



Article Info/Makale Bilgisi

✓Received/Geliş:02.09.2025 ✓Accepted/Kabul:23.12.2025

DOI:<https://doi.org/10.30794/pausbed.1776824>

Research Article/Araştırma Makalesi

Akkuş, H. T. (2025). "Altın Fiyatlarının Tahmininde Makine Öğrenmesi ve Derin Öğrenme Yaklaşımları" *Pamukkale Sosyal Bilimler Enstitüsü Dergisi*, Sayı:71 EYS'25 Özel Sayısı, 6129-6142.

ALTIN FİYATLARININ TAHMİNİNDE MAKİNE ÖĞRENMESİ VE DERİN ÖĞRENME YAKLAŞIMLARI*,**

Hilmi Tunahan AKKUŞ***

Öz

Altın gerek reel gerekse finansal piyasalarda işlem gören önemli bir değer olarak tarih boyunca öncelikli konumunu sürdürmektedir. Bu çalışmada altın fiyatlarının tahmini makine öğrenmesi ve derin öğrenme algoritmaları ile gerçekleştirilmektedir. Analizler sonucunda en iyi tahmin performansına, rassal orman (random forest – RF) algoritması ile ulaşılmıştır. Analiz sonuçlarının yorumlanabilmesi için öznelik önemi (feature importance) ölçümü de gerçekleştirilmiştir. Buna göre altın fiyatlarının tahmininde en önemli değişkenler sırasıyla altın ile aynı emtia sınıfında yer alan gümüş ve ABD 10 yıllık faiz getirisi olarak belirlenmiştir. Altın fiyatlarının tahmini, bireysel yatırımcılar, kurumsal yatırımcılar ve merkez bankalarının altın rezervleri nedeniyle hükümetler açısından önemlidir. Altın piyasasında fiyatların tahmin edilebilmesi, ilgili piyasanın zayıf formda etkinliği konusunda şüphe uyandırmaktadır.

Anahtar kelimeler: *Altın Fiyat Tahmini, Derin Öğrenme, Makine Öğrenmesi, Öznelik Önemi, Piyasa Etkinliği.*

JEL Kodları: C45, C53, G14

MACHINE LEARNING AND DEEP LEARNING APPROACHES IN FORECASTING GOLD PRICES

Abstract

Gold has historically held a prominent position as a significant asset traded in both real and financial markets. In this study, gold price prediction is performed using machine learning and deep learning algorithms. The best predictive performance was achieved using the random forest (RF) algorithm. Feature importance measurements were also performed to interpret the analysis results. Accordingly, the most important variables in predicting gold prices were identified as silver, which is in the same commodity class as gold, and the US 10-year interest rate, respectively. Forecasting gold prices is important for individual investors, institutional investors, and governments due to the gold reserves held by central banks. The ability to predict prices in the gold market raises doubts about the weak-form efficiency of the relevant market.

Keywords: *Gold Price Prediction, Deep Learning, Machine Learning, Feature Importance, Market Efficiency.*

JEL Codes: C45, C53, G14

*Bu çalışma, EYS'25 Python Destekli Denetimli Makine Öğrenmesi ve Python Destekli Derin Öğrenme dersi kapsamında öğretilen teknikler kullanılarak hazırlanmıştır.

**Bu çalışma Balıkesir Üniversitesi Bilimsel Araştırma Projeleri Koordinatörlüğü tarafından desteklenmektedir (Proje No: 2023/165).

***Doç. Dr., Balıkesir Üniversitesi, İktisadi ve İdari Bilimler Fakültesi, Uluslararası Ticaret ve Lojistik Bölümü, BALIKESİR.

e-posta: tunaakkus@balikesir.edu.tr, (<https://orcid.org/0000-0002-8407-1580>)

1. GİRİŞ

Finansal varlık fiyatlarının öngörülebilmesi, yatırımcılar açısından önemli bir fırsattır. Fama (1965, 1970) tarafından ileri sürülen Etkin Piyasalar Hipotezi'ne (EPH) göre, fiyatlar rassal bir yürüyüş sürecini takip etmekte, böylelikle yatırımcıların fiyatları tahmin etmesi ve olağan dışı getiriler elde etmesi mümkün görünmemektedir. EPH'ye göre altın fiyatlarının tahmini de mümkün değildir. Ancak Daniel Kahneman ve Amos Tversky'nin 1974 ve 1979 yıllarındaki çalışmalarının öncülüğünde geliştirilen davranışsal finans teorisinin açıklamaları, EPH'nin iddialarının aksini savunmaktadır. Ayrıca bilgisayar teknolojilerinin sunduğu geliştirilmiş analiz imkanları, finansal piyasa endekslerinin ya da finansal varlık fiyatlarının öngörülmesi konusunda fırsatlar sunabilmektedir. Finansal yatırımlarda istatistiksel, ekonometrik analizler, temel ve teknik analiz yöntemleri, yapay zeka (makine öğrenmesi, derin öğrenme) yöntemleri sıklıkla kullanılmaktadır. Bunlara ilave olarak son dönemde çok daha hızlı hesaplamalar yapabilen kuantum bilgisayar teknolojileri geliştirilmiştir.

Altın gerek akademik çalışmalarda gerekse de finansal piyasalarda popüler bir varlıktır. Sadece ekonomi-finans haberlerinde değil sıradan gazetelerde ya da internet haber sitelerinde ön sıralarda fiyatı açıklanan önemli göstergelerdendir. En son geliştirilen para türü olan kripto paraların ilki olan Bitcoin, "dijital altın" olarak da anılmakta, kıymetli olan, iyi olanlar altınla özdeşleştirilmekte ya da ilişkilendirilmektedir. Arzının sınırlı olması, altının en bilinen ve değerini etkileyen özelliklerinden biridir. Altının para olarak kullanımının yanında finansal varlık olarak kullanımı, süs eşyası veya mücevher olarak kullanımı, endüstriyel kullanımı, tasarruf aracı olarak kullanımı gibi önemli kullanım özellikleri bulunmaktadır.

Altın fiyatı, değişen risk algılarının yakından takip edilen bir göstergesi olmaya devam etmektedir (Swamy ve Lagesh, 2023: 1). Dünyada son dönemde artan savaş, iç savaş, ekonomik kriz vb. karışıklıklar, altına olan ilginin daha da artmasına neden olmaktadır. Dünya Altın Konseyi tarafından gerçekleştirilen "Merkez Bankası Altın Rezervleri Anketi 2025"e göre katılımcıların yüzde 95'i, 2025 yılı için altın rezervlerinin artacağını, yüzde 5'i ise rezervlerin değişmeyeceğini öngörmektedir. Ayrıca merkez bankalarının son üç yılda, önceki 10 yıldaki ortalamadan oldukça fazla bir şekilde, 1.000 tonun üzerinde altın biriktirdikleri belirtilmektedir. Birikim hızındaki bu artışın, jeopolitik ve ekonomik belirsizlik ortamında gerçekleştirildiği ifade edilmektedir. 2025 yılındaki daha fazla altın biriktirme planlarını yönlendiren temel konulardan bazıları: Altının kriz dönemlerindeki performansı, portföy çeşitlendirmesi ve enflasyondan korunma imkanları sunmasıdır (World Gold Council, 2025).

Altın piyasalarının genel özelliklerine kısaca değinmek gerekirse; günümüzde altın piyasalarındaki işlemlerin büyük bir kısmı, tezgâhüstü spot ve türev piyasalarda gerçekleştirilmektedir. Ayrıca dünya altın borsalarının gelişiminin spot işlemlerden vadeli işlemlere doğru evrildiği gözlenmektedir (İncekara ve İncekara, 2016: 137).

Geleneksel olarak altın, gelecekteki enflasyonun öncü göstergesidir (Malliaris ve Malliaris, 2013: 1). Malliaris ve Malliaris (2013), petrol fiyatındaki artışların enflasyon endişelerine katkıda bulunduğunu ve bunun da altın fiyatının artmasına neden olabileceğini iddia etmenin makul bir düşünce olduğunu belirtmektedirler. Altın, enflasyona karşı bir korunma aracı olarak kabul edilmektedir (Ping vd., 2016: 1). Altın gibi kıymetli metaller, süs eşyası veya mücevher görülmesinin yanında yerli olmayan kredilerin geri ödenmesi ve enflasyonun yönetilmesi için bir güvence olarak tüm ulusların merkez bankalarında tutulmaktadır (Tripurana vd., 2022: 274).

