

Pandemi Sürecinde Altın Fiyatları ile Kripto Para İlişkisinin Makine Öğrenme Metotları ile İncelenmesi

MEB, Dr. Ahmet SEL¹

*Sorumlu Yazar, selahmet43@gmail.com

Özet

Yatırımcılar için borsa endekslerinin tahmini endeksin etkilendiği çok fazla değişken olmasından dolayı zor olduğu kadar ihtiyaç duyulan bir konudur. Doğru tahminler yatırımcıların elde ettikleri faydayı en üst düzeye taşır. Pandemi sürecinde dalgalanmalar tüm piyasa ve yatırım araçlarında fazlasıyla gözlenmiştir. Bu çalışmada, pandemi sürecinde seçili kripto para türlerinin altın fiyatları üzerindeki etkisi incelenmiştir. Uygulamalar Python programlama dili kullanılarak yapılmıştır. Bağımsız değişkenler Bitcoin, EOS, Tether, TRON ve Ripple olmak üzere altın fiyatları üzerinde ilişkisi eğitim ve test kümeleri üzerinden makine öğrenmesi gerçekleştirilerek incelenmiştir. Makine öğrenme modellerinden çok değişkenli, karar ağacı, destek vektör makineleri ve rasgele orman regresyon modelleri bir arada kullanılmıştır. Sonuç olarak; en yüksek açıklama oranına ($R^2 = 0,91$) sahip olan destek vektör makineleri yardımıyla altın fiyatları üzerinde Bitcoin +0,755, EOS -0,596, Tether -0,122 ve Tron + 0,220 etkisi olduğu belirlenmiştir. Elde edilen sonuçlar piyasada oynaklığın fazla olduğu dönemlerde yatırımların yönlendirilmesinde karar vericilere yardımcı olacağı düşünülmektedir.

Anahtar Kelimeler: Altın Fiyatları; Kripto Para; Pandemi; Yapay Zeka; Makine Öğrenmesi

Abstract

For investors, forecasting stock market indices is a problem that is as important as it is challenging since the index is affected by so many variables. The benefit that investors get is maximized by accurate forecasts. Fluctuations were observed in all market instruments and investment instruments during the pandemic process. The influence of selected cryptocurrency forms on gold prices during the pandemic process is investigated in this research. The Python programming language is used to render applications. Via training and test sets, the relation between the independent variables Bitcoin, EOS, Tether, TRON and Ripple on gold prices was investigated by machine learning. The multivariate decision tree, help vector machines and random forest regression models were used together for machine learning models. As a result; with the help of support vector machines with the highest explanation rate ($R^2 = 0.91$), it has been determined that there are Bitcoin +0.755, EOS -0.596, Tether -0.122 and Tron + 0.220 effects on gold prices. The results obtained will assist decision-makers in directing their investments in times of high market volatility.

Keywords: Gold Price; Crypto Money; Pandemic; Artificial intelligence; Machine Learning

¹ Bu çalışma 1. Uluslararası Uygulamalı İstatistik Kongresinde özet bildiri olarak sunulmuştur.

1. GİRİŞ

Kripto para, yeterli altyapı ve teknolojinin gelişmesiyle birlikte 2010'lu yıllarda uygulamaya girmeye başlamıştır. Matematiğin bir dalı olan şifreleme yani kriptoloji bilimi temeline dayanan bir para birimidir. Kripto para veya diğer adıyla sanal para, para gibi işlev gören ama paranın aksine ulusal sınırlar ve merkez bankalarından bağımsız bir değişim aracıdır (Maese, vd., 2016, s. 133). Kripto para birimleri olarak bilinen bu şifreli paralar; kriptografik para, sanal para, dijital para ya da elektronik para olarak da adlandırılmaktadır. Kripto paralar hiçbir hükümet, organizasyon veya banka tarafından yönetilmediği, daha hızlı ve güvenilir olduğu için kullanıcılar tarafından maden veya madenci terimleri ile birlikte de kullanılmaktadır (Ateş, 2016, s. 349). Özellikle bazı kripto paralarının değerinin fazlasıyla artması insanları kripto para madenciliğine yöneltmiştir. Ancak sanılanın aksine kripto para üretimi için gereken ekipman ve teknolojiler zahmetli ve masraflı olabileceğini göstermektedir.

Blok zinciri teknolojisiyle geliştirilmiş ilk kripto para birimi Bitcoin (BTC)'dir. BTC, kullanıcılara ait tüm tasarrufların korunduğu, yapılan her işlemin kayıt altına alındığı, halka açık ve uçtan uca çalışan bir elektronik ödeme sistemidir (Nakamoto, 2019). Özellikle uluslararası ticarete güvenilir ve yenilikçi ödeme yöntemi olarak değerlendirilmiştir. Devletlerin bu ticari işlemlerin içeriğini ve transferleri kontrol edememesi eksi bir yön olarak kalmıştır. Ancak diğer para türleri gibi yatırım ve tasarrufların yönlendirilmesiyle tercih edilmeye başlanmıştır. Kripto paralarda giderek artan talep ve işlem hacmi yeni kripto paraların piyasaya girmesine neden olmuştur. Yeni çıkan kripto paralar için işlem hacimleri yüksek olmamasına rağmen spekülatif olaylara fazlasıyla açık oldukları ve kısa sürede yüksek oranda artış ve azalışlar gösterdiği bilinmektedir.

Yatırım araçlarından başında gelen altın, özellikle Türkiye'de "yastık altı" yatırım tabiriyle birikimi oldukça fazladır. Teknolojinin ilerlemesi ile daha çok fiziksel olarak biriktirilen altın yerini dijital hesaplara bırakmıştır. Yatırımcılar için portföy sepetinin gözde elmanı olan altının yanında risklerin azaltılması adına çeşitlendirme yoluna gitmektedirler. Bundan dolayı sepet oluşumunda yatırım araçlarının tamamı için fiyat tahminleri yatırımların yönlendirilmesi adına büyük önem taşımaktadır.

Aralık 2019'da ortaya çıkan koronavirüs (Covid-19) pandemisi piyasalarda olduğu gibi yatırım araçlarının çoğunda da olağan dışı dalgalanmalara sebep olmuştur. Özellikle piyasa ve yatırım araçlarında ani düşüş ve yükselişlerin görülmesi yatırımcılar için tam bir kafa karışıklığı yaratmıştır. Fiyatların tahmin teknikleri ve modelleri ile belirlenmesi gerçekçi karar alma adına yatırımcılar için son derece önemlidir. Tahminin doğruluğu başarılı kararlar alınmasını sağlar ve yatırımcıların fayda maksimizasyonuna ulaşmasına imkân tanır. Yatırım araçları arasında olağandışı durumların güvenli yatırım aracı genellikle altın olarak tabir edilmektedir.

