

# GAZİANTEP UNIVERSITY JOURNAL OF SOCIAL SCIENCES

Journal homepage: <http://dergipark.org.tr/tr/pub/jss>



## Araştırma Makalesi • Research Article

# Türkiye’de Enflasyon Oranlarının Makine Öğrenme Yöntemi ile Tahmini

## Estimation of Inflation Rates in Turkey with Machine Learning Method

Serkan NAS<sup>a</sup> Ayşe AKBOZ CANER<sup>b\*</sup> Ayşe ERGİN ÜNAL<sup>c</sup>

<sup>a</sup> Dr. Öğr. Üyesi, Tarsus Üniversitesi, Yönetim Bilişim Sistemleri Bölümü, Mersin / TÜRKİYE

ORCID: 0000-0002-0040-3091

<sup>b</sup> Doktora Öğrencisi, Tarsus Üniversitesi, Finans ve Bankacılık Bölümü, Mersin / TÜRKİYE

ORCID: 0000-0002-0060-2007

<sup>c</sup> Doç. Dr., Tarsus Üniversitesi, Finans ve Bankacılık Bölümü, Mersin / TÜRKİYE

ORCID: 0000-0001-6551-8933

### MAKALE BİLGİSİ

#### Makale Geçmişi:

Başvuru tarihi: 4 Ekim 2023

Kabul tarihi: 20 Haziran 2024

#### Anahtar Kelimeler:

Enflasyon,  
Makine öğrenmesi,  
Rastgele Orman,  
Karar Ağacı.

### ARTICLE INFO

#### Article History:

Received: October 4, 2023

Accepted: July 20, 2024

#### Keywords:

Inflation,  
Machine learning,  
Random Forest,  
Decision Tree.

### ÖZ

Karar birimleri ve politika yapıcıların başarılı politikalar geliştirebilmelerinin önemli etkileyenlerinden biri gelecek dönemlere ait makroekonomik değişkenlerin doğru tahmin edilmesiyle gerçekleştirilmektedir. Enflasyon, söz konusu makroekonomik göstergeler arasında yer almakta olup başarılı politikalar gerçekleştirebilmek için enflasyonun reel etkilerini ve şiddetini minimize etmek, gelecek dönem değişimlerini ve etkileyenlerini belirlemek, enflasyonu güvenilir tahmin etmek gerekmektedir. Enflasyonun doğru bir şekilde tahmin edilmesi demek kamu sektörü ve özel sektör tarafından hem uygulanacak politikalar açısından hem de alınacak yatırım kararları bakımından önem arz etmektedir. Bu bağlamda yapılan çalışmada, Türkiye için 2008-2023 zaman aralığı kullanılarak üçer aylık veriler seçilmiştir. Çalışmada, geleneksel ekonometri yöntemleri yerine tahmin ile gerçeğin arasındaki farkın en aza indirildiği makine öğrenme yöntemleri kullanılmıştır. Alternatif makine öğrenme metotları olan rastgele orman, karar ağacı ile yapay sinir ağları yöntemi olan çok katmanlı algılayıcı kullanılarak enflasyonu etkilediği düşünülen Brent petrol, Reeskont avans faiz oranı, para arzı, TÜFE, vergi gelirleri, genel bütçe gelirleri, politika faizi, Amerikan Doları/TL paritesi, GSYİH öznitelikleri seçilmiştir. Seçilen öznitelikler ile doğru tahminlemenin yapılacağı yöntem ve etkileyenin belirlenmesi amaçlanmaktadır. Analiz sonuçları karar ağacı modelinin, rastgele orman ve çok katmanlı algılayıcıya oranla en doğru enflasyon oranını tahmin ettiğini göstermektedir. Çalışma sonucundan elde edilen diğer bir bulgu ise Türkiye’de enflasyonun en yüksek belirleyicisinin Amerikan doları olduğu olgusudur.

### ABSTRACT

One of the important factors of decision units and policymakers to develop successful policies is the correct estimation of macroeconomic variables for future periods. Inflation is among these macroeconomic indicators, and to realize successful policies, it is necessary to minimize the real effects and severity of inflation, determine future changes and their effects, and predict inflation reliably. Accurate forecasting of inflation is important both in terms of the policies to be implemented and the investment decisions to be taken by the public and private sectors. In this context, quarterly data were selected for Turkey using the 2008-2023 time period. In the study, machine learning methods were used instead of traditional econometric methods, in which the difference between prediction and reality was minimized. Brent oil, Rediscount advance interest rate, money supply, CPI, tax revenues, general budget revenues, policy rate, US Dollar/TL parity, and GDP attributes, which are thought to affect inflation, were selected by using random forest, decision tree and multi-layered detector, which is an artificial neural networks method, which are alternative machine learning methods. With the selected attributes, it is aimed to determine the method and influencer to make the correct estimation. The analysis results show that the decision tree model predicts the most accurate inflation rate compared to the random forest and multilayer sensor. Another finding from the study is that the highest determinant of inflation in Turkey is the US dollar.

\* Sorumlu yazar/Corresponding author.

e-posta: [ayse\\_akboz@tarsus.edu.tr](mailto:ayse_akboz@tarsus.edu.tr)

## EXTENDED ABSTRACT

Turkey is a country that may be affected by global events and crises from past to present and may suffer from economic problems. One of the most important of these economic problems is inflation. Inflation, which is an important indicator for economic growth and development, refers to the continuous increase in the general level of prices. Forecasting macroeconomic indicators is a difficult process. Achieving price stability and financial stability, which are the major objectives of central banks, is only possible by ensuring low and sustainable inflation. Forecasting inflation in a sustainable and accurate manner is important both for controlling it and for policymakers and investors. In order for an effective and strong monetary and fiscal policy to be implemented and for investors to maximize their profits, accurate forecasting of inflation dynamics is necessary. Forecasting inflation is a troublesome process for scientific research and policy makers. Machine learning method has started to be used in studies since it is a model that reports the closest result to reality.

Various methods such as machine learning methods and econometric analysis methods have been used for forecasting inflation. Although according to Araujo and Gaglianone (2023), the machine learning method is the most accurate method for forecasting inflation, due to the difficulties in interpretation, it is recommended to use a hybrid model that combines econometric analysis and machine learning method, Ülke, Şahin and Subaşı (2018) concluded that the machine learning method is superior to time series models for personal consumption expenditure and inflation forecasting, while the time series model is better for CPI. Medeiros, Vasconcelos, Veiga, and Zilberman (2019) have reported that the LASSO and RF method for inflation forecasting gives stronger results than other machine learning methods.

In this research, a dataset is prepared by selecting a quarterly time period between 2008 and 2023 from the Central Bank of the Republic of Turkey (CBRT) Electronic Data Distribution System (EDDS). Brent oil price per barrel, interest rate used in rediscount advance transactions, money supply, CPI, tax revenues, general budget revenues, policy interest rate, US dollar Turkish lira parity, GDP variables are used in the data set. In the study, the machine learning method, which provides advantages in making accurate and reliable forecasts in large data sets, is used. Three different algorithms were used for forecasting with the machine learning method. These are the decision tree, which consists of a series of consecutive decisions to reach a certain result and is easy to interpret, the random forest, which utilizes the combination of multiple decision trees and is complex to interpret and understand, and the multilayer perceptron artificial neural network method, which works similar to the human brain.