Bu çalışmanın amacı, altın fiyatlarının Rassal Orman (RF), Destek Vektör Regresyonu (SVR), Aşırı Gradyan Artırma (XGBoost) makine öğrenmesi yöntemleri ve Uzun Kısa-Dönem Hafıza (LSTM) derin öğrenme yöntemi kullanılarak tahmin edilmesidir. Çalışmada kullanılan yöntemler, yapay zeka tahmin yöntemleri arasında tahmin performansı açısından tercih edilen yöntemlerdir. Altın fiyatlarının tahmini bireysel-kurumsal yatırımcılar ve risk yöneticileri için önemlidir. Özellikle merkez bankaları tarafından altının rezerv olarak saklandığı düşünüldüğünde, tahminlerin önemi daha da artmaktadır. Elde edilen model, altın yatırımlarına ilgisi olanlarca kullanılabilecektir. Diğer taraftan altın fiyatlarının tahmini, ilgili piyasanın zayıf formda etkinliği ile ilgili bilgi sağlamaktadır. Elde edilen bulgular aynı zamanda altın fiyatlarını etkileyen çeşitli faktörlerin değerlendirilmesini sağlamaktadır. Çalışmada açıklayıcı değişken (girdi) olarak farklı sınıflara ait önemli global değişkenler yanında ABD ile ilgili önemli endeksler ve emtia endeksleri kullanılmaktadır. Literatürdeki diğer çalışmalara göre nispeten daha fazla sayıda değişken tahmin modelinde yer almaktadır. Araştırmada makine öğrenmesi yöntemlerinin yanında derin öğrenme yöntemlerinden zaman serileri tahmininde en çok tercih edilen LSTM modeli de tercih edilmiştir. Bunun yanında açıklanabilir yapay zeka (Explainable Artificial Intelligence - XAI) da çalışma kapsamına dahil edilmektedir. Son olarak çalışma sonunda oldukça yüksek R^2 değeri ile MAE (Ortalama Mutlak Hata) değerleri elde edilmektedir.

Çalışmanın buraya kadarki giriş bölümünü takiben ikinci bölümde literatür incelemesi, üçüncü bölümde çalışmanın yöntemi açıklanmaktadır. Dördüncü bölümde veri ve tanımlayıcı istatistikler, beşinci bölümde ampirik bulgular ve tartışma yer almaktadır. Çalışmanın son bölümünde ise sonuç açıklamaları yer almaktadır.

2. LİTERATÜR İNCELEMESİ

Bu bölümde altın fiyatının tahmini, altın fiyat yönünün tahmini, altın volatilitesinin tahmini, altın fiyatlarıyla getiri ve volatilité açısından ilişkili değişkenler üzerine literatürdeki çalışmalar açıklanmaktadır. Söz konusu tahminler spot ya da vadeli piyasalar üzerine gerçekleştirilmektedir.

Altın fiyat ve volatilitesine etki eden faktörler ile ilgili çalışmalar literatürde önemli yer tutmaktadır. Söz konusu çalışmaların incelenmesi, altın fiyatlarının tahmininde hangi değişkenlerin modele dahil edilebileceği konusunda da önemli ön bilgi verebilmektedir. Malliaris ve Malliaris (2013) petrol, altın ve Avro'nun fiyat davranışları arasındaki karşılıklı ilişkileri araştırmaktadırlar. Araştırma sonucunda petrol, altın ve Avro piyasalarının etkin olduğu, ancak kendi aralarındaki ilişkilerin sınırlı olduğu açıklanmaktadır. Mensi vd. (2013), S&P500 ve emtia piyasaları arasında önemli getiri ve volatilité aktarımı olduğunu gösteren sonuçlar elde etmektedir. Özellikle S&P500 endeksindeki geçmiş şoklar ve dalgalanmalar petrol ve altın piyasalarını güçlü bir şekilde etkilemektedir. Yine Malliaris ve Malliaris (2015), bir iş döngüsü içerisinde ve çeşitli aşamalarda altın getirilerinin davranışını geleneksel finansal değişkenlerle araştırmışlar, çalışmanın sonucunda altın getirilerinin çeşitli rejimlerdeki farklı belirleyicilere bağlı olduğunu tespit etmişlerdir. Ping vd. (2016), altın ile ABD doları arasındaki volatilité yayılım ilişkisini analiz etmişler, analiz sonucunda altın ve ABD doları arasında eş-hareket ve oynaklık taşmasının var olduğu sonucuna ulaşmışlardır. Yüksel ve Akkoç (2016), altın fiyatlarını etkileyen faktörleri analiz ettikleri çalışmanın nedensellik analizi sonuçlarında, çalışmada kullanılan değişkenlerden sadece petrolün altın fiyatlarını öngörmeye kullanılabileceği, bunun yanında varyans ayrıştırması sonuçlarında ise altın fiyatında meydana gelen şokun yaklaşık %97 oranında kendi geçmişinden kaynaklandığı açıklanmaktadır. Buna göre altın yatırımcıları, teknik analiz kullanımı ile tutarlı sonuçlara ulaşabileceklerdir. Qian vd. (2019), altın fiyatının belirleyicileri üzerine yaptıkları araştırmada, TÜFE hariç çalışmada kullanılan diğer faktörlerin (ABD dolar endeksi, federal fon oranı, döviz kuru, petrol fiyatı, S&P500), altın fiyatı üzerinde negatif bir etkiye sahip olduğunu belirlemişlerdir. Madziwa vd. (2022), altın fiyat tahminini yıllık verilerle ve geleneksel ekonometrik modellerle gerçekleştirmişlerdir. Buna göre altın talebi, altın fiyatının Granger nedeni iken, hazine bonusu faiz oranı altın fiyatının Granger nedeni değildir.

Belirsizlik ya da volatilité endeksleri de altın vb. varlıkların tahmininde önemli değişkenler olarak öne çıkmaktadır. Balcılar vd. (2016), ekonomik ve politika belirsizliği göstergelerinin döviz kuru veya petrol fiyatlarına göre altın fiyatlarının daha temel belirleyicisi olabileceğini belirtmektedirler. Buna göre çalışmalarında çeşitli politika ve hisse senedi piyasası belirsizliği ölçümlerinin altın fiyatı getirileri ve oynaklığı üzerindeki etkilerini araştırmışlardır. Analiz sonuçlarına göre çeşitli belirsizlik ölçümlerinden hem altın getirilerine hem de volatilité yönünde önemli nedensellik kanıtı elde etmişlerdir. Ancak düşük veri frekanslarında (çeyreklik veri) istatistiksel olarak daha güçsüz kanıtlara ulaşmışlardır. Shahzad vd. (2017), altı önemli emtianın getirilerinin ve oynaklığının, ekonomik politika belirsizliği (EPU) ve yatırımcı duyarlılıkları ile öngörülebilirliğini incelemektedirler. Araştırma sonucunda yatırımcıların duyarlılıklarının emtia getirilerinin ortalaması ve varyansı üzerinde EPU'ya kıyasla daha derin bir nedensel etkiye sahip olduğunu tespit etmişlerdir. Bilgin vd. (2018), özellikle dört belirsizlik ölçütüne odaklanarak altın fiyatının belirleyicilerini araştırmışlar ve detaylı sonuçlara ulaşmışlardır. Araştırma sonucuna göre; altın fiyatları petrol fiyatındaki negatif değişikliklere pozitif tepki vermekte, bu sonuç altın ve petrol arasındaki ikame etkisinin geçerliliğini ima etmektedir. Ayrıca altın fiyatlarının ABD reel efektif döviz kurundaki pozitif bir değişikliğe negatif tepki verme eğiliminde olduğu ve bu bulgunun teorik beklentiyle, yani zayıf bir doların daha yüksek bir altın fiyatına yol açmasıyla uyumlu olduğu belirlenmiştir. Ek olarak, altın fiyatının VIX endeksindeki negatif değişikliklere pozitif bir tepki verdiği belirlenmiştir. Son olarak, altın fiyatlarının global EPU (GEPU) endeksindeki pozitif değişikliklere pozitif bir tepki verdiği belirlenmiş, bu sonucun altının dünyada yüksek ekonomik ve politik belirsizlik zamanlarında güvenli bir liman olarak kabul edildiği şeklinde açıklanmıştır. Buna karşılık, ekonomik ve politik koşullar iyileştiğinde altın fiyatlarının düşme olasılığı daha düşük bulunmuştur. Qadan (2019), yatırımcıların risk iştahı ile kıymetli metallerin fiyatları arasındaki ilişkiye odaklanmış, VIX endeksinin iki bileşene (gerçekleşen volatilité ve stokastik volatilité risk primi) ayrıştırarak kullanmıştır. Risk iştahı, stokastik volatilité risk primi ile temsil edilmiştir. Analiz sonucunda kıymetli metallerin fiyat ve oynaklığının, hisse senedi piyasasında hakim olan yatırımcıların ekonomik belirsizliğinden ve risk iştahından kaynaklanan şoklar tarafından yönlendirildiği tespit edilmiştir.

