

TÜRKİYE'DE EKONOMİK ŞOKLAR VE KRİZLER BAĞLAMINDA ENFLASYON ÖNGÖRÜSÜ: XGBOOST VE ARMA YÖNTEMLERİNİN KARŞILAŞTIRMASI

Inflation Forecasting in the Context of Economic Shocks and Crises in Türkiye: Comparison of XGBoost and ARMA Methods

Savaş GAYAKER* 

Öz

Enflasyon, ekonomik istikrar ve büyüme üzerinde derin etkiler yaratan, temel bir makroekonomik göstergedir. Fiyatlar genel düzeyindeki süreklilik arz eden artışlar, yalnızca bireylerin satın alma güçlerini zayıflatmakla kalmayıp, ulusal ekonominin çeşitli sektörleri üzerinde de ciddi tehditler oluşturmaktadır. Dolayısıyla, enflasyonun doğru tahmini hem merkez bankaları hem de hükümetler için stratejik bir önem taşımaktadır. Bu çalışma, Türkiye'deki ekonomik şoklar ve kriz dönemlerinde, enflasyon tahmininde XGBoost ve ARMA modellerinin performansını incelemektedir. 1994 ekonomik krizi, 2001 finansal krizi, 2008 küresel finansal krizi ve 2018 döviz krizi gibi sık yaşanan krizler ve Türkiye'nin özgün makroekonomik koşulları göz önüne alındığında, enflasyonun doğru tahminini zorlaştırmaktadır. Çalışmada, kriz dönemleri de dahil olmak üzere farklı zaman dilimlerinde XGBoost makine öğrenimi algoritması ile ARMA modelinin performansı karşılaştırılmaktadır. Ampirik bulgular, XGBoost'un büyük veri setleri ve kriz dönemlerinde güçlü performans gösterdiğini, ancak geleneksel ARMA modelinin daha küçük veri setlerinde daha iyi sonuçlar verdiğini ortaya koymaktadır. Özellikle, ARMA modelinden gelen gecikmeli değişkenlerin XGBoost'a entegre edilmesiyle elde edilen tahmin modeli, kriz dönemlerinde ve tüm örneklem dönemi olan 1990:02-2024:06 arasında en etkili yöntem olarak belirlenmiştir. Bu sonuçlar, enflasyon tahmini için kullanılan modellerin veri yapısına duyarlılığını vurgulamakta ve farklı dönemlerdeki etkinliklerini ortaya koymaktadır.

Abstract

Inflation is a key macroeconomic indicator with profound implications for economic stability and growth. Persistent increases in the general level of prices not only weaken individuals' purchasing power but also pose serious threats to various sectors of the national economy. Accurate inflation forecasting is therefore of strategic importance for central banks and governments. This paper examines the performance of XGBoost and ARMA models in forecasting inflation during economic shocks and crisis periods in Türkiye. The 1994 economic crisis, 2001 financial crisis, 2008 global financial crisis, and 2018 currency crisis, along with Türkiye's unique macroeconomic conditions, complicate accurate inflation forecasting. This study compares the performance of the XGBoost machine learning algorithm and the ARMA model over different periods, including crises. The findings show XGBoost performs well for large datasets and crisis periods, while ARMA performs better for smaller datasets. Particularly, the forecasting model integrating ARMA's lagged variables into XGBoost proves most effective during crises and across the entire sample period, 1990:02-2024:06. These results highlight the models' sensitivity to data structure and their efficiency in different periods.

Anahtar Kelimeler:
Enflasyon Öngörüsü,
XGBoost,
ARMA Modeli.

JEL Kodları:
B22, C22, C53.

Keywords:
Inflation Forecast,
XGBoost,
ARMA Model.

JEL Codes:
B22, C22, C53.

* Dr. Öğr. Üyesi, Ankara Hacı Bayram Veli Üniversitesi, İktisadi ve İdari Bilimler Fakültesi, Türkiye, savas.gayaker@hbv.edu.tr

Makale Geliş Tarihi (Received Date): 02.10.2024 Makale Kabul Tarihi (Accepted Date): 26.11.2024

Bu eser Creative Commons Atıf 4.0 Uluslararası Lisansı ile lisanslanmıştır.



1. Giriş

Enflasyon, ekonomik istikrar ve büyüme üzerinde belirleyici etkiler yaratan temel bir makroekonomik göstergedir. Fiyatlar genel düzeyindeki sürekli artış, sadece bireylerin satın alma gücünü değil, aynı zamanda ulusal ekonominin çeşitli sektörlerini de riske atmaktadır (Niyimbanira, 2013). Yüksek enflasyon, tüketicilerin satın alma gücünü aşındırarak tüketimin azalmasına ve genel ekonomik aktivitenin yavaşlamasına yol açmaktadır (Girdzijauskas vd., 2022). Enflasyonun kalıcı yükselişi, sadece bireylerin alım gücüne zarar vermekle kalmamakta, aynı zamanda işletmelerin kârlılığın ve genel ekonomik büyümeye de ciddi riskler oluşturmaktadır.

Enflasyonun ekonomi üzerindeki etkileri çok yönlüdür. Enflasyon, faiz oranlarını etkilemekte olup, merkez bankaları genellikle artan enflasyona karşı harcamaları ve borçlanmayı sınırlamak için faiz oranlarını artırmaktadır (Noh vd., 2023). Bu durum ekonomik büyümeyi daha da yavaşlatmakta, çünkü yüksek faiz oranları, tüketiciler ve işletmeler için kredileri daha pahalı hale getirmektedir (Dwumfour, 2019). Bunun yanı sıra, enflasyon yatırım kararlarında belirsizlik yaratmakta ve hızla değişen fiyatların olduğu bir ortamda işletmelerin yatırım yapmaktan imtina etmelerine neden olmaktadır. Ayrıca, enflasyonun oluşturduğu belirsizlik ortamı, özellikle gelişmekte olan ülkelerde, sürdürülebilir yatırım stratejilerini zorlaştırmaktadır. Bunun yanı sıra, enflasyon, ücret-fiyat sarmalı denilen bir duruma da yol açabilmektedir. Artan fiyatlar, işçilerin satın alma güçlerini koruyabilmek için daha yüksek ücret talep etmesine sebep olmaktadır. Bu durum, ekonomiyi istikrarsızlaştırmakta ve önemli sosyal ve ekonomik sorunlara yol açabilmektedir. Dolayısıyla, enflasyonun doğru ve zamanında tahmini hem merkez bankaları hem de hükümetler için stratejik bir önem taşımaktadır. Güvenilir enflasyon tahminleri, ekonomik karar alıcıların gelecekteki potansiyel dengesizlikleri öngörmesini ve bu dengesizliklere karşı zamanında önlem almasını sağlamaktadır.

Literatürde enflasyon tahmini için kullanılan yöntemler, geleneksel ekonometrik modellerden (örneğin, Otoregresif Entegre Hareketli Ortalama- ARIMA, Phillips Eğrisi) modern makine öğrenmesi algoritmalarına kadar geniş bir yelpazede yer almaktadır. Geleneksel yöntemler, tarihsel verilere dayalı öngörüler sunarken, makine öğrenmesi yöntemleri özellikle büyük ve karmaşık veri setlerinde daha yüksek tahmin doğruluğu sunma potansiyeline sahiptir (Salkuti, 2020; Ji, 2023; Li vd., 2023). Bu çerçevede, XGBoost (eXtreme gradient boosting) gibi gelişmiş makine öğrenmesi algoritmaları, öznelik seçimi, model optimizasyonu ve aşırı öğrenmeyi önleme konularında sunduğu avantajlar ile öne çıkmaktadır. XGBoost, özellikle verinin karmaşık yapısını öğrenmede ve hızlı hesaplama yetenekleri ile enflasyon tahmini gibi zor problemlerde güçlü bir alternatif olarak literatürde kendine yer bulmuştur (Chen ve Guestrin, 2016; Aras ve Lisboa, 2022; Rizinski vd., 2022; Gono, 2023; Ivaşcu, 2023). Ancak, Türkiye gibi gelişmekte olan ülkelerdeki enflasyon tahmini süreci, sıklıkla yaşanan ekonomik şoklar ve krizlerle daha da karmaşık bir hal almaktadır. Türkiye ekonomisi, son birkaç on yılda birçok ekonomik kriz ve şok yaşamıştır; 1994 krizi, 2001 finansal krizi, 2008 küresel finansal kriz ve 2018 döviz krizi gibi dönemler, enflasyon dinamiklerinde ciddi dalgalanmalara yol açmıştır. Bu tür ekstrem durumlar, geleneksel zaman serisi yöntemlerinin tahmin yeteneğini sınırlayarak, yeni yöntemlerin uygulanabilirliğini test etmek için ideal bir ortam sunmaktadır. Bu bağlamda, XGBoost gibi modern yöntemlerin performansı, özellikle kriz dönemlerinde büyük önem taşımaktadır.

Bu alıřmada, 1990:02-2024:06 dnemine ait aylık veriler kullanılarak, XGBoost ynteminin Trkiye'deki ekonomik řoklar ve kriz dnemlerinde enflasyon tahminindeki performansı incelenmiřtir. XGBoost ynteminin, bu tr ekstrem durumlarda ne lde gvenilir tahminler yapabildiđi deđerlendirilmiř, aynı zamanda klasik zaman serisi yntemlerinden biri olan otoregresif hareketli ortalama (ARMA) modeli ile karřılařtırılmıřtır. Bu erevde, alıřmanın iki temel katkısı olacaktır: Birincisi, XGBoost'un kriz ve řok dnemlerinde tahmin performansını analiz ederek literatrdeki bořluđu doldurmak; ikincisi, geleneksel yntem olan ARMA modeli ile bu yeni yntemin performanslarını karřılařtırarak, hangi řartlar altında hangi yntemin daha etkin olduđuna dair pratik neriler sunmak. Elde edilen sonulara gre, XGBoost yntemi, ncesinde byk bir zaman penceresi olan kriz dnemlerinde gl tahmin performansı sergilerken, geleneksel ARMA modeli daha kk veri setlerinde daha etkili sonular vermektedir. zellikle XGBoost modeline gecikmeli deđerkenlerin eklenmesiyle tahmin dođruluđunun nemli lde arttıđı, kriz dnemlerinde daha tutarlı ngrler sađladıđı grlmřtir. Bu bulgular, Trkiye gibi geliřmekte olan ve sık ekonomik řoklara maruz kalan ekonomilerde, farklı tahmin yntemlerinin uygulanabilirliđine dair nemli igrler sunmaktadır.

alıřmanın ilerleyen blmlerinde ilk olarak literatr taraması sunulmuř, ardından veri seti ve metodoloji detaylandırılmıřtır. Takip eden blmde bulgulara yer verilmiř, son blmde ise tahmin sonuları deđerlendirilerek eřitli nerilerde bulunulmuřtur.

