



# HİSSE SENEDİ DEĞERLERİNİN MAKİNE ÖĞRENİMİ (DERİN ÖĞRENME) İLE TAHMİNİ

Erdoğan GAVCAR<sup>1</sup>

Hüseyin Mustafa METİN<sup>2</sup>

## ÖZET

Günümüzde, borsa piyasaları günlük yaşamı doğrudan etkileyen fenomenlerdir ve her insanın kolaylıkla erişebileceği yatırım araçları haline gelmişlerdir. Birbirleriyle bağlantılı olan ve ulusal ekonomileri büyük ölçüde etkileyen bu piyasalarda büyük miktarlarda sermaye işlemleri yapılmakta ve bu süreçte hisse senetlerinin değerlerinin tutarlı bir şekilde tahmin edilmesi ilgi çekmektedir. Makine öğreniminin de kapsadığı derin öğrenme algoritmaları diğer birçok alanda olduğu gibi finans alanında da tahmin değerlerinin elde edilmesinde sıklıkla uygulanmaktadır. Hatta kripto paralar gibi günlük değişim değerleri üzerinde de analizler yapılmaktadır. Bu çalışmamızda Vestel firmasının hisse senedi fiyatlarının veri değerleri kullanılmıştır. Ocak 2016 ve Aralık 2021 tarihleri arasındaki günlük hisse senedi fiyatlarının veri değerleri kullanılarak, derin öğrenme modellerinden Uzun Kısa Süreli Bellek (Long Short Term Memory (LSTM)) modeli ile hisse senetlerinin açılış fiyat değerleri tutarlı tahminler ile elde edilmiştir.

**Anahtar Kelimeler:** Derin Öğrenme, Finansal Tahmin, Uzun Kısa Süreli Bellek (LSTM), Tekrarlayan Sinir Ağı.

**JEL Kodları:** C45, C51, C81

---

<sup>1</sup> Prof. Dr., Muğla Sıtkı Koçman Üniversitesi, İktisadi ve İdari Bilimler Fakültesi, İşletme Bölümü, gavcar@mu.edu.tr, <https://orcid.org/0000-0002-2748-3933>

<sup>2</sup> Doktora Öğrencisi, Muğla Sıtkı Koçman Üniversitesi Sosyal Bilimler Enstitüsü, İşletme Bölümü, huseyinmustafametin060@posta.mu.edu.tr, <https://orcid.org/0000-0002-1810-0064>

# PREDICTION OF SHARE VALUES WITH MACHINE LEARNING (DEEP LEARNING)

Erdoğan GAVCAR<sup>3</sup>

Hüseyin Mustafa METİN<sup>4</sup>

## ABSTRACT

Today, stock markets are phenomena that directly affect daily life and have become investment tools that are easily accessible to every person. Large amounts of capital transactions are carried out in these markets, which are interconnected and greatly affect national economies. In this process, the consistent estimation of the values of stocks attracts attention. Deep learning algorithms, including machine learning, are frequently applied in obtaining predictive values in the field of finance, as in many other fields. In fact, analyzes are made on daily exchange values such as cryptocurrencies. In this study, data values of stock prices of Vestel company were used. By using the data values of daily stock prices between January 2016 and December 2021, the opening price values of stocks were obtained with consistent estimations with the Long Short Term Memory (LSTM) model, which is one of the deep learning models.

**Keywords:** Deep Learning, Financial Prediction, Long Short Term Memory (LSTM), Recurrent Neural Network.

**JEL Codes:** C45, C51, C81


---

<sup>3</sup> Prof. Dr., Muğla Sıtkı Koçman University, Faculty of Economics and Administrative Sciences, Department of Business Administration, gavcar@mu.edu.tr, <https://orcid.org/0000-0002-2748-3933>

<sup>4</sup> PhD Student, Muğla Sıtkı Koçman University Social Sciences Institute, Department of Business Administration, huseyinmustafametin060@posta.mu.edu.tr, <https://orcid.org/0000-0002-1810-0064>


