



JOEEP

e-ISSN: 2651-5318
Journal Homepage: <http://dergipark.org.tr/joeep>



Araştırma Makalesi • Research Article

Kripto Para Fiyatlarının ARIMA ve Yapay Sinir Ağı Modelleri ile Tahmini

Prediction of Cryptocurrency Prices with ARIMA and Artificial Neural Network Models

Serap Yörübulut ^{a,*} & Emre Yılmaz ^b

^a Dr. Öğr. Üyesi, Kırıkkale Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi, İstatistik Bölümü, Kırıkkale/ Türkiye

ORCID: 0000-0003-0781-4405

^b Yüksek Lisans, Ankara Emniyet Müdürlüğü, Ankara / Türkiye

ORCID: 0000-0003-0412-9461

MAKALE BİLGİSİ

Makale Geçmişi:

Başvuru tarihi: 26 Ekim 2024

Düzeltilme tarihi: 22 Aralık 2024

Kabul tarihi: 2 Mart 2025

Anahtar Kelimeler:

Kripto Para Fiyat Tahmini

ARIMA Modeli

Yapay Sinir Ağları

Kripto Para Piyasası

ARTICLE INFO

Article history:

Received: October 26, 2024

Received in revised form: Dec 22, 2024

Accepted: March 2, 2025

Keywords:

Cryptocurrency Price Prediction

ARIMA Model

Artificial Neural Networks

Cryptocurrency Market

ÖZ

Kripto para piyasasının hızla büyümesi, değişkenlik göstermesi ve belirsizlikleri, yatırımcılar için önemli fırsatlar sunmanın yanı sıra bazı riskler de ortaya çıkarmaktadır. Bu nedenle; kripto para fiyatlarının doğru bir şekilde tahmin edilmesi, yatırım kararlarının daha güvenilir ve bilinçli bir şekilde alınabilmesi açısından kritik öneme sahiptir. Bununla birlikte; yatırımcıların daha bilinçli ve sağlıklı yatırım yapmalarını sağlamak amacıyla, kripto para fiyat tahminine yönelik modelleme çalışmalarının geliştirilmesi büyük önem taşımaktadır. Bu çalışmada temel kripto para birimlerinden olan Bitcoin ve Ethereum fiyatlarının tahmin edilmesinde ARIMA ve Yapay Sinir Ağı modellerinin performansını karşılaştırmayı amaçlamaktadır. Çalışma kapsamında 1 Nisan 2016 ile 1 Mart 2024 tarihleri arasında elde edilen Bitcoin ve Ethereum için günlük fiyat verileri kullanılarak, bu iki modelin kripto para piyasasında hangi koşullar altında daha iyi tahmin yapabildiği incelenmiştir. Elde edilen modellerin performansları hata oranları ve doğruluk açısından karşılaştırıldığında kripto para piyasasındaki yüksek volatiliye rağmen her iki modelinde belirli piyasa koşullarında uygulanabilir olduğu gösterilmiştir. Özellikle YSA ile elde edilen tahmin modellerinin, kripto para piyasasındaki fiyat hareketlerinin daha iyi anlaşılması ve bu alanda etkili yatırım kararları alınabilmesi için önemli bulgular sunmaktadır.

ABSTRACT

The rapid growth, volatility and indicators of the cryptocurrency market provide important opportunities for information, but also pose some risks. Therefore; Accurate prediction of cryptocurrency prices is critical for investment decisions to be made in a more reliable and secure manner. However; In order for the cryptocurrency to gain greater importance in terms of price prediction, to ensure healthier investments. Comparisons of ARIMA and Artificial Neural Network models are made in predicting the prices of Bitcoin and Ethereum, which are among these successful basic cryptocurrencies. Within the scope of the study, daily price data for Bitcoin and Ethereum obtained between April 1, 2016 and March 1, 2024 were used to determine under which conditions the cryptocurrency of these two models could be predicted better. Despite the high performance volatility of the obtained models, cryptocurrencies with opposite characteristics can be found in both models under certain market conditions. In particular, the prediction models obtained with ANN offer important findings for a better understanding of price movements in cryptocurrencies and for effective investment decisions to be made in this area.

1. Giriş

Kripto para birimleri, blokzincir teknolojisi temeline bağlı olarak son on yılda finansal piyasaların yapı taşlarından biri haline gelmiştir. Blok zinciri teknolojisinin bir ürünü olarak

ortaya çıkan bu dijital varlıklar, geleneksel para birimlerine alternatif olarak sunulmuş ve özellikle genç yatırımcılar arasında popülerlik kazanmıştır. Ancak, kripto para piyasalarının aşırı volatilitesi, yatırımcılar için hem büyük kazanç fırsatları hem de ciddi riskler taşıması, araştırmacıları bu dijital varlıkların fiyat hareketlerinin

* Sorumlu yazar/Corresponding author.

e-posta: siybulut@gmail.com

Atf/Cite as: Yörübulut, S. & Yılmaz, E. (2025). Kripto Para Fiyatlarının ARIMA ve Yapay Sinir Ağı Modelleri ile Tahmini. *Journal of Emerging Economies and Policy*, 10(1), 298-311.

This article is published under the Creative Commons Attribution (CC BY 4.0) licence. Anyone may reproduce, distribute, translate and create derivative works of this article (for both commercial and non-commercial purposes), subject to full attribution to the original publication and authors.

doğru anlamaya ve tahmin edilmesine yönelik çalışmalara yönelmiştir. Kripto para piyasasında fiyat hareketleri, geleneksel para birimlerinden farklılık göstermekte ve bu durum fiyat tahminleri için yeni modellerin kullanılmasını zorunlu hale getirmektedir. Auto Regressive Integrated Moving Average (ARIMA) ve Yapay Sinir Ağı (YSA) modelleri, kripto para fiyat tahminleri için sıklıkla kullanılan yöntemler arasında yer almaktadır. ARIMA modeli, geçmiş fiyat hareketlerini dikkate alarak özellikle doğrusal ilişkilerin olduğu durumlarda zaman serisi verilerinin analizinde güçlü bir araç olarak kabul edilirken, YSA, karmaşık ve doğrusal olmayan ilişkileri modelleme konusundaki yetkinliği dikkat çekmektedir. ARIMA'nın doğrusal zaman serisi analizi konusundaki etkinliği ile YSA'nın doğrusal olmayan karmaşık ilişkileri anlamadaki başarısı, bu iki yöntemin birlikte ele alınmasının kripto para piyasalarının öngörülebilirliği açısından önemli bir fırsat sunduğunu göstermektedir.

Bitcoin (BTC) ve Ethereum (ETH), kripto para piyasasında lider konumda olmaları, işlem hacimleri, piyasa değerleri ve teknolojik altyapıları ile dikkate değerdir. BTC, kripto para ekosisteminin ilk ve en bilinen dijital varlığı olarak piyasa hareketlerinin genel yönelimini belirlemede öncü bir rol oynarken, ETH, akıllı sözleşme teknolojisi ile daha geniş bir ekosistemi temsil etmektedir. Bu iki kripto para birimi, güvenilir ve yeterli veri sağlama kapasiteleri nedeniyle tahmin modellerinin uygulanabilirliği açısından önemli bir avantaj sunmaktadır. Ayrıca, bu iki varlık üzerine yapılan analizler, kripto para piyasasının geneline dair çıkarımlar yapılmasını da mümkün kılmaktadır.

Bu çalışma, kripto para piyasalarının öngörülebilirliğini artırmak ve yatırımcıların daha bilinçli kararlar almasını sağlamak için 01 Nisan 2016 ile 01 Mart 2024 tarihleri arasında BTC ve ETH kripto para birimlerinin günlük fiyat verileri kullanılarak ARIMA ve YSA modelleri ile gelecekteki kripto para fiyat tahminlerini yapmayı amaçlamaktadır. Bu zaman aralığının seçilmesinin temel sebebi, Bitcoin ve Ethereum'un bu dönemdeki fiyat hareketlerinin hem piyasa volatilitelerini hem de fiyat trendlerini anlamak için kapsamlı bir veri seti sunmasıdır. Bu çalışma aynı zamanda her iki modelin performansını, kripto para piyasalarının öngörülebilirliği bağlamında değerlendirecek ve bu modellerin finansal tahminlerdeki potansiyelini ortaya koyacaktır. Elde edilen bulgular ile ARIMA gibi geleneksel istatistiksel yöntemler ve YSA gibi makine öğrenme yöntemlerinin performanslarının karşılaştırılması, hangi yöntemin daha iyi tahmin performansına sahip olduğunu belirlenmesine katkı sağlayacaktır. Bu durum yalnızca literatüre özgün bir katkı sunmakla kalmayacak, aynı zamanda kripto para yatırımcıları, finansal analistler ve portföy yöneticileri için de değerli bilgiler sağlayarak daha bilinçli yatırım kararlarının alınmasına destek olacaktır.

2. Literatür Taraması

ARIMA ve YSA modellerinin uygulanışı, avantajları,

sınırlılıkları ve karşılaştırmalı performanslarına odaklanarak, konuyla ilgili literatürde yer alan önemli çalışmalar incelenmiştir.

