T.C
TRAKYA ÜNVİERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ
İŞLETME ANABİLİM DALI
MUHASEBE VE DENETİM BİLİM DALI
YÜKSEK LİSANS TEZİ



MAKİNE ÖĞRENMESİ ALGORİTMALARI İLE DİNAMİK PORTFÖY MODELLEMESİ

BURAK ALTINIŞIK

TEZ DANIŞMANI

PROF. DR. ENGİN DEMİREL

EDİRNE, 2022

Tezin Adı: Makine Öğrenmesi Algoritmaları ile Dinamik Portföy Modellemesi

Hazırlayan: Burak ALTINIŞIK

ÖZET

Bu çalışmanın amacı Borsa İstanbul bünyesinde işlem gören ve sekiz farklı sektörden oluşturulan otuz dokuz hisseden oluşan portföy havuzundan önceki yılların verileri analiz edilerek geleneksel istatistiki yöntemler ve makine öğrenmesi (LSTM) yöntemleri ile oluşturulan iki adet homojen sekiz adet hisseden portföyün performanslarını karşılaştırmaktır. Geleneksel yöntemde 2016-2020 kapanış fiyatları ile getiri, risk, beta katsayıları ile değişim katsayıları hesaplanmıştır, 2020-2021 için lineer regresyon analizleri geçekleştirilip ve en optimize sekiz adet hisseden portföy oluşturulmuştur. Diğer tarafta 2016-2020 verileri makinelere öğretilmiş buna göre 2020-2021 tahmini yaptırılmıştır ve bu tahminlere göre performans açısından en iyi sekiz hisse portföye dahil edilmiştir. Her iki portföyün gerçekleşen performansları karşılaştırılmıştır.

Anahtar Kelimeler: Performans Karşılaştırma , Portföy , LSTM , Makine Öğrenmesi , Nöral Ağlar , Gelecek Tahmini

Thesis Title: Dynamic Portfolio Modelling via Machine Learning Algorithms

Author: Burak ALTINIŞIK

ABSTRACT

The aim of this study is benchmarking about two portfolios that traditionally analyzed and machine learning (LSTM) trained which both they are selected eight securities from a thirty-nine-equity pool which is included Borsa İstanbul and which they are came from eight different sectors. In traditional statistical method, Returns, risks, beta coefficients, Return-risk ratios of equities are calculated by using 2016-2020 closed prices and linear regression is used for the prediction of 2020-2021, Thus most successful eight equity is selected for portfolio. On other side artificial neural networks are trained with data of 2016-2020 and end of this training predictions of 2020-2021 are used for creating of second portfolio which is made of most successful equites aspect of potential.

Keywords: Performance Benchmark, Portfolio, LSTM, Machine Learning, Neural Networks, Predicting

İÇİNDEKİLER

ÖZET i
ABSTRACT ii
İÇİNDEKİLER iii
TABLOLAR LİSTESİ v
FORMÜLLER LİSTESİ vi
ŞEKİLLER LİSTESİ vii
KOD PARÇACIKLARI LİSTESİ viii
GRAFİKLER LİSTESİ ix
KISALTMALAR LİSTESİ x
GİRİŞ 1
LİTERATÜR TARAMASI 2
1.HİSSE SENETLERİ ve DEĞERLEME 5
1.1 Hisse Senedi Kavramı 5
1.2 Hisse Senedi Getirileri 6
1.2.1 Temettü Getirisi 6
1.2.2 Sermaye Getirisi 7
1.2.3 Elde Bulundurma/Tutma Getirisi 7
1.2.4 Diğer Getiri Hesaplama Yöntemleri 8
1.2.4.1 Aritmetik Getiri 8
1.2.4.2 Beklenen Getiri 9
1.2.4.3 Kümülatif/Birikimli Getiri 10
1.3 Hisse Senedi Riski 11
1.4 Değişim Katsayısı 12
1.5 Beta Katsayısı 13
1.6 Alfa Katsayısı 14
2. PORTFÖY DEĞERLEME 15
2.1 Portföy Çeşitleri 15
2.1.1 Portföy Çeşitleri 15
2.1.2 Agresif Portföy 15
2.1.3 Defansif Portföy 16
2.1.4 Gelir Bazlı Portföy 16
2.1.5 Spekülatif Portföy 17
2.2 Portföy Getirisi 17

2.3 Portföy Riski 18
3. MAKİNE ÖĞRENMESİ ve DERİN ÖĞRENME 19
3.1 Makine Öğrenmesi 19
3.2 Makine Öğrenmesi Örnek Uygulaması 21
3.3 Derin Öğrenme 27
3.4 Yapay Sinir Ağları 28
3.4.1 Tekrarlayan Sinir Ağları (RNN) 28
3.4.2 Uzun Kısa Vadeli Bellek (LSTM) 29
4.YÖNTEM 31
4.1 Varsayımlar 31
4.2 Sınırlılıklar 32
4.3 Evren ve Örneklem 33
4.4 Araştırma Modeli 34
4.5 Verilerin Analizi 35
4.5.1 Verilere Erişim 35
4.5.2 Finansal Analiz 37
4.5.3 Yapay Sinir Ağları ile Analiz 40
5.BULGULAR ve YORUM 45
6. SONUÇ 49
KAYNAKÇA 51
EKLER 59

TABLOLAR LİSTESİ

Tablo 1. Girdi Matrisi 21
Tablo 2. Çalışma Kapsamındaki Endeks ve Hisseler 35
Tablo 3. Hisse İsimlerinin Maskelenmesi 36
Tablo 4. Analiz Sonuçları 38
Tablo 5. Hisse Performans Karşılaştırılması 39
Tablo 6. Korelasyon Matrisi 39
Tablo 7. Tahmin Değerleri Sonucu Getiri ve Risk 47
Tablo 8. Analiz Sonuçları LSTM 48
Tablo 9. Portföylerin Karşılaştırılması 49
Tablo 10. Portföylerin Karşılaştırılması Özet 50
Tablo 11. Günlük Fiyat Tahmini 59

FORMÜLLER LİSTESİ

Formül 1. Temettü Getirisi..... 6
Formül 2. Sermaye Getirisi..... 7
Formül 3. Elde Bulundurma Getirisi..... 8
Formül 4. Aritmetik Getiri..... 9
Formül 5. Beklenen Getiri..... 10
Formül 6. Kümülatif Getiri..... 10
Formül 7. Hisse Senedi Riski..... 11
Formül 8. Değişim Katsayısı..... 12
Formül 9. Beta Katsayısı..... 13
Formül 10. Alfa Katsayısı..... 14
Formül 11. Portföy Getirisi..... 17
Formül 12. Portföy Riski..... 18
Formül 13. Kümülatif Ağırlık Toplamı..... 22
Formül 14. Kademeli Düşürme Fonksiyonu..... 24

ŞEKİLLER LİSTESİ

Şekil 1. Yapay Zeka Diyagramı 20
Şekil 2. Ağırlık Toplamı Diyagramı 22
Şekil 3. Sigmoid Fonksiyonu ve Türevi 23
Şekil 4. Sigmoid Fonksiyonunun Değerlere Uygulaması 23
Şekil 5. Kademeli Düşürme Fonksiyonunun Değerlere Uygulanması 25
Şekil 6. İterasyon Sonucu 26
Şekil 7. Derin Öğrenme Katmanları 27
Şekil 8. Yinelenen Ağ Hücresi 28

KOD PARÇACIKLARI LİSTESİ

Kod Parçacığı 1. Hisse Verilerinin Web Servisten Alınması 37
Kod Parçacığı 2. Kütüphanelerin Dahil Edilmesi ve Verilerin Tekrar Alınması 40
Kod Parçacığı 3. Kapanış Fiyatlarının Filtrelenmesi 41
Kod Parçacığı 4. Verilerin Transforme Edilmesi 42
Kod Parçacığı 5. Verilerin Transforme Edilmesi 43
Kod Parçacığı 6. Tahmin Ağının Oluşturulması 43

GRAFİKLER LİSTESİ

Grafik 1. Eğitim ve Tahminleme Sonuçları 45
Grafik 2. Getiri Hesaplamaları Tahmin ve Aktüel Veriler 46
Grafik 3. Oluşturulan Portföyün Analitik Gösterimi 48

KISALTMALAR LİSTESİ

AI: Yapay Zekâ

API: Uygulama Programlama Arayüzü

ARIMA: Bütünleşik Otoregesif Hareketli Ortalama

BIST: Borsa İstanbul

BOT: Otomatik İşlemler Yapan Yazılımlar

COV: Kovaryans Katsayısı

CPU: Merkezi İşlem Birimi\İşlemci

D: Temettü Getirisi

F: Fonksiyon

GPU: Grafik İşleme Birimi

KSAGLIK: Çalışma İçin Oluşturulan Sağlık Endeksi

LSTM: Uzun Kısa Vadeli Bellek

N: Dönem Sayısı

NARX: Doğrusal Olmayan Otoregesif Dışsal Model

NLP: Doğal Dil İşleme

IFSTSOCH:

P: Hisse Senedi Fiyatı

PCA: Temel Bileşen Analizi

Ri: Endeks Getirisi

Rm: Varlık Getirisi

RMSE: Ortalama Kare Sapması

RNN: Yinelemeli Sinir Ağı

Rp: Portföy Getirisi

RPA: Robotik Süreç Otomasyonu

S: Standart Sapma/ Hisse Senedi Riski

SKUK: Kira Sertifikası

SQL: Yapılandırılmış Sorgu Dili

SVM: Destek Vektör Makineleri

T: Dönem veya Zaman

VAR: Varyans

W: Menkulün Portföydeki Ağırlığı

WTI Petrol: West Texas Intermediate, Ham Petrol Derecesi

XBANK: Borsa İstanbul Banka Endeksi

XBLSM: Borsa İstanbul Bilişim Endeksi

XGB/XGBOOST: Açık Kaynaklı Kademeli Artırılmış Karar Ağacı Algoritması

XİNŞA: Borsa İstanbul İnşaat Endeksi

XMESY: Borsa İstanbul Metal Mamul Endeksi

XTCRT: Borsa İstanbul Ticaret Endeksi

XUSIN: Borsa İstanbul Sınai Endeksi

GİRİŞ

Araştırmacılar ve yatırımcılar için gerçekleşecek hisse fiyatlarının tahmin edilmesi son yıllarda üzerine yoğunlaşılan bir konu olmuştur. Fiyatların yönünün öngörülmesi alınacak pozisyon kararının alınmasına sebep olmaktadır. Yapılacak öngörüler için pek çok analiz çeşidi geliştirilmiştir. Ağırlıklı hareketli ortalamalar ile başlayan yöntemler ters Fisher dönüşümü gibi karmaşık indikatörlerin bulunmasına ve kullanılmasına ön ayak olmuştur.

Tüm veya belirli bir aralıktaki fiyatlar üzerinden hesaplanan indikatörler geliştirilirken diğer taraftan GPU ve CPU teknolojilerinin gelişmesi ile tüm endeks hisselerinin tüm kapanış günlerindeki fiyatlarını kote olduktan sonraki tarihten itibaren hesaplayabilen yapay öğrenme algoritmaları geliştirilmiştir.

2011 Yılından itibaren tezgâh altı kripto piyasalarının oluşumu ile beraber tahmin ve strateji modelleri sadece yatırımcıların kararlarını etkilememektedir aynı zamanda büyük oranda spekülatif etkilerle fiyatların yönünü değiştirmektedir. Kripto borsalarında API desteği sunulmaktadır. Dolayısı ile kolay bir şekilde alım ve satım yapan BOT yazılımları kümülatif biçimde hem tahminleme hem de alım ve satım işlemlerini gerçekleştirmektedir. API erişimi kısıtlı olan tezgah üstü veya resmi regülasyonu olan piyasalarda ise RPA yazılımları ile BOT alım ve satımlarına benzer işlemler gerçekleştirilmektedir.

Çalışma fikri bahsedilen spekülatif etkiler ve BOT' yazılımları ile gerçekleştirilen kümülatif spekülasyon etkilerinin diğer yapay sinir ağları tarafından tahmin edilebileceğinden doğmuştur. Oluşturulan spekülatif etkilerin örüntüsünün piyasa üzerinde sistematik gerçekleşmesi ve bu örüntünün geleneksel yöntemlerden ziyade yine yapay sinir ağları tarafından tahmin edebileceği öngörülmüştür.

LİTERATÜR TARAMASI

Agrawal vd. 2019 Hisse teknik indikatörleri vasıtasıyla alım satım sinyalleri hem uzun hem kısa dönem için oluşturulmuştur. Yüksek korelasyon katsayısına sahip indikatörler LSTM modeli ile tahminlenmiştir. Trendleri tahmin edilen endeksler Hindistan bünyesinde otomobil, metal ve banka sektörleridir. Modelleme Python ile oluşturulmuş ve popüler derin öğrenme modülleri olan Keras ve Tensorflow kullanılmıştır günlük tahmin oranı %68,45 olarak gözlemlenmiştir.

Al-Shayea 2017 Dow Jones endeksinin ileri beslemeli derin öğrenme ağları ile tahmin edilmesi gerçekleştirilmiştir. Tahmin modeli olarak NARX modeli kullanılmıştır. NARX performansı diğer modeller ile karşılaştırılmış levenberg-marquardt algoritmasının minimum hata ile en yüksek eğitim performansını sergilediği gözlemlenmiştir.

Büyükkör 2022 WTI ham petrol fiyatları XGB yöntemi ile tahmin edilmiş. Çalışmada 1986 ve 2022 yılları arasındaki petrol fiyatları kullanılmıştır. ARIMA yöntemine göre daha iyi performans sergilediği gözlemlenmiştir.

Canıtez vd. 2022 Yüksek volatilite gösteren kripto para piyasalarında LSTM modeli ile ARIMA modelleri ile tahminleme gerçekleştirilmiş. On bin adet fiyat verisi ile popüler indikatörler isabetlilik artırılmaya çalışılmıştır. Sonuç kısmında ARIMA'nın LSTM'e nazaran %4 daha isabetli olduğu gözlemlenmiştir.

Deorukhkar vd. 2019 Bir sonraki günün fiyatlarını tahmin etmek için LSTM, ARIMA ve RNN modellerinin ileri beslemeli kombinasyonundan oluşan hibrid model kurulmuştur. Oluşturulan modele Ensemble Learning tanımlama yapılmıştır. Çalışmayı gerçekleştirenler bu hibrid modelin diğer modellerin tek başlarına kullanılmasına nazaran daha isabetli olduğunu gözlemlemiştir.

Faurina vd. 2018 Çalışmada üç kademeli bir LSTM ağı oluşturulmuştur. İlk aşamada üç farklı hata minimize yöntemi kullanılmıştır ve dış etkilerden fiyatlar arındırılmıştır. İkinci aşamada ise veri seti segmente edilmiştir. Üçüncü aşamasında dataset LSTM modeline entegre edilerek eğitim sağlanmıştır. Çalışma sonucunda PCA

düzeltim metodu ile LSTM yöntemi %71 başarı oranı ile tahminleme gerçekleştirmiştir.

Gosh vd. 2019 LSTM modeli ile Hindistan piyasalarında firmaların net büyüme hesaplamaları gerçekleştirilmiş ve buna göre hisse fiyatları tahmin edilmeye çalışılmıştır. Veri seti hacmi ile hata oranları arasında negatif korelasyon olduğu sonucunda ulaşılmıştır.

Güleryüz vd. 2021 BIST 30 endeksi üzerinde klasik istatistiki analizler ile yapay zekâ tabanlı modeller karşılaştırılmıştır. ARIMA klasik istatistiki model olarak seçilirken LSTM ise yapay zekâ tabanlı model olarak seçilmiştir. LSTM modelinin ARIMA modeline kıyasla %26 daha başarılı olduğu gözlemlenmiştir.

Jiawei vd. 2019 Nöral sinir ağı yaklaşımı ile hisse piyasasını etkileyen faktörler analiz edilmiştir bu analizler ışığında hisse fiyatları tahmin edilmeye çalışılmıştır.

Kargın vd. 2022 Kripto para piyasasında Bitcoin isimli elektronik finansal aracın fiyat değişimleri LSTM algoritması ile tahmin edilmeye çalışılmış yapılan analiz sonucunda görece düşük bir hata oranı tespit edilmiştir.

Koç vd. 2018 Emeklilik yatırım fonu hisse senedi fiyatları kur ve BIST 100 endeksi gibi girdi değişkenleri ile faiz oranlarının dahil edildiği bir model kullanılarak tahmin edilmiştir. Çalışma sonucunda ağın gerçek değerlere yakın tahmini sonuçlar elde ettiği belirtilmiştir.

