



ETHEREUM'UN ERC-20 TOKENLARI ÜZERİNDEKİ ETKİSİ: LSTM VE CNN MODELLERİYLE KARŞILAŞTIRMALI BİR ANALİZ

Mehmet ÇINAR ¹
Muhammet APAK ²

Öz

Vitalik Buterin tarafından 2013 yılında geliştirilen Ethereum, akıllı sözleşmeler ve ERC-20 token standartları ile blockchain teknolojisini önemli ölçüde ileri taşımıştır. Bu çalışmada Ethereum'un ERC-20 tokenları üzerindeki etkisi Long Short-Term Memory (LSTM) ve Convolutional Neural Networks (CNN) modelleri kullanılarak incelenmektedir. Bu amaçla Ethereum verileri kullanılarak LSTM ve CNN modelleri yardımıyla model eğitimleri gerçekleştirilmiştir. Daha sonra eğitilen modeller ERC-20 token fiyatlarını tahmin etmek amacıyla kullanılmıştır. Çalışmada uygulanan tüm analizler. Çalışma sonuçlarına göre, LSTM modeli; LINK, MATIC ve UNI tokenları için yüksek doğruluk oranlarına ulaşmış, ancak RNDR tokeni tahminlerinde daha düşük performans sergilemiştir. CNN modeli ise LINK tokeni için en yüksek doğruluğu sağlamış ve RNDR tokeni tahminlerinde de başarılı sonuçlar elde etmiştir. Bununla birlikte, CNN modeli MATIC ve UNI tokenlarında LSTM modeline göre daha düşük bir performans sergilemiştir. Bu bulgular, hem LSTM hem de CNN modellerinin Ethereum'un ERC-20 token fiyat dinamiklerini tahmin etmede belirgin bir etkiye sahip olduğunu ortaya koymaktadır. Model performanslarının token bazında değişkenlik göstermesi, piyasa dinamikleri ve likidite seviyelerinin etkisini işaret etmektedir. Çalışma, bu farklılıkların model seçiminde tokenin özelliklerine ve piyasa koşullarına göre yapılmasının önemini vurgulamaktadır.

Anahtar Kelimeler : Ethereum, ERC-20, LSTM, CNN

Jel Sınıflandırılması : C45, F37, G15.

¹ Prof. Dr., Bursa Uludağ Üniversitesi, İktisadi ve İdari Bilimler Fakültesi, Ekonometri Bölümü, Türkiye, mcinar@uludag.edu.tr., ORCID ID: 0000-0001-8441-243X

² Yüksek Lisans Öğrencisi, Bursa Uludağ Üniversitesi, Sosyal Bilimler Enstitüsü, Ekonometri Anabilim Dalı, Türkiye, mhmt09apak@gmail.com, ORCID ID: 0009-0009-3705-5973.

Atıf/Citation (APA 6):

Çınar, M., & Apak, M. (2025). Ethereum'un ERC-20 tokenları üzerindeki etkisi: LSTM ve CNN modelleriyle karşılaştırmalı bir analiz. *Ömer Halisdemir Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 18(1), 476–492. <http://doi.org/10.25287/ohuibf.1577168>.

THE IMPACT OF ETHEREUM ON ERC-20 TOKENS: A COMPARATIVE ANALYSIS WITH LSTM AND CNN MODELS

Abstract

Ethereum, developed by Vitalik Buterin in 2013, has significantly advanced blockchain technology through smart contracts and ERC-20 token standards. This study examines the impact of Ethereum on ERC-20 tokens using Long Short-Term Memory (LSTM) and Convolutional Neural Networks (CNN) models. For this purpose, LSTM and CNN models were trained using Ethereum data and then employed to predict ERC-20 token prices. According to the study's results, the LSTM model achieved high accuracy rates for LINK, MATIC, and UNI tokens but performed poorly in predicting RNDR token prices. The CNN model provided the highest accuracy for LINK tokens and yielded successful results in predicting RNDR token prices. However, the CNN model showed lower performance for MATIC and UNI tokens than the LSTM model. These findings indicate that both LSTM and CNN models significantly impact the prediction of Ethereum's ERC-20 token price dynamics. The variability in model performances across tokens highlights the influence of market dynamics and liquidity levels. In light of these differences, the study emphasizes the importance of selecting the model based on the token's characteristics and market conditions.

Keywords : Ethereum, ERC-20, LSTM, CNN

Jel Classification : C45, F37, G15

GİRİŞ

Geleneksel zaman serisi modelleri, zaman serilerini tahmin etmek için kullanılmasına rağmen, doğrusal olmayan dinamikleri yakalamadaki sınırlılıkları nedeniyle kripto para birimlerini tahmin etmede yetersizdir (Patel vd., 2020). Kripto para birimlerinin doğrusal olmamaları, düzensiz ve değişken kalıplara sahip olmaları nedeniyle birçok çalışmada, kripto para birimlerinin değerlerini tahmin etmek için çok sayıda makine öğrenme algoritmaları kullanmıştır. Makine öğrenimi algoritmaları, geleneksel hipotezlere dayanmadan doğrusal olmayan ilişkileri yakalayabilmekte ve bu da daha güvenilir kripto para birimi tahmin performansı sağlamaktadır (Altan vd., 2019). Çalışmaların çoğunluğunun Bitcoin, Ethereum ve Ripple gibi en yaygın kullanılan kripto para birimlerine odaklanmış olsa da Bitcoin üzerine yapılan çalışmaların daha fazla olduğu görülmektedir.

Son yıllarda Bitcoin'den farklı olarak Ethereum, finansal teknoloji dünyasında devrim yaratan bir yenilik olarak öne çıkmıştır. Ethereum, Vitalik Buterin tarafından 2013 yılının sonlarında tasarlanmış bir blockchain platformudur ve özellikle "akıllı sözleşmeler" konseptini tanıtarak büyük bir yenilik getirmiştir. Ethereum platformu, akıllı sözleşmeler ve ERC-20 gibi token standartları sayesinde, geleneksel finansal sistemlerin ötesinde bir ekosistem yaratma potansiyeline sahiptir. Bu tokenlar, Ethereum blockchain üzerinde inşa edilmiş ve geniş bir yelpazede uygulamalara hizmet eden varlıklardır. Finansal piyasaların doğası gereği karmaşık ve tahmin edilmesi zor olması, makine öğrenmesi modellerini ideal araçlar haline getirmektedir. Bu modeller, büyük veri setlerinden öğrenerek ve geçmiş trendleri analiz ederek gelecekteki hareketleri tahmin etme yeteneğine sahiptir.

Akıllı sözleşmeler, alıcı ve satıcı arasındaki anlaşmanın şartlarının doğrudan kod satırlarına yazılan ve kendiliğinden işleyen kontratlardır. Ethereum ağı bu kontratları otomatik olarak yürütebilme kapasitesi sayesinde esnek ve işlevsel bir ortam sağlamaktadır (Buterin, 2014). Ethereum'un işlevselliğini sağlayan temel mekanizma Ethereum Sanal Makinesi (Ethereum Virtual Machine, EVM)'dir. EVM, yatırımcıların bireysel olarak EVM Byte Kodu yürütebilmesine olanak tanıyan güçlü, Turing-tam bir sanal makinasıdır. Ethereum ağındaki tüm düğümler, yapılan her işlemin geçerli ve doğru olduğu konusunda mutabık kalarak, ağın güvenilir ve gizli olmasını sağlamaktadır (Hirai, 2017). Ethereum, akıllı sözleşmelerin ve merkeziyetsiz uygulamaların (Decentralized Application, DApps) geliştirilmesi için bir platform olarak hizmet vermektedir. Bu platform geliştiricilerin finansal işlemlerden oyunlara ve kimlik yönetim sistemlerine kadar her türlü uygulamayı oluşturabileceği anlamına gelmektedir. Ethereum'un kendi yerel kripto para birimi olan Ether (ETH), ağ üzerindeki

işlemleri gerçekleştirmek ve akıllı sözleşmeler aracılığıyla uygulamaları çalıştırmak için kullanılmaktadır (Oliva, 2022). Ethereum'un tüm bu özellikleri, blockchain teknolojisinin sadece bir para birimi olarak değil, aynı zamanda çeşitli otomatik işlemler ve uygulamalar için bir altyapı sağlayabileceğini göstermesi açısından kritik bir öneme sahiptir. Böylece Ethereum'u bir kripto para platformu olmasının ötesine taşıyarak geniş çapta teknolojik inovasyonun önü açılmıştır.

ERC-20, Ethereum blockchain'inde token oluşturmayı standardize eden bir teknik spesifikasyondur. ERC-20 ifadesindeki ERC, Ethereum için yorum talepleri (Ethereum Request for Comments) anlamına gelmekte ve "20" ise bu önerinin tanımlayıcı (belirteç) numarasıdır. ERC-20, Ethereum üzerinde tokenlar yaratmak ve bunların nasıl davranacağını belirlemek için bir dizi kurallar ve standartlar sunmaktadır. Bu standartlar, Ethereum ağında token geliştiricileri için büyük ölçüde kabul görerek benimsenmiş bir yöntem haline gelmiştir (Cuffe, 2018). Ethereum ana ağında çalışan 200 binden fazla ERC-20 tokeni bulunmaktadır. ERC-20 tokenları, Ethereum blockchain'ini kullanarak dağıtılan ve akıllı sözleşmeler yoluyla işlevsellik kazanan dijital varlıklardır. Bu tokenlar genellikle kripto para birimleri, varlık temsilleri, yönetim hakları gibi çeşitli amaçlar için kullanılmaktadır. ERC-20; tokenların transferi, işlem yapılabilir bakiyenin sorgulanması ve toplam arzın belirlenmesi gibi işlemleri standartlaştırmaktadır (Zhang, 2023).