Decision tree is a machine learning general-purpose prediction and classification mechanism that helps to find the most appropriate outcome by bringing together a series of decision possibilities or a particular problem. Random forest is a supervised machine learning algorithm, created by bringing together multiple decision trees, used in classification and regression problems that are more complex to interpret and understand than the decision tree method, and makes class or number prediction according to type of the problem. Random forest is a type of decision tree, but it has some differences. Random forest creates random subsets and uses these subsets to create smaller trees. This cause the result to have fewer errors. A multilayer perceptron is a complement to a feedforward artificial neural network that can produce a set of outputs with a set of inputs, arranged in a direct graph with at least three layers. The layers in a multilayer perceptron are input, output and hidden layer. In the input and output layer, the problem determines how many elements are required for the process. However, the decision-making process of the hidden layer is done through trial and error.

The data selected in the study were converted to values between 0 and 1 to be used in the algorithm. 80% of the data was divided into 80% for training and 20% for testing, and each algorithm measured the test data with the Mean Absolute Percentage Error Rate (MAPE). The calculation of this MAPE is the difference between the actual value and the output value generated by the machine learning algorithms.

The decision tree algorithm provides the best result with 83.1% according to the analysis results. The random forest and multilayer perceptron predicted correctly 82.73% and 77.04% of the time, respectively. The most influential variable according to the decision tree algorithm is the USD/TL parity with 86.5%. GDP affects inflation by 6.2%, general budget expenditures by 3.3%, Brent oil by 2.7% and other variables by 1.3%.

## Giriş

Ülkelerin makroekonomik sorunlarından biri olan enflasyonu doğru tahmin etmek, politika yapıcılarının ve ekonomik aktörlerin isabetli finansal karar almalarını kolaylaştırmaktadır. Örneğin Merkez Bankaları (MB) enflasyona yönelik gelecek tahminleri yapmakta olup bir anlamda beklenti yönetimi oluşturmaktadır. Yapılan başarılı tahminlerin gerek MB gerekse ülke kredibilitelerini arttıracakları düşünülmektedir. Bu düşüncenin alt yapısında yatırım, üretim ve tüketim için karar alıcıların doğru tercihlerde bulunmaları yatmaktadır. Keza enflasyonun doğru tahmin edilmesi sayesinde yatırımların karlılığı artabilecek, üretim maliyetleri hesaplaması kolaylaşabilecek ve tüketici marjinal faydası yüksek mal sepeti tercih edebilecektir. Söz konusu durumu destekler biçimde Medeiros vd. (2019) enflasyon tahmininin haneler, işletmeler ve politika yapıcılar için büyük değer taşıdığını vurguladıkları çalışmalarında da merkez bankalarının sadece para politikasını bilgilendirmek için değil, aynı zamanda enflasyon beklentilerini sabitlemek ve böylece politika etkinliğini artırmak için önemini belirtmektedirler. Nitekim, ekonomik karar alma sürecini iyileştirme çabasının bir parçası olarak birçok merkez bankası enflasyon tahminlerini düzenli olarak açıklamaktadır. Diğer yandan ekonomide en önemli, önemli olduğu kadar da zor çalışmalardan biri olarak değerlendirilen söz konusu tahminlemeyi yapmada etkili olan pek çok farklı makroekonomik, finansal ve sosyolojik faktör bulunmaktadır. Enflasyonu etkileyen pek çok faktör yanında en doğru tahminlemenin yapılacağı yöntemi seçmek de oldukça önemlidir. Keza tahminlemede çalışılmış farklı yöntemler bulunmakla beraber ARIMA, makine öğrenme algoritmaları, Philips eğrisi modelleri, ya da regresyona dayalı yöntemler bunlardan birkaçıdır. Yapılan ekonometrik çalışmalarda belirli sınırlılıklar bulunmakla beraber özellikle regresyon yöntemlerinde karşılaşılan üç temel sorun mevcuttur. Koop ve Korobilis (2012)'e göre bunlardan ilki, modelde kullanılan açıklayıcı değişken diğer bir değişle tahmin ediciler üzerindeki katsayıların zamanla değişmesi olup Phillips eğrisinin eğiminin zaman içinde değişmesi bu soruna örnek teşkil etmektedir. İkinci sorun enflasyonu tahmin etmede kullanılacak olan değişken sayısının oldukça fazla olması iken son sorun, oluşturulan modelin zaman içinde potansiyel olarak değişebilme ihtimalidir. Örneğin durgunluk ya da canlanma dönemlerinde kullanılacak tahmin edicilerin oran ve nitelikleri farklı olmaktadır. Söz konusu sınırlılıklara karşın günümüzde kullanılan geleneksel istatistiksel yöntemler yanında özellikle ekonomi ve finans alanında yapay zekâ teknikleri kullanılmaya başlanmıştır. Ülke vd. (2018) enflasyon tahmini için zaman serisi ve makine öğrenmesi modellerini karşılaştırdıkları çalışmalarında da bu duruma vurgu yapmışlardır. Çalışma bulgularında makine öğrenimi modellerinin, yüksek oynaklığa sahip çekirdek- Kişisel Tüketim Harcamaları fiyat endeksi (PCE) için zaman serisi modellerine karşı üstün olduğunu tespit ederlerken zaman serisi modellerinin, çekirdek-Tüketici fiyat endeksi (TÜFE) enflasyon tahmininde başarılı sonuçlar verdiğini tespit etmişlerdir. Diğer yandan enflasyonun da içinde bulunduğu ekonomi ve finans değişkenlerinin yüksek belirsizlik ve volatiliteye sahip nitelikleri, söz konusu değişkenlere yönelik tahmin yapmayı zorlaştırmaktadır. Buna karşın örneğin enflasyona yönelik oranların gerçeğe oldukça yakın şekilde tahmin edilmesi özellikle yüksek riske sahip gelişmekte olan ülkelerin ekonomik karar alma ve politika oluşturmaları açısından önemlidir.

Bu çalışmada 2008-2023 zaman diliminde, yıllık veriler seçilerek alternatif makine öğrenme yöntemleri ve Türkiye'de enflasyonu etkilediği düşünülen Brent petrol, Reeskont avans faiz oranı, para arzı, TÜFE, vergi gelirleri, genel bütçe gelirleri, politika faizi, Amerikan Doları/TL paritesi, GSYİH öznitelikleri kullanılarak doğru tahminlemenin yapılacağı yöntem ve etkileyenin belirlenmesi amaçlanmaktadır. Çalışmanın diğer çalışmalardan farkı enflasyon belirleyicilerinin uygulanan farklı makroekonomik politikalara göre sınıflandırılarak analize dahil edilmesi ve literatürde zaman serisi yöntemlerine oranla daha az kullanılan makine

öğrenme algoritmalarının tercih edilmesidir. Gerek enflasyona yönelik doğru tahminlemeyi sağlayacak makroekonomik göstergeyi belirlemesi gerekse kullanılacak en doğru yöntemin oransal açıklamasının yer alması noktalarında çalışmanın, literatüre katkı sağlayacağı düşünülmektedir.

