

T.C.
ONDOKUZ MAYIS ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ



BIST100 ENDEKSİNİN GÜNLÜK MODELLENMESİ

Zübeyir AKTÜRK

YÜKSEK LİSANS TEZİ

TC
ONDOKUZ MAYIS ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

YÜKSEK LİSANS TEZİ

BIST100 ENDEKSİNİN GÜNLÜK MODELLENMESİ

ZÜBEYİR AKTÜRK

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

SAMSUN

2019

Her hakkı saklıdır.

TEZ ONAYI

Zübeyir AKTÜRK tarafından hazırlanan “BIST100 ENDEKSİNİN GÜNLÜK MODELLENMESİ” adlı tez çalışması 11/01/2019 tarihinde aşağıdaki jüri tarafından Ondokuz Mayıs Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı’nda Yüksek Lisans Tezi olarak kabul edilmiştir.

Danışman Prof. Dr. Erdal KILIÇ
Bilgisayar Mühendisliği Anabilim Dalı

Jüri Üyeleri

Başkan Prof. Dr. Mustafa ULUTAŞ
Karadeniz Teknik Üniversitesi

Bilgisayar Mühendisliği Anabilim Dalı

Üye Prof. Dr. Erdal KILIÇ
Ondokuz Mayıs Üniversitesi
Bilgisayar Mühendisliği Anabilim Dalı

Üye Dr. Selçuk ASLAN
Ondokuz Mayıs Üniversitesi
Bilgisayar Mühendisliği Anabilim Dalı

Yukarıdaki sonucu onaylarım. .././2019

Prof. Dr. Bahtiyar ÖZTÜRK

Enstitü Müdürü

ETİK BEYAN

Ondokuz Mayıs Üniversitesi Fen Bilimleri Enstitüsü tez yazım kurallarına uygun olarak hazırladığım bu tez içindeki bütün bilgilerin doğru ve tam olduğunu, bilgilerin üretilmesi aşamasında bilimsel etiğe uygun davrandığımı, yararlandığım bütün kaynakları atıf yaparak belirttiğimi beyan ederim.

10/01/2019

Zübeyir AKTÜRK



ÖZET

Yüksek Lisans Tezi

BIST100 ENDEKSİNİN GÜNLÜK MODELLENMESİ

Zübeyir AKTÜRK

Ondokuz Mayıs Üniversitesi

Fen Bilimleri Enstitüsü

Bilgisayar Mühendisliği Anabilim Dalı

Danışman: Prof. Dr. Erdal KILIÇ

Finansal işlemlerin artışı ile birlikte günümüzde piyasalardaki rekâbet küresel bir ölçüğe taşınmış ve bu durum ekonomik karar birimlerini tüm yönleriyle etkilemiştir. Hükümetlerin para ve maliye politikalarını yürüten kurumlar, bankalar, aracı kurumlar, firmalar, yatırımcılar ve tasarruf sahipleri gelecekteki muhtemel risk ve getirilerin hesaplanabilmesi için ekonomik ve finansal göstergelerin doğru tahminine ihtiyaç duymaktadır.

Finansal tahminleme çalışmalarının genelde iki eksende toplandığı görülmektedir. 1. eksen endeks değer tahmini iken 2. eksen endeks yön tahmini olmaktadır. Finansal tahminlemelerde yapay zeka tekniklerinin ön plana çıktığı lojistik regresyon, çoklu doğrusal regresyon, polinom regresyon, karar ağaçları, rassal ormanlar, destek vektör makineleri, yapay sinir ağları, bulanık mantık, bulanık sinir ağları ve genetik algoritmaların sıklıkla kullanıldığı gözlemlenmektedir. Endeks değer ve yön tahminlerinin yatırımcıların karar alma süreçlerine anlamlı katkı sağlayacak hassasiyette olması gerekmektedir.

Yukarıda belirtilen ihtiyaçlar doğrultusunda, bu yüksek lisans tez çalışmasında hisse senedi piyasasının genel bir göstergesi olan BIST100 endeksinin bir gün sonraki kapanış fiyatı ve yönü tahminlenmiştir. BIST100'e ait 5 değişken, bu değişkenlerden üretilen 46 teknik gösterge ve 4 temel gösterge ile Destek Vektör Regresyonu, Karar Ağaçları, Rassal Ormanlar, Çoklu Doğrusal Regresyon ve Polinom Regresyon yöntemleri kullanılarak BIST100 endeksinin bir gün sonraki kapanış fiyatını ve yönünü tahminleyen bir uygulama geliştirilmiş, ardından söz konusu yöntemlerden karma yöntem çıkarılmış ve son olarak çıkarılan karma yöntem gerçek zamanlı verilerle uygulanarak performansı gerçek zamanlı değerlendirilmiştir. Modeller, orjinal veri setine ek olarak 7 günlük basit ortalaması alınmış veri seti ile de makine öğrenmesine tabi tutulmuş, verideki gürültü miktarı azaltılmıştır. İki yaklaşımın entegrasyonu karma modelin başarısını artırmış ve 0.993951 R^2 değerine ulaşılmıştır. 12.11.2018-07.12.2019 tarihlerinde uygulanan gerçek zamanlı tahminlemede ise 18 günün 15'inde BIST100'ün yönü doğru tahminlenmiştir.

Aralık 2018, 75 sayfa

Anahtar Kelimeler: Destek Vektör Regresyonu, Karar Ağaçları, Rassal Ormanlar, Çoklu Doğrusal Regresyon, Polinom Regresyon, BIST100, Borsa Değer Tahmini, Borsa Yön Tahmini, Karma Tahminleme, Gerçek Zamanlı Tahminleme

ABSTRACT

Master's Thesis

DAILY MODELING OF THE BIST100 (XU100) INDEX

Zübeyir AKTÜRK

Ondokuz Mayıs University

Graduate School of Sciences

Department of Computer Engineering

Supervisor: Prof. Dr. Erdal KILIÇ

With the increase in financial transactions, the competition in the markets has moved to a global scale which has affected the economic decision-making units in all aspects. The institutions of governments that require monetary and fiscal policies, banks, intermediary institutions, firms, investors and savings holders need accurate estimations of economic and financial indicators to calculate the possible risks and rewards of the future.

It is seen that financial prediction studies are generally collected in two axes. The first axis is index value prediction while the second axis is index direction prediction. Logistic regression, multiple linear regression, polynomial regression, decision trees, random forests, support vector machines, artificial neural networks, fuzzy logic, fuzzy neural networks and genetic algorithms are frequently used in financial predictions. Index value and Index direction predictions need to be highly sensitive and accurate to contribute the investors' decision-making processes.

With the needs mentioned above, in this thesis, the value of the next day's BIST100 (XU100) Index, which is a general indicator and index of the stock market in Turkey, closing price and the direction is predicted. With BIST100's 5 variables, 46 technical indicators produced from these variables and 4 fundamental indicators, using Support Vector Regression, Decision Tree, Random Forest, Multiple Linear Regression and Polynomial Regression methods an application that predicts the next day's closing price and direction of BIST100 index is developed. The hybrid method was then extracted from the methods stated above. Finally the hybrid method was applied to real time data.

In addition to the original data set, the models were also subjected to machine learning with a 7-day simple averaged data set and the amount of noise in the data was reduced. The integration of the two approaches increased the success of the hybrid model and reached a value of 0.993951 R². In real time data prediction applied on 12.11.2018-07.12.2019, BIST100's direction is accurately estimated in 15 of the 18 days.

December 2018, 75 pages

Keywords: Support Vector Regression, Decision Tree, Random Forest, Multiple Linear Regression, Polynomial Regression, BIST100, Stock Market Value Prediction, Stock Market Direction Prediction, Hybrid Estimation, Real-Time Prediction

ÖNSÖZ VE TEŞEKKÜR

Yüksek lisans eğitimim süresince bana yol gösteren, tez konusu seçiminde rehberlik eden ve akademik bilgi birikimini paylaşmakta tereddüt etmeyen değerli hocam Prof. Dr. Erdal KILIÇ'a ve ana bilim dalımızın diğer kıymetli hocalarına teşekkürü bir borç bilirim.

Bu süreç içerisinde maddi ve manevi desteklerini benden esirgemeyen sevgili aileme, tez yazım aşamasında beni yalnız bırakmayan eşime ve canım oğlum ile kızıma teşekkürlerimi sunarım.

Aralık 2018, Samsun

Zübeyir AKTÜRK

İÇİNDEKİLER DİZİNİ

ÖZET	i
ABSTRACT	ii
ÖNSÖZ VE TEŞEKKÜR	iii
İÇİNDEKİLER DİZİNİ	iv
SİMGELER VE KISALTMALAR	v
ŞEKİLLER DİZİNİ	vi
ÇİZELGELER DİZİNİ	vii
1. GİRİŞ	1
1.1. Borsa İstanbul	1
1.2. Tezin Amacı	2
2. LİTERATÜR ARAŞTIRMASI	3
3. VERİ VE UYGULAMA	9
3.1. Veri.....	9
3.1.1. Finansal Piyasalarda Analiz Yöntemleri.....	9
3.1.2. Temel Analiz.....	10
3.1.3. Teknik Analiz.....	11
3.1.4. Dow Teorisi.....	11
3.1.5. Göstergeler	12
3.1.6. Temel ve Teknik Analizin Karşılaştırılması	13
3.1.7. Kullanılan Veri.....	14
3.2. Kullanılan Yöntemler.....	15
3.2.1. Veri Önleme	16
3.2.2. Destek Vektör Regresyonu (DVR)	18
3.2.3. Çoklu Doğrusal Regresyon (MLP)	21
3.2.4. Polinom Regresyon (PR)	22
3.2.5. Karar Ağaçları (DT).....	22
3.2.6. Rassal Ormanlar (RF)	23
3.2.7. Geliştirilen Karma Yöntemler.....	24
3.2.8. Gerçek Zamanlı Tahminleme.....	24
3.2.9. Uygulama Akış Diyagramı	24
3.2.10. Uygulamada Kullanılan Kütüphaneler.....	25
4. BULGULAR	26
4.1. Destek Vektör Regresyonu Bulgular	27
4.2. Çoklu Doğrusal Regresyon Bulgular	30
4.3. Polinom Regresyon Bulgular	33
4.4. Karar Ağacı Bulgular	36
4.5. Rassal Ormanlar Bulgular	39
4.6. Karma Modeller Bulgular	42
4.7. Gerçek Zamanlı Tahminleme Bulgular.....	49
5. SONUÇ VE ÖNERİLER	52
KAYNAKLAR	55
EKLER	58
ÖZGEÇMİŞ	64

SİMGELER VE KISALTMALAR

SİMGELER

λ	Güvenlik parametresi
l	Kayıp fonksiyonu
$X (\mathfrak{R}^d)$	Veri uzayı
$R[\lambda]$	Beklenen risk
$R_{emp}[\lambda]$	Deneysel risk
C	Hata maliyeti
x	Normalize edilen veri
u	Ortalama
s	Standart sapması
P_l	Sol düğüm olasılığı
P_r	Sağ düğüm olasılığı
n	Değişken sayısı

KISALTMALAR

BIST	Borsa İstanbul
DT	Decision Tree (Karar Ağacı)
DVR	Destek Vektör Regresyonu
HKT	Hataların Kareleri Toplamı
MAE	Ortalama Mutlak Hata
MAPE	Ortalama Mutlak Yüzde Hata
MLP	Multiple Linear Regression (Çoklu Doğrusal Regresyon)
OUKT	Ortalamaya Uzaklığın Kareleri Toplamı
PR	Polinom Regresyon
R²	Belirlilik Katsayısı
RF	Rational Forest (Rasyonel Orman)
YSA	Yapay Sinir Ağları

ŞEKİLLER DİZİNİ

Şekil 3.1. CRISP-DM.....	15
Şekil 3.2. Destek Vektörleri.....	18
Şekil 3.3. Uygulama Akış Diyagramı.....	24
Şekil 3.4. Uygulamada Kullanılan Python Kütüphaneleri.....	25
Şekil 4.1. 7 Günlük Basit Ortalaması Alınmış Veri Seti İle DVR Tahmini.....	27
Şekil 4.2. Orjinal Veri Seti İle DVR Tahmini.....	28
Şekil 4.3. 7 Günlük Basit Ortalaması Alınmış Veri Seti İle MLR Tahmini	30
Şekil 4.4. Orjinal Veri Seti İle MLR Tahmini	31
Şekil 4.5. 7 Günlük Basit Ortalaması Alınmış Veri Seti İle PR Tahmini.....	33
Şekil 4.6. Orjinal Veri Seti İle PR Tahmini.....	34
Şekil 4.7. 7 Günlük Basit Ortalaması Alınmış Veri Seti İle DT Tahmini.....	36
Şekil 4.8. Orjinal Veri Seti İle DT Tahmini.....	37
Şekil 4.9. 7 Günlük Basit Ortalaması Alınmış Veri Seti İle RF Tahmini.....	39
Şekil 4.10. 7Orjinal Veri Seti İle RF Tahmini.....	40
Şekil 4.11. 7 Günlük Basit Ortalaması Alınmış Veri Seti İle Bütün Yöntemlerin Ortalama Tahmini.....	42
Şekil 4.12. 7 Günlük Basit Ortalaması Alınmış Veri Seti İle Bütün Yöntemlerin Ortalama Tahmininden Geri Dönüşüm.....	43
Şekil 4.13. Orjinal Veri Seti İle Bütün Yöntemlerin Ortalama Tahmini.....	44
Şekil 4.14. 1. Karma Model Tahmini.....	45
Şekil 4.15. 2. Karma Model Tahmini.....	46
Şekil 4.16. Karma Modellerin Ortalama Tahmini.....	47
Şekil 4.17. Gerçek Zamanlı Endeks Değer Tahminleri.....	49
Şekil 4.18. Gerçek Zamanlı Endeks Yön Tahmini.....	50
Şekil 5.1. Modellerin R^2 Değerleri.....	53

ÇİZELGELER DİZİNİ

Çizelge 4.1.Karma Modelin Yön Tahmin Başarısı.....	48
--	----



1. GİRİŞ

Eldeki verilerden yararlanarak gelecekte olabilecekleri modelleyebilmek ve bu modeller üzerinden karar alma mekanizmaları oluşturabilmek her dönemin ilgi çekici konularından biri olmuştur. Biyoloji, fizik, kimya, matematik gibi temel bilimlerden istatistik, ekonomi ve mühendislik gibi farklı disiplinlere kadar geniş bir yelpazede birçok bilim dalı için araştırılmaya ve geliştirilmeye muhtaç bir alan olarak karşımıza çıkmakta, güncelleğini ve popülerliğini korumaktadır. Tahminleme çalışmaları içinde finansal piyasalara yönelik yapılan tahminleme ve modelleme çalışmaları ise önemli bir yer teşkil etmektedir.

Finansal işlemlerin artışı ile birlikte günümüzde piyasalardaki rekâbet küresel bir ölçeğe taşınmış ve bu durum ekonomik karar birimlerini tüm yönleriyle etkilemiştir. Finansal piyasalarda karar birimleri, hükümetlerin para ve maliye politikalarını yürüten kurumlar, bankalar, aracı kurumlar, firmalar, yatırımcılar ve tasarruf sahipleri olarak sınıflandırılabilir. Bu karar birimleri açısından gelecekteki muhtemel risk ve getirilerin hesaplanabilmesi için ekonomik ve finansal göstergelerin doğru tahmini büyük önem taşımaktadır. Yanlış bir tahmin üzerine alınacak ekonomik kararlar, tasarruf sahiplerinden başlayarak finansal sistemi ve ülke ekonomisini ciddi sıkıntılara sokabileceği gibi karar birimlerinin rekabet avantajını da yitirmesine yol açabilir.

Dolayısıyla karar birimlerinin küresel rekabet ortamında başarılı olmaları ve rekabet edilebilirliğinin artırılabilmesi için ekonomik ve finansal göstergelerin optimal tahminine ihtiyaç duyulmaktadır.

1.1.Borsa İstanbul

2017 yılı sonu itibariyle Borsa İstanbul Pay Piyasası'nda 399 adet kote şirket, 3 adet yatırım gayrimenkul fonu ve 9 adet yatırım fonu bulunmaktadır. Bu şirketlerin piyasa değeri toplamı 880,24 Milyar TL'dir.

2017 yılı içerisinde Borsa İstanbul'da 6.967 milyar TL tutarında işlem hacmi gerçekleşmiştir. Pay piyasaları ise söz konusu işlem hacminin %21'lik kısmını oluşturarak 1.468 milyar TL'lik hacme ulaşmıştır. Pay piyasalarındaki hacim 2016 yılına göre yaklaşık %40'lık bir artış sergilemiştir. Bu da günlük ortalama 6 Milyar

TL'lik işlem hacmine tekabül etmektedir (Borsa İstanbul 2017 Yılı Entegre Faaliyet Raporu).

Borsa İstanbul Pay Piyasası 2017 yılı Aralık sonu itibarıyla önemli bir likidite göstergesi olan pay devir hızı sıralamasında Avrupa'da 1. Dünya'da ise 3. sırada yer almıştır. Pay devir hızının yüksek olması Borsa İstanbul'un, likit bir piyasaya sahip olduğunu ve yatırımcıların portföylerini daha kısa vadeli değerlendirdiklerini göstermektedir.

Bu veriler eşliğinde BIST100 endeksinin günlük modellenmesinin gerekliliği daha iyi anlaşılmalı ve optimal bir tahminleme ile anlamlı bir katmadeğer ve çarpan etkisi oluşturulabileceği düşünülmektedir.