Bu çalışmada, pandemi sürecinde altın fiyatlarının belirlenmesinde kripto paraların etkisi incelenmiştir. Altın fiyatlarının tahmini ve yatırım araçları ile ilişkisi konusunda literatürde oldukça fazla çalışma olmasına rağmen makine öğrenme modelleri ve kripto paraların etkilerinin araştırıldığı çalışmaya rastlanmamıştır. Ayrıca çalışma pandemi dönemindeki ilişkileri incelediğinden dolayı diğer çalışmalardan farklılaşmaktadır. Çalışmada analizler Python programlama dili kullanılarak makine öğrenme modellerinden çok değişkenli, karar ağacı, destek vektör makineleri ve rasgele orman regresyon modelleri bir arada kullanılmış ve en iyi sonuç aranmıştır. Elde edilen sonuçların pandemi dönemi gibi olağan dışı durumlarda yatırımların yönlendirilmesi ve portföy sepeti oluşturmada yardımcı olması beklenmektedir.

2. LİTERATÜR TARAMASI

Yapılan literatür arařtırmaları kapsamında zaman serileri yardımıyla yapılan arařtırmalar incelendiğinde; Elmas ve Polat (2014), çalışmalarında 1988-2013 yılları arasında altın fiyatını etkileyen; döviz kuru, Dow Jones Endeksi, faiz oranı, enflasyon oranı, gümüş fiyatı ve petrol fiyatı faktörleri üzerine zaman serileri ile incelenmiştir. Altın fiyatlarını; petrol fiyatları, gümüş fiyatları ve enflasyon oranının pozitif yönde, döviz kuru, Dow Jones Endeksi ve faiz oranının ise negatif yönde etkilediği tespit edilmiştir. Elde edilen sonuca göre faiz oranı dışındaki diğer faktörlerin altın fiyatına etkisi anlamlı bulunmuştur. Gültekin ve Hayat (2016), çalışmalarında altın fiyatlarının Türkiye’de etkilendiği faktörleri zaman serileri için kullanılan Vektör Otoregresif Modeller (VAR) modeli ile arařtırmıştır. 2005:01-2015:04 için aylık veriler ile İstanbul Altın Borsası’nda (İAB) altın fiyatları, faiz oranı, TÜFE, döviz kuru ve BİST 100 endeksi, altının ons fiyatı ve petrol fiyatı ile incelenmiştir. Sonuç olarak, İAB altın fiyatı tahmininde en fazla oran ons ve petrol fiyatı olurken en az faiz oranı olarak belirlenmiştir. Güleç (2018), çalışmasında önde gelen kripto paraları incelemiştir. Çalışmada Bitcoin’in döviz, emtia piyasaları, hisse senedi ve faiz ile olan ilişkisi incelenmiştir. Veriler aylık olarak 2012-2018 dönemini ele almaktadır. İnceleme yöntemi olarak Johansen Eşbütünleşme ve Granger Nedensellik analizleri uygulanmıştır. Sonuç olarak; Bitcoin fiyatları için artan bir trende ve yüksek bir volatiliteye sahip olduğu belirlenmiştir. Karasu ve diğ. (2018), çalışmalarında altın fiyatlarına etki eden faktörleri incelemiştir. 2003-2014 dönemi aylık veriler kullanılarak altın fiyatlarını etkileyen petrol fiyatları, mevduat faiz oranları, enflasyon oranları, gümüş fiyatları ve reel döviz kurları değişkenler olarak seçilerek eşbütünleşme analizi uygulanmıştır. Analiz sonuçlarında Türkiye’de enflasyon oranı ve gümüş fiyatlarının altın fiyatları üzerinde etkisi olduğu belirlenmiştir. Yıldırım (2018), çalışmasında Bitcoin ile altına arasındaki ilişkiyi ADF Birim Kök Testleri, Hata Düzeltme Modeli, Johansen Koentegrasyon Testi ve Düzeltilmiş En Küçük Kareler Modelleri ile değerlendirmiştir. Analiz sonuçlarında Bitcoin ve altın arasında kısa dönem için ilişkisiz olduğu görülmüştür. Ayrıca Bitcoin fiyatlarının altını etkilemezken, altın fiyatlarının Bitcoin fiyatlarını uzun dönemde etkilediği görülmüştür. Cingöz ve Kendirli (2019), çalışmalarında altın için fiyat hareketinde BİST 100 ve dolar kurundaki değişimlerin ilişkisi arařtırılmıştır. Altın fiyatları üzerine BİST 100 ve dolar kurunun uzun vadede anlamlı bir etkisi olabileceği ancak kısa vadede değişkenlerin altın fiyatı üzerinde anlamlı bir etkisinin olmadığı sonucuna ulaşılmıştır. Klein ve diğ. (2018), çalışmalarında Bitcoin ile altın arasındaki ilişki incelenmiştir. Çalışma da koşullu varyans analizi ile Bitcoin ve altının özelliklerini analiz edip karşılaştırılmış ve yapılarındaki farklılıkları bulunmuştur. Sonuç olarak Bitcoin’ in ile altının ters ilişkili olduğu ve hisse senedi piyasalarında temelde farklı özelliklere sahip olduğu görülmüştür.

Yapay sinir ağları ile yapılan çalışmalar incelendiğinde ise; Kocatepe ve Yıldız (2016), çalışmasında yapay sinir ağları yardımıyla altın fiyatında meydana gelen değişimler için yön tahmini yapılmıştır. Uygulama da 2007- 2015 dönemi aylık veriler ile Türkiye altın gram fiyatı bağımlı değişken iken bağımsız değişkenler ham petrol fiyatı, dolar kuru, dolar endeksi, BIST100 endeksi, Standard&Poor’s 500 endeksi, Türkiye enflasyon, faiz ve tahvil oranları, ABD enflasyon, gümüş ve bakır fiyatları ele alınmıştır. Sonuç olarak bağımsız değişkenlerin altın fiyatındaki değişim yönünü %75,24 oranına başarılı olarak tahmin ettiği belirlenmiştir.

