



Derin Öğrenme Teknikleri Kullanılarak Borsadaki Hisse Değerlerinin Tahmin Edilmesi

İlker Dalkıran^{1*}, Mehmet Ozan²

^{1*} Erciyes Üniversitesi, Mühendislik Fakültesi, Elektrik - Elektronik Mühendisliği Bölümü, Kayseri, Türkiye, (ORCID: 0000-0003-2448-3556), ilkerd@erciyes.edu.tr

² Erciyes Üniversitesi, Fen Bilimleri Enstitüsü, Kayseri, Türkiye, (ORCID: 0000-0001-5206-336X) mehmet_ozan@outlook.com.tr

(3rd International Conference on Applied Engineering and Natural Sciences ICAENS 2022, July 20-23, 2022)

(DOI: 10.31590/ejosat.1145949)

ATIF/REFERENCE: Dalkıran, İ. & Ozan, M. (2022). Derin Öğrenme Teknikleri Kullanılarak Borsadaki Hisse Değerlerinin Tahmin Edilmesi *Avrupa Bilim ve Teknoloji Dergisi*, (39), 143-148.

Öz

Borsada işlem gören hisse senetlerinin fiyatlamasında, farklı tipte ve çok miktarda kuvvet etkindir. Bu kuvvetler arasındaki etkileşimlerin karmaşık olması sebebiyle fiyat hareketlerinin önceden tam doğrulukla tahmin edilmesi oldukça zordur. Ancak istatistik teorilerinden doğan ve ancak günümüz bilgisayarları ile uygulanması mümkün olan karmaşık derin öğrenme teknikleri ile bu değerlerin kısa dönem tahminleri mümkündür. Sunulan çalışmada Borsa İstanbul içerisinde işlem görmekte olan ISCTR hisse senedinin uzun dönem verilerine bakılarak günlük değer tahmini yapılmıştır. Ayrıca ilgili hisselerin verilerine ek olarak, tahmin kabiliyetini artırmak amacıyla VAKBN, GARAN, QNBFB ve AKBNK hisse senetlerinin ve USD/TRY, BIST30, BANKX endekslerinin tarihsel verileri de kullanılmıştır. Sunulan çalışmada çok değişkenli yapıda uzun kısa-dönem hafıza (Long Short-Term Memory, LSTM) algoritması Adam ve RMSProp optimize edicileri ile kullanılmış ve performansı gözlemlenmiştir.

Anahtar Kelimeler: Derin Öğrenme, Borsa, Uzun Kısa-Dönem Hafıza, LSTM, Kapılı Tekrarlayan Hücre, GRU.

Predicting Of Stock Market Using Deep Learning Techniques

Abstract

Stock market share values are affected by different and many forces. It is difficult to exactly predict share values in advance due to the fact that the interactions among these forces are complex. However, short-term estimations of these values are possible with complex deep learning techniques that arise from statistical theories and can be realized with today's computer technologies. In this study, one-day value estimation of ISCTR stock traded in the Borsa Istanbul has been made using long term data. In addition to the data of the related stock, historical data of VAKBN, GARAN, QNBFB and AKBNK stock prices and USD/TRY, BIST30 and BANKX indices were also used in the study in order to increase the estimation ability. In the proposed study, Long Short-Term Memory (LSTM) and Gated Recurrent Unit (GRU) algorithms in multivariate structure were used with Adam and RMSProp optimizers and their performances were observed.

Keywords: Deep Learning, Stock Market, Long Short-Term Memory, LSTM, Gated Recurrent Unit, GRU

* Sorumlu Yazar: ilkerd@erciyes.edu.tr

1. Giriş

Borsa; menkul kıymet, emtia, döviz, vadeli işlem ve opsiyon sözleşmelerinin halka açık olarak alınıp satıldığı ve daha da önemlisi denetlenen bir piyasadır. Sermaye piyasası, üretimi desteklerken borsa ise bu amaca ulaşmak için kullanılan mekanizmadır. Hisse senedi piyasası, yatırımcılar için güvenli bir ortam sunarken aynı zamanda düzenli olarak gerçek zamanlı işlem yapmaya ve anlık fiyatlar üzerinden alışveriş yapmaya imkan sağlar (Wikipedia, 2021; Borsa İstanbul A.Ş., 2021).

Borsa veya sermaye piyasalarının tahmini, büyük kâr imkânı sunar ve bu alandaki çoğu araştırmacı için bu durum temel bir motivasyon kaynağıdır. Pazarı tahmin etmek için çoğu araştırmacı ya teknik ya da temel analizi kullanır. Teknik analiz, gelecekteki fiyatları tahmin etmek için fiyatların yönünü analiz etmeye odaklanırken, temel analiz, finansal haberler ve kazanç raporları gibi yapılandırılmamış metin bilgilerini analiz etmeye dayanır (Birgili, 2013).

