

KRİPTO PARA FİYATLARININ TAHMİNİ: ARİMA-GARCH VE LSTM YÖNTEMLERİNİN KARŞILAŞTIRILMASI¹

PREDICTION OF CRYPTOCURRENCY PRICES: COMPARISON OF ARİMA-GARCH AND LSTM METHODS

Neman EYLASOV * Macide ÇİÇEK 

*Arařtırma Makalesi / Geliř Tarihi: 25.10.2023
Kabul Tarihi: 31.03.2024*

Öz

Kripto para birimleri, 2009 yılında ortaya çıkmalarından bu yana oldukça popüler hale gelmiştir. Özellikle Bitcoin'in 3 Ocak 2009'da piyasaya sürülmesinden sonra, dięer kripto para birimlerinin piyasaya çıkışı hız kazanmıştır. Bu popülerlik artışının ardından, kripto para birimlerinin tahmini önemli bir konu haline gelmiştir. Bu çalışmanın ana amacı, Bitcoin (BTC), Ethereum (ETH) ve Binance (BNB) kripto para getirilerini öngörmek için geleneksel zaman serisi yöntemlerinden olan ARİMA-GARCH ile birlikte LSTM (Long Short-Term Memory) derin öğrenme yaklaşımını kullanarak elde edilen tahmin performanslarını karşılaştırmaktır. Bu çerçevede, çalışma literatüre yeni bir katkı sunmayı amaçlamaktadır. Her bir kripto para birimi için farklı zaman aralıklarında günlük veriler kullanılmış ve bu veriler %90 eğitim ve %10 test verisi olarak bölünmüştür. Çalışmada, yöntemler RMSE ve MSE değerlendirme kriterleri kullanılarak karşılaştırılmıştır. Genel olarak, BTC serisinde ARİMA-GARCH yöntemi eğitim verisinde daha iyi sonuçlar gösterirken, test verisi için LSTM yöntemi daha etkili olmuştur. BNB serisinde ise hem eğitim hem de test verisi için LSTM yöntemi daha üstün performans sergilemiştir. ETH serisinde ise her iki veri seti için ARİMA-GARCH yöntemi daha iyi sonuçlar ortaya koymaktadır. Bu çalışma, finansal veri tahmininde her iki yöntemin de önemli bir performans sergileyebildiğini vurgulamaktadır.

Anahtar Kelimeler: Derin Öğrenme, ARİMA-GARCH, LSTM, Kripto Para, Fourier ADF

Jel Kodları: C22, C32, C53, E44

Abstract

Cryptocurrencies have become increasingly popular since their emergence in 2009. Particularly after the release of Bitcoin on January 3, 2009, the introduction of other cryptocurrencies gained momentum. Following this surge in popularity, the prediction of cryptocurrency returns has become a significant topic. The main objective of this study is to compare the forecast performances obtained using traditional time series methods, specifically ARİMA-GARCH, and the Long Short-Term Memory (LSTM) deep learning approach to predict returns for Bitcoin (BTC), Ethereum (ETH), and Binance (BNB) cryptocurrencies. In this context, the study aims to contribute novel insights to the existing literature. Daily data for each cryptocurrency from different time intervals were utilized, with the dataset being divided into 90% training and 10% testing data. The methods were compared using evaluation criteria such as RMSE and MSE. Overall, for the BTC series, the ARİMA-GARCH method demonstrated superior results in the training data, while the LSTM method proved to be more effective for the testing data. In the case of the BNB series, LSTM outperformed in both training and testing datasets. For the ETH series, the ARİMA-GARCH method yielded better results for both datasets. This study emphasizes that both methods can exhibit significant performance in predicting financial data.

Keywords: Deep Learning, ARİMA-GARCH, LSTM, Cryptocurrency, Fourier ADF

Jel Codes: C22, C32, C53, E44

¹ **Bibliyografik Bilgi (APA):** FESA Dergisi, 2024; 9(1), 48 - 62 / DOI: 10.29106/fesa.1380870


*Doktora Öğrencisi, İstanbul Üniversitesi, Sosyal Bilimler Enstitüsü, İktisat Bölümü, nemancylasov@ogr.iu.edu.tr, İstanbul - Türkiye, ORCID: 0000-0002-0087-2808

** Prof. Dr. Kütahya Dumlupınar Üniversitesi, İİBF, İktisat Bölümü, macide.cicek@dpu.edu.tr, Kütahya - Türkiye, ORCID: 0000-0001-7512-767X

1. Giriř

Tarih boyunca deęiřen yüzyüyle, para, iřlemler ve yöntemleri konusunda farklı evrimler geirmiş bir araç olmuřtur. Günümüzde ise her ülke kendi kimlięini yansıtan para birimlerini basmaktadır. řu anki zaman diliminde yaklaşık 160 farklı para birimi kullanılmaktadır. Bugünkü anlamıyla en eski para biçimi, emtia para olarak adlandırılmaktadır. Emtia paranın temel özellięi, deęerini taşıdığı metal ya da malzemeden almasıdır. 1944 yılında ise altın standardıyla bağlantılı olarak kâğıt paralar altın teminatına dayalı bir deęer kazanmıştır. Bu dönemde, hemen hemen tüm ekonomiler kâğıt paraları benimsemiř ve kullanmıştır (Üzer, 2017: 4-5). İnternet üzerinden yapılan alışverişler, ödemeler, para transferleri ve bankacılık iřlemleri günümüzde güvenilir üçüncü taraflara olan bağımlılıęı artırmış durumda. Ancak bu bağımlılıęı ortadan kaldırmak ve merkezi bir otoritenin olmadığı, doğrudan kişiler arası ödemelere olanak tanıyan bir sistem olarak öne çıkan Blockchain, "Satoshi Nakamoto" tarafından önerilmiştir. Nakamoto (2008), Blockchain'i řu şekilde tanımlamıştır: "Kriptografik kanıtlara dayalı olarak güveni inşa eden, iki taraf arasındaki doğrudan iřlemlerin üçüncü bir güvenilir aracıya ihtiyaç duymadan gerçekleştirilebildięi bir elektronik ödeme sistemidir." Bu sistem, adeta bir dijital muhasebe defteri gibi iřlev görür. İki taraf arasında bir iřlem gerekleřtięinde, bu iřlem şifrelenmiş bir şekilde kaydedilir. İsteyen her birey, bu aęa katılma imkanına sahiptir. Bu özgür katılım, Blockchain'in temel özellięi olan şeffaf ve açık bir defter yapısından kaynaklanmaktadır (Vigna ve Casey, 2015: 150). İlk kripto para birimi Bitcoin, 2009 yılında tanımlanamayan bir kiři ya da kişiler tarafından oluřturulan bir dijital varlık olarak ortaya çıkmıştır. Bitcoin, merkezi bir otoriteye veya kuruma baęlı olmadan iřleyen bir sistemdir. Satoshi Nakamoto isimli bir birey ya da grup, 2008 küresel finans krizinden ilham alarak Bitcoin'i geliřtirmiş ve "Bitcoin: Uçtan Uca Elektronik Ödeme Sistemi" adlı bir makale aracılıęıyla konsepti dünyaya duyurmuřtur. Nakamoto'nun amacı, aracı finans kurumlarına gerek kalmadan, insanlar arasında anında ve düşük maliyetli para transferleri saęlayan bir dijital para birimi oluřturmaktır. Bu yüzden de bu dijital para birimine "Bitcoin" adını verdi (Dupuis ve Gleason, 2020: 2; Nakamoto, 2008). Forbes'un Ocak 2024 tarihli raporuna göre, piyasa deęerine göre en büyük 10 kripto para, řekil 1'de sıralanmıştır.


