



## Uzun-Kısa Süreli Bellek Ağı Kullanarak Hisse Senedi Fiyatı Tahmini

Mahmut TOKMAK<sup>1\*</sup>

<sup>1</sup> Asst. Prof. Dr., Burdur Mehmet Akif Ersoy University, Bucak Zeliha Tolunay School of Applied Technology and Management, Department of Management Information Systems, Burdur, Türkiye

Geliş Tarihi/Received: 18.08.2022  
Kabul Tarihi/Accepted: 20.09.2022

Doi: 10.31200/makuubd.1164099  
Araştırma Makalesi/Research Article

### ÖZET

Finansal sistemin en önemli işlemlerden biri hisse senedi alım satımlarıdır. Hisse senedi fiyat verileri finansal zaman serisi olarak ele alınmaktadır. Zaman serisi analizleri kullanılarak yapılan hisse senedi fiyat tahminleri, borsaya kote olmuş hisse senetlerinin gelecekteki değerini belirleme faaliyetidir. Hisse senedinin fiyatını doğru tahmin etmek, yatırımcıların alacağı kararlarda risk faktörünü azaltmaktadır. Bu yüzden yatırımcı için önem arz eden bir konudur. Ancak hisse senedi fiyatını etkileyen birçok değişken olduğu için, tahmin etmesi oldukça karmaşık bir süreçtir. Makine öğrenme yöntemleri özellikle de derin öğrenme algoritmaları birçok alanda olduğu gibi finans alanında da tahminlemede sıkça kullanılmaktadır. Bu çalışmada, derin öğrenme yöntemlerinden olan Uzun-Kısa Süreli Bellek ağları kullanarak hisse senedi fiyatı tahmini yapılmıştır. Borsa İstanbul, Teknoloji Endeksi kapsamındaki dört hisse senedi belirlenerek 2012-2022 yılları arasında 2578 günlük bir veri seti oluşturulmuş ve kurulan model ile eğitim ve test işlemi gerçekleştirilmiştir. Test işlemi sonucunda tutarlı ve gerçeğe yakın tahminler elde edilmiştir.

**Anahtar kelimeler:** Derin Öğrenme, Uzun-Kısa Süreli Bellek Ağı, Hisse Senedi Fiyatı Tahmini.

## Stock Price Prediction Using Long-Short-Term Memory Network

### ABSTRACT

One of the most important transactions of the financial system is stock trading. Stock price data is handle as a financial time series. Stock price predictions using time series analysis are the

activity of determining the future value of stocks listed on the stock market. Predicting the price of the stock correctly reduces the risk factor in the decisions to be taken by the investors. Therefore, it is an important issue for the investor. However, because there are many variables that affect the stock price, it is a very complex process to predict. Machine learning methods, especially deep learning algorithms, are frequently used in prediction in the field of finance, as in many other fields. In this study, stock price prediction was made using Long-Short-Term Memory networks, which is one of the deep learning methods. Four stocks within the scope of Borsa İstanbul Technology Index were determined and a 2578-day data set was created between 2012 and 2022, and training and testing was carried out with the established model. As a result of the test process, consistent and realistic predictions were obtained.

**Keywords:** Deep Learning, Long-Short-Term Memory Network, Stock Price Prediction.

## 1. GİRİŞ

Son yıllarda, hızlı ekonomik gelişme ile birlikte finansal faaliyetlerin sayısı giderek artmakta ve daha karmaşık hale gelmektedir. Finansal veriler, özellikle hisse senedi endeksi verileri, genellikle birden fazla faktörden etkilenen bir zaman serisi olarak ele alınmaktadır. Bu faktörler genel olarak makro ve mikro tipte faktörler olarak sınıflandırılabilir. Bunlar piyasayı uzun vadeli bir ölçekte etkileyen makro faktörler (ekonomik politikalar veya ulusal gayri safi yurtiçi hasıla vb.) ve piyasayı mikro ölçekte etkileyen mikro değişkenlerdir (rastgele olaylar, yatırımcıların mantıksız duygusal dalgalanmaları ve piyasa söylentileri vb.) (Yu & Yan, 2020).

