

Araştırma Makalesi / Research Article

GSYİH BÜYÜME ORANI VE TÜKETİCİ FİYAT ENDEKSİ DEĞİŞİM ORANLARI İLİŞKİSİ VE AYARLANMIŞ MAKİNE ÖĞRENİMİ ÖNGÖRÜCÜLERİ İLE MODELLENMESİ

Emek Ash CİNEL¹ , Ufuk YOLCU² 

ÖZET

Büyüme ve fiyat istikrarı, üzerinde sıkça araştırmaların yapıldığı en önemli konular arasında yer almaktadır. Bu çalışma, 2005 yılının birinci çeyreğinden 2024 yılının üçüncü çeyreğine kadar Türkiye’de Tüketici Fiyat Endeksi (TÜFE) değişim oranları ile Gayri Safi Yurtiçi Hasıla (GSYİH) büyüme oranları arasındaki ilişkiyi incelemektedir. Gecikmeli TÜFE ve GSYİH değerleri kullanarak, dört farklı makine öğrenmesi algoritmasıyla (SVR, GPR, NNR ve CNNR) GSYİH büyüme oranlarının öngörülmesi amaçlanmıştır. Öngörü başarısı dört farklı senaryo altında, HKOK ve ÖMYH ölçütleriyle değerlendirilmiştir. Bulgular, CNNR algoritmasının çoğu senaryoda en düşük hata ile en doğru öngörüleri sağladığını göstermiştir. NNR da özellikle doğrusal olmayan desenleri yakalama konusunda başarılı performans sergilemiştir. CNNR modelinin üstün öngörü doğruluğu, doğrusal ve doğrusal olmayan ilişkileri birlikte modelleyebilme yeteneğinden kaynaklanmaktadır. Genel olarak, makine öğrenmesi algoritmaları—özellikle CNNR ve NNR—enflasyon göstergeleri üzerinden GSYİH büyümesini güvenilir bir şekilde öngörebilecek araçlar sunmaktadır. Bu sonuçlar, özellikle dalgalı enflasyon koşullarında, politika yapıcılar ve analiz uzmanları için daha sağlam ekonomik stratejiler geliştirmede yol gösterici olabilir.

Anahtar Kelimeler: GSYİH Büyümesi, Enflasyon, Öngörü, Makine Öğrenmesi, Sinir Ağları

JEL Sınıflandırması: O11, E20, O4, C49, C45

MODELING THE RELATIONSHIP BETWEEN GDP GROWTH RATE AND CONSUMER PRICE INDEX CHANGE RATES USING TUNED MACHINE LEARNING REGRESSORS

ABSTRACT

Growth and price stability are among the most widely researched topics. This study explores the relationship between Consumer Price Index (CPI) change rates and Gross Domestic Product (GDP) growth rates in Turkey from the first quarter of 2005 to the third quarter of 2024. It aims to forecast GDP growth rates using lagged CPI and GDP values as predictors through four machine learning algorithms:

¹ Doç. Dr., Giresun Üniversitesi, İktisadi ve İdari Bilimler Fakültesi, Giresun, Türkiye, emekasli@yahoo.com

² Prof. Dr., Marmara Üniversitesi, Fen Fakültesi, İstanbul, Türkiye, ufuk.yolcu@marmara.edu.tr

Bu makaleye yapılacak atıf: Cinel, E. A., Yolcu, U. (2026). GSYİH büyüme oranı ve tüketici fiyat endeksi değişim oranları ilişkisi ve ayarlanmış makine öğrenimi öngörücüleri ile modellenmesi. *Uluslararası Yönetim İktisat ve İşletme Dergisi*, 22(1), 104-129. <https://doi.org/10.17130/ijmeh.1706446>

ISSN:2147-9208 E-ISSN:2147-9194

<http://dx.doi.org/10.17130/ijmeh.1706446>

Başvuru Tarihi: 26.05.2025, Yayına Kabul Tarihi: 21.07.2025

Support Vector Regression (SVR), Gaussian Process Regression (GPR), Neural Network Regression (NNR), and Cascade Neural Network Regression (CNNR). Forecasting performance was assessed across four scenarios using RMSE and MAPE metrics. Results revealed that CNNR provided the most accurate forecasts, with the lowest errors in most scenarios. NNR also demonstrated strong performance, particularly in capturing nonlinear patterns. The CNNR model's superior predictive accuracy is attributed to its hybrid architecture, which enables modeling of both linear and nonlinear relationships. Overall, machine learning algorithms, especially CNNR and NNR, offer reliable tools for forecasting GDP growth based on inflation indicators. These findings can support policymakers and analysts in forming more robust economic strategies, especially under volatile inflation conditions.

Keywords: GDP Growth, Inflation, Forecasting, Machine Learning, Neural Networks

JEL Classification Codes: O11, E20, O47, C49, C45

EXTENDED SUMMARY

Research Questions & Purpose

This study aims to examine the relationship between the Consumer Price Index (CPI) change rates and Gross Domestic Product (GDP) growth rates in Turkey from the first quarter of 2005 to the third quarter of 2024. This relationship is examined from an analytical perspective. The study also provides future forecasts for GDP growth rates using explanatory variables consisting of lagged values of GDP growth rates and lagged values of certain derivatives of inflation rates.

Literature Review

In the economic literature, there are many different domestic and foreign studies aiming to predict inflation and GDP growth rates with the idea that inflation and GDP growth rates are related, and it is seen that there is no general consensus among economists on the subject. In most of the studies, it is determined that there is a relationship between inflation and economic growth, but there is no clear consensus on the direction of this relationship.

The fact that the GDP growth rate is one of the basic economic indicators and its important position in determining policies and strategies makes its predictions for the future equally important. In this direction, many different scientific studies have been put forward for this purpose, especially in recent years. In the studies, different prediction models have been developed and GDP predictions have been made. In many of the studies, it has been revealed that the models exhibit superior prediction performances.

Methodology

Machine learning algorithms have shown remarkable success in time series forecasting problems, which are aimed at predicting continuous values from input data and can also be seen as a regression problem, due to their ability to detect complex patterns, process large data sets, and improve forecast accuracy. Machine learning allows systems to automatically identify patterns, make decisions, and adapt to new information by mirroring the human learning process.

Machine learning models can identify recurring patterns in historical data and extract hidden causal relationships, making them a valuable tool for predicting trends in time series

data. In this study, GDP growth rates are predicted using lagged CPI and GDP values with four different machine learning algorithms (SVR, GPR, NNR and CNNR). Forecast success is evaluated under four different scenarios with HKOK and OMYH metrics.

Results and Conclusion

In the study, the average performances as well as the forecasting performances on the test set in each scenario of four ML algorithms, in which the lagged values of the Consumer Price Index “change compared to the previous month” rates in three-month (one-quarter) periods and the lagged values of the GDP growth rates were used as explanatory variables, were examined in detail. It is observed that each ML algorithm produces predictions that are consistent with the observation values in the models where lagged time series of Consumer Price Index Change Rates and Gross Domestic Product are used as explanatory variables for the purpose of GDP forecasting. It is clearly observed that NNR and CNNR algorithms produce predictions that are more consistent with the observation values than GPR and SVR. It is noteworthy that CNNR gives predictions that are more compatible with the observation values than NNR, indicating the superior prediction performance.

Considering both the two error metrics HKOK and OMYH and the visual presentation of the compatibility of the predictions produced by the algorithms with the realized observation values (see Figure 5), it was observed that CNNR showed the superior performance in GDP prediction for the eight periods constituting the whole of 4 different scenarios. It can be said that CNNR, which exhibits the superior forecasting performances on average, especially in three out of four scenarios and when all four scenarios are considered together, exhibits a very superior and impressive performance for GDP growth rate forecasting with OMYH value forecasts around 1% and 3% and slightly above. NNR, on the other hand, exhibited the second best forecasting performance by producing forecasts with OMYH values around and slightly above 2% and 3% on average in all three scenarios and when all four scenarios were considered together, except for the third scenario. Moreover, GPR and SVR still demonstrated an undeniable success in predicting GDP growth rates with proportional errors of around 7% on average when the four scenarios were considered together.

When all the results are evaluated together, it has been shown that NNR and CNNR algorithms, which produce predictions with proportional errors around 3% and below, can be used as modeling and forecasting tools that can be used with confidence in estimating GDP growth rates by both researchers working in the relevant field and public and private sector decision makers.

1. Giriş

Gayri Safi Yurtiçi Hasıla (GSYİH), bir ülkenin ekonomik performansının en kritik göstergelerinden biridir. Genellikle üç aylık veya yıllık olarak ölçülen, belirli bir süre boyunca bir ülkenin sınırları içinde üretilen tüm mal ve hizmetlerin toplam değerini temsil etmektedir. GSYİH, ekonomik sağlık için önemli bir ölçüt görevi üstlenmekte ve hükümet politikalarını, yatırım kararlarını ve sosyal gelişimi şekillendirmede hayati bir rol oynamaktadır. GSYİH, bir ülkenin ekonomik faaliyetinin nicel bir ölçüsünü sağlamakta ve ekonominin büyüdüğünü, durgunlaştığını veya daraldığını değerlendirmeye yardımcı olmaktadır. Pozitif bir GSYİH büyüme oranı ekonomik genişlemeyi gösterirken, negatif bir büyüme oranı durgunluk veya ekonomik gerilemeyi işaret etmektedir. Kişi başına GSYİH ise, toplam GSYİH'yi nüfusa bölerek vatandaşların yaşam standardı ve ekonomik refahı hakkında fikir vermektedir. Daha yüksek bir GSYİH, daha iyi altyapı, sağlık hizmeti ve eğitim, daha yüksek istihdam fırsatları ve yaşam kalitesi anlamını taşımaktadır.

GSYİH tek başına gelir eşitsizliğini veya servet dağılımını hesaba katmamaktadır. Politika yapıcılar ve karar vericiler, faiz oranlarını belirleme ve para arzı düzenlemeleri gibi para politikaları tasarlamak ve uygulamak ve ayrıca istihdam ile ekonomik büyümeyi yönetmek için vergi oranları ve kamu harcamaları organizasyonu gibi maliye politikalarında GSYİH verilerini baz almaktadır. Uzun vadede hükümetler ve resmi kurumlar yol yapımı, enerji şebekeleri ve akıllı şehirler gibi altyapı geliştirme stratejilerini ve refah planlarını, sağlık hizmetleriyle eğitim fonları gibi sosyal programları GSYİH ve GSYİH değişim tahminlerine dayalı olarak belirlemektedir. Dolayısıyla GSYİH, bir ülkenin ekonomisinin temel göstergesi olup, o ülkenin politika kararlarını, yatırım stratejilerini, istihdamını ve uluslararası konumunu belirlemektedir.

