

Nominal çapa olarak açık enflasyon hedeflemesi rejiminde enflasyonun makroekonomik belirleyicilerinin makine öğrenmesi yaklaşımıyla analizi

Analysing the macroeconomic determinants of inflation under the explicit inflation targeting regime as a nominal anchor: A machine learning approach

Nuran Çakır Yıldız¹ 

Muzaffer Göztaş² 

Öz

¹ Dr. Öğr. Üyesi, İÜ-Cerrahpaşa SBMYO, İstanbul, Türkiye, nurcak@iuc.edu.tr

ORCID: 0000-0003-1770-9561

² Arş. Görv., Yıldız Teknik Üniversitesi, İstanbul, Türkiye, muzaffer.goztas@yildiz.edu.tr

ORCID: 0009-0001-7933-901X

Sorumlu Yazar/Corresponding Author:

Nuran Çakır Yıldız,

İÜ-Cerrahpaşa SBMYO, İstanbul, Türkiye

nurcak@iuc.edu.tr

Enflasyonun düşük ve sürdürülebilir bir düzeye indirilebilmesi için para politikası çerçevesinde açık bir hedefin tanımlanması gerekmektedir. Bu hedefleme sürecinde, enflasyon dinamikleri üzerinde doğrudan etkili olduğu varsayılan bir makroekonomik değişken seçilmekte ve söz konusu değişken, para politikasının referans noktası olan "nominal çapa (nominal anchor)" işlevini üstlenmektedir. Ekonomik istikrarın sağlanmasına yönelik en yaygın nominal çapalar döviz kuru çapası, para arzı kontrolüne dayanan nominal çapalar ve enflasyon hedeflemesi rejimleridir. Türkiye'de para politikası stratejisi çerçevesinde 2002-2005 döneminde örtük enflasyon hedeflemesi (implicit inflation targeting) rejimi uygulanmıştır. 2005 yılı, Türkiye'de açık enflasyon hedeflemesi (explicit inflation targeting) rejimine geçişin hazırlık dönemi olarak belirlenmiştir. Bu süreçte Türkiye Cumhuriyet Merkez Bankası (TCMB), stratejik planında bağımsızlık, şeffaflık ve hesap verebilirlik ilkelerine özellikle vurgu yapmış; ayrıca yasal düzenlemelerle fiyat istikrarı para politikasının temel amacı haline getirilmiştir. 1 Ocak 2006 tarihinden itibaren ise Türkiye'de açık enflasyon hedeflemesi rejimi resmen uygulanmaya başlanmıştır. Bu çalışma, 2006-2024 dönemine ait veriler kullanılarak, açık enflasyon hedeflemesi rejimini etkileyen temel makroekonomik göstergeleri makine öğrenmesi (machine learning) temelli ampirik bir analizle incelemektedir. Bulgular, nominal çapa yaklaşımı çerçevesinde TÜFE, gelişmiş ve gelişmekte olan ülkelere göre hesaplanan reel efektif döviz kuru (REER) göstergeleri ile M2 para arzının birlikte kullanımının öne çıktığını; özellikle REER ve M2 değişkenlerinin kombinasyonunun enflasyon/TÜFE dinamiklerini yüksek bir açıklayıcılıkla yansıttığını göstermektedir.

Anahtar Kelimeler: Enflasyon Hedeflemesi, Nominal Çapa, Parasal Hedefleme, Döviz Kuru Hedeflemesi, Makine Öğrenmesi

Jel Kodları: E31, E52, E58, C82

Abstract

To reduce inflation to a low, sustainable level, a clear target must be set within the framework of monetary policy. In this targeting process, a macroeconomic variable assumed to have a direct impact on inflation dynamics is selected and serves as a "nominal anchor," the reference point for monetary policy. The most common nominal anchors for achieving economic stability are the exchange rate anchor, monetary policy-based nominal anchors, and inflation-targeting regimes. Within the framework of its monetary policy strategy, Turkey implemented an implicit inflation-targeting regime during 2002-2005. The year 2005 was designated as a transition period toward the adoption of an explicit inflation targeting regime. During this process, the Central Bank of the Republic of Turkey (CBRT) emphasised the principles of independence, transparency, and accountability in its strategic plan. At the same time, price stability was formally established as the primary objective of monetary policy through legal amendments. As of January 1, 2006, Turkey officially adopted an explicit inflation-targeting framework. This study aims to identify the key macroeconomic indicators influencing Turkey's explicit inflation-targeting regime by employing a machine-learning-based empirical approach using data from 2006 to 2024. The analytical framework integrates multiple macroeconomic variables to evaluate their relative contributions to inflation dynamics under the nominal anchor perspective. The findings reveal that the combined use of the Consumer Price Index (CPI), real effective exchange rate (REER) indicators for both advanced and emerging economies, and the M2 money supply provides a practical and consistent predictive structure. In particular, the combination of REER indicators and the M2 aggregate captures inflation and CPI dynamics with high predictive power, underscoring their critical role in understanding the operational effectiveness of the explicit inflation-targeting framework in Turkey.

Keywords: Inflation Targeting, Nominal Anchor, Monetary Targeting, Exchange Rate Targeting, Machine Learning-Based Analysis

Jel Codes: E31, E52, E58, C82

Atıf/Citation: Çakır Yıldız, N., & Göztaş, M., Nominal çapa olarak açık enflasyon hedeflemesi rejiminde enflasyonun makroekonomik belirleyicilerinin makine öğrenmesi yaklaşımıyla analizi, bmij (2025) 13 (4): 2148-2173 doi: <https://doi.org/10.15295/bmij.v13i4.2676>

Extended Abstract

Analysing the macroeconomic determinants of inflation under the explicit inflation targeting regime as a nominal anchor: A machine learning approach

Literature

Penalised regressions (Lasso, Ridge, Elastic Net) in macroeconomic forecasting can limit overfitting under high-dimensional and multicollinear conditions, thereby improving out-of-sample accuracy. While Gabauer et al. (2024) demonstrate the advantage of penalised linear methods for capturing regime interactions in dynamic network structures, Li and Chen (2014) show that LASSO-based approaches in conjunction with factor models reduce error measures. Although tree-based ensemble methods yield robust results in data-rich analyses (Medeiros et al., 2021), penalised linear models have maintained their superiority in terms of transparency and interpretability. In the context of developing countries, Özgür and Akkoç (2021) found that Lasso/Ridge/Elastic Net could provide a competitive advantage over ARIMA/VAR in Turkish inflation. That variable selection increased resilience to regime breaks. Nowcasting applications have also shown that penalised linear approaches contribute to the accuracy-stability balance in post-crisis periods. This literature generally indicates that addressing trend management and regularisation jointly in macro series that involve trend and regime differentiation can improve out-of-sample performance (e.g., during model development, testing, and validation). In summary, this study systematically tested the findings above by comparing trended and trendless data representations within a linear ML architecture.

Research design and methodology

The research was conducted using monthly data from 2006 to 2024. The dependent variable is the CPI. The explanatory variables are three Real Effective Exchange Rate indicators (CPI-based, Emerging Market-based, Developed Market-based), M2 Money Supply, balance of payments items (Current Account, Capital, Financial, Net Error and Omission, Overall Balance), Deposit Interest Rate, Annual Increase in CPI, Real Interest Rate Calculation, and Reserve Assets. Following simultaneous correlation and scatter analyses (high correlation between CPI-Real Effective Exchange Rate variables and CPI-M2; low correlation between BOP items), Real Effective Exchange Rate indicators and M2 were included in the basic model area.

Multiple linear correlations were detected among the Real Effective Exchange Rate series (VIFs were very high, tolerance $\approx$ 0). Therefore, Principal Component Analysis was applied, and the three series were grouped into a single component named REER_PC1 (under the variable) (EVR_PC1 $\approx$ 98,6%). After PCA, the VIF decreased to approximately 1,51 and the model space was well-conditioned.

Two parallel data representations were then created. Trend data was detrended using the detrending method. All transformations were learned solely from the training data and applied to the test and validation periods using the same parameters. This prevented information leakage. The time periods were divided into training (2006-2020), testing (2021-2022), and validation (2023-2024). Modelling was performed using three linear learning methods. These techniques were, in order, Least Squares (LS), Ridge, and Lasso. In the study, the Ridge and Lasso methods used an alpha weight of 0,001, in addition to the OLS method. As success criteria, R^2 and R^2_{α} (adjusted R^2) were used together with Mean Absolute Error (MAE), Mean Squared Error (MSE), Root Mean Squared Error (RMSE), and Mean Absolute Percentage Error (MAPE) as model success criteria.

Since the variables in the trending and non-trending states represent two views of the same observations, paired comparisons were used. The primary test was the Wilcoxon signed-rank test; for robustness, paired t-tests and paired one-tailed permutation tests were applied. The following hypotheses were tested.

Testing the averages of trending and non-trending representation every month during the validation period ($d_m = \bar{y}_m^{trending} - \bar{y}_m^{detrended}$):

$H_0: Median(d_m)=0$

$H_1: Median(d_m)\neq 0$

When testing whether there is a significant difference in the success rates of the same validation periods, the following hypothesis was formulated ($\Delta_i = R^2_{trendsiz} - R^2_{trendli}$):

$H_0: Median(\Delta_i)\leq 0$

$H_1: Median(\Delta_i)> 0$

All tests were conducted at a significance level of $\alpha=0,05$.

Results and discussion

Trended and untrended lines are close together in both training and testing. For trended OLS, R^2 is $\approx$ 97,9% in training and $R^2\approx$ 96,5% in testing. Similar levels were observed for Ridge and Lasso. During the validation period, a break was detected in all trending models, with $R^2\approx$ 64% (OLS 64,264%; Ridge 64,254%; Lasso 64,221%).

The non-trending line was observed to be significantly superior in validation. $R^2\approx$ 90% (OLS: 90,382%; Ridge: 90,381%; Lasso: 90,381%) and its closer proximity to the training/testing split were noteworthy. This demonstrated that removing the trend component reduced generalisation error by preventing level differences in the validation regime from being carried into the model.

In the analysis of the difference between the validation-period averages, a large and consistent level shift was observed between the monthly averages of the trended and detrended CPI. Paired $t_{test}=172,85$ $p<0,001$; Wilcoxon $W_{test}=0$ $p<0,001$; permutation $p<0,001$. Since the mean difference (trended-trended) was determined to be 1107.172, standard deviation=22,188, Cohen's $d_z\approx$ 49,9, H_0 was rejected, and it was observed that the difference between the means was statistically significant.

In the success difference test of the validation periods, for the R^2 and R^2_{α} pairs, Wilcoxon $W_{test}=21$, $p\approx$ 0,016; paired $t_{test}=49,195$, $p\approx$ 0,001; one-tailed permutation $p\approx$ 0.016, therefore H_0 is rejected, and it is observed that trendless validation successes are significantly higher.

In terms of error metrics, even though R^2 was high, and absolute error-based metrics (especially MSE/RMSE) increased in validation due to scaling and heteroscedasticity. It was found that the level increases in 2023–2024 led to inflation in absolute errors, even for relatively small percentage deviations. The rise in MAPE in some months may reflect structural sensitivity at points where the denominator can approach zero in a trendless series.

The findings suggest that although ML methods do not theoretically require the assumption of stationarity, regime shifts weaken generalisation performance when trend management is not performed; using the PCA + regularisation + detrending method together increases stability. Although it may seem unnecessary to test time-series assumptions for machine learning algorithms, testing has been found to improve model performance.

Conclusion, recommendations, and limitations

The study systematically tested the effect of trending and non-trending data representations on out-of-sample accuracy (test and validation period) within a linear ML framework. The results show that although a similar fit is achieved in training and testing, trendless error is significantly superior in validation ($R^2 \approx$ Matched statistics have confirmed 90% vs. 64%), and this superiority. The implication for practice is that separating the trend component and preferring detrended models during periods of changing policy regimes and pricing behaviours increases the generalisability of forecasts.

Recommendations that can be made based on the results obtained from the study are as follows: (i) Beyond linear detrending, nonlinear detrending, regime breaks (Bai-Perron), time-varying parameters, and scale transformations (log, Box-Cox) can be tested. (ii) Robust loss functions or resampling strategies can be used for heteroscedasticity and outlier sensitivity. (iii) Model combination approaches (e.g., penalised regression + factor model) can be evaluated to maintain linear transparency and gain accuracy.

When evaluated in terms of working constraints, trend removal was performed using a linear trend. The magnitude of the results may vary depending on how trend dynamics are modelled. Furthermore, the data set is monthly and country-specific; findings must be re-examined when the frequency or scope changes.

When evaluated in terms of overall contribution, the real effective exchange rate indicators were aggregated into a single component using PCA, eliminating multiple linear correlations. Trend management and regularisation steps were addressed together, and the difference in out-of-sample performance was statistically demonstrated. This structure is applicable in macroeconomic forecasting.

This study has shown that the most robust and consistent indicators within the nominal anchor approach to inflation (CPI) forecasting are the CPI, real effective exchange rate indicators for both developed and developing countries, and M2 money supply. In summary, the combined use of real effective exchange rate indicators and the M2 money supply has provided a simple, practical framework that explains inflation/CPI dynamics with high explanatory power.

Giriş

Fiyat istikrarı, ekonomik birimlerin ve politika yapıcılarının orta ve uzun vadeli kararlarında enflasyon riskinin ekonomik faaliyetler üzerindeki etkisinin ihmal edilebilecek düzeyde olması durumunu ifade etmektedir. Enflasyonla mücadelede nominal çapa (nominal anchor) mekanizmalarının oluşturulması gerekliliği, makroekonomik politikaların güvenilirlik (credibility) ve disiplin (discipline) ilkeleri açısından yalnızca ekonomistler arasında değil, aynı zamanda politikacılar nezdinde de geniş bir kabul görmüştür (Willett, 1998, s.803).

Robert J. Barro (1979), *Money and the Price Level Under the Gold Standard* başlıklı makalesinde (The Economic Journal) “nominal anchor” terimini sistematik olarak kullanan ilk kişi kabul edilmektedir. Bu çalışmada altın standardı, fiyat seviyesini belirleyen bir “nominal çapa (nominal anchor)” olarak tanımlanır. Yani altının sabit fiyatı, para arzı ve fiyatlar genel seviyesi üzerinde “referans noktası” işlevi görmektedir (Barro, 1979, s.13).