2. Literatr Taraması

Bu blmde, enflasyon tahmininde kullanılan eřitli ekonometrik ve makine đrenimi yaklařımları ile bu yntemlerin dođruluđunu arttırmaya ynelik uygulamalar incelenmiřtir. Literatrde enflasyon tahminine ynelik alıřmalar, geleneksel ekonometrik yntemler ile yeni nesil yapay zek ve makine đrenimi tekniklerini kullananlar olmak zere ikiye ayrılmaktadır.

Stock ve Watson (1999), 1959:01-1997:09 dneminde ABD'de enflasyon tahminlerini Phillips eđrisi erevesinde incelemiřtir. alıřmada, iřsizlik oranına dayalı geleneksel Phillips eđrisi modeli ile diđer makroekonomik deđerkenler ve ekonomik aktivite gstergelerine dayalı alternatif Phillips eđrisi modelleri karřılařtırılmıřtır. Sonular, iřsizlik oranına dayalı Phillips eđrisi tahminlerinin diđer deđerkenlere dayalı modellerden genellikle daha iyi performans gsterdiđini, ancak bazı ekonomik aktivite gstergelerinin (zellikle konut bařlangıları ve üretim kapasitesi kullanımı gibi) enflasyon tahminlerinde iyileřtirmeler sađlayabileceđini gstermiřtir. Chen vd. (2001), 1948:01-1995:04 dneminde ABD enflasyonunu tahmin etmek iin yarı-parametrik ARX yapay sinir ađı modellerini kullanmıřtır. alıřmada, c farklı aktivasyon fonksiyonu (sigmoid, radyal bazlı ve ridgelet) kullanılmıř ve bu modeller, dođrusal modellerle karřılařtırılmıřtır. Sonular, yarı-parametrik ridgelet ARX modelinin tahmin dođruluđu aısından en iyi performansı gsterdiđini ve geleneksel dođrusal modelleri geride bıraktıđını ortaya koymuřtur. Hubrich (2005), 1992:01-2001:12 dneminde Avrupa Blgesi enflasyon tahminlerini bileřenlere dayalı alt-indeks tahminlerinin dođruluđunu incelemek amacıyla tek deđerkenli ve ok deđerkenli dođrusal zaman serisi modellerini kullanarak analiz etmiřtir. alıřmada, HICP (Tketiciler Fiyatları Harmonize Endeksi) bileřenlerinin (gıda, enerji, endstriyel rnler vb.) tahminlerinin, genel HICP enflasyonu tahmin etmekte ne kadar etkili olduđu arařtırılmıřtır. Sonular, bileřen bazlı tahminlerin genel HICP tahminine kıyasla uzun vadede daha yksek dođruluk sađlamadıđını ortaya koymuřtur.

Nakamura (2005), 1960:01-2003:03 döneminde ABD’deki enflasyon tahminlerini yapay sinir ağı (NN) modeli kullanarak analiz etmiştir. Çalışma, NN modelini ve tek değişkenli otoregresif (AR) modellerini karşılaştırarak, kısa vadeli (bir ve iki çeyrek) tahminlerde sinir ağı modelinin AR modellerine kıyasla daha iyi performans gösterdiğini ortaya koymuştur. Çalışmada, erken durdurma prosedürü gibi sinir ağı modelleme tekniklerinin tahmin başarısına katkıda bulunduğu tespit edilmiştir. McAdam ve McNelis (2005), 1970:01-2003:12 döneminde ABD, Japonya ve Avrupa bölgesindeki enflasyon tahminlerini doğrusal ve NN tabanlı kalın modelleri (thick models) kullanarak analiz etmişlerdir. Çalışmada, Phillips eğrisi formülasyonuna dayalı modeller karşılaştırılmış ve özellikle hizmet fiyat endeksleri tahmininde NN modellerinin, bootstrap ve gerçek zamanlı tahminler açısından doğrusal modellerden daha başarılı olduğu tespit edilmiştir. Stock ve Watson (2007), 1960:01-2004:12 döneminde ABD enflasyon tahminlerinin zorlaşmasının nedenlerini incelemek amacıyla, gözlenemeyen bileşenler (UC) modeli ve zamanla değişen parametrelerle çalışan bir trend-döngü modeli kullanarak analiz yapmışlardır. Çalışma, enflasyonun yapısal değişiklikler geçirdiğini ve bu değişikliklerin tahmin zorluklarına katkıda bulunduğunu göstermiştir. Özellikle, 1984 sonrası dönemde Phillips eğrisi gibi çok değişkenli tahmin modellerinin performansında düşüş olduğu, ancak basit tek değişkenli modellerin tahmin hatalarının azaldığı bulunmuştur. Stock ve Watson (2008), 1953:01-2008:01 döneminde ABD’de enflasyon tahminlerini değerlendirmek amacıyla Phillips eğrisi tahminlerini ve çeşitli tek değişkenli tahmin modellerini sözde (pseudo) örneklem dışı yöntemi ile incelemiştir. Çalışmada, enflasyonun aktivite değişkenleri ile tahmin edilip edilemeyeceği araştırılmıştır. Sonuçlar, Phillips eğrisi tahminlerinin zaman zaman tek değişkenli modelleri geride bırakabildiğini, ancak genel olarak bu performansın belli bir zaman dönemi ile sınırlı olduğunu ve çoğu zaman tek değişkenli tahminlerden daha iyi sonuç vermediğini göstermiştir. Koop (2013), 1959:Q1-2008:Q3 döneminde ABD makroekonomik verilerini kullanarak orta ve büyük boyutlu Bayesyen VAR modelleri ile tahmin yapmıştır. Çalışmada, Bayesyen VAR’ların faktör yöntemlerine göre daha iyi tahmin yapabildiği ve Minnesota önselleri ile stokastik arama değişken seçimi (SSVS) yöntemlerinin performanslarının karşılaştırıldığı analizler gerçekleştirilmiştir. Sonuçlar, orta boyutlu VAR’ların büyük boyutlu VAR’lara kıyasla daha iyi tahminler üretebildiğini ve Minnesota önselleri ile SSVS yaklaşımlarının tahmin performanslarının genellikle benzer olduğunu ortaya koymuştur. Faust ve Wright (2013), 1985:01-2011:04 döneminde ABD’deki enflasyon tahminlerini geleneksel ve yeni geliştirilen modelleri karşılaştırarak analiz etmiştir. Çalışmada, subjektif tahminlerin model bazlı tahminlere göre üstün olduğu, özellikle enflasyonun düşük frekanslı yerel ortalaması dikkate alınarak yapılan tahminlerde daha başarılı sonuçlar elde edildiği tespit edilmiştir. Sonuçlar, makroekonomik modelleme yöntemlerinin yanı sıra piyasa bazlı enflasyon tahminlerinin de önemli katkılar sunduğunu göstermiştir.

Stock ve Watson (2016), 1959:01-2015:06 döneminde ABD’deki temel ve trend enflasyonu dinamik faktör modelleri kullanarak analiz etmiştir. Çalışmada, kişisel tüketim harcamaları (PCE) fiyat endeksinin 17 bileşenine dayalı dinamik bir faktör modeli geliştirilmiş ve zamana bağlı ağırlıklar ile sektörler arası ortak hareketlilik dikkate alınmıştır. Sonuçlar, çok değişkenli trend enflasyon tahminlerinin, manşet enflasyonuna dayalı tahminlerden daha kesin olduğunu ve temel enflasyon ölçütlerinin, 1-3 yıllık enflasyon tahminlerinde önemli iyileşmeler sağladığını ortaya koymuştur. Garcia vd. (2017), 2003:01-2015:12 döneminde Brezilya enflasyon tahminlerini yüksek boyutlu modeller ve makine öğrenimi teknikleri kullanarak analiz etmiştir. Çalışmada, LASSO, rastgele ormanlar (RF) ve tam alt küme regresyon gibi yöntemler kullanılmıştır. Sonuçlar, kısa vadeli tahminlerde LASSO’nun, uzun vadeli tahminlerde ise tam alt küme