Lakshminarayanan vd. 2019 LSTM ve SVM ile karşılaştırmalı bil model oluşturulmuştur. Dow Jones endeksi ile ham petrol ve altın fiyatlarının dış değişken dahil edildiği bir veri seti oluşturulmuştur. Model performansı RMSE hatalar karesi oranı ile ölçülmüştür. Dış değişkenler olmadan SVM ve LSTM modellerinin daha iyi performans verdiği ölçülmüştür. LSTM modeli nispi olarak SVM modeline göre daha iyi performans verdiği gözlemlenmiştir.

Manurung vd. 2018 Endonezya 2013-2018 borsası verileri Yahoo web servis sağlayıcısından sorgulanarak LSTM ve ARIMA modelleri ile tahminleme yapılmış ve

her iki model karşılaştırılmıştır. ARIMA modelinin LSTM'e nazaran daha iyi performans sergilediği belirtilmiştir.

Obthong vd. 2020 Çalışmada hangi tahminleme modelinin daha iyi olduğuna dair bir araştırma yapılmıştır. Çalışma sonucunda LSTM modeli sadece hisse senetleri fiyatlarında yüksek tahmin performansı gösterirken RNN algoritmasının hisse fiyatları, bonolar, türev araçlar, Forex işlemleri ve emtia fiyatlarında yüksek performans gösterdiği gözlemlenmiştir.

Roondiwala vd. 2015 RNN ve LSTM kullanılarak hisse fiyatları farklı iterasyonlar ile tahmin edilmiştir. Çalışma sonucunda tahminleme tekniklerinin sadece araştırmacılara değil aynı zamanda yatırımcılar içinde faydalı olduğu belirtilmiştir.

Pramod vd. 2020 Sorgulanan hisse fiyatları veri setini farklı boyutlarda ve oranlarda eğiterek çıktılar karşılaştırılmıştır. Sonuç olarak düşük hata oranları ile tahminlemeler gerçekleştirilmiştir.

Söylemez vd. 2017 Çalışmada muhasebe verileri, piyasa verileri kullanılarak firma bazında başarısızlık tahminleri gerçekleştirilmiştir. Yapay sinir ağı bazlı modellerin diğer modellere nazaran daha az varsayım içerdiğinden yüksek performans verdiği belirtilmiştir.

Söylemez 2020 Çalışmada 2014-2019 yılları arasındaki Brent petrol fiyatları, VIX endeksi, Dow Jones endeksi, ABD doları endeksi ile beraber altın fiyatları tahmin edilmiştir. Yüksek bir tahmin oranı ile altın fiyatlarında isabetlilik yakalandığı belirtilmiştir.

Yüksel vd. 2022 diğer taranan çalışmalardan farklı olarak NLP ile SQL sorgulama syntax yapısının dışında doğal dillerde yazılmış sorgular tahmin ettirilmiştir sorgu sonuçlarında %75 başarı sağlanmıştır.

1.HİSSE SENETLERİ ve DEĞERLEME

1.1 Hisse Senedi Kavramı

Finansal varlıklar, ihraç edene kaynak kullanana finansal getiri ve büyüme sağlayan ürünler olarak tanımlanabilir (Dahlquist vd., 2022:9). Finansal ürünlere fiziki emtia hak, sözleşme, gayrimenkul, araç, elektronik saklanan para dahil pek çok örnek gösterilebilir (Dahlquist vd., 2022:9). Hisse senetleri anonim ortaklıkların sermayelerinin ortaklar açısından ne kadar paylarının olduğunu gösteren enstrümanlardır ve bu araçları ellerinde bulunduran kişiler ortaklık için üzerinde yazan nominal değer kadar hak sahibidir (Sarıkovanlık vd., 2017:169).

Elde edilen kar veya zarar hisse senedinin sermayeye olan payı kadar dağıtılır ve bu finansal araçlar ikincil piyasalarda alınıp satılabilir (Sarıkovanlık vd., 2017:170). Dolayısı ile hisse senedi için birden çok getiri türü vardır bunlardan ilki elde edilen kâr payı iken ikincisi hisse senedinin piyasa fiyatındaki değişim farklarından alış ve satış ile elde edilen sermaye kazancı (Sarıkovanlık vd., 2017:175).

Hisse senetlerinin ikincil piyasalarda oluşan fiyatları tıpkı tüketim ürünleri gibi volatilite gösterebilmektedir(https://www.investopedia.com 24.09.2022). Volatilite yani değişkenlik standart sapma ile hesaplanmaktadır çalışmanın ileri safhalarında bu konuya değinilmiştir(Gibson, 2003:3). Volatilite yani oynaklık yatırımcılar tarafından üzerine tahmin yapılabilir olgudur (https://www.investopedia.com 24.09.2022).

Fiyatların üzerine tahmin yapma girişimi spekülasyon olarak isimlendirilmektedir. Eğer fiyatların yükseleceğine dair bir spekülasyon yapılıyorsa buna uzun pozisyon ismi verilmektedir (https://www.investopedia.com 24.09.2022). Eğer fiyatların düşeceğine dair bir spekülasyon yapılıyorsa buna kısa pozisyon ismi verilmektedir (https://www.investopedia.com 24.09.2022). Kısa pozisyon almak için varant gibi ürünler ile hem uzun hem kısa pozisyon haklarının alınıp satılacağı sadece hisse piyasasına özgü olmayan future, forward, opsiyon ve swap gibi türev ürünler ile bunların piyasaları geliştirilmiştir(Gibson, 2003:8).

1.2 Hisse Senedi Getirileri

1.2.1 Temettü Getirisi

Anonim ortaklıklar, ortaklara hisseleri oranında kar veya zarar yansıtmaktadır (Dahlquist vd., 2022:321). Söz konusu yansıtılan unsur kar ise bu temettü getirisi olarak değerlendirilir. Gordon büyüme modeli, sıfır büyüme modeli, sürekli büyüme iskonto modeli değişken veya sabit olmayan büyüme modelleri gibi birden fazla temettü hesaplama yöntemi bulunmaktadır(Dahlquist vd., 2022:321).

Temettü getirisi senelik, çeyrek bazında veya aylık olarak dağıtılabilir. Bu çalışma içeriğinde oluşturulan modelin varsayımlarına göre şirketler temettü dağıtımı yapmamaktadır. Dolayısı ile temettü dahil edilmiş getiri hesaplamaları kullanılmamıştır. Temettü verimi veya getirisi Formül 1 ile gösterilmektedir *R* getiriyi ifade ederken *D* temettüyü *P* ise hisse senedi piyasa fiyatını ifade etmektedir (Dahlquist vd., 2022:321).

Formül 1. Temettü Getirisi

$$R = \frac{D_t}{P_{t-1}}$$

Kaynak: (Dahlquist vd., 2022:321)

1.2.2 Sermaye Getirisi

Sermaye getirisi hisse senedinin veya herhangi bir kıymet ürün veya sözleşmenin iki farklı dönem arasındaki pozitif veya negatif fiyat farklılıklarıdır (https://www.investopedia.com 24.09.2022). Aradaki geçen süre içerisinde maliyet ile satış fiyatı arasındaki farka göre kar veya zarar hesaplanmaktadır (Lee vd., 2016:61). Sermaye getirisi birden fazla yöntemle tek bir dönem için ölçülebilmektedir. Formül 2 görselindeki formül ile hesaplaması yapılmaktadır *R* getiriyi *P* hisse senedi fiyatını *t* hesaplama yapılan dönemi ifade etmektedir (https://www.investopedia.com 24.09.2022).

Formül 2. Sermaye Getirisi

$$R = \frac{P_t - P_{t-1}}{P_{t-1}}$$

Kaynak: (Lee vd., 2016:61)

1.2.3 Elde Bulundurma/Tutma Getirisi

Getiri hesaplamasında bir dönem kullanılıyor ise sadece bu yöntem ile hesaplama yapılmaktadır (https://www.investopedia.com 24.09.2022). Hisse senetleri nezdinde elde bulundurma getirisi hesaplanırken temettü ödemeleri de dahil edilmektedir (Dahlquist vd., 2022:450). Buna göre elde bulundurma getirisi aşağıdaki Formül 3'te görüldüğü gibi hesaplanmaktadır. *R* getiriyi *P* piyasa fiyatını ve *D* temettü tutarını belirtmektedir.

Formül 3. Elde Bulundurma Getirisi

$$R = \frac{P_t - P_{t-1}}{P_{t-1}} + \frac{D_t}{P_{t-1}}$$

Kaynak: (Dahlquist vd., 2022:450)

Yatırımcılar finansal varlıklarını veya hisselerini birden fazla dönemler halinde ellerinde tutabilmektedirler. Uzun dönem hisse hesaplamaları gerçekleştirilirken sadece dönem başı ve dönem sonu kullanmak yerine günlük, aylık veya yıllık bazda ortalamalar hesaplanabilir. Bu ortalamalar sistematik etkileri gözlemlemek için kullanılabilmektedir (Kaya, 2015:552). Tüm yöntemlerden ziyade çalışma için gerekli olan yöntemlere yer verilmiştir.

1.2.4 Diğer Getiri Hesaplama Yöntemleri

1.2.4.1 Aritmetik Getiri

Birden fazla dönemler için sermaye getirisi hesaplanıyor ise ve bu dönemler için karşılaştırma yapılmak isteniyor veya her bir dönem için hesaplanan getiriler karşılaştırılmak isteniyorsa kullanılabilir (https://financetrain.com 24.09.2022). Aritmetik getiriler ile zaman serisi grafiği çıkarılabilir. Çıkarılan grafik endeks veya sektör grafiği ile karşılaştırılabilir (https://financetrain.com 24.09.2022).

Aritmetik getiri Formül 4 özelinde gösterildiği gibi hesaplanabilmektedir (https://financetrain.com 24.09.2022). Getiriler birbirine yakın ve aynı matematiksel işarete sahip aritmetik getiri gerçek sonuç getirilerin işaretleri farklılaştıkça ve değerler

birbirinden uzaklaştıkça aritmetik getiri birbirinden oldukça farklı sonuçlar vermektedir (https://financetrain.com 24.09.2022). *Ri* ortalama getiri getiri ve t dönemleri ifade etmektedir.

Formül 4. Aritmetik Getiri

$$\bar{R}_i = \frac{R_{i1} + R_{i2} + \cdots + R_{i,t-1} + R_{it}}{T} = \frac{1}{T}\sum_{t=1}^{T} Rit$$

Kaynak: (https://www.rateofreturnexpert.com 18.11.2022)

1.2.4.2 Beklenen Getiri

Getiri hesaplamalarında sadece geçmiş veriler ışığında hareket etmek anlamına gelmediğinden geçmiş performans yanında olası gelecek hesaplamaları da yapılabilmektedir (Quiry vd., 2005:393). Buna göre beklenen getiri kavramı potansiyel getirilerin olasılık dağılımlarının beklenen değerinden oluştuğu söylenebilir(Quiry vd., 2005:393). Daha açık ifade beklenen getiri, muhtemel getirilerin olasılık bazlı ağırlıklarının ortalamasıdır(Quiry vd., 2005:393).

Formül 5 formülünde görüldüğü gibi hesaplanmaktadır. Geçmiş yıl verilerine göre yatırımcılar tarafından iyi, orta ve kötü koşulların sübjektif olarak belirlenen olasılıklar kullanılmaktadır (Quiry vd., 2005:393). Tez analizinde hesaplamalarda beklenen kullanılmamıştır. *E(R)* beklenen getiriyi, *Ri* her hissenin beklenen getirisini ve *Pi* belirlenen gerçekleşme olasılığını göstermektedir.

Formül 5. Beklenen Getiri

$$E(R) = \sum_{i=1}^{n} R_i \; x \; P_i$$

Kaynak: (Quiry vd., 2005:393)

1.2.4.3 Kümülatif/Birikimli Getiri

Bir menkul kıymetin belirli bir dönem boyunca oluşturduğu getirilerin birikimli olarak toplanmasıdır (https://www.northstarrisk.com 26.09.2022). Zaman serisi boyunca getiriler negatif veya pozitif getiriler toplama eklenerek ilerlerler. Bazı hesaplamalarda temettüler hesaplamaya dahil edilebilir (Mitsel, 2012:11).

Kümülatif getiriler fiyattaki fiili artış veya azalışın tüm zaman diliminde incelenmesi ve nihai olarak dönem ve dönemler sonundaki değerde negatif veya pozitif getiri yüzde olarak izlenebilmektedir (https://www.northstarrisk.com 26.09.2022). Kümülatif getiri bazı kaynaklarda elde tutma getirisinin bünyesinde incelenebilmektedir (https://www.northstarrisk.com 26.09.2022). Buna göre kümülatif getiri Formül 6'daki gibi hesaplanabilmektedir. *R* getiri ve *n* dönem sayısını ifade etmektedir.

Formül 6. Kümülatif Getiri

$$R = [(1 + R_1)x(1+R_2)x(1+R_3)x \ldots (1 + R_n)] - 1$$

Kaynak: (Mitsel, 2012:11)

1.3 Hisse Senedi Riski

Risk beklentiler ile gerçekleşen olayların örtüşmeme ihtimalidir veya beklentilerin dış etkiler ile gerçekleşen olayların kısmen veya tamamen etkilenme ihtimalidir (https://www.businessinsider.com 26.09.2022). Risk ve belirsizlik eş anlamlarda kullanılsalar dahi aralarında fark bulunmaktadır (https://www.businessinsider.com 26.09.2022). Risklere etki edilip minimize edilebilirken belirsizliklere yani sistematik riske etki edilememektedir (Kaya, 2015:449).

Her yatırım aracında olduğu gibi hisse senetleri bünyesinde de risk bulunmaktadır (Canıtez vd., 2022:1314). Risk hisse senetlerinde varyans ve standart sapma ile Formül 7 kullanılarak ölçülebilmektedir *Rt* ilgili menkul kıymetin *t* dönemdeki getirisi, *T* dönem sayısı *Rort* ifadesi ilgili menkul kıymetin getiri ortalaması ve *S* ilgili menkulün standart sapmasını ifade etmektedir (Köseoğlu, 2010:23).

Formül 7. Hisse Senedi Riski

$$S^2 = \frac{\sum_{t=1}^{T}(R_t - Rort)^2}{T-1}$$

Kaynak: (Köseoğlu, 2010:23)

1.4 Değişim Katsayısı

Değişim katsayısı veya risk/getiri oranı ne kadarlık bir potansiyel getiri için ne kadar risk alındığını göstermektedir (https://academy.binance.com/tr 26.09.2022). Başka bir ifade ile alım satımı yapılan kıymetin potansiyel bir getiri için ne kadar risk alındığını hesaplamaktadır (https://academy.binance.com/tr 26.09.2022). Dolayısı ile riske edilen her bir birim için potansiyel ne olarak getiri sağlandığı görülmektedir.

Değişim katsayısı hisseler arasında karşılaştırma yapmak için kullanılabilir bir yöntemdir (https://academy.binance.com/tr 26.09.2022). Örneğin birden çok hisse için yüksek getirili ve düşük riskli bir hisseyi o an doğrudan hem getiri hem standart sapmayı inceleyerek anlamak güçtür (https://academy.binance.com/tr 26.09.2022). Anlaşılmasının kolaylığı açısından bu çalışmada bu oranın tersi kullanılmıştır getiri/risk oranı büyüdükçe hissenin getirisi ve riski dengelenmektedir *S* hisse senedinin riskini ve *R* hisse senedinin getirisini ifade etmektedir (https://academy.binance.com/tr 26.09.2022).

Formül 8. Değişim Katsayısı

$$Değişim\ Katsayısı = \frac{S}{R}$$

Kaynak: (https://academy.binance.com/tr 26.09.2022)

1.5 Beta Katsayısı

Beta katsayısı kısaca ilgili hisse senedindeki fiyat hareketinin endeks veya pazar ile uyumlu olup olmadığını ölçen bir indikatördür (Kaya, 2015:519).Beta katsayısı hisse senedi getirileri ile piyasa getirileri arasındaki kovaryansın piyasa getirilerinin varyansına bölünmesi ile bulunur (Lee vd., 2016:62). Piyasa varyansı sistematik riski göstermektedir Beta katsayısı yükseldikçe risk yükselmektedir azaldıkça hisse senedinin riski azalmaktadır (Alp vd., 2015:1).