ERC-20 tokenlarının yararları arasında, Ethereum ekosistemi içerisindeki etkileşimlerde standartlaştırma ve birlikte çalışabilirlik öne çıkmaktadır. Örneğin, tüm ERC-20 tokenları, Ethereum ağını kullanan her cüzdandan, değişim platformu ve diğer hizmetlerle uyumlu şekilde çalışabilmektedir. Böylece geliştiricilerin ve kullanıcıların yeni tokenlar ve uygulamalar geliştirirken daha az uyumluluk sorunu yaşamalarını sağlamaktadır. ERC-20, Ethereum'un token ekosistemini büyük ölçüde standartlaştıran ve birleştiren kritik bir yapı taşıdır. ERC-20, geliştiricilere Ethereum blockchain üzerinde işlevsel ve birbiriyle uyumlu tokenlar yaratma rehberi sunmaktadır. Bu standardın sağladığı tutarlılık ve güvenlik, Ethereum'un dijital varlıklar ve akıllı sözleşmeler aracılığıyla global finansı yeniden şekillendirme potansiyelini artırmaktadır. Bu bilgiler ERC-20 tokenlarının, Ethereum ve Ethereum ağından ne kadar etkilenebileceğini işaret etmektedir.

Ethereum ve ERC-20 tokenları gibi dijital varlıkların fiyatlarını etkileyen çok sayıda faktör olduğundan, bu alan makine öğrenmesinin gücünü test etmek için iyi bir ortam sunmaktadır. Bu nedenle çalışmada, Ethereum verilerini kullanarak, özellikle CNN (Convolutional Neural Networks) ve LSTM (Long Short-Term Memory) modelleri olmak üzere iki farklı makine öğrenmesi modeli aracılığıyla ERC-20 token fiyat tahminlerinin başarısı araştırılmaktadır. Araştırmanın amacı, bu modellerin Ethereum tabanlı altkoinlerin (ERC-20) fiyatını tahmin etme kapasitesini değerlendirmek ve makine öğrenmesi modellerinin bu yeni ve hızla gelişen piyasada nasıl bir etki yaratabileceğini göstermektir. Bu bağlamda Ethereum verileri LSTM ve CNN modelleri kullanılarak eğitilmiştir. Eğitilen modeller ise literatür çalışmalarından farklı olarak Ethereum fiyat tahmini için değil ERC-20 kripto varlıkların kısa vadeli (15 dakikalık) fiyat tahminini ortaya koymak için kullanılmıştır. Bu yönü ile çalışma literatür çalışmalarına göre farklı bir bakış açısı sunmaktadır. Çalışma kurgusu şu şekilde tasarlanmıştır: ikinci bölümde LSTM ve CNN modellerine ilişkin teorik bilgiler sunulmaktadır. Üçüncü bölümde literatür çalışmaları ve dördüncü bölümde ise veri yapısı ve bulguları üzerinde durulmaktadır. Çalışma sonuç ve öneriler bölümüyle tamamlanmaktadır.

I. LSTM VE CNN MODELLERİ

Uzun Kısa Dönemli Bellek (Long Short-Term Memory, LSTM) modelleri, özellikle zaman serisi verilerindeki uzun süreli bağımlılıkları modelleme yeteneği ile öne çıkan gelişmiş bir yapay sinir ağı türüdür. Bu modeller, 1997 yılında Sepp Hochreiter ve Jürgen Schmidhuber tarafından önerilmiştir. LSTM modelinin zaman içerisinde birçok alana uyarlandığı görülmektedir. LSTM'ler, geleneksel Tekrarlayan Sinir Ağları'na (Recurrent Neural Network, RNN) kıyasla daha uzun zaman dilimlerine yayılan bilgileri saklayarak işlemektedir. Bu özelliği sayesinde LSTM'ler zamanla değişen veri akışlarını modellemek için uygun bir alt yapıya sahiptir.

LSTM'lerin temel bileşeni, bir hücre durumu ve bu durumu kontrol eden üç kapıdan (unutma kapısı, giriş kapısı ve çıkış kapısı) oluşmasıdır. Bu yapı, hücre durumundaki bilginin uzun süreler

boyunca korunmasını veya unutulmasını sağlayarak, öğrenilen bilgilerin kaybolmasını veya gereksiz yere karmaşıklaşmasını önlemektedir. Bu özellikler LSTM'leri finansal piyasalar ve doğal dil işleme gibi birçok alanda etkili kılmaktadır.

LSTM modeli, unutma kapısı f_t , giriş kapısı i_t , hücre durumu C_t ve çıkış kapısı o_t olmak üzere dört ana bileşenden oluşmaktadır. Her bir bileşenin matematiksel ifadesi şu şekilde gösterilebilir:

Unutma kapısı, hücre durumunun önceki bilgilerinin ne kadarının korunacağını belirlemektedir.

$$f_t = \sigma(W_f[h_{t-1}, x_t] + b_f) \quad (1)$$

Burada, σ sigmoid aktivasyon fonksiyonudur ve değerleri 0 ile 1 arasında sıkıştırır. W_f unutma kapısı için ağırlık matrisi, b_f ise bias vektörüdür. h_{t-1} önceki gizli durumu, x_t ise t zamanındaki girdiyi temsil etmektedir.

Giriş Kapısı ve Aday Hücre Durumu:

$$i_t = \sigma(W_i[h_{t-1}, x_t] + b_i) \quad (2)$$

$$\tilde{C}_t = \tanh(W_C[h_{t-1}, x_t] + b_C) \quad (3)$$

i_t giriş kapısı, yeni bilginin hücre durumuna ne kadar ekleneceğini belirlerken, \tilde{C}_t o anki aday hücre durumunu hesaplamaktadır. W_f , W_C ağırlık matrisleri ve b_i , b_C bias vektörleri giriş ve aday hücre durumlarını kontrol etmektedir. “tanh” aktivasyon fonksiyonu, değerleri -1 ile 1 arasında normalize etmekte ve böylece hücre durumuna eklenecek aday bilgilerin dengelenmesine yardımcı olmaktadır.

Hücre durumu unutma kapısının çıktısıyla eskiden gelen bilgilerin çarpımı ve giriş kapısının çıktısıyla yeni aday bilgilerin çarpımının toplamı ile güncellenmektedir.

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \quad (4)$$

Hücre durumu, LSTM'in uzun süreli bilgiyi saklamasını sağlamaktadır.

Çıkış Kapısı ve Gizli Durum:

$$o_t = \sigma(W_o[h_{t-1}, x_t] + b_o) \quad (5)$$

$$h_t = o_t * \tanh(C_t) \quad (6)$$

Çıkış kapısı, hangi bilgilerin sonraki katmana veya çıktıya aktarılacağına karar vermektedir. W_o çıkış kapısının ağırlık matrisi, b_o ise bias vektörüdür. Gizli durum, çıkış kapısının çıktısı ile hücre durumunun “tanh” ile işlenmiş hali arasındaki çarpım olarak güncellenmektedir (Zhou, 2022; Tran vd., 2022; Li vd., 2022).

Evrişimsel Sinir Ağları (Convolutional Neural Networks, CNN), özellikle görüntü tanıma ve sınıflandırma görevlerinde kullanılan bir derin sinir ağı sınıfıdır. CNN, uzaysal özelliklerin hiyerarşilerini otomatik ve adaptif olarak öğrenme yetenekleri nedeniyle oldukça etkilidir. Tipik bir CNN mimarisi, girdiye filtreler uygulayarak yerel desenleri tespit eden evrişimsel katmanları, ReLU (Doğrultulmuş Lineer Birim, Rectified Linear Unit) gibi aktivasyon fonksiyonları, özellik haritaları boyutlarını azaltarak örnekleyen ve aşırı öğrenmeyi kontrol eden havuzlama katmanları ve son sınıflandırma için özellikleri birleştiren tam bağlı katmanları içermektedir. CNN'ler otomatik olarak özellik çıkarmakta, parametre paylaşımı yoluyla hesaplama karmaşıklığını azaltmakta ve çeviri değişmezliği sergileyerek görüntü ve video analizi, doğal dil işleme ve daha birçok uygulamada yüksek performans göstermektedir.

Bu güçlü özellikleri sayesinde CNN'ler zaman serileri tahmininde de etkili bir yöntem olarak kullanılmaktadır. Zaman serileri verilerinde CNN modeli, verilerin zamansal düzenlerini ve kalıplarını öğrenmek için aynı evrişimsel katmanları kullanmaktadır. Bu katmanlar verileri farklı filtrelerle işleyerek önemli özellikleri ortaya koymaktadır. Bu özellikler zaman içindeki değişimleri takip etmek için kullanılmaktadır. Dikkat edilebileceği üzere CNN'in zaman serileri tahminindeki gücü, karmaşık ve çok boyutlu veri yapılarını etkili bir şekilde modelleyebilmesinden kaynaklanmaktadır. CNN modeli finansal tahminlerden hava durumu tahminlerine kadar birçok uygulama alanında başarılı sonuçlar

vermektedir. Matematiksel olarak CNN modelinin zaman serileri analizinde kullanılan katmanları şu şekilde ifade edilebilmektedir:

Evrişimsel katmanda zaman serisi verilerinin her bir dilimi X_t , filtreler (W) ve önyargılar (b) kullanılarak işlenmektedir. Bu işlemde her bir zaman dilimi için bir özellik haritası (h_t) oluşturulmaktadır.

$$h_t = \sigma(W * X_t + b) \quad (7)$$

Burada σ , ReLU kullanılarak oluşturulan aktivasyon fonksiyonudur.

