



Open Access Journal
e-ISSN: 2619 - 8991

Araştırma Makalesi (Research Article)

Cilt 8 - Sayı 4: 1057-1066 / Temmuz 2025

(Volume 8 - Issue 4: 1057-1066 /July 2025)

BLOCKCHAIN DESTEKLİ NESNELERİN İNTERNETİ (IOT) VARLIKLARINDA FİYAT TAHMİNİ İÇİN MODEL KARŞILAŞTIRMASI

Çağatay ERSİN^{1*}, Onur KÖKTÜRK²

¹Çankırı Karatekin University, Vocational School, Department of Electronics and Automation, 18200, Çankırı, Türkiye

²Çankırı Karatekin University, Vocational School, Department of Finance, Banking and Insurance, 18200, Çankırı, Türkiye

Özet: Teknolojik gelişmelerin hız kazanmasıyla birlikte Nesnelerin İnterneti (IoT - Internet of Things), küresel ölçekte üretim süreçlerinden akıllı şehir uygulamalarına, kişisel sağlık izleme cihazlarından akıllı spor kıyafetlerine kadar geniş bir yelpazede dönüşüme katkı sağlamaktadır. Nesnelerin İnterneti, cihazların birbirleriyle ve veri merkezleriyle etkileşime geçerek büyük miktarda veri ürettiği bir ekosistem yaratmaktadır. Bu bağlamda, IoT teknolojilerine dayalı blok zinciri tabanlı kripto varlıklar da gelişim göstermiştir. Bu çalışmanın amacı, IoT temalı kripto varlıklardan Vechain (VET), IOTA ve Helium (HNT) için fiyat tahmini yapmaktır. Çalışmada 02.01.2020 - 10.12.2024 tarihleri arasındaki Vechain ve IOTA, 09.06.2020 - 10.12.2024 tarihleri arasındaki Helium coinin günlük kapanış fiyatları kullanılmıştır. Fiyat tahmini için Karar Ağaçları (Decision Trees), Rassal Orman (Random Forest) ve Destek Vektör Regresyonu (SVR) modelleri karşılaştırılmıştır. Karar ağaçları modeli, geçmiş fiyat verilerini baz alarak gelecekteki fiyat hareketlerini tahmin etmeyi amaçlamaktadır. Rassal Orman algoritması, birden fazla karar ağacının bir araya getirilmesiyle oluşan topluluk öğrenme yöntemini kullanarak daha sağlam ve genellenebilir tahminler sunmaktadır. Destek Vektör Regresyonu (SVR) ise veri noktaları arasındaki karmaşık ilişkileri daha iyi yakalamak için hiper düzlemleri kullanarak doğrusal olmayan regresyon modelleri oluşturur. Modellerin performansı Mean Squared Error (MSE) ve R^2 (R-kare) skoru gibi metriklerle değerlendirilmiştir. Sonuçlar, Rassal Orman modelinin Helium ve IOTA coinlerin tahminlerinde yüksek doğruluk sağladığını, VeChain coin için ise SVR'nin daha iyi modellediğini ortaya koymuştur. Karar Ağaçları modeli, bağımsız tahminler üretme konusunda başarılı olmakla birlikte diğer modellere göre nispeten daha düşük performans göstermiştir.

Anahtar kelimeler: Kripto varlıklar, Karar ağaçları, Rassal orman, Destek vektör regresyonu

Model Comparison for Price Prediction in Blockchain-Enabled Internet of Things (IoT) Assets

Abstract With the acceleration of technological developments, the Internet of Things (IoT) contributes to a wide range of transformations, from global production processes to smart city applications, from personal health monitoring devices to smart sportswear. The Internet of Things creates an ecosystem where devices interact with each other and data centers to produce large amounts of data. In this context, blockchain-based crypto assets based on IoT technologies have also developed. The aim of this study is to make a price prediction for IoT themed crypto assets Vechain (VET), IOTA and Helium (HNT). In the study, the daily closing prices of Vechain and IOTA between 02.01.2020 - 10.12.2024, and Helium coin between 09.06.2020 - 10.12.2024 were used. Decision Trees, Random Forest and Support Vector Regression (SVR) models were compared for price prediction. The decision tree model aims to predict future price movements based on past price data. The Random Forest algorithm provides more robust and generalizable predictions by using the ensemble learning method formed by combining multiple decision trees. Support Vector Regression (SVR) creates non-linear regression models using hyperplanes to better capture complex relationships between data points. The performance of the models was evaluated with metrics such as Mean Squared Error (MSE) and R^2 (R-squared) score. The results showed that the Random Forest model provided high accuracy in predictions for Helium and IOTA coins, while SVR modelled better for VeChain coin. The Decision Tree model was successful in producing independent predictions but showed relatively lower performance than other models.

Keywords: Cryptocurrency, Decision trees, Random forest, Support vector regression

*Sorumlu yazar (Corresponding author): Çağatay ERSİN, Çankırı Karatekin University, Vocational School, Department Of Electronics and Automation, 18200, Çankırı, Türkiye

E mail: cagatayersin@karatekin.edu.tr (Ç. ERSİN)

Çağatay ERSİN  <https://orcid.org/0000-0001-5018-9313>

Onur KÖKTÜRK  <https://orcid.org/0000-0002-8603-8063>

Gönderi: 26 Mart 2025

Kabul: 15 Mayıs 2025

Yayınlanma: 15 Temmuz 2025

Received: March 26, 2025

Accepted: May 15, 2025

Published: July 15, 2025

Cite as: Çağatay E, Köktürk O. 2025. A model comparison for price prediction in blockchain-enabled internet of things (IoT) assets. BSJ Eng Sci, 8(4): 1057-1066.

1. Giriş

Nesnelerin Ağı olarak da bilinen Nesnelerin İnterneti (IoT); çoğu zaman her yerde bulunan zekâ ile donatılmış sıradan nesnelerin ağ bağlantılı etkileşimini ifade

etmektedir. IoT, gömülü sistemler aracılığıyla nesneleri etkileşim için entegre ederek, insanlarla ve diğer cihazlarla iletişim kuran dağıtılmış bir cihaz ağı oluşturmaktadır. Temel teknolojilerdeki hızlı gelişmeler sayesinde son yıllarda dünya çapındaki araştırmacılar ve



