



## Hisse Senedi Piyasası Analizinde Farklı Derin Sinir Ağı Modellerinin Karşılaştırılması

Çağrı ÇOBAN<sup>1\*</sup>, Elvan HAYAT<sup>2</sup>



### Arastırma Makalesi

### Makale Geçmişi

**Başvuru Tarihi: 08.12.2023**

**Kabul Tarihi: 25.12.2023**

### Research Article

### Article History

**Date of Application: 08.12.2023**

**Acceptance Date: 25.12.2023**

### **Özet**

Yatırımcılar, tasarruflarını getiri potansiyeli yüksek varlıklara yönlendirerek portföylerini güçlendirmeyi ve daha yüksek getiri elde etmeyi hedeflemektedir. Çeşitli finansal araçlar arasında hisse senetleri yüksek getiri potansiyeli sunan yatırım araçları olarak değerlendirilmektedir. Bu kapsamda hisse senedi fiyat tahmini birçok yatırımcı ve araştırmacının merak konusu olmuştur ve olmaya da devam etmektedir. Ancak yüksek getiri arayışı aynı zamanda yüksek riskleri ve belirsizlikleri de beraberinde getirmektedir. Bu belirsizliğin temel kaynakları arasında hisse senedi fiyatlarını etkileyen siyasi olaylar, toplumsal gelişmeler, uluslararası ilişkiler ve sektörel değişimler yer almaktadır. Doğası gereği zor olan hisse senedi fiyat hareketlerinin tahmini bu çok yönlü ve karmaşık faktörlerin de etkisiyle daha da zorlaşmaktadır.

Geleneksel olarak hisse senedi fiyat tahminleri istatistiksel ve ekonometrik yöntemlere dayandırılmaktadır. Son yıllarda teknoloji ve bilgisayar bilimlerindeki ilerlemeler sayesinde, hisse senedi fiyat tahminlerinde yapay zeka ve makine öğrenmesi metodolojileri giderek daha fazla kullanılmaya başlanmıştır. 2000'li yıllardan itibaren derin öğrenme yöntemlerinin gelişmesiyle birlikte hisse senedi fiyat hareketlerindeki karmaşık ilişkiler tespit edilmeye başlanmış ve başarılı sonuçlar elde edilmiştir.

Bu çalışmada, çok değişkenli Derin Sinir Ağları (Deep Neural Network-DNN), Evrimsel Sinir Ağları (Convolutional Neural Network-CNN) ve Tekrarlayan Sinir Ağları (Recurrent Neural Networks-RNN) modelleri kullanılarak hisse senedi fiyatlarını tahmin etmek ve modellerin performanslarını karşılaştırmak amaçlanmıştır. Bu amaçla, Vestel Elektronik Sanayi ve Ticaret A.Ş. (VESTL) için 03/06/2013-28/05/2021 tarihleri arasında günlük hisse senedi kapanış fiyatları serisi ve bu seriye etki edebilecek bağımsız değişkenler ele alınarak analizler yapılmıştır. Analiz sonuçlarına göre, hata kareler ortalaması (MSE) ve hata kareler ortalamasının karekökü (RMSE) ölçütleri karşılaştırılarak, en iyi performans gösteren modelin CNN olduğu belirlenmiş ve bu modelin RMSE değeri 0.086 olarak hesaplanmıştır.

**Anahtar Kelimeler:** Derin Öğrenme, Hisse Senedi Fiyat tahmini, Derin Sinir Ağları, Tekrarlayan Sinir Ağları, Evrimsel Sinir Ağları

**Jel Kodları:** C45, C88, G17

<sup>1</sup> Bilim Uzmanı, Aydın Adnan Menderes Üniversitesi, Sosyal Bilimler Enstitüsü, Ekonometri Anabilim Dalı, (553) 2025012, [cagricobaan@gmail.com](mailto:cagricobaan@gmail.com), Orcid No. 0009-0008-9752-9395.

<sup>2</sup> Doç. Dr., Aydın Adnan Menderes Üniversitesi, Aydın İktisat Fakültesi, Ekonometri Bölümü, (506) 3990450, [elvan.hayat@adu.edu.tr](mailto:elvan.hayat@adu.edu.tr), Orcid No. 0000-0001-8200-8046.

\*Bu çalışma Çağrı ÇOBAN'ın "Dalgacık Dönüşümü ve Derin Öğrenme Yöntemleri ile Hisse Senedi Fiyat Tahmini" adlı yüksek lisans tezinden türetilmiştir.

## Comparison of Different Deep Neural Network Models in Stock Market Analysis

### Abstract

Investors aim to strengthen their portfolios and achieve higher returns by allocating their savings to assets with high return potential. Among various financial instruments, stocks are considered investment vehicles that offer a high potential for returns. Consequently, stock price prediction has been a subject of curiosity for many investors and researchers and continues to be so. However, the pursuit of high returns also introduces high risks and uncertainties. The fundamental sources of this uncertainty include political events, social developments, international relations, and sectoral changes, all of which influence stock prices. The prediction of stock price movements, which is inherently challenging, becomes even more difficult due to the influence of versatile and complex factors.

Traditionally, stock price predictions have been based on statistical and econometric methods. In recent years, advancements in technology and computer sciences have led to the increasing use of artificial intelligence and machine learning methodologies in stock price predictions. Since the development of deep learning methods in the 2000s, complex relationships in stock price movements have been identified, yielding successful results.

This study aims to predict stock prices using multivariate Deep Neural Networks (DNN), Convolutional Neural Networks (CNN), and Recurrent Neural Networks (RNN) models, and to compare the performance of these models. To achieve this goal, analyses were conducted using the daily closing stock prices series of Vestel Elektronik Sanayi ve Ticaret A.Ş. (VESTL) between June 3, 2013, and May 28, 2021, along with independent variables that could affect this series. According to the analysis results, comparing the mean squared error (MSE) and the square root of the mean squared error (RMSE) metrics, it was determined that the CNN model performed the best, and the RMSE value for this model was calculated as 0.086.

**Keywords:** Deep Learning, Stock Price prediction, Deep Neural Networks, Recurrent Neural Networks, Convolutional Neural Networks

**Jel Codes:** C45, C88, G17

## 1. Giriş

Hisse senedi piyasasındaki dalgalanmaların ve eğilimlerin öngörülmesi hem bireysel yatırımcılar hem de yatırım firmaları için ilgi odağı olmaya devam etmektedir. Hisse senetleriyle ilgili önemli getiri potansiyeli göz önüne alındığında, analistler ve araştırmacılar da hisse senedi fiyat tahmini alanına büyük ilgi göstermektedir. Bununla birlikte hisse senedi fiyatları, ülkenin ekonomik durumu, siyasi ve sosyal olaylar, uluslararası ilişkiler ve sektörel gelişmeler gibi çok yönlü faktörlerden karmaşık bir şekilde etkilenmektedir. Sonuç olarak, hisse senedi fiyat hareketlerini önceden tahmin etme yeteneği zorlu bir görev teşkil etmektedir.