Havuzlama katmanında özellik haritalarının boyutlarını azaltmak ve önemli bilgileri korumak için max-pooling veya average-pooling gibi havuzlama işlemleri uygulanmaktadır.

Tam bağlantılı katmanda havuzlama katmanlarından gelen özellikler düzleştirilmekte ve tam bağlantılı katmanlar beslenmektedir.

$$y_t = \phi(W_f * h_t + b_f) \quad (8)$$

Burada ϕ aktivasyon fonksiyonudur ve W_f ve b_f tam bağlantılı katmanın ağırlıkları ve önyargılarıdır.

Bu katmanlar bütün olarak değerlendirildiğinde bir zaman serisinin gelecekteki değerlerini tahmin etmek için kullanılmaktadır. Kullanılan modellerin verilere uyumunun gücünü ortaya koymak amacıyla aşağıdaki değerlendirme kriterleri kullanılmaktadır:

Ortalama Mutlak Hata (MAE), y_i gerçek, \hat{y}_i tahmin edilen değeri göstermek üzere tahmin edilen değerler ile gerçek değerler arasındaki mutlak farkların ortalamasıdır.

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (9)$$

Kök Ortalama Kare Hatası (RMSE), tahmin edilen değerler ile gerçek değerler arasındaki farkların karelerinin ortalamasının kareködür.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (10)$$

Ortalama Kare Hatası (MSE), tahmin edilen değerler ile gerçek değerler arasındaki farkların karelerinin ortalamasıdır.

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (11)$$

Ortalama Mutlak Yüzde Hatası (MAPE), tahmin edilen değerler ile gerçek değerler arasındaki mutlak farkların, gerçek değerlere oranının ortalamasıdır ve yüzde olarak ifade edilir.

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| * 100 \quad (12)$$

R-Kare (R^2), modelin veriye uyumunu gösteren bir istatistiktir.

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (13)$$

II. LİTERATÜR ARAŞTIRMASI

Son yıllarda araştırmacıların yapay sinir ağları ve makine öğrenimi modellerini sıklıkla birçok alanda kullandıkları görülmektedir. Yapay sinir ağları ve makine öğrenim modelleri üzerine son yıllarda yapılmış çalışmalar çok sayıda olduğundan bu kısımda literatür çalışmaları sunulurken LSTM ve CNN modelleri özelinde ulusal ve uluslararası çalışmalara yer verilmektedir. Yukarıda da ifade edildiği üzere LSTM ve CNN modelleri farklı birçok alana uygulanmış olsa da bu kısımda özellikle finansal piyasalar özelinde kripto varlıklara odaklanan çalışmalar üzerinde durulmaktadır. İlgili literatür çalışmaları Tablo 1 ve Tablo 2'de özetlenmektedir.

Tablo 1: Ulusal Literatür Çalışmaları

Yazar	Model	Değişkenler	Çalışma Sonuçları
Sezer vd. (2019)	CNN, LSTM ve RNN modellerinin finansal tahminlerde kullanımı	Finansal piyasa dalgalanmaları, kripto para birimlerinin fiyatları	CNN, LSTM ve RNN modelleri kripto para birimleri ve finansal piyasalarda dalgalanmaların tahmininde etkili sonuçlar vermiştir.
Demir vd. (2019)	Makine öğrenme yöntemleriyle bitcoin fiyat tahmini	Bitcoin fiyatı	LSTM modeli en yüksek doğruluk oranına ulaşmış, diğer yöntemlerden daha başarılı sonuçlar elde edilmiştir.
Metin (2021)	Bitcoin, Ethereum ve Ripple fiyatlarının regresyon yöntemleriyle analizi	Bitcoin, Ethereum ve Ripple fiyatları	GBDT modeli kripto paraların fiyat tahmininde en iyi sonuçları vermiştir.
Taş Gülüm ve Tulum (2021)	S&P 500 endeksi fiyat tahmini	S&P 500 endeksi fiyat verileri	LSTM ve MLP yöntemleri fiyat tahminlerinde birbirine yakın sonuçlar vermiştir.
Aygün ve Kabakçı (2021)	Bitcoin fiyat tahmininde istatistiksel ve makine öğrenimi modelleri	Bitcoin fiyatı	RNN modeli, diğer yöntemlere göre daha iyi sonuçlar vermiştir.
Yurtsever (2021)	LSTM, Bi-LSTM ve GRU yöntemleri ile altın, petrol fiyatı tahmini	Altın, petrol fiyatları, faiz oranları	LSTM modeli en iyi tahmin sonuçlarını vermiştir.
Tanişman vd. (2021)	Bitcoin fiyat tahmini için LSTM ve ARIMA zaman serisi modelleri	Bitcoin fiyatı	LSTM modeli yakın ve uzak gelecek tahminlerinde düşük hata oranı ile en iyi performansı göstermiştir.
Albayrak ve Saran (2023)	Bist100 hisse senedi fiyat tahmini	Bist100 hisse senetleri	Dikkat mekanizmalı LSTM modeli, diğer modellere göre daha iyi performans göstermiştir.
Odabaşı ve Tokoğlu (2023)	Polkadot kripto para birimi tahmini	Polkadot fiyatı, Ethereum ile ilişkili veriler	LSTM modeli, Ethereum ile ilişkili veriler kullanıldığında yüksek başarı elde etmiştir.
Şenol ve Denizhan (2023)	Bitcoin, Ethereum ve Cardano fiyat tahmini	Bitcoin, Ethereum, Cardano fiyatları	Yapay Sinir Ağları, regresyon analizine göre daha başarılı sonuçlar vermiştir.
Demirci ve Karaatlı (2023)	Bitcoin, Ethereum ve Ripple fiyat tahmini	Bitcoin, Ethereum, Ripple fiyatları	LSTM modeli, Ethereum fiyat tahminlerinde diğer modellere göre daha yüksek doğruluk sağlamıştır.
Polat(2024)	LSTM modeli	RSI, Bollinger Bandları, OBV	Bitcoin fiyat tahmininde en düşük MSE değeri elde edilmiştir.

Ulusal çalışmalar içerisinde yer alan Sezer vd. (2019) çalışmasında CNN, LSTM ve RNN modellerini, Demir vd. (2019) çalışmasında LSTM, DVM, YSA, NB, karar ağaçları ve KNN algoritmalarını, Metin (2021) çalışmasında Çoklu Lineer, Polynomial Regresyon ve GBDT yöntemini, Taş, Gülüm ve Tulum (2021) çalışmalarında LSTM ve MLP yöntemlerini, Aygün ve Kabakçı (2021) çalışmalarında MA, ARIMA, YSA, RNN ve CNN modellerini, Yurtsever (2021) çalışmasında, LSTM, Bi-LSTM ve GRU yöntemlerini, Tanişman vd. (2021) çalışmalarında LSTM ve ARIMA modellerini, Albayrak ve Saran (2023) çalışmalarında ARIMA, LSTM ve GRU modellerini, Odabaşı ve Tokoğlu (2023) çalışmalarında LSTM modelini, Şenol ve Denizhan (2023) çalışmalarında YSA ve regresyon modellerini, Demirci ve Karaatlı (2023) çalışmalarında LSTM ve GRU modellerini, Sağır (2024) çalışmasında CNN, LSTM ve Parçacık Sürü Optimizasyonu, Polat (2024) çalışmasında LSTM modelini kullanarak özellikle kripto varlık tahminlerinde makine öğrenmesi modellerinin diğer istatistiksel ve ekonometrik modellere göre daha başarılı olduklarını ortaya koymuşlardır. İlgili çalışmalara ilişkin detaylar şu şekilde özetlenebilir.

Sezer vd. (2019) çalışmalarında finansal tahminlerde derin öğrenme tekniklerinin kullanımının, özellikle zaman serilerinin tahmininde etkili sonuçlar verdiğini ortaya koymuşlardır. Bu amaçla CNN, LSTM ve RNN gibi modellerin kripto para birimleri ve diğer finansal piyasalardaki dalgalanmaların daha iyi anlaşılmasına olanak tanıdıklarını belirlemiştirler. Benzer şekilde Demir vd. (2019) çalışmalarında 2010-2019 yılları için makine öğrenmesi yöntemleriyle bitcoin fiyat tahmini yapmışlardır. Kullanılan yöntemler; LSTM, DVM, YSA, NB, karar ağaçları ve KNN algoritmalarıdır. Modeller içerisinde en yüksek doğruluk oranı LSTM modelinden elde edilmiştir.

Metin (2021) çalışmasında Bitcoin (BTC), Ethereum (ETH) ve Ripple (XRP) kripto para birimleri analiz edilmiş ve Çoklu Lineer Regresyon, Polynomial Regresyon ve GBDT modelleri kullanılmıştır. Her üç modelde verilere daha iyi uyum gösterdiğini göstermişlerdir. Taş, Gülüm ve Tulum (2021) ise Yahoo Finance verileriyle S&P 500 endeksi üzerinde derin öğrenme yöntemleriyle fiyat tahmini gerçekleştirmiş ve LSTM ile MLP modellerinden yararlanmışlardır. LSTM ve MLP yöntemlerinden elde edilen eğitim ve test hatalarının birbirine yakın sonuçlar verdiği gösterilmektedir. Aygün ve Kabakçı (2021), Bitcoin fiyat tahmini için istatistiksel (MA, ARIMA) ve makine öğrenimi (YSA, RNN, CNN) tekniklerini kullanmış ve RNN modelinin en iyi performansı gösterdiğini bulmuşlardır. Yurtsever (2021), LSTM, Bi-LSTM ve GRU modelleriyle altın, petrol, döviz kuru ve borsa endeksi gibi değişkenlerin tahmininde LSTM modelinin üstün performans sergilediğini ortaya koymuştur. Tanışman vd. (2021) ise Bitcoin fiyat tahmininde LSTM ve ARIMA modellerini karşılaştırmış, LSTM'nin kısa ve uzun vadeli tahminlerde daha başarılı olduğunu tespit etmiştir.