uygulayıcılar tarafından büyük ilgi gören IoT, yaşam kalitemizi iyileştirmeyi vaat eden birçok yenilikçi uygulama için büyük fırsatlar sunmaktadır. Bu teknoloji, bilgi işlem gücündeki ilerlemelerden, elektroniklerin minyatürleştirilmesinden (electronics miniaturization) ve ağ bağlantılarından yararlanarak daha önce mümkün olmayan yeni yetenekler sunan geniş bir ağ bağlantılı ürün, sistem ve sensör yelpazesinde somutlaşmıştır. IoT, teknik, sosyal ve ekonomik açıdan önemli bir gelişen konudur ve tüketici ürünleri, dayanıklı mallar, arabalar ve kamyonlar, endüstriyel ve kamu hizmeti bileşenleri, sensörler ve diğer günlük nesneler, internet bağlantısı ve güçlü veri analitiği yetenekleriyle birleştirilerek çalışma, yaşama ve eğlenme biçimlerini dönüştürme potansiyeline sahiptir. IoT cihazlarının geniş çaplı uygulanması, yaşamımızın birçok yönünü dönüştürme potansiyeline sahiptir. Tüketiciler için, İnternet'e bağlı cihazlar, ev otomasyon bileşenleri ve enerji yönetim cihazları gibi yeni IoT ürünleri, daha güvenli ve enerji verimli bir "akıllı ev" vizyonuna doğru ilerlemektedir. Kişisel IoT cihazları, giyilebilir spor kıyafetleri ve sağlık izleme cihazları ile ağ bağlantılı tıbbi cihazlar, sağlık hizmetlerinin sunulma biçimini dönüştürmektedir. Bu teknoloji, engelli bireyler ve yaşlılar için daha yüksek seviyede bağımsızlık ve yaşam kalitesi sunarken, bunu makul bir maliyetle gerçekleştirebilmektedir. Ağ bağlantılı araçlar, akıllı trafik sistemleri ve yollara ve köprülere gömülü sensörler gibi IoT sistemleri, bizi "akıllı şehirler" fikrine daha da yaklaştırmaktadır. Bu şehirler, trafik sıkışıklığını ve enerji tüketimini en aza indirmeye yardımcı olabilmektedir. IoT teknolojisi ayrıca, üretim değer zinciri boyunca ağ bağlantılı sensörler aracılığıyla bilgiye erişimi artırarak tarım, sanayi ve enerji üretimi ve dağıtımını dönüştürme olasılığı sunmaktadır (Rose, 2015; Xia, 2012). Bilgi teknolojisi (IT) ve operasyonel teknoloji (OT), tarihsel olarak bağımsız çalışmıştır. Ancak, IoT'un artan kullanımı, IT ve OT'nin birleşmesine yol açmıştır. Bu birleşim, iş dünyasına fayda sağlarken aynı zamanda ölçeklenebilirlik, güvenlik, gizlilik, birlikte çalışabilirlik ve büyük veri analitiği gibi birçok zorluğu da beraberinde getirmiştir. IoT ağlarında güvenlik, en büyük endişelerden biridir (Dange ve Nitnaware, 2024). Çünkü IoT'nin kesintisiz çalışması için yalnızca kimliği doğrulanmış ve yetkilendirilmiş cihazlara erişilebilir olması gerekmektedir. Aksi takdirde, bilgi hırsızlığı, veri değişikliği ve kimlik hırsızlığı gibi çeşitli güvenlik risklerinin hedefi haline gelebilmektedir.

IoT'nin bilgi bütünlüğünü korumak için geleneksel güvenlik mekanizmaları tek başına yeterli olmamaktadır (Vishwakarma ve Das, 2021). IoT ağına bağlı cihazların sayısı arttıkça, bu veriler genellikle şifrelenmez ve gizlilik sağlamamaktadır. Bu bağlamda, blockchain teknolojisi büyük faydalar sunabilmektedir. Çünkü elde edilen verilerin anonimliğini hızla güvence altına alınabilmektedir (Ahamad, 2022). Bu nedenle IoT'un güvenliğini sağlamak amacıyla, merkeziyetsiz ve dağıtık bir yaklaşım olarak blok zincir (blockchain) önerilmiştir

(Wang vd., 2020). Merkeziyetsiz sistemler, belirli bir otoriteye veya donanımına bağlı kalmaksızın gizlilik ve ölçeklenebilirlik sağlayabilmektedir. Bu bağlamda, Dağıtık Defter Teknolojileri, IoT ekonomisinin uygulanmasında önemli kolaylaştırıcılar olabilmektedir (Silvano ve Marcelino, 2020). İşlemlerin kaydını katılımcı bilgisayarlardan oluşan bir ağ üzerinde dağıtılmış şekilde tutulan ve 2009 yılında anonim bir geliştirici grubu tarafından geliştirilen Bitcoin, sanal bir para biriminin kullanımını, elektronik ödemeler de dahil olmak üzere, kolaylaştıran bir çevrimiçi iletişim protokolüdür (Böhme vd., 2015).

Bitcoin, bankalar ve finansal kurumlar gibi araçları devre dışı bırakarak işlem yapılmasına ve işlemlerin bireyler arasında doğrudan (peer-to-peer) gerçekleşmesine olanak tanımaktadır (Fauzi vd., 2020). Daha sonraki süreçte geliştirilen ve Bitcoin'den sonra en büyük kripto para platformu olarak kabul edilen Ethereum, Bitcoin'den farklı olarak yalnızca bir dijital para birimi değil, tamamen programlanabilir bir blok zinciri platformudur. Bitcoin, merkeziyetsiz bir değer saklama aracı olarak tasarlanmışken, Ethereum akıllı sözleşmelerin ve merkeziyetsiz uygulamaların (DApp'ler) geliştirilmesi ve çalıştırılmasını kolaylaştırmaktadır. Bu uygulamalar, merkezi araçlara ihtiyaç duymadan otonom bir şekilde çalışabilir ve bu sayede merkeziyetsiz finans (DeFi), tedarik zinciri yönetimi ve değiştirilemez tokenler (NFT'ler) gibi çeşitli sektörlerde daha fazla verimlilik ve şeffaflık sağlamaktadır (Krause, 2024).

Çalışma IoT tabanlı çözümler oluşturmaya hedef alan kripto varlıkları incelemektedir. Bu bağlamda, çalışmada VeChain, IOTA ve Helium kripto varlıklarının geliştirilme amaçları ele alınacaktır. VeChain, şeffaf bilgi akışını, verimli iş birliğini ve yüksek hızlı değer transferlerini mümkün kılmayı hedefleyen güven gerektirmeyen ve dağıtık bir iş ekosistemi yaratmayı amaçlayan bir blok zincir platformudur. VeChain'in çözümü, ürünlerin üretim, lojistik ve tedarik zinciri, perakende ve toptan satış, satış sonrası hizmet ve hatta IoT teknolojileriyle birlikte sahteciliğe karşı blockchain üzerinde tüketici katılımı gibi yaşam döngüsünü kapsayan bir ürün izlenebilirliği çözümü oluşturmaya hedeflemektedir. Moda ve lüks markalar, VeChain çözümlerinin canlı ürünler için uygulamaya koymakta ve sahtecilik faaliyetlerinde büyük azalma sağlamaktadır (VeChain Development Plan and Whitepaper, 2018).