### **Türkiye’de Enflasyon Sorunsalı ve Tarihsel Süreci**

Ekonomik istikrarın sağlanmasında önemli rol oynayan makroekonomik politikalar, ekonomik büyümenin sürdürülebilir olması ve hızla gelişmesi için ortam yaratmakta olup bu durumun başarı ile gerçekleşmesi para ve maliye politikalarının uyumlu bir şekilde hareket etmesine bağlıdır. Birbirine bağlı bu iki politika, iki ayrı otorite tarafından yönetilmektedir. Ekonomi politikaları arasında uyumun sağlanamaması, pek çok ekonomik probleme yol açmaktadır. Örneğin mali disiplinin sağlanamadığı bir ekonomide sürdürülemeyen borç düzeyi, yüksek bütçe açığı gibi sorunlar yaşanmakta, bu durum maliye politikasının para politikasından baskın olmasına neden olmaktadır (Bölükbaş, 2018, s. 48). Maliye politikası kamu gelir ve harcamalarının, tür, şekil ve miktarında değişiklikler yaparak kullanılmasıdır. Kamu harcamaları arttırılarak deflasyonist baskı azaltılabilirken, kamu gelirleri arttırılarak enflasyonist baskı azaltılabilir (Bozkurt ve Göğül, 2010, s. 29). Para politikası, enflasyonist bir durumda, spekülative yatırımları önlemek açısından daha etkindir, çünkü faiz oranının alt veya üst sınırı yoktur. Bu nedenle, sermayenin marjinal verimliliğinin yüksek olması durumunda faiz oranını bu seviyenin üzerine çıkartarak yatırımları önlemek mümkündür (Birinci, 1989, s. 28-29). Küresel kriz sonrası Türkiye ekonomisinde talepte yaşanan durgunluğa karşı gevşek para ve maliye politikası uygulamaları görülmüştür. Bu bağlamda maliye politikası bütçe sürdürülebilirliğine öncelik verirken, para politikasının amacı fiyat istikrarı ve finansal istikrarın birlikte sağlanması olarak belirlenerek politika faizi ile beraber zorunlu karşılık oranı ve faiz koridoru gibi alternatif araçlar kullanılmıştır (Gürkaynak vd., 2022, s. 25; Başçı ve Kara, 2011, s. 4). Yaşanan pek çok makroekonomik soruna karşın uygulanan devlet müdahalelerinin ağırlıklı olarak para ve maliye politikaları araçlarının kullanımı şeklinde olduğu bilinmektedir. Diğer yandan ülkelerin önemli makroekonomik sorunlarından biri olan enflasyonun kontrol altında tutulması için uygulanacak politikalar seçilmeden, enflasyon türünün belirlenmesi, uygun politikalar seçmek açısından önemlidir.

Türkiye, 1970’li yıllardan günümüze dünya genelinde ve ülke çapında meydana gelen olumsuz gelişmeler ve krizlere bağlı olarak makroekonomik sorunlar yaşamaktadır. Bu sorunlardan biri yüksek enflasyondur. Enflasyonla mücadele için çeşitli politikalar uygulanmış, fakat kalıcı bir başarıya ulaşılamamıştır (Petek ve Çelik, 2017, s. 70). Günümüzde, hızlı ve sürdürülebilir bir büyümenin gerçekleşme şartlarından biri enflasyonun makul bir seviyede olması ve bulunduğu seviyenin kontrol altında olması gerekmektedir. Çünkü yüksek enflasyonun olduğu ülkelerin ekonomisinde düzeltilmesi gereken sorunların olduğu düşünülmektedir. Birçok gelişmiş ülkede enflasyon oranı %5’in üzerine çıktığında önlem alma zorunluluğu hissederken, çift haneli yüksek enflasyon yaşayan ülkeler enflasyonla mücadeleden kaçınmakta, bu durum ülkeleri kendi sınırlarına hapsedmektedir (Çetintaş, 2003, s. 146).


TCMB enflasyon raporlarından yapılan derlemeye göre, enflasyonun en yüksek oranda seyrettiği 1970’li yılların başlarında olumlu gelişmeler yaşansa da dışsal şokların etkisiyle, makroekonomik uyumsuzluklar ile yüksek enflasyonun yaşandığı bir döneme girilmiştir. Petrol fiyatlarında ki artıştan kaynaklı maliyet enflasyonu, Türkiye ekonomisinin kısa vadeli dış borç yükünde artışa neden olmuştur. İthal kotaları, gümrük resimleri gibi ekonomik önlem paketleri uygulanmaya çalışılmıştır. Ancak başarılı olunamamış ve TL sık sık devalüe edilmiştir. 1970’lerde maliyet enflasyonu ile başlayan enflasyonist süreç, yerini talep enflasyonuna bırakmıştır. 1980’li yıllar Türkiye ekonomisi açısından kritik reformların gerçekleştiği önemli

bir dönemdir. TCMB söz konusu dönemde reeskont kredileri, açık piyasa işlemleri ve zorunlu karşılık oranını kullanarak parasal büyüklükleri ve enflasyonu kontrol altına almayı amaçlamıştır. Bütçe dengesini sağlamak amacıyla TCMB kaynaklarının kullanılmaya devam ettiği 1990'lar enflasyonun hızla yükseldiği, TL'de önemli oranda değer kaybının olduğu yıllardır. 2000'lerde enflasyon hedeflerinin hükümetle beraber tahmin edildiği, enflasyon tahminlerinin kamu ile paylaşıldığı, faizin temel politika aracı olduğu yapısal dönüşüm sürecine girilmiş olup 2007 yılında kuraklık ile arz yönlü bir şok yaşanmıştır. Aynı dönem enerji fiyatlarında da artış yaşanmış ve maliyet enflasyonu artmıştır. Söz konusu dönemde özellikle TCMB'ye olan güveni artırmak adına enflasyon hedeflerinin artırıldığı görülmektedir. Diğer yandan 2008 yılında yaşanan krizin etkisi birkaç yıl sürmüş olup takibindeki dönemde talepte daralma ve enerji fiyatlarında düşüş yaşanmıştır. Bu durum talep ve maliyet kaynaklı enflasyonda azalma meydana getirmiştir. 2009 yılında enflasyonun hedeflenenin altında çıkması, TCMB tarafından fırsat olarak kabul edilmiş ve faiz oranında ciddi bir düşüş yapmıştır, borçlanma faizi 16,75'den 6.50'ye indirilmiştir. 2008 krizi TCMB için yeni bir anlayış yaratmış, temel hedefi revize edilmiştir ve fiyat istikrarı ile finansal istikrar olarak belirlenmiştir. 2010-2018 yılına kadar enflasyon oranı yatay seyrederken bu durumun nedeni olarak 2010 yılında alınan kararlar enflasyon oranında iyileştirilme yaşanana kadar sıkı para politikasına geçilmesi düşünülebilmektedir. 2018 yılında döviz kurunda meydana gelen ciddi dalgalanma, mal ve hizmet fiyatlarında olumsuz etki yaratmış, talep enflasyonuna neden olmuştur. 2019 yılında Çin'de başlayan ve kısa sürede küresel bir salgın haline gelen Covid-19, 2020 yılında Türkiye'de görülmeye başlamıştır ve sonrasında küresel çapta bir arz sıkıntısı yaşanmıştır. Bu durum, emtia fiyatlarında yaşanan artış, döviz kurunun artması, enflasyon üzerinde birden fazla şok yaratmış olup talep enflasyonu ve maliyet enflasyonunun beraber yaşandığı gözlemlenmiştir. 2020 yılında başlayan Covid-19 salgınına yönelik ekonomik kararlar; faiz indirimi ve doğal gaz fiyatlarında yaşanan artış sonrası 2022 yılında enflasyon oranının %85,51 seviyesine kadar çıktığı görülmüştür.

İncelenen enflasyon tarihçesine göre 1970'li yılların sonlarından günümüze değin yaşanan yüksek ve kalıcı enflasyonun varlığı, genel olarak aşağıdaki gelişmelerle paralellik göstermektedir (Kibritçioğlu, s. 43-44):

- Kamu kesimi bütçe açıklarının yüksek olması ve bu bütçe açıklarından para kazanmak,
- Hükümetlerin devasa altyapı yatırımları,
- Jeopolitik konum ile ilgili yüksek askeri yatırımlar,
- Seçim dönemleri ortaya çıkan popülist politikalar nedeniyle enflasyonist baskılara yol açan siyasi istikrarsızlık,
- İthal girdi mal fiyatında artış nedeniyle döviz kurlarındaki değişikliklerin enflasyonist etkileri,
- Petrol ve doğal gaz gibi kaynakların fiyatlarında artış olarak görünmektedir.

