

T.C.
GEBZE TEKNİK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

TEMEL VE TEKNİK ANALİZE DAYALI MAKİNE ÖĞRENMESİ
İLE HİSSE SENEDİ FİYAT TAHMİNİ:
RASTGELE ORMAN SINIFLANDIRMASI YAKLAŞIMI

DENİZ KAVUK SALIŞ

YÜKSEK LİSANS TEZİ
ENDÜSTRİ MÜHENDİSLİĞİ ANABİLİM DALI

DANIŞMAN: DR. ÖĞR. ÜYESİ A. BURAK PAÇ

TEMMUZ 2024

T.R.
GEBZE TECHNICAL UNIVERSITY
GRADUATE SCHOOL

**STOCK PRICE PREDICTION WITH MACHINE
LEARNING BASED ON FUNDAMENTAL AND
TECHNICAL ANALYSIS: RANDOM FOREST
CLASSIFICATION APPROACH**

DENİZ KAVUK SALIŞ

**A THESIS OF MASTER OF SCIENCE
INDUSTRIAL ENGINEERING DEPARTMENT**

ADVISOR: DR. LECTURER MEMBER A. BURAK PAÇ

JULY 2024

YÜKSEKLİSANS JÜRİ ONAY FORMU

GTÜ Lisansüstü Eğitim Enstitüsü Yönetim Kurulunun 08/07/2024 tarih ve 2024/35 sayılı kararıyla oluşturulan jüri tarafından 16/07/2024 tarihinde tez savunma sınavı yapılan Deniz KAVUK SALIŞ'ın tez çalışması Endüstri Mühendisliği Anabilim Dalında YÜKSEK LİSANS tezi olarak kabul edilmiştir.

JÜRİ

ÜYE

(TEZ DANIŞMANI) : Dr. Öğr. Üyesi A. Burak PAÇ

ÜYE

: Dr. Öğr. Üyesi Suat GENÇ

ÜYE

: Prof. Dr. Mehmet Murat FADİLOĞLU

ONAY

Gebze Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü Yönetim Kurulunun

...../...../..... tarih ve/..... sayılı kararı.

İMZA/MÜHÜR

İthaf:

Canım Aileme

ve

Sevgili Eşime



ÖZET

Son yıllarda ülkemizde borsaya olan ilgi artmaktadır. Bu durum, bilimsel temelden yoksun yatırım tavsiyelerinin ve bilgi kirliliğinin artmasına neden olmuştur. Hisse senedi fiyat tahmini gibi karmaşık problemler için bilimsel yaklaşımlar önem kazanmıştır ve bu yaklaşımlar arasında makine öğrenmesi yöntemleri geniş yer tutmaktadır.

Geliştirilen modellerde genellikle ekonomi, döviz kurları, haber verileri gibi faktörler ile temel analiz veya teknik analiz göstergelerinden bir grup kullanılmaktadır. Ancak, bu iki gösterge türünün bir arada kullanıldığı çalışmalar nadirdir. Teknik analiz göstergeleri yatırımcının güncel tutumunu, temel analiz göstergeleri ise şirketin finansal durumunu yansıtarak yatırım kararlarını destekler.

Bu çalışmada, teknik analiz göstergeleri ve temel analiz verilerinin bileşkesi bir veri seti olarak kullanılmıştır. BIST30’da yer alan 23 şirketin 45 dönemlik bilanço verileri ve geçmiş hisse senedi fiyatları analiz edilmiştir. Makine öğrenmesi yöntemlerinden Rastgele Orman Algoritması kullanılarak, şirketlerinin hisse senedi günlük kapanış fiyatları için en uygun yöntemler o gün için önerilmiştir. Hisselerin günlük fiyatları ve bunlara dayalı olarak hesaplanan trend, salınım ve oynaklık göstergeleri; dönen varlıkların kısa vadeli yabancı kaynaklara oranı, nakit ve nakit benzerlerinin kısa vadeli yabancı kaynaklara oranı, net satışların özsermayeye oranı, net karın özsermayeye oranı gibi temel analiz verileri ile birleştirilmiştir.

Öznitelik seçimi ve Rastgele Orman (RO) sınıflandırıcı parametrelerinin optimizasyonu için sinir ağı entegrasyonu incelenmiştir. Özellik seçimi için hiyerarşik kümeleme, Varyans Şişirme Faktörü (VIF) azaltma ve seçici özellik eleme yöntemleri kullanılmıştır. Rastgele Orman Sınıflandırıcısı ile yapılan tahminlerde, model performansını artırmak için üç katmanlı bir özellik eleme çerçevesi uygulanmıştır. Genetik Algoritma (GA) çerçevesinde, sinir ağları kullanılarak farklı öznitelik seçim stratejilerinin ve RO sınıflandırıcı parametrelerinin etkinliği tahmin edilmiştir. En düşük ortalama karesel hatayı (MSE) sergileyen model, en uygun model olarak belirlenmiştir. Hisse senetleri arasındaki veriler birleştirilerek, tahmin edicilerin performansı analiz edilmiştir.

Bu çalışma, makine öğrenmesi kullanarak hisse senedi kapanış fiyatı tahminleme alanında literatüre katkı sağlamayı ve yatırımcıların yatırım kararları konusunda yardımcı bir kaynak oluşturmayı amaçlamaktadır.

Anahtar Kelimeler: Hisse Senedi Tahmini, Temel Analiz, Teknik Analiz Göstergeleri, Makine Öğrenmesi, Rastgele Orman Algoritması, Genetik Algoritma, Yapay Sinir Ağları.

ABSTRACT

In recent years, interest in the stock market has been increasing in our country. This has led to a rise in investment advice that lacks scientific basis and an increase in information pollution for investors. Scientific approaches have become important for complex problems such as stock price prediction, and among these approaches, machine learning methods hold a significant place.

Developed models generally use factors such as economy, exchange rates, news data, and a group of indicators from fundamental or technical analysis. However, studies that use both types of indicators together are rare. Technical analysis indicators reflect the current attitude of investors in the stock market, while fundamental analysis indicators provide information about the financial status of the company and support investment decisions.

In this study, a dataset combining technical analysis indicators and fundamental analysis data is used. The balance sheet data of 23 companies in the BIST30 index over 45 periods and their past stock prices were analyzed. Using the Random Forest Algorithm, one of the machine learning methods, the most suitable methods for predicting the daily closing prices of these companies' stocks were suggested. The daily prices of the stocks and the trend, oscillation, and volatility indicators calculated based on these prices were combined with fundamental analysis data such as the ratio of current assets to short-term liabilities, the ratio of cash and cash equivalents to short-term liabilities, the ratio of net sales to equity, and the ratio of net profit to equity.

The integration of neural networks for feature selection and optimization of Random Forest (RO) classifier parameters was examined. Hierarchical clustering, Variance Inflation Factor (VIF) reduction, and selective feature elimination methods were used for feature selection. In the predictions made with the Random Forest Classifier, a three-layer feature elimination framework was applied to improve model performance. Within the framework of Genetic Algorithm (GA), neural networks were used to estimate the effectiveness of different feature selection strategies and RO classifier parameters. The model with the lowest mean squared error (MSE) was determined as the most suitable model. The performance of the predictors was analyzed by combining the data among the stocks.

This study aims to contribute to the literature in the field of stock closing price prediction using machine learning and to provide a helpful resource for investors in making investment decisions.

Keywords: Stock Price Prediction, Fundamental Analysis, Technical Analysis Indicators, Machine Learning, Random Forest Algorithm, Genetic Algorithm, Artificial Neural Networks.

TEŞEKKÜR

Tez çalışmam boyunca her türlü desteğini üzerimden hiç eksik etmeyen, çalışmalarımı her daim takdir eden sayın tez hocam Dr. Öğretim Üyesi A. Burak PAÇ' a teşekkür ederim.

Benimle her zaman gurur duyan, desteklerini her zaman yanımda hissettiğim değerli aileme; annem Sevilay KAVUK, babam Şaban KAVUK ve kardeşim Ece KAVUK' a teşekkür ederim. Ayrıca tüm lisansüstü öğretim sürecimin zorluklarıyla başa çıkmam konusunda bana her zaman destek olan ve motivasyon kaynağım olan sevgili eşim Muhammed SALIŞ' a sonsuz teşekkür ederim.



İÇİNDEKİLER

	<u>Sayfa</u>
ÖZET	i
ABSTRACT	ii
TEŞEKKÜR	iii
İÇİNDEKİLER	iv
SİMGELER ve KISALTMALAR DİZİNİ	vi
ŞEKİLLER DİZİNİ	viii
TABLolar DİZİNİ	ix
1. GİRİŞ	1
1.1. Literatür Özeti, Tezin Amacı, Katkısı ve İçeriği	2
2. FİNANSAL PİYASALAR	7
2.1. Hisse Senetleri	8
2.1.1. Hisse Senedi Fiyat Tanımlamaları	9
2.1.2. Hisse Senedi Değer Tanımlamaları	9
2.2. Hisse Senetlerinin Analiz Yöntemleri	10
2.2.1. Temel Analiz	10
2.2.2. Teknik Analiz	11
2.2.2.1. Trend İndikatörleri ve Osilatörler	12
3. MAKİNE ÖĞRENMESİ	15
3.1. Makine Öğrenmesi Yöntemleri	15
3.1.1. Denetimli Öğrenme	16
3.1.2. Denetimsiz Öğrenme	16
3.1.3. Pekiştirmeli Öğrenme	17
3.2. Makine Öğrenmesi Algoritmaları	18
3.2.1. Rastgele Orman Algoritması (RO)	18
3.2.2. Destek Vektör Makineleri (SVM)	20
3.2.3. Uzun Kısa Süreli Bellek (LSTM)	21
3.2.4. Yapay Sinir Ağları (ANN / YSA)	21
3.2.5. Çok Katmanlı Algılayıcı (MLP)	22
4. UYGULAMA MODELİ VE BULGULAR	23
4.1. Çalışmanın Amacı ve Kapsamı	23
4.2. Çalışma Verileri	23
4.3. Verilerin Temizlenmesi ve Düzenlenmesi	24
4.4. Rastgele Orman Sınıflandırma Uygulaması	25
4.4.1. Tahminçiler için Eleme	25
4.4.2. Öznitelik Eleme Yöntemleri	32
4.4.3. Öznitelik Seçimi ve RO Optimizasyonu için YSA Entegrasyonu	35
5. SONUÇ VE DEĞERLENDİRME	42
KAYNAKLAR	44
ÖZGEÇMİŞ	49

TEZ ÇALIŞMASI KAPSAMINDA YAPILAN YAYINLAR	50
EKLER	51



SİMGELER ve KISALTMALAR DİZİNİ

ADX	: Göreceli Yönlü Endeks
ANN /YSA	: Yapay Sinir Ağları
ATR	: Ortalama Gerçek Aralık
BB	: Bollinger Bantları
BİST30	: Borsa İstanbul Ulusal 30 Endeksi
CMF	: Chaikin Para Akışı
CNN	: Evrişimli Sinir Ağı
DT	: Karar Ağacı
ELSTM	: Gömme Uzun Kısa Dönem Bellek
EMA	: Üstel Hareketli Ortalama
ETF	: Borsa Yatırım Fonu
FS	: Feature Selection/ Özellik Seçimi
FTSE	: Financial Times Borsa Endeksi
GA	: Genetik Algoritma
GB	: Gradient Boosting
GRU	: Gated Recurrent Units
KAMA	: Kaufman Uyumlu Hareketli Ortalama
KNN	: K-Nearest Neighbors
LDA	: Lineer Diskriminant Analizi
LP	: Doğrusal Ekstrapolasyon
LR	: Lineer Regresyon
LSTM	: Uzun Kısa Süreli Bellek
MA	: Hareketli Ortalama
MACD	: Hareketli Ortalamaların Yakınsama Sapması
MAE	: Ortalama Mutlak Hata
MFI	: Para Akışı Endeksi
MLP	: Çok Katmanlı Algılayıcı
MSCI	: Morgan Stanley Capital International
MSE	: Hataların Karesinin Ortalaması
NB	: Naive Bayes
OBV	: Dengeleme Hacmi
O-LSTM	: Ortogonal Uzun Kısa Dönem Bellek
OOB	: Out of Bag
PSO	: Parçacık Sürü Optimizasyonu
QP	: Kuadratik Ekstrapolasyon
ReLU	: Rectified Linear Unit/ Düzeltilmiş Doğrusal Birim
RFE	: Yinelemeli Özellik Eleme
RO / RF	: Rastgele Orman
STO	: Stokastik Osilatör
SVM	: Destek Vektör Makineleri
SVR	: Destek Vektör Regresyonu

tanh	: Hiperbolik Tanjant
VIF	: Varyans Şişirme Faktörü
VRNN	: Varyasyonel Tekrarlayan Sinir Ağı
XGBoost	: Aşırı Gradyan Artırma
YD	: Yüksek ve Düşük Fiyat Ortalaması
YDAS	: Yüksek, Düşük, Açılış ve Kapanış Fiyatı Ortalaması
YDS	: Yüksek, Düşük ve Kapanış Fiyatı Ortalaması



ŞEKİLLER DİZİNİ

	<u>Sayfa</u>
Şekil 3.1: Makine öğrenmesi türleri.	15
Şekil 3.2: Denetimli öğrenme akış şeması.	16
Şekil 3.3: Denetimsiz öğrenme akış şeması.	17
Şekil 3.4: Pekiştirmeli öğrenme akış şeması.	18
Şekil 3.5: Rastgele orman algoritması karar ağaçları modeli.	19
Şekil 3.6: Optimal ayrıştırıcı düzlem, marj, destek vektörler.	21
Şekil 3.7: YSA modeli akışı.	22
Şekil 3.8: Çok katmanlı algılayıcı modeli.	22
Şekil 4.1: Tahmincilerin ortalama sırasına karşılık en iyi tahmin sayıları.	27
Şekil 4.2: Özellik kümeleme dendrogramı.	29



TABLÖLER DİZİNİ

	<u>Sayfa</u>
Tablo 1.1: Makine öğrenmesi literatür araştırması.	3
Tablo 1.2: Türkiye' de gerçekleşen makine öğrenmesi çalışmaları.	5
Tablo 2.1: Para piyasası araçları.	7
Tablo 2.2: Sermaye piyasası araçları.	8
Tablo 2.3: Şirket analizi mali oranları.	11
Tablo 4.1: Bist30'daki çalışma grubu şirketleri.	24
Tablo 4.2: Tahmin edici sıralama dağılımı.	26
Tablo 4.3: YSA yaklaşılması ve genetik-parçacık eniyilemesine dayalı her hisse için seçilen yaklaşık en iyi öznelilik seçimi ve RO parametre tercihleri.	31
Tablo 4.4: Özellik seçimi ve rastgele orman sınıflandırma parametreleri.	34
Tablo 4.5: Konfigürasyon parametre seti.	37
Tablo 4.6: Yapay sinir ağı modellerinin farklı parametre seçimleriyle RO doğruluğunu tahmin performansı.	38
Tablo 4.7: Hibrit genetik-parçacık sürüsü optimizasyon algoritması.	41
Ek-A: Hisseye göre tahmin metodu sıralaması.	51

1. GİRİŞ

Günümüz dünyasında yatırımcılar farklı yatırım araçlarıyla varlıklarını yönetmektedir. Bu yatırım araçlarından biri de hisse senedir. Hisse senedi yatırımcıların bir şirkete ortaklığını sağlayabilmesi adına piyasalarda yer alan kıymetli kağıtlardır. Hisse senetlerinin fiyatları günlük ve hatta anlık değişen bir yapıya sahiptir. Bu değişken yapının tahmini için birçok veri tipi ve yöntem kullanılmaktadır. Hisse senedi fiyat tahminlerinde teknik analiz göstergeleri, temel analiz göstergeleri, haberler vb. veriler kullanılmaktadır. Tahmin yöntemi olarak geleneksel yöntemlerin beraberinde teknolojinin gelişmesiyle birlikte yenilikçi yöntemler de uygulanmaktadır.

Bu tez çalışması, BIST 30 endeksinde yer alan şirketlerin hisse senedi fiyatlarını tahmin etmek amacıyla Rastgele Orman (RO) Algoritması kullanarak hem temel hem de teknik göstergeleri bir araya getirmeyi hedeflemektedir. Wiranata ve Djunaidy'nin (2021) belirttiği gibi, literatürde hem temel hem de teknik göstergelerin birlikte kullanıldığı çalışmaların sayısının artmasına katkı sağlamak amaçlanmaktadır. Ayrıca RO sınıflandırması ile birden fazla tahmin edici yöntemin her şirketin günlük hisse fiyatı tahmini sağlanması ve en iyi tahmin yönteminin gün bazlı seçimi ile hibrit bir model oluşturulması amaçlanmaktadır.

Temel amaç, Borsa İstanbul Ulusal 30 Endeksi'nde (BIST30) yer alan şirketlerin hisse senedi tahmini için hızlı ve güvenilir bir makine öğrenmesi yöntemi olan Rastgele Orman Algoritmasını kullanarak en uygun modeli araştırmaktır.

En uygun modelin belirlenmesi için, Rastgele Orman Sınıflandırıcısı ile yapılan tahminlerde model performansını artırmak amacıyla üç katmanlı bir özellik eleme yöntemi uygulanmıştır. Bu süreçte, hibrit bir algoritma kullanılarak Genetik Algoritmalar ve Parçacık Sürüsü Optimizasyonu (PSO) ilkeleri entegre edilmiştir. Genetik Algoritma (GA) çerçevesinde, sinir ağları kullanılarak farklı öznelik seçim stratejilerinin ve RO sınıflandırıcı parametrelerinin etkinliği değerlendirilmiştir.

Bu tez çalışmasında birinci bölümde literatür özeti, tezin amacı, katkısı ve içeriğine yer verilmektedir. İkinci bölümde finansal piyasalar, hisse senedi, hisse senetleri analiz yöntemleri anlatılmıştır. Üçüncü bölümde Makine Öğrenmesi, Makine Öğrenmesi Algoritmaları ve Rastgele Orman Algoritması anlatılmıştır. Dördüncü bölümde,

geliştirilen model, veriler, tez uygulaması ve değerlendirme yöntemleri anlatılmıştır. Beşinci bölümde ise sonuçlar ve önerilere yer verilmiştir.

1.1. Literatür Özeti, Tezin Amacı, Katkısı ve İçeriği

Hisse senedi fiyat tahmini uzun yıllar boyunca literatürde çalışmaları yapılmış karmaşık yapılı ve birden çok değişkeni olan bir problemdir. Teknolojinin getirdiği faydalar ile hisse senedi tahmini probleminin çözümü araştırılmaktadır. Makine öğrenmesi yöntemi de bu probleme çözüm aramada kullanılan son zamanlardaki popüler yöntemdir ve hisse senedi üzerine çalışmalar birçok araştırmacının ilgilendiği çalışma konusudur.

Wiranata ve Djunaidy'in (2021) gerçekleştirmiş olduğu sistematik literatür araştırması literatür çerçevesini daha iyi anlamakta yardımcı olmaktadır. Literatür araştırmalarında 2015' den 2020 yılına kadar geçen sürede yapılan 81 adet çalışmayı incelemişlerdir ve yine çalışmalarında 2019 yılında araştırmaların ivme kazandığını belirtirler.

Veri setlerinin tahmini veya regresyonu, kümeleme, ilişkilendirme, sınıflandırma ve ön işleme analizi, hisse senedi tahmini araştırmasının ana odaklarıdır. Sınıflandırma yöntemi, ilgili çalışmalardan %35.80 pay alırken, tahmin yöntemi %56.79, veri analitiği %4.94, geri kalanı ise kümeleme ve ilişkilendirme yöntemleridir. Bu tür girdi veri setleri için araştırmaların %74.07'si teknik gösterge veri setleri kullanırken, %12.35 araştırma çalışması teknik göstergeler ve haber verilerinin bir kombinasyonunu kullanır ve üçüncü sırada %6.17 oranında teknik göstergeler ve temel verilerin bir kombinasyonunu kullanır.

Yine çalışmalarında belirttiklerine göre;

Hisse senedi tahmini modeli geliştirmek için 48 farklı yöntem uygulanmıştır ve en yaygın olarak uygulanan 9 yöntem belirlenmiştir. Bunlar YSA, LSTM, CNN, MLP, LR, RF, SVM, KNN ve NB'dir. Her bir yöntem bireysel olarak incelendiğinde hangi yöntemin en iyi olduğuna dair kesin bir görüş birliği yoktur.