regresyonunun en iyi performansı gösterdiğini ortaya koymuřtur. Ayrıca, model kombinasyonu kullanılarak tahmin dođruluđunda önemli iyileřmeler sađlanmıřtır. Domit vd. (2019), 2000:Q1-2012:Q3 döneminde Birleřik Krallık'taki ekonomik göstergeleri tahmin etmek için orta ölçekli bir Bayesyen VAR (BVAR) modeli kullanmıřtır. Çalışmada, BVAR modeli ile GSYH büyüme oranı ve enflasyon tahmin edilmiş ve bu tahminler İngiltere Merkez Bankası'nın DSGE modeli olan COMPASS ile karşılaştırılmıştır. Sonuçlar, BVAR modelinin GSYH büyümesi tahminlerinde COMPASS'a göre daha iyi performans gösterdiğini, ancak enflasyon tahminlerinde iki modelin performansının benzer olduğunu ortaya koymuřtur. Carriero vd. (2019), 1993:Q1-2013:Q4 döneminde ABD, Birleřik Krallık, Avrupa bölgesi, Almanya, Fransa, İtalya ve Japonya'da çıktı büyümesi ve enflasyon tahminlerini deđerlendirerek, faktör modelleri, BVAR modelleri, MIDAS modelleri ve DSGE modelleri arasında karşılařtırmalar yapmışlardır. Çalışma, geniş veri setlerini kullanan modellerin tahmin performanslarını, özellikle faktör modelleri ve MIDAS modelleri ile deđerlendirirken, BVAR modellerine kıyasla daha yüksek dođruluk sađladığını göstermiştir. Ayrıca, DSGE modellerinin uzun vadeli enflasyon tahminlerinde özellikle ABD ve Birleřik Krallık'ta başarılı sonuçlar elde ettiđi bulunmuřtur. Medeiros vd. (2021), 1960:01-2015:12 döneminde ABD'deki enflasyon tahminlerini makine öğrenimi yöntemleri kullanarak analiz etmiştir. Çalışmada, RF, LASSO ve Ridge regresyon gibi çeřitli makine öğrenimi modelleri uygulanmıştır. Sonuçlar, RF modelinin enflasyon tahminlerinde diđer yöntemlere göre daha yüksek dođruluk sađladığını ve özellikle verilerin dođrusal olmayan yapısını iyi yakaladığını göstermiştir. Çalışma, geniş veri setleriyle çalışmanın tahmin dođruluđunu %30'a kadar artırabileceđini ortaya koymuřtur. Peirano vd. (2021), 1958:01-2019:06 döneminde Latin Amerika ülkelerindeki enflasyonu tahmin etmek için mevsimsel otoregresif entegre hareketli ortalama (SARIMA) ve uzun kısa süreli bellek (LSTM) modellerini birleřtirerek analiz etmişlerdir. Çalışmada, SARIMA ve LSTM modellerinin dođrusal ve dođrusal olmayan yönlerini birleřtirerek daha yüksek tahmin dođruluđu elde edilmiştir. Sonuçlar, önerilen SARIMA-LSTM modelinin, diđer tekil modellerden daha iyi tahmin performansı sađladığını göstermiştir.

Clark vd. (2024), 1980:Q1-2021:Q1 döneminde ABD enflasyon tahminlerini esnek, parametrik olmayan modeller kullanarak analiz etmişlerdir. Çalışmada, Gaussian süreç regresyonu ve Dirichlet süreç karıřımı modelleri kullanılmış ve bu yöntemlerin enflasyon tahminlerinde dođruluđu artırdığı görülmüřtür. Özellikle, pandemi dönemi gibi oynak dönemlerde bu modellerin geleneksel modellere göre daha iyi performans sergilediđi tespit edilmiştir. Almosova ve Andresen (2023), 1960:01-2020:06 döneminde ABD enflasyonunu tahmin etmek için LSTM ve diđer makine öğrenimi yöntemlerini kullanarak analiz etmişlerdir. Çalışmada, LSTM, SARIMA, Markov-switching ve NN modelleri karşılaştırılmış ve sonuçlar, LSTM'nin özellikle ayarlanmış ve sezonluk düzeltilmemiş veriler üzerinde en iyi performansı gösterdiğini ortaya koymuřtur. Ayrıca, modelin büyük řokların ardından enflasyon eğilimlerini dođru şekilde tahmin ettiđi bulunmuřtur. Hauzenberger vd. (2023), 1963:01-2021:01 döneminde ABD enflasyon tahminlerini dođrusal olmayan boyut indirgeme tekniklerini kullanarak analiz etmişlerdir. Çalışmada, makine öğrenimi teknikleriyle elde edilen gizli faktörler, zamanla deđişen parametre (TVP) regresyonları ile modelleme yapılmıştır. Sonuçlar, özellikle resesyon dönemlerinde dođrusal olmayan boyut indirgeme yöntemlerinin, dođrusal yaklařımlara kıyasla daha rekabetçi enflasyon tahminleri sađladığını göstermiştir.

Türkiye'de enflasyon tahmini, ülkenin benzersiz ekonomik kořulları ve enflasyon oranlarındaki oynaklık nedeniyle kritik bir çalışma alanı olmaktadır. Enflasyon tahminlerinin

doğruluğunu artırmak için geleneksel ekonometrik modeller, makine öğrenmesi teknikleri ve hibrit yaklaşımlar dahil olmak üzere çeşitli metodolojiler kullanılmaktadır. Ogunc vd. (2013), 2003:Q1-2011:Q2 döneminde Türkiye’de kısa vadeli enflasyon tahminlerini bir dizi ekonometrik model kullanarak analiz etmiştir. Çalışmada, tek değişkenli modeller, frekans ve zaman alanı ayrışmasına dayalı yaklaşımlar, Phillips eğrisi temelli zamanla değişen parametre modeli, VAR ve Bayesian VAR modelleri ile dinamik faktör modelleri kullanılmıştır. Sonuçlar, daha fazla ekonomik bilgi içeren modellerin rastgele yürüyüş modeline kıyasla tahmin doğruluğunu %30 oranında artırdığını göstermiştir. Ayrıca, tahminlerin birleştirilmesiyle elde edilen sonuçlar, bireysel modellere göre hata payının azaldığını ortaya koymuştur. Bulut (2018), 2006:04-2016:12 döneminde Türkiye’de 12 aylık ve 24 aylık enflasyon beklentilerini belirlemek için otoregresif dağıtılmış gecikmeli (ARDL) modelini kullanarak analiz etmiştir. Çalışmada, geçmiş enflasyon oranı, enflasyon hedefi, çıktı açığı, USD/TL döviz kuru, petrol fiyatı ve EMBI değişkenleri kullanılmıştır. Sonuçlar, 12 aylık enflasyon beklentisinin geçmiş enflasyon oranı, enflasyon hedefi, çıktı açığı, USD/TL kuru ve petrol fiyatı ile pozitif, gelişmekte olan piyasalar tahvil endeksi (EMBI) ile negatif ilişkili olduğunu, 24 aylık enflasyon beklentisinin ise sadece geçmiş enflasyon oranı ve USD/TL kuru ile pozitif, enflasyon hedefi ve EMBI ile negatif ilişkili olduğunu göstermiştir.

Deka ve Reşatoğlu (2019), 2018 döviz krizi sonrası dönemde Türkiye’deki döviz kuru ve enflasyon tahminlerini ARIMA modeli kullanarak analiz etmiştir. Çalışmada, ARIMA(3,1,3) modelinin Türkiye’nin döviz kuru tahmini için en uygun model olduğu ve ARIMA(1,1,4) modelinin ise TÜFE tahmininde en iyi performansı sağladığı tespit edilmiştir. Sonuçlar, ARIMA modelinin döviz kuru ve enflasyon tahminlerinde güvenilir bir yöntem olduğunu ortaya koymuştur. Akbulut (2022), 2006:01-2020:12 döneminde Türkiye’de enflasyon tahminlerini makine öğrenimi ve zaman serisi modellerini kullanarak analiz etmiştir. Çalışmada, Ridge, Lasso ve çok katmanlı algılayıcı (MLP) modelleri ile VAR modelinin tahmin performansları karşılaştırılmıştır. Sonuçlar, MLP algoritmasının doğrusal modellerden daha iyi tahmin sonuçları verdiğini, ancak VAR modelinin en iyi performansı gösterdiğini ortaya koymuştur. Ayrıca, oynaklığın yüksek olduğu dönemlerde doğrusal olmayan modellerin enflasyon tahminlerinde daha başarılı olduğu tespit edilmiştir. Özgür ve Akkoç (2022), 2007:03-2019:07 döneminde Türkiye’deki enflasyon tahminlerini makine öğrenimi algoritmaları (ridge, lasso, ada lasso ve elastic net) kullanarak analiz etmişlerdir. Çalışmada, ARIMA ve VAR gibi geleneksel ekonometrik modeller ile makine öğrenimi teknikleri karşılaştırılmıştır. Sonuçlar, lasso ve elastic net algoritmalarının, özellikle yüksek enflasyon ve oynaklık dönemlerinde daha iyi tahmin performansı sağladığını göstermiştir. Enerji üretimi, inşaat sektörü göstergeleri ve reel efektif döviz kuru enflasyon tahminlerinde öne çıkan değişkenler olmuştur.

Rayner ve Bolhuis (2020), 2012:Q1-2019:Q4 döneminde Türkiye’deki makroekonomik büyüme tahminlerini, geleneksel en küçük kareler tabanlı yöntemler yerine makine öğrenimi teknikleri kullanarak analiz etmişlerdir. Çalışmada, RF, Gradyan Destekli Ağaçlar ve Destek Vektör Makineleri gibi makine öğrenimi algoritmaları kullanılmıştır. Sonuçlar, makine öğrenimi yöntemlerinin geleneksel modellerden %30 daha düşük tahmin hatası verdiğini göstermiştir. Özellikle ekonomik büyümede büyük dalgalanmaların yaşandığı dönemlerde bu yöntemlerin daha iyi performans sergilediği ortaya konmuştur. Aras ve Lisboa (2022), 2007:01-2021:08 döneminde Türkiye’deki enflasyon tahminlerini makine öğrenimi ve ekonometrik yöntemler kullanarak analiz etmişlerdir. Çalışmada, Ridge, Lasso, RF, XGBoost gibi makine öğrenimi algoritmaları ile VAR gibi geleneksel ekonometrik modeller karşılaştırılmıştır. Sonuçlar, RF ve

XGBoost modellerinin tahmin doęruluęu aısından dięer yntemlere gre stn performans sergiledięini gstermiřtir. Ayrıca, tahminlerde Shapley deęerleri kullanılarak, deęiřkenlerin etkilerini aıklayıcı bir modelleme sunulmuřtur. Ivařcu (2023), 2000:01-2020:08 dneminde Romanya'daki enflasyonu tahmin etmek iin makine ęrenimi modellerini kullanarak analiz yapmıřtır. alıřmada, Destek Vektr Regresyonu, Sinir Aęları, LSTM, RF, XGBoost ve Hafif Gradyan Artırma Makinesi (LightGBM) gibi popler makine ęrenimi algoritmaları tek deęiřkenli ve ok deęiřkenli analizlerde test edilmiřtir. Sonular, verinin az olduęu ortamlarda bu yntemlerin basit otoregresif modelleri geemedięini gstermiřtir.

