_i \geq 0$ değerlerine göre en büyük yapan nokta aranır. Eğer noktası bize çözümü verir. Bu dışbükey (konveks) ikinci dereceden bir optimizasyon problemidir. Bu nedenle

(2.7)'de ifade edilen formülasyonun çözülmesi için, (2.7)'deki ifade Karush-Kuhn-Tucker (KKT) koşulları kullanılarak dual probleme dönüştürülür. Bu problem için KKT koşulları şöyledir (Alpaydın, 2011, s. 264):

$$\frac{\partial L_P}{\partial w} = 0 \Rightarrow w = \sum_i \alpha_i y_i x_i \quad (2.8)$$

$$\frac{\partial L_P}{\partial b} = 0 \Rightarrow \sum_i \alpha_i y_i = 0 \quad (2.9)$$

şeklinindedir. Bu koşullar (2.7)'de yerine yazılacak olursa, optimizasyon problemi dual probleme dönüşür. Elde edilen dual problem şu şekildedir:

$$L_D = \sum_i \alpha_i - \frac{1}{2} \sum_{i,j} \alpha_i \alpha_j y_i y_j x_i \cdot x_j \quad (2.10)$$

$$\alpha_i \geq 0, \forall i \quad (2.11)$$

ifadesi elde edilmiş olur. Burada, L_P ve L_D 'nin aynı amaç fonksiyonundan doğmuş olmalarına rağmen farklı koşullara sahip olmaları ve çözümün L_P 'nin minimizasyonu ya da L_D 'nin maksimizasyonu ile bulunuyor olduğunun unutulmaması gerekir (Borges, 1998, s. 130). (2.10)'daki dual problemin (2.11)'de verilen kısıtlamalar ile çözümü, ikinci dereceden optimizasyon problemi ile sağlanır. Burada dikkat edilirse her eğitim örneği için bir tane Lagrange çarpanının olduğu ve çözümde elde edilen Lagrange çarpanlarının büyük çoğunluğunun sıfır olduğu, yalnızca küçük bir yüzdesi için $\alpha_i > 0$ olduğu görülür. İşte $\alpha_i > 0$ olan bu x_i örnekleri DV'lerdir (Alpaydın, 2011, s. 264). DV'ler H_1 ya da H_2 hiperdüzlemlerinin üzerinde yer alırlar (Borges, 1998, s. 131).

2.2.1.2. Doğrusal Ayrılamayan Veriler İçin Destek Vektör Makineleri

Verilerin doğrusal olarak ayrılamadığı durumlarda, önceki bölümde anlatılan DVM algoritması çalışmaz. Çünkü sınıflar doğrusal ayrılamıyorsa ikisini hatasız ayıran hiperdüzlem yoktur. Bu durumda en az hata yapanı ararız. Bu nedenle


DVM'ni bir miktar hataya izin verebilecek şekilde yeniden tasarlarız (Alpaydın, 2011, s. 266). Bu durumda eğitim verilerinin bir kısmının optimum hiperdüzlemin diğer tarafında kalmasından kaynaklanan problem pozitif bir gevşek değişkenin (ξ_i) tanımlanması ile çözülür (Kavzoğlu ve Çölkesen, 2010, s. 76). Veriler doğrusal olarak tamamen ayrılabilir durumda değilse problemin çözümü için pozitif gevşek değişkenleri, ξ_i , $i = 1, 2, \dots, l$ kullanılır. (2.2) ve (2.3)'deki koşullar bu gevşek değişkenler ile yeniden tanımlanacak olursa, yeni ifadeler:

$$y_i = +1 \text{ için, } w \cdot x_i + b \geq +1 - \xi_i \quad (2.12)$$

$$y_i = -1 \text{ için, } w \cdot x_i + b \leq -1 + \xi_i \quad (2.13)$$

$$\xi_i \geq 0, \forall_i \quad (2.14)$$

şeklinde olacaktır (Burges, 1998, s. 135). Burada, gevşek değişken olan ξ_i 'ler hata terimlerini ifade eder. Şöyle ki; $\xi_i = 0$ olması durumunda x_i örneği doğru sınıflandırılmış, $0 < \xi_i < 1$ olması durumunda x_i örneği doğru sınıflandırılmış ancak H_1 ve H_2 aşırı düzlemleri arasında yer alıyor, $\xi_i \geq 1$ ise yanlış sınıflandırılmış demektir (Alpaydın, 2011, s. 266).



Şekil 3. Doğrusal Ayrılamayan Veri Setleri İçin Hiperdüzlemin Belirlenmesi

Kaynak: Kavzoğlu ve Çölkesen (2010, s. 76).

Şekil 3'te doğrusal ayrılamama durumunda optimum ayırıcı hiperdüzlem görülmektedir. Böyle bir durumda, sınırın maksimum hale getirilmesi ve yanlış

sınıflandırma hatalarının minimum hale getirilmesi arasındaki denge pozitif değerler alan ve C ile gösterilen bir düzenleme parametresi ($0 < C < \infty$) tanımlamasıyla kontrol edilebilir. Düzenleme parametresi ve gevşek değişken kullanılarak doğrusal olarak ayrılamayan veriler için optimizasyon problemi 2.15'deki gibi ifade edilir (Kavzoğlu ve Çölkesen, 2010, s. 76).

$$\min \left[\frac{\|w\|^2}{2} + C \cdot \sum_{i=1}^n \xi_i \right] \quad (2.15)$$

C değişkeni, herhangi bir düzgünleştirme uygulamasında olduğu gibi karmaşıklıkla hatanın görece önemini söyler. Yani, model karmaşıklığı ile sınıflandırma hatası arasında düzenleyici bir görev yapar (Alpaydın, 2011, s. 266).

Bu bilgilere göre Lagrange formülasyonu yeniden şu şekilde ifade edilecektir:

$$L_p = \frac{1}{2} \|w\|^2 + C \sum_{i=1}^n \xi_i - \sum_i \alpha_i \{y_i (x_i \cdot w + b) - 1 + \xi_i\} - \sum_i \mu_i \xi_i \quad (2.16)$$

Yukarıdaki formülasyonda μ_i, ξ_i 'nin pozitif olmasını sağlamak için kullanılmış olan Lagrange çarpanlarıdır. Bu Lagrange formülasyonunda çözülmesi zor olduğundan dolayı doğrusal ayrılabilir örneklerde olduğu gibi dual problemine dönüştürülmektedir. Bu probleme de KKT şartları uygulanırsa (Burges, 1998, s. 136):

$$\frac{\partial L_p}{\partial w} = w - \sum_i \alpha_i y_i x_i = 0 \quad (2.17)$$

$$\frac{\partial L_p}{\partial b} = -\sum_i \alpha_i y_i = 0 \quad (2.18)$$

$$\frac{\partial L_p}{\partial \xi_i} = C - \alpha_i - \mu_i = 0 \quad (2.19)$$

$$y_i (x_i \cdot w + b) - 1 + \xi_i \geq 0 \quad (2.20)$$

$$\xi_i \geq 0 \quad (2.21)$$

$$\alpha_i \geq 0 \quad (2.22)$$

$$\mu_i \geq 0 \quad (2.23)$$

$$\alpha_i \{y_i (x_i \cdot w + b) - 1 + \xi_i\} = 0 \quad (2.24)$$

$$\mu_i \xi_i = 0 \quad (2.25)$$

ifadeleri elde edilir. Bu ifadeler (2.16)'da yerlerine yazılırsa:

$$L_D = \sum_i \alpha_i - \frac{1}{2} \sum_{i,j} \alpha_i \alpha_j y_i y_j x_i \cdot x_j \quad (2.26)$$

Burada (2.26) ile doğrusal olarak ayrılabilen durumdaki (2.10) eşitlikleri benzerlik gösterse de (2.26)'nın kısıtları (2.27)'deki gibi tanımlanmıştır.

$$\text{Kısıtlar: } \sum_i \alpha_i y_i = 0 \text{ ve } 0 \leq \alpha_i \leq C, \forall i \quad (2.27)$$


Bu problemin çözümünde, $\alpha_i > 0$ olan örnekler DV'lerdir ve (2.17)'deki w ağırlık vektörünü tanımlarlar (Alpaydın, 2011, s. 268).

2.2.2. Doğrusal Olmayan Destek Vektör Makineleri

DVM, iki sınıfı birbirinden ayıran marjini en büyük, doğrusal bir ayırt edici düzlem bulmayı amaçlar. Ancak gerçek dünyada çoğu problem doğrusal olarak ayrılabilen duruma uygun değildir. Bu durumda girdi uzayında doğrusal olarak ayrılamayan veriler doğrusal olarak ayrılacakları özellik uzayı olarak tanımlanan yüksek boyutlu başka bir uzaya taşınır ve sınıflandırma o uzayda yapılır. Böylece verilerin doğrusal olarak ayrımı yapılabilen ve sınıflar arasındaki hiperdüzlem belirlenebilmektedir (Kavzoğlu ve Çölkesen, 2010, s. 77).

Bunun için önce, doğrusal olarak ayrılamayan verileri Φ olarak adlandıracağımız bir taşıma fonksiyonu kullanarak, (2.28)'de gösterildiği gibi daha yüksek boyutlu başka bir H Euclid uzayına taşıdığımızı varsayalım.

$$\Phi : \mathfrak{R}^d \rightarrow H \quad (2.28)$$



Şekil 4. Kernel Fonksiyonu ile Verinin Daha Yüksek Bir Boyuta Dönüştürülmesi

Kaynak: Kavzoğlu ve Çölkesen (2010, s. 77).

Şekil 4'te verilerin doğrusal olarak ayrılabilceği daha yüksek boyutlu özellik uzayına taşınması görülmektedir. Φ taşıma fonksiyonudur. Girdi uzayı \mathfrak{R}^d 'de doğrusal olarak ayrılamayan örneklerin, özellik uzayı H 'de doğrusal olarak ayrılabilmesi beklenmektedir.

Bu durumda, eğitim algoritması sadece H uzayındaki verilerin $\Phi(x_i) \cdot \Phi(x_j)$ iç çarpımlarına bağlı olacaktır. Bu çarpımlar 2.29'daki gibi tanımlandığında,

$$K(x_i, x_j) = \Phi(x_i) \cdot \Phi(x_j) \quad (2.29)$$

Burada K fonksiyonu *Çekirdek (Kernel) Fonksiyonu* olarak adlandırılmaktadır. Test aşamasında, DVM, x ve w 'nin iç çarpımlarının hesaplanması ile kullanılır. Bu durumda test aşamasında sistemin test örneğini alacağı değer, karar fonksiyonu olan, eşitlik 2.30'un işareti ile belirlenir. Yani karar fonksiyonu,

$$f(x) = \sum_{i=1}^{N_s} a_i y_i \Phi(s_i) \cdot \Phi(x) + b = \sum_{i=1}^{N_s} a_i y_i K(s_i, x) + b \quad (2.30)$$

Bu fonksiyonda N_s , DV'lerin sayısı, s_i ise DV'lerdir (Burges, 1998, s. 138).

2.2.2.1. Çekirdek Düzenlemesi ve Çekirdek Fonksiyonları

Yukarıda bahsedilen bilgiler ışığında, çekirdek fonksiyonu kullanıldığında, doğrusal olarak ayrılabilen verinin, doğrusal olarak ayrılabilen bir özellik uzayına rahatlıkla taşınabildiği görülmektedir.

DVM'lerde matematiksel olarak $K(x_i, x_j) = \Phi(x_i) \cdot \Phi(x_j)$ şeklinde ifade edilen bir çekirdek fonksiyonu yardımıyla doğrusal olmayan dönüşümler yapılabilmekte ve bu şekilde verilerin yüksek boyutta doğrusal olarak ayrımına imkan sağlamaktadır (Kavzoğlu ve Çölkesen, 2010, s. 77). Eşitlik 2.29'un uygulanması *çekirdek düzenlemesi* olarak bilinir. Çekirdek düzenlemesi, yüksek boyutlu özellik uzayında doğrudan hesaplama yapmak zorunda kalmadan çalışabilmemizi sağlar. Yani $\Phi(\cdot)$ fonksiyonunu hesaplamaya gerek kalmadan örnekler daha yüksek boyutlu H uzayına taşınabilmektedir. Bu düzenleme ile problem primal ağırlık uzayında değil, Lagrange çarpanlarının ikili uzayında çözülür (Suykens vd., 2002, s. 37).

DVM ile gerçekleştirilecek bir sınıflandırma işlemi için kullanılacak çekirdek fonksiyonu ve bu fonksiyona ait optimum parametrelerin belirlenmesi esastır (Kavzoğlu ve Çölkesen, 2010, s.77). Çekirdek fonksiyonu olarak çeşitli fonksiyonlar kullanılabilir. Ancak doğrusal olmayan DVM'lerde kullanılan bu çekirdek fonksiyonları Mercer Teoremi koşullarını sağlamak zorundadır.

Mercer Teoremi:

$$K(x, y) = K(y, x) \quad (2.31)$$

$$\iint K(x, y) f(x) f(y) dx dy \geq 0 \quad (2.32)$$

Eşitlik (2.31), çekirdek fonksiyonun simetrik olma özelliğini ifade eder (Pontil ve Verri, 1998, s. 962). Bu teoreme göre $K(x_i, x_j) = \Phi(x_i) \cdot \Phi(x_j)$ biçiminde yazılabildiğini sağlayan bir Φ eşlemesi varsa pozitif definit ve simetrik $K(x, y)$ bir çekirdek fonksiyonudur. O halde bir $K(x_i, x_j)$ fonksiyonun çekirdek fonksiyonu olabilmesi için gerekli koşullar şu şekilde özetlenebilir (Özkan, 2013. s. 201):

- Sürekli fonksiyon olmalıdır.

- Simetrik olmalıdır:

$$K(x_i, x_j) = K(x_j, x_i)$$
- Herhangi x_1, x_2, \dots, x_n değerleri için pozitif definit olmalıdır. Yani,

$$K = \begin{pmatrix} K(x_1, x_1) & K(x_1, x_2) & \cdots & K(x_1, x_n) \\ \cdots & \cdots & \cdots & \cdots \\ K(x_n, x_1) & K(x_n, x_2) & \cdots & K(x_n, x_n) \end{pmatrix}$$

Yaygın olarak kullanılan çekirdek fonksiyonları şunlardır (Hsu vd., 2003, s. 2):

Doğrusal Çekirdek Fonksiyonu:

$$K(x_i, x_j) = x_i^T x_j$$

Polinom Çekirdek Fonksiyonu:

$$K(x_i, x_j) = (\gamma x_i^T x_j + r)^d, \gamma > 0$$

Sigmoid Çekirdek Fonksiyonu:

$$K(x_i, x_j) = \tanh(\gamma x_i^T x_j + r)$$

Radyal Tabanlı Çekirdek Fonksiyonu (RBF):

$$K(x_i, x_j) = \exp(-\gamma \|x_i - x_j\|^2), \gamma > 0$$

Burada γ , r ve d çekirdek parametreleridir.

2.2.2.2. Çapraz Geçerli Kılma ve Hücre Arama

Bu tez çalışmasında çekirdek fonksiyonları arasında kullanımı en yaygın olan RBF çekirdek fonksiyonu kullanılmıştır. RBF çekirdek fonksiyonu iki parametreye sahiptir: C ve γ . Bir problemde hangi C ve γ 'nin en iyi sonucu vereceğini belirlemek için öncelikle model seçimi (parametre araması) yapılmalıdır. Bunu yapmaktaki amaç, en iyi (C ve γ) değerlerini bulmak ve böylece sınıflayıcının tam olarak bilinmeyen veriyi tahmin edebileceği en iyi parametre kombinasyonunu oluşturmaktır. Bu da çapraz geçerli kılma ile yapılmaktadır. Çapraz geçerli kılma uygulamasında öncelikle eğitim seti eşit büyüklükte k adet parçaya bölünür. Sırayla bir alt küme, geri kalan $k-1$ alt kümelerinin üzerinde çalışılan sınıflayıcı kullanılarak test edilir. Böylece eğitim kümesindeki her bir örnek bir defa tahmin edilmiş olur. Çapraz geçirme uygulaması ile aşırı uyum problemi de ortadan kalkar. Çapraz

geçerlemede en iyi C ve γ değerlerinin bulunması için hücre arama yöntemi tavsiye edilmektedir. Çünkü hücre aramada, her iki parametre değeri içinde hesaplama zamanı diğer metodlardan daha az sürer ve hücre arama ile birbirinden bağımsız olan C ve γ kolayca paralelleştirilebilmektedir (Hsu vd., 2003, s. 5).

2.3. LOJİSTİK REGRESYON ANALİZİ

LR; bağımlı değişkenin kategorik, ikili, üçlü ve çoklu kategorilerde gözlemlendiği durumlarda açıklayıcı değişkenlerle neden sonuç ilişkisini belirlemede yararlanılan bir yöntemdir (Nargeleçekenler, 2005, s. 2).

LR analizinin kullanım amacı, istatistikte kullanılan diğer model yapılandırma teknikleriyle aynıdır. En az değişkeni kullanarak en iyi uyuma sahip olacak şekilde bağımlı (sonuç) değişken ile bağımsız değişkenler kümesi (açıklayıcı değişkenler) arasındaki ilişkiyi tanımlayabilen ve genel olarak kabul edilebilir modeli kurmaktır (Aktaş, 2009, s. 110).

LR analizi çeşitli varsayım bozulmaları (normal dağılıma, ortak kovaryansa sahip olmama gibi) durumlarda diskriminant analizi ve çapraz tablolara bir alternatif oluştururken, bağımlı değişkenin 0 ve 1 gibi ikili (binary) ya da ikiden çok düzey içeren kesikli değişken olması durumunda normallik varsayımının bozulması nedeniyle doğrusal regresyon analizine alternatif olmaktadır. Ancak doğrusal regresyon ve lojistik regresyon arasında üç önemli fark vardır (Coşkun vd., 2004, s. 42-43):

- Doğrusal regresyon analizinde kestirilecek olan bağımlı değişken sürekli iken, lojistik regresyonda bağımlı değişken kesikli bir değer almalıdır.
- Doğrusal regresyon analizinde bağımlı değişkenin değeri, lojistik regresyonda ise bağımlı değişkenin alabileceği değerlerden birinin gerçekleşme olasılığı kestirilir.
- Doğrusal regresyonda bağımsız değişkenlerin çoklu normal dağılım göstermesi koşulu aranırken, lojistik regresyonun uygulanabilmesi için bağımsız değişkenlerin dağılımına ilişkin hiçbir ön koşul yoktur.
-

Genel olarak LR modeli aşağıdaki gibi tanımlanır (Ege ve Bayrakdaroğlu, 2009, s. 146):

$$L = \ln \left[\frac{P_i}{1 - P_i} \right] = Z_i = b_0 + b_1 X_i + e_i \quad (2.33)$$

Burada gerçekleşme olasılığı P_i , $\frac{1}{1 + e^{-Z}}$ denkliği ile hesaplanır. Burada $Z = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \beta_3 X_3 + \dots + \beta_n X_n$ şeklinde yazılır. β 'lar regresyon katsayısını göstermektedir. Dolayısıyla Z değerlerinin ters logaritması alınarak p değerlerine de ulaşılabilir.

LR analizi, bağımlı değişkenin türüne göre üç farklı şekilde kullanılabilir (Burmaoğlu, 2009, s. 51):

- **Sıralı (Ordinal) Lojistik Regresyon**

Bağımlı değişkenin üç veya daha fazla cevaplı olması durumunda uygulanan bir yöntemdir. Bu yöntemde bağımlı değişkenin aldığı cevapların sıralı olması şartı söz konusu olmaktadır.

- **İsimsel (Nomial ve Multinomial) Lojistik Regresyon**

Sıralı lojistik regresyon yöntemine benzer ancak bu yöntemde bağımlı değişkenin aldığı cevapların sıralı olma şartı yoktur.

- **İkili (Binary) Lojistik Regresyon**

Bağımlı değişkenin iki cevaplı olması durumunda uygulanan bir yöntemdir.

Çalışmanın uygulama bölümünde bağımlı değişkenin ikili (binary) değer aldığı LR yöntemi kullanılmıştır. Bu nedenle, bu yöntemi ayrıntılı olarak anlatmakta fayda olduğu düşünülmektedir.

İkili lojistik regresyon yönteminde sınıflayıcı değişken iki sonuçludur. Bu değişken sayısal veya kısa alfanümerik bir değişken olabilir. Analizde sınıflayıcı değişken bağımlı değişken olarak referans kabul edilir ve bağımsız değişkenlerle olan ilişkisi incelenerek sınıflandırmada kullanılacak tahmini regresyon denklemi kurulur. Kurulan denklem yardımıyla sınıfların tahminine çalışılır (Burmaoğlu, 2009, s. 51).

LR'de, bağımlı (çıktı) değişken ikili (binary) 0, 1 gibi kesikli bir değişken olup; risk belirten durum 1, diğer durum 0 ile gösterilir. Herhangi bir regresyon probleminde anahtar değer, verilen bir bağımsız değişken değeri için bağımlı (çıktı)

değişkenin ortalama değeridir. Bu değer koşullu ortalama diye adlandırılır ve $E(Y|x)$ şeklinde gösterilir. Burada Y bağımlı değişkeni, x ise bağımsız değişkeni ifade eder. Doğrusal regresyon analizinde koşullu ortalamayı x'e göre doğrusal bir eşitlikle gösterebiliriz;

$$E(Y|x) = \beta_0 + \beta_1 x \quad (2.34)$$

bu eşitlik, x'in $(-\infty$ ve $+\infty)$ arasında değişen değerler alabileceğini bu nedenle de $E(Y|x)$ 'nin mümkün olan her değeri alabileceğini gösterir. LR analizinde koşullu ortalama aşağıdaki eşitsizliği sağlamak zorundadır.

$$0 \leq E(Y|x) \leq 1 \quad (2.35)$$

LR'de, $E(Y|x) = \beta_0 + \beta_1 x$ eşitliğinin sol tarafı 0-1 arasında sınırlı olasılık değerleri aldığından ve bu değerler sonsuz değerler alabilen açıklayıcı değişkenler ile ilişkilendirildiğinden, söz konusu eşitlik her zaman sağlanamamaktadır. Bu probleme yönelik en iyi çözüm, sonuç değeri olarak ifade edilen olasılık değerinin çeşitli dönüşümlerle $-\infty$ ve $+\infty$ arasında tanımlı hale getirilmesidir. Bu koşulu sağlamak için $E(Y|x)$ 'e uygulanan dönüşüme "*logit dönüşüm*" denir (Atakurt, 1999, s. 192).

Bir olayın olma olasılığı P_i , olmama olasılığı $1 - P_i$ ve $Z_i = \beta_1 + \beta_2 X_i$ şeklinde tanımlandığında,

$$P_i = E\left(Y = \frac{1}{X_i}\right) = \frac{1}{1 + e^{-Z_i}} \quad (2.36)$$

$$1 - P_i = \frac{1}{1 + e^{Z_i}} \quad (2.37)$$

Z_i , $-\infty$ ile $+\infty$ arasında değiştiğinde, P_i , 0 ile 1 arasında değişecek ve aralarında doğrusal bir ilişki olmayacaktır. P_i 'nin $1 - P_i$ 'ye oranı bahis oranını (odds oranı) verecektir. Odds oranı Eşitlik (2.38)'deki gibi ifade edilir (Nargeleçekenler, 2005, s. 3).

$$\Omega = \frac{P_i}{1-P_i} = \frac{1+e^{Z_i}}{1+e^{-Z_i}} = e^{Z_i} \quad (2.38)$$

Eşitlik 2.38'in her iki yanının logaritması alındığında Logit modele ulaşılır (Albayrak, 2006, s. 447). Logit (L_i) model Eşitlik (2.39)'daki gibi tanımlanır (Nargeleçekenler, 2005, s. 4)

$$L_i = \ln\left(\frac{P_i}{1-P_i}\right) = Z_i = \beta_1 + \beta_2 X_i \quad (2.39)$$

Böylece doğrusal olmayan ilişki logit fonksiyonu yardımıyla doğrusal hale getirilmiş olacaktır (Burmaoğlu, 2009, s. 55).

3. BÖLÜM: TEKNİK ANALİZ YÖNTEMİ İLE HİSSE SENEDİ ANALİZİ

Bu bölümde ilk olarak hisse senedi analizi yapılırken yatırımcıların kullandıkları iki önemli analiz türü olan temel ve teknik analiz kavramları hakkında genel bir açıklama yapılmıştır. Daha sonra teknik analizin temel varsayımlarından ve teknik analizin temeli kabul edilen Dow Teorisi'nin temel ilkelerinden bahsedilmiştir. Ardından, teknik analiz uygulamalarında kullanılan yöntemlere kısaca değinilmiştir. Ayrıca, teknik analizde göstergeler kullanırken, göz ardı edilmemesi gereken uyumsuzluk kavramına da değinilmiştir. Bu yöntemler arasından, uygulama bölümünde yararlandığımız göstergeler (indikatörler) ayrıntılı olarak anlatılmıştır. Göstergelerin dayandığı temel mantık, nasıl hesaplandıkları ve yorumlanması hakkında açıklama yapılmıştır.

3.1. GENEL AÇIKLAMA

Hisse senedi analizi, geçmiş verilerden hareketle mevcut durum ve gelecekle ilgili somut verilere dayanan tahminler yapılmasıdır (Civan, 2007, s. 234). Hisse senetlerine yatırım yapan yatırımcılar, piyasada fiyatların yönü hakkında bir tahminde bulunabilmek için çeşitli analizler yaparlar. Bu analizlerin en çok kullanılanları teknik ve temel analizdir. Teknik analiz ile hisse senedi değerlemesine geçmeden önce bu iki yöntemi kısaca açıklamakta fayda olduğu düşünülmektedir.