řekil 1: Piyasa Deęerine Göre En Büyük 10 Kripto Para (Milyar \$)



Kaynak: (Tretina ve Adams, 2024)

Görüldüęü üzere, řekil 1'de Bitcoin (BTC) ilk sırada, Ethereum (ETH) ikinci sırada ve son sırada Avalanche (AVAX) bulunmaktadır. alıřma kapsamında, en yüksek piyasa deęerine sahip olan Bitcoin (BTC), Ethereum (ETH) ve Binance (BNB) kripto paralarının getirileri tahmin edilmiş ve ARIMA-GARCH zaman serisi yöntemi ile derin öğrenme yöntemi olan LSTM yöntemleri karşılařtırılmıştır. Ayrıca, Bitcoin (BTC), Ethereum (ETH) ve Binance (BNB) kripto para birimlerinin 1 Ocak 2023 - 31 Aralık 2024 tarihleri arasındaki aylık kapanıř fiyatları řekil 2'de gösterilmiştir. alıřma, bu üç kripto paranın getirilerinin ARIMA-GARCH ve LSTM yöntemleri kullanılarak aynı anda ilk kez tahmin edilmesiyle literatüre katkı saęlayabilecek bir yaklařım sunmaktadır.

řekil 2: BTC, ETH ve BNB Kripto Para Fiyatlarının Grafięi (\$)



Çalıřmanın ilerleyen bölümlerinde birinci giriř bölümünün ardından ikinci bölümde, kripto para fiyatlarını tahmin etmeye yönelik yapılan çalıřmalar ve ARIMA ile LSTM gibi tahmin yöntemlerini kıyaslayan arařtırmalar özetlenmiřtir. Üçüncü bölüm, kullanılan yöntemlere dair kısa bilgiler içeren metodoloji bölümünü içermektedir. Dördüncü bölüm, verilerin ve zaman aralıklarının ayrıntılı bir şekilde sunulduđu veri bölümünü kapsarken, beřinci bölümde elde edilen bulgular detaylı bir biçimde deđerlendirilmektedir. Son olarak, altıncı bölümde ise çalıřmanın sonuçlarına odaklanılmaktadır.

2. Literatür Taraması

Bu bölümde literatür taraması iki farklı kategoride ele alınmaktadır. İlk olarak, kripto para fiyatlarını tahmin etmeye yönelik yapılan çalıřmalara odaklanılmaktadır. İkinci olarak ise, ARIMA-GARCH ve LSTM gibi tahmin yöntemlerini kullanarak yöntem karřılařtırması yapılan çalıřmalara yer verilmektedir.

2.1. Kripto Para Fiyatlarının Tahmini

Demirci ve Karaatlı (2023) tarafından gerçekleřtirilen bir çalıřmada, Bitcoin, Ethereum ve Ripple gibi kripto para birimlerinin fiyat tahminleri için farklı zaman aralıkları seçilmiř ve bu tahminler için RNN, LSTM ve GRU yöntemleri kullanılmıřtır. Çalıřmanın sonucunda, Bitcoin ve Ripple için GRU modelinin, Ethereum için ise LSTM modelinin daha iyi sonuçlar verdiđi tespit edilmiřtir. řenol ve Denizhan (2023) tarafından yapılan çalıřmada, Bitcoin, Ethereum ve Cardano kripto para birimlerinin fiyat tahminlerini yapmak için 1 Ekim 2021-31 Aralık 2021 tarihleri arasındaki veriler kullanılarak Yapay Sinir Ağları ve Regresyon modelleri kullanılmıřtır. Tahmin edilen sonuçlara göre, Yapay Sinir Ağları (YSA) modeli regresyon modeline kıyasla daha iyi tahmin yapmaktadır. Akay vd. (2022) literatüre kazandırdıkları çalıřmada, XRP,BNB ve ETH kripto paraları tahmin etmek için LSTM ve Yapay Sinir Ağları modellerini kullanmıřlardır. Sonuçlara göre, YSA modeli daha iyi performans göstermektedir. Bir diđer çalıřmada, řahin (2018) 02.02.2012 – 09.01.2018 tarihleri arasında Bitcoinin kapanıř fiyatları veri olarak kullanılarak ARIMA ve Yapay Sinir Ağları tahminleme yapmıřtır. YSA modeli daha iyi sonuç verdiđi sonucuna ulařılmıřtır. řahin ve Özkan (2018) çalıřmalarında, 01.01.2015-11.02.2018 dönemi Bitcoin'in verilerini alarak volatilitenin belirlenmesi amacıyla ARCH, GARCH, ARCHM, EGARCH ve TARARCH modelleri kullanılmıřtır. Sonuç olarak, TARARCH yöntemi volatilitate tahmini için en uygun yöntem olduđu belirlenmiřtir. Odabařı ve Toklu (2023) tarafından gerçekleřtirilen çalıřmada, yapay sinir ağları ve derin öğrenme LSTM yaklařımı kullanılarak 20 Ağustos 2020 - 27 řubat 2023 tarihleri arasındaki veriler ile Polkadot kripto para biriminin tahmini yapılmıřtır. Arařtırma, hem yapay sinir ağlarında hem de derin öğrenmede üstün performans ortaya koymuřtur. Ancak, LSTM yöntemi, daha düşük Hata Kare Kökü (RMSE) ve Hata Kare Ortalaması (MSE) oranlarıyla yapay sinir ağlarından daha iyi sonuç vermiřtir.

2.2. ARIMA-GARCH ve LSTM Yöntemlerinin Karřılařtırılması

Tanıřman vd. (2021), 29 Nisan 2013- 27 řubat 2021 tarihleri arasındaki 2862 günlük verileri kullanarak Bitcoin'in (BTC) açılıř, en yüksek, en düşük, kapanıř, hacim ve market deđerlerini içeren bir veri setiyle ARIMA ve LSTM yöntemlerini kullanarak fiyat tahmini yapmıřlardır. Elde edilen sonuçlar, LSTM modelinin hem yakın hem de uzak gelecek için iyi tahminler yapabildiđini, ancak ARIMA modelinin sadece yakın gelecek için iyi tahminler yapabildiđini göstermektedir. Aliyev vd. (2022) Moskova borsası hisse senedi endeksini (RTS) ARIMA-GARCH zaman serisi yöntemi ve derin öğrenme yöntemi olan LSTM kullanarak tahmin etmiřtir. Çalıřmada, 5 Ocak 2000 - 8 Temmuz 2022 tarihleri arasındaki 5622 günlük veri kullanılmıřtır. Veriler %90 test ve %10 eğitim verisi olarak ayrılmıřtır. Çalıřmanın sonuçlarına göre, her iki tahmin yöntemi de başarılı sonuçlar vermiřtir, ancak LSTM yöntemi eğitim verileri için ARIMA-GARCH yönteminden daha başarılı olduđu tespit edilmiřtir. Test verileri için ise ARIMA-GARCH yöntemi, LSTM yöntemine göre daha başarılı sonuç vermiřtir. Abar (2021) tarafından yapılan çalıřmada, Türkiye'nin BİST100 endeksini açılıř deđerlerini kullanarak ARIMA-GARCH ve LSTM yöntemleri ile tahmin etmiřtir. Çalıřmada, 2 Ocak 1995 - 15 Eylül 2021 dönemi için 6673 günlük veri kullanılmıřtır. Hem zaman serisi yöntemlerinden olan ARIMA-GARCH hem de derin öğrenme yöntemlerinden olan LSTM yöntemleri başarılı sonuçlar vermiřtir ancak LSTM yöntemi ARIMA-GARCH yöntemine göre daha yüksek başarı gösterdiđi sonucuna ulařılmıřtır. Karciođlu vd. (2021) COVID-19'un günlük vaka, ölüm ve iyileřme verilerini tahmin etmiřlerdir. Çalıřmada, ARIMA ve LSTM yöntemleri kullanarak 25 Kasım 2020 ile 6 Ekim 2021 tarihleri arasındaki verilerle 15 gün sonrasının tahminlerini yapmıřlardır. Yapılan tahminler sonucunda, vaka sayısı, iyileřme ve ölüm sayılarında azalma görülmüřtür. ARIMA modeli, vaka ve iyileřme sayıları için daha iyi sonuçlar verirken, ölüm sayıları için LSTM modeli daha iyi sonuçlar vermiřtir. Sevinç ve Kaya (2021a) tarafından gerçekleřtirilen bir arařtırmada, Bingöl'ün Solhan ilçesinin sıcaklık verileri ARIMA ve LSTM yöntemleri kullanılarak tahmin edilmiřtir. Çalıřmada, 1 Ocak 2014 - 27 Nisan 2020 tarihleri arasında 2306 günlük sıcaklık verileri kullanılmıřtır. Sonuçlar, ARIMA yönteminin LSTM yöntemine göre sıcaklık tahmininde daha başarılı olduđunu göstermiřtir. Sevinç ve Kaya (2021b) yapmıř oldukları başka bir çalıřmada, Diyarbakır ilinin 2014 - 2020 yılları arasındaki 2271 günlük sıcaklık verilerini kullanarak ARIMA ve LSTM yöntemleriyle tahmin yapmıřtır. Bu çalıřmada da, ARIMA yöntemi LSTM yöntemine göre daha başarılı sonuçlar vermiřtir. Siami-