Sonuç olarak, literatrde hem Trkiye'de hem de uluslararası dzeyde enflasyon tahmini zerine yapılan alıřmalar, eřitli model ve yaklařımların etkinlięini ortaya koymakta ve bu alanda yapılacak yeni alıřmaların hem geleneksel yntemlerle hem de modern makine ęrenmesi yaklařımlarıyla karřılařtırmalı olarak ele alınmasının nemli katkılar saęlayacaęını gstermektedir.

3. Veri Seti ve Metodoloji

3.1. Veri Seti

Enflasyon, talep enflasyonu, maliyet enflasyonu ve yapısal enflasyon olarak kategorize edilebilecek eřitli faktrlerden etkilenen karmařık bir makroekonomik olgudur. Enflasyonu kapsamlı bir řekilde anlamak iin para arzı, faiz oranları, dviz kurları ve ekonomik byme gstergeleri gibi makroekonomik verilerin analiz edilmesi gerekmektedir. Enflasyonun bařlıca belirleyicilerinden biri olan para arzı, enflasyon oranları zerinde nemli bir etkiye sahiptir. Arařtırmalar, para arzındaki artıřın enflasyon oranlarını ykselttięini, nkn dolařımdaki para miktarının artmasının mal ve hizmetlere olan talebi artırarak fiyatları yukarı ektięini gstermektedir. Malezya'da yapılan bir alıřmada, toplam para arzının enflasyon oranları zerinde nemli ve pozitif bir etkiye sahip olduęu vurgulanmıř ve bu durum, para politikasının enflasyon kontrolndeki kritik roln ne ıkarmıřtır (Yusof vd., 2021). Benzer řekilde, Endonezya'da yapılan bir arařtırma, para arzının enflasyonu pozitif ve anlamlı bir řekilde etkiledięini bulmuř ve bu bulgu, enflyonist eęilimleri anlamada parasal faktrlerin nemini pekiřtirmiřtir (Jumhur vd., 2018). Trkiye'de yapılan bařka bir alıřmada, kısa ve uzun vadede para arzı ile enflasyon arasında anlamlı iliřkiler tespit edilmiřtir (Tursoy ve Mar'i, 2020). Benzer řekilde, Pakistan ve Endonezya'da yapılan arařtırmalar da para arzının enflasyonun bařlıca belirleyicisi olduęunu ortaya koymuřtur (Kemal, 2022; Honor, 2018).


Faiz oranları da enflasyon zerinde belirleyici bir rol oynamaktadır. Yksek faiz oranları genellikle borlanmayı ve harcamayı caydırarak enflasyonun dřmesine neden olabilirken, dřk faiz oranları ekonomik faaliyetleri teřvik ederek enflasyonu artırabilir. Faiz oranları ve enflasyon arasındaki iliřkiyi Taylor Kuralı belirlemektedir. Taylor Kuralı, merkez bankalarının enflasyon ve dięer ekonomik kořulları hesaba katmak iin faiz oranlarını nasıl deęiřtirmesi gerektięini nermektedir (Berument ve Tařçı, 2004; Yazgan ve Yilmazkuday, 2007; Kose vd., 2012).

Dviz kurları, enflasyonu etkileyen bir dięer kritik faktrdr. Yerel para biriminin deęer kaybetmesi, ithalat fiyatlarının artmasına ve bu durumun da enflasyona katkıda bulunmasına yol aabilmektedir. Literatrde bu durum dviz kurundan fiyatlara geiřkenlik olarak bilinmektedir (Kara vd., 2007; Ha vd., 2020). Kamber ve Wong'un (2020) arařtırması, kresel faktrlerin enflasyonu etkiledięini, ancak dviz kurları gibi yerel faktrlerin de farklı ekonomilerde

enflasyon oranlarını belirlemede önemli bir rol oynadığını öne sürmüştür. Son olarak, ekonomik aktivite, enflasyonla karmaşık bir şekilde ilişkilidir. Ekonomik aktivite, talep artışına yol açabilir ve arz bu talebe ayak uyduramazsa fiyatlar artabilir. Yılmaz’ın (2023) ABD’deki enflasyon üzerine yaptığı araştırma, özellikle talep genişlemesi bağlamında ekonomik aktivitenin enflasyonu etkileyen önemli bir faktör olduğunu göstermektedir.

Sonuç olarak literatür incelendiğinde, enflasyonun, para arzı, faiz oranı, döviz kurları ve ekonomik aktiviteden etkilendiği görülmektedir. Bu çalışmada 1994:01-2024:06 dönemi için aylık frekansta tüketici fiyat endeksi (2015=100), belirleyicileri olarak sanayi üretim endeksi (2015=100) (ekonomik aktivite göstergesi olarak), döviz kuru ve faiz oranı (TCMB gecelik borç verme faiz oranı) verileri kullanılmıştır. Veriler, Türkiye Cumhuriyet Merkez Bankası (TCMB) Elektronik Veri Dağıtım Sistemi’nden alınmıştır. Sanayi üretim endeksi (2015=100), Tramo-Seats yöntemi kullanılarak mevsimsellikten arındırılmıştır. Döviz kuru verileri, 1999 öncesinde ABD doları ve Alman markı, 1999 sonrasında ise dolar ve avro üzerinden oluşturulmuştur. 1999 sonrası dönem için, avro ve dolar kurlarının Türk lirası karşılıklarının ortalaması alınarak hesaplanırken, 1994-1999 dönemi için avro ile Alman mark (DM) arasındaki resmi dönüşüm oranı kullanılarak (döviz kuru 0.5 USD + 0.974027 DM şeklinde) hesaplanmıştır (Berument vd., 2014).

Çalışmanın literatüre önemli katkısı kriz dönemlerinin öngörüsünde XGBoost yönteminin başarısının tespit edilmesi olduğu için 1990-2024 arası Türkiye’de gerçekleşen kriz dönemlerinin belirlenmesi gerekmektedir. Bu kriz dönemleri, 1994 ekonomik krizi, 2001 finansal krizi, 2008 küresel finansal krizi ve 2018 döviz krizi olarak belirlenmiştir. Ayrıca 2021 yılının başından itibaren TCMB tarafından başlanan faiz indirimlerinden sonra oluşan yüksek enflasyon dönemi de ele alınmıştır. Grafik 1’de 1990-2024 arasında aylık enflasyonun değişimi ve seçili kriz dönemleri verilmiştir.



Grafik 1. Tarihsel Enflasyon Verileri ve Seçili Dönemler

Grafik 1’de kırmızı ile gösterilen bölgeler XGBoost ve ARMA modelinin performanslarının test edileceği bölgeleri göstermektedir. Ayrıca Tablo 1’de bu dönemler açıkça verilmiştir.

Tablo 1. Seçili Dönemler

Tarih	Enflasyon	Tarih	Enflasyon	Tarih	Enflasyon
01.04.1994	23.38	01.09.2001	5.89	01.12.2018	-0.4
01.05.1994	8.25	01.10.2001	6.07	01.01.2019	1.06
01.06.1994	1.96	01.01.2010	1.85	01.02.2019	0.16
01.07.1994	3.13	01.02.2010	1.45	01.03.2019	1.03
01.08.1994	2.84	01.03.2010	0.58	01.12.2021	13.58
01.09.1994	6.19	01.04.2010	0.6	01.01.2022	11.1
01.10.1994	7.26	01.05.2010	-0.36	01.02.2022	4.81
01.04.2001	10.33	01.06.2010	-0.56	01.03.2022	5.46
01.05.2001	5.05	01.07.2010	-0.48	01.04.2022	7.25
01.06.2001	3.13	01.09.2018	6.3	01.05.2022	2.98
01.07.2001	2.39	01.10.2018	2.67	01.06.2022	4.95
01.08.2001	2.94	01.11.2018	-1.44		

3.2. Metodoloji

XGBoost algoritması, 2016 yılında Chen ve Guestrin (2016) tarafından oluşturulan bir Gradient Boosting (gradyan artırma) yöntemidir. Çeşitli veri madenciliği senaryolarında ve algoritma yarışmalarında yaygın olarak kullanılmaktadır. Algoritmanın temel avantajları hassasiyet, esneklik ve eksik değerlerin otomatik olarak işlenmesidir. XGBoost algoritmasını anlamak için öncelikle gradyan artırma yöntemi açıklanmıştır.