1.2. Tezin Amacı

Borsa İstanbul 30 Kasım 2015 tarihi itibarıyla Nasdaq Sistemine geçiş yaparak 22 yılı aşkın süredir hisse senedi piyasasında kullandığı emir işlem sistemini değiştirmiştir. Yeni emir işleme sistemi olan BISTECH ile Yüksek frekanslı işlemlere (Algorithmic Trading) izin verilerek daha hızlı emir girme ve fiyat avantajı yakalama fırsatı verilmiştir. Dolayısıyla bu fırsattan yararlanabilmek ve rekabet avantajını kaybetmemek için hızlı bir şekilde mevcut ortamı değerlendirerek modelleyen, tahminleyen ve anlık al/sat sinyalleri üreten Algoritmik İşlem Yazılım Robotlarının kullanımı daha önemli hale gelmiştir. Bu robotlar, yapay zeka teknikleri ile oluşturulmuş karar destek sistemleri ile çalışmaktadır. Bu noktada, söz konusu karar destek sistemlerinin oluşturulabilmesi için hisse senedi piyasalarındaki fiyatın ve piyasa yönünün modellenmesi ve tahminlenmesi gerekliliği göze çarpmaktadır.

Türkiye için hisse senedi piyasalarını tahminlemede kullanılabilecek ve "piyasa performansı" hakkında genel bir bilgi verecek en kapsamlı ve en ideal seçenek BIST100 endeksidir. BIST100 endeksi, sektörel temsil kabiliyeti göz önünde bulundurularak seçilmiş 100 şirketin hisse senetlerinden oluşmakta ve bileşik endeksin devamı niteliğindedir.

Modellemenin günlük bazda gerçekleştirilecek olmasının sebebi Borsa İstanbul pay devir hızının yüksek olması ve yatırımcıların portföylerini daha kısa vadeli olarak değerlendirmeleridir.

Tez ile BIST100 endeksinin bir gün sonraki kapanış fiyatının ve yönünün 4 temel ve 46 teknik gösterge ile 5 farklı yöntem kullanılarak tahminlenmesi, ardından söz konusu yöntemlerden karma bir yöntem geliştirilmesi ve son olarak geliştirilen karma yöntemin gerçek zamanlı verilere uygulanarak performansının gerçek zamanlı değerlendirilmesi amaçlanmaktadır.

2. LİTERATÜR ARAŞTIRMASI

Hisse senedi piyasaları, genel ekonomik durum, döviz kurları, petrol fiyatları, faiz oranları, sektörlerin durumu, firma stratejileri, yatırımcıların beklentileri, büyük yatırımcıların tercihleri, diğer borsalara ait hareketler, politik olaylar ve sermaye sahiplerinin psikolojisi gibi pek çok faktör tarafından etkilenmektedir. Bu çerçevede niteliksel ve niceliksel birçok tahmin yöntemi geliştirilerek gelecekteki mutlak belirsizliği ortadan kaldırmak veya bu belirsizliği hesaplanabilir bir hale getirmek amaçlanmıştır.

Bu doğrultuda klasik modeller uzunca bir süre kullanılmış olmakla birlikte, son on yılda yapılan çalışmalarda yapay zeka teknikleri ve veri madenciliğinin ön plana çıktığı gözlemlenmektedir. Lojistik regresyon, çoklu doğrusal regresyon, polinom regresyon, karar ağaçları, rassal ağaçlar, destek vektör makineleri, yapay sinir ağları, bulanık mantık, bulanık sinir ağları ve genetik algoritmalar bu alanda sıklıkla kullanılan yapay zekâ teknikleridir.

Yapılan literatür çalışmasında finansal tahminleme çalışmalarının genelde iki eksende toplandığı görülmüştür. 1. eksen endeks değer tahmini iken 2. eksen endeks yön tahmini olmaktadır. 1. eksen endeks sayısal olarak tahmin edilmeye çalışılmış, 2. eksen endeks yönü, artma ve düşme sınıflarının olduğu ikili sınıflandırma probleminde tabi tutulmuştur.

Her ekseninde kullanılan veri madenciliği yöntemleri ile bağımlı ve bağımsız değişkenler farklılık göstermektedir. (t) zamanındaki bağımlı değişken için (t-1) zamanındaki bağımsız değişkenlerin girdi vektöründe kullanılması bir gün gecikmeli değerlerin kullanımı; (t) zamanındaki bağımlı değişken için (t) zamanındaki bağımsız

değişkenlerin girdi vektöründe kullanılması ise gecikmesiz değerlerin kullanımı durumu olarak adlanılmaktadır.

(t) zamanındaki bağımlı değişken için (t) zamanındaki bağımsız değişkenlerin kullanılması durumunda zaman ve değişken unsuruna dikkat edilmesi gerekmektedir. Örneğin (t) zamanındaki borsa kapanış değeri için (t) zamanındaki borsa açılış, kapanış, düşük, yüksek ve hacim verilerinin ve bunlardan üretilen teknik göstergelerin kullanılması anlamsız ve pratikte karşılığı olmayan bir durumdur. Zira söz konusu değişkenlerin hepsi birbirine bağımlı ve eş zamanlı üretilmektedir.

Bu tez çalışmasında, günümüze kadar iki eksen de yapılmış çalışmaların metotları, değişkenleri (makro-ekonomik göstergeler, borsa endeksleri, teknik göstergeler v.b) ve değişkenlerin gecikmeli/gecikmesiz durumları ayrı ayrı incelenmiş; çalışmaların başarıları, eksiklikleri, bilime olan katkıları değerlendirilmiştir. Gecikmesiz durumlar ile ilgili modeller ve sonuçları yukarıda bahsedilen hususlar doğrultusunda dikkate alınmamıştır.

İlk eksen olan endeks değer tahmininde sınıflandırma problemine sayısal (numeric) olarak yaklaşılmaktadır. Belirlenen bağımsız değişkenlerden, endeks değerini sayısal olarak tahminleyebilmek hedeflenmektedir. Bu eksen de sınıflandırma problemi sayısal olduğu için modellerin performansları R^2 (belirlilik katsayısı), MAE (ortalama mutlak hata), MAPE (ortalama mutlak yüzde hata) gibi yöntemlerle ölçülmektedir.

Akel ve Bayramoğlu (2008), İMKB100 endeks değerinin günlük tahmininde hata geri besleme algoritmasına sahip bir YSA'yı ve bağımsız değişkenlerin bir gün gecikmeli değerlerini kullanmıştır. Analiz dönemini 4 Ocak 1999 - 28 Şubat 2001 olarak belirlemiştir. Çalışmada, bağımsız değişken olarak; USD/TL kuru, İMKB işlem hacmi, Merkez Bankası döviz rezervleri, Merkez Bankası bir aylık mevduat faiz oranı ve altın borsası kapanış fiyatlarının bir gün gecikmeli değerlerini, bağımlı değişken olarak ise İMKB 100 endeksini kullanmıştır. Tüm değişkenleri logaritmik dönüşüme uğratarak analize dahil etmiştir. Eğitim, doğrulama ve test aşamalarına ilişkin sonuçlar MAPE kullanarak değerlendirmiş ve test aşamasının MAPE'sini 1,12 olarak bulmuştur.

Bu çalışma ile veri kümesinde yer alan daha büyük sayısal aralıktaki değişkenlerin daha küçük sayısal aralıktaki değişkenlerin üzerinde baskınlık

kurmasından kaçınmak amacıyla verilerin dönüşüme tabi tutulmasında veya normalize edilerek [0,1] veya [-1,1] aralığında ölçeklendirilmesinde fayda bulunduğu anlaşılmaktadır. Ayrıca verileri (eğitim ve test verisi) olabildiğince sınıfların veri sayısı (artan, azalan) eşit olarak seçmenin, yığın (batch) oluşturmayı engelleyebileceği ve kullanılan yapay zeka metotlarının daha iyi genelleme yapabileceği gözlemlenmektedir.

Kutlu ve Badur (2009) Akel ve Bayramoğlu'nun çalışmasına ek olarak İMKB 100 endeks değerinin günlük tahminine yönelik yaptıkları çalışmalarında girdi vektörüne bazı ülkelerin borsa endeksleri ile hafta günlerini belirten bir değişkeni de eklemiştir. Çalışmada bağımsız değişken olarak; İMKB endeks değeri, USD/TL kur değeri, gecelik faiz değeri, Fransa, Almanya, İngiltere, NASDAQ, DOW JONES, S&P500, Brezilya ve Japonya borsa kapanış fiyatlarının bir gün gecikmeli değerlerini ve haftanın günlerini belirten beş kukla değişkeni kullanmıştır. 2 Temmuz 2001 - 13 Temmuz 2006 dönemine ait verilerden yararlanmıştır. Toplam 1270 veriden 1143'ünü eğitim, 127'sini ise test verisi olarak kullanmıştır. İleri beslemeli YSA kullanarak üç değişik model (M1, M2, M3) tanımlaması yapmış ve modellerin performansını test veri kümesinin R^2 değeri ile ölçmüştür. 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 sahip olduğunu ve haftanın günleri ile dış borsaların endekslerinin endeks tahmini üzerinde olumlu bir etkisi olmadığını görmüştür.

Yakut vd. (2014) ise ileri beslemeli YSA ve bağımsız değişkenlerin gecikmeli değerlerini kullanarak gerçekleştirdiği BIST100 endeks değer tahminini DVM yöntemiyle kıyaslamıştır. Kutlu ve Badur'dan esinlendiği çalışmasında, 2005-2012 tarihleri arasındaki BIST100 endeksinin bir, iki ve üç gün öncesine ait değerleri, USD/TL kuru, gecelik faiz oranı ve NIKKEI (Japonya Borsası), BOVESPA (Brezilya Borsası), FTSE (İngiltere Borsası), CAC (Fransa Borsası) ve DAX (Almanya Borsası) bir gün önceki değerlerini kullanmıştır. Bu değerleri kullanarak 9 farklı model oluşturmuştur. Verilerin %80'lik kısmıyla eğitim kümesi ve geri kalan %20'lik kısmıyla da test kümesi oluşturmuştur. En iyi sonucu YSA'da 0,972 R^2 değeri ile Model 1 (önceki güne ait endeks değeri, Amerikan dolar değeri, faiz değeri) ve Model 2 (önceki güne ait endeks değeri, Amerikan dolar değeri, faiz değeri ile hafta günlerini belirten 5 kukla değişken (P, S, Ç, PE, C) (P, S, Ç, PE=0,

C=1)) vermiştir. DVM'de ise en iyi sonucu 0,977 R² değeri ile Model 3 (önceki güne ait endeks değeri, Amerikan dolar değeri, faiz değeri, Japonya, Brezilya, İngiltere, Fransa, Almanya borsa endeks değerleri ile hafta günlerini belirten 5 kukla değişken vermiştir.

2. eksen olan endeks yön tahmini, tahmin edilecek endeksin bir önceki zaman dilimine göre fiyatının kıyaslanması ve artma/azalma durumunun tespit edilmesidir. Bu ekseninde sınıflandırma problemine nominal olarak yaklaşılmaktadır. Belirlenen bağımsız değişkenlerden endeksin yönünü, artma/azalma, 0/1, -1/1 olarak sınıflandırabilmek hedeflenmektedir. Bu ekseninde sınıflandırma problemi nominal olduğu için etiketleme başarısını yüzdesel olarak ölçebilmek mümkündür.

Diler (2003), İMKB 100 endeksinin günlük hareket yönünü bağımsız değişkenlerin gecikmeli değerleri ile YSA metotunu kullanarak tahmin etmiştir. Çalışmada SMA, 5 ve 10 günlük WMA, momentum, stokastik %K, RSI, MACD olmak üzere 7 teknik göstergenin 1 gün gecikmeli değerlerini bağımsız değişken ve İMKB 100 endeksinin günlük değişim oranını ise bağımlı değişken olarak kullanmıştır. Çalışmada kullanılan değişkenlerin aynı cinsten olmalarını sağlamak amacıyla günlük değişim oranlarını bulmuş, veriler (-1,+1) arasında değer alacak şekilde normalize etmiştir. 1 Ocak 1990 - 11 Kasım 2003 dönemini kapsayan 3418 verinin 2700'ü eğitim verisi, 718'i test verisi olarak kullanmıştır. Hata geri yayma yöntemini kullanarak 7-10-1 ağ yapısında, öğrenme oranı 0,08 ve momentum katsayısı 0,1 ile İMKB 100 endeksinin ertesi günkü yönünü %60,81 oranında tahmin etmiştir.

Hisse senedi piyasalarının yüksek oynaklığı (volatility) fiyatlarda aşırı dalgalanma oluşturmaktadır. Dolayısıyla veri kümesinde oluşan gürültü problemi, geliştirilecek modellerin performansını etkilemektedir.

Sui vd. (2007), Shangay Borsası SSECI endeksinin bir önceki güne göre yönünün tahmini çalışmalarında söz konusu hususu dikkate almıştır. Analiz dönemini 28 Nisan 1997 - 12 Eylül 2006 arası belirlemiştir. Verilerin 1920'sini eğitim verisi olarak 341'ini ise test verisi olarak kullanmıştır. 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 kullanmıştır. Finansal veriler gürültü içerdiği için verileri dalgacık sıkıştırma

yöntemi ile gürültüden arındırmıştır. DVM'yi hem gürültü içeren hem de gürültüden arındırılmış modellere ayrı ayrı uygulamıştır. Gürültüden arındırılmış veri setinde %60,12, gürültü içeren veri setinde ise %54,25 başarı oranı elde etmiştir. Bu sonuçlardan, gürültü içeren verilerin model performansını azaltmakta olduğu, gürültüden arındırılmış verilerle ise daha başarılı sonuçlar elde edildiği anlaşılmaktadır.

Emir (2013) ise doktora çalışmasında YSA ve DVM yöntemlerinin İMKB 100 endeksinin bir önceki güne göre yönünü tahmin etmedeki başarısını incelemiştir. 2005-2011 dönemine ait teknik göstergeler, borsaların endeks değişim oranları ve makroekonomik göstergelerden oluşan veri kümelerinin gecikmeli ve gecikmesiz değerlerinden yararlanmışır. Makroekonomik göstergelerden (Avro, Sterlin, Dolar, Yen kurlarının 1 günlük gecikmeli değerleri ile dolar cinsinden altının ons başına 1 günlük gecikmeli değeri) oluşan veri kümesinde DVM'de %53,8, YSA'da %54,4 başarı oranı elde etmiştir.

Yukarıda belirtilen yöntemlerin birbirine net bir üstünlük sağlayamadığı, çalışmadan çalışmaya başarı durumlarının farklılık arz ettiği gözlemlenmektedir. Bu doğrultuda değişkenlerin seçimi, yöntemlerin seçimi ve optimizasyonu, yöntemlerin hibrit kullanımı başarı performansını doğrudan etkilemektedir. Örneğin DVM eğitiminde çekirdek fonksiyonlarının seçimi ve seçilen çekirdek fonksiyon için belirlenecek parametre seçiminin sınıflandırma başarısını etkilediği, YSA'da ise seçilen mimari, mimarideki katman ve katmandaki nöron sayısı, öğrenme şekli, öğrenme katsayısı, momentum katsayısı, iterasyon sayısı gibi faktörlerin sınıflandırma performansını etkilediği gözlemlenmektedir.

Literatürde yapılmış olan çalışmalar genel olarak değerlendirildiğinde (Masoud, 2014; Aygören vd, 2012; Aksoy, 2001; Özdemir vd, 2011; Tekin, 2013; Kim, 2003; Boyacıoğlu ve Avcı, 2010; Bilgiç, 2017; Çam, 2017; Uyar, 2015; Yılmaz, 2016; Yılmaz, 2015; Ünal, 2015; Alyozbakee, 2016; Baydilli, 2014; Ergür, 2014; Güzel, 2014; Yeşil, 2014; Hou vd, 2018; Sable ve Porwal, 2017; Loke, 2017; Nivetha vd, 2017; Sharma vd, 2017; Ouahilal vd, 2016; Erdal, 2011) 1. eksen olan Endeks değer tahmin çalışmalarında, diğer tahmin problemlerine kıyasen başarılı sonuç üretilse dahi çıktılarının, bazı durumlarda yatırımcıların karar alma süreçlerine anlamlı katkı sağlayacak hassasiyette olmayabileceği düşünülmektedir. Örneğin, klasik bir tahminleme probleminde %97'lik doğru tahmin, başarılı bir model

oluştururken hisse senedi piyasalarında aynı başarı oranına sahip bir modelin %3'lük yanlış tahmini yatırımcılar açısından yeterli olmayabilir.

2. eksen olan Endeks yön tahmini çalışmaları ise endeksin yönüne yönelik ışık tutmakla birlikte yükseliş veya düşüşün boyutunu sunmakta yetersiz kalmaktadır. Yatırımcıların kararı, yön ile beraber gerçekleşecek yükseliş veya düşüşün rakamsal değeri ve oranı ile şekillenmektedir.

Dikkat çeken başka bir unsur, her iki eksen de geliştirilen modellerin genellikle geçmiş zamanlı verilerle uygulanması ve başarılarının geçmiş veriler üzerinden değerlendirilmesidir. Geliştirilen modellerin makine öğrenmesi ile gerçek zamanlı tahminlenmesi ve performanslarının değerlendirilmesine yönelik çalışmaların literatürdeki eksikliği gözlemlenmektedir.

Literatürde yapılan endeks değer tahmin çalışmalarında hisse senedi piyasalarının doğrusal olmayan bir veri olarak kabul edildiği, tahminlemede DVR, YSA, bulanık mantık gibi özellikle doğrusal olmayan veriler için geliştirilmiş yöntemlerin tercih edildiği gözlemlenmektedir. Bu çalışmaların tahmin başarıları ise 96-98 R^2 bandı içerisinde. BIST100 verileri zaman serisi olarak kabul edilip incelendiğinde, verinin bütünü doğrusal olmasa dahi azalış ve yükseliş içeren trendler halinde ilerlediği, dolayısıyla verinin içerisinde doğrusal veya polinom birçok örüntünün olduğu farkedilmektedir. Bu doğrultuda doğrusal ve polinom verileri tahminlemeye yönelik yöntemlerin de endeks değer tahminleme modellerine entegre edilmesi gerekliliği düşünülmektedir.