Kangalli Uyar vd. (2024), kıymetli metal fiyatlarındaki balonları tespit edip, fiyatlardaki balon oluşumunun temel faktörlerini makine öğrenmesi yöntemleri ile araştırmışlardır. Çalışma sonucunda altın fiyatlarındaki balon

oluşumlarına neden olan en önemli üç faktör; ABD 10 yıllık devlet tahvil getirileri, ABD için M1 büyümesi ve ABD Tüketici Güven Endeksi olarak tespit edilmiştir. Genel olarak altın, gümüş ve platin fiyat balonlarının oluşumunda makroekonomik faktörler önemli rol oynarken, paladyum için ise finansal faktörler ve belirsizlik değişkenleri önemli rol oynamaktadır.

Literatürde istatistiksel veya ekonometrik analizlerin yanında makine öğrenmesi, derin öğrenme vb. yöntemlerle doğrudan altın fiyatı, yönü veya altın volatilitesinin tahminleri üzerine gerçekleştirilen çalışmalar da ilgi görmektedir. Altın fiyat ve yön tahmini üzerine gerçekleştirilen çalışmalardan Risse (2019), altının aşırı fiyat (excess return) dinamiklerini tahmin etmek için ayrik dalgacık dönüşümü yaklaşımı ile destek vektör regresyonunu birleştirmektedir. Bu birleşik yöntemle (DWT-SVR) elde edilen sonuçların, tek bir tahmin edici ile elde edilen sonuçlardan oldukça başarılı olduğunu belirtmekte, özellikle enflasyon, ticaret ağırlıklı döviz kuru ve iki emtia endeksinin (S&P Goldman Sachs Commodity Index (GSCI) ve Commodity Research Bureau Index (CRB)) özellikle ilgi çekici olduğunu vurgulamaktadır. Das vd. (2022), ham petrol ve altın fiyatlarının tahmininde Aşırı Öğrenme Makinesi (Extreme Learning Machine- ELM) yöntemini birkaç şekilde geliştirerek kullanmaktadır. Önerilen tahmin modelinin petrol ve altın fiyatlarını tahmin etmek için daha iyi bir araç olabileceğini belirtmiştir. Cohen ve Aiche (2023), hisse senedi endeksi, emtia ve tahvil sınıflarından oluşan verilerle gelecek altın fiyatlarını tahmini için çalışmışlardır. Ayrıca analizlerde üç veri katmanı (ham, gecikmeli ve hareketli ortalama) açıklayıcı değişken olarak kullanılmıştır. Araştırma sonucunda incelenen modeller, altının üç günlük hareketli ortalamasının mevcut günlük altın fiyat hareketine en yüksek katkısı sağladığını, ardından altının 1 ila 4 günlük gecikmeli verilerinin geldiğini tespit etmiştir. En etkili hisse senedi endekslerinin ASX, S&P500, TA35, IBEX ve AEX'in bir günlük gecikmeli verileri olduğu belirlenmiştir. Ayrıca ABD ve Japonya tahvil getirileri ile gaz ve gümüş verilerinin gecikmeleri, bir gün gecikmeli VIX değişkenlerinin de altın fiyatlarının tahmininde etkili oldukları belirlenmiştir. VIX değerinin altın fiyatları üzerinde önemli bir etkisinin olması, ekonomik belirsizliğin altın fiyatlarını etkilediğini ortaya koymaktadır. Gradyan Artırmalı Regresyon Ağaçları (Gradient Boosted Regression Trees – GBRT) ve XGBoost modellerinin, altın yatırımları konusunda bilinçli kararlar vermek için değerli modeller olabilecekleri belirtilmektedir. XGBoost modeli, altın fiyatı hareketlerini tahmin etmede en yüksek doğruluk seviyesini göstermiştir.

Swamy ve Lagesh (2023), Twitter mutluluğu ile ABD altın fiyatları arasındaki ilişkiyi araştırmışlardır. Araştırma sonucunda Twitter mutluluğu ile altın fiyatı arasında hem zaman hem de frekans alanlarında güçlü bir korelasyon olduğu ve nedensellik analizine göre Twitter mutluluğunun altın fiyatını yönlendirdiği tespit edilmiştir. Böylece Twitter ruh halinin altın fiyatını tahmin edebileceği ve altın yatırımı kararlarında dikkate alınabileceği ifade edilmiştir. Yang vd. (2024), Şanghay Vadeli İşlemler Borsası (SHFE), Londra Altın Borsası (LGX) ve New York Ticaret Borsası'ndaki (NYMEX) altın fiyatlarını tahmin etmektedirler. Oluşturulan hibrit model, tahmin hataları ve yön tahmininin doğruluğu açısından diğer geleneksel tahmin modellerinden daha iyi performans göstermektedir. Duman vd. (2025), çeşitli makine öğrenmesi yöntemleriyle gerçekleştirdikleri altın fiyat tahminlerinde, sırasıyla en başarılı altın fiyatı tahmincilerinin WTI, VIX endeksi, S&P500 ve dolar endeksi olduklarını belirtmektedirler. Altın fiyatlarının en iyi tahmin edildiği makine öğrenmesi yönteminin ise RF yöntemi olduğu belirlenmiştir. Bazı çalışmalarda altın ve Bitcoin birlikte analiz edilerek elde edilen sonuçlar karşılaştırılmaktadır. Basher ve Sadorsky (2022), altınla Bitcoin fiyatlarını tahmin ettikleri çalışma sonucunda, teknik göstergeler ve petrol fiyat oynaklığının öngörü açısından en önemli öznitelikler olduklarını belirtmişlerdir.

Altın volatilitesinin tahmininde de yapay zekâ yöntemlerinden yararlanılmaktadır. Kristjanpoller ve Minutolo (2015), altın fiyat volatilitesinin ANN-GARCH hibrit modeli ile tahmin etmeye çalışmışlardır. Sonuçlar, tek başına GARCH yöntemiyle karşılaştırıldığında, YSA-GARCH kullanılarak yapılan tahminlerde MAPE değerinde %25'lik bir azalma gerçekleştirilerek tahmin başarısı artırılmıştır. Fang vd. (2018), ABD altın vadeli fiyat volatilitesini makroekonomik değişkenlerle tahmin etmeye çalışmışlardır. Çalışmanın ampirik sonuçları, makroekonomik değişkenlerin özellikle küresel mali kriz sırasında ve sonrasında altın oynaklığı üzerinde önemli bir etkiye sahip olduğunu göstermektedir. Ayrıca çalışmada uygulanan temel bileşenler analizi sonuçlarına göre, temel bileşenler tahmin doğruluğunu iyileştirmektedir.

Buraya kadar ki açıklamalarda görüldüğü gibi altın fiyatlarının tahmininde veya altınla diğer değişkenler arasındaki ilişkili analizinde çok sayıda farklı türde faktör ele alınmıştır. Pattnaik vd. (2023), altın yatırımı üzerine bibliyometrik bir inceleme gerçekleştirmişler, aynı zamanda gelecekteki çalışmalar için önerilerde bulunmuşlardır. Söz konusu çalışmada, altın üzerine gelecekteki araştırmaların farklı makroekonomik faktörler kullanılarak fiyat tahminine odaklanabileceğini de önermektedirler. Qian vd. (2019), altın fiyatının belirleyicileri üzerine yapılacak gelecekteki araştırmalar için VIX, çarpıklık, GEPU, partizan çatışması (PC) ve EPU gibi belirsizlik ölçütlerine odaklanılmasını önermektedirler.

3. YÖNTEM

Bu kısımda tahmin için gerekli verilerin toplanmasından tahmin sonuçlarının yorumlanmasına kadar ki süreçte uygulanan yöntemler açıklanmaktadır.

