



**T.C.
YALOVA ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**

**ENDÜSTRİ MÜHENDİSLİĞİ ANABİLİM DALI
ENDÜSTRİ MÜHENDİSLİĞİ BİLİM DALI**

MAKİNE ÖĞRENMESİNE DAYALI HİSSE SENEDİ DEĞER TAHMİNİ

YÜKSEK LİSANS TEZİ

BURAK HÜSEYİN

DANIŞMAN: DOÇ. DR. İBRAHİM SABUNCU

**YALOVA
OCAK 2024**



T.C.
YALOVA ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

ENDÜSTRİ MÜHENDİSLİĞİ ANABİLİM DALI
ENDÜSTRİ MÜHENDİSLİĞİ BİLİM DALI

MAKİNE ÖĞRENMESİNE DAYALI HİSSE SENEDİ DEĞER TAHMİNİ

YÜKSEK LİSANS TEZİ

BURAK HÜSEYİN
205109029

DANIŞMAN: DOÇ. DR. İBRAHİM SABUNCU

YALOVA
OCAK 2024

ETİK BEYAN

Yalova Üniversitesi Lisansüstü Eğitim Enstitüsü Tez/Proje Yazım Kurallarına uygun olarak hazırladığım “**MAKİNE ÖĞRENMESİNE DAYALI HİSSE SENEDİ DEĞER TAHMİNİ**” başlıklı bu tez çalışmada; tez içinde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi, tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu, tez çalışmada yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi, kullanılan verilerde herhangi bir değişiklik yapmadığımı, bu tezde sunduğum çalışmanın özgün olduğunu bildirir, aksinin tespiti halinde doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi taahhüt ve beyan ederim.

İmza

Burak HÜSEYİN

ÖNSÖZ

Yüksek lisans eğitimim boyunca benden yardımlarını esirgemeyen, akademik anlamda bana her zaman destek olan ve doğru yolu gösteren sayın danışman hocam **Doç. Dr. İbrahim Sabuncu**'ya teşekkür ederim. Ayrıca, desteklerini ve inançlarını hep hissettiren annem, babam ve tüm aileme çok teşekkür ederim.

Aralık – 2023

Burak HÜSEYİN

Makine Mühendisi





İÇİNDEKİLER

ETİK BEYAN	i
ÖNSÖZ	iii
İÇİNDEKİLER	v
SİMGELER ve KISALTMALAR LİSTESİ	viii
TABLolar LİSTESİ	xiii
ŞEKİLLER LİSTESİ	xv
ÖZET	xvii
ABSTRACT	xix
1. GİRİŞ	1
2. LİTERATÜR	5
3. METODOLOJİ VE ANALİZLER	12
3.1. Veri Toplama	12
3.2. Kullanılan Değişkenler	14
3.2.1. Hisse senedi fiyat değişkenleri	14
3.2.2. Teknik indikatörler	14
3.2.3. Temel indikatörler	15
3.2.4. Petrol üretim verileri	15
3.2.5. Küresel Endeksler	18
3.2.6. Diğer Değişkenler	19
3.3. Korelasyon Analizleri	19
3.4. Rapid Miner İle Tahmin Modelleri	26
3.5. Kullanılan Algoritmalar	30
3.5.1. Decision tree	30
3.5.2. Random forrest	31
3.5.3. KNN modeli	32
3.5.4. Neural network	33
3.5.5. Doğrusal regresyon	34
3.5.6. Derin öğrenme modeli	34
3.5.7. Gradyan arttırılmış ağaç modeli	35
3.5.8. SVM	36
3.5.9. K katmanlı çapraz doğrulama	37
4. BULGULAR	38

5. SONUÇLAR	45
KAYNAKLAR.....	49
ÖZGEÇMİŞ	58





SİMGELER ve KISALTMALAR LİSTESİ

SİMGELER

Σ : Toplam sembolü

KISALTMALAR

ADA	: AdaBoost Classifier
ADX	: Average Directional Index
ANN	: Artificial Neural Network
ATR	: Average True Range
BC	: Bagging Classifier
BIST	: Borsa İstanbul
BP	: Back Propagation
CAC	: Cotation Assistée en Continue
CCI	: Commodity Channel Index
DAX	: Deutscher Aktienindex
EBIT	: Earnings Before Interest Taxes
EBITDA	: Earnings Before Interest Taxes, Depreciation and Amortization
ET	: Extra Tree
EV	: Enterprise Value
FVAÖK	: Faiz ve Vergi Öncesi Kâr
FTSE	: Financial Times Stock Exchange
GBM	: Gradient Boosting Machines
GBT	: Gradient Boosting Trees
GE	: Gradient Evolution
GSYİH	: Gayri Safi Yurt İçi Hasıla
LS	: Least-Squares
LSTM	: Long Short-term Memory
MACD	: Moving Average Convergence/Divergence
MFI	: Money Flow Index
MSE	: Mean Squared error
NASDAQ	: National Association of Securities Dealers Automated Quotations
NSE	: National Stock Exchange of India Limited
NYSE	: New York Stock Exchange
OBV	: On-Balance Volume
P/E	: Price to Earnings
PEG	: Price/Earnings-to-Growth
RF	: Random Forrest
RMSE	: Root-Mean-Square Error
RNN	: Recurrent Neural Networks
ROA	: Return on Assets
ROE	: Return on Equity
ROIC	: Return on Invested Capital
RSI	: Relative strength index
SHEL	: Shell
SMA	: Simple Moving Average
SO	: Stokastik Osilatör

SPNY	: Sony Group Corporation
SVM	: Support Vector machine
SVR	: Support Vector Regression
TTE	: Total Enerji
TUPRS	: Tüpraş
USO	: United States Oil Fund
VC	: Voting Classifier
W%R	: Williams %R
WMA	: Weighted Moving Averages
WTI	: West Texas Intermediate
XELKT	: Bist Elektrik
XKMYA	: Bist Kimya Petrol Plastik







TABLÖLER LİSTESİ

Tablo 3.1. Tüpraş için Yüklenen Veri Seti	14
Tablo 3.2. Tahminlerde kullanılan değişkenler.....	22
Tablo 3.3. Tahminlerde kullanılan değişkenler.....	22
Tablo 3.4. Tüpraş korelasyon analizi	24
Tablo 3.5. Total korelasyon analizi.....	25
Tablo 3.6. Shell korelasyon analizi	25
Tablo 3.7. Omv korelasyon analizi	26
Tablo 3.8. Chevron korelasyon analizi	27
Tablo 3.9. Tüpraş için veri seti.....	28
Tablo 4.1. Omv fiyat tahmini.....	41
Tablo 4.2. Chevron farklı algoritmalar analiz sonuçları	45
Tablo 4.3. Omv farklı algoritmalar analiz sonuçları	45
Tablo 4.4. Shell farklı algoritmalar analiz sonuçları.....	46
Tablo 4.5. Total farklı algoritmalar analiz sonuçları.....	46
Tablo 4.6. Tüpraş farklı algoritmaların analiz sonuçları.....	46



ŞEKİLLER LİSTESİ

Şekil 2.1. Metodoloji.....	13
Şekil 3.1. Tüpraş hisse fiyat verisi	14
Şekil 3.2. Verilerin rapid miner'a aktarılması.....	21
Şekil 3.3. Rapid miner auto model korelasyon analizi.....	21
Şekil 3.4. Rapid miner modeli korelasyon sonuçları	23
Şekil 3.5. Verilerin sisteme yüklenmesi.....	28
Şekil 3.6. Rapid miner veri yükleme operatörü	28
Şekil 3.7. Tahmin algoritmalarında kullanılacak özelliklerin seçilmesi.....	29
Şekil 3.8. Set role operatörü	29
Şekil 3.9. Split data operatörü	30
Şekil 3.10. Rapid miner tahmin algoritması genel görünümü	31
Şekil 3.11. Şematik karar ağacı gösterimi.....	32
Şekil 3.12. Şematik rastgele orman gösterimi.....	32
Şekil 3.13. Şematik knn algoritması gösterimi	34
Şekil 3.14. Şematik üç katmanlı sinir ağı.....	34
Şekil 3.15. 10 katlamalı çapraz doğrulamalı test	38
Şekil 4.1. Write excel operatörü.....	41
Şekil 4.2. Rapid miner omv random forrest tahmin sonuçları	41
Şekil 4.3. Omv tahmin ve gerçek fiyat grafiği	42
Şekil 4.4. Shell tahmin ve gerçek fiyat grafiği.....	43
Şekil 4.5. Chevron tahmin ve gerçek fiyat grafiği	43
Şekil 4.6. Total tahmin ve gerçek fiyat grafiği.....	44
Şekil 4.7. Tüpraş tahmin ve gerçek fiyat grafiği.....	44



MAKİNE ÖĞRENMESİNE DAYALI HİSSE SENEDİ DEĞER TAHMİNİ

ÖZET

Bu çalışmada, beş farklı ülkede (Türkiye, Fransa, Amerika, Avusturya ve İngiltere) petrol rafineri sektöründe faaliyet gösteren şirketlerin fiyat analizleri ve fiyatını etkileyen değişkenlerin önem düzeyleri ile ilgili araştırmalar gerçekleştirilmiştir. Araştırmanın amacı, çeşitli bağımsız değişkenleri kullanarak bağımlı değişken olan hisse fiyatını tahmin etmektir. Bağımlı değişken ile altı kategoride toplam 74 bağımsız değişken arasındaki ilişki incelenmiştir. Bu kategoriler teknik göstergeler, temel göstergeler, ülke endeksleri, fiyatla ilgili değişkenler, petrol üretim verileri, petrol fiyatı ve döviz kurları şeklindedir. Her bir hisse ile incelenen değişkenler arasında korelasyon analizleri gerçekleştirilmiştir. Korelasyon analizleri için Rapid Miner Auto Model modülü kullanılmıştır. Özellikle beş farklı hisse türü için fiyatla ilgili değişkenler arasında anlamlı sonuçlara rastlanmıştır. En düşük korelasyon değerine sahip değişkenler teknik göstergeler ve petrol üretim veriler olmuştur. En güçlü ilişkiler ise temel göstergeler, ülke endeksleri olarak tespit edilmiştir. Araştırmada tahmin edilmeye çalışılan hisse fiyatları için hangi değişkenlerin önemli olduğu sorusuna yanıt aranmıştır.

Tahminler Rapid Miner programı kullanılarak gerçekleştirilmiştir. Çalışmada kullanılan algoritmalar: Lineer Regresyon, Karar Ağacı, Derin Öğrenme, Rastgele Orman, Gradyan Artırma, KNN, Neural Network ve Destek Vektör Makinesi (SVM)'dir. Bu tahminlerin doğruluğunu değerlendirmek için kök ortalama kare hata (RMSE), ortalama mutlak hata (MAE) ve ortalama mutlak yüzde hata (MAPE) gibi değerlendirme metrikleri kullanılmıştır. Chevron, OMV, Total ve Tüpraş şirketleri için en iyi sonuçlar SVM yöntemi ile elde edilmiştir. Shell şirketi için ise en iyi sonuç, Neural Network yöntemi ile bulunmuştur.

Elde edilen bulgulara dayanarak, en iyi sonuçlar genellikle Destek Vektör Makinesi (SVM) yöntemi ile elde edilmiştir. Fakat her hisse türü için her ülkede uygulanabilecek tek bir en iyi yöntem olmadığı açıktır. Bu nedenle en doğru tahminleri üretmek için, belirli bir ülke ve değerlendirilen hisse senedi temel alınarak en uygun yöntemin belirlenmesi gereklidir. Yapılan bu çalışma ile emtia bazlı şirketlere yatırım yapan yatırımcılar için önemli değişkenlerin hangileri olduğu ve yatırımcılar hangi algoritmaları kullanmaları durumunda en yüksek verimlilikle yatırımlarını gerçekleştirir sorularına yanıt aranmıştır.

Anahtar Kelimeler: Tahmin yöntemleri, Borsalar, Makine Öğrenmesi, Derin Öğrenme, Ağaç tabanlı yöntemler



MACHINE LEARNING-BASED STOCK PRICE PREDICTION

ABSTRACT

In this study, research has been conducted on the price analyses of companies operating in the petroleum refinery sector in five different countries (Turkey, France, America, Austria, and England) and the significance levels of variables affecting the price. The aim of the research is to predict the stock price, which is the dependent variable, using various independent variables. The relationship between the dependent variable and a total of 74 independent variables in six categories has been examined. These categories include technical indicators, fundamental indicators, country indices, price-related variables, oil production data, oil prices, and exchange rates. Correlation analyses have been conducted between the variables examined with each stock. The Rapid Miner Auto Model module has been used for correlation analyses.

Significant results have been found among the price-related variables for five different stocks. The variables with the lowest correlation values were technical indicators and oil production data. The strongest relationships were identified as fundamental indicators and country indices. The research aimed to answer the question of which variables are important for predicting stock prices.

Predictions were made using the Rapid Miner program. The algorithms used in the study are Linear Regression, decision tree, deep learning, random forest, gradient boosting, KNN, artificial neural network, and SVM. Evaluation metrics such as RMSE, MAE, and MAPE were used to assess the accuracy of these predictions. The best results for Chevron, OMV, Total, and Tüpraş companies were obtained with the SVM method. For Shell, the best result was found with the artificial neural network method.

Keywords: Prediction methods, Stock markets, Machine Learning, Deep Learning, Tree-based methods



1.GİRİŞ

Borsa, ülke ekonomileri için önemli bir sektördür [1]. Borsalar dört yüzyılı aşkın süredir varlığını sürdürmektedir. 1602 yılında, Hollanda Doğu Hindistan Şirketi'nin kurulmasından kısa bir süre sonra Hollanda'da ilk borsa kurulmuştur. Günümüzde birçok modern ülkenin finansal piyasası bulunmaktadır [2]. Yatırımcılar borsalara yatırımlar yapmakta ve yatırımlarından getiri elde etmektedirler. Borsanın tahmin edilmesi, istatistik, yapay zekâ, ekonomi ve finans gibi birçok alandan araştırmacıların ilgisini çekmiştir [1].

Hisse senedi piyasası doğası gereği dinamik, öngörülemeyen ve doğrusal olmayan bir şekilde karakterize edilir. Hisse fiyatlarını tahmin edilebilmesi, politik koşullar, küresel ekonomi, şirketin mali raporları ve performansı gibi çeşitli faktörlere bağlıdır. Ve zor bir işlemdir [3].

Borsa hızlı değişimlere açıktır ve hisse fiyatlarında rastgele dalgalanmalar mevcuttur. Borsalardaki fiyat hareketleri, kısa zaman aralıklarında daha belirgin olan dalgalanmalarla birlikte rastgele bir süreç olarak kabul edilmektedir. Bazı hisse senetleri genellikle uzun vadeli zaman aralıklarında doğrusal eğilimler gösterebilmektedir. Hisse davranışının kaotik ve oldukça oynak doğası nedeniyle, yapılan yatırımlar yüksek risk içermektedir [4].

Yatırımlardaki riski en aza indirmek için gelecekteki hisse fiyat hareketlerine ilişkin ileri seviye bilgi gereklidir. Sermaye kazancını maksimize etmek ve kaybı en aza indirmek için hisse piyasası fiyatlarındaki trendleri doğru bir şekilde tahmin edilmesi gerekmektedir.[4]

Tahmin algoritmalarının keşfi ile hisse fiyat davranışlarının tahmin edilebileceği gösterilmiştir. Fakat hisse senedi piyasasının davranışının tahmin edilmesi zor bir görevidir. Çünkü piyasalar karmaşık bir yapıya sahiptir. Piyasa, yatırımcıların duyguları, siyasi olaylar ve genel ekonomik koşullar gibi farklı durumlardan etkilenebilmektedir [1].

Borsanın doğru bir şekilde tahmin edilmesi, piyasada yatırım riskini azaltabilir [1]. Piyasalardaki trendleri, piyasaları anlamak ve fiyatların tahmin edilebilmesi için çok sayıda teori ve çalışma geliştirilmiştir [2]. Fakat literatürde fiyat tahmin çalışmalarının yanında fiyatların tahmin edilemeyeceği kabul eden yaklaşımlar da mevcuttur.

Eugene Fama, fiyatların öngörülelemeyeceğini savunmuştur. Literatüre bu konuda önemli katkılar kazandırmıştır. Fama tarafından literatüre kazandırılan etkin piyasa yaklaşımı, fiyat hareketlerinin rastlantısal ve tahmin etmenin mümkün olmadığını savunmaktadır. Fama'ya göre bilgi her zaman yatırım enstrümanlarının fiyatlamalarına yansımaktadır [102]. Bilgi ve fiyat arasındaki ilişki hakkında konuşurken belirli varsayımlar kabul edilmiştir. Piyasadaki tüm oyuncuların rasyonel olduğu, bilgilere erişimin eksiksiz bir şekilde gerçekleştiği ve elde edilecek faydanın maksimum olacağı görüşü kabul edilmiştir [104].

Fakat Fama'nın aksine hisse fiyatının kısmen öngörülebilir olduğuna inanan birçok ekonomist ve istatistikçi de mevcuttur. Bu görüşü savunan araştırmacılar geçmiş fiyatlar ve temel değerlendirme ölçütlerini kullanarak gelecek fiyatların belirlenebileceğini savunmuşlardır [103]. Etkin piyasa hipotezine karşıt görüşlerin temelinde insanların her zaman rasyonel davranamayacağı, teknolojik gelişmeler gibi kavramlar mevcuttur.

Etkin piyasa hipotezi, yeni bilginin piyasaya hızla yayılacağı ve bu bilginin fiyatlara direk olarak etki edeceğini kabul eder. Etkin piyasalar hipotezine göre teknik analiz ve temel analiz yöntemleri kullanılarak elde edilen getiri, rastgele bir şekilde oluşturulan bir portföyden elde edilen getiriden daha yüksek olamayacağını savunur [103]. Ancak teknolojinin gelişmesiyle Fama'nın görüşleri eleştirilmeye başlanmıştır. Teknik ve temel analiz, zaman serisine dayalı tahminler ve makine öğrenme algoritmaları kullanılarak fiyatların öngörülebilmesi için çalışmalar gerçekleştirilmiştir.

Yatırımcıların tamamıyla rasyonel olarak kabul edilmesi gibi varsayımlar etkin piyasa hipotezinin yöneltilecek eleştirilerden olmuştur. Fakat insan yapısı gereği her zaman rasyonel olamamaktadır [99]. Etkin piyasa hipotezini eleştirenlere göre insan her zaman değil ama genellikle irrasyonel olarak yatırım davranışları sergilediğini savunmuştur.

Grossman ve Stiglitz, tarafından etkin piyasa hipotezine yöneltilecek bir diğer eleştiri ise eğer piyasalar güçlü formda etkin ise yatırımcıların bu piyasadan kazanç sağlayamayacağını ve piyasanın çökeceğini söylemişlerdir. Fakat bu şekilde kazanç sağlanamayan ve çöken piyasa mevcut değildir. Ayrıca araştırmacılar bilginin maliyetli olması ve herkes tarafından ulaşılmasının mümkün olmaması gibi sebeplerle

bilginin tam etkin olduđu piyasanın mümkün olamayacağını çalışmalarında savunmuşlardır [100].

Fakat Etkin piyasa hipotezi bilginin maliyetsiz bir şekilde herkes tarafından ulaşılabilceğinden bahsetmiştir. Bilgi üretim süreci zahmetli ve maliyetlidir. Bu yüzden bu bilgi herkes ile paylaşılmaz. Ve bu kıymetli bilgiler piyasadan saklanacağı için etkin piyasa hipotezinin savunduđu şekilde bilgi tam olarak fiyatlara yansımayacaktır [98].