## GİRİŞ

İnsanlar düşünmeye her saniye sıfırdan başlamazlar. Örneğin bu makaleyi okurken her kelimeyi hafızamızdaki kelime bilgisine göre hatırlar ve anlarız. Her şeyi yeniden düşünmeye başlamayız yani düşüncelerimiz kalıcıdır. Çok Katmanlı Algılayıcılar (Multi Layer Perceptron (MLP)) ve Evrimsel Sinir Ağları (Convolutional Neural Networks (CNN)) gibi geleneksel sinir ağları bunu yapamazlar ve bu büyük bir eksiklidir. Tekrarlayan Sinir Ağı (Recurrent Neural Network (RNN)) bilginin kalıcı olmasını sağlayan döngüler yardımıyla bu sorunu giderir.



Şekil 1: Tekrarlayan Sinir Ağı Şeması

Yukarıdaki şemada, bir sinir ağı parçası olan A,  $x_t$  girdisini alır ve bir  $h_t$  çıktısı değeri verir. Bir döngü de bilgilerin ağın bir adımından diğerine geçmesine izin verir. Tekrarlayan bir sinir ağı, aynı ağın birden çok kopyası olarak düşünülebilir ve her biri bir sonrakine bir mesaj iletir.



Şekil 2: Kontrolsüz Tekrarlayan Bir Sinir Ağı


Zincir benzeri tekrarlayan sinir ağları, diziler ile yakından ilişkilidir. Bu tür dizilerden oluşan veriler için kullanılacak sinir ağının doğal mimarisi tekrarlayan sinir ağıdır ve günümüzde çeşitli sorunları çözmeye oldukça başarılı sonuçlar elde etmiştir. Konuşmayı tanıma, dil modelleme, çeviri, metin oluşturma, zaman serilerine bağlı tüm uygulamaları modelleme, video analizleri, güvenlik algılama gibi karmaşık sorun alanları çözümlemelerinde iyi

sonular gstermektedir. Hemen hemen tm bu heyecan verici sonuları veren Uzun Kısa Sreli Bellek (Long Short Term Memory (LSTM)) tekrarlayan sinir aęları en ilgin derin ğrenme trlerinden biridir. Gemiř veri dizilerinden bilgileri kullanmayı ğrenebilir.

## 1. LSTM Aęları

Uzun Kısa Sreli Bellek aęları (genellikle “LSTM” olarak adlandırılır) uzun sreli baęımlılıkları ğrenebilen zel bir tekrarlayan sinir aęı trdr yani tekrarlayan Sinir Aęı (Recurrent Neural Network (RNN)) gibi LSTM’ler de tekrarlayan baęlantılara sahiptir. Hochreiter ve Schmidhuber tarafından tanıtıldı ve sonraki alıřmalarda birok kiři tarafından dzenlenerek popler hale getirildi (Hochreiter ve Schmidhuber, 1997: 1735). Bilgileri uzun sre hatırlamak iin tasarlanmıřtır. Dięer RNN’lerin aksine LSTM, aęırlık gncelleme prosedrnn, hibir etkisi olmayacak kadar kk (kaybolan gradyanlar) veya ok byk deęerler (patlayan gradyanlar) ile sonulanacak kadar byk hale gelen aęırlık deęiřiklikleriyle sonulanması problemini zelebilmektedir. Belirli bir girdinin gizli katman zerindeki ve dolayısıyla aę ıktısı zerindeki etkisi, aęın tekrarlayan baęlantıları etrafında dnerken ya azalıyor ya da katlanarak artıyor. Bu eksiklik literatrde kaybolan gradyan problemi olarak anılır. LSTM, kaybolan gradyan sorununu zlemek iin zel olarak tasarlanmıř bir RNN mimarisidir. LSTM hcreleri, kapılardan ve aęırlıklardan oluřur. Bir LSTM katmanı, bellek blokları olarak bilinen, tekrar tekrar birbirine baęlanan bir dizi bloktan oluřur. Her biri, bir veya daha fazla tekrarlayan baęlı bellek hcreleri ve bu hcreler iin srekli yazma, okuma ve sıfırlama iřlemlerini saęlayan giriř, ıkıř ve unutma kapıları olan  arpımsal birim ierir. Aę, hcrelerle ancak kapılar aracılıęıyla etkileřime girebilir (Rothman, 2018: 376).