Bilişim teknolojisindeki gelişmeler, finansal analiz alanında büyük veri ve yapay zeka teknolojilerinin daha fazla kullanılmasına olanak vermektedir. Hisse senedi fiyatlarının analizinde, tahminler oluşturmak için geleneksel istatistiksel ve ekonometrik modeller ile teknik analiz yöntemlerinin yanı sıra, son yıllarda yapay zeka yöntemlerine artan bir ilgi gözlemlenmektedir. Aslında bunun temel sebebi, doğrusal olmayan, yüksek gürültülü finansal zaman serilerinde geleneksel modellerin yüksek hassasiyete sahip olmaması ve başarılı sonuçlar alınamamasıdır (Albayrak ve Saran, 2023: 162). Bu özellikteki zaman serisi tahminlerinde yapay zekâ teknolojilerinin kullanımı daha başarılı sonuçlar elde edilmesini sağlamaktadır (Arslankaya ve Toprak, 2021: 178). Yapay zeka alanında önemli bir yeri olan yapay sinir ağları (YSA), 1970'lerin sonlarından itibaren öngörü amacıyla hem doğrusal hem de doğrusal olmayan ilişkilerin tahmin edilmesinde kullanılmaya başlanmıştır. Son yıllarda YSA ile pek çok alanda olduğu gibi hisse senedi fiyat tahmininde de oldukça başarılı tahminler yapmak mümkün olmaktadır (Tektaş ve Karataş, 2004; Karaatlı vd., 2005; Wang vd., 2011; Guresen vd., 2011; Monfared ve Enke, 2014; Kim ve Won, 2018; Kazem vd., 2013). Tek bir gizli katmana sahip klasik sinir ağlarına kıyasla, derin sinir ağları her eklenen gizli katman için daha yüksek düzeyde özellik çıkarma yeteneğine sahiptir. Derin sinir ağlarının doğrusal olmayan finansal piyasalara uygunluğu ve başarılı tahminler ürettiği literatürdeki pek çok çalışma ile gözlemlenmiştir (Thakkar ve Chaudhari, 2021).

Bu çalışmanın temel amacı, derin öğrenme yöntemleri kullanılarak hisse senedi verilerinin kapanış değerlerini tahmin etmek ve modellerin performanslarını karşılaştırmaktır. Bu amaçla çalışmada, 3 Haziran 2013 ile 28 Mayıs 2021 tarihleri arasında elektronik, beyaz eşya ve dijital ürünler alanlarında faaliyet gösteren bir şirketler grubu olan Vestel Elektronik Sanayi ve Ticaret A.Ş. (VESTL) için işlem günü kapanış fiyatı verileri toplanmış ve bağımlı değişken olarak ele alınmıştır. Bağımsız değişkenler olarak, kapanış fiyatlarının 20 günlük gecikmeli değerlerinin yanı sıra işlem günü açılış fiyatları, en düşük fiyatlar, en yüksek fiyatlar, gram altın fiyatları, Brent ham petrol fiyatları ve dolar kuru verileri elde edilmiştir. Veri seti eğitim, doğrulama ve test seti olmak üzere ayrılmış ve Klasik Derin Sinir Ağları (Klasik-DNN), Evrimsel Sinir Ağları (CNN- Convolutional Neural Networks), Tekrarlayan Sinir Ağları (Recurrent Neural Networks-RNN) ile eğitilmiştir. Eğitim aşamasından sonra tahmin değerleri elde edilerek model performansları karşılaştırılmıştır.

Bu çalışma dört bölümden oluşmaktadır. Giriş bölümünü izleyen ikinci bölümde derin öğrenme kavramı ve derin öğrenme mimarileri hakkında bilgiler verilmiştir. Bu bölümde model performansını artırmaya yönelik yöntemlerden hiper-parametre optimizasyonu hakkında bilgi verilerek, model performans ölçütlerine değinilmiştir. Üçüncü bölümde, veri ön işleme adımlarının ardından analizde kullanılan derin öğrenme modellerinin eğitiminde uygulanan işlemler ve model tahmin sonuçları ayrıntılı olarak sunulmuştur. Son bölümde, çalışmanın bulgularına ilişkin genel bir değerlendirmeye gidilmiştir.


## 1. Materyal ve Metot

Yapay zeka bir çok disiplinin birleşiminde oluşan, geniş kapsama alanına sahip bir bilim dalıdır. Bu bilim dalının bir alt kolu olan makine öğrenmesi, bilgisayarların karmaşık görev ve bilgileri öğrenip analiz ederek, örüntüler belirlemesi sonucunda algoritmalar ve istatistiksel modeller geliştirerek tahminlerde bulunulmasına olanak sağlayan sistemler bütünüdür. Makine öğrenmesi tekniklerinden biri olan YSA, insan öğrenme mekanizmasının bilgisayarlar tarafından taklit edilebilmesi için geliştirilmiştir. Derin öğrenme YSA yapısının birden çok gizli katmana sahip olan modellerine verilen bir isimdir (Bingöl vd., 2020). İzleyen bölümde derin öğrenme ve derin öğrenme mimarileri, model performansını artırmaya yönelik yöntemler ve model performans değerlendirme ölçütleri hakkında bilgiler verilmiştir.

### 2.1. Derin Öğrenme

Yapay sinir ağları (YSA) ise insan beyninin işleyişinden ilham alarak tasarlanmış bir makine öğrenmesi tekniğidir. YSA, nöron adı verilen işlevsel birimlerin bağlantılarından oluşur ve öğrenme süreçlerini modellemek için kullanılır. Derin öğrenme (DL-Deep Learning) de yapay sinir ağlarının çok katmanlı ve karmaşık yapılarına odaklanan bir alt dalıdır. Derin öğrenme, YSA algoritmalarının 2000’li yıllardan sonra geliştirilmeye başlanmış “derin sinir ağları” olarak da adlandırılan yeni bir türüdür. Derin öğrenme görüntü işleme, doğal dil işleme, el yazısı tanıma, çoklu sınıflandırma, regresyon problemleri, ses tanıma ve zaman serisi tahminleri gibi birçok alanda kullanılmaktadır (Ciaburro ve Venkateswaran, 2017: 38).

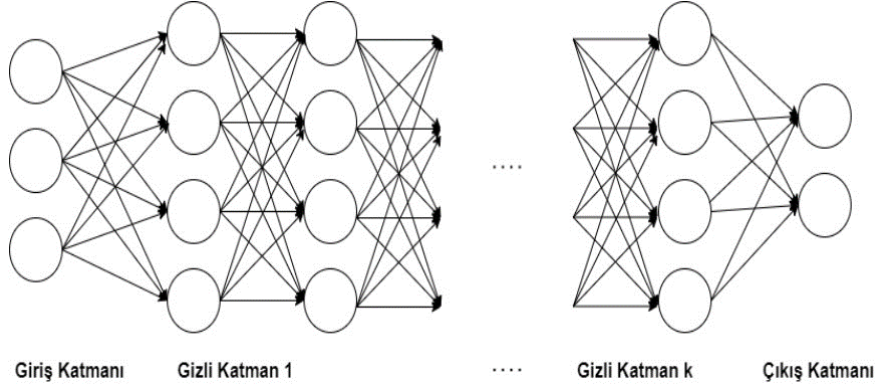
Yapay zeka, makine öğrenmesi, yapay sinir ağları ve derin öğrenme arasındaki ilişki Şekil 2.1’de gösterilmektedir.



Şekil 2.1. Yapay Zeka ve Derin Öğrenme İlişkisi (Tan vd., 2021:160)

Bir veya daha fazla girdiye (bağımsız değişkene) sahip, katman olarak adlandırılan alt alta sinir hücresi (nöron) bloğunun oluşturduğu yapısı ile bir veya birden fazla çıktı üreten bir tahmin modelidir (Arslankaya ve Toprak, 2021: 108). Derin sinir ağları üç tür katmandan oluşmaktadır: Giriş katmanı, gizli katmanlar ve çıkış katmanı. İlk katman olan giriş katmanı

bağımsız değişkenlerin ham olarak ağa verildiği kısımdır, son katman ise çıkış katmanı yani tahmin edilmek istenen değer (bağımlı değişken) sonucunun alındığı katmandır. Giriş katmanı ile çıkış katmanı arasında bulunan katman(lar) ise gizli katmandır. Genellikle, problemin karmaşıklığı arttıkça modeldeki gizli katman sayısı da artırılır. “Derin” terimi, bu modellerde kullanılan çok sayıda gizli katman sayısından gelmektedir (Toğaçar vd., 2019: 110). Şekil 2.2’de derin sinir ağlarının katman yapısı gösterilmektedir.



