

TS-FIS Yöntemi Bulanık Çıkarım Sistemi ile Enflasyon Öngörüsü: Türkiye Örneği

Mehmet Akif KARA^{1*} 

Öz

Ekonomik krizlerin gün geçtikçe etkilerinin daha fazla hissedildiği dönemlerde sıkça konuşulan kavramlardan birisi de enflasyondur. Enflasyon fiyatların genel düzeyindeki artış olarak tanımlanmaktadır. Enflasyon öngörülere krizle mücadele ve krizin etkilerinin azaltılması açısından önemli bir süreçtir. Bu öngörülerin gerçeğe daha yakın elde edilmeleri kararların da doğru verilmesine fayda sağlamaktadır. Türkiye Cumhuriyeti Merkez Bankası her yılın belirli dönemlerinde yayınladığı enflasyon raporlarında enflasyon beklentisi anketi sonuçlarına da yer verilmektedir. Bu çalışmada veri seti olarak 2003-2023 yılları arasında Türkiye Cumhuriyeti Merkez Bankası TÜFE oranları kullanılmıştır. Çalışmada yöntem olarak Yolcu, Eğrioğlu ve Baş (2018) tarafından önerilen TS-FIS yöntemi ile enflasyon tahmininde bulunmaktadır. Bulanık çıkarım sistemleri zaman serisi tahmini için yaygın olarak kullanılmaktadır. Klasik bulanık çıkarım sistemlerinin makul bir tahmin performansı için çok fazla parametre tahmin etmesi gerekmektedir. Yolcu, Eğrioğlu ve Baş (2018) tarafından önerilen çıkarım sistemi ile daha iyi tahmin sonuçları üretildiği görülmektedir. Elde edilen sonuçlar klasik zaman serisi yöntemleri (ARIMA, Holt's, Naive) ile bulanık zaman serisi yöntemleri (Chen, 1996 ve Chen, 2002) ile karşılaştırılmıştır. Sonuç olarak TS-FIS yönteminin enflasyon öngörüsü problemi için en başarılı performansı ürettiği ortaya konulmuştur.

Anahtar Kelimeler: Bulanık zaman serisi, Öngörü, TS-FIS, Bulanık çıkarım sistemleri.

Inflation Forecasting With TS-FIS Method Fuzzy Inference System: The Case of Türkiye

Abstract

Inflation is one of the most frequently discussed concepts in times when the effects of economic crises are felt more and more. Inflation is defined as the increase in the general level of prices. Inflation forecasts are an important process in terms of combating the crisis and reducing the effects of the crisis. Obtaining these forecasts closer to reality helps to make the right decisions. The Central Bank of the Republic of Turkey includes the results of the inflation expectations survey in its inflation reports published at certain periods of each year. In this study, CPI rates of the Central Bank of the Republic of Turkey between 2003 and 2023 are used as the data set. As a method in the study, the TS-FIS method proposed by Yolcu, Eğrioğlu and Baş (2018) is used to forecast inflation. Fuzzy inference systems are widely used for time series forecasting. Classical fuzzy inference systems need to estimate too many parameters for a reasonable forecasting performance. The inference system proposed by Yolcu, Eğrioğlu and Baş (2018) produces better forecasting results. The results obtained are compared with classical time series methods (ARIMA, Holt's, Naive) and fuzzy time series methods (Chen, 1996 and Chen, 2002). As a result, it is revealed that the TS-FIS method produces the best performance for the inflation forecasting problem.

Keywords: Fuzzy time series, Forecasting, TS-FIS, Fuzzy inference systems.

¹Giresun Üniversitesi, İktisadi ve İdari Bilimler Fakültesi İşletme Bölümü, Giresun, Türkiye, akifkara28@gmail.com

*Sorumlu Yazar/Corresponding Author

Geliş/Received: 24.06.2024

Kabul/Accepted: 10.12.2024

Yayın/Published: 15.12.2024

1. Giriş

Kapitalizmin yaşadığı yapısal krizlerin “çevre ülkeler” için farklı sonuçlar ve etkiler ürettiği aşikârdır. Alan yazın incelendiğinde bu sonuçlara ilişkin farklı tespitlerin ve değerlendirmelerin yapıldığı görülmektedir. İktisat, finans ve siyaset bilimi gibi farklı disiplinlerin, farklı söylem setlerini kullanarak konuya ilişkin bilimsel tartışmalar yürüttüğü bilinmektedir (Aytürk, 2011; Erdem, 2011; Guttman, 2023; Kozanoğlu, 2011; Mehmetçik ve Taşkiran, 2023; Önder, 2011; Şiriner ve Doğru, 2008). Enflasyon oranları da ekonomik büyüme ve kriz ilişkisi açısından çeşitli çalışmalara konu olmaktadır (Aydın, 2023; Levine ve Zervos, 1993; Turan, 2011; Ünvar ve Alemdar, 2023; Zengin, 2023). Hem politika yapıcılarının hem de işletmelerin stratejik kararlar alabilmesi için öngörü önemli bir araç haline gelmektedir. Enflasyon, fiyatların genel seviyesindeki artış olarak tanımlanmaktadır (Samuelson ve Nordhaus, 1992: 587). Tabii ki burada kast edilen artış sadece belli mal ve hizmetlerde değil, fiyatlar genel seviyesinde olmaktadır. Enflasyonun yüksek olması paranın alım gücünü azaltmakta ve aynı zamanda yaşanan fiyat değişimlerinin anlaşılmasını zorlaştırmaktadır. Buradan hareketle enflasyon öngörüsü önemlidir. Çünkü enflasyon, bir ülkede gelir düzeyini, gelir dağılımını, yatırımcıların karar alma süreçlerini, istihdam düzeyini, işsizlik düzeyini, maaş ve ücretlerin durumu gibi birçok iktisadi kavramı doğrudan etkilemektedir.