Birçok faktörün etkili olduğu hisse senedi piyasası, dinamik, öngörülemeyen ve doğası gereği doğrusal olmayan bir piyasa olarak nitelendirilir (Sezer vd., 2020). Dinamik bir sistem olan finansal piyasalarda makro ve mikro faktörler analiz edilerek kararlar alınabilir. Ancak bu faktörler sıklıkla değiştiği için tüm makro ve mikro faktörleri toplamak ve bunların etkilerinin boyutlarını belirlemek neredeyse imkansızdır. Bu nedenle, finansal zaman serisi tahmini, genellikle zaman serileri ve makine öğrenimi ile ilgili literatürde zor araştırma alanlarından biri olarak görülmektedir (Yu & Yan, 2020).

Zaman serisi uygulamaları; elektrik sinyali analizi, dil işleme, konuşma tanıma, trafik analizi, hava tahmini, rüzgar hızı tahmini, kirlilik tahmini, işsizlik oranı analizi, enflasyon dinamikleri analizi ve diğerleri gibi birçok alanda geniş bir uygulama yelpazesine sahiptir (Althelaya vd., 2018; Wang vd., 2016). Temel anlamda bir zaman serisi, belirli bir zaman

periyodu boyunca kronolojik sırada düzenli aralıklarla herhangi bir ölçüm veya gözlem dizisidir. Zaman serilerinin analizi, veri modellerini karakterize etmek ve modellemek için istatistiksel teknikleri içerir. Sıralı verileri modellemek için yaygın stokastik modeller bulunmaktadır. Bunlardan en öne çıkanları Otoregresif (AR), Otoregresif Hareketli Ortalama (ARMA) ve Otoregresif Entegre Hareketli Ortalama (ARIMA) modelleridir (Althelaya vd., 2018; Siami-Namini vd., 2018).

Finans sektörü, finansal zaman serisi verileri kullanarak yapılan, tahminlemeye yönelik yöntemlerle her zaman ilgilenmiştir. Klasik zaman serisi tahmin tekniklerinden nispeten daha iyi performansa sahip makine öğrenme modelleri üzerine çok sayıda çalışma yayınlanmıştır (Sezer vd., 2020). Günümüzde, hisse senedi fiyatlarını tahmin etmek için teknik veya temel analize dayalı gelişmiş akıllı teknikler kullanılmaktadır. Özellikle borsa analizi için veri boyutunun çok büyük ve aynı zamanda doğrusal olmadığı düşünüldüğünde bu veri çeşitliliği ile başa çıkmak için, büyük veri setindeki gizli kalıpları ve karmaşık ilişkileri tanımlayabilen verimli modellere ihtiyaç vardır. Bu alandaki makine öğrenimi tekniklerinin, geçmiş yöntemlere kıyasla verimliliği %60-86 oranında artırdığı çalışmalarda gösterilmiştir (Vijh vd., 2020). Bunun yanı sıra, otomatik elektronik ticaret sistemlerinin yaygın olarak uygulanması, daha yüksek verim için artan taleple birleştiğinde, araştırmacıları ve uygulayıcıları daha iyi modeller uygulamak için çalışmaya devam etmeye zorlamaktadır. Bu nedenle, finans ve hesaplamalı zeka literatürüne yeni yayınlar ve uygulamalar eklemeye devam etmektedir (Sezer vd., 2020) .

Bu alandaki önceki çalışmaların çoğu, hisse senedi fiyatlarını tahmin etmek için doğrusal regresyon (Gururaj vd., 2019; Morris vd., 2018; Panwar vd., 2021), Rastgele Yürüme Teorisi (RWT) (Aggarwal, 2018; Daver vd., 2013), Hareketli Ortalama Yakınsama / Iraksama (MACD) (Ahmar, 2019; M'ng, 2018), Otoregresif Hareketli Ortalama (ARMA) (Chopra, 2019; Saxena vd., 2018; Singh vd., 2021), Otoregresif Entegre Hareketli Ortalama (ARIMA) (Almasarweh & Alwadi, 2018; Madhuri vd., 2020; Singh vd., 2021) gibi klasik algoritmalar kullanmışlardır. Son çalışmalar, borsa tahminini makine öğrenimi kullanılarak geliştirilebileceğini göstermektedir. Destek Vektör Makinesi (Gururaj vd., 2019; Panwar vd., 2021; Reddy vd., 2020), Rastgele Orman (Elagamy vd., 2018; Nti vd., 2019; Polamuri vd., 2019; Vijh vd., 2020) [10], Yapay Sinir Ağı (H. Hu vd., 2018; Moghaddam vd., 2016; Vijh vd., 2020), Evrimsel Sinir Ağı , Tekrarlayan Sinir Ağı ve Uzun Kısa Süreli Bellek (LSTM) gibi derin sinir ağları da umut verici sonuçlar sergilemişlerdir (Hossain vd., 2018; Z. Hu vd., 2021;

Mehtab & Sen, 2019, 2020; Mehtab vd., 2020; Rezaei vd., 2021; Sunny vd., 2020; Vijh vd., 2020).