Bir diğer literatür araştırmasını da Al-Alawi ve Alaali (2023) tarafından yapılmıştır. Araştırmalarında farklı sektörler için yapılmış toplamda 12 çalışmayı incelemişler ve tablo haline getirmişlerdir. Tablo 1.1'de Al-Alawi ve Alaali'nin oluşturmuş olduğu çalışma incelemeleri yer almaktadır. Dört ayrı sektör için yapılmış 12 adet incelendiğinde sadece bir modelin doğruluğu kararına varmak mümkün değildir.

Her modelin kendi içerisinde en iyi sonuçları veren araştırma yöntemi bulunmaktadır. Oluşturulan modellerin kullanıldığı sektörler, veri setleri, girdi verileri her yapılan çalışmada farklı çıkarımlara sebep olabilir.

Tablo 1.1: Makine öğrenmesi literatür araştırması.

Araştırmacılar	Sektör	Veri seti	Girdi Verileri	Modeller	Anahtar Bulgular
Subasi vd. (2021)	Piyasa Endeksleri	New York Menkul Kıymetler Borsası, Nikkei, NASDAQ ve FTSE	Hacim, günlük kapanış, açılış, yüksek, düşük ve düzeltilmiş kapanış fiyatları.	ANN, KNN, SVM, DT, RO, Bagging, ve AdaBoost	SVM en iyi sonuçları sağlar.
Nikou vd. (2019)		iShares MSCI United Kingdom ETF	Günlük kapanış fiyatları	LSTM, ANN, SVM ve RO.	LSTM en iyi sonuçları sağlar.
Vijh vd. (2020)	Belirli Hisse Senetleri	Beş hisse senedi: Goldman'ın Sachs, Pfizer, Nike, J& J ve Jpmorgan'ın Chase & co.	Günlük açılış, kapanış, yüksek ve düşük fiyatlar kullanılarak altı yeni değişken oluşturuldu.	ANN ve RO.	ANN en iyi sonuçları sağlar.
Moghar ve Hamiche (2020)		İki hisse senedi: Nike ve Google	Günlük açılış fiyatı	LSTM, ANN, SVM ve RO.	Zaman serisi verilerinin uzunluğu ve eğitim dönemlerinin sayısı tahmin sonuçlarını etkiler.
Jin vd. (2020)		Apple Inc.	Hacim, günlük kapanış, açılış, yüksek ve düşük fiyatları.	LSTM ve duyarlılık analizi	Duyarlılık analizi ve dikkat aracıyla LSTM en iyi sonuçları sağlar.
Biswas vd. (2021)		Dakka Borsası'ndan Hisse Senedi		LSTM, XGBoost, LR, MA, ve Son Değer Algoritması	LSTM en iyi sonuçları sağlar.

(Tablo devamı)

Araştırmacılar	Sektör	Veri seti	Girdi Verileri	Modeller	Anahtar Bulgular
Naik ve Mohan (2019)	Bankacılık	ICICI Bank ve State Bank of India.	Mevcut teknik göstergelerden 33 farklı değişken oluşturulmuştur.	ANN	Özellik seçimi daha iyi sonuçlar sağlar.
Agrawal vd. (2019)		Yes Bank, HDFC, ve SBI.	Hacim, günlük kapanış, açılış, yüksek ve düşük fiyatlar.	O-LSTM, ELSTM, SVM, ve LR.	O-LSTM en iyi sonuçları sağlar.
Saud ve Shakya (2020)		Nepal Investment Bank ve Nabil Bank Limited.		LSTM, GRU, ve VRNN	GRU ve LSTM en iyi sonuçları sağlar.
Shynkevich vd. (2016)	Sağlık Sektörü	28 adet S&P500 firması	Hisse senetlerinin geçmiş fiyatları ve haber makaleleri	SVM ve KNN	Her iki algoritma da daha fazla sayıda haber kategorisiyle daha iyi sonuçlar sağlar.
Ahmed vd. (2022)		Hindistan NSE'de yer alan sağlık firmaları	Twitter haberleri ve günlük açılış ve kapanış fiyatları.	GRU, SVM, LR, ve RF.	GRU en iyi sonuçları sağlar. Ve duyarlılık analizi, tahmin doğruluğunu artırır.
Jariyapan vd. (2022)		Nasdaq'ta yer alan 5 firma	Google trendler ve hisse senetlerinin geçmiş fiyatları.	LDA, KNN, ve SVM.	LDA, piyasa rejimlerini tahmin etmede en iyi sonuçları sağlar

Kaynak: [Al-Alawi ve Alaali, 2023]

Türkiye’de yapılan makine öğrenmesinden faydalanan çalışmalarda mevcuttur. İstanbul Borsasında işlem gören şirketler için yapılan örnek çalışmalar Tablo 1.2’ de verilmiştir. Çalışmalar incelendiğinde hem teknik hem de temel göstergelerin kullanıldığı çeşitli çalışmalar bulunmaktadır. Yine ortak bir yöntemin en iyi sonuç

verdiğini söylemek mümkün değildir. Türkiye genelinde çalışmalar 2021 yılı itibariyle de hız kazandığı söylenebilir.

Tablo 1.2: Türkiye' de gerçekleşen makine öğrenmesi çalışmaları.

Araştırmacılar	Veri seti	Girdi Verileri	Modeller	Anahtar Bulgular
Gündüz vd. (2017)	Garanti Bankası, Türk Hava Yolları ve İş Bankası	Günlük açılış, kapanış, en yüksek, en düşük fiyat verileri, günlük ortalama fiyat, teknik göstergeler ile dolar ve altın fiyatı	Evrişimsel Sinir Ağı	Fiyat öznitelikleri, dolar-altın öznitelikleri veya her iki öznitelikler kullanıldığında doğru tahmin oranı her hisse için farklılık göstermektedir.
Raço (2019)	BİST endeksi 30	Günlük açılış, kapanış, en yüksek, en düşük fiyat ve işlem hacmi, teknik göstergeler	Derin Sinir Ağı, SVR ve ANN	Derin sinir ağı en iyi sonucu vermiştir.
Eliaçık ve Erdoğan (2015)	Bist endeksi 100	Haftalık borsa verileri, Twitter yorumları	Korelasyon analizi	Fiyatlar ile yorumlar arasında 0,2283 korelasyon katsayısına sahip hassas bir ilişki bulunmaktadır.
Ceyhan vd. (2018)	Bitcoin	Metin veri madenciliği, teknik indikatörler, birleştirilen veri seti	Lojistik regresyon, destek vektör makineleri, yapay sinir ağı, adaboost, Rastgele Orman (RF)	Birleştirilen veri setinin adaboost modelinde oldukça başarılı performans göstermiştir.
Altunbaş (2021)	XBANK Banka endeksi	Günlük kapanış, açılış, en yüksek, en düşük değerler, çeşitli teknik göstergeler, çeşitli makroekonomik değişkenler ve metinsel veriler	Boruta algoritması ve hiper parametre optimizasyonu	Siyasi gerginliklerin olduğu dönemlerde metinsel verilerden oluşturulmuş modeller, olmadığı dönemlerde ise finansal ve metinsel verilerin birlikte oluşturduğu model daha başarılı sonuçlar vermektedir.
Arslankaya ve Toprak (2021)	Ereğli Demir ve Çelik Fabrikaları	Hisse kapanış fiyatı	Polinom Regresyon, Random Forest Regresyon, RNN ve LSTM	Modellerin hata değerlerine göre başarı sırası; Random Forest Regresyon modeli, LSTM modeli, RNN modeli ve Polinom Regresyon modeli olduğu görülmektedir.
Koç Ustalı vd (2021)	Bist 30 firmaları	Üç aylık finansal tablo verileri ve aylık kapanış fiyatları	Yapay Sinir Ağları (YSA), Rastgele Orman (RF) algoritması ve XGBoost	Tahminlemede XGBoost algoritması, RO algoritmasından daha iyi sonuç göstermiş, YSA ise bunların gerisindedir.

Ulusal ve uluslararası hisse senedi tahminleme alıřmaları incelendiėinde makine renmesi son zamanlarda popler olan bir yntem haline gelmiřtir. Her arařtırmacının alıřmıř olduėu ekosistem ve dinamikler birbirinden farklı olması sebebiyle ortak bir yntem belirlenememektedir. Bu alıřmada Wiranata ve Djunaidy'in ifade ettiėi teknik gsterge ve temel gstergelerin bir arada alıřıldıėı bir veri grubu zerine alıřarak literatrde az yer kaplayan bir alıřma grubuna katkı saėlamak amalanmaktadır. Beraberinde birbirinden farklı yntemlerin aynı anda kullanılıp RO ile analiz edildiėi ve her hisse senedi iin o gn hangi en uygun tahmin yntemi kullanılacaėı kararının verildiėi bir hibrit alıřma modeli oluřturulmaktadır.



2. FİNANSAL PİYASALAR

Piyasa, kişilerin alıcı ve satıcı kimliğiyle bir araya gelerek karşılıklı mal ve hizmet değişiminin sağlandığı yerdir. Finansal özellik taşıyan araçların bu alışverişinin gerçekleştiği yapıya finansal piyasa denir. Finansal piyasalar global ve ulusal ekonomik sistemin önemli bir parçasıdır ve amaçlarına göre sermaye piyasası ve para piyasası olarak iki piyasa özelliğine ayrılır. “Para piyasası, hazine bonoları, devlet tahvilleri, finansman bonoları, ticari senetler, banka kredileri gibi bir günden bir yıla kadar olan fonların yani kısa vadeli kredi araçlarının kullanıldığı piyasadır.” [Civan, 2007] Para piyasasının en önemli kurumu ticari bankalardır ve ticari bankaların beraberinde hazine, çeşitli finansman kurumları, bankerler ve büyük şirketler de bu piyasanın kurumlarıdır. Tablo 2.1’de para piyasaları araçlarının ve bunları ihraç edenlerin bir listesi bulunmaktadır.

Tablo 2.1: Para piyasası araçları.

Araçlar	İhraç Eden
Hazine Bonoları	Hükümetler
Mevduat Sertifikaları	Bankalar ve Tasarruf Kuruluşları
Finansman Bonosu	Bankalar, Finansman Şirketleri ve Diğer Şirketler
Eurodolar Mevduat	Uluslararası Bankalar
Kabul Kredisi	Bankalar
Merkez Bankası Fonları (Bankalararası Piyasa)	Mevduat Kurumları
Repo Sözleşmeleri	Firmalar ve Finansal Kuruluşlar

Kaynak: [Günel, 2007]

Sermaye piyasası, uzun ve orta vadeli fonların belli oranda getirisi sağlayan ve arz ve talebin karşılandığı piyasalardır. Sermaye piyasasında fonlar hisse senedi, tahvil vb finansal varlıklar ile takas edilir.

Sermaye piyasasını yasal bir zemine oturtmak için 1981 yılında Sermaye Piyasası Kanunu çıkartılmış ve beraberinde işleyiş kuralları belirlenmiş, şeffaf, yatırımcıya güven veren bir ortam yaratılmıştır.

Sermaye piyasasının en önemli aracı, borsada işlem yapan şirketlerin belirli oranda ortak payın olduğunu gösteren hisse senedidir. Hisse senetleri son dönemde değişen ekonomik ortamda toplumun her kesiminden ve yaş aralığından olan yatırımcıların dikkatini çekmektedir. Şirketlerle olan bu ortaklık durumunda şirketin değerinin artmasıyla hisse senedi değeri artar ve düşmesine paralel olarak da hisse seneti değersizleşir. Şirketlerin kâr etmesi durumunda da belirli dönemlerde hisse ortaklarına temettü dağıtılır.

Hisse senedinin beraberinde diğer sermaye piyasası araçları bulunmaktadır. Sermaye piyasası başlıca araçları, ihraç edenler ve vadeleri Tablo 2.2’de verilmiştir.

Tablo 2.2: Sermaye piyasası araçları.

Araçlar	İhraç Eden	Vade
Devlet Tahvilleri	Hükümetler	1-30 yıl
Belediye Tahvilleri	Belediyeler	10-30 yıl
Şirket Tahvilleri	Şirketler	10-30 yıl
İpotek Senetleri	Bireyler ve Şirketler	15-30 yıl
Hisse Senetleri	Şirketler	-

Kaynak: [Günel, 2007]

2.1. Hisse Senetleri

Hisse senedi kavramının birçok araştırmacı tarafından tanımı yapılmıştır. Apak’a göre geniş ve bilimsel tanımları şöyledir.

Hisse senedi, sermayesi paylara bölünmüş ve karşılığında kıymetli evrak niteliğinde hisse senedi çıkarabilen Anonim ortaklık veya sermaye paylara bölünmüş Komandit ortaklıkların kanuni

şekillere uygun olarak düzenledikleri belgeler olup, sermayesinin belirli bir oranını temsil eden sahiplerine o oranda ortaklık hakkı sağlayan senetlerdir.

Özetle Finansal Piyasalar bölümünde de bahsedildiği gibi hisse senedi borsada işlem gören bir şirkete belirli oranlarda ortak olunduğunu kanıtlayan kıymetli evraktır.

Bir yatırımcı hisse senedi olarak şirketin belirli bir oranında ortağı olduğunda; kardan pay alma hakkı, şirketin yönetimine katılma ve oy kullanma hakkı, rüçhan hakkı, tasfiyeden pay alma hakkı, bilgi edinme hakkına sahip olmaktadır.

2.1.1. Hisse Senedi Fiyat Tanımlamaları

Hisse senedi fiyat tanımlamaları aşağıdaki gibidir.

Nominal fiyat: “Bir hisse senedinin nominal fiyatı üzerinde yazılı olan ve muhasebe kayıtlarına geçirilen değerdir. İtibari değer, yazılı değer, kayıtlı değer, saymaca değer veya başa baş değer olarak da adlandırılmaktadır.” [Dağlı, 2009]

İhraç (Emisyon) fiyatı: Bir şirketin yeni çıkarılan hisse senetlerinin ilk kez yatırımcılara sunulduğu fiyattır. İhraç fiyatının belirlenmesinde hisse senetlerinin nominal değeri rol oynar ve yatırımcılar için önemli bir karar verme kaynağıdır.

Piyasa fiyatı: Yatırımcıların alım ve satım işlemlerini gerçekleştirdiği fiyattır. Piyasa fiyatının dinamik bir yapısı vardır ve dalgalanmalar yaşamaktadır.

Borsa fiyatı: Borsada işlem görmeye başlayan hisse senetlerinin borsadaki arz ve talep koşullarına göre oluşan fiyatlarıdır. “Borsanın işleyişine göre fiyatlar günlük olarak belirlenmekte ve en yüksek, ortalama, günlük fiyat gibi türlere ayrılmaktadır.” [Demirel, 2019]

2.1.2. Hisse Senedi Değer Tanımlamaları

Hisse senetlerinin değer tanımlamaları, bir hisse senedi için yapılan verimlilik belirleme çalışmalarında kullanılan ve ölçümlerde ve analizlerde ele alınan tanımlamalardır. Bu tanımlar aşağıda verilmiştir:

Defter değeri: “Bir şirketin öz sermaye toplamının varsa birikmiş zararlar düşüldükten sonra bulunan miktarın hisse senedi sayısına bölünmesiyle bulunan değerdir.” [Bozkurt, 1988]. Bir hisse senedinin defter değeri, piyasa değerinden genel olarak daha düşüktür.

Net aktif değeri: Hisse senedinin genellikle bir yıl sonunda veya bir faaliyet dönemi sonunda düzenlenen bilançoadaki net aktif tutarıdır.

Özsermaye değeri: Şirket öz sermayesinin ödenmiş sermayeye göre hisse senedi adetine bölünmesiyle hesaplanan değerdir.

Tasfiye değeri: “Şirketin iktisadi varlıklarının belirli bir süre içinde zorunlu olarak teker teker satışı ile sağlanabilecek değerden tüm borçlar ödendikten sonra kalan miktarın hisse senedi sayısına bölünmesi ile bulunan değerdir.” [Dağlı, 2009]

Borç değeri: Şirketin t anında yabancı kaynaklar toplamının hisse senedi sayısına bölünmesi ile bulunan değerdir.

Alternatif gelir değeri: Şirket ortakları tarafından oluşturulan sermayenin, şirket içinde şirket sermayesi şeklinde kullanılıp başka bir yatırım alanında değerlendirilmiş olması halinde, hisse senetlerine yatırılan sermaye miktarı ile elde edilebilecek alternatif gelirden bir hisseye düşen gelir tutarını gösteren değerdir.

İşleyen teşebbüs değeri: Bir şirketin faaliyet halindeyken bir bütün olarak satılması veya devredilmesi durumunda elde edilen satış kârının (satış gelirinden borçların çıkarılarak) hisse senedi sayısına bölünmesiyle hesaplanan değerdir.

2.2. Hisse Senetlerinin Analiz Yöntemleri

Bir yatırımcı için karar almada en önemli destek; yatırım yapacağı şirket hisse senedinin iyi bir şekilde analiz edilmesidir. Bu anlamda yatırımcının hem pazarı iyi tanınması hem de değişen ekonomik ve finansal çerçeveyi iyi okuması gerekmektedir. Yatırımcılara yardımcı olabilecek çeşitli analiz araçları bulunmaktadır.

Bu bölümde literatürde üzerine çalışmalar yapılmış olan temel ve teknik analiz yöntemlerinden bahsedilecektir.

2.2.1. Temel Analiz

Temel analiz, firmanın ekonomik durumunu, çalışanlarını, yönetim kurulunu, finansal durumunu, yıllık raporunu, bilanço ve gelir tablosunu, doğal veya yapay afetler gibi yeryüzü ve iklim koşullarını, makroekonomik verileri ve politik verileri kullanarak gelecekteki hisse senedi fiyatını tahmin etmek için kullanır. Temel analiz uzun vadeli hisse senedi fiyat hareketleri için faydalıdır.

Temel analiz; genel ekonomi analizi, sektör analizi ve firma analizinden oluşan üç temel aşaması vardır. Kesin bir kural olmamasıyla birlikte, analiz sıralaması genelden özele doğru yapılır. Bu analizlere bağlı olarak hisse senedinin risk ve getiri ilişkisi ortaya konur ve çeşitli yöntemlere başvurularak gerçek değer hesaplanır. Hesaplanan gerçek değer ve piyasa değeri karşılaştırılır. Gerçek değer piyasa değerinden yüksekse yatırım yapılır, tersi ise hisse satılır veya satın alınmaz yorumu yapılır.

Ekonomi analizi; gayri safi milli hasıla, kişi başına harcanılan gelir, para arzı, faiz oranları ve enflasyon, dış ticaret ve ödemeler dengesi açıkları, kamu kesimi harcamaları, nüfus artış hızı, işgücü, sabit yatırım harcamaları, öncü göstergeler, eş zamanlı göstergeler, gecikmeli göstergeler değerlendirilerek yapılır.

Sektör analizi; sektörün geçmiş dönemlerinde satış hasılatları ve karlardaki büyüme, gelecek dönemlerde endüstrideki arz ve talep durumu, rekabet koşulları, işgücü durumu, hükümet politikaları, uluslararası ilişkiler, sosyal yaşamdaki değişimler ve söz konusu sektördeki şirketlerin hisse senetlerinin piyasa fiyatları değerlendirilerek yapılır.

Şirket analizi; likidite oranları, faaliyet oranları, finansal yapı ile ilgili oranlar ve karlılık oranları değerlendirilerek yapılır. Tablo 2.3’ de oranlar verilmiştir.

Tablo 2.3: Şirket analizi mali oranları.

Oran Grubu	Oran Adı	Açıklama
Likidite Oranları	Cari Oran	Dönen Varlıklar / Kısa Vadeli Yabancı Kaynaklar
	Asit-Test Oranı	Dönen Varlıklar- Stoklar/Kısa Vadeli Yabancı Kaynakları
	Nakit Oran	Nakit ve Nakit Benzerleri / Kısa Vadeli Yabancı Kaynaklar
Faaliyet Oranı	Özsermaye Devir Hızı	Net Satışlar / Özsermaye
Karlılık Oranları	Özsermaye Karlılığı	Net Kar / Özsermaye
	Net Kar Marjı	Net Kar / Net Satışlar
Mali Yapı Oranları	Kısa Vadeli Borç Oranı	Kısa Vadeli Yabancı Kaynaklar / Toplam Aktifler
	Uzun Vadeli Borç Oranı	Uzun Vadeli Yabancı Kaynaklar / Toplam Aktifler
	Özsermaye/Aktif Toplamı Oranı	Özsermaye / Toplam Aktifler

Kaynak: [Okka, 2009]

2.2.2. Teknik Analiz

“Teknik analiz bir hisse senedinin geçmiş hareketlerinin grafikler aracılığıyla incelenerek analiz edilmesi ve geleceğe yönelik tahmin yapılması tekniğidir.”