Albayrak ve Saran (2023), ARIMA, LSTM ve GRU modellerini kullanarak BIST100 hisse senedi fiyatlarını tahmin etmiş ve diğer çalışmalardan farklı olarak 28 finansal göstergiyi analizlerine dahil etmişlerdir. Çalışma sonuçları dikkat mekanizmalı LSTM, GRU, LSTM ve ARIMA sıralamasıyla performans sergilediği bulunmuştur. Odabaşı ve Tokoğlu (2023), Polkadot kripto para biriminin fiyat tahmininde yapay sinir ağları ve LSTM modellerini kullanmış, başarılı sonuçlar elde etmişlerdir. Şenol ve Denizhan (2023), Bitcoin, Ethereum ve Cardano fiyat tahmininde Yapay Sinir Ağları ve Regresyon Analizi yöntemlerini karşılaştırmışlardır. Çalışmada Yapay Sinir Ağları ve Regresyon Analizi yöntemleri ile bu kripto paraların açılış, kapanış, gün içindeki en küçük ve en büyük değerleri kullanılarak bir sonraki günün kapanış değeri tahmin edilmişlerdir. Çalışmada yapay sinir ağlarının daha başarılı olduğu sonucuna ulaşmışlardır. Demirci ve Karaatlı (2023), Bitcoin, Ethereum ve Ripple fiyat tahmininde LSTM ve GRU modellerini kullanmış ve en iyi sonuçların Bitcoin için GRU, Ethereum için ise LSTM modeliyle elde edildiğini ortaya koymuştur.

Polat (2024), Bitcoin'in geçmiş verilerini farklı indikatörlerle destekleyerek LSTM modeliyle fiyat tahmini yapmış ve en iyi sonucun RSI, Bollinger Bantları, MOV(200) ve OBV içeren veri setinden elde edildiğini belirtmiştir. Sağır (2024) ise LeNet-5 tabanlı CNN, LSTM ve Parçacık Sürü Optimizasyonu yöntemleriyle S&P 500 hisselerinde otomatik al/sat stratejileri geliştirmiş ve bu modellerin standart modellere göre daha iyi performans gösterdiğini ortaya koymuştur.

Uluslararası yayınlar incelendiğinde ise Huang ve Yen (2019) ve Zhang (2023) çalışmalarında LSTM ve RNN modellerini, Kumar ve Rath (2020) çalışmalarında MLP ve LSTM modellerini, Mudassir ve Bennbaia ve Unal (2020) çalışmalarında ANN, SANN, SVM ve LSTM yöntemleri, Rajagukguk vd. (2020) çalışmalarında LSTM ve CNN-LSTM hibrit modellerini, Lara-Benítez vd. (2020), Akbulaev vd. (2020), Hu, Zhao ve Khushi (2021), Livieris vd. (2021), Millikan, Subramanian ve Joseph (2021), Wardak ve Rasheed (2022), Zhang (2022), Kumar, Pv ve Jackson (2023), Xu (2023), Babu vd. (2023), Sari vd. (2023), Kumari vd. (2023), Dhokane ve Agarwal (2024) çalışmalarında LSTM modelini, Kashyap, Singh ve V. (2022) ve Oladele (2023) çalışmalarında LSTM ve GRU modellerini, He ve Jiang (2022) ve Wen ve Ling (2023) çalışmalarında CNN ve LSTM modellerini, Minotti (2022) çalışmasında ARIMA ve LSTM modellerini, Abubaker ve Farid (2022) çalışmalarında RNN ve LSTM modellerini, Nair, Marie ve Abd-Elmegid (2023) çalışmalarında RNN, LSTM, GRU, Bi-LSTM ve CONV1D modelleri, Gao (2023) çalışmasında CNN-LSTM modelini, Seabe, Moutsinga ve Pindza (2023) çalışmalarında LSTM, GRU ve Bi-LSTM modellerini, Chen (2023) çalışmasında RF ve LSTM modellerini, Ladhari ve Boubaker (2024) çalışmalarında YSA ve LSTM modellerini kullanmışlardır. Çalışma sonuçları makine öğrenmesi modellerinin diğer istatistiksel ve ekonometrik modellere göre daha başarılı olduklarını ortaya koymaktadır. İlgili çalışmalara ilişkin detaylar Tablo 2'deki gibi özetlenebilir.

Tablo 2: Uluslararası Literatür Çalışmaları

Yazar	Model	Değişkenler	Çalışma Sonuçları
Huang ve Yen (2019)	LSTM ve RNN modellerinin finansal piyasalar için kullanımı	Fiyat, Hacim	LSTM ve RNN modelleri, finansal piyasaların karmaşık veri desenlerini öğrenmede yüksek başarı göstermiştir.
Kumar ve Rath (2020)	Ethereum fiyat tahmini için MLP ve LSTM modelleri	Ethereum Fiyatı, Piyasa Verileri	LSTM modeli, MLP'ye kıyasla marjinal olarak daha iyi performans göstermiştir.
Lara-Benítez vd. (2020)	Zaman serisi tahminleri için LSTM modelleri	Zaman Serisi Verileri	LSTM modelleri, finansal tahminler ve kripto para birimi fiyat analizleri için en iyi performansı göstermiştir.
Hu Zhao ve Khushi (2021)	LSTM ve hibrit modellerin finansal tahminlerde kullanımı	Finansal Veriler, Piyasa Verileri	LSTM ve hibrit modeller, yüksek getiriler ve performans sağlamıştır.
Li., Zhang, ve Krebs (2022)	CNN-LSTM modelleriyle su akışını tahmin etmek	Su Akışı, Mühendislik Verileri	CNN-LSTM modelinin su yönetimi ve ilgili mühendislik uygulamalarında potansiyel olarak daha güvenilir bir tahmin aracı olabileceğini göstermektedir.
Kumar Pv ve Jackson (2023)	LSTM modeli ile kripto para fiyat tahminleri	Kripto Para Fiyatları	LSTM modeli, kripto para fiyatlarını tahmin etmede yüksek doğruluk elde etmiştir.
Xu (2023)	LSTM modeli ile Ethereum fiyat tahmini	Ethereum Fiyatı	LSTM modeli, Ethereum'un gelecekteki fiyatını yüksek doğrulukla tahmin etmiştir.
Nair Marie ve Abd-Elmegid (2023)	Bitcoin fiyat tahmini için RNN, LSTM, GRU modelleri	Bitcoin Fiyatı	LSTM modeli, diğer modellerden daha iyi performans göstermiştir.
Gao (2023)	CNN-LSTM modelinin hisse senedi fiyat tahmininde kullanımı	Hisse Senedi Fiyatları	CNN-LSTM modeli, hisse senedi fiyat tahmininde yüksek doğruluk ve genelleme yeteneği sağlamıştır.
Dhokane ve Agarwal (2024)	LSTM modeli	RSI, Bollinger Bantları, MACD	Model, MAPE, RMSE ve R ² performans ölçütlerinde başarılı sonuçlar göstermiştir.

Huang ve Yen (2019) tarafından yapılan çalışmada, makine öğrenimi tekniklerinin genel olarak finansal piyasaların tahmin edilmesi konusunda LSTM ve RNN modellerinin karmaşık veri desenlerini öğrenme ve tahmin etmede yüksek başarı gösterdiğini ortaya koymuşlardır.

Kumar ve Rath (2020) çalışmalarında, MLP ve LSTM modelleri ile Ethereum'un fiyat eğilimlerini tahmin etmeyi amaçlamaktadır. Çalışmada günlük, saatlik ve dakikalık verileri kullanarak modellerin tahmin performansını değerlendirmişlerdir. Çalışmada LSTM'nin marjinal olarak daha iyi performans gösterdiğini bulmuşlardır. Mudassir vd. (2020), Bitcoin fiyat tahmininde ANN, SANN, SVM ve LSTM modellerini kullanmışlardır. Çalışmada sadece bir günlük veriler değil aynı zamanda yedi, otuz ve doksan günlük veriler de kullanılmıştır. SANN günlük, SVM kısa vadeli, ANN ve LSTM ise uzun vadeli tahminlerde daha başarılı sonuçlar elde etmiştir. Rajagukguk vd. (2020) ise, LSTM ve CNN-LSTM hibrit modellerinin, özellikle güneş ışınımı ve fotovoltajik güç tahmini için kullanıldığını ve bu modellerin finansal piyasalar gibi karmaşık zaman serisi verileri için de uygulanabilir olduğunu, RNN ve LSTM modellerinin Ethereum token analizlerinde kullanımına dair potansiyeller sunduğunu ifade etmişlerdir. Lara-Benítez vd. (2020) tarafından yapılan çalışmada, LSTM mimarilerinin zaman serisi tahminleri için en iyi performansı gösterdiği ve finansal tahminler ile kripto para birimi fiyat analizleri gibi alanlarda etkili olduğu göstermişlerdir. Akbulaev vd. (2020) ise Ethereum ve Bitcoin fiyatları arasındaki ilişki üzerine yapılan analizlerde, LSTM ve diğer makine öğrenimi modellerinin bu tür finansal ilişkileri modellemede kullanılabileceğini belirtmişlerdir.

