



Bitcoin Fiyat Değişimlerinin Makine Öğrenmesi Yöntemi ile Tahmin Edilmesi Prediction of the Bitcoin Price Changes Through Machine Learning

Serkan NAS ^a Ayşe ERGİN ÜNAL ^b

^aTarsus Üniversitesi, İktisadi ve İdari Bilimler Fakültesi, Tarsus, Türkiye, serkannas@tarsus.edu.tr

^bTarsus Üniversitesi, Uygulamalı Bilimler Fakültesi, Tarsus, Türkiye, ayseerginunal@tarsus.edu.tr

MAKALE BİLGİSİ

ÖZET

Anahtar Kelimeler:

Kripto Varlık
Blok zinciri Teknolojisi
Makine Öğrenme Algoritmaları
Tahminleme

Gönderilme Tarihi 2 Mayıs 2023
Revizyon Tarihi 14 Aralık 2023
Kabul Tarihi 20 Aralık 2023

Makale Kategorisi:

Araştırma Makalesi

Amaç – Bitcoin başta olmak üzere kripto varlık fiyatlarında meydana gelen hızlı değişimler gerek finansal yatırımcı gerekse medya tarafından ilgi görmektedir. Buna bağlı olarak kar elde etmek amacı başta olmak üzere pek çok farklı motivasyonla birçok araştırmacı ve finansal aktör, Bitcoin fiyatını etkileyen çeşitli faktörleri belirlemeye çalışmaktadır. Bitcoin fiyat hareketlerini etkilediği düşünülen Fed faiz oranı, altın ve Bitcoin'in farklı fiyat göstergeleri gibi öznitelikler üzerine detaylandırılan bir inceleme yürütülmektedir. Bu bağlamda fiyatları tahmin etmek için kullanılan çeşitli makine öğrenme algoritmaları üzerinde sistematik bir analiz yapılmaktadır.

Yöntem – Farklı dört makine öğrenme modeli kullanılmış olup farklı tahmin hata oranları elde edilmiş ve her birinin çalışmada kullanılabileceği görülmüştür.

Bulgular – Bitcoin veri seti için önerilen en iyi tahmin performansının sırasıyla Tesadüfi Ağaç (RF) %96,38, Karar Ağacı (DT) %96,28, Doğrusal Regresyon 95,06 ve Stokastik Gradient Descent (SGD) Doğrusal Regresyon %93,91 şeklinde olduğunu göstermektedir. Bitcoin fiyat değişimlerinin Fed faiz oranı ve altından ziyade kendi fiyat değişimlerinden daha yüksek oranda etkilendiği diğer sonuçlar arasında yer almaktadır.

Tartışma – Tahmin modellemesinde en iyi sonuçları veren iki algoritmaya bakıldığında, gün içi en yüksek fiyatın son derece etkili olduğu söylenebilmektedir. En düşük fiyat ise ikinci derece en etkili özneliktir. Söz konusu sonuç, Bitcoin'in en çok kendi fiyat dalgalanmalarından etkilendiğini göstermektedir.

ARTICLE INFO

ABSTRACT

Keywords:

Crypto Asset
Blockchain Technology
Machine Learning Algorithms
Forecasting

Received 2 May 2023
Revised 14 December 2023
Accepted 20 December 2023

Article Classification:

Research Article

Purpose – The rapid changes in the prices of cryptoassets, especially Bitcoin, attract attention by both financial investors and the media. Accordingly, many researchers and financial actors, with several different motivations, especially with the aim of making a profit, are trying to determine various factors that affect the price of Bitcoin. A detailed examination is carried out on attributes such as the Fed Interest rate, gold and Bitcoin's different price indicators, which are thought to affect Bitcoin price movements. In this context, a systematic analysis is conducted on various machine learning algorithms used to predict prices.

Design/Methodology/Approach – Four models were used, different estimation error rates were obtained, and it was seen that each of them could be used in the study.

Findings – The analysis results show that the best prediction performance recommended for the Bitcoin dataset is as follows, respectively: random tree (RF) 96.38%, decision tree (DT) 96.28%, linear regression 95.06 and Stochastic Gradient Descent (SGD) linear regression 93.91%. It has been concluded that Bitcoin price changes are more highly affected by their own price changes, rather than the Fed interest rate and gold.

Discussion – According to the two algorithms that give the best results in machine learning algorithms. It can be said that the intraday high price is extremely effective. The lowest price is the second most affective attribute. The result in question shows that Bitcoin is most affected by its own price fluctuations.

Önerilen Atıf/Suggested Citation

Nas, S., Ergin Ünal, A. (2023). Bitcoin Fiyat Değişimlerinin Makine Öğrenmesi Yöntemi ile Tahmin Edilmesi, *İşletme Araştırmaları Dergisi*, 15 (4), 2597-2608.

1. Giriş

Finansal sistem unsurlarından biri olan yatırımcılar, işlem yaptıkları finansal piyasalarda oluşan risk ve getiriye etkileyen faktörlerin değişmesiyle, karar alma tekniklerini gözden geçirmektedirler. Bu bağlamda piyasada fon arz eden için iki farklı amaç ortaya çıkmakta olup ilki getirinin mümkün olduğu kadar artırılması ve riskin minimize edilmesidir. Diğer bir amaç ise yatırım yapılan finansal araçtaki değer kaybının önlenmesidir. Ekonomik aktör özellikle finansal dolarizasyonu ve kamu borcu yüksek olup enflasyonist bir ülkede işlem yaptığında söz konusu risk unsurları daha da derinleşmektedir. Bu bağlamda yatırım yapılacak finansal enstrümanın seçimi için portföy çeşitlemesi yoluna gidilmekte ve bu şekilde risk dağıtılabilir. Keza yatırımcılar sermaye piyasası kurumlarından borsa da işlem yapmakta, güvenli liman olarak nitelendirilen altını değerlendirmekte, yabancı paraya yatırım yapmakta ya da alternatif finansal araçlara yönelmektedirler. Söz konusu araçlardan biri de kripto varlık olup dijital nitelik taşıyan bu alternatif, pek çok ekonomik kesimin yatırım amaçlı kullandığı bir enstrümandır. Kripto varlıklar ilk olarak dijital varlık olan Bitcoin'in ortaya çıkmasından bu yana birçok bilim adamının ve politika yapıcının dikkatini çekmektedir. Fiat para birimleriyle karşılaştırıldığında söz konusu dijital varlıkların kriptografik teknolojilere dayandığı bilinmekte olup herhangi bir hükümet veya merkez bankası tarafından kontrol edilememektedirler. Kripto varlıklara ilişkin diğer özellikler aşağıdaki gibi sıralanabilmektedir (Andolfatto, 2014:9);

- Vergide kullanılması, beyan, kayıt gibi hukuki düzenlemelere tabi değildir.
- Vergiye tabi olmadığından dolayı vergi kesintisine uğramazlar.
- Kamu otoriteleri tarafından hareketler takip edilemez.
- Gizlilik esastır ve kullanıcı varlıkları ve transferleri isteği olmadığı takdirde bilinemez.
- Firmalar için gelir talep edilmemektedir.
- Transfer maliyetleri diğer sistemlere kıyasla çok daha düşüktür.