IoT'a bağlı bütün cihazlar çevrimiçi olduğu zaman hücresel, WiFi ve Bluetooth gibi mevcut çözümler yetersiz kalacaktır. Ayrıca tüm bu süreç çok pahalı olacak ve mevcut bağlantılar çok fazla güç tüketecek veya menzilleri çok sınırlı kalacaktır. Bu sorunlara çözüm üretmek için geliştirilen Helium ağı, dünyanın herhangi bir yerindeki cihazların, enerji tüketen uydular konumlandırma donanımına veya pahalı hücresel planlara ihtiyaç duymadan kablosuz olarak internete bağlanmasını ve kendi konumlarını belirlemesini sağlayan merkeziyetsiz bir kablosuz ağıdır. Güvenli ve açık kaynaklı, geliştiricilerin düşük güç tüketen, internete

bağlı cihazları hızlı ve uygun maliyetli bir şekilde oluşturmalarını sağlamayı amaçlayan Helium ağı, birçok sektörde geniş bir uygulama yelpazesine sahiptir ve türünün ilk merkeziyetsiz kablosuz ağıdır. Helium ağı, geniş alan kablosuz bir ağ sistemi, bir blockchain ve bir protokol token'ından oluşmaktadır. Blockchain, Helium Konsensüs Protokolü (Helium Consensus Protocol) adı verilen yeni bir konsensüs protokolü ve Kapsama Kanıtı (Proof-of-Coverage) üzerinde çalışmaktadır. Kablosuz ağ kapsama alanı sağlayan madenciler, kriptografik olarak doğrulanmış fiziksel bir konum ve zamanda kanıtlarını Helium ağına sunmaktadır (Haleem, 2018). IOTA, 2015 yılında oluşturulmuş bir dağıtık defter platformudur ve "blok zincirsiz kripto para birimi" olarak tanımlanmıştır. IOTA'nın tüm para birimi önceden oluşturulmuştur; dolayısıyla madencilik süreci bulunmamaktadır. Toplam IOTA miktarı yaklaşık 2,8 Peta olarak belirlenmiştir. IOTA, piyasa değeri açısından en önemli ilk on kripto para biriminden biri olarak kabul edilmektedir. IOTA'nın amacı, IoT cihazları arasındaki işlemleri desteklemek ve güçlendirmektir. IOTA, blockchain teknolojisinin dezavantajlarını doğal olarak çözer ve eşler arası mikro ödeme sistemi oluşturmak için gereken özellikleri sunmaktadır. Bu teknolojinin diğer dağıtık defter teknolojilerinden farkı, işlemleri depolamak için blockchain yerine Yönlendirilmiş Döngüsüz Grafik olarak bilinen Tangle adı verilen bir yapıya dayanmasıdır (Alshaikhli vd., 2021; Saa vd., 2023). Bu çalışmanın temel amacı, IoT temalı kripto varlıklar olan Vechain (VET), IOTA ve Helium (HNT) coin'lerinin günlük kapanış fiyatlarını kullanarak fiyat tahmini yapmaktır. Çalışma, 02.01.2020 - 10.12.2024 tarihleri arasındaki Vechain ve IOTA ile 09.06.2020 - 10.12.2024 tarihleri arasındaki Helium kripto varlıklarının fiyat hareketlerini kapsamaktadır.

Literatür incelendiğinde, söz konusu IoT tabanlı kripto varlıkların fiyat tahmini üzerine yapılan çalışmaların oldukça sınırlı olduğu görülmektedir. Bu nedenle, çalışma kripto varlık piyasasında IoT temalı coin'lerin fiyat hareketlerinin öngörülmesine yönelik katkı sağlamayı amaçlamaktadır. Fiyat tahmini için Karar Ağaçları (Decision Trees), Rassal Orman (Random Forest) ve Destek Vektör Regresyonu (SVR) algoritmaları kullanılmıştır. Karar Ağaçları algoritması, geçmiş fiyat verilerini baz alarak doğrudan bir tahminleme süreci yürütmektedir. Rassal Orman, birden fazla Karar Ağacı modelinin çıktılarının birleştirilmesiyle oluşturulan güçlü bir topluluk öğrenme yöntemidir. SVR ise doğrusal olmayan regresyon modelleri oluşturarak fiyat hareketlerindeki karmaşık ilişkileri daha iyi modellemeyi amaçlamaktadır.

1.1. Literatür

Finansal varlıklara olan ilginin arttığı günümüzde başta yatırımcılar olmak üzere araştırmacıların da finansal varlık fiyatlarını tahmin etmek belirsizliği de azaltmak adına daha da önem kazanmaktadır. Sadece geleneksel finansal ürünlerinde değil yüksek volatiliteye sahip kripto varlıklarında fiyat hareketleri tahmin etme

üzerine yapılan çalışmalar gün geçtikçe daha da artmaktadır. Geleneksel ekonometrik yöntemlerin yanı sıra gelişen bilişim teknolojisine bağlı olarak makine ve derin öğrenme modelleri kullanarak da tahmin modelleri oluşturulmaktadır.

Kantar (2020) 2009-2019 dönem aralığı için BIST 100 endeksini Yapay Sinir Ağları ve ARMA (1,1) modeli kullanarak döviz kuru sepeti, altın, mevduat faizi, sanayi üretim endeksi, emisyon, doğrudan portföy yatırımları ve sermaye yatırımları gibi makroekonomik değişkenler ile tahmin etmeyi amaçladığı çalışmasında; Yapay Sinir Ağlarının daha yüksek R2 değerine ve daha küçük MSE değerine sahip olduğu için daha iyi tahmin performansına sahip olduğunu vurgulamıştır.

Akel ve Bayramoğlu (2008) 04.01.1999-28.02.2001 dönem aralığında ve finansal krizin varlığında ABD Doları, Merkez Bankası Döviz Rezervleri, İMKB işlem hacmi, 1 aylık mevduat faiz oranı ve Altın Borsası kapanış fiyatlarını girdi değişkeni olarak seçip Yapısal Sinir Ağları yöntemi ile İMKB 100 endeksi için yaptığı tahminlemede çok katmanlı ve geri besleme algoritması ile başarılı bir tahminleme yapmışlardır.

Altan (2008) yaptığı çalışmasında Ocak 1987- Eylül 2007 tarih aralığı baz alınarak döviz kuru tahminlemesi yapabilmek için aylık veriler ile yapay sinir ağı ve vektör otoregresif modeli kullanmış ve her iki modelden sağlanan sonuçların tahmin performansını arttırdığını belirtmiştir.

Aygören vd., (2012) İMKB 100 endeksi için mevduat faiz oranı, USD kapanış fiyatları, altın fiyatları ve bankalar arası para piyasası işlem hacmi değişkenleri ile ARMA modeli, Yapay Sinir Ağları için Geri Yayılım Algoritması ve Nümerik Arama Modelleri için Newton yöntemi kullanarak yaptıkları tahminleme modellerinden Yapay Sinir Ağlarının daha iyi tahmin başarısı gösterdiğini bulmuşlardır.

Çalışkan ve Deniz (2015) yaptıkları çalışmalarında BİST30 endeksine ait seçilen 27 şirketin 14.12.2009-21.11.2014 dönem aralığındaki günlük hisse senedi fiyatları esas alınarak 32 adet girdi seti ile Yapay Sinir Ağları yöntemi ile 5 günlük fiyatları ortalamada yüzde 58 başarı oranı ile tahminde bulunmuşlardır.

Akşehir ve Kılıç (2019) 01.01.2016-26.04.2019 dönem aralığı için AKBNK, HALKB, GARAN, YKBK ve ISCTR hisse senetlerine ait 50 adet teknik ve temel analiz göstergesini girdi olarak seçip 33 ve 50 göstergeli olarak iki farklı model Karar Ağacı, Rassal Orman ve Çoklu Regresyon yöntemleri ile tahminlemişlerdir. 33 gösterge ile yapılan modelleme ile elde edilen tahmin sonuçlarının daha iyi olduğu tespit edilmiştir.