Portföy sepeti oluşturma konusunda yapılan çalışmalara bakıldığında; Okuyan ve Deniz (2019), çalışmalarında kripto paraların portföy sepetine olan etkileri değerlendirilmiştir. Kripto para türlerinden en gözde olan Bitcoin ve Ethereumun başlıca ülkelerin ve Türkiye’nin borsa endeksleri ile altın, gümüş ve platin fiyatları kullanılmıştır. Elde edilen sonuçlarda kripto para getirileri ile kıymetli maden ve hisse senedi endeksi getirileri arasında pozitif ve anlamlı bir ilişki bulunamamıştır. Bu sonuç kripto paraların kıymetli maden ve hisse senedi portföylerinde iyi bir seçim olacağını göstermiştir. Gül (2020), çalışmasında kripto paralar ile portföy çeşitlendirmesini arařtırmıştır. Bu amaçla, 2015-2020 dönemi günlük verileri yardımıyla hisse senetleri, döviz kurları, emtialar ve yatırım

fonları ile çeşitli portföyler oluşturulmuştur. Daha sonra kripto paralar (Bitcoin, Ethereum, Ripple) portföylere ilave edilerek performansları değerlendirilmiştir. Analiz sonuçlarında, kripto paralar ile diğer varlıkların arasındaki korelasyonların genellikle ters yönlü yani negatif olduğu görülmüştür. Ayrıca, portföylere eklenen kripto paraların çoğunlukla düşük riskler ile daha yüksek getiriler elde edildiği görülmüştür. Bundan dolayı portföy çeşitlendirmesinde kripto paralar iyi bir araç olabilecekleri sonucu çıkmıştır.

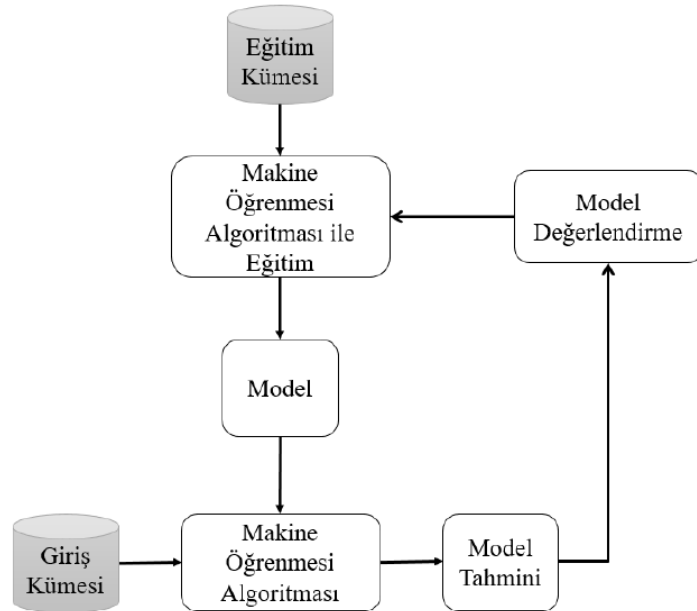
Pandemi döneminde altın fiyatları üzerine yapılan çalışmalar incelendiğinde; Gülhan (2020), çalışmasında Kovid-19 pandemisinin altın fiyatları üzerindeki etkisini ölçmek amacıyla 22.01.2020-08.04.2020 tarihleri arası günlük verilerle ARDL modeli kullanmıştır. Bağımlı değişken olarak altın fiyatlarının ele alındığı çalışmada, Kovid-19 Türkiye vaka sayısı, Kovid-19 Dünya vaka sayısı, US dolar kuru, politika faizi ve akaryakıt fiyatları bağımsız değişkenler olarak analize dâhil edilmiştir. Analiz sonuçlarına göre, kısa dönemde altın fiyatları ile dolar kuru ve politika faizi arasında negatif, akaryakıt fiyatları, Kovid-19 Dünya vaka sayısı, Kovid-19 Türkiye vaka sayısı gecikme değerleri, altın fiyatı gecikme değerleri arasında ise pozitif yönlü ilişki tespit edilmiştir.

3. YÖNTEM

Analiz sonuçlarının anlamlı çıkması adına veriler öncelikle normalleştirme işlemine tabi tutulmuştur. X' normalleştirilmiş değer olmak üzere her bir veri olan X için μ : ortalama ve σ : standart sapma değeri ile Denklem (1) uygulanarak normalleştirme işlemine tabi tutulmuştur.

$$X' = \frac{X - \mu}{\sigma} \quad (1)$$

Elde edilen normalleştirilmiş veriler üzerinden eğitim (%66) ve test (%33) kümeleri oluşturularak makine öğrenmesi gerçekleştirilmiştir. Makine öğrenme sürecinin temel işleyiş yapısı Şekil 1.'de gösterilmiştir.



Şekil 1. Temel makine öğrenmesi süreci

Eğitim kümesi ile makine öğrenmesi algoritması eğitildikten sonra giriş kümesinde yer alan test değerleri yardımıyla elde edilen model üzerinden çıktılar alınarak model değerlendirme işlemine tabi tutulur. Değerlendirme sonucunda elde edilen model yeterli performansı göstermesi durumunda model kabul edilmiş olacaktır. Çalışmada makine öğrenme modellerinde ise çok değişkenli, karar

ağacı, destek vektör makineleri ve rasgele orman regresyon modellerine ayrı ayrı uygulanarak en iyi performansı veren değer araştırılmıştır. Analiz işlemleri sırasında performans ölçütleri olarak açıklayıcılık (belirtme) katsayısı (R^2), kök ortalama kare hatası (Root Mean Square Error) (RMSE) ve ortalama mutlak hata (Mean absolute error) (MAE) değerleri hesaplanarak ölçülmüştür. Burada;

$$y_i = \text{Gözlem değerleri}$$

$$\bar{y}_i = \text{Gözlem değerlerinin ortalaması}$$

$$\hat{y}_i = \text{Tahmin değerleri}$$

$$n = \text{Gözlem sayısı}$$

olmak üzere;

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

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}} \quad (3)$$

$$MAE = \frac{\sum_{i=1}^n (y_i - \hat{y}_i)}{n} \quad (4)$$

şeklinde hesaplanmaktadır. Burada R^2 için 1'e en yakın değeri alması beklenirken RMSE ve MAE için en düşük değeri veren tahmin başarılı sayılacaktır.