Namini vd. (2018), N225, IXIC, HSI, GSPC, DJI, MC, HO, ER, FB, MS ve TR hisse senetlerinin ARIMA ve LSTM yöntemleri ile tahmin edildiđi alıřmalarını literatüre kazandırmıřlar. alıřmada, her bir hisse senedi için farklı veri setleri kullanılarak %70 eđitim ve %30 test verilerine ayrılmıřtır. Sonuç olarak, hisse senetlerinin tahmininde, LSTM yönteminin ARIMA yöntemine göre daha başarılı olduđu bulunmuřtur. Son yıllarda yapılan arařtırmalar, finansal deđiřkenlerin tahmini için zaman serisi yöntemlerinden olan ARIMA ve derin öğrenme yöntemlerinden olan LSTM'in oldukça iyi sonuçlar verdiđini ortaya koymaktadır. Ancak, tahmin edilen deđiřkenlere göre bu yöntemlerin performansı birbirinden farklılık göstermektedir. Bazı arařtırmalar, LSTM yönteminin daha iyi sonuç verdiđini gösterirken, diđer arařtırmalar ARIMA yönteminin daha az RMSE ile başarılı tahmin yapabildiđini ortaya koymaktadır. Genellikle finansal verilerle alıřıldığında, deđiřen varyans sorunu ortaya çıkmaktadır. Bazı arařtırmalarda, ARIMA-GARCH yöntemi kullanılarak bu sorun özölmeye alıřılmıřtır, ancak bu alıřmalar oldukça sınırlıdır. Bu alıřmada, Bitcoin (BTC), Ethereum (ETH) ve Binance (BNB) kripto para getirilerinin tahminlerini yapmak için ARIMA-GARCH ve LSTM yöntemleri kullanılmıř ve her iki yöntemin performansı karşılařtırılmıřtır. Bu alıřmanın diđerlerinden ayrılan özelliđi, Bitcoin (BTC), Ethereum (ETH) ve Binance (BNB) kripto para getirilerinin ilk defa zaman serisi ve derin öğrenme yöntemleri kullanılarak bir arada tahmin edilmesiyle literatüre katkı sađlamasıdır.

3. Metodoloji

3.1. ADF ve Fourier ADF Birim Kök Testleri

Zaman serisi yöntemlerinde, sahte regresyon sorununu önlemek için deđiřkenlerin durađanlıklarını incelemek önemlidir. ARIMA modeli tahmini için, ARIMA (p, d, q) modelinde "d" parametresinin belirlenmesi için birim kök testleri kullanılır. Bu alıřmada, kripto para birimlerinin durađanlıklarını incelemek için Dickey ve Fuller (1981) tarafından geliřtirilen ADF birim kök testi kullanılmıřtır. ADF birim kök testi, Dickey-Fuller (1979) alıřmasındaki birim kök testinin genişletilmiř bir versiyonudur. Bu testte, modele bađımlı deđiřkenin gecikmeleri ilave edilerek otokorelasyon sorunu özölmeye alıřılmaktadır. ADF birim kök testi, sabitsiz ve trendsiz model, sabitli ve trendsiz model, sabitli ve trendli modeller olmak üzere üç farklı model için incelenmektedir. Bu alıřmada, kullanılan Bitcoin (BTC) örneğinde, sabitli ve trendli modelde ADF birim kök testi denkleminin ařađındaki řekildedir.

$$\Delta BTC_t = \beta_0 + \beta_1 t + \beta_2 BTC_{t-1} + \beta_3 \Delta BTC_{t-1} + u_t \quad (1)$$

Denklem 1'de, Δ fark iřlemine β_0 sabit terimi, $\beta_1 t$ trendi, β_2 kripto para biriminin gecikmeli deđerinin katsayısını, ve β_3 kripto para biriminin farkı alınmıř gecikmeli deđerinin katsayısını göstermektedir. Burada, β_2 katsayısı için hesaplanan τ istatistik deđeri, kritik deđerlerden mutlak olarak büyük olduđunda, yokluk hipotezi olan "birim kök var, durađan deđildir" reddedilecektir (Eylasov vd., 2023a: 117). Yani, BTC serisi düzeyde durađan olacaktır. Yapısal kırılmaların meydana geldiđi zaman serilerinde, ADF birim kök testi sonuçları güvenilir olmamaktadır. Bu nedenle, alıřmada yapısal kırılmaları da dikkate alan Fourier ADF birim kök testi kullanılmıřtır. Fourier ADF birim kök testi, Enders ve Lee (2012) tarafından literatüre kazandırılmıřtır. Enders ve Lee'nin alıřmasında, Dickey ve Fuller (1981) alıřmasındaki ADF denkleminin Fourier terimlerinden olan sinüs ve kosinüs terimleri eklenecek yapısal kırılmalarda da iyi sonuç veren yeni birim kök testi geliřtirilmiřtir. Denklem 1'deki eřitlik, Fourier ADF eřitliđi olarak Denklem 2'deki gibi yazılmaktadır.

$$\Delta BTC_t = \beta_0 + \beta_1 t + \beta_2 BTC_{t-1} + \lambda_1 \sin\left(\frac{2\pi kt}{T}\right) + \lambda_2 \cos\left(\frac{2\pi kt}{T}\right) + \beta_3 \Delta BTC_{t-1} + u_t \quad (2)$$

Denklem 2'deki π , 3.1415, k frekans deđerini, T gözlem sayısını ve t trendini ifade etmektedir. Burada dikkat edilmesi gereken nokta, sinüs (λ_1) ve kosinüs (λ_2) terimlerinin istatistiksel olarak anlamlı olmasıdır. Eđer sinüs ve kosinüs terimleri istatistiksel olarak anlamlı deđillerse, normal ADF testi sonuçları geçerli olacaktır (Eylasov vd., 2023b: 145; Gasim ve řenyay, 2023: 125). Eđer Fourier terimleri istatistiksel olarak anlamlı ve BTC katsayısının test istatistik deđerini Enders ve Lee (2012) alıřmasındaki kritik deđerlerden mutlak olarak büyük bulunursa, yokluk hipotezi reddedilerek seri FADF testine göre düzeyde durađan olacaktır.