Esenyel ve Akın (2017) Euro ve İngiliz Sterlin'i için 3 Ocak 2002-31 Ekim 2016 tarih aralığına ait veri setini baz aldıkları çalışmalarında tahminlemede bulunabilmek için Hızlı Öğrenen Makine (Extreme Learning Machine-ELM), ARMA ve ARMA GARCH modellerini kullanmışlardır. Elde edilen bulgulara göre performans kriterleri ile yapılan karşılaştırmada ELM modelinin daha üstün olduğu bulunmuştur.

Chowdhury vd., (2020) çalışmalarında makine öğrenimi algoritmaları ve modelleri kullanarak kripto para endeksi 30 ve Bitcoin Cash, Bitcoin, Doge coin (DOGE); Dash, IOTA (MIOTA), Ethereum, Litecoin, NEM, NEO gibi dokuz kripto para bileşeninin kapanış fiyatını tahmin etmişlerdir. Çalışmada makine öğrenim modellerinden Topluluk Öğrenme Yöntemi (Ensemble Learning Method), Gradyan Destekli Ağaç Modeli (Gradient Boosted Trees Model), Sinir Ağı Modeli (Neural Net Model, K-En Yakın Komşu (K-NN) Modeli (K-Nearest Neighbor (K-NN) Model) kullanılmış ve en iyi çıktıyı elde etmek için modelleri birbirleriyle karşılaştırılmıştır. Çalışmada kullanılan tüm modeller arasında en iyi sonucu Topluluk Öğrenme Yöntemi %92,4 oranında doğru sonuç elde ederken diğer modellerin aksine, K-NN modeli çok etkili bir tahminleme yapamamıştır.

Lyu (2022) BTC, ETH, DOGE, ADA, XRP, LUNA, BNB, LINK, LTC ve BCH kripto varlıklarının kısa vadeli alım satım işlemleri için zaman serisi verilerini tahmin etmeye odaklanmaktadır. Çalışmada Karar Ağacı, Doğrusal Regresyon, Ridge Regresyon, Lasso Regresyon, Rassal Orman, Bayesyen Regresyon, K-En Yakın Komşu, Sinir Ağları, Gradyan Artırma ve Destek Vektör Makinesi makine öğrenimi algoritmaları seçilmiştir. Çalışmadan elde edilen sonuçlara göre, Ortalama Kare Hata kriteriyle Gradyan Artırma algoritmasının, çoğu büyük kripto para birimini tahmin etmede üstün başarı göstermektedir. Ayrıca, Karar Ağacı ve Rassal Orman modelleri, ETH, XRP, LUNA ve LTC gibi belirli kripto para birimlerinde yüksek performans sergilemiştir. Bu nedenle, bu üç algoritma, kripto para piyasasının kısa vadeli gelişmelerini tahmin etmek için yatırımcılara yardımcı olabileceği belirtilmiştir.

Yürük (2023) New York Borsası'nda (NYSE) kote olan Delta Havayolları'nın hisse senetlerinin 2010 Ocak-2021 Aralık dönem aralığı için aylık fiyatları kullanarak Box-Jenkins yöntemi ile tahminleme yaptığı çalışmasında Box-Jenkins yaklaşımının tahmin çıktılarında başarılı sonuçlar verdiği belirtmiştir.

Eylasov ve Çiçek (2024) yaptıkları çalışmalarında Bitcoin (BTC), Ethereum (ETH) ve Binance (BNB) kripto para getirilerini tahminlemek amacıyla ARIMA-GARCH yöntemi ile birlikte derin öğrenme yöntemlerinden LSTM (Long Short-Term Memory) yaklaşımını kullanarak elde ettikleri modellerin tahmin başarılarını karşılaştırmışlardır. Elde ettikleri model sonuçlarına göre Bitcoin'e ait modellemede eğitim verisinde ARIMAGARCH yöntemi, test verisi için ise LSTM yöntemi daha iyi sonuçlar vermiştir. BNB serisinde ise hem eğitim hem de test verisi için LSTM yöntemi diğer modellere göre daha üstün performans sergilemiştir. Ethereum serisinde ise her iki veri seti için ARIMA-GARCH yönteminin daha iyi sonuçlara sahip vurgulamaktadır.

Parvini (2024) yüksek piyasa değerine sahip üç kripto paranın (Bitcoin, Ethereum ve Ripple) kapanış fiyatını öngörmek için Destek Vektör Regresyonuna (SVR) dayalı bir makine öğrenimi modeli önermektedir. Çalışmada

optimal hiperparametreler, parçacık sürü optimizasyonu (PSO) algoritması uygulanarak elde edilmiştir. Ayrıca PSO-SVR yaklaşımı, MLP (Çok Katmanlı Algılayıcı), LSTM (Uzun Kısa Süreli Bellek), Bi-LSTM (Çift Yönlü Uzun Kısa Süreli Bellek) ve ayrıca basit SVR modeli ile karşılaştırılmıştır. PSO-SVR modeli, tüm kripto paralar ve kullanılan performans ölçütleri açısından karşılaştırmalı modellerin tamamından daha iyi performans göstermektedir.

Katina (2024) çalışmasında Otoregresif Entegre Hareketli Ortalama (ARIMA), Mevsimsel ARIMA (SARIMA), Uzun Kısa Süreli Bellek (LSTM) ve Kapılı Tekrarlayan Birim (Gated Recurrent Unit-GRU) modellerinin Bitcoin, Ethereum, Dogecoin, Polygon ve Toncoin gibi çeşitli kripto paralar üzerindeki tahmin doğruluğunu değerlendirmeyi amaçlamaktadır. Çalışmada her bir modelin doğruluğunu değerlendirmek için Ortalama Kare Hata, Ortalama Mutlak Hata, Kök Ortalama Kare Hata ve Ortalama Mutlak Yüzde Hatası gibi performans ölçütleri kullanılmıştır. Çalışmadan elde edilen bulgulara göre derin öğrenme tekniklerinden yararlanan LSTM ve GRU modellerinin, hata ölçütleri açısından genellikle geleneksel ARIMA ve SARIMA modellerinden daha iyi performans gösterdiğini ortaya koymaktadır.

Bouteska (2024) topluluk öğrenimi ve derin öğrenme tahmin modellerinin kapsamlı bir karşılaştırmalı analizini yaptığı çalışmasında, Bitcoin, Ethereum, Ripple ve Litecoin gibi çeşitli kripto paralar üzerinde tahmin başarılarını araştırmıştır. Çalışmanın sonuçları, Kapılı Tekrarlayan Birim (Gated Recurrent Unit-GRU), Basit Tekrarlayan Sinir Ağı (Simple Recurrent Neural Network-RNN) ve LightGBM yöntemlerinin diğer makine öğrenimi yöntemlerinden, ayrıca saf al ve tut (naive buy-and-hold) ve rastgele yürüyüş stratejilerinden daha iyi performans gösterdiğini ortaya koymaktadır. Ayrıca Tablo 1'de makine ve derin öğrenme yöntemleri ile yapılan diğer çalışmalara yer verilmiştir.

