

LSTM ve GRU Hibrit Modeli ile Hisse Senedi Fiyat Tahmini: Türkiye Borsası Uygulaması ve Model Karşılaştırmaları

Stock Price Prediction with LSTM and GRU Hybrid Model: An Application on the Turkish Stock Market and Model Comparisons

Murat ŞİMŞEK^a Öz el SEBETCİ^b Sahib RAHİMOVV^c

^a Ostim Teknik Üniversitesi, Mühendislik Fakültesi, Ankara, Türkiye, murat.simsek@ostimteknik.edu.tr

^b Aydın Adnan Menderes Üniversitesi, Aymes, Aydın, Türkiye, osebetci@adu.edu.tr

^c Ostim Teknik Üniversitesi, Mühendislik Fakültesi, Ankara, Türkiye, sahib.rahimovv@gmail.com

MAKALE BİLGİSİ	ÖZET
Anahtar Kelimeler: Hisse senedi fiyat tahmini LSTM GRU Hibrit Model Derin Öğrenme Finansal Zaman Serileri Tahmini	Amaç – Finansal piyasalarda hisse senedi fiyat tahmini, yatırım kararlarının doğruluğunu artırmak için kritik bir konudur. Geleneksel istatistiksel yöntemler, finansal zaman serilerinin doğrusal olmayan ve yüksek oynaklığa sahip yapısını yeterince yakalayamamaktadır. Bu çalışmada, Uzun Kısa Süreli Bellek (LSTM) ve Gated Recurrent Unit (GRU) modellerini birleştiren bir hibrit derin öğrenme modeli önerilmiştir. Çalışmanın temel amacı, LSTM-GRU hibrit modelinin hisse senedi fiyat tahminindeki başarımını değerlendirmek ve bu modelin performansını LSTM-CNN, LSTM-AUTOENCODER ve LSTM-TRANSFORMER hibrit modelleri ile karşılaştırmaktır.
Gönderilme Tarihi 2 Aralık 2024	Yöntem – Çalışmada, 2020-2023 yılları arasında Türkiye borsasında işlem gören hisse senetlerine ait günlük fiyat verileri kullanılmıştır. Yahoo Finance üzerinden elde edilen veri seti, açılış, en yüksek, en düşük, kapanış fiyatları ve işlem hacmi gibi temel özellikleri içermekte olup, MinMaxScaler yöntemi ile normalize edilmiştir. Modelin başarımı, Kök Ortalama Kare Hatası (RMSE), Ortalama Mutlak Hata (MAE), Ortalama Mutlak Yüzdesel Hata (MAPE), Determinasyon Katsayısı (R ²) ve Ortalama Kare Hata (MSE) metrikleri kullanılarak değerlendirilmiştir. Ayrıca, LSTM-GRU modeli, LSTM-CNN, LSTM-AUTOENCODER ve LSTM-TRANSFORMER hibrit modelleriyle karşılaştırılarak tahmin doğruluğu açısından üstünlüğü test edilmiştir.
Revizyon Tarihi 14 Mart 2025	Bulgular – Deneysel sonuçlar, LSTM-GRU hibrit modelinin, diğer hibrit modellere kıyasla daha düşük hata oranlarına ve daha yüksek doğruluk değerlerine sahip olduğunu göstermektedir. Özellikle RMSE ve MAE değerleri açısından en başarılı model LSTM-GRU olarak belirlenmiştir. Model, Banka-1 ve Holding-1 hisse senetlerinde yüksek doğruluk sağlarken, Şirket-1 hisse senedi için hata oranlarının görece daha yüksek olduğu tespit edilmiştir. Bununla birlikte, LSTM-CNN ve LSTM-AUTOENCODER modelleri makul düzeyde tahmin başarımı gösterirken, LSTM-TRANSFORMER modelinin finansal zaman serilerinde beklenen performansı sağlayamadığı görülmüştür.
Kabul Tarihi 20 Mart 2025	Tartışma – Elde edilen bulgular, LSTM-GRU modelinin finansal zaman serilerindeki karmaşık bağıntıları başarıyla yakaladığını ve hisse senedi fiyat tahmininde güvenilir bir araç olarak değerlendirilebileceğini göstermektedir. Çalışma, hibrit derin öğrenme modellerinin finansal tahmin süreçlerinde kullanım potansiyelini ortaya koymakta ve özellikle LSTM-GRU kombinasyonunun yatırım karar destek sistemleri açısından önemli bir katkı sunduğunu göstermektedir. Gelecekteki çalışmalar, modelin hiperparametre optimizasyonu, gerçek zamanlı piyasa verileriyle adaptasyonu ve makroekonomik değişkenlerin entegrasyonu gibi faktörler üzerinde yoğunlaşarak modelin tahmin kapasitesini artırmayı hedefleyebilir.

ARTICLE INFO	ABSTRACT
Keywords: Stock price prediction LSTM GRU Hybrid Model Deep Learning Financial Time Series Forecasting	Purpose – Stock price forecasting is a crucial task in financial markets, requiring accurate and reliable models to support investment decisions. Traditional statistical methods often fail to capture the nonlinear and highly volatile nature of financial time series. To address these limitations, this study proposes a hybrid deep learning model combining Long Short-Term Memory (LSTM) and Gated Recurrent Unit (GRU) architectures. The primary objective of this research is to evaluate the performance of the LSTM-GRU hybrid model in stock price prediction and compare it against other hybrid models, including LSTM-CNN, LSTM-AUTOENCODER, and LSTM-TRANSFORMER.
	Design/methodology/approach – The study employs daily stock price data from 2020 to 2023, obtained from Yahoo Finance, covering multiple companies listed on the Turkish stock market. The dataset includes open, high, low, close prices, and trading volume, which were normalized using the

Önerilen Atıf/Suggested Citation

Şimşek, M., Sebetci, Ö., Rahimovv, S. (2025). LSTM ve GRU Hibrit Modeli ile Hisse Senedi Fiyat Tahmini: Türkiye Borsası Uygulaması ve Model Karşılaştırmaları, İşletme Araştırmaları Dergisi, 17 (2), 886-904.

Received 2 December 2024	MinMaxScaler technique. The LSTM-GRU model was trained and evaluated using Root Mean Squared Error (RMSE), Mean Absolute Error (MAE), Mean Absolute Percentage Error (MAPE), R^2 , and Mean Squared Error (MSE) metrics. Furthermore, the model's predictive accuracy was benchmarked against LSTM-CNN, LSTM-AUTOENCODER, and LSTM-TRANSFORMER hybrid models to assess its relative effectiveness.
Revised 14 March 2025	
Accepted 20 March 2025	
Article Classification:	Findings – Experimental results indicate that the LSTM-GRU hybrid model outperforms other hybrid architectures in terms of accuracy and robustness. Specifically, the model achieved the lowest RMSE and MAE values, demonstrating high predictive accuracy for stock price movements. The R^2 values suggest that the model effectively captures the underlying structure of stock price fluctuations. Moreover, while LSTM-CNN and LSTM-AUTOENCODER models exhibited reasonable accuracy, the LSTM-TRANSFORMER model demonstrated significantly lower predictive performance, suggesting its limitations in financial time series forecasting.
Research Article	Discussion – The findings highlight the superior performance of the LSTM-GRU model in financial forecasting, making it a reliable tool for investment decision-making. The study further suggests that hybrid deep learning models, particularly those incorporating both LSTM and GRU, are more effective in capturing the complex dependencies of stock price data compared to alternative architectures. Future research should explore hyperparameter optimization, real-time market adaptation, and the inclusion of macroeconomic indicators to enhance the model's predictive capabilities.

1. Giriş

Finansal piyasalar, yatırımcıların stratejik kararlarını desteklemek için doğru ve güvenilir fiyat tahminlerine ihtiyaç duymaktadır. Geleneksel yöntemlerin kullanılması, piyasa dinamiklerinin karmaşıklığını tam olarak yakalayamamakta ve yatırımcılara sınırlı öngörüler sunmaktadır (Khan ve ark., 2023; Chandra ve ark., 2021). Finansal zaman serisi verilerinin yüksek değişkenliği ve nonlineer doğası, tahmin süreçlerinde daha gelişmiş yöntemlerin kullanılmasını zorunlu hale getirmiştir.

Bu bağlamda, derin öğrenme yöntemleri ve özellikle Uzun Kısa Süreli Bellek (LSTM) ve Gated Recurrent Unit (GRU) modelleri, zaman serisi verilerinin karmaşıklığını ele alarak daha isabetli tahminler yapabilme potansiyeline sahiptir (Shahi ve ark., 2020). Son yıllarda LSTM ve GRU gibi derin öğrenme modelleri, finansal piyasalarda yaygın bir şekilde kullanılmaya başlanmış ve tahmin doğruluğunu önemli ölçüde artırmıştır (Pardeshi ve ark., 2023). Bununla birlikte, hibrit modellerin geliştirilmesi, tahmin performansının daha da iyileştirilmesine olanak tanımaktadır (Khan ve ark., 2023).

Hibrit yaklaşımlar, özellikle Empirical Mode Decomposition (EMD) gibi yöntemlerin LSTM ile birleştirilmesiyle, karmaşık finansal verilerin daha iyi modellenmesine katkı sağlamaktadır (Khan ve ark., 2023). Bu çalışmanın özgün değeri, LSTM ve GRU modellerini birleştirerek hisse senedi fiyat tahmininde daha yüksek doğruluk sağlamaya yönelik bir hibrit model geliştirmesidir. Mevcut çalışmalardan farkı, modelin finansal tahminlerde yaygın olarak kullanılan diğer hibrit modellerle (LSTM-CNN, LSTM-AUTOENCODER, LSTM-TRANSFORMER) detaylı şekilde karşılaştırılmasıdır.

Bu çalışmada, Türkiye borsasındaki farklı hisse senetleri üzerinde LSTM-GRU hibrit modelinin performansı test edilmiş ve bu modelin diğer hibrit modellerle kıyaslanarak kapsamlı bir performans analizi yapılmıştır. Veri toplama aşamasında 2020-2023 yılları arasındaki günlük hisse senedi verileri Yahoo Finance aracılığıyla elde edilmiş ve veriler MinMaxScaler ile normalize edilerek modelin eğitiminde kullanılmıştır. Modelin performansı, kök ortalama kare hatası (RMSE), ortalama mutlak hata (MAE), ortalama mutlak yüzdesel hata (MAPE), determinasyon katsayısı (R^2) ve ortalama kare hata (MSE) gibi metriklerle değerlendirilmiştir (Khan ve ark., 2023).