3.2. ARIMA-GARCH Zaman Serisi Modeli

ARIMA-GARCH modeli, dođrusal ARIMA ve kořullu heteroskedastisite GARCH'ı birleřtirerek nonlineer bir hibrit zaman serisi modeli oluřturmaktadır. X_t , alıřmak istediđimiz durađan bir zaman serisini temsil etsin, bunu ARMA süreci olarak Brockwell ve Davis (2002) alıřmasında yer aldıđı gibi ařađındaki řekilde modellenmektedir:

$$\phi(B)X_t = \theta(B)\varepsilon_t \quad (3)$$

ARIMA modeli, standart ARMA modelinin genelleřtirmesidir ve durađan olmayan deđiřkenlerle bařa çıkmak için fark alma tekniđini kullanılmaktadır. Eđer X_t zaman serisi durađan deđilse, uygun bir řekilde serinin farkı alınarak standart ARMA modeline uygun bir durađan seri elde edilebilmektedir. Bu durađan seri ařađındaki řekilde ifade edilmektedir:

$$\phi(B)(1 - B)^d X_t = \theta(B)\varepsilon_t \quad (4)$$

d , fark alma işlemini göstermektedir. Yukarıda önerilen ARMA/ARIMA modeli, t ε 'nin sabit varyansını varsayan lineer bir zaman serisi modeli olmaktadır. Bununla birlikte, birçok ilgili çalışmalar koşullu varyansın varlığını makalelerde gösterilmiştir. Bu nedenle bu modeller bu özelliği iyi bir şekilde yakalayamamaktadırlar. Dahası, sabit hata varyansı hipotezi geçerli değilse, ARIMA'nın parametrelerini tahmin etmek için kullanılan en küçük kareler algoritması sapmalı olacaktır. Bu soruna bir çözüm olarak, heteroskedastisiteyi ardışık hatalar arasındaki nonlineer bir ilişki olarak modellemektir. Zamanla değişen varyansa sahip olan GARCH modeli, zaman serisinin istatistiksel özelliklerini daha iyi karakterize etmede yardımcı olmaktadır. ARIMA-GARCH, ARIMA modelini GARCH modeli ile birleştirerek nonlineer bir zaman serisi modeli oluşturmaktadır. Genel GARCH (p, q) modeli aşağıdaki gibidir:

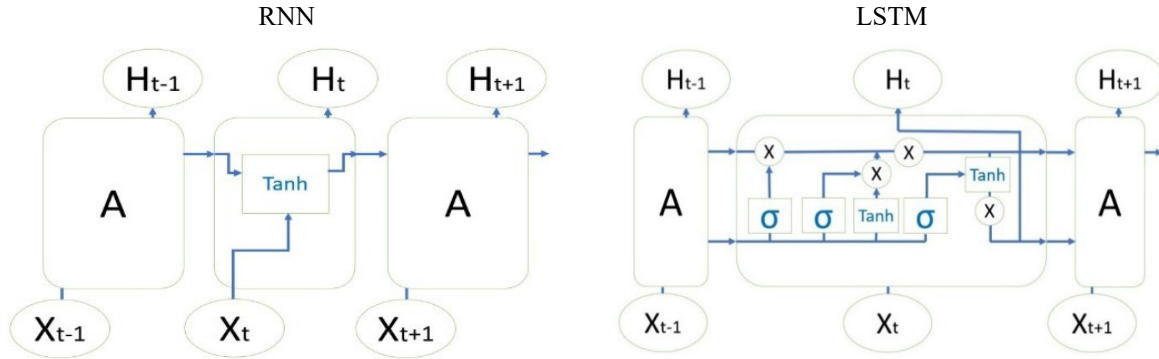
$$\sigma_t^2 = E_{t-1}(\varepsilon_t^2) \text{ ve } \varepsilon_t = \sigma_t e_t, e_t \sim N(0,1) \quad (5)$$

GARCH modeli, geçmiş gözlemler dizisi üzerindeki seri bağımlılığı yakalamak için alternatif parametreleri uygulayarak tahmin hatası t ε 'nin koşullu varyansını tanımlamaktadır.

3.3. LSTM Derin Öğrenme Modeli

LSTM (Uzun-Kısa Süreli Bellek) ilk olarak Hochreiter ve Schmidhuber (1997) tarafından literatüre kazandırılmıştır. Literatüre kazandırılan bu yöntem daha sonra özellikle zaman serisi tahmini problemlerini ele almak için çok popüler hale dönüşmüştür. LSTM, RNN yönteminin modifiye edilmiş hali olarak, birçok farklı problemde iyi çalışmakta ve zaman serisi tahminlerinde aktif olarak kullanılmaktadır. LSTM, sinir ağı tasarımında kapı birimleri ve bellek hücrelerini kullanarak zaman içinde verileri nasıl hatırlayacağı problemi ele almaktadır. Bellek hücreleri, yakın zamanda deneyimlenen verileri depolayan hücre durumlarına sahip olmaktadır. Bilgi her bir bellek hücresine ulaştığında, çıktı hücre durumu ve yenilenen hücre durumu kombinasyonu ile kontrol edilmektedir. Bellek hücresi başka bir bilgi alırsa, çıktı hem yeni bilgi hem de yenilenen hücre durumu kullanılarak işlenmektedir. LSTM, uzun vadeli bağımlılığı olan bir problemin sürdürülmesi amaçlanmıştır. Varsayılan davranışları, bilgiyi uzun bir süre boyunca hatırlamaktır, bunu zorlanarak öğrenmezler. Tüm tekrarlayan sinir ağlarında, sinir ağının tekrarlayan modülleri bir zincir gibi birbirine bağlanmaktadır. Standart RNN'lerin tekrarlayan modülü, Şekil 3'te gösterildiği gibi basit bir yapıya sahiptir, yalnızca tek bir \tanh katmanını içermektedir. Öte yandan, LSTM, aynı şekilde bir zincir yapısını sürdürmekle birlikte, tekrarlayan modülün farklı bir yapıya sahip olduğu şekilde gösterilmiştir.