Bu çalışmada etkin piyasa hipotezinin aksine fiyatların tahmin edilebilirliği kısmen mümkün olduđu görüşü savunulmuştur. Bu amaç doğrultusunda fiyatların tahmin edilebildiği düşünülerek bu konuyla ilgili literatüre bu çalışma ile katkı oluşturulmaya çalışılmıştır. Bu araştırmada tahminler makine öğrenme yöntemleriyle gerçekleştirilecektir.

Finansal literatürde, fiyat tahmini yöntemleri: teknik analiz, temel analiz ve zaman serisine dayalı tahminler ve makine öğrenmesi olmak üzere dört ana grupta incelenmektedir. [3]

Teknik analiz yöntemi, hisse senedinin gelecekteki fiyatını tahmin etmek için hissenin kapanış ve açılış fiyatı, işlem hacmi vb. Hisse senedinin tarihsel fiyatını kullanır [3]. Teknik analiz yöntemiyle tarihsel fiyatlar kullanılarak hissenin gelecekteki fiyat tahmini yapılır. Hareketli ortalama gibi farklı yöntemler mevcuttur. Bu yaklaşım kısa vadeli tahminler için iyi çalışır [5].

Temel analiz yönteminde ise şirket profili, piyasa durumu, politik ve ekonomik faktörler, dışsal makroekonomik faktörler dikkate alınmaktadır [3]. Temel analiz, bir şirketin hisse değerini satışlar, kazançlar, şirket karlılığı ve diğer ekonomik yönlerini inceleyerek hesaplanan bir çalışma türüdür [5]. Bu yöntem özellikle uzun vadeli yatırımlar için kullanılır. Ayrıca temel analiz rasyoları kullanılarak şirketlerin finansal olarak birbirleriyle karşılaştırması yapılabilir [17].

Zaman serileri ise birçok alanda kullanılan, istatistik ve ekonometrinin önemli bir uygulama alanıdır. Zaman serisi modelleri genellikle regresyon modeline benzemesine rağmen, temel varsayımlar yönünden farklılık gösterir (Akdi, 2003).

Hisse fiyatı tahmin mekanizmaları, yatırım stratejilerinin oluşturulması ve risk yönetimi modellerinin geliştirilmesi için önem arz etmektedir [7]. Hisse piyasalarının

etkin işleyişi, piyasada kısa süreli hisse alım satımı yaparak piyasayı likit tutan piyasa araçlarına ihtiyaç duyar. Kısa vadeli fiyat hareketleri için iyi tahminlerde bulunan makine öğrenme algoritmaları önerilmiştir [8].

Makine öğrenim modelleri, zaman serisi verilerinde gizli desenleri bulabilme yeteneğine sahiptir [1]. Makine öğrenmesi, tarihsel verilerde yeni desenler keşfederek, bu verilerde var olan doğrusal ve doğrusal olmayan modelleri kullanarak fiyatları tahmin etmeyi amaçlar [9]. Makine öğrenme teknikleri, geçmiş yöntemlere kıyasla tahminlerdeki verimliliği %60 ila %86 oranında artırdığı kanıtlanmıştır [3]. Makine öğrenmesi yaklaşımı, sistemlerin programlanmasına gerek kalmadan büyük miktardaki geçmiş veriden otomatik olarak öğrenme yeteneğine sahiptir. Makine öğrenme modelleri, literatürde temel ve teknik analizlerden daha iyi performanslar gösterdiği gözlenmiştir [1].

Hisse senedi piyasaları eskiden genellikle finans uzmanları tarafından tahmin edilirdi. Fakat makine öğrenme tekniklerinin gelişmesiyle veri bilimcileri de tahmin problemleriyle uğraşmaya başlamıştır. Ayrıca, bilgisayar bilimcileri de tahmin modellerinin performansını ve tahminlerin doğruluğunu artırmak için makine öğrenme yöntemlerini kullanmaya başlamışlardır [10]. Bu konuya farklı alanlardan birçok araştırmacının ilgi duymasına neden olmuştur. Bu çalışmayı yapmaya iten nedenlerden biri de budur.

İlk olarak, hisse senetlerinin performansını etkileyebilecek bazı önemli faktörler seçilmelidir. Ardından, veri seti kullanılarak farklı modeller, algoritmalar kullanılabilir. Böylece bir hisse fiyatı gelecekteki performansı tahmin edilebilir [11]. Bu çalışma da benzer çalışmalar incelenerek petrol rafineri sektöründe faaliyet gösteren şirketlerin hisse fiyatını etkileyebilecek önemli faktörler tespit edilmiştir.

Finansta, firma politikaları, siyasi olaylar, genel ekonomik koşullar ve işletmelerin beklentileri gibi birçok makroekonomik konu hisse senedi piyasasının hareketlerini etkileyebilmektedir [12]. Ayrıca, emtia fiyat endeksi, banka faiz oranı, banka döviz kuru, yatırımcı beklentileri, kurumsal yatırımcıların tercihleri, diğer hisse senedi piyasalarının hareketleri, yatırımcıların psikolojisi vb. gibi birçok makroekonomik faktörden etkilenebilmektedir [13].

Petrol, dünya ekonomisinde giderek önemli bir rol oynamaktadır. Çünkü dünya enerji tüketiminin neredeyse üçte ikisi ham petrol ve doğal gazdan karşılanmaktadır. Keskin

petrol fiyat hareketleri, özellikle Ocak 2004'ten bu yana küresel petrol fiyatlarının hızla yükselmesi ve küresel ekonomi için dramatik belirsizlik getirmesi nedeniyle toplam ekonomik faaliyeti rahatsız edebilmektedir [14]. Bu nedenle, oynak petrol fiyatları bu konudaki belirsizlik; bu alanda yatırım yapan kişilerin risklerini azaltmak için birçok araştırmacı ve kurum için oldukça ilgi çekici bir konudur. Bu yüzden bu çalışmada emtia bazlı petrol sektöründe faaliyet gösteren şirketler incelenmiştir.

Ham petrol fiyatı temel olarak arz ve talebine bağlı olsa da hava durumu, stok seviyeleri, GSYİH büyümesi, siyasi etkenler gibi birçok olaydan da etkilenebilmektedir [14]. Bu çalışmada incelenen şirketlerin performansını etkileyebilecek petrol stok seviyeleri, petrol fiyatları gibi veriler çalışmada girdi olarak kullanılmıştır.

Ham petrol, neredeyse dünyanın her bölgesi için en önemli emtialardan biridir. Fiyatındaki değişiklikler, dünya ekonomileri üzerinde büyük etkiye sahiptir [15]. Ayrıca küreselleşme ile mal ve hizmet fiyatlarının birbiri üzerindeki etkilerinin belirgin bir şekilde artmasına yol açmıştır. Diğer mallar veya hizmetler üzerinde büyük bir etkiye sahip olan malların başında ham petrol gelmektedir. Ham petrol bugün dünya çapında ticareti yapılan en önemli emtia olarak kabul edilmektedir. Ayrıca küresel ekonominin neredeyse her sektörü ham petrole bağımlıdır [16]. Bu gibi nedenlerle petrol sektöründe faaliyet gösteren şirketlerin bu araştırma için seçilmiştir.

Hisse senedi değer tahmini kapsamında temel analiz değişkenleri, teknik analiz değişkenleri, hisse fiyatıyla ilgili değişkenler, makro ekonomik faktörler gibi birçok farklı kategoriden değişkenin kullanıldığı çalışmalar mevcuttur. Bu çalışmada petrol rafineri sektöründe faaliyet gösteren şirketler için farklı kategorilerdeki değişkenler ve hisse senedi fiyatı arasında korelasyon araştırılmıştır.

Bu çalışmada Uluslararası Petrol Rafineri Firmaları: Tüpraş, OMV, Shell, Total Enerji ve Chevron şirketlerinin verileri kullanılmıştır. Bu veriler investing [17] ve ycharts [18] siteleri üzerinden elde edilmiştir. Bu veriler ile hisse fiyatı arasında ilişki olup olmadığı araştırılmıştır. Çalışma sonucunda sektöre, ülkeye, borsaya hatta hisse senedine bağlı olarak farklı değişkenler farklı parametreler, farklı teknik indikatörler kullanılarak farklı algoritmalar ile tahmin yaklaşımı gerçekleştirilmesi gerekliliği sonucuna varılmıştır.

Bu çalışmanın gerçekleştirilmesindeki neden Türkiye'deki ekonomik gelişmeler olmuştur. Borsa, artık esnafın, memurun vb. farklı meslek gruplarının yatırım aracı haline gelmiştir. Fakat pek çok kişi bu konuda uzmanlığa sahip değildir. Dolayısıyla bu çalışma, amaç olarak bu konuda bilgi birikimi olmayan yatırımcıların doğru yatırım kararları verebilmelerini kolaylaştırmayı hedeflemektedir. Çalışma çıktıları halkın çoğunluğuna fayda sağlayacaktır. Çalışmanın amaç ve motivasyonu yatırımcılar için yardımcı sistemlerin geliştirilmesi, bilgi birikimi eksik yatırımcıların kayıplarını en aza indirmek ve yatırımlarından elde edilebilecek getiriye en yüksek tutmaktır.

Bu çalışmada, uluslararası petrol rafineri firmaları olan Tüpraş, OMV, Shell, Total Enerji ve Chevron şirketlerinin verileri kullanılmıştır. Seçilen şirketler için kullanılan veri setlerinin eksiksiz olması nedeniyle özellikle bu şirketler seçilmiştir. Çalışmaya dahil edilmesi planlanan bazı şirketler, bazı değişken tiplerinde eksi veri bulunması nedeniyle çalışmaya dahil edilememiştir. Seçilen şirket sayısı, bu çalışmanın kısıtı olmuştur.

Bu çalışmada makine öğrenme yöntemlerinin seçilme nedeni literatürde bu yöntemleri ile elde ettiği başarılı sonuçlardır. Gerçekleştirilen bu çalışma ile değişken sayısı ve çeşitliliği artırılarak literatüre bu şekilde katkıda bulunulabileceği hedeflenmektedir. Literatür taramasında incelenen makine öğrenme modellerinden hata oranları açısından üstün modeller bu çalışma için tercih edilmiştir. Decision Trees, Random Forrest, Neural Network, Lineer Regresyon, Derin Öğrenme, Gradient Boosting, SVM algoritmaları bu çalışmada kullanılmıştır. Bu algoritmaların Rapid miner programında mevcut olması ayrıca bu seçimde bir diğer kriter olmuştur.

Sonuç olarak farklı parametreler, farklı teknik indikatörler ve farklı algoritmalar kullanılarak hisse değerini tahmin eden algoritmalar sunulmaya çalışılmıştır. Çalışma beş ana bölümden oluşmaktadır. Birinci bölümde çalışmanın amacından bahsedilmektedir. İkinci bölümde, literatürde benzer olan çalışmalar ve literatürde olan çalışmaların içeriklerinden bahsedilmiştir. Çalışmanın üçüncü bölümünde kullanılan metodoloji ve analizlerden bahsedilmektedir. Dördüncü bölümde ise analizler sonucunda elde edilen bulgulardan bahsedilmektedir. Son bölümde ise tahmin modellerinin sonuçları incelenip çalışmada incelenen hisseler ile ilgili önermelerde bulunulmuştur.

2. LİTERATÜR

Gerçekleştirilen çalışmada çok sayıda bağımsız değişken kullanılması durumunda makine öğrenme algoritmalarının tahmini başarısı artıyor mu ve literatürden daha başarılı sonuçların elde edilebiliyor mu gibi sorulara yanıtlar aranmıştır. Bu kullanılan bağımsız değişkenlerden hangileri fiyat tahmininde daha önemli, yatırım kararları verilirken hangi bağımsız değişkenler daha fazla dikkate alınmalı gibi soruları yanıtlamak için bu çalışma gerçekleştirilmiştir.

Bu konuda yapılmış benzer çalışmalar incelenecektir. Bu çalışmayı gerçekleştiren araştırmacılar hangi değişkenler kullanıldığında fiyat tahmini daha doğru yapılabilir araştırılmıştır. Örneğin yatırımcıların kullandığı investing gibi sitelerde çok sayıda bağımsız değişken mevcut. Yatırımcıların hangi değişkenleri dikkate alacağı ve hangi değişkenlerin önemli olduğu bilinmediği için bu konuda literatür taraması gerçekleştirilmiştir. Hangi bağımsız değişkenler fiyat tahminlerinde daha etkili araştırılmıştır.

Khashman ve Nwulu, Texas Ham petrol haftalık fiyatının 1986-2009 yılları arasındaki haftalık fiyat verisini kullanmıştır. SVM algoritmasını kullanarak tahminlerini gerçekleştirmişlerdir. Ham petrol fiyatını varil başına 5\$ hassasiyet ile tahminlerini gerçekleştirmişlerdir [16].

Başka bir çalışmada Das ve Padhy, Amerika'dan 1 ve Hindistan'dan 2 endeksin 3 yıllık fiyat verisini kullanarak hisse fiyat tahminleri gerçekleştirmiştir. Çalışmada kullanılan bağımsız değişkenler hissenin tavan, taban, açılış, kapanış ve hacim gibi değerleridir. Çalışmada BP ve SVM modelleri kullanılmıştır. SVM modeli daha üstün sonuçlar elde etmiştir [19].

Benzer bir diğer çalışmada Shen ve diğerleri, NASDAQ, S&P500, DJIA indeks, Nikkei 225, DAX, ASX, EUR, AUD, JPY, USD, Silver, Platinum, ham petrol değişkenlerinin 12 yıllık verisini kullanmıştır. Bağımsız değişkenler kullanılarak hisse fiyatının bir gün sonraki değeri tahmin edilmiştir. SVM makine öğrenme algoritmasını kullanan model daha düşük hata oranları ile tahminleri gerçekleştirmiştir [20].

Bir diğer araştırmada Hegazy ve arkadaşları, Adobe, Oracle, HP, American Express, New York Bankası, Coca-Cola, HoneyWell şirketleri için hisse fiyat tahminleri gerçekleştirmiştir. 3 yıllık tarihsel fiyat verisi ve teknik indikatör tipi bağımsız

değişkenler kullanılmıştır. LS-SVM-PSO modeli ile en düşük hata oranı ile tahminler gerçekleştirmiştir [21].

Bir diğer araştırmada Hu ve arkadaşları, 15 şirketin 7 yıllık fiyat verisini kullanmıştır. Makro ekonomik değişkenler ve temel indikatörler çalışmada değişken olarak kullanılmıştır. SVM algoritması kullanılarak gerçekleştirilen tahminler en düşük hata oranları ile gerçekleştirilmiştir [11].

Farklı bir çalışmada ise Patel ve arkadaşları, Random Forrest, SVR, SVR-ANN, SVR-RF ve SVR-SVR hibrit modellerini kullanmışlardır. CNX Nifty ve Hindistan Borsası (BSE)'nin 10 yıllık verisi kullanılmıştır. Teknik indikatörler kullanılarak 10-30 gün ilerisi için tahminler gerçekleştirilmiştir. Kullanılan hata oranlarına göre en iyi tahminler, SVR-ANN hibrit modeli ile gerçekleştirilmiştir [13].

İncelenen bir diğer araştırmada ise Khaidem ve arkadaşları, Nasdaq borsasından Apple, General Elektrik ve Kore Borsasından Samsung gibi şirketlerin RSI, MACD ve OBV gibi teknik indikatörlerini kullanmıştır. 1,2 ve 3 ay sonrasının fiyatları tahmin edilmeye çalışılmıştır. Uzun süreli tahminler için %85-95 doğruluk oranlarında tahminler gerçekleştirilmiştir [4].

Başka bir çalışmada Qiu ve Song, ANN ve GA-ANN algoritmalarını kullanarak Japon borsasının bir sonraki gün değeri yükselecek mi düşecek mi sorusuna cevap aramıştır. 6 yıllık veri ve RSI, CCI, ROC ve Skotastik gibi bağımsız değişkenler kullanılarak gerçekleştirilen tahminlerde GA-ANN algoritması en doğru sonuçları vermiştir [22].

Algoritmaların birbiriyle karşılaştırıldığı bir diğer araştırma ise Chen ve He, Ham petrol talep ve arz oranları, aylık GDP gibi oranlarını kullanarak ham petrol fiyat değerleri tahmin edilmeye çalışmıştır. Random Forrest, M5P, CART, MLR ve ARIMA modelleri arasından en iyi tahmin sonuçlarını Random Forrest modeli ile elde edilmiştir [15].

İncelenen başka bir çalışmada Başak ve arkadaşları, 10 şirketin 10 yıllık verilerini kullanmışlardır. Hisse fiyat trend yönü tespit edilmeye çalışılmıştır. Çalışmada OBV, MACD, Skotastik ve RSI indikatörleri kullanılmıştır. Decision Tree, Gradient Boosted ve Random Forest algoritmaları kullanılarak tahminler gerçekleştirilmiştir. Çalışmada teknik göstergeler kullanılarak orta ve uzun vadeli hisse senedi fiyatı yön tahminleri için yüksek doğrulukta tahminler elde edilebileceği sonucuna ulaşılmıştır [23].

Tahmin algoritmalarını birbiriyle karşılaştıran bir diğer araştırma Mallqui ve Fernandes, tavan, taban, kapanış fiyatı, ham petrol, altın fiyatı, S&P 500, Nasdaq ve Alman Borsa Endeksi (DAX) vb. bağımsız değişkenler kullanılarak bitcoin fiyatı tahmin edilmeye çalışılmıştır. ANN, SVM, RNN ve K-Means algoritmaları kullanılarak gerçekleştirilen tahminlerde SVM algoritması diğer yöntemlere göre daha üstün sonuçlar elde etmiştir [24].

Bir diğer çalışmada Henrique ve arkadaşları, Brezilya, Amerika ve Çin'den 18 şirketin 15 yıllık verisini kullanarak çalışmalarını gerçekleştirmişlerdir. SMA, WMA, RSI ve ATR gibi teknik indikatörleri kullanılmıştır. Hisse fiyatı tahmin edilmeye çalışılmıştır. SVM modeli ile gerçekleştirilen tahminler, diğer yöntemlere göre daha üstün sonuçlar elde etmiştir [7].

Bir diğer çalışmada Wang ve arkadaşları, ham petrol fiyatı, doğal gaz, altın, Nasdaq ve S&P 500 gibi endekslerin 7 yıllık verisini kullanılmıştır. MACD, RSI, CCI, OBV ve ADX gibi bağımsız değişkenler kullanılmıştır. Borsa fiyat yönü tahmin edilmeye çalışılmıştır. SVM, MLP, 1-D CNN ve CDT 1-D CNN algoritmaları arasında en iyi performansı CDT 1-D CNN algoritması sergilemiştir [25].

Makine ve derin öğrenme modellerinin kullanıldığı farklı bir çalışmada Nikou ve arkadaşları, İngiltere Döviz Ticareti Fonu 3 yıllık verisini kullanarak hisse değer tahmini gerçekleştirmiştir. Günlük kapanış değerleri bağımsız değişken olarak kullanılmıştır. ANN, SVM, Random Forrest ve Derin Öğrenme metotları kullanılmıştır. Derin öğrenme yöntemleri daha üstün sonuçlar elde etmiştir [9].

Literatürde daha önce yapılan benzer çalışmadan daha düşük hata oranı ile tahminler gerçekleştirmeyi amaçlayan Khashman ve Nwulu, Pakistan Borsası (PSX)'nin 12 yıllık verisini kullanmıştır. Hissenin tavan, taban, açılış, kapanış ve hacim verisi kullanılmıştır. Bu şekilde hisse fiyatı tahmin edilmeye çalışılmıştır. ANN makine öğrenme algoritması RMSE hata oranı açısından literatürden mevcut çalışmadan daha üstün sonuçlar elde etmiştir [26].