Klasik teknik ve temel analize alternatif olarak borsa hisse değerlerinin, farklı makine öğrenmesi metotları kullanılarak tahmin edilmesine ilişkin örnekler literatürde yer almaktadır.

Moghar, S&P 500 borsasına ait GOOGL ve NKE hisseleri üzerinde yapmış olduğu çalışmada, Uzun Vadeli Borsa (Long Term Stock Exchange, LTSE) tabanlı bir Tekrarlayan Sinir Ağı (Recurrent Neural Network, RNN) kullanımını önermektedir. Önerilen model, 12 iterasyonluk bir eğitim neticesinde GOOGL için 0.0011 ve NKE için 0.0019 ortalama karesel hata (Mean Squared Error, MSE) cinsinden hata ile gelecek olası hisse değerlerini tahmin etmiştir. Eğitim için gereken iterasyon sayısı 100'e çıkarıldığında MSE cinsinden hataların sırası ile 4,97E-04 ve 8,74E-04'e kadar gerilediğini belirtmiştir (Moghar, 2020).

Raço ve Demirci, yapmış olduğu çalışmada 9 katmanlı Destek Vektör Makinesi (Support Vector Machine, SVM) tipi bir yapay öğrenme modeli kullanarak BIST 30 hisse değerleri üzerinde tahminler yapmaya çalışmışlardır. 01.01.2016'dan 11.04.2018'e kadar olan borsa hisselerinin değerlerini veri seti olarak kullanmışlar ve 5 günlük borsa hisse değerlerini tahmin etmeye çalışmışlardır. Kullanmış oldukları modelin giriş değerlerini belirlerken ekonomi yöntemlerini kullanarak hesaplamış oldukları indikatör ve osilatör değerlerinden faydalanmışlardır. Sonuç olarak birinci günden beşinci güne kadar sırası ile 0.0322, 0.109, 0.09, 0.1069, 0.2581 MSE cinsinden hata ile tahminler yapmışlardır. (Raço ve Demirci, 2019).

Konstantinou, yapmış olduğu çalışmada, borsa hisse senedi değerleri üzerinde Japon Mum Grafikleri, Monte-Carlo modelleri ve binomal modeller gibi klasik metotlar yerine makine öğrenme tekniklerini kullanmayı denemiştir ve Pekıştirmeli Öğrenme (Reinforcement Learning, RL) modelini esas alan bir ileri beslemeli yapay sinir ağı kullanmıştır. Veri seti olarak Kasım-2016'dan Haziran-2017 tarihine kadar Stocholm borsasında işlem gören hisselerini tercih etmiştir. Kullanmış olduğu modelde veri setlerindeki aralığı iki dakika, on dakika, otuz dakika ve bir saat olarak kullandığında hep aynı doğrulukla tahminlerin oluştuğunu gözlemlemiştir. Oluşturmuş olduğu model ile ortalama %8 kazanç elde edildiğini raporlamıştır (Konstantinou, 2017).

İnce yapmış olduğu çalışmada, Bitcoin' in olası değerlerini farklı derin öğrenme yöntemleri kullanarak tahmin etmeye çalışmıştır ve açık, kapalı, düşük değer, hacim gibi indikatörlerin

kullanılmasının ileri beslemeli Derin Sinir Ağı (Deep Neural Network, DNN), LSTM ve GRU gibi modellerin kesinliğini arttırdığını gözlemlemiştir (İnce, 2019).

Linzie, yaptığı çalışmada, yapay sinir ağlarını kullanarak finansal analiz ve kısa vadeli borsa tahmini yapmaya çalışmıştır. Literatürdeki diğer çalışmaların aksine teknik indikatörleri kullanmamış ve stokastik gradyen inişi (Stochastic Gradient Descent) içeren bir Aşırı Öğrenme Makinesi (Extreme Learning Machine, ELM) kullanmıştır. Elde ettiği sonuçlarda algoritmanın yalnızca işlem hacmi, gün içi yüksek değer, gün içi düşük değer gibi az sayıda girdiye sahip olması sebebiyle diğer metotlardan yaklaşık olarak %18 daha hızlı eğitildiğini ve ürettiği sonuçlarda oluşan hataların ortalama %0,6 kadar daha düşük olduğunu raporlamıştır (Linzie, 2017).

