

BIST 30 ENDEKSİ PAYLARININ YAPAY ZEKA YÖNTEMİYLE TAHMİNİ ÜZERİNE BİR ARAŐTIRMA¹

FORECASTING THE BIST 30 INDEX SHARES USING ARTIFICIAL INTELLIGENCE TECHNIQUES

Mehmet Harun SONGÜN ² *Murat AKBALIK* ³

Arařtırma Makalesi / Geliř Tarihi: 06.01.2023
Kabul Tarihi: 31.03.2023

Öz

Bu makalede, 7 Ocak 2022 cuma günü itibarıyla Borsa İstanbul 30 endeksinde işlem gören payların gelecekteki deęerini matematiksel model ve algoritmalarla hesaplamak için denetimli Makine Öğrenimi modeli kullanılmıştır. Gelecekteki fiyat öngörüsünü BIST 30 endeksinde yer alan payların Aralık 2003-Ocak 2022 tarihleri arasındaki günlük açılıř, kapanıř, düşük fiyat, yüksek fiyat ve hacim verileri kullanılarak hesaplanmıştır. Veri seti 2020 yılında bařlayan pandemi dönemini ve 2001 yılında Türkiye’de yařanan ekonomik kriz sonrası dönemi kapsamaktadır. Literatürde yer alan çalıřmalardan kapsam bakımından farklı olarak her biri en az 2915 en çok 4707 işlem gününü kapsayan 30 farklı veri setine iki farklı zaman dilimi fiyat öngörüsü uygulanmıştır. Gelecek dönem fiyat öngörüsünde bulunabilmek için Yapay Zeka, Makine Öğrenimi algoritmalarından olan Karar Ağacı algoritması kullanılmıştır.

Anahtar Kelimeler: Yapay Zeka, Karar Ağacı, Fiyat Öngörüsü, Bist30

JEL Sınıflaması: C45, C53, G17.

Abstract

In this article, supervised Machine Learning model was used to statistically calculate the future value of the shares in the BIST 30 index as of January 2022. The future price forecasting is calculated by using the daily opening, closing, low price, high price and volume data of the stocks in the BIST 30 index. December 2003-January 2022 was used as the daily return range. The data set covers the pandemic period that started in 2020 and the post-economic crisis period in Turkey in 2001. Different from the studies in the literature in terms of scope, two different time frame price predictions were applied to each of 30 different data sets. Data sets covers minimum 2915 and maximum 4707 trading days. Decision Tree algorithm, one of the Artificial Intelligence and Machine Learning algorithms, is used to predict the future price.

Keywords: Artificial Intelligence, Decision Tree, Price Forecast, Bist30

JEL Classification: C45, C53, G17.

¹ **Bibliyografik Bilgi (APA):** FESA Dergisi, 2023; 8(1), 270-286 / DOI: 10.29106/fesa.1230607

² Doktorant Mehmet Harun Songün, Marmara Üniversitesi, Bankacılık ve Sigortacılık Enstitüsü, mhs1978@hotmail.com, İstanbul – Türkiye, ORCID: 0000-0003-2487-8857

³ Prof. Dr. Murat Akbalık, Marmara Üniversitesi, Bankacılık ve Sigortacılık Enstitüsü, Sermaye Piyasası ve Borsa Bölümü, makbalik@marmara.edu.tr, İstanbul – Türkiye, ORCID: 0000-0002-7955-3630

1. Giriş

Borsalar genel olarak rasyonel, irrasyonel ve robot yatırımcılar kitlesinden oluşur. Bu yatırımcılar kar maksimizasyonunu hedefleyen, mantık çerçevesinde hareket eden, manipülatif ve spekülasyon gütüsüyle işlem yapan, asimetrik bilgi etkisiyle işlem yapan, sezgisel ve yargısal tahmin gütüsüyle veya yapay zeka sistemi kullanarak işlem yapan olarak da tanımlanabilirler. Hisse senedi fiyatları bu sebeplerden oluştuğu kabul edilirse, hisse senetlerinin fiyat, hacim ve zaman verileri bütün bu sebepleri kronolojik olarak içinde barındıran bilgi yığını denilebilir. Literatürde yer alan makine öğrenme çalışmaları hisse senedi fiyatlarının belirli bir zaman dilimi sonraki yaklaşık değerini hesaplanabileceğini göstermektedir fakat bu durum hisse senetlerine ait fiyatların daha önceden öngörülebilecek bir yol takip etmediğini, tam olarak tesadüfi olduğunu ve daha önceki zamanlarda fiyat dalgalanma ve değişimlerinden hariç olarak rastgele bir zamanda yukarı ya da aşağı yönde hareket gerçekleştirdiğini ifade eden Rastal Yürüyüş teorisi ve piyasada menkul kıymet fiyatlarının menkul kıymet ile ilgili bütün malumatları yansıttığını ve her zaman gerçeğe yakın değerinden işlem gördüğünü bu sebepten ötürü de yatırımcıların piyasa getirisinin üstünde bir kazanç elde etmesinin mümkün olmadığını ileri süren etkin piyasalar hipotezi ile çelişmektedir. Etkin piyasalar hipotezine göre, hisse senedi fiyatları rastgele bir yürüyüş modelini takip etmeli yani piyasa yaklaşık yüzde 50'den fazla doğrulukla tahmin edilemez olmalıdır. Qian ve Rasheed (2007)

Günümüzün finansal yatırımcıları, yetersiz finansal okur yazarlık yüzünden düzgün bir şekilde temel ve teknik analiz yapamadıklarından ötürü optimum kar elde etmek için “düşükten al, yüksekte sat” sözüne uygun bir şekilde hangi hisse senetlerinin alınacağını veya hangi hisse senetlerinin satılacağını bilememek sorunuyla karşı karşıyadır. İyi bir hisse senedine yatırım yapmak uzun vadeli değerini tahmin etmek kar sağlayabilirken, günlük bazda tahmin yapmak veya kötü bir zamanda vasat bir hisse senedine yatırım yapmak feci sonuçlar doğurabilir. Hisse senetleri finansal, siyasi ve global olaylara bağlı olarak her saat hızla dalgalanmaktadır. Borsanın nasıl davrandığının farkında olmak kar elde etmek için çok fazla önem arz etmektedir. Yapay zeka sistemleri birçok veriyi hızlı bir şekilde aynı anda bütünleşik olarak yorumlayabilmesi ve kar maksimizasyonu bakımından öne çıkmaktadır.

Bu çalışmada, finansal yatırım araçlarından olan ve karlılık potansiyeli ile ön plana çıkan hisse senetlerinin çeşitli matematiksel model ve algoritmaların oluşturduğu çeşitli makine öğrenme teknikleriyle gün öncesi ve beş günlük fiyat tahmini elde etmek ve sonuçların performans değerlendirmesi yapmak hedeflenmiştir. Çalışmada, Borsa İstanbul hisse senedi piyasasında makine öğrenme yöntemlerinin fiyat öngörüsünü doğruluğunu araştırmak için, 07 Ocak 2022 cuma günü itibarıyla BIST 30 endeksinde bulunan otuz hisse senedinin 8 Aralık 2003-07, Ocak 2022 tarihleri arasındaki günlük açılış-kapanış, düşük-yüksek fiyat ve hacim verileri kullanılmaktadır. Gün öncesi ve 5 günlük hisse senedi fiyat öngörüsünde bulunmak için, denetimli makine öğrenimlerinden olan karar ağacı algoritması uygulanmıştır. Literatür taraması sonucu elde edilen bulgular literatürde bahsi geçen uluslararası ve ulusal birçok çalışmanın (Donaldson R. Glen ve Mark Kamstra 1997 Müller K-R, Alexander J Smola, Gunnar Ratsch, Bernhard Schölkopf, Jens Kohlmorgen, Vladimir Vapnik 1997 Fan, Alan, Marimuthu Palaniswami 2001 Chen, Wun-Hua, Jen-Ying Shih ve Sushan Wu 2006 Atsalakis, George S., ve Kimon P. Valavanis 2009 Güdelek M.U. 2019 Gu, Shihao, Bryan T. Kelly, ve Dacheng Xiu 2020) makine öğrenme modellerini az sayıdaki veri setine uyguladıkları görülmektedir. Yaptığımız çalışmada hedeflenen, 30 hisse senedinin 4600 günlük fiyat hareketleri veri setine denetimli makine öğrenme tekniğiyle 2 farklı dönem için hesaplanması ve sonuçların karşılaştırılması sonucu literatürde daha önce örneğine rastlamadığımız şekilde kapsamlı olması bakımından diğer çalışmalardan ayrılmaktadır.

Bu çalışma kendi içinde beş bölüme ayrılmaktadır. Birinci bölüm giriş bölümü, ikinci bölümde yapay zeka ve makine öğrenimini zaman serileri ve hisse senedi verilerine uygulayan uluslararası ve ulusal literatür çalışmaları yer almaktadır. Üçüncü bölümde, çalışmanın veri seti ve metodolojisi açıklanmaktadır. Dördüncü bölümde, BIST 30 hisse senetlerinin rastgele orman algoritmasıyla gün öncesi fiyat öngörüsünü doğruluğu yorumlanmaktadır. Beşinci bölümde ise çalışmanın sonuçları özet olarak yer almaktadır.

2. Literatür Taraması

Yapay sinir ağları (YSA) kullanarak borsa tahminine odaklanan çalışmaların bazıları aşağıda verilmiştir. YSA'lar, biyolojik sinir ağlarına dayanarak hesaplama yapan modellerdir.