En basit durumda, aęa bir seferde bir diziden bir gzlem gsterilir ve daha nce grdę hangi gzlemlerle alakalı olduęunu, bunların bir tahmin ile iliřkisini hatırlayabilir. Yani LSTM modeller, verilerden zamansal baęımlılıęı ğrenebilir ve kullanabilir. Bir dizideki uzun vadeli korelasyonları ğrenme yeteneęi nedeniyle LSTM aęları karmařık ok deęiřkenli dizileri doęru bir řekilde modelleme yeteneęine sahiptir. Ayrıca birden fazla paralel girdi dizisini ayrı ayrı modelleyebilirler (Chollet, 2019: 196).



Şekil 3: Dört Katmanlı Üç Adet LSTM Hücresi

$$i_t = \sigma(W_{xi}x_t + W_{hi}h_{t-1} + W_{ic}c_{t-1} + b_i) \quad (1)$$

$$f_t = \sigma(W_{xf}x_t + W_{hf}h_{t-1} + W_{fc}c_{t-1} + b_f) \quad (2)$$

$$c_t = f_t \circ c_{t-1} + i_t \circ \tanh(W_{xc}x_t + W_{hc}h_{t-1} + b_c) \quad (3)$$

$$o_t = \sigma(W_{xo}x_t + W_{ho}h_{t-1} + W_{co}c_t + b_o) \quad (4)$$

$$h_t = o_t \circ \tanh(c_t) \quad (5)$$

$X_t$  girdi vektörü,  $i_t$  giriş kapısı (1),  $f_t$  unutmaya kapısı (2),  $c_t$  hücre durumu (3),  $o_t$  çıkış kapısı (4),  $h_t$  çıkış vektörü (5),  $\sigma$  "sigmoid aktivasyon" fonksiyonu ve  $\tanh$  "tanh aktivasyon" fonksiyonudur (Beysolow, 2018: 38).

## 2.1. LSTM Ağırlıkları

LSTM bellek hücresi, giriş, çıkış ve ayrıca giriş zaman adımları yoluyla oluşturulan ağırlık parametrelerine sahiptir. Giriş ağırlıkları, geçerli zamanda girdiyi ağırlıklandırmak için kullanılır. Çıkış ağırlıkları, son zaman adımından çıktıyı ağırlıklandırmak için kullanılır ve dahili durum, çıktının hesaplanmasında kullanılan dahili durum parametresidir.

## 2.2. LSTM Kapıları

LSTM bellek hücresinin anahtarları kapılardır. Bunlar da hücredeki bilgi akışını yöneten ağırlıklı fonksiyonlarıdır. Üç kapı vardır. Unutmaya kapısı, hücreden hangi bilgilerin atılacağına karar verir. Giriş kapısı, girişten hangi

değerlerin bellek durumunu güncelleyeceğine karar verir. Çıktı kapısı, girdi ve hücrenin belleğine bağlı olarak neyin çıktı alınacağına karar verir (Brownlee, 2017: 10).

Unutma kapısı ve giriş kapısı, dahili durumun güncellenmesinde kullanılır. Çıkış kapısı, hücrenin gerçekte ne çıkardığı konusunda son bir sınırlayıcıdır. Her bir hücreyi sabit tutan bu kapılar tutarlı veri akışını sağlarlar.

### 3. LSTM Yöntemi

Bu çalışmamızda Vestel firmasının 2016 ile 2021 yılları arasındaki hisse senedi fiyatlarının veri değerleri kullanılmıştır.

