

Piyasa Yönünün Derin Öğrenme ile Tahmini: E-7 Ülke Borsaları Üzerine Bir Uygulama

Nazif AYYILDIZ¹

Öz

Bu çalışmada, derin öğrenme yönteminin yükselen piyasa ekonomileri olarak bilinen E-7 ülkelerinin borsa endeksleri üzerindeki tahmin performansının incelenmesi amaçlanmıştır. Bu bağlamda, IPC (Meksika), SSE (Çin), BIST 100 (Türkiye), RTS (Rusya), BOVESPA (Brezilya), IDX (Endonezya) ve NIFTY 50 (Hindistan) borsa endekslerinin günlük hareket yönleri H2O derin öğrenme modeli kullanılarak tahmin edilmiştir. Modelin girdileri olarak, 01.01.2015 ve 31.12.2024 tarihleri arasında günlük kapanış fiyatlarına dayalı olarak hesaplanan teknik göstergeler kullanılmıştır. Tahmin sürecinde veriler %80 eğitim ve %20 test seti olarak bölünmüştür. Hesaplanan doğruluk oranları IPC endeksi için %88,47, SSE için %78,13, BIST 100 için %77,29, RTS için %76,05, BOVESPA için %75,81, IDX için %75,05 ve NIFTY 50 için %74,34 olarak bulunmuştur. Elde edilen bulgular, derin öğrenme yöntemlerinin borsa endeksi hareketlerini belirli bir doğruluk düzeyiyle tahmin edebildiğini göstermektedir.

Anahtar Sözcükler: Derin Öğrenme, H2O Derin Öğrenme Modeli, Sınıflandırma, Gelişmekte Olan Ülkeler

JEL Kodları: C38, C55, G15, G17

Predicting Market Direction With Deep Learning: An Application on E-7 Country Stock Markets

Abstract

This study aims to examine the prediction performance of the deep learning method on the stock indices of E-7 countries, known as emerging market economies. In this context, the daily movement directions of the stock indices of IPC (Mexico), SSE (China), BIST 100 (Turkey), RTS (Russia), BOVESPA (Brazil), IDX (Indonesia), and NIFTY 50 (India) were predicted using the H2O deep learning model. Technical indicators calculated based on the daily closing prices between 01.01.2015 and 31.12.2024 were used as inputs for the model. The data was split into 80% training and 20% test sets during the prediction process. The calculated accuracy rates were 88.47% for the IPC index, 78.13% for SSE, 77.29% for BIST 100, 76.05% for RTS, 75.81% for BOVESPA, 75.05% for IDX, and 74.34% for NIFTY 50. The findings demonstrate that deep learning methods can predict stock index movements with a certain level of accuracy.

Keywords: Deep Learning, H2O Deep Learning Model, Classification, Developing Countries

JEL Codes: C38, C55, G15, G17

¹ Sorumlu Yazar, Öğr. Gör. Dr., Harran Üniversitesi, Suruç Meslek Yüksekokulu, Finans, Bankacılık ve Sigortacılık Bölümü, nazifayyildiz@harran.edu.tr, ORCID ID: 0000-0002-7364-8436

<https://doi.org/10.33203/mfy.1442589>

Geliş Tarihi/Submitted : 25 Şubat 2025

Kabul Tarihi/Accepted : 14 Mart 2025

The content of this journal is licensed under the Creative Commons Attribution-NonCommercial 4.0 International License (CC BY-NC 4.0).



Extended Summary

Stock market indices are important references for measuring the trends in financial markets, and their accurate prediction is of great significance for investors, decision-makers, and regulatory authorities. Stock prices have been a challenging subject to predict due to a wide range of factors such as company activities and external market influences. The Efficient Market Hypothesis suggests that stock prices are determined by new information and cannot be predicted using past data, yet traditional methods such as fundamental and technical analysis, along with more advanced statistical and econometric models, are commonly used in stock market analysis. Recently, machine learning and deep learning methods, with their ability to model nonlinear relationships and handle large data sets, have been achieving high accuracy in stock market predictions.

This study aims to use the H2O deep learning model to predict the directions of the major stock indices of the E-7 countries. The goal is to predict the future movements of the indices of Mexico (IPC), China (SSE), Turkey (BIST 100), Russia (RTS), Brazil (BOVESPA), Indonesia (IDX), and India (NIFTY 50).

In the current literature, studies focusing on stock index direction prediction using deep learning methods typically apply financial or technical indicators to different stock indices. However, no studies have collectively analyzed the stock indices of countries in a specific economic group using deep learning. Additionally, no research has been found that utilizes the H2O deep learning model in this context. Therefore, the scope and methodology of this study are expected to make a significant contribution to the literature.

The data used in the application spans from January 1, 2015, to December 31, 2024, consisting of daily data and related technical indicators (Moving Average, Weighted Moving Average, Exponential Moving Average, MACD, CCI, RSI, Stochastic %K, Stochastic %D, William's %R, and Momentum). The H2O deep learning model, with its multilayer feedforward structure, is employed in this study, with hyperparameters optimized to achieve the best results. The model's working principle is inspired by the functioning of biological neural cells, processing signals at each layer and producing outputs through weighted connections. During the training process, weights are adjusted to minimize errors and improve the model's accuracy. The H2O model's capacity for processing large data sets and the automatic adjustment of hyperparameters have significantly enhanced its prediction power.

The analysis conducted using the deep learning method resulted in the following prediction accuracies for the stock indices of emerging countries: IPC (88.47%), SSE (78.13%), BIST 100 (77.29%), RTS (76.05%), BOVESPA (75.81%), IDX (75.05%), and

NIFTY 50 (74.34%). Therefore, it can be said that the movement directions of the stock indices of emerging countries have been successfully predicted with over 70% accuracy. The findings show that stock index movements can be predicted with a certain level of accuracy using past stock index data.

In this context, the predictability of stock markets can offer various advantages to both market participants and regulators. The predictability of stock prices can primarily contribute to economic growth by increasing investment flows into the market. It can also provide significant benefits to investors in preserving their savings, minimizing transaction costs, identifying investment opportunities, and taking preventive measures against potential risks. This is also important for market regulators, as accurate predictions can guide them in making appropriate decisions and taking corrective actions in a timely manner. Additionally, for business managers, accurate analyses based on past data can help enhance firm values and make strategic decisions. Ultimately, accurately predicting stock indices can enhance the efficiency of financial markets, supporting overall economic stability and the success of businesses.

1. Giriş

Hisse senedi endeksleri, finansal piyasaların genel eğilimini ölçmek için önemli bir referanstır. Borsa endekslerinin tahmin edilmesi yatırımcılar, karar vericiler ve düzenleyici otoriteler için yatırım kararını yönlendirmek, piyasa risklerini değerlendirmek ve makro düzeydeki maliye politikalarını analiz etmek açısından büyük önem taşımaktadır (Kanwal ve diğerleri, 2022). Bu nedenle, borsa endekslerinin gelecekteki eğiliminin doğru bir şekilde ön görülmesi hem uygulayıcılar hem de araştırmacılar için sürekli izlenen ve araştırılan bir konudur. Bununla birlikte, hisse senedi fiyat hareketi, dahili şirketin faaliyet durumu ve dış piyasa fiyat değişikliği gibi çok sayıda faktörden etkilenir. Faktörlerin karmaşıklığı ve değişkenliği hisse senedi fiyat tahminini zorlu bir iş haline getirmektedir (Cui ve diğerleri, 2023).

Hisse senedi piyasalarındaki fiyat eğilimlerini öngörebilmek, sadece hisse senedi piyasaları için değil, aynı zamanda yatırımcılar, piyasa düzenleyicileri ve işletme yöneticileri için çeşitli avantajlar sunabilir. Hisse senedi fiyatlarının hareket yönünü tahmin etmek, öncelikle piyasaya artan yatırım akışını teşvik ederek ekonomik büyümeye katkı sağlayabilir. Ayrıca, yatırımcıların portföylerinde sağlıklı ayarlamalar yapmalarına ve en yüksek getiriyi elde etmelerine yardımcı olacak etkili alım-satım stratejileri oluşturmalarına olanak tanıyabilir. Bununla birlikte, piyasa düzenleyicileri için doğru kararlar almak ve düzeltici önlemleri uygulamak konusunda rehberlik sağlayarak piyasanın adil ve etkin çalışmasına katkıda bulunabilir. Ayrıca, işletme yöneticilerine, firma değerlerini maksimize etme konusunda doğru adımları atma fırsatı sunabilir (Mallikarjuna ve Rao, 2019).