Temel analiz; firmanın halka açıklanan finansal tablolarından ve finansal yansımaları olabilecek bilgilerden yararlanılarak bir firmanın değerinin araştırılmasıdır (Korkmaz ve Ceylan, 2010, s. 287). Afşar ve Afşar (2010, s. 192) temel analizin yapılış amacını "Bir hisse senedinin gerçek değerini, onu etkilediği düşünülen temel faktörlerden yararlanılarak bulmak ve bulunan değeri piyasa değeri ile karşılaştırarak yatırım konusunda karar vermektir" olarak tanımlarlar. Teknik analiz ise; "Belirli bir hisse senedi veya ortalamaya (ya da endekse) ilişkin fiyat, işlem hacmi vb. bilgilerin genellikle grafik formunda kaydı ve resimleştirilmiş bu geçmiş bilgilerden

gelecekteki olası trendi belirleme bilimidir" (Günak, 2007, s. 72). Perşembe (2001, s. 26), teknik analizi "Gelecekteki fiyat yönünü tahmin etmek amacıyla, öncelikle fiyat grafiklerinin kullanılması vasıtasıyla, piyasa hareketinin incelenmesi" olarak tanımlamıştır. Perşembe (2001, s. 26), teknik analizi "Gelecekteki fiyat yönünü tahmin etmek amacıyla, öncelikle fiyat grafiklerinin kullanılması vasıtasıyla, piyasa hareketinin incelenmesi" olarak tanımlamıştır.

Perşembe (2001, s. 49), temel ve teknik analiz arasındaki farkı "Temel analiz bir piyasa hareketinin arkasındaki *sebepleri*, teknik analiz ise *sonuçları* inceler" şeklinde tanımlamıştır. Bu tanımlamadan teknik analizin, temel analize yardımcı olan bir yöntem olduğunu söylemek mümkündür. Çünkü, temel analiz yatırım araçlarının fiyatlarını genel ekonomi, endüstri ve firma verilerinin incelenmesi ile belirler. Teknik analizde ise söz konusu yatırım araçlarının fiyatlarını piyasada ortaya çıkan fiyat değişmelerinden hareketle belirlenir (Aksoy ve Tanrıöven, 2007, s. 531). Bu iki analiz yöntemi birbiri ile karşılaştırıldığında, bazı avantajları ve dezavantajlarından söz edilebilir. Örneğin; kısa vadede gerçekleştirilen al-sat stratejisi, teknik analiz kullanımına daha yatkınken, uzun vadeli yatırım kararları göz önüne alındığında detaylı bir temel analiz çalışması amaca daha iyi hizmet edeceği düşünülmektedir (Ülgen ve Teker, 2005, s. 50).

3.2. TEKNİK ANALİZ VARSAYIMLARI VE DOW TEORİSİ

Hisse senedinin fiyatına etki yapabilecek her şeyin (temel veriler, politik etkiler, psikolojik durum vb.) hisse senedinin fiyatını etkilediğini varsayan teknik analiz, hisse senedinin teknik yönden borsadaki kuvveti veya zayıflığını ölçerek, hisse senedi fiyatının ileride nasıl bir değişim göstereceğini tahmin etmeye çalışır. Borsada işlem gören tüm finansal araçlar için kullanılabilen teknik analizin temel varsayımları şu esaslara dayanır (Afşar ve Afşar, 2010, s. 208-209):

- Hisse senetlerinin piyasa değeri sadece arz ve talebin karşılıklı etkileşimi ile belirlenir.
- Arz ve talep rasyonel ve rasyonel olmayan birçok faktör tarafından etkilenir.
- Hisse senedi fiyatları ve pazarın genel eğilimini gösteren endeksler trendler halinde hareket ederler.

- Arz ve talepte meydana gelen deęişimler, trendlerde deęişmelere neden olur. Bu deęişimler grafiklerle izlenebilir.
- Fiyat deęişimlerine baęlı olarak, grafiklerde ortaya çıkan bazı oluşumlar (formasyonlar) zaman içinde kendini tekrarlar.

Teknik analizin temel amacının fiyat ve hacim trendlerini saptamak ve hisse senetlerinin fiyatlarının dönüm noktalarını belirleyerek gelecekte hisse senedi fiyatlarının ne yönde gelişeceği konusunda yatırımcılara yol göstermek olduğuna daha öncede değinmiştik. Bu amaç doğrultusunda teknik analizde, hisse senetlerinin günlük, haftalık fiyatlarını, en yüksek ve en düşük fiyatları ve işlem hacmini gösteren grafikler hazırlanmaktadır ve hisse senedi fiyat oluşumu ile ilgili yarı logaritmik diyagramlar kullanılması, eğilim grafiklerinin analizi, hareketli-oyunak ortalamaların hesaplanması gibi çeşitli yöntemlerden yararlanarak istatistiki araştırmalar yapılmaktadır (Akgüç, 1998, s. 862).

Teknik analizin çıkış noktası Jones & Company'nin kurucularından Charles H. Dow tarafından 19. yüzyılın sonlarında öne sürülen Dow teorisidir. Charles Dow, teorisi ile ilgili herhangi bir yazılı metin hazırlamamıştır. Dow Teorisi, ilk defa W. P. Hamilton tarafından 1922'de çıkarılmış bir eserde yazılı ifadesini bulmuştur. Teori, Dow'un öğrencileri tarafından 1900'lerin ilk yıllarından beri uygulama alanında önemli bir yer tutmaktadır. Dow Teorisi, sermaye pazarı analizlerinde amacın pazarda fiyatların gidiş yönünü belirlemek olduğu görüşüne dayanmaktadır. Teori, şu iki şeyin önemine dikkat çeker; fiyat davranışları ve işlem hacmi verileri. Çünkü işlem hacminin büyüklüğü, yatırımcıların pazara olan ilgisinin bir göstergesidir. Bu nedenle, teori, işlem hacmi dikkate alınmadan, toplam olarak fiyatların ve bireysel olarak bir hisse senedi fiyatının aşağı ya da yukarı yönde deęişmesinin bir anlam ifade etmeyeceğini savunur (Sarıkamış, 2000, s. 302).

Teknik analizin büyükbabası kabul edilen Dow Teorisi altı temel varsayıma dayanmaktadır. Bu varsayımlara aşağıda kısaca değinilmiştir.

- ***Ortalamalar (endeksler) bize her şeyi anlatır.***

Teknik analizin temel varsayımlarından biri olan ortalamalar her türlü faktörü içerir ifadesi, hisse senedi arz ve talebini etkileyecek her türlü faktörün ve çok sayıda yatırımcının piyasa ile ilgili mevcut ve potansiyel varsayımlarının hisse senedi fiyatlarına yansıtacağı ilkesine dayanır (Civan, 2007, s. 248).

- ***Piyasalarda üç tür fiyat hareketi bulunur.***

Dow teorisine göre hisse senetlerinin üç temel hareketi vardır. Bunlara üç temel 'trend' de denilebilir. Bunlardan ilki ana trend'dir. Ana trend birkaç aydan birkaç yıla kadar sürebilir ve piyasaya hakim olan asıl eğilimi temsil eder. İkincisi; ikincil trend (veya tepki hareketi) haftalar veya aylarla ölçülür ve ana trendin aksi yönünde hareket eder. Üçüncüsü ise günlük dalgalanmalardır. Günlük dalgalanmalar ana trendden bağımsız olarak aynı veya ayrı yönde hareket edebilirler ve birkaç saatten iki ya da üç haftaya kadar uzayabilirler (Perşembe, 2001, s. 62).

- ***Ana trend üç aşamadan geçer.***

Dow teorisine göre hisse senedinin ana trendi yani birincil hareketi, boğa ve ayı piyasası olarak ifade edilmektedir. Fiyatların yükseldiği piyasa boğa piyasası, düştüğü piyasa ise ayı piyasası olarak adlandırılır. Boğa piyasası, kendi içinde üç aşamaya ayrılır. Birinci aşama fiyatların çok düşük seviyelerden yükselmeye başladığı dönemdir. Bu aşamada, piyasadaki durgunluğun değişeceğini hisseden bazı yatırımcılar, cesaretlerini kaybetmiş bazı yatırımcıların, hisselerini satın alırlar. Bu safhaya toplama safhası denir. İkinci aşama, işletme kazançlarındaki artış ve ekonomide canlanma sonucu fiyatların yükselmeyi devam ettirdiği aşamadır. Üçüncü aşamada ise, piyasadaki canlılığı fark eden yatırımcıların hisse senedi satın almak için borsaya hücum ettikleri aşamadır. Bu aşamada hisse senedi fiyatları hızla artar. Spekülatör ve profesyoneller ellerindeki hisseleri satarlar. Ayı piyasası da, boğa piyasası gibi üç aşamada incelenebilir. Boğa piyasasının üçüncü aşaması aynı zamanda ayı piyasasının birinci aşamasıdır. Ayı piyasasının ikinci aşaması, fiyatların çok düştüğü ve panik satışların yaşandığı bir safhadır. Bu aşamada alıcılar azalırken, satıcılar aceleci davranmaktadır. Üçüncü aşama ise paniğe kapılan yatırımcıların fiyatların iyice düşmesine neden oldukları aşamadır (Ceylan, 2007, s. 83).

- ***Ortalamalar veya piyasa göstergeleri birbirini onaylamalıdır.***

Piyasa hareketlerini kontrol eden çeşitli ortalamalar (endeksler) ve göstergeler aynı uyarı sinyali vermeli ve birbirini onaylamalıdır (Karapınar ve Zaif, 2009, s. 245).

- ***İşlem hacmi trend ile birlikte hareket eder.***

Fiyatlar mevcut bir ana trendin yönünde hareket ederken işlem hacmi artar, fiyatlar azaldığında işlem hacmi de azalır (Günak, 2007, s. 74).

- ***Yönü veya eğiminin değiştiğine dair sinyal gelinceye kadar her trend geçerlidir.***

Piyasanın tersine dönüşümünü gösteren sinyaller oluşmadığı sürece mevcut trend geçerlidir yani fiyatlar ana trendi takip eder (Karapınar ve Zaif, 2009, s. 247).

3.3. TEKNİK ANALİZDE KULLANILAN YÖNTEMLER

Teknik analizde bir firmanın değeri, sektörün ya da firmaların özelliklerinden (finansal yapısı, karlılık durumu, likidite durumu, pazar payı gibi) çok piyasanın bu özelliklere gösterdiği tepkiye göre belirlenir. Bu nedenle hisse senedi analizi yapılırken geçmiş fiyat hareketlerinden yararlanır ve bu hareketler; grafikler, formasyonlar, göstergeler gibi çeşitli teknik analiz araçları ile analiz edilerek hisse senetlerinin gelecekteki fiyat hareketleri tahmin edilir (Karapınar ve Zaif, 2009, s. 203).

Teknik analizin geçmiş fiyat hareketlerini izlerken yararlandığı ilk araç; *grafiklerdir*. Grafik çizimi için piyasada oluşan bilgilerden yararlanır. Bunlar; açılış fiyatları, seans içinde ulaşılan en yüksek ve en düşük fiyatlar ve kapanış fiyatlarıdır. Analizciler fiyat hareketlerini gösteren bu grafiklere bakarak hisse senetlerinin gelecek değerleri ile ilgili analiz yapma, yorumlama imkanı elde ederler. Teknik analizde fiyatların takibi temelde dört tür grafikte sağlanır. Bunlar; çizgi, çubuk, sıfır çarpı ve mum grafikleridir (Afşar ve Afşar, 2010, s. 211). İkinci araç; *formasyonlardır*. Formasyon, fiyatların zaman içerisinde göstermiş olduğu davranışların grafiklerde gösterilmesidir. Yani fiyat hareketlerindeki değişimler grafiklere farklı şekillerde yansır ve bu şekiller formasyon olarak adlandırılır. Teknik analiz arz ve talep dengesi değişmediği sürece fiyatların belirli bir yönde trend izleyeceğini varsayar. Ancak insanların psikolojik davranışları, ekonomik koşullar ve daha pek çok faktöre göre değişen arz-talep değişimleri, hisse senedi fiyat trendinin değişimine sebep olur. Hiçbir trend sonsuza kadar devam etmeyeceğine göre, trendde bir değişim olup olmayacağı oluşan formasyonlara bakılarak görülebilir. Trendin değişip değişmediğine göre formasyonlar; trend dönüşüm formasyonları ve ara-geçiş formasyonları (düzeltme formasyonları) olarak iki ana başlık altında incelenebilir (Korkmaz ve Ceylan, 2010, s. 323-324). Teknik analizde kullanılan diğer bir araç ise *göstergelerdir*. Geçmiş fiyat hareketlerinden yararlanarak, bugünün yorumlanması ve bu doğrultuda hisse senetlerinin gelecek fiyatlarının tahmin edilmesi olarak tanımlanan teknik analizde yatırımcıların tahmin yaparken kullandığı pek çok gösterge bulunmaktadır. Bu bölümde tez çalışmamızda

kullanılan teknik göstergelerin ne olduğu ve nasıl hesaplandığı hakkında bilgi verilecektir.

3.4. TEKNİK GÖSTERGELER (İNDİKATÖRLER, OSİLATÖRLER)

Teknik analistler fiyat hareketlerinin yönü ve kuvveti hakkında bilgi edinmek ve fiyat hareketlerinin analizini yapmak amacıyla teknik analiz göstergelerinden yararlanırlar.

Teknik analizde kullanılan göstergeler; kısa ve orta vadeli göstergeler, işlem hacmi ve performans göstergeleri (Çağırman, 1999) ya da trend takip edici göstergeler ve aşırı alım/aşırı satım göstergeleri gibi çeşitli sınıflara tabi tutulabilmektedir. Trend takip edici göstergeler trend yapan piyasalarda, aşırı alım aşırı satım göstergeleri de yan yana giden piyasalarda, sıkışma alanlarında veya tekdüze ve düşük eğimli trend yapan trend kanalı türü piyasalarda iyi sonuçlar verirler gibi bir genelleme yapılabilir (Perşembe, 2002, s. 25).

Teknik analizde bu göstergelerden yararlanılırken göz ardı edilmemesi gereken önemli bir unsur ise; gösterge hareketleri ile fiyat hareketi arasındaki *uyuşmazlıklardır*. Uyuşmazlık kavramı ilk kez 1890'ların sonunda Charles Dow tarafından ortaya atılmıştır. Gösterge hareketi ile fiyat hareketinin uyuşmaması teknik analizde elde edilen piyasa sinyallerinin en sağlıklısidir (Perşembe, 2002, s. 194). Fiyatların yapmış olduğu dip veya tepe seviyeler alçalırken, göstergenin yapmış olduğu dip veya tepe seviyeler yükseliyorsa, gösterge ile fiyatlar arasında bir uyuşmazlık var demektir ve fiyatların kısa bir süre sonra yukarı doğru döneceği düşünülür. Tersisi durumda ise, yani fiyatlarda yükselen dip ya da tepeler varken, göstergede dip ya da tepe seviyeler alçalmaya başlamışsa, fiyatlar kısa bir süre sonra aşağıya dönecektir. İşte bunlar pozitif ve negatif uyuşmazlıklar olarak değerlendirilmektedir (Çağırman, 1999, s. 292). Anlaşılacağı üzere uyuşmazlıklar genellikle bir trend dönüşünün habercisidir. Bu nedenle, her göstergede fiyat ile uyuşmazlık olup olmadığının tespit edilmesi ve varsa bu uyuşmazlığın nasıl bir sinyal verdiğinin anlaşılması gerekir (Perşembe, 2002, s. 195).

3.4.1. Hareketli Ortalamalar (Moving Averages - MA)

Hareketli ortalama, günlük fiyat dalgalanmalarının etkisini yumuşatan ve trend gelişiminin daha net olarak görülmesini sağlayan bir göstergedir. Sadece bir

günü değil belirli bir dönemin karakteristiğini yansıtır. Hareketli ortalama hisse senedi fiyatlarındaki aşırı değişkenliği düzelteren bir gösterge tekniğidir. Bu gösterge yöntemi, iniş çıkış akımlarının değişme durumu ve sürekliliği içinde destek ve direnç noktalarının nerede oluşacağına dair bilgi verir. Yatırımcılar, ortalamanın dönüşlerine ve fiyatın hareketli ortalamaya olan konumuna bakarak alım satım kararı alırlar (Afşar ve Afşar, 2010, s. 228).

Hareketli ortalamalarda al-sat sinyalleri tek hareketli ortalama ve fiyatın kesişmesi ya da iki veya daha fazla hareketli ortalama arasındaki kesişmelere göre belirlenir (Perşembe, 2002, s. 53). Teknik analizciler tarafından hisse senedi kapanış fiyatının, hareketli ortalamanın üzerine çıkması "AL", tersi durumda, kapanış fiyatının ortalamanın altına düşmesini ise "SAT" sinyali olarak yorumlanır. Bu yorum genellikle tekli hareketli ortalamalar kullanıldığında söz konusu olmaktadır. İkili hareketli ortalamaların kullanıldığı durumda ise, kısa vadeli hareketli ortalamanın, uzun vadeli hareketli ortalamayı yukarı doğru kesmesi "AL", kısa vadeli hareketli ortalamanın uzun vadeli hareketli ortalamayı aşağı doğru kesmesi ise "SAT" sinyali olarak yorumlanır (Günak, 2007, s. 178).

Hareketli ortalamalar sürelerine göre şu şekilde sınıflandırılmaktadır (Çağırman, 1999, s. 266):

1. Çok kısa vadeli hareketli ortalamalar 5 ile 15 gün arasındadır.
2. Kısa vadeli hareketli ortalamalar 15 ile 30 gün arasındadır.
3. Orta vadeli olanlar 30 ile 100 gün arasındadır.
4. Uzun vadeli hareketli ortalamalar da 100 ile 200 gün arasındadır.

3.4.1.1. Basit Hareketli Ortalama (Simple Moving Average - SMA)

SMA, belirlenen gün sayısı kadar geriye gidilerek o kadar günün kapanış değerlerinin toplanması ve seçilen gün sayısına bölünmesiyle hesaplanır. Örneğin; 5 günlük bir hareketli ortalama hesaplamak istendiğinde, hangi gün için 5 günlük hareketli ortalama hesaplanacaksa, o günün kapanışı da dahil olmak üzere 5 gün geriye giderek son 5 günün kapanışları toplanır ve 5'e bölünür ve o gün için 5 günlük SMA değeri tespit edilmiş olur (Perşembe, 2002, s. 34).

Hesaplanması:

$$SMA_i = \frac{(C_i + C_{i-1} + C_{i-2} + \dots + C_{i-n})}{n}$$

Formülde,

C = Kapanış fiyatı, (Close)

n = Seçilen gün sayısı

Formülde kullanılan kısaltmalar (C , n) çalışmanın geri kalan bölümlerinde de aynı ifadeleri tanımlamaktadır.

3.4.1.2. Üssel Hareketli Ortalama (Exponential Moving Average - EMA)

EMA hesaplanırken, önce hesaplama yapılacak zaman dilimi için basit hareketli ortalama hesaplanır, daha sonra düne kadar olan üssel hareketli ortalamasının bulunmuş olduğu varsayılarak (EMA_{t-1}), bugünkü oluşan fiyat ile EMA_{t-1} arasındaki farkın belirli bir yüzdesi, EMA_{t-1} 'e eklenir. Böylece bugünkü üssel hareketli ortalama elde edilir.

Hesaplanması:

$$EMA_i = EMA_{i-1} + [YO \times (C_i - EMA_{i-1})]$$

Formülde, YO = Yüzde oranı = $2 / (n+1)$ şeklinde hesaplanır.

EMA, hesaplanma tarzındaki karmaşıklık nedeniyle, bilgisayarlar yardımıyla hesaplanabilmektedir. Ancak en önemli özelliği, yakın geçmişteki verilere daha fazla ağırlık vermesinin yanı sıra mevcut tüm veri noktalarını da hesaba katmasıdır (Perşembe, 2002, s. 39).

3.4.1.3. Ağırlıklı Hareketli Ortalama (Weighted Moving Average - WMA)

WMA, belirlenen dönem içinde son günlere daha fazla ağırlık verilerek hesaplanır. Önce belirlenen gün sayısı kadar geriye gidilir ve o kadar günün kapanış

değerleri (son gün kapanış fiyatı, ondan bir önceki günün kapanış fiyatı, ondan bir önceki fiyat gibi) ortalaması seçilen gün değeri (ilk güne kadar birer gün eksiltilir) ile ayrı ayrı çarpılır elde edilen değerler toplanır. Ardından seçilen gün sayısının kendi içinde birer azaltılarak toplanmasından bulunan değere bölünür.

Hesaplanması:

$$WMA_i = \frac{[(n) \times C_i + (n-1) \times C_{i-1} + (n-2) \times C_{i-2} + \dots + C_n]}{[n + (n-1) + (n-2) + \dots + 1]}$$

3.4.2. Aroon Osilatörü (Aroon Oscillator)

Aroon Osilatörü, Tushar Chande tarafından geliştirilmiştir. Osilatör, fiyatların trend modundan, sıkışma moduna geçtiğini gösterir. Aroon osilatörü, MACD ve hareketli ortalamalar gibi trend izleme göstergelerinin ya da aşırı alım/aşırı satım indikatörlerinin bazı durumlarda yanlış ve yetersiz sinyalleri sonucu piyasanın bir trend içinde mi yoksa sıkışma halinde mi olduğunun ayırt edilemediği durumlarda bir kurtarıcı görevi görür (Borsanaliz, 22.02.2012).

Aroon osilatörü -100 ile 100 arasında bir değer alır ve iki indikatörden oluşur. Bunlardan ilki, belirlenen periyottaki en yakın en yüksek fiyatın görülmesinden bu yana geçen periyot sayısını gösteren *Aroon Up* (*Yukarı Aroon*); ikincisi ise, belirlenen periyottaki en yakın en düşük fiyatın görülmesinden bu yana geçen periyot sayısını gösteren *Aroon Down* (*Aşağı Aroon*) göstergesidir (Günak, 2007, s. 86).

Hesaplanması:

Aroon osilatörü hesaplanırken önce, Aroon Up ve Aroon Down indikatörleri hesaplanır.

$$AroonUp = \left[\frac{n - [\max(H_i)]}{n} \right] \times 100 \quad AroonDown = \left[\frac{n - [\min(L_i)]}{n} \right] \times 100$$

Formülde,

$max(H_i)$ = En yüksek günüçi yüksek değerin gerçekleştiği günden bugüne geçen süre

$min(L_i)$ = En düşük günüçi düşük değerin gerçekleştiği günden bugüne geçen süre

Aroon Up ve Aroon Down değerleri arasındaki fark ise Aroon Osilatörünün değerini belirler:

$$AroonOsc = AroonUp - AroonDown$$

Aroon Up ve Aroon Down, 0 ile 100 arasında dalgalanır. Verilen süre için, hisse senedi fiyatı yeni en yüksek değerler yaptığıında (en yüksek fiyattan kapanmışsa) Aroon Up değeri "100" değerini alır; hisse senedi düşüş yönünde hareket ederse Aroon Up "0" değerini alacaktır. Aroon Down verilen süre için yeni en düşük fiyatlar yaptığıında (en düşük fiyattan kapanmışsa), Aroon Down değeri "100"dür. Eğer, hisse senedi yükseliş yönünde hareket ederse Aroon Down "0" değerini alacaktır (Günak, 2007, s. 87).

Yorumlanması:

Aroon üç şekilde yorumlanmaktadır (Borsanaliz, 22.02.2012):

1. Aroon Up, 70 ile 100 arasında ısrarla kalırken Aroon Down göstergesi 0 ile 30 arasında değerler alıyorsa bu güçlü bir yukarı trend içinde olduğunun göstergesidir. Tersisi durumda, yani, Aroon Down ısrarla 70 ile 100 arasında kalırken Aroon Up 0 ile 30 değerleri arasında kalırsa, bu da hisse senedinin güçlü bir aşağı trend içinde olduğunu gösterir.

2. Aroon Up ve Aroon Down birbirlerine paralel hareket ediyorsa, bu bir sıkışma periyoduna işaret eder. Bu durumda, iki gösterge birbirlerini kesinceye veya 0-100 değerlerine ulaşmaya kadar, sıkışık piyasanın devam edeceği beklenmelidir.

3. Aroon Down çizgisinin Aroon Up'ı aşağıdan yukarıya kesmesi, bir zayıflık işaretidir ve fiyatlarda bir düşüş olacağını belirtir. Aroon Up çizgisinin Aroon Down'ı aşağıdan yukarıya doğru kesmesi, bir güçlenme belirtisidir ve fiyatların yükseliş trendine gireceği beklenmelidir.

3.4.3. Yönsel Hareket Göstergesi (Directional Movement Indicator - DMI)

Welles Wilder tarafından geliştirilen DMI göstergesi; piyasada bir trendin olup olmadığını, trendin yönünü, kuvvetini gösteren, giriş çıkış sinyalleri üreten ve diğer göstergelerle kullanıldığında farklı stratejiler geliştirilmesine olanak sağlayan çok yönlü bir göstergedir. DMI göstergesi; +DI, - DI ve ADX olmak üzere üç parçadan oluşmaktadır. +DI yukarı yönsel hareketi, -DI aşağı yönsel hareketi gösterir, yani trendin ne yönde değiştiğini gösterir (Perşembe, 2002, s. 160).

+DI ve -DI çizgilerinin elde edilme aşamaları şöyledir:

1. *aşama*: Yönsel hareket (DM) hesaplaması yapılır. DM, son günün işlem aralığının (en yüksek - en düşük) dünkü işlem aralığının dışında kalan kısmıdır. İç günlerde DM sıfırken, dış günlerde hem pozitif (+DM), hem negatif (-DM) olacaktır. Yönsel hareket için hangisi daha büyükse o alınır.

$$DM = \text{Bugünün en yükseği} - \text{Dünkü en yüksek}$$

2. *aşama*: Yönsel gösterge (DI)'nın hesaplanması için gerekli olan gerçek işlem aralığının (GİA) hesaplanması yapılır. GİA, o gün için aşağıdakiler hesaplandıktan sonra, şu üç değer en büyüğüdür:

-
- Son günün en yükseği - Son günün en düşüğü
- Son günün en yükseği - Dünkü kapanış
- Dünkü kapanış - Son günün en düşüğü

3. *aşama*: DI hesaplanır.

$$DI = DM / GİA$$

Bu değer pozitif ve negatif olabilir. Ardından +DI ve -DI değerlerinin n günlük ortalaması alınır. Hesaplama kullanılan n, genellikle, Wilder tarafından önerilen 14 gündür.