Ekonomik istikrarın ve alım gücünün temel göstergesi olan enflasyon, Türkiye ekonomisinin kronik hale gelmiş sorunlarından en önemlisidir. Türkiye özellikle son yıllarda dünya genelinde en yüksek oranlı enflasyona sahip olan ülkeler arasında yer almaktadır. İthalata olan bağımlılık, düşük katma değerli dış ticaret yapısının beraberinde getirdiği arz talep dengesizliği ve kamu finansman sorunu enflasyonun süreklilik kazanmasında belirleyici olan ana unsurlardır. Döviz kurlarındaki dalgalanmalar, enerji fiyatlarındaki artışlarla vergi oranlarındaki yükselişler de Türkiye'de enflasyonu tetikleyen diğer faktörlerdir. Dolayısıyla Türkiye ekonomisi için enflasyonla mücadele etmek ve büyümeyi sürdürmek için uygulanan ekonomi politikalarının doğru bir şekilde yönetilmesi gerekmektedir.

GSYİH değerinin enflasyonla ilişkisi olsa da, bu ilişkinin örüntüsünün kesin bir doğrusal yapıyı takip etmediği ve bankacılık sistemleri, ekonomik politikalar ve aracı maliyetler gibi faktörlere de bağlı olarak enflasyonun GSYİH'yi olumlu veya olumsuz yönde etkileyeceği bilinmektedir (Xiong, 2023). Özellikle yüksek enflasyona sahip ülkeler, aşırı düşük enflasyonun ekonomik genişlemeyi engelleyebileceği fikrinden hareketle, enflasyon kontrolünü GSYİH büyümesiyle dengeleyen politikalar geliştirebilmektedir (Dunaev, 2025). Ayrıca, bölgesel ve ulusal ekonomik dinamiklere dayalı özelleştirilmiş politikaların enflasyon ve GSYİH arasındaki ilişkinin dikkate alınarak geliştirilmesi gerektiği bilinmektedir (Kumar vd., 2023).

Bu çalışmada, Türkiye'de 2005-2024 yılları arasında gözlenmiş Tüketici Fiyat Endeksi Değişim Oranları (Enflasyon) ile aynı dönemde gözlenmiş GSYİH büyüme oranları (ekonomik büyüme) ilişkisi analitik bir bakış açısı ile incelenmiştir. Çalışmada aynı zamanda GSYİH büyüme oranlarının gecikmeli değerleri ile enflasyon oranlarının belirli türevlerinin gecikmeli değerlerinin oluşturduğu açıklayıcı değişkenler ile GSYİH büyüme oranlarına ilişkin gelecek öngörüsü gerçekleştirilmiştir. Bu amaçla, *Destek Vektör Regresyonu* (Support Vector Regressi-

on -SVR), Gauss Süreci Regresyonu (Gaussian Process Regression - GPR), Sinir Ağı Regresyonu (Neural Network Regression - NNR) ve Basamaklı Sinir Ağı Regresyonu (Cascade Neural Network Regression - CNNR) olmak üzere dört farklı Makine Öğrenmesi (MÖ) algoritması öngörü aracı olarak kullanılmıştır. Çalışma sonuçları hem CNNR algoritmasının çoğu senaryoda en düşük hata ile en doğru öngörülerini sağladığını göstermiş hem de enflasyon ile GSYİH'nin birbirleriyle yakından ilişkili iki temel makroekonomik gösterge olduğu ispat etmiştir.

2. Literatür İncelemesi

İktisat literatüründe enflasyon ile GSYİH büyüme oranlarının ilişkili olduğu fikriyle, enflasyon ile GSYİH büyüme oranlarının öngörülmesini amaçlayan farklı çok sayıda yerli ve yabancı çalışma yer almakta olup iktisatçılar arasında konuyla ilgili genel bir görüş birliğinin olmadığı görülmektedir. Aşağıda bu çalışmaların bir kısmına tarihsel sıralı olarak yer verilmektedir.

Thirlwall & Barton (1971), çalışmalarında 1958-1967 döneminde ekonomik büyüme ile enflasyon arasındaki ilişkiyi araştırmışlardır. Çalışma sonucunda ekonomik büyümeyle enflasyon arasındaki ilişkinin gelişmiş ülkelerde pozitif yönlü, gelişmekte olan ülkelerde ise negatif yönlü olduğu sonucuna varmışlardır. Lucas (1973), çalışmasında 1951-1967 döneminde 18 farklı ülke için enflasyonla ekonomik büyüme arasındaki ilişkiyi incelemiştir. Çalışma sonucunda fiyat istikrarının olduğu ülkelerde enflasyonla ekonomik büyüme arasındaki ilişkinin pozitif yönlü olduğu ifade edilmiştir. Fischer (1993), çalışmasında enflasyon ve bütçe açığı gibi göstergelerin ekonomik büyüme üzerindeki etkilerini incelemiştir. Çalışmadan elde edilen bulgulara göre enflasyon ile ekonomik büyüme arasında negatif yönlü bir ilişki vardır. Barro (1995), çalışmasında 100 ülke ekonomisi için 1960-1990 döneminde enflasyonla ekonomik büyüme arasındaki ilişkiyi panel veri setinden yararlanarak araştırmıştır. Çalışma sonucunda ortalama enflasyon oranındaki %10'luk bir yükselişin ekonomik büyümeyi %0.2 ile %0.3 oranında azalttığı tespit edilmiştir. Paul vd. (1997), çalışmalarında 70 ülke ekonomisi için 1960-1989 döneminde enflasyonla ekonomik büyüme arasındaki ilişkiyi araştırmışlardır. Çalışmada Granger nedensellik analizinden yararlanılmıştır. Çalışma sonuçlarına göre ülkelerin %40'ında nedensellik mevcut değildir. Ülkelerin üçte birinde tek yönlü nedensellik söz konusuken, ülkelerin beşte birinde çift yönlü nedensellik mevcuttur. Motley (1998), çalışmasında 1960-1990 döneminde farklı ülkeler için ekonomik büyüme ve enflasyon arasındaki ilişkiyi araştırmıştır. Çalışma sonucunda enflasyonla ekonomik büyüme arasında negatif yönlü ilişki olduğu ifade edilmiştir. Burdekin vd. (2000), çalışmalarında 21 gelişmiş ülke ile 51 gelişmekte olan ülke ekonomisi için 1961-1992 döneminde enflasyonla ekonomik büyüme arasındaki ilişkiyi zaman serisi analizinden yararlanarak incelemişlerdir. Enflasyonun artış eğilimine girdiği dönemde ekonomik büyümenin yavaşladığı sonucuna varmışlardır. Aral (2015), 115 ülke ekonomisi için 1960-1995 döneminde enflasyonla ekonomik büyüme ilişkisini panel veri analizinden yararlanarak incelemişlerdir. Çalışmadan elde edilen sonuçlar enflasyonla ekonomik büyüme arasında negatif yönlü ilişkinin olduğunu göstermiştir. Chowdhury (2002), 1950-1997 döneminde Endonezya'da enflasyonla ekonomik büyüme ilişkisini onar yıllık ortalamalar ve serpilme diyagramlarından yararlanarak incelemiştir. Çalışmada elde edilen sonuçlar enflasyonla ekonomik büyüme arasında pozitif yönlü bir ilişkinin olduğunu göstermiştir. Karaca (2003), çalışmasında enflasyon ile ekonomik büyüme arasındaki ilişkiyi incelemiş ve çalışma sonucunda enflasyondan ekonomik büyümeye doğru negatif bir nedensellik olduğunu belirtmiştir. Enflasyon oranındaki 1 puanlık yükselmenin ekonomik büyümeyi %0.37 oranında azaltacağını ifade etmiştir. Terzi & Oltulular (2006), çalışmalarında GSYİH ile enflasyon oranı arasındaki ilişkiyi 1983-2001 döneminde Türkiye'deki yedi farklı bölge için incelemişlerdir.

Çalışmadan elde edilen bulgulara göre Marmara Bölgesi hariç olmak üzere diğer bölgelerde enflasyon ile ekonomik büyüme arasındaki ilişki negatiftir. Berentsen & Shi (2008), çalışmalarında enflasyonla ekonomik büyüme arasındaki ilişkiyi genel denge analizinden yararlanarak incelemişlerdir. Çalışma sonucunda enflasyonla ekonomik büyüme arasında pozitif yönlü ilişkinin olduğunu ifade etmişlerdir. Hussain & Malik (2011), çalışmalarında Pakistan için 1960-2006 döneminde enflasyonla ekonomik büyüme arasındaki ilişkiyi incelemişlerdir. Çalışmada eş bütünleşme testi ve hata düzeltme modelinden yararlanmışlardır. Çalışma sonuçlarına göre enflasyon oranı %9'un üzerinde seyrettiğinde ekonomik büyümeyi negatif yönlü olarak etkilemektedir. Karaçor vd. (2011), çalışmalarında Türkiye'de enflasyon ve ekonomik büyüme ilişkisini sınır testi yönteminden yararlanarak 1988-2007 dönemi için incelemişlerdir. Çalışma sonucunda TÜFE'ye göre hesaplanan enflasyon oranlarıyla ekonomik büyüme arasında kısa ve uzun dönemde negatif yönlü bir ilişkinin olduğu tespit edilmiştir. Emsen vd. (2012), çalışmalarında Türkiye'de 1968-2008 döneminde enflasyonla GSYİH ilişkisini ARDL Modeli Eş Bütünleşme Yaklaşımı'ndan yararlanarak analiz etmişlerdir. Enflasyonla GSYİH oranı arasında negatif yönlü bir ilişkinin olduğu sonucuna ulaşmışlardır. Akan & Kanca (2015), çalışmalarında Türkiye'de 1980-2013 döneminde büyüme ve enflasyon ilişkisini VAR yaklaşımından yararlanarak incelemişlerdir. Çalışma sonucunda ekonomik büyümeden enflasyona doğru tek yönlü bir nedensellik ilişkisinin olduğunu ifade etmişlerdir. Korkulu & Yılmaz (2017), Türkiye'de 1939-2013 döneminde enflasyonla ekonomik büyüme ilişkisini Granger nedensellik analizinden faydalanarak incelemişlerdir. Çalışma sonuçlarına göre enflasyonla ekonomik büyüme ilişkisi negatiftir. Topçu (2017), çalışmasında Türkiye'de 2006-2017 döneminde ekonomik büyümeyle enflasyon ilişkisini Johansen Koentegrasyon testi ve Granger Nedensellik analizi yöntemlerinden yararlanarak incelemiştir. Uzun dönemde enflasyonla ekonomik büyüme arasında bir nedensellik ilişkisinin bulunmadığı sonucuna varmıştır. Granger nedensellik testi sonucuna göre ise ekonomik büyümeden enflasyona doğru tek yönlü bir nedensellik söz konusudur. Karabulut (2019), çalışmasında Türkiye ekonomisinde 2003-2018 döneminde enflasyon ve ekonomik büyüme ilişkisini Granger nedensellik analizinden yararlanarak araştırmıştır. Çalışmada elde edilen bulgulara göre ekonomik büyümeden enflasyona doğru bir nedensellik söz konusu değildir. Çanakçı (2021), enflasyonun 1990'dan 2019'a kadar Türkiye ve ABD'de GSYİH büyümesini kısa vadede etkilediğini göstermiş ve bu doğrultuda bir tahmin modeli önermiştir. Kankpeyeng vd. (2021), 1986'dan 2018'e kadar Gana'da enflasyonun, kamu harcamalarının ve para arzının GSYİH büyümesi üzerindeki etkilerini vektör otoregresif (VAR) modeller kullanılarak analiz etmişler ve düşük enflasyon oranlarının GSYİH büyümesine pozitif katkıda bulunduğunu, yüksek enflasyon oranlarının ise GSYİH'yi negatif yönde etkilediğini ifade etmişlerdir. Tjandrasa (2022), çalışmasında ASEAN-4 ülkelerinde (Endonezya, Malezya, Filipinler ve Tayland) enflasyonun GSYİH büyümesi üzerinde önemli bir olumsuz etkiye sahip olduğunu ve enflasyon kontrol politikalarına olan ihtiyacı vurguladığını tespit etmiştir. Atabey & Karakuş (2022), Türkiye'de 2003-2021 döneminde enflasyon ve büyüme arasındaki ilişkiyi Toda-Yamamoto testini kullanarak araştırmıştır. Çalışma sonucunda enflasyondan büyümeye doğru bir nedensellik ilişkisinin mevcut olduğu tespit edilmiştir. Malec vd. (2024), çalışmalarında Etiyopya ekonomisi için 1991-2020 döneminde enflasyon ve ekonomik büyüme arasındaki ilişkiyi Granger nedensellik analizinden yararlanarak araştırmışlardır. Çalışma sonuçlarına göre enflasyondan büyümeye doğru bir nedensellik ilişkisi mevcuttur. Kumar vd. (2024), oklu doğrusal regresyon analizi, kovaryans testleri ve korelasyon testlerini kullanarak Hindistan'da 2013'ten 2023'e kadar GSYİH büyümesi ile enflasyon arasındaki ilişkiyi ele almışlardır. Çalışma sonucunda GSYİH büyümesiyle enflasyon arasında ilişkinin mevcut olduğunu tespit etmişlerdir. Pediz & Yenilmez (2025), çalışmalarında Türkiye'de enflasyon ve ekonomik büyüme ilişkisini