**Tablo 1:** Vestel Firmasının Günlük Hisse Senedi Değerleri

	Date	Open	High	Low	Close	Adj Close	Volume
0	2016-01-04	4.95	5.020000	4.890000	4.960000	3.905826	4890882
1	2016-01-05	5.01	5.060000	4.890000	5.000000	3.937324	8040998
2	2016-01-06	4.98	5.100000	4.970000	5.080000	4.000321	12378165
3	2016-01-07	5.02	5.070000	4.950000	5.050000	3.976698	8001393
4	2016-01-08	5.08	5.210000	5.070000	5.070000	3.992447	15167720
...	...	...	...	...	...	...	...
1522	2021-12-06	28.50	28.580000	28.000000	28.180000	28.180000	4226745
1523	2021-12-07	28.24	28.620001	28.219999	28.379999	28.379999	5428142
1524	2021-12-08	28.52	28.620001	28.280001	28.400000	28.400000	5730634
1525	2021-12-09	28.42	29.459999	28.420000	29.059999	29.059999	14561062
1526	2021-12-10	29.26	29.879999	29.059999	29.459999	29.459999	12117698

1527 rows x 7 columns

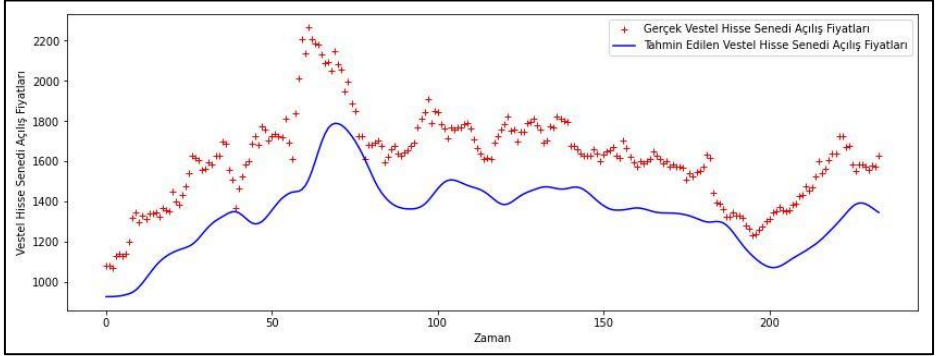
**Kaynak:** Yahoo Finance.

(<https://finance.yahoo.com/quote/VESTL.IS/history?p=VESTL.IS>)

Model oluşturmak için kullandığımız bağımsız değişkenlerimiz üstteki tabloda da görüldüğü gibi; açılış fiyat değeri (Open), gün içerisindeki en yüksek fiyat değeri (High), gün içerisindeki en düşük fiyat değeri (Low), kapanış fiyat değeri (Close) ve gün içerisindeki hacim (Volume) değişkenleridir. Ayarlanmış kapanış fiyatları (Adj Close) modele dahil edilmemiştir. 2021'den önceki veriler modeli eğitmek için seçilmiştir. 2021 yılının verileri ise modeli test etmek için

kullanılmıştır. Ayrıca veriler modelin çözümleyeceği şekilde (min, maks) ölçeklendirmesi ile 0 – 1 aralığına indirgenmiştir ve aktivasyon fonksiyonu olarak “sigmoid” fonksiyonu kullanılmıştır. Ayrıca hata fonksiyonu olarak ortalama kare hata fonksiyonu kullanılmıştır.

