

-ARAŞTIRMA MAKALESİ-

**DERİN ÖĞRENME MODELLERİ İLE HİSSE SENEDİ FİYAT TAHMİNİ:
LSTM, GRU, RNN, MLP MODELLERİNİN KARŞILAŞTIRMALI ANALİZİ**

Zeynep ÇOLAK ¹

Öz

Borsa hakkında tahminlerde bulunmak oldukça zordur ve veri kalıplarına ilişkin kapsamlı bir araştırma gerektirir. Finans analistleri, büyük veri çağında hisse senedi fiyat tahminlerinde genellikle derin öğrenme tekniklerine başvurmaktadır. Bu teknikler, tahminlerin doğruluğunu artırarak yatırımcıların daha bilinçli kararlar almasına olanak tanıyabilmektedir. Ancak, hisse senedi fiyat tahmini, borsa piyasasının karmaşık yapısı ve dinamik etkileşimleri nedeniyle finansal tahminler alanındaki en zorlu ve öngörülemez görevlerden biri olarak kalmaktadır. Derin öğrenme teknolojisi, öncelikle hisse senedi fiyatlarına dayalı finansal zaman serisi tahminini iyileştirmek için finans sektöründe yaygın olarak kullanılmaktadır. Geleneksel hisse senedi fiyat tahmin modellerindeki düşük uyum ve zayıf doğruluk sorununu çözmek için bu makale, derin öğrenme algoritmalarına dayalı bir hisse senedi fiyat tahmin modeli önermektedir. Bu çalışmada, finans piyasalarının en köklü şirketlerinden biri olan Nike'in (NKE) hisse senedi fiyat hareketleri, modern derin öğrenme yaklaşımları kullanılarak analiz edilmiştir. 1993'ten 2024'e uzanan 31 yıllık süreçte, Nike hissesinin günlük açılış, yüksek, düşük, kapanış fiyatları ve işlem hacimlerini içeren bir veri seti kullanılmıştır. Bu amaçla, Uzun-Kısa Süreli Bellek (LSTM) Kapılı Tekrarlayan Birim (GRU) Yinelemeli Sinir Ağları (RNN) Çok Katmanlı Algılayıcı (MLP) olmak üzere dört farklı derin öğrenme modeli ele alınmıştır. Analiz sonuçlarına göre, eğitim metrikleri, LSTM modelinin en düşük MAE (1.606) ve RMSE (0.821) değerleriyle en başarılı eğitim performansını sergilediğini ve 0.998 R² değeriyle veri setindeki varyansın büyük bir kısmını açıkladığını göstermektedir. GRU modeli ise biraz daha yüksek hata metriklerine (MAE: 1.009, RMSE: 1.190) sahip olmakla birlikte, 0.996 R² değeriyle güçlü tahmin yeteneğini korumaktadır. Buna karşılık, RNN ve MLP modelleri, sırasıyla 1.827 ve 1.786 RMSE değerleri ile daha yüksek hata oranları göstermiş ve zaman serisi verilerindeki karmaşık bağımlılıkları yakalamada yetersiz kalmıştır. Sonuçlar, finansal zaman serisi tahminlerinde LSTM ve GRU modellerinin sağladığı avantajları vurgularken, bu modellerin kullanımının özellikle uzun vadeli analizlerde güvenilir sonuçlar üretebileceğini göstermiştir.

Anahtar Kelimeler: Derin Öğrenme, Hisse Senedi Tahmini, LSTM, GRU, RNN, MLP.

JEL Kodları: C02, C22, C53.

Başvuru: 04.12.2024

Kabul: 18.03.2025

¹ Unvan, Kurum, E-Posta, ORCID

STOCK PRICE PREDICTION WITH DEEP LEARNING MODELS: COMPARATIVE ANALYSIS OF LSTM, GRU, RNN, MLP MODELS²

Abstract

Making predictions about the stock market is challenging and requires extensive research into data patterns. In the era of big data, financial analysts often resort to deep learning techniques in stock price forecasting. These techniques can improve the accuracy of forecasts, allowing investors to make more informed decisions. However, stock price forecasting remains one of the most challenging and unpredictable tasks in financial forecasting due to the complexity and dynamic interactions of the stock market. Deep learning technology has been widely used in the financial industry, primarily to improve financial time series forecasting based on stock prices. This paper proposes a stock price prediction model based on deep learning algorithms to solve the problem of low fit and poor accuracy in traditional stock price prediction models. This study analyzes the stock price movements of Nike (NKE), one of the most established companies in the financial markets, using modern deep learning approaches. We use dataset of daily opening, high, low, and closing prices and trading volumes of Nike stock over 31 years from 1993 to 2024. For this purpose, four different deep learning models, namely Long-Short Term Memory (LSTM) Gated Recurrent Unit (GRU) Recurrent Neural Networks (RNN) Multilayer Perceptron (MLP), were used. According to the analysis results, the training metrics show that the LSTM model exhibits the most successful training performance with the lowest MAE (1.606) and RMSE (0.821) values and explains a large portion of the variance in the dataset with an R^2 value of 0.998. The GRU model, on the other hand, has slightly higher error metrics (MAE: 1.009, RMSE: 1.190), but maintains its strong prediction ability with an R^2 value of 0.996. In contrast, the RNN and MLP models showed higher error rates with RMSE values of 1.827 and 1.786, respectively, and were insufficient to capture complex dependencies in time series data. The results highlight the advantages of LSTM and GRU models in financial time series forecasting and show that using these models can produce reliable results, especially in long-term analysis.

Keywords: Deep Learning, Stock Forecasting, LSTM, GRU, RNN, MLP.

JEL Codes: C02, C22, C53.

“Bu çalışma Araştırma ve Yayın Etiğine uygun olarak hazırlanmıştır.”

1. GİRİŞ

Derin öğrenme, son derece karmaşık doğrusal olmayan ilişkileri modelleyebilme yeteneğine sahip olup, etki eden faktörlerin karmaşık özelliklerini kapsamlı bir şekilde tanımlayabilmektedir. Görüntü sınıflandırma ve gen analizi gibi çeşitli alanlarda,

² The Extended English Summary is located the end of the Article

derin öğrenme modellerinin tahmin doğruluğu yüksek başarılarla doğrulanmıştır. Zaman serisi veri analizi ve tahmini konusunda da derin öğrenme algoritmalarına ilişkin araştırmalar yapılmıştır (Akita vd. 2016). Genel olarak, derin öğrenme modelleri, çeşitli araştırma alanlarında üstün performans sergileyerek dikkat çekmektedir. Bu bağlamda, derin öğrenme tekniklerinin kullanılması, hisse senedi trendlerinin tahmin edilmesinde potansiyel bir yaklaşım olarak öne çıkmaktadır.

Finansal zaman serilerinin doğrusal olmaması ve yüksek volatilitesi, hisse senedi fiyatlarının tahmin edilmesini zorlaştırmıştır. Ancak derin öğrenmedeki son gelişmeler ile uzun kısa süreli bellek (LSTM) ve evrişimli sinir ağı (CNN) modelleri gibi yöntemler sayesinde bu tip verilerin analizinde önemli gelişmeler elde edilmiştir. Ayrıca, zaman serilerini farklı frekans spektrumlarına ayıran ampirik mod ayrıştırma (EMD) ve tam topluluk ampirik mod ayrıştırma (CEEMD) algoritmaları da finansal zaman serilerinin analizinde etkili olabilecek yöntemler arasındadır (Rezai vd. 2021).

Finans analistleri, büyük veri çağında hisse senedi fiyat tahminlerinde genellikle derin öğrenme tekniklerine başvurmaktadır (Viadinugroho ve Rosadi, 2021). Bu teknikler, tahminlerin doğruluğunu artırarak yatırımcıların daha bilinçli kararlar almasına olanak tanıyabilmektedir. Ancak, hisse senedi fiyat tahmini, borsa piyasasının karmaşık yapısı ve dinamik etkileşimleri nedeniyle finansal tahminler alanındaki en zorlu ve öngörülemez görevlerden biri olarak kalmaktadır. Bu durum, piyasa faktörlerinin yüksek volatilitesi, belirsizlik ve çok sayıda değişkenle etkileşim içerisinde olmasıyla daha da belirginleşmektedir (Tay ve Cao, 2001). Ekonomi, derin öğrenme ve diğer ilgili alanlardaki araştırmalar, hisse senedi fiyat tahmininde önemli bir devrim yaratmıştır (Al-Tamimi vd. 2011). Bu bağlamda, bu araştırmanın amacı, yatırımcılar ve finansal analistler için hangi derin öğrenme modelinin daha güvenilir tahminler ürettiğini belirlemektir.

Nike, zamanla finansal açıdan güçlü bir konuma ulaşarak küresel ölçekte faaliyet gösteren bir şirkettir. Uzun vadeli finansal analizler açısından güvenilir ve kapsamlı bir veri seti sunması, şirketin hisse senedi fiyatlarının öngörülmesine yönelik çalışmalar için uygun bir örneklem oluşturmasına katkı sağlamaktadır. Ayrıca, Nike hisselerinin yüksek işlem hacmine sahip olması, piyasa hareketlerindeki olası manipülasyon riskini azaltarak tahmin modellerinin daha sağlıklı ve güvenilir sonuçlar üretmesine imkân tanımaktadır. Küresel ölçekte tanınan büyük ölçekli bir şirketin hisse senedi fiyatlarını tahmin etmeye yönelik analizler, yalnızca akademik araştırmalar açısından değil, aynı zamanda finans sektörü ve yatırımcılar için de önemli bir uygulama alanı sunmaktadır. Bu sebeple çalışmada, finans piyasalarının en köklü şirketlerinden biri olan Nike'in (NKE) hisse senedi fiyat hareketleri, modern derin öğrenme yaklaşımları kullanılarak analiz edilmiştir. 1993'ten 2024'e uzanan 31 yıllık süreçte, Nike hissesinin günlük açılış, yüksek, düşük, kapanış fiyatları ve işlem hacimlerini içeren zengin bir veri seti kullanılmıştır. Bu amaçla, Uzun-Kısa Süreli Bellek (LSTM) Kapılı Tekrarlayan Birim (GRU) Yinelemeli Sinir Ağları (RNN) Çok Katmanlı Algılayıcı (MLP) olmak üzere dört farklı derin öğrenme modeli kullanılmıştır.

1.1. Literatür Taraması

Tahmin modellerinin geliştirilmesi, her zaman hisse senedi fiyat tahmini alanındaki en önemli araştırma konularından biri olmuştur. Hisse senedi fiyat tahmin yöntemleri çoğunlukla ekonometrik bir model veya derin öğrenme modelini benimser. Bu iki model, borsadaki karmaşık finansal zaman serisi verilerini işlemeye daha uygun olacak şekilde sürekli olarak geliştirilmiştir.

Ekonometrik modeller açısından, Booth vd. (1994) çalışmalarında, 1970'ler ve 1980'lerde günlük Fin hisse senedi getirilerindeki doğrusal olmayan dinamiklerin doğasını keşfetmek için Grassberger-Procaccia korelasyon boyutlarını kullanmışlardır. Basit bir GARCH modeli, ilk on yıldaki doğrusal olmayanlığı ortadan kaldırır ve ikinci dönemdeki doğrusal olmayanlığı önemli ölçüde azaltır. Bu, Fin hisse senedi getirilerinin doğrusal olmayan bağımlılık gösterdiği ancak bağımlılık biçiminin kaotik olmadığı fikrini desteklemektedir.

Breidt vd. (1998) RCH, genelleştirilmiş ARCH (GARCH) veya standart (kısa hafızalı) stokastik volatilité modellerinin hisse senedi fiyatını tahmin etmek için uygun olmadığını göstermişlerdir. Koşullu varyanslarla başa çıkabilen, uzun hafızalı stokastik volatilité modeli olarak adlandırılan ve diğer modellerden daha üstün olan yeni bir zaman serisi tahmin yöntemi önermişlerdir. Çevik (2002), 1986-2002 dönemi arasındaki aylık verilerle BIST endeksini modellemek amacıyla Box-Jenkins metodolojisinden ARMA yöntemini kullanarak gerçekleştirdiği tahmin çalışmasında, seriye en uygun modelin ARIMA (1,2,1) modeli olduğunu belirlemiştir.

Gökbulut vd. (2014) ise, çalışmalarında çeşitli GARCH modelleri kullanılarak Türk Finans Piyasalarının ortalama getirisi ve koşullu varyansının kapsamlı bir ampirik analizi gerçekleştirilmiştir. CGARCH ve TGARCH, 2002-2014 yılları arasında Türkiye'deki finansal araçların oynaklığını modellemek için üstün görünmektedir. Ayrıca, tüm piyasaların getiri serilerinin; leptokurtosis, asimetri, oynaklık kümelenmesi ve uzun hafızayı içerdiği bulunmuştur. Zhang ve Zhang (2016) diferansiyel bilgiye dayalı geliştirilmiş bir ARIMA-GARCH modeli önermiştir. Bağımlı değişken gecikmesinin yaklaşık diferansiyel bilgisinin eklenmesi ve hisse senedi fiyat değişim eğilimi bilgisinin dikkate alınmasıyla, fiyat değişiminin yönünü tahmin etme yeteneği geliştirilmiştir.