1990-2022 dönemi için VAR modelinden yararlanarak araştırmışlardır. Çalışmadan elde edilen sonuçlara göre fiyat istikrarı sürdürülebilir büyümenin oluşmasını pozitif yönde etkilemektedir. Martyniak vd. (2025), çalışmalarında 1999- 2022 dönemi için AB-27 ülkeleri ve Ukrayna'da enflasyonun GSYİH büyümesi üzerindeki etkisini incelemişlerdir ve AB'de pozitif doğrusal bir ilişkinin Ukrayna'da ise negatif doğrusal bir ilişkinin varlığını ortaya koymuşlardır.

GSYİH büyüme oranının, temel ekonomik göstergelerden biri olması ile politika ve strateji belirlemedeki önemli konumu, onun geleceğe yönelik tahminini de bir o kadar önemli kılmaktadır. Bu doğrultuda bu amaçla özellikle son yıllarda farklı birçok bilimsel çalışma ortaya konmuştur. Söyler & Kızılkaya (2015), çalışmalarında Türkiye'nin GSYİH tahmini için yapay sinir ağları model performanslarını karşılaştırmışlardır. Çalışma sonuçları yapay sinir ağlarının ekonomik büyüme tahmininde başarılı bir yöntem olduğunu göstermiştir. Erdoğan vd. (2018), çalışmalarında Türkiye'de 1965-2015 döneminde ekonomik büyümenin belirleyicilerini ARDL ve CCR yöntemleriyle tahmin etmişlerdir. Elde edilen bulgular Türkiye'de uzun dönemde ekonomik büyümenin tahmininde ARDL ve CCR yöntemlerinin güvenilirliğinin oldukça yüksek olduğunu göstermiştir. Geçgil & Akgül (2020), çalışmalarında Türkiye'nin GSYİH değerlerinin öngörüsünde yapay sinir ağları yönteminden yararlanmışlardır. Çalışma sonucunda GSYİH'nın gerçek değerleriyle tahmini değerleri birbirine çok yakın çıkmıştır. Buradan yapay sinir ağı modelinin tahmin gücünün oldukça yüksek olduğu tespit edilmiştir. Wu & He (2021), çalışmalarında geri yayılım öğrenme algoritmasına dayalı bir yapay sinir ağı (YSA) modeli ile Çin ekonomisini 1980-2020 dönemi için gözlemlemişlerdir. Çalışmalarında aynı zamanda GSYİH verilerini analiz ederek bir öngörü modeli geliştirmişlerdir. Şencan & Şahin (2022), çalışmalarında 2003-2020 döneminde Türkiye'nin ekonomik büyümesini tahmin etmek amacıyla ANFIS modelini kullanmışlardır. Çalışmada elde edilen bulgular ekonomik büyüme tahmininde modelin oldukça başarılı olduğunu göstermiştir. Kumari & Singh (2022), farklı makine öğrenmesi ve derin öğrenme modellerinin kullanıldığı çalışmalarında, Hindistan GSYİH büyüme oranlarını tahmin etmişlerdir. Božić (2022) rastgele orman ve çok katmanlı algılayıcı YSA dahil olmak üzere birden fazla makine öğrenmesi öngörü modeli ile Sırbistan'ın GSYİH'sini tahmin etmiş ve makine öğrenimi modellerinin genellikle geleneksel ekonometrik modellerden daha iyi performans gösterdiği sonucunu ortaya koymuştur. Abifarin vd. (2024), Nijerya'da GSYİH büyümesinin tahmininde enflasyon ve ham petrol fiyatlarının uzun vadeli etkilerini içeren bir öngörü modelinin kullanılabileceğini ortaya koymuşlardır. Almarashi vd. (2024), çalışmalarında Suudi Arabistan'ın GSYİH büyümesini tahmin etmek için stokastik doğrusal, doğrusal olmayan ve hibrit modelleri karşılaştırmışlardır. Çalışma sonucunda otoregresif YSA modelinin diğerlerinden daha iyi bir performansa sahip olduğunu tespit etmişlerdir. Ma (2024), çalışmada bir klasik zaman serisi öngörü modeli olarak ARIMA (0,2,0) modelinin Çin GSYİH tahmininde oldukça başarılı sonuçlar ürettiğini göstermiştir. Yu (2024), Çin'in Jilin ve Heilongjiang eyaletlerinde GSYİH'yi tahmin etmek için ARIMA ve SVR modellerinin bireysel kullanımının yanı sıra ARIMA-SVR hibrit modelini de önermiş ve hibrit modelin üstün öngörü performansları sergilediğini ortaya koymuştur.

3. Öngörü Metodolojisi

Makine öğrenmesi algoritmaları, karmaşık desenleri yakalama, büyük veri kümelerini işleme ve tahmin doğruluğunu iyileştirme yetenekleri sayesinde, girdi verilerinden sürekli değerleri öngörülmesi amaçlanan ve bir regresyon problemi olarak da görülebilecek zaman serisi öngörü problemlerinde önemli dikkate değer bir başarı göstermiştir. Makine öğrenmesi, sistemlerin otomatik olarak kalıpları tanımlamasına, karar vermeyi gerçekleştirmesine ve insan öğrenme sürecini yansıtarak yeni bilgilere uyum sağlamasına olanak tanır. Makine öğrenme

modelleri geçmiş verilerdeki tekrarlayan yapıları belirleyebilir ve gizli nedensel ilişkileri çıkarabilir, bu da onları zaman serisi verilerindeki eğilimleri öngörme konusunda değerli bir araç haline getirir (Ciaburro & Iannace, 2021). Bu çalışmada GSYİH büyüme oranları SVR, GPR, NNR ve CNNR gibi dört farklı makine öğrenmesi algoritması ile öngörülmüştür.

3.1. Destek Vektör Regresyonu

Destek Vektör Regresyonu (SVR) adından da anlaşılacağı gibi, regresyon görevleri için özel olarak tasarlanmış bir destek vektör makinesi çeşididir. Hem doğrusal hem de doğrusal olmayan regresyon problemlerindeki zorlukları ele almaya yarar. Hataları en aza indirmeye odaklanan geleneksel regresyon yöntemlerinden farklı olarak, SVR hataları önceden tanımlanmış bir eşik içinde kısıtlayarak çalışır. Bu, $\mathcal{E}$ -tüpü olarak adlandırılan belirli bir marj içinde optimum değere yaklaşmayı gerektirir. Doğrusal regresyon problemi için tahmin edilecek modeli temsil eden denklem aşağıdaki gibidir:

$$f(x) = x' \beta + b \quad (1)$$

Bu model, $f(x)$ 'in $\beta' \beta$ 'nin minimal norm değeri ile tahmin edilmesini gerektirir. Ayrıca, tüm artıkların $\mathcal{E}$ 'den daha düşük bir değere sahip olması kısıtlaması altında, Denklem (2)'de ifade edildiği gibi, sonraki fonksiyonu en aza indirmeyi amaçlayan bir dışbükey optimizasyon problemi oluşturur.

$$J\beta = 12 \beta' \beta \quad (2)$$

$$\forall i : y_i - x' \beta - b \leq \mathcal{E} \quad (3)$$

Bu kısıtlamaları tüm veri noktaları için tatmin edecek böyle bir $f(x)$ fonksiyonu mevcut olmayabilir. Bu durumda, uygulanabilir olmayan veya tatmin edilmeyen kısıtlamalarla başa çıkmak için, her veri noktası için gevşek değişkenler ξ_i ve ξ_i^* tanımlanır. Bu gevşek değişkenler, regresyon hatalarının ξ_i ve ξ_i^* değerine kadar var olmasına izin verir, ancak yine de gerekli koşulları tatmin eder. Gevşek değişkenleri dahil ederek, amaç fonksiyonu, Denklem (5)'te verilen kısıtlamalara tabi olarak Denklem (4)'te verildiği gibi verilebilir.

$$J(\beta) = \frac{1}{2} \beta' \beta + C \sum_{i=1}^n (\xi_i + \xi_i^*) \quad (4)$$

$$\forall i : y_i - x' \beta - b \leq \mathcal{E} + \xi_i$$

$$\forall i : x' \beta + b - y_i \leq \mathcal{E} + \xi_i^* \quad (5)$$

$$\forall i : \xi_i^* \geq 0$$

$$\forall i : \xi_i \geq 0$$

Bu bağlamda kutu kısıtlaması olarak bilinen parametre C , epsilon marjının ($\mathcal{E}$) ötesinde bulunan örneklerle uygulanan cezayı kontrol eden pozitif bir sayısal değerdir. Denklem (4) ve (5)'te özetlenen optimizasyon problemi, Denklem (6)'da belirtildiği gibi, *Lagrange-Çarpanlarını* içeren bir formülasyon kullanılarak çözülür.