3.1. Çoklu Regresyon Analizi


Regresyon analizi, bağımsız değişken/değişkenler ile bağımlı değişken/değişkenler arasındaki ilişkiyi incelemek için kullanılan bir yöntemdir. Bağımsız ve bağımlı değişkenlerin modelde birer tane olması ile tek değişkenli veya basit regresyon modeli, bağımlı değişkenin tek iken birden fazla bağımsız değişkenin olduğu regresyon modeline de çoklu regresyon modeli olarak adlandırılmaktadır. Birden çok bağımlı ve bağımsız değişkeni bulunan modeller ise çok değişkenli regresyon modeli olarak bilinmektedir. Bir tane bağımlı değişkenin için bağımsız değişkenin sayısının ise iki ve daha fazla olduğu regresyon modeline çoklu regresyon modeli denir (Özdamar, 2004:189).

Bağımlı değişkenin bir tane ve bağımlı değişken üzerindeki etkileri aranan bağımsız değişkenin birden fazla olduğu regresyon modeline çoklu regresyon modeli denir. Çoklu regresyon modeli için Y: bağımlı değişken olmak üzere $i=1..n$ tanımlanan X_i 'ler bağımsız değişkenler için β_0 : sabit iken β_i 'ler katsayılarıdır. n değişkenli model için Denklem (5) gibi yazılabilir.

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_n X_n \quad (5)$$

3.2. Karar Ağacı Modelleri

Veri madenciliği çalışmalarında kullanılan karar ağacı yöntemi, tahmin ve sınıflandırmada başvurulan önemli yöntemlerden biridir. Karar ağacı, girdisi bulunmayan bir kök düğüm ve her biri ayrı birer girdi olarak değerlendirilen iç düğümlerden meydana gelen yönlü bir ağaç şeklindedir. Düğümler karar ağacı modeli için çıktılarını bir başka düğüm için girdi ise test ya da iç düğümü, girdi değilse de yaprak düğümler şeklinde tanımlanır (Maimon ve Rokach, 2010, s. 150). Karar ağacı modellerinin görsel yapısı Şekil 2.'de gösterilmiştir.




Şekil 2. Karar Ağacı Modeli

Karar ağacı modelleri gözetimli öğrenme modeli olmakla birlikte sınıflandırma ve regresyon modellerinde kullanılmaktadır. Karar ağacının her bir dalı programlama da dilinde yer alan “eğer” yapısına uygun olarak ayrılmaktadır. Meydana gelen dallar yardımıyla analize konu olan veri tüm modele işlenmiş olur. Karar ağacı modeli eğitim verisi sonucunda eğitilen modelin test verisi kullanılarak istatistiksel olarak etkinliğinin belirlenmesinden sonra tahmin yöntemleri için kullanılmaktadır. Modelin yapısı özellikle sınıflandırma sonuçlarının görsel olarak gösterimini kolaylaştırmaktadır. Diğer yöntemlere nazaran karar ağacı modellerinin hızlı sonuç vermesi ve veriler arası ilişkilerin yapısal olarak gösterilmesi tercih edilmesinde önemli bir rol oynamaktadır.

Karar ağacı algoritmasının temel amacı karmaşık yapılardan ziyade küçük boyutlu ve az derinlikli ağaçların oluşturulmasıdır. Karar ağacı algoritmaları kullanılarak elde edilen karmaşık ve büyük yapılar genellikle düşük başarı düzeyine sahiptir. Bu sebeple, küçük boyutlu karar ağaçları modelleri oluşturmak amacıyla birçok farklı yaklaşım önerilmiştir. Bu yaklaşımlardan biri düğümlerin oluşturulması ve ayrılmasında ölçütlerin kullanılmasıdır. GINI indeksi, bilgi kazancı, k-kare istatistiği gibi ölçütler, başlıca kullanılan düğüm ayırma ölçütleri arasındadır (Kothari ve Dong, 2001, s. 172). Karar ağacının oluşturulması ve analiz kısmında farklı ölçütlerin kullanılması modelin başarı düzeyini de etkilemektedir. Bundan dolayı tek bir ölçüt ile modelin başarısının sınanması yerine farklı ölçütler kullanılarak başarı düzeyinin karşılaştırılması önemlidir.

3.3. Rasgele Orman Modelleri

Rasgele orman algoritması topluluk öğrenme yöntemlerinden biridir. Topluluk öğrenme yöntemleri, farklı modelleri birleştirerek sonuçları iyileştirmeyi amaçlar. Rasgele orman algoritması birden fazla karar ağaçlarının topluluğundan elde edilmektedir. Rasgele orman algoritması avantajlarından biri hem sürekli hem kesikli değişkenlerin birlikte kullanılabilmektedir. Ayrıca büyük küçük boyutlu veri setlerinde kullanılabilir. Rasgele orman ise doğruluk oranı diğer algoritmaya göre yüksek çıkmaktadır. Dezavantaj olarak ise algoritma siyah kutu yani ağaç yapısı görülmemektedir (Breiman, 2001, s. 20). Rasgele orman yönteminin oluşturduğu yapı Karar ağaçları (KA) yapısıyla meydana gelmektedir. Şekil 3.’te rasgele orman modelinin yapısı görülebilir.



Şekil 3. Rasgele Orman Modeli Yapısı

Karar ağaçlarının her birinden elde edilen sonuçların ortalamaları tahmin değerini vermektedir. Ancak karar ağaçlarında olduğu gibi elde edilen modelin görselleştirilmesi çoğu zaman sorun olabilmektedir. Ağaç yapısını oluşturan dalların oluşumunda en önemli adım meydana gelen dallanmaların hangi kriter ya da öznelik değerinin dikkate alınacağını belirlemesidir. Kaynaklar incelendiğinde bu problemin çözümünde kullanılan çeşitli yaklaşımlar olduğu görülmektedir. Bunlardan en önemli olarak kabul edilenler ise Gini indeksi, Twoing kuralı, bilgi kazancı ve bilgi kazanç oranı ile Ki-Kare olasılık tablo istatistiği yaklaşımlarıdır. ID3 algoritması tek değişkenli karar ağaçlarından olmak üzere bilgi kazancı yaklaşımını kullanırken, C4.5 algoritması bilgi kazancı ve bölünme bilgisi kavramından yararlanmaktadır. Regresyon ağacı ve sınıflandırma yöntemi olarak bilinen CART algoritması ise Twoing kuralını kullanmaktadır (Breiman, Friedman, Olshen ve Stone, 1984:28).