Falinouss, yapmış olduğu çalışmada borsa hisse değerleri hakkında çıkan haberlerin metin madenciliği ismi verilen ve yazılı metinlerin içeriklerinin analiz edilerek sayısal değerlere dönüştürülmesini sağlayan metotlar kullanılarak sayısal olarak anlamlı değerlere dönüştürülebileceğini ve bulunan değerlerin yapay sinir ağlarında giriş değeri olarak kullanılabilceğini keşfetmiştir (Falinouss, 2007).

Gündüz ve arkadaşları yapmış oldukları bir çalışmada Borsa İstanbul içerisinde işlem gören bankaların hisselerini LSTM ve Light-GBM modellerini kullanarak tahmin etmeye çalışmış ve bu iki modelin performanslarını karşılaştırmışlardır. Hisse öz niteliklerinin sayısını azaltmak için Değişken Otokodlayıcı (Variational AutoEncoders, VAE) kullanmış ve elde ettikleri en iyi başarı değerini LSTM modeli için makro ortalama F-Skoru cinsinden 0.685 olarak belirtmişlerdir (Gunduz, Cataltepe, ve Yaslan, 2017).

Site A., 2020 yılında yapmış olduğu tez çalışmasında borsa hisselerinin tahmini üzerine literatüre girmiş çalışmaları özetlemiştir (Site, 2020).

2. Materyal ve Metot

Yapılan literatür taraması neticesinde zaman serilerinin tahmini konusunda farklı makine öğrenimi modellerinin kullanıldığı görülmüştür. Şekil 1'de bu ilişki gösterilmiştir. Bu çalışmada ise makine öğrenmesinin bir alt dalı olan derin öğrenme modelleri, hisse senedi fiyatlarının tahmininde kullanılmıştır. Derin öğrenme modelleri, derin öğrenme algoritmaları kullanılarak eğitilirler ve derin öğrenme algoritmaları her çalıştırıldığında model parametreleri güncellenerek modelin tahmin performansı geliştirilmeye çalışılır. Bu durum, insan beyninin bir durumu veya olayı her incelediğinde farklı fikirler üretmesi gibi düşünülebilir. Ayrıca derin öğrenme modelleri, öğrenmenin sağlanması için çok fazla miktarda veri setine gereksinim duyarlar (Çakır, 2019; Alpaydın, 2020).

Sunulan çalışmada tekrarlayan sinir ağlarının (RNN) özelleştirilmiş bir versiyonu olan LSTM, tahminlerde kullanılmıştır. Gizli katman sayısı, kayar pencere uzunluğu, grup boyutu (batch size) gibi parametreler değiştirilerek LSTM esaslı farklı modeller ortaya konmuş ve Python yazılım dili ile kodları yazılmıştır. Veri setlerinin hazırlanmasında Pandas ve Numpy kütüphaneleri kullanılmıştır. Modellerin hazırlanmasında TensorFlow kütüphanesinden türetilmiş Keras Kütüphanesi kullanılmıştır. Tasarlanan modeller, bir Google bulut hizmeti olan Colab üzerinde eğitilmiş olup, alt yapı olarak Google'ın tahsis etmiş olduğu Tesla T4 model GPU ve Google'ın yapay öğrenme



Şekil 1. Yapay zekâ, makine öğrenmesi ve derin öğrenme arasındaki ilişki (Figure 1. The relationship among Artificial Intelligence, Machine Learning and Deep Learning) (Jeffcok, 2018).

alanlarında kullanılmak üzere tasarlanmış olduğu yeni nesil bir işlemci modeli olan TPU (Tensor Processing Unit) kullanılmıştır (Kızrak, 2019).

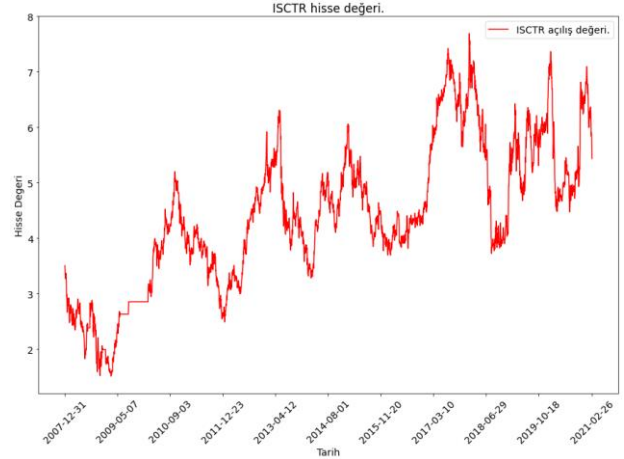
Eğitimi yapılan derin öğrenme modellerinin kararlılığını ve tahmin başarısını artırmak adına volatilitésinin düşük ve işlem hacminin büyük olması sebebiyle tercih edilen, BIST30 ve Borsa İstanbul Bankacılık Endeksi (XBANK) içerisinde yer alan, Türkiye İş Bankası A.Ş. ye ait ISCTR hissesine ilişkin veriler, kaynak veri seti olarak Yahoo Finans sitesinden alınmıştır (Yahoo Finance). Günlük fiyat hareketleri tahmin edilen bu hisseye ek olarak tahmin başarısını artırmak için veri seti içerisine Türkiye Garanti Bankası A.Ş (GARAN), Türkiye Vakıflar Bankası T.A.O (VAKBN), QNB Finansbank A.Ş (QNBFB), Akbank T.A.Ş (AKBNK) hisselerine ve XBANK, BIST30 ve Türk lirası / Amerikan doları endekslerine ait veriler de dahil edilmiştir.