Bu çalışmada, öngörülemeyen finansal zaman serilerinin tahminlemesine yönelik, derin öğrenme tekniklerinden olan yeni bir LSTM ağı önerilmiştir. Dünyadaki ülkeler ekonomik gücünü artırma noktasında ileri teknoloji ürünlerinin üretimine ve üretim esnasında bu teknolojiyi kullanmaya odaklanmıştır. Teknolojinin ülke ekonomisinin büyümesine ve üretkenliğine etkisinin olduğu ifade edilmiştir (Kanat, 2018). Bu nedenle de çalışma kapsamındaki örnek hisse senetleri Borsa İstanbul (BIST) Teknoloji Endeksi (XUTEK) kapsamında belirlenmiştir. Elde edilen veri seti ile yapılan eğitim ve test sonuçları istatistiksel değerlendirme kriterleri ile değerlendirilmiştir.

## **2. MATERYAL VE METOD**

### **2.1. Veri Seti**

Tahminlemede kullanılan BIST XUTEK kapsamındaki Aselsan Elektronik Sanayi ve Ticaret A.Ş.'ye ait ASELS, Alcatel Lucent Teletas Telekomünikasyon A.Ş. ye ait ALCTL, Karel Elektronik Sanayi ve Ticaret A.Ş.'ye ait KAREL, Netaş Telekomünikasyon A.Ş.'ye NETAS hisse senetleri rastgele olarak seçilmiştir. Çalışmada kullanılan firma hisse senetlerine ait veriler, 01.08.2012 tarihi ile 29.07.2022 tarihi aralığında olup, 2578 günlük veri içermektedir. Veri kümesinde yer alan hisse senetlerine ilişkin veriler, Yahoo Finans sitesinden elde edilmiştir ("Yahoo Finance", 2022). BIST100 ve Türk lirası/Amerikan doları endekslerine ait veriler tahmin başarısını artırmak amacıyla veri setine dahil edilmiş ve her bir ele alınan hisse senedine ait veriler ayrı ayrı eğitim ve teste tabi tutulmuştur.

Veri setini 0-1 aralığına dönüştürmek amacıyla Eşitlik (1)'de verilen normalizasyon işlemi uygulanmıştır (İleri vd., 2020). Normalizasyon işlemi Python programlama dili, sklearn kütüphanesinden MinMaxScaler fonksiyonu kullanılarak yapılmıştır.

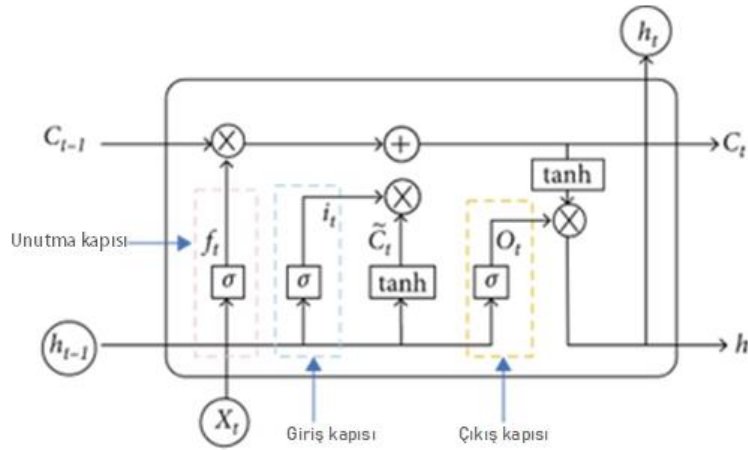
$$z = \frac{x - \min(x)}{\max(x) - \min(x)} \quad (1)$$