Şekil 2.2. Derin Sinir Ağı Katman Yapısı (Tan vd., 2021:160)


## 2.2. Derin Öğrenme Mimarileri

### *Derin Sinir Ağı (Deep Neural Network- DNN )*

Temel olarak giriş, gizli ve çıkış katmanlarından oluşan bir yapıya sahiptir. Her katmandaki nöronlar, önceki katmanlardaki nöronlar ile bağlantılıdır ve YSA'nın çok katmanlı halidir.


### *Evrişimsel Sinir Ağları (Convolutional Neural Network-CNN)*

Hubel ve Wiesel' in 1968 yılında hayvanların görme mekanizmasından esinlenerek geliştirdikleri derin sinir ağıdır (Hubel ve Wiesel, 1968). Evrişimsel Sinir Ağı, filtreleme tabanlı bir yapı ile çalışmaktadır. Bir filtre aracılığıyla görüntünün özellikleri yakalanır ve yakalanan bu özellikler belirgin hale getirilir. Filtreler, resim veya görüntünün ayrıntısına göre farklı boyutlarda belirlenmektedir (Simard vd., 2003). Şekil 2.3 uydru aracılığıyla alınan bir köprü görüntüsünün sınıflandırılmasını sağlayan CNN modelini göstermektedir.




Şekil 2.3. Uydru Görüntülerini Sınıflandıran Evrişimsel Sinir Ağı Modeli

CNN, 3 ana katmandan oluşmaktadır; evrişim, havuzlama (toparlama) ve ileri besleme (tam bağlantı) katmanı. Şekil 2.4 CNN katman yapısını göstermektedir.



Şekil 2.4. Evrişimsel Sinir Ağları

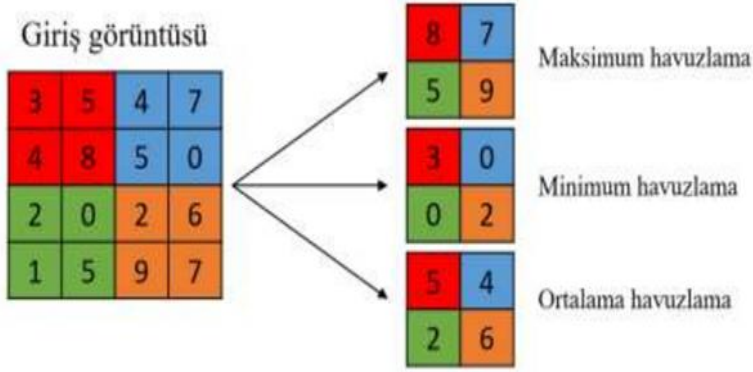
*Evrişim katmanı:* Evrişim katmanında girdi verilerine evrişim işlemi uygulanarak, özellik haritalarının çıkarılmasında kullanılır. Evrişim işlemi filtre (kernel) olarak adlandırılan öğe aracılığıyla gerçekleşir, girdiler filtreler ile matris işlemleri uygulanarak işlenir. Filtre, genellikle küçük boyutlarda olup, ağırlık parametrelerini içerir. Evrişim işlemi, filtre matrisinin girdi verilerinin üzerinde gezdirilerek, her adımda noktasal çarpım yapar ve sonuçları toplar. Bu işlem, girdi verileri üzerinde kayan bir pencere etkisi oluşturur ve filtre matrisinin farklı bölgelerdeki özellikleri tespit etmesi sağlanır (Chollet, 2021). Evrişim katmanının çıktısı olan özellik haritaları, ağına daha derin katmanlarına iletilerek daha karmaşık özelliklerin keşfedilmesine olanak tanır. Şekil 2.5, evrişim filtresinin şekil üzerinde uygulamasını göstermektedir.



Şekil 2.5. Evrişim Uygulaması

*Aktivasyon İşlemleri:* Aktivasyon işlemleri, ağına lineer olmayan ve daha karmaşık ilişkileri saptamasında önemli bir rol oynamaktadır.

*Havuzlama (Toparlama) Katmanı (Pooling Layer):* Havuzlama katmanı, özellik haritasının boyutunu ve parametre sayısını azaltmaktadır (Pervan, 2019: 32). Havuzlama katmanında uygulanan boyut azaltma işlemi bilgilerin kaybolmasına ve performansın düşmesine neden olmaktadır (Kızrak ve Bolat, 2018). Fakat özellik haritalarının boyutunun küçültülmesi modelin ezberlemesini önüne geçmekte ve hesaplama yükünü azaltmaktadır. Havuzlama işlemi ve evrişim işlemi birbirleri ile benzerlik göstermektedir. Belirli filtre türlerinin kullanıldığı bu katmanda filtreler, görüntü üzerinde gezdirilerek piksellerin değerlerinin alındığı işlem olarak gerçekleştirilmektedir (İnik ve Ülker, 2017). Şekil 2.6 bir giriş görüntüsünün boyutunun 4x4 olduğunu gösterilmektedir. Bu görüntü üzerinde, maksimum, en küçük ve ortalama havuzlama işlemleri için 2x2 boyutunda bir pencere kullanılarak havuzlama işlemi yapılan görüntü örneği verilmiştir.




Şekil 2.6. Havuzlama İşlemi

**Tam Bağlantı Katmanı:** Tam bağlantı katmanı, önceki katmandaki tüm özellik haritalarını birleştirerek sonraki katmana iletilmesini sağlar. Genellikle evrimsel sinir ağının son katmanı olarak kullanılan tam bağlantı katmanı, veri örneklerinin özelliklerini temsil eden vektörlerle işlem yapar. Bu vektörler, önceki evrişim ve havuzlama katmanlarından elde edilen özellik haritalarını içerir. Girdilerin daha yüksek seviyeli temsillerini oluşturarak karmaşık desenlerin ve ilişkilerin öğrenilmesine yardımcı olur. Ayrıca, evrimsel sinir ağının sonundaki tam bağlantılı katman, genellikle evrimsel sinir ağının eğitimi sırasında öğrenilen özelliklerin kullanılarak sınıflandırma veya regresyon modelleri tahmini için kullanılan çıktı katmanıdır (Nielsen, 2015).


### **Tekrarlayan Sinir Ağları (Recurrent Neural Networks-RNN)**

Elman 1990 yılında sıralı bilgi işleme üzerine yaptığı çalışmayla RNN derin sinir ağının temellerini atmıştır. RNN derin sinir ağının geleneksel sinir ağlarından farkı tekrarlayan bağlantılara sahip olmasıdır. Tekrarlayan bağlantılar sayesinde, geçmişte olan bilgiyi hatırlayabilmektedir. Bu bilgiler derin sinir ağının hafızasından saklanır (Tokgöz ve Ünal, 2018). RNN derin sinir ağı, zaman serisi problemlerinde ve doğal dil işleme problemlerinde sıklıkla kullanılmaktadır. Şekil 2.7 tekrarlayan sinir ağı yapısını göstermektedir.




Şekil 2.7. Tekrarlayan Sinir Ağı Yapısı

RNN'in temel yapı taşı, hücredir. Hücrenin işleyişi, klasik derin sinir ağlarındaki nöronlara benzemektedir. Hücre giriş verilerini alırken, önceki durumda oluşan çıktıyı da döngüsel bir biçimde geri besleyebilmektedir. Geri besleme döngüsü, RNN derin sinir ağının önceki durumlarda oluşan bilgiyi hatırlayabilmesini sağlamaktadır. Şekil 2.8 tekrarlayan sinir ağının açılımını göstermektedir.



Şekil 2.8. Tekrarlayan Sinir Ağının Açılımı

RNN derin sinir ağının zaman serisi problemlerinde tercih edilmesinin başlıca nedeni geçmiş durumu hatırlayabilme yetenekleridir. Bu özelliği sayesinde RNN derin öğrenme ağları, doğal dil işleme problemleri, dil modelleri, çeviri sistemleri, konuşma tanıma ve finansal veri analizi çeşitli sıralı veri problemlerinde kullanılmaktadır. Şekil 2.9 RNN ağı modelini göstermektedir.