Bu özellikler göz önüne alındığında kripto varlıklar, özellikle belirsizlik dönemlerinde mükemmel çeşitlendiriciler olarak düşünülebilmektedir. Daha açık bir ifade ile geniş işlem hacmi ve riskten korunma araçları sunan bir vadeli işlem piyasası durumunda olan kripto varlık piyasaları, yatırımcılar için cazip borsalar haline gelmektedir. Yeni bir tür ticari varlık olarak kripto, geleneksel finansal varlıklar tarafından gösterilenlerden farklı fiyat dalgalanmaları göstermekte (Corbet vd., 2019) ve etkileyenleri farklılaşmaktadır. Örneğin, halka açık şirketler, kötü yönetim kararları, finansal kısıtlamalar, müşteri kaybı ve tüketici tercihlerindeki değişimler gibi kripto varlık fiyatlarını etkilemeyen birçok nedenden dolayı hisse senedi fiyatlarında düşüş görülmektedir (Caferra and Tomas, 2011:1). Dolayısıyla yatırımcı sayısı önemli ölçüde artan farklı özellikteki bu varlık fiyatlarındaki değişikliğin alternatif finansal araçlara etkisi doğrudan ya da dolaylı olarak gerek akademisyenler gerekse ekonomik aktörler tarafından incelenmektedir.

Blok zinciri teknolojisiyle geliştirilmiş olup işlem hacmi en yüksek kripto varlık Bitcoin (BTC)'dir. Kripto varlıkların piyasa değeri, 23 Aralık 2022 tarihi itibarıyla 808.945.170.500 ABD dolarına ulaşmış olup söz konusu hacmi ile dünyanın en büyük şirketlerinin piyasa değerlemesiyle karşılaştırılabilir durumdadır. Aynı tarihte toplamda 9078 adet türü olan kripto varlık piyasasında, toplam piyasa değerinin büyük çoğunluğu Bitcoin ve Ethereum'dan oluşmaktadır (investing.com).

Kripto varlık türlerinden biri olan Bitcoin'in çeşitli yatırım araçları ile risk ve getiri noktasında kıyaslanması son dönemde tartışılan konulardan biridir. Bu noktada farklı görüşler mevcut olup Huynh vd. (2020)'e göre Bitcoin, göreceli bağımsızlığı nedeniyle daha iyi bir hedge fon olarak düşünülebilmektedir. Wong vd. (2018)'e göre ise Bitcoin ve diğer bir kripto varlık türü olan Litecoin diğer varlık sınıflarıyla negatif veya sıfır korelasyonlar nedeniyle bir hedge olarak faydalı olabileceken yüksek portfolyo riski taşımaktadırlar. Diğer yandan özellikle geleneksel araçlardan olup yatırımcılar ve ekonomik aktörler tarafından güvenli liman olarak adlandırılan altın, tarihsel süreçte gerek savaş ganimeti olarak kullanılması gerekse paranın hammadde olarak kullanılması noktalarında vazgeçilmez bir araç olmuştur. Bu aracın fiyat hareketlerindeki oynaklığının sebebi alternatif finansal araçlara bağlanırken kripto varlık bunlardan biridir. Keza González vd. (2021) çalışmalarında özellikle COVID-19 krizi sırasında oluşan ekonomik ortamda altın fiyat getirileri ile kripto varlık getirileri arasındaki bağlantıya işaret etmektedirler. Bir diğer geleneksel yatırım platformu olup finansal işlemlerin yapıldığı kurumlardan biri olan borsa da işlem gören varlıklar ile kripto varlık ilişkisi, incelenen bir

diğer alternatiftir. Bu konuda yapılan çalışmalar oldukça yeni olmakla beraber kimi çalışmada kripto varlığın finansal yatırımcı için geleneksel araçlara kıyasla doğru bir alternatif olmadığı vurgulanırken kimi çalışmada ise tam tersi iddia edilmektedir. Söz gelimi Thampanya vd. (2020) çalışmalarında ne altın ne de kripto varlığın borsadan korunmak için iyi bir araç görevi görmediğini savunurken Kim vd. (2020) çalışmalarında S&P 500 ve altın fiyatının, günlük getiri ve volatilité açısından Bitcoin için istatistiksel olarak anlamlı olduğunu tespit etmişlerdir.

Bitcoin fiyatlarında zaman içinde meydana gelen hareketlenmenin birçok farklı nedeni olduğu gibi söz konusu nedenler kimi zaman ekonomik ve finansal aktörlerden kaynaklanırken kimi zaman sosyo politik olaylardan kaynaklanmaktadır. Bitcoin sonrası yeni kripto varlık türlerinin piyasada işlem görmesi, ülke ekonomilerinde yaşanan enflasyonist eğilim ve pek çok finansal göstergedeki değişimler, fiyat manipülasyonları ve son dönem de yaşanan Covid-19 salgınının oluşturduğu yapısal değişimler bunlardan birkaçıdır. Bu bağlamda Chen vd. (2003) çalışmalarında kripto varlık fiyat hareketlerinin dinamik yapıya sahip iken doğrusal olmayan yapılara vurgu yapmaktadırlar. Bu durum ise finansal aktörlerden yatırımcılar için fiyat değerlerinin hangi yönde ilerleyeceği beklentisini çok daha önemli ve riskli hale getirmektedir. Keza fiyatlara yönelik yapılabilecek doğru tahminleme kazancın artmasını sağlayacaktır. Yine Mudassir vd. (2020)'e göre belli bir merkezi bulunmayan kripto varlıklar ile ilgili temel sorunlardan biri, temel fiyat modelini inceleme ihtiyacını gösteren fiyat oynaklığıdır. Dahası, Bitcoin fiyatları, verilerin istatistiksel dağılımının zaman içinde değiştiği durağan olmayan davranışlar sergiler. Bu yüzden Bitcoin fiyatlarını olumlu/olumsuz etkileyecek söz konusu etkenler dikkate alındığında fiyat değişimlerinin ne yönde olacağını tahmin etme noktasında doğru öznitelik ya da göstergenin seçilmesi de önem arz etmektedir. Daha açık bir ifade ile Bitcoin fiyat tahminlemesi zaman serisi, makine öğrenme gibi pek çok farklı yöntemle sınanmakta olup en iyi tahmin eden yöntemi ve özneteliği tespit etmek özellikle yatırımcı ve finansal işlem yapan aktörü doğru yönlendirme noktasında önem arz etmektedir. Diğer yandan Bitcoin fiyatının spekülasyona açık olması ve doğrudan bilinen bir fiyatının olmaması geleneksel tahminleme metotlarını kullanmayı daha da güç hale getirmektedir (Sakız ve Gencer, 2017:443). Söz konusu görüşü destekler nitelikte McNally vd. (2018) ABD doları cinsinden Bitcoin fiyatının yönünün hangi doğrulukla tahmin edilebileceğini tespit etmeyi amaçladıkları çalışmalarında, makine öğrenme algoritmalarının ARIMA modeline göre çok daha başarılı tahminleme yaptıklarını vurgulamaktadırlar. Bunun yanında mevcut çalışmalar daha doğru Bitcoin fiyat tahmini için makine öğreniminden yararlanmış olsa da, çok azı farklı veri yapılarına ve farklı modelleme tekniklerinin uygulanmasının fizibilitesine odaklanmıştır. Yine Almeida (2015), Madan vd. (2015), Şahin (2018), Atsalakis vd. (2019), Chauhan vd. (2019), Chen, Z. (2020) vd. çalışmaların pek çoğunda en uygun makine öğrenme algoritmasını bulmak üzere, farklı makine öğrenme algoritmaları ile farklı özniteliklerin kullanılarak kıyaslama yapıldığı görülmektedir.