Kaynar ve Taştan (2009), döviz kuru verilerini kullanarak ARIMA ve Çok Katmanlı İleri Beslemeli Yapay Sinir Ağları (MLP) modelleriyle tahmin yapmış ve MSE ile MAPE değerlerine göre analiz gerçekleştirmiştir. Çalışmada, YSA'nın ARIMA modeline alternatif olarak kullanılabileceği vurgulanmış ve melez bir model önerilmiştir. Bu melez model, bazı durumlarda her iki modelin de performansını aşarak daha isabetli tahminler sağlamıştır. Çalışma, birden fazla modelin bir arada kullanılmasının tek bir modele bağlı tahminlerden daha güvenilir sonuçlar elde edilmesine olanak tanıdığını göstermiştir.

Benli Keskin ve Yıldız (2014) tarafından altın fiyatları üzerine yapılan bu çalışmada, ARIMA ve YSA modelleri karşılaştırılmış ve ARIMA modelinin YSA'ya göre daha iyi tahmin performansı gösterdiği bulunmuştur.

Sakız ve Gencer (2017), Bitcoin fiyatlarını tahmin etmek için Yapay Sinir Ağları (YSA) kullanarak bir çalışma gerçekleştirmiştir. Araştırmacılar, Bitcoin fiyatlarının klasik tahminleme yöntemleriyle hesaplanmasının zorluğunu vurgulamışlardır. Ancak, çalışmada kullanılan YSA modeli beklenen performansı sergileyememiş ve araştırmacıyı tatmin etmeyen sonuçlar elde edilmiştir. Bu durum, yapay zeka tabanlı yöntemlerin her durumda etkili olmadığını ve Bitcoin gibi aşırı volatil piyasalarda farklı yaklaşımların gerekli olabileceğini göstermektedir.

Şahin (2018) tarafından BTC fiyat tahmini üzerine yapılan bu çalışmada, YSA modeli, ARIMA'ya kıyasla daha başarılı sonuçlar vermiştir. MSE ve MAPE değerleri üzerinden yapılan değerlendirmelerde, YSA modeli daha yakın tahminler yapmıştır.

Aras (2019), BTC, ETH, Ripple ve Litecoin kripto para birimleri için tahmin modelleri oluştururken klasik zaman serileri ve Yapay Sinir Ağları (YSA) yöntemlerini kullanmıştır. Çalışmada beş farklı model karşılaştırılmış ve incelenen her bir kripto para birimi için bazı modellerin diğerlerine üstünlük sağladığı görülmüştür. Özellikle BTC, tahmin performansı açısından en iyi sonuçları verirken, ETH tahminlerinde zayıf sonuçlar elde edilmiştir. Bu durum, farklı kripto para birimlerinin piyasa dinamiklerine göre model performanslarının değişebileceğini ve her bir varlık için uygun tahmin yönteminin özenle seçilmesi gerektiğini ortaya koymuştur.

Atlan vd. (2020) Bitcoin, Ripple ve Ethereum kripto para birimleri için YSA, polinomsal eğri uydurma ve derin öğrenme yöntemlerini kullanarak tahminler gerçekleştirmiştir. Salman (2020) Bitcoin kripto para birimi ile ilişkisinin olduğu düşünülen teknik ticari göstergelerle birlikte YSA ile tahminlerde bulunmuştur. Akay vd. (2021) Ripple, Binance ve Ethereum kripto para birimleri için YSA ve derin öğrenme yöntemlerini kullanarak tahminler yapmış YSA ile elde edilen modellerin daha

başarılı sonuçlar verdiği belirlenmiştir.

Hayradi vd. (2022), alt kripto para birimlerinden Polkadot'un günlük kapanış değerlerini kullanarak fiyat tahmini için destek vektör regresyon (SVR) algoritmasını kullanmışlardır. Çalışmada, SVR modelinin tercih edilme nedeni, fiyatı aşırı dalgalı olan kripto paralar veya menkul kıymetler için daha iyi tahmin sunma potansiyeline sahip olmasıdır. Elde edilen sonuçlar, SVR modelinin Polkadot için başarılı bir tahmin performansı sergilediğini ve bu tür volatil piyasalarda etkili bir araç olabileceğini göstermiştir.

Odabaşı vd. (2023) Polkadot kripto para birimi için YSA ve derin öğrenme yöntemleri kullanarak tahminler yapmış ve YSA ile elde edilen tahminin daha başarılı olduğunu belirtmişlerdir.

İncelemeye alınan çalışmaların genelinde, uygun kısıtlar altında YSA yöntemi kullanılarak yapılan tahminlerin ARIMA gibi geleneksel yöntemlere nazaran daha etkin tahminler gerçekleştirdiği sonucuna varılabilir.

Mevcut literatürde Bitcoin ve Ethereum fiyat tahmini üzerine yapılan çalışmalar genellikle tek bir tahmin yöntemiyle sınırlı kalmakta veya sadece kısa dönemli tahminlere odaklanmaktadır. Bu çalışma, hem ARIMA hem de YSA yöntemlerini bir arada kullanarak farklı yaklaşımların performansını karşılaştırmaktadır. Ayrıca, çalışmada geniş bir veri periyodu (2016-2024) ele alınarak, uzun vadeli tahminlere ve piyasa trendlerinin daha kapsamlı analizine olanak sağlanmıştır. Bu yöntem, literatürdeki mevcut boşluğu doldurarak hem model çeşitliliği hem de analiz kapsamı açısından özgünlük sunmaktadır.

3. Kripto Para Birimleri

Dijital paralar, günümüz finansal sistemlerinde önemli bir rol oynamaktadır. Elektronik olarak saklanabilen ve transfer edilebilen bu paralar, fiziksel paraların yerini almaya başlamıştır. Bu dönüşümün arkasında, bankaların her yerde erişilebilir olması ve elektronik paranın yaygınlaşması gibi faktörler yatmaktadır (Çarkacıoğlu, 2016).

Sanal paralar, dijital paradan türemiş olup, somut bir fiziksel karşılığa sahip değildir. Yalnızca elektronik ortamlarda var olurlar ve fiziksel bir değer taşımazlar (Çarkacıoğlu, 2016). Dijital para ve sanal para üzerine yapılan çalışmalar kripto para piyasasını ortaya çıkarmıştır.

Merkezi bir otoriteye veya aracılık eden bir kuruma bağlı olmayan, internet üzerinde kullanılan sanal para birimi kripto para olarak tanımlanır. Kriptografi yöntemleriyle sanal cüzdanlarda saklanır ve bu şifreleme yöntemleriyle kullanılır. Bu nedenle, bu tür sanal para birimlerine "Kripto" adı verilmiştir. Kripto paralar, harcama yapmak ve yatırım amacıyla hem bireyler hem de kurumlar tarafından kullanılır (Çetinkaya, 2018).

Günümüzde aktif olarak alım satımı yapılan kripto para birimlerinin sayısı hızla artmaktadır. 2013 yılında sadece 66 olan kripto para birimi sayısı, Kasım 2024 itibarıyla 9.935'e ulaşmıştır (Statista, 2024). Bu hızlı artış, kripto para

piyasalarının büyüklüğünü ve çeşitliliğini gözler önüne sermekte, aynı zamanda bu piyasaların öngörülebilirliğini artırmaya yönelik tahmin modellerinin geliştirilmesini önemli hale getirmektedir. Madeni değerleri ve devlet desteği olmayan bu para birimlerinin geleneksel bir karşılığı yoktur. Kripto paraların değerleri arz ve talep koşullarına göre anlık olarak belirlenir (Eğilmez, 2017).

Hiçbir devlet, kurum veya organizasyon doğrudan kripto para üretmez ve başkalarının kripto paralarına el koyma yetkisine sahip değildir. Ancak, doğrudan olmasa da dolaylı yollarla, örneğin borsalar üzerinden, kripto paralara el konulması mümkündür. Ayrıca, kripto paralara haciz uygulanması da hukuk sistemine göre gerçekleştirilebilen bir işlemdir (Aymaz, 2024). Bu durum, kripto paraların merkeziyetsiz yapısının, yasal ve finansal süreçler açısından bazı zorluklar doğurduğunu ve devletlerin bu varlıklara yönelik düzenleyici adımlar atma gerekliliğini ortaya koymaktadır.

Kripto paralarda, gönderici ve alıcı dışında üçüncü bir kişi veya aracı bulunmaması, bu paraların güvenliğini ve transfer işlemlerinin sağlıklı bir şekilde gerçekleşmesini sağlar (Çarkacıoğlu, 2016).

3.1. Bitcoin

BTC, 2009 yılında Satoshi Nakamoto takma adını kullanan bir kişi veya grup tarafından ortaya çıkarılan dijital ve kriptografik bir para birimidir. Dijital para ekonomisinin temelini oluşturan kavramlar üzerine kuruludur ve açık kaynak kodludur. Tamamen dijital olup, fiziksel bir temsile ihtiyaç duymaz. Düşük işlem maliyetleri, dünya çapında kullanılabilirliği, finansal özgürlük sağlaması ve güvenilir, anonim bir değer saklama aracı olarak görülmesi, Bitcoin'in popülerliğini artırmaktadır. BTC, herhangi bir resmi kurum ya da özel kuruluş tarafından ihraç edilmez veya garanti edilmez (Sönmez, 2014).