Jasic ve Wood (2004), Jasic, T., & Wood, D. (2004). çeşitli küresel borsa verilerini kullanarak günlük borsa endeks getirilerini tahmin etmek için yapay sinir ağı modeli geliştirmişlerdir. Enke ve Thawornwong (2005), çok sayıda finansal ve ekonomik değişkenin korelasyonlarını değerlendirmek ve etkileşimleri hakkında bilgi kazanmak için tahmine dayalı bir makine öğrenimi tekniği kullanılmaktadır. Bir sonraki çalışma, Liao ve Wang, (2010). çok sayıda finansal ve ekonomik değişkenin tahmine dayalı ilişkilerini ortaya çıkarmak için, zaman açısından etkili olan stokastik sinir ağı modelini tanıtmaktadır Chavan ve Patil (2013), yayınlanan dokuz makalede bulunan farklı

model girdi parametrelerini inceleyerek YSA borsa tahmini anlayışımıza katkıda bulunur. Chong, Han ve Park (2017), borsa analizi ve tahmini için derin öğrenme ağlarını analiz ediyor.

Hisse Senedi Piyasalarını Analiz Etmek İçin destek vektör makinelerini (SVM'ler) kullanan çalışmaların bazıları aşağıda verilmiştir. DVM'ler, örnek sınıflandırma yoluyla borsa tahmin doğruluğunu iyileştirmek için YSA'lara alternatif bir yöntem sunar.

Lee (2009), hisse senedi piyasalarının trendini tahmin etmek için hibrit bir özellik seçim yöntemi ile destek vektör makinesine dayalı bir tahmin modeli geliştirmiştir. Schumaker ve Chen (2009), haber makalelerinin hisse senedi fiyatları üzerindeki etkisine bakarak metinsel analizle birlikte bir Destek Vektör Makinesi (SVM) kullandı. Yeh, Huang ve Lee (2011), çekirdek fonksiyon hiperparametreleri ile uğraşırken borsa değerlerini tahmin etmek için destek vektör regresyonunu kullanırken ortaya çıkan sorunları ele alıyor. Das ve Padhy (2012), Hindistan borsasında gelecekteki fiyatları tahmin etmek için iki farklı makine öğrenme tekniği Destek Vektör Makinesi (SVM) ve geri yayılım sinir (BPN) ağı kullanır:

Hisse Senedi Piyasalarını Analiz Etmek İçin Diğer Tekniklerle Genetik Algoritmaların Kullanıldığı çalışmaların bazıları aşağıda verilmiştir

Kim ve Han (2000), bir hisse senedi fiyat endeksinin değerini tahmin etmek için yapay sinir ağları için ayrıklaştırma ve bağlantı ağırlıklarının belirlenmesine yönelik bir genetik algoritma yaklaşımı önermektedir. Kim ve Lee (2004) de önceki çalışmada kullanılan aynı iki makine öğrenme tekniğine dayanmaktadır. Bir GA kullanarak bir özellik dönüştürme yöntemini iki geleneksel YSA yöntemiyle karşılaştırırlar. Kim, Min ve Han (2006), borsa endeks değerlerini tahmin etmek için YSA ve GA kullanarak benzersiz bir hibrit sistem geliştirmiştir. Kim ve Shin (2007),hibrit bir yapay sinir ağı ve genetik algoritma yönteminin borsa tahmini için etkinliğini araştırıyorlar. Yu, Chen, Wang ve Lai (2008)tarafından yapılan bu hibrit GA ve SVM ile ilgili çalışmada, borsa trendlerini keşfetmek için karma bir çekirdeğe sahip gelişen bir en küçük kareler destek vektör makinesi (LSSVM) öğrenme paradigması önerilmiştir. Ou ve Wang (2009) tarafından hazırlanan bu makalede, Hong Kong borsası HangSeng endeksindeki fiyat hareketini tahmin etmek için on farklı veri madenciliği tekniği tartışılmakta ve uygulanmaktadır. Pierdzioch ve Risse (2018),toplu borsa tahminlerinin rasyonelitesine ilişkin bir ortogonalite testi uygulamak için artırılmış regresyon ağaçları (BRT) olarak bilinen bir makine öğrenimi algoritması kullanır. Zhong ve Enke (2019),bir dizi hisse senedinin günlük getiri yönünü tahmin etmek için bir süreç sunar. Derin sinir ağları (DNN'ler) ve geleneksel YSA'lar, gelecekteki borsa endeksi getirilerinin günlük yönünü tahmin etmek için temel bileşen analizi (PCA) aracılığıyla dönüştürülen iki veri kümesiyle birlikte önceden işlenmiş ancak dönüştürülmemiş tüm veri kümesi üzerine dağıtılır.

Tablo 1. Yapay Zeka ile Gelecek Değeri Öngörüsü Üzerine Yapılan Çalışmalar

Yazarlar	Tarihi	Özet Bilgi
Abe, Masaya, ve Hideki Nakayama	2018	Hisse senedi fiyat hareketlerini bir ay önceden tahmin edilebilmesi için DNN öğrenme performansını inceliyorlar
Ahmed, Nesreen K., Amir F. Atiya, Neamat El Gayar, ve Hisham El-Shishiny	2010	Zaman serisi veri örneği kullanarak birçok makine öğrenme yönteminin karşılaştırmalı analizi yapılmıştır
Altay, E., & Satman, H	2005	İMKB üzerine ANN ve doğrusal regresyon analizlerini karşılaştırmıştır. Makine öğrenmesi modeli olan ANN daha iyi başarı göstermiştir
Atsalakis, George S., ve Kimon P. Valavanis	2009	Literatür taraması sonucunda hisse senedi getiri tahmini analizlerinde, makine öğrenme teknikleri ile genel olarak geleneksel modellerden daha iyi performans gösterdiği sonucuna varmışlardır
Aziz, Saqib, ve Michael Dowling	2019	Makine öğrenmesi ve yapay zeka tekniklerinin risk yönetimi alanında kullandığı teknikleri incelemişlerdir
Berutich, José Manuel, Francisco López, Francisco Luna, ve David Quintana	2016	Genetik algoritmaların geleneksel ve alternatif yöntemlerden ıspanya borsasında daha karlı trade sağladığını savunmuşlardır
Bianchi, Daniele, Matthias Büchner, ve Andrea Tamoni	2019	Makine öğrenmesi yöntemlerinden DNN tahvil getirileri üzerine analiz edip klasik regresyon yöntemleriyle karşılaştırdıklarında , DNN in çok daha iyi performans sağladığı sonucuna varmışlardır

Black, Fischer, ve Robert Litterman	1992	Markowitz'in ortalama varyans portföy optimizasyon modelini, Sharpe oranı kullanarak CAPM ve Lintner ile birleştirerek modern portföyün sınırlarını tartışmışlardır
Booth, Ash, EnricoGerding, ve Frank McGroarty	2015	Random Forest modeline dayalı bir zaman serisi tahmin modeli doğrusal regresyon, NN ve SVR ye göre tahmin doğruluğunu %15 artırdığını ortaya koyuyorlar
Branke, Juergen, BenediktScheckenbach, Michael Stein, KalyanmoyDeb, ve HartmutSchmeck	2009	Çok amaçlı Evrimsel algoritma modeli üzerine çalışma yapmışlardır. portföy seçiminde doğrusal ortalama varyansa dayalı portföy optimizasyonu problemi çözdüğünü,ve daha iyi performans sergilediği sonucuna varmışlardır
Chen, A.-S., ve Leung, M	2004	Döviz paritesi tahminlerinde 2 kademeli NN hata düzeltmeli regresyon modelinin yatırımlarda daha yüksek kar getirisi sağladığını savunmuşlardır
Chen, Wun-Hua, Jen-YingShih, ve SoushanWu	2006	Altı Asya hisse senedi borsalarında finansal zaman serilerine ilişkin SVM in performansını incelemiştir
Deniz, O	2005	Analizlerde kullanılacak veriler kesikli verilerden oluşuyorsa tüm optimal koşullar yerine getirildiğinde kullanılabilir en etkin model Poisson regresyon modeli olduğunu savunmaktadır
Donaldson, R. Glen, ve Mark Kamstra	1997	Londra, New York, Tokyo ve Toronto'dan günlük hisse senedi fiyat hareketi verilerini kullanarak hisse senedi getiri oynaklığı ANN-GARCH tahmin modellerinin performansını inceliyorlar
Dondurmacı, G. A., ve Çınar, A	2014	On bankanın hisse senetlerinin kapanış fiyatları, altın ve dolar kurundaki değişimler ve yabancı borsa endeksleri dikkate alınarak sınıflandırmaya tahmin eden karar ağaçları algoritması oluşturulmuştur.
Fan, Alan, ve MarimuthuPalaniswami	2001	Avustralya Menkul Kıymetler Borsası'nda işlem gören pay senetlerini SVM tarafından seçilen eşit ağırlıklı bir hisse senedi portföyü beş yıllık bir dönemde% 208 getiri sağlarken klasik yöntemlerle oluşturulan portföyün % 71 getiri sağladığını savunmuşlardır
Feng, Guan hao, Stefano Giglio, ve DachengXiu	2017	Varlık getirilerini açıklarken ilgili faktörler arasında en çok yakın zamanda ortaya çıkan faktörlerin karlılığı artırdığını ortaya koymuşlardır
Fernandes, Marcelo, Marcelo C. Medeiros, ve Marcel Scharth	2014	VIX serisinin zaman serisi özelliklerini inceleyerek, VIX'in S&P 500 getirileri ile negatif korelasyon içinde olduğunu ancak S&P 500 hacmi ile pozitif bir ilişkisi olduğunu gösteriyor. Bu iki seri doğrusal olmayan bir ilişkiye sahip olduğunu savunuyorlar
Giamouridis, Daniel	2017	Sistemik yatırım araştırmaları hakkında bazı düşünceler sunarken veri bilimi ve makine öğrenimi, faktör yatırımları, pazar zamanlaması ve koordineli yatırımı inceliyor
Gu, Shihao, Bryan T. Kelly, ve DachengXiu	2020	makine öğrenimi tekniklerinin menkul kıymet fiyatını tahmin etmede geleneksel kesit ve zaman serisi modellerinden daha iyi performans gösterebileceğini savunuyorlar.
Güdelek, M. U.	2019	Çeşitli zaman serisi problemleri incelenmiş ve yaklaşımlar anlatılmıştır , finans verileri üzerine derin öğrenme modeli oluşturulmuş, oluşturulan modelin başarıya ulaştığı savunulmuştur
Lopez de Prado, Marcos	2016	Portföy optimizasyonunda Markowitz'in yaklaşımına alternatif makine öğrenme modeli olan HRP yöntemini kullanarak ağaç kovaryans matrisi oluşturup optimal portföye ulaşmaya çalışmışlardır
Müller K-R, Alexander J Smola, GunnarRätsch, Bernhard Schölkopf, JensKohlmorgen, Vladimir Vapnik	1997	Destek vektör makineleri, zaman serisi tahmini için kullanılır ve radyal tabanlı fonksiyon ağırlarıyla karşılaştırılır. Destek Vektörü yaklaşımı, kıyaslamadaki en iyi bilinen sonucu% 29 oranında iyileştirir
Oh, KyongJo, ve Ingoo Han	2000	Faiz oranlarıyla para politikası arasındaki değişim noktasını BPN makine öğrenme yöntemiyle anamlandıran ve faiz oranını tahmin eden tekniği istatistiksel olarak incelemiştir