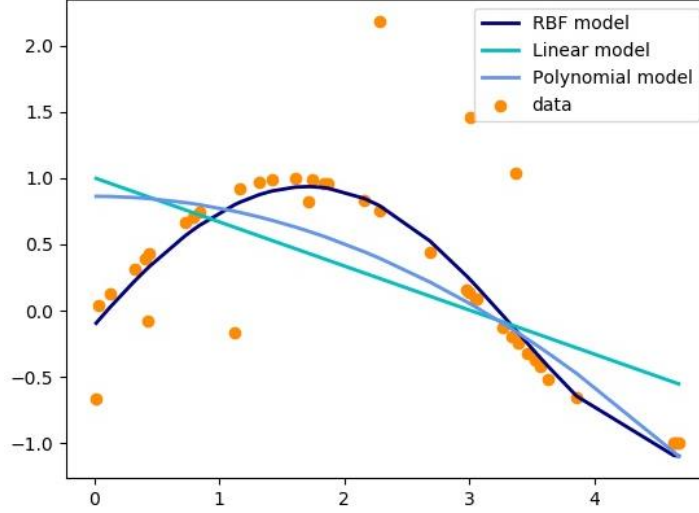
Bagging yöntemi, birçok sınıflama modeline uygulanabilmekle birlikte daha çok karar ağaçları için kullanılmaktadır. Bagging yöntemi veri setinden sınıf yapısını bozmayacak şekilde rastgele örnekler seçilerek (bootstrap) oluşturulan çok sayıda karar ağacının yaptığı sınıf tahminleri oylanarak en çok oy toplayan sınıfı asıl sınıf tahmini olacak şekilde belirleyen öğrenme yöntemidir. Bagging yönteminde art arda oluşturulan ağaçlar önceden oluşturulan ağaçlara bağımlı değildirler ve ağaçlar orijinal veri setinden bootstrap örnekleme yapılarak oluşturulmaktadır.

Rasgele Orman (Random Forests) yönteminde sonradan gelen veriye ait tahmin yapılmasının yanında, değişkenlerin önem derecesi de hesaplanmaktadır. Veri setinde çok sayıda değişken varsa, değişken önem derecesinin hesaplanması model indirgemesi açısından oldukça kullanışlıdır. Örneğin binlerce değişkenin bulunduğu veri setinde, Rasgele Orman yöntemiyle elde edilen önem derecesine göre, kurulacak yeni modelde önem derecesi yüksek değişkenler kullanılarak daha etkin tahminlerin yapılması sağlanabilir.

3.4. Destek Vektör Makineleri

1963 yılında Vladimir Vapnik ve Alexey Chervonenkis tarafından temelleri atılan Destek Vektör Makineleri (Support Vector Machine) (SVM) istatistiksel öğrenme teorisine dayalı bir gözetimli öğrenme algoritmasıdır. Her ne kadar temelleri 60'lı yıllara dayansada 1995 yılında Vladir Vapnik, Bernhard Boser ve Isabelle Guyon tarafından geliştirilmiştir (Akpınar, 2017). SVM modelleri aşırı öğrenmeyi azaltan yapısı ile sınıflandırma ve regresyon problemlerinin çözümünde uygulanan ve daha iyi sonuçlar veren güdümlü bir öğrenme algoritmasıdır (Panigrahi ve Mantri, 2015, s. 763). SVM algoritmasında, regresyon için Destek Vektör Bağlayıcısı (Support Vector Regressor-SVR) adı verilen

bir yapı bulunmaktadır. SVR, regresyon hatalarını en aza indirmek için deneysel riskleri ölçer ve bunun için de bir maliyet fonksiyonu kullanır (Yu, Chen ve Chang 2016, s. 705). SVM algoritması, doğrusal olan ve doğrusal olmayan türlere sahiptir. Hiper düzlemlerdeki en optimal noktayı bulabilmek için kernel adı verilen çekirdek yapılar kullanılır (Lin ve Wang, 2002, s. 465). Şekil 4.'te SVR modelleri için Radial Basis Function (RBF) metodu kernel yapısına göre doğrusal ve polinomal eğrilere göre daha başarılı sonuç verdiği görülmektedir.



Şekil 4. SVR (rbf)-Doğrusal-Polinomal Tahminler

SVM yönteminde doğrusal sınıflanabilen veriler için birbirinden ayırt edilmesi amacıyla doğrusal fonksiyonlar arasından, en büyük marjini olan fonksiyon seçilmektedir. Eğer sınıflamada örneklerin doğrusal bir düzlem ile ayrıştırılabilecek düzeyde değilse, yöntemde kullanılan Kernel fonksiyonu yardımıyla daha yüksek boyutlu bir uzaya aktarılması mümkün olmaktadır. Bu şekilde marjini en yüksek olan hiper düzlemler bulunur. Sonuç olarak veriler bu ayırt edici hiper düzleme göre sınıflara atanır (Coşgun ve Karağaoğlu, 2011, s. 185). Python programlama dili altında bulunan SVR modeli kernel yapıları {'linear', 'poly', 'rbf', 'sigmoid', 'precomputed'} seçenek olarak verilmektedir. Verinin yapısı ve model başarısının yüksekliğine göre bu yapılardan uygun olanı modele uygulanır.

4. UYGULAMA

Uygulamada Python programlama dilinde numpy, matplotlib, pandas, sklearn.metrics ve statsmodels.api kütüphaneleri kullanılmıştır. Bu kütüphaneler yardımıyla makine öğrenme modellerinden çok değişkenli, karar ağacı, destek vektör makineleri ve rasgele orman regresyon modelleri bir arada kullanılmış ve en iyi sonuç aranmıştır.

4.1. Veri ve Değişkenler

Analize konu olan değişkenlerin değerleri dolar cinsinden ele alınarak açık erişim adresi olan (investing.com) sitesinden elde edilmiştir. İnceleme sırasında piyasa da aktif olarak işlem gören 3855 kripto para olduğu görülmüştür. Araştırmanın pandemi sürecini kapsamından dolayı 1/12/2019 ile 8/09/2020 tarihleri arasında veriler incelenmiştir. Analize veriler değerlendirmeye alınırken tarih aralığında ortak olarak işlem gördükleri günler dikkate alınmıştır. Uygulamada kripto paralar arasından en yaygın olarak kullanılan ve piyasa hacmi en az %0,5 yoğunluğa sahip olanlar kullanılmıştır. Bağımsız değişken olarak ele alınan 13 tane kripto para ve değerleri Tablo 1.'de gösterilmiştir.