Hu, Zhao ve Khushi (2021) tarafından yapılan çalışmada derin öğrenme modellerinin özellikle LSTM ve hibrit modellerin yüksek getiriler ve performans sağladığını ifade etmişlerdir. Livieris vd. (2021) kripto para fiyatı ve hareketinin tahmini için çoklu girdili derin öğrenme modelini kullanarak en yüksek piyasa değerine sahip üç kripto para birimi olan Bitcoin (BTC), Ethereum (ETH) ve Ripple (XRP)'in üç ardışık yıllık verileri kullanılarak kapsamlı bir ampirik çalışma yapmışlardır. Çalışma sonucunda önerilen LSTM modelinin karışık kripto para verilerini verimli bir şekilde kullanma yeteneğine sahip olduğunu, aşırı uyumayı azalttığını ve geleneksel tam bağlantılı derin sinir ağlarıyla karşılaştırıldığında hesaplama maliyetini düşürdüğünü ortaya koymuşlardır. Millikan, Subramanian ve Joseph (2021) tarafından yapılan çalışma sonucunda Bitcoin ve Ethereum fiyat tahmininde LSTM modelinin ARIMA modeline göre daha iyi sonuçlar verdiğini ortaya koymuşlardır.


Kashyap, Singh ve V. (2022) çalışmalarında LSTM ve GRU modellerini aşırı fiyat dalgalanmalarıyla başa çıkmak ve güvenilir bulgular üretmek için kullandıklarını açıklamaktadırlar. Modelin performansı ile GRU'nun kripto para birimlerinin çoğu için LSTM'den daha iyi performans gösterdiğini ortaya koymuşlardır. He ve Jiang (2022) çalışmalarında, CNN ve LSTM modellerini birleştirerek hisse senedi fiyat tahmin doğruluğunu artırmayı amaçlamış ve bu modelin performansının diğer modellere göre daha iyi olduğunu göstermişlerdir. Wardak ve Rasheed (2022) çalışmalarında Bitcoin fiyatını en yüksek doğrulukla tahmin etmek için LSTM modelini kullanmışlardır. Kullanılan LSTM modeli Bitcoin fiyatını %95,7 doğrulukla tahmin etmişlerdir. Minotti (2022) çalışmasında ARIMA ve LSTM modelleriyle Bitcoin (BTC), Ethereum (ETH), Cardano (ADA), Solana (SOL) ve Polkadot (NOKTA) olan beş ana kripto para birimini tahmin etmektedir. Çalışma sonucunda LSTM'nin ARIMA'ya göre daha iyi performans sergilediği sonucuna ulaşılmıştır. Wardak ve Rasheed (2022), LSTM modeliyle Bitcoin fiyatını %95,7 doğrulukla tahmin etmiştir. Minotti (2022), LSTM'nin Bitcoin ve diğer kripto paralarda ARIMA'dan daha iyi performans sergilediğini göstermiştir. Abubaker ve Farid (2022), hisse senedi tahmininde LSTM ve RNN modellerinin yatırımcılara etkili bilgiler sunduğunu belirtmişlerdir. Zhang (2022) ise LSTM'nin uzun vadeli hisse senedi tahminlerinde güçlü, kısa vadede ise zayıf performans gösterdiğini ortaya koymuştur.

Kumar, Pv ve Jackson (2023) çalışmasında Bitcoin için Xu (2023) çalışmasında ise Ethereum için LSTM modelini kullanarak yüksek doğruluk oranıyla başarılı sonuçlar bulmuşlardır. Oladele (2023), Bitcoin ve Ethereum fiyat tahmininde LSTM'nin GRU'ya göre daha iyi performans sergilediğini belirtmiştir. Zhang (2023), RNN ve LSTM'in ardışık veri işleme yeteneklerini vurgulamıştır. Nair vd. (2023), Bitcoin fiyat tahmininde LSTM'nin diğer modellere kıyasla daha yüksek doğruluk sağladığını göstermişlerdir. Gao (2023), CNN-LSTM modelinin hisse senedi fiyat tahmininde etkili olduğunu ifade etmiştir. Babu vd. (2023), borsa tahmininde LSTM'nin yüksek doğruluğa sahip olduğunu belirtmişlerdir. Wen ve Ling (2023), Bitcoin fiyat tahmininde LSTM'nin CNN'den daha düşük hata oranı ve yüksek doğruluk sunduğunu göstermiştir. Sari vd. (2023), Solana fiyat tahmininde LSTM'nin başarılı sonuçlar verdiğini belirtmiştir. Seabe, Moutsinga ve Pindza (2023) çalışmalarında üç ana kripto para biriminin (Bitcoin (BTC), Ethereum (ETH) ve Litecoin (LTC)) fiyat tahminleri için LSTM, GRU ve Bi-LSTM modellerini kullanmışlardır. Bi-LSTM'nin LSTM ve GRU'dan daha iyi performans gösterdiğini göstermektedir. Kumari vd. (2023), LSTM'nin Bitcoin fiyat tahmininde umut verici sonuçlar sunduğunu vurgulamıştır. Chen (2023) ise Bitcoin fiyat tahmininde RF modelinin LSTM'den daha düşük hata oranına sahip olduğunu belirtmiştir.

Dhokane ve Agarwal (2024), Hindistan Borsası verileriyle RSI, Bollinger Bantları ve MACD gibi teknik göstergelerle desteklenen LSTM modelinin hisse senedi fiyat ve trend tahmininde başarılı olduğunu göstermiştir. Ladhari ve Boubaker (2024), Bitcoin fiyat tahmininde LSTM, dikkat mekanizmaları ve gradyan optimizasyonunu birleştirerek geliştirdikleri hibrit modelin yüksek doğruluk sağladığını ortaya koymuştur.

III. VERİ VE BULGULAR

Çalışmada Ethereum'un ERC-20 tokenları üzerindeki etkisi analiz edilirken, Binance borsasından API (Application Programming Interface) aracılığıyla çekilen ve 15 dakikalık aralıklarla kaydedilen Ethereum (ETH) veri seti kullanılmıştır. Veri seti 2017 yılının dördüncü çeyreğinden başlayarak 2024 yılının ikinci çeyreğine kadar olan dönemi kapsamakta ve toplamda 224967 gözlemden oluşmaktadır. Veriler Python programlama dili kullanılarak işlenmiştir. Pandas kütüphanesi ile veriler okutulduktan sonra, Ethereum kapanış değerleri sayısal veri tipine çevrilmiş ve eksik veriler temizlenmiştir. Şekil 1'de 2017-2024 dönemi Ethereum kapanış fiyatı verilmektedir. Şekil 1 incelendiğinde 2021 yılında Ethereum'un dikkate değer bir şekilde attığı görülmektedir. Ethereum Aralık 2021'de 4366 \$ ile en yüksek değerine ulaşmıştır. İlaveten 4000 \$'ın üstü Mayıs 2021 ve Nisan 2024 dönemlerinde test edilmiştir. Dikkat edilirse Ethereum Haziran 2022 yılında 1000 \$'a kadar gerilemiştir.



Şekil 1: 2017-2024 Dönemi 15 Dakikalık Ethereum (Eth) Kapanış Fiyatları

Model eğitim sürecinde modelde finansal zaman serisi tahminlerinde yaygın olarak kullanılan ve piyasa dinamiklerini anlamada önemli katkılar sağlayan göstergeler tercih edilmiştir. Bu göstergeler: 'kapanış fiyatı' (close), 'en yüksek fiyat' (high), 'en düşük fiyat' (low), '7 günlük hareketli ortalama' (ma7), '21 günlük üssel hareketli ortalama' (ema21), 'hacim' (volume), 'göreceli güç endeksi' (rsi), ve 'hareketli ortalama yakınsama ıraksama' (macd) şeklindedir. Bu göstergeler fiyat hareketlerindeki kısa ve orta vadeli eğilimleri ve piyasa momentumunu etkili bir şekilde yansıtabilme kapasitesine sahiptirler (Patel vd., 2020; Altan vd., 2019). Böylece, modelin hem kısa hem de orta vadeli piyasa hareketlerini etkili bir şekilde tahmin edebilmesi amaçlanmıştır. Öncelikle bu özellikler, verilerin karşılaştırılabilir olmasını sağlamak amacıyla MinMaxScaler kullanılarak 0 ile 1 arasında ölçeklendirilmiştir. Bu ölçekleme, modelin farklı büyüklükteki değerleri daha iyi bir şekilde işlemesine olanak tanımaktadır. Ethereum fiyat tahmini yapmak üzere ayrı ayrı iki model birbirinden bağımsız olarak eğitilmiş ve bu eğitimlerde LSTM ve CNN tabanlı yapay sinir ağı modelleri kullanılmıştır.

LSTM modeli, TensorFlow ve Keras kütüphaneleriyle üç katmanlı olarak uygulanmıştır. Hem LSTM hem de CNN modelleri 'adam' optimizatörü ve ortalama karesel hata kaybı fonksiyonu ile derlenmiştir. Modeller, 30 zaman adımı boyunca ve toplam 50 epoch süresince eğitilmiştir. Verilerin %80'i modellerin eğitilmesi, %20'si ise test edilmesi amacıyla kullanılmıştır. Her iki model için de erken modellerin aşırı öğrenmesini önlemek için durdurma özelliği kullanılmıştır. Ethereum'un ERC-20 token ekosisteminde merkezi bir role sahip olması nedeniyle, Ethereum fiyat dinamiklerinin ERC-20 tokenlarının fiyat hareketlerini etkilemektedir. Bu bağlamda çalışmada model eğitimi ve tahmin süreci iki aşamalı olarak tasarlanmıştır. İki aşamalı modelleme süreci şu şekilde detaylandırılabilir: İlk aşamada, Ethereum (ETH) fiyat verileri kullanılarak LSTM ve CNN tabanlı modeller eğitilmiştir. İkinci aşamada eğitilen modeller ERC-20 token fiyatlarının tahmininde kullanılmıştır. Bu yaklaşım ile Ethereum'un piyasa hareketlerinin ERC-20 tokenları üzerindeki etkisi daha doğru ve kapsamlı bir şekilde değerlendirilmiş, fiyat tahminlerinin doğruluğu artırılmıştır. Bu stratejik yaklaşımla model bütün

olarak değerlendirildiğinde Ethereum fiyat verileri bağımsız değişkeni, ERC-20 token varlıklarının fiyatları ise bağımlı değişkeni tanımlamaktadır.

