

Altın Risk Primini Tahmininde Makine Öğrenme Modellerinin Etkinliğinin Keşfi: Karşılaştırmalı Bir Yaklaşım

Ahmet AKUSTA¹



Öz



Makale Türü
Araştırma Makalesi

Başvuru Tarihi
10.12.2024

Kabul Tarihi
05.06.2025

DOI
10.47140/kusbder.1599320

Bu çalışma, Türkiye finans piyasalarında Altın Risk Primini (ARP) tahmin etmede makine öğrenimi (MÖ) modellerinin etkinliğini araştırmayı amaçlamaktadır. ARP, yatırımcıların altına yatırım yapmanın riskini telafi etmek için talep ettiği ekstra getiriyi gösteren önemli bir finansal göstergedir. Türkiye'deki finansal piyasaların oynaklığı ve belirsizliği göz önüne alındığında, ARP'yi doğru bir şekilde tahmin etmek yatırımcılar ve finansal piyasaların işleyişi için önemlidir. 2004-2024 yılları arasını kapsayan bir veri seti kullanılarak, ARP'yi modellemek için çeşitli ekonomik ve finansal değişkenler kullanılmıştır. Çalışmada, veri ön işleme sürecinin ardından, basit doğrusal regresyon modellerinden başlayarak karmaşık topluluk yöntemlerine kadar çeşitli MÖ modelleri uygulanmıştır. Uygulanan modeller, Ortalama Mutlak Hata (MAE), Ortalama Kare Hata (MSE), Kök Ortalama Kare Hata (RMSE), Kök Ortalama Logaritmik Kare Hata (RMSLE) ve Ortalama Mutlak Yüzde Hata (MAPE) gibi performans ölçütlerine dayanarak değerlendirilmiş ve karşılaştırılmıştır. Doğrusal Regresyon, Ridge Regresyon ve Rastgele Orman modelleri ARP tahmininde iyi bir performans göstermiştir. Farklı performans ölçütlerine dayalı karşılaştırmalı analizler, Türkiye'deki altın yatırımlarının dinamiklerini ve ARP'yi en iyi şekilde yakalayan modelleri belirlemiştir. Araştırma, Altın Risk Primi tahmininde makine öğrenimi modellerinin potansiyelini ortaya koyarak, finansal tahminleme alanına önemli bir katkı sağlamakta, gelişmekte olan piyasaların değişken koşullarında altın yatırım stratejilerinin daha iyi anlaşılmasına olanak tanımaktadır.

Anahtar kelimeler: Altın risk primi, makine öğrenimi modelleri, finansal tahmin, finansal Piyasalar

Atıf için: Akusta, A. (2025). Altın Risk Primini Tahmininde Makine Öğrenme Modellerinin Etkinliğinin Keşfi: Karşılaştırmalı Bir Yaklaşım. *Kırklareli Üniversitesi Sosyal Bilimler Dergisi*, 9 (1), 1-27.

¹ Sorumlu Yazar: Öğr. Gör. Dr., Konya Teknik Üniversitesi, Rektörlük, E-posta: ahmetakusta@hotmail.com, <https://orcid.org/0000-0002-5160-3210>

Evaluating Machine Learning Models for Gold Risk Premium Prediction: A Comparative Approach

Ahmet AKUSTA²



Abstract



Article Type
Research Article

Application Date
2024-12-10

Acceptance Date
2025-06-05

DOI
10.47140/kusbder.1599320

This study aims to investigate the effectiveness of machine learning (ML) models in predicting the Gold Risk Premium (ARP) in Turkish financial markets. The ARP is an important financial indicator that shows the extra return demanded by investors to compensate for the risk of investing in gold. Given the volatility and uncertainty of financial markets in Turkey, accurately estimating the ARP is important for investors and the functioning of financial markets. Using a dataset covering the period between 2004 and 2024, various economic and financial variables are used to model the ARP. The study involved data preprocessing, application of various ML models ranging from simple linear regression to complex ensemble methods, and evaluation and comparison based on performance measures such as MAE, MSE, RMSE, RMSLE and MAPE. Linear Regression, Ridge Regression and Random Forest models performed well in ARP prediction. Comparative analyses based on different performance measures identified the models that best capture the dynamics of gold investments in Turkey and the ARP. The research makes an important contribution to the field of financial forecasting by demonstrating the potential of machine learning models in Gold Risk Premium estimation, allowing a better understanding of gold investment strategies in the volatile conditions of emerging markets.

Keywords: Gold risk premium, machine learning models, financial forecasting, financial markets

For Reference: Akusta, A. (2025). Evaluating Machine Learning Models for Gold Risk Premium Prediction: A Comparative Approach. *Kırklareli Üniversitesi Sosyal Bilimler Dergisi*, 9 (1), 1-27.

²Corresponding Author: Lec. Dr., Konya Technical University, Rectorate, E-mail: ahmetakusta@hotmail.com, <https://orcid.org/0000-0002-5160-3210>

Giriş

Risk primi, yatırımcıların çeşitli risk türlerini üstlenmek için risksiz bir oran üzerinden talep ettikleri ek getiriye yansıtan temel bir finans kavramıdır. McInish (1980) tarafından özetlenen bu ilke, altın da dahil olmak üzere farklı finansal varlıklarda kritik öneme sahiptir. Altının, diğer varlıklara karşı bir koruma veya güvenli liman olarak hizmet edebilecek bir risk primi sergilemesi dikkat çekmektedir. Mirantes vd. (2014) altının risk priminin dinamiklerini, zamanla değişen ve volatilité ile bu oranların seviyesi ve eğimi gibi piyasa koşullarındaki değişikliklere yanıt veren altın kira oranları üzerinden incelemektedir. Bu husus, altının finansal özelliklerinin karmaşıklığını vurgulamakta ve finansal piyasalardaki daha geniş rolünü tartışmak için zemin hazırlamaktadır. Choudhry vd. (2015) ise altının borsa getirilerine ve oynaklığına karşı nasıl koruma sağlayabileceğini inceleyerek bu tartışmayı genişletmekte ve istikrarlı finansal koşullar altında altının stratejik önemini desteklemektedir.

Makine öğrenme yöntemleri, geniş bir tahmin değişkeni seti kullanılarak altın risk primini tahmin etme doğruluğu açısından değerlendirilmektedir. Sonuçlar, makine öğrenme yöntemleri ve tahmin kombinasyonlarının, altın risk primini tahmin etmede tarihsel ortalamayı aşma kabiliyetinin sınırlı olduğunu göstermektedir. Tahmin değişkenlerinin tek başına kullanıldığı durumlarda ise daha iyi sonuçlar elde edilmektedir (Díaz vd., 2023).

Altın piyasasının çok faktörlü ve doğrusal olmayan yapısı, altın fiyatlarını öngörmeye önemli bir zorluk oluşturmaktadır. Piyasa koşulları, ekonomik krizler, petrol fiyatlarındaki artışlar, vergi avantajları ve faiz oranları gibi dışsal değişkenler altın fiyatlarını etkilemektedir (Nanthiya vd., 2023). Bu nedenle, makine öğrenme modellerinin bu karmaşıklıkları ele alabilecek şekilde tasarlanması gerekmektedir.

Makine öğrenme modellerinin doğruluğunu etkileyen bir diğer önemli unsur, girdi verisinin kalitesi ve model seçimi sürecidir (Nguyen vd., 2019). Girdi verilerinin doğruluğunun sağlanması ve model seçiminin dikkatle yapılması, tahminlerin güvenilirliğini artırabilmektedir. Jeopolitik riskin altın fiyatlarını tahmin etmede potansiyel olarak önemli bir özellik olarak öne çıkması, bu faktörün makine öğrenme ile altın fiyatı tahminine dahil edilmesini zorlaştırmaktadır (Banerjee vd., 2019). Bu durum, modelleme sürecinde dikkate alınması gereken ek bir zorluğu temsil etmektedir.

Makine öğrenme modelleri, altın fiyatlarını tahmin etmede geleneksel istatistiksel yöntemleri sıklıkla geride bırakmaktadır. Destek vektör makineleri algoritmaları, en doğru tahminleri, en düşük hata oranlarını ve en iyi belirlilik katsayısı (R^2) skorunu elde etmektedir (Nguyen vd., 2019). Bu durum, makine öğrenme yöntemlerinin tahmin doğruluğunu artırma potansiyelini ortaya koymaktadır. Ağaç tabanlı makine öğrenme

teknikleri, özellikle karar ağaçları, rastgele orman ve XGBoost, diğer algoritmalarla göre üstün performans sergilemektedir. Rastgele orman, en yüksek R^2 değerine ve en düşük RMSE, MSE ve MAE değerlerine sahip olmaktadır (Elhishi vd., 2023). Bu tekniklerin etkinliği, model seçiminin önemini bir kez daha vurgulamaktadır.