Derin Öğrenme teknolojisinin gelişmesiyle birlikte, birçok akademisyen hisse senedi fiyatını daha doğru tahmin etmek için geleneksel tahmin modelleri yerine yeni ortaya çıkan teknoloji ile sorunu çözmeye çalışmaktadır. Praveen vd. (2023) yaptıkları çalışmada, hisse senedi tahminini ele almış ve LSTM (uzun kısa vadeli bellek) olarak bilinen algoritmayı içeren bir derin öğrenme modeli önermiştir. 2016-2023 tarihleri arasında Hindistan Ulusal Borsasında işlem gören şirketlerin hisse senetleri veri seti olarak kullanılmıştır. Bu çalışma, ertesi günün kapanış fiyatının beklenen değerini ve modelin doğruluğunu sağlayan LSTM ve doğrusal regresyon yöntemlerini kullanmaktadır. LSTM'nin %98 doğruluk oranına ve doğrusal regresyonun %94

doğruluk oranına sahip olması nedeniyle, bu iki algoritmanın karşılaştırılmasından LSTM'nin daha yüksek doğruluk sağladığı sonucuna varılmıştır.

Nelson vd. (2017), gelecekte hisse senedi fiyatının yükselişini ve düşüşünü tahmin etmek için LSTM modelini ve çoklu hisse senedi analiz göstergelerini kullanmıştır. 2008-2015 yılları arasında BM&F Bovespa borsasından IBovespa endeksine dahil olan hisse senetleri veri seti olarak kullanılmıştır. Sonuç, belirli bir hisse senedinin fiyatının yakın gelecekte yükselip yükselmeyeceğini tahmin etmede ortalama %55,9'a kadar doğruluk elde edilmiştir.

Şişmanoğlu vd. (2020) çalışmalarında, derin öğrenme tabanlı modeller olan Uzun Kısa Dönemli Bellek (LSTM), Gated Recurrent Unit (GRU) ve Çift Yönlü Uzun Kısa Dönemli Bellek (BLSTM) kullanılarak, New York Menkul Kıymetler Borsası (NYSE), Nasdaq ve NYSE MKT piyasalarındaki hisse senedi fiyatlarının geleceğe yönelik tahminini amaçlanmışlardır. Analiz, 2 Ocak 1968 ile 9 Nisan 2018 tarihleri arasındaki geniş kapsamlı piyasa verileri üzerinde gerçekleştirilmiştir. Önerilen derin öğrenme mimarilerinin uygulanması sonucunda, piyasa dinamiklerinin belirli ölçüde yakalanabileceği ve bu sayede daha doğru tahminlerin yapılabileceği görülmüştür. Yapılan deneyler sonucunda, 5 günlük giriş verisi ile eğitilen BLSTM modelinin %63,54 yönsel doğruluk oranı ve 0,01 kök ortalama kare hata (RMSE) değeri ile en yüksek performansı gösterdiği belirlenmiştir. Ayrıca, modelin 10 günlük işlem periyodu sonunda %13,47 oranında kâr sağladığı tespit edilmiştir.

Yan vd. (2021) çalışmalarında, LSTM derin sinir ağı, 2008'den 2019'a kadar Şanghay ve Shenzhen 300 Endeksi bileşenlerinin verilerini modellemek ve tahmin etmek için kullanılmıştır ve modelin tahmin doğruluğunu etkileyen üç tür faktör sistematik olarak incelenmiştir. Çalışmanın sonuçlarına göre, LSTM modelinin doğruluğu %62,31'dir. Geleneksel RNN modelinin doğruluğu yalnızca %37,38'dir; bu, LSTM modelinin doğruluğundan 25 puan daha düşüktür. Geleneksel BP modelinin doğruluğu yalnızca %42,41'dir; bu, LSTM modelinin doğruluğundan %20 daha düşüktür ancak geleneksel RNN'den 5 puan daha yüksektir. Ayrıca, RNN teorik olarak zaman serisi olmasına rağmen, zamanlama arttığında, RNN'nin gradyan kaybolma sorununa eğilimli olduğu ve RNN'nin şu anda herhangi bir avantajı olmadığı sonucuna varılabilir. LSTM sinir ağı, BP sinir ağından ve standart RNN'den daha yüksek bir tahmin doğruluğuna sahiptir ve hisse senedi fiyatlarını başarıyla tahmin edebilir.

Aksehir ve Kilic (2022) çalışmasındaki veriler Dow Jones Industrial Average (Dow 30) endeksine ait hisse senetlerinin günlük fiyat verileri 1 Ocak 2008 ile 15 Aralık 2021 tarihleri arasında elde edilmiştir. Veri seti, ilgili hisse senetlerinin açılış, kapanış, düzeltilmiş kapanış, en yüksek, en düşük ve işlem hacmi değerlerini içermektedir. Söz konusu veri kümesinde, düzeltilmiş kapanış fiyatları hisse senetlerini "al", "sat" veya "tut" olarak etiketlemek amacıyla kullanılmış; kapanış, en yüksek, en düşük ve işlem hacmi verileri ise teknik gösterge değerlerinin hesaplanması için değerlendirilmiştir. Çalışmada ki modeller dikkate alındığında etiketleme ve özellik seçimi sorunlarından kaynaklanan veri dengesizliğinden dolayı, sorunları çözmek için yeni bir kural tabanlı

etiketleme algoritması ve yeni bir özellik seçimi yaklaşımı önerilmiştir. Çalışmanın sonuçları, önerilen özellik seçimi ve etiketleme yaklaşımlarını kullanan CNN tahmin modelinin, diğer çalışmalarda yer alan CNN tabanlı modellerden %3-22 daha yüksek doğruluk sağladığını göstermiştir.

Çoban ve Hayat (2023) çalışmalarında, 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 karşılaştırmayı amaçlamışlardır. 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 yapmışlar ve analiz sonuçlarına göre, en iyi performans gösteren modelin CNN olduğu belirlenmiştir. Bu modelin RMSE değeri 0.086 olarak hesaplanmıştır. Bu sonuç, modelin hisse senedi fiyat tahmininde yüksek bir doğruluğa sahip olduğunu göstermektedir. Gavcar ve Metin (2021) çalışmalarında, Vestel Elektronik A.Ş.'nin 2016 ile 2021 yılları arasındaki değerleri 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 modelinden korelasyon katsayısı performans değerlendirme ölçütüne göre %95 doğruluk oranı elde edilmiştir.

Albayrak ve Saran (2023) çalışmalarında, Otoregresif Entegre Hareketli Ortalama (ARIMA) yöntemini tekrarlayan sinir ağlarının üç farklı (LTSM, GRU ve dikkat katmanlı LSTM) modeli ile karşılaştırılmışlardır. Veri seti, 2001-2020 tarih aralığında Borsa İstanbul'dan üç farklı hisse senedi (ASELS, AKBNK ve AKEN) için oluşturulmuştur. Çalışmada Borsa İstanbul verileri üzerinde 28 tane finansal indikatör kullanılarak gün içi tahminler yaparken dört farklı modelin sonuçları karşılaştırılmıştır İstatistiksel ve doğrusal bir model olan ARIMA, zaman serisi tahmininde doğrusal olmayan RNN modelleri ile karşılaştırılmış olup, üç sinir ağı modeline kıyasla daha yüksek ortalama hata oranına sahip olduğu belirlenmiştir. LSTM modeli, GRU ile benzer sonuçlar üretmiş olsa da, GRU modeli performans açısından bir miktar daha üstün bulunmuştur. Bununla birlikte, dikkat mekanizması içeren sinir ağı modeli, diğer temel sinir ağı modellerine kıyasla daha iyi sonuç vermemiştir. Raşo ve Demirci (2019) tarafından gerçekleştirilen çalışmada, Borsa İstanbul 30 (BIST 30) endeksine ait hisse senedi fiyatlarının tahmini amacıyla 9 katmanlı Destek Vektör Makinesi (Support Vector Machine, SVM) tabanlı bir yapay öğrenme modeli kullanılmıştır. Çalışmada, 1 Ocak 2016 ile 11 Nisan 2018 tarihleri arasındaki borsa hisse değerleri veri seti olarak kullanılmış ve beş günlük hisse fiyatlarının tahmini hedeflenmiştir. Modelin giriş değişkenleri belirlenirken, ekonomik analiz yöntemleri kullanılarak hesaplanan indikatör ve osilatör değerlerinden yararlanılmıştır. Çalışmanın sonuçlarına göre, modelin tahmin performansı birinci günden beşinci güne kadar sırasıyla 0.0322, 0.109, 0.09, 0.1069 ve 0.2581 ortalama kare hata (Mean Squared Error, MSE) değerleri ile değerlendirilmiştir.

Dalkıran ve Ozan (2022) çalışmalarında, 31.12.2007- 28.02.2021 tarih aralığında Borsa İstanbul dahilinde Türkiye İş Bankası A.Ş. ye ait ISCTR hissesine ilişkin gün sonu kapanış fiyatları günlük olarak derin öğrenme modelleri kullanılarak tahmin oluşturmuşlardır. Çalışmada çok değişkenli yapıda uzun kısa-dönem hafıza (Long Short-Term Memory, LSTM) algoritması Adam ve RMSProp optimize edicileri ile kullanılmış ve performansı gözlemlenmiştir. Yapılan eğitimler neticesinde farklı parametre değerlerine sahip, LSTM temelli modeller arasında en düşük hata değeri, 32 Batch boyutu, 64 kayar pencere uzunluklu, 256 gizli katman ve RMSProp optimize edici kullanılarak TPU ortamında eğitilen model için elde edilmiştir. Analiz sonuçlarına göre modelin doğrulama hatası MSE (0.01844), MAE (0.07342), MRE (0.01465) olarak bulunmuş ve derin öğrenme modelleri ile yapılan bu tahmin modelinin kabul edilebilir hatalar dahilinde olduğu sonucuna ulaşılmıştır.

Erden (2023) tarafından gerçekleştirilen çalışmada, Borsa İstanbul 30 (BIST-30) endeksinde yer alan önemli hisse senetlerinden biri olan Ereğli Demir ve Çelik Fabrikaları T.A.Ş. (EREGL) verileri kullanılmıştır. Çalışma kapsamında, 1 Ocak 2020 ile 9 Eylül 2022 tarihleri arasındaki 673 günlük fiyat verileri analiz edilmiştir. Farklı zaman gecikmelerine yönelik senaryoların değerlendirildiği çalışmada, tahmin performanslarının karşılaştırılması amacıyla geleneksel Zaman Serisi Modellemesi (ARIMA) ile derin öğrenme tabanlı Uzun-Kısa Vadeli Bellek (LSTM), Geçitli Tekrarlayan Ünite (GRU) ve Özyineli Sinir Ağları (RNN) modelleri kullanılmıştır. Deneysel analizler sonucunda, RNN modelinin diğer yaklaşımlara kıyasla daha üstün bir tahmin performansı sergilediği ve test veri seti üzerinde ortalama %93 doğruluk oranına ulaştığı tespit edilmiştir.

Öztürk ve Karıcı (2024)'ün çalışmasında, hisse senedi fiyat tahminleri için Uzun-Kısa Vadeli Bellek (LSTM), Geçitli Tekrarlayan Ünite (GRU), Üretici Çekişmeli Ağlar (GAN) ve Geliştirilmiş Penaltılı Üretici Çekişmeli Ağlar (WGAN-GP) gibi derin öğrenme yöntemleri karşılaştırılmıştır. Google hisse senedi verileri kullanılarak yapılan analizde, modellerin performansı Kök Ortalama Kare Hata (RMSE), Ortalama Mutlak Hata (MAE) ve Belirlilik Katsayısı (R^2) gibi metriklerle değerlendirilmiştir. Sonuçlara göre, LSTM modeli, en düşük hata oranı ve en yüksek doğruluk ile en iyi performansı sergileyerek RMSE: 4.214, MAE: 3.387 ve R^2 : 0.9509 değerlerine ulaşmıştır. GAN modeli ise güçlü performansı ile dikkat çekmiş ve test verileri üzerinde sırasıyla RMSE: 4.048, MAE: 3.288 ve R^2 : 0.9578 olarak performans göstermiştir. Öte yandan, GRU modeli LSTM ve GAN'a kıyasla daha düşük doğruluk sergileyerek RMSE: 4.303, MAE: 3.42 ve R^2 : 0.9490 değerlerine ulaşmıştır. WGAN-GP modeli ise diğer modellere göre en yüksek hata oranını ve en düşük doğruluğu göstererek RMSE: 11.523, MAE: 9.015 ve R^2 : 0.2452 olarak hesaplanmıştır.