Çalışmada kullanılan ERC-20 tokenlar, model başarısını ortaya koymak açısından farklı özelliklere göre seçilmiştir. Bu özellikler; tokenin işlevi, kullanım alanı ve piyasa hacmidir. Bu kapsamda seçilen tokenlar; LINK, MATIC, UNI, RNDR her biri farklı amaç doğrultusunda üretilmiş farklı kullanım alanları olan kripto varlıklardır. Ethereum (ERC20) jetonlar sektörünün piyasa değeri 9,43T \$'dir ve toplam kripto para birimi piyasası sınırının %355,80'ini temsil etmektedir. LINK (Chainlink), blockchain'lerin gerçek dünya verilerine güvenli bir şekilde erişimini sağlamak için tasarlanmış bir merkezi olmayan oracle ağıdır. Bu ağ, akıllı sözleşmelerin dış dünya ile etkileşime girmesine olanak tanımaktadır. MATIC (Polygon), Ethereum blockchain'inin ölçeklenebilirliğini artırmak ve işlem maliyetlerini düşürmek için bir yan zincir çözümüdür. UNI (Uniswap), kullanıcıların merkezi olmayan bir ortamda token alıp satmalarını sağlayan bir otomatik piyasa yapıcı (AMM) konumundadır. RNDR (Render), sanatçılar ve diğer içerik üreticileri için merkezi olmayan bir GPU render ağı sunarak, kullanıcıların işlem gücünü paylaşmalarını ve karşılığında token kazanmalarını sağlamaktadır. Bu kripto varlıklara ilişkin 2024 yılı mayıs ayı piyasa değerleri Tablo 3'te verilmiştir.

Tablo 3: Kullanılan Tokenların Piyasa Değeri

Token	Piyasa değeri (milyar \$)
LINK	7,9
MATIC	6,7
RNDR	4,3
UNI	4,2

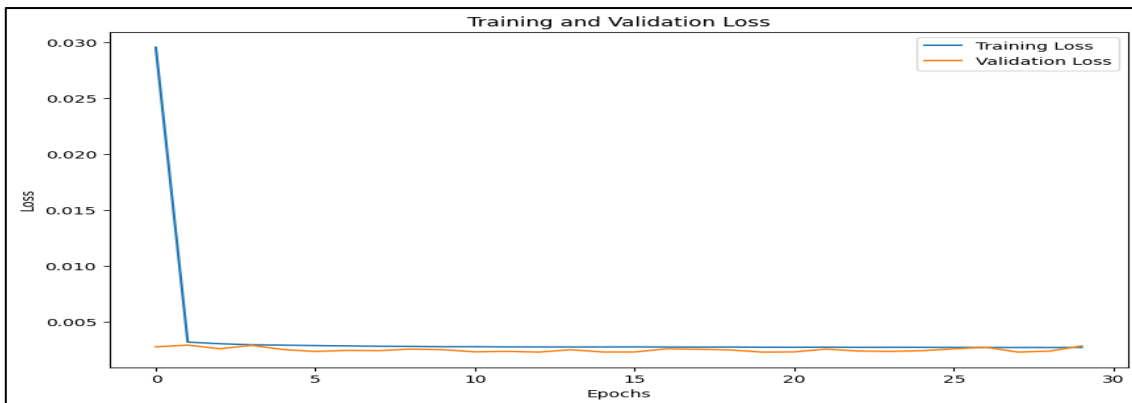
Kaynak: <https://coinmarketcap.com.tr>. (Erişim: 02.06.2024)

Tablo 3'e göre en fazla piyasa değerine sahip olan token 7,9 Milyar \$ ile LINK'tir. Piyasa değeri bakımından ikinci sırada MATIC tokeni gelmektedir. RNDR ve UNI tokenları ise yaklaşık 4,3 Milyar \$'lık piyasa değerlerine sahiptirler. Ethereum verileri yardımıyla eğitilen LSTM ve CNN modellerinin ERC-20 tokenları tahmin etmedeki başarıları sonraki alt bölümlerde sunulmaktadır.

a. LSTM Model Tahmin Sonuçları

Ethereum'un ERC-20 tokenları üzerindeki etkisini analiz etmek amacıyla LSTM modeli kullanılarak eğitim gerçekleştirilmiştir. Aşağıda, eğitim sırasında elde edilen Training Loss (Eğitim Kayıp Değeri) ve Validation Loss (Doğrulama Kayıp Değeri) grafiği verilmiştir. Bu grafik, modelin eğitim süreci boyunca nasıl performans gösterdiğini ve modelin öğrenme eğrisini değerlendirme olanağı tanımaktadır.

Şekil 2'ye göre, modelin eğitim sırasında aşırı öğrenme yaşamadığı ve doğrulama verileri üzerinde de dengeli bir performans sergilediği gözlemlenmektedir. Eğitim ve doğrulama kayıp değerleri, modelin genel performansını değerlendirirken önemli bir ölçüt olup, modelin doğru bir şekilde genel performansını temsil etmektedir.



Şekil 2. LSTM Modeli için Eğitim ve Doğrulama Kayıpları Grafiği

Daha sonra bu model kullanılarak LINK, MATIC, UNI ve RDNDR tokenlarının fiyat tahminleri gerçekleştirilmiştir. Elde edilen sonuçlara ilişkin performans ölçümleri Tablo 4'de verilmiştir.

Tablo 4: LSTM Modeli Uyum Ölçüleri


	MAE	MSE	MAPE	R ²
LINK	0,0968	0,0124	%0,69	0,792
MATIC	0,00569	0,0001	%0,83	0,826
UNI	0,0349	0,0025	%0,48	0,806
RNDR	0,0954	0,0135	%0,87	0,569

LINK (Chainlink) tokeni için LSTM modeli kullanılarak yapılan tahminlerde, Ortalama Mutlak Hata (MAE) 0,0968, Ortalama Kare Hata (MSE) 0,0124, Ortalama Mutlak Yüzde Hata (MAPE) %0,69 ve R² değeri 0,792 olarak hesaplanmıştır. MATIC (Polygon) tokeni için modelin performansı incelendiğinde, MAE değeri 0,00569, MSE değeri $5,93 \times 10^{-5}$, MAPE değeri %0,83 ve R² değeri 0,826 olarak belirlenmiştir. UNI (Uniswap) tokeni için yapılan tahminlerde, MAE değeri 0,0349, MSE değeri 0,0025, MAPE değeri %0,48 ve R² değeri 0,806 olarak hesaplanmıştır. Son olarak RNDR (Render) tokeni için ise MAE değeri 0,0954, MSE değeri 0,0135, MAPE %0,87 ve R² değeri 0,569 olarak belirlenmiştir. RNDR tokeni tahminlerinde hata oranları diğer tokenlara göre nispeten daha yüksek ve R² değeri daha düşüktür.

LSTM modeli ile yapılan analizler, Ethereum'un ERC-20 token fiyatları üzerinde belirgin bir etkisi olduğunu göstermektedir. MAE, MSE, MAPE ve R² değerleri incelendiğinde, modelin özellikle LINK, MATIC ve UNI token fiyatlarını yüksek doğrulukla tahmin edebildiği görülmektedir. Ancak, RNDR tokeni için modelin tahmin performansı diğer tokenlara göre daha düşüktür. Bu farklılıklar, tokenların piyasa dinamikleri, likidite düzeyleri ve Ethereum ile olan ilişkisindeki değişkenliklerden kaynaklanmaktadır.

b. CNN Model Tahmin Sonuçları

Alternatif olarak Ethereum'un ERC-20 tokenları üzerindeki etkisini analiz etmek amacıyla, CNN modeli yukarıdaki süreç kullanarak Ethereum veri seti ile eğitim gerçekleştirilmiştir. Eğitim sürecinde, modelin başarısını ölçmek ve aşırı öğrenme riskini değerlendirmek için eğitim kayıp ve doğrulama kayıp grafiklerine dikkat edilmiştir. Aşağıda, modelin eğitim sürecindeki bu iki kayıp fonksiyonunun karşılaştırmasını gösteren grafik yer almaktadır.



Şekil 3. CNN Modeli için Eğitim ve Doğrulama Kayıpları Grafiği

Şekil 3'te doğrulama kayıp değerinin eğitim sürecinde genellikle istikrarlı olduğu, ancak bazı epochlarda dalgalanmalar gösterdiği görülmektedir. Genel olarak, CNN modeli validation verisi üzerinde iyi bir performans sergilemekte ve aşırı öğrenme belirtileri göstermemektedir. Bu durum, CNN modelinin Ethereum veri seti ile ERC-20 token fiyatlarını tahmin etmede güvenilir bir araç olarak kullanılabileceğini desteklemektedir. Daha sonra bu model kullanılarak LINK, MATIC, UNI ve RDNDR tokenlarının fiyat tahminleri yapılmıştır. Tablo 5'te CNN modeli kullanılarak yapılan ERC-20

tokenlarının fiyat tahmin sonuçlarının Ortalama Mutlak Hata (MAE), Ortalama Kare Hata (MSE), Ortalama Mutlak Yüzde Hata (MAPE) ve R-kare (R²) değerleri sunulmaktadır.