Bitcoin değerini etkileyen çeşitli parametreleri göz önünde bulundurarak Bitcoin fiyatını doğru bir şekilde tahmin etmeyi amaçlayan bu çalışmanın ilk aşamasında Bitcoin fiyatını etkileyen özellikler hakkında teorik bilgilere yer verilmekte iken Bitcoin piyasasındaki günlük eğilimlerin analiz edilmesi hedeflenmektedir. Daha açık bir ifade ile kripto varlıklardan biri olan Bitcoin fiyatlarının, Fed faiz oranı, altın fiyat değişimleri gibi çeşitli öznitelikler kullanılarak makine öğrenme yolu ile tahmin edilmeye çalışıldığı bu çalışma, üç bölümden oluşmaktadır. İlk bölüm kripto varlık fiyat hareketleri ve teorik altyapısını içerirken ikinci bölüm de yazın taraması yapılmaktadır. Son bölüm de ise ekonometrik yöntem, veri seti ve bulgulara ayrılmış olup sonuç bölümünde analiz sonuçları detaylı olarak tartışılmaktadır. Çalışmanın diğer çalışmalardan farkının farklı öznitelik kullanılması ve tahminlemenin dört farklı makine öğrenme teknikleriyle sınanması olduğu düşünülmektedir.

2. Literatür

Kripto varlık fiyatlarındaki hareketliliğin, nedeninin ve yönünün doğru tahmin edilmesi, söz konusu varlıklara yatırım yapan finansal aktörlerin gerek riski azaltma gerekse fazla getiri sağlama amacını gerçekleştireceğinden önem arz eden bir konu haline gelmiştir. Bu bağlamda pek çok çalışma yapılmış olup konunun tarihçesi eskiye dayanmamaktadır. İlgili bölümde, kripto varlıklarla ilgili yapılan ulusal ve yabancı çalışmalar kullanılan yöntem ve farklı öznitelikler ile detaylandırılarak incelenecektir.

Kripto varlığın kendi fiyat değişimlerini öznitelik olarak kullanıp fiyat tahminlemesi yapılan çalışmalardan Sakız ve Kutlugün (2018) çalışmalarında, 2018 Mayıs ayı fiyatlarını, 01:2015 - 04:2018 dönemlerinde Bitcoin

fiyat değişim ortalamalarını yapay sinir ağları yöntemlerini kullanarak analiz etmişlerdir. Çalışma bulguları Bitcoin fiyatlarında tahminlenmiş değer ve gerçekleşen değer arasında bulunan farklılığa işaret etmektedir. Yine aynı dönemde Karakoyun ve Çıbıkdiken (2018), geçmiş Bitcoin fiyatlarını kullanarak sonraki otuz gün için fiyat tahminlemesi yaptıkları çalışmalarında, ARIMA ve Uzun Kısa Süreli Bellek (Long-Short Term Memory-LSTM) algoritmalarını kullanmış olup fiyat tahminlemelerinde uygun algoritmanın Derin Öğrenme olduğu kanısına varmışlardır. Bitcoin fiyat tahminlemesinin Covid-19 öncesi ve sonrası dönem olarak ayrı ayrı incelendiği Kaya vd. (2019)'a ait çalışma sonuçlarına göre Covid-19 öncesi en iyi tahmin modeli Destek Vektör Makineleri iken Covid-19 sonrası ARIMA olduğu tespit edilmiştir. Yine ARIMA Modelinin Bitcoin fiyat tahminlemesi yapılması amaçlı kullanıldığı çalışmalardan Azari (2019)'ye göre kısa dönemde söz konusu yöntem başarılı iken uzun dönemde doğru tahminleme yapılamadığı bulgulanmıştır. Kripto varlık fiyatlarını farklı makine öğrenme algoritmaları kullanarak tahminlemeyi amaçlayan diğer çalışmalara ilişkin bilgiler Tablo 1'de gösterilmektedir.

Tablo 1. Literatür Özeti

Yazarlar	Kullanılan Yöntem	Analiz Sonucu
Shan ve Zhang (2014)	Bayes Linear Regression	Tahminsel başarı oranı %89 olarak tespit edilmiştir.
Madan vd. (2015)	SVM Random Forest	SVM yöntemi ile tahminsel başarı oranı %50 altında iken Random Forest başarı oranı yaklaşık %92 olarak tespit edilmiştir.
Greaves (2015)	Linear Regresyon Logistic SVM Neural Network	Linear Regresyon yöntemi ile tahminsel başarı oranı %53,4, Logistic Regresyon yöntemi ile tahminsel başarı oranı %54,3, SVM yöntemi ile tahminsel başarı oranı ile %53,7, Neural Network yöntemi ile tahminsel başarı oranı %55,1'dir.
Indera vd. (2018)	MLP-NARX Modeli	Tahminsel başarı oranı %99 olarak tespit edilmiştir.
Mcnally vd. (2018)	Bayes Linear Regression (RNN) ve bir Uzun Kısa Süreli Bellek (LSTM)	LSTM, %52'lik en yüksek sınıflandırma doğruluğuna ve %8'lik bir RMSE'ye ulaşır. Yine analiz bulguları Doğrusal Olmayan Derin Öğrenme yöntemlerinin, ARIMA tahmininden daha iyi performans sergilediğini göstermektedir.
Mallqui, D. (2019) vd.	Yapay Sinir Ağları (YSA), Destek Vektör Makineleri (SVM) Artificial Neural Network (ANN)	SVM algoritması, Bitcoin döviz kurlarını tahmin etmek için en iyi sonuçları göstermektedir.