$$\begin{aligned}
 L = & \frac{1}{2} \|\beta\|^2 + C \sum_{i=1}^n (\xi_i + \xi_i^*) \\
 & - \sum_{i=1}^n \alpha_i (\varepsilon + \xi_i - y_i + \langle \beta, x_i \rangle + b) - \sum_{i=1}^n \alpha_i^* (\varepsilon + \xi_i^* + y_i - \langle \beta, x_i \rangle - b) \\
 & - \sum_{i=1}^n (\eta_i \xi_i + \eta_i^* \xi_i^*)
 \end{aligned} \tag{6}$$

burada $\forall i : \alpha_i, \alpha_i^*, \eta_i, \eta_i^* \geq 0$. Ayrıca, optimal koşullar altında, L 'nin bu değişkenlere göre kısmi türevleri ($\forall i : \alpha_i, \alpha_i^*, \eta_i, \eta_i^*$) sıfıra eşittir. Dolayısıyla, Denklem (7)'de, $f(x)$ formülasyonu daha genelleştirilmiş bir biçimde aşağıdaki gibi yeniden ifade edilebilir:

$$f(x) = \sum_{i=1}^n (\alpha_i - \alpha_i^*) k(x_i, x) + b \tag{7}$$

Burada, çekirdek fonksiyonu $k(x_i, x)$ seçimi modelin doğrusal ya da doğrusal olmayan yapıda olmasını belirleyen unsurdur. Aşağıda yaygın olarak kullanılan üç çekirdek fonksiyonu verilmiştir.

İsim	Kernel Fonksiyon Yapısı	Tipi
Lineer (Linear)	$k(x_i, x) = x_i' x_k$	Doğrusal
Gauss (Gaussian)	$k(x_i, x) = \exp(-\ x_i - x_k\ ^2)$	Doğrusal Olmayan
Polinom (Polynomial)	$k(x_i, x) = (1 + x_i' x_k)^q, q \in \{2, 3, \dots\}$ polinom derecesi	Doğrusal Olmayan

3.2. Gauss Süreci Regresyonu

Gauss Süreci Regresyonu, genellikle regresyon problemlerinde kullanılan sağlam bir makine öğrenme algoritmasıdır. GPR, parametrik olmayan bir Bayes yaklaşımına dayalı olması özelliği ile girdi değişkenleri ve çıktı hedefleri arasındaki önceden tanımlanmış parametrelili ilişkilere dayanan geleneksel regresyon yöntemlerinden ayrışır. GPR, girdiler ve çıktılar arasındaki ilişkiyi açıklayabilecek potansiyel fonksiyonların tüm dağılımlarının modellenmesini içerir. Bir fonksiyon içindeki her parametre için kesin değerler arayan MÖ algoritmalarının aksine, GPR, bayes yaklaşımına dayalı olarak, tüm olası değerler üzerinden bir olasılık dağılımı türetir (Rasmussen & Williams, 2005).

$x_i \in \mathbb{R}^d$ ve $y_i \in \mathbb{R}$ bilinmeyen bir dağılımdan çekilmiş olmak üzere, bağımsız ve bağımlı değişkenlerin veri kümesi $\{(x_i, y_i) ; i = \overline{1, n}\}$ ile gösterilsin. Bir GPR modeli, girdi vektö x 'e dayalı olarak bir yanıt değişkeni y 'nin değerini tahmin etmek için tasarlanmıştır. Geleneksel bir doğrusal regresyon modeli aşağıdaki gibi verilir:

$$y = x^T \beta + \varepsilon \quad (8)$$

Burada $\varepsilon \sim \text{Normal}(0, \sigma^2)$. Ayrıca, σ^2 hata varyansını ve β model katsayılarının vektörünü temsil eder ve her ikisi de verilerden tahmin edilir. Bir GPR modeli, *Gauss Süreci* (GP) ve açık *baz fonksiyonları* (*basis functions*) h kullanarak, $f(x_i), i = \overline{1, n}$ olarak gösterilen gizli değişkenler oluşturur ve yanıtı değişkenini açıklar (tahminler). Baz fonksiyonları, girdiler olan x 'i p -boyutlu bir özellik uzayına eşler. Ek olarak, gizli değişkenler (*latent variable*) için oluşturulan kovaryans fonksiyonu, yanıtın desenlerini yakalamak için kullanılır. Bir *Gauss Süreci*, ortak bir Gauss dağılımına sahip sonlu sayıda rastgele değişken kümesinden oluşur. Bu bağlamda, eğer $\{f(x) ; x \in \mathbb{R}^d\}$ bir *Gauss Süreci*'ni temsil ediyorsa, o halde n gözlem $x_1, x_2, \dots, x_n$ verildiğinde, rastgele değişkenler $f(x_1), f(x_2), \dots, f(x_n)$ 'nin ortak dağılımı bir *Gauss Dağılımı* olacaktır. Bir *Gauss Süreci* iki parametre ile karakterize edilir: $m(x)$, ortalama fonksiyon ve $k(x, x')$, kovaryans fonksiyonu. Başka bir deyişle, eğer $\{f(x) ; x \in \mathbb{R}^d\}$ bir *Gauss Süreci* ise;

$$E(f(x)) = m(x) \quad (9)$$

$$\text{Cov}[f(x), f(x')] = E[\{f(x) - m(x)\}\{f(x') - m(x')\}] = k(x, x') \quad (10)$$

Bir GPR modelinin gösterimi Denklem (11)'deki gibi verilebilir.

$$y = h(x^T)\beta + f(x) + \varepsilon \quad (11)$$

Burada $f(x) \sim GP(0, k(x, x'))$. Basitçe, $f(x)$, sıfır ortalama ve kovaryans fonksiyonu $k(x, x')$ olan bir *Gauss Süreci*'den bir örnekleme temsil eder. Ayrıca, $h(x)$ orijinal d -boyutlu bağımsız değişkenler vektörü x 'i p -boyutlu yeni bir bağımsız değişkenler vektörüne dönüştüren bir dizi temel fonksiyonu temsil eder. Dahası, β , temel fonksiyonlar için $p \times 1$ -boyutlu katsayı vektörünü temsil eder. Bu senaryoda, yanıt değişkeni y 'nin her örneği, Denklem (12)'de açıklandığı gibi modellenir.

$$P(y_i | f(x_i), x_i) \sim \text{Normal}(y_i | h(x_i)^T \beta + f(x_i), \sigma^2) \quad (12)$$

Her gözlem x_i için tanımlanan gizli değişkenlerin $f(x_i)$ varlığı GPR modelini parametrik olmayan hale getirir. Bu model, Denklem (13)'de verildiği gibi vektör formunda ifade edilir.

$$P(y|f,X) \sim \text{Normal}(y|H\beta + f, \sigma^2 I) \quad (13)$$

$$X = \begin{pmatrix} x_1^T \\ x_2^T \\ \vdots \\ x_n^T \end{pmatrix}; y = \begin{pmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{pmatrix}; H = \begin{pmatrix} h(x_1^T) \\ h(x_2^T) \\ \vdots \\ h(x_n^T) \end{pmatrix}; f = \begin{pmatrix} f(x_1) \\ f(x_2) \\ \vdots \\ f(x_n) \end{pmatrix} \quad (14)$$

GPR modelinde gizli değişkenler $f(x_1), f(x_2), \dots, f(x_n)$ için ortak dağılım Denklem (15)'de verilmektedir.

$$P(f|X) \sim \text{Normal}(f|0 + K(X,X)) \quad (15)$$


Burada $K(X,X)$;

$$K(X,X) = \begin{pmatrix} k(x_1, x_1) & k(x_1, x_2) & \dots & k(x_1, x_n) \\ k(x_2, x_1) & k(x_2, x_2) & \dots & k(x_2, x_n) \\ \vdots & \vdots & \dots & \vdots \\ k(x_n, x_1) & k(x_n, x_2) & \dots & k(x_n, x_n) \end{pmatrix} \quad (16)$$

3.3. Sinir Ağı Regresyonu

Modern anlamda, ilk olarak Werbos (1974) tarafından doğrusal olmayan problemleri ele almak için önerilen ve daha sonra Rumelhart vd. (1986) tarafından geliştirilen Çok Katmanlı Algılayıcı Sinir Ağları, zaman serisi öngörü problemlerini de kapsayacak şekilde, regresyon problemleri üzerine geniş bir bilimsel literature sahiptir. NNR'da, girdi sinyalleri ağı beslenir ve daha sonra bu bilgiler bir çıktı tahmini üretmek için birden fazla sinir hücresi katmanı aracılığıyla işlenir. Eğitim sırasında ağ, sinir hücreleri arasındaki bağlantıların ağırlıklarını ve yan değerlerini ayarlayarak girdi veri seti özelliklerini çıktı hedefleriyle ilişkilendirerek ilişkiler örüntüsünü öğrenir. Bir girdi katmanı, iki gizli katman ve bir çıktı katmanına sahip bir prototip sinir ağının mimari yapısı Şekil 1'de verilmiştir.

Şekil 1: Bir Sinir Ağı Regresyonu Mimari Yapısı Prototipi




Burada, P girdi vektörünü temsil eder. Ayrıca, girdi sayısı sayısı R 'dir. $IW^{1,1}$, kaynağı 1 (ikinci indeks -girdi katmanından-) ve hedefi 1 (birinci indeks -birinci gizli katmana-) olan Girdi Ağırlık matrisidir ve b^1 , birinci gizli katman için bir yan değerler vektörüdür. Birinci gizli katmandaki nöron sayısı S^1 'dir. a^1 , birinci gizli katman için çıktı vektörüdür ve aynı zamanda ikinci gizli katman için girdi vektörüdür. Birinci gizli katmandaki her sinir hücresi için yanlara sabit bir girdi değeri, 11, beslenir. $LW^{2,1}$, kaynağı 1 (ikinci indeks -birinci gizli katmandan-) ve hedefi 2 (birinci indeks -ikinci gizli katmana-) olan Gizli Katman Ağırlık matrisidir ve b^2 , ikinci gizli katman için bir yan değerler vektörüdür. İkinci gizli katmandaki nöron sayısı S^2 'dir. Ayrıca, $LW^{3,2}$, kaynağı 2 (ikinci indeks -ikinci gizli katmandan-) ve hedefi 3 (ilk indeks -çıkı katmanına-) olan Katman Ağırlık matrisidir ve b^3 , çıktı katmanı için bir yan vektörüdür. Çıkı katmanındaki sinir hücresi sayısı S^3 'tür. Bu çalışmada çıktı katmanındaki sinir hücresi sayısı olan S^3 , 1 olarak alınmıştır.

