

ARAŞTIRMA MAKALESİ / RESEARCH ARTICLE

DOI: 10.52122/nisantasisbd.1648751

KRİPTO VARLIKLARDA UZUN HAFIZA VE VOLATİLİTE DİNAMİKLERİ:
BITCOIN, ETHEREUM VE BINANCE COIN ÖRNEĞİ

Dr. Öğr. Üyesi N. Melis ESENYEL İÇEN

İstanbul Üniversitesi, İktisat Fakültesi,
Ekonometri Bölümü.

e-posta: melis.esenyel@istanbul.edu.tr

ORCID 0000-0003-1150-2535

ÖZ

Bu çalışmada, kripto para piyasasında en yüksek işlem hacmine sahip varlıklar arasında yer alan Bitcoin, Ethereum ve Binance Coin'in günlük kapanış fiyatları incelenmiştir. Çalışmada ele alınan kripto para getirilerinin uzun hafıza özelliği gösterip göstermediğinin belirlenmesi ve uygun model tahmininin yapılması amaçlanmıştır. Getiri serilerinin uzun hafıza özelliğinin tespit edilmesi için literatürde sıklıkla ele alınan Hurst katsayısı, Geweke ve Porter-Hudak testi ve Yerel Whittle Tahmircisi kullanılmıştır. Ayrıca uzun hafızanın tespitine yönelik klasik testlerin yanı sıra, çok değişkenli yerel Whittle Skor tipi test ve Qu (2011) tarafından önerilen uzun hafıza testleri de yapılmıştır. Elde edilen bulgulara göre üç kripto para biriminin de uzun hafıza özelliği gösterdiği tespit edilmiştir. Ardından uzun hafızanın varlığı dikkate alınarak getiri ve koşullu varyansın modellenmesi için Otoregresif Kesirli Bütünleşik Hareketli Ortalama (ARFIMA) ve Kesirli Bütünleşik Genelleştirilmiş Otoregresif Koşullu Değişken Varyans (FIGARCH) modelleri tahmin edilmiştir. Tahmin edilen FIGARCH modellerinde kesirli fark parametresi $0 < d < 1$ şeklinde ve istatistiksel olarak anlamlıdır. Bu bulgu, kripto varlıkların uzun hafıza özelliğine sahip olduğunu ve şokların kalıcı etkiler yarattığını göstermektedir. Analize konu olan kripto varlık piyasalarında uzun hafıza olması, geçmiş fiyatların gelecek fiyatları öngörmek için kullanılabileceği anlamına gelmektedir.

Anahtar Kelimeler: Kripto para, Uzun hafıza, ARFIMA, FIGARCH**Jel Kodları:** C12, C58, E44LONG MEMORY AND VOLATILITY DYNAMICS IN CRYPTO ASSETS: THE CASES OF BITCOIN,
ETHEREUM, AND BINANCE COIN

ABSTRACT

In this research, the daily closing prices of Bitcoin, Ethereum, and Binance Coin-three of the most actively traded cryptocurrencies-are analyzed. The primary objective is to investigate whether these cryptocurrencies' returns exhibit long-memory characteristics and to apply suitable model estimations. To detect the presence of long memory in the return series, well-established techniques from the literature, such as the Hurst exponent, the Geweke and Porter-Hudak test, and the Local Whittle Estimator are utilized. Additionally, advanced methodologies, including the Multivariate Local Whittle Score-type test and the long-memory test formulated by Qu (2011), are implemented. The results confirm that all three cryptocurrencies exhibit persistent memory behavior. Given this evidence, ARFIMA and FIGARCH models are employed to examine both return dynamics and conditional volatility. The FIGARCH model estimations reveal that the fractional differencing coefficient falls between 0 and 1, maintaining statistical significance across all tested cases. These findings indicate that cryptocurrency markets demonstrate long-memory traits, implying that price shocks tend to have lasting effects. The presence of long memory in these markets further suggests that historical price patterns may serve as indicators for forecasting future price movements.

Keywords: Cryptocurrency, Long memory, ARFIMA, FIGARCH**Jel Codes:** C12, C58, E44

Geliş Tarihi/Received: 28.02.2025

Kabul Tarihi/Accepted: 28.05.2025

Yayın Tarihi/Printed Date: 30.06.2025

Kaynak Gösterme: ESENYEL İÇEN, N. M. (2025). "Kripto Varlıklarda Uzun Hafıza ve Volatilite Dinamikleri: Bitcoin, Ethereum Ve Binance Coin Örneği". *İstanbul Nişantaşı Üniversitesi Sosyal Bilimler Dergisi*, 1(13) 253-269.

GİRİŞ

Anonim bir kullanıcı olan Satoshi Nakamoto (Nakamoto, 2008) tarafından tanıtılan ilk dijital para birimi olan Bitcoin'in merkeziyetsiz yapısı, işlemlerdeki şeffaflık, güvenilir altyapısı, işlem hızı, işlem maliyetlerinin düşük olması gibi avantajları diğer kripto para birimlerinin de ortaya çıkışını hızlandırmıştır. Kripto para birimleri, uluslararası işlemlerde daha hızlı ve düşük maliyetle kullanılabilmeleri nedeniyle taşınabilirlik açısından itibari paraya göre bir avantaja sahiptir. Ayrıca, enflasyona direnç gösterme eğilimindedirler ve bu yüzden güvenli liman varlıkları olarak kabul edilirler (Garcia-Medina ve Aquayo-Moreno, 2024). Bununla birlikte kripto varlık piyasaları, geleneksel piyasalara kıyasla daha oynak ve alışılmadık davranışlar gösterme eğilimindedirler. Bu sebeple yatırımcıların herhangi bir kripto para biriminde işlem yaparken dikkatli olmaları gerekmektedir (Bouoiyour vd., 2016). Kripto varlıkların yüksek volatilitesine rağmen, bazı araştırmacılar bu piyasanın daha fazla çeşitlendirme sunduğunu ve kısa vadeli yatırım planları olan yatırımcılar için avantajlar sağladığını ortaya koymuşlardır (Briere vd., 2015).

Kripto paralar risk yönetimi ve piyasadaki büyük şokların öngörülmesinde kritik bir öneme sahip olduklarından özellikle riskten kaçan yatırımcılar tarafından tercih edilmektedir (Dyhrberg, 2016). Dolayısıyla kripto para piyasalarında, uzun hafıza özelliği ve Etkin Piyasa Hipotezi (Efficient Market Hypothesis-EMH) analizleri, özellikle ardışık finansal krizlerin meydana gelmesi durumunda portföy değerlendirmesi için önemlidir (Al-Yahyaee vd., 2020). Finansal piyasalarda etkinlik kavramı uzun zamandır yatırımcılar ve piyasa aktörleri tarafından ilgilenilen bir konu olmuştur. Piyasadaki varlık fiyatlarının rassal yürüyüş süreci izlediği ve piyasanın etkinliği kavramı ilk kez Fama (1965) tarafından ortaya konulmuştur. Fama (1965)'e göre, etkin bir piyasada herhangi bir zamanda menkul kıymetlerin gerçek fiyatları tahmin edilebilir. Başka bir deyişle, finansal varlık fiyatlarının mevcut tüm bilgiyi tam ve doğru bir şekilde yansıttığını ifade etmektedir. Roberts (1967) çalışmasında ise 'Etkin Piyasa Hipotezi (Efficient Market Hypothesis-EMH)' terimini ortaya atmış ve zayıf ve güçlü form testleri arasındaki ayrımı yapmıştır; bu ayrım, Fama (1970) çalışmasında klasik sınıflandırma haline gelmiştir. Bu hipotez, varlık fiyatlarının zaten geçmiş bilgileri yansıttığını ve yeni bilgi geldiğinde fiyatların hızla ayarlandığını, yani doğru bir şekilde fiyatlandığını gösterir (Fama, 1970). Dolayısıyla EMH'nin geçerli olduğu bir piyasada, ortalama getiri üzerinde kar elde edilemeyecektir. Aksine, uzun hafızanın varlığı durumunda, geçmiş varlık fiyatları kullanılarak gelecek fiyatları tahmin etme durumu söz konusu olmaktadır. Bu durumda uzun hafızanın varlığı EMH'yi geçersiz kılmaktadır. Ancak etkin olmayan bir piyasada getirilerin öngörülebilmesiyle anormal kar elde etmek mümkün olacaktır (Lim ve Brooks, 2011).