Farklı makine öğrenme algoritmaları ve farklı bağımsız değişken kullanıldığı durumların analiz edildiği durumları inceleyen Beyaz ve arkadaşları, S&P 500'den 140 şirketin 19 yıllık fiyat verisi kullanmıştır. Hisse değer tahmini gerçekleştirilmiştir. ATR, MACD, MFI, CCI vb. teknik indikatörler kullanılmıştır. Araştırmada temel indikatör kullanılarak gerçekleştirilen tahminler teknik indikatör kullanılan modellere

göre daha doğru sonuçlar elde etmiştir. Temel ve teknik indikatörlerin birlikte kullanıldığı çalışmalarda elde edilen RMSE değerleri, sadece teknik indikatör veya sadece temel indikatör kullanılan modellere göre daha düşük bulunmuştur [27].

Tahmin algoritmalarını birbiriyle karşılaştırıldığı bir diğer araştırmada ise Vijh ve arkadaşları, Nike, Goldman Sachs, Pfizer ve JP Morgan Chase şirketlerinin 10 yıllık verisini kullanarak bir sonraki günün kapanış değerinin tahmin etmeye çalışmışlardır. ANN ve Random Forrest algoritmaları kullanılmıştır. Hisse fiyatı tavan, taban, açılış, kapanış ve hacim verileri kullanılmıştır. RMSE ve MAPE hata oranlarına göre ANN modeli en düşük hata oranları ile tahminleri gerçekleştirmiştir [3].

Türkiye’de gerçekleştirilen bir çalışmada Pabuççu ve arkadaşları, Bitcoin fiyat endeksini kullanarak bitcoin fiyatı yükselecek mi düşecek mi bu sorunun cevabını araştırmıştır. SVM, ANN, Naive Bayes, Random Forrest ve Lojistik Regresyon modellerini kullanılmıştır. Random Forrest modeli diğer tahmin modelleriyle kıyaslandığında daha üstün sonuçlar elde etmiştir [28].

Tahmin algoritmalarını karşılaştırıldığı farklı bir araştırmada ise Nti ve arkadaşları, hisse senedi fiyatlarını tahmin etmeye çalışmıştır. P/E, ROA, ROE ve piyasa değeri gibi temel analiz indikatörü ve RSI, OBV, MACD ve EMA gibi teknik analiz bağımsız değişkenlerini kullanmışlardır. SVM yöntemi, Decision Tree ve Neural Network yöntemlerine göre daha düşük hata oranları ile tahminler gerçekleştirmiştir [29].

İncelenen bir diğer çalışmada Bathla, S&P 500, NYSE, NSE, BSE, Nasdaq, Dow Jones ve Nikei 225 endeksi 5 yıllık verisini kullanmıştır. Tahminlerde hisse fiyatının değeri bağımsız değişken olarak kullanılmıştır. LSTM algoritmasının Mape hata oranı SVR algoritmasına göre daha düşük bulunmuştur [30].

Birçok algoritmanın birbiriyle karşılaştırıldığı bir diğer araştırmada Nabipour ve arkadaşları, 10 yıllık 10 teknik indikatör verisini kullanarak hisse fiyatını tahmin etmeye çalışmışlardır. Decision Tree, Random Forrest, Adaboost, XGBoost, SVM, Naive Bayes, KNN, Lojistik Regresyon, ANN, RNN ve LSTM gibi yöntemler arasından RNN ve LSTM diğer tahmin yöntemlerine göre belirgin bir şekilde daha üstün sonuçlar elde etmiştir [10].

Algoritmaların birbiriyle karşılaştırıldığı bir diğer çalışmada Ampomah ve arkadaşları, çalışmalarında NYSE, Nasdaq ve NSE borsalarından 8 hisse senedi verileri

kullanmışlardır. 4 farklı kategoriden 40 farklı indikatör kullanılmıştır. Random Forrest, XGBoost (XG), Bagging (BC), AdaBoost (Ada), Extra Trees (ET) ve Voting (VC) gibi birçok sınıflandırıcı kullanılmıştır. Test seti için accuracy, precision, F1 ve AUC kıstaslarına göre Extra Trees tipi sınıflandırıcısı daha iyi performans sergilemiştir. Ten-fold Cross Validation Eğitim datasına uygulandığında accuracy testinde AdaBoost, diğer modellere göre daha üstün sonuçlar vermiştir [31].

İncelenen bir diğer araştırmada Yuan ve arkadaşları, SVM, Random Forrest ve ANN algoritmalarını kullanmıştır. 8 yıllık büyüme faktörleri, finansal oranlar (ROE, ROA), kaldıraç oranları, boyut faktörleri, değerlendirme faktörleri, momentum faktörleri, volatilité faktörleri, likidite faktörleri, teknik indikatörler kullanılmıştır. Random Forest algoritması hem özellik seçimi hem de hisse fiyat tahmini için kullanıldığında en iyi sonuçları vermiştir [32].

Benzer bir diğer çalışmada Roy ve arkadaşları, 8 yıllık Kore Endeks verisini kullanarak bir sonraki yılın fiyatı yükselecek mi düşecek mi sorusuna yanıt aranmıştır. Random Forest, Gradient Boosted modellerini kullanılmıştır. Günlük kapanış değeri bağımsız değişken olarak kullanılmıştır. Derin öğrenme modeli, en düşük hata oranları ile tahminleri gerçekleştirmiştir [33].

Tekil ve hibrit modellerin birbiriyle karşılaştırıldığı bir diğer araştırma Xiao ve arkadaşları, 2 Çin petrol şirketinin 102 günlük verisini kullanmıştır. Hissenin tarihsel fiyat verisi ve hareketli ortalama verileri kullanılmıştır. ARIMA-LS-SVM modeli diğer modellerde daha doğru tahminler gerçekleştirmiştir [34].

Özellik seçim algoritmalarının karşılaştırıldığı bir araştırmada Haq ve arkadaşları, NASDAQ'ta işlem gören 88 hissenin 2 yıllık fiyat verisini kullanarak özellik seçim yöntemlerini birbiriyle karşılaştırmıştır. L1-LR, ve SVM ve Random Forrest algoritmaları kullanılarak özellik seçimi gerçekleştirilmiştir. Çalışmanın önerdiği özellik seçim modeli ile elde edilen sonuçlar, mevcut çalışmalardan daha üstün olduğu sonucuna ulaşılmıştır [35].

İncelenen bir diğer çalışmada ise Suryana ve Sen, 5 yıllık veriyi kullanmıştır. Altın, ham petrol, dolar, euro, ve S&P500 vb. bağımsız değişkenler kullanmışlardır. Bu bağımsız değişkenler ile bağımlı değişken altın fiyatı, tahmin edilmeye çalışılmıştır. SVM, Naive Bayes ve KNN algoritmaları kullanılmıştır. Bu algoritmalar, birbiriyle

karşılaştırılmıştır. Hata oranlarına göre KNN algoritması en doğru sonuçları vermiştir [36].

Türkiye’de gerçekleştirilen bir araştırmada Demirel ve arkadaşları, Borsa İstanbul’dan 42 şirketin 9 yıllık verisini kullanmıştır. Bu veriler ile şirketlerin hisse fiyatını tahmin etmeye çalışmışlardır. Makine ve derin öğrenme modelleri tahminlerde kullanılmıştır. SVM modeli, diğer makine öğrenme algoritmalarına göre daha üstün sonuçlar elde etmiştir [12].

Tekli ve hibrit modellerin kullanıldığı Chen ve arkadaşları, çalışmalarında 24 hissenin 10 yıllık verisi kullanmıştır. 19 bağımsız değişken kullanılarak hisse fiyatları, tahmin edilmiştir. Bu araştırmada hibrit ve tekil modeller birlikte kullanılmıştır. Hibrit modeller, tekli modellere göre daha fazla tekrar sayılarına ihtiyaç duymaktadır. Fakat, hibrit modeller, tekil modellere göre daha üstün sonuçlar elde etmiştir [38].


Makine ve derin öğrenme algoritmalarının birbiriyle karşılaştırıldığı bir diğer araştırma Biswas ve arkadaşları, Bangladeş Borsasının 1 yıllık verisini kullanmıştır. Kullanılan bağımsız değişkenler ile 1 gün sonrasının fiyatı tahmin edilmeye çalışılmıştır. LSTM, XGBoost, Hareketli Ortalama, Son Değer ve Lineer Regresyon modelleri kullanılmıştır. MAPE oranlarına göre LSTM derin öğrenme modeli en iyi performansı sergilemiştir [6].

Birçok algoritma kullanılarak gerçekleştirilen bir diğer çalışmada ise Xiaolie ve arkadaşları, 42 çeşit kripto para biriminin 6 aylık verisini kullanmıştır. Gelecekte kripto para değeri yükselecek mi düşecek mi sorusuna yanıt aramıştır. Birçok ülke endeksi ve ham petrol fiyat verisi gibi bağımsız değişkenler ile tahminler gerçekleştirilmiştir. Gradient Boosting, Decision Tree, SVM ve Random Forrest algoritmalarının birbiri ile karşılaştırılmıştır. SVM ve Random Forrest makine öğrenme algoritmaları en düşük hata oranları ile tahminleri gerçekleştirmiştir [39].

Son olarak incelenen araştırmada Mokhtari ve arkadaşları, Apple şirketinin 11 yıllık verisini kullanmıştır. Hisse kapanış fiyatını tahmin etmeye çalışmışlardır. Hisse tavan, taban, açılış, kapanış, hacim ve ayarlanmış kapanış değeri, hacim, hareketli ortalama, MACD, basit hareketli ortalama (SMA), üstel hareketli ortalama (EMA), RSI, MACD ve OBV gibi teknik indikatörler kullanılmıştır. Lineer Regresyon modeli hisse fiyatını LSTM'den daha düşük hata oranları ile tahmin etmiştir [40].

Sonuç olarak bu çalışmada literatürdeki çalışmalardan farklı olarak 74 bağımsız değişken kullanılarak sadece belirli bir sektöre çalışmanın odağı yöneltmiştir. Çalışmada Türkiye’de Petrol Rafineri sektöründe faaliyet gösteren TUPRS ve aynı sektörde faaliyet gösteren Fransa’dan Total, İngiltere’den Shell, Amerika’dan Chevron ve Avusturya’dan OMV şirketlerinin değer tahmini için çalışmalar yürütülmüştür. Hisse senedi fiyat tahmini için fiyat değişkenleri (hisse senedi kapanış, açılış, taban, tavan ve hacim), teknik analiz indikatörleri, temel analiz indikatörleri, ham petrol fiyat verisi ve ülke ve bu ülkelerin enerji, elektrik ve petrol sektörlerinin endeks verileri bağımsız değişkenler olarak bu çalışmada kullanılmıştır. Bu bağımsız ve bağımlı değişkenler arası korelasyonu tespit etmek için tahmin modelleri Rapid Miner programı kullanılarak oluşturulmuştur. 74 kadar bağımsız değişken için korelasyon analizleri yapılarak özellik seçimleri gerçekleştirilmiştir. Hisse değer tahminlerinde kullanılacak bağımsız değişkenler bu yöntem ile her hisse için belirlenmiştir. Literatürde kullanılan algoritmalara benzer Lineer regresyon, Decision Tree, Deep Learning, Gradient Boosted, KNN, Neural Network, Random Forrest ve SVM algoritmaları Rapid Miner programı aracılığı ile kullanılarak hisse değer tahminleri gerçekleştirilmiştir.

Çalışmada seçilen değişkenlerin belirlenmesinde literatürde kullanılan değişkenler belirleyici olmuştur. Her hisse için kullanılacak bağımsız değişkenler literatür taramaları ve profesyonel yatırımcıların kullandığı investing ve ycharts gibi siteler kullanılarak belirlenmiştir. Bir sonraki bölümde çalışmanın metodolojisi Şekil 2.1’de gösterildiği şekilde anlatılacaktır.




Şekil 2.1: Metodoloji

3. METODOLOJİ VE ANALİZLER

3.1 Veri Toplama

Hisse fiyatı makro ekonomik, mikro ekonomik birçok faktöre bağlı değişmektedir. Bir şirket sadece kendi durumundan değil birçok farklı ekonomik faktörden etkilenebilmektedir. Yatırım tercihinde etkili olan ve profesyonel yatırımcıların yatırım yapmadan önce dikkate aldığı literatürde mevcut onlarca farklı faktör tespit edilmiştir. Literatürde tespit edilen bu faktörlerin çoğu, çalışmanın daha geniş kapsamlı olması ve daha önce gerçekleştirilen çalışmalarda fark edilemeyen bazı ilişkilerin tespit edilebilmesi için kullanılmıştır.

Ayrıca profesyonel yatırımcıların kullandığı investing.com [17] ve ycharts.com [18] gibi sitelerde mevcut olan bağımsız değişkenler bu çalışmada kullanılmıştır. Bu araştırmada kullanılan piotroski oranı, küresel petrol üretim verileri gibi literatürde kullanımına rastlanmamış bağımsız değişkenler bu çalışmanın literatürde mevcut olan çalışmalardan farkı olmuştur. Literatürde daha önce kullanılan değişkenler ve petrol rafineri şirketlerinin fiyatını etkileyebilecek literatürde daha önce kullanılmamış değişkenler birlikte kullanılarak bağımsız değişkenler belirlenmiştir. Hisse fiyatını daha doğru tahmin edebilmek için 74 bağımsız değişken bu şekilde belirlenmiştir. Bu süreçte kullanılan bağımlı ve bağımsız değişkenler investing [17] ve ycharts [18] siteleri üzerinden elde edilmiştir. Investing sitesinden alınan veriler Şekil 3.1’de örnek olarak gösterilmiştir.



Şekil 3.1: Tüpraş hisse fiyat verisi [42]

Analizleri yapılacak olan Chevron, Tüpraş, Omv, Total, Shell gibi Avrupa ve Amerika kıtasında rafineri ve enerji sektöründe faaliyet gösteren şirketler seçilmiştir. Bu

seimleri yaparken řirketlerin byk piyasa deęerine sahip ve kendi lkesinde enerji sektrnde faaliyet gsteren ilk 3 řirket arasında olmasına dikkat edilmiřtir. Bunun yanında seilen baęımsız deęiřkenler aısından eksiksiz veriye sahip olması bu řirketlerin seilmesinde etkili olmuřtur.

Seilen firmalar iin investing ve ychart sitelerinden elde edilen hisse baęımlı ve baęımsız deęiřken verileri Excel dosya formatında kaydedilmiřtir [41-45].

rnek olarak Tprař’a ait gnlk baęımsız ve baęımlı deęiřkenlerin verileri Tablo 3.1’de gsterilmiřtir.

Tablo 3.1: Tprař iin yklenen veri seti

Tarih	Fiyat	Aılıř Fiyat	Tavan Fiyat	Taban Fiyat	Hacim	Fiyat Deęiřimi %	ADX	Aroon	Awesome	CCI	MACD	RSI
13.03.2012	23,8	23,3	24,0	23,3	1.890.000	2,63%	28,4	80	-0,2	-70,8	0,5	35,4
14.03.2012	24,8	23,9	24,8	23,9	1.390.000	4,21%	28,1	80	-0,2	34,2	-0,2	48,0
15.03.2012	24,7	24,8	25,0	24,6	839.020	0,24%	27,9	80	-0,1	65,6	0,0	54,5
.	.	.	.	.	.	.	.	.	.	.	.	.
.	.	.	.	.	.	.	.	.	.	.	.	.
.	.	.	.	.	.	.	.	.	.	.	.	.
09.11.2022	430,8	442,1	445,9	429,8	6.860.000	2,53%	56,1	68	14,3	136,5	1,3	73,3
10.11.2022	433,7	430,7	438,7	426,9	6.860.000	0,67%	55,1	68	9,0	112,3	2,1	71,2
11.11.2022	430,3	440,5	442,8	426	8.250.000	0,78%	54,5	68	3,3	97,8	3,6	69,2

Bu alıřmada kullanılan 10 yıllık baęımsız deęiřken veri setine eriřim iin investing ve ycharts sitelerinde cretli yelikler oluřturulmuřtur. Kullanılan veri seti zaman aralıęını belirlemek iin literatrde yer alan mevcut alıřmalar incelenmiřtir.

Yapılan alıřmalarda kullanılan veri zaman aralıkları ok deęiřkenlik gstermektedir. Kimi alıřmalarda 100 gn [34], 6 ay [39], 1 yıllık [6] veri kullanılırken aslında gncel trendlerin dikkate alınması gereklilięi vurgulanmıřtır.

Kimi alıřmalarda ise 2 yıl [35], 3 yıl [9, 19, 21] yeterli grlmřtr. Kimi alıřmalarda ise 5 yıl [30], 6 yıl [22], 7 yıllık [97], [25] verilerin dikkate alınması gereklilięi belirtilmiřtir. Bu konuda tek bir tutarlı yntem yaklařım bulunmamaktadır.

Daha uzun sreli verileri dikkate alan alıřmalarda 8 yıl [32, 33], 11 yıl [40], 12 yıl [16, 20, 26], 15 yıllık [7], 19 yıllık [27] veri aralıkları kullanılmıřtır.

Ama genel olarak alıřmaların oęu yaklaşık 10 yıllık [13, 38, 23, 10] veri kullanmıřtır. Bu yzden bu alıřmayı gerekleřtiren arařtırmacı da 10 yıllık veri kullanmayı tercih etmiřtir.

Hisse fiyat tahminlerinde Rapid Miner programı kullanılmıřtır [107]. Bu program dięer paket programlara gre kolay ve esnek kullanım gibi zelliklere sahip olduęu iin bu program tercih edilmiřtir.

3.2 Kullanılan Deęiřkenler

3.2.1 Hisse Senedi Fiyat Deęiřkenleri

Bu bmde incelenen deęiřkenlerin tanımları Biswas ve arkadaşlarının makalesinden alınmıřtır [6].

Aılıř Fiyatı: Bir hissenin bir iřlem gnnde ilk kez iřlem grdę fiyat

Tavan Fiyatı: Bir hissenin bir iřlem gnnde en yksek deęeri

Taban Fiyatı: Bir hissenin bir iřlem gnnde en dřk deęeri

Kapanıř Fiyatı: Bir iřlem gnnn sonunda belirlenen fiyat

Hacim: Belirli bir zaman diliminde bir hisse senedinin ne kadar payının alınıp satıldıęını ifade eder

3.2.2. Teknik İndikatrler

Bu bmde incelenen deęiřkenlerin tanımları Bařak ve arkadaşlarının makalesinden alınmıřtır [23].

Greceli G Endeksi (RSI): Hissenin ařırı alım ya da ařırı satım durumunu belirleyen bir momentum gstergesidir. RSI 0 ile 100 arasında deęer alır ve genellikle 70'in zerindeyken hissenin ařırı satın alındıęına iřaret etmektedir. RSI, 30'un altında ise hissenin ařırı satıřı gerekleřmektedir.

Stokastik Osilatr (SO): Fiyatın momentumunu takip eder. Genellikle fiyat deęiřiminden nce momentum deęiřir. Bu gsterge, kapanıř fiyatının belirli bir zaman dilimindeki en dřk ve yksek aralıęına gre olan seviyesini ler.

Williams Yüzde Aralığı (W%R): Bir momentum göstergesidir. Geriye dönük periyotta genellikle 14 gün bir piyasanın kapanış fiyatının en yüksek fiyatına göre olan seviyesini gösterir. Değer -100 ile 0 arasında değişir. Değeri -20'nin üzerinde ise satış sinyali olarak yorumlanırken, değeri -80'in altındayken alış sinyali olarak yorumlanır.

OBV: Hisse fiyatlarındaki değişiklikleri tahmin etmek için kullanılır. Bu teknik gösterge, bir hissenin alım ve satım trendlerini bulmak için kümülatif hacmi dikkate alır. Fiyatların yükseldiği günlerde hacimleri toplar ve fiyatların düştüğü günlerde önceki günlerin fiyatlarına göre hacmi çıkarır.