Nominal çapa, para politikası açısından hedef alınan bir nominal değişkendir (Flood ve Mussa, 1994, s.1). Parasal genel denge teorisine göre, ekonomik sistemde nominal değişkenlerin denge değerlerinin belirlenebilmesi için, bu değişkenlerden en az birinin dışsal olarak sabitlenmesi işlemine “çapa politikası” adı verilmektedir (Bruno, 1990, s.7; Patinkin, 1993, s.112).

Nominal çapalar, merkez bankalarının para politikalarını yönlendirmek için kullandıkları temel referans noktalarıdır. Bu çapalar, para otoriteleri için bir hedef işlevi görerek, politika çerçevesine açıklık ve güvenilirlik kazandırmaktadır (Fabris, 2025, s.8).

Merkez bankalarının enflasyonu kontrol etmek veya belirli bir seviyede tutmaya yönelik para politikası uygulamasında enflasyonu doğrudan etkilediği düşünülen bir ekonomik değişken seçilir ve bu değişken nominal çapa (nominal anchor) olarak kullanılmaktadır. Böylece söz konusu hedefler, “nominal çapa” işlevi görerek politikaların tutarlılığını güvence altına almakta ve kamuya şeffaf bir denetim aracı sunmaktadır (Croce ve Khan, 2000, s.48).

Nominal çapanın kuramsal önemi Kydland ve Prescott’un (1977) geliştirdiği “rules versus discretion” yaklaşımındaki keyfi (discretionary) para politikaları üzerinde bir sınırlama işlevi görmesidir. Kydland ve Prescott (1977), Calvo (1978) ile Barro ve Gordon (1983) tarafından da vurgulandığı üzere nominal çapalar zaman tutarsızlığı (time-inconsistency) problemini zayıflatmaya yardımcı olur (Mishkin, 1999, s.1).

Zaman tutarsızlığı yaklaşımına göre, merkez bankaları uzun vadede fiyat istikrarını korumayı hedeflese de kısa vadede çıktı ve istihdam artırma amacına yönelik olarak genişleyici para politikalarını “keyfi politika (discretionary policy)” tercih etmektedirler. Ancak ekonomik birimler bu davranışı öngördükleri için (rasyonel beklentiler) ücret ve fiyatları buna göre ayarlar. Sonuç olarak, ekonomi beklenen düzeyin üzerinde bir çıktı kazanımı elde edemez; buna karşın enflasyonist eğilim kalıcı hale gelir. Bu bağlamda zaman tutarsızlığı, hem merkez bankalarının genişleyici politikaları sürdürme baskısına niçin maruz kaldığını, hem de fiyat istikrarına yönelik güvenin zayıflamasının neden sürekli yüksek enflasyon ile sonuçlandığını açıkça ortaya koymaktadır (Kydland ve Prescott, 1977; Mishkin ve Posen, 1997).

Merkez bankaları uzun vadede fiyat istikrarını hedeflerken, kısa vadede büyüme, istihdam, faiz oranları ve döviz kurları gibi reel değişkenlerle de uyumlu politikalar geliştirmeye çalışmaktadır (Walsh ve Hartley, 1988, s.19). Bu noktada, merkez bankalarının kullandığı nominal çapaların işlevi, kamuoyuna politikaların yönü hakkında güvenilir sinyaller vermek ve beklentileri şekillendirmektir.

Ara hedef olarak belirlenen değişken, para politikasının araçları ile nihai amaç arasında tutarlı (enflasyonla güçlü ve istikrarlı bir ilişkiye sahip olması), öngörülebilir (ara hedefteki değişikliklerin enflasyon üzerinde ölçülebilir bir etki yaratması), izlenebilir (verilerin güvenilir, hızlı ve anlaşılır şekilde elde edilebilmesi) ve şeffaf olması (beklentilerin yönetilebilir olması açısından kamuoyuna açıklanabilirlik) büyük önem taşımaktadır (Önder, 2005, s.34; Aktan, Utkulu ve Togay, 1998, s.8).

Karar vericiler açısından temel mesele, nominal çapanın (nominal anchor) hangi değişken üzerine inşa edileceğinin belirlenmesidir. Bu noktada literatürde üç temel yaklaşım öne çıkmaktadır: yerel para birimine dayalı sistemler, döviz kuru temelli çapalar (exchange rate anchors) ve enflasyon temelli rejimler (inflation-based anchors) (Sachs, Tornell ve Velasco, 1996, s.22).

Parasal hedefleme (monetary targeting), enflasyonun para arzı büyümesine duyarlı olduğu varsayımına dayanan bir para politikası yaklaşımıdır. Bu yöntemde, belirli bir parasal büyüklük (örneğin M2 veya M3) için hedeflenen bir büyüme oranı belirlenerek fiyat istikrarının sağlanması ve ekonomik aktörlerin (piyasalar ve halk) beklentilerinin yönlendirilmesi amaçlanır. Parasal hedefleme

somut ve izlenebilir bir hedef sunması sayesinde para politikasının güvenilirliğini kısa sürede artırma potansiyeline sahiptir (Mishkin, 1997, s.24).

Parasal hedefleme (monetary targeting), politika otoritelerinin güvenilirliğini artırarak zaman tutarsızlığı sorununu azaltan bir para politikası stratejisidir (Cukierman, 1999, s. 12). Bu yaklaşım, paranın dolaşım hızının sabit ve para arzının dışsal (exogenous) olduğu varsayımına dayanır (Mishkin,1999:12). Stratejinin başarısı, para arzı ile enflasyon arasındaki ilişkinin güçlü ve istikrarlı olmasına, para arzının kontrol edilebilirliğine ve para çarpanının (money multiplier) öngörülebilirliğine bağlıdır (Mishkin ve Savastano, 2001, s.13; Croce ve Khan,2000, s.49).

Merkez bankasının para arzını kontrol edebilme kapasitesi, doğrudan fiyat istikrarı hedefiyle ilişkilidir. Parasal hedeflemenin başarısı, para arzının (money supply) para tabanına (monetary base) oranı olarak tanımlanan para çarpanının (money multiplier) istikrarlı ve öngörülebilir olmasına bağlıdır (Paya, 1994, ss. 73-115; Dornbusch ve Fischer, 1998, ss. 418-429). Para çarpanı sabit kaldığında, merkez bankası para tabanındaki değişimlerden hareketle toplam para arzını güvenilir biçimde öngörebilir; bu da para politikası araçlarının fiyat istikrarını sağlamada daha etkin kullanılmasını mümkün kılar (Dornbusch ve Fischer, 1998, s.418).

Parasal hedefleme stratejisi 1980'li yıllardan itibaren para talebindeki dönüşüm nedeniyle para arzı ile enflasyon arasındaki klasik ilişkinin zayıflamasına ve parasal hedeflemenin etkinliğinin sorgulanmasına yol açmıştır. 1980'li yıllardan itibaren finansal yenilikler (elektronik ödeme sistemlerinin yaygınlaşması, yeni mevduat türleri, finansal araç çeşitliliği) ve bankaların rezerv tutma davranışlarındaki değişimler, para çarpanının öngörülebilirliğini zayıflatmıştır. Özellikle bankaların zorunlu karşılık oranlarına verdikleri tepkiler ve likidite tercihlerindeki farklılaşmalar, çarpanın sabit olduğu varsayımını geçersiz kılmıştır. Bu durumun sonucunda para çarpanı istikrarsız hale gelmiş; merkez bankalarının para tabanı üzerinden toplam para arzını güvenilir biçimde tahmin etme ve kontrol etme kapasiteleri önemli ölçüde azalmıştır.

Buna ek olarak, parasal büyüklükler ülkeden ülkeye farklılık göstermekle birlikte teknolojik gelişmeler (dijital ödeme sistemleri, online bankacılık) ve yeni finansal yenilikler (kripto paralar, türev ürünler vb.) paranın kullanım biçimini köklü şekilde değiştirmiştir. Ayrıca para arzı hedefinin esnek olmayışı, kriz anlarında veya ani ekonomik şoklar (örneğin petrol fiyatlarındaki sıçrama ya da doğal afetler) karşısında merkez bankalarının hızlı tepki vermesini engellemiştir (Croce ve Khan, 2000, s.50).

Nominal çapa stratejilerinin en eski biçimlerinden bir diğeri de döviz kuru çapasıdır (exchange rate anchor). Bu yaklaşım, artan enflasyona rağmen sabit bir döviz kurunun korunması (fixed exchange rate) ya da enflasyon oranının altında belirlenerek önceden duyurulan mini devalüasyonlar takvimi (crawling peg) aracılığıyla uygulanmaktadır. Temel amaç, yüksek enflasyon dönemlerinde istikrarsızlaşan para talebini disipline ederek, nominal kur üzerinden fiyat düzeyini ve enflasyon beklentilerini demirlemektir (Kruger, 1997, s.2).

Döviz kurunun nominal çapa olarak enflasyonu düşürme etkisi iki temel kanal üzerinden açıklanmaktadır. İlk olarak, sabitlenen kurun nominal referans işlevi görmesiyle enflasyonist beklentilerin çözülmesi (expectations channel) sağlanmaktadır. İkinci olarak, dış ticarete konu malların fiyat kanalı (tradables price channel) aracılığıyla. Kurun çapa işlevi ticarete konu malların fiyatlarını uluslararası düzeye yaklaştırmakta; bu da iç fiyat istikrarını güçlendirerek enflasyonist sürecin kontrol altına alınmasına katkıda bulunmaktadır. Kura dayalı stratejide temel sorun, döviz kuru yoluyla istikrar sağlamanın başlı başına iyi ya da kötü bir politika olup olmadığı değil, çıkışın (exit) en uygun zamanlamasının ne olduğudur (Bruno,1995, s. 281).

Bu çalışmanın özünü ve uygulamalı kısmını oluşturan enflasyon hedefli çapa politikası ise hem para politikasında bağımsızlığı artırmış hem de kamuoyuna şeffaf ve hesap verebilir bir çerçeve sunarak beklentilerin yönetilmesine olanak tanımıştır. Böylece 1990'ların sonunda, döviz kuru hedeflemesi yerine enflasyon hedeflemesi giderek yaygınlaşmış ve 2000'li yıllarda birçok ülkenin temel para politikası rejimi haline gelmiştir.

Enflasyon hedeflemesi stratejisinin teorik temeli, para politikasının uzun vadede reel değişkenler üzerinde kalıcı bir etkisinin bulunmadığı, buna karşılık fiyat düzeyi ve enflasyon oranı üzerinde belirleyici olduğu varsayımına dayanmaktadır.

Enflasyon hedeflemesi stratejisi, para politikasının uzun vadede reel değişkenler üzerinde kalıcı etkisinin bulunmadığı; buna karşın fiyat düzeyi ve enflasyon oranı üzerinde belirleyici olduğu varsayımına dayanır. Bu yaklaşımda, parasal otorite belirli bir dönem içinde ulaşmayı taahhüt ettiği düşük bir enflasyon oranını açıkça ilan eder. Böylece enflasyon hedefi, para politikasının nihai amacı

haline gelir ve kamuoyuna düzenli biçimde duyurulur (Bernanke, Laubach, Mishkin, ve Posen, 1999, s.4).

Enflasyon hedeflemesinin temel özelliği, fiyat istikrarının açık biçimde önceliklendirilmesi ve beklenti yönetiminin para politikasının merkezine yerleştirilmesidir. Bu çerçevede strateji, hem para politikası kararları için nominal bir çapa (nominal anchor) işlevi görür hem de şeffaflık sayesinde hedeflerin kamuoyu tarafından izlenebilirliğini sağlar (Bernanke vd. 1999; Svensson, 1997; Mishkin, 2000).

Bu rejimin etkinliği, ekonomiyi ve enflasyonu etkileyen şokların niteliğinin doğru anlaşılmasına ve parasal aktarım mekanizmalarının (monetary transmission mechanisms) işleyişinin açık biçimde kavranmasına bağlıdır (Isard ve Laxton, 2000, s.10).

Literatür

Bu çalışmada literatür incelemesi, araştırmanın özgünlüğü ve amacı doğrultusunda iki ayrı açıdan yapılmıştır. İlk olarak, enflasyon hedeflemesi stratejisi başta olmak üzere, yaygın olarak kullanılan diğer temel çapa stratejilerini de kapsayacak şekilde kuramsal bir çerçevede değerlendirme yapılmıştır. İkinci olarak, makine öğrenmesi temelli modelleme yaklaşımları incelenmiş ve bu kapsamda ilgili yöntemlerin çalışmaya sağladığı katkılar tartışılmıştır.

Hall (1983), McCallum (1994) ve Gordon (1985), gibi birçok ekonomist nominal gelir hedeflemesini önermektedir.

Hall (1983), para politikasının genel makroekonomik hedeflerle tutarlılık göstermesi amacıyla nominal GSYH için belirli hedeflerin tanımlanmasını önermektedir. Nominal GSYH'nin hedef seviyesinin altında kalması durumunda genişletici politikalar (örneğin faiz oranlarının düşürülmesi veya rezervlerin artırılması), hedefi aşması durumunda ise sıkılaştırıcı politikalar (faiz oranlarının yükseltilmesi veya rezervlerin azaltılması) uygulanması gerektiğini vurgulamaktadır.

Benzer şekilde, Gordon (1985), nominal GSYH için para politikasının genel hedefleriyle uyumlu bir seviye belirlenmesini önermektedir. Bu yaklaşımın temel amacı, para otoritelerinin gerçekleşmiş GSYH verilerini beklemeden, hedefle sapma yaşanacağına dair göstergeler ortaya çıktığında önceden harekete geçmelerini sağlamaktır. Böylece politika, ileriye dönük (forward-looking) bir perspektif kazanmakta ve olası ekonomik dalgalanmalar ortaya çıkmadan önce gerekli ayarlamalar yapılarak etkiler hafifletilebilmektedir.

McCallum'un (1994) çalışmasında GSMH büyüme hedefinin, reel büyüme ile hedeflenen düşük enflasyonu aynı anda güvenceye alma açısından hem de kur ve para arzı dalgalanmalarına karşı esneklik sağlaması açısından doğrudan enflasyon hedeflemesine göre daha tercih edilebilir olduğunu vurgulamıştır.

Calvo ve Reinhart (2002), "Fear of Floating" isimli çalışmasında dalgalı kur rejiminde bile fiili kur çapası rezerv hareketleri ve faiz oynaklığı kur bağımlılığını ortaya koymuştur.