Piyasaların etkinliği ve varlık fiyatlarındaki volatiliteler birbirine bağlı kavramlardır. Finansal varlıklardaki fiyat dalgalanmaları, yatırımcıların hisse senetlerinin gelecekteki değerine ilişkin beklentilerini belirleyerek piyasanın etkinliğini etkilemektedir (Mensi vd., 2019). Bu sebeple volatilitenin doğru bir şekilde modellenmesi piyasa aktörleri açısından oldukça önemlidir. Doğru modellemenin yapılabilmesi için, finansal zaman serilerinin modellenmesinde dikkate alınması gereken unsurlar irdelenmelidir. Bu unsurlar, uygun varlık tahsisi sağlamanın yanı sıra, aşırı volatiliteden kaynaklanan kayıp ve zararlardan kaçınmaya yardımcı olmaktadır. Uzun hafıza, bu kapsamda dikkate alınması gereken unsurlardan biridir (Hosking, 1981). Eğer piyasa uzun hafıza özelliği göstermiyorsa, geçmiş olaylar bugünün varlık fiyatını etkilemeyecektir (Burton, 1987). Dolayısıyla yatırımcılar ve portföy yöneticileri, gelecekteki kayıplardan kaçınmak için uzun hafızanın finansal varlık üzerindeki etkisini bilmek isteyeceklerdir. Uzun hafızanın dikkate alınmaması, spesifikasyon hatalarına ve yanlış tahminlere sebep olabilir. Tersine, uzun hafıza özelliği göstermeyen bir seride yanıltıcı bir şekilde uzun hafızanın varlığının tespit edilmesinde de benzer durum söz konusudur. Etkin piyasa hipotezi kapsamında bu, piyasa gerçekte etkin iken, etkin olmadığı sonucuna ulaşılmasına sebep olabilir (Dehling vd., 2013; Iacone vd., 2014; Betken, 2016; Wenger vd., 2018).

Kripto para piyasasının etkinliği, kripto varlıkların uzun hafıza yapısı ve volatiliteler tahmini konularında literatürde birçok çalışma yapılmıştır. Çalışmalar incelendiğinde kripto varlıklar arasında Bitcoin'e daha çok yoğunlaşılmış olmakla birlikte, diğer kripto varlıkların da analiz edildiği görülmektedir. Çalışmaların bazıları kripto varlıkların sadece uzun hafızaya sahip olup olmadığına odaklanırken, bazılarında uzun hafıza ile GARCH-tipi model tahminleri yapılmıştır.

Çalışmaların özeti Tablo 1’de verilmiştir. Çalışmalarda ortak bulgu olarak kripto varlık piyasasında uzun hafıza olduğu söylenebilmektedir.

Tablo 1: Kripto para piyasalarında uzun hafıza ve volatilité tahmini üzerine yapılmış çalışmalar

Yazar(lar)	Kripto para	Yöntem
Mensi vd. (2019)	BTC, ETH	GARCH, FIGARCH, FIAPARCH, HYGARCH
Güleç ve Aktaş (2019)	BTC, LTC, ETH, XRP	FIGARCH, FIEGARCH, FIAPARCH
Akkuş ve Çelik (2020)	BTC	R/S, FIGARCH, FIAPARCH, HYGARCH
Al-Yahyaee vd. (2020)	BTC, DASH, ETH, LTC, XMR, XRP	R/S, GSP, GPH, MF-DFA, QR
Kaya Soylu vd. (2020)	XRP, ETH, BTC	R/S, GSP, GPH
Fakhfekh ve Jeribi (2020)	16 kripto para	R/S, GARCH tipi modeller
Rambaccussing ve Mazibas (2020)	BTC, LTC, ETH, BCH, XRP	GPH, Bias test, skip-sampling test
Chkili (2021)	BTC	GPH, GSP, GARCH, FIGARCH, MS-GARCH
Lahmiri ve Bekiros (2021)	45 kripto para	FIGARCH
Kim vd. (2021)	BTC, XRP, ETH, BCH, XLM, LTC, TRX, ADA, IOTA	Bayesyen SV, GARCH tipi modeller
Duan vd. (2021)	BTC	FELW, FCVAR
Hameed vd. (2021)	BTC, ETH, LTC	R/S
Catania ve Grassi (2022)	606 kripto para	Beta-Skew-t-EGARCH
Assaf vd. (2022)	BTC, LTC, ETH, XRP, XMR, DASH	Hurst, FCA
Fleischer vd. (2022)	EOS	LSTM
Wu vd. (2022)	BTC, ETH, BNB, S&P500, altın	DFA
Gubadlı ve Sarıkovanlı (2023)	BTC, XLM, LTC, ETH, USDT, XRP	SV, MCMC
Khan vd. (2023)	BTC, ETH, XRP, USDT	NNETAR, CSS, GMDH-NN
Münyas ve Aydın (2023)	BTC, BNB, ADA, DOGE, ETH, USDT, XRP	Panel birim kök testleri
Nur vd. (2023)	BTC	GARCH-LSTM
Wang vd. (2023)	BTC, ETH, LTC, XRP	GARCH, RF, LSTM
Demirci ve Karaatlı (2023)	BTC, ETH, XRP	RNN, LSTM, GRU
Assaf vd. (2023)	BTC, ETH, LTC, XMR, XLM, TRX, EOS	MLWS, Qu, FCA
Garcia-Medina ve Aguayo-Moreno (2024)	10 kripto para	MLP, GARCH, LSTM, LSTM-GARCH
Yurttagüler (2024)	BTC	GPH

Not: FCA; fraktal bağlantı (connectivity) analizi, FCVAR; kesirli eşbütünlük VAR modeli, FELW; Feasible Exact Local Whittle tahmincisi, GMDH-NN; veri işleme grup yöntemi sinir ağları, GPH; Geweke and Porter-Hudak (1983) testi, GRU; geçitli yinelenen birim, GSP; Gaussian semiparametric test, LSTM; uzun kısa süre hafıza, MCMC; Markov zinciri Monte Carlo, MF-DFA; çoklu fraktal trendden arındırılmış dalgalanma analizi, MLWS; çok değişkenli yerel Whittle uzun hafıza testi, MS-GARCH; Markov switching-GARCH, NNETAR; sinir ağı otoregresif model, QR; kantil regresyon, Qu; Qu (2011) tarafından önerilen uzun hafıza testi, RF; rastlantısal orman, RNN; tekrarlayan sinir ağları, CSS; cubic smoothing spline, SV; stokastik volatilité modeli.

Çalışmada yüksek işlem hacmine sahip ilk 3 kripto para ele alınmıştır. Çalışmada ele alınan kripto para getirilerinin uzun hafıza özelliği gösterip göstermediğinin belirlenmesi ve uygun model tahmininin yapılması amaçlanmıştır. Getiri serilerinin uzun hafıza özelliğinin tespit edilmesi için literatürde sıklıkla ele alınan Hurst katsayısı, Geweke ve Porter-Hudak (GPH) (1983) testi ve Robinson (1995) tarafından önerilen Yerel Whittle Tahmircisi (Local Whittle Estimator-LW) kullanılmıştır. Bunlara ek olarak, Sibbertsen, Leschinski ve Holzhausen (2018) tarafından önerilen çok değişkenli yerel Whittle Skor tipi test (multivariate local Whittle score type-MLWS) ve Qu (2011) tarafından önerilen uzun hafıza testleri de yapılmıştır. Bu testlerde, sıfır hipotez gerçek uzun hafızayı, alternatif hipotez ise sahte uzun hafızayı temsil etmektedir. Yapılan analizler sonucunda uzun hafızanın varlığı durumunda ARFIMA ve FIGARCH model tahminleri yapılmıştır.