Altın fiyatlarını tahmin etmede karar ağacı, destek vektör regresyonu, rastgele orman ve gradyan artırma gibi topluluk tabanlı makine öğrenme stratejileri kullanılmaktadır. Çeşitli makine öğrenme tekniklerinin birleştirilmesi, modelin öngörülebilirliğini ve istikrarını artırabilmektedir (Mahajan vd., 2023). Rastgele orman, Gradyan Artırmalı Regresyon Ağaçları (GBRT) ve Ekstrem Gradyan Artırma (XGBoost) gelecekteki altın fiyatlarını tahmin etmek için kullanılmaktadır. Çeşitli finansal göstergelerin ve hareketli ortalamaların dahil edilmesi, gelecekteki altın fiyatlarını tahmin etmede güçlü bir araç olarak öne çıkmaktadır (Cohen ve Aiche, 2023). Bu stratejilerin kullanımı, altın fiyatlarının daha doğru tahmin edilmesine katkı sağlamaktadır.

Makine öğrenme yöntemlerinin altın risk primini tahmin etmede sınırlamaları bulunmaktadır. İşlem maliyetlerini dikkate alan bir ekonomik değerlendirme, altın getirilerini tahmin etmek için makine öğrenme yöntemlerini kullanan yatırımcıların sınırlı portföy kazançları beklmeleri gerektiğini ortaya koymaktadır (Díaz vd., 2023). Finansal zaman serilerinin oldukça doğrusal olmayan ve rastgele doğası, makine öğrenme algoritmalarıyla altın fiyatını öngörmeye bir zorluk oluşturmaktadır (Kharseh vd., 2022). Bu zorluklar, makine öğrenme modellerinin finansal piyasalardaki uygulamalarında dikkate alınması gereken önemli noktaları işaret etmektedir.

Tahmine dayalı analitik ve istatistiksel modelleme alanındaki son gelişmeler, altın fiyatlarını tahmin etmeye ve finansal piyasalardaki risk priminin nüanslarını anlamaya yönelik önemli araştırma çabalarını hızlandırmaktadır. Bu literatür taraması, altın fiyatlarının tahmininde kullanılan metodolojileri, karşılaşılan zorlukları ve umut vaat eden istatistiksel modelleri incelemektedir. Altının benzersiz konumuna özel bir vurgu yaparak, çeşitli varlık sınıflarında risk priminin hesaplanmasını araştırmaktadır. Bu tartışmaların entegrasyonu, altın fiyat tahmini ve risk primi değerlendirmesinin birbirine bağlılığını aydınlatmakta ve yatırım kararı verme ile portföy yönetimi üzerindeki etkileri hakkında içgörüler sunmaktadır.

Altın fiyat tahmini alanında çok sayıda tahmin tekniği odak noktası olarak öne çıkmaktadır. Araştırmalar, Yapay Sinir Ağları (YSA), hibrit tahmin yaklaşımları ve Rastgele Orman regresyonu ile Destek Vektör Regresyonu gibi makine öğrenimi algoritmalarının kullanımını vurgulamaktadır (Sathasivam vd., 2024; Zainal ve Mustafa, 2015). Makine öğrenimi yöntemleri, özellikle Bayes sinir ağları, %1 gibi düşük bir ortalama hata yüzdesi ile kayda değer bir doğruluk sergilemektedir (Garg,

2021). Sofistike hesaplama modellerine doğru bu yönelim, altın fiyat tahmin metodolojilerinin gelişen manzarasını yansıtmaktadır.

Son çalışmalar, altın fiyatlarını tahmin etmek için Doğrusal Regresyon ve Karar Ağacı gibi belirli modeller üzerinde yoğunlaşmaktadır (Dichtl, 2020; Huaman ve Infantes, 2024). Makine öğrenimi modellerinin, özellikle rastgele orman istatistiksel regresyonunun etkinliği, altın fiyatlarını etkileyen çeşitli faktörler arasında önemli bir korelasyon bulunduğunu göstermektedir (Singh vd., 2023). Farklı tahmin modellerinin kullanımındaki bu artış, altın piyasasını etkileyen faktörlerin karmaşık etkileşimini yansıtarak altın fiyatlarının tahmininde daha ayrıntılı ve incelikli yaklaşımlara doğru bir geçişe işaret etmektedir.

Altın fiyatlarını tahmin etmek hala önemli zorluklar barındırmaktadır. Ekonomik krizler, faiz oranları ve diğer dış değişkenlerden etkilenen altın piyasasının doğasında var olan dalgalanma ve çok faktörlü yapısı, tahmin çabalarını zorlaştırmaktadır (Nanthiya vd., 2023). Bu engeller, altın fiyatlarının dinamik ve öngörülemez doğasını vurgulamakta, tahmin modellerinin ve metodolojilerinin sürekli olarak iyileştirilmesi gerekliliğini ortaya koymaktadır.

ARIMA ve Dinamik Model Ortalaması (DMA) gibi bazı istatistiksel modeller, altın fiyat tahminlerinin doğruluğunu artırma konusunda umut vaat etmektedir (Baur vd., 2019; Gbadamosi vd., 2024). Bu modeller, altın piyasasının karmaşık dinamiklerini yönlendirmede bir umut ışığı sunmakta, tahmin yapmanın zorluğuna rağmen doğru yaklaşımlarla iyileştirmelerin mümkün olduğunu göstermektedir.

Risk primine odaklanıldığında, klasik risk ölçütleri ve prim hesaplama ilkeleri bu primin belirlenmesinde kritik bir rol oynamaktadır (Mildenhall ve Major, 2022). Riske göre ayarlanmış dağılımların ve entropik risk ölçümlerinin uygulanması, doğru değerlendirmeler için gerekli olan nüanslı hususları vurgulayarak risk primi hesaplamalarına ilişkin anlayışı derinleştirmektedir (Brandtner vd., 2018; Sordo vd., 2016).

Altın bağlamında, risk primi önemli zaman değişimleri sergilemekte ve geçiş riskleri, piyasa oynaklığı ile faiz oranları dinamikleri gibi sayısız faktörden etkilenmektedir (Salisu vd., 2023). Altının koruyucu bir varlık olarak rolü ve finansal risklerden korunmadaki etkinliği, daha geniş yatırım varlıkları yelpazesi içindeki benzersiz konumunu pekiştirmektedir (Ischuk vd., 2016).

Altının risk primindeki tarihsel eğilimler önemli zaman değişimleri göstermekte ve risk primi, geçiş ve fiziksel riskler, dış çatışmalar ile piyasa dinamikleri gibi çeşitli faktörlerden etkilenmektedir. Diğer yatırım varlıklarına kıyasla altının risk primi, güvenli liman varlığı olarak rolünü ve stratejik varlık tahsisi için uygunluğunu vurgulamaktadır. Bu görüşler, portföy yönetimi ve yatırım stratejileri üzerinde etkiler

barındırmakta ve farklı ekonomik senaryolar altında portföy riskini yönetmede altının potansiyel değerini öne çıkarmaktadır.

Bu çalışma, makine öğrenmesi modellerinin altın risk primini tahmin etmedeki etkinliğini Türkiye'nin finansal piyasalarında değerlendirmeye odaklanmaktadır. Araştırma, altın yatırımları ve ilgili risk primleri arasındaki karmaşık ilişkiyi ve bu yatırım stratejilerini yönlendirmek için algoritma istatistiklerini analiz etmektedir. Çeşitli makine öğrenimi modellerinin tahmin performansını değerlendirmekte ve MAE, MSE, RMSE, RMSLE ile MAPE gibi performans ölçütlerine dayalı karşılaştırmalı bir analiz yaparak, daha iyi tahmin yetenekleri sunan modelleri belirlemeyi hedeflemektedir. Makine öğrenimi algoritmalarını performans ölçütlerine göre gruplandırma potansiyelini inceleyerek, model seçimine dair detaylı bilgiler sunmayı ve altın risk primi tahminlerinin doğruluğu ile güvenilirliğini artırmayı amaçlamaktadır.

Yöntem

Veri Seti


Çalışmada, 2004-2024 arası aylık gözlemleri içeren bir veri kümesi kullanılmıştır. Bu veri kümesi, saygın kurumlardan elde edilen geniş bir ekonomik ve finansal değişkenler yelpazesini içermektedir. Değişkenler ve kaynakları Tablo 1'de özetlenmiştir.