Elde edilen sonuçlar, LSTM-GRU hibrit modelinin diğer hibrit modellere kıyasla daha üstün performans sergilediğini ve yatırım kararlarında kullanılabilecek güvenilir bir araç olduğunu ortaya koymaktadır.

2. Kavramsal Çerçeve

Finansal zaman serilerinin modellenmesi, karmaşık ve değişken piyasa koşullarından dolayı büyük zorluklar içermektedir. Geleneksel istatistiksel modeller, zaman serisi analizinde uzun yıllardır kullanılmakla birlikte, finansal piyasa verilerinin doğrusal olmayan ve yüksek değişkenliğe sahip yapısını yeterince yakalayamamaktadır (Zhang ve ark., 2020). Bu bağlamda, derin öğrenme modelleri, özellikle LSTM (Uzun Kısa Süreli Bellek) ve GRU (Gated Recurrent Unit) gibi yöntemler, zaman serilerindeki uzun vadeli bağıntıları öğrenmede önemli avantajlar sunmaktadır (Hochreiter & Schmidhuber, 1997).

2.1. LSTM ve GRU Modelleri

LSTM ve GRU modelleri, geleneksel yapay sinir ağlarının aksine geriye yayılım sırasında uzun vadeli bağıntıları öğrenebilme yeteneğine sahiptir. LSTM, unutma (forget), giriş (input) ve çıkış (output) kapıları aracılığıyla bilgiyi düzenleyerek uzun vadeli ilişkileri korur (Hochreiter & Schmidhuber, 1997). GRU ise, giriş kapıları yerine güncelleme (update) ve sıfırlama (reset) kapıları kullanarak LSTM'ye kıyasla daha hesaplamalı olarak verimli bir model sunmaktadır (Cho ve ark., 2014).

Bu iki model, finansal zaman serilerinin tahmininde başarıyla uygulanmış ve piyasadaki dalgalanmaların daha iyi yakalanmasını sağlamıştır. LSTM, daha karmaşık ilişkileri öğrenebilme kapasitesine sahipken, GRU daha düşük hesaplama maliyetiyle hızlı öğrenme avantajına sahiptir (Yang & Wang, 2019).

2.2. Hibrit Modellerin Önemi

Son yıllarda, tek bir derin öğrenme modelinin piyasa hareketlerini modellemek için yeterli olmadığı ve hibrit modellerin daha iyi performans sunduğu ortaya konmuştur (Pardeshi ve ark., 2023). Hibrit modeller, farklı mimarilerin güçlü yönlerini birleştirerek daha doğru ve istikrarlı tahminler yapılmasına olanak tanır.

Bu çalışmada, LSTM ve GRU modellerinin birleşimiyle oluşturulan bir hibrit modelin finansal zaman serisi tahminlerinde performansını analiz ediyoruz. Ayrıca, hibrit modellerin diğer türevleriyle kıyaslanması, literatürdeki mevcut yaklaşımlar ile bu çalışmanın farkını ortaya koymaktadır. devamAşağıda, çalışmada kullanılan hibrit modeller ve literatürdeki karşılıkları açıklanmıştır:

- LSTM-GRU Hibrit Modeli: LSTM'nin uzun dönemli hafıza kapasitesi ile GRU'nun hesaplama verimliliğini birleştiren model.
- LSTM-CNN Hibrit Modeli: LSTM'nin zaman serisi öğrenme yeteneği ile CNN'nin (Convolutional Neural Network) uzamsal özellik çıkarma gücünü birleştiren model (Livieris ve ark., 2021).
- LSTM-AUTOENCODER Hibrit Modeli: LSTM'nin derin zaman serisi analiziyle Autoencoder'ın veri sıkıştırma ve yeniden yapılandırma yeteneğini kullanan model (Singh & Kaur, 2021).
- LSTM-TRANSFORMER Hibrit Modeli: LSTM'nin uzun vadeli bağıntı öğrenme yeteneğini, Transformer'ın (Attention mekanizması) paralel öğrenme kapasitesiyle birleştiren model (Vaswani ve ark., 2017).

Bu modellerin detaylı karşılaştırılması, finansal zaman serisi tahminlerinde en etkili yöntemin belirlenmesini sağlayacaktır.

3.Yöntem

Bu çalışmada, hisse senedi fiyat tahmininde LSTM (Uzun Kısa Süreli Bellek) ve GRU (Gated Recurrent Unit) hibrit modeli kullanılmış ve Türkiye borsasındaki çeşitli hisse senetleri üzerinde test edilmiştir. Ayrıca, modelin performansı LSTM-CNN, LSTM-AUTOENCODER ve LSTM-TRANSFORMER hibrit modelleri ile karşılaştırılmıştır (Khan ve ark., 2023; Pinapatruni ve ark., 2023). Bu bölümde, çalışmada kullanılan veri setleri, veri toplama ve ön işleme süreçleri, model geliştirme ve eğitim aşamaları ile performans değerlendirme metrikleri ayrıntılı olarak açıklanmaktadır. Dolayısıyla bu çalışmada, Türkiye borsasında işlem gören hisse senetlerinin fiyat tahmininde LSTM ve GRU tabanlı bir hibrit model geliştirilmiş ve diğer hibrit modellerle karşılaştırılmıştır. Bu bölümde, veri seti, veri toplama süreci, veri ön işleme adımları, modelin geliştirilmesi ve performans değerlendirme metrikleri detaylı olarak açıklanmaktadır.

Veri Seti ve Veri Toplama Süreci

Bu çalışmada, 2020-2023 yılları arasındaki Türkiye borsasında işlem gören hisse senetlerinin günlük fiyat verileri kullanılmıştır. Veriler Yahoo Finance aracılığıyla Python'daki yfinance kütüphanesi kullanılarak elde edilmiştir (Yang & Wang, 2019).

Her bir hisse senedi için aşağıdaki beş temel özellik kullanılmıştır:

Açılış fiyatı (Open): Günün başlangıcındaki fiyat.

En yüksek fiyat (High): Gün içindeki maksimum fiyat.

En düşük fiyat (Low): Gün içindeki minimum fiyat.

Kapanış fiyatı (Close): Gün sonunda gerçekleşen fiyat.

İşlem hacmi (Volume): Gün içinde işlem gören toplam hisse sayısı.

Veri setinde Garanti Bankası (Banka-1), Akbank (Banka-2), Koç Holding (Holding-1) ve Arçelik (Şirket-1) olmak üzere dört büyük şirketin hisse senedi verileri kullanılmıştır. Şirket isimleri anonim hale getirilerek kodlanmıştır.

Veri Ön İşleme

Veri ön işleme süreci, modelin performansını artırmak için şu adımları içermektedir:

Eksik ve Hatalı Verilerin Temizlenmesi

Eksik veriler lineer interpolasyon ile doldurulmuştur (Shahi ve ark., 2020).

Anormal fiyat değişimleri z-skor analizi ile belirlenmiş ve veri bütünlüğü sağlanmıştır.

Verilerin Normalizasyonu

Modelin daha hızlı öğrenmesi için MinMaxScaler yöntemi kullanılmış ve tüm veriler [0,1] aralığına ölçeklendirilmiştir (Yang & Wang, 2019).

Zaman Adımları (Time Steps)

Modelin geçmiş verilerden öğrenmesini sağlamak için 50 günlük bir zaman adımı (lag) kullanılmıştır.

Yani, 50 günün verisi kullanılarak 51. gün tahmin edilmiştir (Khan ve ark., 2023).

Model Geliştirme ve Eğitim Süreci

LSTM-GRU hibrit modeli, LSTM'nin uzun vadeli bağıntı öğrenme kapasitesi ile GRU'nun hesaplama verimliliğini birleştirmek amacıyla geliştirilmiştir.

Model mimarisi şu bileşenlerden oluşmaktadır:

Giriş Katmanı: 50 günlük veri giriş alır.

LSTM Katmanları: İki katmanlı yapı, uzun vadeli bağıntıları öğrenir.

GRU Katmanları: İki katmanlı yapı, zaman serisi analizini hızlandırır.

Tam Bağlantılı Katmanlar: Çıktıları işleyerek nihai tahminleri üretir.

Çıkış Katmanı: 1 nöron içerir ve kapanış fiyatını tahmin eder.

Model Performansının Değerlendirilmesi

Modelin doğruluk performansını ölçmek için RMSE, MAE, MAPE, R² ve MSE gibi metrikler kullanılmıştır:

RMSE (Root Mean Squared Error): Tahmin hatalarının büyüklüğünü ölçer.

MAE (Mean Absolute Error): Ortalama mutlak hata değerini gösterir.

MAPE (Mean Absolute Percentage Error): Hata oranını yüzdesel olarak hesaplar.

R² (Determination Coefficient): Modelin açıklama gücünü gösterir.

MSE (Mean Squared Error): Hata karelerinin ortalamasını verir.

4. Model Uygulanması

Çalışmada, Türkiye borsasında işlem gören çeşitli hisse senetlerinin fiyat verileri kullanılmıştır. Veriler Yahoo Finance aracılığıyla 2020-2023 yılları arasındaki günlük fiyat ve işlem hacmi verileri şeklinde elde edilmiştir. Toplanan veriler her bir hisse senedi için açılış (Open), en yüksek (High), en düşük (Low), kapanış (Close) fiyatları ve işlem hacmi (Volume) olmak üzere beş temel özelliği içermektedir. Veri toplama aşamasında Python programlama dilinde yfinance kütüphanesi kullanılmıştır. Bu kütüphane, finansal verilerin kolayca indirilip işlenmesine olanak tanıyan güçlü bir araçtır (Yang ve Wang, 2019). Yfinance kullanılarak Türkiye borsasında işlem gören çeşitli hisse senetlerinin günlük verileri çekilmiştir.

Bu çalışmada, Garanti Bankası (GARAN), Akbank (AKBNK), Koç Holding (KCHOL) ve Arçelik (ARCLK) hisse senetlerine ait veriler analiz edilmiştir. Her bir hisse senedi için 1 Ocak 2020 ile 1 Ocak 2023 tarihleri arasındaki veriler indirilmiş ve analiz için hazırlanmıştır. Bu veriler modelin eğitimi ve test edilmesi amacıyla

kullanılmak üzere ikiye ayrılmıştır. Eğitim ve test veri setlerinin oranı %80 eğitim ve %20 test olarak belirlenmiştir.