Bu çalışmanın amacı da enflasyon öngörüsünde farklı yöntemleri kullanmak ve gerçeğe yakın sonuçları hangi yöntemin ürettiğini ortaya koyabilmektir. Bu bağlamda değerlendirildiğinde enflasyonun öngörülebilmesi kapitalizmin krizlerinin engellenmesi, aşılması ya da en az toplumsal etkiyle bertaraf edilebilmesi için önemli olmaktadır.

Yapay sinir ağları, bulanık zaman serisi, yüksek dereceli bulanık zaman serisi gibi geliş(tiril)mekte olan yöntemler öngörü problemlerinin çözümünde son yıllarda giderek artan bir biçimde kullanılmaktadır. Keza, zaman serileri problemleri için tahminler üretmek birçok bilim dalı ve reel problemler için önemli bir hedef olmaktadır. Bulanık çıkarım sistemleri zaman serisi tahmini için yaygın olarak kullanılmaktadır. Klasik bulanık çıkarım sistemlerinin makul bir tahmin performansı için çok fazla parametre tahmin etmesi gerekmektedir. Yolcu, Eğrioğlu ve Baş (2018) tarafından önerilen çıkarım sistemi ile daha iyi tahmin sonuçları üretildiği görülmektedir. Önerilen çıkarım sistemi kümeleme için bulanık c-ortalama yöntemini ve bulanık modelleme için pi-sigma sinir ağını kullanmaktadır. Ayrıca önerilen sistemde alt örnekleme blok bootstrap yöntemi lehine tahminler üretebilmektedir. Bu çalışma, Türkiye Cumhuriyet Merkez Bankası 2003:01- 2023:08 dönemi aylık TÜFE verileri kullanılarak bir model ve öngörü ortaya koyma amacı taşımaktadır. Çalışmada Yolcu, Eğrioğlu ve Baş (2018) tarafından önerilen bulanık çıkarım sistemi (TS-FIS) kullanılmaktadır. Çalışmanın uygulamaları MATLAB programı ile gerçekleştirilmiştir.

2. Literatür İncelemesi

Öngörü ve enflasyon öngörüsüne dair farklı yöntemlerin kullandığı çok sayıda çalışma yapılmıştır.

Uğurlu ve Saraçoğlu (2010) çalışmalarında TCMB 2003:01-2008:02 aylık verilerini kullanarak Türkiye enflasyonunun öngörüsünü araştırmıştır. Çalışmada, klasik zaman serisi yöntemlerinden Naive Model, Üssel Düzeltme Modeli ve ARIMA modeli kullanılmıştır. Bulgular neticesinde ARIMA modelinin uygulama döneminde diğer yöntemlere göre daha iyi performans gösterdiği ortaya koyulmuştur. Uslu vd. (2012) çalışmalarında yüksek dereceli bulanık zaman serisi yöntemi ile enflasyon öngörüsünde bulunmaktadır. Yüksek dereceli bulanık zaman serisi modellerinde ilişkilerin belirlenmesi yapay sinir ağları ile gerçekleştirilmektedir. Çalışmada, yüksek dereceli bulanık zaman serisi ile literatürde yer alan farklı bulanık zaman serisi yaklaşımları ile tüketici fiyat endeksi zaman serisi tahmin edilmiş ve TCMB enflasyon beklentisi anketi sonuçları ile karşılaştırılmıştır. Akdağ ve Yiğit (2016) gerçekleştirdikleri araştırmada Box Jenkins ve Yapay Sinir Ağları yöntemleriyle enflasyon verilerine ait zaman serisi analizi kullanmıştır. Çalışma sonucunda ARIMA modelinin Yapay Sinir Ağı modeline göre daha iyi performans sergilediği ortaya konulmuştur. Al Kadry, Massalesse ve Nur (2022) Endonezya verilerini kullanarak Modifiye Bulanık Zaman Serisi (FTS) Cheng yöntemini ile tahmin gerçekleştirmiştir. Çalışma sonucunda belirtilen yöntemin ister aralık ortalamasına dayalı isterse Sturges denklemi kullanılarak tahminlemede kullanılabileceği ortaya koyulmuştur. Hauenberger, Huber ve Klieber (2023) çalışmalarında doğrusal olmayan boyut azaltma tekniklerini kullanarak gerçek zamanlı enflasyon tahmini yapmıştır. Çalışmada ABD enflasyon verileri üzerinden sofistike boyut azaltma yöntemlerinin temel bileşenlere dayalı doğrusal yaklaşımlarla oldukça rekabetçi enflasyon tahminleri sağladığı vurgulanmaktadır. Almosava ve Andresen (2023) yaptıkları araştırmada enflasyonu verimli bir şekilde tahmin edebilmek ve tahmin performansını artırabilmek için özel bir Yapay Sinir Ağları türü olan tekrarlayan sinir ağını kullanmıştır. Amerika Birleşik Devletleri'ne ait aylık TÜFE oranlarının tek değişkenli tahminlerini hesaplamıştır. LSTM'nin (uzun kısa dönem hafızalı tekrarlayan sinir ağı) otoregresif model (AR), NN ve Markov-Switching modellerinden biraz daha iyi performans gösterdiği, mevsimsel otoregresif model SARIMA ile eşit sonuçlar ürettiği ortaya koyulmaktadır. Araujo ve Gaglianone (2023) makalelerinde Brezilya'da enflasyon tahminini iyileştirmek için makine öğrenmesi yöntemlerini kullanmıştır. Çalışmalarında makine öğrenmesi yöntemlerinin birçok durumda ortalama karesel hata açısından geleneksel ekonometrik modellerden daha iyi performans gösterdiği ifade edilmektedir. En iyi tahminler kümesi tahmin kombinasyonlarını, ağaç tabanlı yöntemleri (Rastgele orman ve xgboost gibi), başabaş enflasyonu ve ankete dayalı beklentileri içermektedir. Pierdzioch (2023) yayınlanan çalışmasında Almanya için büyüme ve enflasyon tahminlerinin etkinliğini yeniden incelemek için