Hisse senedi piyasalarında fiyat eğilimlerinin öngörülebilmesi ancak piyasa için en uygun analiz yönteminin belirlenmesine ve eğilimlerin maksimum doğrulukla tahmin edilebilmesine bağlıdır. Ancak, hisse senedi fiyatlarının tahmin edilebilirliği konusu literatürde tartışmalı bir konudur. Söz konusu tartışma Eugene Fama tarafından 1970’de ortaya atılan Etkin Piyasalar Hipotezi üzerinden yapılmaktadır. Etkin piyasalar hipotezinde, hisse senedi fiyatlarını yeni bilgiler tarafından belirlendiği, fiyatların geçmiş bilgilerle tahmin edilemez olduğu ve rastgele bir yürüyüş izlediği savunulmaktadır. Etkin piyasalar hipotezi ortaya atıldığından beri sürekli eleştirilmiş ve geçerliliği sorgulanmıştır. Diğer yandan, sermaye piyasalarında, hisse senedi fiyatlarının tahmini amacıyla temel ve teknik analiz olmak üzere iki ana yöntem kullanılmaktadır. Temel analiz, finansal tabloların ve ekonomik göstergelerin analiz edilmesini içermektedir. Diğer yandan, teknik analiz, gelecekteki fiyatları tahmin etmek için geçmiş fiyatların analiz edilmesine dayanmaktadır. Bu geleneksel yöntemlere ek olarak, Otogresif Entegre Hareketli Ortalama (ARIMA), Mevsimsel Otogresif Entegre Hareketli Ortalama (SARIMA), Vektör Oto-Regresyon (VAR) gibi istatistiksel ve ekonometrik yöntemler de menkul kıymet borsalarında zaman serilerinin tahmininde kullanılmaktadır. Ancak bu doğrusal yöntemler, hisse senedi fiyatlarını etkileyen değişkenler arasındaki karmaşık ve doğrusal olmayan ilişkileri yakalayabilme konusunda zafiyet gösterebilmektedir. Son

yıllarda, borsa analizi için güçlü araçlar olarak makine öğrenimi yöntemleri geliştirilmiştir, Tahmine dayalı modeller oluşturan makine öğrenimi yöntemleri, finansal serilerin doğrusal olmayan ve durağan olmayan özelliklerini ele alarak yüksek doğruluk performansı göstermektedir. Borsa tahmini için makine öğrenimi teknikleri üzerine yakın zamanda yapılan literatür taraması çalışmalarına göre sinir ağları en sık kullanılan yaklaşımdır (Kumbure ve diğerleri, 2022; Ayyıldız ve İskenderoğlu, 2024). Borsa verilerinin analiz ve tahminindeki sinir ağları arasında en popüler yaklaşımlardan biri olan derin öğrenme ise, çok sayıda doğrusal ve doğrusal olmayan dönüşümden oluşan birden çok işlem katmanına sahip derin bir yapı kullanarak verilerdeki üst düzey soyutlamaları modellemeye çalışan bir dizi algoritmaya dayanan bir makine öğrenimi dalı olarak ortaya çıkmıştır (Albayrak ve Saran, 2023; Zhong ve Enke, 2019). Derin öğrenme modelleri, büyük hacimli verileri etkili bir şekilde işleme ve girdi özellikleri ile karmaşık doğrusal olmayan ilişkileri belirleme yetenekleri sayesinde doğrusal modeller ve makine öğrenimi modellerinden daha iyi performans göstermektedir (Najafabadi ve diğerleri, 2015; Beniwal ve diğerleri, 2024).

Bu çalışmanın amacı, derin öğrenme yönteminin gelişmekte olan ülkelerin borsa endeksleri üzerindeki tahmin performansının ölçülmesidir. Bu amaç doğrultusunda 01.01.2015-31.12.2024 tarihleri arasında günlük veri setleri ve teknik göstergelerden yararlanılarak, gelişmekte olan ülkeler olarak bilinen, E-7 ülkelerinin ana borsa endeksleri; IPC (Meksika), SSE (Çin), BIST 100 (Türkiye), RTS (Rusya), BOVESPA (Brezilya), IDX (Endonezya) ve NIFTY 50 (Hindistan) endekslerinin hareket yönleri tahmin edilmiştir.

Mevcut literatürde, derin öğrenme yöntemleriyle borsa endeks yön tahminine odaklanan çalışmaların genellikle finansal veya teknik göstergeler kullanarak farklı borsa endekslerinde uygulandığı görülmüştür. Ancak, belirli bir ekonomik gruba ait ülkelerin borsa endekslerini derin öğrenme ile topluca inceleyen bir çalışmaya rastlanmamıştır. Ayrıca, H2O derin öğrenme modelinin bu alanda kullanıldığı bir araştırmaya da ulaşılamamıştır. Bu nedenle, çalışmanın hem kapsamı hem de yöntemi açısından literatüre önemli bir katkı sunabileceği düşünülmektedir.

Bu çalışma altı bölümden oluşmaktadır. Çalışmanın bir sonraki bölümünde, literatürde derin öğrenme modelleriyle gelişmekte olan ülkelerin borsa endekslerinin tahminine odaklanan çalışmalar özetlenmiştir. Üçüncü bölümde araştırmada kullanılan veri seti dördüncü bölümde ise uygulamada kullanılan derin öğrenme yöntemi açıklanmaktadır. Beşinci bölümde, araştırmadan elde edilen bulgular açıklanarak literatürdeki benzer çalışmalarla karşılaştırılmıştır. Çalışmanın sonuç kısmında ise, genel olarak elde edilen sonuçlar değerlendirilerek piyasa katılımcılarına, piyasa düzenleyicilere ve gelecekte benzer çalışma yapabilecek araştırmacılara çeşitli öneriler yapılmıştır.

2. Literatür Taraması

Çalışma kapsamında, derin öğrenme yöntemiyle gelişmekte olan ülkelerde borsa endeks hareket yönlerinin tahminine odaklanan çalışmalar incelenmiştir. Bu bölümde, literatür araştırması kapsamında incelenen çalışmalar iki kısma ayrılarak sunulmuştur. İlk kısımda Türkiye dışında farklı gelişmekte olan ülkelerin borsa endeksleri üzerine yapılan çalışmalar; ikinci kısımda ise Türkiye (Borsa İstanbul) özelinde konunun incelendiği çalışmalar özetlenmiştir.