Tablo 1: Veri Kümesi Değişkenleri ve Kaynakları

Kısaltma	Değişken	Kaynak	Literatür Referansı
TREXP	Türkiye Altın Rezervleri	TÜİK	Jones ve Sackley, (2014); Gaspreniene vd., (2018); Xiao, (2022); Koziuk, (2022); Fan vd., (2014)
TRFER	Türkiye Döviz Rezervleri	TCMB	Arize ve Osang, (2007); Jones ve Sackley (2014); Gaspreniene vd. (2018); Xiao (2022); Koziuk (2022); Fan vd. (2014)
TRBCOI	Türkiye İş Dünyası Güven Endeksi	TCMB	(Aye vd., 2015); Baur vd., (2019); Sun vd., (2016); Rosanti ve Hanggraeni, (2022); Öner ve Satıcı, (2020); Barışık ve Dursun, (2021)
TRCF	Türkiye Sermaye Akımları	TCMB	Tufano, (1996); Lou, (2010); Matha vd., (2022); Ghanbari vd., (2022); Nasution vd., (2023)
TREP	Türkiye İhracat Fiyatları	TÜİK	Tuncsiper, (2023); Tovar Jaco vd., (2021)
TRIMP	Türkiye İthalatı	TÜİK	Dumitrescu vd., (2012); Dow vd., (2020); Puryandani ve Robiyanto, (2019)

TRINTR	Türkiye Faiz Oranı	TCMB	Bordo vd., (2007); Ghosh vd., (2004); Doojav ve Damdinjav, (2022)
TRIRMM	Türkiye Enflasyon Oranı	TÜİK	Van Hoang vd., (2016); Bampinas ve Panagiotidis, (2015); Desta, (2022); Shakil vd., (2018)
TRLR	Türkiye Merkez Bankası Borç Verme Oranı	TCMB	Montiel vd., (2010); Olmo ve Navarro, (2018) Mishra ve Montiel, (2012)
TURCPIALL MINMEI	Tüketici Fiyat Endeksi	OECD	Van Hoang vd., (2016); Bampinas ve Panagiotidis, (2015); Desta, (2022); Shakil vd., (2018)
USDTRY	USDTRY Döviz Kuru	FXCM	Ghalayini ve Farhat, (2020); Kalsum vd., (2021); Huseynli, (2023)
XU100	BIST100 Endeksi	BIST	Huong Le vd., (2019); Beh ve Yew, (2021); Arfaoui ve Rejeb, (2017); Rifa'i, (2019) Satyatama ve Sumantyo, (2017)

Veri setinin tanınması için kullanılan değişkenler daha detaylı bir şekilde incelenmiştir. Bu inceleme sürecinde zaman serisi gösterimi, altın risk primi dağılım grafiği ve ısı haritaları gibi çeşitli analiz araçları kullanılmıştır.




Şekil 1: Kullanılan Değişkenlerin Zaman İçinde Değişimi

Şekil 1, çeşitli ekonomik göstergelerin 2004-2024 yılları arasındaki zamansal değişimini göstermektedir. İncelenen değişkenler arasında altın risk primi, faiz oranı, USD/TRY döviz kuru, altın rezervleri, enflasyon oranı ve BIST 100 endeksi bulunmaktadır.

Altın risk primi, zaman içerisinde belirgin dalgalanmalar göstermektedir. Faiz oranı, genel olarak düşüş eğiliminde olmasına rağmen belirli dönemlerde önemli artışlar göstermektedir. USD/TRY döviz kuru sürekli bir artış eğilimi sergilemektedir, özellikle 2021 sonrası dönemde hızlı bir yükseliş gözlemlenmektedir. Altın rezervleri sürekli bir

artış trendi göstermektedir. Enflasyon oranı zamanla artış göstermektedir, özellikle 2020 sonrasında belirgin artışlar görülmektedir. BIST 100 endeksi ise 2020 sonrası dönemde hızlı bir yükseliş göstermektedir.

Değişkenler arasındaki görünen ilişkiler incelendiğinde; USD/TRY döviz kuru ve enflasyon oranı arasında pozitif bir ilişki gözlemlenmektedir. Faiz oranı ve altın risk primi arasında son dönemde pozitif bir ilişki bulunmaktadır. Altın rezervleri ve faiz oranı arasında da özellikle son dönemde pozitif bir ilişki görülmektedir. BIST 100 endeksi ve USD/TRY döviz kuru arasında pozitif bir ilişki gözlemlenmektedir.



Şekil 2: Değişkenlerin Yıllık Ortalama Değişim Isı Haritası

Şekil 2'de, altın risk primi, faiz oranı, enflasyon oranı ve USD/TRY döviz kurunun yıllık ortalama değerlerinin ısı haritası ile gösterimi yer almaktadır. Altın risk primi genellikle düşük değerler göstermiş ve zamanla fazla değişim göstermemiştir. Faiz oranı 2004 yılında yüksek seviyelerde başlamış, 2012'ye kadar düşüş eğilimi göstermiş ve daha sonra yeniden yükselmiştir. Enflasyon oranı ise 2004 yılında düşük seviyelerdeyken, 2018'den itibaren belirgin bir artış göstermiştir. USD/TRY döviz kuru, sürekli bir artış eğilimi göstermiş ve 2023 yılında en yüksek seviyelere ulaşmıştır. Bu değişkenler arasındaki ilişkiyi incelediğimizde, döviz kuru ve enflasyon oranındaki artışların faiz oranları üzerinde baskı yarattığı, faiz oranlarının da altın risk primi ile dolaylı olarak ilişkilendirilebileceği sonucuna varılabilir. Ekonomik göstergelerdeki bu değişimler, genel ekonomik istikrarı ve piyasa koşullarını etkileyen faktörler olarak değerlendirilebilir.

Risk Priminin Hesaplanması

Literatürde, risk priminin nasıl kavramsallaştırılacağı ve ölçüleceğine ilişkin çeşitli bakış açıları bulunmaktadır. Ercolani (2004) risk priminin, ekonomik aktörlerin her bir stokastik değişkenle ilişkili riski azaltmak için ödemeye razı oldukları tutar olarak

yorumlanabileceğini öne sürmektedir. Bu bakış açısı, risk algısının öznel doğasını ve yatırımcıların belirsiz sonuçlara maruz kalmak için ödemeye istekli oldukları fiyatı belirlemede oynadığı rolü vurgulamaktadır.

Risk primi kavramı, yatırımcıların risksiz bir varlığa kıyasla riskli bir varlığa yatırım yapmakla ilişkili riski üstlenmek için talep ettikleri ek getiriye temsil ettiği için finansal piyasalarda temeldir. Risk primi, risksiz bir varlık yerine riskli bir varlığa yatırım yapmanın ödülü olarak anlaşılabilir; burada risksiz varlık tipik olarak bir kıyaslama veya referans noktası olarak hizmet etmektedir (Janczura, 2014).

Bir enstrümanın getirisini hesaplamak için yaygın bir yaklaşım Botosan ve Plumlee (2005) tarafından özetlendiği üzere reel risk priminin (rREALPREM) kullanılmasıdır. Bu ölçü, öz sermaye maliyetinin tahmin edildiği aydan başlayarak bir varlığın satın al ve elde tut gerçekleşmiş getirisini hesaplar ve risksiz oranı çıkarır. Risksiz oranın üzerindeki fazla getiriye izole ederek, yatırımcılar belirli bir varlığa yatırım yaparak üstlenilen ek riskin yeterince telafi edilip edilmediğini değerlendirebilirler.

Risk Primi = Beklenen Getiri (Riskli Varlık) - Risksiz Oran

Altının aylık al ve tut gerçekleşen getirisi, genellikle belirli bir süre boyunca altının elde tutulması sonucunda elde edilen gerçek getiriye yansıtmaktadır. Bu getiri, fiyat dalgalanmaları, temettüler ve altının tutulmasından kaynaklanan diğer gelirler gibi faktörleri dikkate alarak, altının bir yatırım aracı olarak performansını yansıtmaktadır.

Bu çalışmada, Türkiye için IMF tarafından sağlanan iskonto oranı, Türk finans piyasaları bağlamında risksiz oran için bir vekil olarak kullanılmaktadır. Türkiye için iskonto oranı, altının aylık al-tut gerçekleşen getirisinden çıkarılarak altının risk primi hesaplanmaktadır. Bu risk primi, yatırımcıların risksiz bir varlığa yatırım yapmaya kıyasla altın tutmanın getirdiği risklere katlanmak için talep ettikleri ek getiriye ölçmektedir. Bu riskler arasında fiyat oynaklığı, jeopolitik belirsizlik ve enflasyon riski gibi faktörler bulunmaktadır.

Veri Ön İşleme

Veri ön işleme bölümü, analizin bütünlüğünü ve kalitesini sağlamak için titizlikle hazırlanmıştır. Kapsamlı bir değerlendirme sonucunda, veri setinin herhangi bir eksik değer içermediği tespit edilmiş, böylece imputasyon tekniklerine olan ihtiyaç ortadan kaldırılmış ve analizde tüm veri setinin kullanılmasına izin verilmiştir.

Özellik ölçeklerini standartlaştırmak ve makine öğrenimi modellerinin karşılaştırılabilirliğini ve performansını artırmak için 'z-skor' normalleştirme yöntemi kullanılmıştır. Bu yaklaşım, özellikleri sıfır ortalamaya ve bir standart sapmaya sahip olacak şekilde standartlaştırarak model verimliliğini ve istikrarını önemli ölçüde artırmaktadır (Andrade, 2021; Mukhametzyanov, 2023).

Ayrıca, boyut azaltma için Temel Bileşen Analizi'nden (PCA) yararlanılmış ve veri kümesinin varyansının %80'i etkili bir şekilde korunurken boyutları önemli ölçüde azaltılmıştır. Bu yöntem, verileri önemli ölçüde bilgi kaybı olmadan daha kompakt bir forma dönüştürme ve böylece hesaplama karmaşıklığını azaltma becerisiyle övülmektedir (Vidal vd., 2016; Yang vd., 2022). PCA'nın avantajları arasında, veri varyansını yakalamada diğer doğrusal ve doğrusal olmayan boyutsallık azaltma tekniklerinden daha iyi performans gösterdiği kanıtlanmış olan alakasız ve gereksiz verileri ortadan kaldırmadaki etkinliği yer almaktadır (Kherwa vd., 2023).