Rasekhschaffe, KeywanChristian, and Robert C. Jones	2019	Hisse senedi getirilerinin tahmin etmek için makine öğrenmesi kullanırken aşırı uyum sorununun üstesinden gelmenin yolunun farklı makine öğrenme yöntemlerin farklı veri setleriyle oluşturulacak bir tahmin olduğunu savunurlar
Rapach, David E., Jack K. Strauss, Jun Tu, andGuofu Zhou	2019	30 sektör için gecikmeli endüstri getirilerini hesaplamak için LASSO regresyonunu kullanırlar. LASSO tarafından seçilen değişkenler daha sonra LASSO modelinden önyargı etkisini azaltmak için en küçük kareler modeli kullanılarak, tahmin edilen katsayılarda aşağı doğru sıralanmışlardır
Sabharwal, Chaman L	2018	Makine öğrenmesinin mevcut kullanımını ve finans sektöründeki gelecekteki rolünü tartışıyor ve önemini ABD deki büyük bankaların makine öğrenme destekli Robo-danışmanlar örnek göstererek desteklerken , yapay zekanın daha en büyük etkisinin gerçekleşmediğini savunuyor
Şıklar, E	2009	Regresyon analizi için parametre seçimi yapılırken Bayes teoreminin nasıl kullanılacağı gösterilmiştir. Basit ve çoklu bayesci doğrusal regresyon modeli teorik olarak açıklanılmıştır.
Skolpadungket, Prisdarng, KeshavDahal, ve NapatHarnpornchai	2016	Klasik Markowitz (ortalama varyans) portföy optimizasyon modeli, varlık getirilerinin normal olarak dağıtıldığını varsayar. Gerçekte, varlık getirilerinin araçları ve oynaklıkları değişme eğilimindedir, bu da bu değişkenlerin optimal bir portföy oluşturmak için tahmin edilmesini gerektirir. Yazarlar, tahmin modellerinin doğasında var olan yanlışlığı hesaba katmak için çok amaçlı bir genetik algoritma kullanarak portföy optimizasyonu sorununa bir çözüm sunar. Portföy optimizasyon görevine ek bir amaç olarak varlık portföyünün Sharpe oranı hatasının bir yaklaşımı eklendiğinde bu model riski azaltılabilir
Tan, Pang-Ning, Michael Steinbach, AnujKarpatne, ve Vipin Kumar	2018	Farklı makine öğrenme kümeleme teknikleri (örneğin, K-means, hiyerarşik kümeleme) sunar ve çeşitli kümeleme yöntemlerinin güçlü ve zayıf yönlerini karşılaştırılıyor
Tunçel, A. K.	2007	Koşu Testi uygulayarak Türkiye deki hisse senedi piyasalarının zayıf türde etkinliği test edilmiştir. Çalışmada İMKB 100 endeksinde işlem gören pay senetlerinin 2005 yılı 12 aylık dönemine ait günlük iki seans kapanış fiyatları kullanılarak, ardışık fiyat hareketlerinin birbirinden bağımsız olup olmadığı sınanmıştır.
Zimmermann, Hans Georg, Ralph Neuneier, and Ralph Grothmann.	2002	Yüksek getiri sağlayabilmek için Black – Litterman portföy optimizasyon modelini yapay sinir ağlarıyla birlikte çalışmasını sağlıyor. Beklenen getiri tahminleri, Çalışma prensibi Kendisinden önceki modelin hatasını kullanarak hata düzelten yapay sinir ağları oluşturulmuştur. YSA ile oluşturulan portföyün , kıyaslama portföyüyle karşılaştırıldığında daha iyi performans göstermiştir

Hisse senedi fiyatlarının tahmini, son derecede karmaşık bir problemdir ve birçok disiplinde araştırmacılar tarafından incelenmiştir. Politik olaylar, ekonomik koşullar ve tacirlerin beklentileri, borsa hareketini etkileyebilecek faktörlerden sadece birkaçıdır ve doğru tahminleri hem de yatırımcılar hem de araştırmacılar için önemli bir zorluk haline getirir. bu zorlukların üstesinden geldiğini savunan son beş yılda yapay zeka hisse senedi alım satımı üzerine yürütülen en çok alıntı yapılan çalışmalardan bazıları şunlardır:

2018 tarihli " Google Trends ile optimize edilmiş sinir ağlarını kullanarak borsaların yönünü tahmin etme" adlı makalede araştırmacılar, S&P 500 ve Dow Jones Endüstriyel Ortalama Endeksleri için açılış hisse senedi fiyatlarının yönünü tahmin etmede kullanılan geri yayılma sinir ağlarının (BPNN) ağırlıklarını ve temelini optimize etmek için geliştirilmiş bir sinüs kosinüs algoritması (ISCA) tanıttı. ISCA, sinüs kosinüs algoritmasının (SCA) bir uzantısıdır ve BPNN'yi daha da optimize etmek için eklenen ek bir parametre ile birlikte gelir.

ISCA, hisse senedi tahminini iyileştirmek için Google Trends verilerini dikkate alan ISCA-BPNN adlı yeni bir ağ oluşturmak için BPNN ile birleştirilir. Araştırmacılar iki farklı yöntemle tahmini analiz ediyor: I ci yöntem Google Trendler olmadan tahmin, II yöntem ise Google Trendler ile tahmin.

Araştırmacılar, hibrit ISCA-BPNN modelini kullanarak hisse senedi fiyat yönünün tahmin edilebilirliğini değerlendirdiler. Deneysel sonuçlar, ISCA-BPNN'nin açılış fiyatının yönünü her iki yöntem için ve özellikle II ci yöntem için önemli ölçüde tahmin etme açısından BPNN, GWO-BPNN, PSO-BPNN, WOA-BPNN ve SCA-

BPNN dahil diğer modellerden daha iyi performans gösterdiğini gösterdi. Google Trendler ile ISCA-BPNN isabetli fiyat tahmini oranları S&P 500 Endeksi için %86,81'e ve Dow Jones Endüstriyel Ortalama Endeksi için %88,98'e ulaştı. Hu, H., Tang, L., Zhang, S., & Wang, H. (2018).

Genel olarak, çalışma, Google Trends'in borsa endeksinin yönünü tahmin etmede yararlı bir araç olabileceğini buldu. Bu bulguların, portföyleri hakkında bilinçli kararlar almak isteyen yatırımcılar için önemli etkileri olabilir. Bununla birlikte, borsanın karmaşıklığının doğru tahminlerin asla garanti edilemeyeceği anlamına geldiğini ve yatırımcıların herhangi bir tahmine sağlıklı dozda şüphecilikle yaklaşmaları gerektiğini belirtmekte fayda var. Bununla birlikte, bu çalışma, gelişmiş algoritmaların borsa analizi alanına önemli katkılar yapma potansiyeline ilişkin yerinde bir bakış açısı sunmaktadır.

Büyük veri analitiği ve makine öğrenimi algoritmalarının kullanımı, borsa yatırımı da dahil olmak üzere çeşitli alanlarda giderek daha popüler hale geliyor. Ancak, derin sinir ağları (DNN'ler) gibi güçlü makine öğrenimi teknikleri kullanarak günlük borsa getirilerini tahmin etmeye odaklanan sınırlı sayıda araştırma vardır.

2019 tarihli "Hibrit makine öğrenimi algoritmaları kullanarak borsanın günlük getiri yönünü tahmin etme" adlı çalışma, 60 finansal ve ekonomik özelliğe dayalı olarak SPDR S&P 500 ETF'nin günlük getiri yönünü tahmin etmek için kapsamlı bir büyük veri analitiği süreci sunarak bu boşluğu gidermeyi amaçlamaktadır. Çalışma özellikle, dönüştürülmemiş tüm veri kümesine veya PCA kullanılarak dönüştürülmüş iki veri kümesine uygulandığında DNN'lerin ve geleneksel YSA'ların performansını araştırıyor.