Gelişmekte olan ülkelerin borsa endeks hareket yönü tahminlerinin yapıldığı çalışmalar incelendiğinde; Katar, Brezilya, Tayland, Rusya, Çin ve Kore gibi gelişmekte olan ülkelerin borsalarında benzer uygulamaların yapıldığı gözlenmiştir. Söz konusu çalışmalardan Katar Borsası'na odaklanılan Alhazbi ve diğerleri (2020) çalışmasında, hisse senetlerinin hareket yönünün tahmin edilmesinde bir derin öğrenme yöntemi olan Evrişimsel Sinir Ağı (CNN) kullanılmıştır. Yöntemin tahminin doğruluğunu artırmak için geçmiş verilere ek olarak petrol fiyatları ile S&P 500 ve Nikkei endeksi de girdi verisi olarak kullanılmıştır. Veri seti 1 Ocak 2014 ile 31 Aralık 2018 tarihleri arasındaki beş yıllık dönemi kapsamaktadır. Gerçekleştirilen analizin ardından, kullanılan yöntemin Katar Borsası hisse senetlerinin yönünü %74 doğrulukla tahmin edebildiği belirlenmiştir. Brezilya Borsası'nda konunun incelendiği Nelson ve diğerleri (2017) çalışmasında, fiyat geçmişi ve teknik analiz göstergeleri kullanılarak Bovespa endeksinin hareketleri derin öğrenme yöntemlerinden Uzun Kısa Süreli Bellek (LSTM) ile tahmin edilmiştir. Uygulamada 2008'den 2015'e kadarki günlük veriler kullanılmıştır. Elde edilen sonuçlara göre, endeksin hareket yönü %55,9'a varan doğruluk oranıyla tahmin edilmiştir. Benzer şekilde Tayland Vadeli İşlemler Borsası'nda LSTM modelinin uygulandığı Prachyachuwong ve Vateekul (2021) çalışmasında, 2014-2020 döneminde borsada işlem gören hisselerin hareket yönleri tahmin edilmiştir. Uygulama için 15 adet teknik gösterge kullanılmış ve %61,28'lik tahmin doğruluk oranına ulaşılmıştır. Rusya Borsası'na odaklanan Aliyev ve diğerleri (2022) çalışmasında ise, LSTM modelinin tahmin performansı parametrik modellerle karşılaştırılmıştır. 05.01.2000-8.07.2022 dönemi verileri kullanılarak RTSI Endeksi'ni tahmin etmedeki performansları açısından LSTM ile Tek değişkenli Otoregresif Entegre Hareketli Ortalama (ARIMA) modeli karşılaştırılmış ve LSTM derin öğrenme modelinin daha başarılı olduğu tespit edilmiştir. Benzer bir karşılaştırma da Çin Borsası üzerinde yapılmıştır. Yiling ve diğerleri (2022) çalışmasında 06.01.2020-06.01.2021 dönemi günlük verileri kullanılarak SSE 50 endeksinin yönünün tahmininde derin öğrenme modelinin geleneksel hisse senedi tahmin modellerine göre daha güçlü tahmin yeteneği olduğu belirlenmiştir. Kore Borsası'nda konunun incelendiği, Noh ve diğerleri (2023) çalışmasında ise, 2021-2022 yılları günlük verileri kullanılarak KOSPI endeksinin hareket yönü tahmin edilmiştir. Model performansının ölçülmesinde ana ölçüm olarak F1 puanı kullanılmıştır. Elde edilen bulgulara göre, KOSPI'nin hareket yönünün %68 F1 puanı ile tahmin edilebildiği belirlenmiştir.

Borsa İstanbul (BİST) özelinde konuyu ele alan çalışmalar incelendiğinde; hisse

senetleri fiyat hareketlerinin, bankacılık endeksinin, BİST 30, BİST 100 endeksinin ve katılım endeksinin hareket yönünün tahmin edildiği çalışmalar yapıldığı gözlenmiştir. Söz konusu çalışmalardan Borsa İstanbul'da faaliyet gösteren şirketler özelinde konunun ele alındığı Gündüz ve diğerleri (2017) çalışmasında, bir derin sinir ağı çeşidi olan evrişimsel sinir ağı kullanılarak Garanti Bankası (GARAN), Türk Hava Yolları (THYAO) ve İş Bankası (ISCTR) hisse senedi fiyatlarının günlük değişim yönünün tahmin edilmesi amaçlanmıştır. Girdi verisi olarak Ocak 2011-Aralık 2015 tarihleri arasındaki hisselerin günlük verileri, teknik göstergeler, dolar ve altın fiyatları kullanılmıştır. Oluşturulan modellerde, GARAN hissesinin yönü dolar-altın öznitelikleri kullanılarak en yüksek oranda doğru tahmin edilmiştir. Fiyat ve dolar-altın öznitelikleri birleştirildiğinde ise GARAN hissesinin yönünün en yüksek oranda doğru tahmin edildiği gözlemlenmiştir. BİST Banka Endeksi'nin tahminine odaklanılan Altunbaş (2021) çalışmasında ise, 04.11.2015-04.11.2019 tarihleri arasında banka endeksinin günlük fiyat verileri, teknik göstergeler, makroekonomik değişkenler (euro kuru, dolar kuru, Brent petrol, gram altın fiyatları) ve metinsel veriler girdi verisi olarak kullanılmıştır. Genel olarak endeksin yönünün doğru tahmin edildiği, ancak kapanış değerinin tahmininde sapmalar olduğu gözlemlenmiştir. BİST 30 endeksinin gelecekteki değerini tahmin etmeyi amaçlayan Raşo (2019) çalışmasında, 01.01.2016-31.12.2018 tarihleri arasındaki günlük fiyat verileri ve 11 teknik gösterge girdi verisi olarak kullanılarak derin sinir ağları, destek vektör makineleri ve yapay sinir ağları modelleri karşılaştırılmıştır. Derin sinir ağı ile oluşturulan modelin diğer modellerine kıyasla daha başarılı olduğu sonucuna ulaşılmıştır. BİST 30 endeksi üzerine yapılan Santur (2020) çalışmasında ise BİST30 endeksinin 2006-2015 aralığındaki kapanış verileri eğitim, 2015-2018 aralığı kapanış verileri ise test için kullanılmış ve 694 işlem gününe ait test verileri üzerinde önerilen derin öğrenme modeli ile endeksin trend yönü %82 doğrulukla tahmin edilmiştir. BİST Katılım Endeksi'nin tahmin edilmesine odaklanılan Çetin ve Metlek (2021) çalışmasında, bir derin öğrenme modeli olan LSTM kullanılmıştır. BIST 100 endeksi, CBOE oynaklık endeksi, altın oynaklık endeksi ve dolar endeksi tahmin modelinin girdi değişkenleri olarak seçilmiştir. Tasarlanan model ile Katılım Endeksi başarılı bir şekilde tahmin edilmiştir.

Derin öğrenme yöntemleri ile borsa endeks yön tahminine odaklanan çalışmalarda, genellikle finansal veya teknik göstergeler kullanılarak bir veya birkaç farklı borsa endeksinde uygulamaların yapıldığı gözlemlenmiştir. Derin öğrenme yöntemi özelinde belirli ekonomik grup veya kategoride yer alan ülkelerin borsa endekslerinin birlikte incelendiği bir çalışmaya ise ulaşamamıştır. Diğer yandan, çalışmanın yöntemi olan H20 derin öğrenme modelinin borsa endeks yön tahmininde kullanıldığı bir çalışmaya da rastlanılmamıştır. Bu bağlamda, çalışmanın gerek kapsamı açısından gerekse de yöntemi açısından benzer çalışmalardan farklılaşarak literatüre katkı sağlayacağı düşünülmektedir.

3. Yöntem, Değişkenler ve Veriler

3.1. Yöntem

Bu çalışma kapsamında, gelişmekte olan ülkeler olarak bilinen E-7 ülkelerinin ana borsa endeksleri; IPC (Meksika), SSE (Çin), BIST 100 (Türkiye), RTS (Rusya), BOVESPA (Brezilya), IDX (Endonezya) ve NIFTY 50 (Hindistan) endekslerinin günlük hareket yönleri H2O derin öğrenme modeli kullanılarak tahmin edilmiştir. Çalışmada kullanılan H2O derin öğrenme modeli, yöntemin yapısı ve diğer hiperparametre detayları bu bölümde açıklanmıştır.

Derin öğrenme modelleri, geri yayılım kullanılarak stokastik gradyan inişi ile eğitilen çok katmanlı ileri beslemeli bir yapay sinir ağına dayanmaktadır. Ağ, tanh, doğrultucu ve maxout aktivasyon işlevlerine sahip nöronlardan oluşan çok sayıda gizli katman içerebilir. Uyarlanabilir öğrenme oranı, hız tavlama, momentum eğitimi, bırakma gibi gelişmiş özellikler, yüksek tahmin doğruluğu sağlamaktadır. Her hesaplama düğümü, çoklu iş parçacığı (zaman uyumsuz) ile yerel verilerde genel model parametrelerinin bir kopyasını eğitmekte ve ağ genelinde model ortalaması aracılığıyla küresel modele düzenli aralıklarla katkıda bulunmaktadır (H2O, 2024).