+DI ve -DI çizgilerinin yorumlanması

Bu iki çizginin (+DI ve -DI) kesişme yerlerinde alım satım kararı verilir. +DI, -DI'yı yukarı kestiğinde "AL", aşağıya kestiğinde ise "SAT" kararı verilir. Ancak bu alım satım kararlarına bakarken sinyallerin geç gelmesi ve yatay piyasalarda oluşan aşırı sayıdaki kesişmenin (dolayısıyla al ve sat sinyalinin) zararları ve işlem maliyetlerini artırmaları göz ardı edilmemelidir. Wilder, +DI ve -DI'nın bu iki zaafını örtmek için DMI'nın üçüncü çizgisi olan ADX çizgisini hesaplamıştır.

ADX çizgisinin hesaplanması:

ADX hesaplanırken önce Yönel hareket endeksi (DX) hesaplanır:

$$DX = (DI_{fark} / DI_{toplama}) \times 100$$

DI_{fark} ile DI_{toplama} şöyle hesaplanır:

$$DI_{fark} = [(+DI) - (-DI)]$$

$$DI_{toplama} = [(+DI) + (-DI)]$$

Ardından ADX, DX'in hareketli ortalaması (genellikle 14 günlük) alınarak hesaplanır (Perşembe, 2002, s. 161-169).

ADX çizgisinin yorumlanması:

ADX, +DI ve -DI ile birlikte kullanılır; +DI ve -DI senetteki fiyat hareketinin yönünü belirlerken, ADX senedin hareket yönündeki gücünü gösterir. Bu gösterge 0 ile 100 arasında bir değer alır. Aşırı alım ya da satım bölgelerini belirlemede kullanılmaz. ADX'in düşmesi ya da yatay bir seyir izlemesi trendin zayıfladığını, sıfır seviyeleri civarında bulunması yeni bir trendin başlangıcını göstermektedir (Çağırman, 1999, s. 341). Yani ADX, piyasadaki trendin ne tarafa olduğunu değil, trendin var olup olmadığını eğer varsa ne derece kuvvetli olduğunu gösterir (Perşembe, 2002, s. 170). ADX ile +DI ve -DI arasındaki ilişki (kesişme), bazen son derece sağlıklı sinyaller verir. Bu sayede optimum satış zamanı tespit edilebilir. Ancak, bu sinyaller grafiklerde istenilen sıklıkla belirmezler. Bu aşamada ADX'in

tepe yapıp geri döndüğünü tespit etmek gerekir. Wilder, bunun için momentum usulü bir çizgi olan ADXR'yi önermiştir (Perşembe, 2002, s. 172-175).

ADXR çizgisinin hesaplanması:

ADXR, ADX göstergesinden yararlanılarak hesaplanır.

$$ADXR = \frac{(ADX_b + ADX_{b-n})}{2}$$

Formülde,

ADX_b = Bugünün ADX değeri

ADX_{b-n} = n gün (genellikle 14) öncesinin ADX değeri

ADXR'nin yorumlanması:

ADX ve ADXR üst üste çizilerek kullanılmaktadır ve bu kullanım sırasında göstergelerin birbirlerine yaklaşp uzaklaşmaları söz konusudur. Birbirlerini kermeleri halinde alım-satım kararı verilmez. ADX'in ADXR'den uzaklaşması ise trendin gücü hakkında önemli fikirler vermektedir (Çağırman, 1999, s. 342).

En başta da açıklandığı gibi DMI çok yönlü bir göstergedir. Bu nedenle farklı disipline ait göstergeleri (trend takip edici veya aşırı alım/aşırı satım) kullanan yatırımcılar, bu göstergeleri hem trendin yönünü, hem kuvvetini hem de yatay piyasaları tespit edebilen DMI ile birlikte kullanarak hangi disiplinden gelen hangi göstergeye daha fazla ağırlık tanıyacaklarını ve hangi sinyalleri alıp hangilerini göz ardı edeceklerini rahatlıkla belirleyebilirler (Perşembe, 2002, s. 175).

3.4.4. Parabolik SAR (Parabolic SAR)

Welles Wilder tarafından oluşturulan Parabolik SAR, kısa ve orta vadede oluşan yön değişimlerinin tespitinde kullanılır. SAR sözcüğü, İngilizcedeki "Stop And Reversal" (Dur ve Geri dön) sözcüklerinin baş harfleridir. Parabolik SAR, yükselen ve alçalan trendlerde başarılı bir gösterge olmasına rağmen yatay trendlerde yanılma payı artmaktadır. Bu nedenle Wilder, Parabolik SAR'ın piyasalarda trend olup olmadığını gösteren ve var olan trendin gücünü de ölçebilen DMI göstergesiyle birlikte kullanılmasını önermiştir. Parabolik SAR göstergesi grafiklerde fiyat

çubuklarının altına veya üstüne işaretlenen noktalar şeklinde işaretlenir. Bu noktaların değeri ise uzun ve kısa pozisyonlarda farklı formüller kullanılarak belirlenir (Perşembe, 2002, s. 116-121).

Hesaplanması:

Parabolik SAR uzun ve kısa pozisyonlarda aşağıdaki formüller yardımıyla hesaplanmaktadır.

$$SAR_{uzun\ pozisyonda} = SAR_n + HF \times (uzun\ pozisyondayken\ erişilen\ en\ yüksek\ fiyat - SAR_n)$$

$$SAR_{kısa\ pozisyonda} = SAR_n - HF \times (SAR_n - kısa\ pozisyondayken\ erişilen\ en\ düşük\ fiyat)$$

Yukarıdaki formüllerde,

$$SAR_n = \text{Şuan ki periyod}$$

HF = Hızlanma faktörü, ilk periyod için 0.02 olarak belirlenmiştir. Bundan sonraki periyodlarda yeni bir en yüksek ya da en düşük görüldüğünde, yeni en yüksek ya da en düşüğün görüldüğü her periyod için 0.02 artırılır. 0.20'ye ulaştıktan sonra ise artırılmayıp aynı değerde bırakılır. Yeni bir en yüksek ya da en düşük olmaması halinde ise aynı değerinde kalır.

Yorumlanması:

Parabolik SAR, genel olarak, fiyatlar SAR göstergesinin altına düştüğünde "SAT", üstüne çıktığında ise "AL" şeklinde yorumlanır (Günak, 2007, s. 193).

Parabolik SAR, daha çok açığa satış işlemlerinin yasal olduğu piyasalarda kullanılmak üzere hazırlanmıştır. Bu nedenle bizim borsamızda normal alım satım kararları için kullanılmamalıdır. Ayrıca bu gösterge alım ve satımlarda geç sinyaller vermektedir. Bu nedenle diğer teknik göstergeleri tamamlayıcı ve yardımcı bir faktör olarak düşünülmelidir (Çağırman, 1999, s. 347-348).

3.4.5. Hareketli Ortalamaların Birleşmesi-Ayrılması Göstergesi (Moving Average Convergence-Divergence - MACD)

İlk kez 1979 yılında Gerald Appel tarafından geliştirilen MACD göstergesi, teknik analizin en istikrarlı göstergelerinden biri kabul edilir. Gösterge, biri hızlı (12), diğeri yavaş (26) olmak üzere iki adet üssel hareketli ortalamadan oluşur ve içeriğinde bulunan hareketli ortalamaların birbirlerine yakınlaşma ve uzaklaşma miktarını inceleyerek trend yönünü tahmin etmeye çalışır.

Hesaplanması:

MACD çizgisi, 12 günlük üssel hareketli ortalama ile 26 günlük üssel hareketli ortalamanın arasındaki fark alınarak elde edilir.

$$MACD = 12 \text{ günlük EMA} - 26 \text{ günlük EMA}$$

Formülden de anlaşılacağı üzere MACD çizgisi, sıfır eksenini etrafında dalgalanır ve bu değerinin alt veya üst sınırı yoktur (Perşembe, 2002, s. 100-102).

Yorumlanması:

26 günlük üssel hareketli ortalama artarken 12 günlük üssel hareketli ortalama azalıyorsa aradaki fark negatif olacağından gösterge sıfır ekseninin altına düşer ve bu bölge aşırı satım bölgesini gösterir. Bunun tersi durumda, yani 26 günlük üssel hareketli ortalama azalırken 12 günlük üssel hareketli ortalamanın arttığı durumda ise gösterge sıfırın üstüne çıkacağından aşırı alım bölgesini gösterecektir (Konuralp, 2005, s. 168).

Gerald Appel, bu göstereye, trendlerdeki kuvvetlenme ve zayıflamanın zamanlamasını tespit etmek amacıyla 9 günlük üssel hareketli ortalama çizgisini dahil etmiştir. Bu çizgiye Sinyal veya Tetik çizgisi denir. Sinyal çizgisi MACD'daki dalgalanmaları ve MACD'ın tepe yapıp yapmadığını gösterir (Perşembe, 2002, s. 100). Al-sat sinyalleri ise daha hızlı olan MACD ve yavaş olan sinyal çizgisinin kesiştiği noktalarda oluşturulur. Buna göre sinyal çizgisi MACD'ı aşağı yönde kestiğinde "AL", yukarı yönde kestiğinde "SAT" koşulu oluşur. MACD ve sinyal çizgisinin sıfır referans çizgisinin üzerine çıkması piyasadaki çıkışın devam edeceğinin ve daha güçlü bir piyasanın oluştuğunun habercisidir (Çağırman, 1999, s. 325).

Trend takip edici bir gösterge olan MACD'nin en önemli özelliklerinde biri uyuşmazlık üretebiliyor olmasıdır. MACD, pozitif uyuşmazlık durumunda "AL", negatif uyuşmazlık durumunda "SAT" sinyali verir. MACD'daki uyuşmazlık sinyalleri hayli etkili olmasına rağmen, mevcut trende karşı alınacak her kararı diğer göstergelerle de desteklemeli ve asla tek bir göstergeye dayalı kararlar alınmamalıdır (Perşembe, 2002, s. 114-115).

3.4.6. Momentum Göstergesi (Momentum Indicator)

Kullanımı çok eskilere dayanan momentum göstergesini ilk kez Welles Wilder 1978 baskılı "New Concepts in Technical Trading Systems" isimli kitabında işlemiştir (Perşembe, 2002, s. 149). Momentum hız demektir. Teknik analizde erken uyarı veren bir gösterge olarak kabul edilen momentum, senedin belirli bir zaman dilimi içerisinde değerinin ne kadar yükseldiğini ya da ne kadar düştüğünü belirler (Çağırman, 1999, s. 306).

Hesaplanması:

$$Momentum = \left(\frac{C_i}{C_{i-n}} \right) \times 100$$

Yorumlanması:

Momentum göstergesi kısa vadeli hareketlerin izlenmesinde kullanıldığı için genelde seçilen gün sayısı 30'un altındadır. Momentum için referans çizgisi olarak 100 değeri kabul edilir ve al-sat sinyalleri buna göre yorumlanır. Göstergenin 100 eksenini yukarı doğru geçmesi "AL", aşağı doğru geçmesi ise "SAT" sinyali olarak algılanır. Momentum'da aşırı alım ve aşırı satım bölgelerinin tespiti için kabul edilen sınırlar üst sınır için 120, alt sınır için 80'dir. Göstergenin bu üst ve alt sınırlardan daha yukarı çıkması ya da aşağı inmesi aşırı alım-satım bölgeleri olarak kabul edilir (Korkmaz ve Ceylan, 2010, s. 344).

Momentum göstergesinde unutulmaması gereken önemli bir unsur; tıpkı diğer göstergelerde olduğu gibi uyuşmazlıkları değerlendirmektir. Momentum erken uyarı verebilen bir göstergedir ve son günlerdeki fiyatları, geçmiş günlerdeki fiyatlarla kıyaslayabilen bir özelliği olduğu içinde, fiyatların bundan sonraki yönleri

ile ilgili deęişimleri önceden haber verebilmektedir. Ancak momentumun zaman zaman geleceęi haber veren bir gösterge olması gibi özellięi de vardır. Burada dikkat edilmesi gereken, eęer momentum göstergesi geçmişte yapmış olduęu tepelere oranla daha yüksek bir yerde zirve yapmış ise ve buradan da aşıęıya dönmüş olsa dahi satış yapılmamalıdır. Fiyatlar göstergenin yapmış olduęu böyle bir tepeden sonra, çok daha yükseklerle gidebilmektedir (Çaęırman, 1999, s. 306).

3.4.7. Göreceli Güç Göstergesi (Relative Strenght Index - RSI)

Aşırı alım/aşırı satım göstergeleri arasında yaygın olarak kullanılan RSI, ilk kez Welles Wilder'ın 1978 baskılı "New Concepts in Technical Trading Systems" isimli kitabında açıklanmıştır (Perşembe, 2002, s. 132). RSI, hisse senedi fiyatlarının iç gücünü ölçer ve gösterge hesaplanırken yukarı doğru fiyat hareketi ortalaması ile aşıęı doğru fiyat hareketi ortalaması alınarak fiyatların hangi yöne gideceęi belirlenir.

Hesaplanması:

$$RSI = 100 - [100 / (1 + Ortalama yukarı hareket / Ortalama aşıęı hareket)]$$

Ortalama yukarı hareket hesaplanırken (örneğin 14 günlük); son 14 gün içindeki senedin fiyatının arttıęı günlerdeki kapanış fiyatlarının ortalaması bulunur. Örneęin, son 14 günlük RSI hesaplamasında senet, son 5 gün artış kaydetti ise bu beş günün kapanış fiyatları toplanarak 5'e bölünür. Ortalama aşıęı hareket ise aynı şekilde belirlenen gün sayısı içerisinde senet fiyatlarının düştüęü günlerin kapanış fiyatlarının ortalaması alınarak hesaplanır (Çaęırman, 1999, s. 298).

Yorumlanması:

RSI, fiyatlarda oluşan hareketlere göre 0 ile 100 arasında dalgalanır ve iki şekilde yorumlanır; Gösterge, referans seviyesi olan 50 sınırındayken dengededir. Göstergenin referans seviyesini yukarı yönde kesmesi "AL", aşıęı yönde kesmesi "SAT" olarak yorumlanır. Dięer taraftan RSI'nın 70'in üzerinde olması "SAT", 30'un altında olması ise "AL" sinyali olarak algılanır (Korkmaz ve Ceylan, 2010, s. 345). Ayrıca, RSI'da 70 çizgisinin üzeri aşırı alım, 30 çizgisinin altı ise aşırı satım bölgelerini temsil eder. Dięer göstergelerde olduęu gibi RSI ile fiyatlar arasındaki

uyuşmazlıklara dikkat edilmelidir. Bunun yanı sıra RSI göstergesi üzerindeki trend destek ve dirençleri çok önemlidir. Fiyatlarla göstergelerdeki destek ve direnç seviyeleri ile bunların kırılmaları arasındaki bağ dikkatle incelenmelidir (Çağırman, 1999, s. 298).

3.4.8. Stokastik Osilatörü (Stochastic Oscillator - SO)

Stokastik osilatörü, tıpkı RSI gibi bir aşırı alım/aşırı satım göstergesidir. Gösterge, George C. Lane tarafından, bir yukarı trendde kapanışların günlük işlem aralığının üst taraflarında, bir aşağı trendde ise alt taraflarında yoğunlaşacağı varsayımı üzerine oluşturulmuştur (Perşembe, 2002, s. 142). Buna göre, eğer son günün kapanış fiyatı, günün en yüksek fiyatına yakın bir fiyatsa fiyatlarda yükselmenin devam edeceği, günün en düşük fiyatına yakın bir fiyatsa fiyatlarda düşmenin devam edeceği kabul edilir (Konuralp, 2005, s. 166).

SO, kesiksiz bir çizgi olarak gösterilen %K eğrisi (ana eğri) ve aynı grafik üzerine noktalı çizgilerle gösterilen %D eğrisi olarak adlandırılan iki ayrı eğri ile gösterilir. %D, %K'nın bir hareketli ortalamasıdır (Günak, 2007, s. 247).

Hesaplanması:

Stokastik osilatörü, üç aşamada hesaplanmaktadır (Perşembe, 2002, s. 142-143):

1. *aşama*: Ham %K'nın hesaplanması.

$$\text{Ham } \%K_t = (\text{Kapanış}_t - \text{En düşük}_n) / (\text{En yüksek}_n - \text{En düşük}_n) \times 100$$

Ham %K_t: En son periyodun Ham %K'sı

Kapanış_t: En son periyodun kapanışı

En yüksek_n ve En düşük_n: Son n periyodun en yüksek ve en düşük değeri

2. *aşama*: Hızlı %K'nın hesaplanması.

$$\%K_t = [(\%K_{t-1} \times 2) + \text{Ham } \%K_t] / 3$$

%K_t: En son periyodun Hızlı %K'sı

%K_{t-1}: Bir önceki periyodun Hızlı %K'sı

3. aşama: Hızlı %D'nin hesaplanması (Hızlı %D eğrisi, hızlı %K eğrisinin üç periyotluk hareketli ortalamasıdır).

$$\text{Hızlı \%D}_t = [(\%D_{t-1} \times 2) + \text{Ham \%K}_t] / 3$$

$\%D_t$: En son periyodun Hızlı %D'si

$\%DK_{t-1}$: Bir önceki periyodun Hızlı %D'si

Günümüzde göstergenin fiyat hareketlerine karşı aşırı duyarlı olması nedeniyle hızlı stokastik gösterge yerine yavaş stokastik gösterge kullanılmaktadır. Yavaş stokastik gösterge aşağıdaki formül ile hesaplanmaktadır (Perşembe, 2002, s. 143).

$$\text{Yavaş \%K} = \text{Yavaş \%D}$$

$$\text{Yavaş \%D}_t = [(\text{Yavaş \%D}_{t-1} \times 2) + \text{Yavaş \%K}_{t-1}] / 3$$

Yavaş \%D_t : En son periyodun yavaş %D'si

Yavaş \%D_{t-1} : Bir önceki periyodun yavaş %D'si

Yavaş \%K_t : Bir önceki periyodun Yavaş %K'si

Yorumlanması:

SO, 0 ve 100 arasında hareket eder ve aşırı alım/satım bölgeleri 20 ve 80 çizgilerine göre belirlenir. 20 seviyesinin altı aşırı satış bölgesi, 80 seviyesinin üstü aşırı alım bölgesini temsil eder (Çağırman, 1999, s. 284). Stokastik göstergede iki farklı şekilde al-sat kararı verilir; bunlardan ilki, göstergenin 20 seviyesinin altına düşüp tekrar üstüne çıktığı zaman "AL", 80 seviyesinin üzerine çıkıp tekrar altına düştüğünde "SAT", diğeri ise; %K çizgisi, %D çizgisini yukarı doğru kestiğinde "AL", aşağı doğru kestiğinde "SAT" şeklindedir (Günak, 2007, s. 247-248). Göstergenin yorumlanmasındaki en önemli unsur ise, fiyatlarla olan negatif ya da pozitif uyumsuzlukları görüp, değerlendirebilmektir.

3.4.9. Stokastik Momentum Endeksi (Stochastic Momentum Index - SMI)

William Blau tarafından geliştirilen SMI'nın, SO'dan farkı; SO hisse senedi kapanış fiyatıyla belirlenen süre içindeki fiyat aralığını karşılaştırırken; SMI, hisse senedi kapanış fiyatıyla belirlenen süre içindeki fiyat aralığının orta noktasını karşılaştırmaktadır.

SMI, -100 ve +100 aralığında dalgalanır. SMI, iki şekilde yorumlanır. Bunlardan ilki, göstergenin sinyal seviyesini yukarı veya aşağı kesmesine göre alım veya satım yapılabileceği şeklindedir; sinyal seviyesini yukarı doğru kestiğinde "AL", aşağı yönde kestiğinde "SAT" sinyali ürettiği varsayılır. Diğer ise gösterge, -50'nin altından yukarı döndüğünde "AL", +50'nin üzerinden aşağı döndüğünde "SAT" sinyali verdiği şeklindedir (Günak, 2007, s. 243-247).

3.4.10. Williams'ın %R Göstergesi (Williams' %R)

İlk kez Larry Williams'ın "How I Made One Million Dollars Last Year Trading Commodities" isimli kitabında ortaya atılan %R, tıpkı RSI ve SO gibi bir aşırı alım/satım göstergesidir. %R ismindeki R harfi İngilizce Range kelimesi için kullanılmıştır ve işlem aralığını yani seçilen periyodun en yükseği ile en düşüğü arasındaki mesafeye ifade eder (Perşembe, 2002, s. 146).

Hesaplanması:

%R hesaplanırken, öncelikle bir zaman periyodu belirlenir bu periyot genellikle 14 gün olarak alınır. Daha sonra aşağıdaki formül ile hesaplanır (Çağırman, 1999, s. 291):

$$\text{Williams' \% R} = \frac{[(n \text{ gün içindeki en yüksek fiyat} - \text{Bugünkü kapanış fiyatı}) / (n \text{ gün içindeki en yüksek fiyat} - n \text{ gün içindeki en düşük fiyat})] \times (-100)}$$

Yorumlanması:

%R, 0 ile -100 arasında dalgalanır. Göstergenin -80 seviyesinin altına inmesi aşırı satım yapıldığını, -20 seviyesinin üzerine çıkması ise aşırı alım yapıldığını gösterir (Çağırman, 1999, s. 291). %R'ın kullanımının Stokastik'ten hiçbir farkı yoktur. Tıpkı Stokastik'te olduğu gibi, aşırı alım bölgesinde satış, aşırı satım bölgesinde alım yapılır (Perşembe, 2002, s. 148). Bununla birlikte, %R, -80

seviyesinin altından yukarı doğru döndüğünde "AL", -20 seviyesinin üzerinden aşağı doğru döndüğünde ise "SAT" koşulu oluşur (Günak, 2007, s. 277). %R, yatay gelişen trendlere daha iyi uyum sağlar. Ancak en ufak fiyat hareketlerinde dahi çok hızlı bir şekilde aşırı alım ve satım bölgelerine ulaşırlar ve senet fiyatları yukarılara gitse bile, göstergeler belli aralıklarda hareket ettiği için buralardan aşağıya dönerler. Bu yüzden bu tipteki göstergeler tek başına alım ve satım kararı vermekte kullanılmamalıdır. Mutlaka diğer göstergelerden yararlanmak suretiyle bu kararlar verilmelidir (Çağırman, 1999, s. 293). Ayrıca her göstergede olduğu gibi gösterge ile fiyatlar arasındaki uyumsuzluklara dikkat edilmelidir.

3.4.11. Mal Kanal Endeksi (Commodity Channel Index - CCI)

Amerikalı Teknik Analist Donald Lambert tarafından geliştirilen CCI, başlangıçta mal piyasaları için kullanılmış sonraları hisse senedi piyasalarında da başarılı bir şekilde kullanılmaya başlanmıştır. Çıkan ya da düşen piyasalara nazaran, yatay piyasalarda çok daha başarılı bir gösterge olan CCI, aşırı alım ve satım bölgelerini de çok güzel gösteren bir indikatördür (Çağırman, 1999, s. 311-312).

Hesaplanması:

CCI, üç aşamada hesaplanır:

1. *aşama:* Hisse senedi fiyatlarından elde edilen basit hareketli ortalamaların sapmaları bulunur. Sapma hesaplanırken bulunacak değerler (-) olsa dahi (+) kabul edilir. Her gün için sapma değerleri aşağıdaki formülle hesaplanır:

Sapma = Kapanış veya Ort. Fiyat - Kapanış veya Ort. Fiyatın Hareketli Ort.
(Ortalama fiyat = günün en yüksek değeri + en düşük değeri + kapanış fiyatı / 3)

2. *aşama:* Her gün için sapma ortalaması hesaplanır:

Sapma Ortalaması = Sapmaların Toplamı / Gün Sayısı

3. *aşama:* CCI hesaplanır. CCI değerleri (+) veya (-) değerler olarak bulunur.

CCI = Sapma / Sapma Ortalaması × 0.015

Formüldeki 0.015 katsayısı ise sabit kabul edilir.

Yorumlanması:

Kısa vadedeki trend değişikliklerini izleyen CCI, +100 ile -100 arasında bir değer alır. Bu teknik gösterge çok hareketli olmasından dolayı küçük fiyat değişikliklerinde bile +100 ve -100 olan sınır eksenlerinden (referans çizgilerinden) rahatça sapabilmektedir. CCI, +100'ün üzerinde ise bu fiyatların aşırı yükseldiğini, -100'ün altında olması ise fiyatların aşırı düştüğünü gösterir. CCI, +100 aştığında alım yapılmamalıdır (Borsaanaliz, 15.01.2012).

CCI göstergesinin bir başka kullanım tarzı da, göstergenin tek referans çizgisi ile çizilmesi (sıfır seviyesi) suretiyle alım satım kararlarının verilmesidir. Buna göre; gösterge sıfır referans çizgisini yukarı yönde kestiğinde "AL", aşağı doğru kestiğinde ise "SAT" kararı verilmektedir (Çağırman, 1999, s. 314).

Diğer göstergelerde olduğu gibi uyumsuzluklar CCI göstergesi içinde önemlidir. Fiyatlar yükselme eğiliminde iken yani bir öncekine göre daha yukarıda iki tepe gösterirken, CCI tersine alçalan iki tepe şeklinde ortaya çıkmış ise bu fiyatların düşeceğini gösterir. Fiyatlar alçalan iki tepe gösterirken CCI, yükselen iki tepe şeklinde ise fiyatlar yükselecektir. Bu nedenle CCI, +100 seviyesini aşağı yönde kestiğinde "SAT" sinyali, -100 seviyesini yukarı yönde kestiğinde "AL" sinyali verdiği kabul edilir (Konuralp, 2005, s. 170).

3.4.12. Chande Momentum Osilatörü (Chande Momentum Oscillator - CMO)

CMO, Tushar Chande tarafından, "saf momentum"u elde etmek amacıyla geliştirilen bir aşırı alım/satım göstergesidir. +50 seviyesinin üzeri aşırı alım, -50 seviyesinin altı da aşırı satım bölgeleri olarak tanımlanır. -50 seviyesinden alım, +50 seviyesinden satım yapılmalıdır. Gösterge sıfır çizgisinin üzerine çıktığında kesin alım, altına düştüğünde ise kesin olarak satım yapılmalıdır (Günak, 2007, s. 103).