Özetle, ekonometrik modeller ve derin öğrenme modelleri hisse senedi fiyat tahmininde en yaygın kullanılan iki yöntemdir. Bununla birlikte, doğrusal olmayan zaman serisi problemlerini ekonometrik modellerle ele almak zordur, geleneksel makine öğrenimi modelleri ise çoğunlukla tek dönemlik verileri örnek olarak alır ve zaman içinde gelişen birçok örtük bilgiyi göz ardı eder (Baek ve Kim, 2018). Derin öğrenme teknolojisi, zaman serisi verilerini ve çok dönemli verileri etkili bir şekilde

işleyebilen yeni ve gelişmekte olan bir teknolojidir. Aynı zamanda, birden fazla modelin kombinasyonu genellikle tek bir modelden daha iyi performansa sahiptir ve hisse senedi fiyat tahmininde ana yön haline gelmektedir. Bu çalışma, uzun vadeli bir veri seti üzerinde modern derin öğrenme tekniklerinin karşılaştırmalı analizini sunması ve finans piyasalarında derin öğrenme uygulamalarına pratik bir perspektif kazandırması açısından özgün değere sahiptir. Bu çalışmada, Nike hisse senedi fiyatlarına ilişkin kapsamlı bir veri seti kullanılmıştır. Bu veri seti, modelin performansını daha güvenilir ve genellenebilir hale getirmektedir. Ayrıca çalışmada, LSTM, GRU, RNN ve MLP'nin test verisi üzerindeki performansları daha ayrıntılı bir biçimde karşılaştırılmış, her modelin finansal verilerdeki karmaşık desenleri öğrenme kapasitesine ilişkin farklı avantajları vurgulanmıştır. Bununla birlikte, çalışmamızın sınırlılıklarından biri, yalnızca Nike hisse senedi fiyatlarına odaklanmış olmasıdır. Gelecekteki araştırmalar, farklı hisse senetleri ve finansal enstrümanlar üzerinde yapılacak testlerle, modelin genellenebilirliğini artırabilir.

2. YÖNTEM


Bu bölümde çalışma içerisinde kullanılan veri seti ve derin öğrenme modellerinden Uzun-Kısa Süreli Bellek (LSTM) Kapılı Tekrarlayan Birim (GRU) Yinelemeli Sinir Ağları (RNN) Çok Katmanlı Algılayıcı (MLP) hakkında detaylı bilgiler verilecektir.

2.1. Derin Öğrenme Modelleri

2.1.1. Uzun-Kısa Süreli Bellek (LSTM)

LSTM, Hochreiter ve Schmidhuber (1997) tarafından geliştirilen ve uzun vadeli bağımlılıkları öğrenme konusunda özelleşmiş bir derin öğrenme mimarisidir. Geleneksel RNN'lerin karşılaştığı gradyan kaybı problemini çözmek için tasarlanan LSTM, özellikle finansal zaman serisi tahminlerinde yaygın olarak kullanılmaktadır (Selvin vd., 2017). LSTM'in ayırt edici özelliği, unutma, giriş ve çıkış kapıları sayesinde uzun vadeli bilgiyi seçici olarak saklayabilmesi ve güncelleyebilmesidir (Fischer ve Krauss, 2018). Şekil 1'de bir LSTM hücresinin yapısı ve kapıları gösterilmektedir.

Şekil 1. LSTM Hücre Yapısı ve Kapıları



Bu hücrede, t zamanındaki girdi verisi x_t ve bir önceki hücreden gelen çıktı (h_{t-1}), t zamanındaki hücre için girdi olarak kullanılır. İlk olarak, x_t ve h_{t-1} unutma kapısına


iletilir. Unutma kapısı, x_t ve h_{t-1} 'e göre, önceki hücreden aktarılan bilginin ne kadarının korunacağına karar verir. Bellek hücresine giren bu bilgiler, mevcut durumla ilişkilendirilerek kontrol edilir.

Girdi kapısında ise, bellek hücresine aktarılan yeni bilgi miktarı belirlenir. h_{t-1} ve x_t 'ye dayalı olarak, yeni bilgilerin ne kadarının kullanılacağı kararlaştırılır. Bu süreçte, bilgiler ya 1 (kullanılacak) ya da 0 (kullanılmayacak) değerleriyle ifade edilir. Çıktı kapısı ise, hücreden bir çıktı oluşturulup oluşturulmayacağını belirler. Bu kapı da h_{t-1} ve x_t girdilerini alarak, tıpkı girdi kapısında olduğu gibi, 0 veya 1 çıktısı üretir. Son olarak, t zamanındaki hücre durumu, $t+1$ anındaki hücreye aktarılırken, hem h_{t-1} hem de t zamanına ait bilgiler bir araya getirilir (Kim ve Won, 2018; Sakarya ve Yılmaz, 2019).

2.1.2. Kapılı Tekrarlayan Birim (GRU)

GRU, Cho vd. (2014) tarafından LSTM'in daha basit bir alternatifi olarak önerilmiştir. LSTM'den farklı olarak sadece güncelleme ve sıfırlama kapılarına sahip olan GRU, daha az parametre ile benzer performans gösterebilmektedir. Finansal piyasalardaki uygulamalarda, özellikle yüksek frekanslı işlemlerde tercih edilmektedir (Zhang vd. 2018). Şekil 2'de GRU Modeli verilmiştir.

Şekil 2. GRU Modeli




Şekil 2'de görüldüğü gibi GRU yapısında iki temel kapı bulunur: güncelleme kapısı (Z_t), önceki bilginin ne kadarının korunacağını belirler, resetleme kapısı (r_t) ise önceki bilginin ne kadarının unutulacağını kontrol eder. Bu kapılar, geçmişten gelen gizli durumu ve mevcut giriş verisini birleştirerek yeni bir aday gizli durum oluşturur. Güncelleme kapısı, eski ve yeni bilgiyi harmanlayarak son çıktıyı oluşturur. GRU, LSTM'ye göre daha basit bir yapıya sahip olup hücre durumu kullanmaz, bu da öğrenme sürecini hızlandırır ve hesaplama maliyetini azaltır (Kılınç ve Öztürk, 2022).

2.1.3. Yinelemeli Sinir Ağları (RNN)

RNN'ler, Rumelhart vd. (1986) tarafından tanıtilan ve sıralı veri işlemede temel oluşturan bir mimarıdır. Zaman serisi verilerinde ardışık bilgiyi işleyebilme yeteneği ile öne çıkan RNN'ler, hisse senedi fiyat tahmininde klasik bir yaklaşım sunmaktadır (Bao vd. 2017). Ancak uzun vadeli bağımlılıkları öğrenmede yaşadığı zorluklar, LSTM ve GRU gibi gelişmiş mimarilerin ortaya çıkmasına yol açmıştır. RNN'in genel yapısı Şekil 3'de gösterilmiştir.

Şekil 3. RNN Hücre Yapısı ve Kapıları




An unrolled recurrent neural network.

Input olarak ağı bir X_0 verisi girer ve işlemler tamamlandığında h_0 olarak çıkar. Bir sonraki adımda, giriş olarak yeni bir bilgi olan X_1 ve önceki adımın çıktısı olan h_0 kullanılır. Takip eden adımda ise, yeni giriş olarak X_2 ve bir önceki adımın çıktısı olan h_1 devreye girer. Bu süreç, her adımda benzer şekilde tekrarlanır.

2.1.4. Çok Katmanlı Algılayıcı (MLP)

MLP, Rosenblatt (1958) tarafından geliştirilen perceptron modelinin çok katmanlı bir versiyonudur. Finansal tahminlerde baseline model olarak kullanılan MLP, doğrusal olmayan ilişkileri modelleyebilme yeteneği ile öne çıkmaktadır (Heaton vd. 2016). Giriş, gizli ve çıkış katmanlarından oluşan yapısı ile zaman serisi verilerini işleyebilmektedir. Şekil 4, çok katmanlı bir yapay sinir ağının (MLP) temel mimarisini göstermektedir.

Şekil 4: Çok Katmanlı Algılayıcı (MLP)



Haykin (2009), yapay sinir ağlarının üç temel katmandan oluştuğunu belirtmiştir: girdi katmanı (X1, X2, X3), gizli katman(lar) ve çıktı katmanı (Y1, Y2, Y3) (Haykin, 2009). Rumelhart vd. (1986), gizli katmanların ağın doğrusal olmayan ilişkileri öğrenme kapasitesini artırdığını göstermiştir. Bu yapıda, nöronlar arasındaki bağlantılar ağırlıkları temsil eder ve her katman arasında tam bağlantı (fully connected) bulunmaktadır (LeCun vd., 2015). Finansal zaman serilerinde, girdi katmanı genellikle geçmiş fiyat ve hacim verilerini, çıktı katmanı ise tahmin edilmek istenen değerleri temsil eder (Heaton vd., 2016).

2.2. Veri Seti


Bu çalışmada, global spor giyim pazarının lider markalarından biri olan Nike'ın (NKE) hisse senedi fiyat hareketlerini tahmin etmek amacıyla kapsamlı bir veri seti kullanılmıştır. Söz konusu veri seti, 1993'ten 2024'e kadar uzanan 31 yıllık verilerden oluşmaktadır. Veri setimiz, Nike hissesinin günlük bazda temel finansal göstergelerini içermektedir:

- Açılış fiyatları (Open)
- Günlük en yüksek değerler (High)
- Günlük en düşük değerler (Low)
- Kapanış fiyatları (Close)
- İşlem hacimleri (Volume)

Veri seti üzerinde yapılan ön analizlerde eksik değerlere rastlanmamıştır. Derin öğrenme modellerinin optimum performans gösterebilmesi için veri normalleştirme aşamasında iki farklı yöntem karşılaştırmalı olarak değerlendirilmiştir. MinMaxScaler ve StandardScaler yöntemleri kullanılarak yapılan denemelerde, MinMaxScaler'ın Nike hisse verilerinin özelliklerine daha uygun olduğu gözlemlenmiştir (Suthiponpisal ve Tancharoen, 2024). Bu yöntem, Nike hisse fiyatlarının tahmininde daha düşük RMSE ve MAE değerleri ile daha yüksek R² skorları sağlamıştır.


Buna karşılık, StandardScaler yöntemi ile yapılan denemelerde Nike hissesi için daha yüksek hata değerleri ve daha düşük R² değerleri elde edilmiştir. Nike hisse verisinin dağılım özellikleri, uç değerlerin varlığı ve model performans ölçütleri göz önünde bulundurulduğunda, Nike'ın hisse senedi fiyat tahmin çalışmasının devamı için MinMaxScaler yönteminin kullanılmasına karar verilmiştir. Şekil 5'de, Nike hisse senedinin 1993-2024 yılları arasındaki açılış fiyatı zaman serisi ve tespit edilen aykırı değerler gösterilmektedir

Şekil 5. Nike Hisse Senedi Açılış Fiyatı (1993-2024) ve Aykırı Değerler



Grafikte, mavi çizgi açılış fiyatını, kırmızı noktalar ise aykırı değerleri temsil etmektedir. Veri ön işleme aşamasında, hareketli ortalama tabanlı Z-skor yaklaşımı ve çeyrekler arası aralık (IQR) yöntemleri kullanılarak aykırı değer tespiti gerçekleştirilmiştir. Analiz sonucunda, 8034 veri noktasından 316'sının (%3,93) aykırı değer olduğu belirlenmiştir. Bu aykırı değerler özellikle 2020-2022 döneminde yoğunlaşmış olup, hisse senedi fiyatının 125\$ ile 175\$ arasında seyrettiği noktalarda görülmektedir. Ayrıca, 1995-2005 yılları arasında ve 2015 civarında da tekil aykırı değerler tespit edilmiştir. Hundman vd. (2018) LSTM tarzı derin öğrenme modellerinin karmaşık yapısının aykırı değerleri absorbe edebileceğini çalışmalarında göstermişlerdir. Aynı şekilde, Hewamalage vd. (2021) sinir ağı tabanlı modellerin karmaşık olmaları nedeniyle büyük ölçüde aykırı değerlere karşı dirençli olabileceklerini belirtmişlerdir. Şekil 6'da, Nike hisse senedi açılış fiyatının yıllık büyüme oranları sunulmuştur.


Şekil 6. Nike Hisse Senedi Yıllık Büyüme Oranı (1993-2024)



Pozitif büyüme yeşil, negatif büyüme kırmızı çubuklarla gösterilmektedir. Her çubuğun üzerinde o yıla ait yüzdesel değişim değeri belirtilmiştir. Yıllık büyüme

oranları, her yılın ilk ve son işlem günlerindeki açılış fiyatları kullanılarak hesaplanmıştır. Analiz sonuçlarına göre, Nike hissesi özellikle 1994-1996 döneminde çok yüksek büyüme oranları (%60,7, %89,6 ve %78,4) kaydetmiştir. Dikkat çekici şekilde, 1993, 1997, 2003, 2008, 2015, 2021, 2022 ve 2023 yıllarında negatif büyüme görülmüştür. En büyük düşüşler 1993 (%45,0), 1997 (%33,9), 2023 (%26,7) ve 2003 (%24,9) yıllarında gerçekleşmiştir. Son üç yılda (2021-2023) ise hisse senedinin sürekli değer kaybettiği gözlemlenmektedir. 2020'de güçlü bir büyüme (%38,2) sonrası yaşanan bu düşüş dikkat çekicidir. Şekil 7'de Nike (NKE) hisse senedinin 1993-2024 yılları arasındaki fiyat hareketleri gösterilmiştir.