BTC üretimi, dünya çapında dağıtık bir ağdaki gönüllü bilgisayarların işlem gücü ile gerçekleştirilir. İşlem onayları, karmaşık matematiksel problemleri çözen madenciler tarafından sağlanır. İlk problemi çözen belirli miktarda BTC ile ödüllendirilir. Zamanla problemler zorlaşır ve ödül miktarı dört yılda bir yarıya düşer (Çarkacıoğlu, 2016).

3.2. Ethereum

ETH, Vitalik Buterin tarafından geliştirilen açık kaynak kodlu bir blok zinciri platformudur. Akıllı sözleşmelerin kullanımını sağlayarak programlanabilir bir blok zinciri sunar. Bu, dijital varlıklar, oylama sistemleri, oyunlar ve birçok farklı uygulama senaryosunda kullanılabilir (Buterin, 2013).

Dünya çapında en güvenilir ikinci kripto para olarak tercih edilen ETH, pek çok geliştirici ve şirket tarafından kullanılmaktadır. Blok zinciri teknolojisinin geleceği konusunda umut verici bir perspektif sunmakta ve ileride daha geniş çapta kullanılması öngörülmektedir. ETH'nin piyasa değeri, piyasa koşullarına ve talebe bağlı olarak dalgalanabilir (Salehihosseini, 2023).

ETH'nin geçmişi bazı zorluklar da barındırmaktadır. Örneğin, 2016'da, merkeziyetsiz bir girişim sermayesi şirketi olan DAO (Decentralized Autonomous Organization) tarafından yapılan bir saldırı, ETH blok zincirinin ikiye bölünmesine yol açmıştır. DAO, Ethereum ağı üzerinde çalışan ve yatırımcıların projelere fon sağlamasına olanak tanıyan bir platformdur. Ancak, DAO'ya yönelik gerçekleştirilen siber saldırı, platformda güvenlik açığına yol açarak büyük miktarda fonun çalınmasına neden olmuştur. Bu olayın ardından, Ethereum topluluğu, orijinal blok zincirinin bir kısmını geri almak için bir hard fork gerçekleştirmiştir. Orijinal blok zinciri ETH Classic adını almış, diğer blok zinciri ise ETH olarak anılmaya devam etmiştir (Usta ve Doğantekin, 2017). DAO'nun ne olduğu ve bu saldırının Ethereum topluluğu üzerindeki etkileri, kripto para ekosistemini anlamak için önemli bir örnek teşkil etmektedir.

4. Veri Seti ve Araştırma Metodolojisi

Bu çalışmada, BTC ve ETH gibi önemli kripto para birimlerinin günlük değerlerini içeren veri setleri, <https://tr.investing.com/> platformundan toplanmıştır. Veriler, 01 Nisan 2016 ile 01 Mart 2024 tarihleri arasındaki günlük kapanış değerleridir. Seçilen zaman periyodu (2016-2024), kripto para piyasasının önemli bir büyüme ve olgunlaşma dönemini kapsamaktadır. 2016 yılı, Bitcoin ve Ethereum'un ilk kez geniş kitlelerce tanınmaya başladığı ve piyasanın hızla büyüdüğü bir yıl olarak öne çıkmaktadır. 2024 yılına kadar olan veri ise hem piyasa döngülerini hem de COVID-19 pandemisi gibi büyük olayların etkilerini anlamak için yeterince geniş bir analiz dönemi sunmaktadır. Bu zaman aralığı, hem piyasa trendlerinin uzun vadeli analizini mümkün kılmakta hem de gelecekteki potansiyel eğilimleri öngörmeye yardımcı olmaktadır. Tablo 1'e göre, 2892 günlük BTC veri noktası için ortalama 18.015,25; ortanca 10.260,45; maksimum 67.527,90; minimum 415,6 ve standart sapma 16.675,57; ETH veri noktası için ise ortalama 1.033,31; ortanca 431,84; maksimum 4.808,38; minimum 6,70 ve standart sapma 1.111,70 olarak hesaplanmıştır. Yapılan istatistiksel analizlerin anlamlılık düzeyi 0,01 olarak belirlenmiştir. Analizlerde MATLAB ve Eviews programları kullanılmıştır.

Tablo 1: 2016-2024 yılları BTC ve ETH verileri betimleyici istatistikleri

BTC/USD	
Ortalama	18.015,25
Ortanca Değer	10.260,45
Maksimum Değer	67.527,90
Minumum Değer	415,60
Standart Sapma	16.675,57
Veri Sayısı	2.892
ETH/USD	
Ortalama	1.033,31
Ortanca Değer	431,84
Maksimum Değer	4.808,38

Minimum Değer	6,70
Standart Sapma	1.111,70
Veri Sayısı	2.892

Bu çalışmada tahminler için ARIMA ve YSA yöntemleri tercih edilmiştir. Kripto paralar için en uygun ARIMA modelini belirlemek amacıyla Akaike ve Schwarz bilgi kriterleri kullanılmıştır. YSA'da ise en iyi modeli bulmak için LM algoritması uygulanmıştır. Uygun ARIMA ve YSA modelleri belirlendikten sonra, bu modellerin karşılaştırılmasında HKO kriteri kullanılmıştır.

4.1. ARIMA Modeli

ARIMA modeli, zaman serisi analizinde sıkça başvurulan bir yöntemdir. Zaman serilerini modellerken, en uygun doğrusal modeli az parametreyle tespit etmeyi amaçlar. Gelecekteki değerler, serinin geçmiş değerleri ve hata terimlerinin doğrusal kombinasyonları ile tahmin edilir. Bu şekilde, ARIMA modeli otokorelasyonu ve trend bileşenlerini inceleyerek gelecekteki değerler hakkında bilgi sağlamayı hedefler (Abushukur, 2022).

ARIMA modeli, ekonomi, finans ve diğer birçok alanda karmaşık veri setlerinin analizini yapabilmek için yönlendirilmiş tahmin ve simülasyon araçlarıyla birlikte kullanılır (Aygören, 2012). ARIMA modeli AR (Oto-regresif), I (Bütünleşik) ve MA (Hareketli Ortalama) bileşenlerinden oluşmaktadır (Ergül, 2018). AR bileşeni, bir zaman serisinin mevcut değerinin önceki değerlerle olan ilişkisini temsil eder (Tanışman, 2021). I bileşeni, bir zaman serisinin durağan olup olmadığını inceler. Eğer durağan değilse, fark alarak durağan hale getirilir (Tuna, 2019). MA bileşeni ise hata terimlerinin ortalamasını alarak zaman serisinin rastgele hareketlerini gösterir (Kaynak, 2022).

ARIMA modelinin başarısı, üç bileşenin doğru parametrelerle belirlenmesine bağlıdır. Parametrelerin doğru şekilde ayarlanması, modelin veriyi doğru tahmin edebilmesi için kritik öneme sahiptir (Kaynak, 2022).

ARIMA modeli için; Otokorelasyon Fonksiyonu (ACF) ve Kısmi Otokorelasyon Fonksiyonu (PACF) grafikleri modelin AR ve MA bileşenlerinin derecelerinin belirlenmesi sürecinde kritik bir rol oynar. ACF'de belirli bir gecikmeden sonra sıfıra düştüğü nokta MA derecesini belirlerken, PACF'de sıfıra düştüğü nokta AR derecesini belirler (Arslan, 2022).

Birçok ekonomik zaman serisi durağan değildir ve bu, trendler, mevsimsel dalgalanmalar ve rastgele şoklar gibi faktörlerden kaynaklanır. Durağan olmayan serilerin doğru modellenmesi için önce durağan hale getirilmesi gerekir (Duru, 2007).

ARIMA(p,d,q) modelinin genel formülasyonu, serinin d kez fark alınarak durağan hale getirilmesini takiben, AR(p) ve MA(q) modelleri ile eşitlik (1)'de verilmiştir.

$$\left(1 - \sum_{i=1}^p \phi_i L^i\right)(1 - L)^d X_t = \left(1 + \sum_{j=1}^q \theta_j L^j\right) \varepsilon_t \quad (1)$$

Burada:

L : Gecikme operatörü.

X_t : Zaman serisinin t zamanındaki değeri.

ε_t : Beyaz gürültü hata terimidir.

ϕ_i ve θ_j sırasıyla AR ve MA bileşenlerinin katsayılarıdır.

ARIMA Modelinin Uygulama Şeması

- *Durağanlık ve Varyans Sabitleme:* ARIMA modelini uygulamadan önce, serisinin durağan olup olmadığı ADF (Augmented Dickey-Fuller) testi gibi istatistiksel testler ile test edilir. Seri durağan değilse durağanlaştırmak için farklar alınır. Daha sonra zaman serisinin varyansını sabitlemek amacıyla uygun dönüşümler yapılır. Bu süreçte, otoregresyon (p) ve hareketli ortalama (q) değerleri belirlenir.
- *Model Tanımlama:* Deneme yanılma yöntemiyle bir dizi model tanımlanır ve en uygun olan model geleceğe yönelik tahminler için seçilir.
- *Parametre Tahmin ve Seçimi:* Seçilen modelin parametreleri tahmin edilir. Model belirleme sürecinde, F-istatistiği, Akaike Bilgi Kriteri (AIC) ve Schwarz Bilgi Kriteri (SIC) gibi istatistiksel ölçütler kullanılır. Aday modelin parametrelerinin tahmini için olabilirlik fonksiyonu veya en küçük kareler yöntemi gibi yöntemler kullanılarak parametreler belirlenir. Parametreler, olabilirlik fonksiyonunun maksimizasyonu veya hataların karelerinin minimizasyonu ile elde edilir.
- *Model Gözden Geçirme:* Eğer seçilen model zaman serisini yeterli derecede açıklayamazsa, ikinci aşamaya geri dönülür ve tanımlama süreci yeniden ele alınır.
- *Model Doğrulama ve Tahmin:* Bu aşama, seçilen modelin zaman serisini ne kadar etkili bir şekilde açıkladığını değerlendiren bir aşamadır. Ayrıca, bir veya birkaç dönem için geleceğe yönelik tahminler yapılır ve bu tahminler için güven aralıkları belirlenir. (Erdoğan, 2006).