Kaynak veri olarak alınan veri seti içerisinde 31.12.2007 tarihinden 28.02.2021 tarihine kadar olan kısım eğitim (train) verisi olarak kullanılmıştır. Ayrıca 01.03.2021 tarihinden 31.03.2021 tarihine kadar olan kısım, doğrulama (validation) verisi ve 01.04.2021 tarihinden 31.05.2021 tarihine kadar olan kısım ise modelin performansını ölçmek amacıyla test verisi olarak kullanılmıştır. Modelin eğitimi ve testi sırasında hisseye ait 64 günlük gün sonu fiyatları giriş olarak uygulanmış ve 65. günün kapanış fiyatı çıkış olarak alınmıştır. Buna bağlı olarak test süreci ise 2 aşama olarak gerçekleştirilmiştir. 1. aşamada kaynak verisi içerisinden alınan Nisan 2021 dönemine ait veriler tahmin edilirken 2. aşamada ise Nisan 2021 dönemine ait veriler giriş olarak kullanılmış ve Mayıs 2021 dönemi günlük fiyat hareketleri tahmin edilmiştir. Şekil 2' de ISCTR hissesine ait kaynak verisi verilmiştir (Yahoo Finance).

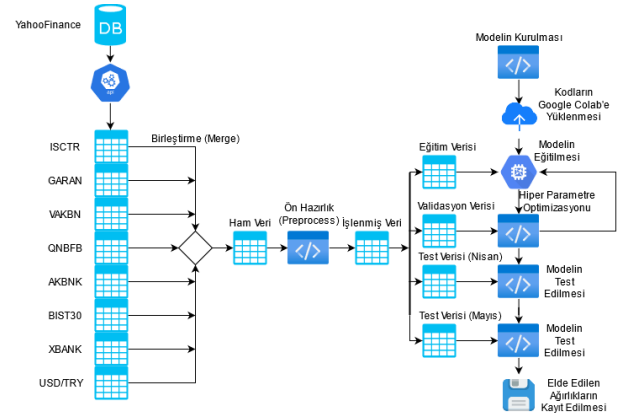
Önerilen derin öğrenme modelinin Keras Kütüphanesi kullanılarak görselleştirilmiş hali Şekil 3(a)'da verilmiştir. Şekilden görüldüğü üzere LSTM hücrelerinin her birinde 256 adet gizli katman bulunmaktadır. Düşüm seyreltme (Dropout) katmanlarının seyreltme oranları 0,2 olarak seçilmiştir. Şekil 3(b)' de ise önerilen modele ilişkin özet yer almaktadır. Model içerisinde 1.852.673 adet eğitilebilir parametre, yani başka bir deyişle ağırlık (W) bulunmaktadır.

2.1. Önerilen Modelin Performansının Ölçülmesi

Eğitimi tamamlanmış derin öğrenme modellerinin performansını ölçmek amacıyla ortalama karesel hata (Mean Squared Error, MSE), ortalama mutlak hata (Mean Absolute Error, MAE) ve ortalama bağıl hata (Mean Relative Error, MRE) şeklinde 3 farklı hata değeri hesaplanmış ve bu hata değerleri üzerinden karşılaştırma yapılmıştır.



Şekil 2. Önerilen modelin eğitiminde kullanılan ISCTR hissesine ait verilerin grafiği (Figure 2. The graph of data belongs to ISCTR stock which is used to train proposed model).



(a)

Total params: 1,852,673
Trainable params: 1,852,673
Non-trainable params: 0

(b)

Şekil 3. Önerilen modelin (a) akış şeması ve (b) özeti (Figure 3. (a) Flowchart (b) Summary of the proposed model).

Matematiksel eşitliği Denklem 1 ile verilen ortalama karesel hata, basitçe bir regresyon eğrisinin bir dizi noktaya ne kadar yakın olduğunu söyler. MSE değeri, her zaman pozitifdir ve bu değerin sifira yakın olması modelin daha iyi bir tahmin yaptığı anlamına gelir (Fitz-Gibbon, 1990).