Şekil 1'de 1974 -2022 aralığında Türkiye'de tüketici fiyatları açısından enflasyon oranları yer almaktadır.



Şekil 1: Enflasyon, tüketici fiyatları (yıllık %), Türkiye

**Kaynak:** Dünya Kalkınma Göstergeleri, Dünya Bankası

Enflasyonun tarihsel süreci incelendiğinde uygulanan para maliye politikaları yanında sosyal ve siyasal gelişmelerinde oranlarda etkili olduğu düşünülmektedir. Bu bağlamda 1974 yılında yaşanan küresel petrol krizi ve takibinde Kıbrıs Barış Harekâtı sonrası Türkiye'ye uygulanan ambargolar sonucunda enflasyon 1976 yılından sonra artış eğimine geçmiştir ve 1978 yılında enflasyon oranında bir sıçrama yaşanmıştır. 1980 yılında yaşanan askerî darbe sonrası enflasyon oranı yatay olarak seyretmiş, 1994 yılında Türkiye ekonomisinde yaşanan kamu kesimi borç kesimi ile hiperenflasyon yaşanmıştır. 2000-2001 krizinden sonra IMF desteğiyle yapısal reform planı hazırlanmıştır ve Türkiye ekonomisinde enflasyon oranı 2018 yılına kadar düşük oranda ilerlemiştir. 2018 yılında başlayan döviz krizi, Mart 2020 yılında koronavirüs salgının ülkede görülmeye başlamasıyla ekonomik anlamda kötüleşme başlamıştır ve 2022 yılında enflasyon %72 seviyesine kadar yükselmiştir.

### Literatür

Enflasyon tahminine yönelik yöntemlerin yapıldığı çalışmalar incelendiğinde ekonometrik analizlerin iki kategoriye ayrıldığı görülmektedir. İlk kategori tek değişkenli modelleri içermekte olup yalnızca enflasyon düzeyine ilişkin geçmiş verilere dayanmakta iken ikinci kategori ise çok değişkenli makroekonomik değişkenleri içeren modeldir (He vd., 2012, s. 649). Diğer yandan son dönemlerde makine öğrenimi algoritmaları kullanılarak yapılan çalışmalar da bulunmaktadır. Aşağıdaki tabloda farklı açıklayıcı değişkenler ve farklı enflasyon tahmin yöntemlerinin kullanıldığı çalışma ve bulgularına yer verilmektedir.

**Tablo 1:** Enflasyon Tahminine Yönelik Çalışmalar

Çalışmanın Adı	YAZAR	ÜLKE	YÖNTEM	DEĞİŞKENLER	BULGULAR
<b>Comparative accuracy of forecasts of inflation: a Canadian study</b>	Mitra ve Rashid (1996)	Kanada	Arıma, Var, Durağan Beklenti Modeli	Düşük Enflasyon, Yüksek Enflasyon, Durağan Enflasyon, Değişken Enflasyon	Bir dönem sonrası tahminlerde değişken enflasyon döneminde VAR, durağan enflasyon döneminde ise ARIMA modelleri daha üstün performans göstermiştir. Dört dönem sonrası tahminlerde ise artan belirsizlikle birlikte VAR modellerinin performansı artış göstermektedir.
<b>Inflation forecasting for aggregates of the</b>	Bikker (1998)	Avrupa Birliği	Var, Tek Değişkenli Otoresgresif		BVAR modellerinin ülkeler genelinde bir dönem ve iki dönem sonrası için iyi



<b>EU-7 and EU-14 with Bayesian VAR models</b>		e Üye Ülkeler	(Uar), Bayesian Var (Bvar) Ve Tek Değişkenli Bayesian Var (Ubvar)		sonuçlar verdiği sonucuna ulaşılmış.
<b>Forecasting Austrian HICP and its Components using VAR and ARIMA Models</b>	Fritzer, Moser, Ve Scharler, (2002)	Avusturya	Arıma, Var	12 Aylık Enflasyon Oranları	ARIMA modellerinin 8 periyot ileriye kadar VAR modellerinden daha iyi bir tahminleme performansı sağladığı, daha uzun periyotlarda VAR modellerinin daha iyi tahminler verdiği sonucuna ulaşılmış.
<b>Can forecasting performance be improved by considering the steady state? An application to Swedish inflation and interest rate</b>	Österholm (2008)	İsveç	Ar, Var	1980-2004 Enflasyon Oranları, Faiz	Modeller de sonuç birbirine yakın çıkmıştır ancak durağan dönemlerde faiz için farklılıklar bulunmaktadır.
<b>ARMA ve Yapay Sinir Ağları Modellerinin karşılaştırmalı analizi: Türkiye örneği</b>	İnsel, Sualp ve Karakaş (2010)	Türkiye	Arma, Sinir Ağı	Döviz Kuru, Enflasyon, Faiz, Reel Gayri Safi Milli Hasıla	Her iki modelde başarılı bulunmuş.
<b>Arıma Modelleri İle Enflasyon Tahminlemesi</b>	Meçik ve Karabacak (2011)	Türkiye	SARIMA, ARIMA	2003-2011 Tüfe serisi	ARIMA modelinin enflasyonu tahmin etmede daha başarılı olduğu görülmektedir.
<b>Neural network models for inflation forecasting: an appraisal</b>	Choudhary ve Haider (2012)	28 OECD ülkesi	Yapay sinir ağı, AR	Tüfe	Yapay sinir ağı modellerinin kısa dönemde enflasyon tahmin etmede daha başarılı olduğu çalışma sonucunda belirtilmiştir.
<b>Box-Jenkins ve Yapay Sinir Ağı Modelleri ile Enflasyon Tahmini</b>	Akdağ ve Yiğit (2016)	Türkiye	ARIMA yöntemi ile yapay sinir ağı	Ocak 2004-Aralık2013 yıllık Tüfe	ARIMA modelinin, yapay sinir ağı modeline kıyasla daha iyi performans gösterdiği görülmektedir.
<b>Inflation forecasting using machine learning methods</b>	Baybuza (2018)	Rusya	Makine Öğrenme	Şubat 2002-Ocak 2016 Tüfe	Rastgele orman modelinin ve Boosting modelinin enflasyon tahmininde daha iyi sonuç gösterdiğini ortaya koymaktadır.

<b>A comparison of time series and machine learning models for inflation forecasting: empirical evidence from the USA.</b>	Ülke, Şahin ve Subaşı (2018)	ABD	Makine Öğrenme	1984-2014 4 Enflasyon göstergesi	Makine öğrenimi modelinin kişisel tüketim harcaması enflasyon tahmini için zaman serisi modellerinden üstün geldiği, TÜFE için ise zaman serisi modelinin daha iyi olduğu sonucuna ulaşılmıştır.
<b>Forecasting Inflation in a Data-Rich Environment: The Benefits of Machine Learning Methods</b>	Medeiros, Vasconcelos, Veiga ve Zilberman (2019)	ABD	Makine Öğrenme	Ocak 1960-Aralık 2015 122 Değişken	Makine öğrenme ile enflasyon tahminin mümkün olduğu kanıtlanan çalışmada, LASSO ve Random Forest yöntemleri diğer yöntemlere göre daha güçlü sonuçlar vermektedir.
<b>Machine learning methods for inflation forecasting in Brazil: New contenders versus classical models</b>	Araujo ve Gagliano (2023)	Brezilya	Makine Öğrenme	Tüfe 12 Aylık Enflasyon	Makine öğrenimi yöntemi diğer yöntemlere göre daha isabetli tahminler yapsa da yorumlamadaki zorluklar nedeni ile hibrit yöntemler önerilmekte.