MACD: Fiyatların iki hareketli ortalamasını karşılaştıran bir momentum göstergesidir. İlk hareketli ortalama 26 günlük üstel hareketli ortalama (EMA) ve ikinci hareketli ortalama ise 12 günlük EMA, 26 günlük EMA'dan 12 günlük EMA çıkarılır [23].

Para Akışı Endeksi (MFI): Fiyat ve hacmi analiz edilerek yapılır. MFI hesap formülü, daha sonra 0-100 aralığı içinde hareket eden ve osilatör haline getirilip bir çizgi olarak çizilen bir değer üretir [46].

Emtia Kanalı İndeksi (CCI): Bir momentum osilatörüdür. Tanımlı bir sınırı olmayan bir osilatördür. Alt veya üst sınırları yoktur. Bu indikatör genellikle sapmaların yanı sıra dönüşleri bulmak için de kullanılır [47].

ADX: Bir trendin zaman içinde ne kadar güçlü veya zayıf olduğunu ölçer [31].

Aroon: Bir varlığın fiyatındaki trend değişikliklerini bulmak için kullanılır. Bir trendin gücünü tahmin etmek için kullanılır [31].

Chaikin: Belirli bir süre boyunca para akışı hacmini ölçmek için kullanılan teknik bir göstergedir. Değeri 1 ile -1 arasında dalgalanır. Alış ve satış baskısındaki değişiklikleri daha fazla ölçmenin bir yolu olarak kullanılabilir ve gelecekteki değişiklikleri ve dolayısıyla yatırım fırsatlarını tahmin etmeye yardımcı olabilir [48].

Awesome: Piyasa momentumunu ölçmek için kullanılan bir göstergedir. 3, 4 ve 5 periyotluk basit hareketli ortalamaların farkını alarak hesaplanır [49].

3.2.3.Temel İndikatörler

Öz Sermaye Karlılığı (ROE): Şirkete yatırılan her bir özsermaye için ne kadar kar elde edilebileceğini söyler. ROE bir şirketi rakipleriyle ve başka sektörlerdeki şirketler ile karşılaştırmak için kullanılabilir [50].

Aktif Karlılık (ROA): Bu oran, bir firmanın kazancının toplam varlıklarına veya kaynaklarına oranını gösterir. Bu rasyo ile firmanın toplam kaynaklarına göre ne kadar karlı olduğu bulunabilir [29].

Piyasa değeri (Market Capitalization): Piyasada gerçekleşen toplam hisse senedi işlemlerini ölçer hissedarların sahip olduğu halka açık şirketin mevcut hisse senetlerinin toplam değeridir. Piyasa değeri, hisse başına piyasa fiyatı ile işlem gören hisselerin sayısının çarpımı ile bulunabilir [29].

Cari Oran (Current Ratio): Bir şirketin mevcut varlıklarını mevcut borçlarına karşı ölçmek için kullanılan orandır. Tüm dönen varlıkların kısa vadeli borçları karşılama gücünü gösterir [50].

Fiyat/Defter Değeri (P/B): Hisselerin temel değerini hisse fiyatıyla karşılaştıran bir orandır. Hissenin değerinin düşük ya da yüksek olduğunun tahmin edilmesi için kullanılır [29].

Fiyat/kazanç oranı (P/E): PE oranı, hisse başına düşen piyasa fiyatının kar başına düşen kazançlara oranıdır. Pay başına düşen öz sermaye değeri olarak hesaplandığı için öz sermaye kazancının bir ölçüsüdür [106].

Aktif Devir Hızı (Asset Turnover): Bir şirketin satış değeri ile ortalama satış değerine kıyaslar. Şirketin varlıklarını nasıl verimli bir şekilde yönettiğini ve değer yaratmak için ne kadar etkili olduğunu ölçmenin bir yoludur [51].

Fiyat/Kazanç Büyüme Oranı (PEG): PE oranının beklenen büyüme oranına olan oranı olarak hesaplanır. Büyüme tipi şirketlerini takip eden analistler ve portföy yöneticileri tarafından yaygın bir şekilde kullanılmaktadır [105].

Şirket Değeri/Faiz Vergi ve Amortisman Öncesi Kar (EV / EBITDA):

Firmanın nakit hariç toplam piyasa değerini, faiz, vergi ve amortisman öncesi kazançları ile ilişkilendirerek hesaplanır. Yatırımcılar, bu oranı kullanarak şirketin değerinin düşük veya yüksek olduğunu belirlemeye çalışır [52].

Piotroski Skoru: Piotroski, finansal geçmiş performansı değerlendirmek amacıyla en yüksek 9 puan, en düşük 0 puan kullanarak bir değerlendirme ölçeğidir. Bu değer, şirketi yatırım yapma açısından şirketi puanlar [53].

İşletme değeri (EV): Varlık ve performans açısından, şirket bilançosuna ve şirket performans sonuçlarına göre şirket değeridir. Şirket değerini ölçmek için özsermaye değeri ve uzun vadeli borçlar kullanılır [54].

Yatırım Sermaye Getirisi: Bir şirketin sermayesinin ne kadar karlı yatırımlara ve ne kadar verimli değerlendirildiğini gösterir [55].

Öz Sermaye Getiri Oranı (Return on Common Equity): Net gelirin ortalama özsermayeye oranlanması ile bulunur [56].

Temettü Verimi: Toplam ödenen temettü fiyatının şirket piyasa değerine oranlanması ile bulunur [57].

Nakit /Toplam Sermaye: Toplam sermayenin, nakit düzeyine oranlanması ile bulunur [58].

Toplam Borç-Sermaye Oranı: Şirketin toplam borcunun firmanın toplam sermayesine oranını ölçer [59].

Faiz ve Vergi Öncesi Kazançlar/ Şirket Değeri: Faiz ve vergi öncesi kazanç (fvök) değerinin işletme değerine oranlanarak bulunur [60].

Şirket Değeri/Yatırım Sermayesi: Şirketin işletme değerinin yatırılmış sermaye değerine oranıdır [61].

Şirket Değeri/Hasılat: Şirketin piyasa değerini hasılatı oranıdır [62].

Brüt Kar Marjı (Gross Profit Margin): Net gelirden satış maliyetlerinin çıkarılması ile elde edilen değer brüt kardır. Brüt kar değeri net gelire oranlanmasıyla net kâr marjı oranı bulunur [63].

Fiyat / işletme faaliyetlerinden gelen kısa dönem nakit akışı (Price to Operating Cash Flow): Şirketin Hisse Fiyatı, Hisse Başına Serbest Nakit Akışıyla bölünerek bu oran elde edilir [64].

Fiyat / Son 1 Yıl Satışları: Şirketin son 12 ayda yaptığı satışın fiyata oranlanmasıyla bulunur [65].

3.2.4. Petrol Üretim Verileri

Dünya Ham Petrol Üretimi: Dünya Ham Petrol Üretimi, dünyada günlük olarak üretilen ham petrol varillerinin sayısını ölçer. Bu metrik ham petrol spot fiyatlarına işaret eder. Birimi Varil/gündür [66].

OPEC Ham Petrol Üretimi: Dünya petrol rezervlerinin üçte ikisini ellerinde bulunduran 13 ülkenin oluşturduğu konfederasyon olan OPEC'in dünyada günlük olarak üretilen ham petrol varillerinin sayısını ölçer. Birimi Varil/gündür [67].

İran Ham Petrol Üretimi: İran'ın dünyada günlük olarak üretilen ham petrol varillerinin sayısını ölçer. Birimi Varil/gündür [68].

ABD Ham Petrol Üretimi: İran'ın dünyada günlük olarak üretilen ham petrol varillerinin sayısını ölçer. Birimi British thermal'dir [69].

Suudi Arabistan Ham Petrol Üretimi: Suudi Arabistan'ın üretilen ham petrol varillerinin sayısını ölçer. Birimi Varil/gün [70].

3.2.5. Küresel Endeksler

DAX: Frankfurt Borsası'nda işlem gören 40 büyük Alman şirketini içeren bir hisse senedi endeksidir [71].

S&P 500: Amerika Birleşik Devletleri'ndeki borsalarda işlem gören en büyük 500 şirketin hisse performansını takip eden bir hisse senedi endeksidir [72].

Nasdaq: New York City merkezli bir Amerikan hisse senedi borsasıdır [73].

New York Menkul Kıymetler Borsası (NYSE): New York City'nin Lower Manhattan'daki Finans Bölgesi'nde bulunan bir Amerikan menkul kıymetler borsasıdır [74].

CAC 40 : Fransız hisse senedi endeksidir. Endeks, Paris'te en önemli 40 hissenin sermaye ağırlıklı bir ölçüsünü ifade eder [75].

FTSE 100 Endeksi: Yüksek piyasa değerine sahip olan Londra Menkul Kıymetler Borsası'nda işlem gören 100 şirketin hisse senedi endeksidir [76].

BIST 30 Endeksi: Borsa İstanbul'da işlem gören, işlem hacmi ve piyasa değeri en yüksek 30 şirketin hisse senedi endekstir [77].

BIST 100 Endeksi: Borsa İstanbul'da işlem gören, işlem hacmi ve piyasa değeri en yüksek 100 şirketin hisse senedi endekstir [78].

NYSE Enerji Endeksi: Enerji sektöründe şirketlerin temsil edildiği NYSE borsasından bir indekstir [79].

CAC Petrol Endeksi: Petrol rafineri sektöründeki şirketlerin temsil edildiği Fransa borsası hisse senedi endeksidir [80].

Dow Jones Petrol Endeksi: Petrol rafineri sektöründeki şirketlerin temsil edildiği Dow Jones borsası hisse senedi endeksidir [81].

S&P 500 Energy (SPNY): Enerji sektöründeki şirketlerin temsil edildiği S&P 500 borsası hisse senedi endeksidir [82].

BIST Kimya Petrol Plastik (XKMYA): Petrol türevli ürün üreten şirketlerin temsil edildiği Borsa İstanbul hisse senedi endeksidir [83].

BIST Elektrik (XELKT): Elektrik üretim sektöründeki şirketlerden oluşan Borsa İstanbul hisse senedi endeksidir [84].

FTSE 350 Elektrik: Elektrik üretim sektöründeki şirketlerden oluşan İngiltere borsası hisse senedi endeksidir [85].

FTSE 350 Petrol Endeksi: Petrol rafineri sektöründeki şirketlerin temsil edildiği İngiltere borsası hisse senedi endeksidir [86].

3.2.6. Diğer Değişkenler

Türk parasının yabancı para birimlerine oranı ve petrol fiyat verileri bu bölümde yer almaktadır.

Bloomberg WTI Ham Petrol: Global petrol endeksidir. Birimi USD'dir [87].


USO: ABD Petrol hisselerinin NYSE Arca'da işlem göre bir yatırım fonudur [88].

USD/TRY: Doların Türk lirasına oranı [89]

EUR/TRY: Euro para biriminin Türk Lirasına oranıdır [90]

3.3 Korelasyon Analizleri

Bu bölümde tahmin algoritmalarına girdi olarak kullanılacak değişkenlerin seçimi için korelasyon analizlerinden bahsedilecektir. Makine öğrenme algoritmalarında kullanılacak değişkenler Excel dosya formatında kaydedilmiştir. Rapid Miner programının Automodel modülü kullanılarak fiyat ve bağımsız değişkenler arasındaki korelasyon değerleri bulunacaktır. Bu bölümde elde edilen korelasyon değerleri ve elde edilen sonuçlar tartışılacaktır.



Şekil 3.2'de görüldüğü şekilde veriler Excel dosya formatında depolanan veriler Rapid Miner modeline aktarılmaktadır. 5 hisse için bu işlem ayrı ayrı gerçekleştirilmiştir.

Date / Time	Price Number	Open Number	High Number	Low Number	Vol. Number	Change %	ADX Number	Arsion Osc. Number	averageosc Number	CCI Number	Chaikin Oscil... Number	MACD Number
Feb 24, 2012	24.320	25.210	25.320	24.210	1780000	-0.031	48.430	52	-0.118	8.851	-447830.006	-0.232
Feb 27, 2012	23.270	24.270	24.430	23.270	1160000	-0.043	46.170	52	-0.323	-82.205	-1229971.195	-0.472
Feb 28, 2012	23.770	23.440	23.930	23.380	1230000	0.021	43.380	52.000	-0.452	-96.430	-1679404.142	-0.619
Feb 29, 2012	23.930	23.880	23.990	23.490	1480000	0.007	41.025	44	-0.598	-95.211	-1421414.284	-0.751
Mar 1, 2012	23.990	23.770	24.270	23.550	1470000	0.003	38.530	44	-0.666	-89.759	-709633.897	-0.780
Mar 2, 2012	23.770	23.880	23.930	23.600	555620	-0.009	36.191	40.000	-0.605	-109.858	-82979.430	-0.799
Mar 5, 2012	23.820	23.660	23.930	23.490	771820	0.002	34.338	36	-0.412	-106.423	220555.242	-0.758
Mar 6, 2012	24.100	23.880	24.270	23.770	1100000	0.012	31.808	-40	-0.190	-66.879	507007.559	-0.748
Mar 7, 2012	24.160	24.100	24.430	24.050	963410	0.003	29.157	-40	-0.029	-44.934	742696.745	-0.701
Mar 8, 2012	23.990	24.320	24.490	23.880	1320000	-0.007	27.036	-40	0.015	-48.270	555124.232	-0.617
Mar 9, 2012	23.490	24.100	24.210	23.380	2030000	-0.021	26.560	-40	-0.022	-85.819	-240618.801	-0.600

Şekil 3.3: Rapid Miner auto model korelasyon analizi

Yüklenen veriler Automodel modülü kullanılarak korelasyon analizleri gerçekleştirilmiştir. Şekil 3.3'teki predict ve next seçenekleri seçilerek model çalıştırılır. Değişkenlerin bağımlı veya bağımsız olduğunun sisteme tanıtılması bu şekilde gerçekleştirilir.

Örneğin Tüpraş şirketi için Tablo 3.2 ve Tablo 3.3'te gösterilen bağımsız değişken çeşitlerinin günlük verileri bu şekilde sisteme yüklenecektir.

Tablo 3.2: Tahminlerde kullanılan değişkenler


Tarihsel Fiyat	Teknik İndikatör	Temel İndikatörler	
Fiyat	ADX	Piyasa değeri	Temettü Verimi
Açılış Fiyatı	Aroon	Toplam Şirket Değeri	Öz Sermaye Karlılığı (ROE)
Tavan Fiyat	Awesome	Şirket Değeri	Varlıklar/Özsermaye
Taban Fiyat	CCI	Şirket Değeri / FVAÖK	Aktif Karlılık (ROA)
Hacim	Chaikin	Şirket Değeri / FVÖK	Cari Oran
Fiyat Değişim %	MACD	Şirket Değeri / Serbest Nakit Akışı	Toplam Borç-Sermaye Oranı
	MFI	Şirket Değeri / Yatırım Sermayesi	Nakit /Toplam Sermaye
	OBV	Şirket Değeri / Hasılat	Brüt Kar Marjı
	ROC	Fiyat/kazanç oranı (P/E)	Öz Sermaye Getiri Oranı (ROCE)
	RSI	Fiyat/Defter Değeri	Aktif Devir Hızı
	Fast Stoch(14days) %K	Fiyat / işletme faaliyetlerinden gelen kısa dönem nakit akışı	Yatırım Sermaye Getirisi (ROIC)
	Slow Stoch(3days) %D	Fiyat / Son 1 Yıl Satışları	PEG
	14-day Williams %R	Piotroski Skoru	

Tablo 3.3: Tahminlerde kullanılan değişkenler

Ülke Endeksleri		Petrol Üretim Veri	Petrol Fiyatı/Döviz Kuru
Bist-30	FTSE 100 Endeks	Dünya Ham Petrol Üretimi	USO(EFT)
Bist-100	FTSE Elektrik Endeksi	OPEC Ham Petrol Üretim	Bloomberg WTI Ham Petrol Fiyat
SP500	Sp500 Enerji Endeksi	İran Ham Petrol Üretimi	Euro/Try
Nasdaq	FTSE Petrol Gaz Endeksi	Amerika Ham Petrol Üretimi	Usd/Try
DAX	Bist Elektrik End.(XELKT)	Arabistan Ham Petrol Üretimi	
Nyse Enerji Endeksi	Bist Petrol Endeksi		
Nyse Endeks	Cac Petrol Gaz Endeksi		
Cac 40 Endeks	Djones Petrol Gaz End.		

Tahmin modellerinde kullanılacak değişken çeşitleri literatürde yer alan çalışmalar incelenerek belirlenmiştir. ADX, CCI ve MACD vb. teknik indikatörler çalışmaya girdi olarak seçilmiştir. Tablo 3.2-3.3'te yer alan tarihsel veri, teknik indikatör ve temel indikatör, ülke endeksleri, petrol üretim verileri, petrol fiyatı ve döviz kurları gibi değişken çeşitleri çalışmada incelenen 5 hisse için de ortak olarak kullanılmıştır.

Tablo 3.2-3.3'te Tüpraş için bağımsız değişken korelasyon analizlerinde kullanılacak veri çeşitleri gösterilmiştir. Bist30, Bist100, Nasdaq, Nyse gibi dünyadan ve ülkemizden borsa endeks verileri seçilmiştir. Çalışmada incelenen şirketler emtia bazlı ve petrol rafineri sektöründe faaliyet gösterdiği için petrol gaz endeksleri Cac, Djones ve FTSE Petrol Gaz Endeksi gibi farklı ülkelerin endeksleri girdi olarak korelasyon analizleri için kullanılmıştır. Ayrıca Tablo 3.3'te gösterilen ham petrol fiyatları ve döviz kurları korelasyon analizlerinde ayrıca girdi olarak kullanılmıştır.



Şekil 3.4: Rapid miner modeli korelasyon sonuçları

Örneğin her hisse için toplam 74 bağımsız değişken korelasyon analizleri yapılmıştır. Her hisse için bağımsız değişken ve bağımlı değişkenler arasındaki korelasyon sonuçları incelendiğinde Tablo 3.4, 3.5, 3.6, 3.7 ve 3.8 tablolarında görüldüğü şekilde sonuçlar elde edilmiştir.

Tablo 3.4: Tüpraş korelasyon analizi

Değişken	Korelasyon
Tavan Fiyatı	%99,94
Taban Fiyatı	%99,93
Açılış Fiyatı	%99,85
Piyasa Değeri	%91,9
Toplam İşletme Değeri	%91,09
İşletme Değeri (EV)	%89,87
BIST Kimya Petrol Plastik Endeksi (XKMYA)	%89,31
BIST 100 Endeksi	%87,96
USD/TRY	%87,01
EUR/TRY	%82,96
BIST Elektrik (XELKT)	%76,37
OBV	%73,22
S&P 500	%57,27
BIST 30 Endeksi	%57,27
CAC 40	%54,73
ABD Ham Petrol Üretimi	%52,81
NYSE Endeksi	%52,24
Yatırım Sermaye Getirisi (ROIC)	%51,33
Budapeşte Menkul Kıymetler Borsası (BSE)	%50,54
Nasdaq	%48,51
FTSE 350 Petrol Gaz Endeksi	%41,71
DAX Alman Borsası Endeksi	%40,33

Tüpraş firması için hisse fiyatı tarihsel fiyat verisi ile tahmin edildiğinde hisse fiyatı arasındaki korelasyon değerleri en yüksek bulunmuş. Literatürde yer alan çalışmalarda genellikle hissenin kendi fiyatı kullanılarak tahmin modelleri kurulmuştur. Literatürde yer alan çalışmaların genellikle tarihsel fiyat verisi tahmin algoritmalarında kullanılmıştır. Bu gerçekleştirilen çalışmada da literatürde yer alan çalışmalarda [6, 9, 19, 20, 21, 30, 33, 34] kullanıldığı gibi yine tarihsel fiyat verisi kullanılmıştır.