Borsa endeks hareket yönlerinin tahmininde, finansal zaman serileri kullanılarak tahmin yapabilen çeşitli derin öğrenme modelleri kullanılmaktadır. Bu çalışmanın yöntemi olarak H2O derin öğrenme modeli tercih edilmiştir. H2O modeli, karmaşık ilişkileri öğrenme yeteneği ve geniş veri setlerini etkili bir şekilde işleyebilme kapasitesiyle dikkat çekmektedir. H2O derin öğrenme modeli; otomatik uyarlanabilir ağırlık başlatma, otomatik veri standardizasyonu, kategorik verilerin genişletilmesi, eksik değerlerin otomatik olarak işlenmesi, otomatik uyarlanabilir öğrenme oranları, çeşitli düzenleme teknikleri, otomatik performans ayarlama, yük dengeleme, ızgara arama, çapraz doğrulama, kontrol noktası oluşturma ve büyük veri kümeleri için farklı dağıtılmış eğitim modları gibi birçok farklı özelliğe sahiptir. Karmaşık yapılandırma işlemlerine ihtiyaç duymamakta ve maksimum performans alınması için modele optimizasyon işlemi uygulanabilmektedir (H2O, 2024).


H2O derin öğrenme modeli, ileri beslemeli bir mimariye sahiptir. Modeldeki temel birim, insan sinir hücresinin biyolojik olarak ilham aldığı bir model olan nörondur. İnsanlarda, nöronların çıkış sinyallerinin değişen güçleri sinaptik kavşaklar boyunca seyahat eder ve ardından bağlı bir nöronun etkinleştirilmesi için giriş olarak bir araya getirilir. Ağırlıklı kombinasyonların hesaplanmasında kullanılan formül Denklem (1)'de verilmiştir (Stetsenko, 2017).

$$\alpha = \sum_{i=1}^n w_i x_i + b \quad (1)$$

Denklem (1)'de de ifade edildiği üzere modelde, ağırlıklı kombinasyon giriş sinyalleri bir araya getirilir ve ardından bağlı nöron tarafından iletilen bir çıkış sinyali $f(\alpha)$ oluşturulur. Şekil 1'de yer alan görselde de ifade edilen f , ağ boyunca kullanılan doğrusal olmayan etkinleştirme fonksiyonunu ve bias b , nöronun etkinleştirme eşiğini temsil Şekil 1'de yer alan görselde de ifade edilen f , ağ boyunca kullanılan doğrusal olmayan etkinleştirme fonksiyonunu ve bias b , nöronun etkinleştirme eşiğini temsil etmektedir (Arora ve diğerleri 2015).

Şekil 1


Etkinleştirme Fonksiyonu



Çok katmanlı, ileri beslemeli sinir ağları, bir giriş katmanı ile başlayarak özellik uzayını eşleştirmek için bir dizi bağlantılı nöron biriminden oluşur (aşağıdaki görselde gösterildiği gibi). Ardından, nonlinearity içeren çok katmanlı katmanlar gelir ve çıkış uzayını eşleştirmek için bir lineer regresyon veya sınıflandırma katmanı ile sona erer. Modelin birimlerinin girişleri ve çıkışları, yukarıda tanımlanan tek bir nöronun temel mantığına uyar (Stetsenko, 2017).

Şekil 2

Çok Katmanlı, İleri Beslemeli Sinir Ağları



Her bir çıktı katmanının altında bias birimleri bulunmaktadır. Nöronları ve diğer nöronlarla olan bağlantıları belirleyen ağırlıklar, tüm ağın çıktısını tamamen belirler. Öğrenme, bu ağırlıkların etiketli eğitim verilerindeki hatayı en aza indirmek amacıyla adapte edildiğinde gerçekleşir. Denklem (2)'de ifade edildiği üzere, her eğitim örneği j

için, amaç bir kayıp fonksiyonunu en aza indirmektir (Arora ve diğerleri, 2015).

$$L(W, B | j) \quad (2)$$

Burada, W , N katmana sahip bir ağ için i ve $i + 1$ arasındaki katmanları bağlayan ağırlık matrisini gösteren $\{W_i\}_{1:N-1}$ koleksiyonunu ifade etmektedir. Benzer şekilde, B , $i + 1$ katmanı için bias sütun vektörünü gösteren $\{b_i\}_{1:N-1}$ koleksiyonudur. Bu çok katmanlı sinir ağlarının temel çerçevesi, derin öğrenme görevlerini gerçekleştirmek için kullanılmaktadır (Ayyıldız, 2024).

H20 derin öğrenme tahmin modelinin uygulama aşamasında öncelikle bir hiperparametre optimizasyonu gerçekleştirilmiştir. Modelin doğruluk oranını artırmak amacıyla öğrenme oranı (0.001, 0.01, 0.1), gizli katman sayısı (2, 3, 4), dropout oranı (0.3, 0.5, 0.7) ve aktivasyon fonksiyonu (ReLU, Sigmoid) gibi hiperparametrelerin farklı kombinasyonları test edilmiştir. Her kombinasyon, modelin performansını daha güvenilir bir şekilde değerlendirmek amacıyla 10 defa çalıştırılmıştır. Eğitim ve test veri setleri, her çalışmada 80:20 oranında bölünmüştür. En iyi sonuç veren hiperparametre değerleri aşağıda detaylı bir şekilde sunulmuştur (H20, 2024):

- Modelin gizli katmanlarında ReLU (Düzleştirilmiş Doğrusal Birim) aktivasyon fonksiyonu kullanılmıştır. ReLU, doğrusal olmayan ilişkileri etkili bir şekilde yakalayabilme özelliği nedeniyle tercih edilmiştir. Sınıflandırma görevlerinde ise modelin çıktısı katmanı, softmax aktivasyon fonksiyonunu kullanmaktadır. Softmax, modelin çıktısını farklı sınıflar arasında bir olasılık dağılımına dönüştürerek sınıflandırma performansını artırmaktadır.
- Öğrenme oranı 0.01 olarak belirlenmiştir. Bu parametre, her eğitim yinelemesinde ağırlıkların ne kadar değiştirileceğini belirlemektedir.
- Model, 10 epoch boyunca eğitilmiştir. Epoch sayısı, modelin tüm eğitim veri setinden kaç kez geçtiğini ifade etmektedir.
- Batch boyutu 32 olarak belirlenmiştir. Bu, her bir yinelemede model ağırlıklarının güncellenmesi için kullanılan eğitim örneklerinin sayısını ifade etmektedir.
- Dropout oranı 0.5 olarak ayarlanmıştır. Bu teknik, aşırı öğrenmenin önlenmesi için eğitim sürecinde nöronların rastgele bir seçimle devre dışı bırakılmasını sağlayarak ağına daha iyi genelleme yapmasına yardımcı olmaktadır.
- Momentum 0.9 olarak belirlenmiştir. Bu parametre, öğrenme sürecini hızlandırarak gradyan vektörlerini doğru yönde iterek yakınsama hızını artırır.
- Model, Stokastik Gradyan İnişi (SGD) algoritması ile optimize edilmiştir. SGD, model ağırlıklarını her bir batch'e dayalı olarak kademeli olarak günceller ve hesaplama verimliliğini artırırken yerel minimumlarda takılma olasılığını azaltmaktadır.

3.2. Değişkenler ve Veriler

Bu çalışma kapsamında gelişmekte olan ülkeler olarak bilinen, E-7 ülkelerinin ana borsa endeksleri; IPC (Meksika), SSE (Çin), BIST 100 (Türkiye), RTS (Rusya), BOVESPA (Brezilya), IDX (Endonezya) ve NIFTY 50 (Hindistan) endekslerinin hareket yönlerinin derin öğrenme yöntemiyle tahmin edilmesi amaçlanmıştır. Bu amaç doğrultusunda, öncelikle en uygun araştırma dönemi belirlenmeye çalışılmıştır. Literatürde yer alan benzer çalışmaların araştırma dönemleri incelenmiş ve daha çok beş yıldan uzun dönemlerde uygulamaların yapıldığı ve Çetin ve Metlek (2021) ve Beniwal ve diğerleri (2024) çalışmalarındaki gibi 10 yılı kapsayan araştırma dönemlerinin daha çok kullanıldığı gözlemlenmiştir. 01.01.2015 ile 31.12.2024 tarihleri arasındaki on yıllık dönem araştırma dönemi olarak belirlenmiştir. 01.01.2015-31.12.2024 olarak belirlenen araştırma döneminde borsaların açık kaldığı gün sayısı ulusal ve resmî tatillerdeki farklılıklar nedeniyle değişiklik göstermiştir. Bu bağlamda incelenen endekslerden; IPC 2.517, SSE 2.431, BIST 100 2.509, RTS 2.503, BOVESPA 2.479, IDX 2.426 ve NIFTY 50 2.477 günlük veriye sahiptir. Söz konusu veri sayılarında on yıllık analiz dönemi düşünüldüğünde analiz sonuçlarını potansiyel olarak etkileyebilecek önemli bir dengesizlik olmadığı göz önüne alınarak analizlerde doğrudan bu gözlem sayıları kullanılmıştır.