Tablo 1. Makine ve Derin Öğrenme Yöntemleri ile Yapılan Çalışmalar

Yazarlar	Zaman Aralığı (Dönem)	Tahmin edilen değişken	Yöntem	Temel bulgular
Özer vd., (2018)	2012-2016	Shangai, Bifty 50, IPC-Meksika, BİST 100, Nadaq, DAX, FTSE 100ve CAC 40 Endeksleri	•Yapay Sinir Ağları •Bulanık Mantık	Modellerin Verimlilik Katsayıları (VK) yüksek bulunmuştur.
Hiransha vd., (2018)	•1.01.1996-30.06.2015 •3.01.2011-30.12.2016	Hindistan Ulusal Borsası (NSE) ve New York Borsası (NYSE)	•Çok Katmanlı Algılayıcı (MLP), •Tekrarlayan Sinir Ağları (RNN), •Uzun Kısa Süreli Bellek (LSTM) •Evrşimsel Sinir Ağı (CNN)	Evrşimsel Sinir Ağı (CNN) diğer yöntemlere göre daha iyi bir tahmin başarısına sahiptir.
Sakarya ve Yılmaz (2019)	02.01.2001-31.12.2018	BİST 30	Derin Öğrenme Yöntemleri	Yapılan tahminleme yüzde 80 doğruluğa sahiptir.
Yavuz vd., (2020)	01.01.2009-23.07.2018	Bitcoin	Yapay Sinir Ağları (YSA)	%99 oranında tahmin başarısı sağlamıştır.
Akay vd., (2022)	01.01.202007.05.2021	Binance Coin BNB, Ripple XRP ve ethereum ETH	•Yapay Sinir Ağları (YSA) •Uzun Kısa Süreli Bellek (LSTM)	YSA modeli seçilen kripto paralar için çok düşük hata payları çıkarmıştır.
Doğan ve Büyükkör (2022)	07.07.2017-06.07.2022	•İstanbul Borsasına (BİST 100) Ereğli Demir ve Çelik ile Aselsan •New York Borsası (NYSE) ve	•Destek Vektör Regresyonu, •Rassal Orman •Extrem Gradyan Arttırma	SVR, en iyi tahmin yöntemi olarak tespit edilmiştir.
Demirci ve Karaatlı (2023)	GRU modelinde Bitcoin, Ethereum ve Ripple günlük kapanış fiyatlarının 04.08.2020-15.09.2020 LSTM modelinde Bitcoin, Ethereum ve Ripple günlük kapanış fiyatlarının 04.08.202015.09.2020 dönemleri	Bitcoin, Ethereum ve Ripple	•Uzun-Kısa Süreli Bellek (LSTM) •Geçitli Yinelenen Birim (GRU)	İki modelde de en iyi tahmin sonucunu Bitcoin vermiştir.

Blok zincir teknolojisi günümüzde tedarik zinciri ve lojistikten finansa kadar birçok farklı sektörlerde kullanılmaktadır. Lojistik alanında Konacıklı ve Eyüpoğlu (2023) akıllı hava mühimmatı sistemleri için takip lojistik takip sistemi tasarlarlarken Tekin vd., (2020) akıllı lojistik faaliyetlerinin Blok zincir teknolojisiyle getirdiği yenilikleri incelemiştir.

Tedarik zinciri alanında ise Koç (2020) örnek olay yönetimini esas aldığı çalışmasında tedarik zinciri izlenebilirliği için firmaların blok zincir teknolojisinin stratejileriyle uyumlu olup olmadığı incelemeleri gerektiğini vurgulamıştır. Cankül ve Kızıldaş (2020) yiyecek içecek firmalarının tedarik zinciri sürecinde blok zincir teknolojisinin kullanılması durumunda firmalara sağlayacağı avantajları irdelemiştir.

Gıda alanında yapılan çalışmalar incelendiğinde Yazar

vd., (2023) gıda güvenliği için blok zincir temalı bir model tasarlarlarken Gökoğlu ve Atalan (2022) blok zincir teknolojisi ile gıda ürünlerinin tedarik zinciri yönetimini incelemişlerdir.


2. Materyal ve Yöntem

Dijital para birimleri, son yıllarda finansal piyasaların önemli bir bileşeni haline gelmiş ve yatırımcılar için cazip bir alternatif olarak görülmeye başlanmıştır. Kripto para birimlerinin değerindeki dalgalanmalar, finansal sistemin dinamiklerini doğrudan etkileyebilmekte ve ekonomik karar alma süreçlerinde önemli bir rol oynamaktadır. Kripto para fiyatlarının doğru bir şekilde tahmin edilmesi hem bireysel yatırımcılar hem de kurumsal finansal aktörler için stratejik karar alma süreçlerini destekleyici bir unsur haline gelmiştir. Kripto para birimlerinin

fiyatlarını tahmin etmek için çeşitli yöntemler kullanılmaktadır. Makine öğrenmesi teknikleri, özellikle regresyon tabanlı modeller, bu alanda öne çıkan yöntemler arasında yer almaktadır. Son yıllarda, yapay zekâ ve makine öğrenmesi algoritmaları, fiyat tahminlerinde daha yüksek doğruluk ve güvenilirlik sağlamak amacıyla etkin bir şekilde kullanılmaktadır.


Bu çalışmada, coin kurlarının tahmini için Karar Ağaçları Regresyonu (Decision Tree Regression), Rassal Orman (Random Forest) ve Destek Vektör Regresyonu (Support Vector Regression - SVR) modelleri kullanılmıştır. Her üç model de denetimli öğrenme (supervised learning) algoritmaları olup, geçmiş fiyat verilerine dayalı olarak gelecekteki fiyat hareketlerini tahmin etmeyi amaçlamaktadır. Karar Ağaçları, veriyi dallara ayırarak tahminleme yapan hiyerarşik bir modeldir. Ancak, aşırı öğrenme problemi nedeniyle modelin genellenebilirlik kapasitesi sınırlı olabilmektedir. Rassal Orman algoritması, birden fazla karar ağacının tahminlerini birleştirerek daha güçlü ve genellenebilir bir model oluşturur. Öte yandan, SVR, doğrusal olmayan ilişkileri modelleme kapasitesine sahip olup, özellikle yüksek volatilité içeren finansal zaman serilerinde etkili sonuçlar sunabilmektedir. Kripto para fiyatları, bireysel yatırımcılar, şirketler ve devletler için ciddi ekonomik sonuçlar doğurabilecek finansal değişkenlerdir. Günlük bazda yaşanan fiyat dalgalanmaları, bireylerin ve işletmelerin gelir seviyelerini doğrudan etkileyebildiği gibi, makroekonomik düzeyde de geniş çaplı etkiler yaratabilmektedir. Bu nedenle, coin kurlarının doğru tahmin edilmesi, sadece bireysel yatırımcılar için değil, geniş ölçekli ekonomik yapıların sağlıklı işleyişi açısından da kritik bir öneme sahiptir.