3.4. Basamaklı Sinir Ağı Regresyonu

Basamaklı sinir ağı, çok katmanlı ileri beslemeli sinir ağının bir türüdür. Demuth, Fahlman ve Fahlman & Lebiere tarafından önerilen basamaklı korelasyon yaklaşımlarına dayalı olarak basamaklı sinir ağını önermektedir. CNNR'nin mimarisi, diğer geleneksel ileri beslemeli çok katmanlı sinir ağları gibi, *girdi*, *çıkı* ve *gizli* katman(lar)dan oluşmasına rağmen, bazı ayırt edici yönler ile geleneksel sinir ağlarından ayrılmaktadır. CNNR'nin temel ayırt edici özelliği, her katmandaki sinir hücrelerinin önceki tüm katmanların sinir hücrelerine bağlı olmasıdır. CNNR'yi diğerler sinir ağlarından ayıran ve üstün kılan bir diğer özellik ise, gizli katmanda kullandığı sigmoid aktivasyon fonksiyonu (doğrusal olmayan yapıda) ve çıkı katmanında kullandığı doğrusal aktivasyon fonksiyonu sayesinde, girdiler ve çıkıtlar arasındaki doğrusal ve doğrusal olmayan ilişkileri birlikte ve eş zamanlı olarak modelleyebilmesidir. İki gizli katmana sahip varsayımsal bir CNNR mimarisi Şekil 2'de gösterilmiştir.

Şekil 2: Varsayımsal Bir Basamaklı Sinir Ağı Regresyonu Mimari Yapısı




4. Uygulama Özellikleri

GSYİH büyüme oranlarının, ülke ekonomilerinin temel göstergelerinden biri olması dolayısıyla, doğru öngörülmesi geleceğe yönelik sosyal, politik ve ekonomik projeksiyonların belirlenmesi açısından oldukça önemlidir. Bu çalışmada, 2005 birinci çeyrek ile 2024 üçüncü çeyrek arasında çeyreklik (üç ayda bir) gözlenmiş Türkiye GSYİH büyüme oranları, aynı dönemde gözlenmiş Tüketici Fiyat Endeksi değişim oranları kullanılarak, hiper-parametreleri bir geçerlilik seti aracılığı ile ayarlanan/optimize edilen 4 farklı MÖ algoritması aracılığıyla modellenmiştir.


4.1. Veri Organizasyonu

Çözümlemelerde, açıklayıcı değişken olarak, Tüketici Fiyat Endeksinin “bir önceki aya göre değişim” oranlarının üçer aylık (biri çeyreklik) periyotlardaki gecikmeli değerlerinin yanı sıra GSYİH büyüme oranları gecikmeli değerleri kullanılmıştır. Böylece birinci ya da yüksek dereceli öngörü modelleri oluşturulması amaçlanmıştır. İlgili döneme ilişkin Tüketici Fiyat Endeksi Aylık Değişimi ve GSYİH çeyreklik büyüme oranları grafikleri sırasıyla Şekil 3 ve Şekil 4 ile verilmiştir.

Şekil 3: Tüketici Fiyat Endeksi Aylık Değişimi



Şekil 4: GSYİH Büyüme Oranları



Öngörü modelleri 4 farklı senaryo üzerinden kurgulanmıştır. Özellikle 2021 yılı sonu ile başlayan yüksek enflasyon öngörülebilirliği oldukça zorlaştırmaktadır. Bu nedenle kısa dönemli, yalnızca gelecek iki çeyreklik dönemin öngörülmesini amaçlayan dört farklı senaryo içerisinde çözümlemeler gerçekleştirilmiştir. Bu amaçla oluşturulan senaryoların özellikleri Tablo 1 ile verilmiştir.

Tablo 1: Öngörü Senaryoları

Senaryo		Eğitim	Geçerlilik		Test	
No	Periyodu	Nokta Sayısı	Periyodu	Nokta Sayısı	Periyodu	Nokta Sayısı
1	2006 1. Çeyrek 2021 14. Çeyrek	64	2022 1. Çeyrek 2022 2. Çeyrek	2	2022 3. Çeyrek 2023 4. Çeyrek	2
2	2006 1. Çeyrek 2022 2. Çeyrek	66	2022 3. Çeyrek 2022 4. Çeyrek	2	2023 1. Çeyrek 2023 2. Çeyrek	2
3	2006 1. Çeyrek 2022 3. Çeyrek	68	2023 1. Çeyrek 2023 2. Çeyrek	2	2023 3. Çeyrek 2023 4. Çeyrek	2
3	2006 1. Çeyrek 2024 2. Çeyrek	70	2023 3. Çeyrek 2023 4. Çeyrek	2	2024 1. Çeyrek 2024 2. Çeyrek	2

4.2. Öngörü Modeli Fonksiyonel Yapıları

Modellerin fonksiyonel yapısını oluşturan GB_q , q inci çeyreğe ilişkin *Gayri Safi Yurtiçi Hasıla Büyüme Oranı*, GB_{q-1} , $q-1$ inci çeyreğe ilişkin *Gayri Safi Yurtiçi Hasıla Büyüme Oranı*, $E_{1,q-1}$, $E_{2,q-1}$ ve $E_{3,q-1}$, $q-1$ inci çeyreğe ilişkin her bir ayda gözlenmiş *Tüketici Fiyat Endeksi Aylık Değişim Oranları*dır. $f(.)$ ise öngörü modelinin fonksiyonel yapısını temsil etmektedir. Kullanılan MÖ algoritmaları gerçekte bilinmeyen ve girdiler ile çıktı arasındaki ilişkiyi temsil eden $f(.)$, öngörü modelinin fonksiyonel yapısını tahmin ederek bu tahmin edilmiş $\hat{f}(.)$ fonksiyonel yapısını kullanarak öngörüler üretirler. Oluşturulan öngörü modellerinin genel özellikleri Tablo 2 ile özetlenmiştir.

Tablo 2: Öngörü Modelleri

Model		
No	Derecesi	Fonksiyonel Yapısı
1	1'inci	$GB_q = f(E_{1,q-1}, E_{2,q-1}, E_{3,q-1}, GB_{q-1}) + \varepsilon_q$
2	2'inci	$GB_q = f\left(E_{1,q-1}, E_{2,q-1}, E_{3,q-1}, GB_{q-1}, E_{1,q-2}, E_{2,q-2}, E_{3,q-2}, GB_{q-2}\right) + \varepsilon_q$

Tablo 2. devam

3	3'üncü	$GB_q = f \begin{pmatrix} E_{1,q-1}, E_{2,q-1}, E_{3,q-1}, GB_{q-1}, \\ E_{1,q-2}, E_{2,q-2}, E_{3,q-2}, GB_{q-2}, \\ E_{1,q-3}, E_{2,q-3}, E_{3,q-3}, GB_{q-3}, \end{pmatrix} + \varepsilon_q$
3	4'üncü	$GB_q = f \begin{pmatrix} E_{1,q-1}, E_{2,q-1}, E_{3,q-1}, GB_{q-1}, \\ E_{1,q-2}, E_{2,q-2}, E_{3,q-2}, GB_{q-2}, \\ E_{1,q-3}, E_{2,q-3}, E_{3,q-3}, GB_{q-3}, \\ E_{1,q-4}, E_{2,q-4}, E_{3,q-4}, GB_{q-4}, \end{pmatrix} + \varepsilon_q$

4.3. Hiper-Parametre (Üst-Parametre) Ayarlama Süreci

4 farklı MÖ algoritması için de bazı üst-parametreler modellerin performansı üzerinde etkin birer rol oynarlar. Bu bakımdan, her bir MÖ algoritma için sırasıyla Tablo 3-6 ile verilen, bazı üst-parametreler geçerlilik kümesi gözlemlerindeki performansı en üst düzeye çıkaracak şekilde ayarlanmış, bir başka ifade ile optimize edilmiştir. Her bir algoritma mevcut üst-parametreleri ilgili kombinasyonlarının yanı sıra farklı öngörü model fonksiyon yapılarını da içerecek sayıda çözümleme gerçekleştirmektedir. Geçerlilik kümesi üzerinde en iyi öngörü performansının elde edildiği üst-parametre ve model fonksiyonel yapı kombinasyonları, test kümesi gözlemlerinin öngörülmesinde kullanılmıştır.

Tablo 3: GPR Üst-Parametreleri ve Kombinasyonları (toplam $4 \times 5 \times 4 \times 8 \times 2 = 1280$ adet)

Üst-Parametre	Ayarlama İzgarası
<u>Temel Fonksiyon (Basis Function)</u> , eğer n gözlem sayısı ise, modele $H\beta$ terimini ekler; burada H temel matris ve β temel katsayıların $p \times 1$ boyutlu vektörüdür.	'none' $\Rightarrow H = \text{Boş Matris}$ 'constant' $\Rightarrow H = I_{(n \times 1)}$ 'linear' $\Rightarrow H = [1 \ X]$ 'pureQuadratic' $\Rightarrow H = [1 \ X \ X \times X]$
<u>Uygunluk Yöntemi (Fit Method)</u> , GPR modelinin parametrelerini tahmin etme yöntemi	'none' $\Rightarrow$ Tahmin yok 'exact' $\Rightarrow$ Tam Gauss süreci regresyonu 'sd' $\Rightarrow$ Veri noktalarının alt kümesi yaklaşımı 'sr' $\Rightarrow$ Regresörlerin alt kümesi yaklaşımı 'fic' $\Rightarrow$ Tamamen bağımsız koşullu yaklaşım
<u>Tahmin Yöntemi (Predict Method)</u> , erilen parametrelere göre bir Gauss süreç modelinden tahminler yapmak için kullanılan yöntem	'exact' $\Rightarrow$ Tam Gauss süreci regresyonu 'sd' $\Rightarrow$ Veri noktalarının alt kümesi yaklaşımı 'sr' $\Rightarrow$ Regresörlerin alt kümesi yaklaşımı 'fic' $\Rightarrow$ Tamamen bağımsız koşullu yaklaşım

Tablo 3. devam

<i>Kernel Function</i> , Form of the covariance function.	'exponential' ⇒ Üstel çekirdek (kernel) 'squaredexponential' ⇒ Karesel üstel çekirdek 'matern32' ⇒ Parametre 5/2 ile ana çekirdek 'matern52' ⇒ Parametre 5/2 ile ana çekirdek 'ardexponential' ⇒ Tahminci başına ayrı bir uzunluk ölçeğine sahip üstel çekirdek 'ardsquaredexponential' ⇒ Tahminci başına ayrı bir uzunluk ölçeğine sahip karesel üstel çekirdek 'ardmatern32' ⇒ Parametresi 3/2 ve tahminci başına ayrı bir uzunluk ölçeği olan ana çekirdek 'ardmatern52' ⇒ Parametresi 5/2 ve tahminci başına ayrı bir uzunluk ölçeği olan ana çekirdek
<i>Standardizasyon (Standardize)</i> , Verileri standardize etmek için gösterge.	'true' ⇒ <i>T</i> Yazılım,tahmin verilerinin her sütununu sırasıyla sütun ortalamasına ve standart sapmaya göre ortalar ve ölçekler, 'false' ⇒ Yazılım verileri standartlaştırmaz