Mangla, N. Vd. (2019)	Logistic Regression, SVM, Auto Regressive Integrated Moving Average (ARIMA) Recurrent Neural Networks (RNN)	Tahminsel başarı oranları kullanılan yöntemlere göre sırasıyla %47, %48, % 53, ve % 50' dir.
Rane, P. ve Dhage S.N. (2019)	Support Vector Model Binomial Generalised Linear Model ARIMA Model Long Short Term Memory Network Model Multilayer Perceptron Neural Network Model Regression Model	Tahminsel başarı oranları kullanılan yöntemlere göre sırasıyla %54, %51, % 53,74, % 52,78 , %55 ve %56' dir.
Chen, Z. (2020) vd.	Logistic regression (LR), linear discriminant analysis (LDA), Random Forest (RF), XGBoost (XGB), quadratic discriminant analysis (QDA), support vector machine (SVM), Uzun Kısa Süreli Bellek (LSTM)	Lojistik Regresyon yöntemi ile tahminsel başarı oranı %66 iken (5 dakikalık fiyat tahmini için) Rastgele Orman, XGBoost, Destek Vektör Makinesi tahmin başarı oranı oranı % 67,2 olarak tespit edilmiştir.
Akay vd. (2021)	Yapay Sinir Ağları Uzun Kısa Süreli Bellek	Yapay Sinir Ağlarının en başarılı tahminleme yöntemi olduğu tespit edilmiştir.
Şenol ve Denizhan (2023)	Yapay Sinir Ağları Regresyon Analizi Yöntemleri	Yapay Sinir Ağları metodunun Regresyon Analizi ile yapılan tahmin çalışmasından daha başarılı sonuçlar verdiği tespit edilmiştir.
Odabaşı ve Toklu (2023)	Yapay Sinir Ağları, Derin Öğrenme Algoritmaları	Yapay Sinir Ağlarının Derin Öğrenme algoritmalarına göre çok daha iyi performans verdiği tespit edilmiştir.
Demirci ve Karaatli (2023)	Uzun Kısa Süreli Bellek (LSTM) Geçitli Yinelenen Birim (GRU)	Analiz bulguları Bitcoin ve Ripple için GRU algoritmasının, Ethereum için ise LSTM algoritmasının daha başarılı sonuçlar verdiğini göstermektedir.

3. Yöntem


3.1. Araştırma modelleri

Makine öğrenmesi, çeşitli alanlarda yaygın olarak kullanılmakta ve bilgisayar yaklaşımları ile kolayca çözülemeyen zor sorunların çözümünde faydalanılmaktadır (Abdulazeez and Maulaud, 2020:140). Makine öğrenmesi, tahminleme konusunu geliştirmek için bilgisayar bilimi ile istatistiksel analizi birleştirir. Yüksek değerli tahminlemeler insan-bilgisayar etkileşimlerinden elde edilebilir. Belirsizlik durumunu veri ile tahmin edilmesini sağlar. Makine öğrenme algoritmaları denetimli ve denetimsiz olarak kategorize edilebilir. Denetimli algoritmalar, etiketli veriden öğrenirken, denetimsiz algoritmalar ise etiketli veri kullanmaz, sadece basit bir şekilde verilerden çıkarım yapmaktadırlar (Kavitha vd., 2016:1). Denetimli öğrenme yöntemi, modeli

öğrenmek için sonuçları bilinen veri kümesini işler. Bu süreç modeli öğrenene kadar yani kabul edilebilir bir performans gösterene kadar devam eder. Bir kez model hazır olduğunda yeni bilinmeyen değerleri bulmak için kullanılır (Patil and Kulkarni, 2019:1365). Regresyon modelleri bağımlı değişkenlerden bağımsız değişkeni tahmin eder. Bu analizlerde karmaşık problemler ele alınır (Kavitha vd., 2016:2).

Bu çalışmada 4 farklı algoritma kullanılmış olup bunlar sırasıyla Doğrusal Regresyon, Stokastik Gradient Descent, Rastgele Orman algoritması ve Karar Ağaçlarıdır. Kullanılan algoritmalarından ilki Doğrusal Regresyondur. Değişkenler arasındaki ilişkiyi tanımlayabilmek için kullanılan en yaygın modeldir. Tek değişkenli veya çok değişkenli veri türü de olsa kavram doğrusal bir ilişki bulmayı amaçlar. Basit Regresyon, Doğrusal Regresyon veya Çoklu Doğrusal Regresyon kullanılabilir (Kavitha vd., 2016:2). Doğrusal Regresyon Denklem 1 ve Grafik 1’de gösterilmiştir.

$$y = x\beta + \varepsilon \quad (1)$$

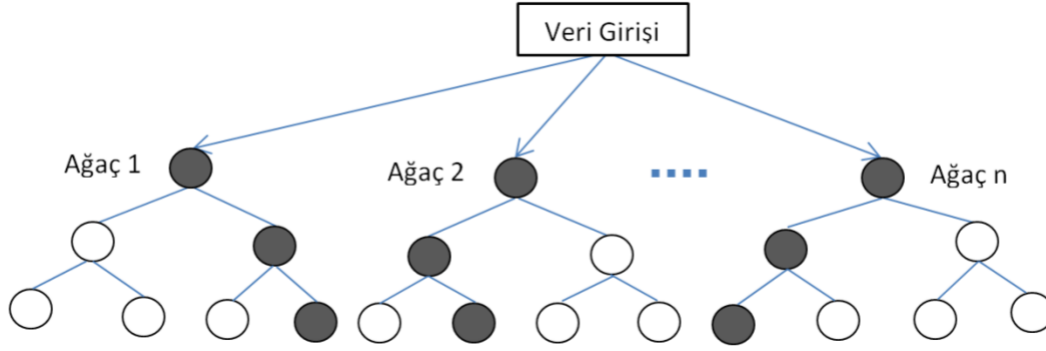


Grafik 1. Doğrusal Regresyon

Dikkate alınması gereken çok fazla öznelik bulunmadığı durumlarda doğrusal algoritma yöntemi başarı oranı yüksek tahminlemede bulunabilmektedir. Doğrusal Regresyon, öznelikler ile hedef değişkenin arasında doğrusal bir ilişki olduğunu tespit eder. Bu sadelik, genellikle Doğrusal Regresyonu küçük örnekler ile yapılan analizler için en uygun seçenek haline getirir ve ayrıca modellerin yorumlanmasını ve anlaşılmasını nispeten kolaylaştırır (Hope, 2020:67).