Gradyan artırma, zayıf tahmin modellerinin bir araya getirilmesiyle oluşturulan doğrusal eklemeli bir modeldir. Nihai model F_M 'yi elde etmek için süreç, M adımda gerçekleştirilmektedir. Her adımda yeni bir temel model $h_{m+1}(x)$ eğitilmektedir. Ardından eğitilen model, önceki modelin tahmin hatalarına dayanan artık değerleri $y - F_m$ ile optimize edilmektedir. Bu yöntem, yeni modellerin tahmin hatalarını azaltarak, topluluk modeli olan F_M 'yi güçlendirerek daha doğru bir tahmin elde edilmesine olanak sağlamaktadır (Friedman, 2001).

$$F_{m+1} = F_m + h_{m+1}(x) \quad (1)$$

Burada, asıl amaç $h_{m+1}(x) = F_{m+1} - F_m$ 'nin nasıl bulunacağını hesaplanmasına dönüşmektedir. Genellikle, temel model $h_{m+1}(x)$ 'i öğrenmek için artık değer olarak, amaç fonksiyonunun negatif gradyanı kullanılmaktadır. XGBoost, birden fazla zayıf sınıflandırıcıyı doğrusal bir şekilde güçlü bir sınıflandırıcıda birleştiren bir Gradient Boosting uygulamasıdır. XGBoost, temel sınıflandırıcılar olarak hem sınıflama ve regresyon ağaçları (CART) hem de doğrusal sınıflandırıcıları desteklemektedir. Maliyet fonksiyonu üzerinde ikinci dereceden Taylor genişletmesi gerçekleştirerek daha bol bilgi ifade etmektedir. Çalışma hızı açısından, XGBoost bölünme noktalarının paralel seçimini desteklemektedir. Bu sayede model eğitimi çok daha az zamana mal olmaktadır. XGBoost'un ana fikri, farklı ağırlıklara sahip zayıf ağaçları sürekli olarak kümeye eklemektir. Kümedeki ağaçlar bir önceki tahminin artıklarına mümkün olduğunca yaklaşmalıdır, bu da (2) numaralı eşitlikteki gibi ifade edilmektedir:

$$\hat{y}_i = \sum_{k=1}^K f_k(x_i) \quad f_k \in F \quad (2)$$

Burada \hat{y}_i tahmin edilen değer, F tüm regresyon ağaçlarını içeren küme, f_k regresyon ağaçlarından biri ve K regresyon ağacı sayısıdır. Tahmin edilen değer \hat{y}_i 'nin gerçek değer y_i 'ye mümkün olduğunca yakın olması ve bu arada genelleme yeteneğini kaybetmemesi

beklenmektedir. Amaç fonksiyonu (Obj)’yi hesaplamak için kullanılan formül (3) numaralı eşitlikte verilmiştir:

$$Obj^{(t)} = \sum_{i=1}^n l(y_i, \hat{y}_i^{(t)}) + \sum_{i=1}^t \Omega(f_t) + \text{sabit} \quad (3)$$

Burada, $l(y_i, \hat{y}_i^{(t)})$ tahmin edilen değer ile gerçek değer arasındaki farkı temsil eden kayıp fonksiyonudur. İkinci dereceden türetilen herhangi bir kayıp fonksiyonu olabilir. $\Omega(f_t)$, modelin karmaşıklığını tanımlayan düzenleme terimidir. $\Omega(f_t)$ değeri ne kadar küçük olursa, karmaşıklık o kadar düşük ve genelleme yeteneği o kadar güçlü olmaktadır.

$$\Omega(f) = \gamma T + \frac{1}{2} \lambda \|w\|^2 \quad (4)$$

Burada T yaprak düğümlerinin sayısı ve W yaprak düğümleri tarafından temsil edilen skordur. XGBoost yöntemi, gradyan artırma sürecinde kayıp fonksiyonunu genişletmek için ikinci dereceden Taylor açılımını kullanmaktadır. Nihai amaç fonksiyonu (5)-(12) numaraları denklemlerde verilmiştir:

$$Obj^{(t)} \approx \sum_{i=1}^n \left[g_i f_t(x_i) + \frac{1}{2} h_i f_t^2(x_i) \right] + \Omega(f_t) \quad (5)$$

$$= \sum_{i=1}^n \left[g_i w_{q(x_i)} + \frac{1}{2} h_i w_{q(x_i)}^2 \right] + \gamma T + \lambda \frac{1}{2} \sum_{j=1}^T w_j^2 \quad (6)$$

$$= \sum_{j=1}^T \left[\left(\sum_{i \in I_j} g_i \right) w_j + \frac{1}{2} \left(\sum_{i \in I_j} h_i + \lambda \right) w_j^2 \right] + \gamma T \quad (7)$$

$$g_i = \partial_{\hat{y}^{(t-1)}} l(y_i, \hat{y}_i^{(t-1)}), h_i = \partial_{\hat{y}^{(t-1)}}^2 l(y_i, \hat{y}_i^{(t-1)}) \quad (8)$$

$$Obj^{(t)} \approx \sum_{i=1}^n \left[g_i f_t(x_i) + \frac{1}{2} h_i f_t^2(x_i) \right] + \Omega(f_t) \quad (9)$$

$$= \sum_{i=1}^n \left[g_i w_{q(x_i)} + \frac{1}{2} h_i w_{q(x_i)}^2 \right] + \gamma T + \lambda \frac{1}{2} \sum_{j=1}^T w_j^2 \quad (10)$$

$$= \sum_{j=1}^T \left[\left(\sum_{i \in I_j} g_i \right) w_j + \frac{1}{2} \left(\sum_{i \in I_j} h_i + \lambda \right) w_j^2 \right] + \gamma T \quad (11)$$

$$g_i = \partial_{\hat{y}^{(t-1)}} l(y_i, \hat{y}_i^{(t-1)}), h_i = \partial_{\hat{y}^{(t-1)}}^2 l(y_i, \hat{y}_i^{(t-1)}) \quad (12)$$

Burada g_i ve h_i hata fonksiyonundaki her bir veri noktasının birinci dereceden türevi ve ikinci dereceden türevidir ve I_j her bir j yaprak düğümündeki örneklerin indeks kümesidir.

$$I_j = \{i \mid q(x_i) = j\} \quad (13)$$

Verilen $q(x_i)$ için w_j 'nin türevini 0'a eşit alarak j yaprak düğümünün en iyi ağırlığı w_j^* elde edilebilir.

$$w_j^* = -\frac{\sum_{i \in I_j} g_i}{\sum_{i \in I_j} h_i + \lambda} \quad (14)$$

Optimum deęer (15) numaralı eşitlikte hesaplanmaktadır:

$$\tilde{L}^{(t)}(q) = -\frac{1}{2} \sum_{j=1}^T \frac{(\sum_{i \in I_R} g_i)^2}{\sum_{i \in I_R} h_i + \lambda} - \frac{(\sum_{i \in I} g_i)^2}{\sum_{i \in I} h_i + \lambda} - \gamma \quad (15)$$

4. Bulgular

Öngörü çalışmalarında tahmin edilen modelin aşırı öğrenme (overfitting) yapmaması için genellikle veri setleri öğrenme ve test verisi olarak iki parçaya ayrılır. Bu çalışmada tüm veri setinin %75'i (310 gözlem) model tahmini için, kalan %25'i (103 gözlem) ise tahmin edilen modelin uyumu için test verisi olarak kullanılmaktadır. 1990:02- 2015:11 arası eğitim veri seti, 2015:12 - 2024:06 arası ise test veri setidir. Bununla birlikte çalışmada XGBoost yönteminin kriz dönemlerindeki başarısını belirlemek amacıyla farklı alt dönemler ele alınmıştır. Bu alt dönemler Tablo 2'de verilmiştir. Öngörü performansının değerlendirilmesinde literatürde farklı ölçütler kullanılmaktadır. Ortalama Hatanın Karekökü (RMSE) yaygın ancak ölçüğe baęlı bir ölçüttür ancak farklı deęişkenlere veya frekanslara sahip modelleri karşılařtırmak için uygun deęildir. Bu çalışmada, farklı veri kümeleri için daha iyi olan Simetrik Ortalama Mutlak Yüzde Hata (sMAPE) ve Ortalama Mutlak Ölçekli Hata (MASE) ölçütleri kullanılmıştır. sMAPE, ölçekten bağımsızlığı ve yorumlanabilirliği nedeniyle sıklıkla kullanılırken, MASE, sMAPE kullanımından kaynaklanan potansiyel sorunları azaltmaktadır. İlgili formüller denklem (16) ve (17)'de yer almaktadır.

$$sMAPE = \frac{2}{h} \sum_{t=1}^h \frac{2|Y_t - \hat{Y}_t|}{|Y_t| + |\hat{Y}_t|} \times 100 \quad (16)$$

$$MASE = \frac{1}{g} \frac{\sum_{t=1}^h |Y_t - \hat{Y}_t|}{\frac{1}{n-m} \sum_{t=m+1}^n |Y_t - Y_{t-m}|} \quad (17)$$

Burada, g dönem dışı tahminlerin miktarını, m veri sıklığını ve n toplam gözlem sayısını ifade etmektedir. Çok sayıda arařtırmacı, sadece sMAPE ve MASE kullanmak yerine Göreceli MASE (RelMASE) ve Göreceli sMAPE (RelMAPE) gibi 'göreceli' ölçütlerin kullanılmasını tavsiye etmiştir (Ahlburg, 1992; Fildes, 1992; Hyndman ve Koehler, 2006). Literatürde performans ölçütü olarak genellikle rastgele yürüyüş süreci kullanılmaktadır (Pesaran vd., 2009; Makridakis vd., 2020). Performans ölçütü olarak Rastgele Yürüyüş Modeli seçildikten sonra göreceli ölçütler, $RelMAPE = sMAPE/sMAPE_{RW}$ ve $RelMASE = MASE/MASE_{RW}$ formülüyle hesaplanmaktadır. Göreceli metriklerin hesaplanmasının ardından ağırlıklı ortalama alınarak Genel Ağırlıklı Ortalama (OWA) kriteri elde edilmektedir.

Çalışmanın temel amacı XGBoost yönteminin enflasyon öngörüsündeki performansını incelemektir. XGBoost yöntemi, temelinde bir karar ağaçları algoritması kullanarak, enflasyon öngörüsünde etkin bir yöntem olarak uygulanmıştır. Bu çalışmada, para arzı (M2), sanayi üretim endeksi (2015=100), döviz kuru ve faiz oranı gibi makroekonomik göstergeler, modelin girdi deęişkenleri olarak entegre edilmiştir. XGBoost, bu deęişkenler arasında karmaşık ilişkileri

öğrenip, her bir karar ağacını sırayla oluşturarak hataları minimize etmek amacıyla modellemeyi optimize etmektedir. Her yeni karar ağacı, önceki ağaçların hatalarını düzeltmek için eğitilmiş ve modelin doğruluğu bu şekilde arttırılmıştır. Bununla birlikte XGBoost yönteminin başarısını karşılaştırmak amacıyla ARMA modeli kullanılmıştır. ARMA modelleri zaman serileri analizinde kullanılan en temel modellerden birisidir. Enflasyon için en uygun model ARMA(1,1) çıkmıştır. Son olarak XGBoost yöntemine farklı bir bakış açısı ile ARMA modelinden gelen 1 gecikme bilgisi eklenmiştir. Diğer bir ifadeyle girdi değişkenleri olarak sanayi üretim endeksi (2015=100), döviz kuru, para arzı (M2) ve faiz oranının anlık değerlerine ek olarak bunların ve enflasyonun 1 gecikmeli değerleri de model dahil edilmiştir. Bu model XGBoost (Gecikmeli) olarak adlandırılmıştır. Tablo 2’de farklı dönemler için bahsedilen modellerin öngörü performanslarına ilişkin sonuçlar verilmiştir. Faiz hariç tüm değişkenlerin logaritmik farkı kullanılmıştır. Faiz serisinin ise yalnızca farkı alınmıştır.