Piyasanın beta katsayısı her zaman için bir sayısına eşittir başka bir değişle piyasadaki tüm menkul kıymetlerin beta katsayısı toplamları teorik olarak bir sayısına eşittir (Alp vd., 2015:2). Beta katsayısı bir sayısına eşitse o hissenin riski piyasanın riski ile tam ilişkili hareket etmektedir (Alp vd., 2015:2).

Beta katsayısının bir sayısından yüksek olması menkulün piyasadaki artıştan daha fazla artış veya azalış göstereceğini göstermektedir (Alp vd., 2015:2). Eğer beta katsayısı bir sayısından düşük ise piyasadaki artış ve azalışlar hissede daha az oranda artış ve azalışlara sebep olacaktır (Kaya, 2015:519). *B* beta *Var* Varyansı ve *Cov* kovaryansı ifade etmektedir. *Ri menkul getirisini ifade ederken Rm piyasa getirisini ifade etmektedir.*

Formül 9. Beta Katsayısı

$$\beta = \frac{Cov(R_{i,}, R_m)}{Var(R_m)}$$

Kaynak: (Farooq, 2020:2)

1.6 Alfa Katsayısı

Beta katsayısı sistematik riski ifade ederken alfa katsayısı fiyat hareketlerinin sistematik olmayan riskini ölçen bir katsayıdır (Farooq, 2020:2). Piyasadaki tüm menkul kıymetlerin alfa toplamı sıfır sayısına eşit olacaktır. Alfa betanın bir alternatifi olmayıp beraber incelenmesi gereken göstergelerdir (https://www.investopedia.com 08.10.2022).

Alfa katsayısı varlık getirilerinin görece karşılaştırılan endeksin getirileri ile arasındaki negatif veya pozitif farktan oluşmaktadır (DiBartolomeo, 1998:2). Portföy yöneticileri çeşitlendirilmiş portföylerde çeşitlendirme etkisini sistematik olmayan riskten arındırmak için hesaplamalarına dahil etmektedirler (Farooq, 2020:2). *Ri* hisse senedi getirisini ifade ederken *Rm* piyasa getirisini ifade etmektedir.

Formül 10. Alfa Katsayısı

$$\alpha = R_i - R_m$$

Kaynak: (DiBartolomeo, 1998:2)

2. PORTFÖY DEĞERLEME

2.1 Portföy Çeşitleri

2.1.1 Portföy Çeşitleri

Yatırımcıların sahip oldukları varlıkları emeklilik fonlarını veya birikimleri tek bir finansal araca yönlendirmeleri yüksek risk oluşturmaktadır (Gökgöz, vd., 2012:4). Dolayısı ile farklı özelliklere yönelik finansal yatırımlar bir araya getirilerek portföyler oluşturulmaktadır (Gökgöz, vd., 2012:4).

Finansal anlamda portföy yatırım enstrümanlarından oluşan yatırım sepeti anlamına gelmektedir. Genel kanı hisseler, bonolar ve tahvillerin portföy olgularının portföy kavramının unsurları olduğudur. Fakat portföy içeriğinde geniş bir yelpazede bulunan gayrimenkul, emtia, sanat eseri, kripto paralar gibi finansal varlıklar içerebilirler(Levišauskaite, 2017:51).

Portföy yapısı anahtar konsepti çeşitlendirme etkisidir. Çeşitlendirme etkisi kısaca piyasa fiyatı hareketleri ters korelasyonda olan hisselerin birbirlerinin risklerini nötr hale getirerek risk azalışı ve getiri artışı sağlanmasıdır (Dahlquist vd., 2022:472).

Yatırımcı davranışları coğrafya, kültür eğitim, amaç, piyasa durumu kişinin ruh hali gibi sayısız parametreden sonsuz olasılıklar doğurmaktadır (Levišauskaite, 2017:17). Dolayısı ile yatırımcı ihtiyaçlarına yönelik enstrümanlar da çeşitlediği gibi bu enstrümanlardan oluşturulan portföylerde yüksek çeşitlilik göstermektedir. Çalışma bünyesinde portföyler popülaritelerine göre incelenmiştir (https://www.forbes.com 16.10.2022).

2.1.2 Agresif Portföy

Agresif portföy yüksek risk kabul eden portföy çeşididir (https://www.forbes.com 16.10.2022). Bu portföydeki hisseler görece yüksek beta katsayısına veya piyasa hareketlerine yüksek duyarlılığa sahiptirler (https://www.forbes.com 16.10.2022). Yüksek beta katsayısına sahip hisseler yüksek

volatilite seyretmektedirler. Agresif yatırımcılar bu tarzda portföyler oluşturmak için yaşam döngülerinin erken safhalarında yer alan sektörde popülerliği henüz oluşmayan erken agresif büyüme gerçekleştiren organizasyonların hisselerinden oluşan portföyler kurmayı tercih etmektedirler (https://www.forbes.com 16.10.2022).

2.1.3 Defansif Portföy

Korumacı veya agresif büyüme politikası benimsemeyen organizasyonların hisseleri yüksek beta taşımazlar dolayısı ile market artış ve azalışlarından izole veya bağımsız biçimde hareket görmektedirler (https://www.forbes.com 16.10.2022).

Döngüsel hisse veya konjonktür ile hareket eden hisselerden farklı olarak korumacı hisseler ekonominin dalgalanmalarından bağımsız hareket ettikleri için bu tarz portföyler riskten yoksun fakat görece düşük getiri ile oluşturulmaktadırlar (https://www.investopedia.com 08.10.2022). Bu tip portföylerde hazine bonoları, devlet tahvilleri gibi riski minimize edecek enstrümanların yoğunluğu agresif portföylere göre yüksek konumlandırılabilir.

2.1.4 Gelir Bazlı Portföy

Bu portföyler temettü dağıtımlarına veya sermaye artırımdaki alım hakları gibi mevcut varlığı zaman bazlı olarak artırmaya yönelik oluşturulmaktadırlar (https://www.investopedia.com 08.10.2022). Hisselerin genellikle fiyat hareketleri ile daha az ilgili olan portföylerde agresif veya defansif hisseler bulunabilir.

Bir gelir bazlı portföy sürekli nakit akışı oluşturma eğiliminde tasarlanmaktadır. Dolayısı ile SKUK, Tahvil, Bono, Mevduat gibi düzenli faiz geliri sağlayan araçlar eklenebileceği gibi doğrudan reel gayrimenkullerde eklenebilir (https://www.investopedia.com 08.10.2022).

2.1.5 Spekülatif Portföy

Geleceğe yönelik Portföy tiplerinin arasında belirsizliğin maksimum olduğu portföy tipleridir. Spekülatif satın alma haberleri üzerine kurulu olabilir satın alınacak şirketin hisselerinin yükselişe geçeceği beklentisi ile uzun pozisyonda portföye dahil edilir (Bhat, 2011:29). Teknoloji veya sağlık sektöründeki atılım beklentileri, yeni kurulmuş bir petrol faaliyeti gösteren bir firmanın ilk üretim beklentileri bu hisselerin spekülatif portföylere ilave edilmelerine sebep olabilirler (Bhat, 2011:29).. Hisselerin yanı sıra piyasa faizi beklentilerine göre ikinci el piyasasında alınan tahvil pozisyonları portföyün riskini düşürmek için ilave edilebilir (Bhat, 2011:29).

2.2 Portföy Getirisi

Tek bir hissenin olduğu portföye ağırlık katsayısı bir olacağı için doğrudan o hissenin kendi getirisi portföyün getirisi olacaktır (Levišauskaite, 2010:55). Portföy getirisi hesaplamasında portföydeki ağırlıklar getirilerin katsayısı olarak kümülatif olarak toplanmaktadır. *W* enstrümanın portföydeki ağırlığını ve *Ri* enstrümanın getirisini ifade etmektedir. *N* varlık sayısını belirtmektedir (Levišauskaite, 2010:55).

Formül 11. Portföy Getirisi

$$R_p = \sum_{i=1}^{N} W_i R_i$$

Kaynak: (Levišauskaite, 2010:55)

2.3 Portföy Riski

Portföyün getirisi için portföyün içinde yer alan yatırım araçlarının getirilerinin ağırlık bazında ortalamaları kullanılırken portföy riskini ortaya çıkarırken ağırlıklı ortalama yöntemi kullanılmaktadır (Levišauskaite, 2010:56). Temel sebep yatırım aracının performansa portföy içindeki yoğunluğu kadar etki edebileceğidir (Levišauskaite, 2010:60).

Yatırım aracı kombinasyonlarında korelasyon çeşitlendirme etkisinin temel unsurudur. Dolayısı ile risk hesaplamasına kovaryans katsayısı da dahil edilmektedir (Levišauskaite, 2010:57). Çalışmada kullanılan portföy risk hesaplaması Förmül 12'ye göre gerçekleştirilmektedir. *W* enstrümanın portföydeki ağırlığını ifade ederken N enstrüman sayısını ifade etmektedir. *Ri* ve *Rj* kovaryans matrisin oluşturan varlık getirilerini ve *Cov* kovaryans katsayını ifade etmektedir.

Formül 12. Portföy Riski

$$\sigma_p = \sqrt{\sum_{i=1}^{N}\sum_{i=1}^{N} w_i w_j Cov(R_i R_j)}$$

Kaynak: (Levišauskaite, 2010:55)

3. MAKİNE ÖĞRENMESİ ve DERİN ÖĞRENME

3.1 Makine Öğrenmesi

Makine Öğrenmesi ve Derin Öğrenme birbirleri yerlerine sıklıkla kullanılan kavramlardır. Her iki kavram da yapay zekâ kümesi içinde yer almaktadırlar. Yapay zekâ tanımı itibari ile "İnsan aklı ile yerine getirilen görev ve işlerin bilgisayar sistemleri tarafından yerine getirilmesidir" (https://levity.ai/ 22.10.2022). Yapay zekanın bir alt kümesi olan Makine Öğrenmesi "Sistemlerin spesifik olarak programlanmadan öğrenme kabiliyeti kazanmasıdır" olarak tanımlanmaktadır (https://flatironschool.com 22.10.2022).

Derin Öğrenme ise "Beyin yapılarına benzeyen Yapay Sinir Ağları ile oluşturulan öğrenme yapılarıdır" cümlesi ile tanımlanmaktadır (https://flatironschool.com 22.10.2022). Dolayısı ile çalışmada oluşturulan model bir derin öğrenme örneğidir (https://flatironschool.com 22.10.2022). Fakat Derin Öğrenme, Makine Öğrenmesinin bir alt kavramı veya bir alt türü olduğuna göre Makine Öğrenmesi örneği olması yanlış bir ifade olmayacaktır (https://levity.ai/ 22.10.2022).

Makine öğrenmesi istatistiğin ve bilgisayar biliminin kesiştiği bir alan olarak bilgisayar sistemlerine belirli görevleri yerine getirmesi adına spesifik olarak o iş için programlanmadan örüntüleri tanımlama ve yeni tahminler ortaya çıkarma yoludur (Alpaydın, 2020:78). Öğrenme süreci denetimli ve denetimsiz olarak ikiye ayrılmaktadır (https://www.geeksforgeeks.org 22.10.2022).

Şekil 1. Yapay Zeka Diyagramı



Kaynak: (https://flatironschool.com 22.10.2022)

Bu ayrılma datanın algoritmaları nasıl beslediğine bağlı olarak değişmektedir (https://levity.ai/ 22.10.2022). Makine Öğrenmesi algoritmaları beyin nöronlarını ağırlık değerleri ile taklit etmektedir. Bir girdiğinin ağırlığı threshold veya eşik değerini geçtiği takdirde nöron tetiklenmektedir (Alpaydın, 2020:78). Bu tetikleme modelde pek çok farklı fonksiyon tipleri olmakla beraber sigmoid fonksiyonu kullanılarak gerçekleştirilmektedir (https://machinelearningmastery.com 22.10.2022).

3.2 Makine Öğrenmesi Örnek Uygulaması

Problem XOR kapısı çözümünden esinlenilmiştir. Aşağıdaki Girdi Matrisi özelinde görülen problemde Girdi-II ve Girdi-III sütunundakilerin problem çıktısı ile matematiksel bir bağıntısı bulunmamaktadır (https://towardsdatascience.com 22.10.2022). Çıktılar doğrudan Girdi-I ile eşit durumdadır dolayısı ile D5 hücresindeki tahmin edilmesi gereken değer A5 değeri ile aynı yani 1 olacaktır. Modelin temel amacı girdileri ağa dahil ederek A5'teki girdiyi minimum hata ile tahmin etmektir.

Tablo 1. Girdi Matrisi

Girdi-I	**Girdi-II**	**Girdi-III**	**Çıktı**
0	**0**	**1**	**0**
1	**1**	**1**	**1**
1	**0**	**1**	**1**
1	**0**	**0**	**?**

Kaynak: (https://towardsdatascience.com 22.10.2022)

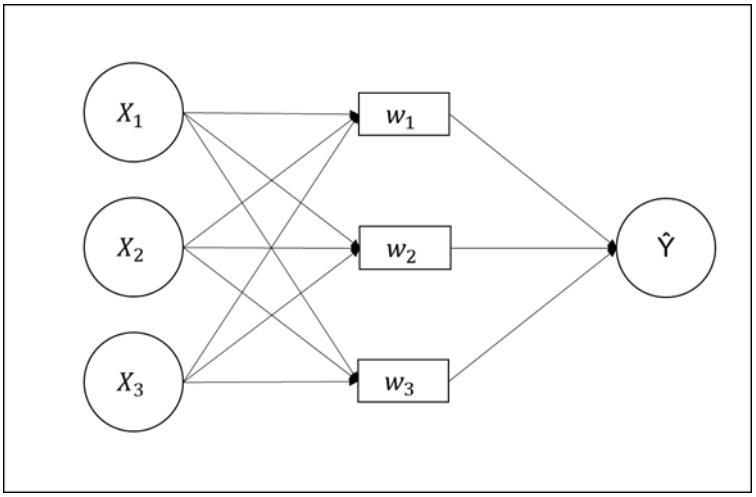
Girdi sütunlarının tamamı belirlenen ağırlıklar ile formüldeki gösterimdeki gibi Kartezyen çarpım ile toplanmaktadırlar. Örnekte karmaşıklığa yol açmaması açısından ağırlıklara bir değeri verilmiştir. Bu işlem sonucunda ortaya ilk y tahmin değeri çıkmaktadır ilk iterasyona göre bu işlemin sonucu [1,3,2] olacaktır (https://asmquantmacro.com 22.10.2022).

Formül 13. Kümülatif Ağırlık Toplamı

$$\hat{Y} = \sum_{ij=1}^{n} X_{ij} x W_j$$

Kaynak: (https://towardsdatascience.com 22.10.2022)

Şekil 2. Ağırlık Toplamı Diyagramı



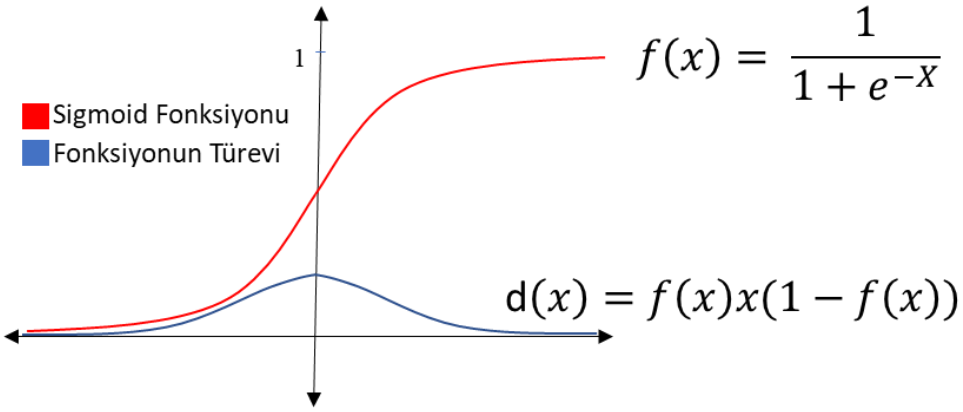
Kaynak: (https://towardsdatascience.com 22.10.2022)

Ağırlık toplam diyagramında görüldüğü üzere matris çarpımından çıkan sonuç gerçek değerler ile uyuşmamaktadır. Çıktılar hesaplama kolaylığı ve kademeli hata düşürme uygulaması açısından sigmoid fonksiyonu ile normalize edilmiştir.