Tüpraş hisse değeri ile Bist Kimya Petrol endeksi, Bist Elektrik Endeksi gibi değişkenler arasında yüksek korelasyon sonuçları elde edilmiştir. Yine aynı şekilde Bist 100, S&P 500, CAC 40, NYSE, DAX vb. farklı ülkelerin endeksleriyle arasında yüksek korelasyon değerleri elde edilmiştir. Elde edilen bu sonuçlar petrol rafineri sektörüne yatırım yapacak yatırımcılar için önemli olacaktır. Hisse fiyat değişiminde, hangi bağımsız değişkenler daha önemli bu konuda yatırımcılar bilgi sahibi olacaktır.

Tüpraş tahmin algoritmalarında hisse değer tahminlerinde Tablo 3.4'te yer alan bu değişkenler kullanılacaktır.

Tablo 3.5: Total korelasyon analizi

Değişken	Korelasyon
Açılış Fiyatı	%99,01
CAC Petrol Gaz Endeksi	%87,12
FTSE 350 Petrol Gaz Endeksi	%61,7
FTSE 100 Endeksi	%53,3
Öz Sermaye Karlılığı (ROE)	%48,79
Dünya Ham Petrol Üretimi	%44,3
Aktif Karlılık (ROA)	%44
Öz Sermaye Getiri Oranı (ROCE)	%43,66
Fiyat/Defter Değeri (P/B)	%42,74
S&P 500 Enerji Endeksi (SPNY)	%40,86

CAC 40 endeksinde yer alan Total şirketi hisse değer tahmininde kullanılacak bağımsız değişkenler arasında korelasyon analizleri yapıldığında Fransa Petrol şirketlerinin yer aldığı CAC Petrol endeksi, İngiltere FTSE 100 endeksi, S&P 500 Enerji endeksi gibi Fransa ve dünyadan farklı ülkelerin endeksleri arasında korelasyonlar sonuçları Tablo 3.5'te gösterildiği şekilde bulunmuştur. Ayrıca dünya Ham petrol fiyatı, ROE, ROA ve Fiyat/Defter değeri gibi temel analiz rasyoları ve hisse senedi değer değişkeni arasında yüksek korelasyon değerleri bulunmuştur.

Tablo 3.6: Shell korelasyon analizi

Değişken	Korelasyon
Taban Fiyatı	%99,78
Açılış Fiyatı	%99,53
FTSE 350 Petrol Gaz Endeksi	%97,16
Tavan Fiyatı	%82,77
CAC Petrol Gaz Endeksi	%75,97
Fiyat/Defter Değeri (P/B)	%73,01
İşletme Değeri/Yatırım Sermayesi	%67,11
S&P 500 Energy (SPNY)	%53,36
NYSE Enerji Endeksi	%53,26
FTSE 350 Petrol Gaz Endeksi	%52,09
Aktif Karlılık (ROA)	%51,55
Dow Jones Petrol Gaz Endeksi (DJUSEN)	%49,7
Öz Sermaye Getiri Oranı (ROCE)	%49,16
Öz Sermaye Karlılığı (ROE)	%46,18
Toplam Borç-Sermaye Oranı	%43,03

İngiltere FTSE 100 endeksinde yer alan Shell şirketi için korelasyon sonuçları incelendiğinde en yüksek korelasyon sonuçları tarihsel veri (taban, açılış fiyatı) arasında bulunmuştur. İngiltere borsasında yer alan bu hisse ile Fransa Petrol Endeksi, S&P 500, NYSE Enerji Endeksi, Alman Petrol Endeksi vb. değişkenler arasında

yüksek korelasyon sonuçları bulunmuştur. Elde edilen bu sonuçlar çalışma için kullanılan değişkenlerin seçiminde isabetli kararlar verildiğini destekler şekildedir.

Ayrıca öz sermaye karlılığı (ROE), aktif karlılık (ROA) ve hisse fiyatı/defter değeri gibi temel analiz rasyoları arasında kuvvetli korelasyon değerleri bulunmuştur. Tablo 3.6'da yer alan değişkenler Shell hisse senedi fiyat tahmin algoritmalarında kullanılacaktır.

Tablo 3.7: Omv korelasyon analizi

Değişken	Korelasyon
Taban Fiyatı	%99,83
Tavan Fiyatı	%99,78
Açılış Fiyatı	%99,56
OBV	%67,49
Fiyat/Defter Değeri (P/B)	%65,96
FTSE 100 End.	%65,43
Fiyat / Son 1 Yıl Satışlar	%63,41
FTSE 350 Petrol Gaz End.	%56,31
CAC 40 End.	%54
NYSE Endeksi	%48,81
Fiyat/İşletme Nakit Akışı	%48,73
DAX Alman End.	%46,55

Viyana borsasında işlem gören OMV hisse senedi ve bağımsız değişkenler arasındaki korelasyon sonuçları incelendiğinde tarihsel fiyat değişkenleri arasındaki korelasyon değerleri en yüksek bulunmuştur.

Ayrıca Alman Borsası, NYSE, Budapeşte Borsası ve FTSE 100 endeksleri ile arasında anlamlı korelasyon değerleri bulunmuştur. İncelenen diğer hisselerden farklı olarak, Chevron şirketine benzer şekilde OBV değişkeni korelasyon sonuçları yüksek bulunmuştur. Tablo 3.7'de yer alan değişkenler tahmin modellerinde girdi olarak kullanılacaktır. Çalışmada dünyanın küresel bir market olduğu sonucunu destekler şekildedir. Birbiriyle ilgisiz gibi gözüken hisse ve marketler arasında aslında korelasyonlar mevcuttur. Bu araştırmadan çıkan sonuçlar bunu destekler şekildedir. Ayrıca Avusturya şirketi olan OMV ve Alman ve Fransa borsa endeksleri arasında yüksek korelasyon sonuçları bulunmuştur.

Tablo 3.8: Chevron korelasyon analizi

Değişken	Korelasyon
Tavan Fiyatı	%99,72
Taban Fiyatı	%99,7
Açılış Fiyatı	%99,43
İşletme Değeri/Yatırım Sermayesi	%70,23
OBV	%69,95
Fiyat/Defter Değeri (P/B)	%69,23
FTSE 350 Petrol Gaz Endeksi	%50,98
Brüt Kar Marjı	%43,1
Öz Sermaye Getiri Oranı (ROCE)	%42,76
S&P 500 Enerji (SPNY)	%42,63
Aktif Karlılık (ROA)	%41,92
CAC Petrol Gaz Endeksi	%41,91

NYSE endeksinde yer alan Chevron şirketi ile bağımsız değişkenler arasında korelasyon analizi yapıldığında en yüksek korelasyon değerleri yine tarihsel fiyat değişkenleri arasında bulunmuştur.

Ayrıca OBV temel indikatör değişkeni, aktif karlılık (ROA) temel analiz rasyosu gibi değişkenler arasında yüksek korelasyon değerleri bulunmuştur. Ek olarak Fransa petrol endeksi, S&P 500 gibi dünyanın farklı ülke endeksleri ile hisse fiyat değişkeni arasında yüksek korelasyon değerleri bulunmuştur.

Tablo 3.8’de yer alan değişkenler bu hisse için tahmin algoritmalarına girdi değeri olarak kullanılacaktır.


3.4 Rapid Miner ile Tahmin Modelleri

Tüpraş, Shell, Total, Chevron ve OMV şirketleri için Rapid Miner programı kullanılarak tahmin modelleri oluşturulmuştur. Araştırmada incelenen hisse fiyatları için kurulan tahmin modelleri aşağıda incelenecektir.

Örneğin Tüpraş hisse fiyat tahmini için Decision Tree, Derin Öğrenme, Gradient Boosted, Lineer Regresyon, Neural Network, Random Forrest, SVM ve KNN algoritmaları kullanılarak tahmin modelleri oluşturulmuştur. Tablo 3.9’da gösterilen 2729 satırlık 13.03.2012-11.11.2022 yılları arası günlük veri Rapid Miner programına yüklenmiştir


Tablo 3.9: Tüpraş için veri seti

Tarih	Fiyat	Açılış Fiyatı	Tavan	Taban Fiyat	Hacim	Fiyat Değişimi %	ADX	Aroon	Awesome	CCI	MACD	MFI	ROC	RSI
13.03.2012	23,8	23,3	24,0	23,3	1.890.000	2,63%	28,4	80	-0,2	-70,8	0,5	51,4	0	35,4
14.03.2012	24,8	23,9	24,8	23,9	1.390.000	4,21%	28,1	80	-0,2	34,2	0,2	52,5	3,5	48,0
15.03.2012	24,7	24,8	25,0	24,6	839.020	0,24%	27,9	80	-0,1	65,6	0,0	60,5	3,0	54,5
.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
09.11.2022	430,8	442,1	445,9	429,8	6.860.000	-2,53%	56,1	68	14,3	136,5	1,3	79,9	17,1	73,3
10.11.2022	433,7	430,7	438,7	426,9	6.860.000	0,67%	55,1	68	9,0	112,3	2,1	73,1	16,3	71,2
11.11.2022	430,3	440,5	442,8	426	8.250.000	0,78%	54,5	68	3,3	97,8	3,6	65,8	17,7	69,2




Şekil 3.5: Verilerin sisteme yüklenmesi

Bilgisayarda Excel formatında hazırlanan veriler Rapid Miner programına import veri kısmından Şekil 3.5'te görüldüğü gibi yüklenecektir. Bu araçlar yardımıyla bu veri yüklendikten sonra tahmin modellerine göre algoritmalar kolayca düzenlenebilmektedir.




Şekil 3.6: Rapid miner veri yükleme operatörü

Retrieve operatörü kullanılarak, önceden Rapid Miner veri tabanına tanımlanan girdiler modele tanıtılır. Makine öğrenme algoritmalarına girdi veriler bu şekilde tanıtılacaktır.



Şekil 3.7: Tahmin algoritmalarında kullanılacak özelliklerin seçilmesi


Korelasyon sonuçlarına göre tahmin algoritmalarında kullanılacak değişkenler import seçeneği ile sisteme aktarılır. Tablo 3.4-3.8’de gösterilen korelasyon sonuçlarına göre tahmin algoritmalarında kullanılacak değişkenler gösterilmiştir. Şekil 3.7’de gösterildiği şekilde select attribute operatörü ile bu kısımda veriler sisteme tanıtılır.



Şekil 3.8: Set role operatörü


Şekil 3.6’da gösterilen retrieve operatörü ile Excel dosyaları sisteme yüklenebilmektedir. Sisteme yüklenen bağımsız değişken tiplerini tanımlamak için

Şekil 3.8’de gösterilen set role operatörü kullanılacaktır. Date Sütununda yer alan tarihler tahmin algoritmasına katılmaz. Bu sütunda yer alan tarih verisi bağımsız değişkenler için bir nevi etiket olarak kullanılacaktır. Bağımsız değişken ve tahmin edilen fiyat verilerinin sistem tanımlanması bu şekilde gerçekleştirilir. Attribute name kısmı price ve target role kısmı etiket olarak verilere tanımlanacaktır.



Şekil 3.9: Split veri operatörü

Şekil 3.9’da split veri operatörü gösterilmiştir. İlgili sitelerden toplanan veriler test ve eğitim verisi olarak gruplandırılır. Verinin %90’lık kısmı eğitim verisi, %10’lık kısmı test verisi olacak şekilde modele tanımlanır. Örneğin Chevron şirketinin 2700 günlük verisi, OMV şirketinin 2600 günlük verisi, Shell şirketinin 2700 günlük verisi, Total şirketinin 2800 günlük verisi ve Tüpraş şirketinin 2700 günlük verisi bu şekilde eğitim ve test verisi olarak ayrılır. Bu 5 şirketin için 2012-2022 yılları arası toplanan verinin ilk 9 yılı eğitim verisi, son 1 yılı test verisi olacak şekilde sisteme tanıtılır. Ayrıca yüzdelik olarak verinin ayrılması için linear sampling seçeneğinin seçili olması gerekmektedir. Bu şekilde Son 1 yılın verisi test verisi olduğu sisteme tanıtılabilmektedir.



Şekil 3.10: Rapid miner tahmin algoritması genel görünümü

Şekil 3.10’da Rapid Miner Programı kullanılarak oluşturulan model gösterilmiştir. Cross Validation operatörüne çift tıklanıldığında açılan pencerede Decision Tree operatörü gösterilmiştir. Buradaki modelden Decision Tree operatörünü kaldırıp, farklı tahmin algoritma operatörleri modele bağlanılabilir. Bu şekilde model farklı tahmin algoritmaları ile tahminler yapmak için uygun hale gelecektir. Örneğin Decision Tree operatörü yerine Random Forrest operatörü modele eklenildiğinde, girdi veriler Random Forrest algoritması ile tahmin edilebilir olacaktır. Rapid Miner uygulamasının bu kadar esnek ve kullanım kolaylıkları sunması sebebiyle bu çalışmada tercih edilmiştir.


3.5. Kullanılan Algoritmalar

3.5.1. Decision Tree

Decision Tree, bir ağaç benzeri yapıya sahip, bir dizi kurallar ile bir hedef değişken üzerinde tahminler gerçekleştirir. Bu algoritma, insanların genellikle karar verirken izlediği benzer bir yaklaşımı izler. Bu nedenle, modelleri sezgiseldir ve kolayca açıklanabilir [31].

Bu algoritma hem regresyon hem de sınıflandırma problemleri için yaygın olarak kullanılan bir metottur. Veri kümesinden ve ilgili özelliklerden şekillendirilen basit karar kurallarını kullanarak bir hedefin tahmin edilmesi tekniğidir. Kolay yorumlanabilir olması veya farklı çıktıları olan sorunları çözebilmeye yetenekleri bu yöntemin üstünlükleridir. Bunun yanında aşırı öğrenmeye neden olan aşırı karmaşık


ağaçlar oluşturma gibi dezavantajı mevcuttur. Şematik bir gösterimi Şekil 3.11’de gösterilmiştir [10].



Şekil 3.11: Şematik karar ağacı gösterimi

3.5.2. Random Forrest

Random Forrest modeli, fazla sayıda karar ağacından oluşur. Model temelde ağaçların tahmin sonuçlarını ortalamaları alınır ve bu yapıya orman denir. Algoritma üç rastgele düşünceden oluşur. Ağaçları oluştururken eğitim verilerinin rastgele seçilmesi, düğümleri bölerken bazı değişken alt kümelerin rastgele seçilmesi ve her temel karar ağacında her düğüme bölme işlemi için tüm değişkenlerin yalnızca bir alt kümesinin kullanılması. Her bir ağaç birleşeni, Random Forrest eğitim süreci sırasında veri kümesinin rastgele bir örneğinden öğrenir. Modelin şematik bir gösterimi Şekil 3.11’de gösterilmiştir [10].



Şekil 3.12: Şematik rastgele orman gösterimi


Karar ağaçları sınıflandırmada problemlerini çözmek için kullanılan popüler makine öğrenme yaklaşımlarından biridir. Aşırı öğrenme etkilerini azaltmak için birçok karar

ağacının birleşimini kullanır. Bir rastgele ormanda, her ağaç bir özellik uzayının rastgele bir alt kümesinde oluşturulur. Genellikle, veri setindeki her bir örneğin M özelliği var ise her ağacın büyümesi için $m = M$ özellik rastgele seçilir. Bu algoritmanın tercih edilme nedeni, karar ağaçlarına göre önemli miktarda oy tabanlı sonuçlar kullanmasıdır [23].

3.5.3. KNN Modeli

KNN algoritması, bilinmeyen bir örnek ile bilinmeyen örneğin en yakın komşuları olan k eğitim örneği arasındaki karşılaştırmaya dayanır. KNN modeli yakın Komşu algoritmasının yeni bir örneğe uygulanmasının ilk adımı, KNN eğitim örneğini bulmaktır. Yakınlık, eğitim örneği setindeki n özeliğe dayalı olarak n boyutlu uzayda bir mesafe olarak tanımlanır. Farklı metrikler, bilinmeyen örneğin ve eğitim örneklerinin arasındaki mesafenin hesaplanması için kullanılabilir. Mesafeler genellikle mutlak değerlere bağlı olduğundan, KNN algoritmasını eğitmeden önce verilerin normalize edilmesi gereklidir. Kullanılan metrikler ve algoritmanın yapılandırılması, operatörün parametreleri kullanılarak gerçekleştirilir. İkinci adımda, KNN algoritması, komşuların çoğunluğuna göre bilinmeyen örneği sınıflandırır. Regresyon durumunda, tahmin edilen değer, bulunan komşuların değerlerinin ortalamasıdır [91].


KNN için genellikle iki özellik önerilir. Bu özellikler, tembel öğrenme ve parametrik olmayan öğrenme şeklindedir. Bu algoritma çalışma safhaları veri kümesini eğitim ve test verilerine ayırma, değerlerin seçimi, hangi mesafe fonksiyonunun kullanılacağını belirleme, test verilerinden yeni bir örnek seçme ve n eğitim örneğine olan mesafeyi hesaplama, elde edilen mesafeleri sıralama ve veri örneğini seçme ve nihayetinde test sınıfını, k komşularının çoğunluk oyuyla örneğe atama şeklinde tarif edilebilir. Şekil 3.12’de KNN şematik olarak gösterilmiştir [10].



Şekil 3.13: Şematik knn algoritması gösterimi

3.5.4. Neural Network

Doğrusal olmayan modellerin oluşturulmasını daha iyi tamamlayabildiği için hisse senedi fiyatı tahmininde geniş çapta kullanılmaktadır. Üç katmanlı, tam bağlantılı bir yapay sinir ağı modeli Şekil 3.13'te gösterilmiştir. Özellik veri setlerini, modelin girdisi olarak kullanmak ve iki gizli katmanın hesaplamasından sonra çıktı katmanı aracılığıyla nihai tahmin sonucunu elde etmek modelin amacıdır. Düğümlerdeki ağırlıklar, hata geri yayılım algoritmasıyla bulunur [32].



Şekil 3.14: Şematik üç katmanlı sinir ağı

Bu makine öğrenme algoritması ilk kez McCulloch ve Pitts tarafından önerilmiş ve daha sonra araştırmacılar tarafından doğrusal olmayan süreçlerin deneysel modellemesinde yaygın olarak kullanılmıştır. Tek katmanlı ve çok katmanlı şekillerde bulunan bir sinir ağı türüdür [9].

Sinir ağlarının, karar verme ve finansal planlama gibi finansal ve yatırım alanlarında geniş uygulamaları mevcuttur. İleri beslemeli ağlardaki düğümler, ardışık katmanlarda

yer alır ve tek yönlü bir bağ vardır. Bir giriş deseninin ağa gelmesiyle birlikte, ilk katman çıktı değerini hesaplar ve bir sonraki katmana iletilir. Bir sonraki katman bu sayıyı giriş olarak alır ve çıktı değerlerini bir sonraki katmana aktarır. [9]

3.5.5. Lineer Regresyon

Sayısal tahminlerde kullanılan bir yöntemdir. Regresyon, bir bağımlı değişken ile bağımsız değişkenler olarak bilinen diğer değişkenler arasındaki ilişkinin gücünü belirlemeye çalışan istatistiksel bir kıstastır. Sınıflandırma, için kullanıldığı gibi, regresyonda sürekli bir değeri tahmin etmek için de kullanılabilir. Örneğin, 4 yıllık fakülte mezunlarının maaşını tahmin etmek veya bir ürünün üretim miktarına göre satışını tahmin etmek için kullanılabilir. Regresyon bir malın fiyat hareketini etkileyen belirli faktörlerin hesaplanması için de kullanılabilir. Bir malın fiyatı, faiz oranları, belirli endüstriler veya sektörlerin ne kadar etkilediğini belirlemek için de kullanılabilir [92].