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (1)$$

Denklem 2 ile tarif edilen ortalama mutlak hata ise her gerçek değer ile veriye en iyi uyan çizgi arasındaki ortalama dikey mesafedir (Fitz-Gibbon, 1990).

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \tilde{y}_i| \quad (2)$$

Bağıl hata, mutlak hatanın gerçek değere bölümü ile hesaplanır. Regresyon problemlerinde çok geniş bir aralıkta tahmin yapılması durumunda MSE veya MAE yerine MRE'nin kullanımı önerilir. Ortalama bağıl hata, elde edilen bağıl hataların aritmetik ortalamalarının hesaplanması ile elde edilir. Bağıl hata ve ortalama bağıl hatanın formülleri Denklem 3 ve Denklem 4 ile verilmiştir (Fitz-Gibbon, 1990).

$$RE = \frac{|y_i - \tilde{y}_i|}{y_i} \quad (3)$$

$$MRE = \frac{1}{n} \sum_{i=1}^n RE_i \quad (4)$$

3. Araştırma Sonuçları ve Tartışma

Tablo 1'de de görüleceği üzere hem GPU hem de TPU ortamlarında eğitimler yapılmış olup eğitim süreleri gözlemlenmiştir. Google tarafından Colab ortamında kullanıcıların hizmetine sunulmuş olan GPU'lar, NVIDIA markasına ait ve yapay zekâ çalışmalarında kullanılmak üzere geliştirilmiş olan Tesla T4 modelleridir. Şekil 4'de bu çalışma kapsamında önerilen derin öğrenme modelinin eğitim sürecinin her bir iterasyonuna ait zaman bilgileri verilmiştir (Ozan, 2021). Her bir iterasyonun üç saniyeden daha kısa sürmesi sebebiyle önerilen model için TPU tabanlı sistem kullanılmıştır (Ozan, 2021).

Tablo 1 incelendiğinde, yapılan eğitimler neticesinde farklı parametre değerlerine sahip, LSTM temelli modeller arasında en düşük hata değeri, 32 Batch boyutu, 64 kayar pencere uzunluğu, 256 gizli katman ve RMSProp optimize edici kullanılarak TPU ortamında eğitilen model için elde edilmiştir. Bu modelin doğrulama (validation) ve test hataları Tablo 2'de verilmiştir.

Önerilen modelin test sürecinin 1. aşamasında Nisan 2021 dönemi için ürettiği tahmini çıkışlar Şekil 5'te verilmiştir.

```
Epoch 2/1000
105/105 [=====] - 6s 61ms/step
Epoch 3/1000
105/105 [=====] - 6s 59ms/step
Epoch 4/1000
105/105 [=====] - 6s 60ms/step
```

(a)

```
Epoch 2/1000
105/105 [=====] - 9s 83ms/step
Epoch 3/1000
105/105 [=====] - 9s 84ms/step
Epoch 4/1000
105/105 [=====] - 9s 85ms/step
```

(b)

Şekil 4. LSTM temelli modelin eğitim süresi, (a) TPU tabanlı sistemde, (b) GPU tabanlı sistemde (Figure 4. Training time of the proposed model with LSTM structure on (a) TPU based hardware (b) GPU based hardware).

Şekil 5'te verilen Nisan 2021 dönemi gerçek ve tahmini çıkışlar kullanılarak hesaplanan mutlak ve bağıl hatalar sırasıyla Şekil 6 ve Şekil 7'de verilmiştir.

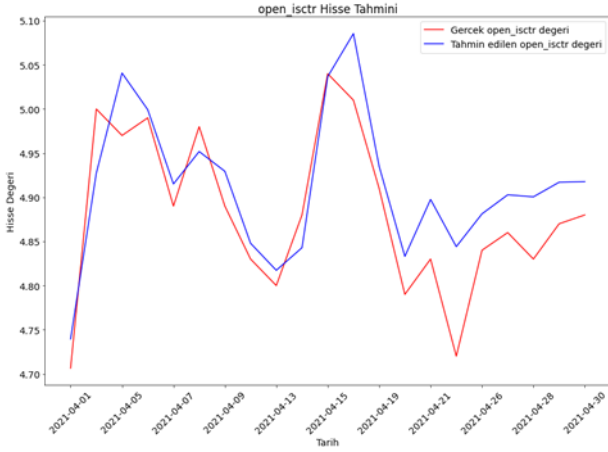
Daha öncede bahsedildiği üzere modelin eğitimi ve testi sırasında hisseye ait 64 günlük gün sonu fiyatları giriş olarak uygulanmış ve 65. günün kapanış fiyatı çıkış olarak alınmıştır. Test sürecinin 2. aşamasında ise Şekil 5'te verilen Nisan 2021 dönemine ait tahmini çıkışlar, modele giriş olarak uygulanmış ve Mayıs 2021 dönemi günlük fiyat hareketleri tahmin edilmiştir. Elde edilen sonuçlar Şekil 8'de verilmiştir.