Tablo 5: CNN Modeli Uyum Ölçüleri

	MAE	MSE	MAPE	R ²
LINK	0,0347	0,00168	%0,25	0,903
MATIC	0,00712	0,00009	%1,05	0,752
UNI	0,0685	0,0075	%0,96	0,724
RNDR	0,0347	0,002	%0,32	0,611

Tablo 5'te CNN modeli kullanılarak yapılan tahminlerde, LINK (Chainlink) tokeni için MAE değeri 0,0347, MSE değeri 0,00168, MAPE değeri %0,25 ve R² değeri 0,903 olarak hesaplanmıştır. MATIC (Polygon) tokeni için model performansı değerlendirildiğinde, MAE değeri 0,00712, MSE değeri 0,00009, MAPE değeri %1,05 ve R² değeri 0,752 olarak bulunmuştur. UNI (Uniswap) tokeni için tahmin sonuçları, MAE değeri 0,0685, MSE değeri 0,0075, MAPE değeri %0,96 ve R² değeri 0,724 olarak hesaplanmıştır. RNDR (Render Token) tokeni için yapılan tahminlerde, MAE değeri 0,0347, MSE değeri 0,002, MAPE değeri %0,32 ve R² değeri 0,611 olarak hesaplanmıştır. CNN modeli ile yapılan analizler genel olarak değerlendirildiğinde LINK ve MATIC tokenları için başarılı tahminler yaptığını, ancak UNI ve RNDR tokenları için tahmin performansının nispeten daha düşük olduğunu göstermektedir. Bu durum, tokenların piyasa dinamikleri ve likidite düzeyleri gibi çeşitli faktörlerin tahmin doğruluğunu etkileyebileceğini ortaya koymaktadır.

SONUÇ VE DEĞERLENDİRME

Bu çalışma, Ethereum'un ERC-20 token fiyatları üzerindeki etkisini değerlendirmek amacıyla LSTM ve CNN modellerinden yararlanmaktadır. Her iki modelin performansı, farklı tokenlar için karşılaştırılmış ve elde edilen sonuçlar analiz edilmiştir. Genel olarak, her iki modelin performansı token bazında değişkenlik gösterdiği bulunmuştur. Diğer bir ifadeyle CNN modeli, LINK ve RNDR tokenları için daha iyi performans gösterirken, LSTM modeli MATIC ve UNI tokenları için daha başarılı olmuştur. Bu durum, CNN modelinin LINK ve RNDR tokenlarının, LSTM modelinin ise MATIC ve UNI tokenlarının fiyat dinamiklerini daha iyi yakalayabildiğini göstermektedir. Bu durum, her iki modelin de güçlü ve zayıf yönlerinin bulunduğunu göstermektedir.

Token bazında sonuçlar değerlendirildiğinde en iyi performansı elde etmede tokenın piyasa dinamikleri ve özelliklerinin etkili olduğu görülmektedir. Zira tokenların piyasa dinamikleri, likidite düzeyleri ve Ethereum ile olan ilişkilerindeki değişkenlikler ilgili tokenın fiyat tahminini etkilemektedir. Bu çalışma bulguları, Ethereum'un ERC-20 token fiyatları üzerinde belirgin bir etkisi olduğunu ve bu etkinin tahmin edilmesinde hem LSTM hem de CNN modellerinin kullanılabilir araçlar olduğunu göstermektedir. Ancak, model performansının token bazında farklılık gösterebileceği ve her token için uygun modelin ayrı ayrı belirlenmesi gerektiği görülmektedir. Çalışmadan elde edilen sonuçlar literatürdeki bulguları desteklemektedir. Özellikle Sezer vd. (2019), Demir vd. (2019), Kumar ve Rath (2020) ve Xu (2023) çalışmalarında vurgulanan LSTM ve CNN modellerinin finansal piyasalardaki tahmin gücü, bu çalışmanın bulgularıyla büyük ölçüde uyum göstermektedir. Çalışmada, LSTM modeli özellikle MATIC ve UNI tokenlarının fiyat tahminlerinde üstün bir performans sergilemiştir. Ayrıca CNN modeli, kısa vadeli tahminlerde LINK ve RNDR tokenları için daha başarılı sonuçlar ortaya koymuştur. Bu durum, Huang ve Yen (2019) ile He ve Jiang (2022) çalışmalarında da belirtildiği gibi, CNN'in zamansal ve mekânsal desenleri yakalama konusundaki yetkinliğiyle ilişkilendirilmektedir. Bununla birlikte, Albayrak ve Saran (2023) ile Zhang (2023) çalışmalarında, LSTM ve CNN modellerinin tahmin performansının; kullanılan verilerin özellikleri, tokenın piyasa dinamikleri ve likidite düzeyine bağlı olarak değişiklik gösterebileceği vurgulanmıştır. Çalışmada da

bu değişken etkiler elde edilmiştir. Çalışmanın katkısı Ethereum'un ERC-20 tokenlarının kısa vadeli fiyat dinamiklerini incelemesi ve her bir token için en uygun modeli belirlemesi yönünde önemli bulgular sunmasıdır. Bu sonuçlar, model seçiminin token bazında optimize edilmesi gerektiğini vurgulayan Dhokane ve Agarwal (2024) ile Ladhari ve Boubaker (2024) gibi çalışmalarla da tutarlıdır.

Sonuç olarak bu çalışma Ethereum'un ERC-20 token fiyatları üzerindeki etkisini anlamada önemli bir adım sunmakta ve bu tokenların fiyatlarını tahmin etmede kullanılacak farklı modellerin performansını karşılaştırarak yatırımcılara ve araştırmacılara değerli bilgiler sağlamaktadır. İlâveten çalışma sonuçları, Ethereum'un ekosistem üzerindeki etkisini anlamaya yardımcı olmaktadır. Gelecekteki çalışmalar, daha geniş veri setleri ve farklı makine öğrenimi teknikleri kullanarak farklı tokenlar için model performanslarını daha da artırmayı hedeflemelidir. Ayrıca, tokenların piyasa koşullarındaki değişimlerin ve dış etkenlerin modeller üzerindeki etkilerini incelemek, daha doğru ve güvenilir tahminler elde edilmesine katkıda bulunacaktır.

KAYNAKÇA

- Abubaker, S. S., ve Farid, S. R. (2022). Stock market prediction using LSTM. *International Journal for Research in Applied Science Engineering Technology*, 10(4), 3178-3184.
- Akbulaev, N., Mammadov, I., ve Hemdullayeva, M. (2020). Correlation and regression analysis of the relation between ethereum price and both its volume and bitcoin price. *Journal of Structured Finance*, 26(2), 46-56.
- Albayrak, E. ve Saran, A. N. (2023). İstatistiksel ve derin öğrenme modellerini kullanarak hisse senedi fiyat tahmini. *Bilgisayar Bilimleri ve Mühendisliği Dergisi*, 16(2), 161-169.
- Altan, A., Karasu, S. ve Bekiros, S. (2019). Digital currency forecasting with chaotic meta-heuristic bio-inspired signal processing techniques. *Chaos, Solitons & Fractals*, 126, 325-336.
- Aygün, B. ve Kabakçı, E. G. (2021). Comparison of statistical and machine learning algorithms for forecasting daily bitcoin returns. *Avrupa Bilim ve Teknoloji Dergisi*, 21, 444-454.
- Babu, R., Usha, D., Kirubadevi, T. ve Kumar, P. S. (2023). Stock price prediction using LSTM. *Journal of Survey in Fisheries Sciences*. 10(3S), 4135-4140.
- Buterin, V. (2014). A next-generation smart contract and decentralized application platform. *White Paper*, 3(37), 2-1.
- Chen, J. (2023). Analysis of bitcoin price prediction using machine learning. *Journal of Risk Financial Management*, 16(51), 1-25.
- Cuffe, P. (2018). The role of the ERC-20 token standard in a financial revolution: The Case of Initial Coin Offerings. In IEC-IEEE-KATS *Academic Challenge*. IEC-IEEE-KATS.
- Demirci, E. ve Karaatlı, M. (2023). Kripto Para fiyatlarının LSTM ve GRU modelleri ile tahmini. *Mehmet Akif Ersoy Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*. 10(1), 134-157.
- Demir, A., Akilotu, B. N., Kadiroğlu, Z. ve Şengür, A. (2019). Bitcoin price prediction using machine learning methods. *1st International Informatics and Software Engineering Conference (UBMYK)*, Ankara, Turkey, 2019.
- Dhokane, R. M. ve Agarwal, S. (2024). LSTM deep learning based stock price prediction with bollinger band, RSI, MACD, and OHLC Features. *International Journal of Intelligent Systems and Applications in Engineering*. 12(3). 1169-1176.
- Gao, S. (2023). Research on stock price prediction based on CNN-LSTM combined model. *Advances in Computer, Signals and Systems*, 7(9), 73-79.
- He, K., ve Jiang, Q. (2022). Research on stock prediction algorithm based on CNN and LSTM. *Academic Journal of Computing & Information Science*, 5(12), 98-106.
- Hirai, Y. (2017). Defining the ethereum virtual machine for interactive theorem provers. in financial cryptography and data security: fc 2017 international workshops, WAHC, BITCOIN, VOTING, WTSC, And TA, Sliema, Malta, April 7, 2017, Revised Selected Papers 21 (pp. 520-535). Springer International Publishing.
- Hu, Z., Zhao, Y., ve Khushi, M. (2021). A survey of forex and stock price prediction using deep learning. *Applied System Innovation*, 4(1), 9, 1-34.
- Huang, Y. P., ve Yen, M. F. (2019). A new perspective of performance comparison among machine learning algorithms for financial distress prediction. *Applied Soft Computing*, 83, 105663.