Veri hazırlama aşamasında, MinMaxScaler kullanılarak veriler normleştirilmiş ve modelin eğitiminde kullanılmaya uygun hale getirilmiştir. Normalizasyon işlemi, verilerin belirli bir aralığa (genellikle [0,1] aralığı) dönüştürülmesini sağlar ve bu süreç, derin öğrenme modellerinin daha iyi performans göstermesi açısından önemlidir (Shahi ve ark., 2020).

Toplanan veriler aşağıdaki gibi her bir hisse senedi için beş günlük örnekler sunmaktadır:

GARAN (Garanti Bankası) Hisse Senedi Verisi: Garanti Bankası hisse senedi için toplanan veri seti toplamda (753) günlük veri noktası içermektedir. Bu veri setinde beş temel özellik bulunmaktadır: Açılış fiyatı (Open), en yüksek fiyat (High), en düşük fiyat (Low), kapanış fiyatı (Close) ve işlem hacmi (Volume). Açılış fiyatı, günün başlangıcındaki hisse senedi fiyatını ifade ederken; en yüksek ve en düşük fiyatlar, gün içerisindeki en yüksek ve en düşük değerleri gösterir. Kapanış fiyatı, gün sonunda hisse senedinin ulaştığı fiyatı belirtir. İşlem hacmi ise, gün boyunca işlem gören hisse senedi adedini temsil eder. Aşağıda, GARAN hisse senedi verisinden 5 günlük örnek veri Tablo 1'de sunulmuştur:

Tablo 1. GARAN(Garanti Bankası) Örnek Veriler Tablosu

Tarih	Açılış	En Yüksek	En düşük	Kapanış	Hacim
2020-02-17	11.649999618530273	11.760000228881836	11.579999923706055	11.739999771118164	25031946
2020-02-18	11.649999618530273	11.6899995803833	11.539999961853027	11.579999923706055	17263085
2020-02-19	11.619999885559082	11.670000076293945	11.34000015258789	11.430000305175781	30623464
2020-02-20	11.399999618530273	11.40999984741211	10.869999885559082	11.079999923706055	59786528
2020-02-21	10.899999618530273	11.350000381469727	10.859999656677246	11.069999694824219	43435284

AKBNK (Akbank) Hisse Senedi Verisi: Akbank (AKBNK) hisse senedi için toplanan veri seti toplamda (753) günlük veri noktası içermektedir. Bu veri setinde beş temel özellik bulunmaktadır: Açılış fiyatı (Open), en yüksek fiyat (High), en düşük fiyat (Low), kapanış fiyatı (Close) ve işlem hacmi (Volume). Açılış fiyatı, günün başlangıcındaki hisse senedi fiyatını ifade ederken; en yüksek ve en düşük fiyatlar, gün içerisindeki en yüksek ve en düşük değerleri gösterir. Kapanış fiyatı, gün sonunda hisse senedinin ulaştığı fiyatı belirtir. İşlem hacmi ise, gün boyunca işlem gören hisse senedi adedini temsil eder. Aşağıda, AKBNK hisse senedi verisinden 5 günlük örnek veri Tablo 2'de sunulmuştur:

Tablo 2. AKBNK(Akbank) Örnek Veriler Tablosu

Tarih	Açılış	En Yüksek	En düşük	Kapanış	Hacim
2020-02-17	8.199999809265137	8.199999809265137	8.100000381469727	8.100000381469727	14929707
2020-02-18	8.079999923706055	8.15999984741211	8.010000228881836	8.069999694824219	24434493
2020-02-19	8.109999656677246	8.130000114440918	7.849999904632568	7.929999828338623	24443789
2020-02-20	7.929999828338623	7.929999828338623	7.559999942779541	7.670000076293945	36507128
2020-02-21	7.579999923706055	7.789999961853027	7.550000190734863	7.679999828338623	34942324

KCHOL (Koç Holding) Hisse Senedi Verisi: Koç Holding (KCHOL) hisse senedi için toplanan veri seti toplamda (753) günlük veri noktası içermektedir. Bu veri setinde beş temel özellik bulunmaktadır: Açılış fiyatı (Open), en yüksek fiyat (High), en düşük fiyat (Low), kapanış fiyatı (Close) ve işlem hacmi (Volume). Açılış fiyatı, günün başlangıcındaki hisse senedi fiyatını ifade ederken; en yüksek ve en düşük fiyatlar, gün

içerisindeki en yüksek ve en düşük değerleri gösterir. Kapanış fiyatı, gün sonunda hisse senedinin ulaştığı fiyatı belirtir. İşlem hacmi ise, gün boyunca işlem gören hisse senedi adedini temsil eder. Aşağıda, KCHOL hisse senedi verisinden 5 günlük örnek veri Tablo 3'de sunulmuştur:

Tablo 3. KCHOL(Koç Holding) Örnek Veriler Tablosu

Tarih	Açılış	En Yüksek	En düşük	Kapanış	Hacim
2020-02-17	20.0	20.15999984741211	19.700000762939453	20.020000457763672	3176450
2020-02-18	20.040000915527344	20.059999465942383	19.700000762939453	19.850000381469727	2915839
2020-02-19	19.799999237060547	19.93000030517578	19.709999084472656	19.889999389648438	3023311
2020-02-20	20.0	20.299999237060547	19.5	19.549999237060547	6582996
2020-02-21	19.5	19.82999923706055	19.309999465942383	19.649999618530273	3930044

ARCLK (Arçelik) Hisse Senedi Verisi: Arçelik (ARCLK) hisse senedi için toplanan veri seti toplamda (753) günlük veri noktası içermektedir. Bu veri setinde beş temel özellik bulunmaktadır: Açılış fiyatı (Open), en yüksek fiyat (High), en düşük fiyat (Low), kapanış fiyatı (Close) ve işlem hacmi (Volume). Açılış fiyatı, günün başlangıcındaki hisse senedi fiyatını ifade ederken; en yüksek ve en düşük fiyatlar, gün içerisindeki en yüksek ve en düşük değerleri gösterir. Kapanış fiyatı, gün sonunda hisse senedinin ulaştığı fiyatı belirtir. İşlem hacmi ise, gün boyunca işlem gören hisse senedi adedini temsil eder. Aşağıda, ARCLK hisse senedi verisinden 5 günlük örnek veri Tablo 4'de sunulmuştur:

Tablo 4. ARCLK(Arçelik) Örnek Veriler Tablosu

Tarih	Açılış	En Yüksek	En düşük	Kapanış	Hacim
2020-02-17	20.600000381469727	20.780000686645508	20.440000534057617	20.5	1749720
2020-02-18	20.5	20.5	20.040000915527344	20.100000381469727	2147052
2020-02-19	20.239999771118164	20.239999771118164	19.809999465942383	20.020000457763672	3087194
2020-02-20	19.93000030517578	20.239999771118164	19.610000610351562	19.690000534057617	4692227
2020-02-21	19.579999923706055	20.020000457763672	19.360000610351562	19.8799991607666	2816666

4.1. Veri Ön İşleme

Veri ön işleme aşaması, ham verilerin modellemeye uygun hale getirilmesi için kritik bir süreçtir. Bu aşama, verilerin temizlenmesi, normalize edilmesi ve modelin girişine uygun formatta yeniden şekillendirilmesi işlemlerini içerir. İlk olarak, ham verilerde eksik veya hatalı kayıtlar tespit edilmiştir. Eksik veriler, modelin doğruluğunu ve performansını artırmak amacıyla, ilgili özelliklerin ortalama değerleri kullanılarak doldurulmuştur (Khan ve ark., 2023). Ayrıca, interpolasyon yöntemleri kullanılarak eksik veri noktalarının tahmin edilmesi sağlanmıştır (Shahi ve ark., 2020). Bu işlem, verilerin tam ve model için uygun hale getirilmesini sağlamaktadır.

Verilerin normalize edilmesi, modelin daha hızlı ve etkili bir şekilde öğrenmesini sağlamak açısından oldukça önemlidir. Bu çalışmada, tüm özellikler MinMaxScaler kullanılarak 0 ile 1 arasına ölçeklendirilmiştir. MinMaxScaler, verilerin aynı ölçek aralığında olmasını sağlayarak modelin öğrenme sürecini optimize eder (Yang ve Wang, 2019). Ölçeklendirme işlemi Denklem 1'de gösterildiği gibi yapılmıştır:

$$X_i = \frac{X - X_{\min}}{X_{\max} - X_{\min}} \quad (1)$$

Verilerin modellemeye önce belirli bir zaman adımı (time step) kullanılarak yeniden şekillendirilmesi gerekmektedir. Bu çalışmada, 50 günlük bir zaman adımı kullanılmıştır. Zaman adımı, modelin geçmiş verilere dayanarak gelecekteki fiyatları tahmin etmesine olanak tanır. 50 günlük veri kullanılarak, 51. günün fiyatı tahmin edilir. Her bir zaman sekansı için Denklem 2'de gösterildiği gibi giriş (X) ve çıkış (Y) setleri oluşturulmuştur:

$$X_t = [X_{t-50}, X_{t-49}, \dots, X_{t-1}] Y_t = X_t \quad (2)$$


Denklem 2'de, X_t zaman adımı t 'deki girdi verilerini, Y_t ise modelin tahmin etmeye çalıştığı fiyatı temsil eder. Bu yöntemde model, geçmiş 50 günlük verilerden öğrenerek 51. günün fiyatını tahmin etmeyi öğrenir (Khan ve ark., 2023).

Veri seti, eğitim ve test setlerine ayrılmıştır. Genellikle veri setinin %80'i eğitim, %20'si ise test için kullanılır. Bu yöntem, modelin öğrenme sürecinde ve gelecekteki veriler üzerinde nasıl performans göstereceğini değerlendirmek için gereklidir (Pinapatruni ve ark., 2023).

Veri ön işleme adımları, modelin eğitime ve performans değerlendirmesine temel oluşturur. Bu süreçler, hisse senedi fiyat tahminlerinde doğruluğun ve güvenilirliğin artırılması için kritik öneme sahiptir (Shahi ve ark., 2020).