Coin kurlarının tahmin edilmesi, regresyon tabanlı bir problem olarak ele alınabilir. Bu tür tahminler için pek çok makine öğrenimi algoritması kullanılmakta olup, yapay sinir ağları ve diğer karmaşık modeller sıklıkla tercih edilmektedir. Yapılan bu çalışmada, Rassal Orman Regresyon Modeli, karar ağacı regresyon modeli ve Destek Vektör Regresyon modeli Python programlama dili kullanılarak uygulanmıştır. Model, VeChain, Helium ve IOTA gibi üç farklı dijital para biriminin değerlerini tahmin etmek amacıyla kullanılmıştır. Çalışmada kullanılan kripto varlıklara ait veriler coinmarketcap sitesinden temin edilmiştir. VeChain, IOTA veri seti 02.01.2020, Helium coin veri seti 09.06.2020 tarihinden itibaren alınan günlük kapanış fiyatlarıyla oluşturulmuştur ve her bir coin için 10.12.2024 tarihine kadar VeChain ve IOTA için 1805, Helium için 1646 veri noktasından oluşmaktadır. Bu veriler, coinlerin geçmiş değerlerini ve zaman içindeki fiyat hareketlerini temsil etmektedir. Bu yıllar arasında alınan datalar için Helium coin grafiği Şekil 1'de gösterilmiştir.




Şekil 1. Günlük Helium Coin veri kapanış grafiği.

IOTA coin'in kapanış fiyatlarına ait günlük veriler, coin'in değerindeki dalgalanmaları ve zaman içindeki fiyat hareketlerini analiz edebilmek için önemli bir kaynak sağlamaktadır. Bu veriler, 02.01.2020 ile 10.12.2024 tarihleri arasındaki kapanış fiyatlarını kapsamakta olup, söz konusu coin'in piyasa trendlerini anlamak için kullanılmıştır. Şekil 2'de IOTA Coin'in günlük kapanış fiyatlarını vermektedir.



Şekil 2. Günlük IOTA coin kapanış grafiği

Alınan verilerle yapılan analizler için VeChain coin'in fiyat hareketlerini gösteren grafik, Şekil 3'te yer almaktadır.




Şekil 3. Günlük Vechain Coin kapanış grafiği

3. Bulgular

Karar ağaçları, özellikle sınıflandırma ve regresyon problemlerinde yaygın olarak kullanılan güçlü algoritmalarından biridir (Kına ve Biçek, 2024; Sharma ve Puri, 2025). Veri madenciliği alanında, bu ağaçlar veriyi analiz etmek ve doğru sonuçlar üretmek için tercih edilir (Orhan ve Kurutkan, 2025; Das et al., 2025). Karar ağaçlarının en belirgin avantajı, hem modelin oluşturulmasının hem de elde edilen sonuçların son derece anlaşılır ve yorumlanabilir olmasıdır (Kına ve Biçek, 2024). Bu sayede, kullanıcılar modelin nasıl

çalıştığını kolaylıkla takip edebilirler. Karar ağaçları, denetimli öğrenme yöntemlerinden biri olup, eğitim verisinden öğrenerek sonuçlar üretir (Orhan ve Kurutkan, 2025; Das et al., 2025). Yapısı, bir ağacı andırır ve bu ağaç kök düğümünden, dallardan ve yapraklardan oluşur. Kök düğüm, verinin bölündüğü ilk noktayı temsil ederken, dallar veri kümesinin daha küçük gruplara ayrıldığı noktaları gösterir (Sharma ve Puri, 2025). Yapraklar ise modelin nihai sonucunu barındırır. Eğer problem bir sınıflandırma problemi ise, yapraklarda bulunan değer sınıf etiketini; eğer regresyon problemi ise

sayısal bir tahmini değerini belirtir (Kına ve Biçek, 2024; Orhan ve Kurutkan, 2025). Çalışmada ilk olarak kripto varlıkların tahmin edilmesinde, karar ağacı regresyon modeli kullanılmıştır. Karar ağacı regresyon modeli, coin kurlarının geçmiş verilerini analiz ederek, zaman içindeki fiyat hareketlerini modellemeye yönelik bir yaklaşım sunmaktadır. Bu model, bu üç coin'in değerindeki olası değişiklikleri tahmin etmek amacıyla, özellikle geçmiş kapanış fiyatları ve diğer ilgili faktörlere dayanarak yapılan hesaplamaları içermektedir. Coinlerin günlük kurlarına ait tahminlerin görsel olarak sunulduğu grafikler, Şekil 4'te yer almaktadır.




Şekil 4. Karar ağaçları regresyonu ile helium, iota, vechain coin verilerinin tahmin grafikleri.

Veri kümesi, her bir coin için günlük kapanış fiyatlarının yanı sıra olası dışsal faktörlerden etkilenebilecek ek parametrelerle zenginleştirilebilir. Bu bağlamda, karar ağacı regresyon modeli, her bir coin'in geçmiş verilerini kullanarak gelecekteki fiyat hareketlerini tahmin etmeyi amaçlamaktadır. Modelin başarısı, doğru veri ön işleme, parametre optimizasyonu ve model doğrulama adımlarının dikkatlice uygulanmasına bağlıdır. Bu çalışma kapsamında, kullanılan karar ağacı regresyon modeli, modelin hem doğruluk hem de genelleme yeteneğini artırmak için çapraz doğrulama yöntemleriyle test edilmiştir.

Rassal Orman, birden fazla karar ağacının bir araya gelerek oluşturduğu bir topluluk öğrenme (ensemble learning) yöntemi olup, tek bir karar ağacının neden olabileceği aşırı öğrenme (overfitting) problemini minimize ederek daha genellenebilir ve sağlam sonuçlar üretmeyi amaçlamaktadır (MacDonald, 2025; İçen vd., 2024). Veri madenciliği alanında, Rassal Orman modeli veri analizi ve tahminleme süreçlerinde yüksek doğruluk sağlamasıyla öne çıkmaktadır (Balişepalli & Thangaraj, 2025). En büyük avantajlarından biri, her bir karar ağacının farklı bir veri alt kümesiyle eğitilmesi ve nihai tahminin bu ağaçların ortalaması alınarak üretilmesidir (Karam, 2025). Bu sayede, model hem aşırı öğrenme riskini azaltır hem de daha dengeli tahminler sunmaktadır. Rassal Orman, denetimli öğrenme


yöntemlerinden biri olup, eğitim verisinden öğrenerek sonuçlar üretir. Model, birden fazla karar ağacından oluştuğu için bireysel ağaçlardaki hataları telafi ederek daha güvenilir tahminler yapabilir (MacDonald, 2025; Karam, 2025). Her bir karar ağacının farklı özellik kombinasyonlarıyla eğitilmesi, modelin veri setinin genel özelliklerini daha iyi kavramasına yardımcı olur. Kripto para fiyatlarının tahmini, regresyon tabanlı bir problem olarak ele alınabilir. Bu tür tahminlerde makine öğrenimi algoritmaları sıkça tercih edilmekte olup, yapay sinir ağları ve diğer karmaşık modellerin yanı sıra, Rassal Orman algoritması finansal zaman serilerinde güçlü bir alternatif olarak öne çıkmaktadır (İçen vd., 2024; Balişepalli & Thangaraj, 2025). Bu çalışmada, Python programlama dili kullanılarak Rassal Orman regresyon modeli uygulanmıştır. Model, VeChain, Helium ve IOTA gibi üç farklı dijital para biriminin değerlerini tahmin etmek amacıyla kullanılmıştır. Rassal Orman modeli, coin kurlarının geçmiş verilerini analiz ederek, zaman içindeki fiyat hareketlerini modellemeye yönelik daha sağlam ve genellenebilir bir tahminleme yaklaşımı sunmaktadır. Rassal Orman, birden fazla karar ağacının tahminlerini birleştirerek daha dengeli ve güvenilir sonuçlar üretmektedir. Özellikle finansal verilerde görülen yüksek volatilité gibi zorlukları aşmada etkili bir yöntem olarak öne çıkmaktadır. Coin kurlarının tahminleri Şekil 5'te yer almaktadır.