- Kashyap, S., Singh, M. ve V., L. (2022). A deep learning approach for crypto price prediction. *International Research Journal of Engineering and Technology*. 9(6), 2976-2981.
- Kumar, D., ve Rath, S.K. (2020). Predicting the trends of price for ethereum using deep learning techniques. In: Dash, S., Lakshmi, C., Das, S., Panigrahi, B. (Eds) *Artificial Intelligence and Evolutionary Computations in Engineering Systems. Advances in Intelligent Systems and Computing*, 1056. Springer, Singapore.
- Kumar, A.S., Pv, G., ve Jackson, B. (2023). Machine learning-based time series analysis for cryptocurrency price prediction: a systematic review and research. In *2023 International Conference On Networking and Communications (ICNWC)* (Pp. 1-5). IEEE.
- Pankaj. (2022, July). A systematic review for crypto currency price prediction using machine learning. In *2022 Fifth International Conference On Computational Intelligence and Communication Technologies (CCICT)* (pp. 339-343). IEEE.
- Kumari, PDSS L. vd. (2023). Analyzing crypto currency price trends with LSTM-based models. *International Journal of Creative Research Thoughts*. 11(4), 1-4.
- Ladhari, A. ve Boubaker, H. (2024). Deep learning models for bitcoin prediction using hybrid approaches with gradient-specific optimization. *Forecasting*. 6, 279-295.
- Lara-Benítez, P., Carranza-García, M., Luna-Romera, J.M. ve Riquelme, J. C. (2020). Temporal convolutional networks applied to energy-related time series forecasting. *Applied Sciences*, 10 (7), 2322, 1-17.
- Li, P., Zhang, J., ve Krebs, P. (2022) Prediction of flow based on a CNN-LSTM combined deep learning approach. *Water*, 14, 993, 1-13.
- Livieris, I. E., Kiriakidou, N., Stavroyiannis, S., & Pintelas, P. (2021). An advanced CNN-LSTM model for cryptocurrency forecasting. *Electronics*, 10(287), 1-16.
- Metin, S. (2021). Kripto para fiyatlarının regresyon analizi yöntemleri ile tahmini: bitcoin, ethereum ve ripple. 2. *Uluslararası Sosyal Bilimler ve İnovasyon Kongresi*. 24-25 Mayıs 2021, Ankara.
- Millikan, E., Subramanian, P., ve Joseph, M. H. (2021). Bitcoin vision: using machine learning and data mining to predict the short-term and long-term price of bitcoin. *Current Trends in Management and Information Technology*. 751-760.
- Minotti, G. (2022). Cryptocurrencies price prediction using LSTM neural network model, *Universita Ca'Forscari Venezia, Master's Degree in Economics and Finance*.
- Mudassir, M., Bennbaia, S., Unal, D., ve Hammoudeh, M. (2020). Time-series forecasting of bitcoin prices using high- dimensional features: a machine learning approach. *Neural Computing and Applications*. 1-15.
- Nair, M., Marie, M. I. ve Abd-Elmegid, L. A. (2023). Prediction of cryptocurrency price using time series data and deep learning algorithms. *International Journal of Advanced Computer Science and Applications*. 14(8), 338-347.
- Odabaşı, M. B. ve Toklu, M. C. (2023). Yapay sinir ağları ve derin öğrenme algoritmalarının kripto para fiyat tahmininde karşılaştırmalı analizi. *Zeki Sistemler Teori ve Uygulamaları Dergisi*. 6(2), 96-107.
- Oladele, S. I. I. (2023). Deep neural network: predicting future prices of cryptocurrency using LSTM and GRU. Preprints, 1-10.
- Oliva, G. A. (2022). Mining the ethereum blockchain platform: best practices and pitfalls (msr 2022 tutorial). In *Proceedings of The 19th International Conference On Mining Software Repositories*, 201-202.
- Patel, M. M., Tanwar, S., Gupta, R. ve Kumar, N. (2020), A deep learning-based cryptocurrency price prediction scheme for financial institutions. *Journal of Information Security and Applications*, 55, 1-12.
- Polat, O. G. (2024). LSTM model ile bitcoin fiyatı tahminlemesi. *İstanbul Ticaret Üniversitesi Finans Enstitüsü. Yüksek Lisans Tezi*.
- Rajagukguk, R. A., Ramadhan, R. A., & Lee, H. J. (2020). A review on deep learning models for forecasting time series data of solar irradiance and photovoltaic power. *Energies*, 13(24), 6623.
- Sağır, A. B. (2024). Hisse senedi alım satımında parçacık sürü optimizasyonu tabanlı CNN-LSTM ağlarının kullanılması. *İstanbul Aydın Üniversitesi Lisansüstü Eğitim Enstitüsü. Yüksek Lisans Tezi*.
- Sari, R., Kusurini, K., Hidayat, T. ve Orphanoudakis, T. (2023). Improved LSTM method for predicting cryptocurrency price using short-term data. *Indonesian Journal of Computing and Cybernetics Systems*. 17(1), 33-44.
- Seabe, P.L., Moutsinga, C.R.B. ve Pindza, E. (2023). Forecasting cryptocurrency prices using LSTM, GRU, and bi-directional LSTM: a deep learning approach. *Fractal and Fractional*, 7(203), 1-18.
- Sezer, O. B., Gudelek, M. U., ve Ozbayoglu, A. M. (2020). Financial time series forecasting with deep learning: a systematic literature review: 2005-2019. *Applied Soft Computing*, 90, 106181.

- Şenol, D. & Denizhan, B. (2023). Kripto para değerinin yapay sinir ağları ve regresyon analizi ile tahmini. *Endüstri Mühendisliği*, 34(1), 42-69.
- Tanışman, S., Karcıoğlu, A. A., Uğur, A. ve Bulut, H. (2021). Bitcoin fiyatının LSTM ağı ve ARIMA zaman serisi modeli kullanarak tahmini ve karşılaştırılması. *Avrupa Bilim ve Teknoloji Dergisi*, (32), 514-520.
- Taş, A. İ., Gülüm, P. ve Tulum, G. (2021). Finansal piyasalarda hisse fiyatlarının derin öğrenme ve yapay sinir ağı yöntemleri ile tahmin edilmesi; S&P 500 Endeksi Örneği. *Düzce Üniversitesi Bilim ve Teknoloji Dergisi*, 9, 446-460.
- Tran, T. K., Le, T. T. T., Bui, T. T., Dang, V. Q., ve Senkerik, R. (2022). Constructing a cryptocurrency-price prediction model using deep learning. in *2022 International Conference on Engineering and Emerging Technologies (ICEET)* (pp. 1-6). IEEE.
- Yurtsever, M. (2021). Gold price forecasting using LSTM, Bi-LSTM and GRU. *Avrupa Bilim ve Teknoloji Dergisi*, 31 (1), 341-347.
- Wardak, A. B. ve Rasheed, J. (2022). Bitcoin cryptocurrency price prediction using long short-term memory recurrent neural network. *European Journal of Science and Technology*, (38), 47-53.
- Wen, N. S. ve Ling, L. S. (2023). Evaluation of cryptocurrency price prediction using LSTM and CNN models. *International Journal on Informatics Visualization*, 7(3-2), 2016-2024.
- Xu, D. (2023). Price prediction of cryptocurrency based on LSTM Model: evidence from ethereum. *Highlights in Science Engineering and Technology*, 39, 744-748.
- Zhang, R. (2022). LSTM-based stock prediction modeling and analysis. *Proceedings of the 7th International Conference On Financial Innovation and Economic Development*, 211, 2537-2542.
- Zhang, C. (2023). The analysis of the risks and improvements of ERC20 tokens. *Highlights in Science, Engineering and Technology*, 39, 1093-1097.
- Zhou, H. (2022). Research of text classification based on TF-IDF and CNN-LSTM. *Journal of Physics Conference Series*, 2171, 1, 1-9.

Etik Beyanı : Bu çalışmanın tüm hazırlanma süreçlerinde etik kurallara uyulduğunu yazarlar beyan eder. Aksi bir durumun tespiti halinde ÖHÜİBF Dergisinin hiçbir sorumluluğu olmayıp, tüm sorumluluk çalışmanın yazar(lar)ına aittir.

Yazar Katkıları : Yazarlar eşit oranda katkı sunmuşlardır.

Çıkar Beyanı : Yazarlar arasında çıkar çatışması yoktur.

Teşekkür (Varsa) : Bu çalışma Bursa Uludağ Üniversitesi Bilimsel Araştırma Projeleri Birimi tarafından desteklenen SYL-2024-1740 kodlu proje sonuçlarından üretilmiştir. Desteklerinden ötürü Bursa Uludağ Üniversitesi Bilimsel Araştırma Projeleri Koordinasyon Birimi'ne teşekkür ederiz.

Ethics Statement : The authors declare that ethical rules are followed in all preparation processes of this study. In case of detection of a contrary situation, ÖHÜİBF Journal does not have any responsibility and all responsibility belongs to the author (s) of the study.

Author Contributions : The authors contributed equally.

Conflict of Interest : There is no conflict of interest between the authors.

Acknowledgement : This study was produced from the results of the project coded SYL-2024-1740 supported by Bursa Uludağ University Scientific Research Projects Unit. We would like to thank Bursa Uludağ University Scientific Research Projects Coordination Unit for their support.