Bu çalışmanın bulguları, DNN'lerdeki gizli katman sayısı 12'den 1000'e çıktıkça, aşırı uyum kontrol edilirken sınıflandırma doğruluğunun kademeli olarak arttığını ortaya koymaktadır. Ayrıca, PCA tarafından temsil edilen veri kümelerine uygulanan DNN'ler, tüm dönüştürülmemiş veri kümesini ve diğer hibrit makine öğrenimi algoritmalarını kullananlardan önemli ölçüde daha yüksek sınıflandırma doğruluğu elde eder.

Buna ek olarak, çalışma, DNN sınıflandırma sürecinin yönlendirdiği Al-Sat stratejilerini iki standart kriterle karşılaştırarak değerlendiriyor. Sonuçlar, PCA tarafından temsil edilen veri tabanlı stratejilerin biraz daha iyi performans gösterdiğini göstermektedir. Zhong, X., & Enke, D. (2019).

Genel olarak, bu çalışma borsa tahmininde büyük veri analitiğinin ve DNN'lerin potansiyelini gösteriyor ve model performansını artırmada PCA gibi özellik dönüştürme tekniklerinin önemini vurguluyor.

"Sürekli ve ikili veriler aracılığıyla makine öğrenimi ve derin öğrenme algoritmalarını kullanarak borsa trendlerini tahmin etme; karşılaştırmalı bir analiz" adlı 2020 yılında yapılan çalışma, makine öğrenimi ve derin öğrenme algoritmaları kullanarak borsa trendlerini tahmin etme riskini azaltmayı amaçlıyor. Yazarlar, deneysel değerlendirmeleri için Tahran borsasından çeşitlendirilmiş finansallar, petrol, metalik olmayan mineraller ve temel metaller olmak üzere dört borsa grubu seçtiler.

Dokuz makine öğrenimi modeli (Karar Ağacı, Rastgele Orman, Uyarlanabilir Güçlendirme (Adaboost), Aşırı Degrade Artırma (XGBoost), Destek Vektörü Sınıflandırıcısı (SVC), Naïve Bayes, K-En Yakın Komşular (KNN), Lojistik Regresyon ve Yapay Sinir Ağı (ANN)) ve iki güçlü derin öğrenme yöntemi (Tekrarlayan Sinir Ağı (RNN) ve Uzun-Kısa süreli hafıza (LSTM)) bu çalışmada karşılaştırılmıştır.

Girdi değerleri, iki farklı yaklaşım olarak kullanılan on yıllık geçmiş verilere ait on teknik göstergedir. İlk yaklaşım, göstergelerin sürekli veri olarak hisse senedi alım satım değerlerine göre hesaplanmasını içerirken, ikinci yaklaşım, göstergeleri kullanmadan önce ikili(binary) verilere dönüştürmeyi içeriyordu. Her tahmin modeli, girdi yollarına dayalı olarak üç ölçümle değerlendirildi.

Değerlendirme sonuçları, sürekli veriler için RNN ve LSTM'nin diğer tahmin modellerinden önemli bir farkla daha iyi performans gösterdiğini göstermektedir. Ayrıca sonuçlar, ikili veri değerlendirmesi için derin öğrenme yöntemlerinin en iyisi olduğunu, ancak ikinci yöntemde modellerin performansının gözle görülür şekilde iyileştirilmesi nedeniyle farkın azaldığını gösteriyor.

2021 yılında yayınlanan "Derin öğrenme ve makine öğrenimi kullanarak getiri tahmini ile portföy optimizasyonu" adlı çalışma, makine öğrenimi ve derin öğrenme modellerini kullanarak getiri tahminini entegre ederek orijinal portföy optimizasyon modelinin performansını artırmaya odaklanmaktadır. Geleneksel zaman serisi modelleri, geçmişte portföy optimizasyon modellerine entegre edilmiştir, ancak performansları, makine öğrenimi ve derin öğrenme modellerinin ezici üstünlüğü tarafından geride bırakılmıştır. Bu nedenle, bu çalışma beş farklı tahmin modeli ile getiri tahmininin portföy oluşumuna entegrasyonunu araştırmaktadır: Rastgele Orman (RF), Destek Vektörü Regresyonu (SVR), Uzun Kısa Süreli Bellek (LSTM) sinir ağı, Derin Çok Katmanlı Perceptron (DMLP), ve Konvolüsyonel Sinir Ağı (CNN).

Bu çalışmanın ilk adımı, portföy oluşumundan önce hisse senedi ön seçimi için bu tahmin modellerinin uygulanmasını içermektedir. Daha sonra, tahmini sonuçlar ilerleyen ortalama varyans (MV) ve Omega olarak bilinen iki farklı portföy optimizasyon modeline dahil edilir. Bu çalışmada, Otoregresif Entegre Hareketli

Ortalama (ARIMA) getiri tahminine sahip portföy modellerini değerlendirme amacıyla kıyaslama yöntemi olarak kullanılmıştır.

Portföy optimizasyon modellerinin değerlendirilmesinde Çin menkul kıymetler 100 endeksini oluşturan hisselerin 2007'den 2015'e kadar olan dokuz yıllık tarihsel verileri kullanılmıştır. Deneysel sonuçlar, RF geri dönüş tahmini olan MV ve Omega modellerinin yani RF+MVF ve RF+OF'nin diğer modellerden daha iyi performans gösterdiğini göstermektedir. Ayrıca, RF+MVF modeli, RF+OF modelinden üstündür. Bununla birlikte, her iki model de, özellikle RF+OF ve RF+MVF için toplam getirilerinin neredeyse yarısını aşındırabilen yüksek işlem ücreti oranlarına sahiptir. Bu nedenle çalışma, yatırımcılara yüksek komisyon oranlarından kaynaklanan işlem ücretini düşmelerini önermektedir. Ma, Y., Han, R., & Wang, W. (2021).

Sonuç olarak, işlem ücreti düştükten sonra, deneysel sonuçlar, RF+MVF'nin hala MVF modelleri arasında en iyi performansı gösterdiğini ve SVR tahminli (SVR+OF) Omega modelinin OF modelleri arasında en iyi performansı gösterdiğini göstermektedir. Ayrıca çalışma, RF+MVF'nin SVR+OF'den daha iyi performans gösterdiğini gösteriyor. Sonuç olarak, bu çalışma yatırımcılara günlük alım satım yatırımları için RF getiri tahmini ile MVF oluşturmalarını önermektedir.

" Teknik göstergeler kullanarak hisse senedi alım satımı için evrişimli sinir ağı" başlıklı makale, teknik göstergeler ve evrişimli sinir ağı (CNN) mimarisinin bir kombinasyonunu kullanarak hisse senedi fiyatlarını tahmin etmeye yönelik yeni bir yaklaşım sunuyor. Yazarlar, yavaş yakınsama ve aşırı uyum gibi geleneksel tahmin modellerinin sınırlamalarının üstesinden gelmek için derin öğrenme modellerinin potansiyelinden yararlanıyor.

Önerilen model, geçmiş stok verilerinden çıkarılan on teknik göstergelyi kullanır ve bunları Gramian Angular Field (GAF) kullanarak bir görüntüye dönüştürür. Ortaya çıkan görüntüler daha sonra, görüntülerdeki kalıpları öğrenen ve gelecekteki hisse senedi fiyatlarını tahmin eden bir CNN modeline beslenir. Yazarlar, modellerinin performansını Ocak 2009'dan Aralık 2018'e kadar NASDAQ ve NYSE verileri üzerinde test ediyor ve karşılaştırma için düşünülen diğer modellerle karşılaştırıldığında üstün tahmin doğruluğu bildiriyor. Chandar, S. K. (2022).

Bu makale, hisse senedi alım satımında derin öğrenme modellerinin potansiyelini sergileyerek finansal tahmin alanına önemli bir katkıyı temsil etmektedir. Önerilen model, doğru ve zamanında hisse senedi fiyatı tahminlerine dayalı bilinçli kararlar almak isteyen tacirler ve yatırımcılar için özellikle yararlı olabilir. Teknik göstergelerin ve GAF'nin bunları CNN modeline aktarmadan önce görüntülere dönüştürmek için kullanılması, daha fazla araştırmayı garanti eden yenilikçi bir yaklaşımdır.

Genel olarak, bu makale, net hedefleri ve metodolojisi olan titiz ve iyi yürütülen bir çalışma sunmaktadır. Yazarların bulgularının finans sektörü için önemli etkileri olabilir ve borsa tahmini için derin öğrenme alanında daha fazla araştırmaya ilham verebilir.