Aktivasyon fonksiyonu veya Lojistik Fonksiyonu lineer olmayan ileri beslemeli yapay sinir ağlarında kullanılan analitik düzlemde “S” hafi şeklinde görülen fonksiyon çeşididir (https://deepai.org/ 22.10.2022).

Kendisine tanımlanan sayıları bir ve sıfır arasına sıkıştırmaktadır. Grafik incelendiğinde belirli değerler arasında iken y değerleri hızlı biçimde değişmektedir (https://deepai.org/ 22.10.2022). Girdilerde yapılan küçük değişimler çıktılarda nispi olarak büyük olmaktadır. Bu iyi bir sınıflandırıcı olarak kullanılabileceği anlamına gelmektedir (https://deepai.org/ 22.10.2022).

Şekil 3. Sigmoid Fonksiyonu ve Türevi



Kaynak: (https://deepai.org 22.10.2022)

Şekil 4. Sigmoid Fonksiyonunun Değerlere Uygulaması

$$\begin{bmatrix} 1 \\ 3 \\ 2 \end{bmatrix} \qquad \begin{matrix} f(1) = \frac{1}{1+e^{-1}} \\ f(3) = \frac{1}{1+e^{-3}} \\ f(2) = \frac{1}{1+e^{-2}} \end{matrix} \qquad \begin{bmatrix} 0.73 \\ 0.95 \\ 0.88 \end{bmatrix}$$

Yapay sinir ağına entegre edilen çıktıların sigmoid fonksiyonu ilk çıktı tahmin değerlerine uygulanır. Dönüşümden sonra değerler Şekil 4'te sağ sütunda gösterildiği gibi olmuştur. Tahmin değerleri ile gerçek değerler arasındaki fark hata oranı olarak tanımlanır. Tanımlanan bu hata oranının minimize edilmesi tahminleri gerçeğe yakınlaştıracaktır.

Tahmin edilen değerlerin gerçeğe yakınlaştırılması için gradient descent kademeli düşürme ile makineye ağırlıkları hata oranlarını minimize sağlanmaktadır. Formül 14 kısmında ağırlıklara yapılan güncelleme gösterilmektedir (https://www.mldawn.com 22.10.2022).

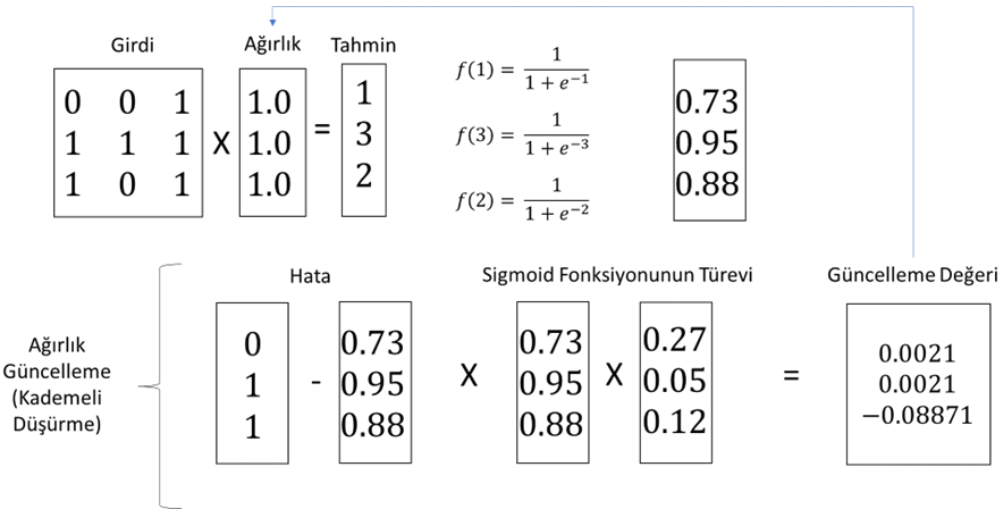
Formül 14. Kademeli Düşürme Fonksiyonu

Ağırlığa yapılan güncelleme = (Hata) x (Sigmoid Fonksiyonu Türevi) x Öğrenme Katsayısı

Kaynak: (https://www.mldawn.com 22.10.2022)

Ağırlığa yapılan güncelleme değeri negatif veya pozitif olabilir. Makine gerçek değerlere ağırlıkları yaklaştırmayı öğrendikçe hata değeri azalacaktır (https://www.mldawn.com 22.10.2022).

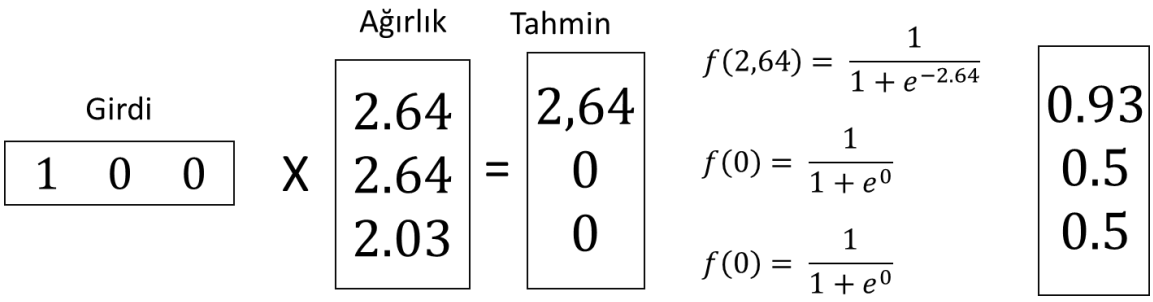
Şekil 5. Kademeli Düşürme Fonksiyonunun Değerlere Uygulanması



Kaynak: (https://towardsdatascience.com 22.10.2022)

Buna göre hata değeri minimum türev değeri sıfıra yakınlaştırmak için bu iterasyon minimum hata noktasına kadar makine tarafından tekrarlanır (https://www.mldawn.com 22.10.2022). Hata değeri asla sıfıra inmez fakat minimuma erişildiğinde gerçeğe en yakın tahminle çıkabilir (https://www.mldawn.com 22.10.2022). Şekil 5'deki gibi ağırlıklar on bin defa güncellendikten sonra ağırlıklar ve tahminler Şekil 6'daki gibidir. Hata kademeli olarak minimuma indirilmiştir.

Şekil 6. İterasyon Sonucu

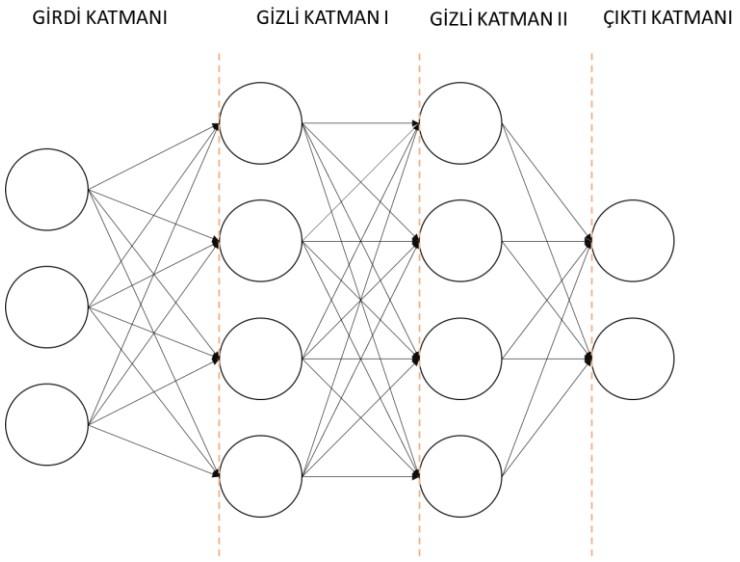


Yeni ağırlıklara göre problemin sorusu olan beşinci satıdaki bir değeri makineye iletildiğinde güncellenmiş ağırlıklara göre 0.07 hata değeri ile 0.93 çıkmaktadır. Çıktı yaklaşık olarak 1'e eşittir model makine öğrenmesinin yapısının anlaşılması açısından derlenmiştir. Model kukla girdilerden etkilenmeden tahmin işlemi gerçekleştirmiştir. Tahmin çıktılarının 0 olmaları beklenirken 0,5 olarak hesaplanmışlardır bunun sebebi fonksiyonda e üzeri sıfır 0 ifadesinin 1 sonuç vermesidir.

3.3 Derin Öğrenme

Derin yapılandırılmış öğrenme olarak da isimlendirilen derin öğrenme bir veya birden fazla gizli katman içeren makine öğrenmesi algoritmalarıdır (Alpaydın, 2020:80). Derin öğrenme mantıksal yapılar ile dataları insan zekâsı gibi yorumlayabilen algoritmalar olarak da tanımlanabilir (Alpaydın, 2020:80). Tanımda geçen insan zekâsı gibi yorumlama amacına katmanlaştırılmış veya gizlenmiş nöronlar ile yani Yapay Sinir Ağları ile gerçekleştirmektedir(Alpaydın, 2020:80).

Şekil 7. Derin Öğrenme Katmanları



Kaynak: (https://adgefficiency.com 22.10.2022)

3.4 Yapay Sinir Ağları

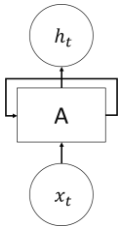
3.4.1 Tekrarlayan Sinir Ağları (RNN)

Geleneksel yapay sinir ağları beyindeki sinapsların iletişim yapısı model alınarak tasarlanmış algoritmalardır (Alpaydın, 2020:78). Fakat normal bir beyin düşünce fonksiyonuna aktardığı olgunun düşünmediği kısımlarını kısa vadeli hafızasında tutmaktadır. Daha az karmaşık anlatım ile makul bir insan okuduğu paragrafın ilk cümlelerini hatırlayarak okumaktadır (Alpaydın, 2020:78).

Klasik yapay sinir ağları bu özellikten yoksundur (https://stanford.edu 22.10.2022). Yinelenen modeller tüm datasındaki öğrenilmiş ağırlıklarını daha kısa vadeli olan datasına göre düzeltmektedir (https://stanford.edu 22.10.2022). Bu özelliği sayesinde büyük verinin tahminlerinde yaratacağı negatif etkiyi o anki kısa vadeli hafızası ile düzeltmektedir (https://stanford.edu 22.10.2022). Finansal piyasalarda yatırımcıların tüm kitlenin ortalamasından ziyade hareketli ortalama kullanmasının aynı şekilde kitlenin örneğe olan etkisini minimize etme işlevi LSTM modelinin işlevi ile benzerlik göstermektedir.

İnsanların her bir düşünme safhasında düşüncelerine yeniden başlamadıkları düşüncesi ile ortaya çıkmış yapılardır (https://stanford.edu 22.10.2022). Öğrenme esnasında kurulan ilişkilerin kalıcı olması adına kendi içlerinde döngüsel akış oluşturmaktadırlar. Her bir yapay sinir ağının çıktısı bir sonraki sinir ağını beslemektedir (https://stanford.edu 22.10.2022).

Şekil 8. Yinelenen Ağ Hücresi



Kaynak: (https://adgefficiency.com 22.10.2022)

Kurulan bu ilişki sayesinde girdiler kısa vadeli hafızaya alınarak çıktıların veya tahminlerin düzeltilmesi sağlanır. Kendi içerisinde dönen bir döngü gibi çalışırlar çalışmada gösterilen örnek uygulamadaki gibi doğrusal değil geriye yönelik ilerlemektedirler. Bu yapılar doğrusal olanlara karşı tamamen avantajlı değillerdir (https://colah.github.io 22.10.2022).

RNN yapıları çok uzun serilerde serinin uzunluğu kadar derin katman yaratmak zorundalar. Dolayısı ile bu zorunluluk optimizasyon problemine yol açmaktadır bu problem kademeli yok olma olarak isimlendirilebilir (https://colah.github.io 22.10.2022). RNN modellerine çözüm olarak GRU ve LSTM önerilmiştir. Çalışmadaki kullanılan verinin yapısından dolayı analiz için RNN yerine LSTM kullanılmıştır (https://colah.github.io 22.10.2022).

3.4.2 Uzun Kısa Vadeli Bellek (LSTM)

LSTM, RNN ağlarının kademeli yok olma problemine çözüm olarak tasarlanmış bir nöral sinir ağı yapısıdır (https://scikit-learn.org 22.10.2022). Tahminleme için anlam ifade eden bilgileri bir hücreden diğer bir hücreye aktaran bir iletişim hattı ve hafızası olarak açıklanabilmektedir (https://scikit-learn.org 22.10.2022). Kısa vadeli hafıza problemi ortadan kaldırılarak önceki veri örüntüleri RNN yapılarının aksine ileriye aktarılabilmektedir (https://scikit-learn.org 22.10.2022).

Geçişler veya kapılar arasında verileri 0 ile 1 sıkıştıran çalışmanın erken safhalarında değinilen sigmoid aktivasyon fonksiyonu bulunmaktadır (https://stanford.edu 22.10.2022). Sigmoid aktivasyonu sonucu sıfır olan bilgiler unutulur bir olan bilgiler ise işlenmeye devam ederler. Verilerin unutulacağı veya tutulacağı istasyon unutma kapısıdır.

Bir önceden gelen verinin hakkında işlem yapılıp yapılmayacağına karar veren bunlara ek olarak ağın regülasyonunu sağlayan istasyon giriş kapısıdır (https://stanford.edu 22.10.2022). Bir sonraki hücreye veri akışını belirleyen yapı çıkış

kapısıdır. Sistem kendini hem uzak hem de yakın hafızaya göre eğitmektedir. LSTM modeli doğal dil işleme, resim işleme, otomatik karakter tanılama gibi yüksek hacimli veri gerektiren alanlarda da kullanılabilir. LSTM mimarisi çalışmanın öğrenme analiz ve tahminleme kısımlarında kullanılmıştır (https://stanford.edu 22.10.2022).

4.YÖNTEM

4.1 Varsayımlar

Çalışmadaki portföyler adi hisse senetlerinden oluşmaktadır. Devlet tahvili, hazine bonosu, mevduatlar, SKUK, gayrimenkul, kripto varlıklar vd. menkul kıymetler hesaplamaları zorlaştıracağından ve portföy performansına etki edebileceklerinden model dışı bırakılmıştır. Enflasyon ve spekülasyon etkileri model dışında tutulmuştur.

Model aynı hisse setinden iki farklı yöntemde performans hesaplamaları ile yatırım portföyü oluşturacakları ve gerçekleşen veriler ile her iki yöntem arasında performans bazlı olarak karşılaştırma yapılmıştır.

Obthong vd. 2020 pek çok tahmin modelini kullanarak hangi yöntemin daha iyi performans gösterdiğini ölçümlemiştir buna göre LSTM modeli hisse senedi fiyatlarında yüksek performans göstermiştir.

Yapılan literatür taramasına göre LSTM modelleri diğer algoritmalara göre daha başarılı performanslar vermektedir ve literatür incelendiğinde RNN ile LSTM modelinin yoğunlukla kullanıldığı görülmektedir. LSTM veri setinde geçmiş ve yakın geçmiş verileri arasında etki dağıtımı gerçekleştirerek baz etkisini minimize etmektedir.

4.2 Sınırlılıklar

Çalışma Türkiye piyasalarından Borsa İstanbul BİST bünyesinde işlem göre hisseler ile sınırlandırılmıştır. BİST piyasasında yüzde 10'luk bir devre kesici bulunmaktadır. Devre kesici özetle fiyat artış ve azalışlarına piyasa düzenleyicisi tarafından kısıtlama getirilmesidir. 2020 yılından önce yüzde 20 olarak devre kesilmekteydi (https://www.borsaistanbul.com/ 24.09.2022).

Oluşturulan modelde tahmin fiyatlarının isabetliliğine pozitif katkı sağlamaktadır. Yatırımcılar piyasa üzerinde doğrudan alım satım yapamazlar alım satım gerçekleştirmek için aracılar yani brokerlar bulunmaktadır (https://www.borsaistanbul.com/ 24.09.2022).

Borsa İstanbul API uygulamalarını izin verilen kurumsal aracılara sağlamaktadır dolayısı ile bireysel ve kurumsal olarak otomatik alım satım yapan BOT yazılımları resmi olarak bulunmamaktadır. Sadece arayüz otomasyonu ile yatırım yapan RPA uygulamaları kullanılabilmektedir.

RPA uygulamaları tıpkı insanlar kurumsal aracıların arayüzlerini kullanabildikleri için işlem yapma olanakları kısıtlıdır. Dolayısı ile BİST algoritmik alım satım ve araştırma için niş bir piyasadır bu sebeple çalışmaya dahil edilmiştir (https://www.borsaistanbul.com/ 24.09.2022).