Şekil 2.9. Tekrarlayan Derin Sinir Ağı Modeli (Doğan ve Türkoğlu, 2019)

### 2.3. Model Performansını Artırmaya Yönelik Yöntemler

#### Hiper-parametre Optimizasyonu

Hiper-parametre kavramını anlayabilmek için öncelikle, model parametresi ile hiper-parametre arasındaki farkın anlaşılması gerekmektedir. Model parametresi, bir modelin eğitim süreci sırasında verilerden öğrendiği ve modelin kendisini ayarlamasına yardımcı olan değerdir. Örneğin, bir YSA modelinde ağırlıklar ve yanlılık değerleri model parametreleridir ve eğitim süreci boyunca optimize edilerek ayarlanır. Hiper-parametreler ise doğrudan verilerle öğrenilmeyen ve araştırmacının önceden belirlemesi gereken değerlerdir. Bu parametreler, modelin yapılandırılmasını ve eğitim sürecinin nasıl gerçekleşeceğini kontrol etmek için kullanılır. Örneğin, bir YSA modelinde öğrenme hızı, döngü sayısı veya gizli katmanların sayısı gibi hiper-parametreler, araştırmacı tarafından belirlenir (Goodfellow vd., 2016). Bu parametrelerin optimize edilmesi, modelin tahmin doğruluğunu etkileyen bir süreçtir ve aynı zamanda modelin performansını da belirlemektedir (Zheng, 2015: 28). Modelin eğitimi sırasında, hiper-parametre değerlerinin farklı kombinasyonları denenir ve en etkili kombinasyon modelin eğitiminde kullanılır (Zheng, 2015: 31). Bu kombinasyonları belirleme işlemi genellikle Izgara Arama (Grid Search) yöntemi ile gerçekleştirilir.

#### Erken Durdurma

Erken durdurma, bir modelin eğitimini belirli bir aşamada sonlandırarak depolama ve zaman tasarrufu sağlamak amacıyla kullanılan bir metottur (Cihan ve Coşkun, 2021). Eğitim sürecinin gereksiz yere devam etmesi, zaman ve hesaplama kaynaklarının etkin bir şekilde kullanılmasına yönelik bir dezavantaj oluşturabilir. Bu yaklaşım, modelin başarı oranının belirli bir süre sonra önemli ölçüde değişmediği durumlarda uygulanır.



## 2.4. Model Performans Değerlendirme Ölçütleri

### *Hata Kareler Ortalaması (Mean Square Error-MSE)*

MSE, gerçek gözlem değerleri ile tahmin edilen gözlem değerleri arasındaki farkı ölçen model performans ölçütüdür. Kullanım amacı kurulan modelin tahmin doğruluğunu belirlemektir. Bu tahmin doğruluğu, gerçek gözlem değerleri ile tahmin gözlem değerleri arasındaki sapmanın ölçülmesi sonucunda belirlenmektedir. MSE denklemi Eşitlik 1’de verilmiştir.

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

### *Hata Kareler Ortalamasının Karekökü (Root Mean Squared Error- RMSE)*

RMSE, model tahmin performansını ölçmek için kullanılan başka bir başarı ölçütüdür. RMSE model performans başarı ölçütü, her bir gözlem dikkate alınarak tahmin değeri ile gerçek değer arasındaki farkın Öklid mesafesi kullanılarak hesaplanır (Zaheer vd., 2023). RMSE’nin denklemi Eşitlik 2’de verilmiştir.

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

## 3. Bulgular

Türkiye’de bir elektronik şirketi olan ve geniş bir ürün yelpazesi sahip olan; Vestel Elektronik Sanayi ve Ticaret A.Ş. (VESTL) hisse senedine ait veri seti oluşturularak kapanış fiyatları tahmin edilmiş ve bulgular sunulmuştur. Veri toplama ve analiz işlemlerinde Python ve R programlama dilleri kullanılmıştır.

### 3.1. Veri Seti ve Yapısı

Veri seti, 03.06.2013-28.05.2021 tarihleri arasında seçilen VESTL hisse senedinin hafta içi günlük kapanış, açılış, en yüksek ve en düşük değerleri ile makroekonomik değişkenlerden gram altın fiyatı, Brent petrol fiyatı ve dolar kuru gözlem değerlerini içermektedir. Analizde hisse senedi kapanış fiyatları bağımlı değişken, diğer değişkenler bağımsız değişken olarak analize dahil edilmiştir. Tüm veriler “www.investing.com” adresinden alınmıştır. Veri setinin ilk ve son beş gözlem değeri Tablo 3.1’de görülmektedir.

Tablo 3.1. VESTL hisse senedi veri seti

Tarih	kapanis	acilis	yuksek	dusuk	petrol	dolar	altin
2013-06-03	1.806	1.849	1.943	1.798	192.158568	1.8828	85.308
2013-06-04	1.951	1.840	1.951	1.840	193.771156	1.8769	84.284
2013-06-05	1.951	1.934	2.028	1.908	194.982592	1.8923	85.238
2013-06-06	1.908	1.925	2.053	1.815	196.154452	1.8932	85.825
2013-06-07	1.934	1.917	1.994	1.917	195.840880	1.8730	83.328
...	...	...	...	...	...	...	...
2021-05-24	26.270	25.624	26.380	25.593	574.256172	8.3882	506.108
2021-05-25	24.695	26.380	26.711	24.695	580.730945	8.4593	516.123
2021-05-26	25.608	24.978	25.608	24.270	582.385381	8.4563	515.556
2021-05-27	25.656	25.656	26.191	25.215	590.528082	8.5017	519.046
2021-05-28	24.900	25.624	25.624	24.663	595.865688	8.5576	524.211

Veri setine ilişkin tanımlayıcı istatistikler Tablo 3.2’de verilmiştir. Veri seti 2010 işlem günü ve 7 değişken içermektedir. Buna göre;