Şekil 3: RNN ve LSTM Tekrarlayan Modüller



Kaynak: (Olah, 2015)

LSTM (Uzun Kısa Süreli Bellek), hücre durumuna veri eklemeyi veya çıkarmayı içerebilmektedir. Bu veriler, kapılar olarak adlandırılan yapılar tarafından bilinçli bir şekilde yönetilmektedir. Kapı, verinin hücre durumuna girebilmesini kontrol etmek için bir yaklaşımdır. Kapı, bir sigmoid fonksiyonu ve nokta bazlı bir çarpma işlemi kombinasyonudur. Sigmoid fonksiyonu sıfırdan bire kadar herhangi bir sayı üretebilmektedir. Bu değer, verinin geçişini kontrol ederek; tahmini sıfır, "hiçbir şey geçirme" anlamına gelirken tahmini bir, "her şeyi geçire" anlamına gelmektedir (Graves, 2013: 5).

$$\text{Güncelleme kapısı, } \Gamma_u = \sigma(W_u[h^{<t-1>}, x^t] + b_u) \quad (6)$$

$$\text{Unutma kapısı, } \Gamma_f = \sigma(W_f[h^{<t-1>}, x^t] + b_f) \quad (7)$$

$$\text{Çıkış kapısı, } \Gamma_o = \sigma(W_o[h^{<t-1>}, x^t] + b_o) \quad (8)$$

LSTM modeli, son zamanlarda deneyimlenen verilerin bir hücreden diğerine geçmesi için farklı kapılar kullanılmaktadır. Bu kapılar, Eşitlik. 6, 7 ve 8'de gösterildiği gibi güncelleme kapısı, unutma kapısı ve çıkış kapısı

olarak bilinmektedir. Bu hücreler, LSTM modelinin hafızasını kontrol etmek için kullanılmaktadır. Burada LSTM'de hem aktivasyon deęerleri hem de aday deęerleri kullanılmaktadır. Bu nedenle, Eřitlik 9'da LSTM hücresinden iki çıktı üretilmektedir, biri aktivasyon, dięeri ise aday deęerlerdir.


$$\text{Çıktılar} \begin{cases} c^{<t>} = \Gamma_u * c^{N<t>} + \Gamma_f * c^{<t-1>} \\ a^{<t>} = \Gamma_o * c^{<t>} \end{cases} \quad (9)$$

Veriler, Őekil 3'ün en üst noktasında bulunan seviye çizgisinden geçirmektedir. Bu seviye çizgisi hücre durumu olarak isimlendirilmektedir. Dolayısıyla, hücre durumu bir tařıma hattına benzer. Hücre durumu, tüm zincir boyunca düz bir Őekilde ilerlerken, sadece bazı küçük lineer iř birlikleriyle birlikte çalışmaktadır.

4. Veri

Bu çalışmada, Bitcoin (BTC), Ethereum (ETH) ve Binance (BNB) kripto getirilerinin tahmin performansını deęerlendirmek amacıyla ARIMA-GARCH zaman serisi modeli ve LSTM derin öğrenme modeli kullanılmıştır. Tüm kripto para verileri, investing.com üzerinden temin edilmiştir. Bitcoin (BTC) için, 1 Ocak 2011 - 16 Ocak 2024 tarihleri arasında 4763 günlük veri kullanılmıştır. Ethereum (ETH) için, 10 Mart 2016 - 16 Ocak 2024 tarihleri arasında 2268 günlük veri kullanılmıştır. Son olarak, Binance (BNB) için, 9 Kasım 2017 - 16 Ocak 2024 tarihleri arasında 2259 günlük veri kullanılmıştır. Çalışmada, tüm kripto paraların kapanıř fiyatlarına dayanarak getiri serileri oluşturulmuřtur. Őekil 4'te, bu serilerin zaman grafięi ve Őahinler vd. (2024) çalışmalarında yer alan $Getiri(BTC, BNB, ETH)_t = (Ln(BTC, BNB, ETH)_t - Ln(BTC, BNB, ETH)_{t-1}) * 100$ formülü ile hesaplanan getiri serisinin zaman içindeki deęiřimleri gösterilmektedir.

Őekil 4: Kripto Para Fiyatlarının Getiri Zaman Serisi Grafikleri



Çalışmada, tüm kripto para getirileri %90 eğitim verisi ve %10 test verisi olarak ayrılmıştır. BTC için 4287 gözlem eğitim, 476 gözlem test verisi olarak belirlenmiştir. BNB için ise 2033 gözlem eğitim, 226 gözlem test verisi olarak ayrılmıştır. ETH için ise 2581 gözlem eğitim, 287 gözlem test verisi olarak belirlenmiştir. Kripto para getirilerinin tanımlayıcı istatistikleri Tablo 1'de yer almaktadır. Tüm kripto para getirilerinin ortalaması pozitif ve sıfıra yakın

değerlerde olduđu gözlemlenmektedir. Bu durum, BTC, BNB ve ETH kripto para birimlerinin seçilen zaman aralıklarında kazanç sağladığını işaret etmektedir.

Tablo 1: Kripto Paraların Tanımlayıcı İstatistikleri

Kripto Para	BTC	BNB	ETH
Tarih Aralığı	02.01.2011-16.01.2024	10.11.2017-16.01.2024	11.03.2016-16.01.2024
Minimum	-84.883	-58.116	-58.964
Maksimum	147.418	53.057	25.860
Medyan	0.012	0.122	0.072
Ortalama	0.249	0.224	0.187
Standart Sapma	5.717	5.562	5.271
Gözlem	4763	2259	2868
Eđitim Verisi	4287	2033	2581
Test Verisi	476	226	287

5. Bulgular

Çalışmanın ilk aşamasında, deđişkenlerin durađanlıkları test edilmiştir. Tablo 2'de, hem ADF birim kök testi hem de Fourier ADF birim kök testi sonuçları sunulmaktadır. ADF birim kök testi sonuçlarına göre, tüm deđişkenler hem sabitli hem de sabitli ve trendli modelde seviyede durađan bulunmaktadır. Bu nedenle, ADF testine göre tüm deđişkenlerin I(0) olduđu sonucuna varılmıştır. Çalışmada ayrıca yapısal kırılmaları dikkate alan Fourier ADF birim kök testi de kullanılmıştır. Tablo 2'de, Fourier ADF birim kök testi sonuçları da sunulmaktadır. Buradaki önemli nokta, Fourier terimlerinin istatistiksel olarak anlamlı olup olmadığıdır. Eđer Fourier terimleri istatistiksel olarak anlamlı deđilse, klasik ADF testi sonuçları geçerli olacaktır. Tablo 2'de FADF testine göre tüm deđişkenler hem sabitli hem de sabitli ve trendli model de seviyede durađandır. Fakat, deđişkenlerin Fourier terimleri istatistiksel olarak anlamlı bulunmadığından ADF testi sonuçları geçerli olacaktır.

Tablo 2: Birim Kök Testi Sonuçları

Kripto para	Sabitli Model Sonuçları		Fourier ADF			
	ADF Test istatistik	Gecikme	ADF Test istatistik	Gecikme	Frekans	F istatistik
BTC	-27.017***	4	-68.278***	0	1	0.81
BNB	-31.424***	1	-48.660***	0	1	0.23
ETH	-56.142***	0	-56.130***	0	1	0.19

Kripto para	Sabitli ve Trendli Model Sonuçları		Fourier ADF			
	ADF Test istatistik	Gecikme	ADF Test istatistik	Gecikme	Frekans	F istatistik
BTC	-27.095***	4	-68.331***	0	1	0.78
BNB	-31.454***	1	-48.705***	0	1	0.61
ETH	-56.152***	0	-56.138***	0	1	0.16

Not: ***, %1 seviyesinde durađanlıđı ifade etmektedir. Gecikme uzunlukları SIC bilgi kriteri tarafından otomatik olarak seçilmiştir.

Tablo 2'deki sonuçlara göre, tüm deđişkenlerin seviyede durađan olduđu ADF birim kök testi ile tespit edilmiştir. Kripto para birimleri için uygun ARIMA modelleri, eğitim verileri kullanılarak belirlenmiştir. R programında, otomatik ARIMA modelinin parametrelerine maksimum değerler olarak sırasıyla 5, 0 ve 5 atanmıştır. AIC bilgi kriterine göre, Bitcoin için en uygun model ARIMA(1,0,1) olarak belirlenirken, BNB için ARIMA(0,0,2) modeli ve ETH için ARIMA(1,0,1) modeli en uygun modeller olarak belirlenmiştir. Finansal verilerdeki deđişken varyans sorunu sıkça ortaya çıkmaktadır. Bu nedenle, seçilen ARIMA modellerinin kalıntılarına ARCH LM testi uygulanmış ve Tablo 3'te sunulan sonuçlar elde edilmiştir.