Bora İstanbul piyasasında çeşitlendirme etkisini artırmak ve farklı davranışta bulunan hisselerinde dahil edilmesi amacıyla rastgele sekiz sektör seçilmiştir. Resmi olarak bulunmayan sağlık endeksi için kriterlere uyan sağlık sektöründen hisseler ile kukla bir endeks oluşturulmuştur.

Her sektör için o sektörde bulunan borsada kote olmuş ve işlem gören hisseler oluşturulan portföylere dahil edilmiştir. Hisseler dahil edilirken beş senelik fiyat geçmişinden daha fazla veri eklemek hisse örneklemini düşüreceğinden veri sorgu tarih aralığı 2016 ile 2021 arasında belirlenmiştir.

4.3 Evren ve Örneklem

Çalışmada internet servis sağlayıcısından 8 farklı sektörden 39 hisseye ait açılış, 2021'den itibaren beş yıl aralığında işlem görmüş hisselerin kapanış fiyatlarından oluşmaktadır. Kapanış fiyatı yerine düzeltilmiş kapanış fiyatının kullanılmamasının sebebi verilerin edinildiği servis sağlayıcısında her hisse için düzeltilmiş kapanış fiyatı her dönem için hesaplanmamasından kaynaklanmaktadır.

Sekiz farklı sektörü BİST bünyesindeki XBANK, XTCRT gibi resmi tanımlı endeksler çalışmaya dahil edilmiştir. XSAGLIK endeks olmadığından dolayı sanal olarak tanımlanmıştır. Oluşturulan sanal sağlık sektörü endeksi çalışma sınırlılığına uyan hisselerden oluşturulmuştur. Sektör nezdindeki hisseler kriterleri karşıladığı sürece rastgele seçilmiştir.

Hisse gerçek isimleri ve sektörleri Tablo 2'de yer almaktadır fakat model içerisinde hesaplamalarda yanılsamalara engel olmak amacıyla hisse kodları veya isimleri veya sektör isimleri kullanılmamıştır.

Örneklem büyüklüğü tek hisse için analiz grubu 1.028 test grubu 256 adet gözlemden oluşmaktadır. Tüm hisseler için analiz grubu 40.053 test grubu için 9.766 olmak üzere toplam veri 49.819 adet gözlemden oluşmaktadır. Çalışmanın evreni tüm BİST piyasası hisseleri olarak düşünülmüştür. Gözlemler hesaplama esansında fiyat başına 10.000 defa tekrar hesaplama işleminden geçirilmiştir toplamda 498.190.000 hesaplama yapılmıştır.

4.4 Araştırma Modeli

Evren ve Örneklem başlığında değinilen veriler Yahoo.com adresinden spesifik olarak hisse bazında elde edilmiştir. Elde edilen verilerin birer kopyası her iki yöntemin modeline entegre edilmiştir.

İlk yöntemde verileri dört senelik geçmişe yönelik olarak finansal tekniklerle analiz etmiştir getirileri, riskleri, değişim katsayıları, alfa ve beta katsayıları hesaplanmış son olarak lineer regresyon ile tahminleme yapılmıştır. Hesaplama sonuçlarına performans ve risk açısından optimal portföy oluşturulmuştur. Oluşturulan portföy performansa göre sıralanmış ve sektör fark etmeden en iyi performanslı seki hisse seçilmiştir.

Sekiz hissenin seçiliyor olmasının arka planında getiri ve riskin otuz dokuz hisse üzerinde normal dağıldığı ve ilk yirmi varlıktan sonra getirisinin düştüğü ve riskinin artması bulunmaktadır.

İkinci yöntemde tarafta ise makine öğrenmesi ile veriler eğitilmiş buna göre bir tahmin çıkarılmış ve bu tahminin verilerine getiri ve risk hesapları yapılmış potansiyel olarak en optimal portföy ortaya çıkarılmıştır. Her iki portföyün sonucu portföy performans ölçüm teknikleri ile gerçek veriler ile karşılaştırılarak hipotez test edilmiştir.

4.5 Verilerin Analizi

4.5.1 Verilere Erişim

Çalışmanın ilk etabında sektörler belirlenmiştir. Sektörler resmi endekslerden seçilmiştir bu endeksler XBANK, XBLSM, XGIDA, XINSA, XMESY, XTCRT, XUSIN ve KSAGLIK olarak belirlenmiştir.

Resmi olarak XSGLK endeksi bulunmadığı için bu endeks kukla olarak oluşturulmuş ve için özel hastane, ecza faaliyetli firmalardan 2016 yılı ve sonrasında borsada işlem görme kısıtına göre seçime dahil edilmiştir. Fakat sağlık alanında bu kıstası karşılayan anonim şirket sayısı kısıtlı olduğundan diğer endekslerde rastgele kriterleri karşılayan beş adet KSAGLIK kukla endeksinde dört adet seçim gerçekleştirilmiştir. Seçilen Hisseler aşağıdaki Tablo 2 içeriğinde görülebilmektedir.

Tablo 2. Çalışma Kapsamındaki Endeks ve Hisseler

Bist Endeksler							
XBANK	**XBLSM-TEKNOLO**	**XGIDA**	**XINSA**	**KSAGLIK**	**XTCRT**	**XUSIN**	**XMESY**
BİST BANKA ENDE	BİST BİLİŞİM ENDE	BİST GIDA ENDEI	BİST İNŞAAT ENDE	SAĞLIK SEKTORU	BİST TİCARET ENDI	BİST SNAİ ENDEI	BIST METAL ESYA MA
YKBNK	LOGO	TBORG	YYAPI	DEVA	MGROS	TUPRS	ASUZU
QNBFB	LINK	TUKAS	YAYLA	ECILC	BIMAS	ARSAN	VESTL
ISCTR	KAREL	KENT	TURGG	RTALB	BIZIM	FRIGO	SAYAS
AKBNK	INDES	DARDL	SANEL	SEYKM	DOAS	BURCE	DITAS
VAKBN	KRONT	ERSU	ORGE		INTEM	TKNSA	SILVR

Hisse borsa kodları hisselerin hangi şirketlere ait olduğuna dair fikir vermektedir. Araştırma objektifliğinin korunması adın tüm hisseler aşağıdaki kısaltmalarla analiz edilmiştir. P harfi bulunduğu endeksi ifade ederken H harfi hisse numarasını belirtmektedir. Her bir portföy indeks numarası ile numaralandırılmış ve her bir portföye ait hisse kendi içinde tekrar numaralandırılmıştır.

Tablo 3. Hisse İsimlerinin Maskelenmesi

DEVA	ECILC	RTALB	SEYKM	
P1H1G	P1H2G	P1H3G	P1H4G	
YKBNK	QNBFB	ISCTR	AKBNK	VAKBN
P2H1G	P2H2G	P2H3G	P2H4G	P2H5G
INDES	KAREL	KRONT	LINK	LOGO
P3H1G	P3H2G	P3H3G	P3H4G	P3H5G
TBORG	TUKAS	KENT	DARDL	ERSU
P4H1G	P4H2G	P4H3G	P4H4G	P4H5G
ORGE	SANEL	TURGG	YAYLA	YYAPI
P5H1G	P5H2G	P5H3G	P5H4G	P5H5G
MGROS	BIMAS	BIZIM	DOAS	INTEM
P6H1G	P6H2G	P6H3G	P6H4G	P6H5G
TUPRS	ARSAN	FRIGO	BURCE	TKNSA
P7H1G	P7H2G	P7H3G	P7H4G	P7H5G
ASUZU	VESTL	SAYAS	DITAS	SILVR
P8H1G	P8H2G	P8H3G	P8H4G	P8H5G

Yahoo web servisinin API modülü ile seçilen hisseler çalışmanın konu aldığı tarihlere göre alınmış ve Excel dosyalarına aktarılmıştır. İşlemin gerçekleştirildiği Kod Parçacığı 1 çerçevesinde aktarım görülebilmektedir.

Read_file hisse isimlerinin bulunduğu dosyadan veri alma işlemi olan fonksiyondur (https://docs.python.org 22.10.2022). Global notasyonu bir sonraki fonksiyonun listeye ulaşabilmesi küresel değişken atanmıştır.

With open metodu ile dosya okuma modunda açılmıştır. Açılan dosyada araştırmada kullanılacak hisselerin listesi bulunmaktadır. Readlines fonksiyonu ile dosyada bulunan liste okunmuştur. Dosyada belirlenen listedeki hisselerin datalarına erişen fonksiyon get_to_data olarak tanımlanmıştır.

Dosyadaki her bir hissenin verileri bir Pandas fonksiyonu olan web.DataReader ile verileri for döngüsü ile excel dosyalarına aktarılmıştır (https://pandas-datareader.readthedocs.io 22.10.2022) (https://finance.yahoo.com 22.10.2022).

Kod Parçacığı 1. Hisse Verilerinin Web Servisten Alınması

```
import pandas_datareader as web
import pandas as pd

def read_file():
    global stocks
    stocks = []
    with open("stocks.txt" , "r") as f:
        stocks_raw = f.readlines()
    for i in stocks:
        stocks.append(i.replace("\n","")
read_file()

def get_to_data():
    for i in stocks:
        df = web.DataReader(i, data_source='yahoo', start='2016-09-
30',end='2021-09-30')
        df.to_excel('{}.xlsx'.format(i))
```

4.5.2 Finansal Analiz

Elde edilen veriler içerisinden her hisse için kapanış fiyatları listelenmiştir. Buna göre 2016-2020 verileri kullanarak ortalama günlük getiri, riskleri, değişim katsayıları hesaplanmıştır. Trend analizi ile bir sonraki dönem 2020-2021 potansiyel olarak fiyat eğilimleri tahmin edilmiştir.

Tahmin edilen sonuçların getiri ve riskleri hesaplanıp gerçekleşen veriler ile tahmin verileri arasındaki farklar ile alfa katsayıları hesaplanmıştır. Sonuçlar aşağıdaki Tablo 4 çerçevesinde gösterilmiştir.

Buna göre beta katsayıları en küçükten büyüğe göre sıralanmış tahmini getirileri pozitifin üzerinde olan hisseler en iyi performans gösteren sekiz hisse seçilmiştir. Oluşturulan portföy Tablo 5 bünyesinde gösterilmektedir. Tablo özelinde

yeşil ve mavi renkler maksimum değerleri ifade ederken kırmızı renkler minimum skalayı göstermektedir.

Tablo 4. Analiz Sonuçları

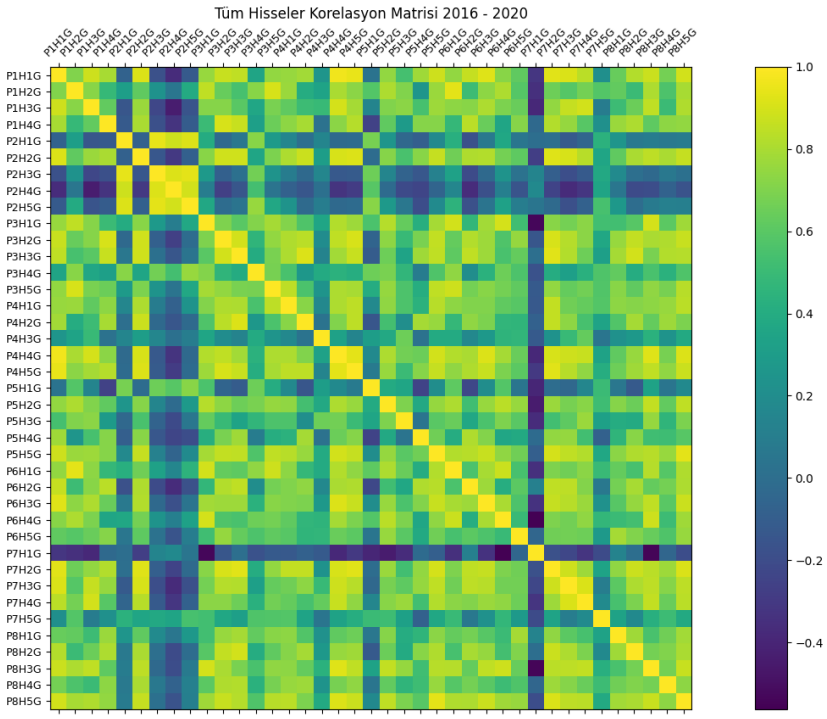
Hisse Senedi	Gerçekleşen Dönem	Ortalama Günlük Getiri	Gerçekleşen Risk	Gerçekleşen Getiri/Risk	Tahmin Edilen Dönem	Tahmini Günlük Ortalama Getiri	Tamini Risk	Tahmini Geitiri/Risk	Beta Katsayısı	Alfa Katsayısı
P7H3G	2016-2020	0.52%	5.12%	10.18%	2020-2021	0.11%	0.07%	158.43%	1.70%	0.41%
P4H3G	2016-2020	0.28%	4.38%	6.46%	2020-2021	0.00%	0.00%	157.39%	2.00%	0.28%
P4H4G	2016-2020	0.28%	3.68%	7.71%	2020-2021	0.09%	0.06%	158.52%	3.10%	0.19%
P2H2G	2016-2020	0.37%	4.45%	8.28%	2020-2021	0.11%	0.07%	158.47%	3.52%	0.26%
P1H4G	2016-2020	0.26%	2.83%	9.04%	2020-2021	0.08%	0.05%	158.52%	4.12%	0.17%
P7H4G	2016-2020	0.24%	3.55%	6.84%	2020-2021	0.08%	0.05%	158.51%	5.44%	0.17%
P1H3G	2016-2020	0.40%	4.05%	9.79%	2020-2021	0.11%	0.07%	158.45%	5.90%	0.29%
P5H3G	2016-2020	0.10%	2.30%	4.27%	2020-2021	0.01%	0.01%	157.59%	6.93%	0.09%
P4H5G	2016-2020	0.23%	3.23%	7.10%	2020-2021	0.09%	0.05%	158.52%	7.24%	0.14%
P6H5G	2016-2020	0.19%	3.62%	5.33%	2020-2021	0.04%	0.03%	158.23%	9.34%	0.15%
P3H2G	2016-2020	0.26%	3.84%	6.83%	2020-2021	0.08%	0.05%	158.51%	10.20%	0.19%
P5H1G	2016-2020	0.13%	4.39%	2.88%	2020-2021	-0.33%	0.24%	-138.10%	10.91%	0.46%
P3H5G	2016-2020	0.26%	3.53%	7.49%	2020-2021	0.05%	0.03%	158.29%	11.34%	0.22%
P8H4G	2016-2020	0.20%	4.02%	4.87%	2020-2021	0.05%	0.03%	158.34%	11.97%	0.14%
P4H2G	2016-2020	0.24%	3.49%	6.96%	2020-2021	0.10%	0.06%	158.51%	12.15%	0.15%
P7H5G	2016-2020	0.07%	3.79%	1.90%	2020-2021	-0.01%	0.00%	-157.20%	12.48%	0.08%
P5H4G	2016-2020	0.14%	3.05%	4.60%	2020-2021	0.07%	0.05%	158.49%	12.54%	0.07%
P5H2G	2016-2020	0.12%	3.51%	3.43%	2020-2021	0.03%	0.02%	158.07%	13.27%	0.09%
P3H3G	2016-2020	0.28%	3.39%	8.35%	2020-2021	0.09%	0.05%	158.52%	13.94%	0.20%
P8H3G	2016-2020	0.15%	3.41%	4.26%	2020-2021	0.05%	0.03%	158.35%	15.72%	0.09%
P1H1G	2016-2020	0.18%	2.75%	6.72%	2020-2021	0.08%	0.05%	158.52%	17.03%	0.10%
P1H2G	2016-2020	0.11%	2.68%	4.01%	2020-2021	0.02%	0.01%	157.76%	17.31%	0.09%
P8H1G	2016-2020	0.17%	3.34%	5.03%	2020-2021	0.05%	0.03%	158.28%	17.50%	0.12%
P8H5G	2016-2020	0.18%	3.32%	5.48%	2020-2021	0.06%	0.04%	158.41%	18.53%	0.12%
P7H2G	2016-2020	0.18%	2.81%	6.44%	2020-2021	0.07%	0.05%	158.48%	18.60%	0.11%
P3H1G	2016-2020	0.08%	2.37%	3.30%	2020-2021	0.02%	0.01%	157.82%	18.99%	0.06%
P3H4G	2016-2020	0.11%	2.69%	4.06%	2020-2021	0.00%	0.00%	-157.33%	21.16%	0.11%
P6H4G	2016-2020	0.08%	2.90%	2.68%	2020-2021	0.02%	0.01%	157.74%	22.27%	0.06%
P8H2G	2016-2020	0.13%	2.93%	4.58%	2020-2021	0.06%	0.04%	158.38%	22.99%	0.08%
P4H1G	2016-2020	0.10%	1.73%	5.64%	2020-2021	0.04%	0.02%	158.12%	23.66%	0.06%
P5H5G	2016-2020	0.15%	2.69%	5.62%	2020-2021	0.05%	0.03%	158.29%	23.96%	0.10%
P6H2G	2016-2020	0.11%	1.67%	6.77%	2020-2021	0.06%	0.04%	158.36%	24.85%	0.06%
P6H3G	2016-2020	0.09%	2.51%	3.49%	2020-2021	0.05%	0.03%	158.27%	25.67%	0.04%
P7H1G	2016-2020	0.05%	2.03%	2.60%	2020-2021	0.02%	0.01%	157.77%	31.09%	0.04%
P6H1G	2016-2020	0.10%	2.25%	4.43%	2020-2021	0.02%	0.01%	157.89%	33.17%	0.08%
P2H5G	2016-2020	0.01%	2.36%	0.48%	2020-2021	-0.03%	0.02%	-156.53%	47.57%	0.04%
P2H1G	2016-2020	0.01%	2.15%	0.27%	2020-2021	-0.02%	0.01%	-156.80%	48.93%	0.03%
P2H4G	2016-2020	-0.01%	2.16%	-0.63%	2020-2021	-0.03%	0.02%	-156.49%	51.53%	0.02%
P2H3G	2016-2020	0.02%	2.09%	1.14%	2020-2021	-0.02%	0.01%	-156.77%	51.73%	0.05%