4.2. Yapay Sinir Ağları

YSA, karmaşık desenleri tanıma ve veriden öğrenme yeteneğine sahip, insan beyninin bilgi işleme sürecinden ilham alınarak geliştirilmiş bilgisayar sistemleridir. YSA, insan beyninin öğrenme ve keşfetme yeteneklerini taklit ederek, dış yardıma ihtiyaç duymadan bu becerileri gerçekleştirebilen bilgisayar modelleridir (Tekin, 2009).

Yapay zeka alanındaki ilk çalışmalar, McCulloch ve Pitts tarafından gerçekleştirilmiştir (Crone, 2004). Sonraki YSA

çalışmalarına Shannon, McCarthy, Hebb, Edmonds, Minsky ve Rochester gibi bilim insanlarının araştırmaları rehberlik etmiştir. Simon ve Newell, ilk teorem kanıtlama programlarını geliştirmiş ve Fiziksel Simge Varsayımı'nı sunmuşlardır (Saraç, 2004).

YSA, karmaşık sorunların çözümünde yaygın olarak kullanılmaktadır. Günümüzde, bu teknolojiler günlük yaşamın birçok alanında, ev cihazları, bilgisayarlar ve cep telefonları gibi ürünlerde yer almaktadır. YSA, endüstriden finans ve sağlığa kadar birçok farklı alanda geniş bir kullanım alanına sahiptir (Ömrüzün, 2019).


YSA, beynin nöronlar arasındaki iletişimini taklit eden karmaşık yapılarıdır. Bu yapılar, veri işleme, ölçüm ve tahminlerde hataları azaltmak amacıyla kullanılır; bu sayede makineler öğrenebilir hale gelir (Özdemir, 2008).

YSA, insan beyninin işleyişinden esinlenerek oluşturulmuş, birbirine bağlı nöronlardan oluşan bilgisayar sistemleridir. Bu sistemlerde giriş, gizli ve çıkış katmanları bulunur. Her katmandaki nöronlar, bir önceki katmandan aldıkları sinyalleri işleyip bir sonraki katmana ileterek bilgi akışını sağlar. YSA, genellikle giriş katmanı, bir veya daha fazla gizli katman ve çıkış katmanından oluşur (Yılmazel, 2018). Giriş katmanı, verinin ağı sunulduğu ilk katmandır; gizli katmanlar ise veriyi işleyen katmanlardır. Gizli katmanların sayısı ve her katmandaki nöron sayısı modele göre değişir. Çıkış katmanı, sonuçları temsil eder (Tuna, 2019).

Aktivasyon fonksiyonları, YSA nöronlarının çıktılarını belirleyen matematiksel işlevlerdir. Bu fonksiyonlar, bir nöronun toplam girdi sinyalini alıp bunu bir çıktı sinyaline dönüştürerek ağı öğrenme ve karar verme sürecine yön verirler. Yaygın aktivasyon fonksiyonları arasında Sigmoid, Tanjant Hiperbolik (tanh), ReLU (Rectified Linear Unit), Leaky ReLU ve Softmax bulunmaktadır (Şahin, 2018).


Klasik programlama, programcı tarafından belirlenen talimatları adım adım izleyen sistemlerdir. Buna karşılık, YSA'lar klasik anlamda programlanmaz; çözülmesi istenen problemle ilgili örnekler üzerinde çalışarak veriler arasındaki ilişkileri öğrenir (Şahin, 2002). Bu süreçte, programcı tarafından belirlenen kurallar yerine ağı, eğitim yoluyla bir algoritma geliştirir. YSA'lar, işledikleri örneklerden elde ettikleri bilgileri kullanarak genellemeler yapar ve daha önce karşılaşmadıkları yeni problemlere uygun çıktılar üretebilirler (Grossberg, 1992). Ayrıca, değişikliklere uyum sağlamak için yeniden eğitilebilirler ve yeni duruma uygun çözümler sunabilirler (Akkurt, 2005).

Yapay Sinir Hücresi (YSH) aynı sinir hücrelerinin taklidini yaparak öğrenme ve olgular arası ilişkiler ortaya koyar (Çakır, 2018).

Şekil 1: Yapay sinir hücresi

Şekil 1’de de görüldüğü gibi YSH’ne dış dünyadan gelen veri ve bilgiler, girdiler (girişler) olarak tanımlanır. YSA, girdileri öğrenmek veya tahmin etmek istediğimiz konuya göre şekillendirilmelidir. Ağırlıklar, YSH’ne iletilen bilgi ve verilerin önem derecesini belirtir. Bu ağırlıklar negatif veya pozitif değerler olabilir ve girdilerle ağırlıklar arasındaki çarpım ($x_i * w_i$), birleştirme fonksiyonuna aktarılır (Çakır, 2018).

Birleştirme fonksiyonu, yapay sinir ağındaki bir sinir hücresine giren birden fazla değeri tek bir değere dönüştürür ve bu fonksiyonun toplama, çarpma, maksimum, minimum gibi çeşitli türleri vardır. Aktivasyon fonksiyonu ise bu birleştirme fonksiyonu tarafından elde edilen değerleri işler ve belirli bir aralıkta mı yoksa dışında mı olduklarını belirler. Sigmoid, Tanh, ReLU, Leaky ReLU ve Softmax gibi çeşitli aktivasyon fonksiyonları bu işlemde kullanılır. Aktivasyon fonksiyonu, işlenen değeri çıktı olarak üretir. Bu çıktı, yapay sinir ağının dışına veya başka bir hücreye iletilir. Girdiler birden fazla olabilirken, çıktı tek bir değer olarak üretilir ve bu çıktı başka sinir hücrelerine girdi olarak kullanılabilir (Öztemel, 2006).

Şekil 1: YSA arasındaki ilişki

Şekil 2’de YSA’nın; girdi katmanı, ara (gizli) katman(lar) ve çıktı katmanı olmak üzere üç temel katmandan oluştuğu görülmektedir.

- **Girdi Katmanı:** Dış dünyadan alınan bilgi ve verilerin işlem yapılmadan ara katmana, yani gizli katmana aktarıldığı yerdir.
- **Ara (Gizli) Katman(lar):** Girdi katmanından alınan ham bilgi ve verilerin, karmaşık işlemlerden geçirilerek çıktı katmanına iletilindiği yerdir.
- **Çıktı Katmanı:** Gizli katmanlardan iletilen işlenmiş bilgi ve verilerin, son kez işlenerek nihai çıktılar

üretildiği ve dış dünyaya sunulduğu katmandır (Öztemel, 2006).

YSA öğrenme süreci, elemanların bağlantı ağırlıklarının belirlenmesiyle başlar. Bir sinir ağı, kullanılmadan önce eğitilmelidir; bu süreç ağı performansı için kritiktir. Başlangıçta rastgele seçilen ağırlıklar, eğitim sırasında güncellenir ve ağı, hata fonksiyonunu minimize ederek en uygun ağırlıklara ulaşır. Bu süreç, ağı genelleme yeteneği kazanarak yeni verilere doğru yanıt verebilmesini sağlar. Rastgele ağırlıklar, nöronların farklı öğrenme yollarını izleyerek modelin genelleme kabiliyetini artırır. (Yılmaz, 2012).

YSA’nın öğrenme süreci:

- Sistem için gerekli olan girdi parametreleri tanımlanır.
- Sistem performansını değerlendirmek için çıktı parametreleri belirlenir.
- Bu çıktı parametreleri, basit bir ölçüm mekanizması ile entegre edilir.
- Girdi ve çıktı çiftlerinden oluşan eğitim ve test veri seti hazırlanır.
- Gizli katman sayısı ve her katmandaki nöron sayısı doğru şekilde belirlenmelidir; bu süreç genellikle deneme-yanılma yöntemiyle başlar ve sonuçlara göre ayarlamalar yapılır.
- Eğitimden geçen YSA modeli, farklı durumlar karşısında davranışını test için simülasyona tabi tutulur.
- İstenen sonuçlar elde edilene kadar bu adımlar tekrarlanır.

şeklinde gerçekleşir (Ömrüzün, 2019).

4.3. ARIMA ve Yapay Sinir Ağı Modellerinin Performans Karşılaştırması

Kripto para fiyat tahminlerinde yaygın olarak kullanılan ARIMA ve (YSA) modellerinin performanslarının karşılaştırılması ile uygun model belirlenmeye çalışılacaktır. ARIMA modeli, zaman serisi verilerinin geçmiş değerlerinin kullanılması ile istatistiksel bir yaklaşım sunarken; YSA modeli, karmaşık ve doğrusal olmayan ilişkileri öğrenme kapasitesine sahip bir makine öğrenme yöntemi olarak, geniş bir uygulama alanına sahiptir.