basit bir bootstrap tabanlı etkinlik testi önermektedir. Bu test ile birlikte bir araştırmacının aday modeller kümesinden örneklem almasını gerektirmesi ve böylece karar problemini izlenebilir hale getirmesi açısından bu tür problemlerin çözümünde kolaylık sağlamaktadır. Theoharidis, Guillen ve Lopes (2023) gerçekleştirdikleri araştırmada enflasyonu tahmin etmek için Varyasyonel Otomatik Kodlayıcıları ve Evrişimli LSTM Ağlarını birleştiren hibrit bir derin öğrenme modeli önermektedir. ABD'ne ait 134 aylık zaman serisini kullanarak, önerdikleri modeli Ridge regresyonu, LASSO regresyonu, Rastgele ormanlar, Bayes yöntemleri, VECM ve çok katmanlı perceptron dâhil olmak üzere çeşitli popüler ekonometrik ve makine öğrenmesi yöntemleriyle karşılaştırmışlardır. Önerdikleri modelin tutarlılık ve örneklem dışı performans açısından diğer modellerden daha iyi performans gösterdiğini ortaya koymuşlardır.

3. TSFIS Yöntemi ve Algoritması

Bulanık teoriye dayalı tahminler elde etmek için literatürde birçok yöntem bulunmaktadır. Bulanık çıkarım sitemleri, bulanık fonksiyon yaklaşımları, bulanık regresyon ve bulanık zaman serisi yöntemleri birçok uygulamada yaygın olarak kullanılmaktadır. Bulanık çıkarım sistemleri ve bulanık fonksiyon yaklaşımları, kuralların sonuç parametreleri veya regresyon fonksiyonlarının parametreleri olan çok fazla parametre belirlemeyi gerektirmektedir. Ayrıca, tahmin problemi için tasarlanmamışlardır. Dolayısı ile gözlemlerin bağımlılığı göz ardı edilmektedir.

Bu çalışmada, Yolcu vd. (2018) tarafından TS-FIS literatüründe ilk defa tahminleme amacıyla tasarlanan ilk bulanık çıkarım sistemi olan yeni bir bulanık çıkarım sistemi uygulanmaktadır. TS-FIS, mevcut bulanık zaman serisi yöntemlerinden farklı olarak üyelik değerlerinin yanı sıra gerçek zaman serisi gözlemlerini de girdi olarak kullanmaktadır. Bulanık kümeler ve bu kümeler için gözlemlerin üyelik değerlerini elde etmek için FCM'den yararlanan bu yöntemde ayrıca, girdiler ve çıktılar arasındaki bulanık ilişkiler için bir model belirlemek üzere PS-NN'yi kullanmaktadır.

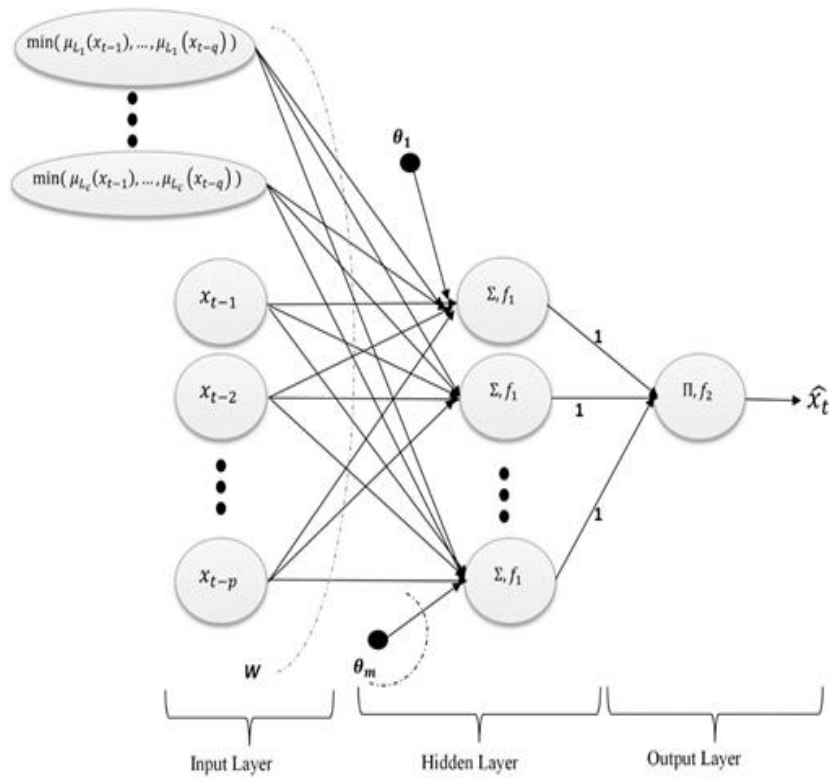
Yolcu vd.(2018) tarafından önerilen bu yöntem bulanık çıkarım sistemleri ve bulanık zaman serilerinden farklı olarak karar vericiye bootstrap örnekleri aracılığıyla olasılıksal tahminler sunmaktadır. Bunun katkısı ise yorumlanabilirlik, bilgi ve fayda içermesi açısından karar vericiler tarafından amaçlanan riskin daha az hale getirilmesidir. Bu bağlamda, TS-FIS'in çeşitli ayırt edici özellikleri Yolcu vd.(2018) tarafından şu şekilde belirtilmektedir:

- TS-FIS, zaman serisi tahmini amacıyla özgün olarak tasarlanmış ilk bulanık çıkarım sistemidir.
- TS-FIS, mevcut bulanık zaman serisi tahmin modellerinin aksine üyelik değerlerinin yanı sıra gerçek gözlemleri de girdi olarak kullanmaktadır.

- Çıktı olarak gerçek değerler üreten TS-FIS, herhangi bir bulanıklaştırma işlemine ihtiyaç duymamaktadır.
- SBB tarafından belirlenen alt örnekler aracılığıyla TS-FIS, aralık tahmini ve tahmin olasılıklarını içeren olasılıksal tahminler üretebilir.

3.1. Nokta Tahmini Elde Etme Süreci

PS-NN'nin girdileri üyelik değerleri ve gecikmeli değişkenler için gerçek gözlemlerdir. Sinir ağının çıktıları ise gerçek gözlemler için tahminlerdir. TS-FIS'in grafiksel gösterimi Şekil 1'te verilmiştir.



Şekil 1. TS-FIS'in grafiksel gösterimi.

TS-FIS'in ana algoritması Algoritma 1'de özetlenmiştir.

Algoritma 1. TS-FIS Ana Algoritması

Adım 1. pn, c_1, c_2 vb. gibi parametreler belirlenir. Bu parametreler aşağıdaki gibidir:

pn : sürünün parçacık sayısı

c_1 : Bilişsel katsayı

c_2 : Sosyal katsayı

$maxt$: Maksimum yineleme sayısı

w : Eylemsizlik ağırlığı

p : Üyelik değerleri kısmı için model derecesi

q : Gecikmeli değişkenler kısmı için model derecesi

m : PS-NN gizli tabaka birim sayısı

n_{test} : Test setinin uzunluğu

c : Bulanık küme sayısı

n : Gözlem sayısı

Adım 2. Zaman serilerinin eğitim veri seti için FCM kümeleme tekniği uygulanır. Daha sonra küme merkezleri ve eğitim verilerinin bu kümelere üyelik değeri elde edilir. Kümeler L_i , ($i = 1, 2, \dots, c$) ile temsil edilir FCM uygulandıktan sonra, üyelik değerleri ve küme merkezleri sırasıyla U matrisi ve V vektörü olarak saklanmaktadır ve aşağıda yer alan eşitlikler ile verilmektedir.

$$U = [u_{ij}] , i = 1, 2, \dots, c ; j = 1, 2, \dots, n - n_{test} \quad (1)$$

$$\eta = [\eta_1, \eta_2, \dots, \eta_c] \quad (2)$$

Burada U matrisinin elemanları zaman serisi gözlemlerinin L_i bulanık kümesine üyelik ($\mu_{L_i}(X_j)$) değerleridir.

Adım 3. PS-NN'nin girdileri (M) ve çıktıları (T) aşağıdaki gibi oluşturulmuştur:

$$M = [Uq, x_{t-1}, x_{t-2}, \dots, x_{t-p}] , t = p+, \dots, n - n_{test} \quad (3)$$

Burada Uq , p model sırasına göre minimum t -normu kullanılarak birleştirilmiş üyelik değeridir. $q = 2, p = 3, c = 3$ olsun, sabit bir t zaman noktası için gecikmeli değişkenlerin üyelik değerleri aşağıda verilmiştir:

$$[\mu_{L_1}(x_{t-1}), \mu_{L_2}(x_{t-1}), \mu_{L_3}(x_{t-1})] = [0.1, 0.2, 0.7]$$

$$[\mu_{L_1}(x_{t-2}), \mu_{L_2}(x_{t-2}), \mu_{L_3}(x_{t-2})] = [0.5, 0.1, 0.4]$$

Birleştirilmiş üyelik değerleri vektörü aşağıdaki gibi elde edilir:

$$Uq = [\min(0.1, 0.5), \min(0.2, 0.1), \min(0.7, 0.4)] = [0.1, 0.1, 0.4]$$

Uq matrisinin eleman sayısı c bulanık kümelerinin sayısıdır, Uq matrisinin her bir elemanı bir

L_i bulanık kümesi içi birleştirilmiş üyelik değeridir. TS-FIS'in çıktıları aşağıdaki gibi gösterilebilir:

$$T = [x_t], t = p + 1, \dots, n - n_{test} \quad (5)$$

Şekil 1'de verilen ağın çıktıları tahminlerdir.