Tablo 3: ARCH Testi Sonuçları

Kripto para	Model	Test İstatistiđi	Serbestlik Derecesi	Anlamlılık
BTC	ARIMA(1,0,1)	9.765	1	0.001
BNB	ARIMA(0,0,2)	150.79	1	0.000
ETH	ARIMA(1,0,1)	67.048	1	0.000

Tablo 3'teki sonuçlara göre, kripto para getirileri için seçilen uygun ARIMA modelinde kalıntıların deđişen varyans sorunu olduđu görülmüştür. "Deđişen varyans yoktur" şeklinde olan sıfır hipotezi %1 seviyesinde reddedilmiştir. Modellerde deđişen varyans sorunu olduğundan, farklı model biçimleri için GARCH modeli tahmin edilmiştir. GARCH(1,1) modelinde kripto para getirileri için deđişen varyans sorununun çözüldüđu tespit

edilmiřtir. BTC, BNB ve ETH için elde edilen model, ortalama denklemi için sırasıyla ARIMA(1,0,1), ARIMA(0,0,2), ARIMA(1,0,1) ve varyans denklemi için GARCH(1,1) biçimindedir. Tablo 4'te BTC için ARIMA-GARCH(1,0,1)(1,1) modelinin tahmin çıktıları yer almaktadır. Tablo 4'te tüm kripto para birimleri için ARIMA-GARCH modellerinin tahmin çıktıları yer almaktadır.

Tablo 4: ARIMA-GARCH Modellerinin Tahmin Çıktısı


BTC ARIMA-GARCH(1,0,1)(1,1) Tahmin Çıktısı				
Parametre	Tahmin	Standart Hata	t-deęeri	Prob
MU	0.220	0.062	3.509	0.000
AR(1)	-0.901	0.057	-15.609	0.000
MA(1)	0.892	0.062	14.224	0.000
OMEGA	0.651	0.261	2.488	0.012
ALPHA1	0.157	0.042	3.672	0.000
BETA1	0.834	0.038	21.825	0.000

BNB ARIMA-GARCH(0,0,2)(1,1) Tahmin Çıktısı				
Parametre	Tahmin	Standart Hata	t-deęeri	Prob
MU	0.124	0.087	1.426	0.153
MA(1)	-0.061	0.025	-2.393	0.016
MA(2)	0.043	0.025	1.691	0.090
OMEGA	0.610	0.155	3.937	0.000
ALPHA1	0.150	0.018	8.212	0.000
BETA1	0.848	0.016	52.541	0.000


ETH ARIMA-GARCH(1,0,1)(1,1) Tahmin Çıktısı				
Parametre	Tahmin	Standart Hata	t-deęeri	Prob
MU	0.174	0.098	1.768	0.076
AR(1)	-0.417	0.147	-2.830	0.004
MA(2)	0.377	0.147	2.568	0.010
OMEGA	1.890	0.710	2.662	0.007
ALPHA1	0.131	0.032	4.119	0.000
BETA1	0.812	0.043	18.78	0.000

GARCH modellerinde kararlılık kriterlerinin $\Omega > 0, \alpha_1 > 0, \beta_1 > 0$ kısıtlamalarını saęlayıp saęlamadığını kontrol edilmelidir (Şahinler, 2022: 52). Tablo 4'te yer alan BTC, BNB ve ETH için tahmin edilen ARIMA-GARCH modellerinde, Omega, alfa ve beta katsayıları pozitif ve istatistiksel olarak anlamlı bulunmaktadır. Alpha1 parametresi, řokların kalıcılığını gösterirken, GARCH Beta1 parametresi volatilitedeki kümelenme kalıcılığını ifade etmektedir. Ayrıca, modellerde alfa ve beta toplamları, tüm kripto para birimleri için 1'den küçüktür. Bu durum, tahmin edilen modellerde kripto para getirilerinin birim kök içermediğini göstermektedir. Dięer taraftan, BNB kripto para getiri serisi için hesaplanan beta1 deęeri 0.848 olarak belirlenmiřtir. Bu deęer dięer serilere göre en yüksek olanıdır. Bu durum, BNB kripto para için řokların volatilitte üzerinde kalıcı etkiler yarattığını ve hemen sönmediğini ifade etmektedir. Ařağıdaki grafikler, kripto para getirilerinin eğitim ve test verilerini kullanarak elde edilen ARIMA-GARCH modellerine ait gerçeę ve tahmini zaman serilerini göstermektedir.


Şekil 5: Bitcoin (BTC) Eğitim Verisi Gerçeę ve Tahmin Deęerleri (ARIMA-GARCH) Tahmini




Őekil 6: Bitcoin (BTC) Test Verisi Gerçek ve Tahmin Deęerleri (ARIMA-GARCH) Tahmini




Őekil 7: Binance (BNB) Eğitim Verisi Gerçek ve Tahmin Deęerleri (ARIMA-GARCH) Tahmini




Őekil 8: Binance (BNB) Test Verisi Gerçek ve Tahmin Deęerleri (ARIMA-GARCH) Tahmini



Őekil 9: Ethereum (ETH) Eğitim Verisi Gerçek ve Tahmin Deęerleri (ARIMA-GARCH) Tahmini




Şekil 10: Ethereum (ETH) Test Verisi Gerçek ve Tahmin Deęerleri (ARIMA-GARCH) Tahmini



Yukarıda yer alan grafiklerdeki kripto para getirilerinin eğitim ve test verilerinde, GARCH tahmin tablosunda da gözlemlendięi gibi, ani ve belirgin deęişimlerin genellikle birbirini takip ettięi ve düşük oynaklık dönemlerinde ise daha küçük deęişimlerin izlendięi görülmektedir. Koşullu varyans grafiklerinde de bu durum açıkça görülmektedir. Bu bulgular, kripto para getiri serilerinin koşullu varyanslarında volatilité kümelenmesinin varlığına işaret etmektedir. Yani, belirli bir dönemde yüksek volatilitenin gözlenmesi, genellikle bu yüksek volatilitenin devam edeceęine ve ardından düşük volatilitenin izleneceęine dair bir eğilim söz konusudur. Bu durum, finansal piyasalardaki belirsizliklerin ve risklerin belirli dönemlerde birikmesi ve ardından daha sakin dönemlerin yaşanmasıyla ilişkilendirilmektedir.


LSTM tahmini için kripto para getirilerine dört katmanlı bir derin öğrenme modeli oluşturulmuştur. Birinci, ikinci ve üçüncü katmanda, LSTM ağı kullanılarak çıktı uzay boyutu 50'ye ayarlanmıştır. Son katmanda çıktı uzay boyutu 1 olan bir *dense* katmanı kullanılmıştır. Girdi olarak, tüm kripto para birimlerinin önceki iki güne ait açılış deęerleri kullanılmış ve çıktı olarak ilgili günün açılış deęeri AR(2) modeli kullanılarak tahmin edilmiştir. Eğitim için *MSE* (Ortalama Kareli Hata) kayıp fonksiyonu ve *ADAM* (Uyarlanabilir Moment Tahmini) optimizasyon algoritması (Kingma ve Ba, 2014) kullanılmıştır. En yüksek devir sayısı 100, yığın sayısı ise 32 olarak ayarlanmış ve tüm kripto para birimi modelleri için devir sayısı Şekil 11'de grafik şeklinde gösterilmiştir.