Özetlemek gerekirse, bu tez çalışmasında 4 temel ve 46 teknik gösterge ile bir sonraki günün endeks değer ve yön tahmini yapılarak endeksin günlük modellenmesi iki eksen üzerinde de gerçekleştirilecektir. Destek Vektör Regresyonu, Karar Ağaçları, Rassal Ormanlar, Çoklu Doğrusal Regresyon ve Polinom Regresyon yöntemleri kullanılarak hem doğrusal hem de doğrusal olmayan yapay zeka tahminleme yöntemleri BIST100 tahminleme problemi için ilk defa bir arada kullanılacaktır. Söz konusu beş yöntemden karma bir yöntem geliştirilecektir. Geliştirilen karma yöntem literatürde ilk defa gerçek zamanlı BIST100 verilerine uygulanarak performansı gerçek zamanlı değerlendirilecektir.

Bu tez ile geliştirilecek modelin literatür taramasında belirtilen modellerden daha iyi performans sergileyebilmesi ve yatırımcılara anlamlı düzeyde ışık tutması nihai olarak hedeflenmektedir.

3. VERİ VE UYGULAMA

Uygulama Python dilinde geliştirilmiştir. Python'un kullanılan versiyonu 3.6 sürümüdür. Python, numpy, pandas, matplotlib, sklearn, tensorflow, keras gibi bir çok veri bilimi, veri madenciliği ve yapay zeka kütüphanelerine sahip olması, modüler yapısı ve net kolay okunabilen yazımından dolayı tercih edilmiştir. IDE (Integrated Development Environment) (Bütünleşik Gelişim Ortamı) olarak Anaconda 3.5.1 üzerinde Spyder 3.2.6 seçilmiştir. Spyder'in gelişmiş düzenleme, etkileşimli test, hata ayıklama ve iç gözlem özellikleri ile Python dili için güçlü bir etkileşimli geliştirme ortamı olması tercih edilme sebebi olmuştur.

3.1. Veri

Bu tez çalışmasında kullanılan veriler, zaman serisi olup 01.01.2010 ile 09.11.2018 tarihi arasındaki 2.154 işlem gününü kapsamaktadır. Kullanılan verilerin detayına geçilmeden önce değişken seçiminde ve üretiminde izlenen yolu gösteren finansal piyasalarda analiz yöntemleri ile temel, teknik analiz ve göstergelere yönelik bilgi aktarımı sağlanacaktır.

3.1.1. Finansal Piyasalarda Analiz Yöntemleri

Finansal piyasalar, denge ve dengesizlik arasında gelip gitmektedir. Her fiyat hareketi karşı bir hareketin sebebi olmaktadır. Herhangi bir ürünün fiyatının yükseldiğini görenler, kazanma fırsatından yararlanmak için bu piyasaya yönelmekte ve talebi artırmaktadır. Bu malı elinde tutanlar ise daha fazla kazanmak için yükselişi görünce beklemeyi tercih etmekte ve arzı azaltmaktadır. Böylece fiyat yükselmeye devam etmektedir (Sermaye Piyasası Faaliyetleri İleri Düzey Lisans Eğitimi).

Fiyat yükseldikçe fırsatı kaçırdığını düşünen bazıları almaktan vazgeçmekte ve talebi azaltmaktadır; fiyatın gereğinden fazla yükseldiğini görenler de bu seviyeleri

kaçırmamak için satışı başlamakta ve arzı azaltmaktadır. Böylece fiyat düşmeye başlamaktadır. Arz ve talebin durumuna göre bu denge sürekli bozulmakta ve tekrar kurulmaktadır.

Bu şartlar altında sermaye sahipleri, büyük zararlarla karşı karşıya kalmamak ve kar fırsatlarını kaçırmamak için yatırım yaptıkları pazarı iyi tanımak ve takip etmek ihtiyacı içerisinde bulunmaktadır. Bu noktada, finansal piyasalarda kullanılan analiz yöntemlerini inceleme ihtiyacı doğmaktadır.

Finansal piyasalarda kullanılan analiz yöntemleri temel ve teknik analiz olarak ikiye ayrılmaktadır. Söz konusu analizlerin çıktıları, bu tez çalışması kapsamında geliştirilecek modellerin bağımsız değişkenlerini oluşturacağı için bu kavramların anlaşılması büyük önem arz etmektedir.

3.1.2. Temel Analiz

Temel analiz, analiz edilecek olgunun performansını etkileyen unsurların tespit edilerek söz konusu unsurların etkisi üzerinden olgunun gerçek değerini bulmak ve mevcut piyasa değeri ile kıyaslamak olarak tanımlanabilir.

Hisse senedi piyasalarında temel analiz uygulaması, öncelikle ilgili ekonominin analiz edilmesi ile başlar. İlgili ekonomi milli gelir, istihdam dengesi, enflasyon ve faiz oranları, bütçe açığı, dış ticaret, ekonomik büyüme, para arzı ve döviz kuru başlıkları altında incelenir. Ardından sektörlerin mevcut durumları ortaya konarak ekonomik faktörlere karşı duyarlılıkları, endüstri hayat eğrisindeki durumları değerlendirilir. Son olarak şirketlerin finansal tabloları analiz edilir ve geleceğe yönelik nakit akımları tahmin edilmeye çalışılır.

Temel analiz yöntemi ile BIST100 endeks tahmini için kullanılacak temel göstergeler, para arzı (M2), sanayi üretimi, tüketici fiyat endeksi, ithalat, ihracat rakamları, cari açık, enflasyon, faiz oranları, yurtiçi milli hâsıla, yabancı rezervleri, işsizlik oranı, pazar baskı endeksi gibi makro-ekonomik göstergelerdir. Bu verilerin birçoğunun aylık veya haftalık bazlı piyasa verileri olmaları sebebiyle söz konusu veriler ancak haftalık veya aylık endeks tahmin çalışmalarında kullanılabilir.

BIST100 endeksinin günlük tahmininde kullanılacak temel analiz göstergeler ise gecelik faiz oranı, USD/TL kuru, ham petrol fiyatları, altın fiyatları ve diğer ülke borsa endeksleri olarak sıralanabilir. Bu tez çalışmasında kullanılan temel

göstergeler, BIST100 endeksi ile korelasyon içeren günlük bazlı göstergelerin arasından seçilmiştir.

3.1.3. Teknik Analiz

Teknik analiz, tahmin edilmek istenen herhangi bir hisse senedi veya endeksin geçmişten geleceğe uzanan bir fonksiyon olarak değerlendirilen ve geçmişteki hareketlerin gelecekte de tekrarlanacağı varsayımına dayanarak gelecekteki muhtemel trendi tahmin etmeye çalışan bir analiz yöntemidir. Teknik analiz, piyasadaki fiyat hareketleri ve işlem hacmini inceleyerek, piyasanın iyimserlik/kötümserlik seviyesini, psikolojisini ve bir sonraki eğilimini tahmin etmeye çalışır.

Teknik analiz yapılırken ekonomik faktörlerin incelenmesi zorunlu değildir. Teknik analizin odaklandığı alan analizi yapılan olgunun arz ve talebi ile fiyat ve işlem miktarından yola çıkılarak hareketlerini ve trendini tahmin edebilmektir. Ayrıca teknik analizin yapılabilmesi için yeterli derinliğe sahip, tek başına hiçbir yatırımcının fiyatları etkileyemeyeceği piyasa koşulları gereklidir.

Teknik analizin temelini oluşturan Dow'un teorisini bu noktada incelemek ve teknik analize bu teori çerçevesinde bakmak faydalı olacaktır.

3.1.4. Dow Teorisi

Dow teorisi 6 ilkeden oluşmaktadır (Sermaye Piyasası Faaliyetleri İleri Düzey Lisans Eğitimi).

- Ortalamalar (endeksler) her türlü faktörü (etkeni) içerir ve yansıtır.
- Piyasada üç temel trend vardır. Her trend, süre bakımından kendinden bir büyük olan trendi düzeltir.
 - ✓ Bir yıldan uzun olan ana trendler veya birincil hareketler,
 - ✓ Üç hafta ile üç ay arasında olan ikincil hareketler,
 - ✓ Üç haftadan az olan ufak oynama veya dalgalanmalar.
- Ana trendler (birincil hareketler) üç aşamadan geçer;
 - ✓ Fiyatlar düşüken akıllı yatırımcıların alıma geçtiği biriktirme veya toparlama dönemi,
 - ✓ Fiyatlar hızla artarken trendi izleyen birçok kişinin alıma geçtiği boğa piyasası dönemi,

- ✓ Hisse senetlerinin özellikle akıllı yatırımcılar tarafından elden çıkarıldığı dağıtım ayı piyasası dönemi
- Ortalamalar veya piyasa göstergelerinin birbirini onaylaması gerekir. Başka bir deyişle, endeks veya ortalamalar birbirleriyle aynı uyarı ve sinyalleri vermelidir.
- İşlem miktarı (volume) trendi onaylamalıdır. İster düşüş, ister artış olsun, her ana trend işlem miktarının artmasıyla desteklenir ve doğrulanır.
- Yönü veya eğiminin değiştiğine dair sinyaller alınana dek her trend geçerlidir.

3.1.5. Göstergeler

Teknik analiz yapılırken, trendleri belirlemek ve oluşumlarını çözümlenmek zordur. Bu güçlüğü aşmak, trend değişimlerini zamanında belirlemek amacıyla fiyat ve işlem miktarı verileri kullanılarak ve belli matematiksel gerçekliklerinden yararlanılarak fiyat hareketlerinin sayısal değerlerle ifade edilmeye çalışıldığı teknik analiz aracına göstergeler adı verilmektedir.

Bu bölümde göstergeler hakkında genel bir sınıflandırma yapılacak, uygulamada kullanılan göstergelerin detayları, formülleri ve yorumlanmaları ise veri ve bulgular aşamasına bırakılacaktır.

Teknik analiz yöntemlerinin vazgeçilmez yardımcıları olan göstergeler verdikleri bilgi açısından dörde ayrılabilir:

1. Momentum Göstergeleri: Belirli bir zaman içinde fiyatların ne kadar hızlı değiştiğini ölçmeye yarar. Momentum göstergelerinden bazıları şunlardır: Commodity Channel Index, Convergence-Divergence, Momentum, Relative Strength Index, Stochastic Oscillator

2. Trend Göstergeleri: Bu türdeki göstergeler mevcut trendin nereye kadar devam edeceğini ve trend dönüşlerini anlamının yanı sıra trend ile ilgili çeşitli bilgileri de elde etmeye çalışırlar. Moving Average, Convergence-Divergence, Parabolic SAR, R Squared, Standart Error göstergeleri örnek olarak verilebilir.

3. Oynaklık Göstergeleri: Fiyatlardaki iniş çıkışların agresiflik durumunu ve fiyat hareketlerinin aralığını gösterir. Bu gruptaki göstergelerden bazıları şunlardır:

Average True Range, Bollinger Bands, Commodity Selection Index, Moving Average, Chaikin's Volatility.

4. Güç Göstergeleri: Piyasanın gücünü ölçmeye yarayan göstergelerdir. Güç göstergelerine örnek olarak Accumulation / Distribution, Demand Index, Chaikin Money Flow, Money Flow Index, Price Volume Trend, Volume Rate of Change göstergeleri gösterilebilir.

Fiyat hareketlerini tam olarak yansıtabilmesi için uygulamada kullanılan teknik göstergeler seçilirken bu dört kategoriden herhangi birisinin es geçilmemesine dikkat edilmiştir.

Uygulamanın bağımsız değişkenlerinin temel ve teknik göstergelerden oluşması temel ve teknik analizin karşılaştırılmasını gerekli kılmaktadır.

3.1.6. Temel ve Teknik Analizin Karşılaştırılması

Temel ve teknik analiz yöntemlerinin her ikisi aynı sorunu çözmek için probleme değişik yönlerden yaklaşmaktadır. Temel analiz nedenleri incelerken; teknik analiz, sonuçları incelemektedir.

Temel analiz, teknik analize göre daha zor bir analiz tekniğidir. Temel analiz, hem analiz aşamasında hem de analizin sonuçlarının kullanılması aşamasında iyi bir finans bilgisini gerektirir.

Tahmin yapılacak süre açısından her iki yaklaşım farklı öneme sahiptir. Temel analiz yöntemi kullanılarak orta ve uzun vadeli tahmin yapmak mümkündür. Buna göre tahmin yapılacak süre aralığı bir yıl ve daha fazla ise bu durumda temel analiz tercih edilebilir. Ancak bu yöntem kısa/orta vadede piyasa psikolojisini dikkate almamaktadır. Dolayısıyla kısa/orta vadede tek başına kullanılması beklentileri karşılamayabilir. Tahmin aralığı bir yıldan az bir süreyi kapsıyorsa piyasa beklentileri ve psikolojisini dikkate almasından dolayı bu defa teknik analiz tercih edilebilir. Teknik analiz yöntemlerinin, temel analiz ve yapısal verilerin de dikkate alınarak kullanılması daha verimli sonuçlara ulaşılmasını sağlar. Ayrıca temel analize dayalı uzun vadeli yatırımlarda teknik analiz, zamanlama (timing) (alım/satım zamanlarının belirlenmesi) için de kullanılabilir.

3.1.7. Kullanılan Veri

Bu endeks çalışmasında kullanılan veriler 01.01.2010 ile 09.11.2018 tarihi arasındaki 2.154 günlük BIST100 endeks verileri (gün içindeki en yüksek değer, gün içindeki en düşük değer, açılış değeri, kapanış değeri ve hacim), S&P500 endeks kapanış değeri, USD/TL paritesi kapanış değeri, brent petrol kapanış değeri, Ishares MSCI Turkey ETF kapanış değerinden oluşmaktadır.

Veriler stooq.com websitesinden temin edilmiştir. Ücretsiz finans verisi erişimi sağlayan Google Finance, Yahoo Finance, Investing, IEX, Quandl ve Tiingo siteleri denenmiş ancak eksik veri, eksik kolon, hatalı veri veya aranan bazı verilerin hiç olmaması gibi sebeplere binaen Stooq.com'da karar kılınmıştır. Stooq Polonya merkezli yayın yapan bir finans websitesidir. Verileri ücretsiz olarak sunmaktadır. Ayrıca Python'un pandas-datareader kütüphanesi ile uzaktan veri erişimine de izin vermektedir.

Stooq.com websitesi üzerinden temin edilen verilerin doğruluğu ve bütünlüğü çeşitli zaman dilimlerinde yapılan örneklemeler ile teyit edilmiştir.

S&P 500 endeksi Standart & Poor's tarafından yapılmakta olup 500 büyük Amerikan şirketten oluşmaktadır. Amerikan Hisse Senedi Piyasasının %75'ini kapsamaktadır. BIST100 gibi S&P 500 de Amerikan Borsaları hakkında genel bir bilgi verecek en kapsamlı ve en ideal seçenektir. 01.01.2010-09.11.2018 tarihlerindeki S&P 500 kapanış değeri ile BIST100 kapanış değeri arasında 0,88'lik pozitif korelasyon bulunmaktadır.

Ishares MSCI (Morgan Stanley Capital International) Turkey ETF ise Türkiye'de yatırım yapılabilirliği izlemek amacıyla BIST 100'de işlem gören 10 hisseden oluşmaktadır. Bunlar; Garanti bankası, Akbank, Bim, Koç Holding, Tüpraş, Sabancı Holding, İş Bankası, Halk Bankası ve Ereğli Demir Çelik, Turkcell hisseleridir. Endeks Nasdaq Borsasında MSCI Turkey EFT (TUR) koduyla işlem görmektedir. Nasdaq Borsası kapanışı Türkiye saatine göre 24:00'da gerçekleştiği için bir sonraki günün BIST100 açılışına yönelik öncü gösterge olabilmektedir.

01.01.2010-09.11.2018 tarihi arasındaki 2.154 günlük veri “^XU100”(BIST100), “^SPX”(S&P 500), “USDTRY”(USD/TL), “CB.F”(Brent Petrol), “TUR.US”(Ishares MSCI Turkey ETF) etiketleri ile stooq.com sitesinden CSV (Comma Separated Values) formatında çekilmiştir.

S&P 500 endeks kapanış deęeri, USD/TL paritesi kapanış deęeri, brent petrol kapanış deęeri, Ishares MSCI Turkey ETF kapanış deęerleri modelde kullanılan temel göstergeleri oluşturmaktadır.

Uygulama içerisinde BIST100'ün gün içindeki en yüksek deęeri, gün içindeki en düşük deęeri, açılış deęeri, kapanış deęeri ve hacim deęerlerinden yola çıkılarak 55 adet teknik gösterge üretilmiştir. Uygulama içerisinde üretilen söz konusu 55 adet teknik göstergenin 8 tanesi güç, 15 tanesi oynaklık, 21 tanesi trend, 8 tanesi momentum ve 3 tanesinde özelleştirilmiş göstergedir.

Özetle uygulama içerisinde kullanılan veriler 01.01.2010-09.11.2018 tarihi arasındaki 2.154 günlük veriyi kapsayan BIST100'e ait 5 deęişken, bu 5 deęişkenden üretilen 55 adet teknik analiz göstergesi ile 4 temel analiz göstergesidir. Uygulama veri seti, 2.154x64 boyutlarında zaman serisi indeksine sahip bir matristir.

3.2.Kullanılan Yöntemler

Bu bölümde geliştirilen uygulamada bağımlı/bağımsız deęişkenlerin tanımlanması, veri ön işleme, öz nitelik seçimi, sırasıyla geliştirilen modeller (Destek Vektör Regresyonu, Karar Ağaçları, Rassal Ormanlar, Çoklu Doğrusal Regresyon ve Polinom Regresyon, Karma) ve gerçek zamanlı tahminleme yöntemleri detaylı incelenmiştir. Uygulama geliştirilirken metodoloji olarak CRISP-DM'den (cross industry standard process for data mining) yararlanılmıştır. CRISP-DM günümüzde sıklıkla kullanılan bir veri madencilięi süreç modeli olup Şekil 3.1'de verilmiştir.



Şekil 3.1: CRISP-DM

3.2.1. Veri Önışleme

İlk olarak stooq.com websitesinden çekilen 01.01.2010-09.11.2018 tarihi arasındaki BIST100, S&P 500, USD/TL, Brent Petrol ve Ishares MSCI Turkey ETF verileri pandas kütüphanesi kullanılarak uygulamaya yüklenmiş, zaman serisi indeksine sahip veri çerçeveleri olarak kaydedilmiştir.