Şekil 7. Nike (NKE) Hisse Senedinin 1993-2024 Yılları Arasındaki Fiyat Hareketleri



Şekil 7 incelendiğinde, hisse senedi 1993'ten 2008'e kadar 2-20 USD bandında istikrarlı bir büyüme sergilemiştir. Bu dönemde düşük volatilité ve yaklaşık %15'lik yıllık ortalama büyüme performansı dikkat çekmektedir. 2009-2019 arası ivmelenme dönemi olarak tanımlanabilir. Bu periyotta hisse fiyatı 20 USD'den 100 USD seviyelerine yükselmiş, yıllık ortalama %25 büyüme performansı göstermiştir. Artan volatilité ve güçlü yukarı trend, Nike'ın küresel pazar payını genişletmesi ve dijital dönüşüm stratejilerinin başarısını yansıtmaktadır.

2020-2024 dönemi ise yüksek volatilité ile karakterize edilmektedir. COVID-19 pandemisinin etkisiyle keskin bir düşüş yaşayan hisse, sonrasında toparlanarak 175 USD ile tarihi zirvesini görmüştür (2021). Son dönemde 75-80 USD bandında dengelenen fiyat hareketi, küresel ekonomik belirsizlikler ve değişen pazar dinamiklerinin etkisini göstermektedir. Bu volatil dönem, derin öğrenme modellerinin tahmin kabiliyetlerini test etmek için önemli bir veri seti sunmaktadır. Tablo 2'de

model parametreleri ve eğitim detayları verilmiştir. Tablo 1, 1993 ile 2024 yılları arasında Nike (NKE) hisse senedi fiyatlarının temel istatistiksel özetini sunmaktadır.

Tablo 1. Çalışmada Kullanılan Verilerin Tanımlayıcı İstatistik Sonuçları

Özellikle	Tarih aralığı	Şimdi	Açılış	Yüksek	Düşük	Hacim	Değişim
Mean		36.43	36.42	36.79	36.05	9,515,414,000	0.31
Min	1993-01-04	1.00	1.35	1.39	1.35	20	-19.98
Max	2024-11-26	176.85	176.35	179.10	175.49	157,450,000,000	15.53
Std		41.14	41.13	41.53	40.71	7,418,105,000	2.02

Tabloda yer alan istatistiklere göre, hisse senedinin "Şimdi" (son fiyat) değeri ortalama 36.43 olarak hesaplanmış, minimum değeri 1.00 ve maksimum değeri ise 176.85 olarak gözlemlenmiştir. Bu geniş fiyat aralığı, hisse senedinin zaman içinde önemli dalgalanmalara maruz kaldığını göstermektedir. Özellikle, minimum fiyatın 1.00 olması, hisse senedinin erken dönemlerinde düşük işlem gördüğünü, ancak uzun vadede önemli bir değer artışı yaşadığını ortaya koymaktadır.

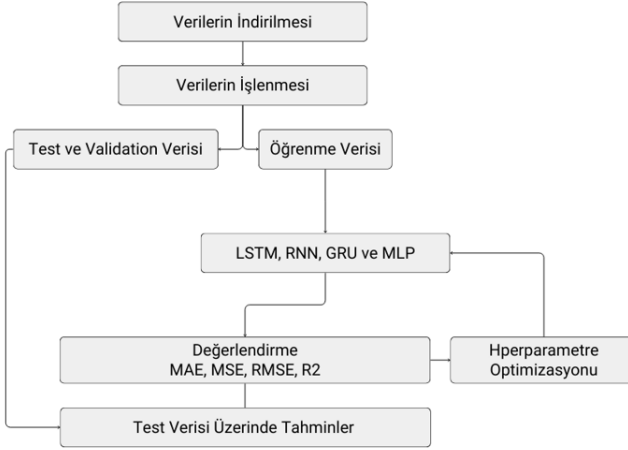
Fiyat değişim oranlarının standart sapması 2.02 olarak hesaplanmıştır, bu da fiyat hareketlerinde belirgin dalgalanmalar olduğunu göstermektedir. Maksimum değişim oranı 15.53 olarak ölçülürken, minimum değişim oranı -19.98 olarak kaydedilmiştir. Bu durum, hisse senedinin bazı dönemlerde yüksek volatilité gösterdiğini ve sert düşüşler ile yükselişler yaşadığını ifade etmektedir.

İşlem hacmi açısından değerlendirildiğinde, ortalama hacmin yaklaşık 9.51 milyar adet olduğu görülmektedir. En yüksek işlem hacmi 157.45 milyar olarak ölçülmüşken, en düşük işlem hacmi 20 adet olarak kaydedilmiştir. Bu durum, piyasanın belirli dönemlerinde likiditenin oldukça yüksek olabileceğini gösterirken, bazı dönemlerde işlem hacminin ciddi şekilde düştüğünü ortaya koymaktadır. Yüksek işlem hacimleri genellikle fiyat hareketlerinin daha istikrarlı olmasına katkı sağlarken, düşük hacimli dönemlerde fiyat oynaklığı artış gösterebilir. Sonuç olarak, hisse senedi fiyatlarının zaman içinde önemli ölçüde dalgalandığı ve belirli dönemlerde yüksek volatilité gösterdiği anlaşılmaktadır.

Nike hisse senedi fiyat tahmin çalışmamızda, veri indirilmesi ile başlayan kapsamlı bir analiz süreci yürütülmüştür. Çalışmanın akış diyagramı şekil 4'de gösterilmiştir. İndirilen 1993-2024 yılları arasındaki Nike hisse senedi verileri, detaylı bir ön işleme sürecinden geçirilmiş; aykırı değer tespiti yapılmış ve bulgular görselleştirilmiştir. İşlenen veriler, öğrenme ve test setlerine ayrılarak LSTM, RNN, GRU ve MLP olmak üzere dört farklı derin öğrenme modeli ile analiz edilmiştir. Modellerin eğitimi sırasında hiperparametre optimizasyonu gerçekleştirilmiş ve böylece model

performansları artırmıştır. Şekil 8’de çalışmada kullanılan modellerin genel çerçevesi sunulmuştur.

Şekil 8. Çalışmada Kullanılan Modellerin Genel Çerçevesi



3. BULGULAR

Bu çalışmada, finans piyasalarının en köklü şirketlerinden biri olan Nike’ın (NKE) hisse senedi fiyat hareketleri, modern derin öğrenme yaklaşımları kullanılarak analiz edilmiştir. 1993’ten 2024’e uzanan 31 yıllık süreçte, Nike hissesinin günlük açılış, yüksek, düşük, kapanış fiyatları ve işlem hacimlerini içeren zengin bir veri seti kullanılmıştır. Veri setinin ilk 5 ve son 5 verisi Tablo 2’de örnek olarak gösterilmiştir. Tablo 3’de ise LSTM modelinin farklı parametrelere göre performans metrikleri verilmiştir.

Tablo 2. Çalışmada Kullanılan Veriler

Tarih	Simdi	Açılış	Yüksek	Düşük	Hacim	Değişim
04.01.1993	2.60	2.60	2.61	2.59	6160000000	0.39
05.01.1993	2.55	2.59	2.60	2.55	5930000000	-1.92
06.01.1993	2.54	2.55	2.57	2.51	11750000000	0.39
07.01.1993	2.55	2.54	2.59	2.54	7110000000	0.39
08.01.1993	2.50	2.55	2.55	2.46	16150000000	-1.96
.
.

20.11.2024	73.36	73.66	73.84	72.71	12290000000	0.74
21.11.2024	73.10	73.36	75.56	73.20	12820000000	2.37
22.11.2024	76.40	76.13	77.50	75.83	12250000000	3.6
25.11.2024	78.26	78.50	79.86	78.41	18330000000	2.40
26.11.2024	78.61	78.90	78.90	77.57	9500000000	-2.8

Tablo 3. LSTM Modelinin Farklı Parametrelere Göre Performans Metrikleri

Batch	Dropout	LSTM Units	Epochs	Train MAE	Train RMSE	Train MAP E	Train R ²	Test MAE	Test RMSE	Test MAP E	Test R ²
16	0.2	50-25	25	1.13	1.29	12.41%	1.00	6.57	8.27	5.64%	0.90
16	0.2	100-50	25	0.67	0.102	6.36%	1.00	6.42	7.51	5.69%	0.91
16	0.2	100-50	50	0.51	0.75	5.64%	1.00	4.35	6.96	3.56%	0.93
16	0.3	50-25	25	0.78	1.11	5.29%	1.00	3.89	5.64	3.38%	0.95
16	0.3	100-50	25	0.73	0.103	7.75%	1.00	3.51	05.08	3.05%	0.96
16	0.5	100-50	25	0.50	0.79	4.18%	1.00	8.45	11.61	6.92%	0.79
32	0.2	50-25	25	0.47	0.81	2.98%	1.00	5.17	6.61	4.51%	0.93
32	0.2	50-25	50	0.48	0.71	5.20%	1.00	5.00	6.53	4.27%	0.93
32	0.2	100-50	25	0.47	0.75	3.79%	1.00	3.97	5.10	3.54%	0.96
32	0.2	100-50	50	0.39	0.57	4.28%	1.00	3.11	04.08	2.75%	0.97
32	0.3	50-25	25	0.85	0.98	12.27%	1.00	4.58	06.08	4.00%	0.94
32	0.3	50-25	50	0.60	0.85	7.13%	1.00	5.42	6.95	4.67%	0.93
32	0.3	100-50	25	0.44	0.75	3.36%	1.00	2.95	04.05	2.87%	0.97
32	0.3	100-50	50	0.61	0.77	6.92%	1.00	2.62	3.66	2.42%	0.97
32	0.5	50-25	25	1.59	1.74	26.03%	0.99	6.94	8.61	6.04%	0.89

32	0.5	50-25	50	0.48	0.69	4.79%	1.00	7.46	10.90	6.01%	0.82
32	0.5	100-50	25	0.59	0.83	7.27%	1.00	3.48	4.48	3.21%	0.97
32	0.5	100-50	50	1.60	0.82	6.88%	1.00	3.15	4.39	2.40%	0.97

Tablo 3’de, LSTM modeli için farklı batch size, dropout oranı, layer sayısı ve epoch sayısı ile nasıl performans gösterdiğini analiz etmek amacıyla gerçekleştirilmiştir. Batch boyutunun 16’dan 32’ye çıkarılması, test seti performansında genel olarak daha düşük hata oranları ve yüksek R² değerleriyle sonuçlanmıştır. Özellikle batch = 32 ile eğitilen modeller, batch = 16’ya kıyasla daha stabil ve genelleştirilebilir sonuçlar vermiştir.

Dropout oranları (0.3 ve 0.5) test setindeki hata oranlarını minimize ederek yüksek R² değerlerine ulaşılmasını sağlamıştır. Daha fazla epoch (örneğin 50) kullanımı, eğitim seti hatalarını düşürse de test seti performansında istikrarsızlığa yol açmıştır. Bu nedenle, eğitim sürecine erken durdurma kriteri eklenmiş ve modelin 5 epoch boyunca iyileşme göstermemesi durumunda eğitimin durdurulması sağlanmıştır. Erken durdurmanın genelleme yeteneği açısından performansını iyileştirdiği ve overfittingi azalttığı görülmüştür (Prechelt, 2002; Bentoumi vd., 2022).

Özellikle dropout = 0.5 ve batch = 32 kombinasyonunda 100-50 nöron yapısı ile eğitilen model, Train RMSE: 0.82, Test RMSE: 4.39, Test R²: 0.97 gibi başarılı sonuçlar vermiştir. Benzer süreç diğer modellere de uygulanarak optimum parametreler belirlenmiştir.

Tablo 4, hisse senedi kapanış fiyatı tahmini için kullanılan derin öğrenme modellerinin temel parametrelerini ve ayarlarını özetlemektedir.

Tablo 4. Model Parametreleri ve Eğitim Detayları

Özellik	LSTM	RNN	GRU	MLP
Ölçeklendirme	MinMax (0, 1)	MinMax (0, 1)	MinMax (0, 1)	MinMax (0, 1)
Aktivasyon Fonksiyonu	Varsayılan	Varsayılan	Varsayılan	Relu
Dropout Oranı	0.5	0.2	0.2	0.2
Katmanlardaki Nöron Sayıları	100, 50	100, 50	100, 50	128, 64
Test Seti Oranı	20%	20%	20%	20%
Batch Boyutu	32	16	32	32
Epoch Sayısı	50	50	50	100
Öğrenme Oranı	0.001	0.001	0.001	0.0005

Bu parametreler, grid search yöntemiyle belirlenmiş ve optimum değerlere ulaşmak için manuel olarak revize edilmiştir.