Verinin Bölünmesi

Veri kümesi, eğitim ve test setlerine bölünmüştür ve verilerin %85'i eğitim için ayrılmıştır, kalan %15'i ise test için ayrılmıştır. Bu bölünme, model performansını değerlendirmek için bir set sağlarken öğrenme için yeterli veri sağlamak amacıyla seçilmiştir.

Model Seçimi ve Değerlendirme

Bu çalışmada, basit doğrusal modellerden karmaşık toplu yöntemlere kadar geniş bir yelpazede yaklaşımları kapsayan kapsamlı bir makine öğrenmesi algoritma seti seçilmiştir.

Her bir model, performans ölçütlerinin güvenilirliği ve sağlamlığı için 10 katlı çapraz doğrulama yaklaşımı kullanılarak güçlendirilmektedir. Bu teknik, eğitim setini on küçük parçaya bölmekte ve değerlendirme sürecinde önyargıyı ve değişkenliği en aza indirmek için dokuz parçayı eğitimde, bir parçayı ise doğrulamada kullanarak bu işlemi tekrar etmektedir.

Performans Değerlendirme Ölçütleri

Modellerin tahmin edici performansı, Ortalama Mutlak Hata (MAE), Ortalama Kare Hata (MSE), Kök Ortalama Kare Hata (RMSE), Kök Ortalama Kare Logaritmik Hata (RMSLE) ve Ortalama Mutlak Yüzde Hata (MAPE) dahil olmak üzere çeşitli ölçütler kullanılarak değerlendirilmiştir.

Sonuçlar

Model Performans Analizi

Altın Risk Primini tahmin etmede çeşitli makine öğrenme modellerinin performansı, Ortalama Mutlak Hata (MAE), Ortalama Kare Hata (MSE), Kök Ortalama Kare Hata (RMSE), Kök Ortalama Kare Logaritmik Hata (RMSLE) ve Ortalama Mutlak Yüzde Hata (MAPE) gibi çeşitli ölçütler kullanılarak değerlendirilmiştir.

Tablo 2: Model Performans Metrikleri

Model	MAE	MSE	RMSE	RMSLE	MAPE
Linear Regression	0,038	0,002	0,047	0,0374	1,773
Ridge Regression	0,038	0,002	0,047	0,0375	1,766
Least Angle Regression	0,038	0,002	0,047	0,0374	1,773
Bayesian Ridge	0,038	0,002	0,047	0,038	1,693
Huber Regressor	0,038	0,002	0,047	0,0376	1,88
Passive Aggressive Regressor	0,042	0,003	0,05	0,0391	1,698
Orthogonal Matching Pursuit	0,042	0,003	0,053	0,0415	1,87
Random Forest Regressor	0,043	0,003	0,054	0,0404	2,747
Light Gradient Boosting Machine	0,044	0,003	0,054	0,0395	2,489
AdaBoost Regressor	0,045	0,003	0,054	0,0414	2,717
Extra Trees Regressor	0,045	0,003	0,055	0,0408	2,651
K Neighbors Regressor	0,046	0,003	0,055	0,0418	2,253
Extreme Gradient Boosting	0,045	0,003	0,056	0,0426	3,308
Gradient Boosting Regressor	0,045	0,003	0,057	0,0407	2,841
Lasso Regression	0,048	0,004	0,058	0,0533	1,085
Elastic Net	0,048	0,004	0,058	0,0533	1,085
Lasso Least Angle Regression	0,048	0,004	0,058	0,0533	1,085
Dummy Regressor	0,048	0,004	0,058	0,0533	1,085
Decision Tree Regressor	0,058	0,006	0,074	0,0481	4,758

Modellerin MAE ve RMSE performans ölçütleri açısından oldukça benzer olduğu gözlemlenmektedir. Örneğin, Linear Regression (lr), Ridge Regression (ridge) ve Least Angle Regression (lar) modelleri arasında MAE ve RMSE değerleri oldukça yakındır. Benzer şekilde, Huber Regressor (huber) ve Passive Aggressive Regressor (par) modelleri de benzer performans sergilemektedir.

Model performansı açısından daha yüksek değerlere sahip modeller de bulunmaktadır. Özellikle, Decision Tree Regressor (dt) modelinin diğer modellere kıyasla daha yüksek MAE, MSE ve RMSE değerlerine sahip olduğu görülmektedir. Ayrıca, Extreme Gradient Boosting (xgboost) ve Random Forest Regressor (rf) gibi modellerin RMSLE değerlerinin diğerlerine göre belirgin şekilde yüksek olduğu fark edilmektedir.

Algoritmaların Sınıflandırılması


Algoritmaların başarı metriklerine göre gruplandırılmasının, modeller arasındaki temel benzerlikleri ortaya koyarak geleneksel tek boyutlu performans değerlendirmelerinin

ötesine geçen içgörüler sunmaktadır. Bu analizde, algoritmalar Ortalama Mutlak Hata (MAE), Ortalama Kare Hata (MSE), Kök Ortalama Kare Hata (RMSE), Kök Ortalama Kare Logaritmik Hata (RMSLE) ve Ortalama Mutlak Yüzde Hata (MAPE) gibi performans metriklerine göre gruplandırılmıştır.

Başarı sınıflandırmasında kaç grup olması gerektiğinin belirlenmesi temel ve gerçekçi bir sorudur. Bu soruya yanıt bulmak için KMeans Kümeleme algoritmasındaki optimal K değeri Dirsek Metodu (Elbow Method) ve Siluet Skoru (Silhouette Coefficient) kullanılmıştır.

Çalışmalar, kümeleme için en uygun k değerini belirlemek amacıyla Dirsek Yöntemini Boşluk İstatistiği ve Siluet Katsayısı gibi diğer tekniklerle karşılaştırmıştır. Bu karşılaştırmalar, Elbow Yönteminin optimum küme sayısını belirlemedeki etkinliğini ortaya koymuştur (Yuan ve Yang, 2019). Ayrıca, Dirsek Yöntemi, optimum k değerinin seçimi gibi zayıflıkları ele alarak performansını artırmak için K-Means algoritması ile entegre edilmiştir (Alamsyah vd., 2022).


Dirsek Yöntemi, K-Means kümelemesinde optimum küme sayısını (k) belirlemek için yaygın olarak kullanılan bir tekniktir. Bu yöntemle, fonksiyonun farklı k değerlerine karşı çizilerek optimum küme sayısı dirseğe benzeyen ve daha yavaş düşmeye başladığı noktanın belirlenmektedir (Shi vd., 2021). Bu nokta gözlemlenerek verilerin altında yatan farklılıkları en iyi temsil eden optimum k değerini seçebilmektedir (Gao vd., 2021).



Şekil 3. Dirsek Metoduna Göre Optimum Küme Sayısı


Şekil 3'te, küme sayısının artışına karşılık belli bir noktadan sonra mesafelerin kareleri toplamındaki azalmanın anlamlı bir şekilde düşmeye başladığı bir "dirsek" noktasının varlığı dikkat çekmektedir. Bu nokta, küme sayısının artırılmasının artık anlamlı bir varyans azalmasına yol açmadığı anlamına gelir ve bu nokta en uygun küme sayısını göstermektedir.

Literatürdeki çalışmalar Siluet Katsayısının K-Means kümelemesinde optimum küme sayısını belirlemek için değerli bir araç olduğunu göstermiştir (Punhani vd., 2022). Siluet Katsayısı, bir nesnenin diğer kümelerle kıyasla kendi kümesine ne kadar benzer olduğunu ölçerek K-Means kümelemesinde optimum küme sayısını (k) belirlemek için kullanılan bir metriktir. Daha yüksek bir Siluet Katsayısı daha iyi tanımlanmış kümeleri ve dolayısıyla daha uygun bir k değerini gösterir (Zoubi ve Al-Rawi, 2008). Şekil 4'te Siluet Skoru grafiği ise kümelenmiş verilerin ne kadar iyi ayrıldığını göstermektedir.



Şekil 4. Siluet Katsayısı Göre Optimum Küme Sayısı

Dirsek Metoduna ve Siluet metodunun birleşik sonuçları, algoritmaların performans metriklerine göre dört farklı gruba ayrılmasının, altın risk primi tahmininde en etkili yapılandırma olduğunu göstermektedir.



Şekil 5. Algoritma Kümele Sonuçlarının Görselleştirilmesi

Şekil 5, farklı regresyon algoritmalarının performans metriklerine, özellikle Ortalama Kare Hata (Mean Squared Error - MSE) ve Ortalama Mutlak Hata (Mean Absolute Error - MAE) değerlerine dayalı olarak kümelenmiş olduğunu göstermektedir. Bu bağlamda kümelenme, sürekli bir çıktının tahmin edilmesi sırasında hangi algoritmaların birbirine benzer performans sergilediğini belirlemek için kullanılmaktadır.

Küme 4 (sarı), bu değerlendirme bağlamında en düşük MAE ve MSE değerlerine sahip algoritmaları içermekte ve ortalama performans açısından en iyi sonuçları verdiğini göstermektedir. Bu küme, Linear Regression, Ridge Regression, Least Angle Regression, Bayesian Ridge ve Huber Regressor gibi doğrusal modelleri kapsar ve bu modeller benzer performans profillerine sahip görünmektedir.