Tablo 1. ISCTR hisse fiyatlarının tahmini için farklı parametre değerleriyle farklı platformlarda yapılan eğitimlere ait MSE hataları (Table 1. MSE errors of the training processes on different platform with different parameters to predict ISCTR stock market prices).

Batch Boyutu	Kayar Pencere Uzunluğu	Gizli Katman Sayısı	Optimize Edici	TPU ortamında eğitilmiş LSTM	GPU ortamında eğitilmiş LSTM
32	32	64	Adam	0.02812	0.02061
32	32	128	Adam	0.06096	0.01599
32	32	256	Adam	0.01886	0.01407
32	32	512	Adam	0.02275	0.05146
32	64	64	Adam	0.01671	0.01734
32	64	128	Adam	0.01487	0.02403
32	64	256	Adam	0.02447	0.01619
32	64	512	Adam	0.01993	0.02938
32	128	64	Adam	0.01899	0.02604
32	128	128	Adam	0.01540	0.01492
32	128	256	Adam	0.02449	0.03910
32	128	512	Adam	0.01813	0.03769
32	32	64	RMSProp	0.02326	0.01374
32	32	128	RMSProp	0.01511	0.03464
32	32	256	RMSProp	0.04402	0.12471
32	32	512	RMSProp	0.02166	0.04352
32	64	64	RMSProp	0.01541	0.02718
32	64	128	RMSProp	0.02853	0.07134
32	64	256	RMSProp	0.01184	0.01305
32	64	512	RMSProp	0.06555	0.02111
32	128	64	RMSProp	0.01446	0.01805
32	128	128	RMSProp	0.02267	0.01223
32	128	256	RMSProp	0.01536	0.02569
32	128	512	RMSProp	0.03352	0.04066

Tablo 2. Önerilen modele ait doğrulama ve test hataları (Table 2. Validation and Test Errors of the proposed model).

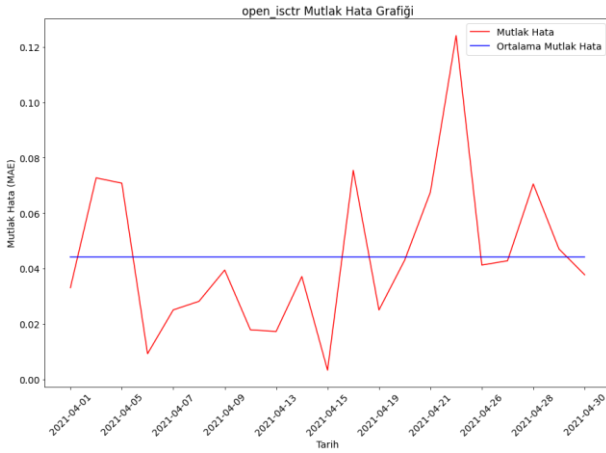
	Hata Türü	Doğrulama Hatası 01.03.2021- 01.04.2021	Test Hatası	
			01.04.2021- 30.04.2021	01.05.2021- 28.05.2021
ISCTR	MSE	0.01844	0.00269	0.00233
	MAE	0.07342	0.04379	0.04068
	MRE	0.01465	0.00900	0.00813



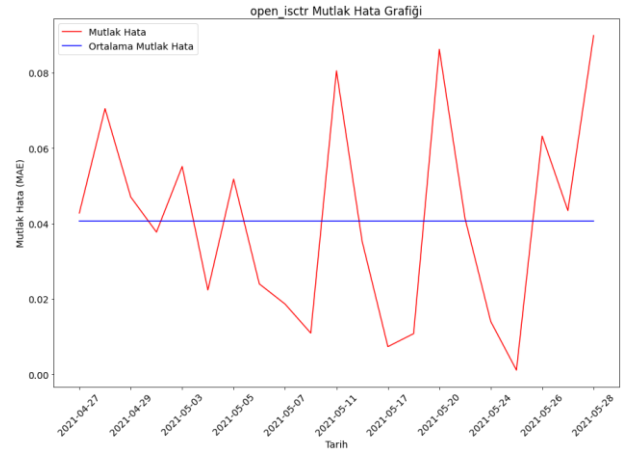
Şekil 5. LSTM temelli modelin Nisan 2021 dönemi test verisi tahmini (Figure 5. Test output of the proposed model with LSTM structure in period of 2021-April).