Ardından S&P 500 kapanış değeri, USD/TL kapanış değeri, Brent Petrol kapanış değeri ve Ishares MSCI Turkey ETF kapanış değeri BIST100 veri çerçevesi ile zaman serisi indeksine göre birleştirilmiştir. İşlem günü olmayan, boş satır ve kolonlara sahip günler veri setinden çıkarılmıştır.

Verilerin doğruluğu ve bütünlüğü çeşitli zaman dilimlerinde yapılan örneklemler ile teyit edilmiş, verilerin matematiksel işleme tabii tutulmasından dolayı veri tiplerinin float (reel sayı) olma durumu kontrol edilmiştir.

BIST100'ün gün içindeki en yüksek değeri, gün içindeki en düşük değeri, açılış değeri, kapanış değeri ve hacim değerlerinden 55 adet teknik gösterge üretilmiştir. Bunların 8 tanesi güç, 15 tanesi oynaklık, 21 tanesi trend, 8 tanesi momentum ve 3 tanesi de özelleştirilmiş göstergedir. Güç göstergeleri volume.py, oynaklık göstergeleri volatility.py, trend göstergeleri trend.py, momentum

göstergeleri momentum.py, özelleştirilmiş göstergeler others.py ismi verilen Python kodları ile üretilmiştir. wrapper.py ismi verilen Python kodu ile tüm göstergeleri tek seferde üretecek bir fonksiyon oluşturulmuştur.

Öznitelik çıkarımına gidilerek BIST100'e ait 5 değişken, bu 5 değişkenden üretilen 55 adet teknik gösterge ile 4 temel göstergeden oluşan toplam 64 adet öznitelik 55 adete düşürülmüştür. 2.154 işlem gününe sahip veri setindeki her bir özniteliğin, bir gün sonraki BIST100 kapanış değeri ile ikili korelasyon analizi pandas kütüphanesinin dataframe sınıfının corr() isimli metodu kullanılarak gerçekleştirilmiştir. İkili korelasyon analizi Pearson korelasyon katsayısı ile yapılmıştır. Öznitelik çıkarımı sonrası modeldeki toplam 55 adet öznitelik, BIST100'e ait 5 değişken, 46 adet teknik analiz göstergesi ve 4 temel göstergeden oluşmaktadır.

"Close_t_plus_1" ve "Direction_t_plus_1" etiketleriyle yeni iki adet kolon üretilerek her bir satıra (her bir gün) bir sonraki günün Endeks kapanış değeri ve Endeks yönü verileri yüklenmiştir.

Bu doğrultuda kullanılan tüm yöntemlerde bağımlı değişkenler, veri setinin son iki kolonu olan bir sonraki günün (t+1) BIST100 kapanış değeri ile bir sonraki günün (t+1) BIST100 yönü olarak belirlenmiştir. Bağımsız değişkenler ise (t) zamanındaki BIST100'e ait 5 adet veri (gün içindeki en yüksek değer, gün içindeki en düşük değer, açılış değeri, kapanış değeri ve hacim), (t) zamanındaki 4 adet temel gösterge (S&P 500, USD/TL, Brent Petrol ve Ishares MSCI Turkey ETF kapanış değerleri) ve (t) zamanındaki 46 adet teknik göstergeden oluşturulmuştur. Örneğin, 01.11.2018 tarihine kadar olan verilerle 02.11.2018 tarihindeki endeks kapanış fiyatı ve yönü tahminlenmiştir.

2015 yılı sonu itibariyle Borsa İstanbul'da yüksek frekanslı işlemlere (Algorithmic Trading) imkan sağlayan yeni emir işleme sistemine (BISTECH) geçilmesi Borsa İstanbul'un oynaklığını artırmış, BIST100 verilerinde ciddi bir gürültü oluşturmuştur.

Verideki bu gürültünün tahminleme sürecindeki olumsuz etkisinden kurtulmak için bütün verilerin 7 günlük basit ortalamasının alınması ve kullanılacak yöntemlerin 7 günlük ortalaması alınmış veri ile de uygulanmasına karar verilmiştir. Söz konusu modelde 7 günlük ortalaması alınmış bağımsız değişkenler ile 7 günlük

ortalaması alınmış bağımlı deęişkenlerin makine öğrenmesi gerçekleştirilmiş ve modelin başarısı ölçülürken 7 günlük ortalaması alınmış bir gün sonraki BIST100 kapanış deęeri ile modelin tahmini kıyaslanmıştır.

Bu doğrultuda uygulamada biri orjinal dięeri 7 günlük basit ortalamadan oluşan 2 veri seti bulunmaktadır. Veri setlerinin her birisi 2.154x55 boyutlarında zaman serisi indeksine sahip matris olup BIST100'e ait 5 adet veri, 4 adet temel gösterge ve 46 adet teknik gösterge bilgilerini taşımaktadır.

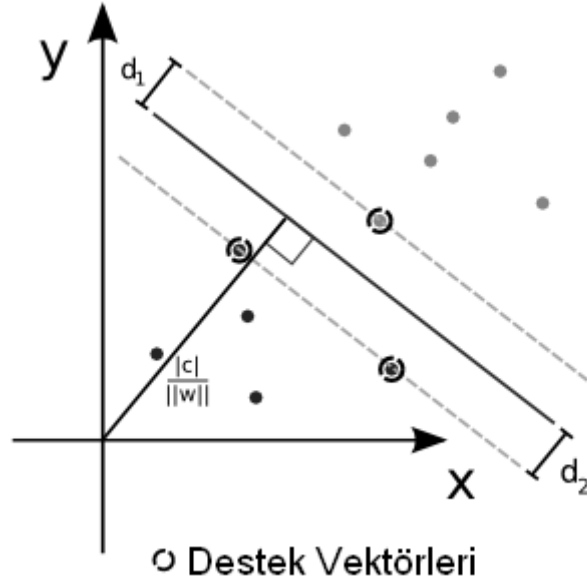
Geliştirilen yöntemlerde makine öğrenmesi gerçekleştirilirken veri seçkisiz (random) olarak üçe bölünmüştür. 2/3 ile makine öğrenmesi ve 1/3 ile test işlemleri gerçekleştirilmiştir.

Tahminlemede geliştirilen modeller; Destek Vektör Regresyonu, Çoklu Doğrusal Regresyon, Polinom Regresyon, Karar Ağaçları, Rassal Ormanlar, Hibrit Model ve Gerçek Zamanlı Tahminleme sıralayla detaylandırılacaktır.

3.2.2. Destek Vektör Regresyonu (DVR)

Destek Vektör Regresyonu (DVR), Destek Vektör Makinesinin (DVM) sayısal tahminleme problemleri için geliştirilmiş özel bir versiyonudur. DVR'yi anlayabilmek için öncelikle DVM ve sınıflandırma problemine bakmakta fayda bulunmaktadır.

DVM “n” boyutlu bir uzayda girdi verisini iki set vektör olarak gören bir yöntemdir. İyi bir sınıflandırma için yapılabilmesi için gerekli olan temel olgu, sınıflandırılacak iki sınıfın arasından geçirilecek hiperdüzlemin sınırının maksimize edilmesidir. İyi bir sınıflandırmada uygun hiperdüzlemi bulmak için iki küme veri setinin en yakın üyelerinin üzerinden iki paralel doğru geçirilir ve bu iki doğrunun tam ortasındaki doğru hiperdüzlemdir. Paralel doğrular hiperdüzlemin sınırlarıdır (marj), destek vektörleri ise veri kümelerinin en yakın üyelerinin üzerinden geçen vektörlerdir. Şekil 3.2 bu vektörleri göstermektedir (Erdal, 2011).



Şekil 3.2: Destek vektörleri

DVR'de ise bir fonksiyonun tahmin edilmesine (öğrenilmesi) regresyon problemi olarak yaklaşılır.

$$f(x, \lambda): X(\mathfrak{R}^d) \rightarrow \mathfrak{R} \quad (3.1)$$

$X(\mathfrak{R}^d)$ gibi bir veri uzayını temsil etmektedir. $\lambda \in A$, A bağımsız özdeş dağılımlı N adet örneği olan parametreler kümesi iken

$$(x_1, x_2), \dots, (x_N, x_N), \quad x_i \in X(\mathfrak{R}^d), \quad y_i \in \mathfrak{R} \quad (3.2)$$

örnekleri bilinmeyen bir $P(x, y)$ dağılımındandır. Burada amaç öyle bir $f(x, \lambda)$ fonksiyonu bulmaktır ki beklenen risk (expected risk) olarak mümkün olan en küçük değer elde edilebilsin (Erdal, 2011).

$$R[\lambda] = \int l(y, f(x, \lambda)) P(x, y) dx dy \quad (3.3)$$

Denklem 3.3'de l kayıp fonksiyonudur (loss function). Genellikle olasılık dağılımı $P(x, y)$ bilinmediğinden beklenen riski $R[\lambda]$ hesap etmek ve minimize etmek olanaksızdır. Fakat denklem 3.2'deki örneklerden dolayı $P(x, y)$ hakkında bilgi sahibi olunabilir. Böylece beklenen riskin olasılıklı bir yaklaşımı olarak denklem 3.4'deki deneysel riski (empirical risk) hesap edilebilir (Erdal, 2011).

$$R_{emp}[\lambda] = \frac{1}{N} \sum_{i=1}^N l(y_i, f(x_i, \lambda)) \quad (3.4)$$

Sadece deneysel riski minimize etmek küçük örneklemeden dolayı tahminde yanlış gibi problemlere neden olmaktadır. Bu problem istatistiksel teori (statistical

theory) veya Vapnik and Chervonenkis teorisi yardımıyla çözülür. VC teorisi denklem 3.5'deki beklenen risk ile deneysel riskin sınırlarını $1 - \eta$ olasılıkla belirler.

$$R[\lambda] \leq R_{emp}[\lambda] + \sqrt{\frac{h(\ln \frac{2N}{h} + 1) - \ln \frac{\eta}{4}}{N}}, \quad \forall \lambda \in A \quad (3.5)$$

Denklem 3.5'de $hf(x, \lambda)$ fonksiyonunun VC-boyutudur (VC-dimension). Beklenen riskin en küçük olması için VC-boyutunun küçük olması gerekmektedir. Belirli sayısı olan bir örnek için optimal bir VC-boyutu vardır. Veri sayısının az olduğu örneklerde h ın doğru seçimi çok önemlidir. Bu yüzden Vapnik tarafından yapısal risk minimizasyonu geliştirilmiştir. Destek vektör makineleri YRM prensiplerini tamamlamak için geliştirilmiştir. Regresyon yapan DVM destek vektör regresyonu (support vector regression) DVR olarak adlandırılmaktadır. DVR'nda amaç denklem 3.5'deki regresyon riskini minimize ederek bir $f(x, w, b)$ fonksiyonu bulmaktır (Erdal, 2011).

$$R_{reg}(f) = \frac{1}{2}(w, w) + C \sum_{i=1}^N l(f(x_i), y_i) \quad (3.6)$$

Denklem 3.6'daki ilk terim DVM'ndeki sınırı ifade eder, C ise hatanın maliyetidir (cost of error). Burada (w, w) i minimize etmek fonksiyonumuzu mümkün olduğunca düzleştirecektir (flatness). Fonksiyonumuz denklem 3.7'de tanımlanmıştır. $\Phi(x): x \rightarrow \Omega$ olmak üzere,

$$f(x, w, b) = (w, \Phi(x)) + b \quad (3.7)$$

denklemin $x \in X(\mathfrak{R}^d)$ i gösterir, burada Ω yüksek boyutlu bir uzayı gösterir, ayrıca $b \in \mathfrak{R}$ dir (Erdal, 2011).

Geliştirilen modelde, DVR'nin veri aralığına dayanıklı olmaması ve marjinal verilere karşı olan hassasiyetine binaen veriler standartlaştırılmıştır. Verilerin standartlaştırılması verilerin birbiriyle olan farkını bozmadan orta değerden sapma aralığına indirgemek anlamına gelmektedir. Verilerin standartlaştırılmasında sklearn kütüphanesinin preprocessing (önişleme) modülünün StandardScaler sınıfından (class) yararlanılmıştır. Böylece veriler makine öğrenmesine tabi tutulmadan 3.8 denklemini doğrultusunda standarde edilmiştir.

$$z = (x - u)/s \quad (3.8)$$

denkleminde x normalize edilen veri, u x 'in içinde bulunduğu kolondaki verilerin ortalaması (mean), s ise x 'in içinde bulunduğu kolondaki verilerin standart sapmasıdır.

DVR'de doğrusal olarak ayrıştırılmayan veriler için çekirdek hilesi kullanılarak boyut artırılmaya gidilir. Geliştirilen modelde ise rbf (radial basis function), polinom, sigmoid ve doğrusal (linear) çekirdek fonksiyonları denenmiş ve en iyi sonucu veren doğrusal fonksiyon çekirdeği seçilmiştir.

Model geliştirilirken sklearn kütüphanesinin svm (Support Vector Machine) modülünün SVR (Support Vector Regression) sınıfından (class) yararlanılmıştır. Hem orjinal hem de 7 günlük ortalaması alınmış verilerin seçkisiz olarak 2/3 ü ile eğitim 1/3 ile de test çalışmaları gerçekleştirilmiştir. Son olarak tahmin edilen değer inverse_transform metodu kullanılarak standartlaştırılmış haline ters dönüşüm sağlanmıştır.

3.2.3. Çoklu Doğrusal Regresyon (MLP)

Çoklu doğrusal ilkeleme olarak da adlandırılan İngilizcesi Multiple Linear Regression olan MLR çok sayıdaki karmaşık hesaplama ve ölçümlere dayalı veri kümesinin basit bir doğruya indirgenmesidir. MLR, doğrusal örüntüye sahip veri durumlarında bir dizi bağımsız değişkenden bir tane bağımlı değişkenin tahminlenmesi problemlerinde başarılı sonuçlar üretebilmektedir.

$$Y = XB + E \quad (3.9)$$

denkleminde Y bağımlı değişken gözlem vektörü, X bağımsız değişkenler gözlem matrisi, B katsayılar vektörü ve E hata vektörüdür. Katsayıların kestirimi ise en küçük kareler yöntemi ile yapılır.

Model geliştirilirken sklearn kütüphanesinin linear_model modülünün LinearRegression sınıfından (class) yararlanılmıştır. Hem orjinal hem de 7 günlük ortalaması alınmış verilerin seçkisiz olarak 2/3 ü ile eğitim 1/3 ile de test çalışmaları gerçekleştirilmiştir. 55 tane bağımsız çoklu değişkenden 1 tane bağımlı çoklu değişken tahminleyen bir formül geliştirilmiştir.

$$Y_1 = B_0 + B_1 X_{i1} + B_2 X_{i2} + \dots + B_{55} X_{i55} + E_{i55} \quad (3.10)$$

formülüyle, t zamanındaki BIST100'e ait 5 adet değişken (gün içinde görülen en yüksek, en düşük değer, açılış ve kapanış değerleri, hacim), 4 temel gösterge ve

46 adet teknik göstege çeşitli katsayılarla çarpılmış ardından kümülatif olarak toplanmış ve (t+1) zamanındaki BIST100 kapanış değeri bulunmuştur.

3.2.4. Polinom Regresyon (PR)

Doğrusal örüntüye sahip olmayan ve polinom dağılım gösteren verilerin tahminlemede polinom regresyon başarılı sonuçlar elde edebilmektedir.

$$Y = B_0 + B_1X + B_2X^2 + \dots + B_hX^H + E \quad (3.11)$$

denkleminde h polinom derecesini göstermektedir.

Model geliştirilirken sklearn kütüphanesinin preprocessing kütüphanesinin PolynomialFeatures sınıfından ve linear_model modülünün LinearRegression sınıfından yararlanılmıştır. Hem orjinal hem de 7 günlük ortalaması alınmış verilerin seçkisiz olarak 2/3 ü ile eğitim 1/3 ile de test çalışmaları gerçekleştirilmiştir. Modelde polinom regresyonun derecesi 1 seçilmiştir.

3.2.5. Karar Ağaçları (DT)

Karar Ağaçları, Decision Tree (DT) bir karar varmak için çeşitli adımlardan oluşan sistemlerde bu adımların olasılıksal değerlerini bir çizge (şekil, graph) üzerinde ağaç (tree) kullanarak göstermek için kullanılır. Karar Ağaçları ile regresyonda bağımsız değişkenler bilgi kazancına göre aralıklara ayrılır. Tahmin esnasında bu aralıktan bir değer sorulduğunda cevap olarak bu aralıktaki (eğitim esnasında öğrendiği) ortalamayı verir. Bu sebeple karar ağacı regresyonu diğer regresyon modelleri gibi sürekli değil, kesiklidir. Bu doğrultuda hibrit model oluşturmada iyi bir parametre olabilmemesinden uygulamada geliştirmeye karar verilmiştir.

Karar ağacı öğrenmesi sırasında, öğrenilen bilgi bir ağaç üzerinde modellenir. Bu ağacın bütün iç düğümleri (interior nodes) birer girdiyi ifade eder. İç düğümler girdilere dallanır. Yapraklarda ise sonuç olarak elde edilen değerler gösterilir. Ağacın öğrenilmesi sırasında, üzerinde eğitim yapılan küme, çeşitli özelliklere göre alt kümelere bölünür, bu işlem, özyineli olarak (recursive) tekrarlanır ve tekrarlama işleminin tahmin üzerinde bir etkisi kalmayana kadar sürer (<http://bilgisayarkavramlari.sadievrenseker.com/>).