1. Ölçeklendirme:

Model girdileri, Min-Max ölçekleme yöntemiyle [0,1] aralığına normalize edilmiştir. Bu işlem, özellikle LSTM (Pranolo vd., 2024), GRU (Makinde, 2024) ve RNN (Munkhdalai vd., 2019) gibi zaman serisi modellerinde modelin daha hızlı öğrenmesini ve ağırlıkların kararlı bir şekilde optimize edilmesini sağlamak amacıyla tercih edilmiştir.

2. Aktivasyon Fonksiyonları:

MLP modeli için katmanlarda Relu aktivasyon fonksiyonu kullanılmıştır (Si vd., 2018). LSTM, GRU ve RNN modellerinde ise aktivasyon fonksiyonu, TensorFlow'un varsayılan olarak kullandığı *tanh* aktivasyon fonksiyonu uygulanmıştır.

3. Dropout Oranı:

Aşırı öğrenmeyi önlemek için LSTM modelleri için 0.5 diğer modeller için 0.2 dropout oranı en iyi sonuç verdiği gözlemlenmiştir. Bu oranla, her bir eğitim adımında modelin belirli nöronlarını rastgele devre dışı bırakarak modelin genelleme kabiliyetini artırmak hedeflenmiştir.

4. Katmanlardaki Nöron Sayıları:

MLP modelinde iki yoğun bağlı katman kullanılmıştır; birinci katmanda 128, ikinci katmanda 64 nöron bulunmaktadır. RNN, GRU ve LSTM modelleri ise iki ardışık zaman serisi katmanından oluşmakta ve ilk katmanda 100, ikinci katmanda 50 nöron içermektedir. Her bir model için farklı nöron sayıları denenmiştir. Yapılan testler ve analizler sonucunda en iyi performansı sağlayan belirtilen nöron sayıları Tablo 2'de gösterilmiştir.

5. Test ve Doğrulama Setleri:

Eğitim seti %80, test seti ise %20 olarak belirlendi. Ancak, Tablo 5'te gösterildiği gibi, eğitim seti %70, doğrulama seti %15 ve test seti %15 olarak ayrıldığında sonuçlar daha kötü oldu. Tablo 5'de bölümlenme sonucu hata metrikleri gösterilmiştir.

6. Eğitim Parametreleri:

Tüm modellerde eğitim işlemi, 32 boyutunda bir batch size ve 50 epoch ile gerçekleştirilmiştir. Mini-batch gradient descent yaklaşımıyla batch boyutu 32 olarak belirlenmiştir. 16, 32 ve 64 değerleri test edilmiş, 32 batch boyutunun RNN hariç diğer modellerde istikrarlı sonucu verdiği gözlemlenmiştir. LSTM, RNN ve GRU'nun 20-30 epoch'da yakınsadığı görülmüş ve bu modeller için epoch sayısının 50 olmasına karar verilmiştir. MLP'nin ise bazen 60 epoch değerlerine kadar eğitime devam ettiği görüldüğü için 100 belirlenmiştir.

Tablo 4'de özetlenen bu ayarlar, tüm modeller için aynı kalacak şekilde yapılandırılmıştır. Bu sayede, farklı model türlerinin tahmin performansları adil bir şekilde karşılaştırılabilir olmuştur. Bu parametrelerin optimizasyonu, modellerin test

verisinde yüksek doğrulukla tahmin yapmasını sağlarken, aynı zamanda aşırı öğrenmeyi (overfitting) engellemeye yönelik bir denge sunmuştur. Tablo 5’de veri bölme oranlarının model performansı üzerindeki etkisi görülmektedir.

Tablo 5. LSTM için Veri Bölme Metodolojilerinin Farkı

Veri Bölme Oranı	MAE	RMSE	MSE	R ²
70/15/15	6.45	7.29	53.14	0.923
80/20	3.15	4.39	19.31	0.971


Bu sonuçlar, %80/20 bölme oranının tüm performans metriklerinde önemli ölçüde daha iyi sonuçlar verdiğini göstermektedir. Ortalama mutlak hata (MAE) değeri 6.45'ten 3.15'e düşmüş, bu da yaklaşık %51'lik bir iyileşme anlamına gelmektedir. Benzer şekilde, kök ortalama kare hata (RMSE) değeri 7.29'dan 4.39'e düşerek %40'lık bir iyileşme göstermiştir. Ortalama kare hata (MSE) değerindeki düşüş ise daha dramatiktir: 53.14'ten 19.31'e, yani yaklaşık %64'lük bir iyileşme söz konusudur. Determinasyon katsayısı (R²) 0.923'den 0.971'e yükselerek modelin açıklayıcı gücünün arttığını göstermektedir.


Çalışmamızda, modelin aşırı öğrenmesini önlemek için 5 epoch boyunca iyileşme göstermeyen modellerin eğitimini durduran bir erken durdurma (early stopping) stratejisi uygulanmıştır. Bu yaklaşım, Prechelt (2002) tarafından önerilen ve derin öğrenme literatüründe yaygın olarak kabul gören bir yöntemdir.

Fischer ve Krauss (2018), finansal zaman serilerinde LSTM modellerinin eğitiminde erken durdurma kriterinin, model performansını önemli ölçüde etkilediğini göstermiştir. Çalışmalarında, 5-10 epoch sabır (patience) değerinin optimal olduğu ve bu değer üzerinde değerlerin aşırı öğrenmeye, altındaki değerlerin ise yetersiz eğitime (underfitting) yol açtığı vurgulanmıştır.

Sonuç olarak, aynı veri seti için yapılan bu iki farklı bölme oranı arasındaki farklar, model performansını doğrudan etkilemektedir. Bu bulgular ışığında, modelin daha yüksek doğrulukla sonuçlar verebilmesi için %80 eğitim ve %20 test verisi oranıyla devam edilmesi daha uygun olduğu görülmektedir. Şekil 9’da derin öğrenme algoritmalarının tahmin grafikleri verilmiştir.

Şekil 9. Derin Öğrenme Algoritmalarının Tahmin Grafikleri





Şekil 9’da LSTM, GRU, RNN ve MLP algoritmalarının hisse senedi kapanış fiyatlarını tahmin etme performansını gösterilmektedir. Dört farklı modelin gerçek fiyatlar ile tahmin edilen değerler arasındaki uyumu incelenmiştir:

1. **LSTM (Birinci Grafik):** LSTM modeli, zaman serisi verilerindeki uzun dönem bağımlılıklarını etkili bir şekilde öğrenebilmesi nedeniyle tahminlerinde yüksek bir doğruluk göstermektedir. Gerçek değerler (mavi çizgi) ile LSTM tahminleri (turuncu çizgi) büyük ölçüde örtüşmektedir. LSTM'nin özellikle fiyat dalgalanmalarını yakalamada oldukça başarılı olduğu görülmektedir.
2. **GRU (ikinci Grafik):** GRU modeli de LSTM’ye benzer şekilde, zaman serisi bağımlılıklarını öğrenmekte etkili bir performans sergilemiştir. Tahmin eğrisi, gerçek fiyatlara oldukça yakındır. Ancak, LSTM ile karşılaştırıldığında GRU'nun küçük dalgalanmalarda biraz daha fazla sapma gösterdiği söylenebilir.
3. **RNN (Üçüncü Grafik):** RNN modeli, GRU ve LSTM’ye kıyasla daha zayıf bir performans göstermektedir. Model, genel eğilimleri takip etmesine rağmen, özellikle ani dalgalanmalarda gerçek değerlerden sapmalar görülmektedir. RNN'nin uzun dönem bağımlılıkları öğrenmekte yetersiz kalması, tahmin doğruluğunu olumsuz etkilemiştir.
4. **MLP (Dördüncü Grafik):** MLP (Çok Katmanlı Algılayıcı) modeli, zaman serisi verilerinde diğer modeller kadar başarılı değildir. Nike hisse senedi tahminindeki düşük performansı, MLP'nin zaman serilerindeki uzun ve kısa dönem bağımlılıklarını öğrenme kapasitesinin sınırlı olmasından kaynaklanmaktadır (Längkvist vd., 2014). MLP, içsel bir hafıza mekanizmasına sahip olmadığı için ardışık bağımlılıkları modelleme konusunda yetersiz kalmaktadır (Gamboa, 2017). Nike hisse senedi verisinin otokorelasyon değerleri, fiyat hareketlerinin yüksek derecede zamansal bağımlılık gösterdiğini ortaya koymuştur. MLP, her dönem verisini bağımsız bir örnek olarak ele alırken, LSTM ve GRU gibi modeller hafıza hücreleri sayesinde bu zamansal ilişkileri daha iyi koruyabilmektedir (Siami-Namini

vd., 2019). Samii vd. (2023), finansal zaman serisi tahminlerinde MLP'nin performansının, verilerdeki zamansal korelasyonları modelleyebilen LSTM ve GRU gibi mimarilere kıyasla genellikle daha düşük olduğunu göstermiştir.

3.1. Çalışmada Kullanılan Hata Metrikleri

3.1.1. Mean Absolute Percentage Error (MAPE)

MAPE, tahmin hatalarının ortalama mutlak yüzdesidir. MAPE, hataların göreceli büyüklüğünü anlamamıza yardımcı olur ve % olarak ifade edilir. Bu metrik, hataların büyüklüğünü oransal olarak değerlendirdiği için farklı ölçeklerdeki veri setleri arasında karşılaştırma yapmayı kolaylaştırır.

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100 \quad (1)$$

Burada:

y_i , gerçek değer

\hat{y}_i , tahmin edilen değeri,

n , veri noktalarının sayısını ifade eder.

Birçok çalışmada, MAPE hata metriğinin %10'un altında olduğu durumlar için, model tahminlerinin kabul edilebilir doğrulukta olduğu ifade edilmiştir (Makridakis vd., 1998).

3.1.2. Mean Squared Error (MSE)

MSE, makine öğrenimi modelinde en yaygın kullanılan hata ölçüm metriklerinden biridir. Gerçek değerlerle tahmin edilen değerler arasındaki farkların karesinin ortalaması olarak tanımlanır. Matematiksel olarak şu şekilde ifade edilir:

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

Burada:

n , Veri noktalarının sayısını (yani, gözlemler veya test verisi sayısı),

y_i , gerçek değeri

\hat{y}_i , Model tarafından tahmin edilen değeri ifade eder.

MSE büyük hatalara karşı daha duyarlıdır; çünkü hata kareleri alınarak büyük hatalar daha fazla vurgulanır. Bununla birlikte, MSE değeri aynı birime sahip olmadığından doğrudan yorumlamada bazı zorluklar ortaya çıkabilir (Chai ve Draxler, 2014).

3.1.3. Mean Absolute Error (MAE)

MAE, bir modelin tahmin ettiği değerler ile gerçek değerler arasındaki mutlak farkların ortalamasını ifade eder. Bu metrik, tahmin hatalarının büyüklüğünü

anlamamıza olanak tanır. MAE, tüm hataları eşit bir şekilde ele alır; her bir veri noktası için hataların mutlak farklarını toplar ve bu toplamı veri noktalarının sayısına bölerek sonuç verir.

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (3)$$

Burada:

y_i , gerçek değer

\hat{y}_i , tahmin edilen değeri,

n , veri noktalarının sayısını ifade eder.

MAE, model doğruluğunu değerlendirmek için yaygın olarak kullanılır ve verinin biriminde ölçülür, bu da yorumu kolaylaştırır (Willmott ve Matsuura, 2005).

3.1.4. Root Mean Squared Error (RMSE)

RMSE, MSE'nin karekökü alınarak elde edilen bir ölçümdür. MSE'de olduğu gibi hata karelerinin ortalaması alınır, ancak sonuç hata miktarının birimi ile aynı olacak şekilde karekök alınarak normalize edilir. RMSE, daha kolay yorumlanabilir bir ölçümdür çünkü sonuç, tahmin edilen değişkenle aynı birime sahiptir. RMSE şu şekilde hesaplanır:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (4)$$

Burada:

n , veri noktalarının sayısını

y_i , gerçek değeri

\hat{y}_i , Modelin tahmin ettiği değeri ifade eder.

RMSE, modelin genel performansını değerlendirirken yaygın olarak kullanılır ve büyük hatalara karşı duyarlı bir metriktir. Yani, RMSE, bir modelin büyük sapmalara karşı ne kadar dayanıklı olduğunu gösterir. MSE ve RMSE arasında temel fark, RMSE'nin sonuçları daha sezgisel hale getirmek için hata birimlerinin dönüştürülmesidir (Willmott ve Matsuura, 2005).

3.1.5. R-squared (R^2)

R^2 , bağımsız değişkenlerin bağımlı değişken üzerindeki etkisini ne kadar iyi açıkladığını gösteren bir istatistiksel ölçüdür. Bu metrik, modelin veriyle ne kadar uyumlu olduğunu değerlendirir ve 0 ile 1 arasında bir değer alır. R^2 değeri 1'e yaklaştıkça, modelin bağımsız değişkenler tarafından açıklanan varyans oranı da artar.

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (5)$$

Burada:

y_i , gerçek değer

\hat{y}_i , tahmin edilen değeri,

y , gerçek değerlerin ortalamasının ifade eder.