### **2.2. Tekrarlayan Sinir Ağı ve Uzun-Kısa Süreli Bellek Ağı**

Tekrarlayan sinir ağı (TSA), ileri beslemeli sinir ağının bir varyasyonudur. İleri beslemeli sinir ağı, her katmanın nöronlardan oluştuğu ve katmanlar arasındaki tüm bağlantıların aynı yönü izlediği, birbiri üzerine yığılmış katmanlardan oluşur. TSA, her bir

düğümün (nöron) kendi kendine bağlanmasıyla gerçekleştirilen döngüsel yapıyı sinir ağına getirmiştir. Kendi kendine bağlı nöronlar kullanılarak, geçmiş girdiler TSA tarafından 'hafızaya alınabilir' ve bu nedenle ağ çıkışını etkileyebilir (Fan vd., 2017; Naik & Mohan, 2019; Yang vd., 2021). TSA'da çıkarım süreci, ileri yayılma ile tamamlanan ileri beslemeli sinir ağına benzer. İleri beslemeli sinir eğitimi geri yayılım ile yapılır. TSA'larda eğitim ise zaman içinde geri yayılım mekanizması (backpropagation through time) ile yapılır (Fan vd., 2017). Ağırlıkların güncellenmesi kullanılan değer Gradyan olarak ifade edilir. TSA'lardaki her çıkıştaki Gradyan sadece o andaki katmana değil de bir önceki katmana da bağlıdır. Zaman aralıklarında geri yayılma sürekli olarak yenilenir ise gradyan sifıra yaklaştırmaya başlayabilir akabinde de zayıflayan Gradyan sorunu ortaya çıkabilmektedir. Benzer olarak Gradyanlar birden büyük olduğunda sonuç büyüyebilir ve patlayan Gradyan sorunu ortaya çıkabilmektedir (Metin & Karasulu, 2019).

LSTM derin öğrenme algoritması, TSA mimarisinin bahsedilen dezavantajlarının üstesinden gelmek için 1997 yılında Hochreiter ve Schmidhuber tarafından tanıtılan tekrarlayan bir sinir ağı olarak bilinir (Hochreiter & Schmidhuber, 1997). LSTM ve geleneksel TSA arasındaki fark, LSTM'deki her düğümün bir bellek hücresi olmasıdır. LSTM, önceki veri bilgilerini mevcut düğümlere bağlar. Her düğüm üç kapı içerir: giriş kapısı, unutma kapısı ve çıkış kapısı (Tsai vd., 2018).



Şekil 1. LSTM mimarisi

**Kaynak:** Lu vd., 2020

LSTM ağlarında öncelikle  $X_t$  ve  $h_{t-1}$  bilgileri giriş olarak kullanılır ve verilerin hangisinin silineceği kararlaştırılır. Bu işlemler, Eşitlik (2) kullanılarak unutma katmanında ( $f_t$ ) yapılır ve sigmoid aktivasyon fonksiyonu kullanılır. Daha sonra yeni verilerin belirleneceği giriş katmanı devreye girer ve ilk olarak ( $i_t$ ) veriler Eşitlik (3) kullanılarak sigmoid fonksiyonu

ile güncellenir. Daha sonra Eşitlik (4) ile yeni veriyi oluşturacak aday veri tanh fonksiyonu ile belirlenir. Yeni veri Eşitlik (5) ile oluşturulur. Son olarak, çıkış katmanında Eşitlik (6) ve Eşitlik (7) kullanılarak çıkış verileri elde edilir. Ağırlık parametreleri ( $W$ ) ve bias parametreleri ( $b$ ), gerçek değerler ile LSTM çıkış değerleri arasındaki farkı en aza indirecek şekilde ağ modeli tarafından öğrenilir (Xiao & Yin, 2019).

$$f_i = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (2)$$

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (3)$$

$$\tilde{C}_t = \tanh(W_C \cdot [h_{t-1}, x_t] + b_C) \quad (4)$$

$$C_t = f_t * C_{t-1} + i_t * \tilde{C} \quad (5)$$

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (6)$$

$$h_t = o_t * \tanh(C_t) \quad (7)$$

Çalışmada önerilen modelin tahmin performansını değerlendirmek için dört farklı istatistiksel değerlendirme kriteri kullanılmıştır. Bu kriterler; determinasyon katsayısı ( $R^2$  veya R-squared) Eşitlik (8)'de, kök ortalama kare hata (Root Mean Square Error-RMSE) Eşitlik (9)'da, ortalama kare hata (Mean Square Error- MSE) Eşitlik (10)'da, Ortalama Mutlak Yüzde Hata (Mean Absolute Percent Error-MAPE) Eşitlik (11)'de verilmiştir (Chicco vd., 2021; Delavar vd., 2019; Liu vd., 2020).