Mevcut literatür incelendiğinde, kripto para piyasalarında uzun hafıza analizi genellikle Hurst katsayısı, GPH veya LW testleri gibi klasik yöntemlerle sınırlı kalmakta; MLWS ve Qu gibi çok değişkenli ve daha güncel yöntemlerin uygulaması ise oldukça sınırlı sayıda çalışmada görülmektedir. Ayrıca, mevcut literatürde ya yalnızca klasik testler kullanılarak kripto para getirilerinin uzun hafıza yapısı araştırılmakta ya da bu testler yapılmadan doğrudan ekonometrik modelleme yöntemlerine başvurulmaktadır. Bu çalışmada ise, hem klasik hem de yeni nesil uzun hafıza testleri sistematik olarak uygulanmış, ardından uzun hafıza tespitine dayalı olarak ARFIMA ve FIGARCH gibi gelişmiş ekonometrik modellerle volatilité analizleri gerçekleştirilmiştir. Böylece, kripto para piyasalarında uzun hafıza ve volatilité dinamiklerinin bütüncül ve yöntemsel çeşitlilik içeren bir yaklaşımla incelenmesi sağlanmıştır.

Çalışmanın ilerleyen bölümlerinde, ilk olarak kullanılan yöntemler detaylı şekilde özetlenmiştir. Ardından kripto varlıklara ilişkin veri seti ve ampirik sonuçlar açıklanmıştır. Nihai olarak, son bölümde ise bölümde çalışmanın bulgularına yönelik sonuç ve değerlendirmeler sunulmuştur.

1. Yöntem

1.1. Uzun Hafızanın Testi ve Modellenmesi

Kesirli bütünleşik model Denklem (1)'deki gibi ifade edilebilir.

$$(1 - L)^d y_t = \varepsilon_t \quad (1)$$

Burada L gecikme operatörü, d kesirli fark parametresi, y_t zaman serisi ve ε_t *iid* dağılıma sahip hata terimini ifade etmektedir. d parametresi, y_t zaman serisinin hafıza yapısını tanımlamaktadır. Hosking (1981)'e göre sürecin davranışı aşağıdaki gibi özetlenebilir.

- i) $-0.5 < d < 0.5$ ise süreç durağan ve çevrilebilir;
- ii) $d = 0$ ise süreç durağan ve kısa hafızalı;
- iii) $d = 1$ ise birim kök süreci (rassal yürüyüş);
- iv) $0 < d < 0.5$ ise süreç durağan ve uzun hafızalı (gözlemler arasında pozitif bağımlılık);
- v) $-0.5 < d < 0$ ise süreç zıt yönlü hafızaya (gözlemler arasında negatif bağımlılık) sahiptir.

Kalıcı (persistent) otoregresif terimlere sahip kısa hafızalı süreçler, uzun hafızalı bir süreçle karıştırılabilir. Uzun hafıza ile bu tür süreçler arasındaki temel fark, y_t 'nin kovaryans davranışdır. Bir durağan süreç olan y_t 'nin otokovaryansını γ_j ile ifade edersek, kısa hafızalı bir sürecin toplanabilir bir otokovaryans fonksiyonu ($\sum_{j=0}^{\infty} |\gamma_j| < \infty$) var iken, uzun hafızalı sürecin otokovaryans fonksiyonu toplanabilir değildir ($\sum_{j=0}^{\infty} |\gamma_j| = \infty$) ve bu süreçte spektral yoğunluk sıfır noktasında sonsuzdur ($f(0) = \infty$). Benzer şekilde, uzun hafızalı bir süreçte yakınsama hızı $\gamma_j = O(j^{2d-1})$ iken, kısa hafızalı bir süreçte yakınsama daha hızlıdır ve $\gamma_j = o(j^{2d-1})$ şeklinde ifade edilebilir (Rambaccussing ve Mazibas, 2020). Bu sebepe uzun ve kısa hafıza durumunu birlikte dikkate alan model ihtiyacı doğmaktadır. Bu bağlamda Otoregresif Kesirli Bütünleşik Hareketli Ortalama (Autoregressive Fractional Integrated Moving Average-ARFIMA) modeli aşağıdaki gibi ifade edilebilir.

$$\Psi(L)(1 - L)^d(y_t - \mu) = \theta(L)\varepsilon_t, \quad \varepsilon_t = z_t\sigma_t, \quad \varepsilon_t \sim iid(0, \sigma_\varepsilon^2) \quad (2)$$

Burada $\Psi(L) = 1 - \sum_{i=1}^p \psi_i L^i$ ve $\Theta(L) = 1 - \sum_{j=1}^q \theta_j L^j$ olup, modelin kısa hafıza özelliğini ifade etmektedir. Kesirli fark parametresi d sıfıra eşit olduğunda, Denklem (1) daha hızlı bir yakınsamaya sahip olan basit bir otoregresif hareketli ortalama modeli (Autoregressive Moving Average-ARMA) haline gelmektedir.

ARFIMA modeli, zaman serilerinin uzun dönemli bağımlılık yapısını analiz etmek için kullanılır. Ancak birçok finansal zaman serisi, yalnızca getirilerde uzun hafıza değil, aynı zamanda volatilité dinamiklerinde de uzun hafıza barındırır. Getiri serilerinin varyansı zamanla değişen yapıya sahip olabilir ve volatilité kümelenmesi sıkça gözlemlenir. Bu durumda, ARFIMA modeli, volatilitenin hafıza yapısını yakalamakta yetersiz kalabilir (Baillie vd., 1996). ARFIMA modellemesinde, eğer getiri serisinin koşullu varyansı sabit değilse ve şokların etkisinin uzun süre devam ettiği gözlemleniyorsa, Kesirli Bütünleşik Genelleştirilmiş Otoregresif Koşullu Değişen Varyans (Fractionally Integrated Generalized Autoregressive Conditional Heteroskedasticity-FIGARCH) modellemesine geçilmesi gerekir. Baillie, Bollerslev ve Mikkelsen (1996) tarafından geliştirilen FIGARCH(1,d,1) modeli, Denklem (3) ile ifade edilebilir.

$$\sigma_t^2 = \omega[1 - \beta(L)]^{-1} + [1 - [1 - \beta(L)]^{-1}\varphi(L)(1 - L)^d]\varepsilon_t^2 \quad (3)$$

Burada ω , β , φ ve d sırasıyla sabit terim, GARCH terimi, ARCH terimi ve uzun hafıza parametresidir. Kesirli fark operatörü $(1 - L)^d$, koşullu volatilitenin uzun hafıza yapısını belirlemektedir. d değerinin 0 ile 1 arasında olması, zaman serisinin volatilitesinde uzun hafızanın var olduğu anlamına gelmektedir.

Uzun hafızanın varlığında, bir serinin gerçekten ilişkili bir d değerine sahip olup olmadığını belirlemek oldukça önemlidir. Uzun hafızanın tespiti için iki aşamalı bir prosedür önerilmektedir (Rambaccussing ve Mazibas, 2020). Öncelikle, Geweke ve Porter-Hudak (GPH) ya da yerel Whittle (Local Whittle-LW) tahminçileri kullanılarak d parametresinin anlamlılığı test edilmektedir. Bu aşamada d istatistiksel olarak anlamsız çıkarsa, ikinci aşamada literatürdeki daha formal testler uygulanmaktadır.