[Kirkpatrick ve Dahlguist, 2011] Teknik analizde borsada oluşan fiyatlar kullanılmaktadır. “Teknik analist, tarihsel piyasa fiyatlarını ve teknik göstergeleri yansıtan grafikleri öğrenerek hisse senedi piyasasını tahmin etmeye çalışır.” [Nti vd., 2019]

“Teknik analizin hisse senedi fiyatlarının tahmininde kullanılabilmesi için aşağıdaki varsayımların kabul edilmesi gerekmektedir.” [Dağlı, 2009]

- Hisse senedinin piyasa fiyatı sadece kendisiyle ilgili arz ve talebin karşılıklı etkisiyle oluşur.
- Hisse senedi arz ve talebi bir kısmı rasyonel, bir kısmı irrasyonel pek çok faktörün etkisi altında şekillenir.
- Piyasadaki küçük dalgalanmalar dikkate alınmadığında, hisse senedi fiyatları uzun süre devam eden belirli bir trend doğrultusunda hareket ederler.
- Trenddeki kesintiler, arz ve talepteki kavramlar sonucu meydana gelir.
- Kaynağına bakılmaksızın, arz ve talepteki kaymalar er veya geç piyasa verilerini işaretlediği grafikler vasıtasıyla tespit edilebilir.
- Çoğu grafiklerdeki fiyat hareketleri zaman içinde aynen tekrarlanır. Yani hisse senedi fiyatlarının bir hafızası bulunmaktadır.

Teknik analiz için trend indikatörleri ve osilatörler olmak üzere iki ana gösterge sınıfı vardır. Trend indikatörleri, finansal piyasalarda mevcut fiyat hareketlerinin yönünü belirlemek için kullanılır. “Osilatörler, fiyatın zaman içerisinde değişmesi ile bir merkez çizginin altında veya üstünde ayarlanan seviyeler arasında dalgalanan bir göstergedir.” [Öztürk, 2016]

2.2.2.1. Trend İndikatörleri ve Osilatörler

Teknik analizde kullanılan trend indikatörler ve osilatörler hisse senedi fiyatı tahminlemesinde yardımcı olmaktadır. Tez içerisinde de kullanılan bazı trend indikatörler ve osilatörler verilmiştir.

1. Üstel Hareketli Ortalama (EMA): Son günlerin önem oranı artırarak fiyatların hareketli ortalamasını gösteren araçtır. “Üssel hareketli ortalama hesaplanırken, son zamanlardaki verilerin ağırlığının daha önceki verilerin ağırlığına göre daha fazla olduğu kabul edilir.” [Sezer, 2018] Ayrıca EMA üzerinden yeni teknik analiz verileri de mümkündür. Bu tezde de belirli gecikmeli EMA üzerine son veri noktasını dikkate alan doğrusal ekstrapolasyon (LP) veya

kuadratik ekstrapolasyon (QP) yöntemiyle istenen dönem (gün) ileriye doğru tahmin edilir. Örneğin; EMA_15+15+LP+3, 15 gecikmeli (parametre 15) Üstel Hareketli Ortalama (EMA), son 15 EMA veri noktasını dikkate alan doğrusal ekstrapolasyon yöntemiyle 3 dönem (gün) ileriye doğru tahmin edilir.

2. Kaufman Uyumlu Hareketli Ortalama (KAMA): Perry Kaufman tarafından geliştirilen bir araçtır. Üstel hareketli ortalamadan yola çıkan bir trend takip göstergesidir. Duyarlılığı, fiyat dalgalanmaları düşük olduğunda fiyatları yakından takip ederken, gürültü arttığında daha uzak mesafeden takip etmesiyle dikkat çeker. Ayrıca fiyat kesişimleri ve dinamik destek/direnç seviyeleri olarak da kullanılabilir. KAMA, diğer analiz teknikleriyle birlikte kullanılarak daha etkili sonuçlar elde edilebilir. Bu tezde de belirli gecikmeli KAMA üzerine son veri noktasını dikkate alan doğrusal ekstrapolasyon (LP) veya kuadratik ekstrapolasyon (QP) yöntemiyle istenen dönem (gün) ileriye doğru tahmin edilir. Örneğin; KAMA_7+7+QP+5, 7 gecikmeli (parametre 7) Kaufmann Hareketli Ortalama, son 7 KAMA veri noktasını dikkate alarak kuadratik ekstrapolasyon yöntemiyle 5 dönem (gün) ileriye doğru tahmin edilir.
3. Stokastik Osilatör ve Sinyali: George Lane tarafından geliştirilen bir momentum indikatörüdür. Alım-satım işlemlerinde olası giriş ve çıkış seviyelerini belirlemek için kullanılır. STO, 0 ile 100 arasında dalgalanan K% ve c adlı iki çizgiden oluşur. K% çizgisi, belirli bir dönemin en yüksek ve en düşük fiyat seviyelerine göre kapanış fiyatındaki değişimi temsil ederken, D% çizgisi K%'nın belirli bir başka dönemine göre ortalamasını gösterir.
4. Göreceli Yönlü Endeks (ADX): J. Welles Wilder tarafından geliştirilmiş bir gecikmeli trend indikatörüdür. ADX, bir menkul kıymetin güçlü bir yükseliş veya düşüş trendini inceler. ADX, +DI çizgisi, -DI çizgisi ve ADX çizgisi olmak üzere üç hattan oluşur. ADX, 0 ile 100 arasında değer alır. Değerler genellikle 40'ın üzerinde güçlü bir trendi, 20'nin altında zayıf bir trendi veya sabit alım-satım aralıklarını gösterir.
5. Ortalama Gerçek Aralık (ATR): J. Welles Wilder tarafından geliştirilmiş teknik analizde oynaklığı ölçmek için kullanılan bir araçtır. 14 günlük bir sürre içerisinde varlıkların ortalama piyasa fiyatını hesaplar ve fiyat oynaklığını gösterir.
6. Hareketli Ortalamaların Yakınsama Sapması (MACD): MACD, teknik analizde kullanılan verimli bir göstergedir ve 1979 yılında Gerald Appel

tarafından geliştirilmiştir. Hareketli ortalamalar arasındaki ilişkiyi yansıtmak için kullanılır. Uyumsuzlukları incelemek için de kullanışlıdır.

7. Bollinger Bantları (BB): Fiyat hareketlerini tahmin etmede etkili bir yöntemdir aynı zamanda hisse senedinin değişkenliği hakkında da bilgi sağlar. Orta, üst ve alt bant olmak üzere üç banttan oluşmaktadır. Üst ve alt bantlar fiyatların en düşük ve en yüksek noktasıdır ve fiyatlar bantlar arasında yer alır.
8. Chaikin Para Akışı (CMF): 1 ve -1 değerleri arasında salınım yaparak belirli bir süre boyunca para hacmini ölçmek için kullanılan bir göstergedir. Satın alma baskısının daha yüksek olduğu durumda değer 1'e yaklaşır tersi durumda ise satış baskısı olduğunda değer -1'e yaklaşır.
9. Dengeleme Hacmi (OBV): Teknik analizde alım satım basıncını ölçmek için kullanılan bir teknik göstergedir. Fiyatın yükseldiği günlerde o günün hacminin birikimli olarak toplanır, düştüğünde ise o günün hacmi birikimli OBV toplamından çıkarılır.
10. Ichimoku Bulutu: Bir grafikte birden fazla göstergeyi bir araya getiren bir teknik analiz yöntemidir. Mum grafiklerinde kullanılarak potansiyel destek ve direnç fiyat bölgeleri hakkında bilgi sağlar. Aynı zamanda gelecek trendlerin yönünü ve piyasa ivmesini tahmin etmek için kullanılır.
11. Para Akışı Endeksi (MFI): Gene Quong ve Avrum Soudack tarafından geliştirilmiş bir osilatördür. MFI, Chaikin Para Akışı (CMF) gibi hem fiyatı hem de hacmi kullanır. MFI, belirli bir dönemde bir menkul kıymete para girişi mi yoksa çıkışı mı olduğunu belirlemek için kullanılır. Varsayılan dönem genellikle 14 gündür. Yükselen MFI, alım baskısı olduğunu, düşen MFI ise satış baskısı olduğunu gösterir.
12. Yüksek ve Düşük Fiyat Ortalaması (YD)
13. Yüksek, Düşük ve Kapanış Fiyat Ortalaması (YDS)
14. Yüksek, Düşük, Açılış ve Kapanış Fiyat Ortalaması (YDAS)


3. MAKİNE ÖĞRENMESİ

Endüstrinin ortaya çıkışından itibaren makineler insanlar tarafından türlü görevler verilmektedir. Buharlı makinelerden bu yana değişen ve gelişen endüstrinin geldiğimiz mevcut Endüstri 4.0 evresinde artık makineler için öğrenme evresi başlamıştır. Arthur Samuel tarafından 1959 yılında makine öğrenmesi kavramı ortaya konmuştur. Makine öğrenmesini girdi verileriyle çıktı verileri arasında bağlantıyı çeşitli algoritmalar aracılığıyla öğrenme süreci olarak tanımlayabiliriz. Oluşan öğrenme sonucu tahmin gerçekleştirilebilmektedir. Bu bize basit bir doğrusal regresyonu çağrıştırabilir sonuç olarak bir bağlam kurulması için sistematik bir yönteme ihtiyaç bulunmaktadır.

Alzubi vd. (2018) göre makineler için öğrenme gerekliliği şu şekilde açıklanmıştır. “Makine öğrenimi, insan müdahalesi olmadan bilgisayarların görevleri sofistike bir şekilde yerine getirmesi için gereklidir. Bu, öğrenme temelinde ve sürekli artan deneyimle, problem karmaşıklığını anlama ve uyum sağlama ihtiyacına dayanır.”

3.1. Makine Öğrenmesi Yöntemleri


Makine öğrenmesi temelde üç çeşit öğrenme yöntemine sahiptir. Bu yöntemler denetimli öğrenme, denetimsiz öğrenme ve pekiştirmeli öğrenme yöntemleridir. Bu yöntemler ile “kategori ve sınıf bulma: Sınıflandırma (Classification), verileri inceleyip tahminde bulunma: Regresyon (Regression), verileri aynı özellikli bölgelere ayırma: Kümeleme (Clustering), verilerin özelliklerinin sayısını azaltarak temel duruma getirmek Boyut azalımı (Dimensionality Reduction) işlemleri yapılabilmektedir.” [Demiray, 2021]



Şekil 3.1: Makine öğrenmesi türleri.

3.1.1. Denetimli Öğrenme

Denetimli öğrenme yöntemi, eğitim verileriyle birlikte doğru çıktılar veya örnek modüller sağlanarak çalışır. Bu eğitim setleri temelinde algoritma, girdi olarak verilen verilerle kendi çıktısını karşılaştırarak daha doğru yanıtlar üretmeyi öğrenir. Denetimli öğrenme aynı zamanda örneklerden öğrenme veya örneklerle öğrenme olarak da bilinir. Bu yöntem, tarihsel verilere dayalı tahminlerde kullanılır. Denetimli öğrenme görevleri, sınıflandırma ve regresyon olarak iki ana kategoriye ayrılabilir. Sınıflandırma görevlerinde çıktı etiketleri kesikli (açık aralıklı) iken, regresyon görevlerinde çıktılar sürekli (kapalı aralıklı) değerlerdir.




Şekil 3.2: Denetimli öğrenme akış şeması.

3.1.2. Denetimsiz Öğrenme

Denetimsiz öğrenme, veri analitiği ve makine öğrenmesinde önemli bir yaklaşımdır. Bu yöntemde, veri setindeki verilerin etiketlenmemiş olduğu bir senaryo ele alınır. Modelde gözetilmeye ihtiyaç duyulmaz ve sadece girdiler kullanılır. Veri setindeki veriler yorumlanır ve ortak alanlar belirlenir. Bu yorumlanan veriler ve bulunan ortak noktalar sayesinde kümeleme işlemi gerçekleştirilir. Kümeleme, benzer verilerin gruplandırılmasıdır. Veriler birkaç gruba ayrılır ve her kümede analiz yapılır. Ayrıca boyut küçültme yöntemi de denetimsiz öğrenme kapsamında ele alınır. Boyut küçültme, değişken sayısını azaltarak veri setini daha anlamlı ve yönetilebilir hale getirir. Denetimsiz öğrenme, istatistik temelli bir yaklaşım olarak kabul edilir ve etiketlenmemiş verilerde gizli yapıyı bulma sorununa yönelir. Bu yöntem, veri

kategorilerinin bilinmediği durumlarda başarılı bir şekilde kullanılabilir. [Koç, 2021; Alzubi vd, 2018]




Şekil 3.3: Denetimsiz öğrenme akış şeması.

3.1.3. Pekiştirmeli Öğrenme

Pekiştirmeli öğrenme, ceza ve ödül puanlaması ile hedefe yaklaşmayı öğreten bir öğrenme modelidir. “Agent adı verilen öğrenen makine, karşılaştığı her duruma bir tepki verir ve karşılığında bir sonuç sinyali alır. Agent, sonuç puanını en yükseğe çıkartmak için çalışır. Pekiştirmeli öğrenmede, Markov karar süreci modeli kullanılmaktadır.” [Koç, 2021]

Pekiştirmeli öğrenme orta düzey bir öğrenme türüdür. Agent adı verilen makine problemler karşısında bir tepki oluşturmaktadır ve karşılığında puanlama almaktadır. Hedef en yüksek puana ulaşmak olduğu için çeşitli olasılıklar keşfedilmeli ve elenmelidir, böylelikle öğrenme sağlanır.



Şekil 3.4: Pekiştirmeli öğrenme akış şeması.

3.2. Makine Öğrenmesi Algoritmaları

Bu bölümde çalışmada kullanılan Rastgele Orman algoritmasından ve kısaca literatürdeki yaygın diğer algoritma türlerinden bahsedilecektir. Verilen beş algoritma Wiranata ve Djunaidy'in (2021) çalışmasında yer alan hisse senedi fiyat tahmini için en çok kullanılan ilk algoritmadır.

3.2.1. Rastgele Orman Algoritması (RO)

Rastgele Orman algoritması sınıflandırma ve regresyonda kullanılan bir öğrenme yöntemidir. 2001 yılında Breiman tarafından geliştirilmiştir. "Prensip olarak rastgele orman, farklı veri örnekleri üzerine inşa edilmiş çok sayıda derin fakat ilişkisiz karar ağacından oluşur" [Breiman, 2001]. Rastgele Orman algoritmasında düğümler ve dallar kullanılır. "Rastgele orman algoritması her bir düğümü veri setindeki tüm öznitelikler arasından en iyisini kullanarak dallara ayırmak yerine, her bir düğümde veri seti içerisinde rastgele seçilen öznitelikler arasından en iyisini kullanarak dallara ayırır." [Kurt vd, 2020]

Yönteme göre düğümleri dallara ayırmak için düğümlerdeki rastgele değerlerden en iyi olanı seçilmekte ve oluşturulan karar ağaçlarına belirli ağırlıklar verilmektedir. Bu ağırlıklar karar ağaçlarının iç hatalarına göre belirlenmekte ve en düşük hataya sahip olan karar ağacına en yüksek, en yüksek hataya sahip karar ağacına en düşük ağırlık verilmektedir. Verilen bu ağırlıklar sınıf tahmininde oy verme işlemi için kullanılmaktadır. Daha sonra bu oylar toplanarak nihai karar verilmektedir. [Koç Usta vd, 2021]

Şekil 3.5' de örnek bir Rastgele Orman algoritması verilmiştir.


Rastgele Orman algoritması dört aşamadan oluşmaktadır. Bu aşamalar; rastgele alt örneklem alma, rastgele özellik seçimi, ağaç oluşturma ve tahmin yapmadan oluşmaktadır.

Rastgele alt örneklem alma: Rastgele bir şekilde veri setinin bir alt kümesi seçilir ve her karar ağacı bu verileri örnek olarak kullanır.

Rastgele özellik seçimi: Tüm karar ağaçları belirli bir öznitelik alt kümesini kullanarak eğitilir. Bu öznitelikler, tüm özellikler arasından rastgele seçilir.

Ağaç oluşturma: Veri setinin alt kümesi ve rastgele seçilmiş öznitelikler kullanılarak karar ağaçları ortaya çıkar.

Tahmin yapma: Tüm karar ağaçlarının sonuçları bir araya getirilir ve nihai sonuç üzerinden tahmin yapılır.



Şekil 3.5: Rastgele orman algoritması karar ağaçları modeli.

Rastgele Orman algoritmasının avantajları ve dezavantajları mevcuttur. Avantajları olarak şunları sayabiliriz:

- Genellikle yüksek doğruluk oranları elde edilir.

- Farklı tipte verileri kullanabilme özelliği ile araştırmacılara esneklik kolaylığı sağlar.
- Veri kümesindeki özniteliklerden önemli olanları otomatik olarak seçebilir böylelikle modelin doğruluğunu artırır.
- Birden fazla karar ağacı oluşturduğundan model oluşturmada geniş bir araştırma imkânı sağlar.
- Makine öğrenmesinde en çok gözlemlenen aşırı uyumluluk ve aşırı öğrenme sorunu minimize eder.

Dezavantajları da inceleyecek olursak aşağıdaki dezavantajlara dikkat edilmesi gerekir:


- Birçok karar ağacı oluşturduğundan büyük veri kümelerinde işlem süresi oldukça düşüktür.
- Yine birçok karar ağacı oluşturduğundan bellek sorunları oluşturabilir.
- Yüksek boyutlu veri kümelerinde özniteliklerin belirlenmesi zor olabilir.
- Karar ağacı sayısı belirlenirken sayı belirlemekte problemle karşılaşılabilir. Karar ağacı sayısı, doğruluk oranı ile ters ancak hız ile doğrusal bir ilişkidir.
- Küçük veri kümelerinde yüksek duyarlılık gösterebilmektedir.

Rastgele Orman algoritmasının genel olarak özelliklerine bakıldığında kullanımı hızlı ve analizi anlaşılır bir yapıda olduğu görülür. Birden fazla değişkenin aynı anda makinede çalıştırılması da farklı karar ağaçlarının paralel bir şekilde değerlendirilmesi de kullanıcılar için olasılıklar içerisinde en iyisine ulaşmasını sağlamaktadır. Öte yandan algoritmanın geliştirilmesi gereken birtakım noktalar vardır. Bu noktalardan geliştirilebilir ve en önemi olan kısıtlı öznitelik seçimi ve karar ağacı sayısı seçimidir.

3.2.2. Destek Vektör Makineleri (SVM)

Destek vektör makineleri sınıflandırma ve regresyon problemleri için kullanılabilen bir denetimli makine öğrenmesi türüdür. Marj hesaplamayı baz alan bir yapı üzerine çalışır. Destek Vektör Makineleri doğrusallığa göre iki alt sınıfa ayrılır. Bu sınıflar; Doğrusal Destek Vektör Makineleri ve Doğrusal Olmayan Destek Vektör Makineleridir.

Destek Vektör Makineleri, karmaşık karar sınırlarını modelleyebilmektedir ve çok sayıda bağımsız değişkenle çalışılabildiğinden genelleme yeteneği yüksektir.



Şekil 3.6: Optimal ayırıştırıcı düzlem, marj, destek vektörler.


[Özçalıcı, 2017]

3.2.3. Uzun Kısa Süreli Bellek (LSTM)

Uzun Kısa Süreli Bellek (LSTM), zamansal veriler üzerinde çalışan bir özyinelemeli bir makine öğrenmesi yöntemidir. LSTM, uzun süreli bağımlı verileri bellekte tutabilen bir yapıya sahiptir. İşleyişinde unutma, giriş ve çıkış kapıları bulunur. Bu sayede LSTM, zaman serilerini sınıflandırmak, işlemek ve tahmin etmek için oldukça uygundur.

3.2.4. Yapay Sinir Ağları (ANN / YSA)

Yapay Sinir Ağları, insan beynini ilham alan yapay nöronların insan beyninin bilgi işleme yöntemini taklit eden ve öğrenme ile genelleme yeteneklerini geliştirebilen bilgisayar sistemleridir. Yapay sinir ağları katmanlı bir yapıya sahiptir. Beş temel elemanı mevcuttur. Bu elemanlar; girdiler, girdi katmanı, ara katman, çıktı katmanı ve çıktıdan oluşmaktadır. Yapay Sinir Ağları denetimli veya denetimsiz olarak öğrenme sağlayabilmektedir.