Edwards ve Savastano (1999), Latin Amerika ekonomileri üzerine yaptıkları araştırmada vaka analizleri, ülke karşılaştırmaları ve zaman serisi verilerini bir arada kullanarak döviz kuru çapası politikalarının etkilerini değerlendirmiştir. Bulgular, bu politikaların kısa vadede enflasyonun kontrol altına alınmasında etkili olduğunu; ancak kriz dönemlerinde devalüasyonlara, finansal istikrarsızlıklara ve ekonomik durgunluklara yol açtığını ortaya koymuştur.

Clarida ve Gertler (1997), Almanya ve İsviçre örneklerinde para arzı hedeflemesinin enflasyonu kontrol etmede görece başarılı olduğunu göstermiştir.

Nelson (2003) ise ABD üzerine yaptığı ampirik analizde, para arzı hedeflemesinin güçlü bir çapa işlevi göremediğini ortaya koymuştur.

Mishkin ve Schmidt-Hebbel (2007), 21 ülkeyi kapsayan panel veri analizlerinde, enflasyon hedeflemesi rejimi uygulayan ekonomilerde hem enflasyon oranlarının hem de enflasyon oynaklığının (volatility) belirgin biçimde azaldığını; buna karşın ekonomik büyüme üzerinde anlamlı bir olumsuz etki gözlenmediğini ortaya koymuşlardır.

Ball ve Sheridan (2005) ise OECD ülkeleri üzerine yaptıkları çalışmada, enflasyon hedeflemesinin nominal çapalama işlevini yerine getirdiğini, ancak enflasyonu düşürme başarısının büyük ölçüde ülkelerin başlangıç koşullarına bağlı olduğunu vurgulamaktadır.

Benzer biçimde, Levin, Natalucci ve Piger (2004), enflasyon hedeflemesinde merkez bankalarının şeffaflık ve hesap verebilirlik politikaları özelliği gereği, beklenti yönetimini güçlendirdiğini ekonomik birimlerin enflasyon tahminlerinde daha düşük oynaklık (volatility) sergilediğini ve sonuçta enflasyon

hedeflemesini benimseyen ülkelerde uzun vadeli enflasyon beklentilerinin daha güçlü şekilde çapalandığını ortaya koymuştur.

Svensson (2010), İsveç üzerine gerçekleştirdiği ampirik incelemede, tahmin-hedefleme (forecast targeting) yaklaşımının piyasa beklentileri üzerinde disipline edici bir etki yarattığı çıkarımında bulunmuştur.

Vega ve Winkler (2005), enflasyon hedeflemesinin ortalama enflasyon, oynaklık ve atalet üzerindeki etkilerini analiz etmiştir. Çalışmada, enflasyon hedeflemesi uygulayan 23 ülkenin deneyimi, bu rejimi benimsemeyen 86 ülkeden oluşan geniş bir kontrol grubuyla karşılaştırılmış ve analiz yoğunluk skoru eşleştirme yöntemi (propensity score matching) kullanılarak gerçekleştirilmiştir. Çalışmada özellikle gelişmekte olan ekonomilerde, enflasyon ataletinin (inflation inertia) kırılmasında ve hem örtük (implicit) hem de açık (explicit), enflasyon hedeflemesinin fiyat istikrarında dalgalanmayı azalttığı sonucuna ulaşılmıştır.

Woodford (2003), teorik ve ampirik simülasyonlara yer verdiği çalışmada, enflasyon hedeflemesinden farklı olarak, fiyat seviyesi hedeflemesinin “geçmiş hataları telafi etme” özelliği nedeniyle uzun vadeli beklentilere daha sağlam bir çapa olduğunu vurgulamıştır. Daha da önemlisi fiyat seviyesi hedeflemesinin ekonomik şoklar karşısında beklentileri daha güçlü biçimde çapalayabileceği biçiminde bir politika çıkarımında bulunmuştur.

Gürkaynak, Levin, Marder ve Swanson (2010), ABD, Euro Bölgesi ve İngiltere verilerini kullanarak yaptıkları çalışmada, enflasyon hedeflemesi uygulayan ülkelere uzun vadeli enflasyon beklentilerinin daha güçlü biçimde çapalandığını ortaya koymaktadır.

Kuttner ve Posen (2001), gelişmiş ülkeler üzerine yaptıkları analizde, enflasyon hedeflemesinin risk primlerini azalttığını ve finansal piyasalarda güveni artırıcı bir özelliği olduğu sonucuna ulaşmıştır.

Özatay ve Sak (2003), Türkiye’de 2001 krizi sonrasında uygulamaya konulan dezenflasyon programı çerçevesinde yürütülen örtük enflasyon hedeflemesi politikasını incelemiş ve bu dönemde beklentilerin yalnızca sınırlı ölçüde çapalandığını ortaya koymuştur. Bununla birlikte, döviz kuru şoklarının beklenti çapasını kırabildiği de bulgulanmıştır.

Çiçek, Akar ve Yücel (2011) ise Türkiye’de 2006 sonrasında uygulamaya başlanan açık enflasyon hedeflemesi rejiminin enflasyon beklentilerini ne ölçüde çapalama özelliği taşıdığını analiz etmiş ve bu süreçte Merkez Bankası’nın güvenilirliğinin de (credibility) ölçülmesine çalışılmıştır.

Torun ve Yılmaztürk (2021), seçilmiş OECD ülkeleri üzerine yaptıkları panel veri analizinde, faiz oranı değişkeninin fark enflasyon üzerinde negatif, ekonomik büyüme değişkeninin ise pozitif bir etkiye sahip olduğunu ortaya koymuşlardır.

Alev (2019), 2006–2018 dönemine ait çeyreklik verilerle yaptığı ARDL analizi sonucunda, Türkiye’de enflasyon ile para arzı, döviz kuru, faiz oranı, GSYH ve bütçe açığı arasında uzun dönemli bir ilişki bulunduğunu belirlemiş; ayrıca döviz kuru oynaklığının enflasyon üzerinde belirleyici olduğunu saptamıştır.

Yenisu (2019) ise 2010–2017 dönemine ait verilerle gerçekleştirdiği Toda–Yamamoto nedensellik analizi sonucunda, petrol fiyatları ve para arzının enflasyonun nedeni olduğunu; buna karşılık faiz, bütçe açığı ve döviz kuru gibi değişkenlerin anlamlı bir nedensellik göstermediğini tespit etmiştir.

Çalışmanın özgünlüğünü oluşturan uygulama bölümünde, makine öğrenmesi temelli yöntemlere ilişkin literatür taraması Tablo 1’de sunulmuştur.

Tablo 1: Ekonometrik Veriler ile Makine Öğrenmesi Kullanarak Dünya Geneline Yapılan Tahminleme Çalışmaları Örnekleri

Makale Başlığı	Değişken	Yöntem	Sonuçlar
Estimating U.S. housing price network connectedness: Evidence from dynamic Elastic Net, Lasso, and Ridge vector autoregressive models (Gabauer, Gupta, Marfatia ve Miller, 2024)	Eyalet bazında konut fiyat getirileri	- VAR modeli - Elastic Net - Lasso - Ridge	Güney eyaletlerinden diğer bölgelere konut piyasası şoklarının yayıldığı bir ağ yapısı tespit edilmiştir. Özellikle Güney bölgeleri konut şoklarını diğer bölgelere iletirken, Kuzeydoğu bölgesi net alıcısı konumundadır; Batı, Güney'den şok alıp Ortabatı ve Kuzeydoğu'ya iletir, Ortabatı ise Kuzeydoğu'ya iletir Güney ve Batı'dan alır. Bu bulgular, konut piyasasındaki bölgesel etkileşimlerin iş döngüsüne etkileri olabileceğini göstermiştir.
Forecasting macroeconomic time series: LASSO-based approaches and their forecast combinations with dynamic factor models (Li ve Chen, 2014)	20 temel makroekonomik gösterge	- LASSO tabanlı regresyon modelleri - Dinamik Faktör Modeli - Tahmin Birleştirme	LASSO tabanlı bütün modeller, çoğu değişken için dinamik faktör modelinden daha başarılı çıkmıştır. Değişkenlerin ekonomik bloklara ayrılarak modellenmesi yorumlanabilirliği artırmıştır. Ayrıca, LASSO modellerinden elde edilen tahminlerin faktör model tahminleriyle birleştirilmesi, tek başına faktör modeline kıyasla anlamlı biçimde daha düşük hata vermiştir.
Forecasting Inflation in a Data-Rich Environment: The Benefits of Machine Learning Methods (Medeiros, Vasconcelos, Veiga ve Zilberman 2021).	Enflasyon ve Yüzlerce Makro-Finansal Gösterge	- Random Forest - Gradient Boosting - ARIMA - Faktör Modelleri	Çok sayıda göstergeyi içeren zengin bir veri ile eğitilen, ML teknikleri geleneksel modellere kıyasla daha yüksek doğrulukta enflasyon tahminleri üretmiştir. Özellikle Random Forest modeli tüm diğer yöntemleri geride bırakarak en iyi performansı göstermiştir.
Inflation forecasting in an emerging economy: selecting variables with machine learning algorithms (Özgür ve Akkoç, 2021)	Makroekonomik Göstergeler	- Lasso - Ridge - Adaptive Lasso - Elastic Net - ARIMA - Çok değişkenli VAR	Makine öğrenimi tabanlı daraltma yöntemlerinin değişken seçiminde geleneksel yöntemlerden üstün olduğu görülmüştür. Özellikle Lasso ve Elastic Net modelleri, Türkiye enflasyonunu tahmin etmede ARIMA ve VAR gibi geleneksel ekonometrik yöntemlerden daha başarılı bulunmuştur. Bu yöntemler, enflasyonu öngörmeye en kritik değişkenlerin enerji üretimi, inşaat sektörü aktivitesi, reel efektif döviz kuru ve para piyasası göstergeleri olduğunu belirlemiştir.
Nowcasting GDP using machine learning methods (Kant, Pick, de Winter, 2025).	83 Makroekonomik ve Finansal Gösterge	- Dinamik faktör modeli - Bagging - Random Forest - Gradient Boosting - Geleneksel faktör modelleri	Genel olarak Random Forest modeli ortalama en yüksek doğrulukta şimdi-tahminleri sağlamıştır. Dinamik faktör modeli ise özellikle geriye dönük revizyonlu dönemler için en iyi sonucu vermiştir. 2008 finansal krizi öncesinde dinamik faktör modeli geçmiş verilerde daha iyi iken, 2008 sonrası dönemde Random Forest faktör modelini geçerek daha iyi sonuçlar vermiştir.
Macroeconomic forecasting using penalised regression methods (Smeekes ve Wijler, 2018)	Büyük Boyutlu Makro Veri Seti, Birim Kök ve Eşbütünlük Özellikleri Taşıyabilen Seriler	- LASSO ve - Geleneksel Faktör Modelleri	Cezalı regresyon yöntemlerinin, modele uyumsuz bir yapı olsa bile (ör. Gerçek veri faktör yapıda olsa dahi) daha dayanıklı ve uyumlu tahminler ürettiği görülmüştür. Özellikle veri setinde birim kökler ve eşbütünlük ilişkileri olduğunda, LASSO gibi yöntemler seçici yetenekleri azalsa bile geleneksel yöntemlere göre daha düşük tahmin hatası sağlamıştır. Büyük ölçekli bir ABD makro veri seti ile yapılan uygulamada da penalize regresyon tekniklerinin faktör modellerine yakın hatta zaman zaman üstün bir tahmin performansı sergilediği, dolayısıyla yüksek boyutlu ortamlarda uygulanabilir olduğunu gösterilmiştir.
Modeling and Predicting U.S. Recessions Using Machine Learning Techniques (Vrontos, Galakis ve Vrontos, 2021).	Aylık Resesyon Göstergesi, Getiri Eğrisi, Kredi, İşgücü Piyasası, Sanayi Üretimi ve Finansal Koşullar	- LASSO - Ridge - Elastic Net - k-NN - Diskriminant Analizi - Naive Bayes - Random Forest - Gradient Boosting	Resesyon tahmininde makine öğrenimi teknikleri belirgin iyileştirmeler sağlamıştır. Özellikle LASSO/Elastic Net ile cezalandırılmış Logit modelleri ve k-NN yöntemi, kısa-orta-uzun vadeli resesyon tahmin ufuklarının tümünde en tutarlı ve yüksek başarıyı göstermiştir. Bu modeller, yalnızca getiri eğrisi gibi tek değişkenli yaklaşımı aşarak ek makro değişkenleri de katarak geleneksel Probit/Logit'i geride bırakmıştır. Düzenlenmiş ayırma analizi, Bayesian sınıflandırma ve Random Forest gibi yöntemler de özellikle kısa vadede iyi performans sergilemiştir.
Nowcasting US GDP Using Tree-Based Ensemble Models and Dynamic Factors (Soybilgen ve Yazgan, 2021)	2000Q2-2018Q4 dönemi ABD GSYİH büyümesi, Reel Sektör, Finansal Göstergeler	- Bagging - Random Forest - Stochastic Gradient Boosting - Dinamik Faktör Modeli	Şimdi tahmin modelinde özellikle reel sektör değişkenlerinden türetilen faktörler ML modellerinde en belirleyici unsurlar olmuştur. Finansal ve fiyat odaklı faktörlerin önemi ise 2008 finansal krizinden sonra artmıştır; 2008-09 krizi sonrasında uygulanan aşırı gevşek para politikaları nedeniyle bu dönemde finansal göstergeler GDP tahmininde daha fazla ağırlık kazanmıştır. Sonuç olarak, faktör+ML yaklaşımı, dinamik faktör modelinin geniş veri bilgisini ve ağaç

			tabanlı yöntemlerin esnekliğini birleştirerek başarılı bir şimdi-tahmin performansı sağlamıştır.
Inflation Forecasting Using Machine Learning Methods (Baybuza, 2018)	TÜFE Enflasyonu ve İlgili Makro Göstergeler, Geçmiş Enflasyon, Çeşitli Para ve Finansal Göstergeler, Küresel Petrol Fiyatları	• LASSO • Ridge • Elastic Net • Random Forest • Gradient Boosting • AR Modelleri	Bu çalışma, Rusya gibi oynak enflasyon geçmişi olan bir ekonomide ML tekniklerinin uygulanabilirliğini göstermiştir. Elde edilen bulgulara göre Random Forest ve Gradient Boosting modelleri, en az geleneksel Rassal Yürüyüş ve AR(1) modelleri kadar iyi enflasyon tahmini yapabilmektedir. Hatta bazı durumlarda ML modelleri, uzmanlarca yapılan öngörüler kadar başarılı sonuçlar üretmiştir. Bu da makine öğrenimi yöntemlerinin Rusya enflasyonunu daha doğru tahmin etme potansiyeli olduğunu göstermiştir.
Real-time inflation forecasting with high-dimensional models: The case of Brazil (Garcia, Medeiros ve Vasconcelos, 2017)	Brezilya aylık enflasyon oranı, Enerji Fiyatları, Döviz Kuru, Anket Beklentileri, Para Arzı	• LASSO • Complete Subset Regression • Faktör Modelleri • Karar Ağaçları • Random Forest	Sonuçlar, LASSO ve benzeri yöntemlerin enflasyonun kısa vadeli öngörüsünde başarılı olabileceğini göstermiştir. Brezilya gibi enflasyon oynaklığının yüksek olduğu bir ekonomide LASSO ve ilgili yöntemler, tek değişkenli Phillips eğrisi gibi geleneksel modelleri belirgin şekilde aşmıştır. Farklı modellerin kombinasyonu, tek bir modele kıyasla daha üstün bir tahmin performansı sağlamıştır. Bu da en iyi ML ve geleneksel modellerin birlikte kullanımıyla tahmin hatasının daha da azaltılabileceğini göstermiştir.