1.1.1. Hurst Üsteli

Çalışmada serilerin uzun hafıza özelliklerini değerlendirmek amacıyla kullanılan yöntemlerden ilki Hurst üstelidir. Hurst üsteli (H), bir zaman serisinin uzun dönemli bağımlılık derecesini ölçen yaygın bir göstergedir. H değeri 0.5'ten büyükse seride uzun hafıza olduğu kabul edilirken, 0.5'e eşit olması serinin rastgele yürüyüş (white noise) özelliği gösterdiğine işaret etmektedir. Bununla birlikte, Hurst üsteli ile kesirli bütünleşme parametresi arasında $H = d + 0.5$ şeklinde teorik bir ilişki bulunmaktadır (Hosking, 1981; Baillie, 1996). Bu bağlamda, Hurst üsteli ve d parametresi birlikte yorumlanarak serilerin uzun hafıza davranışı değerlendirilmektedir.

1.1.2. Geweke ve Porter-Hudak (GPH) Testi

Geweke ve Porter-Hudak (1983), kesirli bütünleşik süreçlerde uzun dönem hafızayı test etmek için yarı parametrik bir yaklaşım önermişlerdir. Bu yöntem ile d parametresi tahmin edilmeye çalışılmaktadır. Fourier dönüşümü ve spektral yoğunluk yardımıyla hesaplanan GPH tahmincisi aşağıdaki gibi ifade edilebilir.

$$\log(I(\omega_j)) = \beta_0 + \beta_1 \log\left(4 \sin^2\left(\frac{\omega_j}{2}\right)\right) + \varepsilon_j \quad (4)$$

Burada $\omega_j = 2\pi j/T$ ($j = 1, 2, \dots, \sqrt{T}$) şeklinde olup Fourier frekansını ve ε_j hata terimini temsil etmektedir. $I(\omega_j)$, aşağıdaki gibi tanımlanan örnek periyodogramı ifade etmektedir.

$$I(\omega_j) = \frac{1}{2\pi T} \left| \sum_{t=1}^T r_t e^{-i\omega_j t} \right|^2 \quad (5)$$

Burada r_t , getiri serisini temsil etmektedir ve kovaryans durağan bir zaman serisi olduğu varsayılmaktadır. Kesirli fark parametresi d 'nin tahmini $\hat{d}_{GPH} = -\hat{\beta}_1$ şeklindedir. GPH testinde, sıfır hipotezi “uzun hafıza yoktur ($d=0$)” olarak ifade edilmektedir.

1.1.3. Yerel Whittle (Local Whittle-LW) Testi

Uzun hafıza parametrelerinin yarı-parametrik tahmini, teorik ve ampirik açılarından zaman serisi literatüründe oldukça yaygın bir kullanım alanı bulmuştur. Bu yöntemler, parametrik yaklaşımın aksine, modelin kısa dönem yapısı üzerinde herhangi bir varsayımda bulunmamaktadır. Spektral yoğunluğu $f(\lambda)$ olan kovaryans durağan bir süreç için yarı-parametrik yaklaşım, Denklem (6) ile verilen yerel yaklaşımla ifade edilir.

$$f(\lambda) \sim G|\lambda|^{-2d} \quad , \quad \lambda \rightarrow 0 \quad (6)$$

Burada, G pozitif sonlu sabit, $-1/2 < d < 1/2$ ve “ $\sim$ ” ilişkinin sol ve sağ tarafları arasındaki oranın $\lambda \rightarrow 0$ iken bire yaklaştığını belirtmektedir (Garcia-Enriquez ve Hualde, 2019).

Denklem (6)'da, $d > 0$ olduğunda f fonksiyonunun $\lambda = 0$ noktasında bir kutbu (pole) vardır. d parametresini tahmin etmek için GPH yaklaşımının yanı sıra Kuensch (1987) ve Robinson (1995) tarafından önerilen yerel Whittle (local Whittle-LW) yaklaşımı da sıklıkla kullanılmaktadır. Robinson (1995), Kuensch (1987)'ün önerisine dayanarak, d parametresinin Gaussian yarı-parametrik tahminini, Denklem (7) ile verilen log-olabilirlik fonksiyonunun minimizasyonu ile elde etmiştir.

$$\mathcal{L}_m(d, G) = \frac{1}{m} \sum_{j=1}^m \left\{ \log G \lambda_j^{-2d} + \frac{I_X(\lambda_j)}{G \lambda_j^{-2d}} \right\} \quad (7)$$

Bu süreç, söz konusu frekanslar için geçerli olan yarı-parametrik model Denklem (6) kullanılarak gerçekleştirilmiştir. d parametresinin kabul edilebilir tahmin aralığı $D = [\nabla_1, \nabla_2]$, $-\frac{1}{2} < \nabla_1 < \nabla_2 < \frac{1}{2}$ olmak üzere, LW tahminleri aşağıdaki gibi ifade edilebilir (Velasco, 2006).

$$(\hat{d}_m^{LW}, \hat{G}_m^{LW}) = \arg \min_{d \in D, 0 < G < \infty} \mathcal{L}_m(d, G) \quad (8)$$

Denklem (8)'de $\hat{G}_m^{LW}$ 'yi modelden çıkarırsak Denklem (9) elde edilmektedir.

$$\hat{d}_m^{LW} = \arg \min_{d \in D} R_m(d) \quad (9)$$

Burada, $R_m(d) = \log \hat{G}_m^{LW}(d) - 2d \frac{1}{m} \sum_{j=1}^m \log \lambda_j$ ve $\hat{G}_m^{LW}(d) = \frac{1}{m} \sum_{j=1}^m \lambda_j^{2d} I_X(\lambda_j)$ şeklindedir. Spektral yoğunluğu Log-periodogram (LP) tahmini ile aynı düzenlilik koşullarını sağlayan homoskedastik martingale fark şoklarına sahip doğrusal zaman serileri için Robinson (1994), d tahmincisinin tutarlı olduğunu ve asimptotik normal dağılımının $2m^{\frac{1}{2}}(\hat{d}_m^{LW} - d) \xrightarrow{d} N(0,1)$ olduğunu göstermiştir. Dolayısıyla frekans sayısı aynı olduğunda LW tahmincisi, LP tahmincisine göre daha etkindir (Velasco, 2006).

2. Veri Seti ve Bulgular

Bu çalışmada, kripto para piyasasında en yüksek işlem hacmine sahip varlıklar arasında yer alan Bitcoin (BTC), Ethereum (ETH) ve Binance Coin (BNB)'in günlük kapanış fiyatları incelenmiştir. İlgili veriler, güvenilir bir kaynak olan CoinMarketCap platformundan temin edilmiştir. Fiyat serilerinin başlangıç tarihleri, her bir kripto varlık için sırasıyla 28 Aralık 2013 (BTC), 9 Ağustos 2015 (ETH) ve 27 Temmuz 2017 (BNB) olarak belirlenmiştir. Tüm seriler için analiz dönemi 6 Ekim 2024 tarihinde sonlandırılmıştır. Çalışmada, fiyat serileri logaritmik getirilere dönüştürülerek ekonometrik analize tabi tutulmuştur. Böylece, serilerin getirilerindeki olası yapısal özellikler ve volatilité dinamikleri daha net bir şekilde incelenmiştir. Çalışmada kullanılan


tüm ekonometrik analizler R yazılımı ile yapılmıştır. Şekil 1'de, ilgili kripto paraların fiyat ve logaritmik getiri serilerine ait grafikler sunulmaktadır.

Kripto para getirilerinin özet istatistikleri ve birim kök test (ADF, PP) sonuçları Tablo 2'de verilmiştir. Ortalama kripto para getirileri pozitif iken, standart sapma ile ölçülen koşulsuz volatilité Ethereum ve Binance Coin'de görece yüksektir. ETH ve BNB getirilerinin çarpıklığı pozitif iken, basıklığın tüm kripto para getirileri için üçten büyük olduğu görülmektedir. Bu da kripto para getirilerinin normal dağılıma göre daha kalın kuyruğa sahip olduğunu ifade etmektedir. Jarque-Bera test istatistikleri %5 düzeyinde anlamlı olup, normal dağılımdan sapmayı doğrulamaktadır. Engle (1982) tarafından önerilen ARCH testi, getirilerde 5 ve 10 gecikme için değişen varyansın varlığını göstermekte ve bu durum bizi GARCH tipi modeller kullanmaya yönlendirmektedir. Panel B'deki Genişletilmiş Dickey-Fuller (ADF) ve Phillips-Perron (PP) testlerinin sonuçlarına göre, iki test istatistiğinin de %5 önem düzeyinde anlamlı olduğu görülmektedir. Dolayısıyla, ele alınan seriler için birim kök sıfır hipotezi reddedilmektedir ve kripto para getirilerinin durağan olduğu söylenebilmektedir.