Adım 4. Parçacıkların konumları ve hızları $Uniform(-1,1)$ dağılımından rastgele üretilir. P ve V matrislerinde saklanır:

$$P = [p_{ij}]; i = 1, 2, \dots, pn; j = 1, 2, \dots, d \quad (6)$$

$$V = [v_{ij}]; i = 1, 2, \dots, pn; j = 1, 2, \dots, d \quad (7)$$

Adım 5. Parçacıkların konum değerlerine göre, her parçacık için uygunluk fonksiyonu değerleri hesaplanır. Bir parçacığın pozisyonu PS-NN'nin girdilerine ve derecesine bağlıdır. PS-NN için girdi sayısı $(p + c)m + m$ 'dir. Bir parçacık için pozisyon sayısı $(p + c)m + m$ 'dir. Bir parçacığın pozisyonları PS-NN'nin ağırlıkları ve yanlarıdır. Bir parçacığın pi-sigma sinir ağındaki konumları Tablo 1'de verilmiştir. Uygunluk fonksiyonu, eğitim hedefleri için ortalama karesel hatanın köküdür (RMSE) ve formülü eşitlik 8'de verilmiştir.

Tablo 1. PS-NN'deki bir parçacığın konumları

$P_{i,1}$	$P_{i,2}$	$P_{i,m}$
$w_{1,1}$	$w_{1,2}$	$w_{1,m}$
$P_{i,m+1}$	$P_{i,m+2}$	$P_{i,2m}$
$w_{2,1}$	$w_{2,2}$	$w_{2,m}$
$P_{i,(p+c)(m-1)+1}$	$P_{i,(p+c)(m-1)+2}$	$P_{i,(p+c)m}$
$w_{(p+c),1}$	$w_{(p+c),2}$	$w_{(p+c),m}$
$P_{i,(p+c)m+1}$	$P_{i,(p+c)m+2}$	$P_{i,(p+c)m+m}$
θ_1	θ_2	θ_m

$$RMSE_i = \sqrt{\sum_{t=p+1}^{n-n_{test}} (x_t - \hat{x}_t)^2} \quad i = 1, \dots, pn \quad (8)$$

Adım 6. RMSE değerlerine göre P_{best} ve g_{best} oluşturulur. P_{best} ve g_{best} Eşitlik (9) ve (10)'da verilmiştir.

$$P_{best} = [Pb_{i,j}]; i = 1, 2, \dots, pn; j = 1, 2, \dots, d \quad (9)$$

$$g_{best} = [Pg_j]; j = 1, 2, \dots, d \quad (10)$$

Adım 7. P ve V kullanılarak iterasyonlar başlatılır.

Adım 7.1. Konumlar ve hızlar Eşitlik (11)'de verilen formül kullanılarak güncellenir.

$$v_{ij}^{k+1} = w \cdot v_{ij}^k + c_1 \cdot rand_1^k \cdot (Pbest_{ij}^k - P_{ij}^k) + c_2 \cdot rand_2^k \cdot (gbest_j^k - P_{ij}^k) \quad (11)$$

Bilişsel (c_1), sosyal (c_2) katsayıları ve w sırasıyla Eşitlik (12), (13), (14)'te verilen denklemler kullanılarak güncellenir (Shi, & Eberhart, 1999).

$$c_1 = (c_{1f} - c_{1i}) \frac{k}{maxt} + c_{1i} \quad (12)$$

$$c_2 = (c_{2f} - c_{2i}) \frac{k}{maxt} + c_{2i} \quad (13)$$

$$w = (w_2 - w_1) \frac{maxt-k}{maxt} + w_1 \quad (14)$$

Burada, $maxt$ iterasyon sayısını ve k geçerli iterasyon sayısını tanımlar.

(c_{1f}, c_{1i}) , (c_{2f}, c_{2i}) ve (w_1, w_2) sırasıyla c_1 , c_2 ve w için olası aralıklardır. Parçacığın yeni konumu Eşitlik (15) kullanılarak hesaplanır.

$$p_{i,j}^{k+1} = p_{i,j}^k + v_{i,j}^{k+1} \quad (15)$$

Adım 7.2. Parçacıkların güncellenmiş konumları kullanılarak RMSE değerleri hesaplanır.


Adım 7.3. RMSE değerlerine göre Pbest ve gbest güncellenir.

Adım 7.4. Durdurma kuralları kontrol edilir. Koşullar karşılanırsa Adım 8'e, aksi takdirde Adım 7.1'e gidin.

Adım 8. PS-NN'nin son konumları olarak son gbest kullanılarak, test verileri için ağıın çıktıları olarak tahminler elde edilir.


4. Bulgular

Çalışmanın veri setini TCMB 2003:01 – 2023:08 tarihleri aylık TÜFE oranlarından oluşturulan zaman serisidir. Şekil 2'te TÜFE oranları zaman serisi gösterilmektedir.



