



A trend-residual decomposition-based modeling approach for Türkiye's total healthcare expenditure forecasting

Rezzan Yardımcı¹, Eşref Boğar^{2*}

¹Department of Biomedical Engineering, Faculty of Engineering Architecture, T.C. Istanbul Yeni Yüzyıl University, 34010, Istanbul, Türkiye

²Department of Biomedical Engineering, Faculty of Technology, Pamukkale University, 20160, Denizli, Türkiye

Highlights:

- Modeling and forecasting of Türkiye's total healthcare expenditure
- A trend-residual decomposition-based model
- A residual model with parameters optimized by least squares estimation and neural network algorithm

Keywords:

- Healthcare expenditure forecasting
- Time series decomposition
- Modeling
- Regression
- Neural network algorithm

Article Info:

Research Article

Received: 20.06.2023

Accepted: 09.12.2023

DOI:

10.17341/gazimmfd.1317413

Acknowledgment:

This study was prepared from the master's thesis titled "A New Decomposition-Based Model for Estimating Health Expenditures" at Pamukkale University, Institute of Science, Department of Biomedical Engineering.

Correspondence:

Author: Eşref Boğar
e-mail: ebogar@pau.edu.tr
phone: +90 258 296 4173

Graphical/Tabular Abstract

The flowchart of the proposed trend-residual decomposition-based model for Türkiye's total healthcare expenditure forecasting is indicated in Figure A.

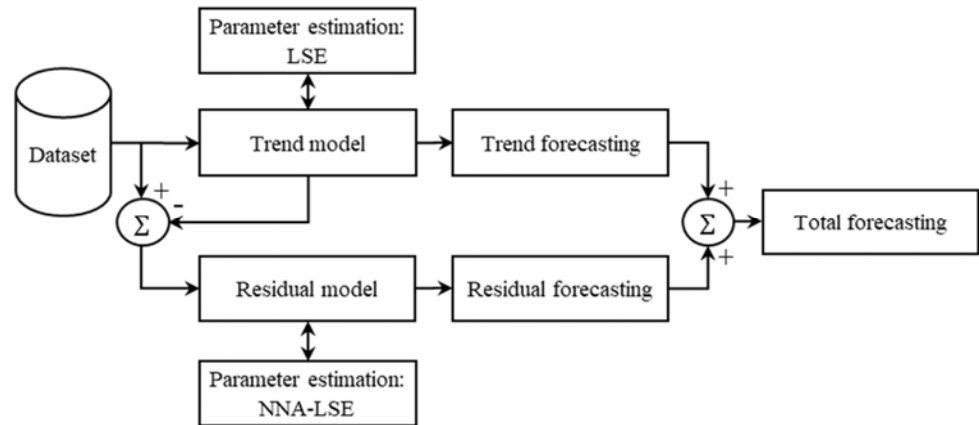


Figure A. General flowchart of the proposed trend-residual decomposition-based forecasting model

Purpose: The main purpose of this study is to develop a trend-residual decomposition-based model for Türkiye's total healthcare expenditure forecasting.

Theory and Methods: The research proposes a two-stage forecasting model based on a time series decomposition that increase forecasting accuracy by reducing the structural complexity of the healthcare expenditure time series. First, a polynomial regression approach is used to determine the trend component of the time series. Then, the residual/detrending component is modeled by a residual model with optimized linear parameters with Least Squares Estimation (LSE) method and non-linear parameters with Neural Network Algorithm (NNA). The total forecasting results are obtained by combining the trend and residual forecasting results.

Results: Using the healthcare expenditure data of 1999-2021, the proposed model is compared with grey models, regression models, exponential smoothing models and ARIMA models. The results reveal that the proposed model has better modeling and forecasting performance than other models. Türkiye's total healthcare expenditure for the years 2022-2030 is forecasted by the proposed model. It is predicted that health expenditures will increase approximately five times from 2022 to 2030 and will reach 2.2 trillion TL in 2030.

Conclusion: Main conclusions of the research are that it is feasible to use the proposed trend-residual decomposition-based model to forecast Türkiye's total healthcare expenditure in the future. In addition, the outputs of the study can be useful for decision-makers such as policy makers, healthcare providers and insurance companies in planning and making conscious decisions.