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (\hat{y}_i - \bar{y})^2} \quad (8)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}} \quad (9)$$

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y})^2 \quad (10)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \frac{|y_i - \hat{y}|}{y_i} * 100 \quad (11)$$

İstatistiksel değerlendirme kriterleri için kullanılan Eşitlik (8)-(11)'deki  $n$  örnek sayısını,  $y_i$   $i$ . gözlemin gerçek değerini,  $\hat{y}_i$   $i$ . gözlemin tahmini değerini ve  $\bar{y}$  gerçek gözlem değerlerinin ortalamasını temsil eder.


Önerilen LSTM modelinin eğitilmesi ve test edilmesi işlemleri için Google Colaboratory bulut sistemi kullanılmıştır. Bu sistem içerisinde birçok Python kütüphanesini

hazır olarak bulundurmakta ayrıca ücretsiz olarak hizmet vermektedir (“Google Colaboratory”, 2022). Colab platformunda Nvidia CUDA teknolojisi kullanılarak GPU desteği ile algoritmaların koşumu hızlandırılmıştır. Dosya yükleme, veri ön işleme, veri çerçevesinin ayarlanması vb. işlemlerde Python numpy, pandas, statistics, matplotlib.pyplot, seaborn kütüphaneleri kullanılmıştır. Önerilen LSTM mimarisi içinse Python Tensorflow Keras kütüphanesi kullanılmıştır. Kurulan LSTM ağı 3 katmandan oluşmakta ve her katmanda 80 nöron bulunmaktadır. dropout oranı 0.2, Loss parametresi Mean Square Error, optimizer parametresi adam, Epoch parametresi 100 olarak ayarlanmıştır.


Önerilen modelde veri setinin %80’i eğitim ve %20’si test olmak üzere ayrılmıştır. ALCTL hisse senedine ait eğitim ve test verilerini içeren grafik Şekil 2’de, ASELS hisse senedine ait eğitim ve test verilerini içeren grafik Şekil 3’te, KAREL hisse senedine ait eğitim ve test verilerini içeren grafik Şekil 4’te, NETAS hisse senedine ait eğitim ve test verilerini içeren grafik Şekil 5’te gösterilmiştir. Modelin eğitimi ve testi sırasında hisseye ait 60 günlük veriler giriş olarak uygulanmış ve 61. günün kapanış fiyatı çıkış olarak alınmıştır.




Şekil 2. ALCTL hisse senedi eğitim ve test verileri



Şekil 3. ASELS hisse senedi eğitim ve test verileri



Şekil 4. KAREL hisse senedi eğitim ve test verileri



Şekil 5. NETAS hisse senedi eğitim ve test verileri

### 3. BULGULAR

Kurulan LSTM modeli eğitildikten sonra yapılan test sonucunda; belirlenen performans metrikleri olan MSE, RMSE, MAPE ve  $R^2$ , sırasıyla ALCTL için 1,5037, 1,2263, 0,0344, 0,8634, ASELS için 0,4784, 0,6917, 0,0252, 0,9675, KAREL için 0,1373, 0,3705, 0,0269, 0,9740, NETAS için 0,4688, 0,6847, 0,0224, 0,9823, 0,90, 9,43 ve 5,99 olarak elde edilmiş ve Tablo 1’de gösterilmiştir.


**Tablo 1.** LSTM test sonuçları

HİSSE SENEDİ	MSE	RMSE	MAPE	R2
ALCTL	1,5037	1,2263	0,0344	0,8634
ASELS	0,4784	0,6917	0,0252	0,9675
KAREL	0,1373	0,3705	0,0269	0,9740
NETAS	0,4688	0,6847	0,0224	0,9823


Çalışmada kullanılan hisse senetlerinin test için ayrılan kısmına ait tahmini değerlerin ve gerçekleşen değerlerin grafik üzerindeki gösterimi Şekil 6-9’da verilmiştir. Görsellerde yer alan grafikler incelendiğinde ve elde edilen performans ölçütleri literatür ışığında




değerlendirildiğinde önerilen LSTM modeli ile yapılan analizler sonucunda tahmini değerlerin gerçek değerlere yakın sonuçlar ürettiği gözlemlenmektedir.