3.1. Veri Ön İşleme

Makine öğrenmesinde veri ön işleme aşamasında verilerin elde edilmesi, verilerin temizlenmesi, verilerin dönüştürülmesi, verilerin eğitim-test sınıflarına ayrılması aşamaları bulunmaktadır. Verinin özelliklerine göre her bir aşamanın yerine getirilmesi tahmin performansını etkileyebilecektir. Analiz için gerekli veriler, birincil veya ikincil kaynaklardan elde edilip ilgili analiz programına yüklenmektedir. Söz konusu veriler içerisinde eksik veriler varsa belirlenen stratejiye göre sorun giderilmektedir. Makine öğrenmesinde veriler belirlenen oranlarda eğitim (train) ve kontrol (test) olarak bölünmektedir. Verilerin dönüştürülmesi aşamasında farklı ölçekteki değişkenler belli bir aralığa getirilmekte, böylece tahminlerin doğruluğu artırılmaktadır.

3.2. Öznitelik Seçimi

Öznitelik seçimi için geliştirilmiş çeşitli yöntemler bulunmaktadır. Örneğin korelasyon matrisi, LASSO, Shapley Katkısız Açıklama Yöntemi (Shapley Additive Explanations – SHAP) vb. Öznitelik seçiminde üç temel strateji vardır: Tek değişkenli istatistik, model tabanlı seçim ve yinelemeli seçim (Müller ve Guido, 2017: 236). Ancak ekonomik alanla ilgili tahminlerde ekonomi teorileri önemli bilgiler sunmaktadır. Gerek öznitelik seçiminde gerekse bulguların yorumlanmasında söz konusu teoriler dikkate alınmaktadır.

En sık kullanılan yöntemlerden biri olan korelasyon yöntemi, değişkenler arasındaki doğrusal ilişkilerin yönü ve gücü (derecesi) hakkında önemli bilgiler sunmakta, bu nedenle de öznitelik seçiminde kullanılabilir. Aralarında ilişki tespit edilen değişkenler öznitelik olarak seçilebilmekle beraber, aralarında yüksek ilişki bulunan değişkenler, bu yöntemle tespit edilip sonrasında ilgili değişkenlerden biri veya birkaçı elimine edilebilmektedir. Böylelikle çoklu doğrusal bağlantı sorununa önlem alınmaktadır.


3.3. Makine Öğrenmesi Modelleri

Bu başlık altında, çalışmada kullanılan RF, SVR, XGBoost makine öğrenmesi yöntemleri ve LSTM derin öğrenme yöntemi açıklanmaktadır. Bu yöntemler, makroekonomik/finansal zaman serilerinin fiyat, getiri ve volatilité tahminlerinde literatürde en çok kullanılan geleneksel yöntemlerdendir.

3.3.1. Rassal Orman (Random Forest – RF)

RF, önemli topluluk öğrenmesi (ensemble learning) yöntemlerinden biridir. Topluluk öğrenmesi; makine öğrenmesinde daha iyi tahminlerin elde edilebilmesi amacıyla birden fazla tahmin modelinin bir araya getirilerek daha güçlü bir model oluşturulmasıdır.

Çoğu durumda, bu topluluğun cevabı, uzman bir kişinin cevabından daha iyidir. Bu duruma kalabalığın bilgeliği denir. Benzer şekilde, bir grup öngörücünün (sınıflandırıcı veya regresörler) tahminleri bir araya getirildiğinde, genellikle en iyi tek öngörücünden daha iyi tahminler elde edilmektedir (Géron, 2019: 189). Böylelikle Büyük Sayılar Yasası sayesinde aşırı öğrenme azaltılmakta yani genelleme gücü artırılmaktadır (Breiman, 2001: 29). Yönteme göre, bootstrap (bagging) örnekleme yani yerine koymalı yeniden örnekleme ile farklı alt veri setleri oluşturulup, her veri seti için ayrı bir karar ağacı eğitilmektedir. En sonunda tahminler, ağaçlar arasında sınıflandırma için “çoğunluk oyu (majority vote)” veya regresyon için “ortalama” ile birleştirilmektedir (Breiman, 2001; Hull, 2021: 138). Bir RF modelinden tahmin oluşturma süreci aşağıda Şekil 1’de gösterilmektedir (Hull, 2021: 137).



Şekil 1: RF modelinden tahmin oluşturma

Regresyon ve sınıflandırma için kullanılabilen RF, en yaygın kullanılan makine öğrenimi yöntemleri arasındadır. RF algoritmaları çok güçlü algoritmalar olup genellikle parametrelerde yoğun ayarlamalar yapmadan iyi çalışmakta ve verilerin ölçeklendirilmesini gerektirmemektedirler (Müller ve Guido, 2017: 87).

3.3.2. Aşırı Gradyan Artırma (Extreme Gradient Boosting – XGBoost)

Önemli topluluk öğrenmesi yöntemlerinden bir diğeri de XGBoost'dur. Yöntem, Chen ve Guestrin (2016) tarafından geliştirilmiştir. XGBoost algoritması, karar ağaçlarının artırma (boosting) metodu için geliştirilmiş versiyonu olup, ağaç güçlendirme sistemlerinde ölçeklenebilirlik, hesaplama verimliliği, sınıflandırma-regresyon problemlerinde performans artışı sağlamayı amaçlamaktadır. Uygulama aşamasında önce ilk yaprak oluşturulur, ardından önceki tahmin hataları minimize edilerek yeni ağaçlar oluşturulur. Hata minimizasyon işlemi, gradyan iniş optimizasyon yöntemi ile gerçekleştirilir (Çavdaroglu ve Arık, 2024: 277).

3.3.3. Destek Vektör Regresyonu (Support Vector Regression – SVR)

Destek Vektör Makinesi (SVM), doğrusal veya doğrusal olmayan sınıflandırma, doğrusal veya doğrusal olmayan regresyon ve hatta aykırı değer tespiti yapabilen güçlü, çok yönlü bir makine öğrenmesi modelidir. SVM, makine öğrenmesi alanındaki en popüler modellerden biridir (Géron, 2019: 153). SVM, ilk olarak Boser vd. (1992) tarafından geliştirilmiştir. Daha sonra SVM, "Çekirdek Makinesi (Kernel Machine)" adı altında geliştirilmiş, son yıllarda popüler hale gelmiştir (Alpaydın, 2014: 349). SVR, SVM algoritmasının regresyon problemine uyarlanmış halidir. SVR'nin doğrusal regresyondan temel farkı: Doğrusal regresyon analizinde hata değerleri minimize edilmeye çalışılırken, SVR'de bu değerler belirli bir aralıkta tutulmaya çalışılmaktadır (Özdemir, 2020: 207).

3.3.4. Uzun Kısa Süreli Bellek (Long Short-Term Memory – LSTM)

Sıralı (ardışık) verilerin tahmininde ilk olarak Yinelemeli Sinir Ağları (Recurrent Neural Network - RNN) geliştirilmiş, ancak söz konusu modeldeki uzun dönem bağımlılık sorununu çözmek için LSTM ve GRU modelleri geliştirilmiştir. RNN'lerle ilgili ilk sorun, uzun veri dizileri girdi olarak kullanıldığında kaybolan gradyan sorunuyla karşılaşılmasıdır (Hull, 2021: 264). LSTM, özellikle zaman serilerinde en çok kullanılan derin öğrenme algoritmasıdır. İlk olarak Hochreiter ve Schmidhuber (1997) tarafından literatüre sunulan yöntem, sonrasında Ger vd. (2000) tarafından geliştirilmiştir. LSTM modelinin ilk versiyonunda giriş kapısı (input gate) ve çıkış kapısı (output gate) varken, sonraki yeni versiyonuna unutma kapısı (forget gate) da eklenmiştir (Gers vd. 2000).

3.4. Modellerin Performans Değerlendirme Kriterleri

Regresyon tahmin modellerin performanslarının değerlendirilmesinde genellikle Ortalama Hata Karesi (Mean Squared Error - MSE), Karekök Ortalama Hata Karesi (Root Mean Squared Error - RMSE), Ortalama Mutlak Hata (Mean Absolute Error - MAE), Ortalama Mutlak Yüzde Hata (Mean Absolute Percentage Error - MAPE), Determinasyon Katsayısı (R-squared - R^2) ve Düzeltilmiş R-kare (Adjusted R-squared - R_{adj}^2) yöntemleri kullanılmaktadır. Bu çalışmada kullanılan performans kriterlerinin hesaplamaları aşağıda gösterilmektedir.

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

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

Denklemlerdeki y_i ; gerçek değer, $\hat{y}_i$; tahmin edilen değer, $\bar{y}$; gerçek ortalama değer ve n ; veri sayısını ifade etmektedir.

Yukarıdaki kriterlerden MAE değeri, hata terimlerini ifade ettiğinden mümkün olduğunca “sıfır” değerine yakın olması; R^2 değeri ise modelin açıklama gücünü ifade ettiği için mümkün olduğunca “bir” değerine yakın olması arzu edilmektedir.