**Kaynak:** Yazar tarafından derlenmiştir.

Literatürde yer alan çalışmaların bulunduğu tablo incelendiğinde, yapılan çalışmalarda makine öğrenme metodlarından yapay sinir ağı modelinin daha fazla kullanıldığı görülmektedir.

### Yöntem

Çalışmanın bu bölümünde, uygulanacak makine öğrenme yöntemleri ve açıklamalarına yer verilmiştir. Çalışma kapsamında bir veri seti hazırlanmış olup makine öğrenme yöntemleri kullanılarak analiz edilmiştir.

#### Makine Öğrenme

Öğrenme görevlerindeki farklılıklardan bağımsız olarak makine öğrenimi teknikleri genellikle insan ırkının var olduğu çağlar boyunca biriktirdiği bilgi ve deneyime dayalı olarak doğayı taklit etmeye çalışmaktadır. Makine öğrenimi tekniklerinden bazıları, insan beyni işlevinin nörolojik çalışmalarıyla, bazıları insan evrimini dikte eden süreçlerle, bazıları insanın bilgi edinme ve muhakemesine ilişkin matematiksel teoriyle ve bazıları da insan işbirlikçi davranışının arkasındaki sosyolojik teoriyle hazırlanmıştır (Min, 2009, s. 16). Mevcut verilerden matematiksel ve istatistiksel yöntemler kullanarak çıkarımlarda bulunan, bu çıkarımlar ile bilinmeyene ilişkin tahminlerde bulunan algoritma ve modellemeden oluşan yapay zekanın bir alt dalı, makine öğrenmesidir (Akay, 2018, s. 45).

Günümüzde standart makine öğrenme algoritmalarının sosyal bilgiler alanında öngörü problemlerinde yaygın olarak kullanıldığı görülmektedir. Makine öğrenmesi, çok sayıda değişkenin bulunduğu büyük veri setlerinde, yüksek dereceli ilişkileri ölçümlemede kolayca




uygulanabilmekte, doğrusal olmayan ilişkileri açıkça belirtmeden tahmin etmesi açısından avantaj sağlamaktadır (Taştan, 2022, s. 136). Yöntemlerine bağlı olarak makine öğrenme birkaç kategoriye ayrışabilir (Min, 2009, s. 16):

1. Kavram öğrenimi; tümevarımlı bir öğrenme sürecinin ardından gelecekteki karar verme süreçleriyle ilgili kavramları doğru bir şekilde tanımak ve oluşturmak için tasarlanmıştır.
2. Karar ağacı öğrenimi; belirli özellikler için değerlerini test ederek ve ardından bir karar ağacı oluşturarak tüm nesnelere sınıflandırmayı amaçlamaktadır.
3. Algılayıcı öğrenme; algılayıcı adı verilen ağın tek bir katmanını kullanarak yararlı bilgi edinmeyi, hatayı azaltmayı ve karar problemlerini çözmeyi hedeflemektedir.
4. Bayesçi öğrenme; bilgisayarın olasılık fonksiyonlarının temsillerini öğrenmesi için eğitilmektedir.
5. Pekiştirmeli öğrenme; ödül biçiminde sürekli geri bildirimde bulunarak bilgisayarın yüksek seviyelerde performans göstermesi için eğitilmesidir.

Makine öğrenme algoritmalarında modelin karmaşıklığı çoğunlukla ayarlanma parametreleri veya hiperparametre diye adlandırılan modele özgü sabitlerin bir fonksiyonudur. Örneğin en yakın komşu algoritmasında hesaba katılacak gözlem sayısı  $K$ , karar ağacında ağacın büyüklüğü, rastgele ormanda değişken sayısı, LASSO'da ceza terimi ve boosting yönteminde öğrenme hızı ve iterasyon sayısı verilebilir. Nedensel etkilerin tahminlemede sapmanın azaltılması veya giderilmesi amacıyla ağaç bazlı makine öğrenme algoritmaları geliştirilmiştir (Taştan, 2022, s. 122- 136).

### Rastgele Orman

İlk olarak Breiman (2001) tarafından tanıtılan Rastgele Orman (RF) algoritması, değişken ile ilişki biçimleri hakkında önceden herhangi bir varsayımda bulunmadan, çeşitli öngörücü değişken türlerine dayalı tahmin kuralları oluşturmak için standart bir parametrik olmayan sınıflandırma ve regresyon aracına dönüşmüştür. Rastgele Orman sınıflandırıcısı, eğitim kümesi ve değişkenlerinin rastgele seçilmiş bir alt kümesini kullanarak birden çok karar ağacı üreten bir topluluk sınıflandırıcısıdır. RF, kullanıcı tarafından ayarlanması gereken birkaç hiper parametreye sahiptir; bu parametreler, her ağaç için rastgele çizilen gözlem sayısı ve bunların değiştirilerek veya değiştirilmeden çizilip çizilmediği, her bir bölme için rastgele çizilen değişkenlerin sayısı, bölme kuralı, bir düğümün içermesi gereken minimum örnek sayısı ve ağaç sayısıdır (Probst vd., 2019, s. 1; Belgiu ve Dragut, 2016, s. 24).




Şekil 2: Random Forest Algoritması

Kaynak: Tafralı, 2022.

Şekilde gösterildiği gibi rastgele orman birden fazla karar ağacı tarafından oluşan bir algoritmadır. Performans değerlendirme kapsamında, veri setinin 2/3 'ü kullanılır. Veri setinin dışlanan bölümü tarafından performans değerlendirmesi yapılmaktadır.

### Karar Ağacı

Karar ağacı 20. yüzyılda elektronik biçimde uygulanan ilk istatistiksel algoritmalar arasında yer alan, genel amaçlı tahmin ve sınıflandırma mekanizmalarıdır. Karar ağacının temel özelliği, bölümler oluşturmak için ilişkili giriş alanlarının veya tahmincilerin değerlerine göre bir hedef veri alanının yenilenen bir alt kümesidir ve ağacın herhangi bir düzeyinde aşamalı olarak benzer düğüm içi hedef değerler ve aşamalı olarak farklı düğümler arası değerler içeren ilişkili alt veri alt kümeleri yapraklar veya düğümler olarak adlandırılmaktadır (Ville, 2013, s. 448).



Şekil 3: Karar ağacı yapısı

**Kaynak:** Kavzoğlu ve Çölkesen, 2010, s. 40.

Karar ağacı modelleri, gözetimli öğrenme modellerinin yanında, sınıflandırma ve regresyon modellerini de kullanmaktadır. Karar ağacı modelinde meydana gelen dallar sayesinde analize konu olan veri bütün modele işlenmiş olur. Diğer modellerin aksine hızlı sonuç vermekte ve veriler arasındaki etkileşimin yapısal olarak gösteriliyor olması modelin tercih edilmesine neden olmaktadır (Sel, 2020, s. 90).