Küme 1 (mor), biraz daha yüksek MAE ve MSE değerlerine sahip olup, Random Forest Regressor, Light Gradient Boosting Machine, AdaBoost Regressor gibi çeşitli ağaç tabanlı ve komşuluk tabanlı modelleri içermektedir. Bu modellerin tahminlerinde daha fazla değişkenlik gösterebileceği, bu da daha yüksek hatalara yol açabileceği düşünülmektedir.

Küme 2 (mavi), model tahminlerinde varyansı azaltmak için genellikle bir önyargı (bias) katkısı sağlayan düzenleme algoritmaları olan Lasso Regression, Elastic Net ve Lasso Least Angle Regression'dan oluşmaktadır.

Küme 3 (yeşil) ise sadece Decision Tree Regressor'ı içermekte ve en yüksek MAE ve MSE değerlerine sahip olması, bu bağlamda diğer algoritmaların çok daha kötü bir performans sergilediğini öne sürmektedir.

Tablo 3 : Modellerin Kümeleme Sonuçları

Model	MAE	MSE	RMSE	RMSLE	MAPE	Küme No
Linear Regression	0,037	0,002	0,046	0,037	1,772	4
Ridge Regression	0,037	0,002	0,046	0,037	1,765	4
Least Angle Regression	0,037	0,002	0,046	0,037	1,772	4
Bayesian Ridge	0,037	0,002	0,046	0,038	1,692	4
Huber Regressor	0,038	0,002	0,046	0,037	1,879	4
Passive Aggressive Regressor	0,041	0,002	0,049	0,039	1,698	4
Orthogonal Matching Pursuit	0,042	0,003	0,053	0,041	1,870	1
Random Forest Regressor	0,043	0,003	0,053	0,040	2,746	1
Light Gradient Boosting Machine	0,043	0,003	0,054	0,039	2,489	1
AdaBoost Regressor	0,044	0,003	0,054	0,041	2,716	1
Extra Trees Regressor	0,045	0,003	0,054	0,040	2,651	1
K Neighbors Regressor	0,045	0,003	0,054	0,041	2,252	1
Extreme Gradient Boosting	0,045	0,003	0,056	0,042	3,307	1
Gradient Boosting Regressor	0,045	0,003	0,057	0,040	2,840	1
Lasso Regression	0,047	0,003	0,057	0,053	1,085	2
Elastic Net	0,047	0,003	0,057	0,053	1,085	2
Lasso Least Angle Regression	0,047	0,003	0,057	0,053	1,085	2
Dummy Regressor	0,047	0,003	0,057	0,053	1,085	2
Decision Tree Regressor	0,058	0,005	0,07	0,048	4,757	3

Tablo 3, farklı makine öğrenmesi modellerinin MAE, MSE, RMSE, RMSLE ve MAPE performans metriklerine göre dört kümeye ayrıldığını göstermektedir. Küme 4, en düşük hata değerlerine sahip modelleri (Linear Regression, Ridge Regression, Bayesian Ridge vb.) içermekte ve bu modellerin yüksek tahmin doğruluğu ile altında yatan veri yapısına en uyumlu algoritmalar olduğunu işaret etmektedir. Örneğin, bu kümedeki modellerin MAE değerleri 0,037 ile 0,041 arasında, MSE değerleri ise 0,002 ile 0,003 arasında değişmektedir.

Küme 1, orta düzey hata performansı sergileyen modelleri (Random Forest, Light GBM, AdaBoost vb.) kapsamaktadır. Bu kümedeki modellerin MAE (0,043-0,045) ve MSE (0,003) değerleri, ılımlı bir uyum sağladıklarını göstermekte, ancak Küme 4'e kıyasla daha sınırlı bir tahmin kapasitesine işaret etmektedir.

Küme 2, Lasso Regression, Elastic Net gibi düzenleştirmeye teknikleri kullanan modelleri içermekte ve bu tekniklerin mevcut veri setinde belirgin bir performans avantajı sağlamadığını ortaya koymaktadır. Bu kümedeki modellerin MAE (0,047) ve MSE (0,003) değerleri, diğer kümelerle karşılaştırıldığında düzenleştirmenin sınırlı etkisini yansıtmaktadır.

Küme 3 ise en yüksek hata değerlerine sahip Decision Tree Regressor modelini barındırmaktadır (MAE: 0,058; MSE: 0,005). Bu durum, modelin aşırı uyum (overfitting) veya fazla karmaşık yapı nedeniyle veriye uyum sağlamakta zorlandığını düşündürmektedir.

Tartışma

Bu çalışma, özellikle altın fiyatı tahmini ile altın risk primi tahmini arasındaki ayrımı açıklığa kavuşturarak, altın yatırımlarının tahminine ilişkin anlayışı önemli ölçüde geliştirmektedir. Nguyen vd. (2019) tarafından vurgulandığı gibi, altın fiyat tahmini literatürde büyük ilgi görmüştür, ancak yatırımcıların risksiz varlıklara göre talep ettikleri ek getirileri dikkate alan altın risk primini tahmin etmenin incelikleri daha az incelenmiştir. Bu araştırma, altın risk primini etkileyen piyasa koşulları ve yatırımcı davranışlarının karmaşık etkileşimini yakalayan modeller kullanarak bu boşluğu ele almaktadır.

10 kat çapraz doğrulama yaklaşımının kullanılması, Nanthiya vd. (2023) vurguladığı üzere model değerlendirmesindeki yanlılık ve değişkenlik zorluklarını ele alarak performans ölçümlerinin güvenilirliğini ve sağlamlığını artırmaktadır. Bu metodolojik titizlik, bulguların altın fiyat tahmini ve risk primi hesaplamaları için öngörücü modellerin ve metodolojilerin iyileştirilmesine katkıda bulunmasını sağlar.

Çalışma, altın risk primi tahmini için gelişmiş makine öğrenimi algoritmalarının uygulanmasını araştırmaktadır. Kapsamlı bir model setinin kullanılması, Dichtl (2020) çalışmasında kullanılan temel doğrusal modellerin ötesine geçmektedir.

Algoritmaların performans ölçütlerine dayalı kümeleme analizi, altın risk primi tahmini bağlamında tahmin modellerinin değerlendirilmesine özgün bir yaklaşım getirmektedir. Bu yöntem, literatürdeki sürekli iyileştirme ve yenilik arayışını (Mildenhall ve Major, 2022) karşılamakla kalmayıp, belirli tahmin senaryoları için en uygun modellerin seçilmesine yönelik stratejik bir çerçeve sunmaktadır. Performans ölçütlerine göre kümelendirilen modellerin karşılaştırmalı güçlü ve zayıf yönleri, böylece daha ayrıntılı biçimde değerlendirilebilmektedir.

Araştırma, altın risk primi tahminine yönelik Makine Öğrenimi (ML) modellerinin karşılaştırmalı analizini ele alarak literatürdeki boşluğu doldurmayı hedeflemektedir. Díaz vd. (2023) gibi önceki çalışmalar, ML modellerini altın piyasası tahmininin çeşitli

yönlerine uygulamıştır; ancak altın risk primini tahmin etme konusundaki kapsamlı bir karşılaştırma henüz yeterince ele alınmamıştır. Geniş bir ML model yelpazesini sistematik olarak değerlendiren bu inceleme, altın risk primini tahmin etmede hangi modellerin en etkili olduğunu ortaya koymayı amaçlamaktadır.

Çalışmanın bazı sınırlamaları bulunmaktadır. Analiz, büyük ölçüde Türkiye'nin finansal piyasalarına ait verilerden yararlandığı için elde edilen bulguların farklı coğrafi bağlamlar veya ekonomik yapıya sahip piyasalara genellenebilirliği kısıtlı olabilir. Küresel finans piyasalarının dinamik ve öngörülemez nitelikleri, yeni ekonomik göstergelerin ve beklenmedik piyasa koşullarının sürekli olarak modele entegre edilmesini gerektirmektedir..

Sonuç

Altın Risk Primini tahmin etme konusunda farklı makine öğrenme modellerinin karşılaştırmalı etkinliği incelenerek, altın yatırımlarının karmaşık doğası ve risk primlerine yönelik artan analitik gereksinimler doğrultusunda önemli bir ihtiyaca yanıt verilmiştir. Kapsamlı analiz, altın risk primine ilişkin mevcut yöntemlere katkı sağlamış ve model performanslarına dair yeni bakış açıları sunmuştur.

Ele alınan temel sorun, finansal piyasalarda önemli bir yere sahip ve yatırımcılara ek getiri sunma potansiyeli taşıyan Altın Risk Priminin isabetli bir biçimde tahmin edilmesidir. Çalışma, Türkiye piyasasına özgü aylık veri serilerini temel alarak çeşitli makine öğrenme modellerinin performansını karşılaştırmış ve yatırımcılara rehber niteliğinde çıkarımlar sağlamıştır.

Elde edilen sonuçlar iki kritik bulguya işaret etmektedir. İlk olarak, Doğrusal Regresyon, Ridge Regresyonu ve Rastgele Orman, Altın Risk Primi tahmininde rekabetçi bir başarı yakalamış ve altın yatırımlarına dair stratejik kararlarda değerli ipuçları sunmuştur. İkincisi, ileri düzey makine öğrenimi modelleri, altın yatırımlarının karmaşık yapısını ve ilişkili risk primini etkili biçimde yakalayabildiğini göstermektedir.