Tablo 1’de derlenen çalışmalardan, tasarım ve amaç bakımından bu makaleye en çok benzeyen örnekler kısaca özetlenmiştir. Yüksek boyutlu makroekonomik göstergelerle tahmin yaparken cezalandırma özelliği bulunan regresyonların (LASSO, Ridge, Elastic Net) aşırı uyumu sınırlama ve genelleme gücünü artırma kapasitesine vurgu yapan çalışmalar öne çıkmaktadır. Örneğin, Gabauer, Gupta, Marfatia ve Miller (2024) konut piyasası ağlarını dinamik LASSO, Ridge ve Elastic Net ile vektör-otoragresif çerçevede tahmin ederek rejimsel etkileşimlerin dönemselliğe duyarlı biçimde yakalanabildiğini göstermiştir. Li ve Chen (2014) LASSO tabanlı yaklaşımları dinamik faktör modelleriyle birleştirerek çok değişkenli ortamda değişken seçimi ve öngörü doğruluğunun birlikte iyileştirilebildiğini rapor etmiş, özellikle tahmin birleştirme adımıyla örneklem dışı hataları düşürmüştür. Medeiros, Vasconcelos, Veiga ve Zilberman (2021) veri-zengin enflasyon ortamında ağaç-ensemble yöntemlerini klasik ARIMA ve faktör modellerine kıyasla doğruluk üstünlüğüyle konumlandırırken, cezalı doğrusal yöntemlerin şeffaflık ve yorumlanabilirlik avantajını koruduğunu belirtmiştir. Gelişen ülke bağlamında Özgür ve Akkoç (2021) Türkiye enflasyonu için LASSO, Ridge ve Elastic Net’in ARIMA/VAR’a karşı rekabetçi ya da üstün performans verdiğini ve değişken seçimi sayesinde modelin rejim kırılmalarına daha dirençli hale geldiğini bulmuştur. Benzer biçimde, geniş gösterge setleriyle GSYH şimdi-tahmini yapan çalışmalar (ör. Kant, Pick ve de Winter, 2025) Random Forest gibi esnek yöntemlerin yanında cezalı doğrusal tekniklerin doğruluk-stabilite dengesi sağladığını, özellikle kriz-sonrası dönemlerde validasyon başarısının belirginleştiğini göstermiştir. Toplu olarak bakıldığında, Tablo 1’deki bu literatür, cezalı regresyonların yüksek korelasyonlu göstergeler ve olası rejim farklılaşmaları altında aşırı uyumu sınırlayarak örneklem dışı dönemde daha tutarlı sonuçlar verdiğine işaret etmektedir (Tablo 1: Gabauer, Gupta, Marfatia ve Miller, 2024; Li ve Chen, 2014; Medeiros, Vasconcelos, Veiga ve Zilberman, 2021; Özgür ve Akkoç, 2021; Kant vd.2025). Bu bulgular, bizim çalışmamızda da trend yönetimi ve düzenleme adımlarını birlikte kullanma gerekçesini metodolojik olarak desteklemektedir.

Araştırma yöntemi

Veri seti

Çalışmada analiz edilen dönem, 2001-2025 yıllarını kapsamaktadır. Uzun dönemli bir perspektif elde edebilmek amacıyla, yıllık frekansta derlenen veriler yerine aylık frekanstaki veriler kullanılmıştır. Enflasyon oranları, Türkiye Cumhuriyet Merkez Bankası (TCMB) tarafından yayımlanan tüketici fiyat endeksi (TÜFE) serilerine dayalı olarak hesaplanmıştır. Bu çalışma için etik kurul onayına gerek yoktur.

Enflasyon beklentilerinin oluşturulmasında, her bir dönem için son on iki aya ait tüketici fiyat endeksi oranlarının ortalaması dikkate alınmış; ayrıca TCMB tarafından ilan edilen resmi enflasyon hedefleri de analize entegre edilmiştir. Bu bağlamda, modelde bağımlı değişken, gerçekleşen enflasyon ile hedeflenen enflasyon arasındaki fark olarak tanımlanmaktadır.

Analizde temel değişken olarak aylık TÜFE (Tüketici Fiyat Endeksi) değişim oranı kullanılmış; buna ek olarak parasal büyüklük göstergesi olarak M2 para arzı modele dâhil edilmiştir.

Türkiye'nin dışa açık bir yükselen piyasa ekonomisi niteliği göz önünde bulundurulduğunda, döviz kurunun fiyat dinamikleri üzerindeki belirleyici rolü özellikle önem taşımaktadır. Döviz kuru hareketlerinin ithal fiyatlar kanalıyla tüketici fiyatlarına yansiyarak enflasyon üzerinde güçlü etkiler oluşturduğu varsayılmaktadır. Bu nedenle nominal ABD doları kuru da analize dahil edilmiştir.

Benzer şekilde, nominal ve reel faiz oranları da modele dâhil edilmiştir. Mevduat faiz oranları, finansal piyasadaki parasal kaynakların maliyetini yansıttığından, kredi faiz oranları ise yatırım kararlarını ve üretim maliyetlerini etkileyerek maliyet yönlü enflasyonun açıklanmasına katkı sunduğundan analizin kapsamına alınmıştır. Buna ek olarak, yabancı para mevduatı, ödemeler bilançosu kapsamında izlenen rezerv varlıklar ve cari işlemler hesabı değişkenleri de enflasyon hedeflemesi ile olan ilişkilerini test etmek amacıyla analize dahil edilmiştir.

Çalışmada kullanılan veri seti, aylık frekanstadır ve 2006 ile 2024 dönemini kapsamakta olup her bir değişken için 228 satırdan oluşmaktadır. Çalışmada kullanılan değişkenlerden oluşan ve tahmin edilen bağımlı değişken TÜFE'dir. Dış denge ve kur göstergeleri kümesinde sırasıyla çalışmada kısaltmaları kullanılan TÜFE Bazlı Reel Efektif Döviz Kuru (REER TÜFE Bazlı), Gelişmekte Olan Ülkeler Bazlı Reel Efektif Döviz Kuru (REER GOÜ Bazlı) ve Gelişmiş Ülkeler Bazlı Reel Efektif Döviz Kuru (REER GÜ Bazlı) yer almıştır. Rezerv varlıklar, mevduat faiz oranı, tüfedeki yıllık artış ve reel faiz hesaplaması yüzde olarak bulunmuştur. Para arzı göstergesi olarak M2 para arzı yer almıştır. Bu değişkenler ekonomik kapsamı genişletmek ve TÜFE ile olası eş zamanlı ilişkileri yakalamak amacıyla seçilmiştir. Veri hazırlama sırasında uç değer duyarlılığı, ölçekte büyük farklar ve çoklu doğrusal bağlantı riski gözden geçirilmiştir. Ek olarak çalışmanın temelinde eksik veri olup olmadığı kontrol edilmiş ancak rastlanılmamıştır.

Araştırmanın deseni

Makroekonomik zaman serileri uzun dalga eğilimleri ve dönemsel kırılmalar içeren karmaşık yapılardır. Trend bileşeni, değişen politika çerçeveleri ve fiyatlama davranışları ile birlikte genelleme gücünü zayıflatabilen bir unsur olarak öne çıkabilmektedir. Bu gibi durumlar modellenen ilişkiyi örneklem içinde (örneğin; model eğitimi) güçlü gösterirken örneklem dışı tahminlerde (örneğin; model test ve validasyon aşaması) belirgin sapmalara yol açabilmektedir. Bu nedenle güvenilir bir tahmin çerçevesi yalnızca iyi uyum sağlayan değil aynı zamanda farklı dönemlerde kararlı sonuç veren bir öğrenme hattı üzerine kurulmalıdır.

Makine öğrenmesi yöntemleri çoğu zaman uygulaması zorunlu dağılım ve zaman serisi varsayımlarına ihtiyaç duymaz. Bununla birlikte trend, mevsimsellik ve değişen varyans gibi temel zaman serisi bileşenlerinin denetlenmesi örneklem dışı performansı iyileştirebilir. Bu çalışma bu gibi varsayımlara gereksinim duyulmasa da veri hazırlık sürecinde bu gibi varsayımların ne kadar önemli olduğunu karşılaştırmalı bir biçimde göstermiştir. Ridge ve Lasso gibi doğrusal yapıyı zayıf büzülme ile istikrarlı ve yorumlanabilir tutarken, makine öğrenmesi (özellikle ağaç-tabanlı yöntemler) doğrusal olmayan ilişkileri ve yüksek dereceli etkileşimleri otomatik olarak yakalayarak genelleme performansını artırır. REER göstergeleri ile M2'nin enflasyon dinamiklerinde sergileyebildiği asimetrik koşula bağlı etkiler bu esnekliği gerekli kılar. Bu nedenle, lasso ve ridge gibi makine öğrenmesi algoritmaları doğrusal modelin yorum gücünü koruyup düzenleme ile stabilize ederken, ML katmanı ile öngörü doğruluğunu ve sağlamlığı iyileştirebileceğinden dolayı makine öğrenmesi algoritmaları tercih edilmiştir. Dönüşümler model geliştirme eğitim döneminde öğrenilir ve aynı parametrelerle test ile validasyon dönemlerine uygulanmıştır. Böylece bilgi sızıntısı riski azaltılır ve farklı rejimlerin genelleme gücü üzerindeki etkisi daha sağlıklı gözlenir. Trendli ve trendsiz iki paralel hat kullanılarak veri temsillerinin doğruluk ve kararlılık üzerindeki etkisi karşılaştırmalı olarak değerlendirilir.

Çalışmanın odağı TÜFE'nin (Tüketici Fiyat Endeksi) zamana ve trend eğilimine duyarlı bir öğrenme mimarisi ile modellenmesi ve gerekli görülmesi de zaman serileri varsayımlarının uygulanmasının çalışma performansına etkisine yönelik tasarlanmıştır. Tasarım iki eksen üzerine kurulmuştur. Birinci eksen veri temsili düzeyidir. Değişkenlerin trendli (orijinal) halleriyle kurulan hat ile trend bileşeni ayrıştırılmış halleriyle kurulan hat karşılaştırılmalı bir biçimde incelenmiştir. İkinci eksen ise model geliştirme süreçlerinin veriyi öğrenme yöntemine yöneliktir. Doğrusal tabanlı bir temel yaklaşımın yanı sıra aşırı uyumu sınırlamaya yönelik model katsayılarını cezalandıran yöntemler kullanılarak karşılaştırma yapılmıştır. Böylece aşırı uyum ve öğrenmeden kaçınılmıştır. Amaç tek bir yöntemi mutlak olarak model geliştirme başarısındaki gücünü görmek olmayıp, farklı veri temsillerinin (trendli/trendsiz) ve düzenleme yapabilen algoritmaların tahmin başarısı ile model başarısı üzerindeki etkisini sistematik biçimde ortaya koymaktır.

GSYH -tahmini yapan çalışmalar (ör. Kant vd., 2025) Random Forest gibi esnek yöntemlerin yanında cezalı doğrusal tekniklerin doğruluk-stabilite dengesi sağladığını, özellikle kriz-sonrası dönemlerde

validasyon başarısının belirginleştiğini göstermiştir. Toplu olarak bakıldığında, Tablo 1’deki bu literatür, cezalı regresyonların yüksek korelasyonlu göstergeler ve olası rejim farklılaşmaları altında aşırı uyumu sınırlayarak örneklem dışı dönemde daha tutarlı sonuçlar verdiğine işaret etmektedir (Tablo 1: Gabauer vd., 2024; Li ve Chen, 2014; Medeiros vd., 2021; Özgür ve Akkoç, 2021; Kant vd., 2025). Bu bulgular, bizim çalışmamızda da trend yönetimi ve düzenleme adımlarını birlikte kullanma gereğini metodolojik olarak desteklemektedir.


Uygulama

Çalışmanın çatısı Şekil 1’de adım adım özetlenen, yalın ve akışkan bir süreç üzerine kurulmuştur. İlk olarak değişken kurulmuş, TÜFE bağımlı değişkeni ile bağımsız değişkenler arasındaki eş-zamanlı ilişkiler için korelasyon analizi yapılmıştır. Zayıf ilişki gösterenler temel modelden çıkarılmıştır (genellikle <30). Ardından Varyans Enflasyon Faktörü (VIF) ve Tolerans ölçümleriyle çoklu doğrusal bağlantı kontrol edilmiştir. REER göstergeleri arasında saptanan yüksek eş doğrusal bağlantı nedeniyle Şekil 1’deki “Boyut İndirgeme” düğümünde Temel Bileşenler Analizi uygulanmış ve ortak bilgi tek iyi koşullandırılmış bileşende toplanmıştır. Sonrasında iki paralel veri temsili oluşturulmuştur. Trendli hat orijinal serileri, trendsiz hat ise doğrusal eğilim bileşeni eğitim döneminde tahmin edilip çıkarılmış serileri kullanır. Tüm dönüşümler yalnızca eğitim dönemi bilgisiyle öğrenilmiş ve test ile validasyon dönemlerine ayrıştırılmıştır. Her iki hatta aynı zaman bölmeleri kullanılmıştır.