Tablo 2: Kripto para getirilerine ait özet istatistikler ve birim kök testleri

Panel A: Özet istatistikler			
	<i>BTC</i>	<i>ETH</i>	<i>BNB</i>
<i>Ortalama</i>	0.113	0.242	0.327
<i>Std. sapma</i>	3.7	5.448	5.986
<i>Çarpıklık</i>	-0.733	0.024	1.022
<i>Basıklık</i>	13.907	12.084	22.853
<i>JB</i>	19862.787 (0)	11507.415 (0)	43630.867 (0)
<i>Q²(5)</i>	4.954 (0.422)	11.001 (0.051)	57.446 (0)
<i>Q²(10)</i>	19.013 (0.04)	17.99 (0.055)	101.068 (0)
<i>ARCH(5)</i>	92.983 (0)	193.012 (0)	371.606 (0)
<i>ARCH(10)</i>	123.932 (0)	211.637 (0)	402.374 (0)
<i>Gözlem sayısı</i>	3936	3347	2629
Panel B: Birim kök testleri			
<i>ADF</i>	-14.927 (0.01)	-13.603 (0.01)	-12.481 (0.01)
<i>PP</i>	-4173.24 (0.01)	-3515.583 (0.01)	-2977.26 (0.01)

Not: Parantez içindeki değerler olasılıkları ifade etmektedir.



Şekil 1: Kripto para fiyat ve getiri grafikleri

Analizin ilk aşamasında, koşullu volatilitede uzun hafızanın varlığı araştırılmıştır. Çalışmada koşullu volatilité göstergesi olarak mutlak ve kareli getiri serileri kullanılmıştır. Uzun hafızanın varlığının araştırılması için Hurst katsayısı, Geweke ve Porter-Hudak'ın (1983) log periodogram regresyonu (GPH) testi ve Robinson'un (1995) yerel Whittle (LW) testi kullanılmıştır ve test sonuçları Tablo 3'te raporlanmıştır.

Tablo 3: Uzun hafıza test sonuçları

Kripto varlık	BTC	ETH	BNB
Panel A: Mutlak getiri			
R/S Hurst	0.69	0.71	0.73
Ampirik Hurst	0.83	0.82	0.94
Teorik Hurst	0.53	0.53	0.53
<i>GPH</i>			
d	0.2933*** (0.0367)	0.3333*** (0.0390)	0.3950*** (0.0427)
<i>Yerel Whittle</i>			
d	0.3038*** (0.0276)	0.3043*** (0.0292)	0.3733*** (0.0318)
<i>MLWS uzun hafıza testi</i>			
Wald istatistiği	0.8688	0.6086	0.8564
<i>Qu uzun hafıza testi</i>			
Wald istatistiği	0.9308	0.5166	0.9529
Panel B: Kareli getiri			
R/S Hurst	0.62	0.67	0.67
Ampirik Hurst	0.71	0.71	0.81
Teorik Hurst	0.53	0.53	0.53
<i>GPH</i>			
d	0.1896*** (0.0367)	0.2149*** (0.0390)	0.3075*** (0.0427)
<i>Yerel Whittle</i>			
d	0.1683*** (0.0276)	0.2055*** (0.0292)	0.2758*** (0.0318)
<i>MLWS uzun hafıza testi</i>			
Wald istatistiği	0.6093	0.7265	0.8753
<i>Qu uzun hafıza testi</i>			
Wald istatistiği	0.6685	0.6348	0.9723

Not: *, **, *** sırasıyla %10, %5, %1 anlamlılık düzeylerini göstermektedir. Bant genişliği m=0.7 olarak alınmıştır. Parantez içindeki değerler standart hataları göstermektedir. MLWS ve Qu uzun hafıza testleri için %5 anlamlılık düzeyinde Ki-Kare tablo değeri 1.252'dir.

Panel A için Hurst katsayıları incelendiğinde üç kripto para için de katsayıların 0.5'ten büyük olduğu görülmektedir. Bu da kripto para piyasalarında kalıcılık (persistence) olduğu, başka bir deyişle piyasaların uzun hafıza özelliği gösterdiği anlamına gelmektedir. Bununla birlikte, Hurst katsayısı büyüdükçe piyasanın kalıcılığı artmaktadır. Buna göre, klasik ve ampirik Hurst katsayısına göre BinanceCoin piyasasının daha kalıcı olduğu söylenebilmektedir. Teorik Hurst katsayısına göre ise üç kripto varlık piyasasının kalıcılıkları aynıdır. Panel B'de verilen Hurst katsayılarının da, Panel A'ya benzer şekilde, 0.5'ten büyük olduğu görülmektedir. Buna göre klasik Hurst katsayısına göre Ethereum ve Binance Coin'in kalıcılıkları aynı iken, ampirik Hurst katsayısına göre Binance Coin piyasası daha kalıcıdır. GPH ve LW test sonuçlarına göre, her üç kripto para için de uzun hafıza parametreleri istatistiksel olarak anlamlı bulunmuştur. Dolayısıyla hem Panel A hem de Panel B için uzun hafızanın var olduğunu söyleyebiliriz. Uzun hafızanın tespitine yönelik klasik testlerin yanı sıra, Sibbertsen, Leschinski ve Holzhausen (2018) tarafından önerilen MLWS testi ve Qu (2011) tarafından önerilen Qu testi sonuçlarına da Tablo 3'te yer verilmiştir. Panel A ve Panel B'de verilen test sonuçlarına göre tüm durumlarda gerçek uzun hafızayı belirten sıfır hipotezi %5 anlam düzeyinde reddedilememiştir. Dolayısıyla kripto para mutlak ve kareli getirilerin gerçek uzun hafızaya sahip olduğu söylenebilmektedir. Uzun hafızanın tespitine yönelik yapılan tüm testlerde ortak kanıya varıldığından, öncelikle ARFIMA modelleri tahmin edilmiştir.

ARFIMA(p, d, q) modelinin uygun parametrelerinin belirlenmesinde *rugarch::autoarfima* fonksiyonu kullanılmıştır. Model seçimi sürecinde, AR ve MA parametreleri için maksimum 5'e kadar tüm olası AR ve MA kombinasyonları değerlendirilmiş ve en düşük AIC (Akaike Bilgi Kriteri) değerine sahip model seçilmiştir. ARFIMA modellerinin tahmin edilmesinin ardından, model kalıntılarında ARCH etkisinin olup olmadığını test etmek amacıyla ARCH LM testi uygulanmıştır. ARFIMA modellerinin parametre tahminleri ve ARCH LM test sonuçları Tablo 4 (Panel A)'te raporlanmıştır. Elde edilen sonuçlar incelendiğinde, ARCH LM testinde, seride ARCH etkisi olmadığını ifade eden sıfır hipotezin reddedildiği görülmektedir. Bu bulgu, serilerde ARCH etkisinin varlığını göstermekte ve volatilité modellerinin kullanılmasının gerekli olduğunu ortaya koymaktadır. Bu sebeple, serilerdeki volatilité dinamiklerini ve uzun hafıza özelliğini daha ayrıntılı olarak inceleyebilmek amacıyla ARFIMA-FIGARCH modeli tahmin edilmiştir ve sonuçlar Tablo 4 (Panel B)'te verilmiştir.