3.5. Özniteliklerin Tahmin Sonucuna Etkilerinin Değerlendirilmesi

Model tahminlerini yorumlamak ve böylece hangi öznitelikliğin ne kadar etkili olduğunun belirlenmesi için öznitelik önemi yöntemleri geliştirilmiştir. Özniteliklerin yorumlanması için farklı özelliklere ve sınıflara sahip yöntemler bulunmaktadır. Bazı yöntemler model bazlı iken bazı yöntemler tüm modeller için uygulama imkanı sunmaktadır. Bu çalışmada söz konusu yöntemlerden ağaç temelli (tree-based) yöntem kullanılmaktadır. Bu yöntem, öznitelikliğin önemini hem görsel hem de sayısal olarak göstermektedir.

4. VERİ SETİ VE TANIMLAYICI İSTATİSTİKLER

Çalışmada kullanılan veri seti, literatür incelemelerinde altın fiyatlarının tahmininde sıklıkla kullanılan önemli verilerdir. Çalışmada 20.01.2006-11.07.2025 dönemine ait günlük frekanslı veriler kullanılmaktadır. Makine öğrenmesi ve derin öğrenme modelleri ile tahminlerde veri sayısının çok olması önemli olduğu için literatürde de yoğun olarak kullanıldığı gibi günlük frekanslı veriler tercih edilmiştir. Çalışmada tüm veri seti için eğitim-test oranı literatürdeki genel uygulamalar dikkate alınarak %80-%20, %75-%25 ve %70-%30 şeklinde ayrılarak ayrı ayrı denenmiştir. Livieris, Pintelas ve Pintelas (2020), örüntülerin değişkenliğini ve kararlılığını homojenleştirmek ve üstel eğilimi azaltmak için hem eğitim hem de test verilerinin doğal logaritma (ln) kullanılarak dönüştürüldüğünü belirtmektedir. Bu çalışmada kullanılan zaman serilerinden oluşan değişkenlerden durağanlık şartlarını sağlamayanlar logaritmik getiri, durağanlık şartlarını sağlayan değişkenler (ABD EPU ve VIX) ise sadece doğal logaritmaları alınarak kullanılmaktadır. Değişkenlerin durağanlıkları ADF testi ile incelenmiştir. Aşağıda Tablo 1’de, çalışmada kullanılan bağımlı değişken ve bağımsız değişkenlere ait bazı bilgiler açıklanmaktadır.

Tablo 1: Çalışmada kullanılan değişkenler

DEĞİŞKEN SINIFI	DEĞİŞKEN	SEMBOL	KAYNAK
Emtia Göstergeleri	Altın (ons) günlük kapanış fiyatı (USD)	Altın	Refinitiv Eikon (LSEG)
	Gümüş günlük kapanış fiyatı (USD)	Gümüş	Refinitiv Eikon (LSEG)
	Paladyum günlük kapanış fiyatı (USD)	Paladyum	Refinitiv Eikon (LSEG)
	Brent petrol günlük kapanış fiyatı (USD)	Brent	Refinitiv Eikon (LSEG)
Borsa/Finans Göstergeleri	Volatilite endeksi günlük kapanış değeri	VIX	www.vix.com
	S&P500 borsa endeksi günlük kapanış fiyatı (USD)	S&P500	www.investing.com
Makroekonomik ve Döviz Göstergeleri	ABD Ekonomik Politika Belirsizliği endeksi	ABD_EPU	www.policyuncertainty.com
	Avro-dolar döviz kuru	EUR/USD	Refinitiv Eikon (LSEG)
	ABD 10 yıllık hazine bono faiz getirisi	ABD_10-Y	www.investing.com

Çalışmada kullanılan açıklayıcı değişken açıklamaları şöyledir:

Brent petrol, ekonomik ve finansal açıdan çok önemli stratejik bir emtiadır. Petrol fiyatlarındaki değişimler doğrudan yatırım maliyetlerini etkilediği için ekonomik büyümeyi de etkilemekte, diğer taraftan enflasyona etkisi vb. nedenlerle dolaylı olarak ekonomik çevreleri etkilemektedir. Brent petrol aynı zamanda spot piyasalar yanında vadeli piyasalarda da işlem gören önemli bir finansal varlıktır.

S&P500 endeksi, dünya genelinde fon yöneticileri ve yatırımcılar tarafından “benchmark” (karşılaştırma ölçütü) olarak kullanılan, ABD borsasında işlem gören en büyük 500 şirketi kapsayan bir borsa endeksidir.

Altın, gümüş ve paladyum, hem sanayide kullanılan kıymetli emtialardan, aynı zamanda yatırım ve tasarruf aracı olarak da kullanılan finansal varlıklardandır.

Döviz kurları, maliyet etkisi ile enflasyon oranlarını etkilemekte, aynı zamanda ihracat ve ithalatın da önemli belirleyicileri arasında yer almaktadır. Euro/Dolar kuru, dünyada en çok işlem gören döviz paritesi olup hem ekonomik hem de finansal açıdan çok büyük öneme sahiptir.


ABD ekonomik politik belirsizlik endeksi (ABD EPU), Baker vd. (2015) tarafından geliştirilen ve günlük haberlere dayalı olarak hesaplanan orta ve uzun vadeli bir belirsizlik endeksidir. ABD, Worldometers verilerine göre 2025 yılı için yaklaşık 347 milyon nüfusu ile dünya nüfusunun yaklaşık %4,22'ini temsil etmesine rağmen, IMF 2024 verilerine göre yaklaşık 29,18 trilyon dolar nominal GSYH'si ile dünya ekonomisinin %26'sından fazlasını temsil eden, dünyanın ekonomik açıdan en güçlü ülkesidir. Dolayısıyla ABD için hesaplanan belirsizlikler, tüm küresel ekonomiyi de etkilemektedir.

VIX, Chicago Board Options Exchange (CBOE) tarafından, S&P500 opsiyon piyasasında beklenen 30 günlük volatilitiyi ölçmek amacıyla hesaplanan bir volatilité endeksi olup, korku endeksi olarak da bilinmektedir. Kısa vadeli olarak piyasa belirsizliği ve riskini ölçmek için kullanılan önemli bir göstergedir.

ABD 10 yıllık tahvil faizi, doların küresel değerini belirleyen, aynı zamanda uluslararası sermaye akışlarını etkileyen önemli bir referans faiz oranıdır.

Tablo 1'de görüldüğü gibi literatürdeki çalışmalar temel alınmakta, farklı türdeki öznelitlikler tahmin modeline dahil edilmekte ve modelin performansı artırılmaya çalışılmaktadır. Bunun yanında literatür bölümünde de açıklandığı gibi Pattnaik vd. (2023) tarafından altın fiyatlarının tahmininde makroekonomik faktörlere odaklanılması önerilmekte, Qian, Ralescu ve Zhang (2019) ise belirsizlik ölçütlerini önermektedir.

Çalışmada kullanılan değişkenler, zaman serisi değişkenleri olduğu için eksik veriler interpolasyon yöntemi ile tamamlanmıştır. Ayrıca ölçeklendirme yöntemlerinden StandardScaler yöntemi kullanılmıştır. Bunun yanında çalışmada nitel veri olmadığı için verilere kodlama (encoding) işlemi gerçekleştirilmemiştir. Aşağıda Şekil 2'de değişkenlerin zaman yolu grafiği gösterilmektedir.




Şekil 2: Değişkenlerin düzey değerlerinin zaman yolu grafikleri

Aşağıda Tablo 2'de tüm değişkenlerin özelliklerini gösteren tanımlayıcı istatistikler, Şekil 3'te de bağımsız değişkenler arasındaki korelasyonları hem sayısal hem de görsel olarak da gösteren ısı haritası (heat map) formatında korelasyon matrisi yer almaktadır.