Eğitim seti için 2006-2020 aralığı, test seti için 2021-2022 ve validasyon seti için ise 2023-2024 yıllarında 12’şer aydan oluşan zaman bölmeleri yer almaktadır. Modelleme Şekil 1’de gösterildiği üzere üç doğrusal öğrenme yöntemi ile yürütülmüştür. En Küçük Kareler temel doğrusal uyumu sağlarken, Ridge katsayı büyüklüklerini L2 cezasıyla küçültür ve Lasso ise L1 cezasıyla bazı katsayıları sıfıra bastırabilir. Çalışmada tüm kestirimciler için öznitelikler yalnızca eğitim kümesi üzerinde standardize edilmiş olup test ve validasyon kümelerine eğitim istatistikleri uygulanmıştır. Ridge ve Lasso’da düzenleme şiddeti $\alpha=0,001$ olarak sabit tutulmuştur. Bu seçim, literatürde yaygın olan log-ölçekli düzenleme ızgaralarının (10-5 gibi) “zayıf büzülme” düğümüne ve kavramına karşılık gelmektedir. EKK’ye oldukça yakın biçimde katsayıları çok fazla küçültmeden ve varyansı azaltarak çözümü daha iyi koşullandırma amacı taşır. Özellikle çoklu bağlantılı bağımsız değişken uzayında (ve zaman serilerinde etkin örnek büyüklüğünü azaltabilen otokorelasyon koşullarında) küçük fakat pozitif bir α ’nın varyanslarını düşürdüğü ve kestirimin kararlılığını arttırmaktadır. Tercih ettiğimiz $\alpha=0,001$, bu “zayıf düzenleme” rejimini temsil eden kanonik bir düğümdür.

Ridge ve Lasso algoritmalarında düzenleme parametresinin log-ölçekte ele alınması ve (genellikle) bu ölçekte seçilmesi standart pratik olarak görülmektedir. Ayrıca $\alpha=0,001$ seçimi, büyük varyanslı (zayıf kısıtlayıcı) bir öncülün deterministik eşleniği olarak, parametreleri hafifçe küçülterek aşırı uyumu engellemektedir. Bu nedenle, optimizasyon yapılmaksızın α ’yı sabitlemek, çalışmamızda yeniden üretilebilirliğini ve zayıf düzenlemeyi koruma açısından hedeflenmiştir (Friedman vd., 2010; Hastie vd., 2009).

Başarı kriterleri olarak R^2 ve R^2_α (düzeltilmiş R^2) ile Ortalama Mutlak Hata (MAE), Ortalama Kare Hatası (MSE), Kök Ortalama Kare Hatası (RMSE) ve Ortalama Mutlak Yüzde Hatası (MAPE) model başarı kriterleri birlikte kullanılmıştır. Trendli ile trendsiz temsil arasındaki farkların istatistiksel değerlendirmesi eşleştirilmiş karşılaştırmalara dayanır. Birincil test Wilcoxon işaretli sıra olup eşleştirilmiş t ve eşleştirilmiş permütasyon testleri sağlamlık kontrolü için kullanılmıştır. Tüm anlamlılık sınamaları $\alpha=0,05$ düzeyinde yürütülmüştür. Bu çerçevede, Şekil 1’deki akışı izleyerek değişken seçimi, boyut indirgeme, iki veri temsili, ortak eğitim-test-validasyon adımlarını ve istatistiksel kıyasın bütünü mimari olarak oluşturmaktadır.



Şekil 1: Çalışma Süreci Akışı ve Mimarisi

Hipotezlerin kurulumu ve sınanması noktasında araştırılan çiftler aynı gözlemlerin iki temsili olduğundan bağımsız değildir. Örneğin validasyon döneminde aynı algoritma ve aynı metrik için trendli ve trendsiz sonuçlar bir çift oluşturur. Gözlem sayısı küçüktür ve farkların normal dağılacığı ya da normal dağılan bir uzaydan geldiği kesin değildir. Bu nedenle dağılım varsayımı gerektirmeyen ve eşleştirilmiş yapıya uygun Wilcoxon işaretli sıra testi temel test olarak kullanılmıştır. Test sonuçlarını daha güvenilir kılmak için eşleştirilmiş t testi ve eşleştirilmiş permütasyon testi de $\alpha=0.05$ anlamlılık düzeyinde kullanılmıştır.

Validasyon döneminde ay bazında trendli ve trendsiz temsilin ortalamaları eşleştirilerek “seviyede fark var mı?” sorusunun sınamasında aşağıdaki hipotez kurulmuş olup tanımsal olarak her ay için $d_m = \bar{y}_m^{trendli} - \bar{y}_m^{trendsiz}$ bilgisi önemlidir.

H_0 : $Medyan(d_m)=0$ (Validasyon döneminde aynı ay için trendli ve trendsiz TÜFE ortalamaları arasında tipik bir fark yoktur; medyan fark sıfırdır.)

H_1 : $Medyan(d_m) \neq 0$ (Validasyon döneminde aynı ay için trendli ve trendsiz TÜFE ortalamaları arasında tipik bir fark vardır; medyan fark sıfırdan farklıdır.)


Aynı validasyon dönemlerinin başarıları arasında anlamlı bir farklılık olup olmadığını sınamak için aşağıdaki hipotez oluşturulmuş olup tanımsal olarak her başarı kriteri çifti için $\Delta_i = R_{trendsiz}^2 - R_{trendli}^2$ bilgisi önemlidir.

H_0 : $Medyan(\Delta_i) \leq 0$ (Validasyon döneminde trendsiz modelin uyum ölçütleri trendli modele göre daha yüksek değildir; tipik fark sıfır ya da trendli yönündedir.)

H_1 : $Medyan(\Delta_i) > 0$ (Validasyon döneminde trendsiz modelin uyum ölçütleri trendli modele göre daha yüksektir; tipik fark pozitifdir.)

Değişkenler arası saçılım


Bu bölümde, belirli bir zamanda değişkenler arasındaki ilişkileri gösteren dağılım grafikleri sunulmaktadır. Dikey eksen bağımlı değişken olarak TÜFE, yatay eksen ise bağımsız değişkenler yer almaktadır. Örneklem aylık sıklığa sahiptir ve 2006-2024 dönemine ait verilerden oluşmaktadır.



Şekil 2: TüFE ile Makro Değişkenler Arasındaki İlişki Örüntüleri: Saçılım Diyagramları (2006–2024)

Şekil 2.a, TüFE ile REER (TüFE bazlı) arasında açıkça negatif, doğrusal olmayan bir ilişki olduğunu göstermektedir. REER düştükçe, yüksek TüFE gözlemleri daha sık hale gelmektedir. Dağılım grafiği, içe doğru kıvrılan bir yapı ve 90-100 arasındaki yaklaşık REER bandının üzerinde zayıflayan bir eğim sergilemektedir. Bu bandın altında eğim daha belirgin hale gelmektedir, ancak değişim seviyesi düşük TüFE’de sınırlı kalmakta ve yüksek TüFE’de artmaktadır. Şekil 2.b, TüFE ile REER (GOÜ bazlı) arasında negatif bir ilişki olduğunu ve eğimli bir dağılım sergilemektedir. Dağılım ve eğimin büyüklüğü, TüFE bazlı ölçüme benzerdir. Şekil 2.c, TüFE ve REER (GÜ) bazlı için benzer bir negatif, kavisli bir model göstermektedir. Burada, üç REER göstergesinin birlikte hareket etme eğilimi dikkat çekicidir.

Şekil 2.d, cari hesap ve TüFE arasında geniş ve asimetrik bir dağılım göstermektedir; belirgin bir tekdüze ilişki göze çarpmamakta olup, periyodik kümeler ve aykırı değerler göze çarpmaktadır. 2.e, Sermaye Hesabı ve TüFE gözlemlerinin çoğunlukla sıfır civarında dikey bir bant oluşturduğunu göstermektedir; ilişki zayıf veya dalgalıdır ve bazı uç değerler belirgindir. Şekil 2.f, Finansal Hesap ve TüFE arasındaki dağılımın geniş olduğunu, ilişkinin net bir yönünün olmadığını ve tek bir eğilim etrafında kümelenme olmadığını göstermektedir. Şekil 2.g, Net Hata ve Eksiklik ile TüFE arasındaki dağılımın yüksek oynaklık ve düzensizlik gösterdiğini, bu da zayıf bir eşzamanlı ilişki olduğunu düşündürmektedir. Şekil 2.h, Mevduat Faiz Oranı ile TüFE arasında pozitif bir korelasyon olduğunu göstermektedir; eğim düşük-orta seviyelerde hafifken, yüksek seviyelerde artış daha belirgindir. Şekil 2.i, M2 PARA ARZI ile TüFE arasında güçlü ve pozitif bir korelasyon olduğunu göstermektedir; dağılım sağa doğru hafif eğik görünmekte ve zaman içinde net bir ortak eğilim sergilemektedir.



Şekil 3: Eş Zamanlı Korelasyon Matrisi: TÜFE ve Açıklayıcı Değişkenler

Değişkenler arası korelasyon

Şekil 3'deki korelasyon panelinde, TÜFE ile REER (TÜFE bazlı), TÜFE ile REER (GOÜ bazlı) ve TÜFE ile REER (GÜ bazlı) tüm ilişkilerin aynı yönde negatif ve yüksek büyüklükte olduğu gözlemlenmiştir. Üç göstergenin katsayıları büyük ölçüde örtüşmektedir; Spearman'ın rho korelasyonu (ρ) yaklaşık -0,90 ve -0,96, Kendall'in tau (τ) yaklaşık -0,70 ve -0,80, Pearson (r) ise yaklaşık -0,6 ve -0,75 bandında gözlemlenmiştir. Bu değerler, REER göstergeleri ile TÜFE arasındaki eşzamanlı ilişkinin güçlü ve tutarlı bir şekilde negatif olduğunu göstermektedir. Bu göstergeler Şekil 2'de yer alan ilgili değişkenlerin saçılım grafikleriyle de beklendiği üzere paralellik göstermektedir.

TÜFE ile M2 PARA ARZI arasında güçlü ve pozitif bir eşzamanlı ilişki gözlemlenmiştir ($\rho \approx 0,99$; $\tau \approx 0,90$; $r \approx 0,99$). TÜFE ile Mevduat Faiz Oranı arasındaki ilişki pozitif ve ılımlıdır ($\rho \approx 0,30-0,35$; $\tau \approx 0,20-0,25$; $r \approx 0,30-0,35$). Buna karşılık, TÜFE ile Cari Hesap, Sermaye Hesabı, Finansal Hesap ve Net Hata ve Eksiklik arasındaki korelasyonlar düşük kalmıştır; Şekil 2'deki grafiklerde gösterildiği gibi, bu değişkenler için korelasyon katsayıları çoğunlukla 0,30'dan az olduğu gözlemlenmiştir.

Çalışmada değişken seçimi eşzamanlı korelasyon sonuçlarına dayandırılmıştır. Korelasyon matrisi, TÜFE ve REER (TÜFE bazlı), REER (GOÜ bazlı) ve REER (GÜ bazlı) değişkenler arasında yüksek mutlak değerler ve negatif korelasyonlar; M2 PARA ARZI ile ise güçlü ve pozitif ilişkiler olduğunu göstermiştir. Buna karşılık, Cari Hesap, Sermaye Hesabı, Finansal Hesap, Net Hata ve Eksiklik ve Mevduat Faiz Oranı değişkenleri ile TÜFE arasındaki korelasyonların düşük kaldığı gözlemlenmiştir.

Bu bulgular çerçevesinde, REER göstergeleri ve M2 PARA ARZINA model dâhil edilmiştir; düşük korelasyonlu değişkenler temel modele dâhil edilmemiştir.

Çoklu doğrusal bağımlılık kontrolü

Çoklu doğrusal bağlantısallık, modelde yer alan açıklayıcı değişkenlerin birbirleriyle yüksek doğrusal ilişki göstermesi ve bunun sonucunda katsayı tahminlerinin varyansının şişmesi, güven aralıklarının genişlemesi güvenilirliğinin azalması durumudur. Bu nedenle, çoklu doğrusal bağlantısallık düzeyi, model geliştirme öncesinde VIF (Varyans Şişirme Faktörü) ve Tolerans ölçümleri kullanılarak kontrol edilir. Her bir bağımsız değişken için, VIF, bağımsız değişkenin diğer tüm açıklayıcı değişkenler üzerindeki çoklu regresyonundan elde edilen R kullanılarak hesaplanır (Formül 1). Tolerans ise bu şişkinliğin tersidir ve bağımsız değişkenin benzersiz bilgi içeriğini gösterir (Formül 2) (Daoud, 2017). Uygulamada, $VIF \approx 1-5$ genellikle kabul edilebilir, 5-10 arasındaki VIF değeri dikkat gerektirir ve 10 ve üzeri VIF değerleri önemli şişme ve çoklu doğrusal bağlantısallığın varlığını gösterir; tersine, toleransı düşük bağımsız değişkenler sorunlu kabul edilir.

$$VIF_j = \frac{1}{1 - R_j^2} \quad (1)$$

$$Tolerans_j = 1 - R_j^2 = \frac{1}{VIF_j} \quad (2)$$


Tablo 2: PCA Öncesi Çoklu Doğrusal Bağlantısallık Kontrolü için VIF ve Tolerans Değerleri

Değişken	İstatistik	
	VIF	Tolerans
REER (TÜFE Bazlı)	169526,979	0,000
REER (GÜ Bazlı)	57553,349	0,000
REER (GOÜ Bazlı)	29895,136	0,000
M2 PARA ARZI	1,5843	0,631

Tablo 2'deki VIF ve Tolerans değerleri, REER göstergeleri arasında önemli derecede çoklu doğrusallık olduğunu ortaya koymaktadır. VIF, REER (TÜFE bazlı) için 169526,979 olup, REER (GÜ bazlı) için 57553,349 ve REER (GOÜ bazlı) için 29895,136 olarak hesaplanmıştır. Bu üç değişkenin Tolerans değerleri ise sıfıra yakın (0,000) bulunmuştur. Bu büyüklükteki VIF değerleri, REER serilerinin birbirleriyle neredeyse doğrusal olarak örtüştüğünü göstermektedir. Buna karşılık, M2 PARA ARZI için VIF 1.5843 ve Tolerans 0,631 elde edildi; önemli bir bağlantı sorunu gözlemlenmedi. Bu tablo, REER değişkenleri model alanına birlikte dâhil edildiğinde, katsayı varyanslarının artabileceğini, işaretlerin ve büyüklüklerin örneklem oynaklığına duyarlı hale gelebileceğini ve tahmin istikrarının zayıflayabileceğini göstermektedir.