3. Veri Seti ve Metodoloji

Bu çalışmada, 7 Ocak 2022cuma günü itibariyle Borsa İstanbul BIST 30 endeksinde işlem gören otuz hisse senedinin08.12.2003-31.01.2022 yılları arasındaki onsekiz yıllık dönemine ait günlük açılış, kapanış, gün içerisi en yüksek fiyat, gün içerisi en düşük fiyat ve hacim bilgileri kullanılmaktadır. Veriler, Borsa İstanbul lisanslı veri sağlayıcısı olan Matriks terminalinden elde edilmiştir. Tablo 2'de BIST 30 da faaliyet gösteren şirketlerin sektörleri, makine öğrenmesi çalışma veri setindeki analiz edilen gün sayısı ve veri setlerinin başlangıç tarihi verilmektedir. BIST 30 işlem gören hisse senetlerinin bankacılık, dayanıklı tüketim, iletişim cihazları, perakende, gayrimenkul yatırım ort., demir çelik temel, otomotiv, tarım kimyasalları, holding, madencilik, petrol ve petrol ürünleri, hava yolları ve hizmetleri, endüstriyel tekstil ve cam olmak üzere 15 farklı sektörde faaliyet göstermektedir. Analiz edilen hisse senetlerinden bazıları2004 yılından sonra BIST 30'da işlem görmeye başlamıştır. Bu hisse senetleri için analize başlangıç tarihi 2003 ten farklı olarak işlem gördükleri ilk pazartesidir. Örneğin EKGYO için analize başlama tarihi, bu hisse senedinin borsada ilk işlem gördüğü pazartesi olan 06.12.2010'dur. Analize başlangıç tarihi olarak 08.12.2003 seçilmesinin sebebi hacim bilgisinin ilk o tarihte erişime açık olmasıdır.

Tablo 2. BIST 30 Hisselerine ve Analize İlişkin Bilgiler

Hisse Kodu	Sektör	Veri seti Başlangıç Tarihi	Veri Seti Gün Sayısı
AKBNK	BANKACILIK	08/12/2003	4684
ARCLK	DAYANIKLI TÜKETİM	08/12/2003	4684
ASLSN	İLETİŞİM CİHAZLARI	08/12/2003	4673

BIMAS	PERAKENDE	18/07/2005	4280
EKGYO	GAYRİMENKUL YATIRIM ORTAKLIĞI	06/12/2010	2915
EREGL	DEMİR, ÇELİK TEMEL	08/12/2003	4681
FROTO	OTOMOTİV	08/12/2003	4684
GARAN	BANKACILIK	08/12/2003	4684
GUBRF	TARIM KİMYASALLARI	08/12/2003	4684
HALKB	BANKACILIK	14/05/2007	3815
HEKTS	TARIM KİMYASALLARI	15/12/2003	4679
ISCTR	BANKACILIK	08/12/2003	4684
KCHOL	HOLDİNG	08/12/2003	4676
KOZAA	MADENCİLİK	09/12/2003	4682
KOZAL	MADENCİLİK	15/02/2010	3128
KRDMD	DEMİR, ÇELİK TEMEL	08/12/2003	4685
PETKM	PETROL VE PETROL ÜRÜNLERİ	08/12/2003	4675
PGSUS	HAVA YOLLARI VE HİZMETLERİ	06/05/2013	2316
SAHOL	HOLDİNG	08/12/2003	4684
SASA	ENDÜSTRİYEL TEKSTİL	08/12/2003	4684
SISE	CAM	08/12/2003	4684
TAVHL	HAVA YOLLARI VE HİZMETLERİ	05/03/2007	3870
TCELL	İLETİŞİM	08/12/2003	4679
THYAO	HAVA YOLLARI VE HİZMETLERİ	08/05/2003	4707
TKFEN	HOLDİNG	23/11/2007	3686
TOASO	OTOMOTİV	08/12/2003	4684
TTKOM	İLETİŞİM	26/05/2008	3560
TUPRS	PETROL VE PETROL ÜRÜNLERİ	08/12/2003	4676
VESTL	DAYANIKLI TÜKETİM	08/12/2003	4684
YKBNK	BANKACILIK	08/12/2003	4679

Tablo 3. BIST 30 Sektörel dağılım

Sektör Adı	Toplam Şirket Adedi
BANKACILIK	5
HAVAYOLLARI VE HİZMETLERİ	3
HOLDİNG	3
DAYANIKLI TÜKETİM	2
DEMİR ÇELİK TEMEL	2
İLETİŞİM	2
MADENCİLİK	2
OTOMOTİV	2
PETROL VE PETROL ÜRÜNLERİ	2
TARIM KİMYASALLARI	2
CAM	1

ENDÜSTRİYEL TEKSTİL	1
GAYRİMENKUL YATIRIM ORTAKLIĞI	1
İLETİŞİM CİHAZLARI	1
PERAKENDE	1


Bu çalışmada, Karar Ağacı olarak bilinen istatistiksel bir makine öğrenme yöntemini kullanılmaktadır. Karar ağaçları, regresyon ağaçları ve sınıflandırma ağaçları bağlamında ikiye ayrılabilen denetimli bir öğrenme tekniğidir. Verilere karşılık gelen yanıt tahmin etmek için; kök (başlangıç) noktasından dallara ayrılarak, yaprak ucuna kadar öğrendiği kuralları uygulayarak ağaçtaki kararları izler. Yaprak tahmin edilen yanıtı içerir. Bir yanıtta her adım, bir değişken değerinin kontrol edilmesini içerir. Regresyon ağaçları, sayısal bir alanın gelecekteki değerlerini tahmin ederek sayısal yanıtlar verirken sınıflandırma ağaçları, 'evet' veya 'hayır' gibi nominal yanıtlar verir. Karar Ağacı denetimli makine öğrenme yöntemini kullanmak için Rapidminer Studio paket programı kullanılmaktadır.

Regresyon Ağacı oluşturma ve tahmin yapma için temel buluşsal yöntem şu şekildedir; Karar Ağaçları modelleri, özellik uzayını eksen paralel bölmeleriyle bölünmüş bir dizi basit dikdörtgen bölgeye bölme mantığıyla çalışır. Yukarıdaki örnekte olduğu gibi beş ayrı bölgeye sahip bir Karar Ağacı, etki alanının eksene paralel bölmeler kullanılarak özellik uzayının alt kümesini tamamen kaplayan ve örtüşmeyen karşılıklı olarak farklı bölgelere bölünmektedir. Yani etki alanının her bölümü, özellik eksenlerinden biriyle hizalanır ve belirli bir bölüme düşen herhangi bir yeni gözlem, bölümlerle birlikte tüm eğitim gözlemlerinin ortalaması tarafından verilen tahmini cevaba sahiptir.

Belirli bir gözlemden bir tahmin elde etmek için, yeni gözlemin ait olduğu bölüm içindeki eğitim gözlemlerinin yanıtlarının ortalaması veya modu kullanılır. Eksene paralel bölme kavramı, doğrudan ikiden büyük boyutlara genelleşir. Uzayın her alt kümesi, boyutun her özellik uzayı için her biri o boyuta denk gelen öğeleri listeleyen bölgelere bölünür. Karar Ağaçları bölünürken bilgi kaybetmektedirler ve verilerdeki küçük değişiklikler karar ağacının yapısında büyük bir değişikliğe neden olabilirler ve bu da kullanılan verilerin doğruluğunun önemini arttırmaktadır.

İki özellik değişkeni (x_1, x_2) ve sayısal yanıtı olan bir regresyon probleminin soyut örneğini ve önceden yetiştirilmiş bir ağacı aşağıdaki şekillerde görebiliriz. Bu, ağacın gerçekleştirdiği bölümlenimin doğasını görselleştirmemizi sağlayacaktır.

Şekil 1. Basit bir Regresyon Ağacı Oluşturma ve Tahmin Yapma.



Karar Ağaçları modelleri, uyarlamalı temel işlev modelleri olarak bilinen daha genel bir makine öğrenimi alanına örnektir. Bu modeller, diğer bazı temel genişletmelerde olduğu gibi özellikleri önceden belirtilmek yerine, doğrudan verilerden öğrenir. Bununla birlikte doğrusal regresyondan farklı olarak, bu modeller parametrelerde doğrusal değildir ve bu nedenle parametreler için yalnızca yerel olarak optimal bir maksimum olasılık tahmini hesaplayabiliriz.

Olasılığa dayalı uyarlamalı temel işlev belirtimi altında, $f(x)$ modeli aşağıdaki şekilde verilir:

$$f(x) = E[y|x] = \sum_{m=1}^M W_m I(X \in R_m) = \sum_{m=1}^M W_m \phi(X; V_m)$$

W_m belirli bir bölgedeki ortalama yanıt olduğunda, R_m ve V_m her bir değişkenin belirli bir eşik değerinde nasıl bölündüğünü temsil eder. Bu bölmeler, R^p 'deki özellik uzayının M'ye nasıl 'hiperblok' bölgelerini ayırdığını tanımlar. Murphy, KP (2012)

Bu çalışmada, yapay zeka tekniğiyle analiz edilen hisse senedi verileri ve tahmin verileri arasındaki aynı zaman dilimine denk gelen gerçek tahmin hatalarının karşılaştırmak ve modelin performansı hakkında bilgi edinmek için dört farklı istatistiksel yöntem kullanılmıştır. Tablodaki sırasıyla verecek olursak Kök Ortalama Kare Hatası (RMSE-RootMeanSquareError) Mutlak Hata (AE-AbsoluteError)Ortalama Göreli Esnek hata(RLE-RelativeError)Ortalama Hatanın Karesi (SE- SquaredError). Bunlara ek olarak sonuçla hesaplamada kullanılan veriler arasındaki korelasyonda verilmiştir.

Kök Ortalama Kare Hata (RMSE): Tahmin hatalarının standart sapmasıdır. Artıklar diğer bir deyişle tahmin hataları, veri noktalarının regresyon çizgisine ne kadar uzak olduğunun bir ölçüsüdür; RMSE, bu konular arasındaki farkın ölçüsüdür. Yani verilerin en uygun çizgi etrafında ne kadar yoğunlaştığını size söyler. Kök ortalama kare hatası, deneysel sonuçları doğrulamak için regresyon analizinde yaygın olarak kullanılmaktadır.