R^2 , modelin açıklayıcılık kapasitesini ölçer ve modelin performansını kıyaslamak amacıyla kullanılır. R^2 'nin yüksek olması, modelin bağımsız değişkenlerin bağımlı değişken üzerindeki etkisini güçlü bir şekilde açıklayabildiğini gösterir (Montgomery vd., 2012).

3.2. Tahmin Performansı Karşılaştırması

Tablo 6'da model performans metrikleri verilmiştir.

Tablo 6. Model Performans Metrikleri

Model	Eğitim				Test			
	MAE	RMSE	MSE	R2	MAE	RMSE	MSE	R2
LSTM	1.606	0.821	0.674	0.998	3.157	4.395	19.31	0.971
GRU	1.009	1.190	1.416	0.996	3.039	4.060	16.48	0.975
RNN	1.703	1.827	3.337	0.990	3.770	5.419	29.36	0.961
MLP	1.438	1.786	3.190	0.991	5.173	7.147	51.07	0.922

Tablo 6'da gösterilen sonuçlar incelendiğinde, LSTM, GRU, RNN ve MLP modellerinin hisse senedi kapanış fiyatlarını tahmin etme başarısını dört farklı metrik kullanarak karşılaştırmaktadır:

Eğitim metrikleri, her modelin tarihsel verilerden nasıl öğrendiğine dair önemli farklılıkları ortaya koymaktadır. LSTM, en düşük MAE (1.606) ve RMSE (0.821) değerleriyle üstün eğitim performansı göstermekte, bu da eğitim verilerindeki altta yatan desenleri en etkili şekilde yakaladığını düşündürmektedir. Bu durum, modelin eğitim veri setindeki neredeyse tüm varyansı açıkladığını gösteren 0.998'lik olağanüstü R^2 değeriyle de desteklenmektedir.

GRU, biraz daha yüksek hata metrikleriyle (MAE: 1.009, RMSE: 1.190) takip etmekte, ancak 0.996'lık R^2 ile güçlü tahmin gücünü korumaktadır. RNN ve MLP modelleri, sırasıyla 1.827 ve 1.786'lık RMSE değerleriyle eğitim sırasında daha yüksek hata oranları göstermekte, bu mimarilerin öğrenme aşamasında verilerdeki karmaşık zamansal bağımlılıkları yakalamada daha fazla zorluk yaşadığını düşündürmektedir.

Test metrikleri, her modelin görülmemiş verilere genelleme kabiliyeti hakkında kritik bilgiler sağlamaktadır. GRU, en düşük test MAE (3.039) ve RMSE (4.060) değerleriyle birlikte en yüksek R^2 puanıyla (0.975) en güçlü genelleme performansını

göstermektedir. Bu, GRU'nun özellikle desen tanıma ile aşırı uyumu önleme arasında denge kurma konusunda etkili olduğunu göstermekte, bu da onu pratik tahmin uygulamaları için özellikle değerli kılmaktadır.


LSTM, biraz daha yüksek hata metrikleriyle (MAE: 3.157, RMSE: 4.395) ve 0.971'lik güçlü bir R^2 ile yakından takip etmektedir. LSTM'in eğitim ve test performansı arasındaki daha büyük fark, üstün eğitim metriklerine rağmen, aşırı uyuma biraz daha yatkın olduğunu düşündürmektedir.

RNN modeli, 5.419'luk test RMSE ve 0.961'lik R^2 ile kapılı tekrarlayan mimarilere (LSTM ve GRU) kıyasla makul ancak daha az optimal bir çözüm oluşturan orta düzeyde genelleme kabiliyeti göstermektedir. Bu, teorik beklentilerle uyumludur, çünkü RNN, LSTM ve GRU'nun sıralı verilerdeki uzun vadeli bağımlılıkları daha iyi yakalamasını sağlayan sofistike kapılama mekanizmalarından yoksundur.

MLP modeli, tüm test metriklerinde (MAE: 5.173, RMSE: 7.147, R^2 : 0.922) en zayıf performansı göstermekte, ileri beslemeli mimarilerin tekrarlayan mimarilere kıyasla zaman serisi tahmin görevleri için temelde daha az uygun olduğunu doğrulamaktadır. MLP için önemli ölçüde daha yüksek MSE (51.07), test veri setindeki aykırı değerleri veya aşırı değerleri ele almada özel bir zorluk yaşadığını vurgulamaktadır.

Şekil 10, Nike (NKE) hisse senedinin 2018 ortasından 2024 sonuna kadar olan kapanış fiyatlarının dört farklı derin öğrenme modeli (LSTM, RNN, GRU ve MLP) kullanılarak yapılan tahminlerini gerçek değerlerle karşılaştırmaktadır.

Şekil 10. Tüm Modeller İçin Hisse Senedi Kapanış Fiyat Tahminleri



1. **LSTM ve GRU Modellerinin Üstünlüğü:** Grafik analizi, literatürle uyumlu olarak LSTM ve GRU modellerinin, özellikle 2020-2021 dönemindeki yüksek volatilité ve trend değişimlerinde daha doğru tahminler ürettiğini göstermektedir. Bu modellerin uzun vadeli bağımlılıkları hafızada tutabilme

- yeteneği, Nike hissesinin kompleks fiyat hareketlerini modellemede belirgin bir avantaj sağlamıştır.
2. **RNN'in Sınırlamaları:** Basit RNN modeli, genel trendi yakalamakla birlikte, grafikte görüldüğü üzere 2020 sonu ve 2021 başındaki keskin hareketlerde LSTM ve GRU'ya kıyasla daha fazla tahmin hatası göstermektedir. Bu durum, RNN'lerin uzun vadeli bağımlılıkları modellemedeki bilinen "kaybolan gradyan" problemiyle tutarlıdır.
 3. **MLP'nin Zamansal Veri İşlemedeki Yapısal Kısıtlamaları:** Grafikte MLP modelinin özellikle trend dönüş noktalarında daha fazla sapma gösterdiği açıkça görülmektedir. Bu durum, MLP'nin doğası gereği zamansal bağlamı açıkça modelleyememesinden kaynaklanmaktadır.

Sonuçlar, zaman serisi tahmininde LSTM'nin en başarılı model olduğunu net bir şekilde ortaya koymaktadır. GRU, LSTM'ye yakın bir performans sergileyerek uygun bir alternatif sunmaktadır. RNN, orta düzey bir performans göstermiş olsa da, zaman serisi tahmini için daha gelişmiş modellere kıyasla yetersiz kalmaktadır. MLP ise bu tür görevlerde düşük performansıyla öne çıkmıştır. Bu çalışma, LSTM ve GRU'nun, özellikle finansal zaman serisi verilerinin tahmini gibi karmaşık senaryolar için daha uygun modeller olduğunu göstermektedir.

4. TARTIŞMA

Bu çalışma, finans piyasalarının karmaşıklığını anlamak ve gelecekteki fiyat hareketlerini tahmin etmek amacıyla Nike (NKE) hisse senedi fiyatlarına ilişkin derin öğrenme modellerinin performansını karşılaştırmalı olarak incelemiştir. Uzun vadeli bir veri seti (1993-2024) kullanılarak gerçekleştirilen bu analiz, LSTM, GRU, RNN ve MLP modellerinin finansal zaman serisi tahmini konusundaki etkinliğini değerlendirmiştir. Çalışmada, uzun vadeli bağımlılıkları öğrenme yeteneğiyle öne çıkan LSTM ve GRU modellerinin yanı sıra, klasik RNN ve baseline olarak kullanılan MLP algoritmaları detaylı bir şekilde ele alınmıştır.

Sonuçlar, LSTM modelinin uzun vadeli bağımlılıkları öğrenme ve yüksek doğruluk oranları elde etme konusundaki üstünlüğünü göstermiştir. LSTM'in unutmama, giriş ve çıkış kapıları sayesinde bilgi akışını daha etkin bir şekilde yöneterek, zaman serisi verilerinde geçmiş dönemlerin etkisini daha başarılı bir şekilde değerlendirdiği görülmüştür. Özellikle RMSE, MAE ve MAPE gibi hata metriklerinde LSTM, diğer modelleri geride bırakmıştır. GRU, benzer bir mimariye sahip olmasına rağmen, daha az parametre kullanımı nedeniyle hesaplama maliyetini azaltmış ve kısa vadeli tahminlerde tatmin edici bir performans sergilemiştir. Gavcar ve Metin (2021) çalışmalarında, Uzun Kısa Süreli Bellek (LSTM) modeli ile hisse senetlerinin açılış fiyat değerleri ile tutarlı tahminler elde etmişlerdir. Karakoyun (2018), LSTM derin öğrenme modelini daha başarılı olduğu gözlemlemiştir. Bu LSTM modelinin, zaman serilerinin tahmininde geleneksel istatistik yöntemlere göre daha uygun olduğunu göstermektedir. Akita vd. (2016) yaptıkları çalışmada, LSTM'in hisse senedi fiyat tahmininde zaman serilerindeki değişikliği yakalamada daha başarılı olduğu sonucuna ulaşmışlardır. LSTM'ye benzer şekilde Shen vd. (2018) çalışmalarında, GRU

modelinin daha yüksek bir tahmin doğruluğu ürettiğini göstermiştir. Benzer şekilde Rahman vd. (2019) ve Saud vd. (2020) GRU modelinin daha iyi tahmin performansı gösterdiğini ortaya koymuşlardır. GRU ve GRU tabanlı modellerin, son dönemde finansal yatırım tahminlerinde oldukça başarılı sonuçlar elde ettiğini ortaya koymuşlardır.

RNN modelleri, temel tekrarlayan mimariyi kullanarak ardışık veriler üzerinde tahmin gerçekleştirmiş, ancak uzun vadeli bağımlılıkları öğrenme noktasında zayıf kalmıştır. Gradyan kaybı ve patlaması gibi yapısal sorunlar nedeniyle performansı, LSTM ve GRU'ya kıyasla sınırlı kalmıştır. Bununla birlikte, RNN'nin basit yapısı, düşük hesaplama maliyeti gerektiren uygulamalarda hala kullanılabilir bir çözüm sunmaktadır. Diğer yandan, MLP modeli, zaman serilerinde doğrusal olmayan ilişkileri modelleme kabiliyetiyle temel bir referans noktası sağlamış, ancak ardışık ve uzun vadeli bağımlılıkların olduğu finansal verilerde diğer modeller kadar etkili bir performans sergileyememiştir.

SONUÇ

1993-2024 yılları arasında Nike hisse senedi fiyatlarındaki önemli dönemler, model tahminlerinin doğruluğu üzerinde farklı etkiler yaratmıştır. Özellikle 2009-2019 yılları arasındaki ivmelenme döneminde, modellerin daha tutarlı tahminler ürettiği gözlenmiştir. Ancak 2020-2024 arasındaki yüksek volatilité döneminde, modellerin tahmin hatalarının arttığı dikkat çekmiştir. Bu durum, finansal piyasaların belirsizliği ve beklenmedik şoklara yanıt verme sürecinin tahmin edilmesindeki zorlukları bir kez daha ortaya koymuştur.

Bu çalışma, finansal zaman serisi tahmininde farklı derin öğrenme modellerinin performansını değerlendirerek, LSTM ve GRU'nun üstünlüğünü ortaya koymaktadır. Eğitim metrikleri, LSTM modelinin en düşük MAE (1.606) ve RMSE (0.821) değerleriyle en başarılı eğitim performansını sergilediğini ve 0.998 R² değeriyle veri setindeki varyansın büyük bir kısmını açıkladığını göstermektedir. GRU modeli ise biraz daha yüksek hata metriklerine (MAE: 1.009, RMSE: 1.190) sahip olmakla birlikte, 0.996 R² değeriyle güçlü tahmin yeteneğini korumaktadır. Buna karşılık, RNN ve MLP modelleri, sırasıyla 1.827 ve 1.786 RMSE değerleri ile daha yüksek hata oranları göstermiş ve zaman serisi verilerindeki karmaşık bağımlılıkları yakalamada yetersiz kalmıştır.

Test metrikleri açısından GRU, en düşük test MAE (3.039) ve RMSE (4.060) değerleriyle en güçlü genelleme performansını sunarken, 0.975 R² değeriyle yüksek bir doğruluk sağlamıştır. LSTM, benzer şekilde başarılı bir performans göstermiş ancak eğitim ve test metrikleri arasındaki fark, modelin aşırı uyuma daha yatkın olduğunu işaret etmektedir. RNN, test aşamasında 5.419 RMSE ve 0.961 R² değerleriyle makul ancak daha düşük bir performans sergilemiş, MLP ise tüm test metriklerinde en düşük doğruluğu göstermiştir (MAE: 5.173, RMSE: 7.147, R²: 0.922).

LSTM ve GRU modellerinin özellikle yüksek volatilité dönemlerinde (2020-2021) daha doğru tahminler ürettiğini ortaya koymuştur. RNN, genel trendleri yakalamakla birlikte, ani fiyat değişimlerinde daha fazla hata yapmış ve uzun vadeli bağımlılıkları modellemede sınırlılıklar göstermiştir. MLP modeli ise zamansal bağlamı doğrudan yakalayamadığından, özellikle trend dönüş noktalarında yüksek hata oranlarına sahip olmuştur.