Şekil 8. LSTM temelli modelin Mayıs 2021 dönemi test verisi tahmini (Figure 8. Test output of the proposed model with LSTM structure in period of 2021-May)




Şekil 6. LSTM temelli modelin Nisan 2021 dönemi test verisine ait mutlak hata grafiği (Figure 6. The absolute error graph of the proposed model with LSTM structure in period of 2021-April).



Şekil 9. LSTM temelli modelin Mayıs 2021 dönemi test verisine ait mutlak hata grafiği (Figure 9. The absolute error graph of the proposed model with LSTM structure in period of 2021-May).



Şekil 7. LSTM temelli modelin Nisan 2021 dönemi test verisine ait bağıl hata grafiği (Figure 7. The relative error graph of the proposed model with LSTM structure in period of 2021-April).



Şekil 10. LSTM temelli modelin Mayıs 2021 dönemi test verisine ait bağıl hata grafiği (Figure 10. The relative error graph of the proposed model with LSTM structure in period of 2021-May).

Şekil 8'de verilen Mayıs 2021 dönemi gerçek ve tahmini çıkışlar kullanılarak hesaplanan mutlak ve bağıl hatalar sırasıyla Şekil 9 ve Şekil 10'da verilmiştir.

Şekil 3(a)'da akış şeması verilen derin öğrenme modelinin Şekil 5'de verilen Nisan 2021 dönemi tahmin başarısının, Şekil 6,

Şekil 7 ve Tablo 2 incelendiğinde kabul edilebilir düzeyde olduğu görülmektedir.

Ayrıca test sürecinin 2. aşamasında Şekil 5'te verilen Nisan 2021 dönemine ait tahmini çıkışlar, modele giriş olarak uygulanmış ve Mayıs 2021 dönemi günlük fiyat hareketleri tahmin edilmiştir. Şekil 8'de verilen Mayıs 2021 dönemine ait tahmini çıkışların da Şekil 9, Şekil 10 ve Tablo 2 incelendiğinde tatmin edici olduğu açıktır.

4. Sonuç

Bu çalışma kapsamında Borsa İstanbul dahilinde BIST 30 ve Borsa İstanbul Bankacılık endeksi (BANKX) içerisinde işlem gören Türkiye İş Bankası A.Ş. ye ait ISCTR hissesine ilişkin gün sonu kapanış fiyatları günlük olarak derin öğrenme modelleri kullanılarak tahmin edilmeye çalışılmıştır. Önerilen modelin başarısını artırmak için veri seti içerisinde Türkiye Garanti Bankası A.Ş (GARAN), Türkiye Vakıflar Bankası T.A.O (VAKBN), QNB Finansbank A.Ş (QNBFB), Akbank T.A.Ş (AKBNK) hisselerine ve XBANK, BIST30 ve Amerikan doları / Türk lirası endekslerine ait veriler de dahil edilmiştir. Eğitim ve test süreçlerinde kullanılmak üzere 31.12.2007 ~ 28.02.2021 tarihlerini kapsayan ve Şekil 2'de grafiği verilen kaynak verisi Yahoo Finance sitesinden alınmıştır.

Modelin eğitimi ve testi sırasında hisseye ait 64 günlük gün sonu fiyatları giriş olarak uygulanmış ve 65. günün kapanış fiyatı çıkış olarak alınmıştır. Buna bağlı olarak test süreci ise 2 aşama olarak gerçekleştirilmiştir. 1. aşamada kaynak verisi içerisinden alınan Nisan 2021 dönemine ait veriler tahmin edilirken 2. aşamada ise Nisan 2021 dönemine ait veriler giriş olarak kullanılmış ve Mayıs 2021 dönemi günlük fiyat hareketleri tahmin edilmiştir.

Elde edilen sonuçlar ve sunulan görseller neticesinde, iletişimin bu denli hızlı olduğu günümüzde askeri, siyasi, ekonomik, jeopolitik her türlü haber akışından oldukça fazla etkilenen borsada günlük fiyat hareketlerinin derin öğrenme modelleri ile tahmini kabul edilebilir hatalar dahilinde yapılmıştır.

Bu çalışmanın ileride yapılacak olan tek bir model ile birden çok hissenin fiyat hareketlerinin tahmini için yapılacak çalışmalara kaynak olacağı düşünülmektedir.

Kaynakça

Alpaydın, E. (2020). *Introduction to Machine Learning, Adaptive Computation and Machine Learning Series, Fourth Edition*. Cambridge, MIT Press.