Doğrusal regresyon, gözlemlenen verilere uygun bir denklem ile değişken ile bir veya daha fazla açıklayıcı değişkenler arasındaki ilişkiyi modellemeye çalışır. Örneğin, bir kişinin kilosunu boyuyla ilişkilendirmek için doğrusal regresyon modeli kullanılabilir [92].

3.5.6. Derin Öğrenme Modeli

Derin öğrenme yöntemleri, bilgisayar görüşünde, konuşma tanıma, görüntü sınıflandırma vb. çeşitli problemlerin çözümünde diğer teknikleri geride bırakmıştır. Geleneksel yöntemlerle derin öğrenme arasındaki temel fark, özelliklerin girdi verilerinden nasıl öğrenildiğidir. Ayrıca, geleneksel yaklaşımlar öznel olup diğer benzer problemlere aktarılamaz. Öte yandan, derin öğrenmeye dayalı yaklaşım, veri tabanlı yaklaşımlar ile verilerdeki desenleri öğrenir. Girdi verilerinden son derece ayrımcı özellikler çıkarmak için bir dizi adım sağlar. [37].

Derin Öğrenme, geri yayılım kullanarak stokastik gradyan inişi ile eğitilen çok katmanlı beslemeli bir yapay sinir ağını temel alır. Ağ, doğrultucu ve maksimum aktivasyon fonksiyonlarına sahip nöronlardan oluşan birçok gizli katmandan oluşur. Uyarlanabilir öğrenme hızı, momentum eğitimi, düşme gibi gelişmiş özellikler yüksek tahmin doğruluğuna ulaşabilir. Her hesaplama düğümü, yerel verileri kullanarak

global model parametrelerinin bir kopyasını çoklu iş parçacığını kullanarak eğitir ve ağ üzerinde model ortalama ile global modele katkı sağlar [93].

Derin öğrenme genellikle makine öğreniminin bir alt kümesi olarak kabul edilir. İlk olarak 2005 yılında tanıtılmıştır. 2012'den itibaren ciddiye alınmaya başlanmıştır. Derin öğrenmenin temeli, model katmanlarında bilgi ve özellikleri temsilinin öğrenilmesine dayanır. İnsan beyni yapısından ilham alan derin öğrenme fikri, yeni olanaklar ve teknolojileri kullanarak yapay zekâ ve makine öğrenme ile ilgili birçok alanda önemli başarılarla imza atmıştır. Sinir ağlarının içsel bir gizli katmanı bulunur. Birden fazla içsel gizli katmana sahip olan bu yapıya derin sinir ağı denir [9].

Son zamanlarda geliştirilen makine öğrenme modellerinden biridir. Ayrıca makine öğrenmesi ve bir yapay zekâ dalıdır. Farklı seviyelerde ve katmanlarda öğrenme kullanarak yüksek düzeyde kavramsal kavramları modellemeye çalışan bir algoritmadan oluşur. Derin öğrenmenin en önemli avantajları, özelliklerin otomatik öğrenilmesi, çok katmanlı öğrenme, yüksek hassasiyetli sonuçlar, yüksek genelleme gücü ve yeni verilerin tanınmasıdır [9].

3.5.7. Gradient Boosted Trees

Gradient Boosted algoritması daha az doğru veya zayıf tahmin modellerinden oluşan bir makine öğrenme algoritmasıdır. Sınıflandırma ağaçlarını kullanılır [33]. Her ikisi de tahmin sonuçlarını giderek iyileşen tahminler aracılığıyla elde eden ileri öğrenme yöntemleridir. Boosting işlemi, ağaçların doğruluğunu artırmaya yardımcı olan esnek bir doğrusal olmayan regresyon prosedürüdür. Zayıf sınıflandırma algoritmalarını artan şekilde değişen verilere uygulayarak, zayıf tahmin modellerinden oluşan bir dizi karar ağacı oluşturulur. Ağaçların doğruluğunu artırırken, hızı ve insan tarafından yorumlana bilirliliğini azaltır. Bu yöntem, bu sorunları en aza indirmek için ağaç artırma yöntemini genelleştirir [94].

Tahmin sonuçları, bir kayıp fonksiyon kullanılarak tahminler iyileştirilerek elde edilir. Önceki ağaçların net kaybını dikkate alarak ardışık ağaçlar ile uyumlu bir şekilde çalışır. Her ağaç, son çözümün bir parçası olarak kısmen bulunur. Ağaç artırma, ağaçların doğruluğunu artırmak için nonlinear regresyon algoritmaları kullanılır. Boosting yöntemi, ağaç tipi algoritmaların hızında bir azalmaya neden olurken, bir modelin şeffaflığında bir eksikliğe yol açar. Fakat nonlinear karar sınırlarının

öğrenilmesi gereken durumlarda daha yüksek bir doğruluk sağlar. Bu makine öğrenme algoritmasının en iyi özelliği, bir kayıp fonksiyon üzerinde optimizasyon yapabilmesidir. Bu makine öğrenme algoritmasının birçok hiper-parametresi vardır. Gürültüye ve aşırı değerlere hassas bir şekilde çalışır. Bu algoritma verilere aşırı uyum sağlamasını önlemek için uygun bir durma noktası gereklidir. Uygun bir durdurma kriteri kullanıldığında genellikle en iyi yöntemlerden birisi olarak kabul edilir [33].

3.5.8. SVM

Stefan Rueping tarafından geliştirilmiştir. Bu öğrenme yöntemi hem regresyon hem de sınıflandırma için kullanılabilen bir yöntemdir. Birçok öğrenme görevi için hızlıdır ve iyi sonuçlar verir. Doğrusal veya kuadratik hatta asimetrik kayıp fonksiyonlarıyla çalışır. Nokta, radyal, polinom, sinirsel, anova, epachnenikov, gauss kombinasyonu ve multikübik gibi çeşitli çekirdek tiplerini destekler [95]. SVM modelleri için sınıflandırma ve regresyon olarak görevler üstlenebilir. SVM'nin temel fikri, örnek verileri pozitif ve negatif olarak iki farklı kategoriye sınıflandırabilen maksimum marj hiper düzlemidir [32].


Genelleştirme hatasının üst sınırlamasını minimize eder. Bir fonksiyonu tahmin etmek için risk minimizasyon prensibine dayanan SVM, aşırı öğrenme sorununa karşı çok dirençlidir ve bu yöntem ile yüksek bir genelleme performansı elde edilebilmektedir [11].

SVM'nin eğitiminin, her zaman tek ve global olarak optimal olan doğrusal bir kısıtlı karesel programlama problemini çözmekle eşdeğerdir. Bu, yerel minimumlarda takılıp kalma riski olmayan, nonlinear optimizasyon gerektiren bir çözüm olduğu anlamına gelir [11].

Standart SVM, bir girdi veri kümesini ele alır. Her bir girdi için girdinin hangi iki olası sınıftan oluştuğunu tahmin eder. Bu da SVM'yi olasılıksız ikili doğrusal bir sınıflandırıcı yapar. İki kategoriye ait olduğu belirtilen bir eğitim örnekleri kümesi verildiğinde, bir SVM eğitim algoritması, yeni örnekleri bir kategoriye veya diğerine atayan bir model oluşturur. Bu makine öğrenme algoritması örnekleri ayrık bir boşlukla bölen haritalandırılmış bir uzaydaki noktalar olarak tarif edilebilir. Yeni örnekler daha sonra aynı uzaya haritalanır ve hangi tarafta olduklarına bağlı olarak bir kategoriye ait olduklarını tahmin edilebilir [95].

3.5.9. K Katlamalı Çapraz Doğrulama

Bağımsız veri kümelerini genelleştirebilecek bir yöntemdir. Bu teknik, bir öngörü modelinin pratikte çalıştığında ne kadar doğru olabileceğini tahmin eder. Model tahminler yapmak için kullanılır. Modelin test aşamasını tanımlamanın amacı, veri doğrulaması yapmak ve bu gibi sorunların ortaya çıkmasını sınırlamaktır. Ayrıca, modelin veri kümesinden bağımsız olarak nasıl genelleştirileceği hakkında bir anlayış sağlayacaktır. Şekil 3.14'te 10-Katmanlı Çapraz Doğrulamalı Test yöntemi şematik olarak gösterilmiştir [36].



Şekil 3.15: 10 katlamalı çapraz doğrulamalı test

Bu makine öğrenme algoritması bir modelin pratikte ne kadar doğru performans göstereceğini tahmin etmek için kullanılır. Eğitim alt işlemi ve Test alt işlemi olarak üzere Çapraz Doğrulama Operatörü, iki alt işleme sahiptir. Eğitim alt işlemi, bir modelin eğitimi için kullanılır. Eğitilen model daha sonra Test alt işlemi içinde uygulanır. Modelin performansı Test aşamasında ölçülür [96].

Giriş Örnek Kümesi, eşit boyutta k alt kümeye bölünür. Bu k kümelerden biri, test veri kümesi olarak tutulur. Yani, test alt işleminin girdisi olarak tutulur. Kalan $k-1$ kümeleri ise eğitim veri kümesi olarak kullanılacaktır. Eğitim alt işleminin girdisi olarak kullanılacaktır. Çapraz doğrulama süreci daha sonra k kez tekrar edilir ve k kümeleri, test verisi olarak tam olarak bir kez kullanılır. k tekrardan elde edilen k kadar sonuç, ortalaması alınır veya başka şekilde birleştirilir ve tek bir tahmin üretmek için kullanılır. k değeri, katlama sayısı parametresi kullanılarak ayarlanabilir [96].

Bir modelin bağımsız test kümelerindeki performansının değerlendirilmesi, görülmemiş veri kümelerindeki performansın iyi bir tahminini verecektir. Ayrıca aşırı öğrenme durumunu da gösterir. Bu, modelin test verilerini çok iyi temsil ettiği ancak yeni veriler için iyi bir genelleme yapmadığı anlamına gelir. Bu nedenle, performans test verileri çok daha kötü olabilmektedir [96].



4. BULGULAR

Bu arařtırmada 5 hisse, 74 bağımsız deęiřken ve 8 makine öğrenme algoritması kullanarak testler yapılmıřtır. Yapılan çalışmalar sonucunda ařağıdaki bulgular elde edilmiřtir. Öncelikle 5 hisse için tahmin edilen fiyat ve gerçek fiyatın karřılařtırıldıęı grafikler verilmiřtir. Ayrıca bu bölümde test sonuçları tek tek ele alınıp tartıřılmıřtır.

Modellerin hata oranını ölçmek için Kök Ortalama Kare Hata (RMSE), Ortalama Mutlak Hata (MAE) ve Ortalama Mutlak Yüzde Hata (MAPE) kullanılacaktır [97]. Tahmin modelinin doęruluęu genellikle tahmin hata düzeyiyle ölçölür. Tahmin hatası ne kadar düşük ise, tahmin doęruluęu o kadar doęru olacaktır [15].

Hataların karelerinin ortalamasının karekökünü ölçmek için kullanılan metrik, RMSE'dir ve ařağıdaki formöl ile ifade edilir [97].

$$RMSE = \sqrt{\frac{\sum_1^n (gerçek - tahmin)^2}{n}}$$


Bu metrik, hataların yayılma derecesini tahmin hatalarının standart sapması ile ölçümleri gerçekteřtirir. Ortalama mutlak hata (MAE) ise çift gözlemler arasındaki hataları hesaplar ve bu hataların mutlak deęerlerinin ortalayarak ölçüm yapan bir metriktir. Ařağıdaki formölde gösterildięi řekilde hesaplar [97].

$$MAE = \frac{\sum_1^n |gerçek - tahmin|}{n}$$

Bu arařtırmada kullanılan bir dięer hata oranı ise MAPE oranıdır. Hata oranını yüzde olarak ölçer. Tahmin mutlak yüzde hatalarının ortalaması ile hesaplanır. MAPE ařağıdaki formöl ile tanımlanır [97].

$$MAPE = \frac{\sum_1^n |gerçek - tahmin|}{\frac{gerçek}{n}} \times 100$$

Bu hata oranları, modellerin tahminleri ne doęrulukta gerçekteřtirdięini öğrenmek için kullanılacaktır.



Şekil 4.1: Write excel operatörü

Rapid Miner RMSE, MAPE ve MAE hata oranları hesaplama seçenekleri programda mevcut değildir. Bu yüzden kurulan model Şekil 4.1’de gösterildiği şekilde düzenlenecektir. Apply operatörünün çıkışına write Excel operatörü bağlanılır. Rapid Miner programından bu şekilde Excel dosya formatında çıktı alınabilir. Bu Excel dosyalarındaki veri ile hata oranları hesaplanacaktır. Tahmin sonuçları Tablo 4.1’de gösterildiği şekilde elde edilir.

Tablo 4.1: Omv fiyat tahmini


Açılış Fiyat	Tavan Fiyat	Taban Fiyat	Fiyat / Defter Değeri	NYSE	CAC40	Date	Fiyat	Tahmin (Fiyat)
53,3	53,7	52,0	1,1	16513,2	6597,4	13.10.2021	52,8	52,9
53,0	53,5	52,2	1,1	16744,3	6685,2	14.10.2021	53,1	52,9
54,0	54,9	53,8	1,1	16871,7	6727,5	15.10.2021	54,4	53,7
.	.	.	.	.	.	.	.	.
.	.	.	.	.	.	.	.	.
.	.	.	.	.	.	.	.	.
47,36	48,35	47,31	0,972206648	14497,8	6276,88	02.11.2022	48,04	45,2
47,75	48,4	47,17	0,972206648	14455,7	6243,28	03.11.2022	47,87	45,2
48,09	50	48,09	0,972206648	14702,8	6416,44	04.11.2022	49,56	46,4

Daha sonra Tablo 4.1’de gösterilen veriler kullanılarak RMSE, MAPE ve MAE hata oranları hesaplanır.

ExampleSet (TEST)		Random Forest Model (Random Forest)		Performa			
Open in		Turbo Prep	Auto Model				
Row No.	Date	Price	prediction(P...	Open	High	Low	cac-40-france
1	Oct 13, 2021	52.760	52.919	53.320	53.700	52.040	6597.380
2	Oct 14, 2021	53.100	52.920	53	53.480	52.200	6685.210
3	Oct 15, 2021	54.420	53.731	54	54.940	53.800	6727.520
269	Nov 2, 2022	48.040	45.209	47.360	48.350	47.310	6276.880
270	Nov 3, 2022	47.870	45.220	47.750	48.400	47.170	6243.280
271	Nov 4, 2022	49.560	46.404	48.090	50	48.090	6416.440

Şekil 4.2: Rapid miner omv random forrest tahmin sonuçları

5 hisse için 8 farklı algoritma kullanılarak tahminler gerçekleştirilir. Örneğin OMV şirketi için Random Forrest makine öğrenme algoritması kullanılarak elde edilen sonuçlar Şekil 4.2’de gösterilmiştir. Kullanılan programın birçok farklı modülü mevcuttur. Bu şekilde liste şeklinde elde edilen tahmin fiyat verisi grafik, şekil ile Rapid Miner programı ile görselleştirilebilmektedir.



Şekil 4.3: Omv tahmin ve gerçek fiyat grafiği


Rapid Miner programı içerisinde yer alan grafik oluşturma aracı kullanılarak elde edilen tahmin sonuçları ve gerçek fiyat değerleri 2021-2022 yılları için Şekil 4.3’te gösterilmiştir. Bu grafikte Omv şirketi için SVM algoritması ile gerçekleştirilen tahminler ve gerçek fiyat verisi görülebilmektedir. Grafikteki renkli noktalar SVM

algoritması ile gerçekleştirilen tahminleri göstermektedir. Lineer çizgi şeklinde gösterim ise gerçek fiyat verisini ifade etmektedir.



Şekil 4.4: Shell tahmin ve gerçek fiyat grafiği

Neural Network algoritması kullanılarak test verisi fiyat verisi tahmin değerleri ve gerçek fiyat değerleri Şekil 4.4'te gösterilmiştir. Bu tahminler Shell şirketi için gerçekleştirilmiştir. Test verisi 2021-2022 yılları arası veriyi içermektedir.



Şekil 4.5: Chevron tahmin ve gerçek fiyat grafiği

SVM algoritması kullanılarak test verisi fiyat verisi tahmin değerleri ve gerçek fiyat değerleri Şekil 4.5'te gösterilmiştir. Bu tahminler Chevron şirketi için gerçekleştirilmiştir. Test verisi 2021-2022 yılları arası veriyi içermektedir.



Şekil 4.6: Total tahmin ve gerçek fiyat grafiği

SVM algoritması kullanılarak test verisi fiyat verisi tahmin değerleri ve gerçek fiyat değerleri Şekil 4.6’da gösterilmiştir. Bu tahminler Total şirketi için gerçekleştirilmiştir. Test verisi 2021-2022 yılları arası veriyi içermektedir.



Şekil 4.7: Tüpraş tahmin ve gerçek fiyat grafiği

SVM algoritması kullanılarak test verisi fiyat verisi tahmin değerleri ve gerçek fiyat değerleri Şekil 4.7’de gösterilmiştir. Bu tahminler Tüpraş şirketi için gerçekleştirilmiştir. Test verisi 2021-2022 yılları arası veriyi içermektedir.

Tablo 4.2: Chevron farklı algoritmalar analiz sonuçları

Chevron:NYSE	RMSE	MAPE (%)	MAE
Decision Tree	23,20	10,74	17,57
Deep Learning	17,16	8,54	13,77
Gradient Boosted	35,86	19,08	30,27
KNN	25,13	14,11	21,67
Lineer Regresyon	2,14	1,04	1,57
Neural Network	4,38	2,07	3,34
Random Forrest	24,58	11,58	18,88
SVM	1,33	0,68	1,01

Modeller çalıştırıldığında algoritmaların hata oranları Tablo 1.8-1,12 gösterilmiştir. Örneğin Chevron şirketi için en düşük hata oranı SVM algoritması ile elde edilmiştir. Yıllık bazda fiyat tahminleri gerçekleştirildiği için hata oranları yüksek çıkmaktadır. Çalışmanın amacı hangi modelin hangi hisse senedi için daha doğru tahminleri gerçekleştireceğini bulmak olduğu için hata oranlarının birbiriyle karşılaştırılması yapılmıştır.

Tablo 4.3: Omv farklı algoritmalar analiz sonuçları

DB:OMV	RMSE	MAPE (%)	MAE
Decision Tree	1,00	1,48	0,69
Deep Learning	3,18	5,76	2,73
Gradient Boosted	7,68	13,85	6,79
KNN	11,06	20,54	9,61
Lineer Regresyon	0,88	1,31	0,59
Neural Network	0,52	0,93	0,42
Random Forrest	1,64	2,54	1,21
SVM	0,40	0,83	0,29

OMV şirketi için en düşük hata oranı SVM algoritması kullanılarak elde edilmiştir. Tablo 4.3'te farklı algoritmaların hata oranları gösterilmiştir.

Tablo 4.4: Shell farklı algoritmalar analiz sonuçları

Shell:LSE	RMSE	MAPE (%)	MAE
Decision Tree	28,39	0,94	21,33
Deep Learning	77,62	2,72	58,94
Gradient Boosted	157,33	6,74	135,37
KNN	71,63	2,56	55,45
Lineer Regresyon	324,07	15,36	317,58
Neural Network	27,75	0,93	19,69
Random Forrest	30,21	1,07	22,84
SVM	64,71	2,99	59,06

Shell şirketi için MAPE, MAE ve RMSE hata oranlarına göre Neural Network makine öğrenme modeli daha üstün sonuçlar elde etmiştir. Tablo 4.4'te farklı algoritmaların hata oranları gösterilmiştir. İncelenen diğer 4 hisseden fiyat tahmininden farklı olarak Shell şirketi için Neural Network makine öğrenme algoritması daha doğru sonuçlar elde etmiştir.