LSTM ve GRU modelleri benzer hata metriklerine sahip olsalar da, davranışsal özelliklerinde önemli farklılıklar göstermektedir. Fischer ve Krauss (2018) çalışmalarında belirttikleri gibi, LSTM'in kapılı mimarisi sayesinde uzun vadeli bağımlılıkları daha iyi yakalayabilme özelliği, özellikle 2020-2021 dönemindeki ani fiyat hareketlerini daha başarılı bir şekilde modellemesini sağlamıştır. GRU ise Cho vd. (2014) tarafından vurgulandığı üzere, daha az parametre kullanması sayesinde hesaplama verimliliği sunmakta ve bu da gerçek zamanlı tahmin uygulamalarında avantaj sağlamaktadır.

RNN modelleri, Bao vd. (2017) çalışmalarında belirtildiği gibi, "kaybolan gradyan" problemi nedeniyle 2018-2019 dönemindeki istikrarlı büyüme periyodunda makul sonuçlar verse de, 2020-2024 arasındaki yüksek volatilité döneminde tahmin performansı önemli ölçüde düşmüştür. Bu durum, RNN'in finansal şoklar karşısında adaptasyon kabiliyetinin sınırlı olduğunu göstermektedir.

MLP modeli ise, Siami-Namini vd. (2019) tarafından vurgulandığı gibi, zamansal bağımlılıkları modelleyememesi nedeniyle grafiklerde görüldüğü üzere trend değişim noktalarında önemli sapmalar göstermiştir. Bu özellik, Nike hissesinin 2021 yılındaki zirve noktasından sonraki düşüş trendinin yakalanmasında MLP'nin yetersiz kaldığını göstermektedir.

Derin öğrenme modellerinin Nike hisse senedi tahmini performansı, finansal piyasaların farklı dönemlerinde değişkenlik göstermiştir. Nabipour vd. (2020) çalışmasında belirtildiği gibi, derin öğrenme modelleri normal piyasa koşullarında yüksek doğruluk sunabilirken, aşırı volatilité dönemlerinde etkinlikleri azalabilmektedir. Bu durum, 2020-2024 dönemindeki COVID-19 pandemisi ve sonrasındaki makroekonomik değişimler gibi beklenmedik olayların yarattığı volatilité artışı sırasında model tahminlerindeki sapmalarda açıkça görülmektedir. Çalışmada kullanılan 31 yıllık uzun dönemli veri seti, Zhang ve Zhang (2016) tarafından önerilen zaman serisi analizinde örneklem büyüklüğünün ve tarihsel verilerin modellenmesinin önemini doğrulamaktadır. Özellikle LSTM ve GRU modelleri, Nike hissesinin 1993-2024 dönemindeki farklı piyasa koşulları ve trend değişimlerini öğrenebilme kapasitesi göstermiştir.

Elde edilen bulgular, LSTM ve GRU'nun finansal zaman serisi tahmininde en uygun modeller olduğunu göstermektedir. GRU, LSTM'ye yakın bir performans sergileyerek alternatif bir çözüm sunarken, RNN ve özellikle MLP'nin bu tür görevlerde yetersiz kaldığı belirlenmiştir. Çalışma, finansal veri setlerinin analizi için kapılı tekrarlayan sinir ağı tabanlı modellerin kullanımının önemini vurgulamaktadır.

Sonuç olarak, bu çalışma, finansal zaman serisi tahminlerinde LSTM ve GRU modellerinin sağladığı avantajları vurgularken, bu modellerin kullanımının özellikle uzun vadeli analizlerde güvenilir sonuçlar üretebileceğini göstermiştir. Bununla birlikte, farklı modellerin performanslarının veri setinin karakteristiğine ve piyasa koşullarına bağlı olarak değişiklik gösterebilmektedir. Çalışmanın yatırımcılar ve finansal analistler için modern derin öğrenme yaklaşımlarının uygulanabilirliği hakkında değerli bir perspektif sunduğu düşünülmektedir. LSTM ve GRU gibi derin öğrenme modellerinin finansal zaman serisi tahmininde yüksek doğruluk sunduğu gözlemlenmiştir. Bu doğrultuda, yatırımcılar bu modeller tarafından üretilen tahminleri karar alma süreçlerinde dikkate alabilirler. Bununla birlikte, volatilitenin arttığı dönemlerde tahmin hatalarının yükseldiği tespit edildiğinden, yatırımcıların portföy yönetim stratejilerini bu belirsizlikleri en aza indirecek şekilde uyarlamaları daha iyi yatırım yapmalarına yardımcı olabilir. Gelecekteki araştırmalar, daha karmaşık hibrit modellerin geliştirilmesi ve alternatif veri kaynaklarının entegrasyonu ile finansal tahminlerin doğruluğunu artırabilir. STM ve GRU gibi RNN tabanlı derin öğrenme modellerinin, XGBoost, CatBoost ve Transformer gibi gelişmiş makine öğrenmesi algoritmalarıyla entegre edilmesi, hisse senedi tahmininde model doğruluğunu artırma potansiyeline sahiptir. Ayrıca, derin öğrenme yöntemlerinin geleneksel istatistiksel modeller (ARIMA, GARCH) ile birleştirilmesi, özellikle yüksek volatiliteli dönemlerde tahmin performansını iyileştirebilir ve modelin piyasa dinamiklerine uyum sağlama kapasitesini artırabilir. Bunun yanı sıra, farklı model kombinasyonlarının ağırlıklandırılmış ensembel öğrenme teknikleri (stacking, boosting) ile optimize edilmesi, tahmin doğruluğunu daha da artırarak, finansal zaman serisi analizi için daha sağlam ve güvenilir bir çerçeve sunabilir.

STOCK PRICE PREDICTION WITH DEEP LEARNING MODELS: COMPARATIVE ANALYSIS OF LSTM, GRU, RNN, MLP MODELS

1. INTRODUCTION

Deep learning, with its ability to model highly complex non-linear relationships and identify intricate properties of influencing factors, has shown promising potential in various fields. Its success in image classification and gene analysis has been well-documented, and research on its application in time series data analysis and prediction is also underway (Akita et al., 2016). The superior performance of deep learning models in diverse research areas has sparked interest, particularly in the context of stock trend forecasting.

In the era of big data, financial analysts often utilize deep learning techniques in stock price forecasting (Viadinugroho and Rosadi, 2021). These techniques can improve the accuracy of forecasts, allowing investors to make more informed decisions. However, stock price forecasting remains one of the most challenging and unpredictable tasks in financial forecasting due to the complexity and dynamic interactions of the stock market. This is further exacerbated by the high volatility, uncertainty and interaction

of market factors with a large number of variables (Tay and Cao, 2001). Research in economics, deep learning and other related fields has revolutionized stock price forecasting (Al-Tamimi et al., 2011). In this context, the purpose of this research is to determine which deep learning model produces more reliable forecasts for investors and financial analysts. This study, which analyzes the stock price movements of Nike (NKE), one of the most established companies in the financial markets, using modern deep learning approaches, holds the potential to significantly enhance stock price forecasting. We use a rich dataset of daily opening, high, low, and closing prices and trading volumes of Nike stock over a 31-year period from 1993 to 2024. For this purpose, four different deep learning models were used: Long-Short Term Memory (LSTM) Gated Recurrent Unit (GRU) Recurrent Neural Networks (RNN) Multilayer Perceptron (MLP)

2. METHODS

This study compares the performance of different deep-learning models in forecasting financial time series. For this purpose, four different deep-learning models are used:

1. Long-Short Term Memory (LSTM): Specialized in learning long-term dependencies

2nd Gated Repetitive Unit (GRU): A more straightforward and faster alternative to LSTM

3. Recurrent Neural Networks (RNN): The basic approach for time series data

4. Multilayer Perceptron (MLP): Traditional artificial neural network architecture

These models were used to predict the future price movements of Nike stock, and their performance was compared on various metrics (MAE, MSE, RMSE, R^2 , and MAPE). The study aims to reveal which deep learning model produces more reliable predictions for investors and financial analysts.

The data used in the study were obtained from <https://tr.investing.com/>. The total data is 8033 because the stock exchange was closed on weekends and other holidays between the specified dates..

3. RESULTS

. LSTM compares the success of GRU, RNN, and MLP models in predicting stock closing prices using four different metrics: Mean Absolute Error (MAE), Mean Square Error (MSE), Root Mean Square Error (RMSE), and Coefficient of Determination (R^2). The performance of the models can be evaluated as follows:

- The LSTM model has the lowest error rates with MAE (2.19), MSE (9.50), and RMSE (3.08) and shows the highest agreement between actual and predicted values with R^2 value (0.985). This reveals that LSTM can effectively learn the long-run

dependencies in time series data and offers high accuracy in its predictions. The high accuracy of LSTM supports why it is often preferred in financial time series forecasting tasks.

- The GRU model performed slightly lower than the LSTM with MAE (3.65), MSE (20.23), and RMSE (4.50). The R^2 value (0.969) shows that the model produces results consistent with the actual values. However, GRU is not as successful as LSTM in capturing short-term fluctuations. Nevertheless, GRU stands out as an effective option in terms of its capacity to learn time series dependencies.

The RNN model performs close to GRU with MAE (3.27), MSE (20.65), and RMSE (4.54). However, the R^2 value (0.968) reveals that its predictions are slightly less consistent compared to LSTM and GRU. RNN has difficulty learning long-run dependencies in time series data, which leads to increased error rates, especially when applied to financial data. RNN underperforms GRU and LSTM in this regard.

- The MLP model has by far the highest error rates with MAE (15.65), MSE (263.19) and RMSE (16.22). Moreover, the R^2 value (0.599) indicates that the model's predictions show a low agreement with the actual values. Since the MLP lacks the capacity to learn the dependencies in time series data, large deviations are observed in its predictions. This result suggests that MLP is unsuitable for complex tasks such as forecasting financial time series.

4. DISCUSSION

RNN models predicted sequential data using the basic recurrent architecture but were weak in learning long-term dependencies. Its performance was limited compared to LSTM and GRU due to structural issues such as gradient loss and bursting. However, the simple structure of the RNN still provides a viable solution for applications requiring low computational cost. On the other hand, the MLP model provided an essential reference point with its ability to model nonlinear relationships in time series. However, it could have performed more effectively in financial data with sequential and long-term dependencies.

CONCLUSION

The results show the LSTM model's superiority in learning long-term dependencies and achieving high accuracy rates. By managing information flow more efficiently through forgetting, entry, and exit gates, LSTM is able to evaluate the impact of past periods on time series data more successfully. Especially in error metrics such as RMSE, MAE, and MAPE, LSTM outperformed other models. Although GRU has a similar architecture, it reduced the computational cost due to the use of fewer parameters and performed satisfactorily in short-term forecasting.

KAYNAKÇA

- Akita, R., Yoshihara, A., Matsubara, T., and Uehara, K. (2016,). Deep learning for stock prediction using numerical and textual information. In 2016 IEEE/ACIS 15th International Conference on Computer and Information Science (ICIS) (pp. 1-6). IEEE. <https://doi.org/10.1109/ICIS.2016.7550882>
- Akşehir, Z. D., and Kilic, E. (2022). How to handle data imbalance and feature selection problems in CNN-based stock price forecasting. IEEE Access, 10, 31297-31305. [doi: 10.1109/ACCESS.2022.3160797](https://doi.org/10.1109/ACCESS.2022.3160797)
- Albayrak, E., ve 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>
- Al-Tamimi, H. A. H., Alwan, A. A., and Abdel Rahman, A. A. (2011). Factors affecting stock prices in the UAE financial markets. *Journal of Transnational Management*, 16(1), 3-19. <https://doi.org/10.1080/15475778.2011.549441>
- Bao, W., Yue, J., and Rao, Y. (2017). A deep learning framework for financial time series using stacked autoencoders and long-short-term memory. *PloS one*, 12(7), e0180944. <https://doi.org/10.1371/journal.pone.0180944>
- Baek, Y., and Kim, H. Y. (2018). ModAugNet: A new forecasting framework for stock market index value with an overfitting prevention LSTM module and a prediction LSTM module. *Expert Systems with Applications*, 113, 457-480. <https://doi.org/10.1016/j.eswa.2018.07.019>
- Bentoumi, M., Daoud, M., Benaouali, M., & Taleb Ahmed, A. (2022). Improvement of emotion recognition from facial images using deep learning and early stopping cross validation. *Multimedia Tools and Applications*, 81(21), 29887-29917.
- Booth, G. G., Martikainen, T., Sarkar, S. K., Virtanen, I., and Yli-Olli, P. (1994). Nonlinear dependence in Finnish stock returns. *European Journal of Operational Research*, 74(2), 273-283. [https://doi.org/10.1016/0377-2217\(94\)90096-5](https://doi.org/10.1016/0377-2217(94)90096-5)
- Breidt, F. J., Crato, N., and De Lima, P. (1998). The detection and estimation of long memory in stochastic volatility. *Journal of Econometrics*, 83(1-2), 325-348. [https://doi.org/10.1016/S0304-4076\(97\)00072-9](https://doi.org/10.1016/S0304-4076(97)00072-9)
- Chai, T., and Draxler, R. R. (2014). Root mean square error (RMSE) or mean absolute error (MAE)? – Arguments against avoiding RMSE in the literature. *Geoscientific Model Development*, 7(3), 1247-1250. <https://doi.org/10.5194/gmd-7-1247-2014>
- Cho, K. (2014). Learning phrase representations using RNN encoder-decoder for statistical machine translation. arXiv preprint arXiv:1406.1078. <https://doi.org/10.48550/arXiv.1406.1078>
- Çevik, O. (2002). İstanbul Menkul Kıymetler Borsası Endeksinin Box-Jenkins Yöntemi İle Modellemesi. *Afyon Kocatepe Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 4(1), 17-32.