Şekil 3.7: YSA modeli akışı.

[Elmas, 2007]

3.2.5. Çok Katmanlı Algılayıcı (MLP)

Çok Katmanlı Algılayıcı, Yapay Sinir Ağlarının bir türüdür ve yaygın formlarından biridir. Yapay Sinir Ağlarının prensibi olan insan beyninin bilgi işleme şeklini taklit etme ve öğrenme sağlama amacıyla kullanılır. Tek katmanlı algılayıcıların çok katmanlı hale getirilmesi ile geliştirilmiştir. Genellikle giriş katmanı, bir veya bazen iki gizli katman ve bir çıkış katmanı içerir. Öğrenme yeteneği sayesinde veri işleyebilir ve tahminleme yapabilir.

Değişkenler arası doğrusal olmayan ilişkilerde verimli ve anlamlı sonuçlar çıkarabilmektedir.



Şekil 3.8: Çok katmanlı algılayıcı modeli.

[Öztemel, 2012]

4. UYGULAMA MODELİ VE BULGULAR

Uygulama çalışmasında öncelikle hedef hisse senetleri belirlenmiştir ve bu hisselerin kapanış fiyatları tahminlemek istenmektedir. Tahminleme yönteminde birden çok yöntemin Rastgele Orman'ın sınıflandırma özelliğinden faydalanarak dinamik bir hibrit tahmin modeli oluşturulması amaçlanmaktadır.

4.1. Çalışmanın Amacı ve Kapsamı

Bu çalışmanın temel amacı Borsa İstanbul Ulusal 30 Endeksi'nde (BIST30) yer alan şirketlerin hisse senedi tahmini için hızlı ve güvenilir bir makine öğrenmesi yöntemi olan Rastgele Orman Algoritması ve temel ve teknik analiz verileri kullanılarak her hisse senedi için en uygun modelin araştırılmasıdır.

Model performansını artırmak için Rastgele Orman Sınıflandırıcısı kullanılarak yapılan tahminlerde, üç aşamalı bir özellik eleme yöntemi uygulanmıştır. Bu süreçte, Genetik Algoritmalar (GA) ve Parçacık Sürüsü Optimizasyonu (PSO) ilkelerini birleştiren hibrit bir algoritma kullanılmıştır. Genetik Algoritma (GA) çerçevesinde, sinir ağları aracılığıyla farklı öznetelik seçim stratejileri ve RO sınıflandırıcı parametrelerinin etkinliği değerlendirilmiştir. Yapılan yöntem araştırmasında RO'nın sınıflandırma yöntemi kullanılarak en iyi tahmin modelini hedeflenmekte ve sonuçlar tartışılmaktadır.

Araştırma sırasında Python'da Scikit-Learn ve Pandas kütüphaneleri ve Random Forest Classifier özellikleri kullanılmıştır.

4.2. Çalışma Verileri

Bu çalışmada BIST30 içerisinde yer alan şirketlerin bilanço tabloları Fastweb Mali Analiz Pro sitesinden alınmıştır ve firmaların son 45 dönemlik (3. Çeyrek 2023' den geriye) verileri toplanmıştır. Beraberinde Investing.com üzerinden geçmişe dönük hisse senedi, Altın ve Euro Döviz fiyatları alınmıştır.

Banka sektöründeki şirketlerin temel analizde esas alınan oranlara uygun olmaması ve 2020 sonrasında halka arz edilmiş şirketlerin öğrenme ve test verileri için yeterli veri sayısı bulunmaması sebebiyle çalışma dışı bırakılmıştır. Toplamda Bist30'da yer alan

ve veri girdileri uygun olan 23 adet hisse senedi incelenmiştir. İncelenen şirketler, şirketlerin sektörleri ve halka arz tarihleri Tablo 4.1’ de verilmiştir.

Toplanan veriler ile her firma için ayrı ayrı literatür kısmında yer verilen temel analiz göstergeleri ve teknik analiz göstergeleri hesaplanmıştır.

Tablo 4.1: Bist30'daki çalışma grubu şirketleri.

Şirket	Kod	Sektör	Halka Arz Tarihi
ALARKO HOLDING	ALARK	Holding	24.05.1989
ASELSAN	ASELS	İletişim ve Savunma	1.08.1990
BİM MAGAZALAR	BIMAS	Perakende Ticaret	6.07.2005
BORUSAN BORU SANAYİ	BRSAN	Metal Ana Sanayi	1.09.1994
EMLAK KONUT GMYO	EKGYO	Gayrimenkul Yat. Ort.	23.11.2010
ENKA İNŞAAT	ENKAI	Bayındırlık ve İmar	24.01.1986
EREĞLİ DEMİR ÇELİK	EREGL	Metal Ana Sanayi	13.01.1986
FORD OTOSAN	FROTO	Otomotiv	13.01.1986
GÜBRE FABRİK.	GUBRF	Gübre ve Ziraî Ürünler	6.01.1986
HEKTAS	HEKTS	Gübre ve Ziraî Ürünler	13.01.1986
KOC HOLDING	KCHOL	Holding	10.01.1986
KOZA ALTIN	KOZAL	Madencilik ve Kıymetli Maden	3.02.2010
ODAS ELEKTRİK	ODAS	Enerji	13.05.2013
OYAK CİMENTO	OYAKC	Çimento, Beton	17.07.1987
PEGASUS	PGSUS	Ulaştırma	18.04.2013
PETKİM	PETKM	Petrol	9.07.1990
SABANCI HOLDING	SAHOL	Holding	2.07.1997
SASA POLYESTER	SASA	Tekstil Kimyasalları	23.10.1996
SİSE CAM	SİSE	Cam	13.01.1986
TOFAS OTO. FAB.	TOASO	Otomotiv	1.07.1991
TUPRAS	TUPRS	Petrol	30.05.1991
TÜRK HAVA YOLLARI	THYAO	Ulaştırma	20.12.1990

4.3. Verilerin Temizlenmesi ve Düzenlenmesi

Bist30’da yer alan şirketlerin 45 dönemlik bilanço tabloları Fastweb Mali Analiz Pro (www.fwmanaliz.com) internet sitesinden elde edilmiştir.

Temel analizde yer alan Likidite, Faaliyet, Karlılık ve Mali Yapı oranlarına ayrıca öğrenme için yeterli veri sağlaması amacıyla söz konusu 45 dönemlik zaman dilimi içerisinde geçmişe dönük fiyat bilgisi yer alan şirketler seçilerek fiyat bilgileri ve Altın ve Euro kuru elde edilmiştir (www.investing.com).

Toplanan veriler her şirket için ayrı ayrı Excel dosyalarında toplanmıştır ve şirketlere ait veriler en eski tarihten en yeni tarihe göre sınıflandırılıp dönemlik veriler günlük verilere dağıtılmıştır.

4.4. Rastgele Orman Sınıflandırma Uygulaması

Öznitelik seçimi, model performansını ve yorumlanabilirliğini artırmada önemli bir rol oynar. Bu çalışma, çoklu bağlantılılıkla başa çıkmak ve Rastgele Orman sınıflandırıcılarının tahmin doğruluğunu artırmak için tasarlanmış kapsamlı bir üç katmanlı özellik eleme çerçevesi sunmaktadır. Çerçeve, finansal uygulamalarda yaygın olan yüksek hacimli veri kümeleri için özel olarak tasarlanmıştır; burada birçok gösterge ve gecikme önemli ölçüde bağlantılılık gösterir.

Sınıflandırma için hazırlanan veri kümesi, hareketli ortalamalar, fiyat oranları ve teknik göstergeler gibi türetilmiş göstergelerin büyük miktarı nedeniyle çok boyutluluk alanı içerir. Bu özellikler arasındaki çoklu bağlantılılık, model kararsızlığına ve aşırı uyuma yol açabilir. Bu sorunu ele almak için metodolojimiz, sınıflandırma görevlerinden önce öznitelik kümesini saflaştırmayı amaçlayan sağlam bir üç katmanlı özellik eleme süreci içermektedir.

4.4.1. Tahminciler için Eleme

Tüm hisse senedi arasındaki verileri birleştirmek, her bir hisse senedi için günlük olarak $\text{Şimdi}+1$ 'i ne kadar etkili bir şekilde tahmin ettiklerini analiz etmemizi sağlar. Tahmin edicileri $\text{Şimdi}+1$ 'e olan yakınlıklarına göre günlük olarak sıralayarak, her bir tahmin edicinin etkililiğini minimum, ortalama ve maksimum sıralar gibi çeşitli ölçütlerle anlayabiliriz.

Her bir tahminci, veri setinde en az bir kez "en iyi tahminci" olarak yer alır ve her tahminci için en az 1. sırayı garanti etmektedir. Öte yandan, neredeyse tüm tahminciler en az bir kez "en kötü tahminci" unvanına ulaşırken, çoğunluğu için maksimum sıralama genelde 81 olmaktadır. Dikkat edilmesi gereken bir nokta ise tüm göstergelerin bazı durumlarda en kötü on sıralama içinde yer alıp geride kalan tek istisna lag 9 için EMA (en kötü sırası 66) ve bir sonraki güne lineer dışsallaması, $\text{EMA}_{9+9+LP+1}$ (en kötü sırası 70) dışında kalmasıdır.

Bu analizi özetleyen Tablo 4.2, 81 tahmin edicisinin Şimdi+1 için en iyi tahminci olarak ne sıklıkla sıralandığını ve Şimdi+1'e olan yakınlıkları açısından ortalama sıralarını net bir şekilde göstermektedir. Bu tablo, tahmin edicilerin en iyi performans dağılımını ve sıklığını göstererek, hem sık sık en iyi performans gösterenleri hem de tahminleri Şimdi+1 ile daha tutarsız olanları vurgulamaktadır. Bu verilerin nihai analizi, bir tahmin edicinin en iyi tahminci olma sıklığı ile ortalama sırası arasında doğrudan bir ilişki olmadığını ortaya koymaktadır. Bu gözlem, Şekil 4.1'deki dağılımla görsel olarak desteklenmektedir. Bu dağılım, yaklaşık hiperbolik bir ilişki önerse de önemli bir değişkenlik göstermektedir.


Tablo 4.2: Tahmin edici sıralama dağılımı.

Estimator	Times Best	Max Rank	Average Rank	Estimator	Times Best	Max Rank	Average Rank
Şimdi	3567	80	18,5	KAMA_7+7+QP+5	415	81	54,0
Yüksek	3057	81	26,7	EMA_5+5+LP+3	414	79	41,3
Düşük	2803	81	25,2	KAMA_5	413	76	27,5
Açılış	2234	80	24,8	KAMA_5+5+QP+5	413	81	56,9
YDS	1566	79	19,1	KAMA_7+7+QP+1	409	81	36,7
YD	1491	79	20,6	KAMA_3+3+LP+5	409	81	48,6
YDAS	1212	78	20,0	KAMA_15+15+QP+5	396	81	51,4
EMA_3	1015	75	19,3	KAMA_7+7+QP+3	395	81	46,1
EMA_3+3+QP+1	881	81	42,8	KAMA_9+9+QP+5	382	81	52,4
EMA_5+5+QP+1	748	81	33,3	EMA_7+7+LP+5	381	81	47,6
EMA_5+5+QP+3	699	81	49,1	KAMA_5+5+LP+1	371	78	35,6
KAMA_3+3+QP+1	692	81	38,4	KAMA_9+9+QP+3	366	81	45,5
EMA_3+3+LP+1	668	81	32,7	KAMA_5+5+LP+5	356	81	48,4
EMA_5	650	71	21,5	KAMA_9+9+LP+5	355	81	49,4
EMA_3+3+LP+3	598	81	43,5	EMA_9+9+LP+3	353	79	42,3
EMA_7+7+QP+1	547	79	32,7	EMA_15+15+LP+3	351	80	46,4
KAMA_3	538	77	23,5	EMA_7+7+LP+3	349	78	41,5
EMA_7+7+QP+3	537	81	44,7	KAMA_9+9+QP+1	344	80	38,4
KAMA_5+5+QP+1	526	81	35,6	EMA_12	337	72	30,7
KAMA_3+3+LP+1	522	80	32,9	KAMA_7+7+LP+1	334	75	38,0
EMA_3+3+QP+3	514	81	62,2	EMA_9+9+LP+1	333	70	36,2
EMA_3+3+LP+5	507	81	50,9	EMA_15	328	78	34,6
EMA_7+7+QP+5	503	81	54,5	EMA_15+15+QP+3	324	80	43,4
EMA_7	501	69	24,0	KAMA_3+3+QP+5	323	81	63,4
EMA_5+5+LP+1	498	78	32,7	KAMA_5+5+LP+3	318	80	42,6
KAMA_5+5+QP+3	476	81	47,9	EMA_15+15+QP+1	316	77	38,7
KAMA_3+3+QP+3	472	81	54,6	KAMA_15+15+QP+1	316	80	43,1
EMA_9+9+QP+1	471	76	33,7	KAMA_7+7+LP+5	315	81	48,8

Tablo devamı

Estimator	Times Best	Max Rank	Average Rank	Estimator	Times Best	Max Rank	Average Rank
EMA_9+9+QP+5	470	81	51,6	KAMA_9	314	78	33,6
EMA_15+15+LP+5	452	81	49,5	KAMA_15+15+QP+3	314	81	47,1
EMA_5+5+QP+5	452	81	59,8	KAMA_7	311	76	30,6
EMA_7+7+LP+1	441	74	34,2	KAMA_15+15+LP+3	299	81	49,2
EMA_9	439	66	26,7	KAMA_9+9+LP+1	293	76	40,4
EMA_15+15+QP+5	433	81	48,7	KAMA_15	289	80	40,2
EMA_5+5+LP+5	432	81	48,2	EMA_15+15+LP+1	284	78	42,6
EMA_9+9+QP+3	428	80	42,8	KAMA_12	282	80	37,5
EMA_9+9+LP+5	425	81	47,6	KAMA_15+15+LP+1	281	79	46,2
KAMA_3+3+LP+3	424	81	42,0	KAMA_9+9+LP+3	274	79	45,2
KAMA_30	424	81	48,9	KAMA_7+7+LP+3	272	79	43,8
KAMA_15+15+LP+5	422	81	51,7	EMA_3+3+QP+5	264	81	70,7
EMA_30	417	81	46,9				

Özellikle, Tablo 4.2’de listelenen ve Şekil 4.1’in sol tarafında yer alan en iyi on tahmin edici, farklı ortalama sıralarda en iyi tahmin sayısında çeşitlilik göstermekte; bu da tahmin edici performansının farklı günler ve hisse senetleri arasında karmaşıklığını ve çeşitliliğini vurgulamaktadır. Benzer şekilde, diğer tahmin edicilerin de benzer sayıda en iyi tahmin elde etmelerine rağmen geniş bir ortalama sıra aralığı bulunmaktadır.




Şekil 4.1: Tahmincilerin ortalama sırasına karşılık en iyi tahmin sayıları.

Bir dizi tahmincinin seçimi için hiyerarşik kümeleme kullanılmıştır. Bu teknik, tahmincileri benzerliklerine göre tanımlayıp kategorize edilmesine yardımcı olmaktadır; benzerlikler ise çiftler arası mesafe matrisinin bir dendrograma

dönüştürülmesiyle nicelleştirilmiştir. Dendrogram, özellikler arasındaki ilişkileri ve bağlantıları görsel olarak temsil ederek, kümeleşmiş verilerin hiyerarşik bir görünümünü sunmaktadır. Şekil 4.2, dendrogram aracılığıyla kümelenmeyi görsel olarak göstermekte ve tahmincilerin nasıl gruplandığını ve kümelerin oluşturulduğu bağlantı seviyelerini illüstre etmektedir.





Şekil 4.2: Özellik kümeleme dendrogramı.

Hiyerarşik kümeleme yapmak için önce hedef değişken olan Şimdi+1'i hariç tutulmuştur, böylece yalnızca özelliklerin farklı örneklerdeki performansına odaklanılmıştır. Kümeleme süreci, her küme içindeki varyansı en aza indiren Ward yöntemini kullanmaktadır; bu da dendrogramı kesmek için hangi nokta seçileceği etkili bir şekilde belirlenmekte ve belirgin gruplar oluşturmaktadır. Analiz için, verileri çok ince bir şekilde segmentlemekten ana grupları yakalayan bir bağlanma seviyesinde dendrogramın kesilmesi tercih edilmiştir; özellikle belirli bir eşik değerine karşılık gelen bağlanma değeri seçilir. Bu eşik, bağlanma değerleri aralığında belirli bir yüzde olarak seçilmektedir.

Oluşan her kümede, özellikleri rastgele oluşturulması yerine, "en iyi tahminci" metriğine dayalı her tahmincinin Şimdi+1'in en iyi tahmincisi olarak ne sıklıkla derecelendirildiği bir seçim kriteri uygulanmaktadır. Her kümeden, en çok en iyi olarak değerlendirilen tahminci tutulmakta ve bu sayede önceki sıralamaya göre en etkili tahmincilerin korunduğu garanti edilir. Bu yaklaşım, yüksek düzeyde korelasyona sahip tahminciler arasındaki tekrarları azaltırken, tahmincilerin çeşitliliğini korumamıza olanak sağlamaktadır.

Ayrıca, hiyerarşik kümelemekten seçilen tahminciler, en iyi tahmincilerin en üst yüzdesinden doğrudan belirlenenlerle birleştirilmektedir. Bu hibrit seçim, hem en etkili bireysel performans gösterenleri hem de kendi kümeleri içinde en iyi performans gösterenleri son tahminci sete dahil edilir. Hem doğrudan sıralama hem de hiyerarşik kümeleme ile seçilen tahmincilerin birleşimi, sonraki modelleme aşamaları için sağlam bir özellik seti sağlamaktadır.

Son tahminci seçimi hem doğrudan hem de küme tabanlı seçimleri birleştirerek, daha fazla modellemenin, yani takip eden Rastgele Orman Sınıflandırmasının performansını artırması beklenen kapsamlı bir tahminci seti sunmaktadır. Bu birleştirilmiş yaklaşım, özellikle modelde yer alan tahmincilerin hem bireysel olarak etkili hem de kolektif olarak uyumlu olmasını sağlamak için sıralama tabanlı ve hiyerarşik yöntemlerin güçlü yönlerini etkili bir şekilde kullanmaktadır.

Tablo 4.3'te uygulanan yapay sinir ağları yaklaşıklaması ve genetik-parçacık eniyilemesine dayalı her hisse için seçilen yaklaşık en iyi öznelik seçimi ve RO parametre tercihleri yer almaktadır.

Tablo 4.3: YSA yaklaşıklaması ve genetik-parçacık eniyilemesine dayalı her hisse için seçilen yaklaşık en iyi öznelilik seçimi ve RO parametre tercihleri.