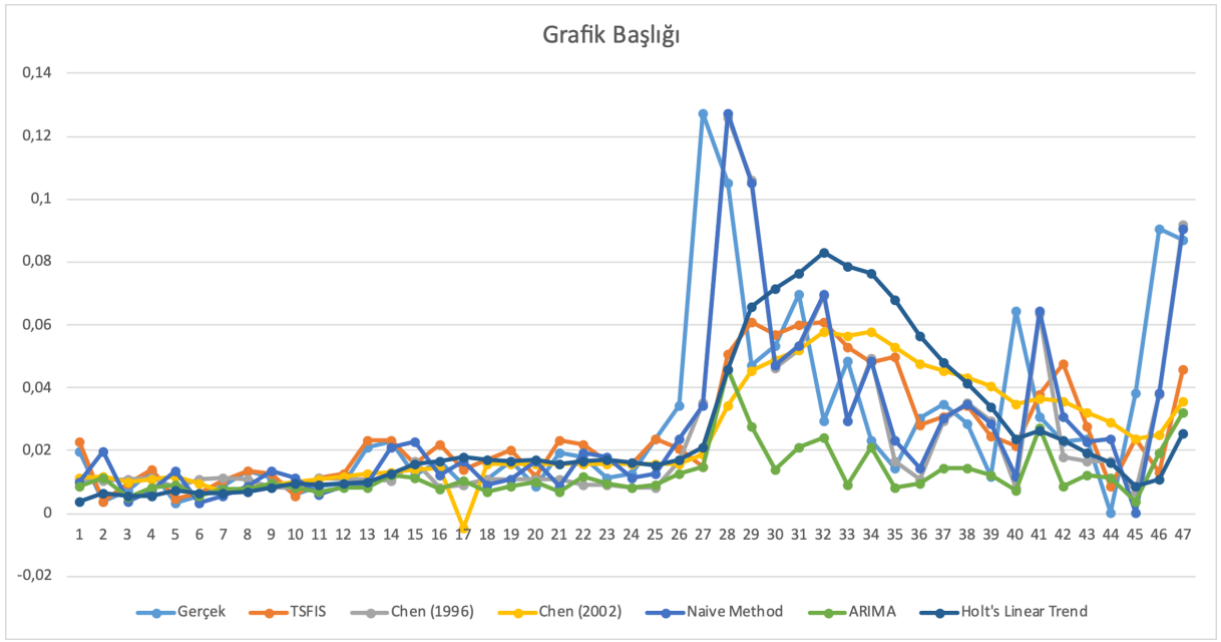
Şekil 2. TÜFE oranları zaman serisi (aylık/2003-2023)

Seri durağan olmadığı için varyansda durağanlık için logaritması ve düzeyde durağanlık için birinci dereceden farkı alınarak yeni bir seri oluşturulmuştur. Şekil 3’de logaritmik birinci fark serisinin grafiği gösterilmektedir.



Şekil 3. Logaritmik 1.fark serisi grafiği

Verinin çözümlenmesinde TS-FIS, Chen (1996), Chen (2002), Naive Metod, ARIMA ve Holt’s Linear Trend yöntemleri kullanılmıştır. Zaman serisinin son 47 gözlemi test kümesi olarak ayrılmış ve bir adım öngörü performansı araştırılmıştır. Yapılan analiz sonucunda tüm yöntemlere ilişkin tahmin değerleri elde edilmiştir. Gerçek değerler ve öngörülerin değerlerine Şekil 4’te yer verilmiştir.



Şekil 4. Yöntemlerin karşılaştırılması

TS-FIS, Chen (1996), Chen (2002), Naive Metod, ARIMA ve Holt's Linear Trend yöntemlerine ilişkin tahmin öngörülürü Tablo 2'de verilmiştir. Tablo 2'de ayrıca mutlak hata ortalaması (MAE), mutlak yüzdelik hata ortalaması (MAPE) ve mutlak yüzdelik hata medyanı (MdAPE) hata ölçütlerinin değerleri de gösterilmektedir.

Tablo 2. Aylık olarak hesaplanan öngörü değerleri

Test Verisi	TS-FIS	Chen (1996)	Chen (2002)	Naive Method	ARIMA	Holt's Linear Trend
0,01982	0,02267	0,01071	0,01118	0,00988	0,00853	0,00384
0,00380	0,00390	0,01052	0,01196	0,01982	0,01137	0,00636
0,00741	0,00975	0,01100	0,00988	0,00380	0,00490	0,00559
0,01342	0,01390	0,01112	0,01092	0,00741	0,00836	0,00566
0,00351	0,00448	0,00836	0,01170	0,01342	0,00924	0,00715
0,00570	0,00652	0,01100	0,00936	0,00351	0,00553	0,00651
0,00851	0,01051	0,01112	0,00703	0,00570	0,00756	0,00631
0,01353	0,01348	0,01071	0,00807	0,00851	0,00783	0,00674
0,01127	0,01256	0,00836	0,00910	0,01353	0,00946	0,00830

0,00582	0,00536	0,00836	0,01014	0,01127	0,00812	0,00937
0,00861	0,01145	0,01112	0,01092	0,00582	0,00671	0,00915
0,00969	0,01262	0,01071	0,01170	0,00861	0,00815	0,00941
0,02109	0,02312	0,01071	0,01248	0,00969	0,00803	0,00982
0,02272	0,02309	0,01052	0,01326	0,02109	0,01198	0,01269
0,01242	0,01592	0,01667	0,01404	0,02272	0,01118	0,01588
0,01668	0,02182	0,00836	0,01456	0,01242	0,00792	0,01660
0,00904	0,01383	0,00910	-0,00440	0,01668	0,01050	0,01792
0,01070	0,01711	0,01071	0,01560	0,00904	0,00700	0,01726
0,01665	0,02018	0,01071	0,01586	0,01070	0,00877	0,01664
0,00885	0,01179	0,01100	0,01586	0,01665	0,01020	0,01714
0,01924	0,02349	0,01071	0,01586	0,00885	0,00703	0,01579
0,01789	0,02213	0,00910	0,01586	0,01923	0,01169	0,01662
0,01113	0,01685	0,00910	0,01586	0,01789	0,00963	0,01714
0,01245	0,01556	0,00836	0,01586	0,01113	0,00802	0,01611
0,02366	0,02374	0,00836	0,01586	0,01245	0,00902	0,01529
0,03452	0,02081	0,01667	0,01586	0,02366	0,01252	0,01695
0,12730	0,01498	0,03511	0,01898	0,03452	0,01505	0,02109
0,10530	0,05080	0,12588	0,03430	0,12730	0,04603	0,04587
0,04697	0,06107	0,10602	0,04521	0,10530	0,02784	0,06585
0,05320	0,05688	0,04645	0,04885	0,04696	0,01406	0,07154
0,06998	0,06007	0,05213	0,05197	0,05320	0,02093	0,07636
0,02937	0,06099	0,06915	0,05768	0,06998	0,02433	0,08287
0,04833	0,05274	0,02943	0,05638	0,02937	0,00923	0,07857
0,02338	0,04821	0,04929	0,05794	0,04833	0,02092	0,07662
0,01450	0,05000	0,01667	0,05274	0,02338	0,00834	0,06797
0,03030	0,02822	0,01100	0,04755	0,01450	0,00961	0,05645
0,03483	0,03095	0,02943	0,04547	0,03030	0,01460	0,04820
0,02843	0,03434	0,03511	0,04313	0,03483	0,01445	0,04141