Şekil 6. ALCTL hisse senedine ait gerçek ve tahmin edilen değerler



Şekil 7. ASELS hisse senedine ait gerçek ve tahmin edilen değerler



Şekil 8. KAREL hisse senedine ait gerçek ve tahmin edilen değerler



Şekil 9. NETAS hisse senedine ait gerçek ve tahmin edilen değerler

#### 4. TARTIŞMA VE SONUÇ

Borsa tahminlemesi, gürültülü ve doğrusal olmayan istikrarsız hisse senedi verileri nedeniyle hisse senedi fon yöneticileri ve finansal analistler için zor bir konudur.

Bu çalışmada, hisse senedi değerlerini tahmin etmek için bir derin öğrenme yaklaşımı olan LSTM modeli önerilmiştir. Önerilen modelin eğitilmesi ve performansının değerlendirilmesi için 01.08.2012 tarihi ile 29.07.2022 tarihleri arasında (BIST) Teknoloji Endeksi (XUTEK) kapsamındaki ASELS, ALCTL, KAREL, NETAS hisse senedi verileri kullanılmıştır. Bu veriler eğitim ve test setleri olarak iki gruba ayrılmıştır. Eğitim verileri sadece modelin öğrenme sürecinde kullanılırken, test verileri öğrenme sürecinde kullanılmamıştır. Modelin öğrenme süreci tamamlandıktan sonra algoritmanın performansı değerlendirilirken test verileri kullanılmıştır. Önerilen LSTM modelinin tahmin performansını değerlendirmek için dört farklı istatistiksel değerlendirme kriteri kullanılmıştır. Bu kriterler şunlardır: MSE, RMSE, MAPE,  $R^2$ . Spesifik olarak  $R^2$  değeri göz önüne alındığında 1'e yakın elde edilen tahmin değerlerinin, modelin tutarlılığına ve doğruluğuna işaret etmektedir (Sevinç & Buket, 2021). Yapılan testler sonucu 0,8634 ile 0,9823 arasında elde edilen skorlar önerilen modelin tahmin doğruluğunun yüksek olduğunu göstermektedir. Test sonucunda yüksek tahmin değerleri elde edilmiştir. Hisse senedi tahmin doğruluğunun gerçeğe yakın değerler elde edilerek geliştirilmesinin finans çevreleri açısından önemli olumlu etkileri olacağı sonucuna varılmıştır.

## ÇATIŞMA BEYANI

Çalışma kapsamında herhangi bir kurum veya kişi ile çıkar çatışması bulunmamaktadır.

## REFERENCES / KAYNAKLAR

- Aggarwal, D. (2018). Random walk model and asymmetric effect in Korean composite stock price index. *Afro-Asian Journal of Finance and Accounting*, 8(1), 85-104.
- Ahmar, A. S. (2019). Sutte Indicator: An approach to predict the direction of stock market movements. *Songklanakarın J. Sci. Technol.*, 40(5), 1229-1231.
- Almasarweh, M., & Alwadi, S. (2018). ARIMA model in predicting banking stock market data. *Modern Applied Science*, 12(11), 309.
- Althelaya, K. A., El-Alfy, E. S. M., & Mohammed, S. (2018). Evaluation of bidirectional LSTM for short-and long-term stock market prediction. *2018 9th International Conference on Information and Communication Systems (ICICS)* (pp. 151-156).
- Chicco, D., Warrens, M. J., & Jurman, G. (2021). The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation. *PeerJ Computer Science*, 7, e623. doi: 10.7717/peerj-cs.623.
- Chopra, N. (2019). Time and frequency analysis using the ARMA model: Evidence from the Indian Stock Market. In *Advances in Management Research* (pp. 101-114). CRC Press.