Tablo 4: SVR Üst-Parametreleri ve Kombinasyonları (toplam $3 \times 41 \times 2 = 246$ adet)

Üst-Parametre	Ayarlama Izgarası
<i>Çekirdek Fonksiyonu (Kernel Function)</i> , Gram matrisini hesaplamak için kullanılır.	'gaussian' ⇒ Gauss veya Radyal Taban Fonksiyonu çekirdeği (kernel) $G(x_j, x_k) = \exp(-\ x_j - x_k\ ^2)$ 'linear' ⇒ Doğrusal çekirdek (kernel) $G(x_j, x_k) = x_j' x_k$ 'polynomial' ⇒ Polinom çekirdek (kernel) $G(x_j, x_k) = (1 + x_j' x_k)^q$
<i>Çekirdek Ölçeği (Kernel Scale)</i> , virgülle ayrılmış çift olarak belirtilir.	'linspace(1,5,41)' ⇒ {1.0,1.1,1.2, ...,5.0}
<i>Standardizasyon (Standardize)</i> , Verileri standardize etmek için gösterge.	'true' ⇒ Yazılım,tahmin verilerinin her sütununu sırasıyla sütun ortalamasına ve standart sapmaya göre ortalar ve ölçekler, 'false' ⇒ Yazılım verileri standartlaştırmaz

Tablo 5: NNR Üst-Parametreleri ve Kombinasyonları (toplam $6 \times 4 \times 11 \times 2 = 528$ adet)

Üst-Parametre	Ayarlama İzgarası
<u>Katman Boyutları (Layer Sizes)</u> , Sinir ağı modelindeki tam bağlı katmanların boyutları, pozitif tam sayı vektörü olarak belirtilir	'LayerSizes' $\Rightarrow \{10, 25, 50, 100, [10\ 10], [25\ 25]\}$
<u>Aktivasyon Fonksiyonu (Activation Function)</u> , Sinir ağı modelinin tam bağlı katmanları için kullanılır	'relu' $\Rightarrow$ Düzeltmeli doğrusal ünite (Rectified linear unit- ReLU) fonksiyonu $f(x) = \begin{cases} x & ; x \geq 0 \\ 0 & ; x < 0 \end{cases}$ 'tanh' $\Rightarrow$ Hiperbolik tanjant (Hyperbolic tangent-tanh) fonksiyonu $f(x) = \tanh(x)$ 'sigmoid' $\Rightarrow$ Lojistik (Sigmoid)fonksiyon $f(x) = 1 / 1 + e^{-x}$ 'none' $\Rightarrow$ Kimlik/Doğrusal (Identity) fonksiyonu $f(x) = x$
<u>Lambda</u> , Düzenleme terimi gücü, negatif olmayan bir skaler olarak belirtilir. Yazılım, hata kareler ortalaması (MSE) kayıp fonksiyonundan ve sırt (L2) ceza teriminden en aza indirme için hedef fonksiyonunu oluşturur.	'linspace(0,5,11)' $\Rightarrow \{0,0.5,1.0,1.5, \dots ,5.0\}$
<u>Standardizasyon (Standardize)</u> , Verileri standardize etmek için gösterge.	'true' $\Rightarrow$ Yazılım,tahmin verilerinin her sütununu sırasıyla sütun ortalamasına ve standart sapmaya göre ortalar ve ölçekler, 'false' $\Rightarrow$ Yazılım verileri standartlaştırmaz a

Tablo 6: CNNR Üst-Parametreleri ve Kombinasyonları (toplam $6 \times 12 = 72$ adet)

Üst-Parametre	Ayarlama İzgarası A
<u>Katman Boyutları (Layer Sizes)</u> , Sinir ağı modelindeki tam bağlı katmanların boyutları, pozitif tam sayı vektörü olarak belirtilir	'LayerSizes' $\Rightarrow \{10, 25, 50, 100, [10\ 10], [25\ 25]\}$

Tablo 6. devam

<u>Eğitim Algoritması</u> (<u>Learning Algorithim</u>), Sinir ağı modelinin optimum parametrelerinin elde edilmesinde kullanılır	'trainlm' ⇒ Levenberg-Marquardt eğitim algoritması (Quasi-Newton tabanlı) eğitim algoritması 'trainbr' ⇒ Bayes Düzeltmeli Levenberg-Marquardt eğitim algoritması 'trainbfg' ⇒ Broyden-Fletcher-Goldfarb-Shanno eğitim algoritması 'trainrp' ⇒ Resilient Backpropagation eğitim algoritması 'trainscg' ⇒ Ölçeklenmiş konjüge gradyan eğitim algoritması 'traincgb' ⇒ Powell-Beale yeniden başlatmalı konjüge gradyan eğitim algoritması 'traincgf' ⇒ Fletcher-Reeves konjüge gradyan eğitim algoritması 'traincgp' ⇒ Polak-Ribière konjüge gradyan eğitim algoritması 'trainoss' ⇒ One-Step (Tek Adımlı) Secant eğitim algoritması 'traingdx' ⇒ momentum katsayılı uyarlanabilir öğrenme oranına dayalı algoritma 'traingdm' ⇒ momentum katsayılı gradyan inişine dayalı eğitim algoritması 'traingd' ⇒ klasik gradyan inişine dayalı eğitim algoritması
--	---

4.4. Değerlendirme Metrikleri

MÖ algoritmalarının üst-parametrelerinin ayarlanması sürecinde, Denklem (17) ile verilen, Hata Kareler Ortalaması Karekök (HKOK) hata ölçütü kullanılırken, algoritmaların test kümesi performanslarının değerlendirilmesinde ise HKOK metriğinin yanı sıra, Denklem (18) ile verilen, Ortalama Mutlak Yüzdelik Hata (OMYH) oransal hata metriği kullanılmıştır.

$$HKOK = \text{karekök}(\text{ortalama}((Hedef_q - Çıktı_q)^2)) \quad (17)$$

$$OMYH = \text{ortalama} \left| \frac{Hedef_q - Çıktı_q}{Hedef_q} \right| \quad (18)$$

5. Uygulama Sonuçları

Tüketici Fiyat Endeksinin “bir önceki aya göre değişim” oranlarının üçer aylık (birer çeyreklik) periyotlardaki gecikmeli değerlerinin yanı sıra GSYİH büyüme oranları gecikmeli değerlerinin açıklayıcı değişkenler olarak kullanıldığı dört MÖ algoritmasının her bir senaryoda test kümesi üzerindeki öngörü performanslarının yanı sıra ortalama performansları Tablo 7 ile özetlenmiştir.

Tablo 7: Öngörü performansları - HKOK

Senaryo	GPR		SVR		NNR		CNNR	
No	HKOK	Sıra	HKOK	Sıra	HKOK	Sıra	HKOK	Sıra
1	1.0861	3	1.9119	4	0.3839	2	0.1682	1
2	0.6289	4	0.4043	3	0.2795	2	0.2521	1
3	1.7582	3	1.5496	2	1.7739	4	0.9413	1
4	2.3718	4	2.2566	3	0.2926	1	0.4715	2
Genel	1.6040	4	1.6817	3	0.9298	2	0.5478	1

Tablo 7 incelendiğinde, Senaryo 1, 2. ve 3 için en iyi öngörü performansları, sırasıyla 0.1682, 0.2521 ve 0.9413 HKOK değerli öngörüler ile CNNR tarafından sergilenmiştir. Senaryo 4 için ise en üstün performans, 0.2926 HKOK değerli öngörüler ile NNR tarafından ortaya konmuştur. Tüm senaryolar birlikte ele alındığında, 4 senaryodaki test kümelerini oluşturan toplam 8 gözlemin öngörülmesinde yine CNNR, 0.5478 HKOK değerli öngörüler üreterek, en üstün performansa sahip olmuştur. Her bir senaryoda dört MÖ algoritmasının performansının göreceli hata metriği olan OMYH bakımından özeti ise Tablo 8 ile verilmiştir.

Tablo 8: Öngörü performansları – OMYH (%)

Senaryo	GPR		SVR		NNR		CNNR	
No	OMYH (%)	Sıra	OMYH (%)	Sıra	OMYH (%)	Sıra	OMYH (%)	Sıra
1	7.93	3	13.15	4	2.80	2	1.26	1
2	3.87	4	2.48	3	1.81	2	1.60	1
3	4.58	3	4.02	2	6.11	4	3.20	1
4	14.89	4	9.83	3	2.11	1	3.67	2
Genel	7.82	4	7.37	3	3.21	2	2.43	1

Tablo 8, hataların gerçek gözlem değerleri içindeki payını gösteren bir hata metriği olan OMYH değerleri ile dört farklı MÖ algoritmasının öngörü performanslarının bireysel değerlendirilmesine olanak sağlar.

✓ GPR;

- Birinci ve üçüncü senaryolarda, sırasıyla 7.93% ve 4.58% oransal hatalar ile en iyi üçüncü öngörü performansına sahiptir
- İkinci ve dördüncü senaryolarda, sırasıyla 3.87% ve 14.89% oransal hatalara sahip öngörüler ile bu 4 MÖ algoritması arasında, en kötü öngörü performansı sergilemiştir.
- 4 senaryo birlikte değerlendirildiğinde ise ortalamada, 7.82% OMYH değerine sahip öngörüler ile yine en kötü performansı sergilemiştir.

✓ *SVR*;

- Dördüncü senaryoda, 4.02% oransal hatalı öngörüler ile en iyi ikinci performansı sergilemiştir.
- İkinci ve dördüncü senaryoda, sırasıyla 2.58% ve 9.83% OMHY değerli öngörüler ile üçüncü en iyi öngörü performansına sahiptir.
- Birinci senaryoda ise, 13.15% oransal hatalara sahip öngörüler ile bu 4 MÖ algoritması arasında, en kötü öngörü performansa sahiptir.
- 4 senaryo birlikte değerlendirildiğinde ise ortalamada, 7.37% OMYH değerli en kötü öngörülerini üretmiştir.


✓ *NNR*;

- Üçüncü senaryoda, 2.11% OMHY değeri ile ürettiği öngörüler ile en üstün performansa sahiptir.
- Birinci ve ikinci senaryolarda, sırasıyla 2.80% ve 1.81% oransal hatalara sahip, ikinci en iyi öngörülerini üretmiştir.
- Üçüncü senaryoda ise, OMYH değeri 6.11% olan öngörüler ile dört MÖ arasında, en kötü öngörü performansını sergilemiştir.
- 4 senaryo birlikte değerlendirildiğinde ise ortalamada, 3.21% oransal hataya sahip öngörüler ile ikinci en üstün performansa sahiptir.