0,01176	0,02452	0,02943	0,04054	0,02843	0,01230	0,03400
0,06437	0,02129	0,00836	0,03482	0,01176	0,00731	0,02385
0,03097	0,03800	0,06347	0,03664	0,06437	0,02709	0,02648
0,02264	0,04754	0,01809	0,03586	0,03097	0,00883	0,02323
0,02358	0,02790	0,01667	0,03222	0,02264	0,01224	0,01909
0,00043	0,00879	0,01667	0,02911	0,02358	0,01139	0,01605
0,03846	0,02382	0,00674	0,02365	0,00043	0,00374	0,00878
0,09065	0,01308	0,03794	0,02495	0,03846	0,01942	0,01075
0,08697	0,04599	0,09184	0,03586	0,09065	0,03195	0,02546
MAE	0,01305	0,01455	0,01576	0,01500	0,01704	0,01806
MAPE	0,79520	1,30982	2,01397	1,76847	1,03096	1,37906
MdAPE	0,27662	0,43619	0,41635	0,47374	0,47336	0,50899

5. Sonular ve neriler

Yapılan analiz sonucunda Yolcu vd. (2018) tarafından nerilen TS FIS yntemi ile Chen (1996) ve Chen (2002) gibi bulanık zaman serisi yntemleri ve Naive Method, ARIMA, Holt's Linear Trend gibi klasik zaman serisi yntemleri ile enflasyon ngrs gerekleřtirilmiřtir. Bu amala, 2003:01-2023:08 dnemi arası aylık TFE verileri kullanılmıřtır. Sonular incelendiğinde, Yolcu vd. (2018) tarafından nerilen TS-FIS ynteminin MAE, MAPE ve MdAPE deėerleri aısından hem diėer bulanık zaman serisi hem de klasik zaman serisi yntemlerinden daha iyi performans gsterdiėi grlmektedir.

Bir yanıyla yapısal hale gelen kriz sreleri ile mcadele etmek, bir yanıyla bu srele iliřkili olarak ekonomik ve sosyal geliřmeyi srdrlebilir kılmak iin fiyat istikrarını saėlamak nemlidir. Fiyat istikrarı bireylere ve firmalara tketim, tasarruf ve yatırım kararlarında ve uzun vadeli planlamada gerek duymadıkları lde dřk bir enflasyon oranını ifade etmektedir. Bu minvalde deėerlendirildiğinde enflasyon oranı, fiyat istikrarını saėlamak iin politika uygulayıcılara yol gstermektedir. Keza enflasyon oranının ngrlmesine ynelik alıřmalar ile alternatif yollar retilmektedir.

Bulanık zaman serisi yntemlerinin yneylem, istatistik ve ekonomi alıřmalarında son yıllarda kullanımının arttıėı grlmektedir. Bu alıřma ile birlikte tahmin ve ngr problemlerinde gereėe yakın sonular retmesi aısından geliřtirilen yeni modellerin de kullanılabileceėi gsterilmektedir.

Bu minvalde konuya ilişkin çalışma yapması muhtemel araştırmacıların bu yöntemleri de kullanarak karşılaştırma yapmaları önerilmektedir.

Teşekkür

Bu kısımda çalışmada yardımları ya da destekleri bulunan kişi veya kişilere ya da kurumlara teşekkür edilebilir.

Yazarların Katkısı

Yazarların makaleye olan katkıları belirtilmelidir. (Örneğin: Tüm yazarlar çalışmaya eşit katkıda bulunmuştur.)

Çıkar Çatışması Beyanı

Yazarlar arasında herhangi bir çıkar çatışması bulunmamaktadır.

Araştırma ve Yayın Etiği Beyanı

Yapılan çalışmada araştırma ve yayın etiğine uyulmuştur.