Tablo 1. Piyasa Hacmi %0,5'ten Büyük Kripto Paralar

Kripto Para	Sembol	Fiyat(USD)	Piyasa Hacmi
Tether	USDT	1,00	38,39%
Bitcoin	BTC	10591,9	24,23%
Ethereum	ETH	340,45	14,12%
Chainlink	LINK	9,54	2,16%
EOS	EOS	2,48	1,66%
TRON	TRX	0,03	1,45%
Ripple	XRP	0,23	1,30%
Litecoin	LTC	44,20	1,12%
Bitcoin Cash	BCH	211,49	0,96%
Power Ledger	POWR	0,08	0,93%
Neo	NEO	21,78	0,79%
Bitcoin SV	BSV	152,63	0,56%
Ethereum Classic	ETC	4,91	0,50%


Kaynak: Kripto Para, link: <https://tr.investing.com/crypto/>

Tablo 1. İncelendiğinde piyasa değerleri incelendiğinde BTC, ETH ve BCH'nin ilk sıralarda yer aldığı görülmektedir. Ancak BTC'nin piyasa değeri USDT'den çok fazla olmasına rağmen piyasa yoğunluğunda ilk sırada yer almaktadır. Bağımsız değişkenler arası korelasyon matrisi Tablo 2.'de gösterilmiştir.

Tablo 2. Bağımsız Değişkenler Arası Korelasyon Matrisi


	BCH	BTC	BSV	LINK	EOS	ETC	ETH	LTC	NEO	POWR	USDT	TRX	XRP
BCH	1,00												
BTC	0,43	1,00											
BSV	0,90	0,43	1,00										
LINK	0,06	0,78	0,08	1,00									
EOS	0,97	0,43	0,83	0,09	1,00								
ETC	0,94	0,45	0,90	0,02	0,88	1,00							
ETH	0,24	0,90	0,25	0,94	0,25	0,21	1,00						
LTC	0,94	0,58	0,80	0,27	0,96	0,84	0,44	1,00					
NEO	0,35	0,82	0,29	0,78	0,41	0,29	0,85	0,53	1,00				
POWR	0,11	0,75	0,21	0,70	0,06	0,17	0,79	0,24	0,57	1,00			
USDT	-0,40	-0,61	-0,53	-0,28	-0,33	-0,49	-0,41	-0,35	-0,39	-0,42	1,00		
TRX	0,34	0,77	0,28	0,79	0,41	0,28	0,84	0,52	0,93	0,52	-0,36	1,00	
XRP	0,72	0,76	0,57	0,59	0,77	0,58	0,71	0,87	0,72	0,36	-0,35	0,71	1,00

Bağımsız değişken olarak alınan 13 kripto para içerisinde regresyon analizi sonuçlarında çoklu bağlantı sorunu olmaması adına korelasyon değerleri hesaplanarak mutlak değerce 0,80'den büyük olan değişkenler analizden çıkarılmıştır. Elde edilen sonuçlarda ise bağımsız değişkenler Bitcoin, EOS, Tether, TRON ve Ripple olmak üzere altın fiyatları bağımlı değişken olarak belirlenmiştir. Bağımlı değişken altın için pandemi sürecindeki fiyat değişimi Grafik 1.'de gösterilmiştir.



Grafik 1. Pandemi Süreci Altın Fiyatları (\$), (Kaynak:investing.com)

Grafik 1. incelendiğinde altın fiyatlarında 2 Aralık 2019 tarihinde başlayan artış trendi 19 Mart 2020 tarihinde dip seviyeye geldikten sonra artışlar devam etmiştir. Ağustos 2020 başında ise en yüksek değerine ulaşmıştır. Bitcoin fiyatlarının pandemi süreci içerisindeki değişimi Grafik 2.'de gösterilmiştir.



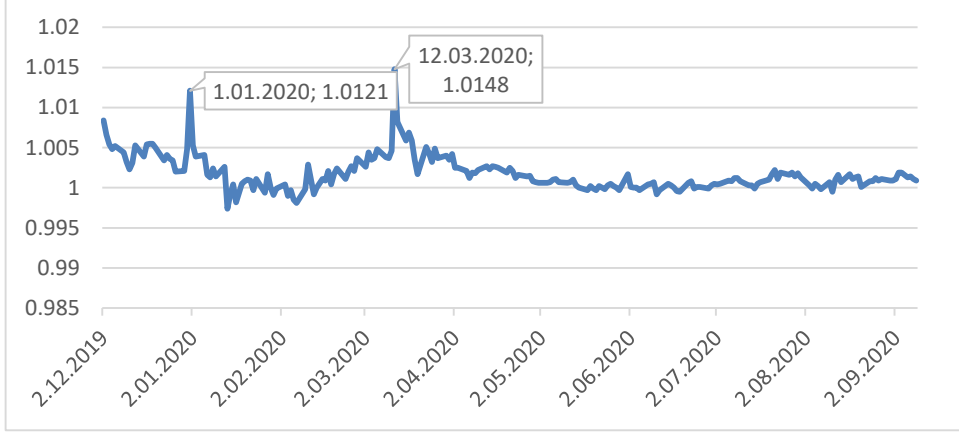
Grafik 2. Pandemi Süreci BTC Fiyatları (\$), (Kaynak:investing.com)

Bitcoin fiyatlarının pandemi sürecinde değişimi izlendiğinde 2 Aralık 2019 tarihinde itibaren artış trendi Şubat ortalarında biterek 12 Mart 2020 tarihinde dip noktaya ulaşmıştır. Ancak 17 Ağustos 2020 tarihinde yaklaşık 2,5 katı değer kazandığı görülmektedir. EOS için pandemi süreci fiyat değişimi Grafik 3'te gösterilmiştir.



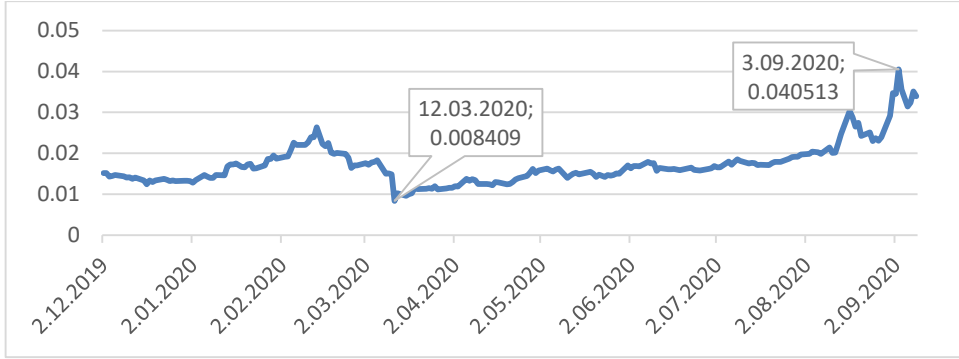
Grafik 3. Pandemi Süreci EOS Fiyatları (\$), (Kaynak:investing.com)

EOS için Grafik 3. İncelendiğinde 12 Şubat 2020 tarihinde pandemi başındaki değerinin 2 katına çıktığı görülmektedir. Ancak tam bir ay sonra 3'te 1 fiyatına inen EOS için fiyatının genel anlamda 2\$-3\$ bandında gezindiği söylenebilir. Tether için fiyat değişimleri Grafik 4'te gösterilmiştir.