CMO pek çok durumun analizinde kullanılabilir. Bu durumlardan bazıları şunlardır; CMO göstergesinde çizilen bir hareketli ortalama ile senede giriş, çıkış kurallarını kontrol etmek mümkündür. Örneğin, 20 günlük CMO kullanılıyorsa, 9 günlük bir hareketli ortalama iyi bir sinyal hattı oluşturabilir. Böyle bir durumda CMO 9 günlük ortalamayı yukarı kestiğinde "AL", aşağı kestiğinde "SAT" şeklinde yorumlanacaktır. CMO aynı zamanda hisse senedinin trend oluşturma derecesini tayin amacıyla da kullanılabilir. CMO arttıkça trend güçlenmektedir. Düşük CMO değerleri hisse senedinin düzeltme bölgelerini gösterir. CMO göstergesi, pozisyon

açma ve kapatma durumlarını belirlemek için de kullanılabilir. CMO yüksek değerlerde ise pozisyon aç, düşük değerlerde ise kapat şeklinde yorumlanmaktadır (Hisse.net, 01.03.2012).

3.4.13. Bollinger Bantları (Bollinger Bands - BB)

John Bollinger tarafından geliştirilen Bollinger bantları (Günak, 2007, s. 94), fiyat değişimlerini izleyen, fiyat ve gösterge hareketlerini karşılaştırmak için kullanılan alım-satım kanallarıdır (Aksoy ve Tanrıöven, 2007, s. 546). Temel mantığı; basit bir şekilde hazırlanmış olan bir hareketli ortalamanın fiyatların ortasından geçmesi yoluyla fiyat hareketlerinin alt ve üst sınırlarının tespit edilmesi esasına dayanır (Çağırman, 1999, s. 275).

Hesaplanması:

Bollinger bantları aşağıdaki gibi hesaplanır (Perşembe, 2002, s. 91):

$$1. \text{ aşama: Sapma} = \left[(C_1 - MA)^2 + (C_2 - MA)^2 + \dots + (C_n - MA)^2 \right] / n$$

$$2. \text{ aşama: Standart Sapma} = \text{Sapmanın Kare Kökü}$$

$$\sqrt{\left[(C_1 - MA)^2 + (C_2 - MA)^2 + \dots + (C_n - MA)^2 \right] / n}$$

$$3. \text{ aşama: Üst Bant} = \text{SMA} + 2 \text{ Standart Sapma}$$

$$\text{Orta Bant} = \text{SMA}$$

$$\text{Alt Bant} = \text{SMA} - 2 \text{ Standart Sapma}$$

$$\text{SMA} = 20 \text{ günlük basit hareketli ortalama}$$

Yorumlanması:

Bollinger bantları fiyatlardaki hareketliliğe bağlı olarak daralır ve genişler. Geniş fiyat hareketliliğinin olduğu dönemlerde bant genişlerken, fiyatlardaki hareket mesafesi daraldıkça bant daralır (Çağırman, 1999, s. 275). Bollinger göstergesinde fiyatların Bollinger üst banda ulaşması "SAT" sinyali, alt banda ulaşması ise "AL" sinyali kabul edilir. Bunun yanı sıra fiyatlardaki değişime göre önemli ölçüde daralıp genişleyebilen Bollinger bantlarının önemli ölçüde daralması, önemli bir trend

değişikliğinin göstergesidir. Bu daralmanın ardından fiyatların Bollinger üst bandını kırması sert bir yükselişin, alt bandını kırması ise keskin bir düşüşün göstergesi kabul edilir (Korkmaz ve Ceylan, 2010, s. 346).

3.4.14. Ortalama Doğruluk Aralığı (Average True Range - ATR)

ATR, fiyatlardaki dalgalanma boyutunu ölçer. Fiyatlar hızla aşağı ya da yukarı hareket ettiğinde gösterge artar. ATR göstergesinin artması, fiyatlardaki değişkenliğin arttığı tersi bir durumda ise fiyatlardaki değişimin düştüğünün habercisidir. Fiyatların yatay hareket etmesi durumunda ATR göstergesi düşer. ATR'nin yatay hareket etmeye başlaması bir süre sonra aşağı ve yukarı ani fiyat hareketlerinin başlayabileceğinin habercisidir (Günak, 2007, s. 91).

Hesaplanması:

$$ATR_i = \max \{ DO_1, DO_2, DO_3 \}$$

Formülde,

DO = Doğruluk oranı. Üç kritere göre hesaplanır:

$$DO_1 = |H_i - L_i| \quad DO_2 = |C_{i-1} - H_i| \quad DO_3 = |C_{i-1} - L_i|$$

H_i = Günün en yüksek fiyatı

L_i = Günün en düşük fiyatı

C_{i-1} = Bir önceki günün kapanış fiyatı

Formülde kullanılan kısaltmalar (H_i , L_i) çalışmanın geri kalan bölümlerinde de aynı ifadeleri tanımlamaktadır.

3.4.15. Chaikin'in Dalgalanma Göstergesi (Volatility, Chaikin's)

Chaikin tarafından volatilitenin tespiti için geliştirilmiş olan bu gösterge, en yüksek fiyat ile en düşük fiyat seviyeleri arasındaki alanın geçmişteki herhangi bir günle olan ilişkisini değerlendirmek için tasarlanmıştır. Bu gösterge, daha çok diğer

teknik göstergelere ve sistem analizlerine yardımcı olacak ek bir gösterge niteliği taşır, alım-satım için kullanılmaz (Çağırman, 1999, s. 336).

Hesaplanması:

Hisse senedinin yüksek ve düşük fiyatları arasındaki farkı mukayese eden Dalgalanma göstergesi hesaplanırken öncelikle günlük yüksek ve düşük fiyatlar arasındaki farkın hareketli ortalaması hesaplanır, ardından çıkan sonucun yüzdesel değişim oranı (ROC) bulunur (Günak, 2007, s. 265).

$$A_i = H_i - L_i \quad B_i = (YO \times A_i) + (1 - YO) \times B_{i-1}$$

$$D_i = B_i - B_{i-m}$$

Formülde,

A_i = Günün en yüksek ve düşük fiyatı arasındaki fark

B_i = Günün en yüksek ve düşük fiyatı arasındaki farkın üssel hareketli ort.

D_i = Değişim Oranı (ROC)

YO = $2/n+1$, n = Üssel hareketli ortalama için seçilen gün sayısı

m = Değişim oranı (ROC) için seçilen gün sayısı

Bu hesaplamalar sonrasında Dalgalanma göstergesi şu formül ile elde edilir:

$$VOLCHA_i = \left(\frac{D_i}{D_{i-m}} \right) \times 100$$

Göstergede genel olarak hareketli ortalama süresi 10-15 gün, ROC değeri de 8-12 gün arasında kullanılır. Ancak bu değerler senede göre daha fazla artırıp azaltılabilir (Çağırman, 1999, s. 337).

Yorumlanması:

Piyasa tepe yaptığında artan volatilitenin, dip yaptığında da düşen volatilitenin eşlik ettiği farzedilir. Kısa bir periyot sonunda Dalgalanma indikatöründe artış, dibin yakın olduğunu; uzun bir süre sonunda Dalgalanma göstergesinde düşüş, tepeye yaklaşıldığını gösterir (Günak, 2007, s. 265). Bu

göstergenin değerinin çok arttığı durumlarda senetteki risk faktörü artar. Göstergenin bir önceki zirvesi baz alınarak kesinlikle aşırı alım bölgesinde olduğuna dair bir yorum yapılmamalıdır. Ancak her senet için değişik gün sayıları kullanmak suretiyle geçmişle ilgili kıyaslamaları yapılmalıdır. Volatilitenin düşük olduğu seviyelerde yapılan alımlarda risk çok az olacaktır (Çağırman, 1999, s. 337).

3.4.16. Toplama/Dağıtım Endeksi (Accumulation/Distribution Index - A/D)

A/D göstergesi, işlem hacmi ve hisse senedi fiyatlarındaki değişimin birleştirildiği, fiyatların trendinin sürüp sürmeyeceği konusunda fikir veren bir teknik göstergesidir. A/D göstergesinin temel mantığı, bir fiyat hareketi ne kadar çok işlem miktarı ile gerçekleşirse o kadar güvenilir olduğu şeklindedir (Çağırman, 1999, s. 366).

Hesaplanması:

$$A/D = \left[\frac{(C_i - L_i) - (H_i - C_i)}{H_i - L_i} \right] \times V_i$$

Formülde,

V_i = İşlem hacmi

Formülden elde edilen sonuç pozitif ise göstergeye ilave edilir. Ters durumda bulunan değer göstergeden çıkarılır. Hergün için bu işlem uygulanır.

Yorumlanması:

A/D'nın yükselmesi hisse senedinin toplandığını, düşmesi ise senedin dağıtıldığını gösterir (Çağırman, 1999, s. 368). Gösterge bir dip yapıp yukarıya dönerek yükselmeye başlarsa "AL" kararı, belli bir tepe yaptıktan sonra düşmeye başlarsa "SAT" kararı alınır (Günak, 2007, s. 84). A/D göstergesi izlenirken de diğer göstergelerde olduğu gibi senet fiyatları ile olan uyumsuzluklara dikkat edilmelidir.

3.4.17. Denge İşlem Hacmi Göstergesi (On Balance Volume - OBV)

OBV, bir senede ya da varlığa para girişinin olup olmadığını belirleyen göstergedir. İşlem hacmini fiyat hareketleri ile karşılaştırır. Göstergenin temel mantığı, fiyatlardaki artış sırasında oluşan işlem miktarlarının toplanması, fiyatlardaki düşüş sırasında oluşan işlem miktarlarının toplamdan çıkartılmasıdır. (Korkmaz ve Ceylan, 2010, s. 345).

Hesaplanması:

OBV hesaplanmadan önce başlangıç günündeki senet fiyat ve işlem hacimleri belirlenir. Ardından gösterge aşağıda belirtilen durumlara göre hazırlanır (Çağırman, 1999, s. 350):

1. *durum*: Bugünkü kapanış fiyatı ile dünkü kapanış fiyatı eşit ise;

$$\text{Bugünkü OBV değeri} = \text{Dünkü OBV değeri}$$

2. *durum*: Bugünkü kapanış fiyatı, dünkü kapanış fiyatından daha yüksek ise;

$$\text{OBV} = \text{Dünkü OBV} + \text{Bugünkü İşlem Miktarı}$$

3. *durum*: Bugünkü kapanış fiyatı, dünkü kapanış fiyatından daha düşük ise;

$$\text{OBV} = \text{Dünkü OBV} - \text{Bugünkü İşlem Miktarı}$$

OBV, yükselişlerde hacmin arttığı, düşüşlerde hacmin azaldığı esasına dayanır. Yükselen trendlerde işlem hacmi yükseliş eğilimindeyken, alçalan trendlerde düşüş eğilimindedir. Fiyatla gösterge arasındaki olası bir uyumsuzluk trendin yönünün değişeceğinin sinyalini verir. Fiyatlar yükselirken göstergede düşüş görülmesi, yükselişin gücünün azaldığı şeklinde yorumlanır.

3.4.18. Para Akışı Endeksi (Money Flow Index - MFI)

MFI göstergesi de Chaikin tarafından geliştirilen, günün ortalama fiyatını baz alan işlem hacmi göstergesidir (Perşembe, 2002, s. 189).

Hesaplanması:

MFI göstergesinde para akışı, önce ortalama fiyatın bulunması ardından ortalama fiyat ile işlem hacmi çarpımı yapılarak elde edilir. Ardından para girişi ve çıkışları bulunarak para oranı ve para akış endeksi hesaplanır (Perşembe, 2002, s. 189):

$$\text{Ortalama Fiyat} = (H_i + L_i + C_i) / 3$$

$$\text{Para Akışı} = \text{Ortalama Fiyat} \times V_i$$

$$\text{Para Oranı} = \text{Para Girişi} / \text{Para Çıkışı}$$

$$\text{Para Akış Endeksi (MFI)} = 100 - (100 / (1 + \text{Para Oranı}))$$

Formülde,

Para Girişi = Seçilen süredeki (Örneğin 14 gün) para girişlerinin toplamı

Para Çıkışı = Seçilen süredeki (Örneğin 14 gün) para çıkışlarının toplamı

Yorumlanması:

MFI, 0 ile 100 arasında dalgalanır. MFI'nın yükselmesi senede para girişi olduğunun, düşmesi ise senetten para çıkışı olduğunun göstergesidir. MFI'da referans çizgileri 20 ve 80 olarak belirlenmiştir. Göstergenin 20 referans çizgisi civarına veya daha aşağılara gelmesi senedin aşırı satışta olduğunu ve alım zamanının geldiğini gösterir. Bu çizginin yukarı doğru geçilmesi "AL" sinyali verir. Göstergenin 80 referans çizgisini yukarı doğru geçmesi halinde senet aşırı alım bölgesindedir ve satış zamanı gelmiştir. 80 referans çizgisini aşağı doğru geçmesi halinde ise "SAT" sinyali vermektedir (Çağırman, 1999, s. 387).

3.4.19. Chaikin Osilatörü (Chaikin Oscillator - CO)

Chaikin'in geliştirmiş olduğu bu gösterge daha çok A/D göstergesini temel olarak hesaplanmış bir işlem hacmi göstergesidir. CO, fiyat hareketleri ile işlem hacmi arasında bağlantı kurabilen ve bu şekilde de senette oluşabilecek yönü tayin etmeye ve trend değişikliklerini belirlemeye yarayan bir göstergedir. CO göstergesi üç temel varsayıma dayanır. *Birincisi*, senedin kapanış fiyatı gün içerisindeki en yüksek ve en düşük fiyatların ortalama değerinden $[(\text{en yüksek} + \text{en düşük}) / 2]$ daha yukarıda kapanmakta ise hisse senedinde toplanma yani alım olduğu, daha düşük seviyelerde oluşursa bu durumda senedin dağıtıldığını gösterir. *İkincisi*, piyasalardaki sağlıklı bir yükselmeye artan işlem hacminin eşlik edeceğidir. Yani

fiyat artışı ile işlem hacmi doğru orantılı olmalıdır. *Üçüncüsü ise*, senedin alım ve satım miktarlarının CO sayesinde tespit etmek suretiyle dip ve tepe seviyelerinin tespit edilebileceği şeklindedir (Çağırman, 1999, s. 371).

Hesaplanması:

$$CO = A/D'nin 10 günlük EMA'sı - A/D'nin 3 günlük EMA'sı$$

Yorumlanması:

Chaikin bu göstergenin özellikle fiyatların uzun vadeli hareketli ortalaması (90 günlük, 50 günlük vb.) ile birlikte kullanılmasını önermektedir. Örneğin, hisse senedi 50 günlük hareketli ortalamasının üstünde yukarı yönde gitmekte ise, göstergenin sıfır çizgisinin altında iken yönünün yukarı dönmesi, "AL" sinyali olarak algılanmalıdır. Tam tersine, hisse senedi 50 günlük hareketli ortalamasının altında giderken ve gösterge sıfır çizgisi üzerinde iken yönünün aşağı dönmesi "SAT" sinyali olarak değerlendirilmelidir (IBS Yazılım, 08.03.2012). Çağırman (1999), diğer teknik göstergelerde olduğu gibi senet fiyatları ile CO arasındaki uyumsuzluklara dikkat edilmesi gerektiğini ve göstergenin tek başına kullanılmamasını, mutlaka diğer göstergelerle birlikte incelenmesini önermektedir.

3.4.20. Chaikin Para Akım Göstergesi (Chaikin Money Flow - CMF)

CMF göstergesi, Chaikin A/D osilatörünü temel alır. A/D göstergesinin arkasındaki temel varsayım, eğer hisse senedinin o günkü kapanış fiyatı o günün orta noktasının [(en yüksek + en düşük) / 2] üzerinde olduğunda o günün alım günü olduğu, tersine, o günkü kapanış fiyatı o günün orta noktasının altında olduğunda o günün dağıtım günü olduğu şeklindedir.

Hesaplanması:

CMF, 21 günlük A/D değerlerinin toplamının 21 gün içinde oluşan toplam işlem miktarına bölünmesiyle elde edilir.

$$A_i = \sum_{i=1}^{21} \left[\frac{(C_i - L_i) - (H_i - C_i)}{H_i - L_i} \times V_i \right] \quad B_i = \sum_{i=1}^{21} V_i$$

$$CMF_i = \frac{A_i}{B_i}$$

Yorumlanması:

CMF, sıfır referans çizgisinin hangi tarafında ise ona göre bir yorum yapılır. Gösterge, sıfır çizgisinin üzerine çıktığında "AL", altına düştüğünde ise "SAT" sinyali verir (Günak, 2007, s. 100-103).

4. BÖLÜM: DESTEK VEKTÖR MAKİNELERİ VE LOJİSTİK REGRESYON YÖNTEMLERİ İLE İMKB 100 ENDEKSİ HAREKET YÖNÜ TAHMİNİ UYGULAMASI

Bu bölümde, İMKB 100 endeksi hareket yönü tahmini amacıyla, VM modellerinden ikili sınıflandırmaya imkan tanıyan DVM ve DVM'nin performansını karşılaştırmak amacıyla ikinci bir yöntem olarak kullanılan LR yöntemlerine dayalı tahmin modelleri oluşturularak, hareket yönü tahmini yapılmıştır. Uygulamada günlük, haftalık ve aylık olarak kullanılan üç veri setinin her biri için ayrı ayrı dört model oluşturulmuştur. Oluşturulan modeller ile elde edilen analiz sonuçları tablolar ve grafikler kullanılarak yorumlanmıştır.

4.1. UYGULAMANIN KAPSAMI

Çalışmada İMKB 100 endeksi ele alınmıştır. 03.04.1995 - 19.03.2012 tarihlerini kapsayan İMKB 100 endeksi günlük, haftalık ve aylık; açılış, kapanış, en yüksek, en düşük ve işlem hacmi verileri kullanılmıştır.

İMKB 100 endeksinin hareket yönünün tahmini amacıyla ikili sınıflandırma yöntemi kullanılmıştır. Endeks değeri arttığında "1", azaldığında "0" olacak şekilde kodlanmıştır. Uygulama için istatistiksel veri analizleri yapan, açık kaynak kodlu programlama dili "R" kullanılmıştır. R dili, Bell Laboratuvarları'nda John Chambers ve arkadaşları tarafından geliştirilen S dilinin bir uzantısıdır (R Core Team, 2012).

DVM paketi olarak DMwR kullanılmıştır (Torgo, 2010). DMwR birçok paketten oluşur. Bu çalışmada xts, zoo, TTR paketlerinden yararlanılmıştır.

Analiz ikili sınıflamaya imkan tanıyan LR yöntemiyle de gerçekleştirilmiş, DVM ile elde edilen sonuçlar karşılaştırılmıştır.

4.2. VERİ SETİ VE ANALİZ

4.2.1. Veri Seti

Analiz, 03.04.1995 - 19.03.2012 arası dönemi kapsamaktadır. Toplam 4226 adet veri günlük, haftalık ve aylık olarak üç veri seti şeklinde düzenlenmiş ve her veri seti için dört model oluşturulmuştur. İMKB 100 endeksinin hareket yönünü tahmin etmek amacıyla teknik analizde kullanılan ve literatürde yaygın olarak kullanım alanı bulan teknik göstergeler (indikatörler); SMA, EMA, WMA, Aroon osilatörü, DMI, Parabolic SAR, MACD, ROC, RSI, SO, SMI, %R, CCI, CMO, BB, ATR, Chaikin dalgalanma göstergesi, CO, A/D osilatörü, OBV, MFI ve CMF bağımsız değişken olarak kullanılmıştır.

Uygulamada kullanılan İMKB 100 endeksi verileri, İMKB'nin resmi sitesinde yer alan veri isteme formu aracılığı ile talep edilerek edinilmiştir.

4.2.2. Analiz

Uygulama günlük, haftalık ve aylık veriler kullanılarak üç ayrı bölümde değerlendirilmiştir. Her veri seti için dört model oluşturulmuştur ve her model farklı değerlendirme kriterlerine göre analiz edilmiştir.

Modelin daha önceden karşılaşmadığı verilerde nasıl bir performans gösterdiğini tespit etmek amacıyla, veriler, eğitim ve test verisi olarak ayrı ayrı değerlendirilmiştir. DVM çekirdek tipi olarak radyal tabanlı çekirdek (RBF) kullanılmıştır. RBF parametreleri cost (C) ve gamma (γ)'nın optimizasyonu için çapraz geçerlilik (cross-validation) yöntemi kullanılmıştır. Çapraz geçerlilik yöntemi aynı zamanda veriye aşırı uyumu önlemek için uygulanmaktadır. Çapraz geçerlilik uygulanmadan önce eğitim verisi her bir alt kümenin dağılımları benzer olacak şekilde rassal olarak parçalanmıştır. Böylece, eğitim kümesi $k-1$ alt eğitim kümesi, kalan kısmı ise test kümesi olacak şekilde belirlenen k adet alt kümeye ayrılmıştır. Belirlenen modellerde $k=10$ olarak alınmıştır. Çapraz geçerlilik testinde cost (C) parametresi 10^4 , 10^3 , 10^2 , 10^1 olmak üzere dört farklı değeri alırken, gamma (γ) parametresi 10^{-6} , 10^{-5} , 10^{-4} , 10^{-3} , 10^{-2} , 10^{-1} olmak üzere altı farklı değer almıştır.

Haftalık ve aylık veriler için ortalamalar alınarak gürültüden arındırılma yapılmıştır. Değişken seçimi yapılarak uygulanan modellerde arama yöntemi olarak

LR analizinden yararlanılmış ve LR ile yapılan arama sonucunda anlamlı kabul edilen değişkenler takip eden modellerde analize dahil edilmiştir.

4.2.2.1. Günlük Veriler Kullanılarak Uygulanan Analiz

Günlük veriler kullanılarak oluşturulan analizde endeks hareketi bir gün önceki değerine göre artış gösterdiğinde "1", azalış gösterdiğinde "0" olacak şekilde kodlanmıştır ve bu değerler bağımlı değişken olarak kullanılmıştır. Analiz dönemini kapsayan 4226 adet verinin 4026 tanesi analize dahil edilebilmiştir. Bunun nedeni SMA, EMA ve WMA göstergeleri için 200 günlük değerler hesaplanmasıdır. Toplam 4026 günlük verinin %80'i (3221 tanesi) eğitim kümesine (modelleme kümesi), %20'si (805 tanesi) test kümesine (tahmin kümesi) ayrılmıştır. Günlük veriler kullanılarak uygulanan analiz, dört modelden oluşmaktadır. Her model için LR ve DVM sonuçları ayrı ayrı değerlendirilmiştir.

MODEL - 1:

Bu analizde değişken seçimi uygulanmamıştır. Toplam 27 adet bağımsız değişken; 20 ve 200 günlük basit hareketli ortalama (SMA20, SMA200), 20 ve 200 günlük üssel hareketli ortalama (EMA20, EMA200), 20 ve 200 günlük ağırlıklı hareketli ortalama (WMA20, WMA200), Aroon osilatörü, ADX, Parabolic SAR, MACD, ROC, RSI, SO (hızlı %D, yavaş %D), SMI, %R, CCI, CMO, BB-HLC (En yüksek, en düşük ve kapanış değerleri ile hesaplanmıştır), BB-C (Kapanış değeri ile hesaplanmıştır), ATR, Chaikin dalgalanma göstergesi, CO, A/D osilatörü, OBV, MFI ve CMF modele dahil edilmiştir.

LOJİSTİK REGRESYON ANALİZİ

LR yöntemi, eğitim kümesindeki, 1699 artış verisinin 1188 tanesini doğru sınıflandırırken, 1522 azalış verisinin 604 tanesini doğru sınıflandırmıştır. Test kümesinde ise, 424 artış verisinin 286 tanesini doğru sınıflandırırken, 381 azalış verisinin 136 tanesini doğru sınıflandırmıştır.

Tablo 1. Günlük Model-1'de LR Yöntemi Sınıflandırma Başarısı

		EĞİTİM KÜMESİ (Modelleme Kümesi)			TEST KÜMESİ (Tahmin Kümesi)		
		Tahmin		Doğru Sınıflandırma Oranı (%)	Tahmin		Doğru Sınıflandırma Oranı (%)
		0	1		0	1	
Gerçek	0	604	918	39.68	136	245	35.69
	1	511	1188	69.92	138	286	67.45
TOPLAM		3221		55.63	805		52.42

Tablo 1 incelendiğinde, LR yönteminin, İMKB 100 endeksi artış yönünü eğitim kümesinde %69.92, test kümesinde %67.45 oranında sınıflandırırken, endeksin azalış yönünü eğitim kümesinde %39.68, test kümesinde %35.69 oranında sınıflandırdığı görülmektedir. LR yönteminin İMKB 100 endeksi hareket yönünü doğru sınıflandırma oranı ise; eğitim kümesinde %55.63 iken test kümesinde %52.42'dir.

DESTEK VEKTÖR MAKİNELERİ

Günlük Model-1 için; 10 kat çapraz geçerleme kullanılarak yapılan analizde, en iyi parametre kombinasyonu ($C=10^4$, $\gamma=10^{-5}$) için en iyi doğruluk oranı %53.87 bulunmuştur. DVM, eğitim kümesindeki 1699 artış verisinin 1347 tanesini doğru sınıflandırırken, 1522 azalış verisinin 441 tanesini doğru sınıflandırmıştır. Test kümesinde ise, 424 artış verisinin 323 tanesini doğru sınıflandırırken, 381 azalış verisinin 99 tanesini doğru sınıflandırmıştır.

Tablo 2. Günlük Model-1'de DVM Yöntemi Sınıflandırma Başarısı

		EĞİTİM KÜMESİ (Modelleme Kümesi)			TEST KÜMESİ (Tahmin Kümesi)		
		Tahmin		Doğru Sınıflandırma Oranı (%)	Tahmin		Doğru Sınıflandırma Oranı (%)
Gerçek		0	1		0	1	
		0	441	1081	28.97	99	282
	1	352	1347	79.28	101	323	76.17
TOPLAM		3221		55.51	805		52.42

Tablo 2 incelendiğinde, DVM yönteminin, İMKB 100 endeksinin artış yönünü eğitim kümesinde %79.28, test kümesinde %76.17 oranında sınıflandırırken, endeksin azalış yönünü eğitim kümesinde %28.97, test kümesinde %25.98 oranında sınıflandırdığı görülmektedir. DVM yönteminin İMKB 100 endeksi hareket yönünü doğru sınıflandırma oranı ise; eğitim kümesinde %55.51 iken test kümesinde %52.42'dir.