### Yapay Sinir Ağları


İnsan beyninin en öncelikli özelliği öğrenmedir. Yapay sinir ağları, öğrenme fonksiyonunu pekiştiren, öğrenme fonksiyonunu örnekler yardımıyla gerçekleştiren bir bilgisayar sistemidir. Yapay sinir ağları, birbirlerine bağlı hücrelerden oluşmaktadır (Öztemel, 2003). Yapay sinir ağ modelleri tek katmanlı, çok katmanlı algılayıcı, ileri beslemeli ve geri beslemeli yapay sinir ağları olarak dört grupta incelenebilir.

- **Tek katmanlı algılayıcı:** Yapay sinir ağ çalışmaları, tek katmanlı algılayıcı ile başlamaktadır. Tek katmanlı algılayıcının en önemli özelliği, problemi bir doğru ve bir düzlem ile sınıflandırmasıdır. Yalnızca girdi ve çıktıdan oluşan tek katmanlı algılayıcılarda sınıflar 1 veya -1 ile gösterilmektedir. Tek katmanlı algılayıcının en önemli sorunu doğrusal olmayan olayları öğrenmemeleridir (Öztemel, 2003).
- **Çok katmanlı algılayıcı:** Çok katmanlı algılayıcı, girdi katmanı, ara katmanlar ve çıktı katmanı olmak üzere üç katmandan oluşmaktadır. Girdi ve Çıktı katmanları kaç adet proses elemanın gerekliliğine problem üzerinden karar verirken, Gizli katmanda böyle bir yöntem bulunmamakta, deneme ve yanılma yoluyla bulunmaktadır (Öztemel, 2003):

**Girdi Katmanı:** Herhangi bir bilgi işlemenin olmadığı bu katmanda dış dünyadan bilgiler toplanır.

**Gizli Katman:** Girdi katmanından alınan bilgilerin işlendiği, birçok problemin çözüldüğü katmandır.

**Çıktı katmanı:** Ara katmandan aldığı bilgileri işleyerek ağın ürettiği çıktıya ulaşır.




**Şekil 4:** Çok katmanlı algılayıcı

**Kaynak:** Konakoğlu, 2020, s. 704.

Bilgiler girdi katmanında toplanıp gizli katmana gönderilmekte, daha sonra çıktı katmanında işlenen bilgiler üzerinden sonuca ulaşılmaktadır.

➤ **İleri beslemeli yapay sinir ağları:**




**Şekil 5:** İleri beslemeli yapay sinir ağ

İleri beslemeli modelde, nöronlar giriş ve çıkış arası düzenli katmanlar hâindedir. Bir katmandan yalnızca takibindeki katmana geçiş izni bulunmaktadır. Girdi katmanından alınan bilgiler, değişikliğe uğramadan gizli katmana iletilir, daha sonra çıktı katmanından geçerek raporlanmaktadır (Öztürk ve Şahin, 2018, s. 31).

**Kaynak:** Öztürk ve Şahin, 2018, s. 31

➤ **Geri beslemeli yapay sinir ağları:**



**Şekil 6:** Geri beslemeli yapay sinir ağ modeli

**Kaynak:** Gönül, Ulu, Bucak ve Bilir, 2015, s. 107

Geri beslemeli yapay sinir ağlarında, nöronlar kendi aralarında sinyal gönderimini geri besleme olarak yapmaktadır, sinyal iletimi ileri ve geri şeklinde olarak iki yönlüdür ve sistemde bir çıkış sinyali, giriş ve çıkışları dinamik biçimde kontrol edebilmektedir (Gönül vd., 2015, s. 106).

### Bulgular

Makine öğrenmesinin en önemli amacı gerçek ile tahmin arasındaki farkın toplamının en aza indirgenmesidir. Bunun için de verilerin algoritmalar hazırlanması, farklı ölçeklerdeki verilerinde standartlaştırılması gerekmektedir. Bu çalışmada veriler 0 ile 1 arasında değerlere çevrilerek algortmada kullanılmıştır. Verilerin %20'si test ve %80'i eğitim için bölünmüş ve her algoritmamız Mutlak Ortalama Hata Yüzde Oranı (MOYH) ile test verilerini ölçmlemiştir. MOHY değeri hesaplanırken makine öğrenme algoritmalarının oluşturduğu çıktı değerle gerçek değer arasındaki fark hesaplanır. Bu farkın mutlak değeri alınıp gerçek değere bölünerek bağıl değer bulunur. Yüz ile çarpılarak hatanın yüzde değerine ulaşılır. Gerçek değerın sıfır olmadığı durumlarda kullanılması gerekmektedir. Denklem 1'de formül ile gösterilmiştir.

$$MOYH = \frac{100}{n} \sum_j^n \frac{e_j}{A_j} \quad (1)$$

Tahminleme çalışması için öznitelikler belirlenmiştir. Bu özniteliklerin seçiminde literatürden faydalanılmış ve korelasyonun az olduğu düşünülen öznitelikler veri kümesine dahil edilmiştir. Veriler 2008 ile 2023 tarihleri arasında 15 yıllık olarak 3 aylık bazda derlenmiştir. Kullanılan öznitelikler ve kaynakları Tablo 2'de yer almaktadır. Öğrenme algoritmaları ve grafiksel gösterimler için Python programlama dilinden faydalanılmıştır.


**Tablo 2:** Öznitelik Tanımları ve Kaynak

• Öznitelik	• Öznitelik Tanımları	• Kaynak
• BRENT	• Varil Başına Düşen Brent Petrol Fiyatı	• TCMB

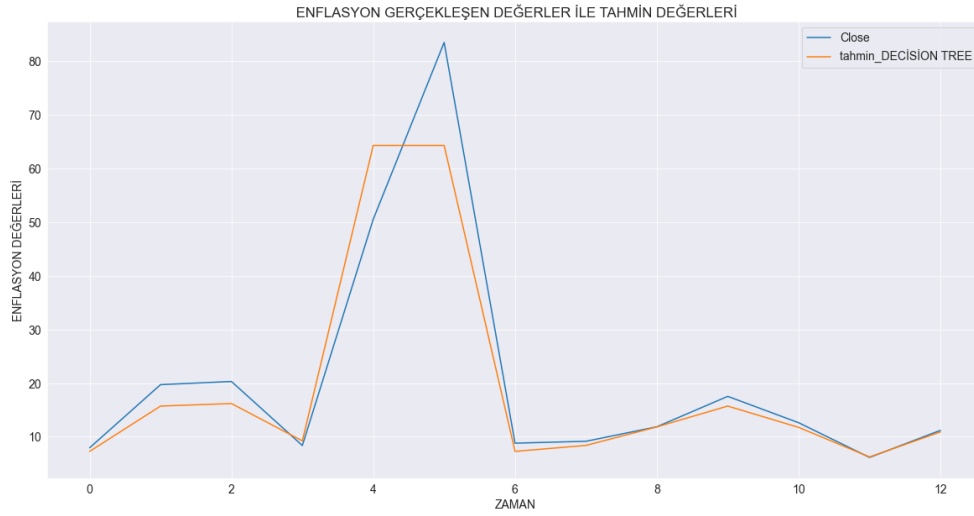
• <b>RF</b>	• Reeskont işlemlerinde uygulanan avans faiz Oranı	• TCMB
• <b>M2</b>	• Para Arzı	• TCMB
• <b>TÜFE</b>	• Tüketici Fiyat Endeksi (Enflasyon)	• TCMB
• <b>VG</b>	• Vergi Gelirleri	• TCMB
• <b>GBG</b>	• Genel Bütçe Gelirleri	• TCMB
• <b>PF</b>	• Politika Faizi	• TCMB
• <b>USD/TRY</b>	• Amerikan Doları Türk Lirası Paritesi	• TCMB
• <b>GSYİH</b>	• Gayri Safi Yurt İçi Hasıla	• TCMB

Tahmin edilmesi planlanan Enflasyon değerinin değişimleri Grafik 2’de gösterilmektedir.