Tablo 5. Hisse Performans Karşılaştırılması

Hisse Senedi	Gerçekleşen Dönem	Ortalama Günlük Getiri	Gerçekleşen Risk	Gerçekleşen Getiri/Risk	Tahmin Edilen Dönem	Tahmini Getiri	Tahmini Günlük Ortalama Getiri	Tahmini Risk	Tahmini Geitiri/Risk	Beta Katsayısı	Alfa Katsayısı
P7H3G	2016-2020	0.52%	5.12%	10.18%	2020-2021	33.63%	0.11%	0.07%	158.43%	1.70%	0.41%
P4H3G	2016-2020	0.28%	4.38%	6.46%	2020-2021	0.02%	0.00%	0.00%	157.39%	2.00%	0.28%
P4H4G	2016-2020	0.28%	3.68%	7.71%	2020-2021	27.33%	0.09%	0.06%	158.52%	3.10%	0.19%
P2H2G	2016-2020	0.37%	4.45%	8.28%	2020-2021	31.12%	0.11%	0.07%	158.47%	3.52%	0.26%
P1H4G	2016-2020	0.26%	2.83%	9.04%	2020-2021	23.42%	0.08%	0.05%	158.52%	4.12%	0.17%
P7H4G	2016-2020	0.24%	3.55%	6.84%	2020-2021	21.82%	0.08%	0.05%	158.51%	5.44%	0.17%
P1H3G	2016-2020	0.40%	4.05%	9.79%	2020-2021	32.46%	0.11%	0.07%	158.45%	5.90%	0.29%
P5H3G	2016-2020	0.10%	2.30%	4.27%	2020-2021	2.16%	0.01%	0.01%	157.59%	6.93%	0.09%

Hisseler arasındaki korelasyon katsayısı matrisi aşağıdaki Tablo 6 çerçevesinde incelenmiştir. Korelasyon matrisinde sarı renkler tam pozitif korelasyonu ifade ederken mavi renkler tam negatif korelasyonu ifade etmektedir skala 1 ile -1 arasındadır.

Tablo 6. Korelasyon Matrisi



4.5.3 Yapay Sinir Ağları ile Analiz

Verilere erişim başlığında değinilen Yahoo web servisinin API modülü tekrar kullanılarak aynı veri seti makine eğitimi için tekrar aynı kaynaktan aktarılmıştır (https://finance.yahoo.com 22.10.2022). Bu aktarım ve kullan diğer modüller aşağıdaki kod parçacığında gösterilmiştir. İlk dokuz satırda çalışmada kullanılacak modüller ve fonksiyonlar entegre edilmiştir.

Kod Parçacığı 2. Kütüphanelerin Dahil Edilmesi ve Verilerin Tekrar Alınması

```
import math
import pandas_datareader as web
import numpy as np
import pandas as pd
from sklearn.preprocessing import MinMaxScaler
from keras.models import Sequential
from keras.layers import Dense, LSTM
import matplotlib.pyplot as plt
import tensorflow

plt.style.use('fivethirtyeight')
df = web.DataReader(hisse_kodu ,data_source='yahoo', start='2016-09-
30',end='2021-09-30')
```

Kaynak: (https://jovian.ai 22.10.2022)

DataFrame pandas modülünün tablolama veri tipidir başlık ve sütunlardan oluşmaktadır (https://pandas.pydata.org 22.10.2022). Sadece kapanış fiyatları üzerinde analiz gerçekleştirilmiştir. Dolayısı ile aktarılan veriler aşağıdaki metotlar ile sadece kapanış fiyatları bazında filtrelenmiştir ve fiyatların 2016 ve 2020 aralığındaki kısmı eğitim için ayrılmıştır. Data isimli yeni bir değişkene pandas modülünün filter isimli metodu ile kapanış fiyatları alınmaktadır.

Pandas modülünün kendi veri tipi olan dataframe yapısına benzer olarak numpy modülünün ise çok boyutlu serileri diziler bulunmaktadır (https://pandas.pydata.org 22.10.2022). Dataset isimli yeni bir değişkene values metodu ile dataframe verisi array verisine dönüştürülmüştür (https://numpy.org 22.10.2022). Web fonksiyonu ile elde edilen beş yıl uzunluğundaki veri setinin dört yılı eğitim için kullanılmıştır. Dolayısı ile aşağıdaki fonksiyon ve metotlarda için uzunluk bilgisi 0.8 katsayısı ile çarpılmıştır.

Kod Parçacığı 3. Kapanış Fiyatlarının Filtrelenmesi

```
data = df.filter(['Close'])
dataset = data.values
training_data_len = math.ceil(len(dataset)* .8)
```

Kaynak: (https://jovian.ai 22.10.2022)

Belirlenen aralıktaki veriler optimizasyon eğitim ve tahmin için 0 ile 1 aralığına sıkıştırılmıştır. Bu işlem eğitim ve tahmin işlemi gerçekleştikten sonra geri alınabilmektedir. Eğitim için bağımlı ve bağımsız değişken olarak kullanılacak iki adet liste oluşturulmuştur. Kod parçacığının ilk kısmında çağrılan MinMaxScaler fonksiyonu değerleri optimizasyon amaçlı olarak sıfır ve bir arasına sıkıştırmaktadır (https://scikit-learn.org 22.10.2022). İlgili fonksiyonun çıktısı yazım sadeliği açısından scaler isimli bir değişkene atanmıştır.

Tüm veri yeni bir değişkene aktarılarak daha önceden belirlenen veri dataset fit_transform fonksiyonu ile yapısına benzetilmiştir. Önceden eğitilecek veri uzunluğu belirlenip sıfır ile bir arasına sıkıştırılan veriden eğitilecek olan yüzde seksenlik kısım makinenin öğreneceği veri olarak belirlenmiştir ve train_data isimli değişkene atanmıştır.

Eğitme işlemi için iki adet boş liste oluşturulmuştur. Eğitilecek değerler 60 birim uzunluğunda paketler halinde x_train datasına eklenmiştir. Toplamda 349 paket

bu listeyi oluşturmuştur. Oluşturulan 60 uzunluğundaki 349 paketin 61.değerleri y_train isimli listeye eklenmiştir ve toplam uzunluk 349 örneklemden oluşmaktadır. x_train içindeki veri paketinin LSTM modelinde eğitilerek y_train listesindeki değerlere tahminlerin yaklaştırması gerçekleştirilecektir.

Kod Parçacığı 4. Verilerin Transforme Edilmesi

```
scaler = MinMaxScaler(feature_range=(0,1))
scaled_data = scaler.fit_transform(dataset)
train_data = scaled_data[0:training_data_len, :]
x_train = []
y_train = []
tr = 60
for i in range(tr,len(train_data)):
    x_train.append(train_data[i-tr:i,0])
    y_train.append(train_data[i,0])
```

Kaynak: (https://jovian.ai 22.10.2022)

For döngüsü, belirli bir liste veya seri içerisinde her bir eleman için işlem yapılmak için kullanılmaktadır (https://www.techopedia.com 18.11.2022). Döngü ile listelere eklenen veriler için np.array metodu ile oluşturulan listeler eğitim için numpy modülünün bir veri tipi olan array tipine dönüştürülmektedir bu veri tipi matematiksel olarak serileri ifade etmektedir. LSTM ağı veriyi üç boyutlu bir numpy dizisi olarak kabul etmektedir (https://keras.io 22.10.2022). Bir önceki adımda oluşturulan eğitim verileri numpy dizilerine bundan dolayı dönüştürülmüştür.

Metot olarak tanımlanan shape dizi hakkında bir üçlü bilgi vermektedir ilk değer seri uzunluğunu ikinci değer paket boyutunu üçüncü değer ise liste boyutunu vermektedir. Yazılan reshape metoduna ile shape metodundan alınan aynı değerler ile bir boyutlu olarak yeniden şekillendirilmesi sağlanmıştır (https://numpy.org 22.10.2022). Aşağıdaki metotlar seriye datayı modelin çoklu katman yapısına uyum sağlaması için kullanılmıştır.

Kod Parçacığı 5. Verilerin Transforme Edilmesi

```
x_train = np.array(x_train)
y_train = np.array(y_train)
x_train.shape
x_train = np.reshape(x_train , (x_train.shape[0], x_train.shape[1],1))
```

Kaynak: (https://jovian.ai 22.10.2022)

Aşağıdaki metotlar seriye datayı modelin çoklu katman yapısına uyum sağlaması için kullanılmıştır. Model isimli değişkene Sequantial metodu ile model tipini ve parametrelerin belirleneceği sınıf atanmıştır.

LSTM metoduna atanan 50 ifadesi 50 Adet Nöronu ifade etmektedir (https://www.tensorflow.org 22.10.2022). Başka bir nöral ağ kullanılmayacağından dolayı return sequences True belirlenmiştir. Daha önce shape hala getirilen x_train serisi uzunluğu 60 ve boyutu 1 olarak modele eklenmiştir. İkinci LSTM katmanı daha fazla katmana ihtiyaç bulunmadığı için False bırakılmıştır.

Modelin ikinci katmanına 25 gizli nöron ilave edilmiştir. Son katmana ise 1 nöron tekil tahmin için ilave edilmiştir. Tekil tahminler kümüle olarak biriktirilmiştir. Modeli compile metodu ile optimizasyon motorunun adam, tahminlerin gerçek değerlerden uzaklaşma değerinin ise hatalar kareler toplamı olacağı tanımlanmıştır.

Batch_size eğitilen örneklerin paket büyüklüğünü epoch ise iterasyon sayısını tüm data için vermektedir. Daha önceden transformasyon edilen x_train ve y_train listeleri modele dahil edilmiştir. Tahminleme işlemleri her hisse için gerçekleştirilmiştir.

Kod Parçacığı 6. Tahmin Ağının Oluşturulması

```
model = Sequential()
```

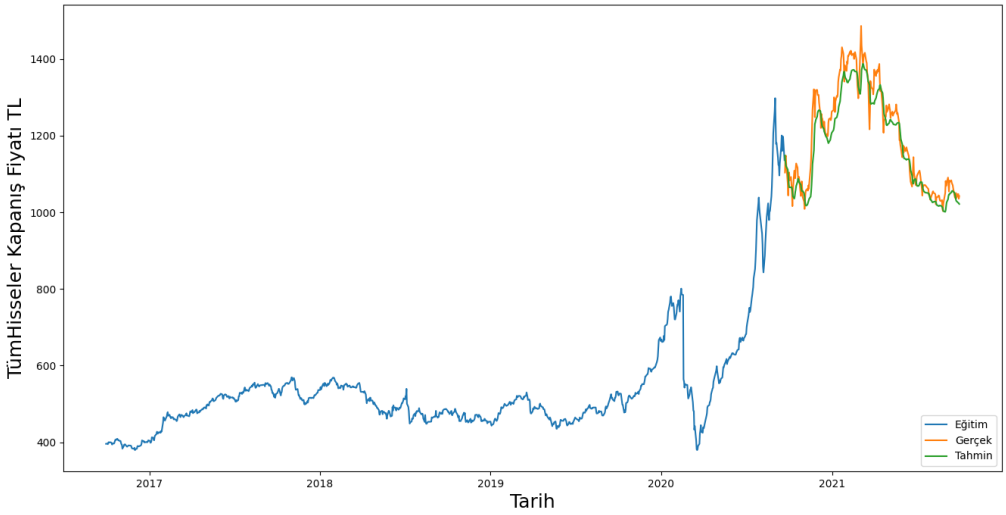
```
model.add(LSTM(50, return_sequences=True , input_shape = (tr,1)))
model.add(LSTM(50, return_sequences=False))
model.add(Dense(25))
model.add(Dense(1))
model.compile(optimizer = 'adam' , loss ='mean_squared_error')
model.fit(x_train,y_train, batch_size = 1 ,epochs = 1)
```

Kaynak: (https://jovian.ai 22.10.2022)

5.BULGULAR ve YORUM

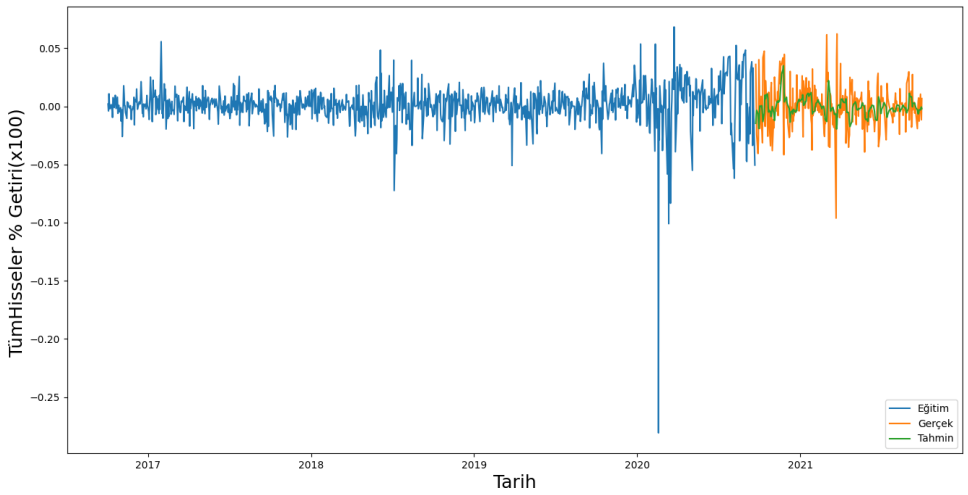
Gerçekleştirilen tahminler sonucunda tüm endeksler için aşağıdaki tahmin değerleri eğitilen algoritma hesaplaması sonucunu göstermektedir. Tüm hisselerin kümülatif olarak fiyat toplam gerçekleşen ve tahminleri aşağıdaki Grafik 1 çerçevesinde görülmektedir. Buna göre mavi renkteki çizgi 2016-2020 yıllarında gerçekleşen fiyatları turuncu renkli çizgi 2020-2021 yılları arasında gerçekleşen fiyatları ve yeşil renkli çizgi ise 2020-2021 yılları arasına yapılan tahmini fiyatları göstermektedir.

Grafik 1. Eğitim ve Tahminleme Sonuçları



Gerçek ve tahminlenen fiyatların günlük getirileri ve tahminlenen dönem için gerçek ve tahmin fiyatlarının getirileri çizdirildiğinde aşağıdaki grafik ortaya çıkmaktadır.

Grafik 2. Getiri Hesaplamaları Tahmin ve Aktüel Veriler



Tahmin sonuçlarına göre oluşturulacak ikinci portföy için getiri ve risk hesaplamaları yapılmıştır. Bu hesaplamalara göre 2020-2021 yılları arasında maksimum getirili ve minimum riskli en iyi sekiz hisse belirlemek için getiri risk oranına göre sıralanmıştır. Hesaplama ve sıralama sonucu aşağıdaki Tablo 7 çerçevesinde görülmektedir.