Mutlak Hata (AE):Tahminin gerçek değerden ortalama mutlak sapmasıdır.

Ortalama Esnek Göreli Hata (REL): Tahminin gerçek değerden mutlak sapmasının, gerçek değerinin ve tahmininin maksimumuna bölünmesinin ortalamasıdır. Yüzde olarak verilmektedir

Hatanın Karesi (SE):Bir veri kümesindeki her örnek için hesaplanan tahmin ile gerçek arasındaki farkın karesinin alındığı satır düzeyinde bir hata hesaplamasıdır. MSE, tüm veri kümesindeki model performansını anlamamıza yardımcı olan bu hataların toplu ortalamasıdır. L2 kaybı olarak da bilinir

4. Bulgular

Tablo 4. BIST 30 Paylarının Gün Ertesi Tahmin Analizine İlişkin Bilgiler

Hisse Kodu	RMSE	AE	REL	SE	Korelasyon
AKBNK	0.132	0.096	2.06%	0.017	0.997
ARCLK	0.483	0.228	1.90%	0.240	0.999
ASLSN	0.225	0.096	1.91%	0.052	0.999
BIMAS	0.642	0.350	1.74%	0.413	1.000
EKGYO	0.048	0.035	1.79%	0.002	0.993
EREGL	0.201	0.074	1.92%	0.041	0.999
FROTO	2.607	0.890	2.08%	6.950	0.999
GARAN	0.175	0.120	2.12%	0.031	0.998
GUBRF	0.857	0.265	2.39%	0.741	0.999
HALKB	0.249	0.176	2.02%	0.062	0.998
HEKTS	0.194	0.045	2.23%	0.042	0.999
ISCTR	0.050	0.094	1.92%	0.002	0.998
KCHOL	0.325	0.170	1.86%	0.109	0.999
KOZAA	0.260	0.123	2.70%	0.068	0.999
KOZAL	1.161	0.960	2.47%	2.621	0.999
KRDMD	0.111	0.044	2.28%	0.013	0.999
PETKM	0.081	0.096	1.81%	0.007	0.999
PGSUS	2.060	1.198	2.49%	4.346	0.998
SAHOL	0.176	0.114	1.86%	0.031	0.998
SASA	0.348	0.082	2.31%	0.132	0.999
SISE	0.140	0.056	1.89%	0.020	0.999
TAVHL	0.511	0.286	2.14%	0.266	0.998
TCELL	0.208	0.135	1.89%	0.044	0.999

THYAO	0.408	0.175	2.07%	0.168	0.999
TKFEN	0.310	0.177	2.02%	0.098	0.999
TOASO	0.676	0.261	2.15%	0.462	0.999
TTKOM	0.122	0.081	1.79%	0.015	0.997
TUPRS	2.111	0.972	1.88%	4.533	0.999
VESTL	0.266	0.128	2.10%	0.072	0.999
YKBNK	0.058	0.040	1.98%	0.003	0.997

Kök Ortalama Kare Hatası (RMSE-RootMeanSquareError) Mutlak Hata (AE-AbsoluteError) Hatanın Karesi (SE-SquaredError) görelî hataya dayalı olan kriterlerdir. Dođan, İ., & Dođan, N. (2020) Bu, hata kareler toplamına dayanan standart istatistiksel metrik kriterleri çođunlukla ortalama deđişkenlik, ortalama hata ve ortalama sapma gibi belirsiz göstergeler olarak da kabul edilirler. Bu standart istatistiksel metrik kriterleri istenmeyen aynı zamanda çok az bilinen özelliklerinden ötürü, hatalı yorumlanma ve hatalı kullanılma problemlerine yol açabilir. Kareler toplamına dayalı bir standart istatistiksel metrik kriterin ortalama deđişkenliđi, ortalama sapmayı veya ortalama hatayı güven verecek bir şekilde yansıtabileceđi açık ve kesin olmayan bir şekilde var olduđu kabul edildiđinden ötürü sıkıntı ve güçlükler ortaya çıkabilir. Bu standart istatistiksel metrik kriterleri deđerlerinin güvenilir bir yorumu yoktur, çünkü kareler toplamına dayalı standart istatistiksel metrik kriterleri, merkezi eđilim ve hata deđişkenliđi yanı sıra sapma büyüklüğüne göre deđişiklik göstermektedir. Willmott CJ, Matsuura K, Robeson SM.(2009) Bu bilgiler çerçevesinde bu çalışmada ana performans kriteri olarak Ortalama Esnek Görelî Hata (REL) kabul edilmiştir.

Tablo 5. BIST 30 Paylarının Sektörsel Bazda Gün Ertesi Performansı

Sektör Adı	REL
PERAKENDE	1,74%
GAYRİMENKUL YATIRIM ORTAKLIđI	1,79%
İLETİŞİM	1,84%
PETROL VE PETROL ÜRÜNLERİ	1,85%
CAM	1,89%
İLETİŞİM CİHAZLARI	1,91%
HOLDİNG	1,91%
DAYANIKLI TÜKETİM	2,00%
BANKACILIK	2,02%
DEMİR ÇELİK TEMEL	2,10%
OTOMOTİV	2,12%
HAVA YOLLARI VE HİZMETLERİ	2,23%
ENDÜSTRİYEL TEKSTİL	2,31%
TARIM KİMYASALLARI	2,31%
MADENCİLİK	2,59%

Gün ertesi en iy fiyat öngörüsü 1,74% lük hata oranıyla BİMAS hisse koduna aittir, en kötü performans 2,70% lik hata oranıyla KOZAA hisse koduna aittir.

Tablo 6. BIST 30 Paylarının Beş Günlük Tahmin Analizine İlişkin Bilgiler

Hisse Kodu	RMSE	AE	REL	SE	Korelasyon
AKBNK	0.246	0.176	3.59%	0.061	0.991
ARCLK	0.462	0.209	1.83%	0.198	0.999
ASLSN	0.225	0.093	1.96%	0.052	0.999
BİMAS	0.730	0.379	1.69%	0.539	0.999

EKGYO	0.092	0.064	3.15%	0.008	0.974
EREGL	0.236	0.079	2.10%	0.057	0.999
FROTO	2.389	0.814	2.17%	5.795	0.999
GARAN	0.310	0.207	3.53%	0.096	0.995
GUBRF	0.794	0.254	2.50%	0.660	0.999
HALKB	0.522	0.380	4.29%	0.273	0.989
HEKTS	0.217	0.046	1.79%	0.049	0.999
ISCTR	0.096	0.067	3.75%	0.009	0.993
KCHOL	0.494	0.260	3.02%	0.247	0.998
KOZAA	0.331	0.143	2.98%	0.112	0.998
KOZAL	2.660	1.451	3.77%	7.149	0.997
KRDMD	0.120	0.046	2.48%	0.014	0.999
PETKM	0.114	0.052	2.81%	0.014	0.998
PGSUS	3.399	1.889	4.15%	11.785	0.994
SAHOL	0.321	0.223	3.66%	0.104	0.995
SASA	0.316	0.072	2.11%	0.123	0.999
SISE	0.176	0.073	2.74%	0.031	0.999
TAVHL	0.487	0.279	2.13%	0.238	0.999
TCELL	0.303	0.189	1.89%	0.092	0.997
THYAO	0.410	0.172	2.49%	0.172	0.999
TKFEN	0.470	0.269	3.30%	0.229	0.997
TOASO	0.544	0.225	2.11%	0.299	0.999
TTKOM	0.204	0.131	2.66%	0.042	0.992
TUPRS	1.884	0.884	1.83%	3.583	0.999
VESTL	0.301	0.128	2.12%	0.096	0.999
YKBNK	0.101	0.067	3.19%	0.010	0.992

Beş günlük en iyi fiyat öngörüsü 1,69% luk hata oranıyla BIMAS hisse koduna aittir, en kötü performans 4,29% luk hata oranıyla HALKB hisse koduna aittir.

Tablo 7.BIST 30 Paylarının Sektörel Bazda Beş Günlük Performansı

Sektör Adı	REL
PERAKENDE	1,69%
İLETİŞİM CİHAZLARI	1,96%
DAYANIKLI TÜKETİM	1,98%
ENDÜSTRİYEL TEKSTİL	2,11%
OTOMOTİV	2,14%
TARIM KİMYASALLARI	2,15%
İLETİŞİM	2,28%
DEMİR ÇELİK TEMEL	2,29%
PETROL VE PETROL ÜRÜNLERİ	2,32%
CAM	2,74%

HAVA YOLLARI VE HİZMETLERİ	2,92%
GAYRİMENKUL YATIRIM ORTAKLIĞI	3,15%
HOLDİNG	3,33%
MADENCİLİK	3,38%
BANKACILIK	3,67%

Tablo 8. BIST 30 Paylarının Gün Ertesi ve Beş Günlük Karşılaştırmalı Analizine İlişkin Bilgiler

Hisse Kodu	REL1 Günlük	REL5 Günlük
AKBNK	2.06%	3.59%
ARCLK	1.90%	1.83%
ASLSN	1.91%	1.96%
BIMAS	1.74%	1.69%
EKGYO	1.79%	3.15%
EREGL	1.92%	2.10%
FROTO	2.08%	2.17%
GARAN	2.12%	3.53%
GUBRF	2.39%	2.50%
HALKB	2.02%	4.29%
HEKTS	2.23%	1.79%
ISCTR	1.92%	3.75%
KCHOL	1.86%	3.02%
KOZAA	2.70%	2.98%
KOZAL	2.47%	3.77%
KRDMD	2.28%	2.48%
PETKM	1.81%	2.81%
PGSUS	2.49%	4.15%
SAHOL	1.86%	3.66%
SASA	2.31%	2.11%
SISE	1.89%	2.74%
TAVHL	2.14%	2.13%
TCELL	1.89%	1.89%
THYAO	2.07%	2.49%
TKFEN	2.02%	3.30%
TOASO	2.15%	2.11%
TTKOM	1.79%	2.66%
TUPRS	1.88%	1.83%
VESTL	2.10%	2.12%
YKBNK	1.98%	3.19%

Hisse bazında her iki dönem için en iyi performansı sergileyen 1,72% lik hata ortalamasıyla BIMAS, en kötü performansı sergileyen 3,32% lik ortalamasıyla PGSUS olmuştur. 2 dönem arası en yüksek farka sahip olan hisse

kodu HALKB'dir, aradaki fark 2,27% dir. TCELL hisse kodu her iki dönemde de 1,89% hata oranıyla tahminde bulunmuştur.