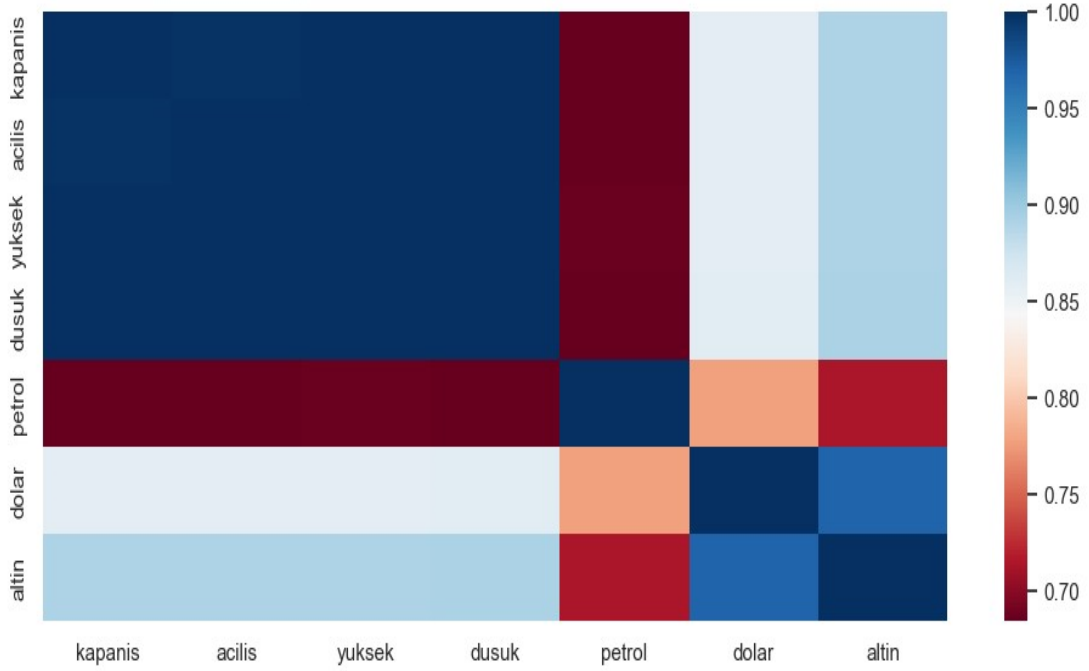
- kapanış (işlem günü kapanış değeri) değişkeninin ortalaması 7.44 TL, standart sapması ise 5.15 TL’dir. İlk çeyrek 4.56 TL, medyan 5.88 TL ve üçüncü çeyrek ise 8.83 TL değerini almıştır.
- açılış (işlem günü açılış değeri) değişkeninin ortalaması 7.45 TL, standart sapması ise 5.15 TL’dir. İlk çeyrek 4.58 TL, medyan 5.89 TL ve üçüncü çeyrek ise 8.88 TL değerini almıştır.
- yüksek (işlem günü en yüksek değeri) değişkeninin ortalaması 7.62 TL, standart sapması ise 5.28 TL’dir. İlk çeyrek 4.68 TL, medyan 5.99 TL ve üçüncü çeyrek ise 9.09 TL değerini almıştır.
- düşük (işlem günü en düşük değeri) değişkeninin ortalaması 7.31 TL, standart sapması ise 5.05 TL’dir. İlk çeyrek 4.48 TL, medyan 5.81 TL ve üçüncü çeyrek ise 8.65 TL değerini almıştır.
- petrol (işlem günü Brent petrol fiyatı) değişkeninin ortalaması 256.29 standart sapması ise 108.05 TL’dir. İlk çeyrek 171.30 TL, medyan 227.96 TL ve üçüncü çeyrek ise 342.42 TL değerini almıştır.
- dolar (işlem günü dolar kuru) değişkeninin ortalaması 4.20 TL, standart sapması ise 1.87 TL’dir. İlk çeyrek 2.69 TL, medyan 3.61 TL ve üçüncü çeyrek ise 5.75 TL değerini almıştır.

- altın (işlem günü gram altın fiyatı) değişkeninin ortalaması 194.56 TL, standart sapması ise 119.96 TL'dir. İlk çeyrek 100.44 TL, medyan 145.59 TL ve üçüncü çeyrek ise 255.56 TL değerini almıştır.

Tablo 3.2. Tanımlayıcı istatistikler

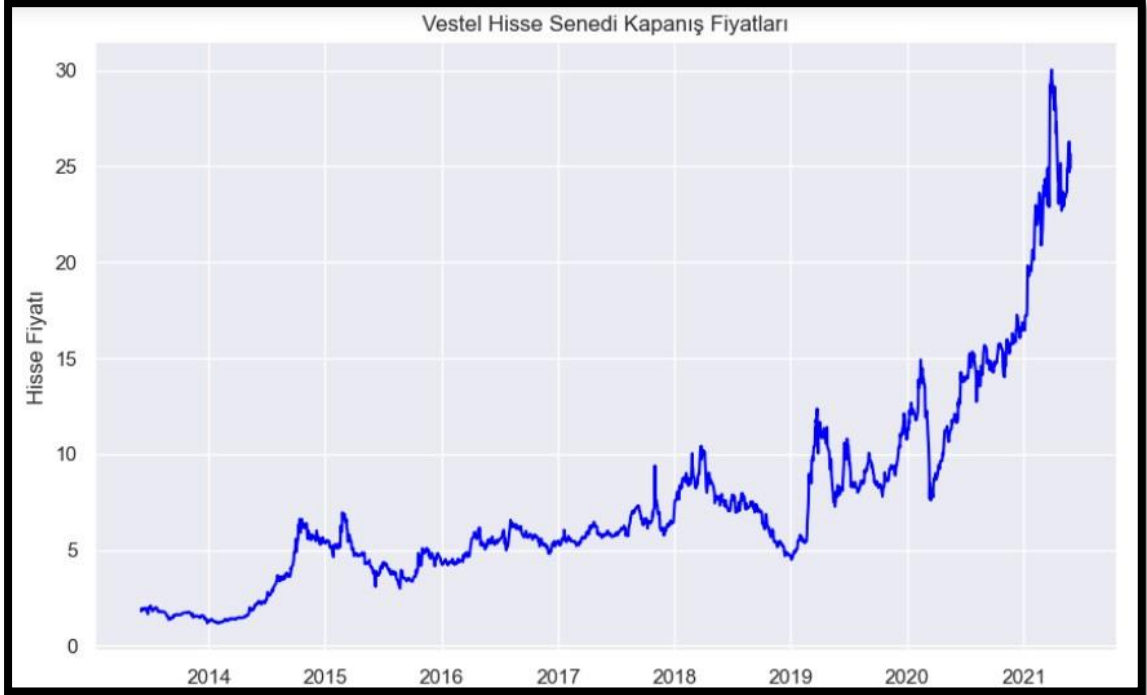
	kapanis	acilis	yuksek	dusuk	petrol	dolar	altin
count	2010	2010	2010	2010	2010	2010	2010
mean	7.43901	7.44894	7.61658	7.31008	256.292	4.20469	194.555
std	5.15258	5.15242	5.28351	5.04804	108.054	1.87223	119.962
min	1.176	1.176	1.21	1.116	84.8165	1.859	74.045
25%	4.56225	4.57725	4.677	4.48325	171.302	2.68545	100.437
50%	5.879	5.8915	5.9935	5.81	227.955	3.6071	145.592
75%	8.83275	8.87575	9.091	8.64575	342.415	5.7547	255.56
max	30.018	30.538	30.947	29.483	595.866	8.5576	534.981

Veri seti için hesaplanan korelasyon matrisine ait ısı grafiği (heatmap) Grafik 3.1'de verilmiştir. Korelasyon matrisi incelendiğinde, işlem günü kapanış fiyatı değeri ile gün içinde şekillenen açılış değeri, en yüksek değeri ve en düşük değeri arasında 1'e yakın ilişki tespit edilmiştir. Makroekonomik değişkenler olan dolar, altın ve petrol ile kapanış fiyatları arasındaki ilişki incelenmiş; gram altın ile kapanış fiyatları arasında %89,12'lik, dolar ile kapanış fiyatları arasında %85,91'lik, petrol ile kapanış fiyatları arasında ise %68,50'lik ilişki bulunmaktadır. Grafik 3.1' deki ısı haritasından, bağımlı değişken olan işlem günü kapanış fiyatı değeri ile gün içinde şekillenen açılış değeri, en yüksek değeri ve en düşük değeri arasında güçlü pozitif bir ilişki olduğu görülmektedir. Makroekonomik değişkenler olan dolar, altın ve petrol ile kapanış fiyatları arasındaki ilişki incelenmiş; petrol ile orta düzeyde negatif yönlü ilişki, dolar ve altın ile pozitif yönlü güçlü bir ilişki tespit edilmiştir.



Grafik 3.1. Isı haritası

Grafik 3.2’de Vestel hisse senedinin kapanış fiyatları serisi verilmiştir. Kapanış fiyatları serisi 2014 yılının ikinci çeyreğinden 2019 yılının son çeyreğine kadar dalgalı bir seyir izlemektedir. Şirket satış gelirlerinde, 2020 yılının ilk çeyreğinde salgın nedeniyle % 19’ luk bir azalma yaşamış, bu da hisse senedi fiyatlarında düşüş etkisi yaratmıştır. İkinci çeyrekte ise azalma yerini toparlanma sürecine bırakmıştır. 2020 yılının kalan 2 çeyreklik döneminde sektördeki talep artışı ile birlikte yılın geri kalanında olumlu bir hava oluşmuş ve şirket, karını % 73 arttırarak yılı tamamlamıştır. Şirket karlılığında oluşan bu durumun etkisi hisse senedi fiyatlarında olumlu bir etki yaratmış ve hisse fiyatları yükseliş trendine girmiştir.