Mevcut araştırmanın Türkiye verileriyle sınırlı olması ve seçilen makine öğrenme modellerinin kapsamı, bulguların genelleştirilebilirliği açısından temkinli olmayı gerektirmektedir. Altın fiyatlarını etkileyebilecek küresel faktörlerin ve beklenmedik piyasa dalgalanmalarının modellere entegrasyonu, gelecekteki araştırmaların odak alanları arasında yer alabilir. Farklı ülkelerde veya değişik zaman dilimlerinde benzer analizler yapmak ve yeni makine öğrenme tekniklerini dâhil etmek, altın risk primi tahmin performansını daha da geliştirebilir.

Makalenin Araştırma ve Etik Beyanı Bilgileri

Yazarın Çıkar Çatışması Beyanı	Araştırmaya konu olan durum, olgu veya kurum ile yazarlar arasında herhangi bir çıkar çatışması bulunmamaktadır.
Yazar(lar) Katkı Oranı Beyanı	Çalışmanın tamamlanmasında birinci yazarın katkı oranı % 100'dür.
Etik Kurul Onay Belgesi	Araştırma/inceleme sırasında etik kurul onay belgesi gerektiren herhangi bir bilimsel yöntem kullanılmamıştır.

Kaynakça

- Alamsyah, A., Prasetyo, P. E., Sunyoto, S., Bintari, S. H., Saputro, D. D., Rohman, S., & Pratama, R. N. (2022). Customer segmentation using the integration of the recency frequency monetary model and the K-means cluster algorithm. *Scientific Journal of Informatics*, 9, pp.189–196. <https://doi.org/10.15294/sji.v9i2.39437>
- Andrade, C. (2021). Z scores, standard scores, and composite test scores explained. *The Indian Journal of Psychological Medicine*, 43(6), pp.555–557. <https://doi.org/10.1177/02537176211046525>
- Arfaoui, M., & Rejeb, A. B. (2017). Oil, gold, US dollar and stock market interdependencies: A global analytical insight. *European Journal of Management and Business Economics*, 26(3), pp.278–293. <https://doi.org/10.1108/ejmbe-10-2017-016>
- Arize, A. C., & Osang, T. (2007). Foreign exchange reserves and import demand: Evidence from Latin America. *World Economy*, 30(9), pp.1477–1489. <https://doi.org/10.1111/j.1467-9701.2007.01052.x>
- Aye, G. C., Gupta, R., Hammoudeh, S., & Kim, W. J. (2015). Forecasting the price of gold using dynamic model averaging. *International Review of Financial Analysis*, 41, pp.257–266. <https://doi.org/10.1016/j.irfa.2015.03.010>
- Bampinas, G., & Panagiotidis, T. (2015). Are gold and silver a hedge against inflation? A two century perspective. *International Review of Financial Analysis*, 41, pp.267–276. <https://doi.org/10.1016/j.irfa.2015.02.007>
- Banerjee, D., Ghosal, A., & Mukherjee, I. (2019). Prediction of gold price movement using geopolitical risk as a factor. *Advances in Intelligent Systems and Computing*, 814, 879–886. https://doi.org/10.1007/978-981-13-1501-5_77
- Barişik, S., & Dursun, E. (2021). Gold, stock market, currency market of the economic confidence index impact test: The case of Turkey. *Cumhuriyet Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 22(1), pp.253–280. <https://doi.org/10.37880/cumuiibf.742002>
- Baur, D. G., Beckmann, J., & Czudaj, R. (2019). The relative valuation of gold. *Macroeconomic Dynamics*, 24(6), pp.1346–1391. <https://doi.org/10.1017/s1365100518000895>
- Beh, W. L., & Yew, W. K. (2021). The asymmetric responses of stock prices in US market. *ITM Web of Conferences*, 36(2), pp.1–8. <https://doi.org/10.1051/itmconf/20213601013>

- Bordo, M. D., Dittmar, R., & Gavin, W. T. (2007). Gold, fiat money, and price stability. *The BE Journal of Macroeconomics*, 7(1). <https://doi.org/10.2202/1935-1690.1525>
- Botosan, C. A., & Plumlee, M. A. (2005). Assessing alternative proxies for the expected risk premium. *The Accounting Review*, 80, 21–53. <https://doi.org/10.2307/4093160>
- Brandtner, M., Kürsten, W., & Rischau, R. (2018). Entropic risk measures and their comparative statics in portfolio selection: Coherence vs. convexity. *European Journal of Operational Research*, 264, pp.707–716. <https://doi.org/10.1016/j.ejor.2017.07.007>
- Choudhry, T., Hassan, S. S., & Shabi, S. (2015). Relationship between gold and stock markets during the global financial crisis: Evidence from nonlinear causality tests. *International Review of Financial Analysis*, 41, pp.247–256. <https://doi.org/10.1016/j.irfa.2015.03.011>
- Cohen, G., & Aiche, A. (2023). Forecasting gold price using machine learning methodologies. *Chaos, Solitons and Fractals*, 175. <https://doi.org/10.1016/j.chaos.2023.114079>
- Desta. (2022). Analysis of the causal relationship between precious metal prices and inflation: Evidence from Ethiopia. *International Journal of Economics and Business Administration*, 10(1), 77–88. <https://doi.org/10.35808/ijeba/749>
- Díaz, J. D., Hansen, E., & Cabrera, G. (2023). Gold risk premium estimation with machine learning methods. *Journal of Commodity Markets*, 31. <https://doi.org/10.1016/j.jcomm.2022.100293>
- Dichtl, H. (2020). Forecasting excess returns of the gold market: Can we learn from stock market predictions? *Journal of Commodity Markets*, 19, 100106. <https://doi.org/10.1016/j.jcomm.2019.100106>
- Doojav, G., & Damdinjav, D. (2022). The macroeconomic effects of unconventional monetary policies in a commodity-exporting economy: Evidence from Mongolia. *International Journal of Finance and Economics*, 28(2), pp.1–28. <https://doi.org/10.1002/ijfe.2669>
- Dow, J., Han, J., & Sangiorgi, F. (2020). Hysteresis in price efficiency and the economics of slow-moving capital. *Review of Financial Studies*, 34(6), pp.2857–2909. <https://doi.org/10.1093/rfs/hhaa110>
- Dumitrescu, E. I., Arezki, R., Freytag, A., & Quintyn, M. (2012). Commodity prices and exchange rate volatility: Lessons from South Africa's capital account liberalization. *IMF Working Paper*, 19(168). <https://doi.org/10.5089/9781475505160.001>
- Elhishi, S., Rabea, Z., & El-Metwally, S. (2023). Exploring the predictive power of machine learning algorithms on daily gold prices. In *The Impact of AI Innovation on Financial Sectors in the Era of Industry 5.0* (pp. 131–150). IGI Global. <https://doi.org/10.4018/979-8-3693-0082-4.ch008>
- Ercolani, M. G. (2004). Risk aversion and risk loving in the small: A decomposition of the multivariate risk premium. *Bulletin of Economic Research*, 56(1), pp. 81–106. <https://doi.org/10.1111/j.1467-8586.2004.00190.x>
- Fan, W., Fang, S., & Tao, L. (2014). Macro-factors on gold pricing during the financial crisis. *China Finance Review International*, 4(1), pp.58–75. <https://doi.org/10.1108/cfri-09-2012-0097>