Regresyon ağacındaki ayırımlar iki sonuçlanan düğüm için tahmin edilen toplam varyansın minimize olmasının gerekliliği anlamına gelen “artıkların karelerini azaltma algoritmasına” göre gerçekleştirilir.

$$\text{argmin}[P_l \text{Var}(Y_l) + P_r \text{Var}(Y_r)]x_j \leq x_j^R, j = 1, \dots, M \quad (3.12)$$

denkleminde P_l ve P_r sırası ile sol ve sağ düğümlerin olasılıklarıdır. M eğitim setindeki değişkenlerin sayılarıdır. Değişken j x_j olarak gösterilmektedir. x_j^R ise değişken x_j nin en iyi ayırım değerini göstermektedir. $\text{Var}(Y_l)$, $\text{Var}(Y_r)$ karşılıklı sağ ve sol alt düğümler için sorumlu vektörlerdir. $x_j \leq x_j^R, j = 1, \dots, M$ optimal ayırım sorgulaması anlamına gelmektedir.

Model geliştirilirken sklearn kütüphanesinin tree modülünün DecisionTreeRegressor sınıfından yararlanılmıştır. Bölünme MAE (Ortalama Mutlak Hata) yöntemi ile gerçekleştirilmiştir.

Hem orjinal hem de 7 günlük ortalaması alınmış verilerin seçkisiz olarak 2/3 ü ile eğitim 1/3 ile de test çalışmaları gerçekleştirilmiştir.

3.2.6. Rassal Ormanlar (RF)

Rassal Ormanlarda, Random Forest (RF) sınıflandırma işlemi sırasında birden fazla karar ağacı kullanılarak sınıflandırma değerinin yükseltilmesi hedeflenir. Bireysel olarak oluşturulan karar ağaçları bir araya gelerek karar ormanı oluşturur. Buradaki karar ağaçları bağlı olduğu veri setinden rastgele seçilmiş birer alt kümedir (<http://bilgisayarkavramlari.sadievrenseker.com/>).

Rassal ormanlar karar ağaçları gibi hem doğrusal hem de doğrusal olmayan veri ile çalışır. Ayrıca karar ağacına göre aşırı uyum (overfitting) probleminden kaçabilmesinden dolayı uygulamada geliştirilmesine karar verilmiştir.

Model geliştirilirken sklearn kütüphanesinin ensemble modülünün RandomForestRegressor sınıfından yararlanılmıştır. Bölünme MAE (Ortalama Mutlak Hata) yöntemi ile gerçekleştirilmiş, 10 adet ağaç kullanılmıştır.

Hem orjinal hem de 7 günlük ortalaması alınmış verilerin seçkisiz olarak 2/3 ü ile eğitim 1/3 ile de test çalışmaları gerçekleştirilmiştir Modelde oluşturulan ormandaki ağaç sayısı 10 seçilmiştir.

3.2.7. Geliştirilen Karma Yöntemler

Karma Model oluşturulurken yukarıda geliştirilen modeller birbirleriyle entegre edilerek regresyon ve sınıflandırma işlemlerinin başarısı artırılmaya çalışılmıştır.

Birinci Karma Modelde, öğrenim, orjinal veri seti ve 7 günlük basit ortalaması alınmış veri seti ile geliştirilen Destek Vektör Regresyonu, Çoklu Doğrusal Regresyon, Polinom Regresyon, Karar Ağaçları, Rassal Ormanlar yöntemlerinin makine öğrenmeleri ile sağlanmıştır. Söz konusu karma modelde bütün modeller birbirleriyle entegre edilmiştir.

İkinci Karma Modelde, öğrenim orjinal veri ile geliştirilen Çoklu Doğrusal Regresyon, orjinal veri ile geliştirilen Rassal Ormanlar ve 7 günlük basit ortalaması alınmış veriler ile geliştirilen Polinom Regresyon makine öğrenmeleri ile sağlanmıştır.

Sonrasında iki karma yöntem birleştirilerek gerçek zamanlı tahminlemede kullanılmıştır.

Gerçek zamanlı yön tahminin de ise yukarıda belirtilen 2 karma modelin yön tahmini, 7 günlük basit ortalaması alınmış veri seti ile geliştirilmiş DVR modelin yön tahmini ve orjinal veri ile geliştirilmiş DVR modelin yön tahmini ile entegre edilmiştir.

3.2.8. Gerçek Zamanlı Tahminleme

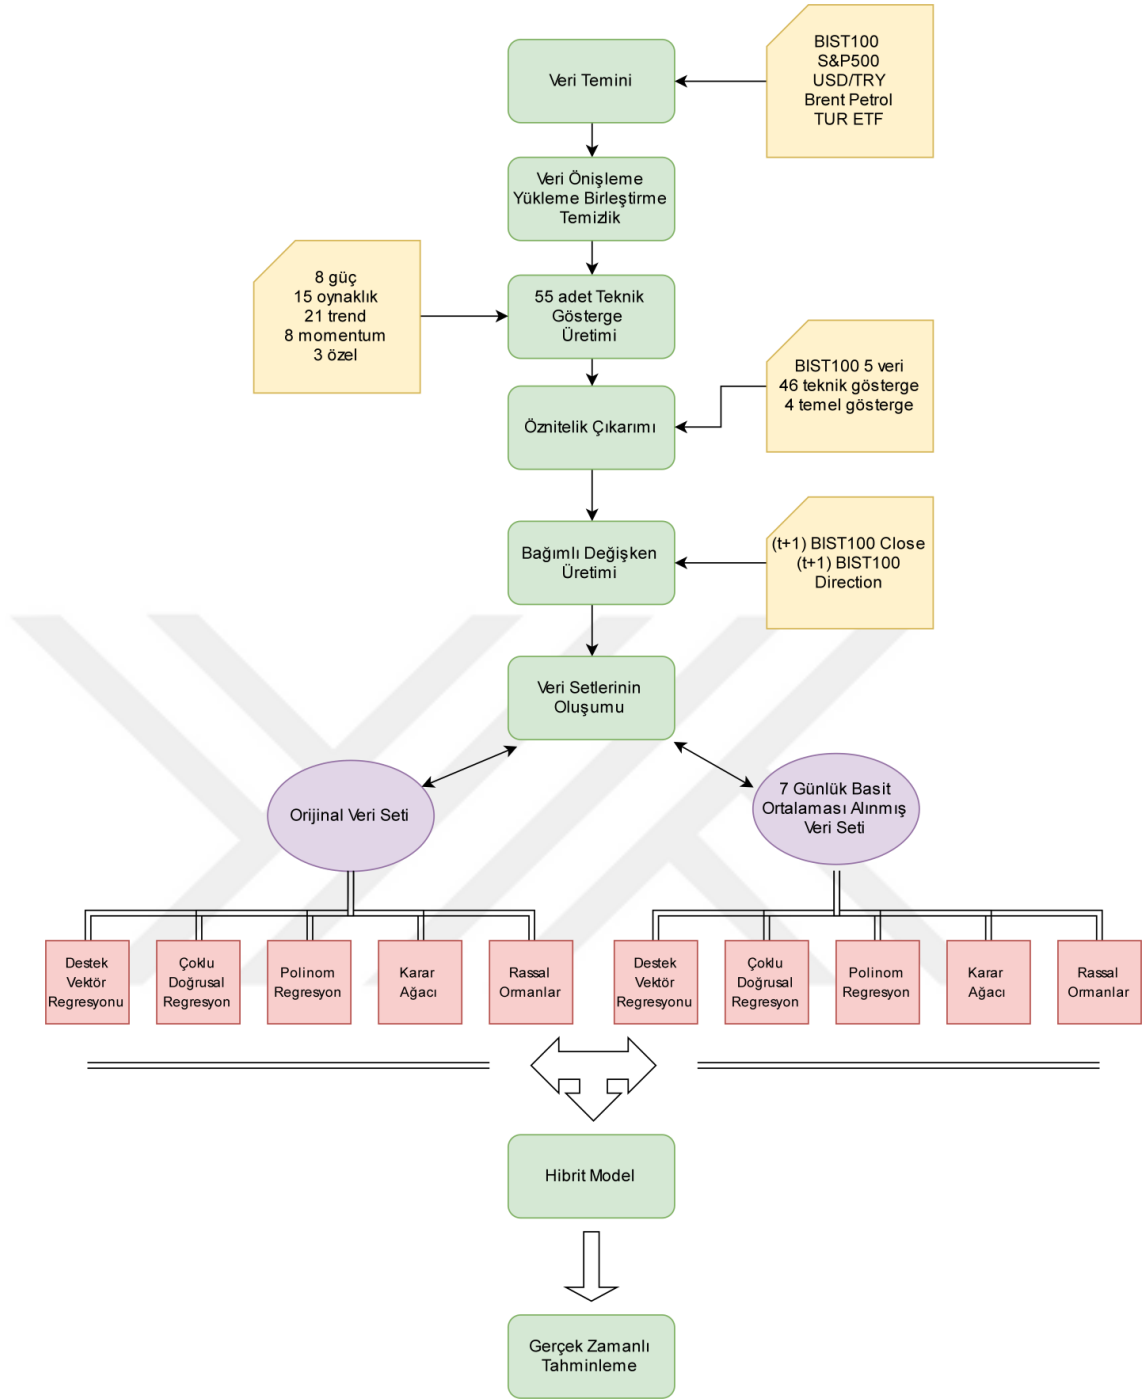
12.11.2018-07.12.2018 tarihlerinde toplam 4 haftalık zaman dilimi boyunca gerçek zamanlı tahminleme gerçekleştirilmiştir.

Gerçek zamanlı tahminlemede, geliştirilen karma yöntem gerçek zamanlı veriler ile kullanılmıştır. Örneğin 12.11.2018 tarihinde piyasalar kapandıktan sonra 12.11.2018 tarihi verileri ile 13.11.2018 tarihindeki BIST100 kapanış değeri ve yönü tahminlenmiştir. Başarısı ise 13.11.2018 tarihinde piyasaların kapanması ile ölçülmüştür. Bu işlemler söz konusu süre zarfında hergün yinelenmiştir.

Gerçek zamanlı tahminleme işlemi 01.01.2010-09.11.2018 tarihleri arasındaki verilerden elde edilen makine öğrenmesi ile gerçekleştirilmiştir.

3.2.9. Uygulama Akış Diyagramı

Geliştirilen uygulamanın akış diyagramı Şekil 3.3'te gösterilmiştir.



Şekil 3.3: Uygulama Akış Diyagramı

3.2.10. Uygulamada Kullanılan Kütüphaneler

Geliştirilen uygulamada kullanılan Python kütüphaneleri Şekil 3.4'te toplu olarak verilmiştir.

```

import pandas as pd
import numpy as np
import matplotlib.pyplot as plt
import datetime as dt
from sklearn.preprocessing import StandardScaler
from sklearn.svm import SVR
from sklearn.preprocessing import PolynomialFeatures
from sklearn.linear_model import LinearRegression
from sklearn.cross_validation import train_test_split
from sklearn.model_selection import cross_val_score
from sklearn.tree import DecisionTreeRegressor
from sklearn.ensemble import RandomForestRegressor
from sklearn.metrics import r2_score
from sklearn.metrics import roc_auc_score
from sklearn.metrics import confusion_matrix
from sklearn.metrics import classification_report

```

Şekil 3.4: Uygulamada Kullanılan Python Kütüphaneleri

4. BULGULAR

Bu bölümde geliştirilen modellerin (Destek Vektör Regresyonu, Karar Ağaçları, Rassal Ormanlar, Çoklu Doğrusal Regresyon ve Polinom Regresyon, Karma) ve gerçek zamanlı tahminlemenin sonuçları ve başarıları sırayla incelenmiştir.

Yön tahmininde sınıflandırma problemi nominal olduğu için etiketleme başarısı F_1 Değerlendirme (F_1 Skor) (F_1 -Scoring) yöntemiyle ölçülmüştür.

F_1 Değerlendirme yöntemi iki sınıflandırıcının tek ölçüt ile değerlendirilmesi için kullanılır. Test edilen verilerin doğruluğunu kesinlik ve hassasiyet bilgilerini kullanarak çözümler.

$$p = \frac{\{ilgili\text{getirim}\} \cap \{bütün\text{veri çıkarımı}\}}{\{bütün\text{veri çıkarımı}\}} \quad (4.1)$$

$$r = \frac{\{ilgili\text{getirim}\} \cap \{bütün\text{veri çıkarımı}\}}{\{ilgili\text{veri çıkarımı}\}} \quad (4.2)$$

3.12 ve 3.13 denklemlerinde p Kesinlik (Precision) ve r Hassiyet (Recall) ifade eder.

$$F_1\text{Skor} = 2 \frac{pr}{p+r} \quad (4.3)$$

Denkleminde belirtildiği gibi F_1 Skoru p ve r değerlerinin harmonik ortalamasıdır.

Uygulamada F_1 Skoru sklearn kütüphanesinin metrics modülünün classification_report sınıfı ile hesaplanmıştır.

Endeks değer tahmininde ise sınıflandırma problemi sayısal olduğu için modellerin performansları R^2 (R Square) yöntemiyle değerlendirilmiştir. R^2 değeri hataların kareler toplamının ortalamaya uzaklığın kareler toplamına bölümünün 1'den çıkarılması ile oluşur. R^2 değeri, 1'e yakın olması istenir çünkü bu değer tahminin başarılı olduğunu gösterir.

$$R^2 = 1 - \left(\frac{HKT}{OUKT}\right) \quad (4.4)$$

Denkleminde HKT hataların (Regresyon eğrisine denk gelmeyen her nokta) kareleri toplamını, OUKT ise herbir noktanın ortalamaya uzaklığının kareleri toplamını ifade eder.


Uygulamada R^2 değeri sklearn kütüphanesinin metrics modülünün r2_score sınıfı ile hesaplanmıştır.

4.1.Destek Vektör Regresyonu Bulgular

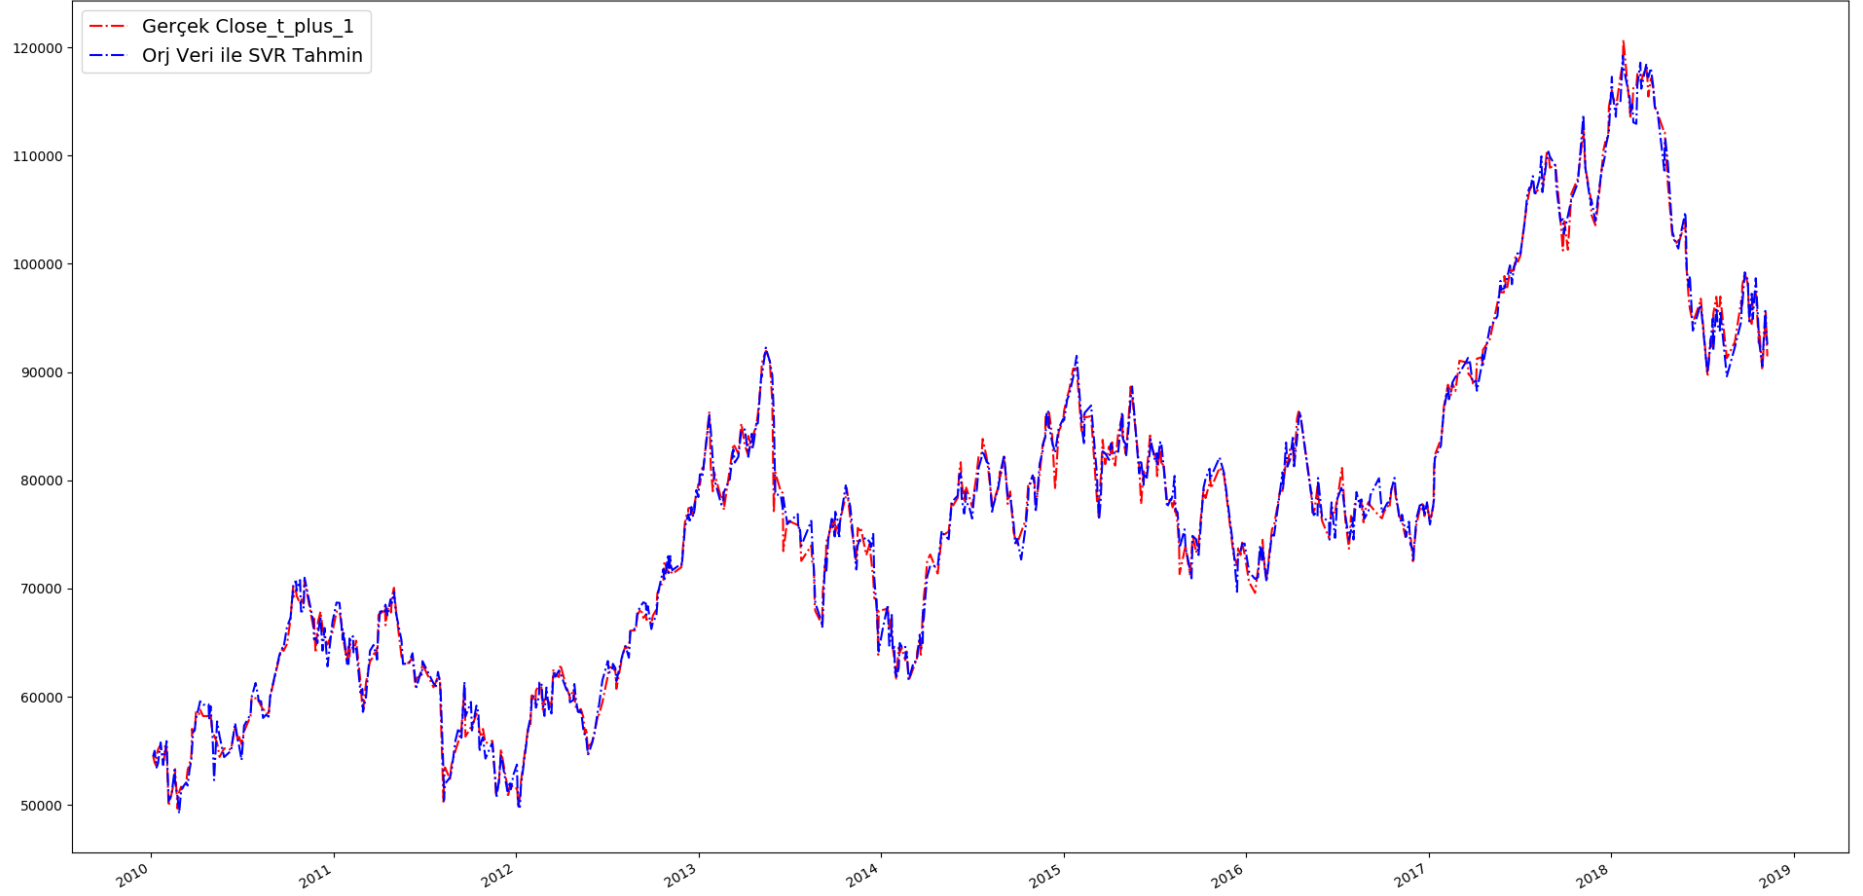
DVR ile geliştirilen model önce 7 günlük basit ortalaması alınmış veri seti ile ardından ortalaması alınmamış orjinal günlük veri seti ile uygulanmıştır. 7 günlük basit ortalaması alınmış bağımlı ve bağımsız değişkenleri içeren veri seti ile modelin R^2 değeri 0.99811 hesaplanmıştır.