Grafik 3.2. Vestel hisse senedi kapanış fiyatları

### 3.2. Derin Öğrenme Mimarisi ve Eğitimi

VESTL hisse senedi veri setindeki değişkenlere min-max normalizasyon işlemi uygulanmıştır. Normalize edilmiş veri seti eğitim ve tahmin için 3 parçaya ayrılmıştır. Zaman serisi verileri ardışık veriler olduğu için verinin ilk %90'lık kısmı eğitim için, %90-%95 aralığı doğrulama son %5'lik kısım ise test verisi olarak belirlenmiştir. Modelin eğitimi için Klasik-DNN, CNN, RNN yöntemleri kullanılmıştır. Model mimarisi olarak 26 nörondan oluşan 1 girdi katmanı, 4 gizli katman ve 1 nörondan oluşan çıkış katmanından oluşmuş hisse senedi kapanış fiyatını temsil etmektedir. Gizli katmanlardaki nöron sayısı sırasıyla 32-64-128-256'dır. (Goodfellow, 2016).

Derin öğrenme mimarilerinde farklı aktivasyon fonksiyonları bulunmasına rağmen, genellikle ReLU fonksiyonu tercih edilmektedir (Nair ve Hinton, 2010; Krizhevsky vd., 2012). ReLU fonksiyonunun kullanıldığı derin sinir ağlarında öğrenme hızının arttığı ve kaybolan gradyan sorununu önlemek için etkili olduğu gözlemlenmiştir (Glorot vd., 2011). DL teknikleriyle eğitim aşaması gerçekleştirileceği zaman hiper-parametre değerlerinin ayarlanması gerekmektedir. Bu hiper-parametre değerleri modeli eğiten kişi tarafından belirlenmektedir, eğitim aşamasından kullanılan hiper-parametrelerin değerinin ne olacağı model başarısı açısından oldukça önemlidir. Modellerin eğitim aşamasında kullanılmış olan hiper-parametreler; döngü sayısı, pencere genişliği ve optimizasyon algoritmasıdır. DNN'nin, öğrenme aşaması filtre katsayılarının ve katmanlar arası ağırlıkların optimum seviyede belirlenmesiyle gerçekleşir. Bu ağırlıkların optimum şekilde güncellenmesi, öğrenme işleminin sonucunda başarılı sonuçlar alınması için çok önemlidir. Geri Yayılım Algoritması ağırlık çıkışındaki hata miktarını geriye doğru yayarak her bir ağ ağırlığının hataya katkısını hesaplar ve böylece ağırlıklar güncellenir. Bu çalışmada, ağırlıkların ideal değerlerde güncellenmesi için Adam (Kingma ve Ba, 2014) ve Adadelata (Zeiler, 2012) algoritmaları optimizasyon algoritması olarak belirlenmiştir. Döngü, eğitim sürecinde tüm

veri setinin kaç kez gösterildiğini ifade etmektedir. Genellikle döngü sayısı arttıkça öğrenme başarısı artmaktadır. Bu sebeple döngü sayıları 4,8,12 ve 50 olarak seçilmiştir. Pencere genişliği ise bir döngüde derin ağı gösterilecek veri sayısını belirlemek için kullanılmaktadır (Nazir vd., 2018: 406). Derin öğrenme modelleri, belirlenen hiper-parametre değerlerinin kombinasyonlarıyla eğitilmesi işlemi için ızgara arama yönteminden geçirilmiştir. Izgara arama yöntemi sonucunda tüm hiper-parametre kombinasyonları ile eğitilen modeller içerisinde en başarılı modeli oluşturan hiper-parametre değerleri tespit edilmiştir. Tablo 3.3'te derin sinir ağı eğitimindeki adımlara yer verilmiştir.

Tablo 3.3. Derin sinir ağı eğitiminde uygulanan işlemler

<b>Veri zaman türü</b>	Günlük				
<b>İşlem günü aralığı</b>	03-06-2013/28-05-2021				
<b>Veri setinin bölünmesi</b>	<b>Eğitim Verisi</b>	<b>Doğrulama Verisi</b>			<b>Test Verisi</b>
	İlk %90	%90 ile %95 aralığı (%5)			Son %5
<b>Normalizasyon yöntemi</b>	Min-max				
<b>Bağımsız değişkenler(girdi)</b>	1	20. güne kadar gecikmeli değerleri			
	2	İşlem günü en düşük değeri			
	3	İşlem günü en yüksek değeri			
	4	İşlem günü açılış değeri			
	5	İşlem günü gram altın fiyatı(TL)			
	6	İşlem günü dolar kuru(TL)			
	7	İşlem günü Brent petrol fiyatı(TL)			
<b>Bağımlı değişken(çıkıtı)</b>	Hisse senedi kapanış fiyatı				
<b>Tahmin için kullanılan Yöntemler</b>	Klasik-DNN/ CNN/ RNN				
<b>Hiper-parametreler ve değer aralığı</b>	Pencere sayısı	2,4,6,8,12,16,20			
	Döngü sayısı	4,8,12,50			
	Optimizasyon algoritması	Adam, Adadelata			
<b>Derin öğrenme katman yapısı</b>	Girdi Katmanı	1.Gizli katman	2. Gizli katman	3.Gizli katman	4.Gizli katman
	(20,6)	32	64	128	256

VESTL hisse senedi verileri için ele alınan her bir model, ızgara arama yöntemiyle belirlenen hiper-parametreler kullanılarak eğitilmiştir. Ayrıca modelin eğitimi sırasında Python dili "TensorFlow" kütüphanesinde bulunan, erken durdurma yöntemi kullanılmıştır. Bu yöntem, modelin eğitimi sırasında RMSE ölçütünün takip edilmesi işlemi ile gerçekleşir.

Modeldeki başarı ölçütü olan RMSE ardışık 3 döngü sonucunda düşüş göstermemiş ise, model eğitim işlemi durmaktadır. Böylece, gereksiz işlem tekrarıyla kaçınılarak en kısa süre içerisinde en başarılı modelin tespit edilmesi sağlanmıştır.

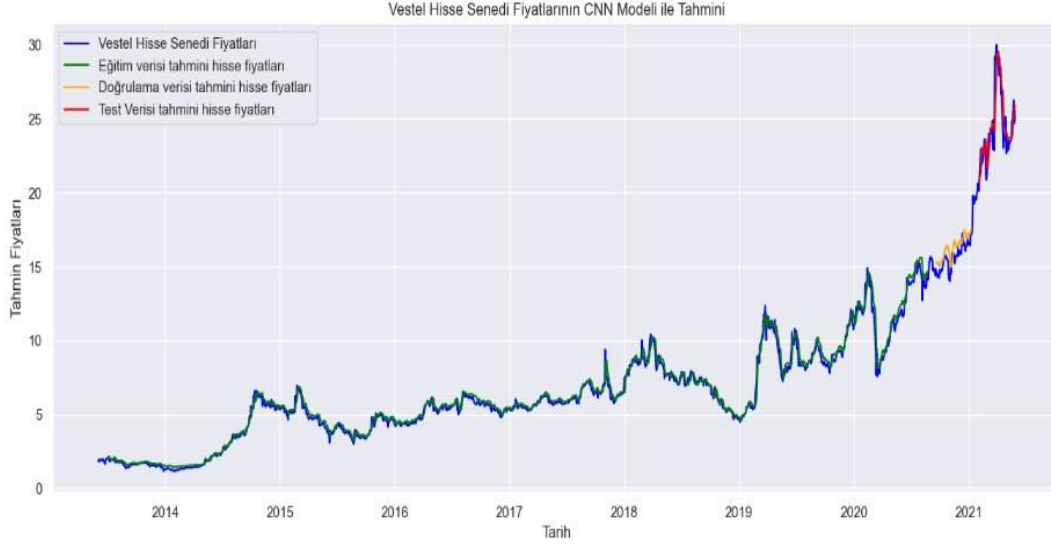
### 3.3. Kurulan Modeller ve Performans Ölçütleri

Farklı 3 derin öğrenme yöntemi ve farklı hiper-parametre değerleri ile yapılan model eğitimleri sonucundan tahmin aşamasına geçilmiştir. Tablo 3.4'te her derin öğrenme metodu için en az hata ile tahminde bulunan modellerin hiper-parametre değerleri ve eğitim-doğrulama-test veri setleri için başarı ölçütü değerleri verilmiştir.