**Grafik 2:** Hedef Veriye Ait Grafik



Bu çalışmada, 3 farklı makine öğrenimi algoritması kullanılmış olup farklı tahmin hata oranları elde edilmiştir. En iyi sonuçlar MOYH kriterine göre karar ağaçları %83,1, rastgele orman ağacı %82,79 ve çok katmanlı algılayıcılar %77,04 başarı oranında tahminlemede bulunmuşlardır.

**Grafik 3:** Tüketici Fiyat Endeksi Gerçek Değerler ile Tahmin Değerlerinin Grafiği

Karar ağacı algoritmasında, USD/TRY özniteliğinin etkisi %86,5 ile en çok etkileyen öznitelik olmuş, sırasıyla en çok etkileyen öznitelik ise %6,2 ile GSYİH, %3,3 ile GBG ve %2,7 ile Brent petrol olmuştur. Diğer özniteliklerin toplam etkisi %1,3 olarak gerçekleşmiştir. MOYH başarı ölçütüne göre en başarılı sonuca karar ağacı algoritması %83,1 olmuştur. Grafik 2’de tüketici fiyat endeksi değerleri ile (mavi renk) tahmin değerleri (kırmızı renk) gösterilmektedir.

### Sonuç

2020 yılında ortaya çıkan salgın sonrasında hükümetler tarafından uygulanan politikalar talepte artışa neden olmuş, talep artışı ise arz problemine neden olmuştur. Birçok ülkede enflasyonda artış görülmeye başlanmıştır. Enflasyon, durgunluğa ve dolayısıyla refah kaybına neden olmaktadır. Enflasyon tahminlemesinin doğru bir şekilde yapılması, ekonomik birimler ve alınacak ekonomik kararlar açısından önemlidir. Özellikle Türkiye gibi kırılgan ekonomiye sahip ve kronikleşen enflasyon sorunu olan ülkeler açısından doğru tahminleme ile enflasyonla ilgili belirsizliğin azaltılması sağlanacağı, bu durumun ülke ekonomisine olumlu bir şekilde yansıtacağı düşünülmektedir.

Türkiye’de yaşanan enflasyonist sürecin ortadan kalkması için enflasyonun parasal bir olgu olduğunun benimsenmesi ve parasal genişlemenin sonlandırılması gerektiğini savunan görüşler bulunmaktadır. Söz konusu görüşün aksine 1980’li yıllardan sonra uygulanan neoliberal kuralların enflasyonu parasal araçlarla çözmeye çalıştığının ancak başarısız olduğunu savunan görüşler de bulunmaktadır (Kartal, 2011, s. 78). Bu bağlamda çalışmada, sözü geçen iki farklı görüşün bir anlamda sınamasını yapmak üzere diğer bir değişle para ve maliye politikaları araçlarının enflasyon üzerindeki etkilerini belirlemek ve en doğru enflasyon oranını tahmin eden yöntemin bulunması hedeflenmiştir. Analiz dahilinde kullanılan değişkenlerden vergi gelirleri, genel bütçe gelirleri gibi değişkenler maliye politikasını temsil ederken faiz ve para arzı göstergeleri para politikasını temsil etmektedir. Diğer yandan enflasyonun türüne göre uygulanabilecek alternatif politikalar farklılaştığından maliyet enflasyonunu temsilen Brent petrol ve döviz kuru göstergeleri kullanılmıştır. Tahminlemeyi yapmak üzere ise üç farklı makine öğrenme algoritması kullanılmış olup bunlar karar ağacı, rastgele orman ve çok katmanlı algılayıcıdır. Analiz bulguları %83,1 oranı ile en iyi sonucu veren makine öğrenme algoritmasının karar ağacı algoritması olduğunu gösterirken, diğer yöntemlerden rastgele orman %82,79 ve çok katmanlı algılayıcı %77,04 oranında başarılı tahminleme yapmıştır. Yine karar ağacı algoritmasına göre makroekonomik özniteliklerden



özellikle kurun %86,5 oranı ile en etkili öznitelik olduğu tespit edilmiştir. GSYİH etkisi %6,2, GBG %3,3, BRENT %2,7 ve diğer özniteliklerin %1,3 etkisinin olduğu görülmektedir. Bu bağlamda enflasyonu en başarılı şekilde tahmin etmede kullanılan özneliğin dolar kuru ve brent petrol olarak bulunduğu saptanmıştır. Benzer şekilde Bilgin (2023) çalışmasında, petrol fiyatları ve dolar ile enflasyon arasında tek yönlü nedensellik ilişkisi tespit etmiştir. Özellikle son dönemlerde enflasyonu hızlandıran olgu olarak enerji fiyatları ve döviz kurundaki artış görülmekte olup Türkiye ekonomisinin döviz kuruna karşı fazlaca hassas olduğu düşünülmektedir. Bu yapıyı tetikleyen önemli faktörlerden bir tanesi de cari açığın fazla olmasıdır. Türkiye'nin enerjide dışa bağımlı olması, enerji fiyatlarındaki artışın üretime maliyet olarak yansımaya neden olmaktadır.

Elde edilen bulgular, maliyet enflasyonunun varlığına işaret etmekte iken vergi kullanılarak uygulanan maliye politikasının para politikası uygulamalarına kıyasla daha etkin olduğunu göstermektedir. Diğer yandan ekonomik büyümenin enflasyon tahminlemedeki etkisi talep enflasyonu ile açıklanabilmekte iken 2018-2020 yıllarında arz ve talep enflasyonları bir arada görülmüştür. Çalışmada elde edilen başarılı enflasyon tahminlemede ülke Merkez bankaları için önemli olduğu düşünülmektedir. Keza etkili para politikası, doğru enflasyon tahminlerine bağlı olup yanlış tahminleme durumunda politika duruşu gerekenden daha sıkı veya daha gevşek olacaktır. Bu durumda ise sistematik tahmin hataları merkez bankalarının güvenilirliğini ve enflasyon beklentilerini tutturma yeteneklerini zayıflatabilmektedir.

### Kaynakça

- Akay, E. Ç. (2018). Ekonometride yeni bir ufuk: Büyük veri ve makine öğrenmesi. *Sosyal Bilimler Araştırma Dergisi*, 7(2), 41-53.
- Akdağ, M., Yiğit, V. (2016). Box-Jenkins ve yapay sinir ağı modelleri ile enflasyon tahmini. *Atatürk Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 30 (2), 0-0. Retrieved From <https://Dergipark.Org.Tr/En/Pub/Atauniiibd/Issue/29907/322094>
- Araujo, GS., Gaglianone, WP (2023). Brezilya'da enflasyon tahmini için makine öğrenimi yöntemleri: Klasik modellere karşı yeni yarışmacılar. *Latin Amerika Merkez Bankacılığı Dergisi*, 4 (2), 100087.
- Başçı, E., Kara, H. (2011). Finansal istikrar ve para politikası. *İktisat İşletme ve Finans*, 26(302), 9-25.
- Baybuza, I. (2018). Inflation forecasting using machine learning methods. *Russian Journal of Money and Finance*, 77(4), 42-59.
- Belgiu, M., Drăguț, L. (2016). Random forest in remote sensing: A review of applications and future directions. *ISPRS journal of photogrammetry and remote sensing*, 114, 24-31.
- Bikker, J. A. (1998). Inflation forecasting for aggregates of the EU-7 and EU-14 with Bayesian VAR models. *Journal of Forecasting*, 17(2), 147-165.
- Bilgin, M. S. (2023). Enerji (petrol) fiyatları ve döviz kurunun enflasyon üzerindeki etkisi, Türkiye örneği: Toda-Yamamoto Modeli ile ampirik bir analiz (2014-2022). *Sakarya İktisat Dergisi*, 12(1), 1-14.
- Birinci, Y. (1989). Enflasyon, para politikası ve stratejileri. *İstanbul Üniversitesi İktisat Fakültesi Mecmuası*, 47(1-4).
- Bozkurt, C., Göğül, P. K. (2010). Para ve maliye politikalarının koordinasyonu. *Akademik Araştırmalar ve Çalışmalar Dergisi (AKAD)*, 2(2), 27-44.
- Bölükbaş, M. (2018). Para ve maliye politikalarının enflasyon üzerindeki etkisi: BRIC ülkeleri ve Türkiye için bir Bootstrap Panel Granger Nedensellik Analizi. *Bankacılar Dergisi*, 105, 47-62.
- Çetintaş, H. (2003). Türkiye'de enflasyon ve büyüme. *İstanbul Üniversitesi Siyasal Bilgiler Fakültesi Dergisi*, (28).