Şekil 11: LSTM Modeli Tüm Kripto Para Birimleri için Devir (Epoch) Sayıları




Aşağıda yer alan grafikler, kripto para getirileri üzerinde eğitim ve test verilerini kullanarak oluşturulan LSTM modellerinin gerçek ve tahmini zaman serilerini göstermektedir. ARIMA-GARCH tahminlerine benzer şekilde, LSTM tahminleri de başarılı sonuçlar elde etmiştir. Grafiklerde dikkat çeken önemli bir nokta, ani ve belirgin deęişimlerin genellikle birbirini takip ettięi ve düşük oynaklık dönemlerinde ise daha küçük deęişimlerin izlendięidir. Ayrıca, Şekil 18'de, LSTM modeli tarafından tahmin edilen eğitim ve test verilerinin gerçek verilerle birlikte gösterildięi grafiklere de yer verilmiştir.


Őekil 12: Bitcoin (BTC) Eđitim Verisi Gerçek ve Tahmin Deđerleri (LSTM) Tahmini




Őekil 13: Bitcoin (BTC) Test Verisi Gerçek ve Tahmin Deđerleri (LSTM) Tahmini




Őekil 14: Binance (BNB) Eđitim Verisi Gerçek ve Tahmin Deđerleri (LSTM) Tahmini




Őekil 15: Binance (BNB) Test Verisi Gerçek ve Tahmin Deđerleri (LSTM) Tahmini




Şekil 16: Ethereum (ETH) Eğitim Verisi Gerçek ve Tahmin Değerleri (LSTM) Tahmini

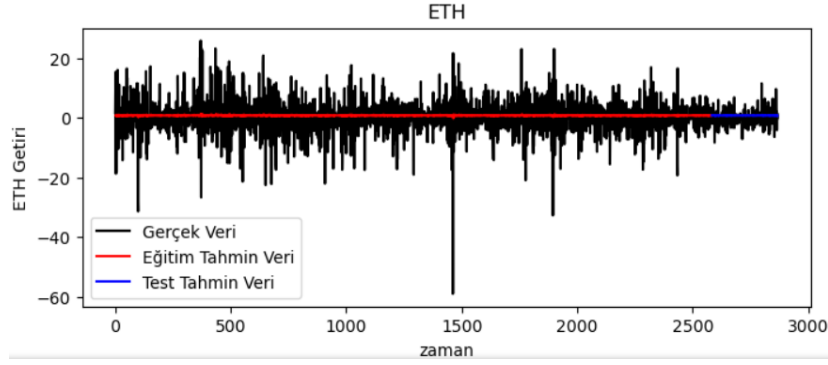


Şekil 17: Ethereum (ETH) Test Verisi Gerçek ve Tahmin Değerleri (LSTM) Tahmini



Şekil 18: LSTM Yaklaşımı BTC, BNB ve ETH Tahminleri





Çalışmanın son aşamasında, ARIMA-GARCH ve LSTM modellerinin performansını değerlendirmek için çeşitli ölçütler kullanılmıştır. Tablo 5'te yer alan hesaplamalara göre, BTC eğitim verisi için LSTM modeli, ARIMA-GARCH modeline kıyasla daha düşük RMSE ve MSE değerleri elde ederek daha iyi bir performans sergilemiştir. Ancak, BTC test verisi için durum tam tersidir; ARIMA-GARCH modeli, LSTM modeline göre daha iyi sonuç vermiştir. BNB kripto parası için ise hem eğitim hem de test verisi için LSTM modeli, daha düşük RMSE ve MSE değerleri ile üstün performans göstermiştir. Son olarak, ETH verisinde ise ARIMA-GARCH yöntemi, LSTM yöntemine göre daha düşük RMSE ve MSE değerleriyle daha etkili bir tahmin performansı sergilemiştir. Bu sonuçlar, farklı kripto para birimleri için farklı tahmin modellerinin etkili olabileceğini göstermektedir.

Tablo 5: Modeller için Değerlendirme Ölçütleri

Ölçüt	BTC Kripto Parası için Değerlendirme			
	Eğitim Verisi		Test Verisi	
	ARIMA-GARCH	LSTM	ARIMA-GARCH	LSTM
RMSE	5.97709	5.849	2.424841	2.452
MSE	35.72561	34.217	5.879853	6.014

Ölçüt	BNB Kripto Parası için Değerlendirme			
	Eğitim Verisi		Test Verisi	
	ARIMA-GARCH	LSTM	ARIMA-GARCH	LSTM
RMSE	5.79725	5.7889	2.416944	2.3655
MSE	33.6081	33.5124	5.841616	5.5959

Ölçüt	ETH Kripto Parası için Değerlendirme			
	Eğitim Verisi		Test Verisi	
	ARIMA-GARCH	LSTM	ARIMA-GARCH	LSTM
RMSE	5.492329	5.5311	2.330373	2.4452
MSE	30.16568	30.594	5.430639	5.9794

6. Sonuç

Günümüzde giderek sayısı artan ve bazı ülkeler tarafından resmi kabul gören kripto paralar popüler hale dönüşmektedir. Forbes'un Ocak 2024 tarihli raporuna göre, kripto paraların toplam piyasa değeri yaklaşık 1,7 trilyon doları bulmuştur (Duggan ve Adams, 2024). Çalışmada, Ethereum, Bitcoin ve Binance kripto para getirilerinin tahmini için derin öğrenme yöntemlerinden olan LSTM ve zaman serisi yöntemlerinden olan ARIMA-GARCH modeli kullanılmıştır. Çalışmada, tüm kripto para verilerinin %90'ı eğitim verisi olarak, %10'u ise test verisi olarak ayrılmıştır. BTC için 4287 gözlem eğitim, 476 gözlem test verisi olarak belirlenmiştir. BNB için ise 2033 gözlem eğitim, 226 gözlem test verisi olarak ayrılmıştır. ETH için ise 2581 gözlem eğitim, 287 gözlem test verisi olarak belirlenmiştir. İlk olarak ARIMA modelinin d parametresinin belirlenmesi için değişkenlerin durağanlıkları ADF ve yapısal kırılmaları dikkate alan Fourier ADF birim kök testleri ile incelenmiştir. Her iki birim kök testi sonucuna göre tüm kripto para birimleri seviyede durağan $I(0)$ bulunmuştur. ARIMA-GARCH mı LSTM yöntemi mi daha iyi performans sergilediğini bulmak için çalışmada, belirlilik katsayısı, RSME ve MSE kriterleri kullanılmıştır. Çalışma sonuçlarına göre, Bitcoin (BTC) eğitim tahmini için LSTM modeli, test tahmini için ARIMA-GARCH daha iyi sonuç vermiştir. Binance (BNB) kripto para birimi tahmini için ise LSTM modeli, ARIMA-GARCH modeline göre daha başarılıdır. Ethereum (ETH) kripto para birimi tahmini için ise ARIMA-GARCH modeli, LSTM modeline göre daha başarılı bulunmuştur. Çalışmadaki bulgu Tanışman vd. (2021) çalışmasındaki sonuçla örtüşmektedir. Bu çalışmanın diğer çalışmadan farkı üç kripto para biriminin ilk kez getirileri ARIMA-GARCH hibrit modeli ve LSTM derin öğrenmesi kullanılması ve yapısal kırılmaları dikkate alan FADF testinin uygulanmasıdır. Gelecekte yapılacak çalışmalar olarak, kripto paraların gelecek tahminleri bu

yöntemlerle öngörüle bilinir ve modeller günlük veriler yerine saatlik, dakikalık vb. gibi daha sık veriler ile eğitilebilir.