Bu çalışmada, her iki modelin performansını değerlendirmek amacıyla Hata Kareler Ortalama (HKO) ölçütü kullanılmıştır. HKO, tahmin edilen değerler ile gözlemlenen değerler arasındaki farkların karelerinin ortalamasının karekökünü alarak hesaplanan bir hata ölçütüdür. Düşük HKO değerleri, modelin tahminlerinin gerçek değerlere yakınlığını ve modelin etkinliğini belirlemede kritik bir değer olarak kullanılmaktadır.

ARIMA modelinin uygulanmasında, öncelikle zaman

serisinin durağanlığı ADF testi ile test edildikten sonra uygun modelin belirlenmesi için AIC ve SIC ölçütleri kullanılmıştır. YSA modelinde ise, ağın mimarisinin belirlenmesi için çeşitli katman sayıları ve nöron yapılandırılmaları test edilmiştir. Eğitim ve test veri setleri üzerinden her iki model için HKO değerleri hesaplanmıştır.

5. Bulgular

Kripto para birimlerinden BTC ve ETH'un 01 Nisan 2016 ile 01 Mart 2024 tarihleri arasındaki günlük kapanış değerleri dikkate alınarak ARIMA ve YSA modelleri kullanılarak tahmin sonuçları aşağıda verilmiştir.

5.1. Bitcoin İçin ARIMA Model Sonuçları

BTC fiyat tahmini için ARIMA modeli uygulamak için öncelikle serinin durağanlığı ADF testi ile test edilmiş ve sonuçlar Tablo 2'de verilmiştir. ADF testi, hem otokorelasyon hem de trend bileşenlerini dikkate alarak, serinin zamanla değişip değişmediğini ortaya koymada önemli bir rol oynamaktadır. Bu nedenle, elde edilen sonuçlar, modelleme sürecinde serinin uygunluğunu ve analiz için geçerliliğini sağlamak için kritik öneme sahiptir.

Tablo 2: Günlük BTC verisine ait ADF test istatistik sonucu

	t-istatistik	p-değeri
ADF Test İstatistiği	-0.345	0.9157

$H_0: \delta = 0$ Seri durağan değildir.

$H_1: \delta < 0$ Seri durağandır.

Tablo 2 'ye göre elde edilen p değeri 0,9157'dir; bu değer 0,01'den büyüktür. Bu sonuçla hipotezimiz reddedilemez ve günlük BTC serisinin %99 güvenilirlikle durağan olmadığı ve birim kök içerdiği sonucuna varılır. Serinin durağan hale getirilmesi için bir fark işlemi uygulanmış ve sonuçlar Tablo 3'de verilmiştir.

Tablo 3: Birinci dereceden farkı alınmış günlük BTC verisinin ADF test istatistik sonucu

	t-istatistik	p-değeri
ADF Test İstatistiği	-55.224	0.0001

$H_0: \delta = 0$ Seri durağan değildir.

$H_1: \delta < 0$ Seri durağandır.

Tablo 3'e göre elde edilen p-değeri 0,0001'dir; ki bu değer 0,01'den küçüktür. Bu sonuçla hipotezimiz reddedilir ve serinin istatistiksel olarak %99 güvenilirlikle durağan hale geldiği sonucuna varılır. Dolayısıyla, fark alma işlemi sonlandırılır.

ARIMA için olası modeller arasından en uygun olanı seçerken, birkaç önemli kriter göz önünde bulundurulmaktadır. Bu kriterler arasında katsayıların anlamlılığı, modelin açıklayıcılığını ve performansını değerlendiren bilgi kriterleri olan Akaike Bilgi Kriteri (AIC)

ve Schwarz Bilgi Kriteri (SIC) kullanılmıştır. Bu çalışma kapsamında, BTC verileri için yapılan analizler sonucunda en uygun modelin ARIMA(10, 1, 9) olarak belirlendiği tespit edilmiştir. Modelin özellikleri Tablo 4'te sunulmuştur.

Tablo 4: Günlük Bitcoin serisine ait ARIMA modeli

Değişken	Katsayı	Std. Hata	t-istatistik	p-değeri
C	22.959	22.972	0.999	0.318
AR(10)	0.037	0.012	3.138	0.002
MA(9)	-0.935	0.037	-25.466	0.000
AIC(Akaike Info Criterion)	16.355			
SIC(Schwarz Criterion)	16.398			

Modelin doğruluğunu ve güvenilirliğini sağlamak için yapılan diğer testler arasında ACF (Autocorrelation Function) ve PACF (Partial Autocorrelation Function) testleri yer almaktadır. Bu testler, modelin doğru parametrelerle belirlendiğini ve gelecekteki tahminlerin güvenilir olduğunu doğrulamaktadır.

Durbin-Watson testi ile modelin hata terimlerinin bağımsız olup olmadığı kontrol edilmiştir. Testin sonucu olan Durbin-Watson değeri 2.05, hata terimlerinin bağımsız olduğunu ve modelin doğruluğunu artırdığını göstermektedir.

Ayrıca, modelin hata terimlerinin homoskedastik olup olmadığı White testi ile test edilmiştir. Testin p-değeri 0.38 olup, hata terimlerinin sabit varyansa sahip olduğunu ve heteroskedastik bir sorun olmadığını ortaya koymaktadır.

Son olarak, Jarque-Bera testi ile modelin hata terimlerinin normal dağılıp dağılmadığı kontrol edilmiştir. Testin p-değeri 0.21 bulunmuş, bu da hata terimlerinin normal dağıldığını göstermektedir.

Modelin belirlenmesinde, en fazla anlamlı katsayıların elde edilmesi, modelin güvenilirliğini artıran bir faktör olmuş ve AIC ve SIC değerlerinin sırasıyla 16,355 ve 16,398 ile en düşük değerleri göstermesi, ARIMA(10, 1, 9) modelinin diğer alternatif modellere göre daha uygun olduğunu ortaya koymaktadır.

Bu testlerin tümü, ARIMA modelinin geçerliliğini ve güvenilirliğini desteklemektedir. Sonuçlar, modelin tahminler için uygun ve güvenilir bir araç olduğunu ortaya koymaktadır.

5.2. Ethereum İçin ARIMA Model Sonuçları

ETC fiyat tahmini için ARIMA modeli uygulamak için öncelikle serinin durağanlığı ADF testi ile test edilmiş ve sonuçlar Tablo 5'de verilmiştir.

Tablo 5: Günlük ETH verisine ait ADF test istatistik sonucu

	t- istatistik	p- değeri
ADF Test İstatistiği	-1,122	0,709

$H_0: \delta = 0$ Seri durağan değildir.

$H_1: \delta < 0$ Seri durağandır.

Tablo 5'e göre elde edilen p-değeri 0,709'dur ve bu değer 0,01'den büyüktür. Bu sonuçla hipotezimiz reddedilemez ve günlük ETH serisinin %99 güvenilirlikle durağan olmadığı sonucuna varılır. Seriyi durağan hale getirmek için birinci derece fark alma işlemi yapılmış ve sonra seri durağan hale getirilmiştir sonuçlar Tablo 6'da verilmiştir.

Tablo 6: Birinci dereceden farkı alınmış günlük ETH verisinin ADF test istatistik sonucu

	t-istatistik	p-değeri
ADF Test İstatistiği	-20.114	0.000

$H_0: \delta = 0$ Seri durağan değildir.

$H_1: \delta < 0$ Seri durağandır.

Tablo 6'ya göre elde edilen p-değeri 0,000'dır ve bu değer 0,01'den küçüktür. Bu sonuçla, hipotezimiz reddedilir ve serinin % 99 güvenilirlikle durağan hale geldiği sonucuna varılır.

ETH verileri için yapılan analizler sonucunda en uygun modelin ARIMA(5,1,7) olarak belirlendiği tespit edilmiştir. Modelin özellikleri Tablo 7'te sunulmuştur.

Tablo 7: Günlük ETH serisine ait ARIMA modeli

Değişken	Katsayı	Std. Hata	t-istatistik	p-değeri
C	0.002	0.001	1.472	0.141
AR(5)	0.899	0.038	23.480	0.000
MA(7)	-0.041	0.018	-2.279	0.000
AIC(Akaike Info Criterion)	-3.079			
SIC(Schwarz Criterion)	-3.069			

Tablo 7 incelendiğinde, olası modeller arasında en fazla anlamlı katsayıya sahip ve en düşük AIC ile SIC değerlerine sahip olan ARIMA (5,1,7) modelinin en uygun model olduğu belirlenmiştir.

ETH için de modelin doğruluğunu ve güvenilirliğini test etmek amacıyla birkaç istatistiksel test daha yapılmıştır. ACF ve PACF testleri ile modelin hata terimlerinin bağımsız olup olmadığı kontrol edilmiştir. Bu testler, modelin doğru parametrelerle belirlendiğini ve gelecekteki tahminlerin güvenilir olduğunu doğrulamaktadır.


White testi için p-değeri 0,29 olup, bu sonuç hata terimlerinin sabit varyansa sahip olduğunu göstermektedir. Ayrıca, Jarque-Bera testi için p-değeri 0,18

bulunmuş olup, bu da hata terimlerinin normal dağıldığı varsayımını sağlamaktadır.