MODEL - 2 :

Bu analiz deęişken seçimi yapılarak uygulanmıştır. LR analizinde anlamlılık deęeri $p < 0.25$ olan 14 bağımsız deęişken; SMA20, WMA20, ADX, Parabolic SAR, ROC, RSI, hızlı %D, SMI, CCI, CMO, BB-HLC, BB-C, ATR ve Chaikin dalgalanma göstergesi analize dahil edilmiştir.

LOJİSTİK REGRESYON ANALİZİ

LR yöntemi, eğitim kümesindeki 1699 artış verisinin 1231 tanesini doğru sınıflandırırken, 1522 azalış verisinin 550 tanesini doğru sınıflandırmıştır. Test kümesinde ise, 424 artış verisinin 307 tanesini doğru sınıflandırırken, 381 azalış verisinin 119 tanesini doğru sınıflandırmıştır.

Tablo 3. Günlük Model-2'de LR Yöntemi Sınıflandırma Başarısı

		EĞİTİM KÜMESİ (Modelleme Kümesi)			TEST KÜMESİ (Tahmin Kümesi)		
		Tahmin		Doğru Sınıflandırma Oranı (%)	Tahmin		Doğru Sınıflandırma Oranı (%)
		0	1		0	1	
Gerçek	0	550	972	36.13	119	262	31.23
	1	468	1231	72.45	117	307	72.40
TOPLAM		3221		55.29	805		52.91

Tablo 3 incelendiğinde, LR yönteminin, İMKB 100 endeksinin artış yönünü eğitim kümesinde %72.45, test kümesinde %72.40 oranında sınıflandırırken, endeksin azalış yönünü eğitim kümesinde %36.13, test kümesinde %31.23 oranında sınıflandırdığı görülmektedir. LR yönteminin, İMKB 100 endeksi hareket yönünü doğru sınıflandırma oranı ise; eğitim kümesinde %55.29 iken test kümesinde %52.91'dir.

DESTEK VEKTÖR MAKİNELERİ

Günlük Model-2 için; 10 kat çapraz geçirme kullanılarak yapılan analizde, en iyi parametre kombinasyonu ($C=10^4$, $\gamma=10^{-4}$) için en iyi doğruluk oranı %53.36 bulunmuştur. DVM, eğitim kümesindeki 1699 artış verisinin 1263 tanesini doğru sınıflandırırken, 1522 azalış verisinin 505 tanesini doğru sınıflandırmıştır. Test

kümesinde ise, 424 artış verisinin 315 tanesini doğru sınıflandırırken, 381 azalış verisinin 114 tanesini doğru sınıflandırmıştır.

Tablo 4. Günlük Model-2'de DVM Yöntemi Sınıflandırma Başarısı

		EĞİTİM KÜMESİ (Modelleme Kümesi)			TEST KÜMESİ (Tahmin Kümesi)		
		Tahmin		Doğru Sınıflandırma Oranı (%)	Tahmin		Doğru Sınıflandırma Oranı (%)
		0	1		0	1	
Gerçek	0	505	1017	33.18	114	267	29.92
	1	436	1263	74.33	109	315	74.29
TOPLAM		3221		54.88	805		53.29

Tablo 4 incelendiğinde, DVM yönteminin, İMKB 100 endeksinin artış yönünü eğitim kümesinde %74.33, test kümesinde %74.29 oranında sınıflandırırken, endeksin azalış yönünü eğitim kümesinde %33.18, test kümesinde %29.92 oranında sınıflandırdığı görülmektedir. DVM yönteminin İMKB 100 endeksi hareket yönünü doğru sınıflandırma oranı ise; eğitim kümesinde %54.88 iken test kümesinde %53.29'dur.

MODEL-3:

Bu modelde, bir önceki LR analizinde anlamlılık değeri $p < 0.05$ olan yedi bağımsız değişken; SMA20, WMA20, ROC, RSI, BB-HLC, BB-C ve ATR analize dahil edilmiştir.

LOJİSTİK REGRESYON ANALİZİ

LR yöntemi, eğitim kümesindeki 1699 artış verisinin 1352 tanesini doğru sınıflandırırken, 1522 azalış verisinin 376 tanesini doğru sınıflandırmıştır. Test kümesinde ise, 424 artış verisinin 327 tanesini doğru sınıflandırırken, 381 azalış verisinin 86 tanesini doğru sınıflandırmıştır.

Tablo 5. Günlük Model-3'de LR Yöntemi Sınıflandırma Başarısı

		EĞİTİM KÜMESİ (Modelleme Kümesi)			TEST KÜMESİ (Tahmin Kümesi)		
		Tahmin		Doğru Sınıflandırma Oranı (%)	Tahmin		Doğru Sınıflandırma Oranı (%)
		0	1		0	1	
Gerçek	0	376	1146	24.70	86	295	22.57
	1	347	1352	79.57	97	327	77.12
TOPLAM		3221		53.64	805		51.30

Tablo 5 incelendiğinde, LR yönteminin, İMKB 100 endeksinin artış yönünü eğitim kümesinde %79.57, test kümesinde %77.12 oranında sınıflandırırken, endeksin azalış yönünü eğitim kümesinde %24.70, test kümesinde %22.57 oranında sınıflandırdığı görülmektedir. LR yönteminin İMKB 100 endeksi hareket yönünü doğru sınıflandırma oranı ise; eğitim kümesinde %53.64 iken test kümesinde %51.30'dur.

DESTEK VEKTÖR MAKİNELERİ

Günlük Model-3 için; 10 kat çapraz geçişleme kullanılarak yapılan analizde, en iyi parametre kombinasyonu ($C=10^2$, $\gamma=10^{-1}$) için en iyi doğruluk oranı %52.87 bulunmuştur. DVM, eğitim kümesindeki 1699 artış verisinin 1245 tanesini doğru sınıflandırırken, 1522 azalış verisinin 715 tanesini doğru sınıflandırmıştır. Test

kümesinde ise, 424 artış verisinin 286 tanesini doğru sınıflandırırken, 381 azalış verisinin 138 tanesini doğru sınıflandırmıştır.

Tablo 6. Günlük Model-3'de DVM Yöntemi Sınıflandırma Başarısı

		EĞİTİM KÜMESİ (Modelleme Kümesi)			TEST KÜMESİ (Tahmin Kümesi)		
		Tahmin		Doğru Sınıflandırma Oranı (%)	Tahmin		Doğru Sınıflandırma Oranı (%)
		0	1		0	1	
Gerçek	0	715	807	46.97	138	243	36.22
	1	454	1245	73.27	138	286	67.45
TOPLAM		3221		60.85	805		52.67

Tablo 6 incelendiğinde, DVM yönteminin, İMKB 100 endeksinin artış yönünü eğitim kümesinde %73.27, test kümesinde %67.45 oranında sınıflandırırken, endeksin azalış yönünü eğitim kümesinde %46.97, test kümesinde %36.22 oranında sınıflandırdığı görülmektedir. DVM yönteminin İMKB 100 endeksi hareket yönünü doğru sınıflandırma oranı ise; eğitim kümesinde %60.85 iken test kümesinde %52.67'dir.

MODEL - 4:

Bu modelde bir önceki LR analizinde anlamlılık değeri $p < 0.05$ olan üç bağımsız değişken; ROC, BB-HLC ve BB-C analize dahil edilmiştir.

LOJİSTİK REGRESYON ANALİZİ

LR yöntemi, eğitim kümesindeki 1699 artış verisinin 1389 tanesini doğru sınıflandırırken, 1522 azalış verisinin 338 tanesini doğru sınıflandırmıştır. Test kümesinde ise, 424 artış verisinin 338 tanesini doğru sınıflandırırken, 381 azalış verisinin 78 tanesini doğru sınıflandırmıştır.

Tablo 7. Günlük Model-4'de LR Yöntemi Sınıflandırma Başarısı

		EĞİTİM KÜMESİ (Modelleme Kümesi)			TEST KÜMESİ (Tahmin Kümesi)		
		Tahmin		Doğru Sınıflandırma Oranı (%)	Tahmin		Doğru Sınıflandırma Oranı (%)
Gerçek		0	1		0	1	
		0	338	1184	22.20	78	303
	1	310	1389	81.75	86	338	79.71
TOPLAM		3221		53.61	805		51.67

Tablo 7 incelendiğinde, LR yönteminin, İMKB 100 endeksinin artış yönünü eğitim kümesinde %81.75, test kümesinde %79.71 oranında sınıflandırırken, endeksin azalış yönünü eğitim kümesinde %22.20, test kümesinde %20.47 oranında sınıflandırdığı görülmektedir. LR yönteminin İMKB 100 endeksi hareket yönünü doğru sınıflandırma oranı ise; eğitim kümesinde %53.61 iken test kümesinde %51.67'dir.

DESTEK VEKTÖR MAKİNELERİ

Günlük Model-4 için; 10 kat çapraz geçişleme kullanılarak yapılan analizde, en iyi parametre kombinasyonu ($C=10^2$, $\gamma=10^{-1}$) için en iyi doğruluk oranı %53.55 bulunmuştur. DVM, eğitim kümesindeki 1699 artış verisinin 1566 tanesini doğru sınıflandırırken, 1522 azalış verisinin 203 tanesini doğru sınıflandırmıştır. Test

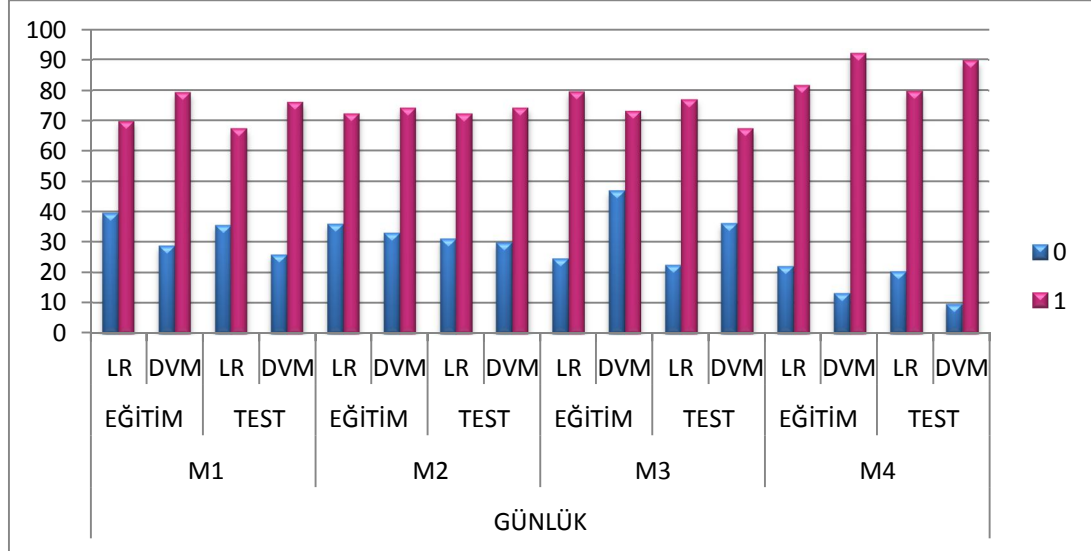
kümesinde ise, 424 artış verisinin 381 tanesini doğru sınıflandırırken, 381 azalış verisinin 37 tanesini doğru sınıflandırmıştır.

Tablo 8. Günlük Model-4'de DVM Yöntemi Sınıflandırma Başarısı

Gerçek		EĞİTİM KÜMESİ (Modelleme Kümesi)			TEST KÜMESİ (Tahmin Kümesi)		
		Tahmin		Doğru Sınıflandırma Oranı (%)	Tahmin		Doğru Sınıflandırma Oranı (%)
		0	1		0	1	
0	203	1319	13.33	37	344	9.71	
1	133	1566	92.17	43	381	89.85	
TOPLAM		3221		54.92	805		51.92

Tablo 8 incelendiğinde, DVM yönteminin, İMKB 100 endeksinin artış yönünü eğitim kümesinde %92.17, test kümesinde %89.85 oranında sınıflandırırken, endeksin azalış yönünü eğitim kümesinde %13.33, test kümesinde %9.71 oranında sınıflandırdığı görülmektedir. DVM yönteminin İMKB 100 endeksi hareket yönünü doğru sınıflandırma oranı ise; eğitim kümesinde %54.92 iken test kümesinde %51.92'dir.

Şekil 5'te günlük veriler kullanılarak oluşturulan dört ayrı model için uygulanan analiz sonuçlarına göre, İMKB 100 endeksi artış ve azalış hareket yönü sınıflandırma oranları her iki yöntem içinde karşılaştırmalı olarak verilmiştir.



Şekil 5. Günlük Modeller için LR ve DVM'nin Artış "1", Azalış "0" Yön Tahminleri

Şekil 5'te, Günlük Model-1, Model-2 ve Model-4 test kümesi sonuçları incelendiğinde, İMKB 100 endeksi artış yönünü DVM'nin (%76.17, %74.29, %89.85) LR'den (%67.45, %72.40, %79.71) daha iyi sınıflandırdığı, azalış yönünü ise LR'nin (%35.69, %31.23, %20.47) DVM'den (%25.98, %29.92, %9.71) daha başarılı sınıflandırdığı görülmektedir. Model-3'te ise artış yönünü sınıflandırmada LR (%77.12) DVM'den (%67.45) daha iyiyken, azalış yönünü sınıflandırmada DVM (%36.22) LR'den (%22.57) daha başarılı bulunmuştur.

4.2.2.2. Haftalık Veriler Kullanılarak Uygulanan Analiz

Haftalık veriler kullanılarak oluşturulan analizde endeks hareketi bir hafta önceki değerine göre artış gösterdiğinde "1", azalış gösterdiğinde "0" olacak şekilde kodlanmıştır ve bu değerler bağımlı değişken olarak kullanılmıştır. Toplam 840 haftalık verinin %80'i (700 tanesi) eğitim kümesine (modelleme kümesi), %20'si (140 tanesi) test kümesine (tahmin kümesi) ayrılmıştır. Haftalık veriler kullanılarak uygulanan analiz, dört modelden oluşmaktadır. Her model için LR ve DVM sonuçları ayrı ayrı değerlendirilmiştir.

MODEL -1:

Haftalık veriler kullanılarak oluşturulan bu modelde, günlük veriler ile uygulanan Model-1'de olduğu gibi değişken seçimi yapılmamıştır. Tüm değişkenler analize dahil edilmiştir.

LOJİSTİK REGRESYON ANALİZİ

LR yöntemi, eğitim kümesindeki 408 artış verisinin 332 tanesini doğru sınıflandırırken, 292 azalış verisinin 167 tanesini doğru sınıflandırmıştır. Test kümesinde ise, 76 artış verisinin 56 tanesini doğru sınıflandırırken, 64 azalış verisinin 38 tanesini doğru sınıflandırmıştır.

Tablo 9. Haftalık Model-1'de LR Yöntemi Sınıflandırma Başarısı

		EĞİTİM KÜMESİ (Modelleme Kümesi)			TEST KÜMESİ (Tahmin Kümesi)		
		Tahmin		Doğru Sınıflandırma Oranı (%)	Tahmin		Doğru Sınıflandırma Oranı (%)
Gerçek		0	1		0	1	
	0	167	125	57.19	38	26	59.37
	1	76	332	81.37	20	56	73.68
TOPLAM		700		71.28	140		67.14

Tablo 9 incelendiğinde, LR yönteminin, İMKB 100 endeksinin artış yönünü eğitim kümesinde %81.37, test kümesinde %73.68 oranında sınıflandırırken, endeksin azalış yönünü eğitim kümesinde %57.19, test kümesinde %59.37 oranında sınıflandırdığı görülmektedir. LR yönteminin İMKB 100 endeksi hareket yönünü doğru sınıflandırma oranı ise; eğitim kümesinde %71.28 iken test kümesinde %67.14 olarak gözlenmiştir.

DESTEK VEKTÖR MAKİNELERİ

Haftalık Model-1 için; 10 kat çapraz geçirme kullanılarak yapılan analizde, en iyi parametre kombinasyonu ($C=10^4$, $\gamma=10^{-5}$) için en iyi doğruluk oranı %76.37 bulunmuştur. DVM, eğitim kümesindeki 408 artış verisinin 344 tanesini doğru sınıflandırırken, 292 azalış verisinin 161 tanesini doğru sınıflandırmıştır. Test

kümesinde ise, 76 artış verisinin 63 tanesini doğru sınıflandırırken, 64 azalış verisinin 35 tanesini doğru sınıflandırmıştır.

Tablo 10. Haftalık Model-1'de DVM Yöntemi Sınıflandırma Başarısı

		EĞİTİM KÜMESİ (Modelleme Kümesi)			TEST KÜMESİ (Tahmin Kümesi)		
		Tahmin		Doğru Sınıflandırma Oranı (%)	Tahmin		Doğru Sınıflandırma Oranı (%)
Gerçek		0	1		0	1	
	0	161	131	55.13	35	29	54.68
	1	64	344	84.31	13	63	82.89
TOPLAM	700		72.14	140		70.0	

Tablo 10 incelendiğinde, DVM yönteminin, İMKB 100 endeksinin artış yönünü eğitim kümesinde %84.31, test kümesinde %82.89 oranında sınıflandırırken, endeksin azalış yönünü eğitim kümesinde %55.13, test kümesinde %54.68 oranında sınıflandırdığı görülmektedir. DVM yönteminin İMKB 100 endeksi hareket yönünü doğru sınıflandırma oranı ise; eğitim kümesinde %72.14 iken test kümesinde %70.0 oranında gözlenmiştir.

MODEL-2:

Bu analiz deęişken seçimi yapılarak uygulanmıştır. LR analizinde anlamlılık deęeri $p < 0.25$ olan 15 bağımsız deęişken; SMA200, EMA20, WMA20, Aroon osilatörü, ADX, ROC, hızlı %D, yavaş %D, SMI, %R, CCI, BB-HLC, BB-C, ATR ve CO göstergeleri analize dahil edilmiştir.

LOJİSTİK REGRESYON ANALİZİ

LR yöntemi, eğitim kümesindeki 408 artış verisinin 334 tanesini doğru sınıflandırırken, 292 azalış verisinin 168 tanesini doğru sınıflandırmıştır. Test kümesinde ise, 76 artış verisinin 56 tanesini doğru sınıflandırırken, 64 azalış verisinin 34 tanesini doğru sınıflandırmıştır.

Tablo 11. Haftalık Model-2'de LR Yöntemi Sınıflandırma Başarısı

		EĞİTİM KÜMESİ (Modelleme Kümesi)			TEST KÜMESİ (Tahmin Kümesi)		
		Tahmin		Doğru Sınıflandırma Oranı (%)	Tahmin		Doğru Sınıflandırma Oranı (%)
		0	1		0	1	
Gerçek	0	168	124	57.53	34	30	53.12
	1	74	334	81.86	20	56	73.68
TOPLAM		700		71.71	140		64.28

Tablo 11 incelendiğinde, LR yönteminin, İMKB 100 endeksinin artış yönünü eğitim kümesinde %81.86, test kümesinde %73.68 oranında sınıflandırırken, endeksin azalış yönünü eğitim kümesinde %57.53, test kümesinde %53.12 oranında sınıflandırdığı görülmektedir. LR yönteminin İMKB 100 endeksi hareket yönünü doğru sınıflandırma oranı ise; eğitim kümesinde %71.71 iken test kümesinde %64.28'dir.

DESTEK VEKTÖR MAKİNELERİ

Haftalık Model-2 için; 10 kat çapraz geçirme kullanılarak yapılan analizde, en iyi parametre kombinasyonu ($C=10^4$, $\gamma=10^{-6}$) için en iyi doğruluk oranı %76.72 bulunmuştur. DVM, eğitim kümesindeki 408 artış verisinin 354 tanesini doğru

sınıflandırırken, 292 azalış verisinin 126 tanesini doğru sınıflandırmıştır. Test kümesinde ise, 76 artış verisinin 66 tanesini doğru sınıflandırırken, 64 azalış verisinin 31 tanesini doğru sınıflandırmıştır.

Tablo 12. Haftalık Model-2'de DVM Yöntemi Sınıflandırma Başarısı

		EĞİTİM KÜMESİ (Modelleme Kümesi)			TEST KÜMESİ (Tahmin Kümesi)		
		Tahmin		Doğru Sınıflandırma Oranı (%)	Tahmin		Doğru Sınıflandırma Oranı (%)
		0	1		0	1	
Gerçek	0	126	166	43.15	31	33	48.43
	1	54	354	86.76	10	66	86.84
TOPLAM		700		68.57	140		69.28

Tablo 12 incelendiğinde, DVM yönteminin, İMKB 100 endeksinin artış yönünü eğitim kümesinde %86.76, test kümesinde %86.84 oranında sınıflandırırken, endeksin azalış yönünü eğitim kümesinde %43.15, test kümesinde ise %48.43 oranında sınıflandırdığı görülmektedir. DVM yönteminin İMKB 100 endeksi hareket yönünü doğru sınıflandırma oranı ise; eğitim kümesinde %68.57 iken test kümesinde %69.28 olarak gözlenmiştir.

MODEL-3:

Bu modelde, bir önceki LR analizinde anlamlılık değeri $p<0.05$ olan yedi bağımsız değişken; EMA20, WMA20, ROC, hızlı %D, BB-C, ATR ve CO analize dahil edilmiştir.

LOJİSTİK REGRESYON ANALİZİ

LR yöntemi, eğitim kümesindeki 408 artış verisinin 338 tanesini doğru sınıflandırırken, 292 azalış verisinin 153 tanesini doğru sınıflandırmıştır. Test kümesinde ise, 76 artış verisinin 65 tanesini doğru sınıflandırırken, 64 azalış verisinin 33 tanesini doğru sınıflandırmıştır.

Tablo 13. Haftalık Model-3'de LR Yöntemi Sınıflandırma Başarısı

		EĞİTİM KÜMESİ (Modelleme Kümesi)			TEST KÜMESİ (Tahmin Kümesi)		
		Tahmin		Doğru Sınıflandırma Oranı (%)	Tahmin		Doğru Sınıflandırma Oranı (%)
Gerçek		0	1		0	1	
		0	153	139	52.39	33	31
	1	70	338	82.84	11	65	85.52
TOPLAM		700		70.14	140		70.0

Tablo 13 incelendiğinde, LR yönteminin, İMKB 100 endeksinin artış yönünü eğitim kümesinde %82.84, test kümesinde %85.52 oranında sınıflandırırken, endeksin azalış yönünü eğitim kümesinde %52.39, test kümesinde ise %51.56 oranında sınıflandırdığı görülmektedir. LR yönteminin İMKB 100 endeksi hareket yönünü doğru sınıflandırma oranı ise; eğitim kümesinde %70.14 iken test kümesinde %70.0 olarak gözlenmiştir.

DESTEK VEKTÖR MAKİNELERİ

Haftalık Model-3 için; 10 kat çapraz geçirme kullanılarak yapılan analizde, en iyi parametre kombinasyonu ($C=10^2$, $\gamma=10^{-2}$) için en iyi doğruluk oranı %77.19 bulunmuştur. DVM, eğitim kümesindeki 408 artış verisinin 328 tanesini doğru sınıflandırırken, 292 azalış verisinin 177 tanesini doğru sınıflandırmıştır. Test

kümesinde ise, 76 artış verisinin 62 tanesini doğru sınıflandırırken, 64 azalış verisinin 34 tanesini doğru sınıflandırmıştır.

Tablo 14. Haftalık Model-3'de DVM Yöntemi Sınıflandırma Başarısı

		EĞİTİM KÜMESİ (Modelleme Kümesi)			TEST KÜMESİ (Tahmin Kümesi)		
		Tahmin		Doğru Sınıflandırma Oranı (%)	Tahmin		Doğru Sınıflandırma Oranı (%)
		0	1		0	1	
Gerçek	0	177	115	60.61	34	30	53.12
	1	80	328	80.39	14	62	81.57
	TOPLAM	700		72.14	140		68.57

Tablo 14 incelendiğinde, DVM yönteminin, İMKB 100 endeksinin artış yönünü eğitim kümesinde %80.39, test kümesinde %81.57 oranında sınıflandırırken, endeksin azalış yönünü eğitim kümesinde %60.61, test kümesinde %53.12 oranında sınıflandırdığı görülmektedir. DVM yönteminin İMKB 100 endeksi hareket yönünü doğru sınıflandırma oranı ise; eğitim kümesinde %72.14 iken test kümesinde %68.57 olarak gözlenmiştir.

MODEL-4:

Bu modelde bir önceki LR analizinde anlamlılık değeri $p < 0.05$ olan dört bağımsız değişken; WMA20, ROC, ATR ve CO göstergeleri kullanılmıştır.

LOJİSTİK REGRESYON ANALİZİ

LR yöntemi, eğitim kümesindeki 408 artış verisinin 340 tanesi doğru sınıflandırırken, 292 azalış verisinin 154 tanesini doğru sınıflandırmıştır. Test kümesinde ise, 76 artış verisinin 62 tanesini doğru sınıflandırırken, 64 azalış verisinin 33 tanesini doğru sınıflandırmıştır.

Tablo 15. Haftalık Model-4'de LR Yöntemi Sınıflandırma Başarısı

		EĞİTİM KÜMESİ (Modelleme Kümesi)			TEST KÜMESİ (Tahmin Kümesi)		
		Tahmin		Doğru Sınıflandırma Oranı (%)	Tahmin		Doğru Sınıflandırma Oranı (%)
Gerçek		0	1		0	1	
		0	154	138	52.73	33	31
	1	68	340	83.33	14	62	81.57
TOPLAM		700		70.57	140		67.85

Tablo 15 incelendiğinde, LR yönteminin, İMKB 100 endeksinin artış yönünü eğitim kümesinde %83.33, test kümesinde %81.57 oranında sınıflandırırken, endeksin azalış yönünü eğitim kümesinde %52.73, test kümesinde %51.56 oranında sınıflandırdığı görülmektedir. LR yönteminin İMKB 100 endeksi hareket yönünü doğru sınıflandırma oranı ise; eğitim kümesinde %70.57 iken test kümesinde %67.85 olarak gözlenmiştir.