2010 ile 2018 yılları arasındaki 7 günlük basit ortalaması alınmış veri setinden 1443 eğitim verisi ile gerçekleştirilen makine öğrenmesi sonucunda 711 bağımlı test değişkene karşı elde edilen DVR tahmin sonuçları Şekil 4.1'de verilmiştir.

Orjinal veri seti ile gerçekleşen DVR modelin R^2 değeri ise 0.99465'dir. Söz konusu verilerin DVR tahmin sonuçları Şekil 4.2'de verilmiştir.



Şekil 4.1: 7 Günlük Basit Ortalaması Alınmış Veri Seti İle DVR Tahmini




Şekil 4.2: Orjinal Veri Seti İle DVR Tahmini

4.2.Çoklu Doğrusal Regresyon Bulgular


Çoklu Doğrusal Regresyon ile geliştirilen model önce 7 günlük basit ortalaması alınmış veri seti ile ardından orjinal veri seti ile uygulanmıştır. 7 günlük basit ortalaması alınmış bağımlı ve bağımsız değişkenleri içeren veri seti ile modelin R^2 değeri 0.99983 hesaplanmıştır.

2010 ile 2018 yılları arasındaki 7 günlük basit ortalaması alınmış veri setinden 1443 eğitim verisi ile gerçekleştirilen makine öğrenmesi sonucunda 711 bağımlı test değişkene karşı elde edilen MLR tahmin sonuçları Şekil 4.3'de verilmiştir.

Orjinal veri seti ile gerçekleşen MLR modelin R^2 değeri ise 0.99486'dır. Söz konusu verilerin MLR tahmin sonuçları Şekil 4.4'te gösterilmiştir.



Şekil 4.3: 7 Günlük Basit Ortalaması Alınmış Veri Seti İle MLR Tahmini




Şekil 4.4: Orjinal Veri Seti İle MLR Tahmini

4.3.Polinom Regresyon Bulgular


Polinom Regresyon ile geliştirilen model önce 7 günlük basit ortalaması alınmış veri seti ile ardından orjinal veri seti ile uygulanmıştır. 7 günlük basit ortalaması alınmış bağımlı ve bağımsız değişkenleri içeren veri seti ile modelin R^2 değeri 0.99982 hesaplanmıştır.

2010 ile 2018 yılları arasındaki 1443 eğitim verisi ile gerçekleştirilen makine öğrenmesi sonucunda 711 bağımlı test değişkenine karşı elde edilen PR tahmin sonuçları Şekil 4.5'te verilmiştir.

Orjinal veri seti ile gerçekleşen PR modelin R^2 değeri ise 0.98656'dır. Söz konusu verilerin PR tahmin sonuçları Şekil 4.6'da gösterilmiştir.



Şekil 4.5: 7 Günlük Basit Ortalaması Alınmış Veri Seti İle PR Tahmini




Şekil 4.6: Orjinal Veri Seti İle PR Tahmini

4.4.Karar Ağacı Bulgular


Karar Ağaçları ile geliştirilen model önce 7 günlük basit ortalaması alınmış veri seti ile ardından orjinal veri seti ile uygulanmıştır. 7 günlük basit ortalaması alınmış bağımlı ve bağımsız değişkenleri içeren veri seti ile modelin R^2 değeri 0.99914 hesaplanmıştır.

2010 ile 2018 yılları arasındaki 1443 eğitim verisi ile gerçekleştirilen makine öğrenmesi sonucunda 711 bağımlı test değişkenine karşı elde edilen DT tahmin sonuçları Şekil 4.7'de verilmiştir.

Orjinal veri seti ile gerçekleşen DT modelin R^2 değeri ise 0.99051'dir. Söz konusu verilerin DT tahmin sonuçları Şekil 4.8'de gösterilmiştir.



Şekil 4.7: 7 Günlük Basit Ortalaması Alınmış Veri Seti İle DT Tahmini




Şekil 4.8: Orjinal Veri Seti İle DT Tahmini

4.5.Rassal Ormanlar Bulgular


Rassal Aalarile geliřtirilen model 7 gnlk basit ortalaması alınmıř veri seti ile ardından orjinal veri seti ile uygulanmıřtır. 7 gnlk basit ortalaması alınmıř baėımlı ve baėımsız deėiřkenleri ieren veri seti ile modelin R^2 deėeri 0.99940 hesaplanmıřtır.

2010 ile 2018 yılları arasındaki 1443 eėitim verisi ile gerekleřtirilen makine ėrenmesi sonucunda 711 baėımlı test deėiřkenine karřı elde edilen RF tahmin sonuları Őekil 4.9'da verilmiřtir.

Orjinal veri seti ile gerekleřen RF modelin R^2 deėeri ise 0.99408'dir. Sz konusu verilerin RF tahmin sonuları Őekil 4.10'da gsterilmiřtir.



Şekil 4.9: 7 Günlük Basit Ortalaması Alınmış Veri Seti İle RF Tahmini



Şekil 4.10: Orjinal Veri Seti İle RF Tahmini

4.6.Karma Modeller Bulgular

7 günlük basit ortalaması alınmış veri seti ile uygulanan DVR, MLR, PR, DT ve RF modeller birleştirilerek tahmin ortalaması alınmış ve 0.99969 R^2 başarı oranı elde edilmiştir. Tahmin sonuçları Şekil 4.11'de verilmiştir.

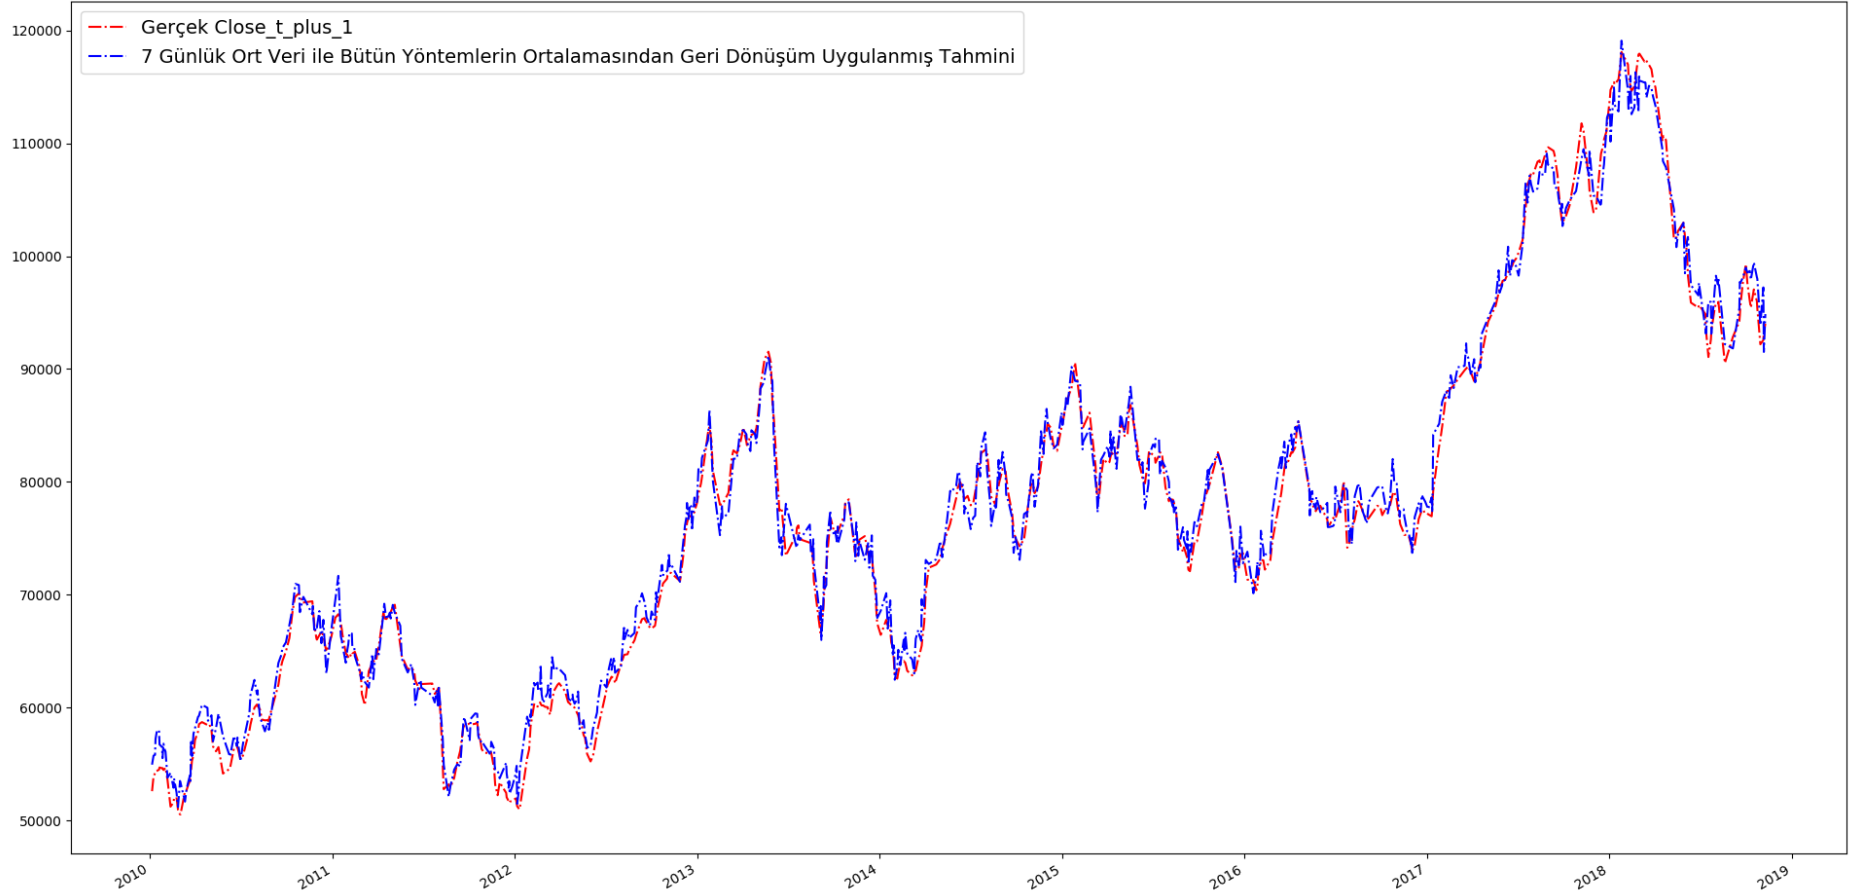
Söz konusu tahminler 7 ile çarpılıp son 6 günün gerçek BIST100 Close_t_plus_1 değerinin toplamından çıkartılarak ters dönüşüme tabi tutulmuş ve 7 günlük basit ortalaması alınmış BIST100 Close_t_plus_1 değerinin tahminlemesi orjinal BIST100 Close_t_plus_1 tahmin değerine çevrilmiştir. 0.99038 R^2 değerine ulaşıldığı bu dönüşümün tahmin sonuçları Şekil 4.12'de gösterilmiştir.

Ayrıca orjinal veri seti ile uygulanan DVR, MLR, PR, DT ve RF modelleri birleştirilerek tahmin ortalaması alınmış ve 0.99426 R^2 başarı oranı elde edilmiştir. Tahmin sonuçları Şekil 4.13'de verilmiştir.


Geliştirilen birinci karma modelde 0.99359, ikinci karma modelde 0.99394 ve iki karma modelin birleştirilmesiyle 0.99396 R^2 değerlerine ulaşılmıştır. Karma modellerin tahminleri sırayla Şekil 4.14, 4.15 ve 4.16'da gösterilmiştir.




Şekil 4.11: 7 Günlük Basit Ortalaması Alınmış Veri Seti İle Bütün Yöntemlerin Ortalama Tahmini




Şekil 4.12: 7 Günlük Basit Ortalaması Alınmış Veri Seti İle Bütün Yöntemlerin Ortalama Tahmininden Geri Dönüşüm




Şekil 4.13: Orjinal Veri Seti İle Bütün Yöntemlerin Ortalama Tahmini



Şekil 4.14: 1. Karma Model Tahmini



Şekil 4.15: 2. Karma Model Tahmini



Şekil 4.16: Karma Modellerin Ortalama Tahmini

4.7.Gerçek Zamanlı Tahminleme Bulgular

01.01.2010-09.11.2018 tarihleri arasındaki 7 günlük basit ortalaması alınmış veri seti ile gerçekleştirilen DVR, MLR, PR, DT, RF modellerinin ve 01.01.2010-09.11.2018 tarihleri arasındaki orjinal veri seti ile gerçekleştirilen DVR, MLR, PR, DT, RF modellerinin gerçek zamanlı verilerle endeks değer tahminleme sonuçları Şekil 4.17'de, endeks yön tahminleme sonuçları ise Şekil 4.18'de verilmiştir.

Söz konusu şekiller üzerinde karma modellerin değer ve yön tahminleme sonuçları da gösterilmiştir.

Gerçek zamanlı tahminleme gerçekleştirilen 12.11.2018-07.12.2018 tarihleri arasında BIST100 endeksi 6 gün azalmış, 12 gün ise artmıştır. Oynaklığın (volatility) çok olduğu ve endeksin bir trend arayışı içerisinde olduğu bu dönem zarfında geliştirilen karma model 6 azalışın 5'ini, 12 artışın ise 10'unu olmak üzere toplam 18 günün 15'ini doğru tahminleyerek 0.84 F_1 değerine ulaşmıştır.

Çizelge 4.1'de gerçek zamanlı yön tahminin F_1 Skor sonuçları verilmiştir.

	Precision	Recall	F₁ Score	Support
0	0.71	0.83	0.77	6
1	0.91	0.83	0.87	12
Avg/total	0.84	0.83	0.84	18

Çizelge 4.1: Karma Modelin Yön Tahmin Başarısı

Index	Close	Close_t_plus_1	svr	mlr	pr	dt	rf	ort_1	ort_2	svr_7	mlr_7	pr_7	dt_7	rf_7	ort_1_7	ort_2_7	7_orj_don	svr_ort	Hibrit_1	Hibrit_2	Hibrit_ort
2018-11-12 00:00:00	91445.3	92708.6	91413.9	91442	90374	93189.3	92648.2	91813.5	92045.1	94194.1	93758.5	93718.1	94996.7	94130.2	94159.5	93944.3	94404.1	92526	93047.6	92881.6	92905.3
2018-11-13 00:00:00	92708.6	93287.2	92577.7	92710.7	92501.4	94419.1	93043.8	93050.6	92877.2	93841.6	93478.2	93497.7	94996.7	94130.2	93988.9	93804.2	96555.6	93083.3	94161.4	93187.5	93657.1
2018-11-14 00:00:00	93287.2	93296.8	93417.9	93428.2	93643.6	90262.9	94041.7	92958.9	93735	93543.1	93031.6	93074.1	93861.7	93765.1	93455.1	93398.3	94707.3	93468	93520	93404.5	93472.9
2018-11-15 00:00:00	93296.8	93616.4	93163.9	93205.2	94686.6	90262.9	93683.9	93000.5	93444.5	93635.1	93061.3	93131.8	93127	93408.9	93272.8	93235.1	95694.6	93352.4	93742.1	93288.2	93525.8
2018-11-16 00:00:00	93616.4	94570.9	93362.3	93460.4	95351.1	90262.9	93112	93109.8	93286.2	93481.3	92830.1	92872.8	93127	93063.4	93074.9	92946.8	93882.4	93409.9	93294.2	93079.5	93241.9
2018-11-19 00:00:00	94570.9	91686.4	94205.4	94306.4	93918.8	94174	95560.7	94433	94933.6	93807.3	93312.2	93367.5	93765.9	93251.5	93500.9	93281.8	94814.3	94046.2	94295.3	94150.5	94205.5
2018-11-20 00:00:00	91686.4	92707.9	91204.6	91202.7	91224.7	90262.9	91641.1	91107.2	91421.9	93625.2	92943.3	92901.6	93765.9	93056.7	93258.5	93000	92738.7	92172.9	92052.9	92161.7	92109.2
2018-11-21 00:00:00	92707.9	93003.3	91993.3	92141	91642.4	90262.9	92513.7	91710.6	92327.3	93624.4	93401.3	93395.7	93765.9	93308.8	93499.2	93355	94824.2	92645.7	92936.2	92861.5	92862.9
2018-11-23 00:00:00	93003.3	93962.4	92795.8	92531.9	89771.4	90262.9	93105.6	91693.5	92818.7	93493.3	93299.7	93222.1	93765.9	93430.4	93442.3	93365.1	94943.9	93074.8	92943.3	93020.4	92990.9
2018-11-26 00:00:00	93962.4	93517	93884.5	93411.8	90322	94759.6	95222.4	93520.1	94317.1	93403.6	93331.6	93236.8	93861.7	93781.5	93523	93556.6	95231.3	93692.1	93948.6	93776.9	93848.6
2018-11-27 00:00:00	93517	94071	93535.7	93376.4	94165.2	90262.9	92805.4	92829.1	93090.9	93152.5	93219.8	93138.9	93861.7	93939.5	93462.5	93579.6	95199.6	93382.4	93580.1	93114.9	93392.1
2018-11-28 00:00:00	94071	95125.6	94221.6	93939.8	93910.1	94759.6	95074.1	94381.1	94507	93222.7	93303.6	93248.8	93861.7	93939.5	93515.3	93621.5	96031	93822	94577.1	93877.9	94218.2
2018-11-29 00:00:00	95125.6	95416	95520.5	95165.6	95131.7	94174	96190.3	95236.4	95677.9	93342.4	93415.7	93367.6	93861.7	94121.1	93621.7	93768.4	93478.4	94649.3	94393.2	94522.8	94479.1
2018-11-30 00:00:00	95416	94974.4	95719.3	95440.1	96792.8	94174	95069.4	95439.1	95254.8	94333.9	94383.8	94362.7	94146.4	94236.1	94292.6	94310	95013.7	95165.1	95046.1	94808.7	94986.8
2018-12-03 00:00:00	94974.4	93880.5	94815.6	94979.2	95158.1	94174	94427.2	94710.8	94703.2	94803.2	94547.6	94478	94146.4	94472.5	94489.5	94510	94432	94810.6	94585.8	94590.6	94624.9
2018-12-04 00:00:00	93880.5	92827.3	93522.1	93709.4	93016.2	94759.6	94217.8	93845	93963.6	94749.8	94533.5	94520.7	94778.5	94631.1	94642.7	94582.3	95303.1	94013.1	94409	94242.2	94287.4
2018-12-06 00:00:00	92827.3	93699.5	92648.7	92636.1	92747.2	90262.9	92567.8	92172.6	92602	94224.9	94096.5	94106.8	94778.5	94319.8	94305.3	94208.2	93502.4	93279.2	93038.2	93354.4	93183.8
2018-12-07 00:00:00	93699.5	92227.3	93748.4	93537.3	92677	90262.9	92597.5	92564.6	93067.4	94342.2	94230.9	94232.3	94778.5	94448.3	94406.4	94339.6	94687.8	93985.9	93555.9	93649.8	93658.9