4.2.LSTM-GRU Hibrit Modelinin Geliştirilmesi

Bu çalışmada, hisse senedi fiyat tahminlerinde daha yüksek doğruluk elde etmek amacıyla LSTM (Uzun Kısa Süreli Bellek) ve GRU (Gated Recurrent Unit) modellerini birleştiren bir hibrit model geliştirilmiştir. LSTM ve GRU'nun birleşik kullanımı, finansal zaman serisi verilerinin ardışık yapısını daha iyi öğrenerek fiyat dalgalanmalarını daha isabetli şekilde öngörebilmek için ideal bir yöntem sunmaktadır. Bu hibrit modelin geliştirilme süreci, mimari tasarım ve modelleme aşamalarını kapsamaktadır. Hibrit model, LSTM'nin uzun dönem bağıntılarını öğrenme yeteneği ile GRU'nun daha hesaplamalı olarak verimli yapısını birleştirerek güçlü bir tahmin modeli oluşturur (Khan ve ark., 2023; Pinapatruni ve ark., 2023). Modelin mimarisi Şekil 1'de gösterilmiştir.



Şekil 1. LSTM-GRU Model Gelişim Süreci

Modelin mimarisi, LSTM ve GRU katmanlarının güçlü yönlerini birleştirerek daha isabetli tahminler yapmayı amaçlamaktadır. İlk olarak, modelin giriş katmanı belirli bir zaman adımıdaki (50 gün) verileri kabul eder. Giriş katmanının ardından, LSTM katmanları kullanılarak ardışık verilerin zaman serisi yapısı öğrenilir. LSTM katmanları, uzun dönem bağıntıları öğrenmek için idealdir ve bu katmanlar ardışık veri bağıntılarını iyi yakalar (Shahi ve ark., 2020). İkinci aşamada, GRU katmanları eklenir ve bu katmanlar modelin öğrenme sürecini hızlandırarak daha az hesaplama maliyeti ile zaman serisi ilişkilerini öğrenir.

Son olarak, LSTM ve GRU katmanlarından elde edilen çıktılar birleştirilir ve tamamen bağlantılı (fully connected) katmanlar üzerinden nihai tahminler yapılır. Hibrit modelin bu yapısı, LSTM'nin uzun dönem hafızası ile GRU'nun daha hızlı hesaplama yeteneğini optimize eder.

Modelin Aşamaları:

Giriş Katmanı: Modelin giriş katmanı, 50 günlük zaman adımlarındaki fiyat ve işlem hacmi gibi beş temel özelliği kabul eder.

LSTM Katmanları: İki adet LSTM katmanı, ardışık verilerin özelliklerini öğrenir. Dropout katmanları, aşırı öğrenmeyi (overfitting) önlemek için LSTM katmanlarının ardından yerleştirilmiştir (Yang ve Wang, 2019).

GRU Katmanları: İki adet GRU katmanı, zaman serisi ilişkilerini daha hesaplamalı olarak verimli bir şekilde öğrenir. Dropout katmanları burada da kullanılarak modelin genelleme yeteneği artırılır.

Birleştirme Katmanı: LSTM ve GRU katmanlarından elde edilen çıktılar, birleştirilerek tamamen bağlantılı katmanlara aktarılır.

Tam Bağlantılı Katmanlar: Son aşamada, birleştirilmiş katmanlardan elde edilen veriler tam bağlantılı katmanlardan geçirilir. İlk tam bağlantılı katman, 50 nörondan oluşur ve ardından ReLU aktivasyon fonksiyonu kullanılır. Son katman ise tek bir nöron içerir ve hisse senedi fiyat tahminini yapar (Pinapatruni ve ark., 2023).

Modelin hiperparametreleri, katman sayısı, nöron sayısı ve dropout oranı gibi parametreler optimize edilmiştir. Hibrit modelin bu yapısı, verilerin zaman serisi doğasını dikkate alarak gelecekteki fiyatları daha yüksek doğrulukla tahmin etmek için tasarlanmıştır. Bu model, hisse senedi piyasasındaki dalgalanmaları ve trendleri yakalamada oldukça etkili bir araçtır.

4.3. LSTM-CNN Hibrit Modelinin Geliştirilmesi

Bu çalışmada, hisse senedi fiyat tahmininde daha yüksek doğruluk elde etmek amacıyla LSTM (Uzun Kısa Süreli Bellek) ve CNN (Convolutional Neural Network) modellerini birleştiren bir hibrit model tasarlanmıştır. Hibrit model, LSTM'nin zaman serisi verilerinin ardışık ilişkilerini öğrenme yeteneği ile CNN'nin uzaysal özellikleri çıkarma kabiliyetini birleştirerek, hem zaman serisi hem de uzaysal ilişkileri öğrenmeyi amaçlamaktadır (Khan ve ark., 2023). Bu birleşik yaklaşım, finansal verilerin daha derin yapısal ilişkilerini öğrenme ve daha doğru tahminler yapma imkanı sağlar (Zhang ve ark., 2020). Modelin mimarisi Şekil 2'de gösterilmiştir.



Şekil 2. LSTM-CNN Model Gelişim Süreci

Model Mimarisi:

Giriş Katmanı: Modelin giriş katmanı, 50 günlük bir zaman adımı ve 5 farklı özelliği içeren (açılış, kapanış, en yüksek, en düşük fiyatlar ve işlem hacmi) verileri kabul eder. Bu veri, hem zaman serisi özelliklerinin hem de uzaysal kalıpların işlenmesine olanak sağlar (Pinapatruni ve ark., 2023).

LSTM Katmanları: İlk olarak, iki adet LSTM katmanı zaman serisi verilerinin uzun dönem bağıntılarını öğrenir. LSTM katmanları, özellikle zaman serisi verilerindeki ardışık ilişkileri modellemek için idealdir. Her LSTM katmanının ardından, modelin aşırı öğrenmesini (overfitting) önlemek için dropout katmanları eklenmiştir (Shahi ve ark., 2020).

CNN Katmanları: LSTM katmanlarından gelen çıktılar, CNN katmanları tarafından işlenir. CNN, finansal verilerin yerel kalıplarını ve uzaysal ilişkilerini öğrenmek için kullanılır. CNN katmanları, evrişim işlemi (convolution) yaparak verinin uzaysal özelliklerini çıkarır. Max-pooling katmanları ile verilerin boyutları küçültülerek, modelin öğrenmesi için en önemli özellikler vurgulanır (Yang ve Wang, 2019).

Birleştirme Katmanı: LSTM ve CNN katmanlarından gelen çıktılar birleştirilir. Bu katman, her iki modelin güçlü yönlerini birleştirerek daha kapsamlı bir veri işleme sağlar. Birleştirilen veri, modelin daha güçlü tahminler yapmasına olanak tanır (Khan ve ark., 2023).

Tam Bağlantılı Katmanlar: Son aşamada, birleştirilmiş veriler tam bağlantılı katmanlardan geçirilir. İlk tam bağlantılı katmanda 50 nöron bulunur ve ReLU aktivasyon fonksiyonu kullanılır. Son katmanda ise tek bir nöron yer alır ve bu nöron hisse senedi fiyat tahminini üretir. Dropout katmanları bu aşamada da kullanılarak modelin genelleme yeteneği artırılır.

Hiperparametre Optimizasyonu: Modelin geliştirilmesi sürecinde katman sayısı, nöron sayısı, dropout oranı ve CNN katmanlarının filtre boyutları gibi hiperparametreler dikkatle optimize edilmiştir. Modelin derin yapısı, hem LSTM hem de CNN katmanlarının avantajlarını birleştirerek hisse senedi fiyat tahminlerinde daha yüksek doğruluk ve güvenilirlik sağlamayı amaçlamaktadır (Shahi ve ark., 2020). Bu hibrit model, hem geçmiş verilerin zaman serisi özelliklerini öğrenmekte hem de bu verilerin uzaysal ilişkilerini çıkararak daha kapsamlı tahminler yapmaktadır. Bu sayede model, hisse senedi piyasasındaki dalgalanmaları ve trendleri daha isabetli bir şekilde tahmin edebilmektedir.

4.4. LSTM-AUTOENCODER Hibrit Modelinin Geliştirilmesi

Bu çalışmada, hisse senedi fiyat tahminlerinde daha yüksek doğruluk ve verimlilik sağlamak amacıyla LSTM (Uzun Kısa Süreli Bellek) ve Autoencoder modellerini birleştiren bir hibrit model geliştirilmiştir. LSTM, zaman serisi verilerindeki uzun vadeli bağıntıları öğrenme yeteneği ile öne çıkarken, Autoencoder, verilerin sıkıştırılması ve yeniden oluşturulması için etkili bir araçtır (Zhang ve ark., 2020; Singh ve ark., 2021). Bu iki modelin birleşimi, hem zaman serisi hem de verilerin sıkıştırılmış yapısal özelliklerini dikkate alarak tahmin doğruluğunu artırmayı hedefler. Modelin mimarisi Şekil 3'te gösterilmiştir.



Şekil 3. LSTM-AUTOENCODER Model Gelişim Süreci

Model Mimarisi:

Giriş Katmanı: Modelin giriş katmanı, 50 günlük bir zaman adımında 5 farklı özellik (açılış, kapanış, en yüksek, en düşük fiyatlar ve işlem hacmi) içeren verileri kabul eder. Bu katman, verilerin modele uygun formatta girmesini sağlar (Khan ve ark., 2023).

LSTM Katmanları: İki adet LSTM katmanı, zaman serisi verilerindeki uzun vadeli bağıntıları öğrenmek amacıyla kullanılır. İlk katman verilerin ardışık ilişkilerini öğrenirken, ikinci katman daha derin özellikleri çıkarmaya yöneliktir. Her iki katmandan sonra, aşırı öğrenmeyi (overfitting) önlemek için dropout katmanları eklenmiştir (Shahi ve ark., 2020).

Encoder Katmanı: LSTM katmanlarından elde edilen veriler, Autoencoder yapısının encoder kısmı tarafından işlenir. Encoder, veriyi sıkıştırarak önemli özellikleri çıkarır ve veriyi daha kompakt hale getirir. Bu işlem, verinin boyutunu küçülterek daha verimli işlenmesini sağlar (Zhang ve ark., 2020).

Decoder Katmanı: Encoder tarafından sıkıştırılan veriler, decoder katmanında yeniden oluşturulur. Bu işlem, verinin orijinal boyutlarına dönüştürülmesi sürecidir ve verinin temel özelliklerinin korunmasını sağlar. Gereksiz bilginin elimine edilmesi, modelin daha etkili tahminler yapmasına katkıda bulunur (Singh ve ark., 2021).