DESTEK VEKTÖR MAKİNELERİ

Haftalık Model-4 için; 10 kat çapraz doğrulama kullanılarak yapılan analizde, en iyi parametre kombinasyonu ($C=10^1$, $\gamma=10^{-1}$) için en iyi doğruluk oranı %76.78 bulunmuştur. DVM, eğitim kümesindeki 408 artış verisinin 341 tanesini doğru sınıflandırırken, 292 azalış verisinin 159 tanesini doğru sınıflandırmıştır. Test

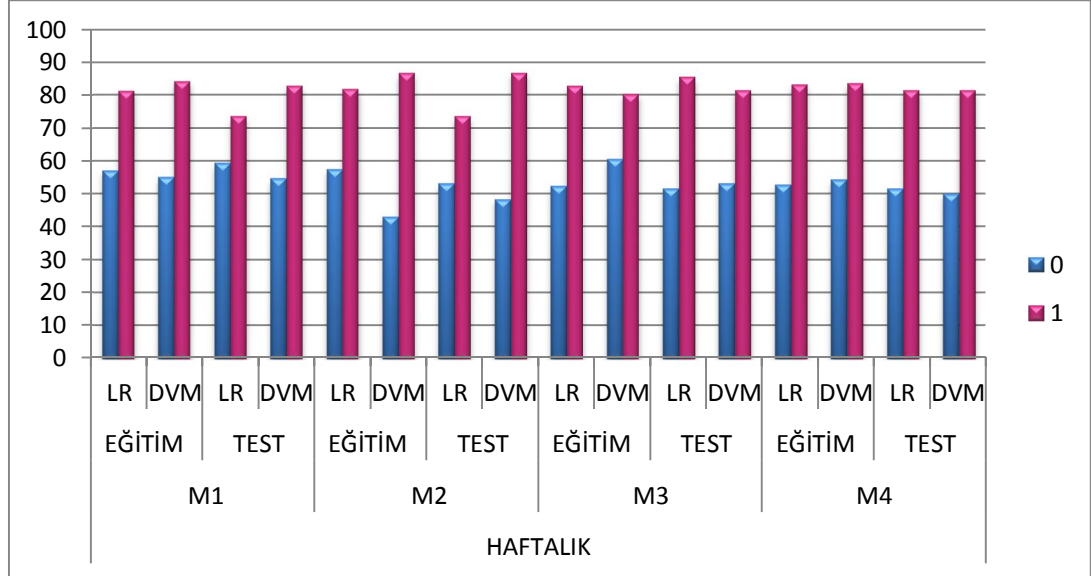
kümesinde ise, 76 artış verisinin 62 tanesini doğru sınıflandırırken, 64 azalış verisinin 32 tanesini doğru sınıflandırmıştır.

Tablo 16. Haftalık Model-4'de DVM Yöntemi Sınıflandırma Başarısı

		EĞİTİM KÜMESİ (Modelleme Kümesi)			TEST KÜMESİ (Tahmin Kümesi)		
		Tahmin		Doğru Sınıflandırma Oranı (%)	Tahmin		Doğru Sınıflandırma Oranı (%)
		0	1		0	1	
Gerçek	0	159	133	54.45	32	32	50.0
	1	67	341	83.57	14	62	81.57
TOPLAM		700		71.42	140		67.14

Tablo 16 incelendiğinde, DVM yönteminin, İMKB 100 endeksinin artış yönünü eğitim kümesinde %83.57, test kümesinde %81.57 oranında sınıflandırırken, endeksin azalış yönünü eğitim kümesinde %54.45, test kümesinde ise %50.0 oranında sınıflandırdığı görülmektedir. DVM yönteminin İMKB 100 endeksi hareket yönünü doğru sınıflandırma oranı ise; eğitim kümesinde %71.42 iken test kümesinde %67.14 olarak gözlenmiştir.

Şekil 6'da haftalık veriler kullanılarak oluşturulan dört ayrı model için uygulanan analiz sonuçlarına göre, İMKB 100 endeksi artış ve azalış hareket yönü sınıflandırma oranları her iki yöntem içinde karşılaştırmalı olarak verilmiştir.



Şekil 6. Haftalık Modeller İçin LR ve DVM'nin Artış "1", Azalış "0" Yön Tahminleri

Şekil 6'da test kümesi sonuçları incelendiğinde, Haftalık Model-1, Model-2'de, İMKB 100 endeksi artış yönünü DVM (%82.89, %86.84) LR'ye (%73.68, %73.68) göre daha başarılı sınıflandırdığı, azalış yönünü sınıflandırmada ise LR'nin (%59.37, %53.12) DVM'den (%54.68, %48.43) daha iyi sonuçlar verdiği görülmektedir. Haftalık Model-3'te azalışları DVM (%53.12), LR'den (%51.56) daha iyi tahminlerken, artışları sınıflandırmada LR (%85.52), DVM'den (%81.57) daha başarılı bulunmuştur. Model-4'te ise azalış yönünü LR (%51.56), DVM'den (%50.0) daha iyi sınıflandırırken, artış yönünü her iki yöntemin de aynı oranda (%81.57) tahminlediği görülmektedir.

4.2.2.3. Aylık Veriler Kullanılarak Uygulanan Analiz

Aylık veriler kullanılarak oluşturulan analizde endeks hareketi bir ay önceki değerine göre artış gösterdiğinde "1", azalış gösterdiğinde "0" olacak şekilde kodlanmıştır ve bu değerler bağımlı değişken olarak kodlanmıştır. Toplam 193 aylık verinin %80'i (155 tanesi) eğitim kümesine (modelleme kümesi), %20'si (38 tanesi) test kümesine (tahmin kümesi) ayrılmıştır. Aylık veriler kullanılarak uygulanan

analiz, dört modelden oluşmaktadır. Her model için LR ve DVM sonuçları ayrı ayrı değerlendirilmiştir.

MODEL-1:

Bu analizde değişken seçimi uygulanmamıştır. Toplam 27 adet bağımsız değişken analize dahil edilmiştir.

LOJİSTİK REGRESYON ANALİZİ

LR yöntemi, eğitim kümesindeki 92 artış verisinin 81 tanesini doğru sınıflandırırken, 63 azalış verisinin 51 tanesini doğru sınıflandırmıştır. Test kümesinde ise, 25 artış verisinin 17 tanesini doğru sınıflandırırken, 13 azalış verisinin 7 tanesini doğru sınıflandırmıştır.

Tablo 17. Aylık Model-1'de LR Yöntemi Sınıflandırma Başarısı

		EĞİTİM KÜMESİ (Modelleme Kümesi)			TEST KÜMESİ (Tahmin Kümesi)		
		Tahmin		Doğru Sınıflandırma Oranı (%)	Tahmin		Doğru Sınıflandırma Oranı (%)
Gerçek		0	1		0	1	
	0	51	12	80.95	7	6	53.84
	1	11	81	88.04	8	17	68.0
TOPLAM		155		85.16	38		63.15

Tablo 17 incelendiğinde, LR yönteminin, İMKB 100 endeksinin artış yönünü eğitim kümesinde %88.04, test kümesinde %68.0 oranında sınıflandırırken, endeksin azalış yönünü eğitim kümesinde %80.95, test kümesinde ise %53.84 oranında sınıflandırdığı görülmektedir. LR yönteminin İMKB 100 endeksi hareket yönünü doğru sınıflandırma oranı ise; eğitim kümesinde %85.16 iken test kümesinde %63.15 olarak gözlenmiştir.

DESTEK VEKTÖR MAKİNELERİ

Aylık Model-1 için; 10 kat çapraz geçişleme kullanılarak yapılan analizde, en iyi parametre kombinasyonu ($C=10^2$, $\gamma=10^{-1}$) için en iyi doğruluk oranı %79.88

bulunmuştur. DVM, eğitim kümesindeki 92 artış verisinin 92 tanesini doğru sınıflandırırken, 63 azalış verisinin 63 tanesini doğru sınıflandırmıştır. Test kümesinde ise, 25 artış verisinin 14 tanesini doğru sınıflandırırken, 13 azalış verisinin 5 tanesini doğru sınıflandırmıştır.

Tablo 18. Aylık Model-1'de DVM Yöntemi Sınıflandırma Başarısı

		EĞİTİM KÜMESİ (Modelleme Kümesi)			TEST KÜMESİ (Tahmin Kümesi)		
		Tahmin		Doğru Sınıflandırma Oranı (%)	Tahmin		Doğru Sınıflandırma Oranı (%)
		0	1		0	1	
Gerçek	0	63	0	100	5	8	38.46
	1	0	92	100	11	14	56.0
TOPLAM		155		100	38		50.0

Tablo 18 incelendiğinde, DVM yönteminin, İMKB 100 endeksinin artış yönünü eğitim kümesinde %100, test kümesinde %56.0 oranında sınıflandırırken, endeksin azalış yönünü eğitim kümesinde %100, test kümesinde %38.46 oranında sınıflandırdığı görülmektedir. DVM yönteminin İMKB 100 endeksi hareket yönünü doğru sınıflandırma oranı ise; eğitim kümesinde %100 iken test kümesinde %50.0 olarak gözlenmiştir.

MODEL-2:

Bu analiz deęişken seçimi yapılarak uygulanmıştır. LR analizinde anlamlılık deęeri $p < 0.25$ olan 10 bağımsız deęişken; MACD, ROC, yavaş %D, SMI, CCI, BB-HLC, BB-C, Chaikin dalgalanma göstergesi, A/D osilatörü ve CMF analize dahil edilmiştir.

LOJİSTİK REGRESYON ANALİZİ

LR yöntemi, eğitim kümesindeki 92 artış verisinin 81 tanesini doğru sınıflandırırken, 63 azalış verisinin 42 tanesini doğru sınıflandırmıştır. Test kümesinde ise, 25 artış verisinin 18 tanesini doğru sınıflandırırken, 13 azalış verisinin 7 tanesini doğru sınıflandırmıştır.

Tablo 19. Aylık Model-2'de LR Yöntemi Sınıflandırma Başarısı

		EĞİTİM KÜMESİ (Modelleme Kümesi)			TEST KÜMESİ (Tahmin Kümesi)		
		Tahmin		Doğru Sınıflandırma Oranı (%)	Tahmin		Doğru Sınıflandırma Oranı (%)
Gerçek		0	1		0	1	
		0	42	21	66.67	7	6
	1	11	81	88.04	7	18	72.0
TOPLAM		155		79.35	38		65.78

Tablo 19 incelendiğinde, LR yönteminin, İMKB 100 endeksinin artış yönünü eğitim kümesinde %88.04, test kümesinde %72.0 oranında sınıflandırırken, endeksin azalış yönünü eğitim kümesinde %66.67, test kümesinde ise %53.84 oranında sınıflandırdığı görülmektedir. LR yönteminin İMKB 100 endeksi hareket yönünü doğru sınıflandırma oranı ise; eğitim kümesinde %79.35 iken test kümesinde %65.78'dir.

DESTEK VEKTÖR MAKİNELERİ

Aylık Model-2 için; 10 kat çapraz geçişleme kullanılarak yapılan analizde, en iyi parametre kombinasyonu ($C=10^4$, $\gamma=10^{-5}$) için en iyi doğruluk oranı %75.31 bulunmuştur. DVM, eğitim kümesindeki 92 artış verisinin 77 tanesini doğru

sınıflandırırken, 63 azalış verisinin 32 tanesini doğru sınıflandırmıştır. Test kümesinde ise, 25 artış verisinin 19 tanesini doğru sınıflandırırken, 13 azalış verisinin 5 tanesini doğru sınıflandırmıştır.

Tablo 20. Aylık Model-2'de DVM Yöntemi Sınıflandırma Başarısı

		EĞİTİM KÜMESİ (Modelleme Kümesi)			TEST KÜMESİ (Tahmin Kümesi)		
		Tahmin		Doğru Sınıflandırma Oranı (%)	Tahmin		Doğru Sınıflandırma Oranı (%)
Gerçek		0	1		0	1	
	0	32	31	50.79	5	8	38.46
	1	15	77	83.69	6	19	76.0
TOPLAM		155		70.32	38		63.15

Tablo 20 incelendiğinde, DVM yönteminin, İMKB 100 endeksinin artış yönünü eğitim kümesinde %83.69, test kümesinde %76.0 oranında sınıflandırırken, endeksin azalış yönünü eğitim kümesinde %50.79, test kümesinde ise %38.46 oranında sınıflandırdığı görülmektedir. DVM yönteminin İMKB 100 endeksi hareket yönünü doğru sınıflandırma oranı ise; eğitim kümesinde %70.32 iken test kümesinde %63.15 olarak gözlenmiştir.

MODEL-3:

Bu modelde, bir önceki LR analizinde anlamlılık değeri $p < 0.05$ olan iki bağımsız değişken; ROC ve CCI göstergeleri analize dahil edilmiştir.

LOJİSTİK REGRESYON ANALİZİ

LR yöntemi, eğitim kümesindeki 92 artış verisinin 79 tanesini doğru sınıflandırırken, 63 azalış verisinin 35 tanesini doğru sınıflandırmıştır. Test kümesinde ise, 25 artış verisinin 17 tanesini doğru sınıflandırırken, 13 azalış verisinin 5 tanesini doğru sınıflandırmıştır.

Tablo 21. Aylık Model-3'de LR Yöntemi Sınıflandırma Başarısı

		EĞİTİM KÜMESİ (Modelleme Kümesi)			TEST KÜMESİ (Tahmin Kümesi)		
		Tahmin		Doğru Sınıflandırma Oranı (%)	Tahmin		Doğru Sınıflandırma Oranı (%)
Gerçek		0	1		0	1	
	0	35	28	55.56	5	8	38.46
	1	13	79	85.86	8	17	68.0
TOPLAM		155		73.54	38		57.89

Tablo 21 incelendiğinde, LR yönteminin, İMKB 100 endeksinin artış yönünü eğitim kümesinde %85.86, test kümesinde %68.0 oranında sınıflandırırken, endeksin azalış yönünü eğitim kümesinde %55.56, test kümesinde ise %38.46 oranında sınıflandırdığı görülmektedir. LR yönteminin İMKB 100 endeksi hareket yönünü doğru sınıflandırma oranı ise; eğitim kümesinde %73.54 iken test kümesinde %57.89 olarak gözlenmiştir.

DESTEK VEKTÖR MAKİNELERİ

Aylık Model-3 için; 10 kat çapraz geçişleme kullanılarak yapılan analizde, en iyi parametre kombinasyonu ($C=10^1$, $\gamma=10^{-1}$) için en iyi doğruluk oranı %76.96 bulunmuştur. DVM, eğitim kümesindeki 92 artış verisinin 75 tanesini doğru sınıflandırırken, 63 azalış verisinin 36 tanesini doğru sınıflandırmıştır. Test

kümesinde ise, 25 artış verisinin 18 tanesini doğru sınıflandırırken, 13 azalış verisinin 6 tanesini doğru sınıflandırmıştır.

Tablo 22. Aylık Model-3'de DVM Yöntemi Sınıflandırma Başarısı

		EĞİTİM KÜMESİ (Modelleme Kümesi)			TEST KÜMESİ (Tahmin Kümesi)		
		Tahmin		Doğru Sınıflandırma Oranı (%)	Tahmin		Doğru Sınıflandırma Oranı (%)
		0	1		0	1	
Gerçek	0	36	27	57.14	6	7	46.15
	1	17	75	81.52	7	18	72.0
TOPLAM		155		71.61	38		63.15

Tablo 22 incelendiğinde, DVM yönteminin, İMKB 100 endeksinin artış yönünü eğitim kümesinde %81.52, test kümesinde %72.0 oranında sınıflandırırken, endeksin azalış yönünü eğitim kümesinde %57.14, test kümesinde ise %46.15 oranında sınıflandırdığı görülmektedir. DVM yönteminin İMKB 100 endeksi hareket yönünü doğru sınıflandırma oranı ise; eğitim kümesinde %71.61 iken test kümesinde %63.15 olarak gözlenmiştir.

MODEL-4:

Bu modelde de, bir önceki LR analizinde anlamlılık değeri $p < 0.05$ olan bir bağımsız değişken; ROC analize dahil edilmiştir.

LOJİSTİK REGRESYON ANALİZİ

LR yöntemi, eğitim kümesindeki 92 artış verisinin 75 tanesini doğru sınıflandırırken, 63 azalış verisinin 35 tanesini doğru sınıflandırmıştır. Test kümesinde ise, 25 artış verisinin 18 tanesini doğru sınıflandırırken, 13 azalış verisinin 6 tanesini doğru sınıflandırmıştır.

Tablo 23. Aylık Model-4'de LR Yöntemi Sınıflandırma Başarısı

		EĞİTİM KÜMESİ (Modelleme Kümesi)			TEST KÜMESİ (Tahmin Kümesi)		
		Tahmin		Doğru Sınıflandırma Oranı (%)	Tahmin		Doğru Sınıflandırma Oranı (%)
Gerçek		0	1		0	1	
	0	35	28	55.56	6	7	46.15
	1	17	75	81.52	7	18	72.0
TOPLAM	155		70.96	38		63.15	

Tablo 23 incelendiğinde, LR yönteminin, İMKB 100 endeksinin artış yönünü eğitim kümesinde %81.52, test kümesinde %72.0 oranında sınıflandırırken, endeksin azalış yönünü eğitim kümesinde %55.56, test kümesinde ise %46.15 oranında sınıflandırdığı görülmektedir. LR yönteminin İMKB 100 endeksi hareket yönünü doğru sınıflandırma oranı ise; eğitim kümesinde %70.96 iken test kümesinde %63.15 olarak gözlenmiştir.

DESTEK VEKTÖR MAKİNELERİ

Aylık Model-4 için; 10 kat çapraz geçişleme kullanılarak yapılan analizde, en iyi parametre kombinasyonu ($C=10^2$, $\gamma=10^{-1}$) için en iyi doğruluk oranı %77.20 bulunmuştur. DVM, eğitim kümesindeki 92 artış verisinin 74 tanesini doğru sınıflandırırken, 63 azalış verisinin 36 tanesini doğru sınıflandırmıştır. Test


kümesinde ise, 25 artış verisinin 17 tanesini doğru sınıflandırırken, 13 azalış verisinin 6 tanesini doğru sınıflandırmıştır.

Tablo 24. Aylık Model-4'de DVM Yöntemi Sınıflandırma Başarısı

		EĞİTİM KÜMESİ (Modelleme Kümesi)			TEST KÜMESİ (Tahmin Kümesi)		
		Tahmin		Doğru Sınıflandırma Oranı (%)	Tahmin		Doğru Sınıflandırma Oranı (%)
Gerçek		0	1		0	1	
	0	36	27	57.14	6	7	46.15
	1	18	74	80.43	8	17	68.0
TOPLAM		155		70.96	38		60.52

Tablo 24 incelendiğinde, DVM yönteminin, İMKB 100 endeksinin artış yönünü eğitim kümesinde %80.43, test kümesinde %68.0 oranında sınıflandırırken, endeksin azalış yönünü eğitim kümesinde %57.14, test kümesinde ise %46.15 oranında sınıflandırdığı görülmektedir. DVM yönteminin İMKB 100 endeksi hareket yönünü doğru sınıflandırma oranı ise; eğitim kümesinde %70.96 iken test kümesinde %60.52 olarak gözlenmiştir.

Şekil 7'de aylık veriler kullanılarak oluşturulan dört ayrı model için uygulanan analiz sonuçlarına göre, İMKB 100 endeksi artış ve azalış hareket yönü sınıflandırma oranları her iki yöntem içinde karşılaştırmalı olarak verilmiştir.



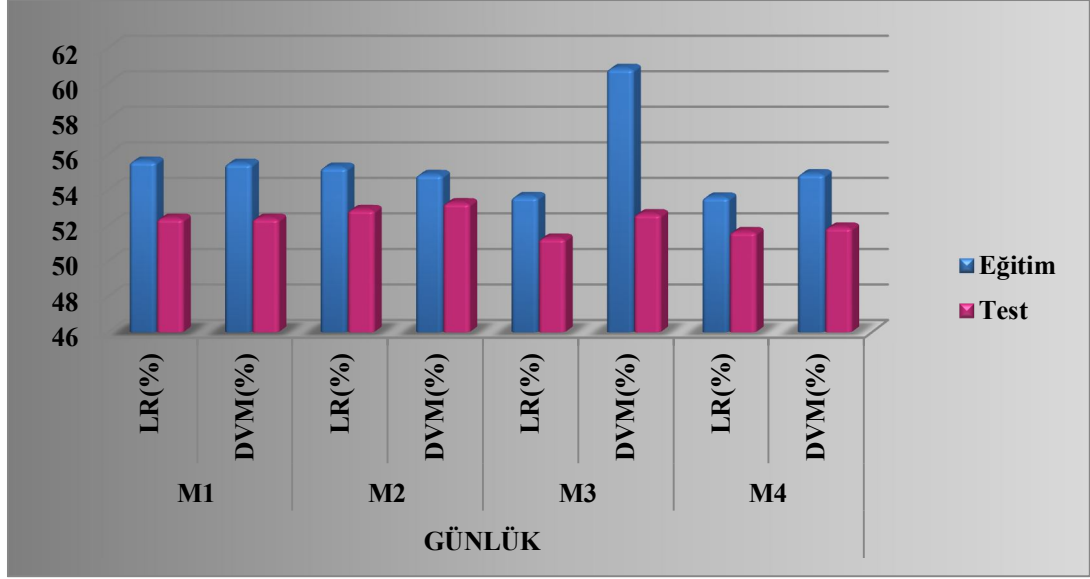
Şekil 7. Aylık Modeller İçin LR ve DVM'nin Artış "1", Azalış "0" Yön Tahminleri

Şekil 7'de test kümesi sonuçları incelendiğinde, günlük ve haftalık verilerle kurulan model sonuçlarının aksine DVM ve LR'nin, İMKB 100 endeksi artış ve azalış hareket yönünü sınıflandırmadaki başarıları birbirine yakın gözlenmiştir. Model-1'de artış ve azalış yönünü sırayla LR (%68.0, %53.84), DVM'den (%56.0, %38.46) daha başarılı sınıflandırırken, Model-3'de artış ve azalışları sırayla DVM (%72.0, %46.15) LR'den (%68.0, %38.46) daha iyi sınıflandırmıştır. Aylık Model-2 sonuçlarına bakıldığında DVM'nin (%76.0) artışları, LR'den (%72.0) daha iyi, azalışları ise LR'nin (%53.84) DVM'den (%38.46) daha iyi sınıflandırdığı, Model-4'te ise azalışları her iki yöntemin de aynı oranda (%46.15) sınıflandırdığı ancak artışları LR'nin (%72), DVM'den (%68) daha iyi sınıflandırdığı görülmektedir.

4.3. ANALİZ SONUÇLARININ GENEL DEĞERLENDİRİLMESİ

Günlük veriler kullanılarak uygulanan analiz sonuçlarının değerlendirilmesi:

Günlük veriler ile uygulanan analizde, İMKB 100 endeksinin günlük değerlerinden oluşan veri seti için dört model oluşturulmuştur. Her model için uygulama sonuçları aşağıda değerlendirilmiştir.



Şekil 8. LR ve DVM Yöntemlerinin Günlük Modellere Göre Doğru Sınıflandırma Yüzdeleri

Şekil 8'de günlük veri seti için oluşturulan dört ayrı model için LR ve DVM yöntemlerinin İMKB 100 endeksi hareket yönünü doğru sınıflandırma sonuçları verilmiştir. Değişken seçimi yapılmadan oluşturulan Model-1 analiz sonuçları incelendiğinde; LR yönteminin, İMKB 100 endeksi hareket yönünü doğru sınıflandırma oranı; eğitim kümesinde %55.63, test kümesinde %52.42 iken DVM yöntemi İMKB 100 endeksi hareket yönünü; eğitim kümesinde %55.51, test kümesinde ise %52.42 oranında sınıflandırma yaptığı görülmektedir.

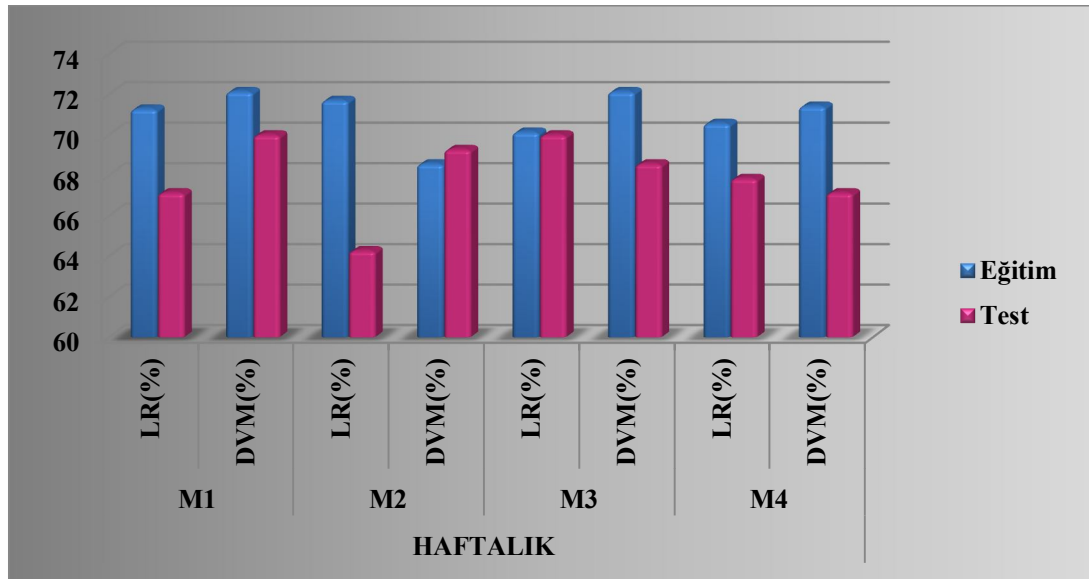
LR analizinde anlamlılık değeri $p < 0.25$ olan 14 bağımsız değişken ile oluşturulan Model-2 analiz sonuçları incelendiğinde; LR yönteminin İMKB 100 endeksi hareket yönünü doğru sınıflandırma oranı; eğitim kümesinde %55.29 iken test kümesinde %52.91'dir. DVM yönteminin İMKB 100 endeksi hareket yönünü doğru sınıflandırma oranı ise; eğitim kümesinde %54.88 iken test kümesinde %53.29 olduğu gözlenmiştir.

LR analizinde anlamlılık değeri $p < 0.05$ olan yedi bağımsız değişken ile oluşturulan Model-3 incelendiğinde; LR yönteminin İMKB 100 endeksi hareket yönünü doğru sınıflandırma oranı; eğitim kümesinde %53.64, test kümesinde %51.30 iken DVM yöntemi, endeksin hareket yönünü eğitim kümesinde %60.85, test kümesinde %52.67 oranında doğru sınıflandırmıştır.