Birgili, M.E. (2013). *Teknik analiz yöntemini kullanan yatırımcıların davranışsal finans modelleri ile açıklanması Türkiye'de bir araştırma*. (Yüksek Lisans Tezi, Adnan Menderes Üniversitesi, Aydın) Erişim Adresi https://tez.yok.gov.tr/UlusalTezMerkezi/TezGoster?key=iTkOhwevEenJZ3onUvs52sfD9fLcOAWqg7lqyJOSETPnLt6_FdrimGo7dQBiyw7F

Borsa İstanbul A.Ş. (2021). *Vadeli İşlem ve Opsiyon Piyasası*. Erişim adresi <https://www.borsaistanbul.com/tr/sayfa/48/vadeli-islem-ve-opsiyon-piyasasi>

Çakır, Ö. (2019). *Derin Öğrenme Nedir?*. Erişim adresi <https://www.yapayzekatr.com/2019/12/16/derin-ogrenme-nedir/>

Falinouss, P. (2007). *Stock trend prediction using news articles: a text mining approach*. (MSc Thesis, Lulea University of Technology, Lulea). Erişim adresi <http://www.diva-portal.org/smash/get/diva2:1019373/FULLTEXT01.pdf>

Fitz-Gibbon, C.T. (1990). *Performance indicators*. Clevedon, Multilingual Matters LTD.

Gunduz, H., Cataltepe, Z. ve Yaslan, Y. (2017). *Stock market direction prediction using deep neural networks*. *25th Signal Processing and Communications Applications Conference (SIU)* içinde(1-4. Ss.). Antalya, Türkiye.

İnce, N.T. (2019). *Predicting the bitcoin trend using technical indicators for deep learning algorithmic features*. (MSc Thesis, Boğaziçi University, İstanbul). Erişim adresi <https://tez.yok.gov.tr/UlusalTezMerkezi/TezGoster?key=vjszP7PzV0HebcjFEvDfwM8JDRDiftc4zmyi94wT8TnUyUBU-biobdxj7sRlpSaT>

Jeffcok, P. (2018). *What's the Difference Between AI, Machine Learning, and Deep Learning?*. Erişim adresi <https://blogs.oracle.com/bigdata/post/whatx27s-the-difference-between-ai-machine-learning-and-deep-learning#:~:text=Machine%20learning%20is%20a%20subject,to%20solve%20more%20complex%20problems>.

Kızrak, A. (2019). *Step-by-Step Use of Google Colab's Free TPU*. Erişim adresi <https://heartbeat.fritz.ai/step-by-step-use-of-google-colab-free-tpu-75f8629492b3>.

Konstantinou, R. (2017). *Stock market prediction using artificial neural networks*. (MSc Thesis, Chalmers University of Technology, Gothenburg). Erişim adresi <https://publications.lib.chalmers.se/records/fulltext/256121/256121.pdf>

Linzie, A. (2017). *Financial analysis with artificial neural networks short-term stock market forecasting*. (Undergraduate Honors Theses Gardner-Webb University, Cleveland). Erişim adresi <https://digitalcommons.gardnerwebb.edu/cgi/viewcontent.cgi?article=1006&context=undergrad-honors>

Moghar, A. (2020). *Stock Market Prediction Using LSTM Recurrent Neural Network*. *Procedia Computer Science*, 170, 1168-1173.

Ozan, M. (2021). *Derin öğrenme teknikleri kullanılarak borsadaki hisse değerlerinin tahmin edilmesi*. (Yüksek Lisans Tezi, Erciyes Üniversitesi, Kayseri). Erişim adresi https://tez.yok.gov.tr/UlusalTezMerkezi/TezGoster?key=8tbPippmWV_b-Irrn9YEAgQPn0J8uqy13m_LpjiALSWhF4xBuEhNOI_BdTAAET7M

Raço, H. ve Demirci, M. (2019). *Predicting the Turkish Stock Market BIST 30 Index Using Deep Learning*. *Uluslararası Mühendislik Araştırma ve Geliştirme Dergisi*, 11, 7-8.

Site, A. (2020). *Stock market prediction using machine learning models*. (Yüksek Lisans Tezi, Dokuz Eylül Üniversitesi, İzmir). Erişim adresi <https://tez.yok.gov.tr/UlusalTezMerkezi/TezGoster?key=f10Kw4p1rmMDotyKRdYv1GqKGm8UNSWJBWEHU-M2VMQbX6VNTIKchZgQePYi5LVf>

Wikipedia. (2021). *Borsa*. Erişim adresi <https://tr.wikipedia.org/wiki/Borsa>

Yahoo Finance. *İş Bankası A.Ş. ye Ait ISCTR Hisselerinin Geçmiş Verileri* içinde. Erişim adresi <https://finance.yahoo.com/quote/ISCTR.IS/history?p=ISCTR.IS>