✓ *CNNR*;

- Birinci, ikinci ve üçüncü senaryolarda, sırasıyla 1.26%, 1.60% ve 3.20% OMHY değerleri ile ürettiği öngörüler ile en üstün performanslarını sergilemiştir.
- Dördüncü senaryoda ise, 3.67% oransal hatalara sahip, ikinci en iyi öngörülerini üretmiştir.
- 4 senaryo birlikte değerlendirildiğinde ise ortalamada, 2.43% oransal hataya sahip öngörüler ile yine en üstün performansa sahiptir.


Her bir MÖ algoritmasının öngörü performansları, gözlenmiş GSYİH değerleri ile tahminlerini içeren birlikte sunan Şekil 5. Tarafından görselleştirilmiştir. Şekil 5 incelendiğinde, her bir MÖ algoritmasının GSYİH öngörüsü amacıyla, *Tüketici Fiyat Endeksi Değişim Oranları* ve *Gayri Safı Yurtiçi Hasılaya* ilişkin gecikmeli zaman serilerinin açıklayıcı değişkenler olarak kullanıldığı modellerde, gözlem değerleri ile uyumlu öngörüler ürettiği söylenebilmekle beraber, *NNR* ve *CNNR* algoritmalarının *GPR* ve *SVR* ye göre gözlem değerleri ile daha yüksek uyuma sahip öngörüler ürettiği açıkça gözlenmektedir. *CNNR*'nin ise *NNR* ye göre gözlem değerleri ile daha uyumlu, yani en üstün öngörü performansını işaret eden, öngörüler verdiği söylenir.

Şekil 5: Öngörülerin Gözlemler ile Uyumunu


a) GPR sonuçları



b) SVR sonuçları



c) NNR sonuçları



d) CNNR sonuçları

Hem HKOK ve OMYH gibi iki hata metriği hem de algoritmaların ürettiği öngörülerin gerçekleşen gözlem değerleri ile uyumunun görsel sunumu dikkate alındığında 4 farklı senaryonun bütününi oluşturan sekiz dönem için GSYİH öngörüsünde en üstün performansın *CNNR* tarafından ortaya konduğu gözlenmiştir. Bu doğrultuda, *CNNR* tarafından üretilen öngörülerin gözlenen değerler ile uyumu bir ileri seviyede incelenmiştir. Bu inceleme kapsamında *CNNR* tarafından üretilen öngörülerin *açıklayıcı (bağımsız)* değişken ve gözlenen GSYİH değişim oranlarının *yanıt (bağımlı)* değişken olduğu ve Denklem (19) ile matematiksel modeli verilen bir *basit doğrusal regresyon modeli (B-DRM)* kurulmuştur. Buradaki temel beklenti, modele ilişkin regresyon (β) ve belirleme (R^2) katsayılarının 1'e yakın bir değere sahip olmasıdır. Katsayıların 1 değerini alması, modelin öngörülerini ile gerçek değerler arasında *mükemmel (tam)* bir uyum olduğunu gösterir. Ayrıca, regresyon katsayısının güven aralığının 1 değerini içermesi, bu katsayının 95% olasılıkla değerini alabileceğini gösterir. *CNNR* algoritmasının öngörülerini ile gerçek gözlemler arasında üretilen *B-DRM* parametrelerine ilişkin bilgiler Tablo 9'da özetlenmiştir.


$$Y_t = \beta \hat{Y}_t + \varepsilon_t, \quad t = 1, 2, \dots, T \quad (19)$$

Tablo 9: B-DRM sonuçları

$Y = \hat{\beta} \hat{Y}_t$	Test istatistiği	p-Değeri	β için 95% Güven Aralığı		$R^2\%$
			Alt Sınır	Üst Sınır	
$Y = 0.985418 \hat{Y}_t$	81.7225	1.0814E-11	0.956905	1.013930	99.8953

Tablo 9'dan, CNNR algoritmasının öngörülleri ile gerçek gözlemler arasında üretilen B-DRM için regresyon ($\hat{\beta} = 0.985418$) ve belirleme ($R^2 = 0.998953$) katsayılarının neredeyse 1 olduğu açıkça görülmektedir. Ek olarak, β için 95% güven aralığı 1'i içerir. Bu, üretilen tahminlerin gerçek gözlemlenen değerlerle yakından eşleştiğini gösterir. Başka bir deyişle, CNNR algoritmasının mükemmel yakın bir öngörü performansı sergilediği düşünülebilir. Öngörülerin gerçek gözlemlenen değerlerle bu dikkate değer eşleşmesi, öngörülerin gerçek değerlere göre bir saçılım grafiğini sunan Şekil 6'da görülebilir. Uygulama sonuçları bütüncül olarak değerlendirildiğinde, elde edilen tatmin edici tahmin performansları, özellikle kamu yönetimi ve özel sektör aktörleri tarafından düzenli izleme sistemlerine entegre edilerek karar kalitesinin artırılmasına imkân verebilir.

Şekil 6: Öngörülerin Gerçek Değerler ile Saçılım Grafiği



6. Sonuç

Gayri Safi Yurtiçi Hasıla büyüme oranı, bir ülkenin ekonomisinin genişleme veya daralma hızını gösterir ve genellikle belirli bir dönemde reel GSYİH değerindeki yüzde değişimle ölçülür. GSYİH büyüme oranı, ülkelerin ekonomik gücünü ve seyrini yansıtan temel makroekonomik göstergelerden biridir. Bu bakımdan, hükümetler, yatırımcılar ve uluslararası kurumlar tarafından ekonomik performansı değerlendirmek ve stratejik kararlar almak için yaygın olarak kullanılır. Bu doğrultuda, GSYİH büyüme oranlarının öngörüsünün, ekonomik

tahminleme, mali ve parasal politika ile yatırım kararlarındaki kritik rolü yadsınamaz. Ayrıca, enflasyon ve GSYİH, birbirleriyle yakından ilişkili iki temel makroekonomik göstergedir. Zaman içinde fiyatların genel düzeyindeki artışı ifade eden enflasyon; tüketim, yatırım ve para politikasını etkileyerek GSYİH'yı belirleyen unsurlar üzerinde doğrudan etki yaratabilir. Bu ilişkinin doğru modellenenebilmesi, istikrarlı ve sürdürülebilir büyüme hedefleyen politika yapıcılar için hayati önemdedir. GSYİH büyüme oranlarının öngörülmesinde, yalnızca GSYİH'nın gecikmeli değerlerinin değil, aynı zamanda TÜFE değişim oranlarının gecikmeli değişkenlerinin de modele dâhil edilmesi, makroekonomik dinamiklerin daha kapsamlı bir şekilde temsil edilmesini sağlar. Enflasyon göstergeleri, para politikaları ve tüketim davranışları aracılığıyla ekonomik büyümeyi dolaylı olarak etkilediğinden, bu değişkenlerin kullanımı modelin öngörü gücünü ve açıklayıcılığını artırır.

Bu çalışmada, bu noktadan hareketle, 2005 birinci çeyrek ile 2024 üçüncü çeyrek arasında çeyreklik (üç ayda bir) gözlenmiştir. Türkiye GSYİH büyüme oranları, aynı dönemde gözlenmiş Tüketici Fiyat Endeksi değişim oranları kullanılarak, hiper-parametreleri bir geçerlilik seti aracılığı ile ayarlanan/optimize edilen 4 farklı MÖ algoritması aracılığıyla, dört farklı dönemi içeren dört farklı senaryo üzerinden, modellenmiştir. Özellikle hem dört senaryonun üçünde hem de dört senaryo birlikte düşünüldüğünde ortalamada en üstün öngörü performanslarını sergileyen *CNNR*'nin, %1 ve %3 civarında ve biraz üzerinde OMYH değerli öngörüler ile GSYİH büyüme oranı öngörüsü için oldukça üstün ve etkileyici bir performans sergilediği söylenebilir. *NNR* ise, üçüncü senaryo dışında hem üç senaryoda hem de dört senaryo birlikte düşünüldüğünde ortalamada %2 ve %3 civarında ve biraz üzerinde OMYH değerlerine sahip öngörüler üretirken en iyi ikinci öngörü performansını sergilemiştir. Ayrıca, *GPR* ve *SVR* ise dört senaryo birlikte düşünüldüğünde ortalamada %7 civarında oransal hatalara sahip öngörüler ile GSYİH büyüme oranlarının öngörülmesinde yine de yadsınamaz bir başarı ortaya koymuşlardır. Bununla birlikte modellemesi gerçekleştirilen her bir senaryo ayrı ayrı ele alındığında, en üstün öngörü performansları sergileyen *CNNR* birinci ve ikinci senaryolarda %1 civarında ve biraz üzerinde oransal hatalarla olağan üstü ve oldukça değerli öngörü sonuçları üretmiştir. Bu durum, GSYİH büyüme oranlarının öngörülmesinde TÜFE gecikmeli değişkenleri kullanılırken, üç ve altı aylık periyotlarda daha başarılı sonuçların üretilebileceği sonucunu ortaya koyar.

Tüm sonuçlar birlikte değerlendirildiğinde, özellikle %3 civarında ve altında oransal hatalar ile öngörüler üreten *NNR* ve *CNNR* algoritmalarının hem ilgili alanda çalışan araştırmacılar, hem de kamu ve özel sektör karar vericileri için, GSYİH büyüme oranları tahmininde güvenle kullanabilecekleri birer modelleme ve öngörü aracı olarak kullanılabileceğini göstermiştir. Daha da spesifik olarak, *CNNR* algoritmasının üstün öngörü performans yeteneğinin, onun hem doğrusal hem de doğrusal olmayan ilişkileri birlikte modelleyebilmesine olanak tanıyan mimari ve fonksiyonel yapısından kaynaklandığı ve karmaşık ve kaotik ilişkiler barındıran GSYİH büyüme oranı öngörüsü gibi problemlerde güvenle kullanılabileceği söylenebilir.

Bu çalışmada elde edilen öngörü performansları dikkate alındığında, özellikle *CNNR* ve *NNR* algoritmalarının ekonomik yönetim süreçlerine katma değer sağlayacak şekilde uyarlanması mümkündür. Bu yöntemlerin periyodik olarak uygulanarak güncel verilerle beslenmesi, politika yapıcılarının orta vadeli büyüme hedeflerini ve makroekonomik dengeleri daha gerçekçi tahmin etmelerine yardımcı olabilir. Örneğin, Hazine ve Maliye Bakanlığı ya da Türkiye Cum-

huriyet Merkez Bankası gibi kurumlar, CNNR ve NNR temelli tahmin modellerini mevcut ekonomik izleme sistemlerine dâhil ederek, GSYİH büyümesi ve tüketici fiyatları eğilimlerini daha yakından takip edebilir. Benzer şekilde, gelişmiş ülkelerde de makine öğrenimi temelli öngörü yöntemlerinin, para politikası senaryolarının geliştirilmesinde kullanımı yaygınlaşmaktadır. Bu kapsamda, çalışmada önerilen algoritmaların karar alma döngüsüne entegre edilmesi, düzenli raporlamalarda ve yatırımcı bilgilendirmelerinde tamamlayıcı bir araç olarak değerlendirilebilir.