- Gao, M., Pan, S., Chen, S., Li, Y., Pan, N., Pan, D., & Shen, X. (2021). Identification method of electrical load for electrical appliances based on K-means++ and GCN. *IEEE Access*, 1(1), 99. <https://doi.org/10.1109/access.2021.3057722>
- Garg, S. (2021). Forecasting of gold prices using Bayesian regularization neural network. *Lecture Notes in Electrical Engineering*, 692, pp.147–153. https://doi.org/10.1007/978-981-15-7486-3_15
- Gasparyniene, L., Remeikiene, R., Sadeckas, A., & Ginevičius, R. (2018). Gold investment incentives: An empirical identification of the main gold price determinants and prognostication of gold price future trends. *Economics and Sociology*, 11(3), pp.248–264. <https://doi.org/10.14254/2071-789x.2018/11-3/15>
- Gbadamosi, S. L., Nwulu, N. I., & Akinola, S. O. (2024). Exploring the effectiveness of a multilayer neural network model for gold price prediction [Badanie efektywności wielowarstwowego modelu sieci neuronowej do przewidywania ceny złota]. *Przegląd Elektrotechniczny*, 2024. <https://doi.org/10.15199/48.2024.03.28>
- Ghalayini, L., & Farhat, S. (2020). Modeling and forecasting gold prices. *Journal of Economics and Business*, 3(4). <https://doi.org/10.31014/aior.1992.03.04.314>
- Ghanbari, H., Larni Fooeik, A. M., Eskorouchi, A., & Mohammadi, E. (2022). Investigating the effect of US dollar, gold, and oil prices on the stock market. *Journal of Future Sustainability*, 2(3), pp.97–104. <https://doi.org/10.5267/j.jfs.2022.9.009>
- Ghosh, D., Levin, E. J., Macmillan, P., & Wright, R. E. (2004). Gold as an inflation hedge? *Studies in Economics and Finance*. <https://doi.org/10.1108/eb043380>
- Huaman, P., & Infantes, O. (2024). Prediction techniques applied to gold price analysis: A comparative approach. *Lecture Notes in Networks and Systems*, 812, 529–537. https://doi.org/10.1007/978-981-99-8031-4_46
- Huong Le, T. M., Jian, Z., & Zhu, Z. (2019). Impact of macroeconomic variables on stock price index: Evidence from Vietnam stock market. *Research Journal of Finance and Accounting*, 10(12). <https://doi.org/10.7176/rjfa/10-12-04>
- Huseynli, N. (2023). Analyzing the relationship between oil prices and gold prices before and after COVID-19. *International Journal of Energy Economics and Policy*, 13(2), 373–378. <https://doi.org/10.32479/ijeep.13820>
- Ischuk, T. L., Zhilkin, D. V., & Aikina, T. Y. (2016). Gold as a tool for hedging financial risks. *IOP Conference Series: Earth and Environmental Science*, 43(1), 012085. <https://doi.org/10.1088/1755-1315/43/1/012085>
- Janczura, J. (2014). Pricing electricity derivatives within a Markov regime-switching model: A risk premium approach. *Mathematical Methods of Operations Research*, 79, 1–30. <https://doi.org/10.1007/S00186-013-0451-8/FIGURES/7>
- Jones, A. T., & Sackley, W. H. (2014). An uncertain suggestion for gold-pricing models: The effect of economic policy uncertainty on gold prices. *Journal of Economics and Finance*, 40, 367–379. <https://doi.org/10.1007/s12197-014-9313-3>
- Kalsum, U., Hidayat, R., & Oktaviani, S. (2021). The effect of inflation, interest rates and world oil prices on gold prices in Indonesia with the US dollar exchange rate as an intermediary variable. *International Journal of Finance Research*, 2(1). <https://doi.org/10.47747/financeinvestmentderivative.v2i1.228>

- Kharseh, M., Yousef, B., Amara, K. A., & Sakhrieh, A. (2022). Predicting market behavior with artificial neural networks: Gold price as an example. *2022 International Conference on Electrical and Computing Technologies and Applications, ICECTA 2022*, pp.287–290. <https://doi.org/10.1109/ICECTA57148.2022.9990343>
- Kherwa, P., Khurana, J., Budhraj, R., Gill, S., Sharma, S., & Rathee, S. (2023). Dimension reduction techniques in distributional semantics: An application specific review. In *Data Wrangling: Concepts, Applications and Tools* (pp. 147–185). <https://doi.org/10.1002/9781119879862.ch8>
- Koziuk, V. (2022). Drivers of gold fraction in global exchange reserves. *Journal of European Economy*, 21(2)-81, pp.138–153. <https://doi.org/10.35774/jee2022.02.137>
- Lou, D. (2010). A flow-based explanation for return predictability. *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.1468382>
- Mahajan, R., Patil, P., Chikmurge, D., & Barve, S. (2023). Forecasting gold price using ensemble-based machine learning approach. In *Proceedings of the 2023 International Conference on Innovative Computing, Intelligent Communication and Smart Electrical Systems, ICSES 2023*. <https://doi.org/10.1109/ICSES60034.2023.10465360>
- Matha, R., Kumar, S., & Raghavendra, E. (2022). Dynamic relationship between equity, bond, commodity, forex and foreign institutional investments: Evidence from India. *Investment Management and Financial Innovations*, 4, pp.65–82. [https://doi.org/10.21511/imfi.19\(4\).2022.06](https://doi.org/10.21511/imfi.19(4).2022.06)
- McInish, T. H. (1980). The determinants of municipal bond risk premiums by maturity. *The Journal of Financial Research*, 3(2), 129. <https://doi.org/10.1111/j.1475-6803.1980.tb00045.x>
- Mildenhall, S. J., & Major, J. A. (2022). Pricing insurance risk: Theory and practice. In *Pricing insurance risk: Theory and practice*. Wiley. <https://doi.org/10.1002/9781119756538>
- Mirantes, A. G., Población, J., & Serna, G. (2014). Commodity derivative valuation under a factor model with time-varying market prices of risk. *Review of Derivatives Research*, 18(1), 75–93. <https://doi.org/10.1007/s11147-014-9104-1>
- Mishra, P., & Montiel, P. J. (2012). How effective is monetary transmission in low-income countries? A survey of the empirical evidence. *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.2127036>
- Montiel, P. J., Spilimbergo, A., & Mishra, P. (2010). Monetary transmission in low income countries. *IMF Working Paper*, 12(5). <https://doi.org/10.5089/9781455208883.001>
- Mukhametzyanov, I. Z. (2023). MS-transformation of Z-score. In *International Series in Operations Research and Management Science*, 348, pp.151–166. Springer. https://doi.org/10.1007/978-3-031-33837-3_8
- Nanthiya, D., Gopal, S. B., Balakumar, S., Harisankar, M., & Midhun, S. P. (2023). Gold price prediction using ARIMA model. In *2nd IEEE International Conference on Vision Towards Emerging Trends in Communication and Networking Technologies, ViTECoN 2023*. <https://doi.org/10.1109/ViTECoN58111.2023.10157017>
- Nasution, M. A., Putri, T. M. S., Sani, A., & Bahri, S. S. (2023). The influence of cash flow, profitability, and sales growth on stock prices with capital structure as intervening variables in banking companies listed on the Indonesia Stock Exchange 2015-2019.

- International Journal of Economics and Management*, 1(1).
<https://doi.org/10.54209/iem.v1i01.5>
- Nguyen, D. B. B., Prokopczuk, M., & Simen, C. W. (2019). The risk premium of gold. *Journal of International Money and Finance*, 94, pp.140–159.
<https://doi.org/10.1016/j.jimonfin.2019.02.011>
- Olmo, J., & Navarro, M. S. (2018). Unconventional monetary policies and the credit market. *International Journal of Monetary Economics and Finance*, 11(5), 480.
<https://doi.org/10.1504/ijmef.2018.095777>
- Öner, H., & Satıcı, H. K. (2020). How does gold and oil price volatility affect Turkish financial markets? *International Journal of Research in Business and Social Science*, 9(4), 2147–4478. <https://doi.org/10.20525/ijrbs.v9i4.733>
- Punhani, A., Faujdar, N., Mishra, K. K., & Manoharan, S. (2022). Binning-based silhouette approach to find the optimal cluster using K-means. *IEEE Access*, 10, 115025–115032. <https://doi.org/10.1109/access.2022.3215568>
- Puryandani, S., & Robiyanto, R. (2019). Gold: Hedge, safe haven or diversifier for Indonesian capital market. *Fokus Ekonomi Jurnal Ilmiah Ekonomi*, 14(2), pp.226–239.
<https://doi.org/10.34152/fe.14.2.226-239>
- Rifa'i, A. (2019). Optimized fuzzy backpropagation neural network using genetic algorithm for predicting Indonesian stock exchange composite index. *Proceeding of the Electrical Engineering Computer Science and Informatics*, 6(1).
<https://doi.org/10.11591/eecsi.v6.1980>
- Rosanti, N., & Hanggraeni, D. (2022). The effect of changes in oil prices and gold prices on the return of the sectoral stock index in Indonesia from 1999–2019. *Proceedings of the EAI International Conference on Sustainable Development Goals Implementation Science*. <https://doi.org/10.4108/eai.31-3-2022.2320947>
- Salisu, A. A., Olaniran, A., & Lasisi, L. (2023). Climate risk and gold. *Resources Policy*, 82. <https://doi.org/10.1016/j.resourpol.2023.103494>
- Sathasivam, S., Adebayo, S. A., Velavan, M., Fuad, N. J. A. B. Z., & Munawir, N. J. B. A. (2024). Developing optimization and prediction model for gold price forecasting in Malaysia. *AIP Conference Proceedings*, 2905(1), 030010. <https://doi.org/10.1063/5.0171625>
- Satyatama, H. R., & Sumantyo, R. (2017). Performance analysis of Indonesia's mining sector price index. *Signifikan Jurnal Ilmu Ekonomi*, 6(2).
<https://doi.org/10.15408/sjie.v6i2.5395>
- Shakil, M. H., Mustapha, I. M., Tasnia, M., & Saiti, B. (2018). Is gold a hedge or a safe haven? An application of ARDL approach. *Journal of Economics Finance and Administrative Science*, 22(44), pp.61–76. <https://doi.org/10.1108/jefas-03-2017-0052>
- Shi, C., Wei, B., Wei, S., Wang, W., Liu, H., & Liu, J. (2021). A quantitative discriminant method of elbow point for the optimal number of clusters in clustering algorithm. *EURASIP Journal on Wireless Communications and Networking*, 22(1).
<https://doi.org/10.1186/s13638-021-01910-w>
- Singh, G., Tripathy, B., & Singh, J. (2023). An evaluation of extreme learning machine algorithm to forecasting the gold price. In *7th International Conference on Electronics*,