Şekil 5. Rassal orman regresyonu ile helium, iota, vechain coin verilerinin tahmin grafikleri.

Destek Vektör Regresyonu, veri noktaları arasındaki karmaşık ilişkileri modelleyerek doğrusal olmayan regresyon problemlerini çözeblen güçlü bir makine öğrenme algoritmasıdır (Fatah vd., 2025). SVR, rassal orman regresyon modeli gibi yüksek volatiliteye sahip finansal zaman serilerinde etkili sonuçlar sunmaktadır. Model, geçmiş kapanış fiyatları ve diğer ilgili faktörlere dayanarak fiyat hareketlerini modellemek

amacıyla oluşturulmuştur. SVR, fiyat dalgalanmalarını daha iyi yakalayarak, aşırı öğrenme riskini azaltan bir hiper düzlem tabanlı tahminleme yöntemi kullanmaktadır (Karam, 2025). SVR modeli Helium, IOTA ve VeChain gibi üç farklı dijital para biriminin değerlerini tahmin etmek amacıyla kullanılmıştır. SVR modeli ile Coin kurlarının tahminleri Şekil 6'da verilmiştir.



Şekil 6. Günlük coin verilerinin tahmin grafiği (SVR modeli ile).

4. Tartışma

Dimitriadou ve Gregoriou (2023) Bitcoin fiyat hareketlerini bir makine öğrenmesi çerçevesinde tahmin etmek için Lojistik Regresyon, Destek Vektör Makineleri ve Rassal Orman algoritmasını kullanmışlardır. Çalışmadan elde edilen ampirik sonuçlara göre, geleneksel Lojistik Regresyon modelinin doğruluk oranı %66'ya ulaşarak Doğrusal Destek Vektör makineleri ve Rassal Orman algoritmasından daha iyi performans gösterdiğini ortaya koymaktadır. Chen vd., (2020) Bitcoin'in günlük fiyatlarının tahmininde istatistiki modeller ve makine öğrenmesi modellerinin performanslarını karşılaştırmış ve en iyi performansı doğrusal regresyon modeli göstermiştir. Makine öğrenme modelleri içerisinde ise en iyi doğruluk oranına SVR modelinin sahip olduğu bulunmuştur.

Yapılan bu çalışmada ise modelin başarısını değerlendirmek için, tahmin edilen ve gerçek değerler arasındaki farklar incelenmiştir. Mean Squared Error hata ölçüsü olup, tahmin edilen değer ile gerçek değer arasındaki farkların karesinin ortalamasını temsil etmektedir. R^2 skoru, modelin tahmin gücünü ifade etmektedir; bu değer 1'e yakın olması, modelin yüksek doğrulukla çalıştığını göstermektedir. VeChain coin için, SVR modeli en düşük MSE değerine (0.000004034) ve en

yüksek R^2 skoruna (0.9979) sahip olup, en başarılı model olarak öne çıkmaktadır. Karar ağaçları modeli ise en yüksek hata oranını göstermiştir. Bu sonuçlar Chen vd., (2020)'nin çalışmasını destekler niteliktedir. Helium coin için, Rassal Orman modeli en düşük MSE (0.3131995) ve en yüksek R^2 (0.9965) değerleri ile en iyi performansı sergilemiştir. Karar ağaçları, 0,52578MSE ve 0.9942 R^2 ile nispeten daha düşük bir performans göstermiştir. IOTA coin için, Rassal Orman modeli yine en düşük hata oranına sahip olup (MSE: 0.0006429), R^2 skoru 0.9973 ile oldukça yüksek bir doğruluk sergilemiştir.

Elde edilen sonuçlar, Rassal Orman modelinin Helium ve IOTA coin fiyatlarını tahmin etme konusunda en iyi performansı sergilediğini gösterirken SVR modelinden elde edilen sonuçlar çalışmada ele alınan diğer iki modele göre nispeten daha kötü tahmin sonuçları vermektedir. Karar ağaçları modeli genel olarak daha dengeli ve güvenilir tahminler sağlamaktadır. Bu çalışma, makine öğrenmesi tekniklerinin dijital para birimlerinin gelecekteki değerlerini tahmin etme konusundaki etkinliğini bir kez daha vurgulamaktadır. Tablo 2'de Coin verilerine uygulanan regresyon modellerinin MSE değerleri verilmiştir. Tablo 3'te Coin verilerine uygulanan regresyon modellerinin R^2 değerleri Tablo 3'te verilmiştir.

Tablo 2. Coinlerin MSE değerleri

Model	Helium	IOTA	VeChain
Karar Ağaçları	0,52578	0,00115	1,5818
Rassal Orman	0.3131995	0.0006429	0.000006251
SVR	0.600722	0.004071	0.000004034

Tablo 3. Regresyon Modellerinin R^2 değerleri

Model	Helium	IOTA	VeChain
Karar Ağaçları	0.9942	0.9949	0.9913
Rassal Orman	0.9965	0.9973	0.9968
SVR	0.9934	0.9833	0.9979

4. Sonuç

Bu çalışma, IoT temalı dijital para birimleri olan VeChain, IOTA ve Helium coin'lerinin fiyatlarını tahmin etmek için Karar Ağaçları, Rassal Orman ve Destek Vektör Regresyonu modellerini kullanarak önemli bulgulara ulaşılmıştır. Yapılan analizler, Rassal Orman modelinin genellikle en düşük hata oranı ve en yüksek R^2 değerine sahip olduğunu göstermiştir. Vechain coin için SVR modeli en düşük hata oranına (MSE: 0.000004034) ve en yüksek R^2 değerine (0.9979) ulaşarak en iyi performansı sergilemiştir. Helium coin için de Rassal Orman modeli (MSE: 0.313, R^2 : 0.9965) en başarılı model olmuştur. IOTA coin'de de en düşük hata oranını (MSE: 0.0006429) yine Rassal Orman modeli elde etmiştir, ancak bu noktada Karar ağaçları modeli düşük doğruluk göstermiştir. Elde edilen sonuçlar, Rassal Orman modelinin dijital para birimlerinin fiyatlarını tahmin etmede güçlü bir araç olduğunu ve en yüksek doğruluğu sağladığını göstermektedir. Ancak, SVR modeli de bazı durumlarda belirli avantajlar sunmaktadır. Sonuçlar, makine öğrenmesi tekniklerinin ekonomik analizlerde önemli katkılar sunduğunu ve özellikle IoT temalı kripto varlıkların fiyat hareketlerini doğru bir şekilde tahmin etmenin yatırımcılar, analistler ve ekonomi uzmanları için kritik bir konu olduğunu göstermektedir.