Kaynaklar

- Akdağ, M., ve Yiğit, V. (2016). Box-Jenkins ve yapay sinir ağı modelleri ile enflasyon Tahmini, *Atatürk Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 30(2), 269-283.
- Al Kadry, I. R., Massalesse, J., & Nur, M. (2022). Forecasting inflation in Indonesia using the modified fuzzy time series Cheng, *Jurnal Matematika, Statistika dan Komputasi*, 19(1), 210-222.
- Almosova, A., & Andresen, N. (2023). Nonlinear inflation forecasting with recurrent neural networks, *Journal of Forecasting*, 42(2), 240-259.
- Araujo, G. S., & Gaglianone, W. P. (2023). Machine learning methods for inflation forecasting in Brazil: New contenders versus classical models, *Latin American Journal of Central Banking*, 4(2), 100087.
- Aydın, A. (2023). Türkiye ekonomisi için 1980 sonrasında enflasyon ve büyümenin işsizlik üzerindeki etkileri: ARDL yaklaşımı, *Sosyal Bilimlerde Nicel Araştırmalar Dergisi*, 3(1), 1-22.
- Aytürk, Y. (2011). Finansallaşma ve reel ekonomi, Derleyen Hayri Kozanoğlu içinde *Uç(ur)amayan Balon: Finans*, 60-90, Ayrıntı Yayınları, İstanbul.
- Chen, S.M. (1996). Forecasting enrolment based on fuzzy time series, *Fuzzy Sets Systems*, 81, 311-319.
- Erdem, N. (2011). Türkiye ekonomisinde dışa bağımlılığın değişen "bilançosu". Hazırlayan Erkin Başer, Nihal Koçyiğit, Mustafa Öziş içinde, *Bugüne Bakmak: 1980 Sonrası Türkiye'de Yaşanan Toplumsal Dönüşüm Süreçleri*, s. 65-93, Dipnot Yayınları, Ankara
- Guttman, R. (2023). Can we reform capitalism for its own good? A roadmap to sustainability., *PSL Quarterly Review*, 76(304).

- Hauzenberger, N., Huber, F., & Klieber, K. (2023). Real-time inflation forecasting using non-linear dimension reduction techniques, *International Journal of Forecasting*, 39(2), 901-921.
- Kozanoğlu, H. (2011). Finansallaşma ve Türkiye, Derleyen Hayri Kozanoğlu içinde *Uç(ur)amayan Balon: Finans*, s.11-59, Ayrıntı Yayınları, İstanbul.
- Levine, R. Ve Zervos, S. (1993). Looking at the facts: What we know about policy and growth from cross-country analysis, *WorldBank Policy Research Working Papers*, No: 1115, March, 1-51.
- Mehmetcik, H., & Taskiran, D. (2023). Political crises of capitalism. In *Capitalism at a Crossroads: A New Reset?*, pp. 181-194, Springer International Publishing.
- Önder, İ. (2011). Emperyalizmin Türkiye'yi dönüştürme etkisi: 1980 sonrası politikalar, Hazırlayan Erkin Başer, Nihal Koçyiğit, Mustafa Öziş içinde, *Bugüne Bakmak: 1980 Sonrası Türkiye'de Yaşanan Toplumsal Dönüşüm Süreçleri*, s. 31-58, Dipnot Yayınları, Ankara.
- Pierdzioch, C. (2023). A bootstrap-based efficiency test of growth and inflation forecasts for Germany, *Economics Letters*, 224, 111029.
- Samuelson, P.A. & Nordhaus, W.D.(1992). *Economics*. McGraw-Hill: Int. Editions..
- Shi, Y. & Eberhart, R.C. (1999). Empirical study of particle swarm optimization, *Proceedings of the 1999 Congress on Evolutionary Computation- CEC99*, 3, 1945-1950, IEEE.
- Şiriner, İ. ve Doğru, Y. (2008). *Türkiye'de büyümenin ekonomi politiği: 1980 sonrası Türkiye ekonomisi üzerine bir inceleme*, Dipnot Yayınları, Ankara.
- Theoharidis, A. F., Guillén, D. A., & Lopes, H. (2023). Deep learning models for inflation forecasting. *Applied Stochastic Models in Business and Industry*, 39, 447-470.
- Turan, Z. (2011). Dünyadaki ve Türkiye'deki krizlerin ortaya çıkış nedenleri ve ekonomik kalkınmaya etkisi, *Niğde Üniversitesi İİBF Dergisi*, 4(1), 56-80.
- Uğurlu, E. & Saraçoğlu, B. (2010). Türkiye'de enflasyon hedeflemesi ve enflasyonun öngörüsü, *Dokuz Eylül Üniversitesi İktisadi İdari Bilimler Fakültesi Dergisi*, 25(2), 57-72 .
- Uslu, V. R. , Yolcu, U. , Eğrioğlu, E. , Aladağ, Ç. & Başaran, M. A. (2012). Yüksek dereceli bulanık zaman serisi yaklaşımı ile Türkiye enflasyon öngörüsü . *Dokuz Eylül Üniversitesi İktisadi İdari Bilimler Fakültesi Dergisi*, 27 (1) , 85-95.
- Ünüvar, İ., & Alemdar, H. (2023). 2001-2020 yılları arasında enflasyon ve ekonomik büyüme ilişkisinin genel bir yorumu. *Sosyal Beşeri Ve İdari Bilimler Alanında Uluslararası Araştırmalar XII*, 39.
- Yolcu, U., Baş, E. ve Eğrioğlu, E. (2018). A new fuzzy inference system for time series forecasting and obtaining the probabilistic forecasts via subsampling block bootstrap. *Journal of Intelligent & Fuzzy Systems*, 35(1), 1-10.
- Zengin, B. (2023). Finansal gelişmenin ekonomik büyümeye etkisi: Türkiye ekonomisinin toda-yamamoto yaklaşımıyla analizi. *İşletme Araştırmaları Dergisi*, 15(3), 2331-2346.