Birleştirme Katmanı: LSTM ve Autoencoder katmanlarından elde edilen çıktılar, birleştirilerek daha kapsamlı veri işleme sağlar. Bu katman, iki farklı modelin güçlü yönlerini bir araya getirerek nihai tahminler öncesinde verilerin işlenmesini tamamlar (Pinapatruni ve ark., 2023).

Tam Bağlantılı Katmanlar: Birleştirilmiş veriler, tam bağlantılı katmanlar üzerinden nihai tahmin yapılmadan önce işlenir. İlk tam bağlantılı katman, 50 nörondan oluşur ve ReLU aktivasyon fonksiyonu kullanılır. Son katman ise tek bir nöron içerir ve bu nöron hisse senedi fiyat tahminini üretir (Yang ve Wang, 2019).

Hiperparametre Optimizasyonu: Modelin geliştirilmesi sırasında katman sayısı, nöron sayısı, dropout oranı ve Autoencoder katmanlarının boyutları gibi hiperparametreler optimize edilmiştir. Bu hibrit model, hem LSTM'nin zaman serisi öğrenme kapasitesi hem de Autoencoder'ın verileri sıkıştırarak önemli bilgileri çıkartma yeteneğini birleştirerek daha yüksek doğruluk sağlar (Khan ve ark., 2023).

Bu hibrit model, finansal zaman serilerindeki karmaşık yapısal ilişkileri öğrenmek ve piyasalardaki dalgalanmaları tahmin etmek amacıyla geliştirilmiştir. LSTM-Autoencoder hibrit modeli, hisse senedi piyasalarındaki trendleri ve ani fiyat hareketlerini yakalamada etkili bir araç olarak tasarlanmıştır (Zhang ve ark., 2020).

4.5. LSTM-TRANSFORMER Hibrit Modelinin Geliştirilmesi

Bu çalışmada, hisse senedi fiyat tahmininde daha yüksek doğruluk ve verimlilik elde etmek amacıyla LSTM (Uzun Kısa Süreli Bellek) ve Transformer modellerini birleştiren bir hibrit model geliştirilmiştir. LSTM, zaman serisi verilerindeki uzun vadeli bağıntıları öğrenirken, Transformer modeli, dikkat (attention) mekanizması sayesinde önemli kısımları öğrenir ve tahmin yapar. Bu iki modelin birleşimi, finansal verilerdeki karmaşık ilişkilerin daha iyi öğrenilmesini sağlayarak tahmin doğruluğunu artırmayı amaçlar (Vaswani ve ark., 2017; Zhou ve ark., 2021). Modelin mimarisi Şekil 4'te gösterilmiştir.



Şekil 4. LSTM-TRANSFORMER Model Gelişim Süreci

Model Mimarisi:

Giriş Katmanı: Modelin giriş katmanı, 50 günlük bir zaman adımında 5 farklı özellik (açılış, kapanış, en yüksek, en düşük fiyatlar ve işlem hacmi) içeren verileri kabul eder. Bu katman, verilerin modele uygun formatta girmesini sağlar (Khan ve ark., 2023).

LSTM Katmanları: İki adet LSTM katmanı, zaman serisi verilerindeki uzun vadeli bağıntıları öğrenmek için kullanılır. Bu katmanlar, verilerin ardışık ilişkilerini modelleyerek gelecekteki fiyat tahminini iyileştirir. Her LSTM katmanından sonra, aşırı öğrenmeyi (overfitting) önlemek için dropout katmanları eklenmiştir (Shahi ve ark., 2020).

Transformer Katmanları: LSTM katmanlarından gelen çıktılar, Transformer modelinin dikkat mekanizması ile işlenir. Transformer modeli, çok başlı dikkat (multi-head attention) mekanizması ile verilerin önemli kısımlarını öğrenir. Bu mekanizma, verinin farklı bölümlerini paralel olarak analiz ederek zaman serisi verilerindeki karmaşık bağıntıları keşfeder (Vaswani ve ark., 2017; Zhou ve ark., 2021).

Birleştirme Katmanı: LSTM ve Transformer katmanlarından elde edilen çıktılar birleştirilir. Bu katman, her iki modelin güçlü yönlerini bir araya getirerek daha kapsamlı veri işleme sağlar.


Tam Bağlantılı Katmanlar: Birleştirilmiş veriler, tam bağlantılı katmanlardan geçirilir. İlk tam bağlantılı katman 50 nörondan oluşur ve ReLU aktivasyon fonksiyonu kullanılır. Son katman, tek bir nöron içerir ve hisse senedi fiyat tahminini yapar.

Hiperparametre Optimizasyonu:

Modelin geliştirilmesi sürecinde, katman sayısı, nöron sayısı, dropout oranı ve Transformer katmanlarının başlık sayısı gibi hiperparametreler optimize edilmiştir. LSTM'nin uzun vadeli bağıntıları öğrenme yeteneği ile Transformer'ın dikkat mekanizması, finansal zaman serisi verilerinin daha iyi analiz edilmesini sağlar. Bu hibrit model, hisse senedi piyasasındaki dalgalanmaları ve trendleri daha iyi yakalamak için geliştirilmiştir (Zhou ve ark., 2021).

4.6. Modellerin Eğitimi ve Testi

Bu bölümde, geliştirilen LSTM ve GRU hibrit modelinin eğitimi ve test edilmesi süreci detaylı olarak açıklanmaktadır. Modelin performansı, eğitim sırasında kullanılan veri setleri ve test aşamasında kullanılan bağımsız veri setleri üzerinde değerlendirilmektedir. Eğitim sürecinde veriler belirli bir zaman adımı (50 gün) kullanılarak yeniden şekillendirilmiş ve MinMaxScaler normalizasyon yöntemi uygulanmıştır. Hiperparametreler dikkatle seçilerek modelin öğrenme süreci optimize edilmiştir. Test aşamasında ise modelin genelleme yeteneği ve tahmin doğruluğu, bağımsız bir veri seti ile ölçülmüştür. Modelin tahmin performansı, RMSE, MAE, MAPE, R² ve MSE gibi metriklerle değerlendirilmiştir (Khan ve ark., 2023; Shahi ve ark., 2020). Şekil 5'te modellerin eğitim ve test süreçleri gösterilmiştir.



Şekil 5. Modellerin Eğitim ve Test Süreci

4.7. Modellerin Eğitim Süreci

Bu çalışmada, hisse senedi fiyat tahminleri için LSTM-GRU, LSTM-AUTOENCODER, LSTM-TRANSFORMER ve LSTM-CNN modelleri olmak üzere dört farklı hibrit model kullanılmıştır. Her bir modelin eğitimi, Adam optimizasyon algoritması kullanılarak gerçekleştirilmiş ve kayıp fonksiyonu olarak

'mean squared error' (MSE) tercih edilmiştir. Model performansını izlemek ve overfitting'i önlemek amacıyla doğrulama veri seti kullanılmıştır.

Veri Setinin Hazırlanması: Daha önce açıklanan veri ön işleme adımlarından geçirilen veriler, eğitim ve doğrulama setlerine ayrılmıştır. Eğitim seti, veri setinin %80'ini, doğrulama seti ise %20'sini içermektedir. Bu ayırım, modelin genelleme yeteneğini ve gerçek dünya verileri üzerindeki performansını değerlendirmek amacıyla yapılmıştır.

Modelin Derlenmesi: Her bir model, Adam optimizasyon algoritması ve MSE kayıp fonksiyonu ile derlenmiştir. Adam optimizasyon algoritması, öğrenme hızını dinamik olarak ayarlayarak modelin daha hızlı ve etkili bir şekilde öğrenmesini sağlamaktadır. LSTM-GRU, LSTM-AUTOENCODER, LSTM-TRANSFORMER ve LSTM-CNN modelleri, her biri kendi yapısal özelliklerine göre optimize edilmiştir. Bu modellerin derlenmesi, hesaplama verimliliği ve doğruluğu artırmak için dikkatlice yapılandırılmıştır.

Modelin Eğitimi: Her bir model, belirli bir epoch sayısı boyunca (100 epoch) eğitim verileri üzerinde eğitilmiştir. Eğitim süreci boyunca batch size 64 olarak belirlenmiş ve her epoch sonunda modelin doğrulama veri seti üzerindeki performansı izlenmiştir. Eğitim sırasında her epoch sonunda eğitim ve doğrulama kayıpları kaydedilmiştir. Bu süreç, modelin overfitting yapıp yapmadığını belirlemek ve genel performansını değerlendirmek amacıyla gerçekleştirilmiştir.

Eğitim tamamlandıktan sonra, modellerin nihai performansı test veri seti üzerinde değerlendirilmiştir. Bu test süreci, modellerin bilinmeyen verilere karşı genelleme yeteneğini ve gerçek dünya senaryolarındaki başarısını ölçmek için yapılmıştır. Performans metrikleri (RMSE, MAE, MAPE, R^2 ve MSE) kullanılarak her bir modelin tahmin doğruluğu ve hata oranları hesaplanmıştır. Bu metrikler, modellerin güçlü ve zayıf yönlerini belirlemek ve genel performanslarını değerlendirmek için kullanılmıştır. Modellerin performanslarının değerlendirilmesi, yatırım kararlarında güvenilir tahminler yapabilme potansiyelini ortaya koymaktadır.