Tablo 7. Tahmin Değerleri Sonucu Getiri ve Risk

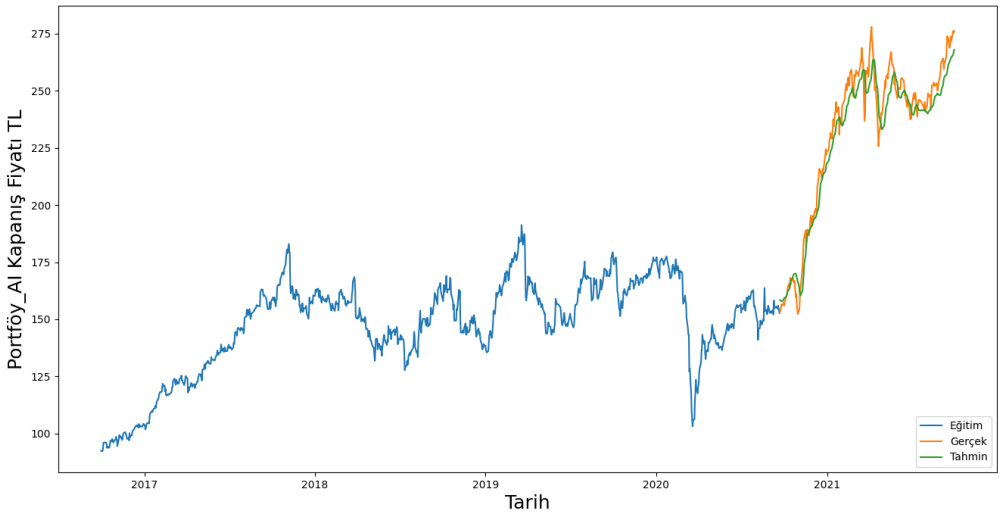
Hisse	Ortalama Getiri	Standart Sapma	Getiri/Risk Oranı
P1H4G	0.59%	1.46%	40.67%
P3H2G	0.22%	0.84%	26.47%
P3H5G	0.23%	0.88%	26.21%
P8H3G	0.49%	1.94%	25.38%
P6H4G	0.33%	1.50%	22.32%
P8H2G	0.22%	1.21%	17.87%
P7H1G	0.12%	0.66%	17.75%
P3H1G	0.21%	1.44%	14.68%
P5H3G	0.22%	1.58%	14.18%
P7H2G	0.14%	1.12%	12.22%
P5H2G	0.13%	1.23%	10.39%
P5H1G	0.10%	1.05%	9.92%
P1H1G	0.05%	0.58%	9.46%
P6H5G	0.24%	2.95%	8.00%
P7H5G	0.10%	1.43%	6.97%
P2H1G	0.06%	0.90%	6.90%
P8H1G	0.08%	1.13%	6.88%
P3H4G	0.13%	1.91%	6.57%
P3H3G	0.12%	1.98%	5.99%
P8H4G	0.14%	2.26%	5.97%
P8H5G	0.12%	2.30%	5.15%
P4H1G	0.04%	1.00%	3.95%
P5H4G	0.07%	1.80%	3.89%
P2H4G	0.03%	1.04%	3.32%
P7H4G	0.03%	0.79%	3.26%
P5H5G	0.03%	1.21%	2.76%
P2H3G	0.01%	0.95%	1.38%
P7H3G	-0.04%	1.47%	-3.02%
P6H2G	-0.02%	0.42%	-4.72%
P1H2G	-0.05%	0.59%	-8.92%
P4H5G	-0.06%	0.56%	-9.86%
P2H5G	-0.07%	0.71%	-10.00%
P6H1G	-0.08%	0.64%	-11.78%
P6H3G	-0.10%	0.79%	-12.42%
P4H4G	-0.54%	3.51%	-15.24%
P4H3G	-0.31%	1.95%	-16.15%
P1H3G	-0.30%	1.64%	-18.14%
P4H2G	-0.14%	0.70%	-20.48%
P2H2G	-0.21%	0.63%	-33.89%

Model varsayımlarına göre hisselerden en yüksek performans veren sekiz hisseden portföy oluşturulmuştur. Tahmin ile oluşturulan portföy aşağıdaki Tablo 8 ve tahmin değerlerinin analitik grafiği Grafik 2 çerçevesinde görülmektedir.

Tablo 8. Analiz Sonuçları LSTM

Hisse	Ortalama Getiri	Standart Sapma	Risk/Getiri Oranı
P1H4G	0.59%	1.46%	40.67%
P3H2G	0.22%	0.84%	26.47%
P3H5G	0.23%	0.88%	26.21%
P8H3G	0.49%	1.94%	25.38%
P6H4G	0.33%	1.50%	22.32%
P8H2G	0.22%	1.21%	17.87%
P7H1G	0.12%	0.66%	17.75%
P3H1G	0.21%	1.44%	14.68%

Grafik 3. Oluşturulan Portföyün Analitik Gösterimi



6. SONUÇ

Her iki yöntemle oluşturulan yatırım portföyleri analiz edilen dönemdeki karşılaştırma amaçlı derlenmiştir. Her iki analiz tekniğinde ortak hesaplamalar kullanılarak performans karşılaştırması yapılabilmektedir.

Portföy I klasik analiz yöntemleri risk getiri ve diğer parametrelere kullanılarak gerçekleştirilmiş ve geleceğe yönelik lineer regresyon teknikleri ile analiz yapılmıştır. Fakat yatırım yılı gerçekleştiğinde portföy içerisinde bulunan dört adet hisse düşük performans göstermiş ve negatif getiri ve negatif getiri risk oranı izlemişlerdir. Negatif getiri gösteren hisse portföydeki en küçük beta katsayısına sahip endeksle beraber hareket edeceği tahmin edilen P4H3G isimli hissedir.

Portföy II incelendiğinde oluşturulan portföyde negatif getiri izleyen hisse bulunmadığı görülmüştür LSTM modeli artış azalışları tahmin etmekte tutarlı çıktılar göstermiştir. Tahmini değer ile gerçekleşen değer arasındaki farkın karesi ortalama hata oranı olarak isimlendirilmektedir. Portföy I ortalama %0.0074 hata oranı ile tahminleme yaparken Portföy II %0.0005 ortalama ile tahminleme gerçekleştirmiştir.

Tablo 9. Portföylerin Karşılaştırılması

PORTFÖY I	2016-2020 Analiz Edilen Dönem			2020 - 2021 Tahminleri				2020 - 2021 Gerçekleşen Dönem		
Hisse Senedi	Ortalama Getiri	Gerçekleşen Risk	Getiri/Risk Oranı	Ortalama Getiri	Tamini Risk	Getiri/Risk Oranı	Beta Katsayısı	Ortalama Getiri	Gerçekleşen Risk	Getiri/Risk Oranı
P7H3G	0.52%	5.12%	10.18%	0.11%	0.07%	158.43%	1.70%	0.13%	4.67%	2.87%
P4H3G	0.28%	4.38%	6.46%	0.00%	0.00%	157.39%	2.00%	-0.14%	4.91%	-2.92%
P4H4G	0.28%	3.68%	7.71%	0.09%	0.06%	158.52%	3.10%	-0.16%	7.06%	-2.20%
P2H2G	0.37%	4.45%	8.28%	0.11%	0.07%	158.47%	3.52%	-0.21%	2.86%	-7.43%
P1H4G	0.26%	2.83%	9.04%	0.08%	0.05%	158.52%	4.12%	0.71%	4.21%	16.77%
P7H4G	0.24%	3.55%	6.84%	0.08%	0.05%	158.51%	5.44%	0.12%	3.77%	3.22%
P1H3G	0.40%	4.05%	9.79%	0.11%	0.07%	158.45%	5.90%	-0.23%	4.33%	-5.23%
P5H3G	0.10%	2.30%	4.27%	0.01%	0.01%	157.59%	6.93%	0.23%	3.83%	5.98%
PORTFÖY II	2016-2020 Analiz Edilen Dönem			2020 - 2021 LSTM Tahminleri				2020 - 2021 Gerçekleşen Dönem		
Hisse Senedi	Ortalama Getiri	Gerçekleşen Risk	Getiri/Risk Oranı	Ortalama Getiri	Tamini Risk	Getiri/Risk Oranı	Beta Katsayısı	Ortalama Getiri	Gerçekleşen Risk	Getiri/Risk Oranı
P1H4G	0.26%	2.83%	9.04%	0.59%	1.46%	40.67%	-	0.71%	4.21%	16.77%
P3H2G	0.26%	3.84%	6.83%	0.22%	0.84%	26.47%	-	0.28%	2.93%	9.43%
P3H5G	0.26%	3.53%	7.49%	0.23%	0.88%	26.21%	-	0.27%	2.80%	9.77%
P8H3G	0.15%	3.41%	4.26%	0.49%	1.94%	25.38%	-	0.64%	4.75%	13.56%
P6H4G	0.08%	2.90%	2.68%	0.33%	1.50%	22.32%	-	0.39%	3.70%	10.66%
P8H2G	0.13%	2.93%	4.58%	0.22%	1.21%	17.87%	-	0.20%	2.52%	7.98%
P7H1G	0.05%	2.03%	2.60%	0.12%	0.66%	17.75%	-	0.16%	1.84%	8.76%
P3H1G	0.08%	2.37%	3.30%	0.21%	1.44%	14.68%	-	0.22%	2.84%	7.89%

Portföy performansları aşağıdaki Tablo 9 çerçevesinde incelenmiştir. Buna göre Portföy I bünyesinde zarar gerçeklememiş tahmin edilen değere yaklaşık %5'lik bir sapma ile beklentilerin üzerinde pozitif performans göstermiştir. Portföy II yaklaşık %12'lik bir sapma ile beklentilerin üzerinde performans göstermiştir. Portföy dizimi oluşturma konusunda Portföy II %128 kümülatif getiri ile Portföy I çok daha kazançlı bir yatırıma olanak sunmuştur. Gerçekleşen kısımda Portföy II yüksek kazanca rağmen %1.17 oranında riske katlanmaktadır fakat çok daha düşük getiriye sahip Portföy I riski %1.62 olarak gerçekleşmiştir. Dolayısı ile Portföy II kazanç ve risk bakımından daha optimize bir tablo çizmiştir.

Tablo 10. Portföylerin Karşılaştırılması Özet

Parametreler	PORTFOY I	PORTFOY I	PORTFOY II	PORTFOY II
	Lineer Tahmin Edilen 2020 - 2021	**Gerçekleşen 2020-2021**	**LSTM Tahmini 2020-2021**	**Gerçekleşen 2020-2021**
Portföy Getirisi	21.50%	27.335%	128.129%	140.193%
Ortalama Portföy Getirisi	0.07422%	0.05653%	0.30214%	0.36012%
Portföy Varyansı	0.00001%	0.02644%	0.00207%	0.01372%
Portföy Standart Sapması	0.03338%	1.62603%	0.45545%	1.17119%

Çalışma hazırlanırken daha yüksek bir işlem gücü ile BİST bünyesindeki her hisse senedi için yapılabilirliği düşünülmüştür. Nöral ağların tahminleme gücü yüksek olmasına rağmen her bir veri için binlerce iterasyon ve hesaplama gerektirmektedir dolayısı ile hem çevresel faktörler hem hisselerin firma içi mali tabloları kullanılarak tahminleme isabetliliği artırılabilecektir.

KAYNAKÇA

Kitaplar

Akyüz, Yılmaz, Held, Günther, Finance and The Real Economy Issues And Case Studies In Developing Countries, Şili, 1993

Alpaydın, Ethem, Yapay Öğrenme, İstanbul, 2020

Aras, Güler, Tezcan, Nuray, Furtuna Kutlu, Özlem, Kazak Hacıoğlu, Evrim, Türkiye Sermaye Piyasasında Faaliyet Gösteren Aracı Kurumların Performans ve Etkinlik Analizi, İstanbul, 2018

Bhat, Sudhindra, Security Analysis And Portfolio Management, Hindistan 2011

Büyükkör, Yasin, Xgboost Makine Öğrenmesi Yöntemi Kullanılarak Ham Petrol Fiyatının Tahminlenmesi, Ankara, 2022

Dahlquist, Julie, Knight, Rainford, Principles Of Fianance, Amerika Birleşik Devletleri, 2022

Drake, Peterson, Pamela, Fabozzi, Frankj., The Basics Of Finance, Amerika Birleşik Devletleri, 2010

Gibson, Charles H., Financial Reporting & Analysis, Amerika Birleşik Devletleri, 2009

Gibson, Nigel, Essential FINANCE, İtalya, 2003

Karğın, Mahmut, Yıldız, Selim Baha, Gözkonan, Hasan Ümit, Para, Bankacılık ve Finans Tartışmaları, Bursa, 2022

Kaya, Ferudun, Finansal Yönetim, İstanbul, 2015

Levišauskaite, Kristina, Investment Analysis And Portfolio Management, İtalya 2010

Quiry, Pascal, Dallocchio, Maurizio, Le Fur, Yann, Salvi, Antonio, Salvi, Corporate Finance Theory And Practice, İngiltere, 2005

Sarıkovanlık, Vedat, Sermaye Piyasaları ve Finansal Kurumlar Yönetimi, Elektronik Kitap 2017

Makaleler

Agrawal, Manish, Khan, Asif Ullah, Shukla, Kumar Piyush, Stock Indices Price Prediction Based on Technical Indicators using Deep Learning Model, International Journal on Emerging Technologies, 2019, Cilt 10, Sayı 2, Sayfa 186-194

Alp, Ali, Bilir, Hakan, "Beta Calculation And Robust Regression Methods: An Example From The Istanbul Stock Exchange", International Research Journal Of Marketing And Economics", 2017, Cilt 2, Sayı 11, Sayfa 43-54

Al-Shayea, Qeethara K., Neural Networks to Predict Stock Market Price, Proceedings of the World Congress on Engineering and Computer Science, 2017, Cilt 1, Sayı 1, Sayfa 25-27

Buda, Andrej, Life time of correlation between stocks prices on established and emerging markets, Life-time Of Correlation And Its Application, 2010, Cilt 1, Sayfa 1-17

Canıtez, Mert Ali, Savaş, Serkan, Kripto Para Piyasa Değeri Tahmini için Özellik Tabanlı LSTM ve ARIMA Karşılaştırması, 3rd International Conference on Applied Engineering and Natural Sciences, 2022, Sayfa 20-23

Cochrane, Jhon H., Macro-Finance, Review of Finance, 2017, Sayfa 945-985

Deorukhkar, Omkar S., Lokhande, Shrutika H., Nayak, Vanishree R., Chougule, Amit A., Stock Price Prediction using combination of LSTM Neural Networks, ARIMA and Sentiment Analysis, International Research Journal of Engineering and Technology (IRJET), 2019, Cilt 6, Sayı 3, Sayfa 3497-3503

Faurina, Ruvita, Winduratna, Bondhan, Nugroho, Prapto, Predicting Stock Movement Using Unidirectional LSTM and Feature Reduction: The Case of An Indonesia Stock, International Conference on Electrical Engineering and Computer Science (ICEECS), 2018, Sayfa 180-185

Ghosh, Achyut, Bose, Soumik, Maji,Giridhar, Debnath, Narayan C., Sen, Soumya, Stock Price Prediction Using LSTM on Indian Share Market, EPiC Series in Computing, 2019, Cilt 1, Sayı 63, Sayfa 101-110

Gökgöz, Fazıl, Günel, Mehmet, Ogan, Türk Yatırım Fonlarının Portföy Performanslarının Analizi, Ankyra: Ankara Üniversitesi Sosyal Bilimler Enstitüsü Dergisi, 2012, Sayı 3, Cilt 2, Sayfa 3-25

Hollstein, Fabian, Prokopzcuk, Marcel, Estimating Beta, Journal of Fınancıal and Quantıtatıve Analysis, 2016, Cilt 51, Sayı 4, Sayfa 1437-1466

Hooda, D.S, Stehlik, Milan, Portfolio Analysis Of Investments In Risk Management, The Open Statistics and Probability Journal, 2011, Sayı 3, Sayfa 21-26

Jiawei, Xu, Murata, Tomohiro, Stock Market Trend Prediction with Sentiment Analysis based on LSTM Neural Network, Proceedings of the International MultiConference of Engineers and Computer Scientists, 2019, Sayfa 13-15