Tablo 2. Farklı Dönemler İçin Modellerin Öngörü Performanslarına İlişkin Sonuçlar

Dönemler		ARMA(1,1)	XGBoost	XGBoost Gecikmeli	RW
1990:01-1994:10 (n=57)	MAPE	0.60	0.54	0.80	0.78
	RealMAPE	0.77	0.70	1.03	1.00
	sMAPE	61.15	71.65	73.67	63.73
	RealsMAPE	0.96	1.12	1.16	1.00
	OWA	0.87	0.91	1.09	1.00
	Başarı Yüzdesi	13.30	8.87	-9.28	0.00
1990:01-2001:10 (n=141)	MAPE	0.43	0.72	0.30	0.45
	RealMAPE	0.95	1.59	0.66	1.00
	sMAPE	38.04	51.80	26.60	61.45
	RealsMAPE	0.62	0.84	0.43	1.00
	OWA	0.79	1.22	0.55	1.00
	Başarı Yüzdesi	21.47	-21.78	45.31	0.00
1990:01-2010:07 (n=246)	MAPE	3.82	2.11	1.64	2.10
	RealMAPE	1.82	1.00	0.78	1.00
	sMAPE	125.87	121.39	126.23	164.05
	RealsMAPE	0.77	0.74	0.77	1.00
	OWA	1.29	0.87	0.78	1.00
	Başarı Yüzdesi	-29.49	12.79	22.31	0.00
1990:01-2019:03 (n=350)	MAPE	2.38	1.53	1.42	3.59
	RealMAPE	0.66	0.43	0.40	1.00
	sMAPE	127.98	96.51	111.76	133.86
	RealsMAPE	0.96	0.72	0.83	1.00
	OWA	0.81	0.57	0.62	1.00
	Başarı Yüzdesi	19.06	42.59	38.49	0.00
1990:01-2022:06 (n=389)	MAPE	0.39	0.72	0.43	0.66
	RealMAPE	0.60	1.10	0.66	1.00
	sMAPE	94.65	121.16	43.90	98.97
	RealsMAPE	0.96	1.22	0.44	1.00
	OWA	0.78	1.16	0.55	1.00
	Başarı Yüzdesi	22.24	-16.00	45.07	0.00
1990:01-2024:06 (Tüm veri dönemi n=413)	MAPE	2.13	3.59	2.25	2.02
	RealMAPE	1.06	1.78	1.12	1.00
	sMAPE	70.57	78.86	60.95	120.93
	RealsMAPE	0.58	0.65	0.50	1.00
	OWA	0.82	1.22	0.81	1.00
	Başarı Yüzdesi	17.94	-21.76	18.97	0.00

Tablo 2 incelendiđinde, 1990:01-1994:10 dneminde ARMA(1,1) yntemi %13.3 bařarı oranıyla en yksek performansı gsterirken, XGBoost %8.87 ile onun gerisinde kalmıřtır. Gecikmeli XGBoost ise negatif bir bařarı oranıyla (-%9.28) en dřk performansı sergilemiřtir. Bu bulgu, Stock ve Watson (2007) tarafından basit tek deđiřkenli modellerin, bazı dnemlerde ok deđiřkenli modellere kıyasla daha yksek dođruluk sađlayabileceđi bulgularıyla uyumludur. XGBoost'un performans dřklđ, sınırlı veri gzlemlerine sahip bu dnemde karmařık yapısının etkin alıřamamasından kaynaklanmıř olabilir. 1990:01- 2001:10 dneminde ise Gecikmeli XGBoost %45.31 ile aık ara en bařarılı yntem olmuřtur. ARMA(1,1) %21.47 ile daha makul bir bařarı gsterirken, XGBoost negatif bir bařarı oranıyla (-%21.78) en kt performansı gstermiřtir. 1990:01- 2010:07 dneminde, Gecikmeli XGBoost %22.31 ile yine en bařarılı yntem olurken, XGBoost %12.79 ile ortalama bir bařarı gstermiřtir. ARMA(1,1) ise bu dnemde negatif bir bařarı oranı (-%29.49) ile en dřk performansı sergilemiřtir. 1990:01-2019:03 dnemine bakıldıđında, XGBoost %42.59 bařarı oranıyla en yksek performansa sahiptir. Ancak, Gecikmeli XGBoost %38.49 ile ona ok yakın bir bařarı gstermiřtir. ARMA(1,1) ise %19.06 bařarı oranıyla daha dřk bir performans sergilemiřtir. 1990:01-2022:06 dneminde yine Gecikmeli XGBoost %45.07 ile en yksek bařarı oranına sahipken, ARMA(1,1) %22.24 ile orta seviyede bir bařarı gstermiřtir. XGBoost ise -%16 bařarı oranıyla en dřk performansı gstermiřtir. Tm veri dnemi olan 1990:01- 2024:06 dneminde Gecikmeli XGBoost %18.97 bařarı oranı ile en bařarılı yntem olmuřtur. ARMA(1,1) %17.94 ile ok yakın bir performans gstermiřtir. Ancak XGBoost yine negatif bir bařarı oranı (-%21.76) ile en dřk performansı gstermiřtir. Gecikmeli XGBoost'un stn performansı, zellikle byk veri setlerinde ve kriz dnemlerinde zaman serisi iindeki isel bađımlılıkları yakalama kabiliyetinden kaynaklanmaktadır. Bu bulgu, Koop (2013) ve Faust ve Wright (2013) alıřmalarında ileri srlen, dođrusal olmayan modellerin daha karmařık veri setlerinde daha bařarılı sonular verdiđi bulgularıyla uyumludur. Ayrıca Nakamura (2005) ve McAdam ve McNelis (2005) alıřmaları, dođrusal olmayan modellerin dođrusal modellere kıyasla daha iyi sonular verdiđini gsterirken, zgr ve Akko (2022) alıřmasında, yksek oynaklık dnemlerinde makine đrenimi modellerinin stn performans gsterdiđini belirtmiřtir.

Kriz dnemlerinde genel olarak Gecikmeli XGBoost, zellikle uzun veri dneminde sahip kriz dnemlerinde (%45.31 ile 1990:01- 2001:10 ve %45.07 ile 1990:01- 2022:06) en yksek bařarı oranlarına ulařarak olduka bařarılı sonular vermiřtir. XGBoost ise bazı dnemlerde (%42.59 ile 1990:01- 2019:03) bařarılı olsa da, diđer dnemlerde dřk ve hatta negatif bařarı oranları ile etkisiz kalmıřtır. Bu nedenle kriz dnemlerinde Gecikmeli XGBoost yntemi, genel olarak daha istikrarlı ve bařarılı bir ngr aracı olarak ne ıkmaktadır. Bu bulgu, Ogunc vd. (2013) alıřmasındaki tahmin modellerinin kriz dnemlerinde daha iyi sonular verdiđi bulgularıyla uyumlu grnmektedir. Ancak, yalnızca 1990:01-1994:10 dneminde ARMA modelinin performansı XGBoost ve Gecikmeli XGBoost'a gre daha iyi ıkmıřtır. XGBoost, byk ve karmařık veri setleri zerinde gl performans gsteren bir makine đrenme algoritmasıdır. Ancak, bu dnemde kullanılan gzlem sayısının sınırlı olması, XGBoost'un potansiyel performansını ortaya koymasını zorlařtırmıřtır. Ivařcu (2023) verinin az olduđu ortamlarda makine đrenmesi algoritmalarının basit otoregresif modelleri geemediđini belirtmiřtir. Nitekim genel olarak elde edilen sonular bu bulguyla paralellik gstermektedir.

5. Sonuç

Bu çalışma, 1990-2024 tarihleri arasında Türkiye’deki enflasyon öngörüsünde XGBoost ve ARMA modellerinin performansını karşılaştırarak, kriz dönemlerinde bu yöntemlerin etkinliğini değerlendirmeyi amaçlamaktadır. Özellikle Türkiye’nin yaşadığı ekonomik kriz ve şok dönemlerinde (1994 krizi, 2001 finansal krizi, 2008 küresel finansal kriz, 2018 döviz krizi) her iki yöntemin tahmin doğruluğu incelenmiştir. Çalışmada XGBoost, karar ağaçları algoritmasına dayalı bir makine öğrenme yöntemi olarak, sanayi üretim endeksi, döviz kuru, para arzı (M2) ve faiz oranı gibi makroekonomik göstergeleri kullanarak enflasyon öngörüsünde uygulanmıştır. Ayrıca, gecikmeli verilerin modele dahil edildiği "Gecikmeli XGBoost" yöntemi de performans değerlendirmelerine eklenmiştir.