4.8. Modellerin Test Süreci

Modellerin test edilmesi, eğitilmiş modelin bilinmeyen verilere karşı performansını değerlendirmek amacıyla gerçekleştirilmiştir. Bu süreçte kullanılan test veri seti, modelin genelleme yeteneğini ve gerçek dünya senaryolarındaki başarısını ölçmek için kritik bir öneme sahiptir. Test sürecinde, modelin daha önce görmediği veriler üzerindeki tahmin yeteneği değerlendirilmektedir. Bu sayede, modelin gerçek dünya uygulamaları için ne kadar etkili olabileceği belirlenmiştir. Test veri seti, eğitim sırasında kullanılmayan ve modelin öğrenme sürecine dahil edilmeyen verilerden oluşmaktadır. Test sürecinde, modelin tahmin ettiği değerler ile gerçek değerler karşılaştırılarak performans metrikleri (RMSE, MAE, MAPE, R^2 ve MSE) hesaplanmıştır. RMSE (Root Mean Squared Error), modelin tahmin hatalarının büyüklüğünü ölçerken, MAE (Mean Absolute Error), ortalama mutlak hatayı belirtir. MAPE (Mean Absolute Percentage Error), tahmin hatalarının yüzdesel büyüklüğünü gösterir ve R^2 (R-squared) modeli açıklama gücünü ifade eder. MSE (Mean Squared Error) ise hata karelerinin ortalamasını sunar. Bu metrikler, modelin tahmin doğruluğunu ve güvenilirliğini değerlendirmek için kullanılmaktadır. Performans metrikleri, modelin güçlü ve zayıf yönlerini belirlemede önemli rol oynamaktadır. Test sonuçları, modelin gerçek dünya senaryolarında nasıl performans göstereceği hakkında değerli bilgiler sağlamaktadır. Bu sonuçlar, modelin finansal zaman serisi verileri üzerindeki etkinliğini doğrulamakta ve modelin yatırım kararları için güvenilir bir araç olarak kullanılabilirliğini ortaya koymaktadır. Ayrıca, test sürecinde elde edilen bulgular, modelin iyileştirilmesi gereken alanları belirlemeye yardımcı olmaktadır. Sonuç olarak, modelin test edilmesi, modelin genel performansını ve potansiyel uygulamalarını kapsamlı bir şekilde değerlendirmek için kritik bir adımdır (Sim ve ark., 2019; Chen ve ark., 2021; Hsieh ve ark., 2011; Rather ve ark., 2015).

Test Verilerinin Hazırlanması: Test veri seti, eğitim sürecinde kullanılmayan %20'lik veri setinden oluşmaktadır. Test verileri, eğitim verileri ile aynı ön işleme adımlarından geçirilmiştir. Bu adımlar, verilerin tutarlı ve karşılaştırılabilir olmasını sağlamak için önemlidir.

Tahminlerin Yapılması: Eğitilmiş model, test veri seti üzerinde tahminler yapmıştır. Tahminler, modelin gelecekteki hisse senedi fiyatlarını ne kadar doğru bir şekilde öngörebildiğini belirlemek için kullanılmıştır. Modelin tahmin yeteneği, finansal analiz ve yatırım kararları için büyük bir öneme sahiptir.

Sonuçların Değerlendirilmesi: Modelin performansı, test veri seti üzerinde RMSE (Root Mean Squared Error), MAE (Mean Absolute Error), MSE (Mean Squared Error), R^2 (R-Squared), ve MAPE (Mean Absolute Percentage Error) metrikleri kullanılarak değerlendirilmiştir. Bu metrikler, modelin tahmin hatalarının büyüklüğünü ve genel başarısını ölçmek için kullanılmıştır. RMSE ve MAE, modelin tahminlerinin ne kadar doğru olduğunu ve hata oranlarının büyüklüğünü gösterirken, MAPE, tahmin hatalarının yüzdesel büyüklüğünü belirler. R^2 , modelin veri setindeki değişkenliği ne kadar iyi açıkladığını gösterir ve MSE, hata karelerinin ortalamasını verir. Bu metrikler, modelin performansını objektif bir şekilde değerlendirmek ve karşılaştırmak için kritik öneme sahiptir.

RMSE (Root Mean Squared Error): RMSE, modelin tahmin ettiği değerler ile gerçek değerler arasındaki farkın karesinin ortalamasının kareköküdür. Bu metrik, tahmin hatalarının büyüklüğünü ölçerek modelin performansını değerlendirir. Düşük RMSE değerleri, modelin tahminlerinin gerçek değerlere daha yakın olduğunu gösterir ve bu da modelin yüksek doğrulukta tahminler yapabildiğini ifade eder (Sim ve ark., 2019; Chen ve ark., 2021; Hsieh ve ark., 2011; Rather ve ark., 2015). RMSE hesaplanması Denklem 3’de gösterilmiştir.

$$RMSE(y, \hat{y}) = \sqrt{\frac{\sum_{i=0}^{N-1} (y_i - \hat{y}_i)^2}{N}} \quad (3)$$

Denklem 3’de bulunan y_i , gerçek değerleri, $\hat{y}_i$ ise tahmin edilen değerleri temsil etmekte olup, N ise toplam veri sayısını göstermektedir.

MAE (Mean Absolute Error): MAE, modelin tahmin ettiği değerler ile gerçek değerler arasındaki mutlak farkların ortalamasını ifade etmektedir. Bu metrik, tahmin hatalarının büyüklüğünü ölçmek için kullanılmakta olup, düşük MAE değerleri modelin tahminlerinin gerçek değerlere yakın olduğunu göstermektedir. MAE, tahmin doğruluğunu değerlendirmek için basit ve anlaşılır bir yöntemdir (Sim ve ark., 2019; Chen ve ark., 2021). MAE hesaplanması Denklem 4’de gösterilmiştir.

$$MAE(y, \hat{y}) = \frac{\sum_{i=0}^{N-1} |y_i - \hat{y}_i|}{N} \quad (4)$$

Denklem 4’de bulunan y_i , gerçek değerleri, $\hat{y}_i$ ise tahmin edilen değerleri temsil etmekte olup, N ise toplam veri sayısını göstermektedir.

MSE (Mean Squared Error): MSE, modelin tahmin ettiği değerler ile gerçek değerler arasındaki farkların karesinin ortalamasını ifade eder. Bu metrik, tahmin hatalarının büyüklüğünü ölçmek ve modelin performansını değerlendirmek için kullanılır. Düşük MSE değerleri, modelin tahminlerinin gerçek değerlere daha yakın olduğunu gösterir ve bu da modelin yüksek doğrulukta tahminler yapabildiğini ifade eder (Sim ve ark., 2019; Chen ve ark., 2021). MSE hesaplanması Denklem 5’de gösterilmiştir.

$$MSE(y, \hat{y}) = \frac{\sum_{i=0}^{N-1} (y_i - \hat{y}_i)^2}{N} \quad (5)$$

Denklem 5’de bulunan y_i , gerçek değerleri, $\hat{y}_i$ ise tahmin edilen değerleri temsil etmekte olup, N ise toplam veri sayısını göstermektedir.

R^2 (R-Squared): R^2 , bir modelin veri setindeki değişkenlikleri ne kadar iyi açıkladığını ölçen bir metriktir. R^2 değeri 0 ile 1 arasında değişir ve 1’e yaklaştıkça modelin tahminlerinin doğruluğu artar. R^2 , modelin bağımsız değişkenlerle bağımlı değişken arasındaki ilişkiyi ne kadar iyi açıkladığını gösterir. Yüksek R^2 değeri, modelin veri setindeki varyansın büyük bir kısmını açıklayabildiğini ve dolayısıyla daha iyi bir tahmin performansına sahip olduğunu belirtir. (Sim ve ark., 2019; Chen ve ark., 2021). R^2 hesaplanması Denklem 6’da gösterilmiştir.

$$R_2(y, \hat{y}) = 1 - \frac{\sum_{i=0}^N (y_i - \hat{y}_i)^2}{\sum_{i=0}^N (y_i - \bar{y})^2} \quad (6)$$

Denklem 6’da bulunan y_i gerçek değerleri, $\hat{y}$ tahmin edilen değerleri, $\bar{y}$ ise gerçek değerlerin ortalamasını temsil eder. R^2 , modelin performansını değerlendirmede ve karşılaştırmada önemli bir metriktir.

MAPE (Mean Absolute Percentage Error): MAPE, modelin tahmin ettiği değerler ile gerçek değerler arasındaki mutlak farkların, gerçek değerlere oranlanarak yüzdesel olarak ifade edilmesinin ortalamasıdır. Bu metrik, tahmin hatalarının büyüklüğünü yüzdesel olarak ölçer ve düşük MAPE değerleri, modelin tahminlerinin gerçek değerlere yakın olduğunu gösterir. MAPE, modelin doğruluğunu değerlendirmek için

yaygın olarak kullanılır (Sim ve ark., 2019; Chen ve ark., 2021). MAPE hesaplanması Denklem 7’de gösterilmiştir.

$$\text{MAPE}(\hat{y}, y) = \frac{100\%}{N} \sum_{i=0}^{N-1} \frac{|y_i - \hat{y}_i|}{|y_i|} \quad (7)$$

Denklem 7’de bulunan y_i , gerçek değerleri, $\hat{y}_i$ ise tahmin edilen değerleri temsil etmekte olup, N ise toplam veri sayısını göstermektedir.

Modelin test edilmesi, eğitilmiş modelin bilinmeyen verilere karşı performansını değerlendirmek amacıyla gerçekleştirilmiştir. Bu süreçte kullanılan test veri seti, modelin genelleme yeteneğini ve gerçek dünya senaryolarındaki başarısını ölçmek için kritik bir öneme sahiptir. Modelin performansını objektif bir şekilde değerlendirmek için test süreci, eğitim sırasında kullanılmayan ve modelin hiç görmediği verilerle yürütülmüştür. Bu yaklaşım, modelin gerçek dünya uygulamalarında nasıl bir performans sergileyebileceğini anlamak için gereklidir. Test süreci boyunca, modelin tahmin ettiği değerler ile gerçek değerler karşılaştırılarak, performans metrikleri (RMSE, MAE, MAPE, R^2 ve MSE) hesaplanmıştır. RMSE (Root Mean Squared Error) ve MAE (Mean Absolute Error), modelin tahmin hatalarının büyüklüğünü ölçerken, MAPE (Mean Absolute Percentage Error) tahmin hatalarının yüzdesel büyüklüğünü gösterir. R^2 (R-squared), modelin veri setindeki değişkenliği ne kadar iyi açıkladığını belirlerken, MSE (Mean Squared Error) ise hata karelerinin ortalamasını verir. Bu metrikler, modelin tahmin doğruluğunu ve güvenilirliğini değerlendirmenin yanı sıra, modelin güçlü ve zayıf yönlerini belirlemede önemli rol oynamıştır (Sim ve ark., 2019; Chen ve ark., 2021; Hsieh ve ark., 2011; Rather ve ark., 2015). Performans metriklerinin hesaplanması, modelin çeşitli açılarından ne kadar etkili olduğunu görmemizi sağlar. Örneğin, RMSE ve MAE, modelin hata oranlarının mutlak değerlerini verirken, MAPE, bu hataların oransal büyüklüğünü belirler. R^2 , modelin açıklama gücünü gösterir ve MSE, hata karelerinin ortalamasını vererek, modelin genel performansını değerlendirir. Bu metriklerin birlikte değerlendirilmesi, modelin genel performansını kapsamlı bir şekilde anlamamıza olanak tanır. Elde edilen sonuçlar, modelin güçlü ve zayıf yönlerini belirlemek için kullanılabilir. RMSE ve MAE değerlerinin düşük olması, modelin yüksek doğrulukla tahminler yapabildiğini gösterirken, yüksek R^2 değeri, modelin veri setindeki değişkenlikleri iyi bir şekilde açıkladığını gösterir. MAPE oranlarının düşük olması, modelin tahmin hatalarının yüzdesel olarak düşük olduğunu belirtir. Bu sonuçlar, modelin yatırım kararları için güvenilir bir araç olarak kullanılabilirliğini ortaya koymaktadır. Sonuç olarak, modelin test edilmesi, modelin genel performansını ve potansiyel uygulamalarını kapsamlı bir şekilde değerlendirmek için kritik bir adımdır (Hochreiter ve Schmidhuber, 1997; Yang ve Wang, 2019; Minh ve ark., 2018).