Temel bileşenler analizi


Aşırı çoklu doğrusallık bulguları (REER göstergeleri için çok yüksek VIF değerleri ve sıfıra yakın tolerans değerleri) nedeniyle, üç ayrı REER serisinin ortak varyasyonunu tek bir değişkene yoğunlaştırmak için Temel Bileşen Analizi (PCA) uygulanmıştır. Bu yaklaşım, yüksek korelasyonlu açıklayıcı değişkenlerin neden olduğu dengesiz katsayıları ve şişirilmiş standart hataları azaltırken, modele kayıpsız aktarılacak bilgileri özetlemiştir. Uygulamanın sonucunda, üç REER değişkeninden yeni bir bileşik gösterge türetilerek ve REER_PC1 olarak adlandırılmıştır.



Şekil 4: REER Göstergelerinin Açıklanan Ortak Varyans ve Bileşen Yamaç Grafiği

Şekil 4'te sunulan yamaç grafiği, birinci bileşenin toplam varyansın %98,6'sını açıkladığını, ikinci bileşenin katkısının %1,4'te kaldığını ve üçüncü bileşenin ihmal edilebilir düzeyde olduğunu göstermiştir. Eğrideki belirgin kırılma ilk bileşende oluşmuş olup, Kaiser ölçütü değerlendirildiğinde tek bileşenli bir özetlemenin yeterli olduğu anlaşılmıştır. Kaiser ölçütü bağlamında, standartlaştırılmış p değişkenli bir Temel Bileşenler Analizinde k . bileşenin öz değeri λ_k , açıklanan varyans oranı EVR_k ile ilişkiyi sağlamaktadır (Formül 3). Temel bileşenler analizinde ele alınan değişken sayısı (p) 3 olduğundan $\lambda_1 \approx 2,96$, $\lambda_2 \approx 0,04$ ve $\lambda_3 \approx 0,00$ olarak bulunmuştur ve PC1 için $\lambda_k > 1$ koşulu sağlanmıştır (Goretzko & Ruscio, 2024).

$$\lambda_k = EVR_k \times p, k = 1, \dots, p \quad (3)$$



Şekil 5: REER göstergeleri için PCA Grafiği (PC1-PC2-PC3): Yük Vektörleri ve Gözlem Dağılımı

Şekil 5'te gösterilen üç boyutlu yük vektörleri ve gözlem dağılımı, REER (TÜFE bazlı), REER (GÜ bazlı) ve REER (GOÜ bazlı) değişkenlerinin PC1'e aynı yönde ve benzer büyüklüklerde yüklendiğini, PC2 ve PC3'ün katkılarının ise zayıf kaldığını ortaya koymaktadır. Gözlemler PC1 ekseninde boyuna hizalanmıştır, bu da üç REER göstergesi arasındaki ortak hareketin tek bir boyutta güçlü bir şekilde yakalandığını göstermektedir.

Tablo 3: PCA Sonrası REER Göstergelerinden Üretilen Yeni Değişkenli Çoklu Doğrusal Bağlantı Kontrolü

Değişken	İstatistik	
	VIF	Tolerans
REER_PC1	1,514	0,661
M2 PARA ARZI	1,514	0,661

PCA kullanılarak, üç REER göstergesi tek bir bileşen (REER_PC1) halinde birleştirildi ve çoklu doğrusal bağlantısallık ölçümleri nihai modelde yeniden hesaplandı. Tablo 3'te gösterildiği gibi, REER_PC1 için VIF=1,514 ve Tolerans=0,661, M2 PARA ARZI için ise aynı VIF=1,514 ve Tolerans=0,661 değerleri elde edilmiştir. Bu değerler açıklayıcı değişkenler arasında artık önemli derecede çoklu doğrusal bağlantısallık sorunu olmadığını göstermektedir. İlk üç REER serisi arasındaki çok yüksek korelasyon (Şekil 3), PCA kullanılarak tek bir boyuta indirgenmiştir; böylece, katsayı tahminlerinin istikrarı artırılmış ve standart hata enflasyonu önemli ölçüde azaltılmıştır. Sonuç olarak, REER_PC1 ve M2 PARA ARZI değişkenlerinden oluşan nihai açıklayıcı değişkenler kümesi istatistiksel olarak iyi koşullandırılmış ve modelleme aşaması için uygun bulunmuştur.

Trend dinamiklerinin testi ve detrend yaklaşımı

Zaman serisi yöntemlerinde (ARIMA/SARIMA gibi) durağanlık ve eğilim varsayımları kritik öneme sahipken, birçok makine öğrenimi tekniği bu tür kısıtlamaları doğrudan gerektirmez. Ancak, güçlü ve yaygın eğilimlerin, özellikle model geliştirme süreçlerinde farklı dönemlerde (eğitim-test-doğrulama) hata ölçümlerini ve genelleme gücünü etkileyebileceği test edilmiştir. Bu nedenle, iki paralel yapılandırma tasarlanmıştır: (i) değişkenlerin trendli (orijinal) formuyla oluşturulan bir model ve (ii) aynı değişkenlerin trendden arındırılmış (trend kaldırılmış) formuyla oluşturulan bir model. Amaç, trend bileşeninin ayrılmasının doğruluk ve kararlılıkta ölçülebilir bir iyileşme sağlayıp sağlamadığını doğrudan ve karşılaştırmalı olarak değerlendirmektir.

Tablo 4: Mann-Kendall Trend Testi Sonuçları


DEĞİŞKEN		İSTATİSTİK			
		BETA0	BETA1	Ztest	p Değeri
TÜFE	Bağımlı	-218,984	6,154	3,588	0,000
REER (Bileşik)	Bağımsız	2,753	-0,024	-11,576	0,000
M2 PARA ARZI	Bağımsız	-2377875406,129	45604521,066	3,852	0,000

Bağımlı ve bağımsız değişkenlerimiz üzerinde 2006 ile 2024 yılları arasındaki aylık örneklem üzerinde uygulanan doğrusal trend tahminleri ve Mann-Kendall testi sonuçları, önemli eğilimlerin varlığını göstermiştir. TÜFE için eğim katsayısı $\beta_1=6,154$ olup, pozitif bir artışa eğilimindedir; Mann-Kendall istatistiği $Z_{Test}=3,588$ ve $p<0,001$ 'dir. REER_PC1 değişkeni için, $\beta_1=-0,024$, $Z_{Test}=-11,576$ ve $p<0,001$ ile negatif ve güçlü bir düşüş eğilimi tespit edilmiştir. M2 PARA ARZI değişkeninde, $\beta_1=45604521,066$ ile pozitif bir eğilim tespit edilmiştir; $Z_{Test}=3,852$ ve $p<0,001$. Bu bulgular, temel değişkenlerin belirgin ve farklı eğilimler taşıdığını ortaya koymaktadır.

$$y_t = \beta_0 + \beta_1 t + \mu_t \quad (4)$$

$$\mu_t = y_t - (\beta_0 + \beta_1 t) \quad (5)$$

Detrending, seriden deterministik doğrusal eğilimin çıkarılması yoluyla uygulanmıştır. Her bir seri (bağımlı ve bağımsız değişkenler) için Formül 4 biçimindeki trend modeli (Tablo 4) tahmin edilmiş olup, ardından Formül 5 biçimindeki artık μ_t tahmin edilmiştir. Böylece seriler, ortalaması yaklaşık olarak 0 etrafında salınan ve kısa dönemli dalgalanmaları muhafaza eden bir hale dönüştürülmüştür.



Şekil 6: Trend/Detrend Yapısının Seriler Üzerindeki Karşılaştırmalı Grafikleri

Şekil 6.a, özellikle 2021'den sonra orijinal TÜFE serisinde görülen net artış eğilimini göstermektedir. Şekil 6.b, sıfır civarında dalgalanan trendden arındırılmış TÜFE'yi göstermektedir. Şekil 6.c, REER_PC1 içindeki net düşüş eğilimini gösterirken, Şekil 6.d, trendden arındırılmış REER_PC1 içindeki döngüsel değişimleri ortaya koymaktadır. Şekil 6.e, M2 PARA ARZI değişkeninin güçlü bir artış eğilimi gösterdiğine işaret ederken, Şekil 6.f, trendden arındırılmış M2 PARA ARZI değişkeninin sıfır civarında dalgalandığını ve kısa vadeli oynaklık gösterdiğini ortaya koymaktadır. Bu görsel karşılaştırma, eğilim bileşeninin seriden nasıl ayrıldığını ve böylece karşılaştırılabilir bir ölçekte karşılaştırmalarını sağladığını göstermektedir. Bu, verilere dayalı olarak iki yaklaşımın (trend/detrend) açıkça ayırt edilebildiği ve farklı model geliştirme süreçlerinin başarısını üzerine etkisi konusunda bir gösterge olarak modellemede yararlı olacaktır.

Modelleme

Temel bileşenler analizi bölümünde elde ettiğimiz REER_PC1 (üç REER göstergesinin ortak açıklanan varyansına dayanan bileşik bir değişken) ve M2 PARA ARZI bağımsız değişkenleri kullanarak TÜFE bağımlı değişkeni modellenmiştir. Çalışma iki paralel çizgide yürütülmüştür: (i) tüm değişkenlerin orijinal (trendli) biçimiyle oluşturulan bir model ve (ii) aynı değişkenlerin trendden arındırılmış (trendsiz) biçimiyle oluşturulan bir modelleme biçimi. Zaman bölümü modelleme aşamaları sırayla, eğitim için 2006-2020, test için 2021-2022 ve doğrulama için 2023-2024 olarak belirlenmiştir. Performans karşılaştırmaları için aşağıdaki ise R^2 , Düzeltilmiş R^2 , MAE, MAPE, MSE ve RMSE başarı kriterleri kullanılmıştır. Bu, trend bileşenini ayırmanın, potansiyel olarak farklı rejimlerin olduğu dönemlerde modelin doğruluğunu ve istikrarını etkileyip etkilemediğini belirlememizi sağlamıştır.

Çalışmada kullanılan trendli ya da trendsiz modeller farketmeksizin her iki modelleme aşamasında da 3 farklı algoritma kullanılmıştır. Bu algoritmalarından ilki olan En Küçük Kareler (EKK) yöntemi gözlenen değerlerle modelin tahminleri arasındaki artıkların kareleri toplamını en aza indirerek Beta (β) katsayılarını seçer. Herhangi bir ceza terimi yoktur; dolayısıyla β 'lar yalnızca veri uyumuna göre belirlenir. Varsayımlar sağlandığında sapmasız ve verimli tahmin üretir; ancak çoklu doğrusal bağlantı ve uç değerler karşısında β 'ların oynaklığı artabilir (Jarantow, Pisors ve Chiu, 2023).

Lasso, β katsayılarının mutlak değerlerine L1 cezası uygular. Bu ceza, bazı β 'ları tam olarak sıfıra iterek modelde aynı anda düzenleme ve değişken seçimi yapmış olur. Çok sayıda bağımsız değişken içeren modellerde yalın ve yorumlanabilir bir model üretmektedir. Ceza gücü yine α ile kontrol edilir (Freijeiro-González, Febrero-Bande ve González-Manteiga, 2022).

Ridge, EKK'nin amaç fonksiyonuna β büyüklüklerini "ölçeğe göre" baskılayan bir L2 cezası ekleyerek pratikte her bir β sıfıra doğru küçültülür (shrinkage kavramı), fakat tipik olarak tam sıfıra yaklaşmaz sadece çok fazla küçülür. Bu da birlikte değişen açıklayıcılar ve çoklu doğrusal bağlantıya meyilli modeller olduğunda β katsayılarını dengeler, varyansı düşürür ve genelleme hatasını azaltır. Ceza gücü Lasso algoritmasıyla aynı biçimde α ile ayarlanır (Rokem ve Kay, 2020).

Trendli verilerin detrended yöntemiyle trendsizleştirilmiş versiyonlarıyla 2 farklı değişken yapısının 3 farklı algoritma ve her algoritma için de 3 farklı model sürecinin başarıları karşılaştırılmıştır.


Tablo 5: Eğitim-Test-Validasyon Aşamalarına Göre Model Uyum ve Hata Ölçütleri (Trendli/Trendsiz)

TREND	YÖNTEM	ADIM	İSTATİSTİK & BAŞARI KRİTERİ						
			N (Ay)	R^2	R^2_α	MAE	MAPE	MSE	RMSE
TRENDLİ	EKK	Eğitim	180	%97,892	%97,868	10,614	4,501	211,290	14,536
		Test	24	%96,457	%96,120	35,132	5,104	1736,818	41,675
		Validasyon	24	%64,264	%60,861	236,068	10,783	86173,196	293,553
	Ridge	Eğitim	180	%97,892	%97,868	10,614	4,501	211,290	14,536
		Test	24	%96,457	%96,119	35,137	5,105	1737,035	41,678
		Validasyon	24	%64,254	%60,850	236,108	10,785	86197,884	293,595
	Lasso	Eğitim	180	%97,892	%97,868	10,615	4,502	211,290	14,536
		Test	24	%96,455	%96,118	35,152	5,106	1737,789	41,687
		Validasyon	24	%64,221	%60,814	236,234	10,792	86277,764	293,731
TRENDSİZ	EKK	Eğitim	180	%99,598	%99,593	8,016	7,840	205,824	14,347
		Test	24	%89,621	%88,632	51,414	152,962	3376,413	58,107
		Validasyon	24	%90,382	%89,466	122,195	18,734	19361,055	139,144
	Ridge	Eğitim	180	%99,598	%99,593	8,016	7,839	205,824	14,347
		Test	24	%89,620	%88,632	51,415	152,962	3376,521	58,108
		Validasyon	24	%90,381	%89,465	122,197	18,734	19362,018	139,147
	Lasso	Eğitim	180	%99,598	%99,593	8,016	7,841	205,824	14,347
		Test	24	%89,620	%88,631	51,416	152,968	3376,680	58,109
		Validasyon	24	%90,381	%89,465	122,198	18,734	19362,355	139,149

Tablo 5'e bakıldığında Trendli veri yapısındaki modellerde üç farklı algoritmanın da Eğitim ve Test adımlarında yakın performans verdiği gözlemlenmiştir. EKK yöntemi için R^2 =%97,892 ve Test'te R^2 =%96,457; benzer biçimde Ridge ve Lasso'da da aynı düzeylerde korunmuştur. Buna karşın Validasyon (2023-2024) döneminde tüm yöntemlerde belirgin bir kırılma meydana gelmiş olup, EKK'de R^2 =%64,264, Ridge'de %64,254 ve Lasso'da %64,221 olarak hesaplanmıştır. Düzenleme (Ridge ve Lasso) eğitim ve testte aşırı uyumu önlese de validasyon dönemindeki keskin düşüşü önleyememiştir. Aşırı uyuma karşı dayanıklı olan bu 2 algoritma validasyon döneminde başarısız olmuştur. Buna neden olarak trendli verilerde Eğitim döneminde öğrenilen verilerin Validasyon dönemini karşılayamaması veya serideki validasyon dönemi rejiminin eğitim ve teste göre farklı bir rejim içermesinden kaynaklanıyor olabileceği göz önünde bulundurulmalıdır.