Tablo 4: ARFIMA-FIGARCH modeli tahmin sonuçları

Kripto varlık	BTC	ETH	BNB
<i>Panel A: ARFIMA model tahmini</i>			
d	0.0358* (0.0186)	0.0688*** (0.0189)	0.1373*** (0.0188)
Ar1	-	-0.0625** (0.0251)	-1.0754*** (0.0081)
Ar2	-	-	-0.0890*** (0.0236)
Ma1	0.0631** (0.0250)	-	-0.9840*** (0.0214)
ARCH LM (7)	114.53***	230.73***	343.76***
<i>Panel B: ARFIMA-FIGARCH model tahmini</i>			
μ	0.1548*** (0.0484)	0.1731* (0.1018)	0.0488 (0.1048)
Ar1	-	-0.0512 (0.0313)	0.8167*** (0.0595)
Ar2	-	-	0.0943** (0.0397)
Ma1	-0.0555* (0.0314)	-	-0.9439*** (0.0117)
d_m	0.0391 (0.0246)	0.0485* (0.0250)	0.1060* (0.0590)
ω	0.6928*** (0.1203)	1.4308*** (0.2998)	0.8297*** (0.2180)
α_1	0.2662*** (0.0410)	0.1377** (0.0566)	0.0734 (0.0604)
β_1	0.5915*** (0.0521)	0.4346*** (0.0693)	0.4410*** (0.0707)
d_v	0.4714*** (0.0559)	0.4273*** (0.0476)	0.5161*** (0.0474)
<i>Panel C: Diagnostik testler</i>			
Ljung-Box Q	1.5546 (5) [0.7265]	2.8096 (5) [0.4429]	3.1714 (5) [0.3766]
	2.3790 (9) [0.8553]	4.7186 (9) [0.4719]	5.8509 (9) [0.3157]
ARCH LM	2.310 (7) [0.6518]	5.502 (7) [0.1785]	0.6572 (7) [0.0766]
Log-olabilirlik	-10394	-9965.937	-7626.777
AIC	5.2851	5.9593	5.8089
BIC	5.2962	5.9721	5.8290

Not: *, **, *** sırasıyla %10, %5, %1 anlamlılık düzeylerini göstermektedir. Panel A'da parantez içindeki değerler standart hataları, Panel B'dekiler ise Ljung-Box Q ve ARCH LM testinin gecikmelerini ifade etmektedir. Köşeli parantez içindeki değerler olasılık değeridir. d_m ve d_v sırasıyla ortalama ve volatilité modellerinin kesirli fark parametrelerini ifade etmektedir.

BTC, ETH ve BNB için yapılan ARFIMA-FIGARCH model tahminleri, her bir kripto paranın farklı getiriler ve volatilité dinamiklerine sahip olduğunu göstermektedir. Panel B’de verilen ARFIMA FIGARCH model tahminlerine bakıldığında, tüm kripto varlıklar için uzun hafıza parametresi d_v , 0.5’e yakındır ve %1 düzeyinde istatistiksel olarak anlamlıdır. Bu bulgu, kripto varlıkların uzun hafıza özelliğine sahip olduğunu ve şokların kalıcı etkiler yarattığını göstermektedir ve bu bulgu, kripto piyasalarında volatilité şoklarının kalıcı etkiler taşıdığını vurgulayan çok sayıda akademik çalışmayla uyumludur. Analize konu olan kripto varlık piyasalarında uzun hafıza olması, geçmiş fiyatların gelecek fiyatlarını öngörmek için kullanılabileceği anlamına gelmektedir. BTC ve ETH için tahmin edilen modelde, α_1 ve β_1 parametrelerinin anlamlı bulunması volatilitenin hem gecikmeli hata hem de varyans bileşenleri tarafından açıklandığını ve geleneksel GARCH etkilerinin devam ettiğini göstermektedir. Bununla birlikte, BNB için volatilitenin gecikmeli hata terimi (α_1) anlamlı değildir; bu da BNB’de volatilitenin ARCH bileşeniyle yeterince açıklanamadığı, daha çok GARCH (gecikmeli varyans bileşeni) ve uzun hafıza etkileriyle açıklandığı anlamına gelmektedir. Tahmin edilen modeller için yapılan diagnostik test sonuçları ise Panel C’de verilmiştir. Ljung-Box Q testine göre, ARFIMA-FIGARCH modellerinin kalıntılarında otokorelasyon etkisinin olmadığı söylenebilir. ARCH LM testine göre de, kalıntılarda ARCH etkisinin olmadığını belirten sıfır hipotezi reddedilememiştir. Bu durumda ARFIMA-FIGARCH modellerinin kalıntılarında ARCH etkisinin bulunmadığı söylenebilir. Bu sonuçlar, tahmin edilen ARFIMA-FIGARCH modellerinin artıklarının model yeterliliği açısından tatmin edici olduğunu göstermektedir.

SONUÇ VE DEĞERLENDİRME

Bu çalışmada, Bitcoin, Ethereum ve Binance Coin gibi yüksek işlem hacmine sahip kripto varlıkların fiyat dinamikleri, uzun hafıza modelleriyle detaylı olarak incelenmiştir. Bulgular, tüm kripto varlıkların fiyat ve getiri serilerinde uzun hafıza özelliklerinin mevcut olduğunu ortaya koymaktadır. Hurst katsayılarının 0.5’ten büyük olması, piyasalarda kalıcılık özelliğinin varlığını ve fiyat şoklarının uzun süreli etkiler yarattığını göstermektedir. Üç kripto para birimi için farklı uzun hafıza ölçümleri sonucunda piyasaların farklı kalıcılık derecelerine sahip olduğu belirlenmiştir. Öyle ki, mutlak getiriler için hesaplanan klasik ve ampirik Hurst katsayısına göre BinanceCoin piyasası, kareli getiriler için hesaplanan klasik Hurst katsayısına göre Ethereum ve Binance Coin piyasaları, ampirik Hurst katsayısına göre ise yine Binance Coin piyasası daha kalıcıdır. Koşullu varyansın uzun hafıza yapısına sahip olduğunu kanıtlamak amacıyla yapılan GPH, LW, MLWS ve Qu testlerinin sonuçları da bu bulgularla uyumludur. Çalışmada kullanılan ARFIMA-FIGARCH modellemeleri, her kripto varlığın farklı volatilité yapısına sahip olduğunu ortaya koymuştur. ETH ve BNB’nin hem ortalama hem de koşullu varyans modelinde uzun hafıza etkisi görülürken, BTC’de bu etkinin yalnızca koşullu varyans modelinde anlamlı olduğunu görülmektedir. Ayrıca, BNB için ARCH etkisinin istatistiksel olarak anlamlı olmaması, volatilitenin ağırlıklı olarak GARCH ve uzun hafıza bileşenleriyle açıklandığını işaret etmiştir.

Analiz bulguları, kripto para piyasalarının uzun hafıza yapısına sahip olduğunu ve geçmiş fiyatların gelecekteki fiyat hareketleri üzerinde öngörücü bir etkiye sahip olabileceğini göstermektedir. Bu bulgu, finansal piyasalarda etkin piyasa hipotezinin öne sürdüğü gibi fiyatların tamamen rastgele ve geçmişten bağımsız olarak oluşmadığını, aksine, tarihsel fiyat bilgilerinin piyasa dinamiklerinde belirleyici bir rol oynayabileceğini göstermektedir. Bu durum, piyasalardaki yatırımcı davranışları açısından önem arz etmektedir; çünkü fiyat şoklarının kalıcı etkileri, stratejik yatırım kararlarında geçmiş fiyat hareketlerinin dikkate alınmasını gerektirmektedir.