5. Bulgular ve Tartışma


Geliştirilen LSTM-GRU hibrit modelinin hisse senedi fiyat tahminlerindeki performansı değerlendirilmektedir. Modelin başarımı RMSE, MAE, MAPE, R^2 ve MSE gibi istatistiksel ölçütler kullanılarak analiz edilmiş ve diğer hibrit modeller (LSTM-CNN, LSTM-AUTOENCODER ve LSTM-TRANSFORMER) ile karşılaştırılmıştır.

Modelin Performans Sonuçları

Modelin performansı, eğitim ve test veri setleri üzerinde yapılan tahminler sonucunda hesaplanmış olup Tablo 5’te sunulmaktadır. LSTM-GRU modeline ait tahminlerin görselleştirilmiş sonuçları ise Şekil 6’da gösterilmektedir.

Tablo 5. LSTM-GRU Modeli Performans metrikleri

Hisse Senedi Kodu	RMSE	MAE	MAPE	R2	MSE
Banka-1	0.267	0.194	1.78%	0.948	0.071
Banka-2	0.122	0.074	1.09%	0.605	0.016
Holding-1	0.637	0.371	1.62%	0.987	0.400
Şirket-1	1.353	0.795	1.96%	0.971	1.831



Şekil 6. LSTM-GRU Model Sonuç Grafikleri

Elde edilen sonuçlar, LSTM-GRU modelinin hisse senedi fiyat tahminlerinde genel olarak başarılı performans sergilediğini ortaya koymaktadır. Model, Banka-1 ve Holding-1 hisse senetleri için yüksek doğruluk sağlamış, Şirket-1 hisse senedi için ise hata oranı diğer hisse senetlerine kıyasla daha yüksek bulunmuştur. Özellikle Holding-1 hisse senedi için R^2 değeri 0.987 olup, modelin yüksek açıklayıcılığa sahip olduğunu göstermektedir.


Ancak, Şirket-1 hisse senedi için RMSE ve MAE değerlerinin yüksek olması, modelin bazı sektörlerde daha fazla hata yapabileceğine işaret etmektedir. Bu durum, finansal piyasalardaki farklı volatilité düzeylerinin modelin tahmin performansına etkisini inceleme gerekliliğini ortaya koymaktadır.

Diğer Modellerle Karşılaştırma

Geliştirilen LSTM-GRU modeli, diğer hibrit modeller olan LSTM-CNN, LSTM-AUTOENCODER ve LSTM-TRANSFORMER ile karşılaştırılmıştır. Karşılaştırma sonuçları Tablo 6’da sunulmakta olup, ilgili tahminlerin görselleştirilmiş sonuçları Şekil 7, 8 ve 9’da gösterilmektedir.

Tablo 6. LSTM-CNN Modeli Performans Metrikleri

Hisse Senedi Kodu	RMSE	MAE	MAPE	R2	MSE
Banka-1	0.3596	0.2022	1.9411	0.9702	0.0772
Banka-2	0.1461	0.0803	1.2077	0.9823	0.0213
Holding-1	0.6570	0.4017	1.7032	0.9921	0.4316
Şirket-1	1.4393	0.8340	2.0714	0.9901	2.0918




Şekil 7. LSTM-CNN Model Sonuç Grafikleri

LSTM-GRU modeli ile karşılaştırıldığında, LSTM-CNN modeli bazı metriklerde tatmin edici sonuçlar üretmiş olsa da, genel doğruluk açısından daha düşük performans göstermiştir. Özellikle RMSE ve MAE değerleri açısından LSTM-GRU modelinin üstün olduğu görülmektedir. Örneğin, Banka-1 hisse senedi için LSTM-GRU modelinin RMSE değeri 0.267 iken, LSTM-CNN modeli için bu değer 0.359 olarak hesaplanmıştır.

Benzer şekilde, LSTM-AUTOENCODER modelinin performansı incelendiğinde, modelin bazı hisse senetlerinde başarılı sonuçlar ürettiği ancak genel hata oranlarının LSTM-GRU modeline kıyasla daha yüksek olduğu görülmektedir (Tablo 7).

Tablo 7. LSTM-AUTOENCODER Modeli Performans Metrikleri

Hisse Senedi Kodu	RMSE	MAE	MAPE	R2	MSE
Banka-1	0.2792	0.2076	2.2827	0.9820	0.0779
Banka-2	0.1868	0.1339	2.1074	0.9711	0.0349
Holding-1	0.7412	0.5139	2.3296	0.9899	0.5508
Şirket-1	1.3952	0.9623	2.6860	0.9906	1.9462




Şekil 8. LSTM-AUTOENCODER Model Sonuç Grafikleri

LSTM-TRANSFORMER modeli, genel olarak diğer modellerle kıyaslandığında en düşük doğruluk oranına sahip olmuştur (Tablo 8). Özellikle R² değerlerinin düşük olması, modelin açıklayıcılığının sınırlı olduğunu göstermektedir.

Tablo 8. LSTM-TRANSFORMER Modeli Performans Metrikleri

Hisse Senedi Kodu	RMSE	MAE	MAPE	R2	MSE
Banka-1	0.9793	0.6486	6.4054	0.7791	0.9591
Banka-2	0.5563	0.3710	5.5227	0.7441	0.3095
Holding-1	2.1501	1.3558	5.4996	0.1095	4.6233
Şirket-1	3.3587	1.8368	4.4458	0.1610	5.2618



Şekil 9. LSTM-TRANSFORMER Model Sonuç Grafikleri

Elde edilen sonuçlar, LSTM-TRANSFORMER modelinin finansal zaman serisi tahminlerinde diğer modellere kıyasla daha düşük doğruluk sunduğunu göstermektedir. Bu durum, Transformer tabanlı modellerin finansal verilerde doğrusal olmayan bağıntıları yeterince yakalayamayabileceğini düşündürmektedir. LSTM-GRU modeli, diğer hibrit modellere kıyasla en düşük RMSE ve MAE değerlerine sahip olmasıyla, hisse senedi fiyat tahminlerinde daha güvenilir bir araç olarak öne çıkmaktadır.

Tablo 9. Farklı Hibrit Modellerin Performans Karşılaştırması

Model	RMSE (Düşük İyi)	MAE (Düşük İyi)	MAPE (Düşük İyi)	R ² (Yüksek İyi)
LSTM-GRU	0.267	0.194	1.78%	0.948
LSTM-CNN	0.359	0.202	1.94%	0.970
LSTM-AUTOENCODER	0.279	0.207	2.28%	0.982
LSTM-TRANSFORMER	0.979	0.648	6.40%	0.779

Sonuç olarak, LSTM-TRANSFORMER modeli, genel olarak LSTM-GRU modeline kıyasla daha yüksek hata oranlarına ve daha düşük doğruluk oranlarına sahiptir. Bu bulgular, LSTM-GRU modelinin hisse senedi fiyat tahmininde daha güvenilir ve doğru sonuçlar sunduğunu ve finansal tahminlerde daha etkili bir araç olduğunu ortaya koymaktadır. LSTM-GRU modelinin üstün performansı, yatırım kararlarında kullanılabilirliğini artırmaktadır.

6. Sonuç ve Öneriler

Bu çalışma, LSTM ve GRU modellerini birleştirerek hisse senedi fiyat tahminlerinde doğruluğu artırmayı amaçlayan bir hibrit model geliştirmiş ve bu modelin diğer hibrit modellerle (LSTM-CNN, LSTM-AUTOENCODER, LSTM-TRANSFORMER) karşılaştırmasını yapmıştır. Çalışma kapsamında Türkiye borsasında işlem gören dört farklı hisse senedi üzerinde deneyler gerçekleştirilmiş ve modelin başarıımı değerlendirilmiştir.

Elde edilen sonuçlar, LSTM-GRU hibrit modelinin diğer hibrit modellere kıyasla daha düşük hata oranlarına ve daha yüksek tahmin doğruluğuna sahip olduğunu göstermektedir. Modelin özellikle Banka-1 ve Holding-1 hisse senetlerinde başarılı tahminler yaptığı, ancak bazı sektörlerde (örneğin Şirket-1 hisse senedi) hata oranlarının diğer hisse senetlerine kıyasla daha yüksek olduğu gözlemlenmiştir.

Çalışmada kullanılan modellerin performans karşılaştırmaları incelendiğinde, LSTM-TRANSFORMER modelinin diğer modellere kıyasla daha düşük doğruluk oranlarına sahip olduğu tespit edilmiştir ($R^2 = 0.779$). Bu bulgu, transformer tabanlı modellerin finansal zaman serisi tahminlerindeki etkinliğinin sınırlı

olabileceğini göstermektedir. Buna karşın, LSTM-GRU modeli, uzun vadeli bağıntıları yakalama kapasitesi ve düşük hesaplama maliyeti ile finansal tahminler açısından güçlü bir alternatif olarak öne çıkmaktadır.