Bulgular, Gecikmeli XGBoost yönteminin gözlem sayısının fazla olduğu kriz dönemlerinde yüksek başarı oranları ile öne çıktığını göstermektedir. Özellikle 1990:01- 2001:10 ve 1990:01 - 2022:06 dönemlerinde Gecikmeli XGBoost, diğer yöntemlere kıyasla daha yüksek doğrulukta sonuçlar üretmiştir. Bununla birlikte, az sayıda gözleme sahip 1990:01 -1994:10 döneminde ARMA modeli, XGBoost ve Gecikmeli XGBoost’a göre daha iyi performans sergilemiştir. Bu durum, XGBoost’un küçük veri setlerinde potansiyel performansını tam olarak ortaya koyamadığını, ancak büyük veri setleri üzerinde daha etkin olduğunu işaret etmektedir. Ayrıca, çalışmada Gecikmeli XGBoost modelinin XGBoost’tan daha iyi performans göstermesi, enflasyon öngörüsünde gecikmeli değerlerin eklenmesinin önemli olduğunu ortaya koymaktadır. ARMA modelinden elde edilen gecikme bilgisinin XGBoost’a dahil edilmesi, XGBoost’un performansını önemli ölçüde artırmıştır. Bu bulgu, enflasyon tahminlerinde XGBoost yöntemi kullanılmasında sadece bağımsız değişkenlerin anlık değerlerinin değil, aynı zamanda gecikmeli değerlerinin de önemli bir açıklayıcı unsur olduğunu vurgulamaktadır. Gecikmeli XGBoost modelinin bu kadar başarılı olmasının nedeni, zaman serisi verilerindeki bu içsel bağımlılıkların dikkate alınmasıdır.

Genel olarak, çalışmada kriz dönemlerinde doğru enflasyon öngörüsü yapılabilmesi için kullanılan modelin veri seti büyüklüğü ve yapısına duyarlılığını göstermektedir. Gecikmeli XGBoost, uzun vadeli ve büyük veri setlerinde üstün performans sergilerken, ARMA modeli daha sınırlı veri setlerinde öne çıkmaktadır. Bu bulgular, gelecekte yapılacak enflasyon tahmin çalışmalarında model seçiminde dikkat edilmesi gereken noktalar üzerine önemli ipuçları sunmaktadır. Özellikle, zaman serisi dinamiklerinin dikkate alındığı modellerin daha güvenilir tahminler sunduğu, bu çalışmayla ortaya koyulmuştur. Elde edilen bulgular ışığında, enflasyon öngörülerinin daha etkin yapılabilmesi için politika yapıcıların kriz ve şok dönemlerinde makine öğrenmesi tekniklerinden faydalanmaları önerilmektedir. Özellikle Gecikmeli XGBoost gibi zaman serisi dinamiklerini dikkate alan modellerin, merkez bankaları ve ekonomik karar alıcılar tarafından enflasyon öngörüsü ve para politikalarının şekillendirilmesinde kullanılmasının, ekonomik istikrarı sağlama noktasında faydalı olacağı düşünülmektedir.

Araştırmacıların Katkı Oranı Beyanı

Yazarlar makaleye eşit oranda katkı sağlamış olduklarını beyan eder.

Araştırma ve Yayın Etiği Beyanı

Etik kurul izni ve/veya yasal/özel izin alınmasına gerek olmayan bu çalışmada araştırma ve yayın etiğine uyulmuştur.

Araştırmacıların Çıkar Çatışması Beyanı

Bu çalışmada herhangi bir potansiyel çıkar çatışması bulunmamaktadır.

Kaynakça

- Ahlburg, A.D. (1992). Predicting the job performance of managers: What do the experts know? *International Journal of Forecasting*, 7(4), 467-472. [https://doi.org/10.1016/0169-2070\(92\)90030-D](https://doi.org/10.1016/0169-2070(92)90030-D)
- Akbulut, H. (2022). Forecasting inflation in Turkey: A comparison of time-series and machine learning models. *Economic Journal of Emerging Markets*, 14(1), 55-71. <https://doi.org/10.20885/ejem.vol14.iss1.art5>
- Almosova, A. and Andresen, N. (2023). Nonlinear inflation forecasting with recurrent neural networks. *Journal of Forecasting*, 42(2), 240–259. <https://doi.org/10.1002/for.2901>
- Aras, S. and Lisboa, P. (2022). Explainable inflation forecasts by machine learning models. *Expert Systems with Applications*, 207, 117982. <https://doi.org/10.1016/j.eswa.2022.117982>
- Berument, H.M. and Taşçi, H. (2004). Monetary policy rules in practice: Evidence from Turkey. *International Journal of Finance & Economics*, 9(1), 33-38. <https://doi.org/10.1002/ijfe.219>
- Berument, M.H., Ceylan, N.B. and Dogan, B. (2014). An interest-rate-spread-based measure of Turkish monetary policy. *Applied Economics*, 46(15), 1804–1813. <https://doi.org/10.1080/00036846.2014.884703>
- Bulut, Ü. (2018). Inflation expectations in Turkey: Determinants and roles in missing inflation targets. *Journal of Central Banking Theory and Practice*, 7(3), 73-90. <https://doi.org/10.2478/jcbtp-2018-0024>
- Carriero, A., Galvao, A.B. and Kapetanios, G. (2019). A comprehensive evaluation of macroeconomic forecasting methods. *International Journal of Forecasting*, 35(4), 1226–1239. <https://doi.org/10.1016/j.ijforecast.2019.02.007>
- Chen, T. and Guestrin, C. (2016). XGBoost: A scalable tree boosting system. In B. Krishnapuram and M. Shah (Eds.), *Proceedings of the 22nd ACM SIGKDD international conference on knowledge discovery and data mining* (pp. 785-794). Papers presented at the KDD '16: The 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. San Francisco, California. New York: Association for Computing Machinery.
- Chen, X., Racine, J. and Swanson, N.R. (2001). Semiparametric ARX neural-network models with an application to forecasting inflation. *IEEE Transactions on Neural Networks*, 12(4), 674–683. Retrieved from <https://ieeexplore.ieee.org/>
- Clark, T.E., Huber, F., Koop, G. and Marcellino, M. (2024). Forecasting US inflation using Bayesian nonparametric models. *The Annals of Applied Statistics*, 18(2), 1421-1444. doi:10.1214/23-AOAS1841
- Deka, A. and Reşatoğlu, N. (2019). Forecasting foreign exchange rate and consumer price index with Arima model: The case of Turkey. *International Journal of Scientific Research and Management*, 7(08), 1254-1275. <https://doi.org/10.18535/ijstrm/v7i8.em01>
- Domit, S., Monti, F. and Sokol, A. (2019). Forecasting the UK economy with a medium-scale Bayesian VAR. *International Journal of Forecasting*, 35(4), 1669–1678. <https://doi.org/10.1016/j.ijforecast.2018.11.004>
- Dwumfour, R. (2019). Explaining banking spread. *Journal of Financial Economic Policy*, 11(1), 139-156. <https://doi.org/10.1108/jfep-02-2018-0031>
- Faust, J. and Wright, J.H. (2013). Forecasting inflation. In G. Elliott and A. Timmermann (Eds.), *Handbook of economic forecasting: Volume 2A* (pp. 2–56). Princeton: Princeton University Press.
- Fildes, R. (1992). Forecasting structural time series models and the Kalman filter. *International Journal of Forecasting*, 8(4), 635. [https://doi.org/10.1016/0169-2070\(92\)90072-h](https://doi.org/10.1016/0169-2070(92)90072-h)
- Friedman, J.H. (2001). Greedy function approximation: A gradient boosting machine. *Annals of Statistics*, 29(5), 1189-1232. <https://doi.org/10.1214/aos/1013203451>
- Garcia, M.G., Medeiros, M.C. and Vasconcelos, G.F. (2017). Real-time inflation forecasting with high-dimensional models: The case of Brazil. *International Journal of Forecasting*, 33(3), 679–693. <https://doi.org/10.1016/j.ijforecast.2017.02.002>

- Girdzijauskas, S., Štreimikienė, D., Griesienė, I., Mikalauskiene, A. and Kyriakopoulos, G. (2022). New approach to inflation phenomena to ensure sustainable economic growth. *Sustainability*, 14(1), 518. <https://doi.org/10.3390/su14010518>
- Gono, D. (2023). Silver price forecasting using extreme gradient boosting (XGBoost) method. *Mathematics*, 11(18), 3813. <https://doi.org/10.3390/math11183813>
- Ha, J., Stocker, M. and Yilmazkuday, H. (2020). Inflation and exchange rate passthrough. *Journal of International Money and Finance*, 105, 102187. <https://doi.org/10.1016/j.jimonfin.2020.102187>
- Hauzenberger, N., Huber, F. and Klieber, K. (2023). Real-time inflation forecasting using non-linear dimension reduction techniques. *International Journal of Forecasting*, 39(2), 901–921. <https://doi.org/10.1016/j.ijforecast.2022.03.002>
- Honoré, T. (2018). Monetary policy and inflation: Empirical evidence from Cameroon. *International Journal of Economics Finance and Management Sciences*, 6(5), 200-207. <https://doi.org/10.11648/j.ijefm.20180605.11>
- Hubrich, K. (2005). Forecasting euro area inflation: Does aggregating forecasts by HICP component improve forecast accuracy? *International Journal of Forecasting*, 21(1), 119–136. <https://doi.org/10.1016/j.ijforecast.2004.04.005>
- Hyndman, R.J. and Koehler, A.B. (2006). Another look at measures of forecast accuracy. *International Journal of Forecasting*, 22(4), 679-688. <https://doi.org/10.1016/j.ijforecast.2006.03.001>
- Ivaşcu, C. (2023). Can machine learning models predict inflation? *Proceedings of the International Conference on Business Excellence*, 17(1), 1748-1756. <https://doi.org/10.2478/picbe-2023-0155>
- Ji, Y. (2023). Shock therapy in transition countries: A behavioral macroeconomic approach. *Comparative Economic Studies*, 65(3), 483-510. <https://doi.org/10.1057/s41294-023-00211-z>
- Jumhur, J., Nasrun, M., Agustiar, M. and Wahyudi, W. (2018). Pengaruh jumlah uang beredar, ekspor dan impor terhadap inflasi (Studi empiris pada perekonomian Indonesia). *Jurnal Ekonomi Bisnis Dan Kewirausahaan*, 7(3), 186-201. <https://doi.org/10.26418/jebik.v7i3.26991>
- Kamber, G. and Wong, B. (2020). Global factors and trend inflation. *Journal of International Economics*, 122, 103265. <https://doi.org/10.1016/j.jinteco.2019.103265>
- Kara, H., Küçük Tuğer, H., Özlale, U., Tuğer, B., Yavuz, D. and Yücel, M.E. (2007). *Exchange rate pass-through in Turkey: Has it changed and to what extent?* (CBRT Research Department Working Paper No. 05/04). Retrieved from <https://www.tcmb.gov.tr/wps/wcm/connect/EN/TCMB+EN/Main+Menu/Publications/Research/Working+Papers/2005/05-04>
- Kemal, M. (2022). Is inflation in Pakistan a monetary phenomenon? *The Pakistan Development Review*, 45(2), 213-220. <https://doi.org/10.30541/v45i2pp.213-220>
- Koop, G.M. (2013). Forecasting with medium and large Bayesian VARs. *Journal of Applied Econometrics*, 28(2), 177–203. 1537. <https://doi.org/10.1002/jae.1270>
- Kose, N., Emirmahmutoglu, F. and Aksoy, S. (2012). The interest rate–inflation relationship under an inflation targeting regime: The case of Turkey. *Journal of Asian Economics*, 23(4), 476-485. <https://doi.org/10.1016/j.asieco.2012.03.001>
- Li, Y.S., Pai, P.F., and Lin, Y.L. (2023). Forecasting inflation rates by extreme gradient boosting with the genetic algorithm. *Journal of Ambient Intelligence and Humanized Computing*, 14(3), 2211-2220. <https://doi.org/10.1007/s12652-022-04479-4>
- Makridakis, S., Spiliotis, E. and Assimakopoulos, V. (2020). The M4 Competition: 100,000-time series and 61 forecasting methods. *International Journal of Forecasting*, 36(1), 54-74. <https://doi.org/10.1016/j.ijforecast.2019.04.014>
- McAdam, P. and McNelis, P. (2005). Forecasting inflation with thick models and neural networks. *Economic Modelling*, 22(5), 848–867. <https://doi.org/10.1016/j.econmod.2005.06.002>
- Medeiros, M.C., Vasconcelos, G.F., Veiga, Á. and Zilberman, E. (2021). Forecasting inflation in a data-rich environment: The benefits of machine learning methods. *Journal of Business & Economic Statistics*, 39(1), 98–119. <https://doi.org/10.1080/07350015.2019.1637745>