Tablo 3.4. Model performanslarının karşılaştırılması

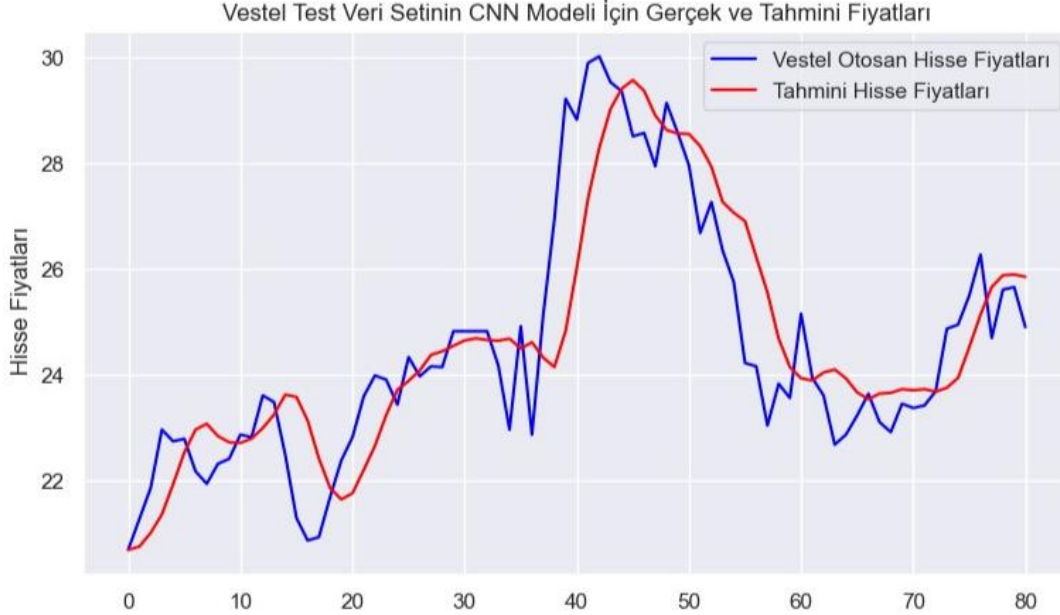
Derin Sinir Ağı Türü	Hiper-parametre			Veri Seti	Başarı ölçütü	
	Optimizasyon algoritması	Döngü Sayısı	Pencere Genişliği		MSE	RMSE
Klasik DNN	Adadelta	50	6	Eğitim	0.0215	0.1466
				Doğrulama	0.2267	0.4761
				Test	0.7268	0.8525
CNN	Adam	12	16	Eğitim	0.0006	0.0245
				Doğrulama	0.0030	0.0548
				Test	0.0074	<b>0.086</b>
RNN	Adam	50	6	Eğitim	0.0003	0.0173
				Doğrulama	0.0009	0.03
				Test	0.1065	0.3263

Eğitilen modellerin sonuçlarını incelendiğinde en az hata ile tahminde bulunan model Adam optimizasyon algoritması ile eğitilmiş, 12 döngü sayısından oluşan ve 16 pencere genişliğine sahip CNN derin öğrenme mimarisi olmuştur. En başarılı model olan CNN derin öğrenme modeli tahmin sonuçları Grafik 3.3'te verilmiştir. Grafik 3.3'te VESTL hisse senedi tahmininde kullanılan eğitim-doğrulama-test veri setlerinin orijinal değerleri mavi çizgiler ile verilmiştir. Grafikteki yeşil çizgi, veri setinin ilk %90'lık kısmını oluşturan eğitim veri seti için model tahminlerini göstermektedir. Grafikteki sarı çizgi, veri setinin ilk %90-%95'lik kısmı olan doğrulama veri seti için tahmini hisse senedi kapanış değerlerini vermektedir. Grafikte kırmızı çizgiler ise veri setinin son %5'lik kısmını olan test veri seti ile tahmin edilmiş hisse senedi kapanış fiyatlarını temsil etmektedir.



Grafik 3.3. CNN derin sinir ağı ile VESTL hisse senedi tahmini fiyatları

Grafik 3.4'te, VESTL test veri setinin gerçek değerleri ve CNN derin sinir ağı ile tahmin edilen değerleri verilmiştir. CNN derin öğrenme modeli ile tahmin edilen sonuçlar test veri setinde 0. ile 30. işlem günü arasındaki dalgalanmaları, daha sonrasında 40. ile 45. günler arasında yükseliş trendini ve 45. ile 65. günler arasında gerçekleşen düşüş trendini başarılı şekilde tahmin etmiştir. Model test verisinde gerçekleşen dalgalanmaları ve artan ve azalan trendi başarılı bir şekilde yakalamıştır.



Grafik 3.4. CNN derin sinir ağı ile VESTL hisse senedi tahmini fiyatları



#### 4. Sonuç

Bu çalışmada, hisse senedi kapanış fiyatlarının tahmini için Klasik-DNN, CNN ve RNN olmak üzere üç farklı derin sinir ağı modeli kullanılarak analizler yapılmış ve model performansları karşılaştırılmıştır. Bunun için, Vestel Elektronik Sanayi ve Ticaret A.Ş. (VESTL) şirketine ait kapanış fiyatı verileri 3 Haziran 2013-28 Mayıs 2021 dönemi için günlük olarak elde edilmiştir. Kapanış fiyatları analizde bağımlı değişken olarak ele alınırken, bağımsız değişkenler olarak, kapanış fiyatlarının 20 günlük gecikmeli değerleri, işlem günü için açılış fiyatı, en düşük fiyat, en yüksek fiyat, gram altın fiyatı, Brent petrol fiyatı ve dolar kuru verileri kullanılmıştır. Modellerin eğitilmesi süreci sonucunda VESTL hisse senedi için toplam 168 farklı olası model gözden geçirilmiştir. Bu olası modeller oluşturulurken 3 farklı derin öğrenme metodu, 2 farklı optimizasyon algoritması, 7 farklı pencere sayısı ve 4 farklı döngü sayısı kullanılmıştır. Tüm bu değerlerin kombinasyonları, ızgara arama yöntemi kullanılarak model eğitiminde denenmiş ve en az hata tahmini veren model tespit edilmeye çalışılmıştır. Ayrıca, modellerin eğitimi aşamasında erken durdurma yöntemi kullanılmıştır. Buna göre, modeldeki başarı ölçütü olan RMSE ardışık 3 döngü sonucunda düşüş göstermemiş ise model eğitim işlemi durmaktadır. Böylece işlem tekrarından kaçınılarak en kısa süre içerisinde en başarılı modelin tespit edilmesi sağlanmıştır. Analiz sonucunda en başarılı modelin döngü sayısı 16, pencere genişliği 12, optimizasyon algoritması Adam ile eğitilen CNN derin öğrenme mimarisi olduğu tespit edilmiştir. Bu model 0.086 RMSE değeri ile en az hata ile tahminde bulunan model olarak belirlenmiştir.

Çalışmada sunulan ampirik sonuçlar, derin öğrenme ağlarının üstünlüğünü kesin bir şekilde gösteren bir kanıt sunmamakla birlikte, gelecekteki fiyat hareketleri hakkında öngörüler elde etmek için kullanılabileceğini göstermektedir. Gelecek çalışmalarda, hisse senedi fiyat tahminleri için derin sinir ağı modellerine farklı değişkenlerin de bağımsız değişkenler olarak eklenmesi ve hibrit derin ağ algoritmaları ele alınarak analizler yapılması planlanmaktadır. Böylece, hisse senedi fiyat tahminlerinde daha başarılı ve güvenilir sonuçlar elde etmenin mümkün olacağı düşünülmektedir.