Makine öğrenme algoritmalarının amacı öğrenme süreci içinde amaç fonksiyonunu optimize etmektir. Stokastik Gradient Descent, denetimli makine öğrenimi tekniklerinden biridir ve öğrenme sürecinde maliyet işlevini optimize eder. Amaç, maliyet fonksiyonunu en aza indirmektir. Eğitimli küme ile gerçek sonuçlar arasındaki kareleri alınmış hataların toplamını kullanarak ağırlıkları alınmıştır (Lakshmi, 2016:520). Başka bir deyişle, Stokastik Dereceli Alçalma Yöntemi (SDA), θ_k maliyet fonksiyonunu minimize/maksimize etmek için her bir θ_k parametresini $\partial J(\theta)/\partial \theta_k$ yönünde güncellemeye dayanan popüler bir optimizasyon tekniğidir. Bu teknik özellikle konvolüsyonel öğrenme ve otomatik kodlayıcılar gibi güncel yapay öğrenme yöntemlerinde sıklıkla kullanılmaktadır. Gradient Descent Yöntemi, makine öğrenmesinde çok önemli bir yere sahiptir. Yapay sinir ağlarında, en iyi öğrenme işlemi gerçekleşene kadar, her adımda ağırlıkların değerlerinin güncellenmesi gerekir ve bu güncelleme işlemi belirli yöntemler dahilinde yapılmaktadır (Yazan nd Talu, 2017:1). Bu çalışmada Stokastik Gradient Descent, Linear Regresyon Yöntemi kullanılmıştır.

Rastgele Orman algoritması (Random Forest, RF) denetimli makine öğrenme algoritmalarından biri olup sınıflandırmada ve tahminlemede kullanılabilen, tahminlemede de başarılı olarak bilinen bir algoritmadır. RF parametrik ve doğrusal olmayan model olup ilk defa 1995 yılında Ho tarafından önerilmiştir. RF, ağaç tahmincilerinin bir kombinasyonudur; öyle ki ormandaki her bir ağaç için aynı dağılımla ve bağımsız olarak seçilen vektörün değerlerine bağlıdır (Breiman, 2001:5).



Şekil 1. Karar Ağacı

Başarı oranını artırmak amacıyla tek bir karar ağacı yerine birçok karar ağacının çıktısına göre çalışmaktadır. Rastgele Orman algoritması sadeliği ve etkinliği ile bilinen makine öğreniminin temsili algoritmalarından biri olarak düşünülebilir. Ayrıca son sınıflandırıcısının sınıflandırması olarak en iyi sınıflandırma ağacını seçen karar ağacı tabanlı bir sınıflandırıcı olarak tanımlanabilir (Abdulkareem vd., 2021:128). RF algoritması tahminleme yapabilmek için fazla sayıdaki veriden oluşan öznelikten grubunu yani girdi vektörünü değerlendirir. $RF(x)$ ile RF yöntemi tahmin ağaçlarını oluşturur ve nihai değerlerin ortalamasını alır. K kadar karar ağaçları $T(x)$ oluşturulduktan sonra tahmin yapılır. RF, regresyon tahmin edicisinin formülize edilmiş hali Denklem 2’de gösterilmiştir. (Rodriguez-Galiano vd., 2015:806).

$$f_{rf}^K(x) = \frac{1}{K} \sum_{k=1}^K T(x) \quad (2)$$

Karar ağaçları, sınıflandırma ve tahminleme mekanizmalarıdır. 20. yüzyılın sonlarındaki ilk statiksel algoritmalarındandır. Bu mekanizma yapay zeka, makine öğrenmesi, sınıflandırma, tahminleme, bilgi keşfi için oldukça disiplinlerarası, genel amaçlar için kullanılabilen, yoğun hesaplamalı bir yöntem olarak evrimleşmiştir. Karar ağaçlarının en temel özelliği, bir hedef veri alanının özyinelemeli bir altkümüsi ilişkili giriş alanlarının değerlerine göre veya bölümler oluşturmak için öngörücüler ve ilişkili soyundan gelen veri alt kümeleri (yapraklar veya düğümler olarak adlandırılır) aşamalı olarak benzer yaprak içi (veya düğüm içi) hedef değerler içerir ve ağacın herhangi bir seviyesinde giderek farklılaşan yaprak (düğümler) arası değerleridir (De ville, 2013:448). Karar ağacı, karar verme problemine modern bir çözümdür. Problem alanından verileri öğrenerek ve sistematik analitikle desteklenen bir tahminleme modeli oluşturmaktadır (Patil vd., 2019:1365). Karar ağaçları birçok farklı alanlarda kullanılabilen ve uygulanabilmektedir. Bu yaklaşım giriş bilgisinden doğru bilgiye ulaşabilmek için testler yapmakta ve bu testler sürekli filtreden geçirilmektedir. Birçok farklı karar ağacının farklı doğruluk ve maliyet etkinliği bulunmaktadır (Navada and Nizam, 2011:37). Karar ağaçları aynı zamanda hangi öznelikliğin etkili olduğu hakkında bilgi vermektedir.

Veriler normalleştirildikten sonra %20’si test için kullanılmak üzere 4 farklı makine öğrenme algoritmaları ile tahmin çalışması yapılmıştır. Tüm makine öğrenme algoritmaları seçilen başarı ölçüt koşuluna göre çalıştırılmıştır. Amaç bu hata kriterini en aza getirmektir. Tahminleme çalışmalarında Mutlak Ortalama Hata Yüzde Oranı (MOYH) sıklıkla kullanılmaktadır. Bu değer hesaplanırken makine öğrenme algoritmalarının oluşturduğu çıktı değer ile gerçek değer arasındaki fark hesaplanır. Bu farkın mutlak değeri alınıp gerçek değere bölünerek bağıl değer bulunur. Yüz ile çarpılarak hatanın yüzde değerine ulaşılır. Gerçek değerinin sıfır olmadığı durumlarda kullanılması gerekmektedir. Denklem 3’te formül ile gösterilmiştir.

$$MOYH = \frac{100}{n} \sum_j \frac{e_j}{A_j} \quad (3)$$

3.2. Evren ve Örnekleme

Makine öğrenme metoduyla yapılan çalışmalarda, hedef değişken tahmininde, tahmin başarısını etkileyen en önemli faktörlerden biri oluşturulan öznelik kümesidir. Bu çalışmada makine öğrenme metoduyla, Bitcoin fiyatının bir gün sonraki değeri tahmin edilmeye çalışılmıştır. Hisse senedi ve emtia gibi finansal varlıkları etkileyen birçok öznelik olmasına rağmen Bitcoin için bu öznelikler geçerli olamamaktadır. Bitcoin fiyatının genellikle arz ve talep dengesi ile yatırımcıların fiyatın yükseleceğine veya düşeceğine dair geliştirdikleri

inanca göre hareket ettiği düşünülmektedir. Genel olarak Bitcoin fiyatını etkileyen davranışların psikolojik olduğu, daha açık bir ifade ile söz konusu fiyatların sosyal medya başta olmak üzere pek çok farklı kanallar ile oluşan görüş doğrultusunda oluştuğu bilinmektedir. Bu bilgiler ışığında Bitcoin fiyat tahmininde oluşan fiyat değerlerini ve teknik analiz verilerini öznitelik olarak almanın daha doğru olacağı düşünülmüştür. Altın fiyatlarının öznitelik olarak alınmasının sebebi en güvenilir yatırım aracı olarak görülmesidir. Öznitelik kümesinde yer alan Fed faizleri alternatif yatırım araçlarına olan talebi temsil eden öznitelik olarak kullanılmıştır.