Tablo 2: Tanımlayıcı istatistikler

	Ortalama	Std. Sapma	Min.	%25	%50	%75	Maks.	Gözlem Sayısı
Altın	1.433,93	519,59	538,60	1.161,58	1.318,88	1.750,55	3.432,19	5.081
Brent	77,49	23,46	19,33	60,67	74,49	95,49	146,08	5.081
Gümüş	20,63	6,90	8,86	15,66	18,32	24,67	48,41	5.081
ABD_EPU	126,04	98,28	3,32	65,51	99,00	151,79	1.026,38	5.081
Paladyum	973,34	641,07	159,50	542,00	771,00	1.184,10	3.180,29	5.081
EUR/USD	1,23	0,14	0,96	1,11	1,19	1,33	1,60	5.081
VIX	19,52	8,79	9,14	13,63	17,16	22,56	82,69	5.081
S&P500	2.511,00	1.382,68	676,50	1.364,30	2.075,00	3.363,00	6.280,46	5.081
ABD_10-Y	2,87	1,12	0,51	1,98	2,72	3,77	5,29	5.081

Tablo 2’de S&P500 endeksinin standart sapması en yüksektir. S&P500 endeksi her ne kadar ABD borsasının bir endeksi olsa da küresel olarak finansal piyasaların yönü hakkında bilgi verir. Kripto varlıklar dışındaki diğer yatırım araçlarıyla karşılaştırıldığında, hisse senetleri riski daha yüksek yatırım araçları olarak bilinmektedir. Hisse senedi yatırımlarının tahvil ya da bono yatırımları gibi garantili bir getirisi söz konusu değildir. Ayrıca hisse senedi yatırımları sistematik ve sistematik olmayan risklerden etkilenmektedir. Tablo 2’ye göre volatilitesi yüksek diğer varlıklar altın ve paladyumdur. Altın, finansal piyasalarda güvenilir liman (safe haven) olarak görülen bir varlıktır. Bu çalışmanın analizlerinin kapsadığı 20.01.2006-11.07.2025 döneminde küresel olarak çok önemli gelişmeler yaşanmıştır. Öncelikle dünyada ilk kez küresel ölçekte bir kriz olan 2008 krizi, ardından ABD başta olmak üzere tüm dünyada krizden çıkış için uygulanan parasal genişleme politikaları, sonrasında Avrupa Borç Krizi (2009-2015) ilk akla gelen ve ekonomik etkileri büyük olan olaylardır. Diğer önemli olaylar arasında Covid-19, Brexit, ABD-Çin ticari çekişmeleri ve son dönemdeki savaşlar sayılabilir. Paladyum da altın gibi kıymetli metaller sınıfına dahil olup spekülasyon yatırımlara konu olan bir emtiadır. Ayrıca altına kıyasla küçük bir piyasası olması nedeniyle, paladyum arz ve talepteki değişikliklerden kolayca etkilenebilmektedir.



Şekil 3: Isı haritası formatında korelasyon matrisi

Altın ve S&P500 endeksi arasındaki korelasyon 0,82’dir. Bu iki değişken küresel ölçekte gösterge olarak görülmekte ve yatırımcı davranışlarından etkilenmektedirler. Literatür incelemelerinde, altın fiyatlarının tahmininde sıklıkla S&P500 endeksinin kullanıldığı görülebilmekte veya aralarındaki ilişki araştırılmaktadır. EUR/USD kuru ve S&P500 endeksi arasındaki korelasyon da yüksektir (-0,70). ABD Merkez Bankası (FED) tarafından açıklanan faiz oranı artışları, bir taraftan doların değerini artırmakta (bu durumda EUR/USD kurunun düşmesi beklenir), diğer taraftan hisse senedi piyasalarını olumsuz etkilemekte, gelişmekte olan ülkelerden sermaye çıkışlarına neden olabilmektedir. S&P500 endeksi ve paladyum arasındaki korelasyon 0,66 olarak hesaplanmıştır. Paladyum, endüstriyel bir metaldir ve otomotiv üretiminde kullanılmaktadır. Böylece ekonomik büyüme durumlarında her iki varlık da olumlu olarak etkilenmektedir. VIX ve kıymetli metaller arasında risk algısı

nedeniyle pozitif ilişkiler beklenmekte, ancak söz konusu ilişki dönemsel olarak değişim gösterebilmektedir. Şekil 3'e göre VIX ve kıymetli metaller arasında farklı yönlerde ancak oldukça düşük ilişkiler tespit edilmiştir.

Altın fiyat tahmininde kullanılabilecek değişken seçiminde, aralarında çok yüksek derecede korelasyon olan değişkenler elenmiştir. Bu kapsamda STOXX Europe 600 borsa endeksi, S&P500 borsa endeksi ile; ABD döviz kuru endeksi (DXY), EUR/USD ile; platin de paladyum ile aralarındaki yüksek korelasyon nedeniyle modele dahil edilmemiştir. Böylelikle çoklu doğrusal bağlantı sorunundan (ÇDBS) kaçınılmıştır.

Yukarıda belirtilen değişkenlerin yanında söz konusu değişkenlerden türetilen hareketli ortalama (moving average – MA), üssel hareketli ortalama (exponential moving average – EMA), Hareketli Ortalama Yakınsama Uzaklaşması (moving average convergence divergence – MACD), değişim oranı (rate of change - ROC), Z-Score değerleri de açıklayıcı değişken olarak tahmin modeline dahil edilmektedir. Hareketli ortalama değerleri, genellikle zaman serilerinin eğilim (trend) özelliklerini yakalamak için kullanılmaktadır. Makine öğrenmesi modellerinde volatilité değişkeni de belirsizliği hesaplamak için öznitelik olarak modele eklenebilmektedir. MACD ise makine öğrenmesinde sıklıkla kullanılan momentum (ivme) indikatörlerinden biridir. Değişim oranı, fiyatın belirli bir süre içinde yüzdesel olarak ne kadar arttığını veya azaldığını ölçen momentum göstergelerindendir. Z-Score, veri değerlerinin ne kadar normalden saptığını gösteren bir ölçümdür. Böylece farklı sınıflara ait teknik indikatörler modele dahil edilmiştir.

5. AMPİRİK BULGULAR

Bu çalışmada, altın fiyat endekslerinin tahminleri Python programlama dili ile gerçekleştirilmiştir. Daha önce belirtildiği gibi tüm veri seti için eğitim-test oranı literatürdeki genel uygulamalar dikkate alınarak %80-%20, %75-%25 ve %70-%30 şeklinde ayrılarak ayrı ayrı denenmiştir. Bunun yanında en uygun hiper parametrelerin belirlenebilmesi için GridSearch işlemi gerçekleştirilmiştir.

Çalışmada model performansının değerlendirilmesinde MAE ve R^2 değerleri kullanılmaktadır. Özellikle aşırı öğrenme (overfitting) sorunu için R^2 değeri train ve test sonuçları için ayrı ayrı alınmaktadır. Çalışmada kullanılan gözlem sayısının nispeten az olmaması, bir taraftan aşırı öğrenme konusunda şüpheleri azaltsa da diğer taraftan modelin güvenilirliği için aşağıda bazı ilave analizler de gerçekleştirilmiştir. Bu kapsamda makine öğrenmesi yöntemlerinde k-katlı çapraz doğrulama (k-fold cross validation) işlemi gerçekleştirilmiş, ardından tahmin modellerinin hata dağılımları kontrol edilmiştir.


Öncelikle çapraz doğrulama işlemi ile veri seti 5 katmana ($k = 5$) ayrılarak tahminler gerçekleştirilmekte, buradan “ortalama” performans metrikleri elde edilmektedir. Aşağıda söz konusu değerler Tablo 3'te birlikte gösterilmektedir.

Tablo 3: Performans Sonuçları

MODEL	Train-Test Oranı	R^2 (Test)	R^2 (Train)	MAE (Test)
RF	%70-%30	0,6181	0,7285	0,0059
XGBoost	%70-%30	0,6025	0,6839	0,0060
SVR	%70-%30	-2,5184	-5,0886	0,0229
LSTM	%70-%30	0,6115	0,6618	0,0061
RF	%75-%25	0,6274	0,7193	0,0059
XGBoost	%75-%25	0,5952	0,6729	0,0061
SVR	%75-%25	-2,4101	-4,8887	0,0229
LSTM	%75-%25	0,6044	0,6557	0,0062
RF	%80-%20	0,6232	0,7154	0,0062
XGBoost	%80-%20	0,5867	0,6716	0,0064
SVR	%80-%20	-2,1561	-4,8604	0,0230
LSTM	%80-%20	0,6226	0,6622	0,0064

Elde edilen bulgular, test değerine göre altın fiyatının en iyi tahmininde %75-%25 train-test oranı için 0,6274'lük bir R^2 değerini göstermektedir. Buna göre RF modeli, analiz kapsamındaki modeller arasında altın fiyatını en iyi tahmin eden model olmaktadır. İkinci en iyi model LSTM modelidir ancak SVR model sonuçları anlamsızdır. GridSearchCV sonucunda çalışma kapsamındaki en iyi model olan RF modeline ait hiper parametreler: 'max_depth': 15, 'max_features': 'sqrt', 'min_samples_leaf': 10, 'n_estimators': 400.