Tablo 4.5: Total farklı algoritmalar analiz sonuçları

Total:ENXTPA	RMSE	MAPE (%)	MAE
Decision Tree	1,52	2,36	1,23
Deep Learning	2,68	4,90	2,51
Gradient Boosted	5,27	8,42	4,43
KNN	6,47	10,15	5,32
Lineer Regresyon	0,80	1,31	0,66
Neural Network	0,65	0,97	0,49
Random Forrest	2,04	3,10	1,63
SVM	0,46	0,79	0,34

Total şirketi için en düşük hata oranları, SVM algoritması kullanılarak elde edilmiştir. Tablo 4.5'te farklı algoritmaların hata oranları gösterilmektedir. SVM, RMSE, MAPE ve MAE hata oranlarına göre diğer algoritmalarından daha üstün sonuçlar elde etmiştir.

Tablo 4.6: Tüpraş farklı algoritmaların analiz sonuçları

TUPRS:BIST	RMSE	MAPE (%)	MAE
Decision Tree	122,98	35,27	98,74
Deep Learning	128,85	42,33	111,66
Gradient Boosted	163,99	56,59	146,17
KNN	139,04	43,72	117,69
Lineer Regresyon	30,38	12,55	27,22
Neural Network	46,29	9,92	30,43
Random Forrest	133,60	40,32	110,37
SVM	6,62	2,07	5,00

Tüpraş şirketi için en düşük hata oranları SVM algoritması ile elde edilmiştir. Tablo 4.6’da farklı algoritmaların hata oranları gösterilmiştir.

Farklı makine öğrenme algoritmalarının birbiriyle karşılaştırıldığı çalışmalar incelenmiştir. Literatürde bu çalışmaya benzer şekilde farklı makine algoritmaları farklı çalışmalarda en üstün sonuçları elde etmiştir. Bu araştırmada ve literatürde yer alan araştırmalarda olduğu gibi ilgili testler yapılmadan fiyat tahmini için en iyi algoritma ve en kötü algoritma şeklinde yöntemleri sınıflandırmak mümkün değildir.

Literatürde hangi makine öğrenme algoritmalarının kullanıldığı incelenmiştir, en başarılı algoritma hangisi olduğu araştırılmıştır. Literatürde birçok makine öğrenme algoritmasını birbiriyle karşılaştıran çalışma mevcuttur. SVM ile diğer makine öğrenme algoritmalarından daha başarılı sonuçlar elde edilen çalışmalar olmuştur [19, 20, 24, 12, 39]. Derin öğrenme algoritması ile diğer yöntemlerden daha başarılı sonuçlar elde eden çalışmalar da literatürde vardır [6, 10, 30, 33, 40]. Ayrıca Random Forrest algoritması ile diğer algoritmalarından daha doğru tahminler elde eden çalışmalar da vardır [4, 28, 15].

Bulgular kısmında elde edilen sonuçlar yatırımcılar için kullanılabilir. Örneğin Fransa’da yatırım yapan yatırımcılar, Total şirketine yatırım yaparken kendileri için önemli olan değişkenleri bilebilecektir. Korelasyon sonuçları incelendiğinde tarihsel fiyat, Fransa ve İngiltere’nin Petrol Endeks fiyatı gibi verilerin kendisi için önemli olduğu sonucuna ulaşabilecektir. Ayrıca aktif karlılık, fiyat-defter değeri gibi temel rasyoların bu hisseye yatırım yaptığında hisse fiyatını etkileyen değişkenlerden olduğunu bilebilecektir. Bu şekilde 5 farklı ülkede bu şirketlere yatırım yapan yatırımcılar, bu çalışmanın bulgular kısmından faydalanarak kendileri için önemli değişkenler hangileri olduğu hakkında fikir sahibi olabilecektir

5. SONUÇLAR

Bu çalışmada bağımsız değişken sayısını arttırılarak ve farklı makine öğrenmesi algoritmalarını kullanarak sadece bir sektöre çalışmanın odağı yöneltilerek bu çalışma gerçekleştirilmiştir. Daha önce literatürde gerçekleştirilen çalışmalardan farklı olarak daha önce kullanılmamış piyotroski skor ve petrol üretim verileri ve EFT'ler gibi bağımsız değişkenler kullanılmıştır. Bu şekilde daha başarılı tahminler gerçekleştirilebilir mi bu araştırılmıştır.

Literatürde mevcut olan ama yeni gelen finansal sektördeki gelişmelerle birlikte çok fazla teknik indikatörler rasyolar ve finansal göstergeler mevcuttur. Bu sebeple bu çalışmada çok sayıdaki indikatör ve bağımsız değişken ve farklı makine öğrenme algoritmaları kullanılmıştır.

5 hisse için 8 tahmin algoritması kullanılarak tahminler gerçekleştirilmiştir. Yapılan analizler sonucu 5 farklı ülkeden (Türkiye, Amerika, Fransa, İngiltere ve Avusturya) 5 hisse senedi (Tüpraş, Total, Shell, OMV, Chevron) ve 8 farklı algoritma (SVM, Random Forrest, KNN, Decision Tree, Lineer Regresyon, Derin Öğrenme, Gradient Boosted, Neural Network) kullanılarak 40 ayrı analiz gerçekleştirilmiştir. Elde edilen bulgular Tablo 4.2-4.6'de gösterilmiştir. RMSE, MAE ve MAPE hata oranlarına göre değerlendirmeler gerçekleştirilmiştir.

Total, Tüpraş, OMV ve Chevron hisseleri için SVM algoritması en düşük hata oranları ile tahminler gerçekleştirmiştir. Shell şirketi için en doğru sonuçlar Neural Network algoritması ile elde edilmiştir.

Bu sonuçlara göre: Her hisse için tek bir doğru en iyi yöntem olduğunu söylemek mümkün değildir. Yöntemlerin çoğunda SVM en doğru sonucu vermiş olmasına rağmen hisse fiyatının en doğru şekilde tahmin edilebilmesi için her hisse için en doğru algoritmanın tespit edilmesi önemlidir. Yatırımcıların tek bir algoritmaya bağlı kalarak hisse değer tahminleri yapması bu çalışmadan çıkan sonuca göre yeterli olmayacaktır. Yatırımcıların portföylerinde yer alan her hisse için uygun algoritmanın seçilmesi önemlidir. Bu şekilde yatırımlarındaki riskler en aza indirgenmiş olabilecek ve daha karlı yatırımların yapılması mümkün olabilecektir.

5 hisse fiyat tahmini için kullanılan değişkenlerin tespit edilebilmesi için Rapid Miner programında Auto Model kullanılmıştır. İncelenen değişkenler arasından en yüksek

korelasyon değerlerine günlük fiyat değişkenleri sahiptir. Daha sonra yüksek korelasyon değerlerini temel indikatörler, ülke endeksleri elde etmiştir. En düşük korelasyon değerlerine ise teknik göstergeler ve petrol üretim verileri sahip olmuştur. Shell hisse fiyat değişkeni ile teknik indikatör, döviz kuru ve petrol üretim verileri cinsinden değişkenler arasında korelasyon sonuçları zayıf olarak bulunmuştur. Chevron ve OMV hisse fiyatı ile petrol üretim verileri ve petrol fiyatı-döviz kuru cinsinden değişkenler arasındaki korelasyon sonuçları yine zayıftır. Total Enerji şirketi için yine aynı şekilde teknik indikatör ve petrol fiyatı-döviz kuru cinsinden değişkenler ile arasında zayıf korelasyon vardır.

Bu çalışmada sadece belirli bir sektöre odaklanılmıştır. Bu sektördeki hisselerin performansını etkileyen değişkenlerin önem düzeyi tespit edilmiştir. Bu şekilde spesifik bir alana yöneldiğimizde daha doğru tahminler elde edilebileceği düşünülmektedir.

Sonuç olarak bu çalışma literatüre tahmin algoritmalarında kullanılan değişken sayısı ve bu değişken çeşitliliğinin tahminleri nasıl etkilediğini görebilmek için önemli bir katkı sunacaktır. Günlük fiyat bağımsız değişkeni önemli bir faktör olduğu sonucuna varılmıştır. Yatırımcılar için kurulan bu modeller yol gösterici olabilecektir. Yatırımcılar rafineri sektöründe faaliyet gösteren şirketlere yatırım yaptıklarında hangi faktörlerin önemli olacağını bileceklerdir.

Bu çalışmada makine öğrenme algoritması ve korelasyon analizi gerçekleştirilerek 2 aşamadan oluşan bir model önerilmiştir. Bu tahmin algoritmalarının elde ettiği sonuçlara göre bulgular tartışılmıştır. Bu şekilde bir model önerisinin yanında temel analiz ve teknik analiz yöntemlerini kullanan yatırımcılar için de belirli sonuçlar elde edilmiştir.

Ayrıca bu çalışmadan bu şirketlere temel ve teknik analiz yöntemlerini kullanarak yatırımlar yapan yatırımcılar için de belirli sonuçlar elde edilmiştir ve bu şirketlere yatırım yapan kişiler için faydalı olabileceği düşünülmektedir. Örneğin Total şirketi için yatırımlar gerçekleştirecek yatırımcı Cac Petrol Gaz endeksinin kendisi için önemli olduğu zaten tahmin edilebilir bir olgudur. Fakat İngiltere FTSE 350 Petrol Gaz Endeksi verisi veya FTSE 100 endeksinin Total fiyat verisi ile ilişkili olduğu sonucu bulunmuştur. Elde edilen bu korelasyon sonuçları aynı kıtada faaliyet gösteren şirket ve market fiyatları arasında anlamlı ilişki mevcuttur sonucu çıkarılabilir. Buna

ek olarak S&P 500 Enerji endeksi ve Total şirketi arasında bulunan korelasyon sonuçları üzerinden dünyanın küresel bir Pazar ve birçok finansal piyasa ve marketin birbiriyle ilişkili olduğu sonucuna ulaşılabilmektedir. Elde edilen bu sonuçlar ile Total şirketine yatırım yapan kişi yatırımlarında bu unsurları da dikkate alarak gerçekleştirmelidir. Total şirketini temel analiz yöntemleri açısından inceleyen yatırımcılar için en önemli temel analiz bağımsız değişkeni öz sermaye karlılığı oranı olarak bulunmuştur. Teknik analiz yöntemlerini kullanarak yatırımlar gerçekleştiren yatırımcılar için herhangi bağımsız değişken önerilememiştir.

Tüpraş şirketine yatırım yapacak yatırımcılar için elde edilen korelasyon sonuçları detaylı olarak incelenmiştir. Bu hisse ile Amerikan borsaları Nasdaq, S&P 500 ve NYSE ile anlamlı korelasyon sonuçları elde edilmiştir. Türkiye borsa endeksleri Bist 30, Bist 100, Bist Petrol Endeksi, Bist Elektrik endeksi ile anlamlı korelasyon sonuçları elde edilmiştir. Bunlara ek olarak İngiltere, Almanya ve Fransa borsa endeksleri ile de ilişkili korelasyon sonuçları bulunmuştur. Bunların yanında Tüpraş şirketine temel analiz yöntemleri kullanılarak yatırım yapılacaksa piyasa değeri ve işletme değeri gibi bağımsız değişkenler önemli bağımsız değişkenler olduğu sonucuna ulaşılmıştır. Elde edilen bu sonuçlar ile yatırımcılar için hangi bağımsız değişkenlerin daha önemli olduğu bulunabilmektedir. Temel analiz yöntemlerini kullanarak yatırımlar gerçekleştirecek yatırımcılar için çıkan sonuç ise en önemli bağımsız değişken toplam işletme değeri olarak bulunmuştur.

Shell şirketine yatırım yapan kişiler için sonuçlar detaylı olarak incelenmiştir. İngiltere ve Fransa ve Amerikan Dow Jones petrol gaz endeksleri arasında anlamlı sonuçlar bulunmuştur. Temel analiz yöntemleri ile bu şirketlere yatırım yapılacaksa en önemli bağımsız değişkenler fiyat/defter değeri, aktif karlılık ve öz sermaye karlılığı olarak bulunmuştur. Teknik analiz yöntemlerini kullanarak bu şirkete yatırım yapacak kişiler için önerilecek bağımsız değişken bulunamamıştır.

Chevron şirketine yatırımlar gerçekleştirilecekse, yatırımcılar için belirli sonuçlar bulunmuştur. Ülke endeksleri açısından incelenirse İngiltere ve Amerikan enerji endeksleri için anlamlı korelasyon sonuçları bulunmuştur. Temel analiz yöntemini kullanarak bu hisseye yatırımlar gerçekleştirilecekse en önemli bağımsız değişken işletme değeri/yatırım sermayesi olarak bulunmuştur. Teknik analiz değişkenleri kullanarak bu şirkete yatırımlar gerçekleştirildiği durumda çalışmadan kullanılan

bağımsız değişkenlerin arasından en anlamlı korelasyon sonucu obv bağımsız değişkeni için bulunmuştur.

Çalışmadan elde edilen sonuçlara göre OMV şirketine yatırımlar yapacaksa; Omv hisse fiyatı ile Fransa, Amerika ve Alman borsa endeksleri arasında anlamlı korelasyon sonuçları bulunmuştur. Avusturya şirketi için Avrupa'daki diğer ülke endeksleri ile anlamlı korelasyon sonuçlarının bulunması tahmin edilebilir bir sonuçtur. Temel analiz yöntemlerini kullanarak bu hisseye yatırımlar gerçekleştirecekse ise en anlamlı temel analiz bağımsız değişkeni fiyat/defter değeri oranı olarak bulunmuştur.

Yapılan çalışmanın 5 farklı ülke için de ortak değişkenler kullanılmıştır. Her ülke için ortak olan bu bağımsız değişkenler ile farklı ülke borsalarında faaliyet gösteren hisse fiyatları arasındaki ilişkiyi gözlemleyebilmek için bu yöntem tercih edilmiştir. Bu şekilde 74 adet bağımsız değişken kullanılması bu çalışmanın kısıtı olmuştur. Her ülkeye özgü küresel olmayan indikatörler kullanılamamıştır. Gelecekte ülkelere özgü bağımsız değişkenler kullanılarak tahmin performanslarını nasıl etkilediğini araştırmak için farklı çalışmalar yürütülebilir. Bu değişkenler ile hisse fiyatı arasında ne kadar güçlü korelasyon değerleri var. Bu bağımsız değişkenler kullanıldığında tahmin performansları nasıl değişiyor sorularına yanıtlamak için bu araştırmalar yürütülebilir.

Ayrıca bu çalışmada seçilen şirketler için kullanılan veri setlerinin eksiksiz olması nedeniyle bu şirketler seçilmiştir. Çalışmaya dahil edilmesi planlanan bazı şirketler, bazı değişken tiplerinde eksiklik bulunması nedeniyle çalışmaya dahil edilememiştir. Seçilen şirket sayısı, bu çalışmanın bir diğer kısıtı olmuştur.





KAYNAKLAR

- [1] E. K. Ampomah, G. Nyame, Z. Qin, P. C. Addo, E. O. Gyamfi and M. Gyan, "Stock market prediction with gaussian naive bayes machine learning algorithm," *Informatica (Slovenia)*, vol. 45, no. 2, pp. 243–256, Jun. 2021, doi: 10.31449/inf.v45i2.3407.
- [2] R. L. D. Almeida and R. F. Neves, "Stock market prediction and portfolio composition using a hybrid approach combined with self-adaptive evolutionary algorithm," *Expert Syst Appl*, vol. 204, Oct. 2022, doi: 10.1016/j.eswa.2022.117478.
- [3] M. Vijh, D. Chandola, V. A. Tikkiwal, A. Kumar, "Stock Closing Price Prediction using Machine Learning Techniques," in *Procedia Computer Science*, Elsevier B.V., 2020, pp. 599–606. doi: 10.1016/j.procs.2020.03.326.
- [4] L. Khaidem, S. Saha and S. R. Dey, "Predicting the direction of stock market prices using random forest," Apr. 2016, [Online]. Available: <http://arxiv.org/abs/1605.00003>
- [5] K. Sutradhar, S. Sutradhar, A. I. Iqbal, S. K. Gupta, and M. M. Khan, "Stock market prediction using recurrent neural network's lstm architecture," in *2021 IEEE 12th Annual Ubiquitous Computing, Electronics and Mobile Communication Conference, UEMCON 2021*, Institute of Electrical and Electronics Engineers Inc., 2021, pp. 541–547. doi: 10.1109/UEMCON53757.2021.9666562.
- [6] M. Biswas, A. Shome, A. Islam, A. J. Nova and A. Shamim, "Predicting stock market price: A logical strategy using deep learning," in *ISCAIE 2021 - IEEE 11th Symposium on Computer Applications and Industrial Electronics*, Institute of Electrical and Electronics Engineers Inc., Apr. 2021, pp. 218–223. doi: 10.1109/ISCAIE51753.2021.9431817.
- [7] B. M. Henrique, V. A. Sobreiro and H. Kimura, "Stock price prediction using support vector regression on daily and up to the minute prices," *Journal of Finance and Data Science*, vol. 4, no. 3, pp. 183–201, Sep. 2018, doi: 10.1016/j.jfds.2018.04.003.
- [8] A. Doshi, A. Issa, P. Sachdeva, S. Rafati and S. Rakshit, "Deep Stock Predictions," Jun. 2020, [Online]. Available: <http://arxiv.org/abs/2006.04992>
- [9] M. Nikou, G. Mansourfar, and J. Bagherzadeh, "Stock price prediction using DEEP learning algorithm and its comparison with machine learning algorithms," *Intelligent Systems in Accounting, Finance and Management*, vol. 26, no. 4, pp. 164–174, Oct. 2019, doi: 10.1002/isaf.1459.
- [10] M. Nabipour, P. Nayyeri, H. Jabani, S. Shahab and A. Mosavi, "Predicting Stock Market Trends Using Machine Learning and Deep Learning Algorithms Via Continuous and Binary Data; A Comparative Analysis," *IEEE Access*, vol. 8, pp. 150199–150212, 2020, doi: 10.1109/ACCESS.2020.3015966.