Kaynakça

- Abar, H. (2021). BİST100 Endeksi için Fiyat Öngörüsü: ARIMA VE LSTM (Ed. Rençber, Ö. F.). *Veri Madenciliğinde Kullanılan Regresyon Modelleri ve R ile Uygulamalı Örnekler* içinde (s. 173-194). Ankara: Nobel.
- Akay, M. K., Canik, F., Yeşilyurt, C., & Günkut, M. Ş. (2022). Yapay Zekâ Teknikleri ile Kripto Para Değeri Tahmini. *Ekonomi Bilimleri Dergisi*, 14(1), 72-101.
- Aliyev, F., Eylasov, N., & Gasim, N. (2022). “Applying Deep Learning in Forecasting Stock Index: Evidence from RTS Index”. *2022 IEEE 16th International Conference on Application of Information and Communication Technologies (AICT), October 12- 14, 2022, Washington-USA*.
- Brockwell, P. J. & Davis, R. A. (2002). *Introduction to Time Series and Forecasting*, 2nd edition, New York: Springer-Verlag.
- Demirci, E. & Karaatlı, M. (2023). Kripto Para Fiyatlarının LSTM ve GRU Modelleri ile Tahmini. *Mehmet Akif Ersoy Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 10 (1), 134-157.
- Dickey, D. A., & Fuller, W. A. (1979). Distribution of the estimators for autoregressive time series with a unit root. *Journal of the American statistical association*, 74(366a), 427-431.
- Dickey, D. A., & Fuller, W. A. (1981). Likelihood ratio statistics for autoregressive time series with a unit root. *Econometrica: journal of the Econometric Society*, 1057-1072.
- Duggan, W. & Adams, M. (2024). “January 2024 Crypto Market Forecast” <https://www.forbes.com/advisor/investing/cryptocurrency/crypto-market-outlook-forecast/#:~:text=The%20total%20market%20capitalization%20of,%241.7%20trillion%20heading%20into%202024>. (Eriřim Tarihi: 30.01.2024).
- Dupuis, D. & Gleason, K. (2020). Money Laundering With Cryptocurrency: Open Doors And The Regulatory Dialectic, *Journal Of Financial Crime*. <https://www.emerald.com/insight/publication/issn/1359-0790>. (Eriřim Tarihi: 12.05.2023).
- Enders, W., & Lee, J. (2012). A unit root test using a Fourier series to approximate smooth breaks. *Oxford bulletin of Economics and Statistics*, 74(4), 574-599.
- Eylasov, N., Gasim, N., Aliyev, F., & Şahinler, A. N. (2023a). Impact of Renewable Energy Consumption on CO2 Emissions in Türkiye: Evidence from ARDL And Bayer-Hanck Cointegration Techniques. *Green Economics*, 1(2), 111-125.
- Eylasov, N., Zortuk, M., & Svilokos, T. (2023b). Investigating The Environmental Kuznets Curve Hypothesis with Energy Consumption for Türkiye: Evidence from Fourier ADF and ARDL Approach. *Journal of Modern Technology & Engineering*, 8(2), 140-153.
- Gasim, N., Şenyay, L. (2023). A Comparative Study on The Forecasting Performance of TimeVaryig Coefficient Models. Evidence from USD/TRY Exchange Rate. *Journal of Modern Technology & Engineering*, 8(2), 119-139.
- Graves, A. (2013). Generating sequences with recurrent neural networks. *arXiv preprint arXiv:1308.0850*.
- Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural computation*, 9(8), 1735-1780.
- Karçiođlu, A. A., Tanıřman, S., & Bulut, H. (2021). Türkiye'de COVID-19 Bulařısının ARIMA Modeli ve LSTM Ađı Kullanılarak Zaman Serisi Tahmini. *Avrupa Bilim ve Teknoloji Dergisi*, (32), 288-297.
- Kingma, D. P., & Ba, J. (2014). Adam: A method for stochastic optimization. *arXiv preprint arXiv:1412.6980*.
- Nakamoto, S. (2008). Bitcoin: A Peer to Peer Electronic Cash System. <https://bitcoin.org/bitcoin.pdf>. (Eriřim Tarihi: 16.05.2023).
- Odabařı, M. B., & Toklu, M. C. (2023). Yapay Sinir Ađları ve Derin Öğrenme Algoritmalarının Kripto Para Fiyat Tahmininde Karřılařtırılmalı Analizi. *Journal of Intelligent Systems: Theory and Applications*, 6(2), 96-107.
- Olah, C. (2015). Understanding LSTM. <http://colah.github.io/posts/2015-08-Understanding-LSTMs>. (Eriřim Tarihi: 12.05.2023).
- Sevinç, A., & Kaya, B. (2021a). Derin Öğrenme ve İstatistiksel Modelleme Yöntemiyle Sıcaklık Tahmini ve Karřılařtırılması. *Avrupa Bilim ve Teknoloji Dergisi*, (28), 1222-1228.

Sevinç, A., & Kaya, B. (2021b). Derin Öğrenme Yöntemleri ile Sıcaklık Tahmini: Diyarbakır İli Örneđi. *Computer Science*, (Special), 217-225.

Siame-Namini, S., Tavakoli, N., & Namin, A. S. (2018). “A comparison of ARIMA and LSTM in forecasting time series”. *2018 17th IEEE international conference on machine learning and applications (ICMLA), December 17-19, 2018, Orlando-USA*.

Şahin, E. E. & Özkan, O. (2018). Asimetrik Volatilitenin Tahmini: Kripto Para Bitcoin Uygulaması. *Bilecik Şeyh Edebali Üniversitesi Sosyal Bilimler Dergisi*, 3(2), 240-247.

Şahin, E. E. (2018). Kripto para Bitcoin: ARIMA ve yapay sinir ađları ile fiyat tahmini. *Fiscaoeconomia*, 2(2), 74-92.

Şahinler, A. N. (2022). Volatility Spillover Effects Between Green Bonds and Clean Energy Markets: A Time-Varying Granger Causality Perspective. *Discussions Between Economic Agents: Global Problems* (pp. 49-71). Cham: İksad Publishing House

Şahinler, A. N., Ozbugday, F. C., Basci, S., & Omay, T. (2024). Static and Dynamic Connectedness Between Green Bonds and Clean Energy Markets. *In The ESG Framework and the Energy Industry: Demand and Supply, Market Policies and Value Creation* (pp. 137-158). Cham: Springer International Publishing.

Şenol, D. & Denizhan, B. (2023). Kripto Para Deđerinin Yapay Sinir Ađları ile Tahmini. *Endüstri Mühendisliđi*, 34(1), 42-69.

Tanişman, S., Karciođlu, A. A., Uđur, A. & Bulut, H. (2021). LSTM Sinir Ađı ve ARIMA Zaman Serisi Modelleri Kullanılarak Bitcoin Fiyatının Tahminlenmesi ve Yöntemlerin Karşılaştırılması. *Avrupa Bilim ve Teknoloji Dergisi*, (32), 514-520.

Tretina, W. & Adams, M. (2024). “Top 10 Cryptocurrencies of February 2024” <https://www.forbes.com/advisor/investing/cryptocurrency/top-10-cryptocurrencies/>. (Erişim Tarihi: 30.01.2024).

Üzer, B. (2017). *Sanal Para Birimleri*. Uzmanlık Yeterlik Tezi, Türkiye Cumhuriyet Merkez Bankası Ödeme Sistemleri Genel Müdürlüğü, Ankara.

Vigna P. ve Casey J. (2015). *Kripto Para Çađı*, 2. Baskı, Ankara: Buzdađı Yayın Evi.