Sonuç olarak, yapılan tüm testler modelin geçerliliğini ve güvenilirliğini doğrulamaktadır. ARIMA modelinin uygunluğu ve doğruluğu, ACF, PACF, White testi ve Jarque-Bera testi sonuçlarıyla güçlendirilmiştir. Bu testler, modelin ETH fiyatlarının tahmininde güvenilir bir araç olduğunu göstermektedir.


5.3. Bitcoin İçin Yapay Sinir Ağları Model Sonuçları

BTC veri seti için Matlab programı kullanılarak YSA yöntemi ile veri setinin %80 eğitim, %10 doğrulama ve %10 test olarak bölünmesi, makine öğrenimi ve zaman serisi tahmin çalışmalarında yaygın bir uygulamadır. Bu oran, modelin hem yeterli sayıda veriyle eğitilmesini hem de doğruluk ve genelleme kapasitesinin etkili bir şekilde ölçülmesini sağlamaktadır. Eğitim verisi, model parametrelerinin optimize edilmesinde kullanılırken; doğrulama ve test verileri, modelin farklı veri setleri üzerindeki performansını değerlendirmektedir. Şekil 3 ile Neural Network kısmında 1 giriş, 1 çıkış ve 10 nöronlu ara katmanı olan YSA yapısı görülmektedir. Eğitim sırasında veriler rastgele alınmış ve Levenberg-Marquardt algoritması kullanılmıştır. Model performans ölçümünde HKO ölçütü kullanılmıştır. Eğitim 18 iterasyonda tamamlanmış, performans değeri 1.39e+09 ve veri değişim oranı 5.73e+09 olarak elde edilmiştir

Şekil 3: Günlük BTC serisine ait YSA modeli


Şekil 4'de, eğitim, doğrulama ve test veri setlerinin yanı sıra modelin genel başarı oranları da görülmektedir. Eğitim verilerinde başarı oranı $R=0,99863$, doğrulama verilerinde $R=0,99869$ ve test verilerinde $R=0,99865$ olarak hesaplanmıştır. BTC verilerine ait yapay sinir ağıımızın toplam model başarısı ise 0,99864'tür. Bu yüksek R değerleri, modeldeki öğrenme işleminin oldukça başarılı olduğunu göstermektedir.

Şekil 4: BTC verisine ait modeldeki gizli katmanda eğitim, doğrulama, test ve tüm model sonuçlarına göre tahmin başarısı grafiği




5.4. Ethereum İçin Yapay Sinir Ağları Model Sonuçları
ETH için veri setinin %80'i eğitim, %10'u doğrulama ve %10'u test olarak kullanılarak YSA yöntemiyle tahmin yapılmıştır.

Şekil 5: Günlük ETH serisine ait YSA modeli



Şekil 5'de görülen model, 1 giriş, 1 çıkış ve 10 nöronlu ara katmandan oluşmaktadır. Eğitimde LM algoritması kullanılmış ve model performansı HKO ile ölçülmüştür. Eğitim 14 iterasyonda tamamlanmış, performans değeri $1.03e+07$ ve veri değişim oranı $4.53e+07$ olarak bulunmuştur.

Şekil 6: ETH verisine ait modeldeki gizli katmanda eğitim, doğrulama, test ve tüm model sonuçlarına göre tahmin başarısı grafiği



Şekil 6'da, eğitim, doğrulama ve test veri setlerinin yanı sıra modelin genel başarı oranları da görülmektedir. Eğitim verilerinde başarı oranı $R=0.99833$, doğrulama verilerinde $R=0.99759$ ve test verilerinde $R=0.99795$ olarak hesaplanmıştır. Ethereum verilerine ait yapay sinir ağımızın toplam model başarısı ise 0.99814 'tür. Bu yüksek R değerleri, modeldeki öğrenme işleminin oldukça başarılı olduğunu göstermektedir.

5.5. ARIMA ve Yapay Sinir Ağları İle Tahmin Sonuçlarının Değerlendirilmesi

Özellikle 2022 yılının ilk aylarında hem küresel hem de ekonomik etkenler sebebiyle kripto para piyasasında önemli dalgalanmalar gerçekleşmiştir. ABD Merkez Bankası'nın faiz artırma beklentileri ve enflasyonist baskılar, yatırımcıları daha güvenli limanlara yönlendirmiş, bu da BTC ile ETH'de ciddi değer kayıplarına yol açmıştır. Bu sebeple 2022 yılının Ocak ayı için ARIMA ve YSA modellerinin tahmin performanslarının değerlendirilmesi model karşılaştırılması için önemli olacaktır.

2022 yılı Ocak ayına ait verilerine dayalı grafikler, ARIMA ve YSA modellerinin piyasa dinamiklerini ne kadar doğru yansıttığını kapsamlı bir şekilde incelemeye olanak tanımıştır.

Şekil 7'de 2022 yılı Ocak ayına ait BTC günlük fiyat gerçek değerleri, YSA modeli ve ARIMA modeli kullanılarak yapılan tahmin değerleri sunulmuştur. Tablo incelendiğinde, BTC için YSA ve ARIMA modelleriyle yapılan tahminlerin, gerçek değerlere oldukça yakın olduğu görülmüştür.

Şekil 7: 2022 yılı Ocak ayı günlük BTC verisine ait gerçek ve tahmini değer karşılaştırma grafiği



Tablo 8’de ARIMA ve YSA modelleri ile hesaplanan 2016-2024 yıllarına ait BTC verilerine ilişkin HKO değerleri verilmiştir. ARIMA yöntemi kullanılarak yapılan tahminler; 2018, 2019, 2021 ve 2024 yılları için daha iyi performans gösterirken; YSA yöntemi ise 2016, 2017, 2020, 2022 ve 2023 yılları için daha iyi tahmin performansına sahiptir. Yıllara göre YSA’nın tercih edilebilir olduğu söylenebilir.

Tablo 8: ARIMA ve YSA modellerine ile elde edilen 2016-2024 yılları BTC günlük verilerine ait HKO değerleri

	HKO Değerleri	Kripto Paralar	HKO Değerleri	
ARIMA	807,92	BTC 2016	340,88	YSA
	142.712,20	BTC 2017	142.439,34	
	147.261,96	BTC 2018	148.369,13	
	104.873,06	BTC 2019	105.371,50	
	181.884,88	BTC 2020	179.886,87	
	3.477.590,93	BTC 2021	3.638.382,25	
	1.034.360,18	BTC 2022	1.034.308,27	
	432.112,91	BTC 2023	430.385,26	
	1.809.908,22	BTC 2024	1.866.299,23	

Şekil 8: 2022 yılı Ocak ayı günlük ETH verisine ait gerçek ve tahmini değer karşılaştırma grafiği



Şekil 8’de 2022 yılı Ocak ayına ait ETH günlük fiyat gerçek değerleri ve tahmin değerleri sunulmuştur. Tablo incelendiğinde, ETH için YSA ve ARIMA modelleriyle yapılan tahminlerin, gerçek değerlere oldukça yakın olduğu görülmüştür.

Tahmin değerlerinin, gerçek fiyat verileriyle olan uyumunu görsel olarak sergileyerek, modellerin performansını değerlendirmeye olanak tanımaktadır. Özellikle, YSA ve ARIMA modellerinin tahminlerinin zaman içindeki değişimlerle nasıl örtüştüğü ve hangi modelin daha tercih edilebilir sonuçlar verdiği belirgin hale getirilmiştir.

Tablo 9: ARIMA ve YSA modelleri ile elde edilen 2016-2024 yılları ETH günlük verilerine ait HKO değerleri

	HKO Değerleri	Kripto Paralar	HKO Değerleri	
ARIMA	3,44	ETH 2016	1,75	YSA
	396,81	ETH 2017	391,14	
	1.373,73	ETH 2018	1.390,93	
	74,50	ETH 2019	69,15	
	248,48	ETH 2020	242,79	
	21.654,40	ETH 2021	23.179,72	
	8.269,08	ETH 2022	8.237,05	
	1.928,81	ETH 2023	1.941,33	
	5.085,23	ETH 2024	4.958,48	

Tablo 9’da, ARIMA ve YSA modelleri ile hesaplanan 2016-2024 yıllarına ait ETH verilerine ilişkin HKO değerleri verilmiştir. ARIMA yöntemi ile 2018, 2021 ve 2023 yılları için tahmin performansları daha iyi iken, YSA yöntemi 2016, 2017, 2019, 2020, 2022 ve 2024 yılları için daha iyi tahmin performansına sahiptir.

6. Sonuç

Bu çalışma ile, BTC ve ETH kripto para birimlerinin fiyat tahmininde kullanılan ARIMA ve YSA yöntemlerinin tahmin performansları karşılaştırılmıştır. YSA modelinin ARIMA modeline göre BTC ve ETH fiyat tahminlerinde kısmen daha iyi sonuçlar verdiği ortaya konulmuştur. Her iki model fiyat hareketlerini öngörmede başarılı olsa da YSA, kripto para piyasasındaki karmaşıklık ve yüksek volatilité olması sebebiyle ARIMA modeline kıyasla daha iyi uyum sağlayabileceği belirlenmiştir.