Aşağıda çalışma kapsamında tahmin performansı en iyi modele (RF) ait hata terimlerinin dağılımları grafik olarak gösterilmektedir. X ekseninde modelin tahmin ettiği getiriler, y ekseninde ise gerçek getiriler ile tahmin edilen getiriler arasındaki fark yani hata değerleri karşılaştırılmaktadır. Kırmızı çizgi hatanın sıfır olduğu doğruyu gösterirken mavi noktalar gözlem değerlerini temsil etmektedir.



Şekil 4: RF tahmin modeli için hata terimlerinin dağılımı

Şekil 4'te RF tahmin modelinden elde edilen hata terimlerinin dağılımı gösterilmektedir. Buna göre tahmin modelinden elde edilen hata terimlerinin normal dağılımlı olması beklenmektedir. Elde edilen RF modelinin hatalarının genellikle sıfır ortalama etrafında dağıldığı görülmektedir.

Model tahmin sonuçlarının açıklanmasında özneliliklerin önemi irdelenmektedir. “Öznitelik önemi” yönteminde her bir özneliliğin (feature) tahmin performansına katkısı görülmektedir. Buna göre tahmin modellerinden en iyi performansa sahip model olan RF tahmininin özneliliklerin önemi sonucu aşağıda Şekil 5'te gösterilmektedir.



Şekil 5: RF tahmin modeli için özneliliklerin önemi

Yukarıdaki Şekil 5'e göre altın fiyat tahmini için en önemli öznitelikler sırasıyla gümüş, ABD 10 yıllık faiz oranı ve ABD 10 yıllık faiz oranı Z skoru ile S&P500 borsa endeksidir. Özellikle altın ile aynı emtia sınıfına ait olan gümüş getirilerinin altın getiri tahmininde çok büyük paya sahip olduğu görülebilmektedir.

6. SONUÇ

Altın fiyatı, finansal piyasalarda işlem gören bir varlık, gelecekteki enflasyonun ve risk algısının önemli bir göstergedir. Aynı zamanda altın fiziki olarak da talep edilen önemli bir reel varlıktır. Altın fiyatlarının tahmini bireysel ya da kurumsal yatırımcılar kadar devletler açısından önemlidir. Bu çalışmada altın fiyatlarının tahmini makine öğrenmesi ve derin öğrenme algoritmaları ile gerçekleştirilmektedir. Çalışmada emtia, borsa/finans, makroekonomik ve döviz kuru sınıflarından öznitelikler kullanılmakta, böylelikle tahmin performansının artırılması düşünülmektedir. Aynı zamanda çeşitli teknik indikatörler kullanılarak da tahmin performansı artırılmaya çalışılmaktadır. Çalışmada 20.01.2006-11.07.2025 dönemine ait günlük frekanslı veriler kullanılmaktadır. Analiz dönemi için tahminlerde makine öğrenmesi yöntemlerinden SVR, RF ve XGBoost; derin öğrenme yöntemlerinden ise LSTM'e yer verilmiştir.

En iyi tahmin sonucuna, RF algoritması ile ulaşılmıştır. Çalışmada gerek makine öğrenmesi gerek derin öğrenme yöntemlerinin kullanılabilmesi için veri sayısı artırılmaya çalışılmış ve bu durum analiz döneminin geniş tutulmasına yol açmıştır. Söz konusu dönemde de dünyada altın fiyatlarının değerini ve yönünü etkileyen önemli küresel olaylar (2008 küresel krizi, Covid-19, savaşlar, ülkeler arasında sınır çatışmaları, ABD başkanlık seçimleri vb.) meydana gelmiştir. Aslında piyasa etkinliği açısından değerlendirildiğinde eğer bir piyasa etkin ise, o piyasanın öngörülebilmesi beklenmektedir. Altın piyasası da hem yüzyıllardır işlem görmesi hem de fiyatı küresel olarak belirlenen bir varlık olması nedeniyle zayıf formda etkinliği en yüksek karşılaması beklenen piyasalardandır. Bu yüzden Etkin Piyasalar Hipotezine (EPH) göre, altın piyasasının tahmininin de kolay olmaması gerekmektedir.

Analiz sonuçlarının yorumlanabilmesi için öznitelik önemi de gerçekleştirilmiştir. Buna göre altın fiyatlarının tahmininde en önemli değişkenler sırasıyla gümüş ve ABD 10 yıllık faizi oranıdır. S&P500 borsa endeksi de diğer önemli bir değişken olarak belirlenmiştir. En az etkili değişkenler ise sırasıyla VIX ve Avro/Dolar döviz kurdur. Altın ve gümüş her ikisi de aynı varlık sınıfına yani kıymetli metaller sınıfına aittirler. Altın ile gümüş arasında "altın gümüş oranı" şeklinde genel olarak yapılan bir karşılaştırma söz konusudur. Bu iki kıymetli metalin fiyatları arasında yatırımcılar tarafından her zaman bir ilişki kurulmaya çalışılmaktadır. ABD 10 yıllık tahvil faizi, doların küresel değerini belirleyen önemli bir referans faiz oranıdır. Dünyada altın fiyatları da dolar cinsinden ifade edilmektedir. Altın ve S&P500 borsa endeksi genellikle birlikte değerlendirilen, birincisi ekonomik/finansal sıkıntı dönemlerinde güvenilir liman olarak başvurulmuş bir varlık iken ikincisi ise ekonomik/finansal rahatlık dönemlerinde başvurulmuş bir varlıktır. Bulgular, portföy yöneticileri, risk yöneticilerinin yanı sıra ülke yöneticileri açısından önemlidir. Buna göre altına ister fiziki ister finansal yatırım yapanlar, altın fiyatlarının öngörüsünde gümüş fiyatları, ABD 10 yıllık faiz oranı ve S&P500 endeksini dikkatlice izlemelidirler. Aynı zamanda Merkez Bankalarının rezervlerinde de altın bulunduğu için ülke yöneticileri de altın fiyatlarındaki değişimlerde söz konusu endeksleri dikkate almalıdır. Fiyatların bu şekilde önceden belirlenebilmesi finansal teori açısından altın piyasasının zayıf formda etkinliğine şüphe düşürmektedir. Zira Etkin Piyasalar Hipotezi'ne göre fiyatlar rassal bir yol izlemekte ve önceden tahmin edilememektedir.

Elde edilen bulgulardan literatürdeki çalışmalarla önemli ölçüde uyum sağlayanlar bulunmaktadır. Malliaris ve Malliaris (2013), Mensi vd. (2013), Risse (2019), Cohen ve Aiche (2023) çalışmaları söz konusu çalışmalar arasındadır. En iyi tahmin modeli açısından değerlendirdiğimizde, bu çalışmada en iyi modelin RF olduğu, ancak XGBoost modelinin de RF modeline yakın sonuçlar elde ettiği görülmektedir. Duman vd. (2025), altın fiyatlarının en iyi tahmin edildiği makine öğrenmesi yönteminin RF olduğunu belirtmişlerdir. Cohen ve Aiche (2023) çalışmasında XGBoost modeli, altın fiyat hareketlerini tahmin etmede en yüksek doğruluk seviyesini göstermiştir.

Gelecekteki çalışmalarda, doğal dil işleme yöntemi ile Twitter'den (X) elde edilen duygu analizi verileri, altın fiyatlarının tahmininde kullanılabilir. Bunun yanında temel bileşenler analizi (PCA) yöntemi kullanılarak da tahminler gerçekleştirilebilecektir. Makine öğrenmesi sonuçlarının ARIMA sonuçları ile karşılaştırılması ve sonuçlarının değerlendirilmesi de mümkündür. Bu çalışmaya ait girdi değişkenleri günlük frekansta olduğu için aylık olarak yayımlanan global göstergeler (örn. Global EPU, uluslararası iş döngüsü) veya ABD ile ilgili önemli makroekonomik göstergeler (örn. ABD enflasyon oranı, ABD işsizlik oranı, ABD GSYH vb.) çalışmaya dahil edilememiştir. Bu nedenle sonraki çalışmalarda aylık verilerle çalışılabilecek ve söz konusu değişkenler de dikkate alınabilecektir. Bunun yanında teknik indikatörler, kriz dönemleri için kukla değişkenler gibi yeni değişkenler de tahmin modeline eklenebilecektir. Son dönemde kullanılmaya başlanan hibrit makine öğrenmesi/derin öğrenme

yöntemleri ile de tahminlerin yapılabilmesi, çalışmanın tahmin performansını artırabilecektir. Diğer taraftan altın fiyatlarının yönünün tahmini de gerek akademik gerekse uygulama açısından önemli bilgiler sunabilmektedir.