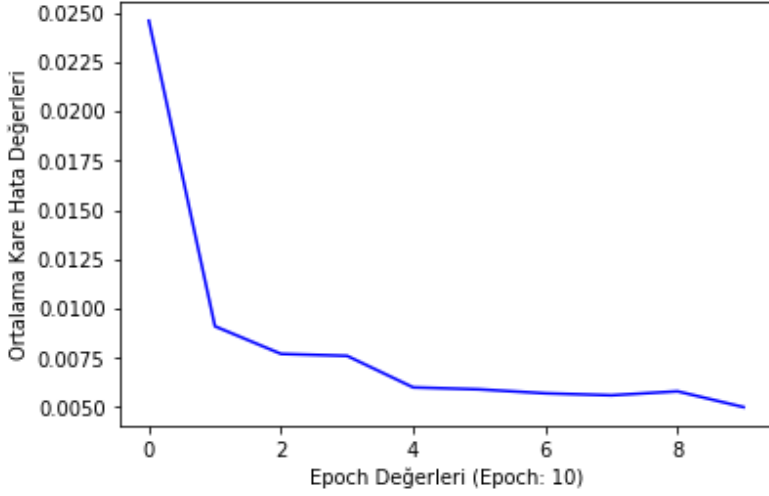
**Grafik 1:** Gerçek ve Tahmin Edilen Açılış Fiyatları



Modele 50, 60, 80, 120 adet LSTM hücresi eklenmiş, tüm bu ayarlamalar ile ortalama kare hatası 0,0050 olacak şekilde modelimiz oluşturulmuştur. Araştırmamızda epoch iterasyon değerimiz 10 verilmiştir ve her döngüdeki hata değerleri grafiği Grafik 2’de gösterilmiştir. Burada model hızlı öğrenmektedir.

**Grafik 2:** Her İterasyondaki Tahminlerin Hata Değerleri





## SONUÇ VE ÖNERİLER

Bu çalışmada, derin öğrenme modellerinden LSTM mimarisi kullanılarak Vestel şirketinin hisse senedi açılış fiyatlarının tahminine yönelik bir model geliştirilmiştir. 2016 ile 2021 yılları arasındaki değerler kullanılarak belirli bir döneme ait hisse senedi değerleri 0,0050 hata ile tahmin edilmiştir. Bu verilerin yaklaşık %80'i (1293 adet) eğitim için kullanılırken yaklaşık %20'si (234 adet) test verisi olarak kullanılmıştır. LSTM modelinde giriş, ara ve çıkış olmak üzere her katmanda Python programlama dili kullanılmış, 179561 parametre eğitilmiştir. Araştırmada, eğitim verisi arttıkça modelin daha tutarlı sonuçlar verdiği görülmüştür. Modelde, aktivasyon fonksiyonu "relu" fonksiyon seçildiğinde de tutarlı sonuçlar vermiştir, "sigmoid" aktivasyon fonksiyonuna nazaran "relu" aktivasyon fonksiyonu daha hızlı işlemektedir. Modelimizde, geçmiş 60 günlük veri dizileri ile ileriye dönük 61. günün hisse senedi açılış değeri dizileri tahmin edilmiştir. LSTM modelinden korelasyon katsayısı performans değerlendirme ölçütüne göre %95 doğruluk oranı elde edilmiştir.

Sonuçlara göre öncelikle yapılabilecek önerimiz eğitim veri seti ne kadar artarsa model daha iyi kurulmakta ve tahminler daha tutarlı olmaktadır. Hata fonksiyonu olarak ortalama mutlak hata fonksiyonu aykırı değerlerin etkisini daha azaltmıştır. Aktivasyon fonksiyonu olarak "sigmoid" fonksiyonu "relu" fonksiyonuna göre daha yavaş işlemektedir. Bu nedenle aktivasyon fonksiyonu olarak "relu" kullanılabilir. Model yapısı gereği de hızlı öğrenmektedir.

## KAYNAKÇA

Beysolow, T. (2018), **Applied Natural Language Processing with Python**, Apress, San Francisco

Brownlee, J. (2017), **Develop Sequence Prediction Models With Deep Learning**, Machine Learning Mastery, New York

Chollet, F. (2019), **Deep Learning with Python**, Manning, Shelter Island

Hochreiter, S.,ve Schmidhuber, J. (1997), Long Short-Term Memory, **Neural Computation**, 9(8), 1735-1780.

Rothman, D. (2018), **Artificial Intelligence By Example**, Packt, Birmingham