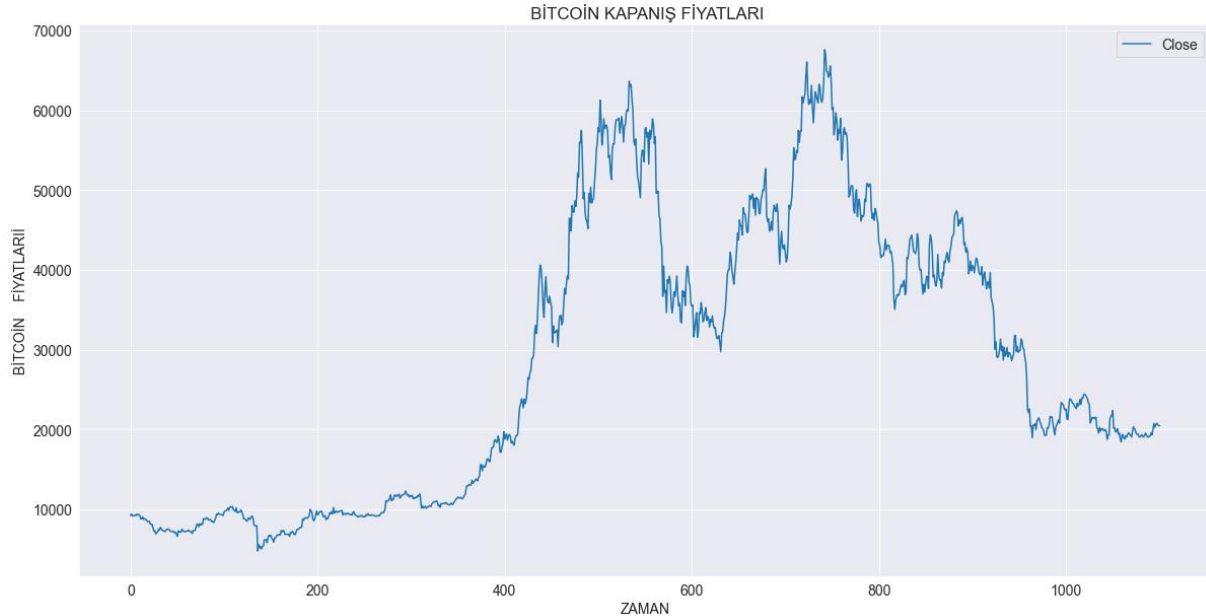
3.3. Veri Seti

Bu amaçla Bitcoine ait 1124 adet günlük fiyat hareketleri, fiyatların ağırlıklı ortalaması, stokastik değerleri, Fed faiz oranı ve altın fiyatları öznitelik olarak belirlenip öznitelik veri kümesi oluşturulmuştur. XAUUSD fiyatı, 5 ve 50 günlük hareketli ortalama için günlük kapanış fiyatları baz alınmıştır. Stokastik değerler ise kapanış fiyatlarına göre hesaplanmıştır. Öznitelik tanım ve kaynakları Tablo 2’de gösterilmektedir.

Tablo 2. Öznitelik Tanımları ve Kaynak

Öznitelik	Öznitelik Tanımları	Kaynak
Açılış fiyatı	Bitcoinin açılış açılış değeri	Matriks
En yüksek fiyat	Bitcoinin işlem gördüğü o gün ki en yüksek fiyatı	Matriks
En düşük fiyat	Bitcoinin işlem gördüğü o gün ki en düşük fiyatı	Matriks
%K(5,3)	Stokastik göstergesinin K değeri	Matriks
%D(3)	Stokastik göstergesinin D değeri	Matriks
MAV(5)	Bitcoin fiyatının son 5 günlük kapanış fiyatının ortalaması	Matriks
MAV(50)	Bitcoin fiyatının son 50 günlük kapanış fiyatının ortalaması	Matriks
XAUUSD	Spot altın ABD doları	Matriks
FED	Federal fonların gelecek faiz oranları	Investing.com

Tahmin edilmesi planlanan Bitcoin değerinin değişimleri Grafik 2’de gösterilmektedir.



Grafik 2. Hedef Veriye Ait Grafik

3.4. Veri Analizi


Öğrenme algoritmaları ve grafiksel gösterimler için Python programlama dilinden faydalanılmıştır.

3.5. Bulgular

Bu çalışmada, 4 farklı model kullanılmış olup farklı tahmin hata oranları elde edilmiştir. En iyi sonuçlar OMYH kriterine göre, rastgele orman (RF) %96,38, karar ağacı (DT) %96,28, doğrusal regresyon %95,06 ve Stokastik gradyan azalma (SGD) %93,91 olarak gerçekleşmiştir.

RF algoritmasında, en yüksek fiyat özneliğinin etkisi %64 ile en çok etkileyen öznelik olmuş, sırasıyla en çok etkileyen öznelik ise %25 ile en düşük fiyat, %5,5 ile 5 günlük ağırlıklı ortalama ve %4,4 ile açılış fiyatı olmuştur. Diğer özneliklerin toplam etkisi %2,5 olarak gerçekleşmiştir.

MOYH başarı ölçütüne göre en başarılı sonuca RF algoritması % 96,38 ile ulaşmıştır. Grafik 3'te Bitcoinin fiyat değerleri ile (mavi renk) tahmin değerleri (kırmızı renk) gösterilmektedir.



Grafik 3. Bitcoin Gerçek Değerler ile Tahmin Değerlerinin Grafığı

4. Sonuç ve Öneriler

Çalışmada Bitcoin varlığının açılış, kapanış, yüksek, düşük fiyat değerleri, kapanış fiyatlarından oluşan teknik analiz göstergeleri, altın ve Fed faiz fiyatlarından oluşan öznelikler kümesi oluşturularak makine öğrenmesi algoritmaları ile Bitcoin fiyatı tahmin edilmeye çalışılmıştır. Uygulama dili olarak Python programlama dili kullanılmıştır.