Grafik 4. Pandemi Süreci USDT Fiyatları (\$), (Kaynak:investing.com)

Tether fiyat değişimi için Grafik 4. incelendiğinde dikkat çeken nokta 12 Mart 2020 tarihinde en yüksek değerine ulaşmasıdır. Bunun dışında 1\$ bandında fiyatının değişkenlik gösterdiği söylenebilir.



Grafik 5. Pandemi Süreci TRX Fiyatları (\$), (Kaynak:investing.com)

TRON fiyat değişiminin 12 Mart 2020 tarihinde dip yaptığı ve 3 Eylül 2020 tarihinde ise tavan yaparak yaklaşık 5 katına çıktığı görülmüştür.



Grafik 6. Pandemi Süreci XRP Fiyatları (\$), (Kaynak:investing.com)

Ripple fiyatlarının ise 14 Şubat 2020 tarihinde tavan yaptığı görülmüştür. Genel olarak değerlendirdiğimizde bağımsız değişken olarak alınan kripto paralar için 12 Mart 2020 tarihinde Tether tavan yapmasına rağmen diğerleri dip fiyat noktalarına düşmüşlerdir.

4.2. Analiz Sonuçları

Normalleştirme işlemine tabi tutulmuş veriler üzerinden regresyon modelleri makine öğrenmesi sonucunda elde edilen sonuçlar ile kernel yapısı Radial basis function (rbf) olarak seçilen Destek Vektör Makineleri yönteminin daha başarılı olduğu görülmüştür.

Tablo 3. Makine Öğrenmesi Sonucu Modellerin Regresyon Başarıları

Regresyon Yöntemi	Rkare	MAE	RMSE
Çok Değişkenli	0,80	0,38	0,45
Karar Ağacı	0,80	0,28	0,52
Destek Vektör Makineleri	0,91	0,25	0,35
Rasgele Orman	0,83	0,28	0,37

Destek Vektör Makineleri regresyon modeli sonucunda XRP anlamsız olduğu için modelden çıkartılması sonucu elde edilen model aşağıdaki gibidir.

Tablo 4. SVM Regresyon Modeli Katsayı Sonuçları

Bağımsız	Katsayı	Standart Hata	p(olasılık)
BTC	0,755	0,047	0,000
EOS	-0,596	0,029	0,000
USDT	-0,122	0,031	0,000
TRX	0,220	0,043	0,000

Analiz sonucunda elde edilen regresyon modeli aşağıdaki gibidir.

$$Altın = 0,755 * BTC - 0,596 * EOS - 0,122 * USDT + 0,220 * TRX$$

Destek Vektör Makineleri regresyon modeli sonucunun Altın fiyatları üzerinde $R^2=0,91$ olmak üzere Bitcoin pozitif yönlü 0.755, EOS negatif yönlü 0.596, Tether için negatif yönlü 0.122 ve Tron için pozitif yönlü 0,220 etkinin olduğu belirlenmiştir.

Yoğunluk değerleri dikkate alındığında Tether ilk sırada yer alarak negatif etkisi gözlenmiştir. Bitcoin ise ikinci sırada yer alarak pozitif yönde daha güçlü bir etkiye sahiptir. Yoğunluk sıralamasında EOS ve Tron yakın değerler almasına rağmen EOS negatif yönde daha güçlü bir etkiye sahip olduğu görülmüştür.

5. SONUÇ ve ÖNERİLER

Tasarruf ile elde edilen paranın yatırım araçları yardımıyla biriktirilmesi gelir elde etmekten öte günümüzde değer kaybının önlenmesi amacıyla da gerçekleştirilmektedir. Bu yüzden yatırımların

yönlendirilmesinde tahminlerin doğru ve yerinde olması yatırımcı için hayati önem arz etmektedir. Ancak pandemi sürecinde piyasalarda meydana gelen büyük dalgalanmalar panik ortamını arttırmıştır. Doğru kararlar alabilen yatırımcılar için büyük kar elde etme fırsatı doğmuş olmasına rağmen bir o kadar da zarara sebep olduğu görülmüştür. Kar ve zarar dengesini gözetebilmek adına portföy sepeti uygulamasında bu çalışma için altın ve kripto paralar incelemeye alınmıştır. Çalışmada pandemi sürecinde seçili kripto para türlerinin altın fiyatları üzerindeki etkisi incelenmiştir.

Bağımsız değişkenler Bitcoin, EOS, Tether, TRON ve Ripple olmak üzere altın fiyatları üzerinde ilişkisi eğitim (%66) ve test (%33) kümeleri üzerinden makine öğrenmesi gerçekleştirilerek incelenmiştir. Bitcoin fiyatlarının tahmin sonuçlarının regresyon performansları R^2 , RMSE ve MAE değerleri hesaplanarak ölçülmüştür. Makine öğrenme modellerinden çok değişkenli, karar ağacı, destek vektör makineleri ve rasgele orman regresyon modelleri bir arada kullanılmıştır. Sonuç olarak; destek vektör makineleri için kernel yapısı "rbf" için açıklayıcılık oranı $R^2 = 0,91$ olmak üzere altın fiyatları üzerinde Bitcoin +0,755, EOS -0,596, Tether -0,122 ve Tron + 0,220 şeklinde etkisi olduğu belirlenmiştir.