ARIMA modelinin geleneksel zaman serisi analiz tekniklerine dayalı olması, tahminlerde kısa vadeli fiyat hareketlerini analiz etme yeteneği ve durağan yapıya sahip verilerde daha iyi tahmin sonuçları vermektedir. Ancak bu model, piyasanın beklenmedik ani dalgalanmalara ve mevsimsellik gibi yapısal olmayan değişikliklere karşı duyarlıdır. Literatürde de belirtildiği gibi, ARIMA modeli genellikle kısa vadeli tahminlerde uygunluk göstermekte, fakat volatilitési yüksek piyasalar için sınırlı kalabilmektedir. Bu durum, özellikle kripto para piyasasındaki ani fiyat dalgalanmaları söz konusu olduğunda, ARIMA modelinin bazı dönemlerde tahmin

performansında düşüş yaşamasına sebep olmuştur.

YSA modeli ise, karmaşık veriler arasındaki ilişkileri öğrenme ve doğrusal olmayan ilişkileri modelleme yeteneği sayesinde kripto para piyasası için fiyat tahminlerinde daha başarılı sonuçlar vermektedir. Bu çalışma özelinde, YSA modeli BTC ve ETH gibi kripto paraların fiyat hareketlerinde daha esnek bir yapı sunarak, özellikle ani fiyat dalgalanmaları durumunda ARIMA modeline göre daha iyi tahmin sonuçları vermektedir. Bu bulgu, literatürde finansal piyasa tahminlerinde YSA modellerinin doğruluğunu vurgulayan birçok çalışma ile paralellik göstermektedir.

Bu çalışma; BTC ve ETH gibi piyasa lideri kripto para birimlerinin fiyat tahminine yönelik ARIMA ve YSA yöntemlerini karşılaştırmalı olarak ele alarak literatürdeki önemli bir boşluğu doldurmayı amaçlamaktadır. Özellikle geniş bir zaman periyodunda elde edilen bulgular; YSA modelinin ARIMA'ya kıyasla daha başarılı olduğu, özellikle YSA'nın elde ettiği tahminlerin gerçek verilere daha yakın olduğu gözlemlenmiştir. YSA'nın doğrusal olmayan yapıları öğrenme yeteneği sayesinde zaman serisi tahminlerinde daha yüksek doğruluk sunduğu vurgulanmıştır. Bu da kripto para piyasasının dinamik ve değişken doğası göz önünde bulundurulduğunda YSA'nın daha hassas ve etkili bir araç olabileceğini göstermektedir. Bu bulgular, kripto para piyasasında yatırımcılar ve analistler için YSA tahmin yönteminin kullanılabileceğini ve geliştirilmesi gerektiğini vurgulamaktadır.

Sonuç olarak, kripto para piyasası gibi dinamik ortamlarda YSA'nın ARIMA modeline göre avantajlı olduğunu göstermiştir. Ancak, her iki modelin de eksiklikleri ve üstün yönleri bulunduğundan, literatürde de sıklıkla önerildiği gibi hibrit modeller veya gelişmiş makine öğrenme yaklaşımlarının ele alınması, bu alandaki gelecekteki çalışmalara önemli katkılar sunabilir.

Kaynakça

- Abushukur, A. M. (2022). *Yapay Sinir Ağları ve ARIMA hibrit zaman serisi modeli ile havayolu rezervasyonu tahmini* (Yüksek lisans tezi). Karabük Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliği Anabilim Dalı.
- Akay, M. K., Canik, F., Yeşilyurt, C., & Günkut, M. Ş. (2021). Yapay zeka teknikleri ile kripto para değeri tahmini. *Ekonomi Bilimleri Dergisi*, 14(1), 72-101.
- Akkaş, F. E. (2020). *Balina optimizasyon algoritması ve Levenberg-Marquardt yöntemi ile doğal uçuşma verilerinin ters çözümü için ardışık melez bir yaklaşım* (Yüksek lisans tezi). Süleyman Demirel Üniversitesi, Fen Bilimleri Enstitüsü, Jeofizik Mühendisliği Anabilim Dalı.
- Akkurt, A. (2005). *Yapay sinir ağları ve Türkiye elektrik tüketimi tahmin modeli* (Yüksek lisans tezi). İstanbul

Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliği Anabilim Dalı.

- Al-Sharif, L., & Makhdoom, I. (2021). Machine learning in cryptocurrency trading: A review. *Journal of Finance and Investment Analysis*, 10(1), 1-20.
- Aras, S. (2019). Kripto para fiyatlarının klasik ve yapay sinir ağı modelleri ile tahmini. *Kafkas Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 10(20), 608-640.
- Arslan, B. (2022). Çoklu regresyon, ARIMA ve yapay sinir ağı yöntemleri ile Türkiye elektrik piyasasında fiyat tahmin ve analizi. *Journal of Management and Economics Research*, 20(1), 331-353.
- Atlan, F., Pençe, İ., & Çeşmeci, M. (2020). Kripto paralardan Bitcoin, Ethereum ve Ripple için yapay zekâ ile online fiyat tahmin modeli. *28th Signal Processing and Communications Applications Conference (SIU)*, 2165-0608.
- Aymaz, A. (2024). Kripto Paraların Haczi. *Ankara Üniversitesi Hukuk Fakültesi Dergisi*, 72(4), 1635-1700.
- Aygören, H. S. (2012). İMKB 100 endeksinin yapay sinir ağları ve Newton nümerik arama modelleri ile tahmini. *Uluslararası Alanya İşletme Fakültesi Dergisi*, 4(1), 73-88.
- Benli Keskin, Y., & Yıldız, A. (2014). Altın fiyatının zaman serisi yöntemleri ve yapay sinir ağları ile öngörüsü. *Dumlupınar Üniversitesi Sosyal Bilimler Dergisi*, (42), 213-224.
- Buterin, V. (2013). *Ethereum white paper*. GitHub repository. <https://github.com/ethereum/wiki/wiki/White-Paper>
- Can, A. (2014). *Yapay sinir ağları ile heyelan duyarlılık haritalarının üretilmesinde farklı algoritmaların kullanımının araştırılması* (Yüksek lisans tezi). Hacettepe Üniversitesi, Fen Bilimleri Enstitüsü, Jeoloji Mühendisliği Ana Bilim Dalı.
- Can, M. (2009). *İşletmelerde zaman serileri analizi ile tahmin* (Doktora tezi). İstanbul Üniversitesi, Sosyal Bilimler Enstitüsü, İşletme Anabilim Dalı.
- Crone, S. F. (2004). A business forecasting competition approach to modeling artificial neural networks for time series prediction. In *Proceedings of the International Conference on Artificial Intelligence (IC-AI '04)* (Vol. 1). Las Vegas, NV, USA.
- Çakır, F. S. (2018). Yapay sinir ağları matlab kodları ve matlab toolbox çözümleri. Nobel Akademik Yayıncılık. *Yapay sinir ağları Matlab kodları ve Matlab toolbox çözümleri* (1. baskı). Nobel Kitabevi. Ankara.
- Çarkacıoğlu, A. (2016). *Kripto-para Bitcoin*. Sermaye Piyasası Kurulu Araştırma Dairesi, Araştırma Raporu.
- Çetinkaya, Ş. (2018). Kripto paraların gelişimi ve para piyasalarındaki yerinin SWOT analizi ile incelenmesi.