## Kaynaklar

- 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>
- ARSLANKAYA, S., & TOPRAK, Ş. (2021). Makine öğrenmesi ve derin öğrenme algoritmalarını kullanarak hisse senedi fiyat tahmini. International Journal of Engineering Research and Development, 13(1), 178-192. <https://doi.org/10.29137/umagd.771671>
- BINGOL, K., AKAN, A. E., ÖRMECİOĞLU, H. T., & ER, A., (2020). Artificial intelligence applications in earthquake resistant architectural design: Determination of irregular structural systems with deep learning and ImageAI method. Journal of The Faculty of Engineering and Architecture of Gazi University , vol.35, no.4, 2197-2209.
- CHOLLET, F. (2018). *Deep Learning with Python*. Manning Publications Co.
- CIABURRO, G., & VENKATESWARAN, B. (2017). *Neural Networks with R: Smart models using CNN, RNN, deep learning, and artificial intelligence principles*. Packt Publishing Ltd.
- CİHAN, P., & COŞKUN, H. (2021). Performance comparison of machine learning models for diabetes prediction. *29th Signal Processing and Communications Applications Conference (SIU)* (Pp. 1-4). IEEE.
- GLOROT, X., BORDES, A., & BENGIO, Y. (2011). Deep sparse rectifier neural networks. *Proceedings of the Fourteenth International Conference On Artificial Intelligence and Statistics* (p. 315-323).
- GOODFELLOW, I., BENGIO, Y., & COURVILLE, A. (2016). *Deep Learning*. MIT Press.
- GURESEN, E., KAYAKUTLU, G., & DAİM, T. U. (2011). Using artificial neural network models in stock market index prediction. *Expert systems with Applications*, 38(8), 10389-10397.
- HUBEL, D. H., & WIESEL, T. N. (1968). Receptive fields and functional architecture of monkey striate cortex. *The Journal of physiology*, 195(1), 215-243. <https://doi.org/10.1113/jphysiol.1968.sp008455>
- KARAATLI, M., GÜNGÖR, İ., DEMİR, Y., KALAYCI, Ş. (2005). Hisse senedi fiyat hareketlerinin yapay sinir ağları yöntemi ile tahmin edilmesi. *Journal of Management and Economics Research*, 3(3), 38-48.
- KAZEM, A., SHARIFI, E., HUSSAIN, F.K., SABERI, M., & HUSSAIN, O.K. (2013). Support vector regression with chaos-based firefly algorithm for stock market price forecasting. *Applied soft computing*, 13(2), 947-958. <https://doi.org/10.1016/j.asoc.2012.09.024>.
- AYYÜCE KIZRAK, M., & BOLAT, B. (2018). Derin Öğrenme ile Kalabalık Analizi Üzerine Detaylı Bir Araştırma. *Bilişim Teknolojileri Dergisi*, 11(3), 263-286. <https://doi.org/10.17671/gazibtd.419205>.
- KIM, H.Y., WON, C.H. (2018). Forecasting the volatility of stock price index: A hybrid model integrating LSTM with multiple GARCH-type models. *Expert Systems with Applications*, 103:25-37.

- KINGMA, D.P., & BA, J. (2014). Adam: A Method for Stochastic Optimization. *CoRR, abs/1412.6980*.
- KRIZHEVSKY, A., SUTSKEVER, I., & HINTON, G. E. (2012). ImageNet Classification with Deep Convolutional Neural Networks. In Proceedings of the 25th International Conference on Neural Information Processing Systems- Volume 1 (NIPS'12). Curran Associates Inc., Red Hook, NY, USA, 1097–1105.
- MONFARED, S.A. & ENKE, D. (2014). Volatility Forecasting Using a Hybrid GJR-GARCH Neural Network Model, *Procedia Computer Science*, Vol.36, 246-253, <https://doi.org/10.1016/j.procs.2014.09.087>.
- NAIR, V., & HINTON, G. E. (2010). Rectified linear units improve restricted boltzmann machines. In Proceedings Of The 27th International Conference On Machine Learning (ICML10) (pp. 807-814).
- NAZIR, S., PATEL, S., & PATEL, D. (2018). Hyper parameters selection for image classification in convolutional neural networks. *2018 IEEE 17th International Conference on Cognitive Informatics & Cognitive Computing (ICCI\*CC)*, Berkeley, CA, USA, 2018, pp. 401-407, doi: 10.1109/ICCI-CC.2018.8482081.
- NIELSEN, M. A. (2015). *Neural Networks and Deep Learning*. Determination Press.
- İNİK, Ö., & ÜLKER, E. (2017). Derin öğrenme ve görüntü analizinde kullanılan derin öğrenme modelleri. *Gaziosmanpaşa Bilimsel Araştırma Dergisi*, 6(3), 85-104.
- PERVAN, N. (2019). Derin öğrenme yaklaşımları kullanılarak türkçe metinlerden anlamsal çıkarım yapma. Yüksek Lisans Tezi, Ankara Üniversitesi Fen Bilimleri Enstitüsü, Ankara.
- SIMARD, P. Y., STEINKRAUS, D., & PLATT, J. C. (2003). Best practices for convolutional neural networks applied to visual document analysis," *Seventh International Conference on Document Analysis and Recognition, 2003. Proceedings.*, Edinburgh, UK, 2003, pp. 958-963, doi: 10.1109/ICDAR.2003.1227801.
- TAN, F. G., YÜKSEL, A. S., AYDEMİR, E., ERSOY, M. (2021). Derin öğrenme teknikleri ile nesne tespiti ve takibi üzerine bir inceleme. *Avrupa Bilim ve Teknoloji Dergisi* (25), 159-171. <https://doi.org/10.31590/ejosat.878552>
- TEKTAŞ, A., & KARATAŞ, A. (2010). Yapay sinir ağları ve finans alanına uygulanması: hisse senedi fiyat tahminlemesi. *Atatürk Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 18(3-4).
- THAKKAR, A. & KINJAL CHAUDHARI, K. (2021). A comprehensive survey on deep neural networks for stock market: The need, challenges, and future directions, *Expert Systems with Applications*, 177,114800,<https://doi.org/10.1016/j.eswa.2021.114800>.
- TOĞAÇAR, M., ERGEN, B., & CÖMERT, Z. (2020). BrainMRNet: Brain tumor detection using magnetic resonance images with a novel convolutional neural network model. *Medical hypotheses*, 134, 109531. <https://doi.org/10.1016/j.mehy.2019.109531>.
- TOKGÖZ, A., & ÜNAL, G. (2018, May). A RNN based time series approach for forecasting turkish electricity load. 26th Signal Processing and Communications Applications Conference (SIU), Izmir, Turkey ,pp. 1-4. doi: 10.1109/SIU.2018.8404313.
- WANG, J.Z., WANG, J.J., ZHANG, Z.G. & GUO, S.P. (2011). Forecasting stock indices with back propagation neural network, *Expert Systems with Applications*, Vol.38, Issue 11, 14346-14355, <https://doi.org/10.1016/j.eswa.2011.04.222>.

ZAHEER S, ANJUM N, HUSSAIN S, ALGARNI AD, IQBAL J, BOUROUIS S, ULLAH SS.(2023). A Multi Parameter Forecasting for Stock Time Series Data Using LSTM and Deep Learning Model. *Mathematics*, 11(3):590. <https://doi.org/10.3390/math11030590>

ZEILER, M. D. (2012). ADADELTA: An Adaptive Learning Rate Method (Version 1). arXiv. <https://doi.org/10.48550/ARXIV.1212.5701>