- Nakamura, E. (2005). Inflation forecasting using a neural network. *Economics Letters*, 86(3), 373–378. <https://doi.org/10.1016/j.econlet.2004.09.003>
- Niyimbanira, F. (2013). An econometric evidence of the interactions between inflation and economic growth in South Africa. *Mediterranean Journal of Social Sciences*, 4(13), 219-225. <https://doi.org/10.5901/mjss.2013.v4n13p219>
- Noh, J., Cheon, J., Seong, H., Kwon, Y. and Yoo, K. (2023). Impacts of smoking ban policies on billiard hall sales in South Korea using objective sales information of a credit card company: Quasi-experimental study. *MIR Public Health Surveill*, 10, e50466. <https://doi.org/10.2196/preprints.50466>
- Ogunc, F., Akdoğan, K., Başer, S., Chadwick, M., Ertug, D., Hulagu, T., ... Tekatli, N. (2013). Short-term inflation forecasting models for Turkey and a forecast combination analysis. *Economic Modelling*, 33, 312-325. <https://doi.org/10.1016/j.econmod.2013.04.001>
- Özgür, O. and Akkoç, U. (2022). Inflation forecasting in an emerging economy: Selecting variables with machine learning algorithms. *International Journal of Emerging Markets*, 17(8), 1889-1908. <https://doi.org/10.1108/ijoem-05-2020-0577>
- Peirano, R., Kristjanpoller, W. and Minutolo, M. (2021). Forecasting inflation in Latin American countries using a SARIMA–LSTM combination. *Soft Computing*, 25(16), 10851-10862. <https://doi.org/10.1007/s00500-021-06016-5>
- Pesaran, M.H., Schuermann, T. and Smith, L.V. (2009). Forecasting economic and financial variables with global VARs. *International Journal of Forecasting*, 25(4), 642-675. <https://doi.org/10.1016/j.ijforecast.2009.08.007>
- Rayner, B. and Bolhuis, M. (2020). *Deus ex machina? A framework for macro forecasting with machine learning* (IMF Working Paper No. 20/45). <https://doi.org/10.5089/9781513531724.001>
- Rizinski, M., Peshov, H., Mishev, K., Chitkushev, L., Vodenska, I. and Trajanov, D. (2022). Ethically responsible machine learning in fintech. *IEEE Access*, 10, 97531-97554. <https://doi.org/10.1109/access.2022.3202889>
- Salkuti, S.R. (2020). A survey of big data and machine learning. *International Journal of Electrical & Computer Engineering*, 10(1), 575-580. <http://doi.org/10.11591/ijece.v10i1.pp575-580>
- Stock, J.H. and Watson, M.W. (1999). Forecasting inflation. *Journal of Monetary Economics*, 44(2), 293–335. [https://doi.org/10.1016/S0304-3932\(99\)00027-6](https://doi.org/10.1016/S0304-3932(99)00027-6)
- Stock, J.H. and Watson, M.W. (2007). Why has US inflation become harder to forecast? *Journal of Money, Credit and Banking*, 39, 3–33. <https://doi.org/10.1111/j.1538-4616.2007.00014.x>
- Stock, J.H. and Watson, M.W. (2008). *Phillips curve inflation forecasts* (NBER Working Paper No. 14322). Retrieved from https://www.nber.org/system/files/working_papers/w14322/w14322.pdf
- Stock, J.H. and Watson, M.W. (2016). Core inflation and trend inflation. *The Review of Economics and Statistics*, 98(4), 770–784. https://doi.org/10.1162/REST_a_00608
- Tursoy, T. and Mar'i, M. (2020). Lead-lag and relationship between money growth and inflation in Turkey: New evidence from a wavelet analysis. *Theoretical and Practical Research in Economic Fields*, 11(1), 47-57. [https://doi.org/10.14505/tpref.v11.1\(21\).04](https://doi.org/10.14505/tpref.v11.1(21).04)
- Yazgan, E. and Yilmazkuday, H. (2007). Monetary policy rules in practice: Evidence from Turkey and Israel. *Applied Financial Economics*, 17(1), 1-8. <https://doi.org/10.1080/09603100600606206>
- Yılmaz, S. (2023). Investigating factors influencing inflation in the USA. *Equinox Journal of Economics Business and Political Studies*, 10(2), 128-142. <https://doi.org/10.48064/equinox.1339198>
- Yusof, N., Nin, L., Kamal, H., Taslim, J. and Zainoddin, A. (2021). Factors that influence the inflation rate in Malaysia. *International Journal of Academic Research in Business and Social Sciences*, 11(9), 626-637. <https://doi.org/10.6007/ijarbss/v11-i9/10838>

INFLATION FORECASTING IN THE CONTEXT OF ECONOMIC SHOCKS AND CRISES IN TÜRKİYE: COMPARISON OF XGBOOST AND ARMA METHODS

EXTENDED SUMMARY

Objective

This study examines the performance of XGBoost, a machine learning algorithm, and the traditional ARMA (AutoRegressive Moving Average) model in forecasting inflation in Türkiye during periods of economic shocks and crises. Given Türkiye’s frequent exposure to economic crises (e.g., the 1994 economic crisis, the 2001 financial crisis, the 2008 global financial crisis, and the 2018 currency crisis), accurate inflation forecasting is critical for economic stability and policy formulation.

Literature Review

Existing literature extensively covers the use of traditional econometric models like ARMA and advanced machine learning techniques such as XGBoost for inflation forecasting. Time-series models, especially ARMA, have been widely used for forecasting macroeconomic indicators due to their ability to model linear patterns. However, recent studies show that machine learning models, particularly XGBoost, offer superior predictive capabilities in complex datasets, especially for nonlinear relationships. Furthermore, hybrid models combining machine learning algorithms with traditional methods are increasingly being employed to enhance forecasting accuracy during volatile periods (Akbulut, 2022; Aras and Lisboa, 2022).

Methodology

The dataset spans the period from January 1990 to June 2024. It includes macroeconomic indicators such as the Consumer Price Index (CPI), exchange rates, money supply (M2), and interest rates, all used as explanatory variables. The XGBoost model was applied to forecast inflation, using these variables as input. Additionally, a variant of the XGBoost model with lagged variables ("Lagged XGBoost") was implemented to assess its predictive strength. As a traditional econometric approach, the ARMA model was also applied for comparison. The study focuses on crisis periods and the entire sample period to evaluate model performance across different time horizons.

Findings

The results indicate that XGBoost outperforms ARMA during crisis periods, particularly when the dataset is large. Including lagged variables in the XGBoost model further improves predictive accuracy, demonstrating that the inflation forecast benefits significantly from incorporating time-series dynamics. For example, between 1990-2001 and 1990-2022, Lagged XGBoost showed superior forecasting accuracy compared to ARMA and the standard XGBoost

model. However, ARMA proved more effective in shorter time spans or when the dataset is smaller, suggesting that XGBoost's potential is best realized with larger, more complex datasets.

Conclusion

This study demonstrates that XGBoost, particularly when augmented with lagged variables, is highly effective in forecasting inflation during periods of economic volatility in Türkiye. However, traditional models like ARMA remain relevant for smaller datasets and shorter forecasting horizons. These findings highlight the importance of considering both traditional econometric models and modern machine learning techniques for inflation forecasting, particularly in economies like Türkiye, which experience frequent economic shocks.

Policy Implications

From a policy perspective, it is recommended that decision-makers, including central banks, utilize machine learning models like XGBoost, especially during periods of economic uncertainty. Given their ability to capture complex patterns and dynamics, these models can support more accurate inflation forecasts, thus aiding in formulating more effective monetary policies. Policymakers should also consider hybrid models that integrate traditional time-series features to improve the robustness of economic forecasts.