Hisse Senedi	Criterion	Bootstrap	OOB Score	FS Method	Min Samples Leaf	Min Samples Split	Estimator Linkage Ratio	Estimator Champ Ratio	Linkage Ratio	VIF Ratio	Elimination Ratio	N Estimators	Max Depth	Min Weight Fraction Leaf	Max Features	Max Leaf Nodes	Min Impurity Decrease
ODAS	log_loss	DOĞRU	DOĞRU	4	5	5	0,06487	0,74850	0,22993	0,99000	0,03655	124,33895	115,15932	0,38821	1,00000	1030,00000	0,06159
EREGL	gini	YANLIŞ	YANLIŞ	1	1	10	0,34551	0,23477	0,76273	0,63792	0,22322	130,01485	118,74709	0,01968	0,86318	1030,00000	0,04603
PGSUS	gini	DOĞRU	DOĞRU	3	3	9	0,14461	0,00000	0,30224	0,40322	0,66285	109,44047	110,09541	0,45354	1,00000	1008,44548	0,04734
FROTO	log_loss	DOĞRU	DOĞRU	3	5	7	0,00000	0,62311	0,99000	0,99000	0,40627	126,47137	111,98489	0,50000	0,22756	1017,83225	0,05280
TOASO	gini	DOĞRU	DOĞRU	2	5	10	0,22728	0,44465	0,34994	0,32139	0,99000	127,68304	112,71296	0,46618	0,01000	1030,00000	0,00605
SASA	gini	DOĞRU	DOĞRU	4	5	4	0,63558	0,92125	0,99000	0,45718	0,41991	117,87805	123,80778	0,44184	0,93943	1030,00000	0,00000
PETKM	gini	DOĞRU	DOĞRU	3	1	6	0,72716	0,51754	0,81252	0,18852	0,63916	120,86774	117,37878	0,27010	0,64544	1030,00000	0,10000
BRSAN	gini	DOĞRU	DOĞRU	1	5	4	0,83530	0,80971	0,40449	0,26659	0,99000	129,74612	114,16899	0,49846	0,01000	1030,00000	0,06074
GUBRF	gini	DOĞRU	DOĞRU	4	3	10	0,97000	0,97000	0,32935	0,51836	0,05439	113,79180	116,66256	0,34411	0,51951	1030,00000	0,10000
ALARK	gini	DOĞRU	DOĞRU	5	5	5	0,90243	0,46659	0,99000	0,68014	0,66824	112,06073	117,41272	0,11064	1,00000	1030,00000	0,09631
ENKAI	log_loss	YANLIŞ	YANLIŞ	5	4	9	0,97000	0,14148	0,48096	0,24771	0,38831	122,61091	126,61839	0,38111	0,26122	1030,00000	0,03051
EKGYO	gini	DOĞRU	DOĞRU	3	5	4	0,69242	0,33124	0,25253	0,00000	0,16178	126,96780	113,30150	0,10947	0,93847	1030,00000	0,06591
TUPRS	entropy	YANLIŞ	YANLIŞ	5	3	9	0,00000	0,70469	0,40646	0,61148	0,46077	119,83036	123,71399	0,39183	1,00000	1030,00000	0,07391
TCELL	gini	DOĞRU	DOĞRU	1	5	7	0,01217	0,74851	0,33232	0,46047	0,03573	112,59099	118,44203	0,43248	0,39539	1030,00000	0,03065
BIMAS	log_loss	DOĞRU	DOĞRU	5	3	3	0,49668	0,44844	0,83499	0,60880	0,14777	111,71885	113,97177	0,26274	0,42796	1030,00000	0,08966
KCHOL	entropy	DOĞRU	DOĞRU	5	4	4	0,42982	0,25225	0,24628	0,00000	0,65054	131,54621	118,40563	0,34642	0,01000	1030,00000	0,06829
SAHOL	log_loss	DOĞRU	DOĞRU	3	3	9	0,19379	0,81481	0,99000	0,00000	0,96218	133,55894	121,15608	0,35075	0,68730	1030,00000	0,04005
HEKTS	entropy	YANLIŞ	YANLIŞ	5	3	7	0,36628	0,00000	0,75576	0,99000	0,40206	127,29188	117,24090	0,33057	0,35134	1030,00000	0,03425
THYAO	entropy	DOĞRU	DOĞRU	3	5	9	0,46823	0,30019	0,45015	0,99000	0,50177	119,66671	119,22247	0,13416	0,48809	1030,00000	0,08314
OYAKC	gini	DOĞRU	DOĞRU	1	3	4	0,41479	0,90185	0,67588	0,63229	0,00000	112,32556	112,87229	0,47235	0,65017	1030,00000	0,06692
SISE	gini	YANLIŞ	YANLIŞ	2	5	9	0,24029	0,85411	0,48379	0,00000	0,01227	118,54195	120,30335	0,03908	1,00000	1030,00000	0,09315
KOZAL	log_loss	DOĞRU	DOĞRU	5	3	3	0,97000	0,47019	0,29033	0,98664	0,00000	123,89639	124,53638	0,15126	0,01000	1030,00000	0,07380
ASELS	entropy	DOĞRU	DOĞRU	3	1	3	0,97000	0,89384	0,94749	0,10240	0,64714	125,89640	120,92201	0,20207	0,87974	1030,00000	0,03848

Hisseler için seçilen tahminci eleme oranlarına bakıldığında nadiren çok yüksek eleme oranları görülmektedir (ASELS: Estimator Linkage Ratio: 0.97, Estimator Champ Ratio: 0.894). Hisselerin çoğu için bu oranlar geniş bir aralıktadır, fakat her iki yöntemde %50'den fazla eleme yapılarak kalan tahmincilerin bileşkesinin alınması yaygındır. Öznitelik elemesinde de durum benzerdir, her üç eleme yöntemi için eleme oranları geniş bir aralıktadır, fakat ortalama olarak tüm yöntemlerde özniteliklerin yaklaşık %50'sinin elenmesiyle bir bileşke ortaya çıkarmak optimal gözükmemektedir. Öznitelik seçimi yöntemleri (FS Method) arasında "3'üncü" en sık tercih edilmekle birlikte 3'üncü, 4'üncü ve 5'inci arasında dengeli bir dağılım vardır. 1'inci öznitelik seçim yöntemi daha az tercih edilmekte, 2'nci ise nadirdir.

RO parametre seçimlerinde dal bölünmesi kalite kriteri olarak gini öne çıkmakla birlikte, hisseler için optimal parametre seçimleri arasında her üç kritere rastlanmaktadır. OOB skorlaması yapılarak bootstrapping tercihi yaygındır. Örneklemde en az veri sayısı (min samples split) ve yapraklarda en az veri sayısı (min samples leaf) için spektrumun büyük tarafında tercihlere daha sık rastlanmaktadır.

Maksimum öznitelik parametresinde ek olarak eleme yapılmaması (MaxFeatures=1) yaygın olmakla birlikte, ek olarak elemeler için belli daha düşük oranları tercihler de söz konusudur. Min Impurity Decrease için ortalaması 0.05 olan geniş bir spektrum söz konusudur. Maksimum derinlikte 100-120 arası yaygın olup aralığın 1000'e kadar uzanan daha üst kısmı optimal tercihlerde kullanılmamıştır. Aksine, Maksimum Yaprak değerinde 1000 üzeri ve bu parametre için aralığın en üst değeri olan 1030 yaygındır. Rastgele ormandaki ağaç sayısı (N Estimators) için 100-130 aralığı tüm hisselerdeki tercih olmuş, 10-500 kapsamındaki diğer değerler optimal tercihler arasında kullanılmamıştır.

4.4.2. Öznitelik Eleme Yöntemleri

Öznitelik eleme çerçevesi, özellik fazlalığını sistematik olarak azaltmak ve modelin alaka düzeyini artırmak için tasarlanmış üç katmandan oluşur:

- 1. Hiyerarşik Kümeleme Tabanlı Eleme:** Bu katman, özelliklerin yakınlığını bağlantı mesafelerine göre belirlemek için hiyerarşik kümelemeyi kullanır. Önceden belirlenmiş bir oranla en yakın kümeler önce birleştirilerek özellikler elenir. Sıkı bağlı kümeler içindeki özellikleri eleyerek, bilgi değerini önemli ölçüde azaltmadan çoklu

bağılantılılık azaltılır, çünkü kümeler içindeki en temsilci özellikler, Rastgele Orman özellik önem puanlarına göre korunur.

2. Varyans Şişirme Faktörü (VIF) Azaltma: Bu katmanda en yüksek VIF'leri gösteren özellikler elenir. Bu, mükemmel çoklu bağılantılılığı gösteren sonsuz VIF'lere sahip tüm özellikleri içerir. VIF yöntemi, tahmin edici değişkenler korelasyonluysa, tahmin edilen regresyon katsayısının varyansının ne kadar arttığını ölçer. Yüksek VIF özelliklerini azaltmak, sınıflandırıcının tahmin sağlamlığını artırır.

3. Seçici Özellik Eleme: Bu katmanda beş önceden tanımlanmış stratejiden seçilen yönteme bağlı olarak, belirli bir oranla öznetelikler elenir. Strateji şu seçenekler arasından seçilir:

- **k-En İyi Özellik Seçimi:** Çıkış değişkeniyle en alakalı olan ilk k özelliklerini korumak için Ki-kare istatistiklerini kullanır.
- **Rastgele Orman Özellik Önemi:** Önceden bir Rastgele Orman modelinden türetilen önemlerine göre ilk k özelliklerini korur.
- **Rastgele Orman ile Yinelemeli Özellik Eleme (RFE):** Rastgele Orman tahmincisine dayalı olarak en az önemli özellikleri sırasıyla kaldırır.
- **Gradient Boosting Özellik Önemi:** Rastgele Orman önem yöntemine benzer, ancak bir Gradient Boosting modeli kullanır.
- **Gradient Boosting ile RFE:** Yinelemeli özellik eleme için Gradient Boosting Sınıflandırıcısını kullanır.

Yukarıda ifade edilen her üç katman parametre olarak girilen oranlarda öznetelik eler. Nihai olarak seçilen öznetelikler üç katmandaki elemelerden sonra kalan özneteliklerin bileşkesidir.

Her bir hisse senedi için analiz edilen model konfigürasyonları, her katmandaki öznetelik eleme derecesini ve değerlendirme için kullanılan nihai Rastgele Orman Sınıflandırıcısının performansını etkileyen çeşitli parametre ayarlarıyla kapsamlı deneylerle optimize edilecektir. Öznetelik eleme için katmanlı yaklaşım, çoklu bağılantılılık ve özellik fazlalığını nüanslı bir şekilde ele almayı sağlar. Öznetelik alanını sistematik olarak azaltmakla, model sadece hesaplama açısından verimli hale gelmekle kalmaz, aynı zamanda finansal hareketleri tahmin etmede daha yüksek doğruluk gösterir. Tablo 4.4, öznetelik seçimi, tahminci seçimi ve sınıflandırma

performansını optimize etmek için denemelerde kullanılan parametrelerin aralığını ve dağılımını sunmaktadır.

Tablo 4.4: Özellik seçimi ve rastgele orman sınıflandırma parametreleri.

Parametre	Açıklama	Değerler
Kümeleme ile Tahminci Eleme Oranı	Hiyerarşik kümeleme ile tüm tahminciler üzerinden bu oranda eleme yapılır. En yakın kümelerden sadece en fazla tahmin başarısı olan seçilerek sıra ile elenir.	0.0 - 0.97 ¹
Başarı Sayısına göre Tahminci Eleme Oranı	Tüm tahminciler üzerinden bu orana göre eleme yapılır. Şimdi+1'i en fazla sayıda en iyi tahmin eden tahminciler seçilir.	0.0 - 0.97
Hiyerarşik Kümeleme Eleme Oranı	Küme bağlantısına dayalı olarak elenen özelliklerin oranı	0.0 - 0.99
VIF Eleme Oranı	VIF puanlarına dayalı olarak elenen özelliklerin oranı	0.0 - 0.99
Nihai Katman Eleme Oranı	Nihai seçim katmanında elenen özelliklerin oranı	0.0 - 0.99
Özellik Seçim Yöntemi	Nihai seçim katmanında kullanılan yöntem	1 (k-En İyi), 2 (RF Önemi), 3 (RF RFE), 4 (GB Önemi), 5 (GB RFE)
Tahminci Sayısı	Ormandaki ağaç sayısı	10, ..., 500
Kriter	Bir bölünmenin kalitesini ölçmek için kullanılan fonksiyon	"gini", "entropy", "log_loss"
Maksimum Derinlik	Ağacın maksimum derinliği	5, ..., 1000
Bölünmede Minimum Örnek Sayısı	Bir düğümü bölmek için gereken minimum örnek sayısı	2, 3, ..., 10
Yaprakta Minimum Örnek Sayısı	Bir yaprak düğümünde gereken minimum örnek sayısı	1, 2, 3, 4, 5
Yaprakta Minimum Ağırlıklı Toplam Ağırlık Oranı	Bir yaprak düğümünde gereken toplam ağırlıkların minimum ağırlıklı oranı	0.0 - 0.5
Maksimum Yaprak Düğüm Sayısı	Maksimum yaprak düğüm sayısı	30, ..., 1000
Minimum Safsızlık Azalması	Bu değerden büyük veya eşit bir safsızlık azalması bu düğümde bölünme yapar	0.0 - 0.1
Bootstrap	Ağaçları oluştururken bootstrap örneklerinin kullanılıp kullanılmadığı	True, False
OOB Skoru	Genel doğruluğu tahmin etmek için out-of-bag örneklerinin kullanılıp kullanılmadığı	True (sadece bootstrap True ise), False

¹ Sürekli parametreler, aralıklarında sürekli uniform dağılıma göre örneklenir. Ayırık ve kategorik parametreler, ayırık uniform dağılıma göre örneklenir.

5000 veri noktası, belirli bir günde ‘Şimdi+1’i tahmin eden en iyi tahmincinin Rastgele Orman Sınıflandırmasının doğruluğu üzerindeki özellik eleme ve Rastgele Orman parametre seçiminin etkisini değerlendirmek için toplanır. Veri, Tablo 4.4’te belirtilen dağılımlara göre rastgele seçilen bir hisse senedi için rastgele örneklenir. Özellik seçimi, her katmanda katmana özgü eleme oranlarına göre özelliklerin elendiği üç katmanda gerçekleştirilir. Üçüncü katmanda, eleme oranı parametresi 0 değerine sahipse özellik eleme yapılmaz. Aksi takdirde, 1-5 arası değerlerden örneklenen birine göre beş özellik eleme yaklaşımından biri uygulanır. Hiyerarşik kümeleme ile seçimdeki özellik önemleri, Rastgele Orman özellik önemlerine göre seçim ve Rastgele Orman Sınıflandırıcısı ile Yinelemeli Özellik Eleme, Rastgele Orman Sınıflandırıcısı ile Tahminci Sayısı-OOB Skoru parametreleri ayarlanarak kullanılır ve eğitim için ayrılan veri ile eğitilir (70% bölünme).

Üç katmanda özellik seçimi tamamlandıktan sonra, Şimdi+1’in günlük en iyi tahmincisini tahmin etmek için bir Rastgele Orman Sınıflandırıcısı eğitilir. Bu sınıflandırıcı, seçilen giriş sütunları ile eğitilir, Tahminci Sayısı-OOB Skoru parametreleri örneklenen parametre değerlerine göre ayarlanır ve kronolojik olarak sıralanmış verilerin 70/70-95% eğitim/test bölünmesi ile eğitilir. Eğitimden sonra, bu nihai sınıflandırıcının tahmin doğruluğu hesaplanır, bu da Şimdi+1’in en iyi tahmincisinin doğru tahminlerinin oranıdır.

Tablo 4.4’ten farklı hisse senetleriyle parametre seçimlerinin rastgele örneklenmesiyle toplanan veriler, parametre seçiminin tahmin doğruluğu üzerindeki etkisini genellemek için kullanılır. Bu, denetimli parametre seçimi-tahmin doğruluğu verileri üzerinde bir Derin Sinir Ağı öğrenme modeli uygulanarak yapılır. Öğrenme modeli, her hisse senedi için yaklaşık olarak optimal parametre seçimini belirlemek için kullanılacaktır, bu da bir sonraki bölümde tartışılacaktır.

4.4.3. Öznitelik Seçimi ve RO Optimizasyonu için YSA Entegrasyonu

Analize başlamak için “Ticker”, “FS Method”, “Criterion”, “Min Samples Split”, “Min Samples Leaf”, “Bootstrap” ve “OOB Score” gibi kategorik değişkenler one-shot encoding kullanılarak dönüştürülmüştür. Bu yöntem kategorik değişkenleri, sayısal girdi formatları gerektiren sinir ağları tarafından işlenmesi için gerekli olan ikili bir matrise dönüştürür. Bu kodlanmış kategorik özellikler daha sonra “Bağlantı Oranı”,

“VIF Oranı”, “Eleme Oranı”, “n Tahmin Ediciler”, Maksimum Derinlik”, “Min Ağırlık Fraksiyonu Yaprığı”, “Maksimum Özellikler”, “Maksimum Yaprak Düğümleri” ve “Min Safsızlık Azalması” gibi sürekli değişkenlerle birleştirilmiştir. Bu kapsamlı veri seti, çeşitli sinir ağı konfigürasyonlarının eğitilmesi ve değerlendirilmesine yönelik bütünsel bir yaklaşımı kolaylaştırmıştır.

4.4.3.1. Yaklaşık Optimizasyon için Sinir Ağı Modelleri

Amaç bir Genetik Algoritma (GA) çerçevesinde her bir hisse için farklı özellik seçim stratejilerinin ve RO Sınıflandırıcı parametrelerinin etkinliğini yaklaşık olarak tahmin etmek için sinir ağlarını kullanmaktır. Bu yaklaşım, Genetik Algoritmanın sinir ağının tahminlerine dayalı olarak parametre ayarlarını keşfetmesine ve optimize etmesine olanak tanıyarak kapsamlı yapılandırma testi ihtiyacını azaltarak verimliliği artırır.

Araştırılan konfigürasyonlar ağ derinliği, bırakma oranları ve aktivasyon fonksiyonları açısından çeşitlilik göstermiştir:

Orta ve Derin Ağlar; yapılandırmalar, verilerdeki karmaşık örüntüleri etkili bir şekilde yakalamak ve Düzeltilmiş Doğrusal Birim (ReLU) ve Hiperbolik Tanjant (tanh) aktivasyonlarını kullanarak değişen derinliklere sahip katmanları kullanmıştır.

Yüksek Bırakma Yapılandırmaları; artan bırakma oranına sahip ağlar, modellerin görünmeyen veriler üzerinde iyi genelleme yapabilmesi için çok önemli olan aşırı uyumu azaltmak için test edilmiştir.

Karışık Aktivasyon Fonksiyonları; ReLU, tanh ve sigmoid aktivasyonlarını birleştiren ağlar, her bir fonksiyonun kendine özgü avantajlarından (verimli gradyan yayılımı için ReLU, normalleştirilmiş çıktı için tanh ve pürüzsüz olasılıksal çıktılar için sigmoid) yararlanmayı amaçlamıştır.

Aşamalı ve Yüksek Derinlikli Ağlar; bazı modeller, aşırı uyum risklerini aşamalı olarak en aza indirirken karmaşık, yüksek boyutlu veri kümelerini işlemek için tasarlanmış aşamalı bırakma özelliğine sahip çok derin yapılara sahiptir.

Özel Yapılar; öğrenme dinamikleri ve model performansı üzerindeki etkilerini değerlendirmek için alternatif aktivasyon fonksiyonları ve çeşitli bırakma seviyeleri içeren konfigürasyonlardır.

Her konfigürasyon, doğrulama kaybındaki iyileşmeler sona erdiğinde eğitimi durduran erken durdurma gibi doğrulama stratejileriyle titiz bir eğitimden geçirilerek

modellerin aşırı eğitilmemesi ve optimum performanslarında değerlendirilmesi amaçlanmıştır. Tablo 4.5'te, belirli bir özellik seçimi ve sınıflandırıcı parametreleri ayarının (Tablo 4.5'te belirtildiği gibi parametre seti) RO Sınıflandırma doğruluğunun tahmini için karşılaştırılan sinir ağı modellerini özetlemektedir.

Dense(x, 'aktivasyon'), "aktivasyon" olarak gösterilen belirli bir aktivasyon fonksiyonu kullanan X nöronlu tam bağlı bir katmanı temsil eder. Dropout(rate), eğitim sırasında her güncellemede giriş birimlerinin bir kısmını rastgele sıfıra ayarlayarak aşırı uyumun önlenmesine yardımcı olan bir bırakma katmanını ifade eder. Oklar(→) her bir model içindeki katmanların sırasını göstermekte ve işlemlerin gerçekleşme sırasını ortaya koymaktadır. Bu yapılandırılmış gösterim, her sinir ağı modeli içindeki yapı unsurları ve bunların işlevleri hakkında netlik sağlar.

Tablo 4.5: Konfigürasyon parametre seti.