Trendden arındırılmış modellerde eğitim başarıları trendsiz modellere göre oldukça yüksektir. Kendi içinde değerlendirildiğinde ise EKK için R^2 =%99,598, Ridge ve Lasso için aynı düzeyde olup R^2 =%99,598'dur. Test adımında R^2 =%89,620 ve validasyon adımında R^2 =%90,382 olarak elde edilmiştir; Ridge ve Lasso sonuçları neredeyse aynıdır. Trendsiz modellerde validasyon dönemi başarısı ve R^2 değerlerinin, trendli modellere nazaran çok daha yüksek olup eğitim ve test dönemlerine ait R^2 değerlerine oldukça yakın olduğu gözlemlenmiştir. Böylece trendsiz modelde, trendli modele kıyasla verilerdeki trend yapısının sıfıra yaklaştırılmasının olası farklı rejimsel dönemler üzerindeki etkisi

gözlemlenebilmektedir. Trendsizleştirme (Detrending) sonrasında modelin genelleme gücünün yüksek olduğu ve kalan açıklayıcı yapının doğrusal çerçevede tutarlı olduğu söylenebilir.



Şekil 7: EKK, LASSO ve RIDGE Algoritmalarının Trendli ve Trendsiz Yapıdaki Serilerin Tahminlemedeki Gerçek Değer ve Tahmin Edilen Değer Karşılaştırması

Tablo 5'te yüksek R^2 ve düzeltilmiş R^2 değerlerine rağmen, kriterlerin niteliği ve veri yapısı birlikte değerlendirildiğinde, büyük MAE, MAPE, MSE ve RMSE değerlerinin tutarlıdır. R^2 , toplam varyansın ne kadarının açıklandığını gösteren göreceli bir uyum ölçüsüdür ve serinin çoğunu oluşturan ortak sapma hesaba katıldığında kolayca artabilir. Ancak, bunu yakalamak, hatayı mutlaka olarak azaltmaz. Şekil 7.b'de de görüldüğü üzere 2021'den sonraki rejim değişikliği ve 2023-2024'teki önemli büyüme, tahminlerde sistematik bir hata artışı getirmiş ve böylece mutlak hata temelli ölçütleri (MAE, MSE ve RMSE) artırmış olabilir. Ek olarak, MSE ve RMSE ölçeğe bağlıdır, yani TÜFE seviyeleri ve oynaklık yüksek olduğunda, küçük sapmalar bile önemli mutlak hatalara neden olabilir. MAPE'nin yüksek görünümü, özellikle trendden arındırılmış seride paydanın sıfıra yaklaştığı noktalarda, metriklerin yapısal olarak aykırı değerlere ilerliyor olmasından kaynaklanıyor olabilir. Bağımlı değişken küçük olduğunda, aynı büyüklükteki hatalar yüzdelere orantılı olarak şişirir ve %100'den büyük değerler de bu gibi durumlarda görülebilir.

Eğitim sütunundaki grafikler (Şekil 7.a, 7.d ve 7.g), tahmin edilen ve gerçek değerlerin neredeyse tamamen aynı olduğunu göstermektedir. Test sütununda (Şekil 7.b, 7.e ve 7.h), uyum büyük ölçüde korunmuştur. Buna karşılık, validasyon sütununda (Şekil 7.c, 7.f ve 7.i), tahminler ile gerçek değerler arasında belirgin bir sapma ortaya çıkmaktadır. Bu fark, 2023-2024 döneminde seviye yükselmeleri sırasında özellikle belirgin hale gelmekte ve heteroskedastisiteye (seviye yükseldikçe artan sapma) ve rejim değişikliklerine duyarlı bir tahmin hatası olduğunu göstermektedir. Üç algoritma da benzer bir model sergilemektedir, bu da doğrulama performansındaki bozulmanın, yalnızca aşırı uyumdan ziyade dönem yapısındaki değişiklikler ve ölçek etkileriyle tutarlı olduğunu göstermektedir.

Trend bileşeni kaldırıldıktan sonra, eşleşme eğitim (Şekil 7.j, 7.m ve 7.p) ve test (Şekil 7.k, 7.n ve 7.r) grafiklerinde güçlüdür, ancak validasyon (Şekil 7.l, 7.o ve 7.s) grafiklerinde sapma devam etmekte, ancak trend durumuna kıyasla biraz daha sınırlı görünmektedir. Bu grafikler, trend bileşeninin ayrılmasının, özellikle önemli seviye değişikliklerinin olduğu yıllarda, göreceli hatanın artışı azaltılabileceğini göstermiştir. Ancak, rejim değişiklikleri tamamen ortadan kaldırılmadığında, tahmin edilen ve gerçek değerler arasındaki fark yine de artabilir.

Trend yapısına sahip TÜFE Bağımlı değişkenin REER_PC1 ve M2 PARA ARZI değişkenleriyle 3 farklı yöntem kullanarak (EKK, Ridge ve Lasso) modellenmesi sonucunda eğitim ve test setlerinin başarı kriterleri arasında belirgin bir farklılık görülmezken, validasyon setinde model başarısının düşüşü bariz bir şekilde fark edilmiştir. Bu farklılık TÜFE bağımlı ve her 2 bağımsız değişkenden trend eğrisinin çıkartılmasıyla elde edilen değişkenler ile bir model kurularak ve aynı yöntemler ile sınanarak giderilmeye çalışılmıştır. Bu noktada trendli veriler ve trendsiz verilerin model başarı kriterlerinde ve validasyon aşamasında anlamlı bir artış gözlemlenmiştir. Ancak bu artışın istatistiksel olarak test edilerek $\alpha=0,05$ anlamlılık düzeyinde anlamlılık göstermesi gerekmektedir ki trendden arındırmanın etkisinin olduğunu söyleyebilelim.

Aynı aylar için eşleşen gözlemleri karşılaştırdığımız ve trendsiz değerleri doğrudan trendli serisinden elde edildiğinden, örnekler bağımsız değildir. Bu nedenle, eşleştirilmiş t testi (ay içi farklar için) ve bu farklar için aykırı değer varsayımlarını hafifletmek için Wilcoxon işaretli sıra testi kullanılmıştır. Bu nedenle bağımsız örneklemeler için olan testler bu analiz için uygun bulunmamıştır.

Tablo 6: Trendli ve Trendsiz TÜFE Serisinde Validasyon Dönemi Ortalamaları

Ay	Ortalama TÜFE	
	Trendli Seri	Trendsiz Seri
Ocak	1593,750	520,424
Şubat	1657,605	578,126
Mart	1704,610	618,977
Nisan	1753,770	661,983
Mayıs	1791,225	693,284
Haziran	1835,440	731,345
Temmuz	1936,970	826,721
Ağustos	2033,825	917,422
Eylül	2108,600	986,044
Ekim	2174,010	1045,300
Kasım	2231,865	1097,001
Aralık	2271,965	1130,947

Tablo 6’da eşleştirilmiş testler, trendli ve trendsiz serileri arasında belirgin bir seviye kayması olduğunu tutarlı bir şekilde göstermektedir. Eşleştirilmiş $t_{Test} = 172,857$ ve $p < 0,001$ sonucunu vermiştir. Wilcoxon işaretli sıra testi $W_{Test} = 0,000$, $p < 0,001$ sonucunu vermiş olup eşleştirilmiş permütasyon testi ise $p < 0,001$ sonucunu vermiştir. Ay içi ortalama fark 1107,172 (Trendli-Trendsiz) olup, standart sapması 22,188’dir ve bu da Cohen’in $d_r=49,899$ ’a karşılık gelir. Birlikte ele alındığında, bu iki taraflı sonuçlar H_0 ’ı $\alpha=0,05$ ’te reddederek, TÜFE’nin trendli ve trendsiz aylık ortalamaları arasında büyük bir farklılık olduğunu göstermiştir.

Trendli ve trendsiz TÜFE değişkeninin validasyon dönemleri arasındaki farklılık anlamlı şekilde değiştiği test edilmiştir. Bu farkın modelin validasyon döneminde model başarı kriterleri açısından

farklılaşıp farklılaşmadığını test etmek gerekmektedir. Bunun temel nedeni trendli döneme ait serilerin eğitim ve test dönemlerinde iyi başarı göstermesi ancak validasyon döneminde aşağıdaki Tablo 6'da da görüldüğü üzere düşmesi validasyon döneminin rejimsel olarak farklı olduğunu düşündürmüştür. Bu olası rejimsel kırılmayı ve farklılaşmayı trend fonksiyonunun veriden çıkartılmasıyla giderilmiş olabileceğini test etmek ve bunun model başarısına yansımaları sınamak için iki farklı trend versiyonuyla elde edilen modellerin başarı kriterleri arasındaki anlamlı bir farklılığın bulunup bulunmaması istatistiksel olarak test edilmiştir.

Ortalamaları karşılaştırdığımız ve sınađığımız aşamada kullanılan gibi Wilcoxon işaret sıra testi kullanılmıştır. Bunun temel nedeni eşleştirilmiş algoritma ve başarı kriterinin kullanılıyor olmasıdır.

Tablo 7: Trendli ve Trendsiz Serilerden Elde Edilen Validasyon Dönemi Başarı Kriterleri

Yöntem	Başarı Kriteri	Model	
		Trendli	Trendsiz
EKK	R^2	%64,264	%90,382
	R^2_α	%60,861	%89,466
LASSO	R^2	%64,221	%90,381
	R^2_α	%60,814	%89,465
RIDGE	R^2	%64,254	%90,381
	R^2_α	%60,850	%89,465

Tablo 7'daki eşleştirilmiş performans çıktıları (R^2 ve R^2_α) kullanarak, iki validasyon dönemini karşılaştırdık. Wilcoxon işaretli sıra testi, $W_{Test} = 21,000$, $p=0,016$ sonucunu vermiştir, bu da tek taraflı hipotez için α %5 anlamlılık düzeyinde H_0 'ın reddedilmesine yol açmıştır. Eşleştirilmiş t-testi ($t_{Test} = 49,195$, $p<0,001$) ve tek taraflı eşleştirilmiş permütasyon testi ($p=0,015$) ile tutarlı kanıtlar elde edilmiştir. Bu sonuçlar bir arada değerlendirildiğinde, EKK, Ridge ve Lasso'da, doğrulama dönemi R^2 ve R^2_α değerlerinin trendli modele göre trendsiz validasyon döneminde daha yüksek olduğu tespit edilmiştir. Kısacası, trend bileşeninin kaldırılması, 2023-2024 doğrulama verilerinde genelleme performansında istatistiksel olarak anlamlı bir iyileşme sağladığı söylenebilir.

Bulgular

Eğitim ve test dönemlerinde, trendli model ile trendsiz model yakın başarı düzeyleri sergilerken, validasyon döneminde (2023-2024) trendli modellerin $R^2 \approx \%64$ civarına düştüğü; buna karşılık trendsiz modellerin $R^2 \approx \%90$ mertebesine yükseldiği görülmüştür (R^2_α için de benzerdir). Bu farklılaşma, eğitim-test dönemlerine kıyasla validasyonda gözlenen seviyelenme ve rejim farklılaşmasının trend bileşeni üzerinden modele taşındığında genelleme gücünü zayıflattığını, trend ayrıştırması yapıldığında ise bu zayıflamanın büyük ölçüde giderildiğini göstermiştir.

Trendli ve trendsiz validasyon başarı ölçütleri arasındaki fark, eşleştirilmiş testlerle istatistiksel olarak teyit edilmiştir. Wilcoxon $W_{Test}=21,000$, $p=0,016$, eşleştirilmiş $t_{Test}=49,195$, $p<0,001$ eşleştirilmiş (tek yönlü) permütasyon testi $p=0,016$. Yani trendsiz modellerin validasyonda trendli modellere kıyasla anlamlı biçimde daha yüksek uyum sergilediği sonucuna ulaşılmıştır. Buna rağmen, hata ölçütlerinin (özellikle MSE ve RMSE için) ölçek bağımlılığı ve heteroskedastisite eğilimi nedeniyle yüksek seyredebileceği, seviye arttıkça aynı oransal sapmanın mutlak hata olarak büyüdüğü de görülmüştür. Tam da bu noktada makine öğrenmesi ya da derin öğrenme tekniklerinde zaman serisi varsayımlarının test edilmesine gerek duyulmuyor gibi görölse de oldukça önemli olduğu bir kez daha görülmüştür.

Çalışmanın başlıca katkıları üç başlıkta özetlenebilir: (i) Üç ayrı REER göstergesinin PCA ile tek bir REER_PC1 bileşenine indirgenmesi ve çoklu doğrusal bağlantının sayısal olarak ortadan kaldırılması; (ii) Trendli-trendsiz kurguların dış-örnek doğruluk açısından nicel ve istatistiksel kıyaslaması; (iii) EKK, Ridge ve Lasso'nun şeffaf ve kıyaslanabilir bir mimaride uygulanması adımları model başarısını doğrudan ya da dolaylı olarak etkileyen adımlar olduğu tespit edilmiştir. Bulgular, farklı rejimlere geçişin beklendiği dönemlerde trend yönetimi yapılmadan kurulan doğrusal modellerin yüzeyde yüksek uyum verse dahi genelleme açısından kırılma olabileceğini göstermiştir.

Çalışma sürecinde karşılaşılan sınırlılıklar ve gelecek çalışmalar açısından, bu çalışmada detrend işlemi doğrusal eğilim bileşeni üzerinden yürütülmüştür; doğrusal olmayan trendler, rejim kırılmaları (örneğin; Bai-Perron), zamanla değişen parametreler veya esnek dönüşümler (log-ölçek, Box-Cox) ele alındığında ek kazanımlar sağlanabilir. Ayrıca, hataların koşullu varyansındaki olası değişimleri

yakalamak üzere robust standart hatalar, yeniden örnekleme veya ağırlıklandırılmış kayıp fonksiyonları kullanılabilir. Özellikle heteroskedastisite açısından önlem olarak uygulanabilirler.