Makine öğrenme algoritmalarının başarısı, hem seçilen özneliklerin temsil gücüne hem de bu öznelik kümesinin yapısına bağlı olmaktadır. Özneliklerin temsil gücü çok olsa da, bu özneliklerin kombinasyonu makine öğrenme algoritmalarının başarısını değiştirebilmektedir. Bu çalışmada da, öznelikler kümesinde özellikle kapanış fiyatlarının etkisi görüldüğünde geçmiş günlerdeki fiyat hareketlerinden öznelik kümesi oluşturularak Bitcoin fiyat değeri tahmin edilmeye çalışılmış fakat sonuçlarda iyileşme gözlemlenmemiştir. Fed faizi ve altın fiyatlarının öznelik tahmininde çok etkili olmamasına rağmen, öznelik kombinasyonundan çıkarıldığında başarı tahmini azalmaktadır. Bu da makroekonomik göstergelerin de az da olsa Bitcoin fiyatını etkilediğini göstermektedir. Özneliklerin seçimi ve öznelikler kümesinin yapısı kullanılan makine öğrenme algoritmasının kendisinden daha önemli olabilmektedir.

En iyi sonuçlar OMYH kriterine göre, rastgele orman (RF) %96,38 ile gerçekleşmiştir. Bu sonuç Madan (2015) ve Chen (2020) çalışmaları ile paralellik göstermektedir. RF algoritmasında, en yüksek fiyat özneliğinin etkisi %64 ile en çok etkileyen öznelik olup ikinci en çok etkileyen öznelik ise %25 ile en düşük fiyat olmuştur. İki özneliğin toplam etkisi %89 olduğu için fiyat değerlerinin çok etkili olduğu düşünülmektedir. Tahmin modellemesinde en iyi sonuçları veren ikinci algoritmaya bakıldığında, gün içi en yüksek fiyatın yine son derece etkili olduğu söylenebilmektedir. En düşük fiyat ise ikinci derece etkili özneliktir. Bu da Bitcoin'in kendi fiyat dalgalanmalarından hareket ettiğini düşündürmektedir. Ciaian (2015)'e ait 5 yıllık (2009–2015) günlük veriler kullanılarak ve zaman serisi analitik mekanizmaları uygulanarak yapılan çalışmada, piyasa güçlerinin ve Bitcoin'in yatırımcılar ve kullanıcılar için çekiciliğinin, Bitcoin fiyatı üzerinde önemli bir etkiye

sahip olduğunu bulmuşlardır. Aynı çalışmada makro-finansal gelişmelerin uzun vadede Bitcoin fiyatını yönlendirdiğini tespit etmediklerini ifade etmişlerdir. Kjarland ve Meland (2018) Bitcoin'deki fiyat dalgalanmalarını inceledikleri çalışmalarında, Bitcoin'in kendisi ile ilgili haberlere göre fiyatın yukarı veya aşağı itildiğini, Bitcoin'in güvenli bir yatırım aracı olduğunu kanıtlayamadıklarını ve fiyatın teknik faktörlerden etkilendiğini ifade etmişlerdir. Bu iki çalışmada elde edilen bulgular analiz sonuçlarını destekler niteliktedir. Bu sonuçlara istinaden, modellerin tahmin performansının iyileştirilebilmesi için farklı öznitelik kümesi oluşturma çalışmaları yapılabilir. Fiyat hareketlerinin çok etkili olmasından dolayı, tahmin başarısını etkileyebilecek uygun teknik analiz parametreleri araştırılarak öznitelik kümesinde kullanılabilir. Yine bundan sonraki çalışmalarda farklı kripto varlıklar, kripto varlıkları etkilediği düşünülen farklı öznitelikler ve makine öğrenme algoritmalarının kullanılabilirliği düşünülmektedir.

KAYNAKÇA

- Abdulkareem, N.M. and Abdulazeez, A.M. (2021). Machine Learning classification based on Radom Forest Algorithm: A review, *International Journal of Science and Business*, 5(2), 128-142. doi: <https://doi.org/10.5281/zenodo.4471118>.
- Akay, M.K., Canik, F., Yeşilyurt, C. ve Günkut, M.Ş. (2021). Yapay zeka teknikleri ile kripto para değeri tahmini, *Ekonomi Bilimleri Dergisi*, 14(1), 72-101.
- Almeida, J., Tata, S., Moser, A. and Smit, V. (2015). Bitcoin prediciton using ANN, *Neural networks*, 1-12.
- Atsalakis, G.S., Atsalaki, I.G., Pasiouras, F. and Zopounidis, C. (2019). Bitcoin price forecasting with neuro-fuzzy techniques", *European Journal of Operational Research*, 276(2): 770-780.
- Andolfatto, D. (2014). Bitcoin and beyond: The possibilities and pitfalls of virtual currencies, *Federal Reser and Bank of St Louis, Central Banker*.
- Azari, A. (2019). Bitcoin price prediction: An ARIMA approach, arXiv preprint arXiv:1904.05315.
- Breiman, L. (2001). Random forests, *Machine Learning*, 45, 5-32.
- Caferra, R. and Vidal-Tomás, D. (2021). Who raised from the abyss? A comparison between cryptocurrency and stock market dynamics during the COVID-19 pandemic, *Finance Research Letters*, 101954.
- Chauhan, A., Kumar, M. and Saini, V.K. (2019). Bitcoin financial forecasting, *International Journal of Advance Research, Ideas and Innovations in Technology*, 5(2):1923- 1925.
- Chen, A. S., Leung, M. T. and Daouk, H. (2003). Application of neural networks to an emerging financial market: forecasting and trading the taiwan stock Index. *Computers & Operations Research*, 30(6), 901-923.
- Chen, Z., Li, C. and Sun, W. (2020). Bitcoin price prediction using machine learning: An approach to sample dimension engineering, *Journal of Computational and Applied Mathematics*, 365, 112395.
- Ciaian, P., Rajcaniova, M. and Kancs, D. (2016). The economics of Bitcoin price formation, *Applied Economics*, 48(19), 1799-1815, Doi: 10.1080/00036846.2015.1109038
- Corbet, S., Larkin, C. and Lucey, B. (2020). The contagion effects of the COVID-19 pandemic: Evidence from gold and cryptocurrencie, *Finance Research Letters*, 35, 101554.
- De Ville, B. (2013). Decision trees, *Wiley Interdisciplinary Reviews: Computational Statistics*, 5(6), 448-455.
- 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.
- González, M.D.L.O., Jareño, F. and Skinner, F.S. (2021). Asymmetric interdependencies between large capital cryptocurrency and Gold returns during the COVID-19 pandemic crisis, *International Review of Financial Analysis*, 76, 101773.
- Greaves, A. and Au, B. (2015). Using the bitcoin transaction graph to predict the price of bitcoin, *Semanticscholar.org*, 8.