Sonuç olarak, kripto para piyasalarının uzun hafıza yapısına sahip olması, bu piyasaların etkin piyasa hipotezine tam olarak uymadığını göstermektedir. Bu durum, yatırımcılara arbitraj fırsatları sunabileceği gibi, düzenleyici kurumlar açısından da piyasa risklerinin daha yakından izlenmesini gerektirmektedir. Gelecekteki çalışmalar, bu modelleri farklı piyasa koşullarında uygulayarak sonuçları karşılaştırmalı analizlerle genişletebilir. Ayrıca, kripto piyasalarındaki volatilitenin belirleyicileri üzerine yapılacak çalışmalar, piyasa risklerinin daha iyi yönetilmesine katkı sağlayabilir. Bulgular doğrultusunda, kripto varlık piyasalarında fiyat dinamiklerinin daha iyi anlaşılması ve öngörülerde bulunulabilmesi için uzun hafıza modellerinin kullanımının yaygınlaştırılması önerilmektedir. Bu bağlamda, ARFIMA ve FIGARCH gibi gelişmiş ekonometrik

modellerin, hem bireysel yatırımcılar hem de kurumlar tarafından piyasa tahminlerinde etkin bir şekilde kullanılması faydalı olacaktır.

KAYNAKÇA

- Akkuş, H. T., & Çelik, İ. (2020). Modeling, forecasting the cryptocurrency market volatility and value at risk dynamics of bitcoin. *Muhasebe Bilim Dünyası Dergisi*, 22(2), 296-312.
- Al-Yahyaee, K. H., Mensi, W., Ko, H. U., Yoon, S. M., & Kang, S. H. (2020). Why cryptocurrency markets are inefficient: The impact of liquidity and volatility. *The North American Journal of Economics and Finance*, 52, 101168.
- Assaf, A., Bhandari, A., Charif, H., & Demir, E. (2022). Multivariate long memory structure in the cryptocurrency market: The impact of COVID-19. *International Review of Financial Analysis*, 82, 102132.
- Assaf, A., Mokni, K., Yousaf, I., & Bhandari, A. (2023). Long memory in the high frequency cryptocurrency markets using fractal connectivity analysis: The impact of COVID-19. *Research in International Business and Finance*, 64, 101821.
- Baillie, R. T., Bollerslev, T., & Mikkelsen, H. O. (1996). Fractionally integrated generalized autoregressive conditional heteroskedasticity. *Journal of econometrics*, 74(1), 3-30.
- Betken, A. (2016). Testing for change-points in long-range dependent time series by means of a self-normalized Wilcoxon test. *Journal of Time Series Analysis*, 37(6), 785-809.
- Bouoiyour, J., Selmi, R., Tiwari, A. K., & Olayeni, O. R. (2016). What drives Bitcoin price. *Economics Bulletin*, 36(2), 843-850.
- Briere, M., Oosterlinck, K., & Szafarz, A. (2015). Virtual currency, tangible return: Portfolio diversification with bitcoin. *Journal of Asset Management*, 16, 365-373.
- Burton, G. M., & Shah, S. N. (1987). Efficient Market Hypothesis. *The New Palgrave: A Dictionary of Economics*, 2, 120-23.
- Catania, L., & Grassi, S. (2022). Forecasting cryptocurrency volatility. *International Journal of Forecasting*, 38(3), 878-894.
- Chkili, W. (2021). Modeling Bitcoin price volatility: Long memory vs Markov switching. *Eurasian Economic Review*, 11(3), 433-448.
- Dehling, H., Roach, A., & Taqqu, M. S. (2013). Non-parametric change-point tests for long-range dependent data. *Scandinavian Journal of Statistics*, 40(1), 153-173.
- Demirci, E., & Karaatlı, M. (2023). Kripto Para Fiyatlarının LSTM Ve GRU Modelleri ile Tahmini. *Journal of Mehmet Akif Ersoy University Economics and Administrative Sciences Faculty*, 10(1), 134-157.
- Duan, K., Li, Z., Urquhart, A., & Ye, J. (2021). Dynamic efficiency and arbitrage potential in Bitcoin: A long-memory approach. *International Review of Financial Analysis*, 75, 101725.
- Dyhrberg, A. H. (2016). Bitcoin, gold and the dollar – A GARCH volatility analysis. *Finance Research Letters*, 16, 85-92.
- Engle, R. F. (1982). Autoregressive conditional heteroscedasticity with estimates of the variance of United Kingdom inflation. *Econometrica: Journal of the econometric society*, 987-1007.
- Fakhfekh, M., & Jeribi, A. (2020). Volatility dynamics of crypto-currencies' returns: Evidence from asymmetric and long memory GARCH models. *Research in International Business and Finance*, 51, 101075.
- Fama, E. F. (1965). The behavior of stock-market prices. *Journal of Business*, 38(1), 34-105.

- Fama, E. F. (1970). Efficient capital markets: A review of theory and empirical work. *The Journal of Finance*, 25(2), 383–417.
- Fama, E. F. and Blume, M. E. (1966). Filter rules and stock-market trading. *The Journal of Business* 39(S1), 226–241.
- Fleischer, J. P., von Laszewski, G., Theran, C., & Parra Bautista, Y. J. (2022). Time series analysis of cryptocurrency prices using long short-term memory. *Algorithms*, 15(7), 230.
- García-Enríquez, J., & Hualde, J. (2019). Local Whittle estimation of long memory: Standard versus bias-reducing techniques. *Econometrics and Statistics*, 12, 66-77.
- García-Medina, A., & Aguayo-Moreno, E. (2024). LSTM-GARCH hybrid model for the prediction of volatility in cryptocurrency portfolios. *Computational Economics*, 63(4), 1511-1542.
- Geweke, J., & Porter-Hudak, S. (1983). The estimation and application of long memory time series models. *Journal of time series analysis*, 4(4), 221-238.
- Gubadlı, M., & Sarıkovanlı, V. (2023). Kripto Para Piyasasında Volatil Davranışların Asimetrik Stokastik Volatilite Modeli ile Testi. *Uluslararası Yönetim İktisat ve İşletme Dergisi*, 19(1), 61-82.
- Güleç, T. C., & Aktaş, H. (2019). Kripto para birimi piyasalarında etkinliğin uzun hafıza ve değişen varyans özelliklerinin testi yoluyla analizi. *Eskişehir Osmangazi Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 14(2), 491-510.
- Hameed, Z., Shafi, K., & Nawab, S. (2021). Long Term Memory Effect in Selected Cryptocurrencies. *Research Journal of Social Sciences and Economics Review*, 2(2), 255-263.
- Hosking, J. R. M. (1981). Fractional differencing. *Biometrika*, 68 (1), 165–176.
- Iacone, F., Leybourne, S. J., & Robert Taylor, A. M. (2014). A fixed-b test for a break in level at an unknown time under fractional integration. *Journal of Time Series Analysis*, 35(1), 40-54.
- Kaya Soylu, P., Okur, M., Çatıkkaş, Ö., & Altıntig, Z. A. (2020). Long memory in the volatility of selected cryptocurrencies: Bitcoin, Ethereum and Ripple. *Journal of Risk and Financial Management*, 13(6), 107.
- Khan, F. U., Khan, F., & Shaikh, P. A. (2023). Forecasting returns volatility of cryptocurrency by applying various deep learning algorithms. *Future Business Journal*, 9(1), 25.
- Kim, J. M., Jun, C., & Lee, J. (2021). Forecasting the volatility of the cryptocurrency market by GARCH and Stochastic Volatility. *Mathematics*, 9(14), 1614.
- Kuensch, H. R. (1987, December). Statistical aspects of self-similar processes. In *Proceedings of the first World Congress of the Bernoulli Society* (Vol. 1, pp. 67-74). Utrecht: VNU Science Press).
- Lahmiri, S., & Bekiros, S. (2021). The effect of COVID-19 on long memory in returns and volatility of cryptocurrency and stock markets. *Chaos, Solitons & Fractals*, 151, 111221.
- Lim, K. P., & Brooks, R. (2011). The evolution of stock market efficiency over time: A survey of the empirical literature. *Journal of economic surveys*, 25(1), 69-108.
- Mandelbrot, B. (1966). Forecasts of future prices, unbiased markets, and “martingale” Models. *Journal of Business*, 39(S1), 242–255.
- Mensi, W., Al-Yahyaee, K. H., & Kang, S. H. (2019). Structural breaks and double long memory of cryptocurrency prices: A comparative analysis from Bitcoin and Ethereum. *Finance Research Letters*, 29, 222-230.
- Münyas, T., & Aydın, G. K. (2023). Etkin piyasa hipotezi ve kripto para piyasaları üzerine bir uygulama. *Alanya Akademik Bakış*, 7(3), 1203-1216.
- Nakamoto, S., & Bitcoin, A. (2008). A peer-to-peer electronic cash system. *Bitcoin*.–URL: <https://bitcoin.org/bitcoin.pdf>, 4(2), 15.