Sonuç

Enflasyon hedeflemesi rejimleri üzerine yapılan ampirik çalışmaların büyük bölümü geleneksel ekonometrik yöntemlere dayanmaktadır. Svensson (1997), açık enflasyon hedeflemesinin politika şeffaflığı ve beklenti yönetimi üzerindeki rolünü teorik düzeyde ele alırken; Mishkin (2000) ve Bernanke vd. (1999), enflasyon hedeflemesinin fiyat istikrarını artırdığını ancak yapısal kırılmaların (structural breaks) tahmin doğruluğunu zayıflatabildiğini göstermiştir. Arestis ve Sawyer (2008) ise nominal çapa yaklaşımı içinde para arzı ve döviz kuru bileşenlerinin rolünü tartışmış, ancak model performansını makine öğrenmesi teknikleriyle incelememiştir. Daha yakın dönemde Hyndman ve Athanasopoulos (2018) ile Medeiros vd. (2021), zaman serisi tahminlerinde makine öğrenmesi tabanlı yöntemlerin klasik doğrusal modellere kıyasla, özellikle rejim değişimlerinin yaşandığı dönemlerde daha yüksek genelleme başarısı sergilediğini vurgulamışlardır.

Bu araştırma hem enflasyon hedeflemesi rejimlerinin değerlendirilmesi hem de makine öğrenmesi yaklaşımlarının makroekonomik politika analizine entegrasyonu açısından literatüre özgün ve metodolojik olarak yenilikçi bir katkı sunmaktadır. Özellikle trend ayrıştırması, model seçimi ve değişken etkileşimi konularında elde edilen bulgular, gelecekteki çalışmalara metodolojik referans sağlayabilecek niteliktedir.

Bu çalışma, enflasyon (TÜFE) tahminine yönelik nominal çapa yaklaşımı içinde en sağlam ve tutarlı göstergelerin TÜFE, gelişmekte olan ve gelişmiş ülkeler bazlı reel efektif döviz kuru göstergeleri ve M2 para arzı olduğunu göstermiştir. Özetle, reel efektif döviz kuru göstergeleri ve M2 para arzı'nın birlikte kullanılması, enflasyon/TÜFE dinamiklerini yüksek açıklayıcılık ile açıklayan basit ve pratik bir çerçeve sunmuştur.

Çalışma üç temel katkı sunmaktadır: Nominal çapa (nominal anchor) teorisini Türkiye bağlamında makine öğrenmesi metodolojisiyle bütünleştirerek, enflasyon hedeflemesi literatürüne veri odaklı yeni bir yorum kazandırmaktadır.

Trendli-trendsiz modelleme ayrımının, genelleme kapasitesi üzerindeki etkisini istatistiksel olarak (Wilcoxon, t-test, permütasyon testi) kanıtlayarak, model seçimi literatürüne ampirik bir katkı sağlamaktadır.

REER (reel efektif döviz kuru) göstergelerinin M2 para arzı ile birlikte kullanıldığında, enflasyon/TÜFE hareketlerini yüksek doğrulukla açıklayabildiğini göstererek, politika analizlerinde basit ama etkili bir tahmin çerçevesi önermektedir.

Hakem Değerlendirmesi / Peer-review:

Dış bağımsız

Externally peer-reviewed

Çıkar Çatışması / Conflict of interests:

Yazarlar çıkar çatışması bildirmemiştir.

The authors have no conflict of interest to declare.

Finansal Destek / Grant Support:

Yazarlar bu çalışma için finansal destek almadığını beyan etmiştir.

The authors declared that this study has received no financial support.

Yazar Katkıları / Author Contributions:

Fikir/Kavram/Tasarım - Idea/Concept/ Design: N.Ç.Y.. Veri Toplama ve/veya İşleme - Data Collection and/or Processing: N.Ç.Y., Analiz ve/veya Yorum - Analysis and/or Interpretation: N.Ç.Y., M.G., Kaynak Taraması- Literature Review: N.Ç.Y., M.G., Makalenin Yazımı - Writing the Article N.Ç.Y., Eleştirel İnceleme - Critical Review: N.Ç.Y., Onay - Approval: N.Ç.Y., M.G.

Kaynakça / References

- Aktan, C.C., Utkulu, U., & Togay, S. (1998). Nasıl bir para sistemi. İstanbul: İMKB Yayını.
- Alev, N. (2019). Türkiye’de enflasyonun belirleyicileri: ARDL sınır testi yaklaşımı (2006:Q1-2018:Q2 Dönemi). *Uluslararası Ekonomi, İşletme ve Politika Dergisi*. Cilt 3, Sayı 1, 1-18.
- Ball, L., & Sheridan, N. (2005). Does inflation targeting matter? in B. S. Bernanke & M. Woodford (Eds.), *The inflation-targeting debate* (pp. 249-282). University of Chicago Press.
- Başçı, E. & Kara, H. (2005). Enflasyon hedeflemesi ve Türkiye deneyimi. TCMB Çalışma Tebliği.
- Barro R.J. (1979). Money and the price level under the gold standard. *The Economic Journal*, Vol. 89, No. 353 (March, 1979), pp. 13-33 (21 pages) Printed in Great Britain
- Baybuza, I. (2018). Inflation forecasting using machine learning methods. *Russian Journal of Money and Finance*, 77(4), 42-59.
- Bernanke, B. S., Laubach, T., Mishkin, F.S. & Posen, A.S. (1999). *Inflation Targeting: Lessons from the international experience*. Princeton, New Jersey: Princeton University Press.
- Bruno, M. (1990). High inflation and the nominal anchors of an open economy. National Bureau of Economic Research Working Paper, No. 3518.
- Calvo, G.A., & Reinhart, C. M. (2002). Fear of floating. *The Quarterly Journal Of Economics*, 117(2), 379-408.
- Clarida, R., & Gertler, M. (1997). How the Bundesbank conducts monetary policy. In C. D. Romer & D. H. Romer (Eds.), *Reducing inflation: Motivation and strategy* (pp. 363-412). University of Chicago Press.
- Croce, E. & Khan M. S. (2000). Monetary regimes and inflation targeting. *Finance and Development*, 37(3), 48-51.
- Cukierman, A. (1999). The inflation bias result revisited. *Economics and Politics*, 11(3), 295-319.
- Çiçek, S., Akar, C., & Yücel, E. M. (2011). Türkiye’de enflasyon beklentilerinin çapalanması ve güvenilirlik [Anchoring of inflation expectations and credibility in Turkey]. *İktisat, İşletme ve Finans*, 26(304), 37-55.
- Daoud, J. I. (2017). Multicollinearity and regression analysis. *Journal of Physics: Conference Series*, 949, 012009.
- Dornbusch, R., & Fischer, S. (1998). *Macroeconomics* (6th ed.). New York: McGraw-Hill.
- Edwards, S. & M.A. Savastano (1999): Exchange rates in emerging economies: What do we know? What do we need to know?, NBER Working Paper No. 7228.
- Fabris, N. (2025). Monetary regimes with two nominal anchors: Are they possible? *Journal of Central Banking Theory and Practice*, 1, 5-19.
- Flood, R. P., & Mussa, M. (1994). Issues concerning nominal anchors for monetary policy (NBER Working Paper No. 4850). Cambridge, MA: National Bureau of Economic Research.
- Freijeiro-González, L., Febrero-Bande, M., & González-Manteiga, W. (2022). A critical review of LASSO and its derivatives for variable selection in the presence of covariate correlations. *International Statistical Review*, 90(1), 118-145.
- Friedman, J. H., Hastie, T., & Tibshirani, R. (2010). Regularisation paths for generalised linear models via coordinate descent. *Journal of Statistical Software*, 33(1), 1-22.
- Gabauer, D., Gupta, R., Marfatia, H. A., & Miller, S. M. (2024). Estimating U.S. housing price network connectedness: Evidence from dynamic Elastic Net, Lasso, and Ridge vector autoregressive models. *International Review of Economics & Finance*, 89, 349-362.
- Garcia, M., Medeiros, M., & Vasconcelos, G. F. R. (2017). Real-time inflation forecasting with high-dimensional models: *The case of Brazil*. *International Journal of Forecasting*, 33(3), 679-693.
- Gordon, R. J. (1985). The conduct of domestic monetary policy. In A. Ando, H. Eguchi, R. Farmer, & Y. Suzuki (Eds.), *Monetary policy in our times* (pp. 19-55). MIT Press.

- Goretzko, D., & Ruscio, J. (2024). The comparison data forest: A new comparison data approach to determine the number of factors in exploratory factor analysis. *Behavior Research Methods*, 56, 1838–1851.
- Hastie, T., Tibshirani, R., & Friedman, J. (2009). *The elements of statistical learning: Data mining, inference, and prediction* (2nd ed.). Springer. (Bkz. Ch. 3, Sec. 3.4.1–3.4.3 ≈ pp. 61–69: Ridge Regression p. 61; The Lasso p. 68; Discussion p. 69)
- Isard, P., & Laxton, D. (2000). *Inflation-forecast targeting and the role of conditional projections*. Washington, DC: International Monetary Fund.
- Jarantow, S. W., Pisors, E. D., & Chiu, M. L. (2023). Introduction to the use of linear and nonlinear regression analysis in quantitative biological assays. *Current Protocols*, 3(6), e801.
- Kant, D., Pick, A., & de Winter, J. (2024). Nowcasting GDP using machine learning methods. *AStA Advances in Statistical Analysis*. Advance online publication.
- Krueger, A. O. (1997). *Exchange rate policy* (NBER Working Paper No. 5896). Cambridge, MA: National Bureau of Economic Research.
- Kydland, F. & Prescott, E. (1977). Rules rather than discretion: The inconsistency of optimal plans. *Journal of Political Economy*, June 1977, 473–92.
- Li, J., & Chen, W. (2014). Forecasting macroeconomic time series: LASSO-based approaches and their forecast combinations with dynamic factor models. *International Journal of Forecasting*, 30(4), 996–1015.
- McCallum, B. T. (1994). *Monetary policy and the term structure of interest rates*. NBER Working Paper No. 4938. National Bureau of Economic Research.
- Medeiros, M. C., Vasconcelos, G. F. R., Veiga, Á., & 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.
- Mishkin, F. S. (1999). *International experiences with different monetary policy regimes*. NBER Working Paper, No. 6965. (International Experiences)
- Mishkin F. S. (2001). *Issues in inflation targeting, price stability and the long-run target for monetary policy*, Proceeding of A Seminar Held by The Bank of Canada
- Mishkin F. S. & Savastano M. A. (2001). *Monetary policy strategies for emerging market countries: lessons from Latin America*. Seventh Dubrovnik Economic Conference, Dubrovnik, Croatia, June 28–30.
- Mishkin, F. S. & Posen A. S. (1997). *Inflation targeting: lessons from four countries*. Federal Reserve Bank of New York Economic Policy Review, August, 3(3).
- Mishkin, F. S., & Schmidt-Hebbel, K. (2007). Does inflation targeting make a difference? In F. S. Mishkin & K. Schmidt-Hebbel (Eds.), *Monetary policy under inflation targeting* (pp. 291–372). Banco Central de Chile
- Önder, T. (2005). *Para politikası: Araçları, amaçları ve Türkiye uygulaması*. Uzmanlık Yeterlilik Tezi, Ankara: Türkiye Cumhuriyet Merkez Bankası, Piyasalar Genel Müdürlüğü
- Özatay, F., & Sak, G. (2003). The 2000–2001 financial crisis in Turkey. *Emerging Markets Finance and Trade*, 39(4), 5–38.
- Özgür, Ö., & Akkoç, U. (2021). Inflation forecasting in an emerging economy: Selecting variables with machine learning algorithms. *International Journal of Emerging Markets*, 17(8), 1889–1908.
- Patinkin, D. (1993). Israel's stabilisation program of 1985, or some simple truths of monetary theory. *Journal of Economic Perspectives*, 7 (2): 103–128.
- Paya, M. (1994). *Para Teorisi ve Politikası*. İstanbul: Filiz Kitabevi.
- Rokem, A., & Kay, K. (2020). Fractional ridge regression: A fast, interpretable reparameterisation of ridge regression. *GigaScience*, 9(12), gaa133.
- Sachs, J., Tornell, A. & Velasco, A. (1996), "Financial Crises in Emerging Markets: The Lessons from 1995," *Brookings Papers on Economic Activity*, No. 1, 147–215

- Smeekes, S., & Wijler, E. (2018). Macroeconomic forecasting using penalised regression methods. *International Journal of Forecasting*, 34(3), 408–430.
- Soybilgen, B., & Yazgan, M. E. (2021). Nowcasting US GDP using tree-based ensemble models and dynamic factors. *Computational Economics*, 57(1), 387–417.
- Svensson, L.E.O. (1997). Inflation forecast targeting: Implementing and monitoring inflation targets. *European Economic Review*, 41(6), 1111–1146.
- Svensson, L.E.O., (1998a). Inflation targeting as a monetary policy rule. NBER Working Paper No. 6790.
- Taylor, J.B. (1993). Discretion versus policy rules *in* practice. *Carnegie-Rochester Conference Series on Public Policy*, 39, 195–214.
- Torun, M., & Yılmaztürk, R. G. (2021). Enflasyon hedeflemesinin temel belirleyicileri: Seçilmiş OECD ülkeleri için panel veri analizi. *Bilim-Teknoloji-Yenilik Ekosistemi Dergisi (Journal of Science-Technology-Innovation Ecosystem)*, 2(1), 1–8.
- Vega, M., & Winkelried, D. (2005). Inflation targeting and inflation behavior: A successful story? *International Journal of Central Banking*, 1(3), 153–175.
- Yenisu, E. (2019). Türkiye’de enflasyonun temel belirleyicileri: Toda-Yamamoto nedensellik analizi. *Siyaset, Ekonomi ve Yönetim Araştırmaları Dergisi*, 7(1), 43–58.
- Vrontos, S.D., Galakis, J., & Vrontos, I. D. (2021). Modeling and predicting U.S. recessions using machine learning techniques. *International Journal of Forecasting*, 37(2), 647–671.
- Walsh, C.E. & Hartley P.R. (1998). Financial intermediation monetary policy and equilibrium business cycle. *Federal Reserve Bank of San Fransisco Review*, (4)
- Willet T.D.(1998). Credibility and discipline effects of exchange rates as nominal anchors: The need to distinguish temporary from permanent pegs. *View The World Economy: August*, 21(6), 705-850.
- Woodford, M. (2003). *Interest and prices: Foundations of a theory of monetary policy*. Princeton University Press.