Katkı Oranı Beyanı

Yazarların katkı yüzdeleri aşağıda verilmiştir. Yazarlar makaleyi incelemiş ve onaylamıştır.

	Ç.E.	O.K.
K	50	50
VTI	30	70
VAY	60	40
KT	40	60
YZ	60	40
KI	50	50
GR	60	40

K= kavram, VTI= veri toplama ve/veya işleme, VAY= veri analizi ve/veya yorumlama, KT= kaynak tarama, YZ= Yazım, KI= kritik inceleme, GR= gönderim ve revizyon.

Çatışma Beyanı

Yazarlar bu çalışmada hiçbir çıkar ilişkisi olmadığını beyan etmektedirler.

Etik Onay Beyanı

Bu araştırmada hayvanlar ve insanlar üzerinde herhangi bir çalışma yapılmadığı için etik kurul onayı alınmamıştır.

Kaynaklar

Ahamad S, Gupta P, Acharjee PB, Kiran KP, Khan Z, Hasan MF. 2022. The role of block chain technology and Internet of Things (IoT) to protect financial transactions in crypto currency market, Mater Today Proc, 56: pp: 2070-2074.
Akay MK, Canik F, Yeşilyurt C, Günkut MŞ. 2022. Yapay zekâ

teknikleri ile kripto para değeri tahmini, Ekom Bil Derg, 14(1): pp: 72-101.

- Akel V, Bayramoğlu MF. 2008. Finansal kriz dönemlerinde yapay sinir ağları ile finansal öngöründe bulunma: İMKB 100 endeksi örneği, Uluslararası Sermaye Hareketleri ve Gelişmekte Olan Piyasalar Sempozyumu, pp: 36-69.
- Akşehir ZD, Kılıç E. 2019. Makine öğrenmesi teknikleri ile banka hisse senetlerinin fiyat tahmini, Türk Bilişim Vakfı Bilg Bilim Müh Derg, 12(2): pp: 30-39.
- Alshaikhli M, Elfouly T, Elharrouss O, Mohamed A, Ottakath N. 2021. Evolution of Internet of Things from blockchain to IOTA: a survey, IEEE Access, 10: pp: 844-866.
- Altan Ş. 2008. Döviz kuru öngörü performansı için alternatif bir yaklaşım: yapay sinir ağı, Gazi Üniv İİBF Derg, 10(2): pp: 141-160.
- Aygören H, Sarıtaş H, Morali T. 2012. İMKB 100 endeksinin yapay sinir ağları ve Newton nümerik arama modelleri ile tahmini, Uluslararası Alanya İşlet Fakül Derg, 4(1): pp: 73-88.
- Balişpallı NK, Thangaraj V. 2025. Prediction of cryptocurrency's price using ensemble machine learning algorithms, Eur J Manage Bus Econ, pp:25-42.
- Bouteska A, Abedin MZ, Hajek P, Yuan K. 2024. Cryptocurrency price forecasting—a comparative analysis of ensemble learning and deep learning methods, Int Rev Financ Anal, 92(103055): pp: 1-12.
- Böhme R, Christin N, Edelman B, Moore T. 2015. Bitcoin: economics, technology, and governance, J Econ Perspect, 29(2): pp: 213-238.
- Cankül D, Kızıltaş MÇ. 2020. Yiyecek içecek işletmelerinde tedarik zinciri ve blokzincir teknolojisi, J Gastron Hosp Travel, 3(2): pp: 244-259.
- Chen Z, Li C, Sun W. 2020. Bitcoin price prediction using machine learning: an approach to sample dimension engineering, J Comput Appl Math, 365: pp: 112395.
- Chowdhury Rahman MA, Rahman MS, Mahdy MRC. 2020. An approach to predict and forecast the price of constituents and index of cryptocurrency using machine learning, Phys A Stat Mech Appl, 551(124569): pp: 1-17.
- Çalışkan MMT, Deniz D. 2015. Yapay sinir ağlarıyla hisse senedi fiyatları ve yönlerinin tahmini, Eskişehir Osmangazi Üniv İİBF Derg, 10(3): pp: 177-194.
- Dange S, Nitnaware P. 2024. Secure Share: optimal blockchain integration in IoT systems, J Comput Inf Syst, 64(2): pp: 265-277.
- Das N, Moharana L, Nayak S, Routray A. 2025. Emotional blink patterns: a possible biomarker for anxiety detection in a HCI framework, SN Comput Sci, 6(3): pp: 1-14. DOI: 10.1007/s42979-025-03810-y
- Demirci E, Karaatlı M. 2023. Kripto para fiyatlarının LSTM ve GRU modelleri ile tahmini, J Mehmet Akif Ersoy Univ Econ Adm Sci Fac, 10(1): pp: 134-157.
- Dimitriadou A, Gregoriou A. 2023. Predicting Bitcoin prices using machine learning, Entropy, 25(5): pp: 777.
- Doğan S, Büyükkör Y. 2022. Makine öğrenmesi ile finansal zaman serisi tahminleme, Ankara HBV Üniv İİBF Derg, 24(3): pp: 1205-1230.
- Esenyel İçen NM, Demirezen S, İçen H. 2024. A machine learning-based Bitcoin price forecasting, In: Blockchain, İstanbul Univ Press, İstanbul, Türkiye, pp: 47-71.
- Esenyel NM, Akın M. 2017. Comparing accuracy performance of ELM, ARMA and ARMA-GARCH model in predicting exchange rate return, Alphanumeric J, 5(1): pp: 1-14.
- Eylasov N, Çiçek M. 2024. Kripto para fiyatlarının tahmini: ARIMA-GARCH ve LSTM yöntemlerinin karşılaştırılması, Finans Ekon Sosyal Araş Derg, 9(1): pp: 48-62.

- Fatah MA, Dikananda AR, Rifai A. 2025. Support vector regression to improve Ethereum price prediction for trading strategies, *J Artif Intell Eng Appl*, 4(2): pp: 738-744.
- Fauzi MA, Paiman N, Othman Z. 2020. Bitcoin and cryptocurrency: challenges, opportunities and future works, *J Asian Finance Econ Bus*, 7(8): pp: 695-704.
- Gökoğlu K, Atalan İ. 2022. Tarımsal gıda ürünlerinin tedarik zinciri yönetimine blok zincir teknolojisinin etkisi, *Ahi Evran Üniv İİBF Derg*, 6(1): pp: 97-112.
- Haleem A, Allen A, Thompson A, Nijdam M, Garg R. 2018. A decentralized wireless network, *Helium Netw*, pp: 1-20. <http://whitepaper.helium.com/> (accessed date: July 11, 2025).
- Hiransha M, Gopalakrishnan EA, Menon VK, Soman KP. 2018. NSE stock market prediction using deep-learning models, *Procedia Comput Sci*, 132: pp: 1351-1362.
- .