Beyan ve Açıklamalar (Disclosure Statements)

1. Bu çalışmanın yazarı, araştırma ve yayın etiği ilkelerine uyduğunu kabul etmektedir (The author of this article confirms that their work complies with the principles of research and publication ethics).
2. Yazar tarafından herhangi bir çıkar çatışması beyan edilmemiştir (No potential conflict of interest was reported by the author).
3. Bu çalışma, intihal tarama programı kullanılarak intihal taramasından geçirilmiştir (This article was screened for potential plagiarism using a plagiarism screening program).

KAYNAKÇA

- Alpaydın, E. (2014). *Introduction to Machine Learning*. The MIT Press, England.
- Baker, S. R., Bloom, N. ve Davis, S. J. (2015). "Measuring economic policy uncertainty", NBER Working Paper No. 21633. National Bureau of Economic Research.
- Balcilar, M., Gupta R., ve Pierdzioch, C. (2016). "Does uncertainty move the gold price? New evidence from a nonparametric causality-in-quantiles test", *Resources Policy*, 49, 74-80.
- Basher, S. A. ve Sadorsky, P. (2022). "Forecasting Bitcoin price direction with random forests: How important are interest rates, inflation, and market volatility?", *Machine Learning with Applications*, 9, 100355.
- Bilgin, M. H., Gozgor, G., Lau, C. K. M. ve Sheng, X. (2018). "The effects of uncertainty measures on the price of gold", *International Review of Financial Analysis*, 58, 1-7.
- Boser, B. E, Guyon, I. M. ve Vapnik, V. N. (1992). "A training algorithm for optimal margin classifiers", *Proceedings of the Fifth Annual Workshop on Computational Learning Theory, COLT '92*. New York, USA. 144-152.
- Breiman, L. (2001). "Random forests", *Machine Learning*, 45(1), 5-32.
- Chen, T. ve Guestrin, C. (2016). "XGBoost: A scalable tree boosting system", In *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining* (s. 785-794). Association for Computing Machinery.
- Cohen, G. ve Aiche A. (2022). "Forecasting gold price using machine learning methodologies", *Chaos, Solitons & Fractals*. 175(2), 114079.
- Çavdaroğlu, G. Ç. ve Arık, A. O. (2024). "Topluluk Öğrenmesi", *Makine Öğrenmesi Algoritmaları içinde* (Editör: M. Gök) (s. 251-280). Nobel Yayıncılık, Ankara.
- Das, S., Sahu, T. P. ve Janghel, R. R. (2022). "Oil and gold price prediction using optimized fuzzy inference system based extreme learning machine", *Resources Policy*, 79, 103109.
- Duman, S., Turnacıgil, S., Arık, E. ve Aktaş, M. A. (2025). "The role of international variables in predicting gold prices: Analysis with machine learning algorithms", *Sosyoekonomi*, 33(63), 103-113.
- Fama, E. (1965). "Random walks in stock market prices", *Financial Analysts Journal*, 21(5), 55-59.
- Fama, E. (1970). "Efficient markets: A review of theory and empirical work", *Journal of Finance*, 25, 1181-1185.
- Fang, L., Yu, H. ve Xiao, W. (2018). "Forecasting gold futures market volatility using macroeconomic variables in the United States", *Economic Modelling*, 72, 249-259.
- Géron, A. (2019). *Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems*, O'Reilly Media, Canada.
- Gers, F. A., Schmidhuber, J. ve Cummins, F. (2000). "Learning to forget: Continual prediction with LSTM", *Neural Computation*, 12(10), 2451-2471.
- Hochreiter, S. ve Schmidhuber, J. (1997). "Long short-term memory", *Neural Computation*, 9(8), 1735-1780.
- Hull, I. (2021). *Machine Learning for Economics and Finance in TensorFlow 2: Deep Learning Models for Research and Industry*. Apress Media, New York.
- İncekara, B. ve İncekara, R. (2016). "Dünya altın piyasaları", *Niğantaşı Üniversitesi Sosyal Bilimler Dergisi*, 4(2), 116-147.

- Kahneman, D. ve Tversky, A. (1979). "Prospect theory: An analysis of decision under risk", *Econometrica*, 47(2), 263-292.
- Kangalli Uyar, S. G., Uyar, U. ve Balkan, E. (2024). "Fundamental predictors of price bubbles in precious metals: A machine learning analysis", *Mineral Economics*, 37, 65-87.
- Kristjanpoller, W. ve Minutolo, M. C. (2015). "Gold price volatility: A forecasting approach using the artificial neural network-GARCH model", *Expert Systems with Applications*, 42(20), 7245-7251.
- Livieris, I. E., Pintelas, E., & Pintelas, P. (2020). "A CNN – LSTM model for gold price time-series forecasting", *Neural Computing and Applications*, 32, 17351–17360.
- Madziwa, L., Pillalamarri, M. ve Chatterjee, S. (2022). "Gold price forecasting using multivariate stochastic model", *Resources Policy*, 76, 102544.
- Malliaris, A. G. ve Malliaris, M. (2013). "Are oil, gold and the euro inter-related? Time series and neural network analysis", *Review of Quantitative Finance and Accounting*, 40(1), 1-14.
- Malliaris, A. G. ve Malliaris, M. (2015). "What drives gold returns? A decision tree analysis", *Finance Research Letters*, 13, 45-53.
- Mensi, W., Beljid, M., Boubaker, A. ve Managi, S. (2013). "Correlations and volatility spillovers across commodity and stock markets: Linking energies, food, and gold", *Economic Modelling*, 32, 15-22.
- Müller, A. C., & Guido, S. (2017). *Introduction to machine learning with Python: A guide for data scientists*. O'Reilly Media, USA.
- Özdemir, M. (2020). "R ile Programlama ve Makine Öğrenmesi" (Ed: Y. Çelikkilek). Nobel Akademik Yayıncılık, Ankara.
- Pattnaik, D., Hassan, M. K., DSousa, A. ve Ashraf, A. (2023). "Investment in gold: A bibliometric review and agenda for future research", *Research in International Business and Finance*, 64, 101854.
- Ping, P. Y., Ahmad, M. H. B. ve Ismail, N. B. (2016). "Volatility spillover effect study in US dollar and gold market based on bivariate-BEKK model", 23rd Malaysian National Symposium of Mathematical Sciences: Advances in Industrial and Applied Mathematics, Johor Bahru; Malaysia.
- Qadan, M. (2019). "Risk appetite and the prices of precious metals", *Resources Policy*, 62, 136-153.
- Qian, Y., Ralescu, D. A. ve Zhang, B. (2019). "The analysis of factors affecting global gold price", *Resources Policy*, 64, 101478.
- Risse, M. (2019). "Combining wavelet decomposition with machine learning to forecast gold returns", *International Journal of Forecasting*, 35(2), 601–615.
- Shahzad, S. J. H., Raza, N., Balcilar, M., Ali, S. ve Shahbaz, M. (2017). "Can economic policy uncertainty and investors sentiment predict commodities returns and volatility?", *Resources Policy*, 53, 208-218.
- Swamy, V. ve Lagesh, M. A. (2023). "Does happy twitter forecast gold price?", *Resources Policy*, 81(C), 103299.
- Tripurana, N., Kar, B., Chakravarty, S., Paikaray, B. K. ve Satpathy, S. (2022). "Gold price prediction using machine learning techniques", <https://ceur-ws.org/Vol-3283/Paper108.pdf> (Erişim Tarihi: 02.07.2025).
- Tversky, A. ve Kahneman, D. (1974). "Judgment under uncertainty: Heuristics and biases", *Science*, 185(4157), 1124-1131.
- World Gold Council (2025). Central Bank Gold Reserves Survey 2025. <https://www.gold.org/goldhub/research/central-bank-gold-reserves-survey-2025> (Erişim Tarihi: 30.06.2025).
- Yang, M., Wang, R., Zeng, Z. ve Li, P. (2024). "Improved prediction of global gold prices: An innovative hurst-reconfiguration-based machine learning approach", *Resources Policy*, 88, 104430.
- Yüksel, R. ve Akkuş, S. (2016). "Altın fiyatlarının yapay sinir ağları ile tahmini ve bir uygulama", *Doğuş Üniversitesi Dergisi*, 17(1), 39-50.