Çalışmada kullanılan teknik gösterge seçiminde, derin öğrenme modelleriyle endeks yön tahminine odaklanan benzer çalışmalar incelenmiştir. Bu bağlamda, öncelikle Gündüz ve diğerleri (2017), Gudelek ve diğerleri (2017) ve Prachyachuwong ve Vateekul (2021) çalışmalarında kullanılan teknik göstergeler hesaplanmıştır. Ardından, tahmin performansını arttıran, farklı bir ifadeyle, istatistiksel açıdan modele anlamlı katkı sağlayabilecek göstergelerden bir bölümü girdi değişkeni olarak analize dahil edilmiştir. Girdi değişkeni olarak kullanılan teknik göstergeler ve hesaplanış şekilleri Tablo 1’de sunulmuştur.

Bu çalışmada, geçmiş kapanış verilerinden yararlanılarak hesaplanan Basit Hareketli Ortalama, Ağırlıklı Hareketli Ortalama, Üstel Hareketli Ortalama, Momentum, Stokastik K, Stokastik D, Göreceli Güç Endeksi, Hareketli Ortalamaların Uyumu, Larry William’s R ve Emtia Kanalı Endeksi göstergeleri, derin öğrenme modelinin performansının artırılması amacıyla modelde girdi değişkenleri olarak kullanılmıştır. Borsa endekslerinin kapanış fiyatlarına göre, “düşüş” veya “yükseliş” olarak ifade edilen ertesi günkü hareket yönü ise çıktı verisi olarak kullanılmıştır.

Tablo 1**Teknik Göstergeler ve Hesaplanış Şekilleri**

Teknik Göstergeler	Hesaplanış Şekli
<i>Basit Hareketli Ortalama (MA)</i>	$\frac{C_t + C_{t-1} + \dots + C_{t-30}}{n}$
<i>Ağırlıklı Hareketli Ortalama (WMA)</i>	$\frac{((n) * C_t + (n-1) * C_{t-1} + \dots + C_{t-14})}{(n + (n-1) + \dots + 1)}$
<i>Üstel Hareketli Ortalama (EMA)</i>	$EMA(k)_t = EMA(k)_{t-1} + \alpha * (C_t - EMA(k)_{t-1})$
<i>Momentum (Mom)</i>	$C_t - C_{t-n}$
<i>Stokastik K% (%K)</i>	$\frac{C_t - LL_{t-n}}{HH_{t-n} - LL_{t-n}} * 100$
<i>Stokastik D% (%D)</i>	$\frac{\sum_{i=0}^{n-1} K_{t-i} \%}{n}$
<i>Göreceli Güç Endeksi (RSI)</i>	$100 - \frac{100}{1 + (\sum_{i=0}^{n-1} UP_{t-i}/n)/(\sum_{i=0}^{n-1} DW_{t-i}/n)}$
<i>Hareketli Ortalamaların Uyumu (MACD)</i>	$MACD(n)_{t-i} + \frac{2}{n+1} * DIFF_t - MACD(n)_{t-1}$
<i>Larry William's R% (LW)</i>	$\frac{H_n - C_t}{H_n - L_n} * 100$
<i>Emtia Kanal Endeksi (CCI)</i>	$\frac{M_t - SM_t}{0,015D_t}$

* C_t :Kapanış Fiyatı L_t :En Düşük Fiyat H_t :En Yüksek Fiyat $DIFF_t = EMA(12)_t - EMA(26)_t$ α :Düzeltilme Faktörü LL_t :Son t gün için minimumların minimumu HH_t :Son t gün için maksimumların maksimumu $M_t = (H_t + L_t + C_t)/3$ $SM_t = \sum_{i=0}^n M_{t-i+1}/n$ $D_t = \sum_{i=1}^n |M_{t-i+1} - SM_t|/n$ UP_t :t zamandaki yukarı yönlü fiyat DV_t :t zamandaki aşağı yönlü fiyat

Kaynak: Prachyachuwong ve Vateekul (2021).

Derin öğrenme modelinin uygulama aşamasında, veri setinin uygun bir oranda eğitim ve test veri seti olmak üzere iki ayrı parçaya ayrılması gerekmektedir. Eğitim veri seti üzerinden öğrenen derin öğrenme modelinin yaptığı tahminler test veri seti ile karşılaştırılmakta ve tahmin performansı ölçülmektedir. Literatürde veri setinin hangi oranlara bölüneceği konusunda genel bir görüş birliği olmamakla birlikte, büyük veri setleri için sınıflandırma süreçlerinde genellikle 80:20 oranının kullanılması önerilmektedir (Racz ve diğerleri, 2021; Ayyildiz, 2023). Diğer yandan, Alhazbi ve diğerleri (2020), Mallikarjuna ve Rao (2020), Yang ve diğerleri (2020) ve Çetin ve

Metlek (2021) gibi benzer çalışmalarda da 80:20 oranının kullanıldığı gözlemlenmiştir. Literatürdeki öneriler ve benzer çalışmalar dikkate alınarak veri seti %80'i eğitim ve %20'si ise test verisi olmak üzere iki parçaya bölünmüştür. Modelde kullanılan hiper parametrelerin bulunması amacıyla bir optimizasyon işlemi gerçekleştirilmiştir. Optimizasyonun ardından önce oluşturulan model eğitilmiş sonrasında gerçekleştirilen tahminler test amacıyla ayrılan veri seti ile karşılaştırılarak kullanılan derin öğrenme modelinin tahmin doğruluk performansı ölçülmüştür.

4. Bulgular, Analiz ve Değerlendirmeler

Derin öğrenme modelleri ile ikili sınıflandırma yapıldığında, sınıflandırmanın değerlendirilmesinde karışıklık matrisine göre yapılmaktadır. İkili sınıflandırma için kullanılan karışıklık matrisi Tablo 2'de ifade edilmektedir (Han ve diğerleri, 2012).

Tablo 2

İkili Sınıflandırma Karışıklık Matrisi

	Gerçek Pozitif Değer	Gerçek Negatif Değer
Öngörülen Pozitif Değer	Doğru Pozitif	Yanlış Negatif
Öngörülen Negatif Değer	Yanlış Pozitif	Doğru Negatif

İkili sınıflandırma karışıklık matrisi, bir sınıflandırma modelinin doğruluğunu değerlendirmek için yaygın olarak kullanılan önemli bir araçtır. Bu matris, modelin tahmin ettiği sınıflarla gerçek sınıflar arasındaki ilişkileri anlaşılmasına yardımcı olur ve modelin hatalarını analiz edilmesinde oldukça faydalıdır. Karışıklık matrisi genellikle dört temel değerden oluşur. Doğru Pozitif, modelin pozitif bir sınıfı doğru bir şekilde tahmin ettiği durumu ifade eder. Yani, model pozitif sınıfı doğru bir şekilde tanıdığına, bu değeri temsil eder. Yanlış Negatif, modelin pozitif bir örneği negatif olarak yanlış sınıflandırması durumunu gösterir. Yanlış Pozitif, modelin negatif bir örneği pozitif olarak yanlış sınıflandırması durumudur. Doğru Negatif ise, modelin negatif bir örneği doğru bir şekilde negatif olarak tahmin ettiği durumu ifade etmektedir.

Sınıflandırıcıların performansını değerlendirmek, makine öğrenmesi ve istatistiksel modelleme alanında kritik bir adımdır. Bu değerlendirme, modelin doğruluğunu, güvenilirliğini ve genellenebilirliğini belirlemek için temel bir ölçüt sağlar. Sınıflandırma modelinin başarısını anlamak, doğru tahminler yapabilmesi ve genellikle karşılaştığı farklı veri kümeleri üzerinde etkili çalışabilmesi açısından büyük önem taşır. Performansın değerlendirilmesi amacıyla en yaygın olarak doğruluk oranı (accuracy) kullanılmaktadır. Bununla birlikte, bir sınıflandırıcının performansını değerlendirmek için hangi metriğin seçileceğine ilişkin uygulayıcılar arasında genel bir kılavuz da bulunmamaktadır (Liu ve diğerleri, 2014).