- Çoban, Ç., ve Hayat, E. (2023). Hisse Senedi Piyasası Analizinde Farklı Derin Sinir Ağı Modellerinin Karşılaştırılması. *Adnan Menderes Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 10(2), 120-139. <https://doi.org/10.30803/adusobed.1402228>
- Dalkıran, İ., ve Ozan, M. (2022). Derin Öğrenme Teknikleri Kullanılarak Borsadaki Hisse Değerlerinin Tahmin Edilmesi. *Avrupa Bilim ve Teknoloji Dergisi*, 39, 143-148.
- Erden, C. (2023). Derin Öğrenme ve ARIMA Yöntemlerinin Tahmin Performanslarının Kıyaslanması: Bir Borsa İstanbul Hissesi Örneği. *Yönetim Ve Ekonomi Dergisi*, 30(3), 419-438. <https://doi.org/10.18657/yonveek.1208807>
- Fischer, T., and Krauss, C. (2018). Deep learning with long short-term memory networks for financial market predictions. *European journal of operational research*, 270(2), 654-669. <https://doi.org/10.1016/j.ejor.2017.11.054>
- Gamboa, J. C. B. (2017). Deep learning for time-series analysis. *arXiv preprint arXiv:1701.01887*.
- Gavcar, E., ve Metin, H. M. (2021). Hisse senedi değerlerinin makine öğrenimi (derin öğrenme) ile tahmini. *Ekonomi ve Yönetim Araştırmaları Dergisi*, 10(2), 1-11.
- Gökbulut, R. İ., and Pekkaya, M. (2014). Estimating and forecasting volatility of financial markets using asymmetric GARCH models: An application on Turkish financial markets. *International Journal of Economics and Finance*, 6(4), 23-35. <http://dx.doi.org/10.5539/ijef.v6n4p23>
- Haykin, S. (2009). *Neural networks and learning machines*, 3/E. Bangalore:Pearson Education
- Heaton, J. B., Polson, N. G., and Witte, J. H. (2016). Deep learning in finance. arXiv preprint arXiv:1602.06561. <https://doi.org/10.48550/arXiv.1602.06561>
- Hewamalage, H., Bergmeir, C., and Bandara, K. (2021). Recurrent neural networks for time series forecasting: Current status and future directions. *International Journal of Forecasting*, 37(1), 388-427.
- Hochreiter, S., and Schmidhuber, J. (1997). Long short-term memory. *Neural Computation*, 9(8), 1735-1780. <https://doi.org/10.1162/neco.1997.9.8.1735>
- Hundman, K., Constantinou, V., Laporte, C., Colwell, I., and Soderstrom, T. (2018, July). Detecting spacecraft anomalies using lstms and nonparametric dynamic thresholding. In Proceedings of the 24th ACM SIGKDD international conference on knowledge discovery & data mining (pp. 387-395).
- Karakoyun, E. Ş. (2018). Derin öğrenme ile zaman serilerinin gerçek zamanlı tahmini. Yüksek Lisans Tezi, Necmettin Erbakan Üniversitesi.
- Kılınç, H. Ç., ve Öztürk, Y. (2022). Hibrit Gri Kurt Optimizasyonu ile Kapılı Tekrarlayan Birim Modeli Kullanılarak Günlük Akım Tahmini. *Avrupa Bilim ve Teknoloji Dergisi*, (35), 259-267. <https://doi.org/10.31590/ejosat.1062777>
- Kim, H. Y., and 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.
<https://doi.org/10.1016/j.eswa.2018.03.002>
- Längkvist, M., Karlsson, L., & Loutfi, A. (2014). A review of unsupervised feature learning and deep learning for time-series modeling. *Pattern Recognition Letters*, 42, 11-24.
- LeCun, Y., Bengio, Y., and Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436-444. <https://doi.org/10.1038/nature14539>
- Makridakis, S., Wheelwright, S. C., and Hyndman, R. J. (1998). *Forecasting: methods and applications*. New York City: John Wiley & Sons.
- Makinde, A. (2024). Optimizing Time Series Forecasting: A Comparative Study of Adam and Nesterov Accelerated Gradient on LSTM and GRU networks Using Stock Market data. arXiv preprint arXiv:2410.01843.
- Montgomery, D. C., Peck, E. A., and Vining, G. G. (2012). *Introduction to linear regression analysis*, New York City: John Wiley & Sons.
- Munkhdalai, L., Munkhdalai, T., Park, K. H., Lee, H. G., Li, M., and Ryu, K. H. (2019). Mixture of activation functions with extended min-max normalization for forex market prediction. *IEEE Access*, 7, 183680-183691
- Nabipour, M., Nayyeri, P., Jabani, H., Mosavi, A., and Salwana, E. (2020). Deep learning for stock market prediction. *Entropy*, 22(8), 840. <https://doi.org/10.3390/e22080840>
- Nelson, D. M., Pereira, A. C., and De Oliveira, R. A. (2017, May). Stock market's price movement prediction with LSTM neural networks. In 2017 International Joint Conference on neural networks (IJCNN) (pp. 1419-1426). Ieee. <https://doi.org/10.1109/IJCNN.2017.7966019>
- Öztürk, C., and Karacı, A. (2024). An Empirical Analysis of Stock Price Prediction Using Deep Learning Methods: LSTM, GRU, GAN, and WGAN-GP. *Gazi Journal of Engineering Sciences (GJES)/Gazi Mühendislik Bilimleri Dergisi*, 10(3).
- Praveen, P., Shrivani, S., Srija, R., and Tajuddin, M. (2023, June). A model to stock price prediction using deep learning. In 2023 International Conference on Sustainable Computing and Smart Systems (ICSCSS) (pp. 242-252). IEEE. <https://doi.org/10.1109/ICSCSS57650.2023.10169558>
- Prechelt, L. (2002). Early stopping-but when?. In *Neural Networks: Tricks of the trade*. Berlin, Heidelberg: Springer Berlin Heidelberg.
- Pranolo, A., Setyaputri, F. U., Paramarta, A. K. A. I., Triono, A. P. P., Fadhillah, A. F., Akbari, A. K. G., and Uriu, W. (2024). Enhanced Multivariate Time Series Analysis Using LSTM: A Comparative Study of Min-Max and Z-Score Normalization Techniques. *ILKOM Jurnal Ilmiah*, 16(2), 210-220.
- Rahman, M. O., Hossain, M. S., Junaid, T. S., Forhad, M. S. A., and Hossen, M. K. (2019). Predicting prices of stock market using gated recurrent units (GRUs) neural networks. *Int. J. Comput. Sci. Netw. Secur.*, 19(1), 213-222.
- 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.

- Rezaei, H., Faaljou, H., and Mansourfar, G. (2021). Stock price prediction using deep learning and frequency decomposition. *Expert Systems with Applications*, 169, 114332. <https://doi.org/10.1016/j.eswa.2020.114332>
- Rosenblatt, F. (1958). The perceptron: a probabilistic model for information storage and organization in the brain. *Psychological review*, 65(6), 386.
- Rumelhart, D. E., Hinton, G. E., and Williams, R. J. (1986). Learning representations by back-propagating errors. *Nature*, 323(6088), 533-536. <https://doi.org/10.1038/323533a0>
- Sakarya, Ş., ve Yılmaz, Ü. (2019). Derin öğrenme mimarisi kullanılarak BİST30 indeksinin tahmini. *European Journal of Educational and Social Sciences*, 4(2), 106-121.
- Samii, A., Karami, H., Ghazvinian, H., Safari, A., and Dadrasajirlou, Y. (2023). Comparison of DEEP-LSTM and MLP models in estimation of evaporation pan for arid regions. *Journal of Soft Computing in Civil Engineering*, 7(2), 155-175.
- Saud, A. S., and Shakya, S. (2020). Analysis of look back period for stock price prediction with RNN variants: A case study on banking sector of NEPSE. *Procedia Computer Science*, 167, 788-798. <https://doi.org/10.1016/j.procs.2020.03.419>
- Selvin, S., Vinayakumar, R., Gopalakrishnan, E. A., Menon, V. K. and Soman, K. P. (2017). Stock price prediction using LSTM, RNN and CNN-sliding window model. 2017 International Conference on Advances in Computing, Communications and Informatics (ICACCI), Udupi, India, pp. 1643-1647, [doi: 10.1109/ICACCI.2017.8126078](https://doi.org/10.1109/ICACCI.2017.8126078).
- Shen, G., Tan, Q., Zhang, H., Zeng, P., and Xu, J. (2018). Deep learning with gated recurrent unit networks for financial sequence predictions. *Procedia computer science*, 131, 895-903. <https://doi.org/10.1016/j.procs.2018.04.298>
- Si, J., Harris, S. L., and Yfantis, E. (2018). A dynamic ReLU on neural network. In 2018 IEEE 13th Dallas Circuits and Systems Conference (DCAS) (pp. 1-6). IEEE.
- Siami-Namini, S., Tavakoli, N., and Namin, A. S. (2019). A comparison of ARIMA and LSTM in forecasting time series. 17th IEEE International Conference on Machine Learning and Applications (ICMLA), 1394-1401.
- Şişmanoğlu, G., Koçer, F., Önde, M. A., and Sahingöz, O. K. (2020). Derin öğrenme yöntemleri ile borsada fiyat tahmini. *Bitlis Eren Üniversitesi Fen Bilimleri Dergisi*, 9(1), 434-445. [doi: 10.17798/bitlisfen.571386](https://doi.org/10.17798/bitlisfen.571386).
- Tay, F. E., and Cao, L. (2001). Application of support vector machines in financial time series forecasting. *Omega*, 29(4), 309-317. [https://doi.org/10.1016/S0305-0483\(01\)00026-3](https://doi.org/10.1016/S0305-0483(01)00026-3)
- Viadinugroho, R. A. A., and Rosadi, D. (2021, March). Long short-term memory neural network model for time series forecasting: case study of forecasting IHSG during Covid-19 outbreak. In *Journal of Physics: Conference Series* (Vol. 1863, No. 1, p. 012016). IOP Publishing. <https://doi.org/10.1088/1742-6596/1863/1/012016>

- Willmott, C. J., and Matsuura, K. (2005). Advantages of the mean absolute error (MAE) over the root mean square error (RMSE) in assessing average model performance. *Climate Research*, 30(1), 79-82. <https://doi.org/10.3354/cr030079>
- Yan, X., Weihan, W., and Chang, M. (2021). Research on financial assets transaction prediction model based on LSTM neural network. *Neural Computing and Applications*, 33(1), 257-270. <https://doi.org/10.1007/s00521-020-04992-7>
- Zhang, G., and Zhang, X. (2016). ARMAD-GARCH Stock Price Forecasting Model Based on Differential Information. *Systems Engineering-Theory & Practice*, 36(05), 1136-1145.
- Zhang, Q., Yang, L. T., Chen, Z., and Li, P. (2018). A survey on deep learning for big data. *Information Fusion*, 42, 146-157. <https://doi.org/10.1016/j.inffus.2017.10.006>

KATKI ORANI / CONTRIBUTION RATE	AÇIKLAMA / EXPLANATION	KATKIDA BULUNANLAR / CONTRIBUTORS
Fikir veya Kavram / <i>Idea or Notion</i>	Araştırma hipotezini veya fikrini oluşturmak / <i>Form the research hypothesis or idea</i>	Zeynep ÇOLAK
Tasarım / <i>Design</i>	Yöntemi, ölçeği ve deseni tasarlamak / <i>Designing method, scale and pattern</i>	Zeynep ÇOLAK
Veri Toplama ve İşleme / <i>Data Collecting and Processing</i>	Verileri toplamak, düzenlemek ve raporlamak / <i>Collecting, organizing and reporting data</i>	Zeynep ÇOLAK
Tartışma ve Yorum / <i>Discussion and Interpretation</i>	Bulguların değerlendirilmesinde ve sonuçlandırılmasında sorumluluk almak / <i>Taking responsibility in evaluating and finalizing the findings</i>	Zeynep ÇOLAK
Literatür Taraması / <i>Literature Review</i>	Çalışma için gerekli literatürü taramak / <i>Review the literature required for the study</i>	Zeynep ÇOLAK