Koç, Selehattin, Onocak, Derya, Yapay Sinir Ağları İle Emeklilik Yatırım Fonu Hisse Senedi Fiyatlarının Tahmini, Finans Ekonomi ve Sosyal Araştırmalar Dergisi, 2018, Cilt 3, Sayı 3, Sayfa 590-600

Köseoğlu Derindere, Sinem, 1997-2010 Dönemi Türk Bankacılık Sektörü Risk Analiz, Niğde Üniversitesi İ.İ.B.F Dergisi, 2010, Cilt 3, Sayı 2, Sayfa 119-133

Lee, Hui-Shan, Cheng, Fan-Fah, Chong, Shyue-Chuan, Markowitz Portfolio Theory and Capital Asset Pricing Model for Kuala Lumpur Stock Exchange: A Case Revisited, International Journal of Economics and Financial Issues, 2016, Cilt 6, Sayı 3, Sayfa 59-65

Manurung, Adler Haymans , Budiharto, Widodo, Prabowo, Harjanto, Algorıthm And Modelıng Of Stock Prıces Forecastıng Based On Long Short-Term Memory (LSTM), ICIC Express Letters, 2018, Cilt 12, Sayı 12, Sayfa 1277-1283

Omisore, Lyiola, Yusuf, Munirat, Christopher, Nwufo, The Modern Portfolio Theory As An İnvestment Decision Tool, Journal of Accounting and Taxation, 2012, Cilt 4, Sayı 2, Sayfa 19-28

Pramod, B S, Shastry, Mallikarjuna, ISSN, 2020, Cilt 83, Sayfa 5246-5251

Roondiwala, Murtaza, Patel, Harshal, Varma, Shraddha, Predicting Stock Prices Using LSTM, International Journal of Science and Research, 2015, Sayfa 1754-1756

Söylemez, Yakup, Çok Katmanlı Yapay Sinir Ağları Yöntemi ile Altın Fiyatlarının Tahmini, Sosyoekonomi Dergisi, 2020, Cilt 28, Sayı 46, Sayfa 271-291

Söylemez, Yakup, Türkmen Yılmaz, Sibel, Yapay Sinir Ağları Modeli İle Finansal Başarısızlık Tahmini, Finans Ekonomi ve Sosyal Araştırmalar Dergisi, 2017, Cilt 2, Sayı 4, Sayfa 270-284

Suwarno, Agus, Mahadwartha, Anom, Putu, The Analysis Of Portfolio Risk Management Using Var Approach Based On Investor Risk Preference, KINERJA, 2017, Cilt 2, Sayı 21,

Troncoso, Arturo, The Concept Of Risk In Portfolio Theory, Panorama Pocıoeconómıco Año, 2008, Sayı 26, Sayfa 182-195

Yüksel, Asım Sinan, Karabıyık, Muhammed Abdulhamid, Doğal dil işleme yöntemleriyle metinden SQL sorgusu tahmini üzerine bir çalışma, Niğde Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi, 2022, Cilt 11, Sayı 4, Sayfa 846-855

Tezler

Abalkhail, Musaad A. , The Modern Portfolıo Theory In Optımızıng Rısky-Asset Portfolıo, Yüksek Lisans Tezi, California State Polytechnic University, Pomona, 2017, Sayfa 1-43

Bellici, Murat, Türkiye'De Portföy Yönetimi Ve Portföy Yönetim Şirketi Kurulması Üzerine Bir Uygulama, Yüksek Lisans Tezi, Kadir Has Üniversitesi, 2005, Sayfa 1-134

Hansson, Magnus, On stock return prediction with LSTM networks, Yüksek Lisans Tezi, Lund University, 2017, Sayfa 1-36

Kalfa, Veli Rıza, Portföy Analizi ev Doğrusal Programlama Metodu İle İMKB'de Bir Uygulama, Adnan Menderes Üniversitesi, 2010, Sayfa 1-121

Keçeci, Ekin, Yinelemeli Sinir Ağları İle Finansal Veri Tahmini, Yüksek Lisans Tezi, Hacettepe Üniversitesi, 2022, Sayfa 1-37

İnternet Kaynakları

DiBartolomeo, Dan, Implementation of Equity Return Forecasting Methods, Northfield Information Services, 1998, Sayfa 1-10, https://www.northinfo.com/documents/124.pdf (Erişim Tarihi: 18.11.2022)

Farooq, M. Sharmeen, Evaluating Stock Performance with Jensen Alpha and Beta, INDIAN INSTITUTE OF MANAGEMENT KOZHIKODE, 2020, Sayfa 1-5, https://iimk.ac.in/research/markconf20/ (Erişim Tarihi: 18.11.2022)

Güleryüz, Didem, Özden, Erdemalp, Gülhan, Ünal, Predicting BIST 30 Index with ARIMA and RNN-LSTM Models, 2021, Sayfa 2-10, https://www.researchgate.net/profile/Didem-Gueleryuez (Erişim Tarihi: 18.11.2022)

https://adgefficiency.com/guide-deep-learning/ (Erişim tarihi: 22.10.2022)

https://asmquantmacro.com/2015/08/14/pattern-recognition-with-neural-network-in-excel-a-toy-example/ (Erişim tarihi: 22.10.2022)

https://borsaistanbul.com/tr (Erişim Tarihi: 24.09.2022)

https://colah.github.io/posts/2015-08-Understanding-LSTMs/index.html (Erişim tarihi: 22.10.2022)

https://deepai.org/machine-learning-glossary-and-terms/sigmoid-function (Erişim tarihi: 22.10.2022)

https://docs.python.org/3/library/functions.html (Erişim tarihi: 22.10.2022)

https://finance.yahoo.com (Erişim tarihi: 22.10.2022)

https://flatironschool.com/blog/deep-learning-vs-machine-learning/ (Erişim tarihi: 22.10.2022)

https://jovian.ai/rishabh25126/stock-price-prediction (Erişim tarihi: 22.10.2022)

https://keras.io/api/layers/recurrent_layers/lstm/ (Erişim tarihi: 22.10.2022)

https://levity.ai/blog/difference-machine-learning-deep-learning (Erişim tarihi: 22.10.2022)

https://machinelearningmastery.com/a-gentle-introduction-to-sigmoid-function/ (Erişim tarihi: 22.10.2022)

https://medium.com/analytics-vidhya/understanding-basics-of-deep-learning-by-solving-xor-problem-cb3ff6a18a06 (Erişim tarihi: 22.10.2022)

https://numpy.org/doc/stable/reference/generated/numpy.array.html (Erişim tarihi: 22.10.2022)

https://numpy.org/doc/stable/reference/generated/numpy.reshape.html (Erişim tarihi: 22.10.2022)

https://pandas.pydata.org/docs/reference/api/pandas.DataFrame.html (Erişim tarihi: 22.10.2022)

https://pandas.pydata.org/docs/reference/api/pandas.DataFrame.html (Erişim tarihi: 22.10.2022)

https://pandas-datareader.readthedocs.io/en/latest/remote_data.html (Erişim tarihi: 22.10.2022)

https://scikit-learn.org/stable/modules/generated/sklearn.preprocessing.MinMaxScaler.html (Erişim tarihi: 22.10.2022)

https://scikit-learn.org/stable/modules/neural_networks_supervised.html (Erişim tarihi: 22.10.2022)

https://stanford.edu/~shervine/l/tr/teaching/cs-230/cheatsheet-recurrent-neural-networks (Erişim tarihi: 22.10.2022)

https://towardsdatascience.com/how-neural-networks-solve-the-xor-problem-59763136bdd7 (Erişim tarihi: 22.10.2022)

https://towardsdatascience.com/whats-the-role-of-weights-and-bias-in-a-neural-network-4cf7e9888a0f (Erişim tarihi: 22.10.2022)

https://www.businessinsider.com/personal-finance/what-is-standard-deviation (Erişim tarihi: 26.09.2022)

https://www.forbes.com/advisor/investing/portfolio/ (Erişim tarihi: 16.10.2022)

https://www.geeksforgeeks.org/difference-between-machine-learning-and-deep-learning/ (Erişim tarihi: 22.10.2022)

https://www.investopedia.com/terms/a/alpha.asp (Erişim tarihi: 08.10.2022)

https://www.investopedia.com/terms/d/defensiveinvestmentstrategy.asp (Erişim tarihi: 08.10.2022)

https://www.investopedia.com/terms/p/percentage-change.asp (Erişim tarihi: 24.09.2022)

https://www.investopedia.com/terms/s/stock.asp (Erişim tarihi: 24.09.2022)

https://www.mldawn.com/deriving-the-gradient-descent-rule-part-2/ (Erişim tarihi: 22.10.2022)

https://www.northstarrisk.com/cumulative-return (Erişim tarihi: 26.09.2022)

https://www.rateofreturnexpert.com/arithmetic-return/ (Erişim Tarihi: 18.11.2022)

https://www.techopedia.com/ (Erişim Tarihi: 18.11.2022)

https://www.tensorflow.org/api_docs/python/tf/keras/Sequential (Erişim tarihi: 22.10.2022)

Lakshminarayanan, Sai Krishna, McCrae, John, A Comparative Study of SVM and LSTM Deep Learning Algorithms for Stock Market Prediction, 2019, Sayfa 1-12, https://ceur-ws.org/Vol-2563/aics_41.pdf (Erişim Tarihi: 18.11.2022)

Marling, Hannes, Emanuelsson, Sara, The Markowitz Portfolio Theory, YAYIN, 2012, Sayfa 1-6, https://www.scirp.org/(S(i43dyn45teexjx455qlt3d2q))/reference/ReferencesPapers.aspx?ReferenceID=2527874 (Erişim Tarihi: 18.11.2022)

Mitsel, A. A. , BASICS OF FINANCIAL MATHEMATICS, Mınıstry Of Educatıon And Scıence Of The Russıan Federatıon, 2012, Sayfa 1-145, https://portal.tpu.ru/SHARED/l/LEVCHENKOEA/academic/prof-eb/Uchebnoe_posobie.pdf (Erişim Tarihi: 18.11.2022)

Obthong, Mehtabhorn , Tantisantiwong, Nongnuch, Jeamwatthanachai, Watthanasak, Wills, Gary, 2020, Sayfa 1-9, https://www.scitepress.org/Papers/2020/93407/93407.pdf (Erişim Tarihi: 18.11.2022

EKLER

Oluşturulan model ile 2 Aralık 2022 ve 1 Aralık 2022 tarihleri için BIST 100 hisseler için tahminleme yapılmış 2 Aralık tarihindeki tahmini ve gerçek fiyatlar arasındaki oran ile hata göstergesi oluşturulmuştur. Buna hata oranı 2 puandan düşük olan hisseler filtrelenmiş ve büyükten küçüğe sıralanmıştır ve 5 Aralık tarihi için potansiyel getiriler hesaplanmıştır. Potansiyel getirilere göre pozisyon tavsiyesi verilmiştir sonuçlar günlük analiz tablosunda gösterilmiştir.

Tablo 11 Günlük Fiyat Tahmini

Hisse	2022-12-01 Gerçek Fiyat	2022-12-02 Tahmini Fiyat	2022-12-02 Gerçek Fiyat	2022-12-05 Tahmini Fiyat	Hata Oranı	2022-12-05 Potansiyel Getiri	Pozisyon Tavsiyesi
GWIND	25,04	28,55	25,04	23,32	0,88	-7%	Kısa
KONTR	155,80	175,87	155,80	154,33	0,89	-1%	Kısa
AGHOL	101,00	109,31	101,00	99,24	0,92	-2%	Kısa
ISFIN	8,80	9,46	8,80	9,40	0,93	7%	Uzun
ARCLK	91,10	97,57	91,10	88,73	0,93	-3%	Kısa
TOASO	139,20	148,41	139,20	135,46	0,94	-3%	Kısa
BIMAS	123,00	130,12	123,00	127,82	0,95	4%	Uzun
SKBNK	2,69	2,83	2,69	2,66	0,95	-1%	Kısa
HALKB	9,99	10,45	9,99	9,71	0,96	-3%	Kısa
SAHOL	39,98	41,60	39,98	41,25	0,96	3%	Uzun
ULKER	35,82	37,19	35,82	34,29	0,96	-4%	Kısa
SOKM	23,00	23,78	23,00	23,75	0,97	3%	Uzun
TMSN	70,00	72,11	70,00	65,49	0,97	-6%	Kısa
EREGL	41,42	42,46	41,42	38,23	0,98	-8%	Kısa
OYAKC	19,86	20,32	19,86	19,72	0,98	-1%	Kısa
AKBNK	16,86	17,04	16,86	17,20	0,99	2%	Uzun
VAKBN	9,76	9,80	9,76	9,72	1,00	0%	Kısa
ERBOS	176,30	176,25	176,30	178,72	1,00	1%	Uzun
DOHOL	8,16	8,05	8,16	7,99	1,01	-2%	Kısa
TTKOM	17,46	17,13	17,46	15,92	1,02	-9%	Kısa
EKGYO	7,14	7,00	7,14	6,94	1,02	-3%	Kısa
TCELL	33,04	32,30	33,04	34,59	1,02	5%	Uzun
GARAN	25,86	25,24	25,86	26,69	1,02	3%	Uzun
ENJSA	29,56	28,80	29,56	31,16	1,03	5%	Uzun
ISCTR	10,44	10,10	10,44	9,56	1,03	-8%	Kısa
TUKAS	22,78	21,97	22,78	21,93	1,04	-4%	Kısa
TSKB	4,04	3,88	4,04	3,93	1,04	-3%	Kısa
EGEEN	4779,90	4554,16	4779,90	4541,30	1,05	-5%	Kısa
MAVI	122,00	115,67	122,00	118,45	1,05	-3%	Kısa
IPEKE	37,12	35,13	37,12	35,38	1,06	-5%	Kısa

MGROS	126,10	118,98	126,10	122,56	1,06	-3%	Kısa
ODAS	11,19	10,53	11,19	10,59	1,06	-5%	Kısa
NUGYO	8,11	7,61	8,11	7,57	1,07	-7%	Kısa
AKFGY	5,60	5,22	5,60	5,54	1,07	-1%	Kısa
ALBRK	3,40	3,16	3,40	3,71	1,08	9%	Uzun
QUAGR	62,20	56,92	62,20	58,85	1,09	-5%	Kısa
ISDMR	32,30	29,49	32,30	30,97	1,10	-4%	Kısa
BAGFS	43,56	39,77	43,56	42,73	1,10	-2%	Kısa
ASELS	47,04	42,30	47,04	45,40	1,11	-3%	Kısa
ENKAI	26,06	23,39	26,06	24,13	1,11	-7%	Kısa
KARSN	12,80	11,47	12,80	11,68	1,12	-9%	Kısa
KRDMD	14,76	13,20	14,76	15,02	1,12	2%	Uzun
ISMEN	46,10	41,20	46,10	45,54	1,12	-1%	Kısa
TRGYO	18,56	16,56	18,56	17,66	1,12	-5%	Kısa
BUCIM	6,19	5,51	6,19	5,72	1,12	-8%	Kısa
KCHOL	68,85	60,86	68,85	64,44	1,13	-6%	Kısa
FROTO	441,00	389,79	441,00	421,87	1,13	-4%	Kısa
AYDEM	22,58	19,89	22,58	22,90	1,14	1%	Uzun
DOAS	156,60	135,64	156,60	143,09	1,15	-9%	Kısa
AEFES	64,00	55,31	64,00	63,33	1,16	-1%	Kısa
NTHOL	15,62	13,45	15,62	15,41	1,16	-1%	Kısa
VESBE	13,15	11,31	13,15	11,97	1,16	-9%	Kısa
TKFEN	42,72	36,35	42,72	39,12	1,18	-8%	Kısa
TUPRS	481,10	402,03	481,10	480,24	1,20	0%	Kısa
GOZDE	17,65	14,55	17,65	17,80	1,21	1%	Uzun
CCOLA	193,70	158,78	193,70	192,60	1,22	-1%	Kısa
YKBNK	11,35	9,14	11,35	10,47	1,24	-8%	Kısa
DEVA	57,70	44,51	57,70	54,14	1,30	-6%	Kısa
YYLGD	42,70	32,14	42,70	41,03	1,33	-4%	Kısa

Çalışmada kullanılan grafik tablo ve kaynak kodlara aşağıdaki linkten erişilebilmektedir.

https://drive.google.com/drive/folders/1-AJeF68kJLqeTLmrDFegL2EWnJWMVTkj?usp=share_link