Bu çalışma kapsamında performans değerlendirmesinde kullanılan ve toplam veri içindeki doğru sınıflandırılan örneklerin oranını ölçen doğruluk metriği (3) nolu

denklemden gösterildiği şekilde hesaplanmaktadır (Sokolova ve Lapalme, 2009).

$$\text{Doğruluk} = \frac{\text{Doğru Pozitif} + \text{Doğru Negatif}}{\text{Pozitif} + \text{Negatif}} \quad (3)$$

Çalışma kapsamında derin öğrenme yönteminin gelişmekte olan ülkelerin borsa endekslerinin hareket yönlerini tahmin etme performansı incelenmiştir. Gerçekleştirilen analizlerden elde edilen karışıklık matrisi ve doğruluk oranları en yüksek tahmin oranından en düşüğe doğru sıralanarak Tablo 3'te sunulmuştur.

Tablo 3
Karışıklık Matrisi ve Doğruluk Oranları

Endeks	Hareket Yönü	Gerçek Yükseliş	Gerçek Düşüş	Toplam	Doğruluk
IPC	Öngörülen Yükseliş	208	16	224	%88,47
	Öngörülen Düşüş	42	237	279	
	Toplam	250	253	503	
SSE	Öngörülen Yükseliş	186	94	280	%78,13
	Öngörülen Düşüş	14	200	214	
	Toplam	200	294	486	
BIST 100	Öngörülen Yükseliş	158	70	228	%77,29
	Öngörülen Düşüş	44	230	274	
	Toplam	202	300	502	
RTS	Öngörülen Yükseliş	157	40	197	%76,05
	Öngörülen Düşüş	80	224	304	
	Toplam	237	264	501	
BOVESPA	Öngörülen Yükseliş	147	26	173	%75,81
	Öngörülen Düşüş	94	229	323	
	Toplam	241	255	496	
IDX	Öngörülen Yükseliş	128	26	154	%75,05
	Öngörülen Düşüş	95	236	331	
	Toplam	223	262	485	
NFTY 50	Öngörülen Yükseliş	191	89	280	%74,34
	Öngörülen Düşüş	38	177	215	
	Toplam	229	266	495	

Tablo 3'te yer alan karışıklık matrisi incelendiğinde; derin öğrenme modelinin IPC endeksinin 503 günlük hareketinden 208 yükseliş ve 237 düşüş, SSE endeksinin 486 günlük hareketinden 186 yükseliş ve 200 düşüş, BİST 100 endeksinin 502 günlük hareketinden 158 yükseliş ve 230 düşüş, RTS endeksinin 501 günlük hareketinden 157 yükseliş ve 224 düşüş, BOVESPA endeksinin 496 günlük hareketinden 147 yükseliş ve 229 düşüş, IDX endeksinin 485 günlük hareketinden 128 yükseliş ve 236 düşüş, NIFTY 50 endeksinin ise 495 günlük hareketinden 191 yükseliş ve 177 düşüş hareketini doğru tahmin ettiği görülmektedir. Dolayısıyla, derin öğrenme yöntemi kullanılarak IPC endeksi %88,47, SSE endeksi %78,13, BIST 100 endeksi %77,29, RTS endeksi %76,05, BOVESPA endeksi %75,81, IDX endeksi %75,05 ve NIFTY 50 endeksi %74,34 oranında doğrulukta tahmin edilmiştir. Elde edilen bu sonuç, benzer çalışmalar olarak Nelson ve diğerleri (2017), Alhazbi ve diğerleri (2020), Santur (2020), Prachyachuwong ve Vateekul (2021), Aliyev ve diğerleri (2022) ve Noh ve diğerleri (2023) çalışmaları ile girdi verileri, derin öğrenme modeli ve elde edilen doğruluk oranları açısından karşılaştırıldığında çalışmanın bulgularının literatüre katkısı daha iyi anlaşılabilir. Söz konusu benzer çalışmalardan Brezilya Borsası'nda Bovespa Endeksi'nin hareket yönünün tahmin edildiği Nelson ve diğerleri (2017) çalışmasında, fiyat geçmişi ve teknik analiz göstergeleri kullanılarak Uzun Kısa Süreli Bellek (LSTM) ile %55,9 doğruluk oranıyla tahmin edilmiştir. Tayland Vadeli İşlemler Borsası'nda LSTM modelinin uygulandığı Prachyachuwong ve Vateekul (2021) çalışmasında ise, 15 adet teknik gösterge kullanılmış ve %61,28'lik tahmin doğruluk oranına ulaşılmıştır. Katar Borsası'nın hareket yönüne odaklanan Alhazbi ve diğerleri (2020) çalışmasında, Evrişimsel Sinir Ağı (CNN) ile geçmiş verilere ek olarak petrol fiyatları ile S&P 500 ve Nikkei endeksi de girdi verisi olarak kullanılmış ve %74 doğrulukla tahmin yapılmıştır. Santur (2020) çalışmasında ise BİST30 endeksinin 2006-2015 aralığındaki kapanış verileri eğitim, 2015-2018 aralığı kapanış verileri ise test için kullanılmış ve 694 işlem gününe ait test verileri üzerinde önerilen derin öğrenme modeli ile endeksin trend yönü %82 doğrulukla tahmin edilmiştir. Gelişmekte olan ülkelerdeki incelenen borsalarda farklı girdi ve derin öğrenme modelleri kullanılarak %55,9 ile %82 arasında doğrulukla tahmin yapıldığı görülmektedir. Bu çalışmada en yüksek doğrulukla tahmin edilen borsa endeksi IPC endeksidir. IPC endeksi, çalışmada ulaşılan en yüksek doğruluk oranı olan %88,47 doğrulukla tahmin edilmiştir. En düşük doğrulukla tahmin edilen endeks ise %74,34 doğrulukla NIFTY 50 endeksidir. Bir başka ifadeyle, geçmiş verilere ek olarak on farklı teknik gösterge ve H20 derin öğrenme modeli kullanarak yedi gelişmekte olan ülkenin ana borsa endeksi %74,34 ile %88,47 arasında değişen doğruluk oranlarıyla tahmin edilmiştir. Dolayısıyla incelenen dönemde borsa endekslerinin hareket yönlerinin başarılı bir şekilde tahmin ettiği söylenebilir.

Derin öğrenme yöntemi kullanılarak yapılan analizde, yedi farklı borsa endeksinin hareket yönü %70'in üzerinde bir doğruluk oranı ile tahmin edilmiştir. Bu sonuç, geçmiş endeks verileri ve teknik göstergeler kullanılarak borsa endekslerinin hareket yönlerinin belirli bir doğruluk seviyesinde tahmin edilebileceğini ortaya koymaktadır. Ancak,

tahmin başarısının borsa endekslerine göre farklılıklar gösterdiği de gözlemlenmiştir. İncelenen borsaların her biri, farklı piyasa dinamiklerine sahip olup, bu durum modelin performansını etkileyen önemli bir faktör olabilir. Örneğin, borsaların piyasa değeri, kayıtlı şirket sayısı, işlem hacmi, piyasa işleyişi, teknolojik alt yapı, yerel ve kurumsal yatırımcı tabanı gibi dinamikler, her borsanın davranışını farklı şekillerde şekillendiren etmenlerdir. Bu faktörler, borsa endekslerinin ticaret hacmi, volatilité düzeyi ve genel eğilimleri üzerinde önemli etkiler yaratabilir. Örneğin, yüksek işlem hacmine sahip büyük piyasa borsalarında, yatırımcıların psikolojik eğilimleri ve piyasa haberlerinin etkisi farklı olabilirken, daha küçük ve gelişmekte olan piyasalarda yerel faktörler, kurumsal yatırımlar ve teknolojik alt yapı gibi unsurlar etkili olabilir. Dolayısıyla, tahmin başarısındaki farklılıkların, borsa dinamiklerinin çeşitliliğinden kaynaklandığı düşünülmektedir.