- Choudhary, M. A., Haider, A. (2012). Neural network models for inflation forecasting: An appraisal. *Applied Economics*, 44(20), 2631–2635.
- Fritzer, F., Moser, G., Scharler, J. (2002). *Forecasting Austrian HICP and its components using VAR and ARIMA models* (No. 73). Working paper.
- Gagliano, L. (2023). *Seizure prediction: From patient perspectives to advanced signal processing and machine learning algorithms*. (Doctoral dissertation, Polytechnique Montréal).
- Gönül Y., Ulu Ş., Bucak A., Bilir A. (2015). Yapay sinir ağları ve klinik araştırmalarda kullanımı. *Genel Tıp Dergisi*. 25(3), 104-111.
- Gürkaynak, R. S., Kısacıkoglu, B., Lee, S. S., Şimşek, A. (2022). Türkiye'nin enflasyon tercihleri. A. S. Akat and S. Gürsel (Eds.), *Çıkmaz yol: Düünden yarına türkiye ekonomisi*, (pp. 123-148) içinde. İstanbul: İstanbul Bilgi Üniversitesi Yayınları.
- İnsel, A., Sualp, M. N., Karakaş, M. (2010). Arma ve yapay sinir ağları modellerinin karşılaştırmalı analizi: Türkiye örneği. *İktisat İşletme ve Finans*, 25(290), 35-64.
- Kartal, F. (2011). Türkiye'de enflasyon hedeflemesi stratejisi ve para politikasının görünümü. *Maliye ve Finans Yazıları*, 1 (91), 77-100.
- Kavzoğlu, T., Çölkesen, İ. (2010). Karar ağaçları ile uydu görüntülerinin sınıflandırılması. *Harita Teknolojileri Elektronik Dergisi*, 2(1), 36-45.
- Kibritçioglu, A. (2002). "Causes of inflation in Turkey: A literature survey with special reference to theories of inflation". Forthcoming in: *Inflation and Disinflation in Turkey*, (ed. by Kibritçioglu, A., L. Rittenberg, and F. Selçuk). Aldershot: Ashgate, pp. 43-76.
- Konakoglu, B. (2020). Çok katmanlı algılayıcı yapay sinir ağı ile jeodezik elipsoidal koordinatların ( $\varphi$ ,  $\lambda$ ,  $h$ ) 3 boyutlu global kartezyen koordinatlara ( $X$ ,  $Y$ ,  $Z$ ) dönüşümü. *Gümüşhane Üniversitesi Fen Bilimleri Dergisi*, 10(3), 702-710.
- Koop, G., Korobilis, D. (2012). Forecasting inflation using dynamic model averaging. *International Economic Review*, 53(3), 867–886.
- He, Q., Shen, H., Tong, Z. (2012). Investigation of inflation forecasting. *Applied Mathematics and Information Sciences*, 6(3), 649-655.
- Meçik, O., Karabacak, M. (2011). Arıma modelleri ile enflasyon tahminlemesi: Türkiye uygulaması. *Sosyal Ekonomik Araştırmalar Dergisi*, 11 (22), 177-198. Retrieved From <https://Dergipark.Org.Tr/Tr/Pub/Susead/Issue/28413/302352>
- Medeiros, M. C., Vasconcelos, G. F., Veiga, Á., & Zilberman, E. (2019). Forecasting inflation in a data-rich environment: the benefits of machine learning methods. *Journal of Business & Economic Statistics*, 39(1), 98-119.
- Medeiros, M. C., Vasconcelos, G. F., 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.
- Min, H. (2009). Artificial intelligence in supply chain management: Theory and applications. *International Journal of Logistics: Research and Applications*, 13(1), 13-39.
- Mitra, D., Rashid, M. (1996). Comparative accuracy of forecasts of inflation: A Canadian Study. *Applied Economics*, 28(12), 1633-1637.
- Österholm, P. (2008). Can forecasting performance be improved by considering the steady state? An application to Swedish inflation and interest rate. *Journal of Forecasting*, 27(1), 41-51.
- Öztemel, E. (2003). *Yapay sinir ağları*. İstanbul: Papatya.
- Öztürk, K., Şahin, M. E. (2018). Yapay sinir ağları ve Yapay Zekâ'ya genel bir bakış. *Takvim-i Zekayi*, 6 (2), 25-36. Retrieved from <https://dergipark.org.tr/tr/pub/takvim/issue/40063/427526>

- 
- Petek, A., Çelik, A. (2017). Türkiye’de enflasyon, döviz kuru, ihracat ve ithalat arasındaki ilişkinin ekonometrik analizi (1990-2015). *Finans Politik ve Ekonomik Yorumlar*, (626), 69-87.
- Probst, P., Wright, M. N., Boulesteix, A. L. (2019). Hyperparameters and tuning strategies for random forest. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 9(3), e1301.
- Sel, A. (2020). Pandemi sürecinde altın fiyatları ile kripto para ilişkisinin makine öğrenme metotları ile incelenmesi, *İstatistik ve Uygulamalı Bilimler Dergisi*, 2(1), pp. 85-98.
- Tafralı, S. (2022). “Yapay Öğrenme: Rastgele Orman.” E. T. 17.07.2023 <https://medium.com/machine-learning-t%C3%BCrkiye/yapay-%C3%B6%C4%9Frenme-rastgele-orman-e8debd886e7>
- Taştan, H. (2022). Ekonometri ve makine öğrenmesi etkileşimi üzerine. *Ekonomi-tek*, 11 (2), 107-149. Retrieved from <https://dergipark.org.tr/en/pub/ekonomitek/issue/72833/1171361>
- Tay Bayramoğlu, A., Öztürk, Z. (2017). Arıma ve gri sistem modelleri ile enflasyon tahmini. *Itobiad: Journal Of The Human & Social Science Researches*, 6(2).
- The World Bank, World Development Indicators (2023), <https://databank.worldbank.org/source/world-development-indicators/preview/on>
- Ülke, V., Sahin, A., Subasi, A. (2018). A comparison of time series and machine learning models for inflation forecasting: empirical evidence from the USA. *Neural Computing and Applications*, 30, 1519-1527.
- Ville, B. (2013). *Decision trees*. *Wiley Interdisciplinary Reviews: Computational statistics*, 5(6), 448–455. doi:10.1002/wics.1278
-