Klein ve diğ. (2018), çalışmasının sonucu olan Bitcoin ile altın arasındaki ters ilişki ve Yıldırım (2018), çalışmasında Bitcoin fiyat hareketlerinin altın fiyatlarını etkilemezken, altın fiyat hareketlerinin Bitcoin fiyatlarını uzun vadede etkilediğini belirlemiştir. Ancak pandemi sürecinde bu ilişkinin pozitif yönlü olarak gerçekleştiği görülmüştür. Ayrıca portföy çeşitlendirmelerinde Okuyan ve Deniz (2019) ile Gül (2020), çalışmalarında kripto paraların hisse senedi ve kıymetli maden portföyleri için iyi bir çeşitlendirme varlığı olduğunu göstermiştir. Dolayısıyla, kripto paraların portföy çeşitlendirmesi için iyi bir araç olabilecekleri ve portföy performanslarını olumlu etkiledikleri sonucuna varılmıştır.

Kripto paraların fazlasıyla etkin olmasına rağmen fiyat oynaklıklarının yüksek olması yatırım konusunda sınırlandırmaktadır. Ancak yapılan yatırımların piyasa içinde büyüklüğü ve yüksek getirilerinden dolayı tercih edilmeleri giderek artmaktadır. SVM modelinin kripto para türleri ile altın fiyatlarını tahmin etmede diğer makine öğrenme modellerine göre daha tutarlı sonuçlar verdiği görülmüştür. Elde edilen sonuçlar piyasada oynaklığın fazla olduğu dönemlerde yatırımların yönlendirilmesinde karar vericilere yardımcı olacaktır. Bundan sonraki çalışmalarda pandemi süreci sonrası değerlendirilebilir ve dönemsel olarak yatırım araçları da çeşitlendirilerek kripto paralar ile emtia ürünleri arası ilişkiler incelenebilir.

KAYNAKÇA

- Aksoy, E., Teker, T., Mazak, M., & Kocabıyık, T. (2020). Kripto paralar ve fiyat ilişkileri üzerine bir analiz: Toda-Yamamoto nedensellik analizi ile bir inceleme. *Süleyman Demirel Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, (37), 110-129.
- Akpınar, H. (2014). *Data: Veri madenciliği veri analizi*. Papatya Yayıncılık Eğitim.
- Ateş, B. A. (2016). Kripto para birimleri, bitcoin ve muhasebesi. *Çankırı Karatekin Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 7(1), 349-366.
- Breiman, L. (2001). *Random forests*. *Machine learning*, 45(1), 5-32.
- Breiman, L., Friedman, J. H., Olshen, R. A. and Stone, C. J. (1984). *Classification and regression trees*. Monterey, Calif., USA: Wadsworth.
- Cingoz, F., & Kendirli, S. (2019). Altın fiyatları, döviz kuru ve borsa istanbul arasındaki ilişki. *Finans Ekonomi ve Sosyal Araştırmalar Dergisi (FESA)*, 4(4), 545-554.

- Cosgun, E., & Karaağaoğlu, E. (2011). Veri madenciliği yöntemleriyle mikrodizilim gen ifade analizi. *Hacettepe Tıp Dergisi*, 42, 180-189.
- Elmas, B., & Polat, M. (2014). Altın fiyatlarını etkileyen talep yönlü faktörlerin tespiti: 1988-2013 dönemi. *Cumhuriyet Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 15(1), 171-187.
- Güleç, Ö. F. (2018). Bitcoin ile finansal göstergeler arasındaki ilişkinin incelenmesi. *Kırklareli Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 7(2), 18-37.
- Gülhan, Ü. (2020). Kovid-19 pandemisinin altın fiyatlarına etkisi: ardl analizi. *Atatürk Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 34(3), 1111-1125.
- Gültekin, Ö. E., & Hayat, E. A. (2016). Altın fiyatını etkileyen faktörlerin var modeli ile analizi: 2005-2015 dönemi/Analysis of factors affecting the gold prices through var model: 2005-2015 period. *Ege Akademik Bakis*, 16(4), 611.
- Karasu, S., Altan, A., Saraç, Z., & Hacıoğlu, R. (2018, May). Prediction of Bitcoin prices with machine learning methods using time series data. In *2018 26th Signal Processing and Communications Applications Conference (SIU)* (pp. 1-4). IEEE.
- Klein, T., Thu, H. P., & Walther, T. (2018). Bitcoin is not the new gold—a comparison of volatility, correlation, and portfolio performance. *International Review of Financial Analysis*, 59, 105-116.
- Kocatepe, C. İ., & Yıldız, O. (2016). Ekonomik endeksler kullanılarak Türkiye’deki altın fiyatındaki değişim yönünün yapay sinir ağları ile tahmini. *Düzce Üniversitesi Bilim ve Teknoloji Dergisi*, 4(3).
- Kothari, R., & Dong, M. (2001). Decision trees for classification: A review and some new results. In *Pattern recognition: from classical to modern approaches* (pp. 169-184).
- Maese, V. A., Avery, A. W., Naftalis, B. A., Wink, S. P., & Valdez, Y. D. (2016). Cryptocurrency: A primer. *Banking LJ*, 133, 468.
- Maimon O., Rokach L. (2010). "Classification Trees". *Data Mining and Knowledge Discovery Handbook*, Editör: O., Maimon, L. Rokach, Springer, New York, A.B.D., 149-175.
- Nakamoto, S. (2019). *Bitcoin: A peer-to-peer electronic cash system*.
- Nebil, F. S. (2018). Bitcoin ve kripto paralar. *Pusulayayıncılık, İstanbul*.
- Okuyan, H. A., & Deniz, A. G. D. (2019). Kripto paraların geleneksel finansal varlıklarla ilişkisi. *Scientific Committee*, 108. II. International Conference on Empirical Economics and Social Sciences (ICEESS' 19) June 20-21-22, / Bandırma – Turkey
- Özdamar K. (2004). *Paket programlar ile istatistiksel veri analizi*. Eskişehir: Kaan Kitabevi.
- Panigrahi, S. S., & Mantri, J. K. (2015, October). Epsilon-SVR and decision tree for stock market forecasting. In *2015 International Conference on Green Computing and Internet of Things (ICGCIoT)* (pp. 761-766). IEEE.
- Lin, C. F., & Wang, S. D. (2002). Fuzzy support vector machines. *IEEE transactions on neural networks*, 13(2), 464-471.
- Yıldırım, H. (2018). Günlük bitcoin ile altın fiyatları arasındaki ilişkinin test edilmesi: 2012-2013 yılları arası johansen eşbütünleşme testi. *Itobiad: Journal of the Human & Social Science Researches*, 7(4).
- Yu, P. S., Chen, S. T., & Chang, I. F. (2006). Support vector regression for real-time flood stage forecasting. *Journal of Hydrology*, 328(3-4), 704-716.