5. Sonuç

Hisse senedi alım satımı, halka açık şirketlerin hisselerinin dünya genelinde milyonlarca aktif yatırımcının katıldığı bir borsa platformunda alınıp satıldığı bir süreçtir. İşletme politikaları, makroekonomik etkiler, küresel etkiler, teknolojik gelişmeler ve yatırımcı tercihleri gibi birçok faktör hisse senedi piyasalarını etkilemektedir. Bu etkenler, yatırımcılar için belirsizliği artırır ve fiyat hareketlerini tahmin etmeyi zorlaştırır. Hisse senedi fiyatlarının tahmin edilebilirliği konusu ise literatürde tartışmalı bir konudur. Fama'nın (1970) etkin piyasalar hipotezine göre, hisse senetleri fiyatları yeni bilgiler tarafından belirlenmektedir ve fiyatlar geçmiş bilgilerle tahmin edilemez, rastgele bir yürüyüş izler. Ancak, etkin piyasalar hipotezi ortaya atıldığından beri sürekli eleştirilmiş ve geçerliliği sorgulanmıştır. Diğer yandan, sermaye piyasalarında, hisse senedi fiyatlarının tahmini amacıyla temel ve teknik analiz olmak üzere iki ana yöntem kullanılmaktadır. Temel analizde, hisse senetleriyle ilgili ekonomi, sektör ve firma analizleri yapılarak gerçek değer belirlenmekte ve piyasa fiyatı ile karşılaştırılarak alım veya satım kararı verilmektedir. Teknik analiz ise ekonomi ve sektör analizi yapmadan, sadece geçmiş fiyat hareketleri ve işlem hacmi gibi verilere dayanarak gelecekteki fiyat hareketlerini tahmin edilmeye çalışılır. Son yıllarda teknolojik gelişmelerle birlikte, hisse senedi piyasalarında bilgisayar ve yapay zeka tabanlı makine öğrenmesi teknikleri daha yaygın bir şekilde kullanılmaktadır. Makine öğrenmesi, geçmiş ilişkileri ve eğilimleri tespit ederek geleneksel tekniklere göre daha doğru ve hızlı tahminler yapılmasını sağlamaktadır. Söz konusu tekniklerden biri olan derin öğrenme ise, yüksek boyutlu zaman serisi verilerindeki karmaşık ilişkileri ve eğilimleri tespit edebilen bir yetenek sunarak daha kesin ve hızlı tahminler yapma potansiyeli taşımaktadır.

Bu çalışma kapsamında, derin öğrenme yönteminin gelişmekte olan ülkelerin borsa endeksleri üzerindeki tahmin performansının ölçülmesi amaçlanmıştır. Bu amaç doğrultusunda gelişmekte olan ülkeler olarak bilinen E-7 ülkelerinin ana borsa endeksleri; IPC (Meksika), SSE (Çin), BIST 100 (Türkiye), RTS (Rusya), BOVESPA (Brezilya),

IDX (Endonezya) ve NIFTY 50 (Hindistan) endeksleri üzerinde uygulama yapılmıştır. Söz konusu endekslerin hareket yönlerinin tahmininde ise, derin öğrenme yöntemi olarak H20 derin öğrenme modeli kullanılmıştır. Analizlerde 01.01.2015-31.12.2024 dönemine ait günlük veri seti ile söz konusu veri setine bağlı olarak hesaplanan Hareketli Ortalama, Ağırlıklı Hareketli Ortalama, Üstel Hareketli Ortalama, MACD, CCI, RSI, Stokastik %K, Stokastik %D, William's %R ve Momentum teknik göstergeleri girdi verisi olarak kullanılmıştır. Oluşturulan tahmin modeli ile derin öğrenme yönteminin endekslerin hareket yönlerini tahmin etmedeki performansı incelenmiştir. Derin öğrenme yöntemi kullanılarak gerçekleştirilen analizler sonucunda, gelişmekte olan ülkelerin borsa endekslerinden; IPC, SSE, BIST100, RTS, BOVESPA, IDX ve NIFTY50 endeksi sırasıyla %88,47, %78,13, %77,29, %76,05, %75,81, %75,05 ve %74,34 oranında doğrulukta tahmin edilmiştir. Dolayısıyla, gelişmekte olan ülkelerin borsa endekslerinin hareket yönlerinin %70'in üzerinde doğrulukla başarılı bir şekilde tahmin edildiği söylenebilir.

Elde edilen bulgular, geçmiş borsa endeks verileri kullanılarak endeks hareket yönlerinin belirli bir düzeyde doğru bir şekilde tahmin edilebileceğini ortaya koymaktadır. Bu çerçevede, hisse senedi piyasalarının öngörülebilirliği, hem piyasa katılımcılarına hem de piyasa düzenleyicilere çeşitli avantajlar sunabilir. Hisse senedi fiyatlarının tahmin edilebilirliği, öncelikle piyasaya yapılan yatırım akışını artırarak ekonomik büyümeyi destekleyebilir. Aynı zamanda, yatırımcılar için birikimlerini koruma, işlem maliyetlerini minimize etme, yatırım fırsatlarını değerlendirme ve potansiyel risklere karşı önceden tedbir alma konularında önemli faydalar sağlayabilir. Bu durum aynı zamanda piyasa düzenleyicileri için de önem taşımaktadır. Elde edilen doğru tahminler, uygun kararlar alınması ve düzeltici önlemlerin zamanında alınması konusunda düzenleyicilere rehberlik edebilir. Ayrıca, işletme yöneticileri için de geçmiş verilere dayalı doğru analizler, firma değerlerini artırmak ve stratejik kararlar almak konusunda yardımcı olabilir. Sonuç olarak, borsa endekslerinin doğru bir şekilde tahmin edilmesi, finansal piyasaların etkinliğini artırarak genel ekonomik stabilitenin ve işletmelerin başarısının desteklenmesine katkı sağlayabilir.

Elde edilen sonuçların yanı sıra çalışma için birtakım kısıtlardan da bahsedilebilir. Uygulamanın belli bir dönem aralığı için yapılması, makroekonomik değişkenlerin kullanılmaması, tek bir modelle tahminlerin yapılması, gelişmekte olan ülkeler içerisinde yalnızca belirli bir grubun borsa endeksinin ele alınması çalışmanın kısıtları olarak sıralanabilir. Gelecekte gerçekleştirilecek çalışmalarda, mevcut literatürde bulunan çeşitli teknik göstergelerle birlikte faiz oranları, enflasyon, döviz kuru gibi makroekonomik verilerin girdi değişkenleri olarak entegre edilmesi, tahmin yönteminin doğruluk oranını artırabilir. Tahmin süreçlerinde hibrit modellerin kullanılması, daha etkili ticaret stratejilerinin oluşturulmasına katkı sağlayabilir. Ayrıca, sadece belirli bir dönem veya endeksle sınırlı kalmaksızın, farklı dönemler ve/veya farklı borsa endeksleri üzerinde uygulamalar gerçekleştirilebilir. Bu önerilen yöntemler, finansal piyasalarda daha

güvenilir ve koşullara uygun tahminler elde etme konusunda araştırmacılara ve uygulayıcılara yeni perspektifler sunabilir.

Yazarlık Beyanı: Tüm yazarlar çalışmanın tasarımı, veri toplama, analiz ve makale yazımına katkıda bulunmuştur. Tüm yazarlar makalenin son halini gözden geçirerek onaylamıştır.

Çıkar Çatışması Beyanı: Yazar(lar), araştırma, yazarlık ve yayımlama süreçlerinde herhangi bir çıkar çatışması bulunmadığını beyan eder.

Finansman: Yazar(lar), bu çalışmaya herhangi bir mali destek veya finansman sağlanmadığını beyan eder.

Etik Beyanı: Yazar(lar), bu çalışmada bilimsel ve etik ilkelere uyulduğunu ve kullanılan tüm kaynakların düzgün bir şekilde alıntalandığını beyan eder.