- Uluslararası Ekonomi ve Siyaset Bilimleri Akademik Araştırmalar Dergisi*, 2(5), 11–21.
- Deveci, M. (2012). *Yapay sinir ağları ve bekleme süresinin tahmininde kullanılması* (Yüksek lisans tezi). Gazi Üniversitesi, Sosyal Bilimler Enstitüsü, İşletme Ana Bilim Dalı, Üretim Yönetimi Bilim Dalı.
- Doğan, G. (2010). *Yapay sinir ağları kullanılarak Türkiye'deki özel bir sigorta şirketinde portföy değerlendirmesi* (Yüksek lisans tezi). Hacettepe Üniversitesi, Fen Bilimleri Enstitüsü, İstatistik Anabilim Dalı.
- Duru, Ö. (2007). *Zaman serileri analizinde ARIMA modelleri ve bir uygulama* (Yüksek lisans tezi). İstanbul Üniversitesi, Sosyal Bilimler Enstitüsü, Ekonometri Anabilim Dalı.
- Eğilmez, M. (2017). *Kendime yazılar: Kripto paralar, Bitcoin ve blockchain*. <https://www.mahfiegilmez.com/2017/11/kripto-paralar-bitcoinve-blockchain.html>
- Erdoğan, E. (2006). *Zaman serilerinde ARIMA modelleri* (Yüksek lisans tezi). Muğla Üniversitesi, Fen Bilimleri Enstitüsü, İstatistik ve Bilgisayar Bilimleri Anabilim Dalı.
- Ergül, B. (2018). Türkiye'deki iş kazalarının zaman serisi analiz teknikleri ve yapay sinir ağları tekniği ile incelenmesi. *Karaelmas Journal of Occupational Health and Safety*, 2(2), 63–74.
- Eylasov, N., & Çiçek, M. (2024). Kripto para fiyatlarının tahmini: ARIMA-GARCH ve LSTM yöntemlerinin karşılaştırılması. *Finans Ekonomi ve Sosyal Araştırmalar Dergisi*, 9(1), 48-62.
- Grossberg, S. (1992). *Neural networks and natural intelligence*. Massachusetts Institute of Technology. The MIT Press. USA.
- Hayradi, D., Hâkim, A., Atmaja, D., & Yutia, S. (2022). Implementation of support vector regression for Polkadot cryptocurrency price prediction. *International Journal of Information Visualization*, 6(1-2), 201-207.
- Kadılar, C. (2005). *SPSS uygulamalı zaman serileri analizine giriş*. Ankara: Bizim Büro Basımevi.
- Kaftan, İ. (2010). *Batı Türkiye gravite ve deprem katalog verilerinin yapay sinir ağları ile değerlendirilmesi* (Doktora tezi). Dokuz Eylül Üniversitesi, Fen Bilimleri Enstitüsü, Jeofizik Mühendisliği Bölümü, Jeofizik Mühendisliği Anabilim Dalı.
- Karahan, M. (2015). Yapay sinir ağları metodu ile ihracat miktarlarının tahmini: ARIMA ve YSA metodunun karşılaştırmalı analizi. *Ege Akademik Bakış*, 15(2), 165–172.
- Kaya, İ., Oktay, S., & Engin, O. (2005). Kalite kontrol problemlerinin çözümünde yapay sinir ağlarının kullanımı. *Erciyes Üniversitesi Fen Bilimleri Enstitüsü Fen Bilimleri Dergisi*, 21(1), 92–107.
- Kaynak, G. (2022). *Kestirimci bakım planlaması için zaman serisi modellerine dayalı arıza zamanı tahmini* (Yüksek lisans tezi). Necmettin Erbakan Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliği Anabilim Dalı.
- Kaynar, O., & Taştan, S. (2009). Zaman serisi analizinde MLP yapay sinir ağları ve ARIMA modelinin karşılaştırılması. *Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 33, 161–172.
- Odabaşı, M. B., & Toklu, M. C. (2023). Yapay sinir ağları ve derin öğrenme algoritmalarının kripto para fiyat tahmininde karşılaştırmalı analizi. *Journal of Intelligent Systems: Theory and Applications*, 6(2), 96-107.
- Ömrüüzun, B. (2019). *Yapay sinir ağları ile kripto paraların fiyat modellemesi* (Yüksek lisans tezi). İstanbul Üniversitesi, Sosyal Bilimler Enstitüsü, İşletme Anabilim Dalı.
- Özdemir, Ö. (2008). *Zaman serisi modellemesinde yapay sinir ağlarının kullanımı ve bir uygulama* (Yüksek lisans tezi). Anadolu Üniversitesi, Fen Bilimleri Enstitüsü, İstatistik Anabilim Dalı.
- Öztemel, E. (2006). *Yapay sinir ağları*. İstanbul: Papatya Yayıncılık.
- Sakız, B., & Gencer, A. H. (2017). Yapay sinir ağları ile bitcoin fiyatını tahminleme. In *International Conference on Eurasian Economies* (pp. 438-444).
- Salehihosseini, P. (2023). *Kripto paralar, blockchain teknolojisi ve kripto paraların kullanım alanları* (Yüksek lisans tezi). Ufuk Üniversitesi, Sosyal Bilimler Enstitüsü, Uluslararası Ticaret ve Finansman Ana Bilim Dalı.
- Salman, M. (2020). Price prediction of different cryptocurrencies using technical trade indicators and machine learning (Yüksek lisans tezi). Altınbaş Üniversitesi, Lisansüstü Eğitim Enstitüsü, Bilgi Teknolojileri Ana Bilim Dalı.
- Saraç, T. (2005). *Yapay sinir ağları ile yazılım proje süresinin tahmini* (Yüksek lisans tezi). Gazi Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliği Anabilim Dalı.
- Statista, (2024). Number of cryptocurrencies 2013-2024 | Statista.
- Sönmez, A. (2014). Sanal para Bitcoin. *The Turkish Online Journal of Design, Art and Communication*, 4(3), 1-14. İstanbul Kültür Üniversitesi.
- Şahin, E. E. (2018). Kripto para Bitcoin: ARIMA ve yapay sinir ağları ile fiyat tahmini. *Fiscoeconomia*, 2(2), 74-92.
- Şahin, Ş. (2002). *Yapay sinir ağları yardımı ile dinamik bir*

senaryo analizi (Doktora tezi) İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliği Ana Bilim Dalı.

- Tanişman, S., Karcioğlu, A. A., Uğur, A., & Bulut, H. (2021). LSTM sinir ağı ve ARIMA zaman serisi modelleri kullanılarak Bitcoin fiyatının tahminlenmesi ve yöntemlerin karşılaştırılması. *Avrupa Bilim ve Teknoloji Dergisi*, 32, 514-520. <https://doi.org/10.31590/ejosat.1039890>
- Tekin, M. (2009). *Üretim yönetimi* (Cilt 1, 6. baskı). Günay Ofset.
- Tuna, M. (2019). *Altın fiyatlarının yapay sinir ağları ve ARMA modelleri ile tahminlenmesi* (Yüksek lisans tezi) Adnan Menderes Üniversitesi, Sosyal Bilimler Enstitüsü, Ekonometri Anabilim Dalı.
- Usta, A., & Doğanterkin, S. (2017). *Blockchain 101 V2*. BKM.
- X, Y., et al. (2020). Comparative study of time series models in cryptocurrency price prediction. *International Journal of Financial Studies*, 8(2), 28.
- Yalçın, E., & Çelik, H. (2020). A comparison of machine learning techniques for predicting Bitcoin prices. *Journal of Economic Studies*, 47(5), 1090-1105.
- Yılmaz, E. (2012). *Hidrolik bir sistemin yapay sinir ağları ile modellenmesi ve katsayıları genetik ve parçacık sürü algoritmaları ile optimize edilmiş PID ile kontrolü* (Yüksek lisans tezi). Marmara Üniversitesi, Fen Bilimleri Enstitüsü, Elektronik ve Bilgisayar Eğitimi Anabilim Dalı.
- Yılmazel, Ö., Afşar, A., & Yılmazel, S. (2018). Konut fiyat tahmininde yapay sinir ağları yönteminin kullanılması. *Uluslararası İktisadi ve İdari İncelemeler Dergisi*, 20, 285-300. <https://doi.org/10.18092/ulikidince.341584>

Extended Summary

Purpose

Especially in recent years, cryptocurrencies have become an important investment tool as an alternative to traditional financial assets. The prices of crypto assets without a central authority are constantly increasing in volatility depending on market conditions and macroeconomic factors. BTC and Ethereum ETH are the leading cryptocurrencies in terms of market value and number of users. The high volatility in BTC and ETC values makes price predictions difficult for investors and market analysts. This situation increases the need for accurate prediction models day by day.

This study aims to compare the effectiveness of ARIMA and ANN models in predicting Bitcoin and Ethereum prices. While the ARIMA model performs time series analysis that deals with more linear relationships based on historical price data, ANN models provide more effective predictions with their complex relationships and multi-layered structures.

This study aims to compare the effectiveness of ARIMA and ANN models in predicting the prices of BTC and ETH cryptocurrencies. While the ARIMA model performs time series analysis that deals with more linear relationships based on historical price data, ANN models offer more effective predictions with their complex relationships and multi-layered structures.

Literature Review

In the existing literature, various forecasting models have been used for cryptocurrencies. Şahin (2018) made BTC price forecast with ANN and ARIMA models; In the evaluations made on MSE and MAPE values, it was revealed that ANN model gave more successful forecasts. In the study of Eylasov and Çiçek (2024), the forecasting performances obtained by using ARIMA-GARCH and LSTM (Long Short-Term Memory) deep learning approach from traditional time series methods to forecast BTC, ETH and BNB cryptocurrency returns were compared and it was revealed that both methods showed good performance for different situations. While Al-Sharif and Makhdoom (2021) used machine learning methods in cryptocurrency price forecasting, X et al. (2020) showed the applicability of time series analysis for cryptocurrency forecasting. Yalçın and Çelik (2020) showed that price forecasts made with ANN offer significant advantages over traditional methods. However, the comparison of ARIMA and ANN models has often been overlooked. This study aims to fill the gap in the literature and provide a more comprehensive understanding by comparing the forecasting performances of traditional statistical methods, ARIMA time series and ANN models.

Design/Methodology/Approach

This study is designed as an applied research. In order to analyze the daily price data of BTC and ETH obtained from Investing.com, which is a secondary data source, data between April 1, 2016 and March 1, 2024 were used. In the design of the study, in the data preparation process, the

completion of missing data, the data being made stationary for the ARIMA model, and the determination of the most appropriate parameters were ensured. For the ANN model, the most appropriate prediction model was determined according to the HKO criterion as a result of statistical analysis and model validation methods, using 80% of the data as training, 10% as test and 10% as validation data.

Findings

The aim of the study is to examine the accuracy of ARIMA and ANN models in price predictions in terms of error rates and performance indicators and to determine which model provides better results. The results obtained show that both models are applicable under certain conditions in the cryptocurrency market; however, they also emphasize the effect of high volatility on the prediction processes. In addition, the study aims to contribute to existing models in the literature and provides important data to market analysts, investors and researchers.

As a result, this study will evaluate the effectiveness of the methods used for the prediction of cryptocurrencies, allowing more conscious action in making investment decisions. In addition, the findings obtained will form a basis for future cryptocurrency prediction studies and contribute to research in this field.