Konfigürasyon	Açıklama
Orta Derinlik	Dense(128, 'relu') → Dropout(0.3) → Dense(64, 'relu') → Dropout(0.2) → Dense(32, 'relu') → Dropout(0.1)
Tanh ile Daha Derin Ağ	Dense(256, 'tanh') → Dropout(0.2) → Dense(128, 'tanh') → Dropout(0.2) → Dense(64, 'tanh') → Dropout(0.1)
Karışık Aktivasyonlar Yüksek Bırakma	Dense(128, 'relu') → Dropout(0.4) → Dense(128, 'tanh') → Dropout(0.3) → Dense(64, 'sigmoid') → Dropout(0.2)
Sığ Sigmoid Ağ	Dense(64, 'sigmoid') → Dropout(0.3) → Dense(64, 'sigmoid') → Dropout(0.2) → Dense(32, 'sigmoid') → Dropout(0.1)
Artırılmış Derinlik Karışık Aktivasyonlar	Dense(256, 'relu') → Dropout(0.25) → Dense(128, 'relu') → Dropout(0.2) → Dense(64, 'tanh') → Dropout(0.15) → Dense(32, 'sigmoid') → Dropout(0.1)
Derin Ağ Düşük Seyreltme	Dense(256, 'relu') → Dropout(0.1) → Dense(256, 'relu') → Dropout(0.1) → Dense(128, 'relu') → Dropout(0.1) → Dense(64, 'relu') → Dropout(0.1)
Yüksek Seyreltmeli Derin Katmanlar	Dense(128, 'relu') → Dropout(0.3) → Dense(128, 'tanh') → Dropout(0.25) → Dense(128, 'tanh') → Dropout(0.2) → Dense(64, 'sigmoid') → Dropout(0.15) → Dense(64, 'sigmoid') → Dropout(0.1) → Dense(32, 'sigmoid') → Dropout(0.05)
Dönüşümlü Aktivasyonlar Orta Düzeyde Seyreltme	Dense(256, 'relu') → Dropout(0.2) → Dense(128, 'sigmoid') → Dropout(0.15) → Dense(128, 'relu') → Dropout(0.1) → Dense(64, 'sigmoid') → Dropout(0.05) → Dense(32, 'relu') → Dropout(0.05) → Dense(32, 'sigmoid') → Dropout(0.05)
Genişletilmiş Ağ Çok Düşük Kopma	Dense(512, 'relu') → Dropout(0.05) → Dense(256, 'relu') → Dropout(0.05) → Dense(128, 'relu') → Dropout(0.05) → Dense(64, 'relu') → Dropout(0.05) → Dense(32, 'relu') → Dropout(0.05) → Dense(32, 'relu') → Dropout(0.05) → Dense(16, 'relu')
Dönüşümlü Aktivasyon Katmanlı Büyük Ağ	Dense(1024, 'relu') → Dropout(0.05) → Dense(512, 'relu') → Dropout(0.05) → Dense(256, 'relu') → Dropout(0.05) → Dense(256, 'tanh') → Dropout(0.05) → Dense(128, 'tanh') → Dropout(0.05) → Dense(64, 'sigmoid')

4.4.3.2. Optimal Sinir Ağı Modelinin Seçimi

Eğitim sonrası modeller, özel bir test seti üzerinde ortalama karesel hatalarına (MSE) göre değerlendirilmiştir. En düşük MSE'yi sergileyen model, çeşitli özellik seçimi ve sınıflandırıcı ayarlarının etkisini tahmin etmek için Genetik Algoritma için de kullanılmaya en uygun model olarak kabul edilir. Tablo 4.6'da MSE ve ortalama mutlak hata (MAE) ölçütleriyle yapay sinir ağı modellerinin farklı parametre seçimlerinde Rastgele Orman doğruluğunu tahmin etme performansı verilmiştir.

Tablo 4.6: Yapay sinir ağı modellerinin farklı parametre seçimleriyle RO doğruluğunu tahmin performansı.

Konfigürasyon	MSE	MAE
Orta Derinlik	0,00180368	0,029327638
Tanh ile Daha Derin Ağ	0,00180393	0,029865114
Karışık Aktivasyonlar Yüksek Bırakma	0,00184085	0,029158413
Sığ Sigmoid Ağ	0,001796207	0,029843559
Artırılmış Derinlik Karışık Aktivasyonlar	0,001782683	0,02928927
Derin Ağ Düşük Seyreltme	0,001721762	0,028664121
Çok Derin Progresif Seyreltme	0,001759507	0,02893484
Yüksek Seyreltmeli Derin Katmanlar	0,001717749	0,028552134
Dönüşümlü Aktivasyonlar Orta Düzeyde Seyreltme	0,001819926	0,029932817
Genişletilmiş Ağ Çok Düşük Seyreltme	0,001740275	0,028984411
Dönüşümlü Aktivasyon Katmanlı Büyük Ağ	0,001800113	0,029492818

Tablo 4.6'da tüm modellerin 800 adet öznitelik seçimi ve Rastgele Orman parametresi seçimiyle ortaya çıkan RO, tahmin doğruluğu ile eğitildikten sonra 200 test verisi için MSE ve MAE başarı değerleri sergilenmektedir. Modellerin performansı yakın olmakla birlikte, Yüksek Seyreltmeli Derin Katmanlar mimarisi en yüksek başarıyı göstermiştir. Burada, daha derin bir model ve seyreltmenin önemi ortaya çıkmaktadır. Daha derin model, verideki karmaşık örüntülerin öğrenilmesinde başarıyı artırırken seyreltmenin artması aşırı uyumlanmanın önüne geçilmesini ve öğrenmenin daha genel hale gelmesini sağlamaktadır.

Seçilen en başarılı yapay sinir ağı tahmin modeli, genetik ve parçacık sürüsü hibrit algoritmasının ayrılmaz bir parçasıdır ve farklı özellik seçim yöntemleri ve Rastgele Orman parametreleri kombinasyonları için sonuçları tahmin etmek için uygun maliyetli bir yöntem sağlar. Bu yaklaşım, Genetik Algoritmanın verimliliğini önemli ölçüde artırarak optimum veya optimuma yakın konfigürasyonlara daha hızlı ve daha bilinçli bir yakınsamayı kolaylaştırır.

Sinir ağlarının optimizasyon sürecine başarılı bir şekilde entegre edilmesi, makine öğrenimi modellerini evrimsel algoritmalarla birleştirme potansiyelinin altını çizmektedir. Bu hibrit yaklaşım, özellikle finansal zaman serisi tahmini bağlamında özellik seçimi ve model ayarlama için sofistike bir yöntemi temsil etmektedir. Bu entegrasyon sadece hesaplama taleplerini azaltmakla kalmaz, aynı zamanda optimum model konfigürasyonlarının araştırmasına etkin bir şekilde rehberlik etmek için sinir ağlarının tahmin gücünden de yararlanır.

4.4.3.3. Hibrit Genetik-Parçacık Sürüsü Algoritması ile Parametre Ayarlarının Optimize Edilmesi

Her bir hisse senedi için Rastgele Orman Sınıflandırma parametrelerini optimize etmek için Genetik Algoritmalar ve Parçacık Sürüsü Optimizasyonu (PSO) ilkelerini entegre eden hibrit bir algoritma kullanılır. Bu yöntem, Rastgele Orman Sınıflandırma doğruluğunu en üst düzeye çıkartmayı amaçlayarak, özellik seçimi ve sınıflandırma için çeşitli parametre kombinasyonlarının etkinliği yaklaşık olarak tahmin etmek için bir sinir ağı modelinden yararlanır.

Optimizasyon stratejisi hem GA hem de PSO tekniklerini kullanmakta ve bunların sırasıyla kategorik ve sürekli parametrelere uygulanmasını etkili bir şekilde ayırmaktadır. Bu iki yaklaşım, çözüm uzayının kapsamlı bir şekilde araştırılmasını ve kullanılmasını sağlar.

1. İlk Nüfus Üretimi: Algoritma parçacık sürüsü özelliğinden dolayı “parçacıklar” olarak adlandırılabilen bir dizi potansiyel çözüm üretir. Her bir parçacık, özellik seçimi ve Rastgele Orman parametrelerinin bir kombinasyonunu temsil eder ve sürekli parametreler için belirli “hızlar” eşlik eder ve iterasyonlar boyunca ayarlamalarını belirler.

2. Nüfus Yapısı: Nüfus üç eşit bölüme ayrılmıştır.

- En üstteki üçte birlik kısım: Sinir ağından gelen uygunluk değerlendirmelerine dayalı olarak en iyi performans gösteren çözümlerini içerir.
- Ortanca üçte birlik kısım: Daha ileri genetik ve PSO modifikasyonları için üst üçteki birlik kısımdan doğrudan kopyalar alır.
- En alttaki üçte birlik kısım: Üst üçte birlik kısımdan da kopyalar alır ancak sürekli parametreler için yalnızca PSO ayarlamalarına tabi tutulur.

3. Genetik ve PSO İşlemleri:

- Ortanca üçte birlik kısım (Kategorik Parametreler için Genetik İşlemler)
 - Mutasyon: Orta üçte birlik kısımdaki çözümlerin her bir kategorik parametresi, mutasyon olasılığı tarafından tanımlanan bir olasılıkla rastgele değiştirilebilir. Bu mutasyon, popülasyona genetik çeşitlilik katarak yeni kategorik konfigürasyonların keşfedilmesine yardımcı olur.
 - Sürekli Parametreler için PSO Ayarlamaları: Orta üçte birlik kısımdaki sürekli parametreler, ilgili hızlarına göre pertürize edilerek çözümlerin çözüm uzayında çevre alanları keşfetmesine izin verilir.
- En alttaki üçte birlik kısım (PSO Dynamics): Bu segmentte hiçbir mutasyon meydana gelmez. Sürekli parametreler, daha önce başarılı olan bölgelerin etrafındaki aramayı rafine ederek ve istismar yeteneklerini geliştirerek, bireysel hızlara dayalı olarak pertürize edilir.

4. Hibrit Optimizasyon Döngüsü: Her iterasyon, çözümlerin tahmini uygunluklarına göre sıralanmasını içerir; bu, özellik seçimi ve sınıflandırma için ilgili parametreler kullanıldığında günlük en iyi “Şimdi+1” tahmincisini tahmin etmek/sınıflandırmak için yaklaşık Rastgele Orman Sınıflandırma doğruluğudur. Bu parametre seçiminin doğruluğunun tahmini için yukarıda Bölüm 4.4.2.2’de tartışıldığı gibi seçilen “en iyi” sinir ağı kullanılır. En iyi performans gösteren çözümler daha sonra orta ve alt üçte bire çoğaltılır ve burada belirli değişikliklere tabi tutulur. Tanımlanan yineleme sayısının tamamlanması veya yakınsama kriterlerinin sağlanması üzerine algoritma, her bir hisse senedinin Rastgele Orman Sınıflandırıcısı için en uygun ayarlar olarak en yüksek uygunluğa sahip çözümleri seçer.

5. Gerçek Zamanlı Görselleştirme ve Yakınsama: Optimizasyon süreci gerçek zamanlı olarak görselleştirilir ve popülasyonun iterasyonlar arasındaki uygunluk değişiklikleri gösterilir. Bu görselleştirme, optimizasyon stratejisinin etkinliğini değerlendirmeye yardımcı olur ve parametre ayarlamaları hakkında içgörü sağlar.

6. Son Seçim: Belirlenen sayıda iterasyonun tamamlanmasının veya yakınsama kriterlerine ulaşılmasının ardından algoritma, her bir hisse senedinin rastgele Orman

Sınıflandırıcısı için en uygun ayarlar olarak en yüksek uygunluğa sahip çözümleri seçer.

4.4.3.4. Algoritma Parametreleri

Bu hibrit yaklaşım, GA ve PSO uygulamalarını sırasıyla kategorik ve sürekli parametrelere ayırarak, her bir parametre türünün en uygun yöntem kullanılarak optimize edilmesini sağlar. Bu strateji sadece parametre arama verimliliğini artırmakla kalmaz, aynı zamanda Rastgele Orman modellerinin genel tahmin doğruluğunu da önemli ölçüde geliştirir. Algoritma parametreleri aşağıdaki gibidir.

- Grup büyüklüğü; popülasyondaki toplam çözüm(partikül) sayısını tanımlar.
- Yineleme sayısı; optimizasyon işlemi için iterasyon sayısını belirtir.
- Mutasyon olasılığı; popülasyonun orta üçte birlik kısmında kategorik parametrelerdeki mutasyon olasılığını belirler.
- Sürekli sınırlar; sürekli parametreler için aralığı tanımlar ve PSO sürecindeki hızlar aracılığıyla pertürbasyonlarının kapsamını belirler.

Tablo 4.7, günlük tahmin doğruluğunu en üst düzeye çıkarmak amacıyla her bir hisse senedi için özellik seçimi ve sınıflandırma için yaklaşık optimum parametre ayarı sağlayan genetik- parçacık sürüsü algoritmasını göstermektedir.

Tablo 4.7: Hibrit genetik-parçacık sürüsü optimizasyon algoritması.

Adım	Açıklama
0	Girdi: Başlangıç popülasyonu P
1	group_size, iter_count, prob_mutate, continuous_bounds tanımla
2	Popülasyon P'yi 3 * group_size büyüklüğünde başlat
3	P'deki her birey için, sürekli parametreler için hız ve konumu başlat
4	P'deki her bireyin uygunluğunu Rastgele Orman Sınıflandırma doğruluğunu kullanarak değerlendir
5	iter_count kadar iterasyon için:
6	P'yi uygunluğa göre azalan sırayla sırala
7	P'nin üst üçte birini orta ve alt üçte birine kopyala
8	Orta üçte birdeki her birey için:
9	Her kategorik parametre için:
10	prob_mutate olasılığı ile mutasyon yap
11	Her sürekli parametre için:
12	Hızına göre parametre değerini değiştir
13	Alt üçte birdeki her birey için:
14	Her sürekli parametre için:

Tablo devamı

Adım	Açıklama
15	Hızına göre parametre değerini değiştir
16	Orta ve alt üçte birdeki değiştirilmiş bireylerin uygunluğunu değerlendir
17	Performans iyileştirmesine göre hızları güncelle
18	Çıktı: P'den en iyi performans gösteren birey

5. SONUÇ VE DEĞERLENDİRME

Karmaşık ve birden çok değişkenleri olan hisse senedi kapanış fiyatı tahmini ve yöntem belirlenmesi problemi çeşitli dönemlerde çeşitli araştırmacıların bir çözüm bulmak amacıyla üzerine çalışılmıştır. Bu çalışmada da ele alınarak rasyonel yöntemler belirlenip bu yöntemler ile Rasgele Orman Algoritmasından yararlanılarak hibrit bir tahminleme yöntemi ortaya koymak istenmiştir. Hedef çalışma grubu olarak Borsa İstanbul Ulusal 30 Endeksinde yer alan ve veri özellikleri uygun olan 23 hisse senedi incelenmiştir.

Bu çalışmada Rastgele Orman çalışmasının gruplama yönünden faydalanılmıştır. Gruplama yöntemi uygulanırken beraberinde hisse senetlerinin öznelilik seçimi de üç aşamalı bir eleme yöntemi ile model performansının artırılması amaçlanmıştır. Temel analiz ve teknik analiz göstergeleri arasından öznelilik seçimi ve RO parametrelerinin seçimi için Yapay Sinir Ağlarının entegrasyonu ve Genetik Algoritmadan faydalanılmıştır.

Rastgele Orman Sınıflandırıcısının çok karmaşık ve çok boyutlu bir veriyle beslendiğinde hangi tahmincinin yarınki tahminde en iyi sonucu vereceği yönünde makine öğrenmesi sağlanmıştır. Öğrenmede kullanılması için 81 ayrı tahminleyici sınıfı sunulmuş ve bu sınıflar arasından Rasgele Orman Algoritmasının o gün için en iyi tahminciyi tahmin etmesini istenmiştir. Tahminci sayısının fazlalığından dolayı her hisse kapanış fiyatı tahmininde RO kesinlik (accuracy) sonuçları %5 olarak hesaplanmaktadır. Bazı hisselerde optimizasyonlar sayesinde %10 oranlarına kadar çıkmaktadır. Tahmin yöntemleri değerlendirmesinde kesinlik oranının beraberinde MSE ve rank değerleri de göz önüne alınmıştır. MSE değeri tahmincinin tahmini ile gerçekleşen kapanış fiyatı arasındaki oran olarak incelenmiştir. Bir hisse senedi için birden çok tahmincilerinin MSE değerinin başarılı olabileceği görülebilmektedir. Her

gün için bütün tahminciler bir sıraya sokulmuş ve bu tahmincilerin ne kadar sıklıkla en iyi veya kaçınıcı en iyi tahminci oldukları incelenmiştir. Bu sıraların ortalamasını hesaplanmış ve ortalama rank değerlerine ulaşılmıştır. Bunların beraberinde RO gün bazlı olarak saptamış olduğu en iyi tahmincinin günlük sırası takip edilmiştir ve bu sıralamada da RO en üst sıralarda gelmektedir. Bu sebeple iyi bir öğrenme olduğunu görülmektedir.

RO da karşılaşılan istikrarlı üst sıralarda yer alma durumu en iyi tahminciler içerisinde yer alan “Şimdi” ve “YDS” gibi tahmincileri, her hisse için aynı istikrarı sağlayamamaktadır. RO'nun en üst sırada yer aldığı (OYAK), fiyatın gördüğü en son değer olduğu için geçmesi zor olan “Şimdi” tahmincisinden de daha üstte yer aldığı durumlar mevcut çeşitli hisseler için mevcuttur. Kullanılan (RO hariç) tahminciler arasında Şimdi tahmincisi baskın sıklıkla en iyi tahminci olduğu için bazı RO tahminlerinde (TOASO) de aşırı uyumlara durumlarıyla da karşılaşılmaktadır. Ek A’da bahsedilen durumların örnek hisseleri yer almaktadır.

Ek olarak bir diğer ulaşılan sonuç RO öğrenmesi için bir parametre ayarı ve öznitelik seçiminin parametre ayarını yapmak için bir optimizasyon çalışması yapılması yararlı sağlamıştır. Bu optimizasyon ayarı yapılmadan ve yapılmış haline bakıldığında gerek rankda gerek MSEde optimize edilmiş ROnun iyi sonuçlar verdiği görülmüştür.

Gelecek araştırmalarda bir çalışma önerisi olarak RO algoritması kullanılarak hisse senetleri için en iyi tahminleyicinin tek bir sonuç olarak verilmesi konusunda geliştirmeler yapılabilir.

KAYNAKLAR

Agarwal P., Bajpai S., Pathak A., Angira R., (2017) "Stock market price trend forecasting using machine learning", International Journal for Research in Applied Science and Engineering Technology (IJRASET) 5(4):1673–1676.

Agrawal M., Khan A. U., Shukla P. K., (2019), "Stock price prediction using technical indicators: a predictive model using optimal deep learning", International Journal of Recent Technology and Engineering, 6 (2), 2297-2305.

Ahmed D., Neema R., Viswanadha N., Selvanambi R., (2022), "Analysis and Prediction of Healthcare Sector Stock Price Using Machine Learning Techniques: Healthcare Stock Analysis", International Journal of Information System Modeling and Design (IJISMD), 13 (9), 1-15.

Ahuja R., Kumar Y., Goyal S., Kaur S., Sachdeva R. K., Solanki V.,(2023), "Stock Price Prediction By Applying Machine Learning Techniques", 2023 International Conference on Emerging Smart Computing and Informatics (ESCI), Pune, India, 01-03 March.

Al-Alawi A. I., Alaali Y.A., (2023), "Stock Market Prediction using Machine Learning Techniques: Literature Review Analysis", International Conference On Cyber Management And Engineering, 153-157, Bangkok, Thailand, 26-27 January.

Albayrak E., Saran A. N., (2023), "İstatistiksel ve Derin Öğrenme Modellerini Kullanarak Hisse Senedi Fiyat Tahmini", Bilgisayar Bilimleri ve Mühendisliği Dergisi, 16 (2), 161-169.

Altunbaş C., (2021), "Derin Öğrenme ile Hisse Senedi Piyasası Tahmini", Yüksek Lisans Tezi, Aydın Adnan Menderes Üniversitesi.

Alzubi J., Nayyar A., Kumar A., (2018), "Machine Learning from Theory to Algorithms: An Overview", Journal of Physics: Conference Series, Second National Conference on Computational Intelligence, 1142, Bangalore, India, 5 December.

Anbalagan T., Maheswari S.U., (2014), "Classification and prediction of stock market index based on fuzzy metagraph", Procedia Computer Science, 47, 214–221.

Apak S., (1995), "Sermaye Piyasaları ve Borsa", Bilim Teknik Yayınevi.

Arsırankaya S., Toprak Ş., (2021), "Makine Öğrenmesi ve Derin Öğrenme Algoritmalarını Kullanarak Hisse Senedi Fiyat Tahmini ", Uluslararası Mühendislik Araştırma ve Geliştirme Dergisi, 13(1), 178-192.

Berberoğlu N., Arslan S., Afşar M., (1992), "Hisse Senetlerinde Değerleme Yöntemleri ve Türkiye’de Hisse Senetlerinin Fiyatlarını Belirleyen Faktörlerin Analizi", Anadolu Üniversitesi İktisadi Ve İdari Bilimler Fakültesi Dergisi, 10(1), 1-34.

Biswas M., Shome A., Islam M. A., Nova A. J., Ahmed S., (2021), "Predicting stock market price: A logical strategy using deep learning", 11th IEEE Symposium on Computer Applications & Industrial Electronics (ISCAIE), 218-223, Penang, Malaysia, 03-04 April.

Bozkurt Ü., (1988), "Menkul Değer Yatırımlarının Yönetimi", İktisat Bankası Eğitim Yayınları.

Breiman L., (2001), "Random forests", Machine Learning, 45, 5-32.