- [11] Z. Hu, J. Zhu, and K.Tse, "Stocks market prediction using support vector machine," in Proceedings of 2013 6th International Conference on Information Management, Innovation Management and Industrial Engineering, ICIII 2013, 2013, pp. 115–118. doi: 10.1109/ICIII.2013.6703096.
- [12] U. Demirel, H. Cam and R. Unlu, "Predicting stock prices using machine learning methods and deep learning algorithms: the sample of the istanbul stock exchange," Gazi University Journal of Science, vol. 34, no. 1, pp. 63–82, 2021, doi: 10.35378/gujs.679103.
- [13] J. Patel, S. Shah, P. Thakkar, and K. Kotecha, "Predicting stock market index using fusion of machine learning techniques," Expert Syst Appl, vol. 42, no. 4, pp. 2162–2172, 2015, doi: 10.1016/j.eswa.2014.10.031.
- [14] W. Xie, L. Yu, S. Xu, and S. Wang, "LNCS 3994 - A New Method for Crude Oil Price Forecasting Based on Support Vector Machines," 2006.
- [15] E. Chen and X. J. He, "Crude Oil Price Prediction with Decision Tree Based Regression Approach," Journal of International Technology and Information Management, vol. 27, no. 4, pp. 2–16, May 2019, doi: 10.58729/1941-6679.1391.
- [16] A. Khashman and N. I. Nwulu, "Intelligent prediction of crude oil price using support vector machines," in 9th IEEE International Symposium on Applied Machine Intelligence and Informatics, SAMI 2011 - Proceedings, 2011, pp. 165–169. doi: 10.1109/SAMI.2011.5738868.
- [17] investing.com, "Investing." Accessed: May 10, 2023. [Online]. Available: <https://www.investing.com>
- [18] ycharts.com, "Ycharts." Accessed: May 10, 2023. [Online]. Available: <https://www.ycharts.com>
- [19] S. P. Das and S. Padhy, "Support Vector Machines for Prediction of Futures Prices in Indian Stock Market," 2012.
- [20] Shen, Shunrong, Haomiao Jiang and Tongda Zhang. "Stock Market Forecasting Using Machine Learning Algorithms." (2012).
- [21] O. Hegazy, O. S. Soliman and M. A. Salam, "A machine learning model for stock market prediction," International Journal of Computer Science and Telecommunications, vol. 4, no. 12, pp. 17–23, 2013.
- [22] M. Qiu and Y. Song, "Predicting the direction of stock market index movement using an optimized artificial neural network model," PLoS One, vol. 11, no. 5, May 2016, doi: 10.1371/journal.pone.0155133.
- [23] S. Basak, S. Kar, S. Saha, L. Khaidem and S. R. Dey, "Predicting the direction of stock market prices using tree-based classifiers," North American Journal of Economics and Finance, vol. 47, pp. 552–567, Jan. 2019, doi: 10.1016/j.najef.2018.06.013.

- [24] D. C. A. Mallqui and R. A. S. Fernandes, "Predicting the direction, maximum, minimum and closing prices of daily Bitcoin exchange rate using machine learning techniques," *Applied Soft Computing Journal*, vol. 75, pp. 596–606, Feb. 2019, doi: 10.1016/j.asoc.2018.11.038.
- [25] J. Wang, T. Sun, B. Liu, Y. Cao, and D. Wang, "Financial Markets Prediction with Deep Learning," in *Proceedings - 17th IEEE International Conference on Machine Learning and Applications, ICMLA 2018*, Institute of Electrical and Electronics Engineers Inc., Jan. 2019, pp. 97–104. doi: 10.1109/ICMLA.2018.00022.
- [26] Y. Abuzir and A. M. Baraka, "Financial stock market forecast using data mining in palestine," *Palestinian Journal of Technology & Applied Sciences*, pp. 2104–2109, 2019, doi: 10.5281/zenodo.2582909.
- [27] E. Beyaz, F. Tekiner, X. J. Zeng and J. Keane, "Comparing Technical and Fundamental Indicators in Stock Price Forecasting," in *Proceedings - 20th International Conference on High Performance Computing and Communications, 16th International Conference on Smart City and 4th International Conference on Data Science and Systems, HPCC/SmartCity/DSS 2018*, Institute of Electrical and Electronics Engineers Inc., Jan. 2019, pp. 1607–1613. doi: 10.1109/HPCC/SmartCity/DSS.2018.00262.
- [28] H. Pabuçcu, S. Ongan and A. Ongan, "Forecasting the movements of Bitcoin prices: an application of machine learning algorithms," *Quantitative Finance and Economics*, vol. 4, no. 4, pp. 679–692, 2020, doi: 10.3934/QFE.2020031.
- [29] I. K. Nti, A. F. Adekoya, and B. A. Weyori, "A systematic review of fundamental and technical analysis of stock market predictions," *Artif Intell Rev*, vol. 53, no. 4, pp. 3007–3057, Apr. 2020, doi: 10.1007/s10462-019-09754-z.
- [30] G. Bathla, "Stock price prediction using lstm and svr," in *PDGC 2020 - 2020 6th International Conference on Parallel, Distributed and Grid Computing*, Institute of Electrical and Electronics Engineers Inc., Nov. 2020, pp. 211–214. doi: 10.1109/PDGC50313.2020.9315800.
- [31] E. K. Ampomah, Z. Qin and G. Nyame, "Evaluation of tree-based ensemble machine learning models in predicting stock price direction of movement," *Information (Switzerland)*, vol. 11, no. 6, Jun. 2020, doi: 10.3390/info11060332.
- [32] X. Yuan, J. Yuan, T. Jiang and Q. U. Ain, "Integrated Long-Term Stock Selection Models Based on Feature Selection and Machine Learning Algorithms for China Stock Market," *IEEE Access*, vol. 8, pp. 22672–22685, 2020, doi: 10.1109/ACCESS.2020.2969293. 04698-5.
- [33] S. S. Roy, R. Chopra, C. K. Lee, C. Spampinato and B. M. Ivatlood, "Random forest, gradient boosted machines and deep neural network for stock price forecasting: a comparative analysis on South Korean companies," *Int. J. Ad Hoc and Ubiquitous Computing*, vol. 33, no. 1, 2020.

- [34] C. Xiao, W. Xia, and J. Jiang, "Stock price forecast based on combined model of ARI-MA-LS-SVM," *Neural Comput Appl*, vol. 32, no. 10, pp. 5379–5388, May 2020, doi: 10.1007/s00521-019-
- [35] A. U. Haq, A. Zeb, Z. Lei, D. Zhang "Forecasting daily stock trend using multi-filter feature selection and deep learning," *Expert Syst Appl*, vol. 168, Apr. 2021, doi: 10.1016/j.eswa.2020.114444.
- [36] Y. Suryana and T. W. Sen, "JISA (Jurnal Informatika dan Sains) The Prediction of Gold Price Movement by Comparing Naive Bayes, Support Vector Machine, and K-NN," *JISA (Jurnal Informatika dan Sains)*, vol. 4, no. 2, pp. 112–120, 2021, [Online]. Available: www.finance.yohoo.com,
- [37] J. Rasheed, A. Jamil, A. A. Hameed, M. Ilyas, A. Ozyavas, and N. Ajlouni, "Improving stock prediction accuracy using cnn and lstm," in *2020 International Conference on Data Analytics for Business and Industry: Way Towards a Sustainable Economy, ICDABI 2020*, Institute of Electrical and Electronics Engineers Inc., Oct. 2020. doi: 10.1109/ICDABI51230.2020.9325597.
- [38] W. Chen, L. Jia, Z. Haoyu, and M. K. Mehlawat, "Mean–variance portfolio optimization using machine learning-based stock price prediction," *Appl Soft Comput*, vol. 100, Mar. 2021, doi: 10.1016/j.asoc.2020.106943.
- [39] S. Xiaolei, L. Mingxi and S. Zeqian, "A novel cryptocurrency price trend forecasting model based on LightGBM," *Financ Res Lett*, vol. 32, Jan. 2020, doi: 10.1016/j.frl.2018.12.032.
- [40] S. Mokhtari, K. K. Yen and J. Liu, "Effectiveness of artificial intelligence in stock market prediction based on machine learning," *International Journal of Computer Applications* , vol. 183, no. 7, Jun. 2021, doi: 10.5120/ijca2021921347.
- [41] investing.com, "Cvx." Accessed: Jan. 10, 2023. [Online]. Available: <https://www.investing.com/equities/chevron>
- [42] investing.com, "TUPRS." Accessed: Feb. 25, 2023. [Online]. Available: <https://www.investing.com/equities/tupras>
- [43] investing.com, "OMV." Accessed: Feb. 25, 2023. [Online]. Available: <https://www.investing.com/equities/omv-ag?cid=1015183>
- [44] investing.com, "TTE." Accessed: Feb. 25, 2023. [Online]. Available: <https://www.investing.com/equities/total>
- [45] investing.com, "SHEL." Accessed: Feb. 25, 2023. [Online]. Available: <https://www.investing.com/equities/royal-dutch-shell-a-shr?cid=23655>
- [46] tradingview.com, "Money Flow." Accessed: Feb. 25, 2023. [Online]. Available: <https://tr.tradingview.com/scripts/moneyflow>

- [47] tradingview.com, “Commodity Channel Index.” Accessed: Feb. 25, 2023. [Online]. Available: <https://tr.tradingview.com/ideas/commoditychannelindex>
- [48] tradingview.com, “Chaikin.” Accessed: Mar. 30, 2023. [Online]. Available: <https://tr.tradingview.com/scripts/chaikinmoneyflow>
- [49] tradingview.com, “Awesome Oscillator.” Accessed: Feb. 15, 2023. [Online]. Available: <https://www.tradingview.com/scripts/awesomeoscillator>
- [50] Berman, Karen, Knight, Joe ve Case, John (2006), Financial Intelligence, ISBN: 1-59139-764-2, Business Literacy Institute, USA.
- [51] investopedia.com, “Asset Turnover.” Accessed: Feb. 25, 2023. [Online]. Available: <https://www.investopedia.com/ask/answers/032415/how-asset-turnover-calculated.asp>
- [52] A. Damodaran, Investment valuation : Tools and techniques for determining the value of any asset, 3rd ed. Hoboken, N.J.: Wiley, 2012.
- [53] R. Durán-Vázquez, A. Lorenzo-Valdés, and C. E. Castillo-Ramírez, “Effectiveness of corporate finance valuation methods: Piotroski score in an Ohlson model: The case of Mexico,” Journal of Economics, Finance and Administrative Science, vol. 19, no. 37, pp. 104–107, Dec. 2014, doi: 10.1016/j.jefas.2014.04.003.
- [54] Ogbulu, O. M., & Emeni, F. K. (2012). Capital structure and firm value: Empirical evidence from Nigeria. International Journal of Business and Social Science, 3(19), 252–261.
- [55] investopedia.com, “Asset Turnover.” Accessed: Jan. 15, 2023. [Online]. Available: <https://www.investopedia.com/terms/r/returnoninvestmentcapital.asp>
- [56] corporatefinanceinstitute.com, “Return on Common Equity.” Accessed: Feb. 10, 2023. [Online]. Available: <https://corporatefinanceinstitute.com/resources/accounting/return-on-common-equity>
- [57] investopedia.com, “Yield on Cost.” Accessed: Jan. 05, 2023. [Online]. Available: <https://www.investopedia.com/terms/y/yield-on-cost.asp>
- [58] investopedia.com, “Cash Ratio.” Accessed: Feb. 18, 2023. [Online]. Available: <https://www.investopedia.com/terms/c/cash-ratio.asp>
- [59] investopedia.com, “Total Debt to Capitalization.” Accessed: Feb. 25, 2023. [Online]. Available: <https://www.investopedia.com/terms/t/total-debtto-capitalization-ratio.asp>
- [60] investopedia.com, “Ebit Ev Multiple.” Accessed: Jan. 10, 2023. [Online]. Available: <https://www.investopedia.com/terms/e/ebit-ev-multiple.asp>

- [61] wallstreetprep.com, “Ev Invested Capital.” Accessed: Feb. 15, 2023. [Online]. Available: <https://www.wallstreetprep.com/knowledge/ev-invested-capital>
- [62] investopedia.com, “Ev Revenue Multiple”, Accessed: Jan. 15, 2023. [Online]. Available: <https://www.investopedia.com/terms/e/ev-revenue-multiple.asp>
- [63] investopedia.com, “Gross Profit Margin.” Accessed: Feb. 10, 2023. [Online]. Available: https://www.investopedia.com/terms/g/gross_profit_margin.asp
- [64] investopedia.com, “Price to Cash Flowratio.” Accessed: Jan. 10, 2023. [Online]. Available: <https://www.investopedia.com/terms/p/price-to-cash-flowratio.asp>
- [65] finbox.com, “Price to Sales.” Accessed: Feb. 25, 2023. [Online]. Available: https://finbox.com/NASDAQGS:AMZN/explorer/price_to_sales_ltm/
- [66] ycharts.com, “World Crude Oil Production.” Accessed: Jan. 10, 2023. [Online]. Available: https://ycharts.com/indicators/world_crude_oil_production
- [67] ycharts.com, “Opec Crude Oil Production.” Accessed: Feb. 15, 2023. [Online]. Available: https://ycharts.com/indicators/opec_crude_oil_production
- [68] ycharts.com, “Iran Crude Oil Production.” Accessed: Jan. 10, 2023. [Online]. Available: https://ycharts.com/indicators/iran_crude_oil_production
- [69] ycharts.com, “Us Crude Oil Production.” Accessed: Feb. 10, 2023. [Online]. Available: https://ycharts.com/indicators/us_crude_oil_production_mer
- [70] ycharts.com, “Saudi Arabia Crude Oil Production.” Accessed: Jan. 10, 2023. [Online]. Available: https://ycharts.com/indicators/saudi_arabia_crude_oil_production
- [71] investing.com, “DAX.” Accessed: Feb. 15, 2023. [Online]. Available: <https://www.investing.com/indices/germany-30>
- [72] investing.com, “Spx-500.” Accessed: Feb. 15, 2023. [Online]. Available: <https://www.investing.com/indices/us-spx-500>
- [73] investing.com, “NASDAQ.” Accessed: Feb. 20, 2023. [Online]. Available: <https://www.investing.com/indices/nasdaq-composite>
- [74] investing.com, “NYSE.” Accessed: Feb. 20, 2023. [Online]. Available: <https://www.investing.com/indices/nyse-composite>
- [75] investing.com, “CAC40.” Accessed: Jan. 20, 2023. [Online]. Available: <https://www.investing.com/indices/france-40>
- [76] investing.com, “FTSE.” Accessed: Feb. 25, 2023. [Online]. Available: <https://www.investing.com/indices/uk-100>
- [77] investing.com, “BIST30.” Accessed: Jan. 25, 2023. [Online]. Available: <https://www.investing.com/indices/ise-30>

- [78] investing.com, “BIST100.” Accessed: Feb. 25, 2023. [Online]. Available: <https://www.investing.com/indices/ise-100>
- [79] investing.com, “Nyse Energy.” Accessed: Jan. 05, 2023. [Online]. Available: <https://www.investing.com/indices/nyse-energy>
- [80] investing.com, “FROG.” Accessed: Feb. 05, 2023. [Online]. Available: <https://www.investing.com/indices/cac-oil---gas>
- [81] investing.com, “DJUSEN.” Accessed: Jan. 05, 2023. [Online]. Available: <https://www.investing.com/indices/dj-oil---gas>
- [82] investing.com, “SPNY.” Accessed: Feb. 10, 2023. [Online]. Available: <https://www.investing.com/indices/s-p-500-energy>
- [83] investing.com, “XKMYA.” Accessed: Jan. 10, 2023. [Online]. Available: <https://www.investing.com/indices/ise-chem.,petrol.,plastic>
- [84] investing.com, “XELKT.” Accessed: Feb. 10, 2023. [Online]. Available: <https://www.investing.com/indices/ise-electricity>
- [85] investing.com, “FTNMX651010.” Accessed: Jan. 15, 2023. [Online]. Available: <https://www.investing.com/indices/electricity>
- [86] investing.com, “FTNMX601010.” Accessed: Feb. 15, 2023. [Online]. Available: <https://www.investing.com/indices/oil---gas>
- [87] investing.com, “BCOMCL.” Accessed: Jan. 15, 2023. [Online]. Available: <https://www.investing.com/indices/bloomberg-wti-crude-oil>
- [88] investing.com, “USO.” Accessed: Feb. 15, 2023. [Online]. Available: <https://www.investing.com/etfs/united-states-oil-fund>
- [89] investing.com, “USD/TRY.” Accessed: Jan. 15, 2023. [Online]. Available: <https://www.investing.com/currencies/usd-try>
- [90] investing.com, “EUR/TRY.” Accessed: Feb. 15, 2023. [Online]. Available: <https://www.investing.com/currencies/eur-try>
- [91] rapidminer.com, “K-NN.” Accessed: Jan. 10, 2023. [Online]. Available: https://docs.rapidminer.com/10.1/studio/operators/modeling/predictive/lazy/k_nn.html
- [92] rapidminer.com, “Lineer regresion.” Accessed: Feb. 10, 2023. [Online]. Available: https://docs.rapidminer.com/10.1/studio/operators/modeling/predictive/functions/linear_regression.html
- [93] rapidminer.com, “Deep Learning.” Accessed: Jan. 10, 2023. [Online]. Available:

- https://docs.rapidminer.com/latest/studio/operators/modeling/predictive/neural_nets/deep_learning.html
- [94] rapidminer.com, “Gradient Boosted Trees.” Accessed: Feb. 10, 2023. [Online]. Available: https://docs.rapidminer.com/9.10/studio/operators/modeling/predictive/trees/gradient_boosted_trees.html
- [95] rapidminer.com, “SVM.” Accessed: Feb. 10, 2023. [Online]. Available: https://docs.rapidminer.com/9.9/studio/operators/modeling/predictive/support_vector_machines/support_vector_machine.html
- [96] rapidminer.com, “Cross Validation.” Accessed: Feb. 15, 2023. [Online]. Available: https://docs.rapidminer.com/10.1/studio/operators/validation/cross_validation.html
- [97] J. T. Firouzjaee and P. Khaliliyan, “The Interpretability of LSTM Models for Predicting Oil Company Stocks: impacts of correlated features,” Jan. 2022, [Online]. Available: <http://arxiv.org/abs/2201.00350>
- [98] G. Akerlof, "the market for "lemons": quality uncertainty and the market mechanism", the quarterly journal of economics, vol. 84, no. 3, p. 488, 1970. <https://doi.org/10.2307/1879431>
- [99] C. Tufan and R. Sariçiçek, “Davranışsal Finans Modelleri, Etkin Piyasa Hipotezi ve Anomalilerine İlişkin Bir Değerlendirme”, Trakya Üniversitesi Sosyal Bilimler Dergisi, vol. 15, no. 2, pp. 159–182, 2013.
- [100] S. Grossman ve J. Stiglitz, "On the impossibility of informationally efficient markets",, 1980. <https://doi.org/10.7916/d8765r99>
- [101] L. Karabıyık, A. Anbar, “Sermaye piyasası ve yatırım analizi”. Ekin Basım Yayın Dağıtım, (2010)
- [102] M., Kıyılar, ve M. Akkaya, “Davranışsal finans”. İstanbul: Literatür Yayıncılık, (2016).
- [103] B. Malkiel, "The efficient market hypothesis and its critics", Journal of Economic Perspectives, vol. 17, no. 1, p. 59-82, 2003. <https://doi.org/10.1257/089533003321164958>
- [104] E. Fama, "Efficient capital markets: a review of theory and empirical work", The Journal of Finance, vol. 25, no. 2, p. 383, 1970. <https://doi.org/10.2307/2325486>
- [105] A. Damodaran, Investment Philosophies: Successful Strategies and the Investors Who Made Them Work. Hoboken, NJ: Wiley, 2012.
- [106] A. Damodaran, The Dark Side of Valuation: Valuing Old Tech, New Tech, and New Economy Companies. New Jersey: Pearson Education, 2010.

[107] altair.com, “Rapid Miner.” Accessed: May 10, 2023. [Online]. Available: <https://altair.com/altair-rapidminer>





ÖZGEÇMİŞ

İlk ve orta öğrenimini Bursa’da tamamladı. Kocaeli Üniversitesi Makine Mühendisliği Bölümünden 2016 yılında mezun oldu. 2016 ve 2021 yılları arasında Tekaydınlar Otomotiv’de Test Mühendisi olarak çalıştı. 2021 yılından beri Ons Makine’de Tasarım Mühendisi olarak çalışmaktadır.

TEZDEN TÜRETİLEN YAYIN VE ESERLER

Hüseyin B., “Stock Price Prediction by Machine Learning Using 70 Independent Variables” ICDBME-2023 3 RD INTERNATIONAL CONGRESS ON DIGITAL BUSINESS, MANAGEMENT & ECONOMICS SEPTEMBER 8-9, 2023 BOOK OF ABSTRACT. 2023. [Online]. Erişilebilir: www.nobelkitap.com