- Communication and Aerospace Technology, ICECA 2023* (pp. 523–529). <https://doi.org/10.1109/ICECA58529.2023.10395223>
- Sordo, M. A., Castaño-Martínez, A., & Pigueiras, G. (2016). A family of premium principles based on mixtures of TVaRs. *Insurance: Mathematics and Economics*, 70, 397–405. <https://doi.org/10.1016/j.insmatheco.2016.07.006>
- Sun, X., Shen, H., Cheng, X., & Zhang, Y. (2016). Market confidence predicts stock price: Beyond supply and demand. *PLoS One*, 11(7), pp.1–10. <https://doi.org/10.1371/journal.pone.0158742>
- Tovar Jaco, C. A., Mucha Alhuay, M. K., Venegas Rodriguez, P. B., Santillan Zapata, N. A., & Deza Quispe, J. A. (2021). Analysis of macroeconomic determinants of Peruvian gold export value in the period 2003–2019. *International Journal of Financial Research*, 12(2), 43–54. <https://doi.org/10.5430/ijfr.v12n2p43>
- Tufano, P. (1996). Who manages risk? An empirical examination of risk management practices in the gold mining industry. *The Journal of Finance*, 51(4). <https://doi.org/10.2307/2329389>
- Tuncsiper, C. (2023). Nowcasting the gold prices in Türkiye employing multilayer perceptron (MLP) networks. *International Journal of Innovative Research in Multidisciplinary Education*, 2(4). <https://doi.org/10.58806/ijirme.2023.v2i4n07>
- Van Hoang, T. H., Lahiani, A., & Heller, D. (2016). Is gold a hedge against inflation? New evidence from a nonlinear ARDL approach. *Economic Modelling*, 54, pp.54–66. <https://doi.org/10.1016/j.econmod.2015.12.013>
- Vidal, R., Ma, Y., & Sastry, S. S. (2016). Principal component analysis. In *Interdisciplinary applied mathematics*, 40 (pp. 25–62). Springer Nature. https://doi.org/10.1007/978-0-387-87811-9_2
- Xiao, B. (2022). A study on the hedging function of gold in the light of economic policy uncertainty. *Computational Intelligence and Neuroscience*, 2022(1), 1556475. <https://doi.org/10.1155/2022/1556475>
- Yang, C. C., Garzon, M., & Deng, L. Y. (2022). Conventional statistical approaches. In *Dimensionality reduction in data science* (pp. 79–95). Springer International Publishing. https://doi.org/10.1007/978-3-031-05371-9_4
- Yuan, C., & Yang, H. (2019). Research on K-value selection method of K-means clustering algorithm. *J — Multidisciplinary Scientific Journal*, 2(2), 226–235. <https://doi.org/10.3390/j2020016>
- Zainal, N. A., & Mustaffa, Z. (2015). A literature review on gold price predictive techniques. In *4th International Conference on Software Engineering and Computer Systems, ICSECS 2015: Virtuous Software Solutions for Big Data* (pp. 39–44). <https://doi.org/10.1109/ICSECS.2015.7333120>
- Zoubi, M. B. A., & Al-Rawi, M. (2008). An efficient approach for computing silhouette coefficients. *Journal of Computer Science*, 4(3). <https://doi.org/10.3844/jcsp.2008.252.255>

Evaluating Machine Learning Models for Gold Risk Premium Prediction: A Comparative Approach

Extended Summary

Purpose and Significance

This study investigates the effectiveness of machine learning (ML) models in predicting the Gold Risk Premium (GRP) in the volatile and uncertain financial markets of Turkey. The GRP, defined as the additional return investors require for holding gold as opposed to a risk-free asset, is a critical financial indicator with implications for portfolio management and investment decision-making. Accurate estimation of GRP is crucial for understanding the dynamics of gold investments, particularly in emerging markets like Turkey, where economic fluctuations and geopolitical uncertainties significantly impact market behaviors.

The research fills a gap in the financial forecasting literature by shifting the focus from gold price prediction to GRP estimation, thus emphasizing the nuanced relationship between gold's role as a safe-haven asset and the associated risks investors undertake. The study is significant because it employs an extensive dataset spanning from 2004 to 2024, integrating various macroeconomic and financial indicators to develop and evaluate machine learning models. Through a comparative approach, the research aims to identify the models that best capture the intricacies of GRP and provide actionable insights for both academics and practitioners.

Method

The study adopts a structured methodological framework, beginning with data collection and preprocessing. The dataset includes monthly observations from 2004 to 2024, comprising key variables such as Turkey's gold reserves, exchange rates, interest rates, inflation rates, and stock market indices. These variables were sourced from reputable institutions, including the Turkish Statistical Institute (TÜİK) and the Central Bank of Turkey (TCMB).

Data preprocessing involved addressing missing values, standardizing feature scales using z-score normalization, and reducing dimensionality with Principal Component Analysis (PCA). PCA retained 80% of the dataset's variance while effectively reducing computational complexity. The dataset was then split into training (85%) and testing (15%) subsets to ensure robust model evaluation.

A wide range of machine learning models was applied, including:

- Linear Regression
- Ridge Regression
- Least Angle Regression
- Bayesian Ridge
- Random Forest Regressor
- Gradient Boosting Machines
- Support Vector Machines

To assess model performance, five metrics were employed: Mean Absolute Error (MAE), Mean Squared Error (MSE), Root Mean Squared Error (RMSE), Root Mean Squared Logarithmic Error (RMSLE), and Mean Absolute Percentage Error (MAPE). Additionally, a 10-fold cross-validation technique was utilized to enhance the reliability of performance evaluation by minimizing bias and variance.

To further analyze the models, an innovative clustering approach was adopted. Using metrics such as the Elbow Method and Silhouette Score, the study grouped algorithms based on their performance to identify models with similar predictive capabilities.

Findings

The findings of the study highlight the predictive power of various machine learning models in estimating GRP. Linear Regression, Ridge Regression, and Bayesian Ridge models consistently outperformed others, demonstrating the lowest error rates across multiple metrics. These models exhibited strong predictive capabilities due to their simplicity and ability to generalize well to the dataset's structure.

Tree-based models such as Random Forest Regressor and Gradient Boosting Machines also performed commendably, albeit with slightly higher error rates compared to linear models. Their ability to capture non-linear relationships between variables proved beneficial, although at the cost of increased complexity and computational demand.

The clustering analysis revealed four distinct groups of models based on their performance:

1. Cluster 4 (Highest Accuracy): Linear Regression, Ridge Regression, and Bayesian Ridge, characterized by low MAE and MSE scores.

2. Cluster 1 (Moderate Accuracy): Random Forest and Gradient Boosting Machines, which provided competitive but less consistent results.
3. Cluster 2 (Regularization Models): Lasso Regression and Elastic Net, whose performance indicated the limited contribution of regularization for GRP estimation.
4. Cluster 3 (Lowest Accuracy): Decision Tree Regressor, which exhibited the highest error rates, signaling overfitting tendencies and poor generalization.

An analysis of the economic variables revealed significant relationships with GRP. For instance, USD/TRY exchange rates and inflation rates showed a positive correlation, indicating their influence on the perceived risk of gold investments. Furthermore, gold reserves and interest rates exhibited a dynamic interaction with GRP, underscoring the complex interplay of macroeconomic factors.

Discussion and Conclusions

The study's findings contribute to the growing body of literature on financial forecasting by demonstrating the applicability and effectiveness of machine learning models for GRP estimation. Unlike previous research focusing primarily on gold price prediction, this study sheds light on the risk premium dynamics, offering a more nuanced understanding of gold investments.

The strong performance of linear models suggests that GRP can be effectively captured by relatively simple algorithms when coupled with robust data preprocessing and feature selection. This finding aligns with the argument that simpler models often suffice for financial forecasting tasks when the data is well-structured. Tree-based models, while less accurate in this context, remain valuable for capturing non-linearities and complex interactions between variables.

The clustering analysis provided additional insights, revealing the relative strengths and weaknesses of different algorithms. Models in Cluster 4 demonstrated superior performance, making them suitable candidates for GRP estimation. In contrast, models in Cluster 3, such as the Decision Tree Regressor, highlighted the risks of overfitting and the need for careful model selection.

The study also emphasized the critical role of macroeconomic indicators in GRP prediction. Variables such as exchange rates, inflation, and gold reserves emerged as key drivers, reaffirming their importance in financial modeling. These findings highlight the need for continuous monitoring of economic conditions to refine predictive models and ensure their relevance in dynamic markets.

Despite its contributions, the study acknowledges certain limitations. The focus on Turkey's financial markets may restrict the generalizability of findings to other

regions. Moreover, the reliance on historical data assumes market conditions remain relatively stable, which may not always hold true in rapidly evolving global markets.

Future research should explore the applicability of these findings to other emerging markets and extend the analysis to incorporate real-time data. Additionally, integrating advanced machine learning techniques such as deep learning and ensemble methods could further enhance predictive accuracy. The inclusion of global factors, such as geopolitical risks and international trade dynamics, would also provide a more comprehensive understanding of GRP.

In conclusion, this study demonstrates the potential of machine learning models to predict GRP effectively, offering valuable insights into the dynamics of gold investments. By identifying high-performing models and elucidating key economic drivers, the research contributes to better-informed investment strategies and advances the field of financial forecasting.