Tablo 9. BIST 30 Paylarının Sektörel Bazda Gün Ertesi ve Beş Günlük Karşılaştırmalı Analizine İlişkin Bilgiler

SEKTÖR	FİRMA SAYISI	BİST 30 % ORANI	REL 1 Günlük	REL 5 Günlük
BANKACILIK	5	16,67	2,02%	3,67%
HAVA YOLLARI VE HİZMETLERİ	3	10,00	2,23%	2,92%
HOLDİNG	3	10,00	1,91%	3,33%
DAYANIKLI TÜKETİM	2	6,67	2,00%	1,98%
DEMİR ÇELİK TEMEL	2	6,67	2,10%	2,29%
İLETİŞİM	2	6,67	1,84%	2,28%
MADENCİLİK	2	6,67	2,59%	3,38%
OTOMOTİV	2	6,67	2,12%	2,14%
PETROL VE PETROL ÜRÜNLERİ	2	6,67	1,85%	2,32%
TARIM KİMYASALLARI	2	6,67	2,31%	2,15%
CAM	1	3,33	1,89%	2,74%
ENDÜSTRİYEL TEKSTİL	1	3,33	2,31%	2,11%
GAYRİMENKUL YATIRIM ORTAKLIĞI	1	3,33	1,79%	3,15%
İLETİŞİM CİHAZLARI	1	3,33	1,91%	1,96%
PERAKENDE	1	3,33	1,74%	1,69%

Sektörel bazda her iki dönem için en iyi performansı sergileyen sektör 1,72% lik hata ortalamasıyla Perakende , en kötü performansı sergileyen 2,98% lik ortalamasıyla Madencilik sektörü olmuştur.

5. SONUÇ

Yapay zeka yöntemleriyle borsalarda getiriler sağlayıp sağlamadığı birçok araştırmaya konu olmuştur. Bir hisse senedinin veya endeksin günlük veya haftalık tahmini, kısa vadeli işlemler için getiri sağlayan bir öneri sistemi olarak hizmet edebilir. Literatür incelendiğinde yapay zeka yöntemlerinin bunu sağladığı ve hisse senedi fiyat öngörüsü modellerinin doğruluk oranı 2000 yılından bu yana hızla arttığı görülmektedir. Uzun vadeli hisse senedi yatırıma uygun seçimler günümüz dünyasında oldukça kolaylaşmıştır fakat kısa vadeli işlemler için aynı şey geçerli değildir. Her yatırımcı için, yatırımlarından en üst düzeyde kar elde etmek birinci hedef olsa da bireysel yatırımcılar bu konuda oldukça zorlanmaktadırlar . Bu çalışmada, Ocak 2022 tarihi itibarıyla BIST 30 endeksinde yer alan payların gelecekteki değerini Aralık 2003-Ocak 2022 tarihleri arasındaki günlük açılış, kapanış, düşük fiyat, yüksek fiyat ve hacim verileri kullanılarak hesaplanmıştır. Veriler Borsa İstanbul lisanslı veri sağlayıcısı olan Matriks programından indirilmiştir. Çalışmada, yapay zeka analiz tekniği olan denetimli makine öğrenme modeli Karar Ağacı algoritması kullanılmaktadır. Karar ağaçları tahmin yeteneğini değerlendirmek için ertesi gün tahmin performansını 5 günlük performansı ile karşılaştırıyoruz. Modelleri eğitmek ve test etmek için Rapidminer Studio paket programı kullanıldı. algoritmadan da şunu gördük: bize daha iyi sonuçlar verdi karar ağaçları finansal tahmin için umut verici bir araç türüdür Borsa İstanbul 30 endeksinde işlem gören paylardan on dördünün Arçelik, Aselsan, Bim, Emlak Gayrimenkul Ortaklığı, Ereğli Demir Çelik, İş Bankası, Koç Holding, Petkim, Sabancı Holding, Şişecam, Türkcell, Türk Telekom, Tüpraş ve Yapı Kredi Bankası gün ertesi fiyat öngörüsü hisselerin günlük ortalama hareket boyuna oranla istatistiksel olarak pozitif getiri sağladığı görülmektedir. BIST30 endeksinin günlük ortalama hareket boyu başarı kriteri olarak kabul edildiğinde, birçoğu sıfır getiri bandında bulunmaktadır. BIST30 endeksinin 5 günlük ortalama hareket dalga boyu %4 olarak kabul edilip beş günlük fiyat öngörüsü incelendiğinde Pegasus Hava yolları ve Halk Bankası fiyat öngörülerini dışındaki 28 hisse senedinin fiyat öngörüsünün pozitif getiri sağladığı görülmektedir. İki tahmin aralığının performans karşılaştırmasında, 5 günlük ortalama getirisinin gün ertesi ortalama getirisinin den daha başarılı olduğu görülmektedir.

Bundan sonra yapılacak çalışmalarda farklı hisse senedi endeksinden farklı veri seti analiz kapsamına alınarak, araştırılabilir. Çalışmada sunulan sonuçların geçerliliği, farklı metodolojiler kullanılarak karşılaştırılabilir. Hisse senedi türüne daha uygun tahmin sisteminin doğruluğunu iyileştirerek yeniden uygulanabilir. Bunlara ek olarak Karar Ağacı algoritması 5 günlük fiyat öngörüsü sonuçlarında haftanın günü anomalisi varlığını ortaya çıkarmıştır

bu konu ayrı bir çalışmada incelenebilir. Bu, çalışmada açıklamayı amaçladığı konunun yalnızca bir kısmını açıklığa kavuşturmuştur, geliştirilebilir.

Kaynakça

- Abe, M., Nakayama, H. (2018). Deep Learning for Forecasting Stock Returns in the Cross-Section. In: Phung, D., Tseng, V., Webb, G., Ho, B., Ganji, M., Rashidi, L. (eds) *Advances in Knowledge Discovery and Data Mining. PAKDD 2018. Lecture Notes in Computer Science()*, vol 10937
- Ahmed, Nesreen K., Atiya, Amir F., Gayar, Neamat El and El-Shishiny, Hisham (2010) 'An Empirical Comparison of Machine Learning Models for Time Series Forecasting', *Econometric Reviews*, 29: 5, 594 — 621
- Altay, E., & Satman, M. H. (2005). Stock market forecasting: artificial neural network and linear regression comparison in an emerging market. *Journal of Financial Management & Analysis*, 18(2), 18.
- Atsalakis, G.S., & Valavanis, K.P. (2009). Surveying stock market forecasting techniques - Part II: Soft computing methods. *Expert Syst. Appl.*, 36, 5932-5941.
- Aziz, S., & Dowling, M. (2019). Machine learning and AI for risk management. In *Disrupting finance* (pp. 33-50). Palgrave Pivot, Cham.
- Beruticha, J.M., López, F., Luna, F., Quintana, D. (2016). Robust technical trading strategies using GP for algorithmic portfolio selection. *Expert Systems with Applications*, 46, pp. 307-315.
- Bianchi, D., Büchner, M., & Tamoni, A. (2021). Bond risk premiums with machine learning. *The Review of Financial Studies*, 34(2), 1046-1089.
- Black, F., & Litterman, R. (1992). Global portfolio optimization. *Financial Analysts Journal*, 48(5), 28-43.
- Booth, A., Gerding, E., & McGroarty, F. (2015). Performance-weighted ensembles of random forests for predicting price impact. *Quantitative Finance*, 15(11), 1823-1835.
- Branke, J., Scheckenbach, B., Stein, M., Deb, K., & Schmeck, H. (2009). Portfolio optimization with an envelope-based multi-objective evolutionary algorithm. *European Journal of Operational Research*, 199(3), 684-693.
- Chandar, S. K. (2022). Convolutional neural network for stock trading using technical indicators. *Automated Software Engineering*, 29, 1-14.
- Chavan, P. S., & Patil, S. T. (2013). Parameters for stock market prediction. *International Journal of Computer Technology and Applications*, 4(2), 337
- Chen, A. S., & Leung, M. T. (2004). Regression neural network for error correction in foreign exchange forecasting and trading. *Computers & Operations Research*, 31(7), 1049-1068.
- Chen, W. H., Shih, J. Y., & Wu, S. (2006). Comparison of support-vector machines and backpropagation neural networks in forecasting the six major Asian stock markets. *International Journal of Electronic Finance*, 1(1), 49-67.
- Chong, E., Han, C., & Park, F. C. (2017). Deep learning networks for stock market analysis and prediction: Methodology, data representations, and case studies. *Expert Systems with Applications*, 83, 187-205.
- Das, S. P., & Padhy, S. (2012). Support vector machines for prediction of futures prices in Indian stock market. *International Journal of Computer Applications*, 41(3).
- Deniz, Ö. (2005). Poisson regresyon analizi. *İstanbul Ticaret Üniversitesi Fen Bilimleri Dergisi*, 4(7), 59-72.
- Donaldson, R. G., & Kamstra, M. (1997). An artificial neural network-GARCH model for international stock return volatility. *Journal of Empirical Finance*, 4(1), 17-46.
- Dondurmacı, G. A., & Çınar, A. (2014). Finans sektöründe veri madenciliği uygulaması. *Akademik Sosyal Araştırmalar Dergisi*, 2(1), 258-271.
- Enke, D., & Thawornwong, S. (2005). The use of data mining and neural networks for forecasting stock market returns. *Expert Systems with Applications*, 29(4), 927-940.
- Fan, A., & Palaniswami, M. (2001, July). Stock selection using support vector machines. In *IJCNN'01. International Joint Conference on Neural Networks. Proceedings (Cat. No. 01CH37222)* (Vol. 3, pp. 1793-1798). IEEE.
- Feng, G., Giglio, S., & Xiu, D. (2020). Taming the factor zoo: A test of new factors. *The Journal of Finance*, 75(3), 1327-1370.