Öneriler ve Gelecek Çalışmalar İçin Yönelimler

Bu çalışmanın bulguları doğrultusunda aşağıdaki öneriler sunulmaktadır:

Farklı Piyasa Koşullarında Modelin Test Edilmesi

LSTM-GRU modeli, Türkiye borsasına ait hisse senedi verileri üzerinde test edilmiştir. Modelin farklı finansal piyasalarda ve değişen ekonomik koşullarda nasıl performans gösterdiğini değerlendirmek amacıyla, uluslararası borsalar, döviz piyasaları ve emtia fiyatları gibi farklı veri setleri üzerinde test edilmesi önerilmektedir.

Hiperparametre Optimizasyonu ile Modelin Geliştirilmesi

Modelin başarımını artırmak için grid search, Bayesian optimization veya genetik algoritmalar gibi hiperparametre optimizasyon yöntemlerinin uygulanması faydalı olacaktır. Bu tür optimizasyon teknikleri, modelin öğrenme hızı, katman sayısı ve nöron sayısı gibi hiperparametrelerinin en uygun değerlerle belirlenmesine yardımcı olabilir.

Gerçek Zamanlı Veri ile Uygulanabilirliğin Araştırılması

Modelin finansal piyasalarda gerçek zamanlı olarak uygulanabilirliği test edilmemiştir. Modelin gerçek zamanlı veri akışlarını işleyip işleyemediğini test etmek ve tahmin performansını değerlendirmek önemli bir araştırma alanı olarak öne çıkmaktadır.

Ekonomik ve Politik Faktörlerin Modele Dahil Edilmesi

Çalışmada yalnızca hisse senedi fiyatları ve işlem hacmi gibi teknik göstergeler kullanılmıştır. Makroekonomik değişkenlerin (enflasyon, faiz oranları, jeopolitik riskler) ve haber analizlerinin modele entegre edilerek tahmin başarımının nasıl değiştiğinin araştırılması önerilmektedir.

Farklı Derin Öğrenme Mimari Modelleri ile Karşılaştırmalar

Çalışmada yalnızca belirli hibrit modeller incelenmiştir. BERT, GPT ve TCN (Temporal Convolutional Network) gibi derin öğrenme modellerinin zaman serisi tahminlerindeki performanslarının LSTM-GRU modeli ile karşılaştırılması gelecek çalışmalar için önemli bir katkı sağlayabilir.

Sonuç olarak bu çalışma, hisse senedi fiyat tahmininde LSTM-GRU hibrit modelinin üstünlüğünü ortaya koymuş ve modelin finansal zaman serisi verilerinde başarılı sonuçlar sunduğunu göstermiştir. Önerilen geliştirmeler ile modelin genelleme yeteneği artırılarak daha geniş çapta uygulanabilirliği sağlanabilir. Bu bağlamda, derin öğrenme yöntemlerinin finansal karar destek sistemlerinde nasıl daha etkin kullanılabileceğine yönelik araştırmaların artırılması gerekmektedir.

Kaynakça

- Bukhari, A.H., Raja, M.A.Z., Sulaiman, M., Islam, S., Shoaib, M., & Kumam, P. (2020). Fractional neuro-sequential ARFIMA-LSTM for financial market forecasting. *IEEE Access*, 8, 71326-71338. <https://doi.org/10.1109/ACCESS.2020.2988238>
- Chandra, R., & He, Y. (2021). *Bayesian Neural Networks for Stock Price Forecasting*. SpringerLink.
- Chen, W., Jiang, M.R., Zhang, W.G., & Chen, Z.S. (2021). A novel graph convolutional feature-based convolutional neural network for stock trend prediction. *Information Sciences*, 556, 67-94. <https://doi.org/10.1016/j.ins.2020.08.025>
- Guo, Q., Lei, S., Ye, Q., & Fang, Z. (2021). MRC-LSTM: A hybrid approach of multi-scale residual CNN and LSTM to predict bitcoin price. In *Proceedings of the International Joint Conference on Neural Networks* (pp. 1-8). IEEE. <https://doi.org/10.1109/IJCNN.2021.9505956>
- Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural Computation*, 9, 1735-1780. <https://doi.org/10.1162/neco.1997.9.8.1735>
- Hossain, M.A., Karim, R., Thulasiram, R., Bruce, N.D.B., & Wang, Y. (2018). Hybrid deep learning model for stock price prediction. In *Symposium Series on Computational Intelligence (SSCI)*, IEEE, Bangalore, India, 1837-1844. <https://doi.org/10.1109/SSCI.2018.8628641>
- Hsieh, T.J., Hsiao, H.F., & Yeh, W.C. (2011). Forecasting stock markets using wavelet transforms and recurrent neural networks: An integrated system based on artificial bee colony algorithm. *Applied Soft Computing*, 11, 2510-2525. <https://doi.org/10.1016/j.asoc.2010.10.003>
- Jiang, Q., Wang, S., & Zhang, Z. (2017). An intelligent stock trading decision support system through integration of genetic algorithm-based fuzzy neural network and artificial neural network. In *IEEE International Conference on Big Data*, 2823-2824. <https://doi.org/10.1109/BigData.2017.8258296>
- Karim, M. E., Foysal, M., & Das, S. (2022, November). Stock price prediction using Bi-LSTM and GRU-based hybrid deep learning approach. In *Proceedings of Third Doctoral Symposium on Computational Intelligence: DoSCI 2022* (pp. 701-711). Singapore: Springer Nature Singapore.
- Khan, D. M., Alshanbari, H. M., & El-Bagoury, A. H. (2023). Prediction of complex stock market data using an improved hybrid EMD-LSTM model. *Applied Sciences*, 13(3), 1429. <https://doi.org/10.3390/app13031429>
- Livieris, I.E., Kiriakidou, N., Stavroyiannis, S., & Pintelas, P. (2021). An advanced CNN-LSTM model for cryptocurrency forecasting. *Electronics*, 10(3), 287. <https://doi.org/10.3390/electronics10030287>
- Luca, D.P., & Oleksandr, H. (2016). Artificial neural networks architectures for stock price prediction: Comparisons and applications. *International Journal of Circuits, Systems, and Signal Processing*, 10, 403-413.
- Mehtab, S., Sen, J., & Dutta, A. (2020). Stock price prediction using LSTM-based deep learning models. *arXiv*. <https://doi.org/10.48550/arXiv.2207.06605>
- Minh, D.L., Sadeghi-Niaraki, A., Huy, H.D., Min, K., & Moon, H. (2018). Deep learning approach for short-term stock trends prediction based on two-stream gated recurrent unit network. *IEEE Access*, 6, 55392-55404. <https://doi.org/10.1109/ACCESS.2018.2871439>
- Mohanty, S., Vijay, A., & Gopakumar, N. (2022). Stockbot: Using LSTMs to predict stock prices. *arXiv preprint*, <https://doi.org/10.48550/arXiv.2207.06605>
- Pardeshi, K., Singh, S. S., & Gill, S. S. (2023). Stock market price prediction: A hybrid LSTM and sequential self-attention based approach. *arXiv*. <https://doi.org/10.48550/arXiv.2308.04419>
- Pinapatruni, R., Mohammed, F., Mohiuddin, S. A., & Patel, D. (2023). A hybrid model for forecasting stock prices using Bayesian and LSTM. SpringerLink.

- Qin, Y.S., Song, D.J., Cheng, H.F., Jiang, G.F., & Cottrell, G.W. (2017). A dual-stage attention-based recurrent neural network for time series prediction. In Proceedings of the 26th International Joint Conference on Artificial Intelligence (IJCAI), Melbourne, Australia, 2627-2633.
- Qiu, J., Wang, B., & Zhou, C. (2020). Forecasting stock prices with long-short term memory neural network based on attention mechanism. PloS one, 15(1), e0227222.
- Raju, S.M., & Tarif, A.M. (2020). Real-time prediction of bitcoin price using machine learning techniques and public sentiment analysis. In Proceedings of the International Joint Conference on Neural Networks (pp. 1-8). IEEE. <https://doi.org/10.1109/IJCNN.2020.9207563>
- Rather, A.M., Agarwal, A., & Sastry, V.N. (2015). Recurrent neural network and a hybrid model for prediction of stock returns. Expert Systems with Applications, 42, 3234-3241. <https://doi.org/10.1016/j.eswa.2014.12.003>
- Rezaei, H., Faaljou, H., & Mansourfar, G. (2021). Stock price prediction using deep learning and frequency decomposition. Expert Systems with Applications, 69, 114332. <https://doi.org/10.1016/j.eswa.2020.114332>
- Shahi, T. B., Shrestha, A., Neupane, A., & Guo, W. (2020). Stock price forecasting with deep learning: A comparative study. Mathematics, 8(9), 1441. <https://doi.org/10.3390/math8091441>
- Sim, H.S., Kim, H.I., & Ahn, J.J. (2019). Is deep learning for image recognition applicable to stock market prediction? Complexity, 10, 4324878. <https://doi.org/10.1155/2019/4324878>
- Singh, G., & Kaur, H. (2021). Autoencoder-based stock price prediction models. Journal of Finance and Data Science, 7(1), 28-41.
- Tsantekidis, A., Passalis, N., Tefas, A., & Kannianen, J. (2017). Intraday stock price forecasting using recurrent neural networks with multiple-step ahead fine-tuning. arXiv preprint, <https://doi.org/10.48550/arXiv.1705.04733>
- Vaswani, A., Shazeer, N., Parmar, N., et al. (2017). Attention is all you need. Advances in Neural Information Processing Systems, 30, 5998-6008. <https://doi.org/10.48550/arXiv.1706.03762>
- Yang, D., & Wang, L. (2019). Financial time series forecasting with LSTM. Journal of Finance and Data Science, 5(1), 21-28.
- Yang, J., & Wang, L. (2019). Financial data analysis with Python. IEEE.
- Yang, Q., & Wang, C. (2019). A study on forecast of global stock indices based on deep LSTM neural network. Statistics Research, 36, 65-77.
- Zhang, X., He, H., & Zhu, W. (2020). Stock market prediction: A deep learning approach. IEEE Transactions on Neural Networks and Learning Systems.
- Zhou, F., Huang, Z., & Zhang, C. (2022). Carbon price forecasting based on CEEMDAN and LSTM. Applied Energy, 311, 118601. <https://doi.org/10.1016/j.apenergy.2022.118601>
- Zhou, H., Zhang, S., Lan, J., et al. (2021). Informer: Beyond efficient transformer for long sequence time-series forecasting. Proceedings of the AAAI Conference on Artificial Intelligence, 35(12), 11106-11115. <https://doi.org/10.1609/aaai.v35i12.17245>