- Daver, G., Karacaer, M., & Ünlü, H. (2013). Testing of BIST and TURKDEX: Random walk and market efficiency. *International Journal of Economics and Finance Studies*, 5(2), 10-22.
- Delavar, M., Gholami, A., Shiran, G., Rashidi, Y., Nakhaeizadeh, G., Fedra, K., & Hatefi Afshar, S. (2019). A novel method for improving air pollution prediction based on machine learning approaches: A case study applied to the capital city of Tehran. *ISPRS International Journal of Geo-Information*, 8(2), 99. doi: 10.3390/ijgi8020099.
- Elagamy, M. N., Stanier, C., & Sharp, B. (2018). Stock market random forest-text mining system mining critical indicators of stock market movements. *2018 2nd international conference on natural language and speech processing (ICNLSP)* (pp. 1-8).
- Fan, J., Li, Q., Hou, J., Feng, X., Karimian, H., & Lin, S. (2017). A spatiotemporal prediction framework for air pollution based on deep RNN. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, IV-4/W2, 15-22. doi: 10.5194/isprs-annals-IV-4-W2-15-2017.
- Google Colaboratory. (2022). *Colaboratory*. Erişim tarihi: 10.08.2022, <https://colab.research.google.com/>
- Gururaj, V., Shriya, V. R., & Ashwini, K. (2019). Stock market prediction using linear regression and support vector machines. *Int J Appl Eng Res*, 14(8), 1931-1934.
- Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural Computation*, 9(8), 1735-1780. doi: 10.1162/neco.1997.9.8.1735
- Hossain, M. A., Karim, R., Thulasiram, R., Bruce, N. D., & Wang, Y. (2018). Hybrid deep learning model for stock price prediction. *2018 Ieee Symposium Series on Computational Intelligence (SSCI)* (pp. 1837-1844).
- 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.
- Hu, Z., Zhao, Y., & Khushi, M. (2021). A survey of forex and stock price prediction using deep learning. *Applied System Innovation*, 4(1), 9.
- İleri, S., Karabina, A., & Kılıç, E. (2020). Comparison of different normalization techniques on speakers' gender detection. *Mehmet Akif Ersoy Üniversitesi Uygulamalı Bilimler Dergisi*, 2(2), 1-12.
- Kanat, E. (2018). Türkiye'nin teknoloji sektörü ve döviz kurları ile ilişkisi: Borsa İstanbul teknoloji endeksi. *Finans Politik & Ekonomik Yorumlar*, 55(645), 61-74.
- Liu, D., Lee, S., Huang, Y., & Chiu, C. (2020). Air pollution forecasting based on attention- based LSTM neural network and ensemble learning. *Expert Systems*, 37(3), e1251. doi: 10.1111/exsy.12511
- Lu, W., Li, J., Li, Y., Sun, A., & Wang, J. (2020). A CNN-LSTM-based model to forecast stock prices. *Complexity*, 2020, 1-10.
- Madhuri, C. R., Chinta, M., & Kumar, V. P. (2020). Stock market prediction for time-series forecasting using prophet upon arima. *2020 7th International Conference on Smart Structures and Systems (ICSSS)* (pp. 1-5).
- Mehtab, S., & Sen, J. (2019). A robust predictive model for stock price prediction using deep learning and natural language processing. *arXiv preprint arXiv:1912.07700*.
- Mehtab, S., & Sen, J. (2020). Stock price prediction using convolutional neural networks on a multivariate timeseries. *arXiv preprint arXiv:2001.09769*.
- Mehtab, S., Sen, J., & Dutta, A. (2020). Stock price prediction using machine learning and LSTM-based deep learning models. *Symposium on Machine Learning and Metaheuristics Algorithms, and Applications* (pp. 88-106), Springer.
- Metin, İ. A., & Karasulu, B. (2019). İnsan aktivitelerinin sınıflandırılmasında tekrarlayan sinir ağı kullanan derin öğrenme tabanlı yaklaşım. *Veri Bilimi*, 2(2), 1-10.