Kaynakça

- Albayrak, E., & Saran, N. (2023). İstatistiksel ve Derin Öğrenme Modellerini Kullanarak Hisse Senedi Fiyat Tahmini. *Türkiye Bilişim Vakfı Bilgisayar Bilimleri ve Mühendisliği Dergisi*, 16(2), 161-169. <https://doi.org/10.54525/tbbmd.1031017>
- Alhazbi, S., Said AB & Al-Maadid, (2020) Using Deep Learning to Predict Stock Movements Direction in Emerging Markets: The Case of Qatar Stock Exchange, 2020 IEEE International Conference on Informatics, IoT, and Enabling Technologies (ICIoT), Doha, Qatar, 440-444. <https://doi.org/10.1109/ICIoT48696.2020.9089616>
- Aliyev, F., Eylasov N. & Gasim, N. (2022) Applying Deep Learning in Forecasting Stock Index: Evidence from RTS Index, 2022 IEEE 16th International Conference on Application of Information and Communication Technologies (AICT), Washington DC, DC, USA, 2022, 1-4. <https://doi.org/10.1109/AICT55583.2022.10013496>
- Altunbaş, C. (2021) *Derin Öğrenme ile Hisse Senedi Piyasası Tahmini [Yüksek Lisans Tezi]*. Adnan Menderes Üniversitesi, Sosyal Bilimler Enstitüsü.
- Arora, A., Candel, A., Lanford, J., Ledel, E., & Parmar, V. (2015). Deep Learning with H2O. H2O.ai, Erişim Tarihi:22.02.2024, [DeepLearning_Vignette.pdf \(h2o-release.s3.amazonaws.com\)](https://arxiv.org/pdf/1512.03274v1.pdf)
- Ayyıldız, N. (2023) Prediction of Stock Market Movements with Machine Learning Index, Özgür Publications. <https://doi.org/10.58830/ozgur.pub354>
- Ayyıldız ve İskenderoğlu (2024) How effective is machine learning in stock market predictions? *Heliyon*, 10(2). <https://doi.org/10.1016/j.heliyon.2024.e24123>
- Ayyıldız, N. (2024). Bankacılık Sektörüne Derin Öğrenme Yöntemiyle Bakış: BİST Banka Endeksi Hareket Yönlerinin Tahmini. *İnsan ev Toplum Bilimleri Araştırmaları Dergisi*, 13(3), 1277-1291. <https://doi.org/10.15869/itobiad.1451709>
- Beniwal, M., Singh, A. & Kumar, N. (2024). Forecasting multistep daily stock prices for long-term investment decisions: A study of deep learning models on global indices, *Engineering Applications of Artificial Intelligence*, 129. <https://doi.org/10.1016/j.engappai.2023.107617>
- Cui, C., Wang, P., Li, Y. & Zhang, Y. (2023), McVCsB: A new hybrid deep learning network for stock index prediction, *Expert Systems with Applications*, 232. <https://doi.org/10.1016/j.eswa.2023.120902>
- Çetin D. Ve Metlek S (2021). Türkiye'deki İslami Hisse Senedi Endeksinin, Endeks Tabanlı Öznitelikler Kullanılarak Derin Öğrenme Yöntemi ile Tahmini. *Acta Infologica*, 5(2), 287 - 298. <http://dx.doi.org/10.26650/acin.975633>
- Gudelek, M. U. Bölük S. A. & Özbayoğlu, A. M. (2017). A deep learning based stock trading model with 2-D CNN trend detection, 2017 IEEE Symposium Series on Computational Intelligence (SSCI),

- Honolulu, HI, USA, pp. 1-8, <http://dx.doi.org/10.1109/SSCI.2017.8285188>
- Gündüz, H., Çataltepe, Z., & Yaslan, Y. (2017). Derin Sinir Ağları ile Borsa Yönü Tahmini, Stock Market Direction Prediction Using Deep Neural Networks, Signal Processing and Communications Applications Conference (SIU), İzmir.
- Han, J., Kamber, M. & Pei, J. (2012). *Data Mining: Concepts and Techniques*. Third Edition, Elsevier Science & Technology. USA.
- H2O (2024), H2O Deep Learning (Neural Networks), Erişim Tarihi:22.02.2024, <https://docs.h2o.ai/h2o/latest-stable/h2o-docs/data-science/deep-learning.html>
- Kanwal, A., Lau,M.F., P.H. Ng,S., Sım,K.Y. & Chandrasekaran,S. (2022). BiCuDNNLSTM-1dCNN-A hybrid deep learning-based predictive model for stock price prediction, *Expert Systems with Applications*, 202. <https://doi.org/10.1016/j.eswa.2022.117123>.
- Kumbure, M.M., Lohrmann C., Luukka, P.& Porras, J.(2022). Machine learning techniques and data for stock market forecasting: A literature review, *Expert Systems with Applications*,197. <https://doi.org/10.1016/j.eswa.2022.116659>.
- Liu, Y, Zhou, Y. Wen, S. & Tang, C. (2014), A Strategy on Selecting Performance Metrics for Classifier Evaluation, *International Journal of Mobile Computing and Multimedia Communication*, 6, 20-35. <http://dx.doi.org/10.4018/IJMCMC.2014100102>
- Mallikarjuna, M.& Rao, R.P. (2019), Evaluation of forecasting methods from selected stock market returns. *Financ Innov* 5(40). <https://doi.org/10.1186/s40854-019-0157-x>
- Najafabadi, M. M., Villanustre, F., Khoshgoftaar, T. M., Seliya, N., Wald, R., & Muharemagic, E. (2015). Deep learning applications and challenges in big data analytics. *Journal of big data*, 2(1), 1-21. <https://doi.org/10.1186/s40537-014-0007-7>
- Nelson, D. M. Q. Pereira A. C. M. & De Oliveira, R. A. (2017) Stock market's price movement prediction with LSTM neural networks, 2017 International Joint Conference on Neural Networks (IJCNN), Anchorage, AK, USA, pp. 1419-1426. <https://doi.org/10.1109/IJCNN.2017.7966019>
- Noh Y, Kim J-M, Hong S, Kim S. (2023), Deep Learning Model for Multivariate High-Frequency Time-Series Data: Financial Market Index Prediction. *Mathematics*.; 11(16):3603. <https://doi.org/10.3390/math11163603>
- Prachyachuwong K, & Vateekul P. (2021) Stock Trend Prediction Using Deep Learning Approach on Technical Indicator and Industrial Specific, *Information*. 12(6):250. <https://doi.org/10.3390/info12060250>
- Racz, A., Bajusz, D. & Heberger, K. (2021). Effect of Dataset Size and Train/Test Split Ratios in QSAR/QSPR, Multiclass Classification, *Molecules*, 26, 1111. <https://doi.org/10.3390/molecules26041111>.
- Raço, H. (2019). Deep Learning Based Stock Market Prediction Using Technical Indicators [Yüksek Lisans Tezi]. en Bilimleri Enstitüsü, Gazi Üniversitesi, Ankara.
- Santur, Y. (2020). Deep Learning Based Regression Approach for Algorithmic Stock Trading: A Case Study of the BIST30. *Gümüşhane Üniversitesi Fen Bilimleri Dergisi*, 10(4), 1195-1211. <https://doi.org/10.17714/gumusfenbil.707088>
- Sokolova, M. & Lapalme, G. (2009). A systematic analysis of performance measures for classification tasks. *Information Processing & Management*. 45. 427-437. <https://doi.org/10.1016/j.ipm.2009.03.002>
- Stetsenko, P. (2017), *Machine Learning with Python and H2O*, Fifth Edition, Erişim Tarihi:22.02.2024, *DeepLearning_Vignette.pdf* (h2o-release.s3.amazonaws.com)
- Yang, C. Zhai, J. & Tao, G. (2020). Deep Learning for Price Movement Prediction Using Convolutional Neural Network and Long Short-Term Memory, *Mathematical Problems in Engineering*. <https://doi.org/10.1155/2020/2746845>

- Yiling, D., Ning, S., Jiahao, X., Pengyan, L., Jiabin W. & Sai, T. (2022). Research on Shanghai Stock Exchange 50 Index Forecast Based on Deep Learning. *Mathematical Problems in Engineering*. 1-9. <http://dx.doi.org/10.1155/2022/1367920>
- Zhong, X., & Enke, D. (2019). Predicting the daily return direction of the stock market using hybrid machine learning algorithms, *Financial Innovation*, 5. <https://doi.org/10.1186/s40854-019-0138-0>.