Şekil 4.17: Gerçek Zamanlı Endeks Değer Tahminleri

Index	Direction	svr_yon	mlr_yon	pr_yon	dt_yon	rf_yon	ort_1_yon	ort_2_yon	svr_7_yon	mlr_7_yon	pr_7_yon	dt_7_yon	rf_7_yon	ort_1_7_yon	ort_2_7_yon	7_orj_don_yon	svr_ort_yon	h_1_yon	h_2_yon	h_ort_yon
2018-11-12 00:00:00	1	0	0	0	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
2018-11-13 00:00:00	1	0	1	0	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
2018-11-14 00:00:00	1	1	1	1	0	1	0	1	1	0	0	1	1	1	1	1	1	1	1	1
2018-11-15 00:00:00	1	0	0	1	0	1	0	1	1	0	0	0	1	0	0	1	1	1	0	1
2018-11-16 00:00:00	1	0	0	1	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0
2018-11-19 00:00:00	0	0	0	0	0	1	0	1	0	0	0	0	0	0	0	1	0	0	0	0
2018-11-20 00:00:00	1	0	0	0	0	0	0	0	1	1	1	1	1	1	1	1	1	1	1	1
2018-11-21 00:00:00	1	0	0	0	0	0	0	0	1	1	1	1	1	1	1	1	0	1	1	1
2018-11-23 00:00:00	1	0	0	0	0	1	0	0	1	1	1	1	1	1	1	1	1	0	1	1
2018-11-26 00:00:00	0	0	0	0	1	1	0	1	0	0	0	0	0	0	0	1	0	0	0	0
2018-11-27 00:00:00	1	1	0	1	0	0	0	0	0	0	0	1	1	0	1	1	0	1	0	1
2018-11-28 00:00:00	1	1	0	0	1	1	1	1	0	0	0	0	0	0	0	1	0	1	0	1
2018-11-29 00:00:00	1	1	1	1	0	1	1	1	0	0	0	0	0	0	0	0	0	0	0	0
2018-11-30 00:00:00	0	1	1	1	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0
2018-12-03 00:00:00	0	0	1	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
2018-12-04 00:00:00	0	0	0	0	1	1	0	1	1	1	1	1	1	1	1	1	1	1	1	1
2018-12-06 00:00:00	1	0	0	0	0	0	0	0	1	1	1	1	1	1	1	1	1	1	1	1
2018-12-07 00:00:00	0	1	0	0	0	0	0	0	1	1	1	1	1	1	1	1	1	0	0	0

Şekil 4.18: Gerçek Zamanlı Endeks Yön Tahmini

5. SONUÇ VE ÖNERİLER

Fiyat hareketlerini yüksek hassasiyette yansıtan, momentum, trend, oynaklık, güç, gösterge sınıflarını kapsayan 55 adet teknik göstergenin üretilmesi, BIST100'e yön veren temel göstergelerin tespit edilmesi, temel ve teknik göstergelerin bir arada kullanılması ve son olarak BIST100 ile korelasyon durumuna göre öznitelik seçimine gidilmesi modellerin veri kısmını optimize etmiş, başarısını artırmıştır.

Modellerin 7 günlük basit ortalaması alınmış veri seti ile makine öğrenmesi ve yine aynı veri seti üzerindeki tahmin başarısı, orijinal veri seti ile gerçekleştirilen makine öğrenmesi ve tahmin başarısından yüksektir. 7 günlük basit ortalama alınması verideki gürültü miktarını azaltmış ve tahminleme başarısını artırmıştır.

7 günlük basit ortalaması alınmış veri seti ile gerçekleştirilen makine öğrenmelerinde en iyi tahminlemeyi MLR, ardından sırasıyla PR, RF ve DT sergilemiş, DVR ise sonuncu olmuştur.

Orjinal veri seti ile gerçekleştirilen makine öğrenmelerinde ise en iyi tahminlemeyi MLR, ardından sırasıyla DVR, RF ve DT sergilemiş, PR ise sonuncu olmuştur. Bütün modellerin başarıları Şekil 5.1'de verilmiştir.

Modeller tek başına incelendiğinde MLR en iyi performans sergilemiştir. Söz konusu performansta BIST100'ün azalış/yükseliş trendleri içerisinde ilerlemesi ve birçok doğrusal örüntü oluşturmasının etkisi büyüktür. Endeks değer tahmin modellerinde doğrusal verilerle çalışan yöntemlerinmodele entegrasyonunun başarı oranı artırdığı sonucuna ulaşılmıştır.

RF'nin performansı her iki veri setinde de DT'den daha iyi olmuştur. Birden fazla ağacın öğrenmeye ve tahminlemeye olan katkısı ve kollektif öğrenmenin başarısı ortaya konmuştur.

PR, ortalaması alınarak gürültüden kurtarılmış veri setinde iyi performans sergilese de orjinal veride aynı performansı yakalayamamıştır. DVR'de ise tam tersi bir durum yaşanmıştır. DVR'de kullanılan çekirdek hilesi ile verilerin 3. boyuta taşınması yerel minimum ve maximum noktalara daha rahat ulaşılmasını sağlamıştır.

Gerçek zamanlı tahminlemenin gerçekleştirildiği 12.11.2018-07.12.2018 tarihleri Borsa İstanbul'da oynaklığın (volatility) çok olduğu ve endeksin bir yön/trend arayışı içerisinde olduğu döneme denk gelmiştir. Ancak endeks azalış veya yükseliş trendi içerisine girmeden 91.000-96.000 bandında gitgeller yaşamıştır. Geliştirilen model söz konusu şartlar altında 0.84 F_1 değerine ulaşarak yüksek performans sergilemiştir.

Geliştirilen modellerin haftalık ve aylık verilerle de uygulanabileceği düşünülmektedir. Bir sonraki haftanın veya bir sonraki ayın kapanışı tahminlenebilir. Yatırımcılara daha geniş vade ve daha geniş marjlarda alım satım fırsatları kazandırılabilir. Haftalık ve aylık verilerle model geliştirilirken daha fazla temel gösterge bulunabilir ve tahmin başarısı artırılabilir.

BIST100 endeksi “piyasa performansı” hakkında genel bir bilgi veren en kapsamlı ve en ideal olduğu için mevcut modeller hisse senetleri için de uygulanabilir. Hisse senetlerinin bir gün sonraki kapanış fiyatları tahminlenerek yatırımcılara katkı sağlanabilir.

Bir gün sonraki BIST100 kapanış değer tahminlemesine ek olarak bir sonraki günün açılış, en düşük ve en yüksek değerleri de tahminlenebilir. Yatırımcılara gün içindeki dalgalanmalardan yararlanabilecekleri kararlar üretilebilir.

(t) zamanın verileri ile (t+1) (t+2) (t+3) zamanı BIST100 kapanış fiyatları tahminlenebilir. (t) zamanı verileri bağımsız değişken (t+1) (t+2) (t+3) zamanı kapanış fiyatları ise bağımlı değişken olur. Ardından (t+1) kapanış değeri için (t-2) zamanındaki verilerin (t+3) tahmini, (t-1) zamanındaki verilerin (t+2) tahmini ve (t) zamanındaki verilerin (t+1) tahmininden yola çıkılarak yeni bir makine öğrenmesi ve tahminleme yapılabilir. Böylece trend değişim noktalarını tahminlemede mevcut modelin trend dönüşümlerindeki dezavantajını gidermede yardımcı olabilir.

Index	Aciklama	SVR	MLR	PR	DT	RF	Ort_1	7_orj_don_tah	Hib_1	Hib_2	Hib_Ort
0	7 Günlük Ort verilerle makine öğrenimi ve testi	0.998108	0.999825	0.999817	0.999142	0.999397	0.999685	0.990383	nan	nan	nan
1	Orjinal verilerle makine öğrenimi ve testi	0.994645	0.994859	0.986558	0.990512	0.994083	0.994252	nan	nan	nan	nan
2	Hibrit Modelin Sonuçları	nan	nan	nan	nan	nan	nan	nan	0.993582	0.993935	0.993951

Şekil 5.1: Modellerin R^2 Değerleri

KAYNAKLAR

- Akel, V. ve Bayramođlu, M. F. (2008). “Kriz Dönemlerinde Yapay Sinir Ağları ile Finansal Öngörüde bulunma: İMKB 100 Endeksi Örneđi”. International Symposium on International Capital Flows and Emerging Markets, 24-28 Nisan 2008, Balıkesir, Bandırma.
- Aksoy, H. (2001). “Modelling The Ise100 Index By Using Fuzzy Logic And Neural Fuzzy Systems”, Yüksek Lisans Tezi
- Alyozbakee, A. (2016). “Yapay Sinir Ađını Kullanarak Irak Borsası Tahmini”, Yüksek Lisans Tezi
- Aygören, H. Ve Saritaş, H. (2012). “İMKB 100 Endeksinin Yapay Sinir Ağları ve Newton Nümerik Arama Modelleri ile Tahmini”. International Journal of Alanya Faculty of Business Yıl:2012, C:4, S:1, s.73-88
- Baydilli, Y. (2014). “Bist-100Endeksinin Veri Madenciliđi ve Finansal Ağ Teknikleriyle İncelenmesi”, Yüksek Lisans Tezi
- Bilgiç, E. (2017). “Google Trends Arama Hacim Endeksinin Borsa İstanbul Endeksi (Bist) Üstünde Testi”, Yüksek Lisans Tezi
- Borsa İstanbul A.Ş, Borsa İstanbul 2017 Yılı Entegre Faaliyet Raporu
- Boyacıođlu, M. A. ve Avcı, D. (2010). “An Adaptive Network-Based Fuzzy Inference System (ANFIS) for the prediction of stock market return: The case of the Istanbul Stock Exchange”, Elsevier, Expert Systems with Applications 37 (2010) 7908–7912
- Chatzis, S., Siakoulis, V., Petropoulos, A., &Stavroulakis, E. (2017). “Forecasting Stock Market Crisis Events Using Deep And Statistical Machine Learning Techniques”, 0957-4174©2018 Elsevier, Expert Systems With Applications 112 (2018) 353–371
- Çam, S. (2017). “Döviz Kuru, Altın Fiyatları Ve Borsa Getirileri Yönünün Yapay Sinir Ağları Ve Yüksek Dereceden Markov Zincirleri Modelleri İle Tahmini”, Yüksek Lisans Tezi
- Diler, A. İ. (2003).” İMKB Ulusal-100 Endeksinin Yönünün Yapay Sinir Ağları Hatayı Geriye Yayma Yöntemi ile Tahmin Edilmesi”. İMKB Dergisi, 7(25-26), 66-82.
- Emir, Ş. (2013). “Yapay Sinir Ağları ve Destek Vektör Makineleri Yöntemlerinin Sınıflandırma Performanslarının Karşılaştırılması: Borsa Endeks Yönünün Tahmini Üzerine Bir Uygulama”, Doktora Tezi
- Erdal, H. İ. (2011). “Destek Vektör Makineleri İle Tahmine Dayalı Modelleme ve Bir Uygulama”, Doktora Tezi
- Ergür, B. (2014). “Borsa İstanbul (BIST) Hisse Fiyat Deđişim Yönünün İlişkisel Borsa Ađı Kullanılarak Tahmin Edilmesi”, Yüksek Lisans Tezi
- Güzel, F. (2014). “Bulanık Sinir Ađı Yapısı İle Borsa Endeks Getirisi Tahmini BİST100 Örneđi”, Yüksek Lisans Tezi
- Gyorfi, L., Ottucsak, G. &Walk, H. (2011). Machine Learning For Financial Engineering, Imperial College Press
- Henrique, B., Sobreiro, V. &Kimura, H. (2018). “Stock Price Prediction Using Support Vector Regression On Daily And Up To The Minute Prices”, 2405-

- 9188©2018 Elsevier, The Journal of Finance and Data Science 4 (2018) 183-201
- Hou, X., Zhu, S., Xia, L., & Wu, G. (2018). "Stock Price Prediction Based On Grey Relational Analysis And Support Vector Regression", 978-1-5386-1243-9/18/ ©2018 IEEE, The 30th Chinese Control and Decision Conference (2018 CCDC)
- Kim, K. J. (2003). "Financial Time Series Forecasting Using Support Vector Machines". *Neurocomputing*, 55, 307–319.
- Kutlu, B. ve Badur, B. (2009). "Yapay Sinir Ağları ile Borsa Endeksi Tahmini". *Yönetim*, 20(63), 25-40.
- Lee, T., Cho, J., Kwon, D., & Sohn, S. (2018). "Global Stock Market Investment Strategies Based On Financial Network Indicators Using Machine Learning Techniques", 0957-4174©2018 Elsevier, *Expert Systems With Applications* 117 (2018) 228–242
- Lohrmann, C., & Luukka, P. (2018). "Classification of Intraday S&P500 Returns With a Random Forest", 0169-2070©2018 Elsevier, *International Journal of Forecasting* 35 (2019) 390–407
- Loke K. S. (2017). "Impact Of Financial Ratios And Technical Analysis On Stock Price Prediction Using Random Forests", 978-1-5386-0765-7/17 ©2017 IEEE
- Masoud, (2014). "Predicting Direction of Stock Prices Index Movement Using Artificial Neural Networks: The Case of Libyan Financial Market". *British Journal of Economics, Management & Trade* 4(4): 597-619, 2014
- Müller, C. & Guido, S. (2016). *Introduction to Machine Learning with Python, A Guide For Data Scientists*, O'Reilly
- Nivetha, Y. & Dhaya, C. (2017). "Developing a Prediction Model for Stock Analysis", 2017 International Conference on Technical Advancements in Computers and Communications, 978-1-5090-4797-0/17 ©2017 IEEE DOI 10.1109/ICTACC.2017.11
- Ouahilal, M., Mohajir, M. & Chahhou, M. (2016). "Optimizing Stock Market Price Prediction Using A Hybrid Approach Based On Hp Filter And Support Vector Regression", 978-1-5090-0751-6/16 ©2016 IEEE
- 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.
- Pan, Y., Xiao, Z., Wang, X., & Yang, D. (2017). "A Multiple Support Vector Machine Approach To Stock Index Forecasting With Mixed Frequency Sampling", 0950-7051©2017 Elsevier, *Knowledge-Based Systems* 122 (2017) 90–102
- Russell, R. (2018) *Machine Learning, Step-by-step Guide To Implement Machine Learning Algorithms With Python*
- Sable, S. & Porwal, A. (2017). "Stock Price Prediction Using Genetic Algorithms And Evolution Strategies", 978-1-5090-5686-6/17/ ©2017 IEEE, International Conference on Electronics, Communication and Aerospace Technology ICECA 2017
- Sarkar, D., Bali, R. & Sharma T. (2018). *Practical Machine Learning with Python, A Problem Solver's Guide to Building Real-World Intelligent Systems*, Apress
- Sharma, N. & Juneja, A. (2017). "Combining Of Random Forest Estimates Using Lsboost For Stock Market Index Prediction", 2017 2nd International Conference for Convergence in Technology (I2CT), 978-1-5090-4307-1/17 ©2017 IEEE

- 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.
- Tekin, S. (2013). "Destek Vektör Makineleri Yöntemi İle İMKB 100 Endeksi Hareket Yönü Tahmini", Yüksek Lisans Tezi
- Türkiye Sermaye Piyasası Aracı Kuruluşlar Birliği (2011). Sermaye Piyasası Faaliyetleri İleri Düzey Lisans Eğitimi, Analiz Yöntemleri
- Uyar, H. (2015). "BIST (Borsa İstanbul) Verilerinin Çeşitli Bulanık Zaman Serileri Yaklaşımları İle Öngörülerinin Karşılaştırılması", Yüksek Lisans Tezi
- Ünal, H. (2015). "Bulanık Doğrusal Programlama ve Borsa İstanbul'da Bir Uygulama", Yüksek Lisans Tezi
- Yakut, E. Ve Bekir, E. (2014). "Yapay Sinir Ağları Ve Destek Vektör Makineleri Yöntemleriyle Borsa Endeks Tahmini". Suleyman Demirel University The Journal of Faculty of Economics and Administrative Sciences Y.2014, Vol.19, No.1, pp.139-157.
- Yeşil, H. (2014). "Hisse Senedi Getirilerinin Öngörüsünde Finansal Zaman Serisi Modellerinin Karşılaştırılması Borsa İstanbul Örneği", Yüksek Lisans Tezi
- Yılmaz, C. (2016). "Teknik Analiz Göstergelerinin Performans Analizi Borsa İstanbul Üzerine Uygulama", Yüksek Lisans Tezi
- Yılmaz, M. (2015). "Hava Durumları ve Borsa Endeks Getirileri Borsa İstanbul Üzerine Ampirik Bir Uygulama", Yüksek Lisans Tezi
- Zang, J., Cui, Z., Xu, Y., & Li, T. (2018). "A Novel Data-Driven Stock Price Trend Prediction System", 0957-4174©2018 Elsevier, Expert Systems With Applications 97 (2018) 60–69
- (2018, Kasım) <http://bilgisayarkavramlari.sadievrenseker.com/>
- (2018, Kasım) <https://mertricks.com/2014/11/29/veri-madenciligi-3-veri-hazirlama-bolum-1/>