- M'ng, J. C. P. (2018). Dynamically Adjustable Moving Average (AMA') technical analysis indicator to forecast Asian Tigers' futures markets. *Physica A: Statistical Mechanics and its Applications*, 509, 336-345.
- Moghaddam, A. H., Moghaddam, M. H., & Esfandyari, M. (2016). Stock market index prediction using artificial neural network. *Journal of Economics, Finance and Administrative Science*, 21(41), 89-93.
- Morris, K. J., Egan, S. D., Linsangan, J. L., Leung, C. K., Cuzzocrea, A., & Hoi, C. S. (2018). Token-based adaptive time-series prediction by ensembling linear and non-linear estimators: A machine learning approach for predictive analytics on big stock data. *2018 17th IEEE International Conference on Machine Learning and Applications (ICMLA)* (pp. 1486-1491).
- Naik, N., & Mohan, B. R. (2019). Study of stock return predictions using recurrent neural networks with LSTM. *International Conference on Engineering Applications of Neural Networks* (pp. 453-459), Springer.
- Nti, K. O., Adekoya, A., & Weyori, B. (2019). Random forest based feature selection of macroeconomic variables for stock market prediction. *American Journal of Applied Sciences*, 16(7), 200-212.
- Panwar, B., Dhuriya, G., Johri, P., Yadav, S. S., & Gaur, N. (2021). Stock market prediction using linear regression and SVM. *2021 International Conference on Advance Computing and Innovative Technologies in Engineering (ICACITE)* (pp. 629-631).
- Polamuri, S. R., Srinivas, K., & Mohan, A. K. (2019). Stock market prices prediction using random forest and extra tree regression. *Int. J. Recent Technol. Eng*, 8(1), 1224-1228.
- Reddy, G. T., Reddy, M. P. K., Lakshmana, K., Kaluri, R., Rajput, D. S., Srivastava, G., & Baker, T. (2020). Analysis of dimensionality reduction techniques on big data. *IEEE Access*, 8, 54776-54788. doi: 10.1109/ACCESS.2020.2980942
- Rezaei, H., Faaljoui, H., & Mansourfar, G. (2021). Stock price prediction using deep learning and frequency decomposition. *Expert Systems with Applications*, 169, 114332.
- Saxena, H., Anurag, A. V., Chirayath, N., Bendale, R., & Kaul, S. (2018). Stock prediction using ARMA. *International Journal of Engineering and Management Research (IJEMR)*, 8(2), 1-4.
- Sevinç, A., & Buket, K. (2021). Derin öğrenme ve istatistiksel modelleme yöntemiyle sıcaklık tahmini ve karşılaştırılması. *Avrupa Bilim ve Teknoloji Dergisi*, (28), 1222-1228.
- Sezer, O. B., Gudelek, M. U., & Ozbayoglu, A. M. (2020). Financial time series forecasting with deep learning: A systematic literature review: 2005-2019. *Applied Soft Computing*, 90, 106181.
- Siame-Namini, S., Tavakoli, N., & Namin, A. S. (2018). A comparison of ARIMA and LSTM in forecasting time series. *2018 17th IEEE international conference on machine learning and applications (ICMLA)* (pp. 1394-1401).
- Singh, S., Parmar, K. S., & Kumar, J. (2021). Soft computing model coupled with statistical models to estimate future of stock market. *Neural Computing and Applications*, 33(13), 7629-7647.
- Sunny, M. A. I., Maswood, M. M. S., & Alharbi, A. G. (2020). Deep learning-based stock price prediction using LSTM and bi-directional LSTM model. *2020 2nd Novel Intelligent and Leading Emerging Sciences Conference (NILES)* (pp. 87-92).
- Tsai, Y.-T., Zeng, Y.-R., & Chang, Y.-S. (2018). Air pollution forecasting using RNN with LSTM. *2018 IEEE 16th Intl Conf on Dependable, Autonomous and Secure Computing, 16th Intl Conf on Pervasive Intelligence and Computing, 4th Intl Conf on Big Data Intelligence and Computing and Cyber Science and Technology Congress(DASC/PiCom/DataCom/CyberSciTech)* (pp. 1074-1079). doi: 10.1109/DASC/PiCom/DataCom/CyberSciTec.2018.00178
- Vijh, M., Chandola, D., Tikkiwal, V. A., & Kumar, A. (2020). Stock closing price prediction using machine learning techniques. *Procedia Computer Science*, 167, 599-606.

Wang, H. Z., Wang, G. B., Li, G. Q., Peng, J. C., & Liu, Y. T. (2016). Deep belief network based deterministic and probabilistic wind speed forecasting approach. *Applied Energy*, 182, 80-93.

Yahoo Finance. (2022). *Yahoo finance*. Erişim tarihi: 06.08.2022, <https://finance.yahoo.com/>

Yang, F., Chen, J., & Liu, Y. (2021). Improved and optimized recurrent neural network based on PSO and its application in stock price prediction. *Soft Computing*, 1-16.

Yu, P., & Yan, X. (2020). Stock price prediction based on deep neural networks. *Neural Computing and Applications*, 32(6), 1609-1628.