Ceyhan K., Kurtulmaz E., Sert O. C., Ozyer T., (2018), "Bitcoin Movement Prediction With Text Mining", 26th IEEE Signal Processing and Communications Applications Conference, 1-4, İzmir, Türkiye, 02-05 May.

Civan M., (2007), "Sermaye Piyasası Analizleri ve Portföy Yönetimi", Gazi Kitabevi.

Dağlı H., (2009), "Sermaye Piyasası ve Portföy Analizi", 3. baskı, Derya Kitabevi.

Demiray S., (2021), "Makine Öğrenmesi Algoritmaları ile Hisse Senedi Kapanış Tahmini", Yüksek Lisans Tezi, İstanbul Aydın Üniversitesi.

Demirel U., (2019), "Hisse Senedi Fiyatlarının Makine Öğrenmesi Yöntemleri ve Derin Öğrenme Algoritmaları İle Tahmini", Yüksek Lisans Tezi, Gümüşhane Üniversitesi.

Efecan Güler, <https://efecanxrd.medium.com/random-forest-karar-a%C4%9Fac%C4%B1-algoritmas%C4%B1-nedir-random-forest-algorithm-28a6172cdd50>

Eliaçık A.B., Erdoğan N., (2015), "Mikro Bloglardaki Finans Toplulukları için Kullanıcı Ağırlıklandırılmış Duygu Analizi Yöntemi", Ulusal Yazılım Mühendisliği Sempozyumu (UYSM) 781-793, İzmir, Türkiye, 9-11 Sep.

Elmas Ç., (2007), "Yapay Zekâ Uygulamaları", Seçkin Yayıncılık.

Ghaznavi A., Aliyari M., Mohammadi M.R., (2016), "Predicting stock price changes of tehran artmis company using radial basis function neural networks", International Research Journal of Applied and Basic Sciences, 10(8), 972–978.

Günel M., (2007), "Para Banka ve Finansal Sistem", 2. Baskı, Yeni Dönem Yayınları.

Gündüz H., Çataltepe Z., Yaslan Y., (2017), "Derin Sinir Ağları ile Borsa Yönü Tahmini, Stock Market Direction Prediction Using Deep Neural Networks", 25. Signal Processing and Communications Applications Conference (SIU), İzmir, Türkiye, 15-18 May.

<https://academy.binance.com/tr/articles/bollinger-bands-explained>. Erişim Tarihi: 03.06.2024

<https://academy.binance.com/tr/articles/ichimoku-clouds-explained>. Erişim Tarihi: 03.06.2024

<https://devhuntery.wordpress.com/2018/09/20/rastgele-ormanrandom-forest-algoritmasi/>. Erişim Tarihi: 01.04.2024

<https://www.investing.com/>. Erişim Tarihi: 18.04.2024

<https://medium.com/academy-team/makine-%C3%B6%C4%9Frenmesi-regresyon-modellerindeki-hata-metriklerine-g%C3%BCncel-bak%C4%B1%C5%9F-mae-mse-rmse-r-kare-d1ab758c5759>. Erişim Tarihi: 01.04.2024

<https://scikit-learn.org/stable/modules/generated/sklearn.ensemble.RandomForestRegressor.html>. Erişim Tarihi: 18.04.2024

<https://tr.tradingview.com/scripts/kama/>. Erişim Tarihi: 03.06.2024

https://www.whselfinvest.com/en/trading_strategies_02_belkhayate.php#:~:text=Description,towards%20the%20centre%20of%20gravity. Erişim Tarihi: 03.06.2024

<https://yatirimakademisi.envizyon.com.tr/4-teknik-indikatorler/4-1-osilatorler/>. Erişim Tarihi: 03.06.2024

<https://yatirimakademisi.envizyon.com.tr/4-teknik-indikatorler/4-1-osilatorler/4-1-1-ortalama-yonsel-endeks-adx/>. Erişim Tarihi: 03.06.2024

<https://yatirimakademisi.envizyon.com.tr/4-teknik-indikatorler/4-1-osilatorler/4-1-2-chaikin-para-akisi-cmf/>. Erişim Tarihi: 03.06.2024

Jariyapan P., Singvejsakul J., Chaiboonsri C., (2022), "A Machine Learning Model for Healthcare Stocks Forecasting in the US Stock Market during COVID-19 Period", Journal of Physics: Conference Series, 2287 (1), Singapore, Singapore, 18-20 Feb.

Jin Z., Yang Y., Liu Y., (2020), "Stock closing price prediction based on sentiment analysis and LSTM", Neural Computing and Applications, 32 (13), 9713-9729.

Kirkpatrick C. D., Dahlquist J., (2011), "Technical Analysis: The Complete Resource for Financial Market Technicians", 2. Baskı, FT Press.

Koç Ustalı N., Tosun N., Tosun Ö., (2021), "Makine Öğrenmesi Teknikleri ile Hisse Senedi Fiyat Tahmini", Eskişehir Osmangazi Üniversitesi İİBF Dergisi, 16(1), 1-16.

Koç Y., (2021), "Makine Öğrenmesi ile Çok Terimli Hisse Senedi Yönlü Tahmini: Bist100 Örneği", Yüksek Lisans Tezi, Kadir Has Üniversitesi.

Kurt A., Buldu B., Cedimoğlu İ.H., (2020), " Xgboost ve Rastgele Orman Algoritmalarının Ağ Tabanlı Saldırı Tespitine Yönelik Performanslarının Karşılaştırılması", International Marmara Sciences Congress (Spring), 730-736.

Lawal Z. K., Yassin H., Zakari R. Y., (2020), "Stock Market Prediction using Supervised Machine Learning Techniques: An Overview", IEEE Asia-Pacific Conference on Computer Science and Data Engineering (CSDE).

Moghar A., Hamiche M., (2020), "Stock market prediction using LSTM recurrent neural network", Procedia Computer Science, 170, 1168-1173.

Naik N., Mohan B. R., (2019), "Optimal feature selection of technical indicator and stock prediction using machine learning technique", International Conference on Emerging Technologies in Computer Engineering, 261-268. May.

Nikou M., Mansourfar G., Bagherzadeh J., (2019), "Stock price prediction using DEEP learning algorithm and its comparison with machine learning algorithms", Intelligent Systems in Accounting, Finance and Management, 26 (4), 164-174.

Nti I.K., Adekoya A.F., Weyori B.A., (2019), "A systematic review of fundamental and technical analysis of stock market predictions", Artificial Intelligence Review, 53, 3007-3057.

Okka O., (2009), "Finansal Yönetim Teori ve Çözümlü Problemler", Nobel Yayıncılık.

Özçalıcı M., (2017), "Hisse Senedi Fiyat Tahmininde Genetik Algoritma ile Değişken Seçimi", Anadolu Üniversitesi Sosyal Bilimler Dergisi, 17 (3), 109-124.

Öztemel E., (2012), "Yapay Sinir Ağları", Papatya Yayıncılık.

Öztürk H., (2016), "Teknik Analizde Alım-Satım Sistemi Oluşturma: Sistemin Geçmişe Yönelik Testleri", Finansal Araştırmalar ve Çalışmalar Dergisi, 8(15), 469-493.

Papuçcu H., (2019), "Borsa Endeksi Hareketlerinin Makine Öğrenme Algoritmaları ile Tahmini", Uluslararası İktisadi ve İdari İncelemeler Dergisi, 23, 179-190.

Raşo H., (2019), "Deep Learning Based Stock Market Prediction Using Technical Indicators", Yüksek Lisans Tezi, Gazi Üniversitesi.

Saud A. S., Shakya S., (2020), "Analysis of look back period for stock price prediction with RNN variants: A case study on banking sector of NEPSE", Procedia Computer Science, 167, 788-798.

Sezer Ö.B., (2018), "Zaman Serisi Verilerinin Derin Yapay Sinir Ağları ile Analizi ve Eniyilemesi:Finandal Tahmin Algoritmaları", Doktora Tezi, Tobb Ekonomi ve Teknoloji Üniversitesi.

Shynkevich Y., McGinnity T. M., Coleman S. A., Belatreche A., (2016), "Forecasting movements of health-care stock prices based on different categories of news articles using multiple kernel learning" Decision Support Systems, 85, 74-83.

Subasi A., Amir F., Bagedo K., Shams A., Sarirete A., (2021), "Stock Market Prediction Using Machine Learning", Procedia Computer Science, vol. 194, 173-179.

Tan Z., Yan Z., Zhu G., (2019), "Stock selection with random forest: An exploitation of excess return in the Chinese stock market", Heliyon, 5 (8),

Tsai C.F., Hsiao Y.C., (2010), "Combining multiple feature selection methods for stock prediction: union, intersection, and multi-intersection approaches", Decision Support Systems, 50(1), 258–269.

Vijh M., Chandola D., Tikkiwal V. A., Kumar A., (2020), "Stock closing price prediction using machine learning techniques", Procedia computer science, 167, 599-606.

Vural B. B., (2007), "Yapay Sinir Ağları ile Finansal Tahmin", Yüksek Lisans Tezi, Ankara Üniversitesi.

Wiranata R. B., Djunaidy A., (2021), "The Stock Exchange Prediction using Machine Learning Techniques: A Comprehensive and Systematic Literature Review ", Jurnal Ilmu Komputer dan Informasi (Journal of Computer Science and Information), 14/2, 91-112.

Yıldız G., (1999), " Hisse Senedi Yatırım Kriterleri ve Alternatif Olarak MVA/EVA Değişim Oranı: İ.M.K.B.'de bir Uygulama", Yüksek Lisans Tezi, Anadolu Üniversitesi.

Yurduseven N., Müngen A. A., (2022), "Finansal Zaman Serilerini Tahminlemede Kullanılan Yöntemlere Genel Bir Bakış", BŞEÜ Fen Bilimleri Dergisi, 9(1), 653-671.

ÖZGEÇMİŞ

Deniz Kavuk Salıř, lise eęitimini E.C.A. Elginkan Anadolu Lisesi'nde tamamladı (2009-2013). Ardından, Kocaeli Üniversitesi'nde Endüstri Mühendislięi bölümünde lisans eęitimini bitirdi (2013-2017). řu anda Gebze Teknik Üniversitesi'nde Endüstri Mühendislięi alanında yüksek lisans yapmaktadır (2021-2024).

Mesleki kariyerine 2017 yılında Murat Ticaret Kablo Sanayi'de Malzeme Planlama Mühendisi olarak başladı ve burada 2020 yılına kadar çalıştı. Daha sonra, 2020-2021 yılları arasında Arfesan Arkan Fren Elemanları Sanayi'de Planlama Mühendisi olarak görev yaptı. 2021 yılından itibaren ise Ford Otosan'da Mühendislik Deęişiklięi Devreye Alma Takım Üyesi olarak çalışmaktadır.



TEZ ÇALIŞMASI KAPSAMINDA YAPILAN YAYINLAR

Kavuk-Salıř D., (2024), “Temel ve Teknik Analize Dayalı Makine Öğrenmesi İle Hisse Senedi Fiyat Tahmini: Rastgele Orman Regresyonu Yaklaşımı”, 8. Lisansüstü Arařtırmalar Sempozyumu, Kocaeli, Türkiye, 30-31 Mayıs.



EKLER

Ek-A: Hisseye göre tahmin metodu sıralaması.

Hisse Adı	Method	Accuracy	MSE	Rank
OYAKC	RF_Tuned	0,27777778	0,00102003	12,68518519
OYAKC	RF_Default	0,29629630	0,00130432	13,81481481
OYAKC	Yüksek		0,00132427	16,51851852
OYAKC	Şimdi		0,00141036	15,88888889
OYAKC	KAMA_3		0,00160493	17,20370370
OYAKC	EMA_3		0,00172923	16,50000000
OYAKC	YDAS		0,00193316	18,11111111
OYAKC	KAMA_7		0,00194777	19,31481481
OYAKC	YDS		0,00214537	19,42592593
OYAKC	Açılış		0,00216671	19,88888889
OYAKC	KAMA_5		0,00236014	21,74074074
OYAKC	EMA_5		0,00258553	20,37037037
OYAKC	KAMA_7+7+QP+1		0,00260307	19,22222222
OYAKC	KAMA_9		0,00274313	24,42592593
OYAKC	YD		0,00290072	23,66666667
OYAKC	KAMA_9+9+QP+1		0,00355970	24,88888889
OYAKC	EMA_7		0,00368116	23,37037037
OYAKC	EMA_9		0,00503634	25,64814815
OYAKC	KAMA_9+9+LP+1		0,00531855	30,00000000
OYAKC	KAMA_7+7+LP+1		0,00532810	29,20370370
OYAKC	EMA_5+5+LP+1		0,00625540	30,12962963
OYAKC	KAMA_5+5+LP+1		0,00656434	30,33333333
OYAKC	EMA_3+3+LP+1		0,00684451	32,62962963
OYAKC	EMA_5+5+QP+1		0,00685308	32,09259259
OYAKC	KAMA_3+3+LP+1		0,00714437	34,59259259
OYAKC	Düşük		0,00725378	39,01851852
OYAKC	KAMA_7+7+QP+3		0,00736744	30,42592593
OYAKC	EMA_7+7+QP+1		0,00738712	31,01851852
OYAKC	KAMA_15+15+QP+3		0,00784548	30,85185185
OYAKC	EMA_12		0,00789511	31,33333333
OYAKC	KAMA_15+15+QP+1		0,00804651	34,14814815
OYAKC	KAMA_12		0,00807211	36,87037037
OYAKC	KAMA_9+9+QP+3		0,00819034	29,33333333
OYAKC	KAMA_15+15+LP+1		0,00837316	30,98148148
OYAKC	KAMA_15+15+QP+5		0,00885219	30,61111111
OYAKC	EMA_7+7+LP+1		0,00949260	36,59259259
OYAKC	EMA_9+9+QP+1		0,01017673	36,51851852
OYAKC	KAMA_15		0,01062878	41,66666667
OYAKC	EMA_15		0,01137155	37,35185185
OYAKC	KAMA_15+15+LP+3		0,01165739	37,24074074

Tablo devamı

Hisse Adı	Method	Accuracy	MSE	Rank
OYAKC	KAMA_9+9+LP+3		0,01191954	35,77777778
OYAKC	KAMA_5+5+QP+1		0,01260475	46,16666667
OYAKC	KAMA_30		0,01322892	36,81481481
OYAKC	KAMA_9+9+QP+5		0,01323976	40,50000000
OYAKC	EMA_9+9+LP+1		0,01361572	40,85185185
OYAKC	KAMA_3+3+QP+1		0,01453375	46,38888889
OYAKC	EMA_15+15+QP+1		0,01569720	42,31481481
OYAKC	KAMA_15+15+LP+5		0,01651231	47,50000000
OYAKC	EMA_30		0,01661902	48,50000000
OYAKC	KAMA_7+7+LP+3		0,01752509	47,22222222
OYAKC	KAMA_5+5+LP+3		0,01775692	48,12962963
OYAKC	EMA_3+3+LP+3		0,01832423	48,83333333
OYAKC	KAMA_9+9+LP+5		0,01845941	48,79629630
OYAKC	EMA_5+5+LP+3		0,01880622	45,38888889
OYAKC	KAMA_7+7+QP+5		0,01917745	50,35185185
OYAKC	EMA_9+9+LP+3		0,01975745	47,87037037
OYAKC	EMA_7+7+LP+3		0,02112924	47,11111111
OYAKC	KAMA_5+5+QP+3		0,02240472	55,79629630
OYAKC	EMA_5+5+QP+3		0,02331604	55,74074074
OYAKC	KAMA_3+3+LP+3		0,02460429	60,31481481
OYAKC	EMA_7+7+QP+3		0,02766551	57,98148148
OYAKC	EMA_15+15+LP+1		0,02946418	48,50000000
OYAKC	KAMA_7+7+LP+5		0,03008499	60,59259259
OYAKC	EMA_3+3+QP+1		0,03018456	58,59259259
OYAKC	EMA_3+3+LP+5		0,03142436	57,14814815
OYAKC	KAMA_5+5+QP+5		0,03168514	59,72222222
OYAKC	EMA_15+15+QP+3		0,03354524	54,87037037
OYAKC	EMA_5+5+LP+5		0,03379856	57,61111111
OYAKC	EMA_9+9+QP+3		0,03551113	61,70370370
OYAKC	EMA_7+7+LP+5		0,03611501	55,75925926
OYAKC	EMA_9+9+LP+5		0,03697097	54,66666667
OYAKC	KAMA_5+5+LP+5		0,03704246	64,53703704
OYAKC	EMA_15+15+LP+3		0,04086643	57,53703704
OYAKC	KAMA_3+3+LP+5		0,04276285	69,68518519
OYAKC	EMA_7+7+QP+5		0,04488428	66,85185185
OYAKC	EMA_5+5+QP+5		0,04531861	67,24074074
OYAKC	KAMA_3+3+QP+3		0,04625221	69,11111111
OYAKC	EMA_15+15+QP+5		0,04989437	65,18518519
OYAKC	EMA_15+15+LP+5		0,05861444	69,16666667
OYAKC	EMA_9+9+QP+5		0,05955328	71,01851852
OYAKC	KAMA_3+3+QP+5		0,07939755	75,81481481
OYAKC	EMA_3+3+QP+3		0,08769203	75,64814815
OYAKC	EMA_3+3+QP+5		0,11872639	78,66666667

Hisse Adı	Method	Accuracy	MSE	Rank
TOASO	RF_Tuned	0,16666667	0,00170526	13,88888889
TOASO	Şimdi		0,00170526	13,88888889
TOASO	EMA_3		0,00206336	14,31481481
TOASO	YDS		0,00218655	16,09259259
TOASO	YDAS		0,00225336	16,05555556
TOASO	RF_Default	0,14814815	0,00244061	17,37037037
TOASO	EMA_5		0,00244915	17,11111111
TOASO	YD		0,00257637	18,16666667
TOASO	Düşük		0,00260350	18,48148148
TOASO	EMA_7		0,00264103	17,92592593
TOASO	EMA_9		0,00280491	18,22222222
TOASO	Yüksek		0,00285827	19,00000000
TOASO	EMA_12		0,00318594	19,57407407
TOASO	Açılış		0,00330960	20,50000000
TOASO	KAMA_3		0,00354476	17,44444444
TOASO	EMA_15		0,00361359	20,85185185
TOASO	KAMA_15		0,00613375	29,33333333
TOASO	KAMA_5		0,00642092	24,29629630
TOASO	EMA_5+5+QP+1		0,00743803	30,66666667
TOASO	EMA_7+7+QP+1		0,00745638	29,62962963
TOASO	EMA_3+3+LP+1		0,00772635	30,11111111
TOASO	EMA_5+5+LP+1		0,00798503	29,25925926
TOASO	KAMA_5+5+QP+3		0,00821265	27,05555556
TOASO	KAMA_3+3+LP+1		0,00835045	29,38888889
TOASO	KAMA_12		0,00857252	28,62962963
TOASO	KAMA_7		0,00909792	28,35185185
TOASO	EMA_9+9+QP+1		0,00933725	32,59259259
TOASO	KAMA_9		0,00982136	29,31481481
TOASO	KAMA_5+5+QP+5		0,01013144	30,72222222
TOASO	KAMA_5+5+QP+1		0,01054283	31,77777778
TOASO	EMA_3+3+QP+1		0,01077625	31,70370370
TOASO	EMA_15+15+LP+1		0,01137531	31,18518519
TOASO	EMA_7+7+LP+1		0,01160119	35,90740741
TOASO	EMA_15+15+LP+3		0,01177590	30,48148148
TOASO	EMA_9+9+LP+1		0,01367769	39,98148148
TOASO	EMA_15+15+LP+5		0,01399105	34,46296296
TOASO	EMA_15+15+QP+1		0,01436149	38,70370370
TOASO	KAMA_15+15+LP+1		0,01482951	37,38888889
TOASO	KAMA_3+3+QP+1		0,01497468	36,83333333
TOASO	KAMA_5+5+LP+1		0,01680724	43,81481481
TOASO	KAMA_7+7+QP+1		0,01684791	42,74074074
TOASO	KAMA_3+3+LP+3		0,01736652	41,03703704
TOASO	KAMA_15+15+QP+1		0,01756827	39,18518519
TOASO	EMA_5+5+LP+3		0,01785795	43,37037037
TOASO	KAMA_15+15+LP+3		0,02032242	40,77777778