- Nur, I. M., Nugrahanto, R., & Fauzi, F. (2023). Cryptocurrency Price Prediction: A Hybrid Long Short-Term Memory Model With Generalized Autoregressive Conditional Heteroscedasticity. *BAREKENG: Journal of Mathematics and Its Applications*, 17(3), 1575-1584.
- Qu, Z. (2011). A test against spurious long memory. *Journal of Business & Economic Statistics*, 29(3), 423-438.
- Rambaccussing, D., & Mazibas, M. (2020). True versus spurious long memory in cryptocurrencies. *Journal of Risk and Financial Management*, 13(9), 186.
- Roberts, H. (1967). Statistical versus clinical prediction of the stock market", unpublished manuscript. Chicago, University of Chicago, Centre for Research on Security Prices.
- Robinson, P. M. (1994). Rates of convergence and optimal spectral bandwidth for long range dependence. *Probability Theory and Related Fields*, 99, 443-473.
- Robinson, P. M. (1995). Gaussian semiparametric estimation of long range dependence. *The Annals of statistics*, 1630-1661.
- Samuelson, P. A. (1965). Proof that properly anticipated prices fluctuate randomly. *Industrial Management Review*, 6(2), 41-49.
- Sibbertsen, P., Leschinski, C., & Busch, M. (2018). A multivariate test against spurious long memory. *Journal of Econometrics*, 203(1), 33-49.
- Velasco, C. (2006). Semiparametric estimation of long-memory models. *Handbook of Econometrics*, 1, 353-395.
- Wang, Y., Andreeva, G., & Martin-Barragan, B. (2023). Machine learning approaches to forecasting cryptocurrency volatility: Considering internal and external determinants. *International Review of Financial Analysis*, 90, 102914.
- Wenger, K., Leschinski, C., & Sibbertsen, P. (2018). A simple test on structural change in long-memory time series. *Economics Letters*, 163, 90-94.
- Wu, X., Wu, L., & Chen, S. (2022). Long memory and efficiency of Bitcoin during COVID-19. *Applied Economics*, 54(4), 375-389.
- Yurttagüler, İ. (2024). Kripto Para Birimi Piyasalarında GPH Yöntemi ile Uzun Hafıza Analizi: Bitcoin Örneği. *Ekonomi Politika ve Finans Araştırmaları Dergisi*, 9(1), 123-139.

EXTENDED ABSTRACT

GENİŞLETİLMİŞ ÖZET

**LONG MEMORY AND VOLATILITY DYNAMICS IN CRYPTO ASSETS: THE CASES OF
BITCOIN, ETHEREUM, AND BINANCE COIN**

Introduction and Research Purpose: Market efficiency and asset price volatility are interconnected concepts. Volatility in financial assets influences investors' expectations regarding future stock prices and, consequently, market efficiency (Mensi et al., 2019). Therefore, accurately modeling volatility is crucial for market participants. To achieve proper modeling, it is essential to examine the factors that should be considered when modeling financial time series. These factors not only ensure optimal asset allocation but also help prevent losses and damages caused by excessive volatility. Long memory is one of the key aspects that should be taken into account in this context (Hosking, 1981). If a market does not exhibit long memory properties, past events will not influence today's asset prices (Burton, 1987). As a result, investors and portfolio managers will want to understand the impact of long memory on financial assets to mitigate future losses. Ignoring long memory can lead to specification errors and incorrect forecasts. Conversely, misidentifying long memory in a series that does not actually exhibit this property can lead to similar issues. Under the Efficient Market Hypothesis, this could result in the erroneous conclusion that the market is inefficient when, in reality, it is efficient (Dehling et al., 2013; Iacone et al., 2014; Betken, 2016; Wenger et al., 2018).

This study examines the top three cryptocurrencies with the highest trading volume. The main objective is to determine whether the returns of these cryptocurrencies exhibit long memory properties and to estimate an appropriate model. To detect long memory characteristics in return series, commonly used methods in the literature—such as the Hurst exponent, the Geweke and Porter-Hudak (GPH) test (1983), and the Local Whittle Estimator (LW) proposed by Robinson (1995)—have been applied. Additionally, beyond classical tests for detecting long memory, the study also employs the multivariate local Whittle score-type test (MLWS) proposed by Sibbertsen, Leschinski, and Holzhausen (2018) and the long memory tests suggested by Qu (2011). In these tests, the null hypothesis represents true long memory, while the alternative hypothesis represents spurious long memory. If long memory is detected, ARFIMA and FIGARCH model estimations are performed accordingly.

Literature Review: Numerous studies in the literature have examined market efficiency in cryptocurrency markets, the long memory structure of crypto assets, and volatility forecasting. While many studies focus more on Bitcoin, other cryptocurrencies have also been analyzed. Some studies solely investigate whether crypto assets exhibit long memory, whereas others combine long memory analysis with GARCH-type model estimations. A summary of these studies is presented in Table 1. A common finding across these studies is that the cryptocurrency market exhibits long memory characteristics.

Methodology and Findings: In this study, the daily closing prices of Bitcoin (BTC), Ethereum (ETH), and Binance Coin (BNB), which are among the highest trading volume cryptocurrencies, are analyzed. The relevant data is obtained from CoinMarketCap, a reliable data source. The starting dates for the price series are determined as December 28, 2013, for BTC, August 9, 2015, for ETH, and July 27, 2017, for BNB. The analysis period for all series ended on October 6, 2024. The price series are converted into logarithmic returns for econometric analysis.

The findings indicate that the return and squared return series of cryptocurrencies exhibit true long memory. Since all tests reached a common conclusion regarding the presence of long memory, ARFIMA models are estimated first. Residuals from the estimated ARFIMA models are obtained, and the ARCH LM test is conducted, revealing the presence of ARCH effects. Consequently, FIGARCH models, which belong to the GARCH family and are appropriate for long memory modeling, are estimated.

Conclusions and Recommendation: The analysis results suggest that cryptocurrency markets exhibit long memory properties, implying that past prices may have a predictive effect on future price movements. This is significant for investor behavior, as persistent price shocks necessitate considering past price movements in strategic investment decisions. Based on these findings, it is recommended that long memory models be widely utilized to better understand and forecast price dynamics in cryptocurrency markets. In this regard, advanced econometric models such as ARFIMA and FIGARCH can be effectively used by both individual investors and institutions for market predictions.

KATKI ORANI BEYANI VE ÇIKAR ÇATIŞMASI BİLDİRİMİ

Sorumlu Yazar <i>Responsible/Corresponding Author</i>	NİMET MELİS ESENYEL İÇEN			
Makalenin Başlığı <i>Title of Manuscript</i>	KRİPTO VARLIKLARDA UZUN HAFIZA VE VOLATİLİTE DİNAMİKLERİ: BITCOIN, ETHEREUM VE BINANCE COIN ÖRNEĞİ			
Tarih <i>Date</i>	18.06.2025			
Makalenin türü (Araştırma makalesi, Derleme vb.) Manuscript Type (Research Article, Review etc.)	Araştırma makalesi			
Yazarların Listesi / List of Authors				
<i>Sıra No</i>	Adı-Soyadı <i>Name - Surname</i>	Katkı Oranı <i>Author Contributions</i>	Çıkar Çatışması <i>Conflicts of Interest</i>	Destek ve Teşekkür (Varsa) <i>Support and Acknowledgment</i>
1	NİMET MELİS ESENYEL İÇEN	%100	Yazar, herhangi bir finansal ya da kişisel çıkar çatışması bulunmadığını beyan eder.	-