LR analizinde anlamlılık değeri $p < 0.05$ olan üç bağımsız değişken ile oluşturulan Model-4 analiz sonuçları incelendiğinde ise; LR yönteminin İMKB 100 endeksi hareket yönünü eğitim kümesinde %53.61, test kümesinde %51.67 oranında doğru sınıflandırırken, DVM yönteminin İMKB 100 endeksi hareket yönünü eğitim kümesinde %54.92, test kümesinde %51.92 oranında sınıflandırdığı görülmektedir.

Haftalık veriler kullanılarak uygulanan analiz sonuçlarının değerlendirilmesi:

Haftalık veriler ile uygulanan analizde, İMKB 100 endeksinin haftalık değerlerinden oluşan veri seti için dört model oluşturulmuştur. Şekil 9'da haftalık veri seti için oluşturulan dört ayrı model için LR ve DVM yöntemlerinin İMKB 100 endeksi hareket yönünü doğru sınıflandırma sonuçları verilmiştir.



Şekil 9. LR ve DVM Yöntemlerinin Haftalık Modellere Göre Doğru Sınıflandırma Yüzdeleri

Tüm değişkenler kullanılarak uygulanan Model-1 analiz sonuçları incelendiğinde; LR yönteminin İMKB 100 endeksi hareket yönünü doğru sınıflandırma oranı; eğitim kümesinde %71.28 iken test kümesinde %67.14'dür.

DVM yönteminin ise, İMKB 100 endeksi hareket yönünü doğru sınıflandırma oranı ise; eğitim kümesinde %72.14 iken test kümesinde %70.0 olduğu görülmektedir.

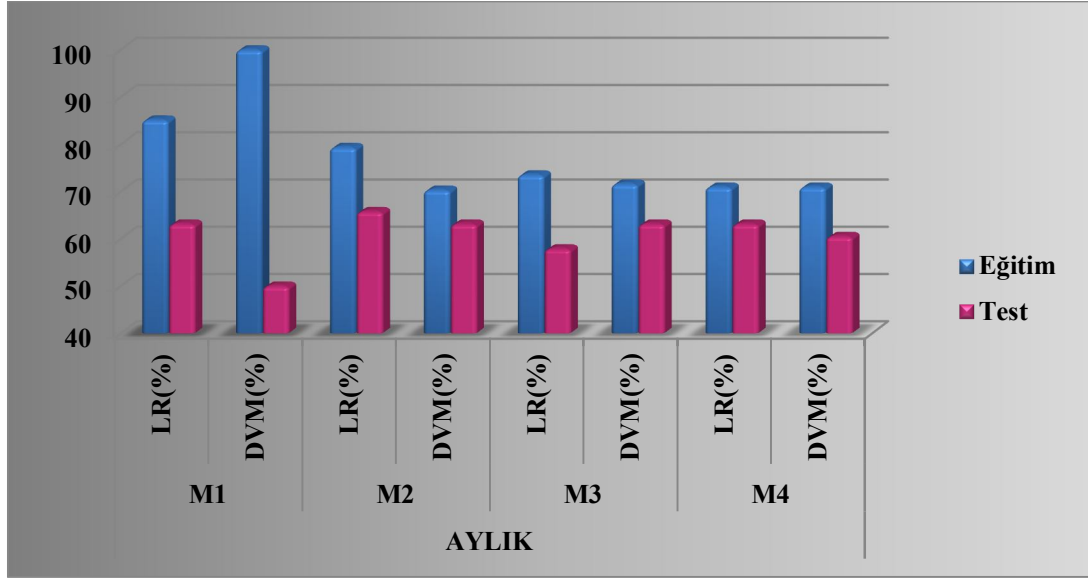
LR analizinde anlamlılık değeri $p < 0.25$ olan 15 bağımsız değişken ile oluşturulan Model-2 analiz sonuçları incelendiğinde; LR yönteminin İMKB 100 endeksi hareket yönünü doğru sınıflandırma oranı eğitim kümesinde %71.71, test kümesinde %64.28 iken DVM yönteminin, endeksin hareket yönünü eğitim kümesinde %68.57 iken test kümesinde %69.28 oranında sınıflandırdığı gözlenmiştir.

LR analizinde anlamlılık değeri $p < 0.05$ olan yedi bağımsız değişken ile oluşturulan Model-3 analiz sonuçları incelendiğinde; LR yönteminin İMKB 100 endeksi hareket yönünü doğru sınıflandırma oranı; eğitim kümesinde %70.14, test kümesinde %70.0 olarak gözlenirken, DVM yöntemi İMKB 100 endeksi hareket yönünü eğitim kümesinde %72.14 iken test kümesinde %68.57 oranında doğru sınıflandırmıştır.

LR analizinde anlamlılık değeri $p < 0.05$ olan dört bağımsız değişken ile oluşturulan Model-4 analiz sonuçları incelendiğinde; LR yönteminin İMKB 100 endeksi hareket yönünü eğitim kümesinde %70.57, test kümesinde %67.85 oranında sınıflandırırken, DVM yönteminin, İMKB 100 endeksi hareket yönünü doğru sınıflandırma oranı; eğitim kümesinde %71.42 iken test kümesinde %67.14 olarak gözlenmiştir.

Aylık veriler kullanılarak uygulanan analiz sonuçlarının değerlendirilmesi:

Aylık veriler ile uygulanan analizde, İMKB 100 endeksi aylık değerlerinden oluşan veri seti için dört model oluşturulmuştur. Şekil 10'da aylık veri seti için oluşturulan dört ayrı model için LR ve DVM yöntemlerinin İMKB 100 endeksi hareket yönünü doğru sınıflandırma sonuçları verilmiştir.



Şekil 10. LR ve DVM Yöntemlerinin Aylık Modellere Göre Doğru Sınıflandırma Yüzdeleri

Değişken seçimi yapılmadan uygulanan Model-1 analiz sonuçları incelendiğinde; LR yönteminin İMKB 100 endeksi hareket yönünü doğru sınıflandırma oranının; eğitim kümesinde %85.16 iken test kümesinde %63.15 olduğu görülmektedir. DVM yöntemi ise İMKB 100 endeksi hareket yönünü eğitim kümesinde %100 oranında sınıflandırırken, test kümesinde bu oran %50.0 olarak gözlenmiştir.

LR analizinde anlamlılık değeri $p < 0.25$ olan 10 bağımsız değişken ile uygulanan Model-2 analiz sonuçları değerlendirildiğinde; LR yönteminin İMKB 100 endeksi hareket yönünü eğitim kümesinde %79.35 iken test kümesinde %65.78 oranında sınıflandırırken, DVM, İMKB 100 endeksi hareket yönünü eğitim kümesinde %70.32, test kümesinde %63.15 oranında doğru sınıflandırmıştır.

LR analizinde anlamlılık değeri $p < 0.05$ olan iki bağımsız değişken ile uygulanan Model-3 analiz sonuçların incelendiğinde; LR yönteminin İMKB 100 endeksi hareket yönünü doğru sınıflandırma oranı; eğitim kümesinde %73.54, test kümesinde %57.89'dir. DVM ise, endeksin hareket yönünü eğitim kümesinde %71.61, test kümesinde %63.15 oranında sınıflandırmıştır.

LR analizinde anlamlılık değeri $p < 0.05$ olan bir bağımsız değişken ile uygulanan Model-4 analiz sonuçları incelendiğinde; LR yöntemi İMKB 100 endeksi hareket yönünü eğitim kümesinde %70.96, test kümesinde %63.15 oranında doğru

sınıflandırırken, DVM yönteminin, endeksin hareket yönünü doğru sınıflandırma oranları; eğitim kümesinde %70.96 iken test kümesinde %60.52 olarak gözlenmiştir.

5. BÖLÜM: SONUÇ VE TARTIŞMA

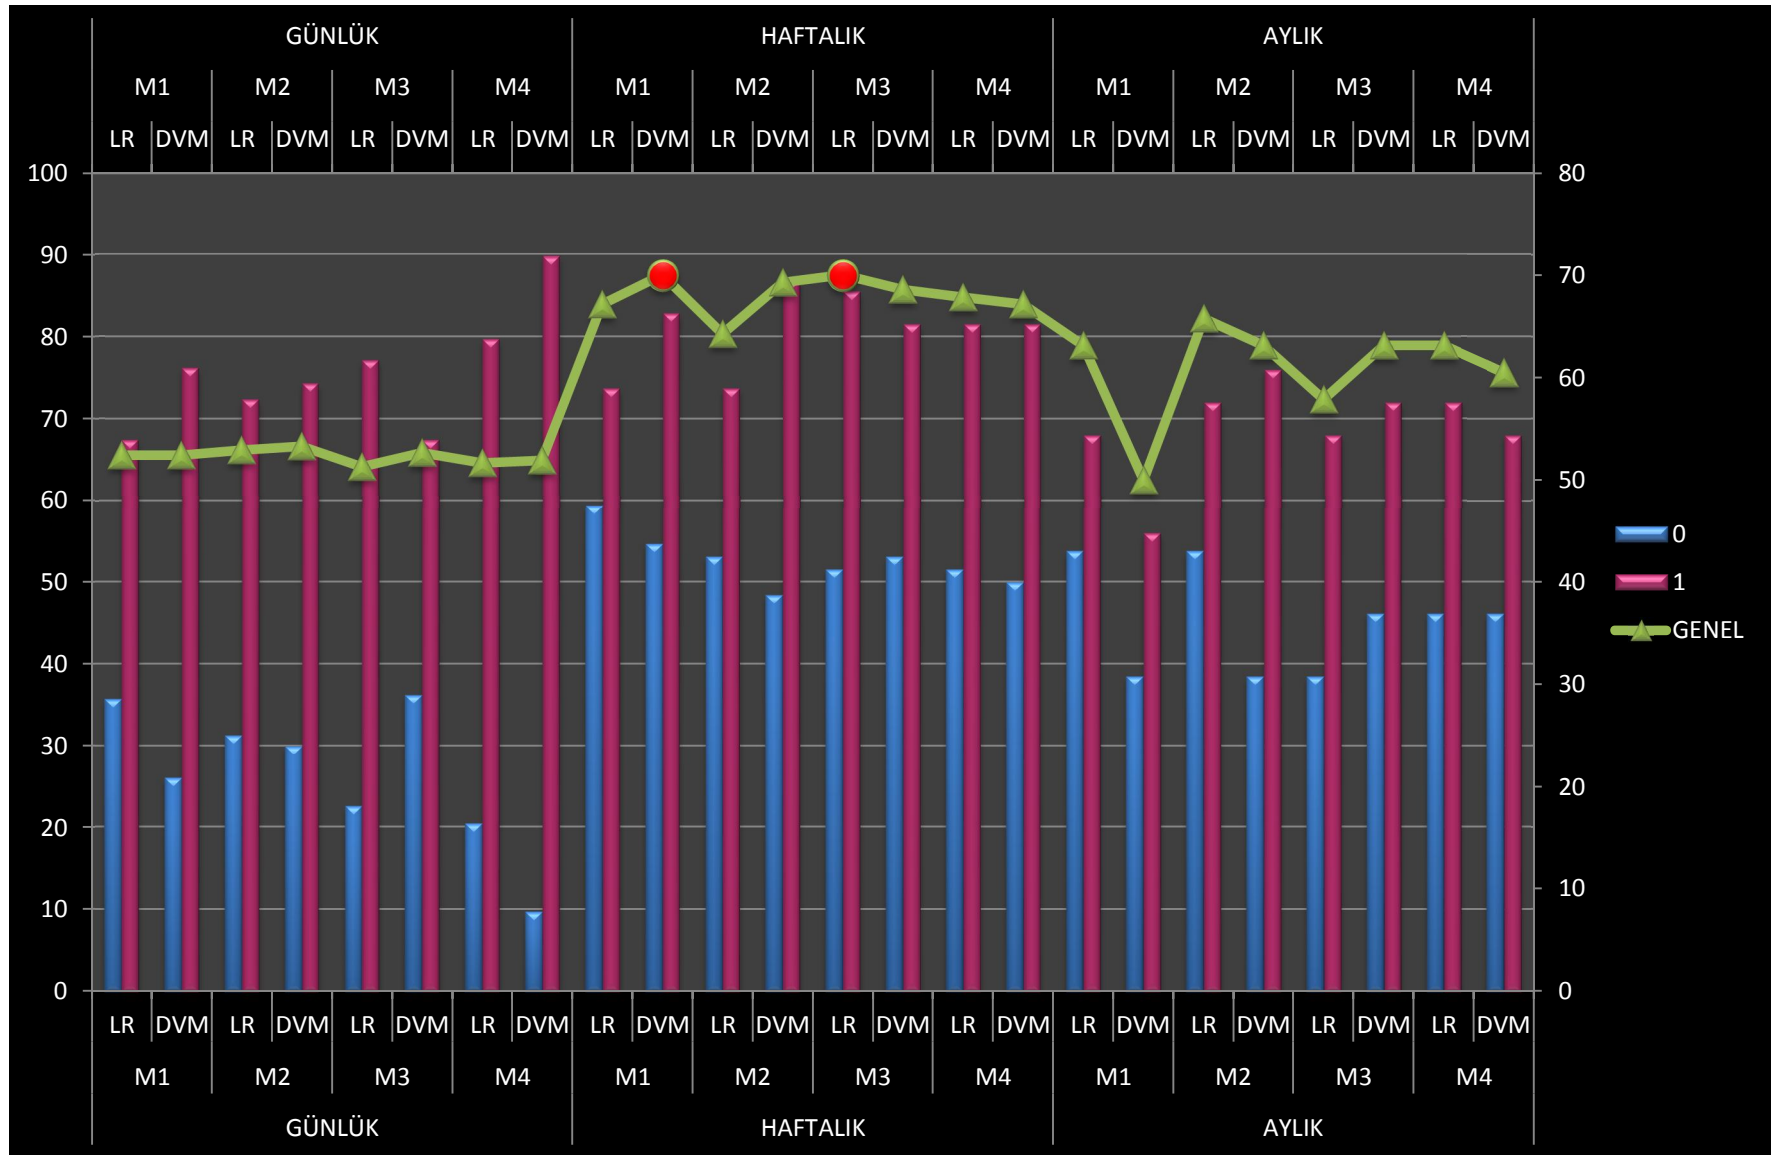
Hisse senetlerinin gelecek yönünün tahmini, hisse senedi fiyatlarının diğer yatırım araçlarına nazaran yüksek belirsizlik ve volatiliteye sahip olması nedeni ile gerek yatırımcılar gerekse araştırmacılar için önem arz etmiştir. Bu durum, hisse senedi tahminine yönelik, geçmişten günümüze, farklı değerlendirme yöntemleri ve pek çok farklı teknik kullanılarak çok sayıda tahmin çalışması yapılmasına sebep olmuştur.

Literatürde İMKB 100 endeksi tahminine yönelik gerek klasik teknikler ile gerek veri madenciliği yöntemlerinden YSA'nın kullanıldığı çok sayıda çalışma olmasına karşın, DVM'lerin kullanıldığı sadece iki çalışmaya rastlanılmıştır. Oldukça yeni bir öğrenme algoritması olan DVM'lerin, hisse senedi analizlerinde diğer yöntemlere alternatif bir yöntem olarak kullanılabilirliğini göstermek ve hangi veri seti üzerinde en iyi tahmin performansı gösterdiğini belirlemek amacıyla bu çalışmada ikili sınıflamaya imkan tanıyan DVM yöntemi kullanılmıştır.

Çalışmada analiz dönemi olarak belirlenen 1995/2012 dönemi, günlük, haftalık ve aylık veri setleri halinde değerlendirilmiş, haftalık ve aylık veriler için uygulanan ortalama alma ile gürültüden arındırma yapılmıştır. Her veri seti için oluşturulan model sonuçları çalışmada kullanılan diğer bir yöntem olan LR yöntemi ile karşılaştırılmıştır.

Uygulamada üç veri setinin (günlük, haftalık, aylık) herbiri için dört model oluşturulmuştur. Kurulan her model için analize dahil edilecek değişkenler LR analizi yapılarak belirlenmiştir. RBF DVM'lerin parametre optimizasyonu için çapraz geçerlilik uygulanmış böylelikle en iyi doğruluk oranı tespit edilerek DVM eğitimi gerçekleştirilmiştir.

Analiz sonuçları, öncelikle her iki yöntem için İMKB 100 endeksi artış ve azalış hareket yönü doğru sınıflandırma başarıları, ardından eğitim ve test kümesi için genel başarı oranları ayrı ayrı değerlendirilmiştir. Yapılan değerlendirmeler itibariyle aşağıdaki sonuçlara ulaşılmıştır:



Şekil 11. LR ve DVM Yöntemlerinin Artış "1", Azalış "0" Yön Tahminleri ve Genel Sınıflandırma Tahmin Sonuçları

Şekil 11'de LR ve DVM'nin her model için artış ve azalış yön tahminleri ve tahmin kümesi için doğru sınıflandırma yüzdeleri verilmiştir. Turuncu ile işaretli noktalar her iki yöntemde en iyi tahmin sonuçlarını göstermektedir. Değişken seçimi yapılmadan oluşturulan Günlük Model-1 analiz sonuçlarına bakıldığında, her iki yöntemde İMKB 100 endeksi yönünü doğru sınıflandırma oranının aynı olduğu görülmektedir (%52.42). Bu modelde azalışları LR (%35.69), DVM'den (%25.98) daha iyi tahminlerken, artışları DVM (%76.17), LR'den (%67.45) daha iyi tahminlemiştir. Haftalık veriler ile kurulan Model-1 analiz sonuçları incelendiğinde, haftalık veriler kullanıldığında yani örnek sayısı daha az olduğunda DVM sınıflandırma performansının arttığı görülmektedir. LR yöntemi endeksin hareket yönünü tahmin kümesinde %67.14 oranında doğru sınıflandırırken, DVM yöntemi %70.0 oranında sınıflandırmıştır. Bu sonuçlar ışığında haftalık ve aylık veriler için uygulanan gürültüden arındırmanın LR ve DVM'nin performansını arttırdığı açıktır. Haftalık Model-1 aynı zamanda artış ve azalış tahmin oranlarının birbirine en yakın olduğu modellerden biridir. DVM artışları (%82.89), azalışları ise (%54.68) oranında tahminlerken, LR artışları (%73.68), azalışları ise (%59.37) oranında tahminlemiştir. Ancak Aylık Model-1 sonuçları gösterir ki değişken seçimi yapılmadığında, veriler gürültüden arındırılrsa da DVM performansına negatif yönde etki etmektedir. Aylık Model-1'de DVM ve LR'nin genel sınıflandırma oranları azalmış olsa da, her iki yöntem için de artış ve azalışların birbirine en yakın olduğu modellerden diğeri de bu modeldir. DVM artışları (%56.0), azalışları (%38.46) oranında tahminlerken, LR artışları (%68.0), azalışları (%53.84) oranında tahminlemiştir. Şekil 11'de Aylık Model-1 sonuçları incelendiğinde, her iki yöntemde genel sınıflandırma oranlarının çok düşük olmasına rağmen artış ve azalış tahmin düzeylerinin yakınlığı net bir şekilde görülmektedir.

Anlamlılık değeri $p < 0.25$ olan bağımsız değişkenler ile uygulanan analiz sonuçlarına göre, her iki yöntem için de en iyi tahmin performansının 15 bağımsız değişkenin analize dahil edildiği haftalık verilerle oluşturulan Model-2'de olduğu gözlenmiştir. DVM'nin İMKB 100 endeksinin hareket yönünü doğru sınıflandırma oranı %69.28, LR %64.28'dir. Bu modelde artışları DVM (%86.84), LR'den (%73.68) daha iyi tahminlerken, azalışları ise LR (%53.12), DVM'den (%48.43) daha iyi tahminlemiştir. 14 bağımsız değişken ile kurulan Günlük Model-2 sonuçları da DVM'nin tahmin performansının (%53.29), LR'den daha iyi olduğunu göstermektedir (%52.91). Ancak bağımsız değişken sayısını azalttığımız Aylık

Model-2 sonuçları incelendiğinde DVM'nin tahmin performansında (%63.15), LR'ye göre azalma gözlenmiştir (%65.78). Günlük ve Aylık Model-2 sonuçlarında da yine artışları DVM'nin (Günlük M2: %74.29, Aylık M2: %76.0) LR'den (Günlük M2: %72.40, Aylık M2: %72.0) daha iyi tahmin ettiği, azalışları ise LR'nin (Günlük M2: %31.23, Aylık M2: %53.84) DVM'den (Günlük M2: %29.92, Aylık M2: %38.46) daha iyi tahminlediği sonucuna ulaşılmıştır.

Anlamlılık değeri $p < 0.05$ olan bağımsız değişkenler ile uygulanan Günlük, Haftalık ve Aylık Model-3 sonuçlarını genel olarak değerlendirdiğimizde, DVM'nin İMKB 100 endeksi hareket yönünü doğru tahminleme oranının LR'den daha iyi olduğunu göstermektedir. Yedi bağımsız değişken ile uygulanan Günlük ve Haftalık Model-3 sonuçları karşılaştırıldığında, Günlük Model-3; DVM %52.67, LR %51.30 iken Haftalık Model-3; DVM %68.57, LR %70.0 olduğu gözlenmiştir. Günlük, Haftalık ve Aylık Model-3 analizlerinde, DVM'nin en iyi tahmin performansı yedi bağımsız değişken ile uygulanan Haftalık Model-3'te gözlenmiştir (%68.57). Aynı durum Aylık Model-3 sonucunda da geçerlidir. DVM %63.15 ile LR'den (%57.89) daha yüksek sınıflandırma başarısı göstermiştir. Günlük ve Haftalık Model-3'te diğer model sonuçlarının aksine azalışları DVM, artışları ise LR daha iyi tahminlemiştir. Günlük Model-3 için, DVM azalış yön tahmin oranı %36.22, LR %22.57 iken DVM artış yön tahmin oranı %67.45, LR %77.12'dir. Haftalık Model-3 için DVM azalış yön tahmin oranı %53.12, LR %51.56, artış yön tahmini DVM %81.57, LR ise %85.52'dir.

Anlamlılık değeri $p < 0.05$ olan bağımsız değişkenler ile uygulanan Günlük, Haftalık ve Aylık Model-4 sonuçlarını genel olarak değerlendirdiğimizde, üç bağımsız değişken ile uygulanan Günlük Model-4 sonucu incelendiğinde, DVM'nin tahmin performansı %51.92 ile LR'den (%51.67) daha iyi iken, dört bağımsız değişken ile uygulanan haftalık Model-4'te DVM %67.14, LR ise %67.85 oranında doğru tahminleme yapmıştır. Tek bağımsız değişken ile uygulanan Aylık Model-4 sonuçları (DVM %60.52, LR %63.15), DVM'nin tahmin oranının azaldığını göstermiştir. Aylık Model-4'de LR ve DVM yöntemleri azalışları aynı oranda tahminlerken (%46.15), artışları LR'nin (%72.0), DVM'den (%68.0) daha iyi tahminlediği gözlenmiştir.

Bu bilgiler ışığında şu sonuçlara ulaşılmıştır;

- İMKB 100 endeksi hareket yönünü tahminlemede, uygulamada kullanılan her iki yöntemin tahmin sonuçları birbirine yakın gözlenirse de, genel olarak değerlendirildiğinde DVM, LR yöntemine göre daha iyi doğru sınıflandırma performansı göstermektedir.
- Farklı veri setleri için uygulanan model sonuçları, DVM yönteminin, İMKB 100 endeksi artış yönünü, azalış yönünden daha yüksek performansla tahminlediğini göstermiştir. LR ise endeksin azalış yönünü tahminlemede daha başarılı bulunmuştur.
- Değişken seçimi yapılarak oluşturulan model sonuçları gösterir ki teknik analiz göstergeleri anlamlı bir şekilde DVM tahmin performansına etki etmektedir.
- Üç farklı veri seti için oluşturulan model sonuçlarına göre LR yönteminin en iyi performansı Haftalık Model-3'te gözlenmiştir (%70.0). Ancak bu modelde artış (%85.52) ve azalış (%51.56) tahmin sonuçları arasındaki fark çok fazladır. LR yönteminin artış ve azalışları birbirine en yakın tahminlediği modeller; Haftalık Model-1 ve Aylık Model-1'dir. Haftalık Model-1'de LR artışları (%73.68) azalışları (%59.37) olarak tahminlerken, Aylık Model-1'de artışları (%68.0), azalışları ise (%53.84) oranında tahminlemiştir. Tahmin oranları arasındaki farklar birbirine yakınlık gösterse de, Aylık Model-1'de LR genel sınıflandırma oranı (%63.15), Haftalık Model-1'e göre (%67.14) daha düşüktür.
- DVM performansı, gürültüden arındırılmış veri setlerinde, gürültüden arındırılmayan günlük veri seti tahminlerinden çok daha iyidir. Şöyle ki; günlük, haftalık, aylık veri setleri ile oluşturulan model sonuçlarına göre DVM'nin en iyi performansının haftalık model sonuçlarında aldığı gözlenmiştir. DVM'nin İMKB 100 endeksi hareket yönünü en iyi tahminleme oranı (%70.0) Haftalık Model-1'de gözlenmiştir. Bu model aynı zamanda artışların (%54.68) ve azalışların (%82.89) en iyi tahmin edildiği modellerden biridir. Artış ve azalışların yüksek oranda ve birbirine en yakın tahmin edildiği modellerden bir diğeri de Haftalık Model-3'tür. Haftalık Model-3'te DVM artışları %81.57, azalışları ise %53.12 oranında sınıflandırmıştır. Ancak bu modelde genel sınıflandırma oranı %68.57'dir. Sınıflandırma

problemlerinde genel doğruluk oranının yüksek oranda olmasının yanı sıra her sınıfın tahmin düzeyinin yüksek olması (birbirine yakın olması) arzu edilir ve bu sonuçları veren modelin uzun vadede kazandıracığı düşünülür. Bu nedenle, İMKB 100 endeks yönünün tahmininde Haftalık Model-1'in kullanılabilirliğini önermekteyiz.