Tablo devamı

Hisse Adı	Method	Accuracy	MSE	Rank
TOASO	EMA_3+3+QP+3		0,02150179	44,88888889
TOASO	EMA_3+3+LP+3		0,02153445	47,12962963
TOASO	EMA_7+7+LP+3		0,02166278	48,42592593
TOASO	KAMA_7+7+QP+3		0,02279344	48,88888889
TOASO	KAMA_7+7+LP+1		0,02311314	50,66666667
TOASO	EMA_7+7+QP+3		0,02331814	45,85185185
TOASO	EMA_9+9+LP+3		0,02374409	52,09259259
TOASO	EMA_15+15+QP+3		0,02587038	49,66666667
TOASO	EMA_9+9+QP+3		0,02592300	50,24074074
TOASO	KAMA_15+15+LP+5		0,02628665	48,75925926
TOASO	KAMA_15+15+QP+3		0,02691927	49,44444444
TOASO	EMA_5+5+LP+5		0,02794290	50,92592593
TOASO	KAMA_5+5+LP+3		0,02882210	57,11111111
TOASO	KAMA_7+7+QP+5		0,02952143	56,29629630
TOASO	EMA_5+5+QP+3		0,02961576	53,33333333
TOASO	KAMA_9+9+LP+1		0,02964141	57,07407407
TOASO	EMA_3+3+LP+5		0,02989638	50,55555556
TOASO	EMA_7+7+LP+5		0,03125402	56,57407407
TOASO	EMA_3+3+QP+5		0,03170287	52,64814815
TOASO	KAMA_3+3+LP+5		0,03374381	60,94444444
TOASO	EMA_9+9+LP+5		0,03378932	58,03703704
TOASO	KAMA_9+9+QP+1		0,03584488	65,18518519
TOASO	KAMA_15+15+QP+5		0,03717464	61,62962963
TOASO	KAMA_7+7+LP+3		0,03747511	65,00000000
TOASO	EMA_15+15+QP+5		0,03809911	57,16666667
TOASO	KAMA_5+5+LP+5		0,03910228	65,94444444
TOASO	KAMA_30		0,04147014	48,77777778
TOASO	KAMA_3+3+QP+3		0,04277584	63,42592593
TOASO	KAMA_9+9+LP+3		0,04303209	67,87037037
TOASO	KAMA_3+3+QP+5		0,04461042	62,79629630
TOASO	EMA_7+7+QP+5		0,04714895	64,31481481
TOASO	EMA_9+9+QP+5		0,05128845	64,98148148
TOASO	KAMA_9+9+QP+3		0,05165265	74,55555556
TOASO	KAMA_7+7+LP+5		0,05174936	74,24074074
TOASO	EMA_5+5+QP+5		0,05255690	66,87037037
TOASO	KAMA_9+9+LP+5		0,05446651	74,38888889
TOASO	KAMA_9+9+QP+5		0,06480440	78,66666667
TOASO	EMA_30		0,12673798	80,48148148

Hisse Adı	Method	Accuracy	MSE	Rank
ENKAI	YDS		0,00275913	20,44444444
ENKAI	YDAS		0,00280148	20,98148148
ENKAI	Şimdi		0,00289539	20,75925926
ENKAI	YD		0,00313638	22,53703704
ENKAI	RF_Tuned	0,05555556	0,00319172	21,62962963
ENKAI	EMA_3		0,00325885	23,16666667
ENKAI	Açılış		0,00404703	24,00000000
ENKAI	EMA_5		0,00408720	25,35185185
ENKAI	Düşük		0,00408780	27,22222222
ENKAI	EMA_7		0,00505133	27,92592593
ENKAI	KAMA_3		0,00532041	29,85185185
ENKAI	Yüksek		0,00542501	34,75925926
ENKAI	EMA_3+3+LP+1		0,00595942	32,22222222
ENKAI	EMA_5+5+QP+1		0,00600978	31,79629630
ENKAI	KAMA_5		0,00608081	27,05555556
ENKAI	EMA_9		0,00610722	31,33333333
ENKAI	KAMA_7		0,00623566	32,31481481
ENKAI	EMA_12		0,00725618	34,74074074
ENKAI	KAMA_9		0,00736934	35,66666667
ENKAI	KAMA_12		0,00815594	36,85185185
ENKAI	KAMA_3+3+LP+1		0,00823635	35,64814815
ENKAI	EMA_15		0,00840651	37,77777778
ENKAI	KAMA_5+5+QP+1		0,00844757	37,00000000
ENKAI	RF_Default	0,03703704	0,00875976	37,46296296
ENKAI	EMA_7+7+QP+1		0,00969101	34,01851852
ENKAI	EMA_5+5+LP+1		0,01003531	35,16666667
ENKAI	KAMA_15		0,01027729	40,55555556
ENKAI	EMA_9+9+QP+1		0,01108550	35,31481481
ENKAI	KAMA_9+9+QP+1		0,01126822	34,53703704
ENKAI	EMA_3+3+LP+3		0,01166644	36,51851852
ENKAI	EMA_7+7+LP+1		0,01184967	33,92592593
ENKAI	EMA_9+9+LP+1		0,01358497	35,44444444
ENKAI	KAMA_3+3+LP+3		0,01407057	36,57407407
ENKAI	EMA_15+15+QP+1		0,01440151	38,11111111
ENKAI	KAMA_15+15+QP+1		0,01450034	38,83333333
ENKAI	KAMA_7+7+LP+1		0,01481619	36,83333333
ENKAI	KAMA_9+9+LP+1		0,01488985	39,09259259
ENKAI	KAMA_7+7+QP+1		0,01534629	39,81481481
ENKAI	EMA_3+3+QP+1		0,01583538	40,61111111
ENKAI	KAMA_5+5+LP+1		0,01656135	41,48148148
ENKAI	KAMA_3+3+QP+1		0,01795677	44,14814815
ENKAI	KAMA_7+7+QP+3		0,01821872	40,88888889
ENKAI	EMA_5+5+LP+3		0,01861535	42,22222222
ENKAI	EMA_7+7+LP+3		0,01950305	43,31481481
ENKAI	KAMA_5+5+QP+3		0,01951107	44,94444444

Tablo devamı

Hisse Adı	Method	Accuracy	MSE	Rank
ENKAI	KAMA_3+3+LP+5		0,01970216	43,03703704
ENKAI	KAMA_7+7+QP+5		0,01972422	42,57407407
ENKAI	KAMA_9+9+QP+3		0,02003286	42,61111111
ENKAI	KAMA_7+7+LP+3		0,02020125	41,44444444
ENKAI	KAMA_3+3+QP+3		0,02057227	47,55555556
ENKAI	KAMA_15+15+LP+1		0,02072218	46,85185185
ENKAI	EMA_9+9+LP+3		0,02086718	45,50000000
ENKAI	KAMA_9+9+LP+3		0,02089802	42,11111111
ENKAI	EMA_5+5+QP+3		0,02106802	47,42592593
ENKAI	EMA_3+3+LP+5		0,02177868	44,94444444
ENKAI	EMA_15+15+QP+3		0,02235446	47,18518519
ENKAI	KAMA_5+5+LP+3		0,02324677	45,53703704
ENKAI	KAMA_9+9+QP+5		0,02326136	50,27777778
ENKAI	EMA_15+15+LP+1		0,02342222	51,55555556
ENKAI	EMA_3+3+QP+3		0,02349570	47,40740741
ENKAI	KAMA_15+15+QP+3		0,02538105	50,51851852
ENKAI	EMA_15+15+QP+5		0,02579300	47,25925926
ENKAI	EMA_7+7+LP+5		0,02583995	48,20370370
ENKAI	KAMA_7+7+LP+5		0,02589218	46,98148148
ENKAI	EMA_9+9+LP+5		0,02610732	49,31481481
ENKAI	EMA_5+5+LP+5		0,02636910	50,24074074
ENKAI	KAMA_15+15+QP+5		0,02727387	49,75925926
ENKAI	KAMA_3+3+QP+5		0,02786976	53,48148148
ENKAI	KAMA_5+5+LP+5		0,02927026	51,40740741
ENKAI	EMA_7+7+QP+3		0,02937913	53,46296296
ENKAI	EMA_3+3+QP+5		0,02960115	52,20370370
ENKAI	KAMA_9+9+LP+5		0,02970624	47,33333333
ENKAI	EMA_9+9+QP+3		0,02984768	52,22222222
ENKAI	EMA_15+15+LP+3		0,03047213	58,33333333
ENKAI	KAMA_15+15+LP+3		0,03076212	52,50000000
ENKAI	KAMA_5+5+QP+5		0,03444494	57,96296296
ENKAI	EMA_15+15+LP+5		0,03695685	62,61111111
ENKAI	KAMA_15+15+LP+5		0,04296280	57,74074074
ENKAI	EMA_5+5+QP+5		0,04481087	65,50000000
ENKAI	KAMA_30		0,05558951	58,35185185
ENKAI	EMA_9+9+QP+5		0,05611146	70,07407407
ENKAI	EMA_7+7+QP+5		0,06087874	70,57407407
ENKAI	EMA_30		0,09993884	70,92592593

Hisse Adı	Method	Accuracy	MSE	Rank
PETKM	Şimdi		0,00335548	21,00000000
PETKM	RF_Default	0,00000000	0,00357487	23,25925926
PETKM	YDS		0,00394115	22,66666667
PETKM	RF_Tuned	0,01851852	0,00398717	23,59259259
PETKM	YD		0,00403470	22,44444444
PETKM	Yüksek		0,00406545	24,38888889
PETKM	YDAS		0,00469801	24,88888889
PETKM	Açılış		0,00575981	28,53703704
PETKM	EMA_3		0,00626125	28,74074074
PETKM	Düşük		0,00683760	30,42592593
PETKM	EMA_3+3+LP+1		0,00857043	34,14814815
PETKM	KAMA_3+3+LP+1		0,00872577	32,00000000
PETKM	EMA_5+5+QP+1		0,00902868	32,79629630
PETKM	KAMA_3		0,00968948	33,55555556
PETKM	KAMA_5+5+QP+1		0,00991121	33,22222222
PETKM	EMA_7+7+QP+1		0,01058205	37,01851852
PETKM	EMA_5		0,01077859	36,31481481
PETKM	KAMA_7+7+QP+1		0,01111030	31,88888889
PETKM	KAMA_3+3+QP+1		0,01131736	33,59259259
PETKM	KAMA_5+5+LP+1		0,01218342	33,22222222
PETKM	KAMA_5+5+QP+3		0,01272270	34,50000000
PETKM	EMA_7+7+QP+3		0,01316186	34,16666667
PETKM	KAMA_3+3+LP+3		0,01342839	34,81481481
PETKM	EMA_5+5+LP+1		0,01342920	38,87037037
PETKM	EMA_9+9+QP+1		0,01361737	39,50000000
PETKM	EMA_7		0,01419287	39,55555556
PETKM	EMA_3+3+LP+3		0,01420113	34,87037037
PETKM	KAMA_7+7+QP+3		0,01439506	36,79629630
PETKM	KAMA_5+5+QP+5		0,01491435	34,50000000
PETKM	EMA_9+9+QP+3		0,01491911	32,50000000
PETKM	EMA_3+3+QP+1		0,01507580	41,77777778
PETKM	EMA_5+5+QP+3		0,01593256	38,00000000
PETKM	KAMA_3+3+QP+3		0,01605943	39,74074074
PETKM	EMA_7+7+QP+5		0,01643712	35,53703704
PETKM	KAMA_5+5+LP+3		0,01651773	37,38888889
PETKM	KAMA_9+9+QP+3		0,01702386	37,11111111
PETKM	KAMA_30		0,01709490	39,85185185
PETKM	KAMA_7		0,01733615	40,00000000
PETKM	KAMA_9+9+QP+1		0,01738878	41,05555556
PETKM	KAMA_5		0,01741441	47,00000000
PETKM	KAMA_7+7+QP+5		0,01749241	39,00000000
PETKM	KAMA_3+3+LP+5		0,01758365	38,75925926
PETKM	EMA_9		0,01851160	44,68518519
PETKM	EMA_5+5+QP+5		0,01871858	40,62962963
PETKM	EMA_5+5+LP+3		0,01881431	39,92592593

Tablo devamı

Hisse Adı	Method	Accuracy	MSE	Rank
PETKM	KAMA_3+3+QP+5		0,01923418	40,38888889
PETKM	EMA_3+3+LP+5		0,01977052	39,38888889
PETKM	KAMA_9		0,01993946	42,31481481
PETKM	EMA_3+3+QP+3		0,02003747	46,14814815
PETKM	EMA_9+9+QP+5		0,02045123	41,01851852
PETKM	KAMA_12		0,02072195	40,53703704
PETKM	KAMA_9+9+QP+5		0,02110062	41,07407407
PETKM	KAMA_5+5+LP+5		0,02196254	45,18518519
PETKM	EMA_12		0,02269558	48,14814815
PETKM	EMA_7+7+LP+1		0,02474988	47,38888889
PETKM	EMA_3+3+QP+5		0,02532460	49,75925926
PETKM	EMA_15		0,02543515	50,92592593
PETKM	KAMA_15		0,02563626	43,51851852
PETKM	KAMA_7+7+LP+1		0,02622160	47,70370370
PETKM	EMA_5+5+LP+5		0,02697344	48,74074074
PETKM	KAMA_9+9+LP+1		0,02793211	45,53703704
PETKM	EMA_15+15+QP+1		0,02802169	45,83333333
PETKM	KAMA_15+15+QP+1		0,03015332	52,31481481
PETKM	EMA_7+7+LP+3		0,03064757	49,35185185
PETKM	KAMA_15+15+QP+3		0,03075098	49,87037037
PETKM	KAMA_7+7+LP+3		0,03098603	45,50000000
PETKM	KAMA_9+9+LP+3		0,03184752	45,75925926
PETKM	EMA_9+9+LP+1		0,03264276	51,50000000
PETKM	KAMA_15+15+QP+5		0,03387942	51,42592593
PETKM	EMA_15+15+QP+3		0,03519041	53,25925926
PETKM	KAMA_9+9+LP+5		0,03619787	48,85185185
PETKM	KAMA_7+7+LP+5		0,03749619	48,29629630
PETKM	EMA_9+9+LP+3		0,03951909	57,70370370
PETKM	EMA_7+7+LP+5		0,04010949	58,57407407
PETKM	KAMA_15+15+LP+1		0,04285226	53,05555556
PETKM	KAMA_15+15+LP+3		0,04641605	54,64814815
PETKM	KAMA_15+15+LP+5		0,04771546	55,68518519
PETKM	EMA_15+15+QP+5		0,04833990	63,20370370
PETKM	EMA_9+9+LP+5		0,04895536	62,57407407
PETKM	EMA_15+15+LP+1		0,05729991	61,12962963
PETKM	EMA_15+15+LP+3		0,06513904	64,55555556
PETKM	EMA_15+15+LP+5		0,07075880	65,92592593
PETKM	EMA_30		0,16992615	78,70370370

Hisse Adı	Method	Accuracy	MSE	Rank
TCELL	YDS		0,003114077	22,77777778
TCELL	RF_Tuned	0,092592593	0,003145746	21,35185185
TCELL	Şimdi		0,003145746	21,35185185
TCELL	YD		0,003265606	22,5
TCELL	YDAS		0,003697414	23,35185185
TCELL	Açılış		0,004994542	25,38888889
TCELL	KAMA_5		0,005165039	25,18518519
TCELL	EMA_3		0,005366784	25,35185185
TCELL	KAMA_3		0,00546488	26,62962963
TCELL	RF_Default	0	0,006616372	29,81481481
TCELL	EMA_5		0,006849598	28,35185185
TCELL	KAMA_7		0,007457113	26,16666667
TCELL	Yüksek		0,008245992	35,48148148
TCELL	EMA_7		0,008683274	32,18518519
TCELL	KAMA_12		0,008976086	34,96296296
TCELL	KAMA_3+3+LP+1		0,009017403	34,09259259
TCELL	KAMA_5+5+LP+1		0,009386231	30,53703704
TCELL	EMA_5+5+LP+1		0,009687627	32,01851852
TCELL	EMA_9		0,00991049	35,16666667
TCELL	Düşük		0,010146373	38,46296296
TCELL	KAMA_9		0,010222026	36,37037037
TCELL	EMA_7+7+QP+1		0,010348575	34,7962963
TCELL	EMA_3+3+LP+1		0,010590141	37,2037037
TCELL	EMA_9+9+QP+1		0,010953807	33,88888889
TCELL	KAMA_9+9+QP+1		0,011028121	36,53703704
TCELL	EMA_12		0,011116913	36,83333333
TCELL	KAMA_7+7+LP+1		0,01133622	32,75925926
TCELL	KAMA_9+9+QP+3		0,011339758	37,01851852
TCELL	KAMA_5+5+LP+3		0,011640058	34,90740741
TCELL	EMA_15		0,011810313	37,33333333
TCELL	EMA_7+7+LP+1		0,011881986	35,83333333
TCELL	KAMA_7+7+QP+1		0,012055913	34,92592593
TCELL	KAMA_9+9+QP+5		0,012222936	38,51851852
TCELL	KAMA_15		0,012336427	37,40740741
TCELL	KAMA_9+9+LP+1		0,013066661	38,75925926
TCELL	EMA_5+5+LP+3		0,013174466	39,12962963
TCELL	KAMA_7+7+LP+3		0,01367631	38,37037037
TCELL	KAMA_7+7+QP+5		0,013775992	38,5
TCELL	EMA_15+15+QP+1		0,013777424	38,14814815
TCELL	KAMA_7+7+QP+3		0,013909004	40,64814815
TCELL	EMA_5+5+QP+1		0,014087785	43,05555556
TCELL	KAMA_15+15+QP+1		0,014345451	41,37037037
TCELL	KAMA_5+5+LP+5		0,015344922	40,07407407
TCELL	EMA_9+9+LP+1		0,015369743	41,61111111
TCELL	EMA_7+7+LP+3		0,015530792	43

Tablo devamı

Hisse Adı	Method	Accuracy	MSE	Rank
TCELL	KAMA_9+9+LP+3		0,015606061	41,92592593
TCELL	KAMA_5+5+QP+1		0,015898078	42,2962963
TCELL	KAMA_15+15+QP+3		0,016059559	43,98148148
TCELL	EMA_9+9+QP+3		0,016183089	44,37037037
TCELL	KAMA_7+7+LP+5		0,016301776	44,87037037
TCELL	EMA_5+5+LP+5		0,017582814	43,07407407
TCELL	EMA_3+3+QP+1		0,017609231	40,87037037
TCELL	KAMA_15+15+QP+5		0,017871201	46,25925926
TCELL	KAMA_9+9+LP+5		0,018367675	45,94444444
TCELL	KAMA_3+3+LP+3		0,019024125	47,88888889
TCELL	EMA_15+15+QP+3		0,019870848	42,5
TCELL	EMA_9+9+LP+3		0,020854537	48,68518519
TCELL	KAMA_3+3+QP+1		0,020951459	47,44444444
TCELL	KAMA_15+15+LP+1		0,02157395	47,42592593
TCELL	EMA_7+7+LP+5		0,021916659	51,66666667
TCELL	KAMA_3+3+LP+5		0,02191758	49,62962963
TCELL	EMA_3+3+LP+3		0,023567238	48,38888889
TCELL	KAMA_15+15+LP+3		0,025044899	50,68518519
TCELL	EMA_7+7+QP+3		0,025070856	50,61111111
TCELL	EMA_3+3+LP+5		0,027533792	52,66666667
TCELL	KAMA_15+15+LP+5		0,027680338	50,55555556
TCELL	EMA_15+15+QP+5		0,029441141	54,83333333
TCELL	EMA_9+9+LP+5		0,029765096	55,81481481
TCELL	KAMA_5+5+QP+5		0,030346644	55,62962963
TCELL	KAMA_5+5+QP+3		0,030439381	49,94444444
TCELL	EMA_15+15+LP+1		0,033154653	53,53703704
TCELL	EMA_9+9+QP+5		0,033831772	57,5
TCELL	EMA_5+5+QP+3		0,035642093	53,62962963
TCELL	EMA_5+5+QP+5		0,040199738	56,24074074
TCELL	EMA_7+7+QP+5		0,040475463	60,42592593
TCELL	EMA_3+3+QP+3		0,040731694	52,75925926
TCELL	EMA_15+15+LP+3		0,04219413	57,16666667
TCELL	KAMA_30		0,049918347	63,05555556
TCELL	EMA_15+15+LP+5		0,051452788	57,44444444
TCELL	EMA_3+3+QP+5		0,052478203	59,53703704
TCELL	KAMA_3+3+QP+3		0,05577286	59,46296296
TCELL	KAMA_3+3+QP+5		0,063574732	64,33333333
TCELL	EMA_30		0,123425364	72,77777778