Gelecek çalışmalarda, GSYİH büyüme oran öngörüsünde, belirsizliğe bulanık bir yaklaşım sunacak farklı modelleme araçları kullanılabilir ya da bunların mevcut MÖ algoritmalarına entegre edilmesi ile melez bazı modelleme yaklaşımları geliştirilebilir.

Katkı Oranı Beyanı

Çalışmadaki katkı oranı, 1. yazar %50, 2. yazar %50 şeklindedir.

Destek ve Teşekkür

Değerli yorumları ve yapıcı eleştirileri için editör ve hakemlere teşekkür ederim.

Çıkar Çatışması Beyanı

Bu çalışmada herhangi bir çıkar çatışması bulunmamaktadır.

Kaynakça

- Abifarin, M. O., Isah, A., Yakubu, Y. & Adeyemi, R. A. (2024). A study on the effect of the growth rate of gross domestic product on some macroeconomic variables. *Science World Journal*, 1, 24-28.
- Akan, Y. & Kanca, O. C. (2015). Türkiye’de dış borçlanma ve enflasyon ilişkisi: VAR yaklaşımı (1980-2013). *Hacettepe Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 33(3), 1-22.
- Almarashi A., Daniyal M & Jamal F (2024). Modelling the GDP of KSA using linear and non-linear NNAR and hybrid stochastic time series models. *Plos One*, 19(2), 114-118.
- Aral, A. (2015). *Türkiye’de döviz kuru ve dış ticaret ilişkisi:1992–2013 dönemi eş bütünleşme analizi* (Yayınlanmamış Yüksek Lisans Tezi). Aydın Adnan Menderes Üniversitesi Sosyal Bilimler Enstitüsü, Aydın.
- Atabey, A. Ö. & Karakuş, M. (2022). Türkiye’ye yönelik enflasyon, dış ticaret ve ekonomik büyüme ilişkisinin ampirik analizi. *Cumhuriyet Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 23(3), 747-759.
- Barro, R. J. (1995). Inflation and economic growth. *Bank of England quarterly bulletin*, 35(2), 407-443.
- Berentsen, A. & Shouyong, S. (2008). Financial deepening, inflation and growth. *Working Paper: Money, Banking and Payments*, Federal Reserve Bank of Chicago.
- Božić, R. (2022). Forecasting GDP growth using data mining on the example of Serbia. *Novi Ekonomist*, 16(31).
- Burdekin, R. C. K., Denzau, A. T., Keil, M. W., Sitthiyot, T. & Willet, T. D. (2000). When does inflation hurt economic growth? Different nonlinearities for different economies. Claremont McKenna Collage & Claremont Graduate School, No:2000–22.
- Chowdhury, A. (2002). Does inflation affect economic growth? The relevance of the debate for Indonesia. *Journal of Asia Pacific Economy*, 7(1), 20-34.
- Ciaburro, G. & Iannace, G. (2021). Machine learning-based algorithms to knowledge extraction from time series data: A review. *MDPI*, 6(6), 1-30.

- Çanakcı, M. (2021). Does inflation affect economic growth? A case of Turkey and U.S. *International Journal of Economics and Financial Issues*, 11(3), 45–54.
- Demuth, H. (1992). Neural network toolbox. In: Edition, M. (Ed.), Natick, Massachusetts, USA.
- Dunaev, B. (2025). Inflation dynamics in the country's economy. *International Theoretical Science Journal*, 61(1), 115–119.
- Emsen S., Turan, S. A. & Aksu, H. (2012). Sınır testi ile enflasyon ve ekonomik büyüme ilişkileri: Türkiye üzerine incelemeler. *Anadolu Üniversitesi Sosyal Bilimler Dergisi*, 12(2), 25–40.
- Erdoğan, L., Tiryaki, A. & Ceylan, R. (2018). Türkiye’de uzun dönem ekonomik büyümenin belirleyicilerinin ARDL, FMOLS, DOLS ve CCR yöntemleriyle tahmini. *Hacettepe Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 36(4), 39–57.
- Fahlman, S. E. (1988). Faster-learning variations on back-propagation: An empirical study in proceedings of the 1988 Connectionist Models Summer School, Morgan Kaufmann.
- Fahlman, S. E. & Lebiere, C. (1990). The cascade-correlation learning architecture. In: Advances in neural information processing systems (NIPS), 1, 524–532.
- Fischer, S. (1993). The role of macroeconomic factors in growth. *Journal of Monetary Economics*, 32(3), 48–51.
- Geçgil, G. & Akgül, Y. (2020). Türkiye’nin GSYİH değerlerinin yapay sinir ağları ile tahmini üzerine bir inceleme. *Nicel Bilimler Dergisi*, 2(1), 61–77.
- Granger, C.W.J. (1969). Investigating causal relations by econometric models and cross-spectral methods. *Econometrica*, 37(3), 424–438.
- Hussain, S. & Malik, S. (2011). Inflation and economic growth: Evidence from Pakistan. *International Journal of Economics and Finance*, 3(5), 262–276.
- Johansen, S. (1990). Maximum likelihood estimation and inference on cointegration with applications to the demand for Money. *Oxford Bulletin of Economics and Statistics*, 52, 169–210.
- Kankpeyeng, J. G., Maham, I. & Abubakar, M. (2021). Impact of inflation on gross domestic product growth in Ghana. *Ghana Journal of Development Studies*, 1, 64–71.
- Karabulut, Ş. (2019). Türkiye’de ekonomik büyüme ve enflasyon ilişkisi. *Optimum Ekonomi ve Yönetim Bilimleri Dergisi*, 6(2), 171–184.
- Karaca, O. (2003). Türkiye’de enflasyon-büyüme ilişkisi: Zaman serisi analizi. *Doğuş Üniversitesi Dergisi*, 4(2), 247–255.
- Karaçor, Z., Özer, H. & Saraç, Taha B. (2011). Enflasyon ve ekonomik büyüme ilişkisi: Türkiye ekonomisi üzerine ekonometrik bir uygulama (1988–2007). *Niğde Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 4(2), 29–44.
- Korkulu, A. & Yılmaz, B. (2017). Türkiye’de büyüme-enflasyon ilişkisi: Granger nedensellik analizi (1939–2013). *International Journal of Academic Value Studies*, 3(13), 85–93.
- Kumar, S., Kumar, A., Shaikh, G. M., Ali, K. & Azhar, M. (2023). The long run impact of exchange rate and inflation on GDP: A panel data approach consistent with data from Brazil, Russia, India, China and South Africa (BRICS). *Journal of Economic Impact*, 5(3), 317–326.
- Kumar, M., Komirelli, A., Meghana, S. & Prafull, L. N. (2024). A study on analysis of the relationship between GDP growth and inflation in India. *International Journal of Scientific Research in Engineering and Management*, 1, 117–131.
- Kumari, S. & Singh, S.K. (2022). Deep learning-based time series models for GDP and ICT growth prediction in India. *International Conference on Computing, Communication, and Intelligent Systems (ICCCIS)*, Greater Noida, India, 250–256.

- Lucas, R. E. (1973). Some international evidence on output-inflation trade off. *The American Economic Review*, 63(3), 326–334.
- Ma, Y. (2024). Analysis and forecasting of GDP using the arima model. *Information Systems and Economics*, 5, 91–97.
- Malec, K., Maitah, M., Rojik, S., Aragaw, A., & Fulnečková, P. R. (2024). Inflation, exchange rate and economic growth in Ethiopia: A time series analysis. *International Review of Economics & Finance*, 96, 103–161.
- Martyniak, I., Trubnik, T. & Kostenko, Y. (2025). Comprehensive empirical analysis of the impact of inflationary processes on economic development: Trends, mechanisms and forecasting models. *Social Development: Economic and Legal Issues*, 1, 42–47.
- Motley, B. (1998). Growth and inflation: A cross-country study. *Federal Reserve Bank of San Francisco Economic Review*, No: 1, 1528.
- Paul, S., Kearney, C. & Chowdhury, K. (1997). Inflation and economic growth: A multi-country empirical analysis. *Applied Economics*, 29, 1387–1401.
- Pediz, B. & Yenilmez, F. (2025). Vergi yükü, enflasyon ve ekonomik büyüme ilişkisi: 1990-2022 Türkiye örneği. *Journal of Institute of Economic Development and Social Researches*, 9(36), 56–78.
- Rasmussen & Williams (2005). *Gaussian Processes for Machine Learning*, By: Carl Edward Rasmussen, Christopher K. I. Williams, *The MIT Press*, 1, 7–31.
- Söyler, H. & Kızılkaya, O. (2015). Türkiye'nin GSYİH tahmini için yapay sinir ağları model performanslarının karşılaştırılması. *Cumhuriyet Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 16(1), 45–58.
- Şencan, D. & Şencan Şahin, A. (2022). Anfis yöntemi kullanılarak Türkiye'de GSYİH tahmini. *Kafkas Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 13(26), 953–971.
- Terzi, H. & Oltulular, S. (2006). Enflasyon-büyüme sürecinde sabit sermaye yatırımları. *İktisadi ve İdari Bilimler Dergisi*, 20(1), 3–6.
- Thirlwall, A.P. & Barton, C. A. (1971). Inflation and growth: The international evidence. *Banco Nazionale del Lavoro Quarterly Review*, No:98, 263–275.
- Tjandrasa, B. B. & Dewi, V. I. (2022). The model of GDP growth in ASEAN-4 countries: Control of corruption as an intervening variable. *Journal of Economics, Business and Accountancy Ventura*, 25(1), 1–9.
- Toda, H.Y. & Yamamoto, T. (1995). Statistical inference in vector autoregressions with possibly integrated processes. *J. Econom.* 66(1), 225–250.
- Topçu, E. (2017). Enflasyon oranı-ekonomik büyüme ilişkisi: Türkiye örneği. *Nevşehir Hacı Bektaş Veli Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 7(2), 180–191.
- Wu, J. & He, Y. (2021). Prediction of GDP in time series data based on neural network model. *IEEE International Conference on Artificial Intelligence and Industrial Design (AIID)*, Guangzhou, China, 20–23.
- Xiong, M. (2023). Relationship between GDP and inflation rate. *BCP Business & Management*, 40, 372–376.
- Yu, Z. (2024). Analysis of economic impact based on time series model - taking the GDP of two provinces as an example. *Highlights in Business, Economics and Management*, 30, 125–134.