- Ho, T. K. (1995). Random decision forests. *In Proceedings of 3rd international conference on document analysis and recognition, IEEE, 1, 278-282.*
- Hope. T.M.H. (2020). Linear Regression, *Machine Learning Medhods and Aplications to Brain Disorde*, 67-81
- Huynh, T.L.D., Nasir, M.A., Vo, X.V. and Nguyen, T.T. (2020). Small things matter most: The spillover effects in the cryptocurrency market and gold as a silver bullet, *The North American Journal of Economics and Finance*, 54, 101277.
- Karakoyun, E.S. and Çıbıkdiken, A.O. (2018). Comparison of arima time series model and lstm deep learning algorithm for bitcoin price forecasting, *In The 13th Multidisciplinary Academic Conference in Prague*, 171-180.
- Kavitha, S., Varuna, S. and Ramya, R. (2016). A comparative analysis on linear regression and support vector regression, *In 2016 Online International Conference on Green Engineering and Technologies*, 1-5.
- Kaya, U., Akba F., Medeni, İ. ve Medeni, T. (2020). Covid-19 öncesi ve sonrasındaki Bitcoin fiyat değişimlerinin Makine Öğrenmesi, zaman serileri analizi ve derin öğrenme yöntemleriyle değerlendirilmesi, *Bilişim Teknolojileri Dergisi*, 13(3), 341-355.
- Kim, J. M., Kim, S. T. and Kim, S. (2020). On the relationship of cryptocurrency price with us stock and gold price using copula models, *Mathematics*, 8(11), 1859.
- Kjærland, F., Meland, m., Oust, A. and Øyen, V. (2018). How can bitcoin price fluctuations be explained?, *International Journal of Economics and Financial Issues*, 8(3), 323.
- Lakshmi, J.V.N. (2016). Stochastic Gradient Descent using Linear Regression with Python, *International Journal of Advanced Engineering Research and Applications*, 2, 8.
- Madan, I., Saluja, S. and Zhao, A. (2015). Automated bitcoin trading via machine learning algorithms, <http://cs229.stanford.edu/proj2014/Isaac%20Madan>, 20.
- Mallqui, CA.D. and Fernandes. AS.R. (2019). Predicting the direction, maximum, minimum and closing prices of daily Bitcoin exchange rate using machine learning techniques, *Applied Soft Computing*, 75, 596-606.
- Mangla, N., Bhat, A., Avabratha, G. and Bhat, N. (2019). Bitcoin price prediction using machine learning, *International Joutnal of Information and Computing Science*, 6(5), 318-320
- Maulud, D.H. and Abdulazeez, A.M. (2020). A review on Linear Regression comprehensive in machine learning, *Journal of Applied Science and Technology Trends*, 1(4)140 –147.
- McNally, S., Roche, J. and Caton, S.(2018). Predicting the price of bitcoin using machine learning, *In 2018 26th Euromicro International Conference on Parallel, Distributed and Network-Based Processing*, 339-343.
- Mudassir, M., Bennbaia, S., Unal, D. and Hammoudeh, M. (2020). Time-series forecasting of Bitcoin prices using high-dimensional features: a machine learning approach, *Neural Computing And Applications*, 1-15.
- Navada, A., Ansari, A. N., Patil, S. and Sonkamble, B.A. (2011). Overview of use of decision tree algorithms in Machine Learning, *In 2011 IEEE Control and System Graduate Research Colloquium*, 37-42.
- Odabaşı, M. B. ve Toklu, M. C. (2023). Yapay sinir ağları ve derin öğrenme algoritmalarının kripto para fiyat tahmininde karşılaştırmalı analizi, *Journal Of Intelligent Systems: Theory And Applications*, 6(2), 96-107.
- Patil, S. and Kulkarni, U. (2019). Accuracy prediction for distributed decision tree using machine learning approach, *In 2019 3rd International Conference on Trends in Electronics and Informatics*, 1365-1371.
- Rane, P.V. and Dhage, S.N. (2019). Systematic erudition of bitcoin price prediction using machine learning techniques, *In 2019 5th International Conference on Advanced Computing & Communication Systems (ICACCS)*, 594-598.
- Rodriguez-Galiano, V., Sanchez-Castillo, M., Chica-Olmo, M. and Chica-Rivas, M.J.O.G.R. (2015). Machine learning predictive models for mineral prospectivity: An evaluation of neural networks, random forest, regression trees and support vector machines, *Ore Geology Reviews*, 71, 804-818.

- Sakız, B., Gencer, A. H. (2017). Yapay sinir ağları ile bitcoin fiyatını tahminleme forecasting the bitcoin price via artificial neural networks, *International Conference On Eurasian Economies*, Session 3d: Finans.
- Sakız, B. and Kutlugün, E. (2018). Bitcoin price forecast via blockchain technology and artificial intelligence algorithms, *In 2018 26th Signal Processing and Communications Applications Conference (SIU)*, 1-4.
- Shah, D. and Zhang, K. (2014). Bayesian regression and Bitcoin, 52nd Annual Allerton Conference on Communication, Control, and Computing (Allerton) Illinois, USA, IEEE, 409-414.
- Syzdykova, A. ve Azretbergenova, G. (2021). Bitcoin fiyatının altın ve ham petrol fiyatları ile ilişkisinin analizi, *In Traders International Trade Academic Journal*, 4(1), 43-58.
- Şenol, D. ve Denizhan, B. (2023). Kripto para değerinin yapay sinir ağları ile tahmini, *Endüstri Mühendisliği*, 34(1), 42-69.
- Thampanya, N., Nasir, M.A. and Huynh, T.L.D. (2020). Asymmetric correlation and hedging effectiveness of gold & cryptocurrencies: From pre-industrial to the 4th industrial revolution. *Technological Forecasting and Social Change*, 159, 120195. <https://doi.org/10.1016/j.techfore.2020.120195>.
- Yuksel, A.D. and Yazıcı, M. (2015). Price reversals and price continuations following large price movements, *Journal of Business Management*, 30 (2), 15-27.
- Wong, W.S., Saerbeck, D. and Delgado Silva, D. (2018). Cryptocurrency: A new investment opportunity? An investigation of the hedging capability of cryptocurrencies and their influence on stock, bond and gold portfolios. *SSRN Electronic Journal*. doi: 10.2139/Ssrn.3125737
- Yazan, E. and Talu, M.F. (2017). Comparison of the stochastic gradient descent based optimization techniques. *In 2017 International Artificial Intelligence and Data Processing Symposium*, 1-5.