EKLER

EK A: Gerçek Zamanlı Tahminleme Test Verileri

Date	Açılış	Kapanış	En Yüksek	En Düşük	Hacim	TA_1	TA_2	TA_3	TA_4	TA_5	TA_6
2018-11-12	93005,79	93695,34	91445,28	91445,28	9,55E+08	-1,1E+09	-9,5E+08	69204543	-0,08121	7,15E+11	-0,00061
2018-11-13	91532,34	93094,93	91297,67	92708,56	1,19E+09	-2,8E+08	1,19E+09	3,09E+08	-0,09495	2,41E+09	-0,00033
2018-11-14	92530,56	93691,34	91945,76	93287,16	1,39E+09	1,42E+09	1,39E+09	3,1E+08	-0,05621	8,01E+11	-0,00028
2018-11-15	93523,34	94002,47	92695,3	93296,84	1,33E+09	6,4E+08	1,33E+09	3,27E+08	-0,07683	8,42E+10	-0,00017
2018-11-16	93785,88	94308,31	92743,88	93616,45	9,94E+08	8656680	9,94E+08	2,76E+08	-0,03432	-1,3E+11	-2E-05
2018-11-19	93568,15	94602,73	93568,15	94570,9	1,18E+09	1,22E+09	1,18E+09	2,53E+08	0,0522	-1,9E+11	0,000401
2018-11-20	94279,75	94391,73	91545,81	91686,35	1,62E+09	-3,5E+08	-1,6E+09	2,27E+08	0,035418	-1,2E+12	0,000175
2018-11-21	92021,5	92707,95	91559,38	92707,95	1,2E+09	-2,7E+08	1,2E+09	2,2E+08	0,080155	-2,8E+10	2,76E-05
2018-11-23	92581,57	93003,27	92028,74	93003,27	8,29E+08	2,03E+09	8,29E+08	4,33E+08	0,154712	-1E+12	-0,00017
2018-11-26	93521,69	94435,84	93455,3	93962,35	1,42E+09	8,78E+08	1,42E+09	6,96E+08	0,112832	2,79E+11	-0,00025
2018-11-27	93904,88	94104,44	93043	93516,96	1,26E+09	-8,6E+07	-1,3E+09	6,65E+08	0,149111	2,21E+11	-0,00031
2018-11-28	93516,96	94673,35	93516,96	94070,97	1,26E+09	-1,9E+08	1,26E+09	6,72E+08	0,145893	-1,7E+10	-0,00027
2018-11-29	94070,97	95544,59	94070,97	95125,57	1,2E+09	4,66E+08	1,2E+09	6,53E+08	0,184354	-9,2E+10	-0,00011
2018-11-30	95125,57	95416,03	94527,68	95416,03	1,65E+09	2,17E+09	1,65E+09	6,85E+08	0,201859	5,3E+11	3,59E-05
2018-12-03	96366,96	96829,78	94974,45	94974,45	1,45E+09	2,03E+08	-1,5E+09	4,41E+08	0,111516	-3,8E+10	0,000178
2018-12-04	94649,89	95550,5	93530,38	93880,49	1,39E+09	-2,4E+09	-1,4E+09	1,83E+08	0,020562	3,99E+11	7,78E-05
2018-12-06	93506,84	93866,56	92375,25	92827,29	1,16E+09	-1,4E+09	-1,2E+09	2,3E+08	0,027838	6,33E+11	-0,00011
2018-12-07	93521,18	93807,04	93149,26	93699,49	9,98E+08	2,17E+08	9,98E+08	2,1E+08	0,035801	7,16E+10	-0,00013
2018-12-10	93245,87	93453,7	92217,54	92227,32	8,47E+08	-1,6E+08	-8,5E+08	42526269	0,0445	1,86E+11	-0,00022

Date	TA_7	TA_8	TA_9	TA_10	TA_11	TA_12	TA_13	TA_14	TA_15	TA_16
2018-11-12	-22958651	1113,4928	2155,1188	99810,939	88769,033	94289,986	93054,907	95284,623	90825,191	98991,01
2018-11-13	2105893,9	1113,4928	2129,5574	99158,195	88829,506	93993,85	93293,234	95420,419	91166,049	98991,01
2018-11-14	25116266	1113,4928	2102,1305	98455,256	89014,519	93734,887	93543,857	95580,712	91507,002	98991,01
2018-11-15	8811978,4	1113,6084	2045,3476	97470,727	89429,631	93450,179	93717,728	95636,222	91799,234	97453,96
2018-11-16	3544058,2	1117,4233	2010,9963	96813,696	89702,911	93258,303	93700,962	95566,642	91835,282	96454,57
2018-11-19	15448877	1117,4233	1941,2523	96452,801	89875,439	93164,12	93602,074	95357,731	91846,417	95947,73
2018-11-20	-37432224	1117,4233	2018,6693	96284,807	89743,898	93014,352	93350,419	95178,843	91521,995	95947,73
2018-11-21	-36144601	1129,874	1956,5193	96242,189	89710,412	92976,3	93056,192	94821,004	91291,38	95947,73
2018-11-23	15971506	1133,4732	1886,3772	96255,008	89728,703	92991,855	92910,498	94534,39	91286,606	95947,73
2018-11-26	17273026	1133,4732	1853,9624	96277,603	89727,578	93002,59	93016,81	94581,674	91451,946	95947,73
2018-11-27	8664598,2	1128,1004	1797,3537	96219,439	90083,285	93151,362	93152,76	94598,762	91706,758	95947,73
2018-11-28	1497112,8	1128,1004	1751,5706	96061,535	90648,296	93354,915	93324,764	94706,679	91942,849	95947,73
2018-11-29	20939892	1140,7472	1731,717	95975,184	91227,133	93601,158	93518,659	94873,378	92163,94	95947,73
2018-11-30	18526245	1140,7472	1671,4765	96186,254	91318,925	93752,589	93697,497	95010,334	92384,66	95947,73
2018-12-03	-1666751	1135,4679	1684,6089	96285,243	91305,079	93795,161	93901,165	95243,092	92559,238	95947,73
2018-12-04	-22777417	1122,389	1708,5739	95968,106	91415,492	93691,799	93908,485	95348,966	92468,004	95493,3
2018-12-06	-29035685	1109,7975	1694,0501	95849,556	91344,004	93596,78	93956,658	95261,678	92651,638	95493,3
2018-12-07	-3594584	1120,2251	1643,0286	95577,387	91436,792	93507,089	94079,342	95335,283	92823,401	95416,03
2018-12-10	-3925057	1102,6245	1631,523	95591,101	91295,188	93443,144	94074,785	95356,889	92792,681	95416,03

Date	TA_17	TA_18	TA_19	TA_20	TA_21	TA_22	TA_23	TA_24	TA_25	TA_26
2018-11-12	89999,9	-728,1611	-655,9589	-72,20225	93489,564	94217,725	16,678796	0,9019387	1,1097292	0,2077904
2018-11-13	89999,9	-736,5256	-672,0722	-64,45336	93369,41	94105,935	17,030034	0,9632409	1,0430187	0,0797778
2018-11-14	89999,9	-688,5294	-675,3636	-13,1657	93356,756	94045,285	16,947719	0,9732007	1,0144341	0,0412334
2018-11-15	89999,9	-642,3068	-668,7523	26,445495	93347,538	93989,845	16,65823	1,0210349	0,9917573	0,0292776
2018-11-16	89999,9	-573,2768	-649,6572	76,380359	93388,909	93962,186	16,175511	1,0733187	0,9899928	0,0833259
2018-11-19	89999,9	-436,522	-607,0301	170,50815	93570,754	94007,276	15,517173	1,1818709	0,8803545	0,3015164
2018-11-20	89999,9	-554,5098	-596,5261	42,016242	93280,846	93835,355	16,004165	1,0729466	0,9028697	0,1700769
2018-11-21	89999,9	-559,1361	-589,0481	29,911983	93192,708	93751,844	16,456373	1,0514223	0,9822402	0,0691821
2018-11-23	89999,9	-532,8305	-577,8046	44,974104	93163,563	93696,394	16,638366	0,9746996	1,0558846	0,081185
2018-11-26	89999,9	-429,6407	-548,1718	118,53111	93286,454	93716,094	15,748879	0,9590328	1,0739423	0,1149096
2018-11-27	89999,9	-379,4275	-514,4229	134,99545	93321,916	93701,344	15,177251	0,9240914	1,1061709	0,1820795
2018-11-28	90200,71	-291,5682	-469,852	178,28381	93437,155	93728,723	14,243708	0,9387014	1,0733224	0,134621
2018-11-29	91445,28	-135,2822	-402,938	267,65585	93696,911	93832,194	13,655201	1,0084346	1,0171789	0,0087443
2018-11-30	91445,28	11,876406	-319,9751	331,85153	93961,391	93949,515	13,108729	1,084825	0,9307136	0,1541115
2018-12-03	91445,28	91,810483	-237,618	329,42849	94117,246	94025,436	13,474567	1,1416068	0,8601714	0,2814354
2018-12-04	91445,28	66,123158	-176,8698	242,99293	94080,822	94014,699	12,757216	1,0774134	0,8944927	0,1829206
2018-12-06	91445,28	-38,77173	-149,2502	110,47843	93887,971	93926,743	12,31995	0,9894539	1,0040939	0,01464
2018-12-07	91445,28	-50,93529	-129,5872	78,651901	93858,974	93909,909	11,913916	0,974496	1,00658	0,032084
2018-12-10	91445,28	-177,3227	-139,1343	-38,18844	93607,95	93785,273	12,093412	0,9132014	1,0272379	0,1140365

Date	TA_27	TA_28	TA_29	TA_30	TA_31	TA_32	TA_33	TA_34	TA_35	TA_36
2018-11-12	-0,107776	25,916206	-55,08343	-542,336	-32,87278	-26,45044	-6,422339	96695,585	92650,735	32
2018-11-13	-0,11061	25,76731	-45,61924	-3452,32	-32,49367	-28,10044	-4,393228	96417,32	92650,735	28
2018-11-14	-0,111641	25,659969	-24,50609	-3734,987	-30,7815	-28,94189	-1,839609	96417,32	92650,735	24
2018-11-15	-0,111182	25,446934	-7,44137	-3249,469	-30,89656	-29,62297	-1,27359	96417,32	92650,735	20
2018-11-16	-0,108872	25,287227	8,4548965	-870,8935	-31,62619	-30,34302	-1,28317	96417,32	92650,735	16
2018-11-19	-0,103239	24,947116	45,451333	958,9	-30,50341	-30,73763	0,2342187	96417,32	92650,735	12
2018-11-20	-0,101357	24,827958	-23,81148	2933,3775	-30,1801	-31,06865	0,8885418	95934,008	92650,735	8
2018-11-21	-0,099776	24,740254	-31,21503	1751,3695	-29,18101	-31,11613	1,9351215	96015,048	92650,735	4
2018-11-23	-0,097663	24,64446	-13,61915	2501,4445	-26,92562	-30,60676	3,6811404	96061,648	92650,735	4
2018-11-26	-0,093112	24,503181	43,148113	503,6295	-24,78855	-29,70851	4,9199671	96144,063	92650,735	4
2018-11-27	-0,087856	24,373216	21,126422	-312,152	-21,83735	-28,52448	6,6871246	96199,08	92650,735	40
2018-11-28	-0,081033	24,17041	42,083394	-1909,635	-18,49656	-27,15948	8,6629233	96689,82	92650,735	36
2018-11-29	-0,071104	24,012781	84,906509	-892,5985	-15,34827	-25,4319	10,083627	96689,82	92650,735	32
2018-11-30	-0,05877	23,878928	90,575014	-465,4295	-11,67785	-23,21541	11,537562	96222,673	92650,735	28
2018-12-03	-0,04615	23,843293	106,48536	-498,321	-8,233492	-20,74098	12,507487	96222,673	92650,735	24
2018-12-04	-0,03606	23,756337	34,952936	-75,349	-7,021854	-18,16784	11,145986	96029,343	92650,735	20
2018-12-06	-0,030218	23,640964	-40,25984	974,12	-5,523195	-15,53919	10,015999	95320,993	92650,735	16
2018-12-07	-0,025606	23,435983	-1,085639	-1820,739	-4,52163	-13,04986	8,5282319	94332,448	92650,735	12
2018-12-10	-0,025027	23,255373	-58,23211	-735,1945	-4,490973	-10,79458	6,3036027	94237,228	92650,735	8

Date	TA_37	TA_38	TA_39	TA_40	TA_41	TA_42	TA_43	TA_44	TA_45	TA_46
2018-11-12	64	-32	37,223523	45,542398	-3,923082	45,795524	37,328088	46,140389	-62,67191	-1511,314
2018-11-13	60	-32	45,34754	52,667509	-4,120104	45,95357	53,696865	46,457394	-46,30313	-1904,513
2018-11-14	56	-32	48,846025	59,436253	-4,155623	44,89321	61,193995	50,739649	-38,806	-2189,244
2018-11-15	52	-32	48,909158	60,067828	-4,185018	45,451881	61,319422	58,736761	-38,68058	-2220,13
2018-11-16	48	-32	51,203511	65,907721	-4,133761	45,808091	65,460725	62,658047	-34,53928	-1912,191
2018-11-19	44	-32	57,742385	72,561309	-3,855037	53,030136	75,569062	67,449736	-24,43094	-1447,206
2018-11-20	40	-32	39,353063	63,999284	-4,254079	45,982896	27,419961	56,149916	-72,58004	-1143,448
2018-11-21	36	-32	46,336948	64,074172	-4,360998	53,305394	28,293934	43,760986	-71,70607	-1113,134
2018-11-23	32	-28	48,321921	62,644806	-4,384414	53,019715	34,218831	29,977575	-65,78117	-1183,585
2018-11-26	28	-24	54,61294	62,629883	-4,170353	50,768749	53,460504	38,657756	-46,5395	-1095,22
2018-11-27	24	16	51,268678	63,07316	-4,07869	51,306037	46,731044	44,80346	-53,26896	-1154,899
2018-11-28	20	16	55,205572	63,028648	-3,859647	50,210296	63,840171	54,677239	-36,15983	-864,2271
2018-11-29	16	16	61,956245	70,541959	-3,401785	51,096844	90,133556	66,90159	-9,866444	-300,0803
2018-11-30	12	16	63,694991	78,223536	-2,916779	65,127676	96,972865	83,648864	-3,027135	171,29424
2018-12-03	8	16	58,967443	75,868774	-2,581276	54,725008	66,462525	84,522982	-33,53747	544,27676
2018-12-04	4	16	48,646444	68,4687	-2,536099	45,957268	44,184202	69,206531	-55,8158	845,03194
2018-12-06	4	12	40,727695	61,67914	-2,745765	41,913197	24,252219	44,966316	-75,74778	810,31576
2018-12-07	32	-20	48,706231	60,960034	-2,715217	44,852272	40,758748	36,39839	-59,24125	701,26226
2018-12-10	28	-20	38,589682	55,828343	-3,040928	40,148328	12,897689	25,969552	-87,10231	431,26997

Date	Dolar	Petrol	ETF	SP500
2018-11-12	5,47132	70,12	24,13	2726,22
2018-11-13	5,47797	65,47	24,42	2722,18
2018-11-14	5,46426	66,12	24,68	2701,58
2018-11-15	5,36467	66,62	25,33	2730,2
2018-11-16	5,33417	66,76	25,47	2736,27
2018-11-19	5,31751	66,79	25,53	2690,73
2018-11-20	5,38182	62,53	24,3	2641,89
2018-11-21	5,31806	63,48	25,16	2649,93
2018-11-23	5,28735	58,8	25,32	2632,56
2018-11-26	5,25554	60,56	25,75	2673,45
2018-11-27	5,26307	60,4	25,69	2682,17
2018-11-28	5,22362	59,09	26,37	2743,79
2018-11-29	5,17498	59,91	26,54	2737,76
2018-11-30	5,22475	59,46	26,26	2760,17
2018-12-03	5,248	61,69	26,08	2790,37
2018-12-04	5,38867	62,08	24,78	2700,06
2018-12-06	5,34145	60,06	25,32	2695,95
2018-12-07	5,30071	61,67	25,11	2633,08
2018-12-10	5,32659	59,97	24,72	2637,72

ÖZGEÇMİŞ

AdıSoyadı : Zübeyir AKTÜRK

DoğumYeri: Kdz. Ereğli

DoğumTarihi: 04.12.1985

Yabancı Dili : İngilizce

Eğitim Durumu

Lise : Kdz. Ereğli Anadolu Lisesi (2003)

Lisans : Orta Doğu Teknik Üniversitesi Mühendislik Fakültesi Bilgisayar Mühendisliği (2009)

Çalıştığı Kurum/Yıl

Scan Associates Berhad, Kuala Lumpur, Malezya, Stajer Bilgisayar Mühendisi, 07/2007-09/2007

Federal Elektrik, İstanbul, Türkiye, Yazılım Mühendisi, 06/2008-09/2009

Orta Karadeniz Kalkınma Ajansı (OKA), Samsun, Türkiye, Uzman, 09/2009-Halen