- Fernandes, M., Medeiros, M. C., & Scharth, M. (2014). Modeling and predicting the CBOE market volatility index. *Journal of Banking & Finance*, 40, 1-10.
- Güdelek, M. U. (2019). Zaman serisi analiz ve tahmini: Derin öğrenme yaklaşımı (Master's thesis, TOBB ETÜ Fen Bilimleri Enstitüsü).
- Giamouridis, D. (2017). Systematic investment strategies. *Financial Analysts Journal*, 73(4), 10-14.
- Gu, S., Kelly, B., & Xiu, D. (2020). Empirical asset pricing via machine learning. *The Review of Financial Studies*, 33(5), 2223-2273.
- Hadavandi, E., Shavandi, H., & Ghanbari, A. (2010). Integration of genetic fuzzy systems and artificial neural networks for stock price forecasting. *Knowledge-Based Systems*, 23(8), 800-808.
- Hu, H., Tang, L., Zhang, S., & Wang, H. (2018). Predicting the direction of stock markets using optimized neural networks with Google Trends. *Neurocomputing*, 285, 188-195.
- Iqbal, Z., Ilyas, R., Shahzad, W., Mahmood, Z., & Anjum, J. (2013). Efficient machine learning techniques for stock market prediction. *International Journal of Engineering Research and Applications*, 3(6), 855-867.
- Jasic, T., & Wood, D. (2004). The profitability of daily stock market index trades based on neural network predictions: Case study for the S&P 500, the DAX, the TOPIX and the FTSE in the period 1965–1999. *Applied Financial Economics*, 14(4), 285-297.
- Kim, K. J., & Han, I. (2000). Genetic algorithm approach to feature discretization in artificial neural networks for the prediction of stock price index. *Expert Systems with Applications*, 19(2), 125-132.
- Kim, K. J., & Lee, W. B. (2004). Stock market prediction using artificial neural networks with optimal feature transformation. *Neural Computing & Applications*, 13(3), 255-260.
- Kim, M. J., Min, S. H., & Han, I. (2006). An evolutionary approach to the combination of multiple classifiers to predict a stock price index. *Expert Systems with Applications*, 31(2), 241-247.
- Kim, H. J., & Shin, K. S. (2007). A hybrid approach based on neural networks and genetic algorithms for detecting temporal patterns in stock markets. *Applied Soft Computing*, 7(2), 569-576.
- Koç Ustalı, N., Tosun, N., Tosun, Ö. (2021). “Makine Öğrenmesi Teknikleri ile Hisse Senedi Fiyat Tahmini”, *Eskişehir Osmangazi Üniversitesi İİBF Dergisi*, 16(1), 1 – 16.
- Lee, M. C. (2009). Using support vector machine with a hybrid feature selection method to the stock trend prediction. *Expert Systems with Applications*, 36(8), 10896-10904.
- Liao, Z., & Wang, J. (2010). Forecasting model of global stock index by stochastic time effective neural network. *Expert Systems with Applications*, 37(1), 834-841.
- Lopez de Prado, M. (2016). *Building Diversified Portfolios That Outperform Out-of-Sample* (Presentation Slides). Available at SSRN 2713516.
- Ma, Y., Han, R., & Wang, W. (2021). Portfolio optimization with return prediction using deep learning and machine learning. *Expert Systems with Applications*, 165, 113973.
- Murphy, K. P. (2012). *Machine learning: a probabilistic perspective*. MIT press.
- Müller, K. R., Smola, A. J., Rätsch, G., Schölkopf, B., Kohlmorgen, J., & Vapnik, V. (1997, October). Predicting time series with support vector machines. In *International conference on artificial neural networks* (pp. 999-1004). Springer, Berlin, Heidelberg.
- Nabipour, M., Nayyeri, P., Jabani, H., Shahab, S., & Mosavi, A. (2020). Predicting stock market trends using machine learning and deep learning algorithms via continuous and binary data; a comparative analysis. *IEEE Access*, 8, 150199-150212.
- Oh, K. J., & Han, I. (2000). Using change-point detection to support artificial neural networks for interest rates forecasting. *Expert Systems with Applications*, 19(2), 105-115.
- Ou, P., & Wang, H. (2009). Prediction of stock market index movement by ten data mining techniques. *Modern Applied Science*, 3(12), 28-42.
- Pierdzioch, C., & Risse, M. (2018). A machine-learning analysis of the rationality of aggregate stock market forecasts. *International Journal of Finance & Economics*, 23(4), 642-654.

- Rasekhschaffe, K. C., & Jones, R. C. (2019). Machine learning for stock selection. *Financial Analysts Journal*, 75(3), 70-88.
- Rapach, D. E., Strauss, J. K., Tu, J., & Zhou, G. (2019). Industry return predictability: A machine learning approach. *The Journal of Financial Data Science*, 1(3), 9-28.
- Sabharwal, C. L. (2018). The rise of machine learning and robo-advisors in banking. *IDRBT Journal of Banking Technology*, 28.
- Skolpadungket, P., Dahal, K., & Harnpornchai, N. (2016). Handling Model Risk in Portfolio Selection Using Multi-Objective Genetic Algorithm. In *Artificial Intelligence in Financial Markets* (pp. 285-310). Palgrave Macmillan, London.
- Schumaker, R. P., & Chen, H. (2009). Textual analysis of stock market prediction using breaking financial news: The AZFintext system. *ACM Transactions on Information Systems (TOIS)*, 27(2), 12.
- Strader, Troy J.; Rozycki, John J.; ROOT, THOMAS H.; and Huang, Yu-Hsiang (John) (2020) "Machine Learning Stock Market Prediction Studies: Review and Research Directions," *Journal of International Technology and Information Management*: Vol. 28 : Iss. 4 , Article 3.
- ŞIKLAR, E. (1999) REGRESYON ANALİZİNDE BAYESÇİ YAKLAŞIM. *Anadolu Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 15(1), 113-122.
- Tan, P. N., Steinbach, M., & Kumar, V. (2013). *Data mining cluster analysis: basic concepts and algorithms. Introduction to data mining*, 487, 533.
- Tunçel, A. K. (2007). Rassal yürüyüş (random walk) hipotezi'nin İMKB'de test edilmesi: koşu testi uygulaması. *Gazi Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 9(2), 1-18.
- Urquhart, A., Gebka, B., & Hudson, R. (2015). How exactly do markets adapt? Evidence from the moving average rule in three developed markets. *Journal of International Financial Markets, Institutions and Money*, 38, 127-147.
- Viswanathan, K., Choudur, L., Talwar, V., Wang, C., Macdonald, G., & Satterfield, W. (2012, April). Ranking anomalies in data centers. In *2012 IEEE Network Operations and Management Symposium* (pp. 79-87). IEEE.
- Vochozka, M., & Sheng, P. (2016). The application of artificial neural networks on the prediction of the future financial development of transport companies. *Communications-Scientific letters of the University of Zilina*, 18(2), 62-67.
- Wang, Y., Wong, J., & Miner, A. (2004, June). Anomaly intrusion detection using one-class SVM. In *Proceedings from the Fifth Annual IEEE SMC Information Assurance Workshop, 2004*. (pp. 358-364). IEEE.
- Xiao-si, X., Ying, C., & Ruo-en, R. (2006, October). Studying on forecasting the enterprise bankruptcy based on SVM. In *2006 International Conference on Management Science and Engineering* (pp. 1041-1045). IEEE.
- Yeh, C. Y., Huang, C. W., & Lee, S. J. (2011). A multiple-kernel support vector regression approach for stock market price forecasting. *Expert Systems with Applications*, 38(3), 2177-2186.
- Yu, L., Chen, H., Wang, S., & Lai, K. K. (2008). Evolving least squares support vector machines for stock market trend mining. *IEEE Transactions on evolutionary computation*, 13(1), 87-102.
- Zhong, X., & Enke, D. (2019). Predicting the daily return direction of the stock market using hybrid machine learning algorithms. *Financial Innovation*, 5(1), 1-20.
- Zimmermann, H. G., Neuneier, R., & Grothmann, R. (2001). Active portfolio-management based on error correction neural networks. *Advances in Neural Information Processing Systems*, 14.