Kara vd. (2011)'nin İMKB 100 endeksini tahminlemek amacıyla 10 teknik gösterge ve günlük kapanış fiyatları kullanarak yaptıkları benzer çalışmada, YSA ve DVM yöntemlerini karşılaştırmışlar ve YSA'nın (%75.74), DVM'den (%71.52) daha iyi sonuç verdiği sonucuna ulaşmışlardır. Bu çalışmada ise günlük verilerle oluşturulan modellerde DVM'nin, LR'den daha başarılı sınıflandırma yaptığı sonucuna ulaşılmasına rağmen DVM'nin günlük modellerde genel sınıflandırma oranı düşük gözlenmiştir. Bu tez çalışmasına benzer şekilde, İMKB 100 endeksi getiri yönünü tahminlemek amacıyla LR ve DVM yöntemini kullanan Özdemir vd. (2011) aylık veriler kullanarak yaptıkları çalışmalarında, değişken seçimi ile uyguladıkları analizde arama yöntemi olarak GA'dan yararlanmışlardır. Çalışmada LR genel sınıflandırma oranı %86.2 iken DVM'nin tüm değişkenler ile oluşturulan modelde genel sınıflandırma oranı %79.3, değişken seçimi ile oluşturulan modelde ise %86.2'dir. Ancak gerek tüm değişkenler ile kurulan modelde (pozitif getiri yönü tahmin oranı: %93.8, negatif getiri oranı: %61.5) gerekse değişken seçimi sonucu oluşturulan modelde (pozitif getiri yönü tahmin oranı: %100, negatif getiri oranı: %69.2) DVM'nin İMKB 100 endeksi pozitif ve negatif getiri yönünü doğru sınıflandırma oranları arasındaki fark fazladır. Bu çalışmada ise DVM ve LR yöntemleri için en iyi genel tahmin oranı (%70.0) bulunmuş ancak artış ve azalış yön tahminlerinde birbirine yakın oranlar gözlenmiştir.

Bu çalışmada kullanılan üç ayrı veri setinden yalnızca haftalık ve aylık veriler için gürültüden arındırma yapılmıştır. Bundan sonra yapılacak çalışmalarda, çok fazla dalgacı olmasından dolayı gürültü içerdiği kabul edilen günlük veriler içinde gürültüden arındırmanın DVM performansına olumlu etki edeceği düşünülmektedir. Sui vd. (2007)'nin, günlük verileri dalgacık sıkıştırma yöntemi ile gürültüden arındırmaları ve gürültüden arındırılmış veri setinde (%60.12), gürültü içeren veri setine göre (%54.25) daha iyi sonuçlar almış olmaları bu düşüncüyü onaylamaktadır.

Bu tezin literatüre katkıları şu şekilde özetlenebilir;

İMKB 100 endeksi tahminine yönelik yapılan çalışmalarda genel olarak kullanılan YSA ve diğer klasik tekniklerden farklı olarak DVM yöntemi

kullanılmıştır. DVM yöntemi diğer bir sınıflandırma yöntemi olan LR ile karşılaştırılmıştır ve İMKB 100 endeksi hareket yönü tahmininde başarılı bir yöntem olduğu sonucuna ulaşılmıştır.

DVM kullanılarak uygulanan çalışmalarda arama yöntemi olarak kullanılan GA yerine, değişken seçiminde arama yöntemi olarak LR analizinden yararlanılmıştır. LR'nin uygulama kolaylığı ve hesaplama zamanından tasarruf sağlaması nedeniyle arama yöntemi olarak literatürde kullanılan diğer yöntemlere alternatif olduğu sonucuna ulaşılmıştır.

Yapılan literatür incelemesinde İMKB 100 endeksi tahmini için DVM ile yapılan iki çalışmaya rastlanmış ve bu çalışmalarda DVM performansı günlük ve haftalık veriler için değerlendirilmiştir. Bu çalışmada ise üç ayrı veri setinin de analize alınması ve her biri için DVM tahmin sonuçlarının değerlendirilmesinin literatüre önemli bir katkı yaptığı söylenebilir.

Ayrıca çalışmada çok sayıda teknik analiz göstergesinin DVM performansına etkisi değerlendirilmiş ve anlamlı bir şekilde etkilediği gözlenmiştir.

İMKB 100 endeksi yönünün tahmin edildiği diğer çalışmalardan farklı olarak günlük, aylık ve haftalık veri setlerinin her birine göre ayrı ayrı modeller oluşturulması ve bu doğrultuda DVM ve LR yöntemlerinin sınıflandırma başarısının değerlendirilmesi ve DVM'lerinin gürültüden arındırılmış veri setleri ile sınıflandırma başarısı artarken, çok fazla dalgalanma göstermesinden dolayı gürültü içeren günlük veri setlerinde performansının azaldığının ispatlanması bundan sonra İMKB 100 endeksinin tahminine yönelik yapılacak çalışmalara önemli bir katkı sağlamıştır.

Bundan sonra yapılacak çalışmalarda, RBF çekirdek fonksiyonu haricinde farklı çekirdek fonksiyonları ve parametre değerleri kullanılabilir çünkü DVM'ler için çekirdek fonksiyonu seçimi çok önemlidir. Bu çalışmada kullanılan bağımsız değişkenler haricinde farklı değişkenlerle analizler yapılabilir ve değişken seçimi için başka arama algoritmalarından yararlanılabilir. Ayrıca LR yerine farklı sınıflandırma yöntemleri ile yapılacak karşılaştırmaların DVM'nin sınıflandırma gücünü daha net görebilmemize katkı sağlayacağı düşünülmektedir.

EK: KISALTMALAR

Kısaltma	İngilizce Açılımı	Türkçe Açılımı
%R	Williams'%R	Williams'ın %R Göstergesi
A/D	Accumulation/Distribution Oscillator	Toplama/Dağıtım Osilatörü
ALF	Alexander's Filter	Alexander Filtresi
ARCH	Autoregressive Conditional Heteroscedasticity	Otoregresif Koşullu Değişen Varyans
ARIMA	Autoregressive Integrated Moving Average	Bütünleştirilmiş Otoregresif Hareketli Ortalama
ARMA	Autoregressive Moving Averages	Otoregresif Hareketli Ortalamalar
BB	Bollinger Bands	Bollinger Bantları
BPNN	Back-Propagation Neural Networks	Geri Yayılım Sinir Ağları
CBR	Case-Based Reasoning	Durum Tabanlı Çıkarsama
CCI	Commodity Channel Index	Mal Kanal Endeksi
CFS	Correlation-Based Feature Selection	Korelasyon Tabanlı Özellik Seçimi
CO	Chaikin Oscillator	Chaikin Osilatörü
DA	Discriminant Analysis	Diskriminant Analizi

DI	Directional Indicator	Yönel Gösterge
Dn	Disparity	Kapanış Fiyatının n Günlük Hareketli Ortalamaya Oranı
EBNN	Elman Back-propagation Neural Networks	Elman Geri Yayılım Sinir Ağları
EMA	Exponential Moving Avarage	Üssel Hareketli Ortalama
FNN	Fuzzy Neural Networks	Bulanık Sinir Ağları
F_SSFS	F-Score and Supported Sequential Forward Search	F Değeri ile Desteklenen Sıralı İleri Arama
GA	Genetic Algorithm	Genetik Algoritma
GADVM	Genetic Algorithm-Based Support Vector Machine	Genetik Algoritma Tabanlı Destek Vektör Makineleri
GARCH	Generalized Autoregressive Conditional Heteroskedasticity	Genelleştirilmiş Otoresif Koşullu Değişen Varyans Analizi
LDA	Linear Discriminant Analysis	Doğrusal Diskriminat Analizi
LIBSVM	A Library for Support Vector Machines	Açık Kaynak Kodlu DVM Kütüphanesi
LR	Logistic Regression	Lojistik Regresyon
MA	Moving Average	Hareketli Ortalama
MACD	Moving Average Convergence-Divergence Indicator	Hareketli Ortalamaların Birleşmesi-Ayrılması Göstergesi
MAE	Mean Absolute Error	Ortalama Mutlak Hata
MAPE	Mean Absolute Percent Error	Ortalama Mutlak Hata Yüzdesi

MDA	Multiple Discriminate Analysis	Çoklu Diskriminant Analizi
MFI	Money Flow Index	Para Akım Endeksi
MKSVR	Multiple Kernel Support Vector Regression	Çoklu Çekirdek Destek Vektör Regresyon
ML	Makximum Likelihood	Maksimum Olabilirlik
MLP	Multi Layer Perceptron	Çok Katmanlı Pörseptron
MSE	Mean Square Error	Ortalama Karesel Hata
MSO	Moving Stochastic Oscillator	Hareketli Stokastik Osilatör
NMSE	Normalized Mean Squared Error	Normalize Edilmiş Ortalama Karesel Hata
NN	Neural Networks	Sinir Ağları
OBV	On Balance Volume	Denge İşlem Hacmi Göstergesi
PSY	Psychological Line	Psikolojik Sınır
QDA	Quadratic Discriminant Analysis	Kuadratik Diskriminant Analizi
RBF	Radial Basis Function	Radyal Tabanlı Çekirdek Fonksiyonu
RDP	Relative Difference in Percentage of Price	Fiyatın Göreceli Oransal Farkı
RMSE	Root Mean Square Error	Hata Kareler Ortalamasının Karekökü
ROC	Rate of Change	Değişim Oranı
RSI	Relative Strength Index	Göreceli Güç Endeksi
RW	Random Walk Model	Rasgele Yürüyüş Modeli
SKSVR	Single Kernel Support Vector Regression	Tek Çekirdek Destek Vektör Regresyon
SMA	Simple Moving Average	Basit Hareketli Ortalama
SO	Stochastic Oscillator	Stokastik Osilatör

SOFM	Self Organizing Feature Map	Kendini Örgütleyen Özellik Haritaları
SOM	Self Organizing Map	Ön düzenleyici Haritalar
SSO	Slow Stochastic Oscillator	Yavaş Stokastik Osilatör
SVM	Support Vector Machines	Destek Vektör Makineleri
WMA	Weighted Moving Average	Ağırlıklı Hareketli Ortalama
WR	Williams Overbought/Oversold Index	Williams'ın Aşırı Alım/Aşırı Satım Göstergesi

KAYNAKÇA

- Abe, S. (2005). *Support Vector Machines For Pattern Classification*. London: Springer.
- Afşar, A. ve Afşar, M. (2010). *Finansal Ekonomi SPK Lisanslama Sınavlarına Uyumlu*. Ankara: Detay Yayıncılık.
- Akay, A. (2009). Yapay Sinir Ağları ile İMKB-100 Endeksi Gelecek Değer Öngörüsü. Yayınlanmış Yüksek Lisans Tezi, Karadeniz Teknik Üniversitesi Sosyal Bilimler Enstitüsü, Trabzon.
- Akbilgiç, O. (2011). Hibrit Radyal Tabanlı Fonksiyon Ağları ile Değişken Seçimi ve Tahminleme: Menkul Kıymet Yatırım Kararlarına İlişkin Bir Uygulama. Yayınlanmış Doktora Tezi, İstanbul Üniversitesi Sosyal Bilimler Enstitüsü, İstanbul.
- Akcan A. ve Kartal C. (2011). İMKB Sigorta Endeksini Oluşturan Şirketlerin Hisse Senedi Fiyatlarının Yapay Sinir Ağları İle Tahmini. *Muhasebe ve Finansman Dergisi*, 27-40.
- Akel, V. ve Bayramoğlu, M. F. (2008). Kriz Dönemlerinde Yapay Sinir Ağları ile Finansal Öngöründe bulunma: İMKB 100 Endeksi Örneği. International Symposium on International Capital Flows and Emerging Markets, 24-28 Nisan 2008, Balıkesir, Bandırma.
- Akgüç, Ö. (1998). *Finansal Yönetim*. (7. Baskı). İstanbul: Avcıol Basım Yayın.
- Akpınar, H. (2000). Veri Tabanlarında Bilgi Keşfi ve Veri Madenciliği. *İ.Ü. İşletme Fakültesi Dergisi*, 29(1), 1-22.
- Aksoy, A. ve Tanrıöven, C. (2007). *Sermaye Piyasası Yatırım Araçları ve Analizi*. (3. Baskı). Ankara: Gazi Kitabevi.
- Aktaş, C. (2009). Lojistik Regresyon Analizi: Öğrencilerin Sigara İçme Alışkanlığı Üzerine Bir Uygulama. *Sosyal Bilimler Enstitüsü Dergisi*, 26(1), 107-121.
- Albayrak, A. S. (2006). *Uygulamalı Çok Değişkenli İstatistik Teknikleri*. (1.Baskı). Ankara: Asil Yayın Dağıtım.
- Albayrak, A. S. ve Koltan Yılmaz, Ş. (2009). Veri Madenciliği: Karar Ağacı Algoritmaları ve İMKB Verileri Üzerine Bir Uygulama. *Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 14(1), 31-52.

- Alpaydın, E. (2011). *Yapay Öğrenme*. (1. Baskı). İstanbul: Boğaziçi Üniversitesi Yayınevi.
- Atakurt, Y. (1999). Lojistik Regresyon ve Tıp Alanında Kullanımına İlişkin Bir Uygulama. *Ankara Üniversitesi Tıp Fakültesi Mecmuası*, 52(4), 191-199.
- Borsanaliz, <http://www.borsanaliz.com/teknik/cc1.shtml> kaynağından 15 Ocak 2012 tarihinde alınmıştır.
- Borsanaliz, <http://www.borsanaliz.com/teknik/aroon.shtml> kaynağından 22 Şubat 2012 tarihinde alınmıştır.
- Burges, C. J. C. (1998). *A Tutorial on Support Vector Machines for Pattern Recognition, Data Mining and Knowledge Discovery*, Kluwer Academic Publishers, Boston, USA, 2, 121-167.
- Burmaoğlu, S. (2009). Birleşmiş Milletler Kalkınma Programı Beşeri Kalkınma Endeksi Verilerini Kullanarak Diskiriminant Analizi, Lojistik Regresyon Analizi ve Yapay Sinir Ağlarının Sınıflandırma Başarılarının Değerlendirilmesi. Yayınlanmış Doktora Tezi, Atatürk Üniversitesi Sosyal Bilimler Enstitüsü, Erzurum.
- Ceylan, A. (2007). Sermaye Piyasaları ve Finansal Kurumlar. N. Aydın (Ed.), *Hisse Senedi Piyasaları* (s. 60-86). Eskişehir: Anadolu Üniversitesi Yayınları.
- Chiu, D. Y. & Chen, P. J. (2009). Dynamically Exploring Internal Mechanism of Stock Market by Fuzzy-Based Support Vector Machines with High Dimension Input Space and Genetic Algorithm. *Expert Systems with Applications*, 36, 1240-1248.
- Civan, M. (2007). *Sermaye Piyasası Analizleri ve Portföy Yönetimi*. Ankara: Gazi Kitabevi.
- Coşkun, S., Kartal, M., Coşkun, A. ve Bircan, H. (2004). Lojistik Regresyon Analizinin İncelenmesi ve Dişhekimliğinde Bir Uygulama. *Cumhuriyet Üniversitesi Diş Hekimliği Fakültesi Dergisi*, 7(1), 41-50.
- Çağırman, H. (1999). *Finans Piyasalarında Bermuda Şeytan Üçgeni*. (1. Baskı). Ankara: Siyasal Kitabevi.
- Diler, A. İ. (2003). İMKB Ulusal-100 Endeksinin Yönünün Yapay Sinir Ağları Hatayı Geriye Yayıma Yöntemi ile Tahmin Edilmesi. *İMKB Dergisi*, 7(25-26), 66-82.
- Ding, Y., Song, X. & Zen, Y. (2008). Forecasting Financial Condition of Chinese Listed Companies Based on Support Vector Machine. *Expert Systems With Applications*, 34, 3081-3089.

- Ege, İ. ve Bayrakdarođlu, A. (2009). İMKB Şirketlerinin Hisse Senedi Getiri Başarılarının Lojistik Regresyon Tekniđi ile Analizi. *ZKÜ Sosyal Bilimler Dergisi*, 5(10), 139-158.
- Erastö, P. (2001). *Support Vector Machines-Backgrounds and Practice, Academic Dissertation for The Degree of Licentiate of Philosophy*. Rolf Nevanlinna Institute, Helsinki.
- Ercan, S. (2011). Destek Vektör Makineleri Kullanarak Patent Deđerleme. Yayınlanmış Yüksek Lisans Tezi, İstanbul Üniversitesi Fen Bilimleri Enstitüsü, İstanbul.
- Günak, N. (2007). *İleri Teknik Analiz Uygulamaları*. (1. Baskı). İstanbul: Literatür Yayıncılık.
- Günay, M. ve Alkan, A. (2010). Spektral Yöntemler ve DVM sınıflandırıcı ile EMG İşaretlerinin Tasnifi. *KSÜ Mühendislik Bilimleri Dergisi*, 13(2), 63-69.
- Gür, N. (2009). Hisse Senedi Fiyat Hareketlerinin Tahmini için Bir Yapay Sinir Ađı Modeli Önerisi. Yayınlanmış Yüksek Lisans Tezi, Kocaeli Üniversitesi Fen Bilimleri Enstitüsü, Kocaeli.
- Haznedarođlu, F. ve Taş, O. (2010). İMKB Endeks Tahmin Sistemi Geliştirmede Finansal Parametrelerin Seçimi. *itüdergisi/d mühendislik*, 9(6), 149-156.
- Hisse.net, <http://www.hisse.net/forum/archive/index.php/t-1809.html> kayaađından 1 Mart 2012 tarihinde alınmıřtır.
- Hsu, C. W., Chang, C. C. & Lin, C. J. (2003). A Practical Guide to Support Vector Classification. Technical Report, Department of Computer Science and Information Engineering, National Taiwan University, <http://www.csie.ntu.edu.tw/~cjlin/papers/guide/guide.pdf> kaynađından 4 Ocak 2013 tarihinde alınmıřtır.
- Hsu, S. H., Hsieh, J. J. P. A., Chih, T. C. & Hsu, K. C. (2009). A Two-Stage Architecture for Stock Price Forecasting by Integrating Self-Organizing Map and Support Vector Regression. *Expert Systems with Applications*, 36, 7947-7951.
- Huang, C. L. & Tsai, C. Y. (2009). A Hybrid SOFM-SVR with A Filter-Based Feature Selection for Stock Market Forecasting. *Expert Systems with Applications*, 36, 1529-1539.
- Huang, S. C. & Wu, T. K. (2008). Integrating GA-Based Time-Scale Feature Extractions with SVMs for Stock Index Forecasting. *Expert Systems with Applications*, 35, 2080-2088.
- Huang, W., Nakamori, Y. & Wang, S. Y. (2005). Forecasting Stock Market Movement Direction with Support Vector Machine. *Computers & Operations Research*, 32, 2513-2522.

- IBS Yazılım, <http://pitmsg.ibsyazilim.com/help/hacimgosterge.html> kaynağından 8 Mart 2012 tarihinde alınmıştır.
- Kara, Y., Boyacıoğlu, 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, 5311-5319.
- Karaatlı, M. A. (2003). Yapay Sinir Ağları Yöntemi ile Tahmin (İMKB’de Bir Uygulama). Yayınlanmış Yüksek Lisans Tezi, Süleyman Demirel Üniversitesi Sosyal Bilimler Enstitüsü, Isparta.
- Karapınar, A. ve Zaif, F. A. (2009). *Uluslararası Finansal Raporlama Standartları ile Uyumlu Finansal Analiz*. Ankara: Gazi Kitabevi.
- Kavzoğlu, T. ve Çölkesen, İ. (2010). Destek Vektör Makineleri ile Uydu Görüntülerinin Sınıflandırılmasında Kernel Fonksiyonlarının Etkilerinin İncelenmesi. *Harita Dergisi*, 144, 73-82.
- Kaya, H. ve Köymen, K. (2008). Veri Madenciliği Kavramı ve Uygulama Alanları. *Doğu Anadolu Bölgesi Araştırmaları Dergisi*, 6(2), s. 159-164.
- Kim, K. J. (2003). Financial Time Series Forecasting Using Support Vector Machines. *Neurocomputing*, 55, 307–319.
- Konuralp, G. (2005). *Sermaye Piyasaları Analizler, Kurumlar ve Portföy Yönetimi*. (2.Baskı). İstanbul: Alfa Yayınları.
- Korkmaz, T. ve Ceylan, A. (2010). *Sermaye Piyasası ve Menkul Değer Analizi*. (5. Baskı). Bursa: Ekin Yayınevi.
- Kutlu, B. ve Badur, B. (2009). Yapay Sinir Ağları ile Borsa Endeksi Tahmini. *Yönetim*, 20(63), 25-40.
- Lee, M. C. (2009). Using Support Vector Machine with A Hybrid Feature Selection Method To The Stock Trend Prediction. *Expert Systems with Applications*, 36, 10896-10904.
- Mayıl, G. (2011). Hareketli Ortalamalar Yöntemine Göre Oluşan Al-Sat Sinyal Getirilerinin İMKB’de Değerlendirilmesi. Yayınlanmış Doktora Tezi, Sakarya Üniversitesi Sosyal Bilimler Enstitüsü, Sakarya.
- Moralı, T. (2011). İMKB 100 Endeksinin Yapay Sinir Ağları ve Newton Nümerik Arama Modelleri ile Tahmini ve Sonuçların Karşılaştırılması. Yayınlanmış Yüksek Lisans Tezi, Pamukkale Üniversitesi Sosyal Bilimler Enstitüsü, Denizli.
- Nargeleçekenler, M. (2005). Suç Veri Tabanının Lojistik Regresyon ile Tahmini: Bursa Örneği. *Polis Bilimleri Dergisi*, 7(2), 31-50.

- Ni, L. P., Ni, Z. W. & Gao, Y. Z. (2011). Stock Trend Prediction Based On Fractal Feature Selection and Support Vector Machine. *Expert Systems with Applications*, 38, 5569-5576.
- Özdemir, A. K., Tolun, S. ve Demirci, E. (2011). Endeks Getirisi Yönünün İkili Sınıflandırma Yöntemiyle Tahmin Edilmesi: İMKB-100 Endeksi Örneği. *Niğde Üniversitesi İİBF Dergisi*, 4(2), 45-59.
- Özkan, Y. (2013). *Veri Madenciliği Yöntemleri*. (2. Baskı). İstanbul: Papatya Yayıncılık.
- Perez-Cruz, F., A Afonso-Rodriguez J. & Giner, J. (2003). Estimating GARCH Models Using Support Vector Machines. *Quantitative Finance*, 3, 1-10.
- Pai, P. F. & Lin, C. S. (2005). A Hybrid ARIMA and Support Vector Machines Model In Stock Price Forecasting. *Omega*, 33, 497-505.
- Perşembe, A. (2001). *Teknik Analiz Mi Dedin? Hadi Canım Sen de!*. (1. Baskı). 1. Kitap. İstanbul: Scala Yayıncılık.
- Perşembe, A. (2002). *Teknik Analiz Mi Dedin? Hadi Canım Sen de!*. (1. Baskı). 3. Kitap. İstanbul: Scala Yayıncılık.
- Pontil, M. & Verri, A. (1998), Properties of Support Vector Machines. *Neural Computation*, 10(4), 955-974.
- R Core Team (2012). R: A Language and Environment for Statistical Computing. R Foundation for Statistical Computing. Vienna, Austria.
- Sap, M. N. M. & A. M. Awan (2005). Stock Market Prediction Using Support Vector Machines. *Jurnal Teknologi Maklumat*, 17(2), 27-35.
- Sarikamış, C. (2000). *Sermaye Pazarları*. (4. Baskı). İstanbul: Alfa Yayınları.
- Schölkopf, B. & Smola, A. J. (2002). *Learning with Kernels Support Vector Machines, Regularization, Optimization and Beyond*. Cambridge, USA: The MIT Press.
- Sui, X., Hu, Q., Yu, D., Xie, Z. & Qi, Z. (2007). A Hybrid Method for Forecasting Stock Market Trend Using Soft-Thresholding De-noise Model and SVM. *Springer Verlag Berlin Heidelberg*, 387-394.
- Suykens, J. A. K., Gestel, T. V., Brabanter, J. D., Moor, B. D. & Vandewalle, J. (2002). *Least Squares Support Vector Machines*. Singapore: World Scientific.
- Tay, F. E. H. & Cao L. J. (2002). Modified Support Vector Machines In Financial Time Series Forecasting. *Neurocomputing*, 48, 847-861.

- Tektaş, A. ve Karataş, A. (2004). Yapay Sinir Ağları ve Finans Alanına Uygulanması: Hisse Senedi Fiyat Tahminlemesi. *İktisadi ve İdari Bilimler Dergisi*, 18(3-4), 337-349.
- Timor, M. ve Şimşek, U. T. (2008). Veri Madenciliğinde Sepet Analizi ile Tüketici Davranışı Modellemesi. *Yönetim*, 19(59), 3-10.
- Tolun, S. (2008). Destek Vektör Makineleri: Banka Başarısızlığının Tahmini Üzerine Bir Uygulama. Yayınlanmış Doktora Tezi, İstanbul Üniversitesi Sosyal Bilimler Enstitüsü, İstanbul.
- Torgo, L. (2010). Data Mining with R. Learning with Case Studies Chapman and Hall/CRC.
- Uyar, M., Yıldırım, S. ve Gençoğlu, M. T. (2011). Güç Kalitesindeki Bozulma Türlerinin Sınıflandırılması İçin Bir Örüntü Tanıma Yaklaşımı. *Gazi Üniv. Müh. Mim. Fak.*, 26(1), 41-56.
- Ülgen, M. ve Teker, S. (2005). İstanbul Menkul Kıymetler Borsası'nda İşlem Gören Sanayi Şirketleri İçin Bir Analitik Değerleme Tekniği Uygulaması. *itüdergisi/b sosyal bilimler*, 2(1), 49-57.
- Vapnik, V. N. (1995). *The Nature of Statistical Learning Theory*. NewYork: Springer-Verlag.
- Vapnik, V. N. (1998). *Statistical Learning Theory*. New York: John Wiley & Sons.
- Yeh, C. Y., Huang, C. W. & Lee, S. J. (2011). A Multiple-Kernel Support Vector Regression Approach for Stock Market Price Forecasting. *Expert Systems with Applications*, 38, 2177-2186.
- Yu, L., Wang, S. & Lai, K. K. (2005). Mining Stock Market Tendency Using GA-Based Support Vector Machines. *Springer Verlag Berlin Heidelberg*, 336-345.