Türkiye'nin toplam sağlık harcaması tahmini için trend-artık ayrıştırması temelli bir modelleme yaklaşımı

Rezzan Yardımcı¹, Eşref Boğar^{2*}

¹T.C. İstanbul Yeni Yüzyıl Üniversitesi, Mühendislik Mimarlık Fakültesi, Biyomedikal Mühendisliği Bölümü, 34010, İstanbul, Türkiye

²Pamukkale Üniversitesi, Teknoloji Fakültesi, Biyomedikal Mühendisliği Bölümü, 20160, Denizli, Türkiye

ÖNEÇİKANLAR

- Türkiye'nin toplam sağlık harcamasının modellenmesi ve tahmini
- Trend-artık ayrıştırması temelli model
- Parametreleri en küçük kareler tahmini ve sinir ağı algoritması ile optimize edilmiş artık modeli

Makale Bilgileri

Araştırma Makalesi

Geliş: 20.06.2023

Kabul: 09.12.2023

DOI:

10.17341/gazimmfd.1317413

Anahtar Kelimeler:

Sağlık harcaması tahmini,
zaman serisi ayrıştırması,
modelleme,
regresyon,
sinir ağı algoritması

ÖZ

Sağlık harcamalarının doğru tahmini, sağlık sistemleri ve politikaların sürdürülebilirliği açısından oldukça önemli bir konudur. Bu çalışma kapsamında Türkiye'nin toplam sağlık harcamasını yüksek doğrulukla tahmin etmek için trend-artık ayrıştırması temelli bir model önerilmiştir. Önerilen model iki aşamalı bir tahmin prosedürüne sahiptir. İlk aşamada, polinomiyal regresyon kullanılarak sağlık harcaması zaman serisinin trendi belirlenmektedir. İkinci aşamada ise zaman serisinin trendden arındırılmış kısmını modellemek için doğrusal parametreleri en küçük kareler tahmin yöntemiyle ve doğrusal olmayan parametreleri sinir ağı algoritmasıyla optimize edilmiş bir artık modeli önerilmiştir. 1999-2021 yıllarına ait sağlık harcaması verileri kullanılarak önerilen modelin performansı gri modeller, regresyon modelleri, üstel yumuşatma modelleri ve ARIMA modelleri ile karşılaştırılmıştır. 1999-2017 yıllarının eğitim 2018-2021 yıllarının ise test için kullanılmasıyla elde edilen sonuçlar, önerilen modelin diğer modellerden daha iyi modelleme ve tahmin performansına sahip olduğunu göstermektedir. Bu nedenle, 2022-2030 yılları için Türkiye'nin toplam sağlık harcaması önerilen model ile tahmin edilmiş olup 2030 yılında 2,2 trilyon TL değerine ulaşacağı öngörülmüştür.

A trend-residual decomposition-based modeling approach for Türkiye's total healthcare expenditure forecasting

HIGHLIGHTS

- Modeling and forecasting of Türkiye's total healthcare expenditure
- A trend-residual decomposition-based model
- A residual model with parameters optimized by least squares estimation and neural network algorithm

Article Info

Research Article

Received: 20.06.2023

Accepted: 09.12.2023

DOI:

10.17341/gazimmfd.1317413

Keywords:

Healthcare expenditure
forecasting,
time series decomposition,
modeling, regression,
neural network algorithm

ABSTRACT

Accurate forecasting of health expenditures is a fundamental issue for the sustainability of health systems and policies. In this study, a trend-residual decomposition-based model is proposed to forecast Türkiye's total healthcare expenditure with high accuracy. The proposed model has a two-stage forecasting procedure. In the first stage, the trend of the health expenditure time series is determined using polynomial regression. In the second stage, a residual model with optimized linear parameters by least squares estimation method and non-linear parameters by neural network algorithm is proposed to model the detrending part of the time series. The performance of the proposed model using healthcare expenditure data for the years 1999-2021 are compared with grey models, regression models, exponential smoothing models and ARIMA models. The results obtained by using the years 1999-2017 for training and the years 2018-2021 for test demonstrate that the proposed model has better modeling and forecasting performance than other models. Therefore, Türkiye's total healthcare expenditure for the years 2022-2030 has been forecasted with the proposed model and it is predicted that it will reach 2.2 trillion TL in 2030.

*Sorumlu Yazar/Yazarlar / Corresponding Author/Authors : rezzan.yardimci@yeniuyuzuil.edu.tr, *ebogar@pau.edu.tr / Tel: +90 258 296 4173

1. Giriş (Introduction)

Sağlık harcaması, uluslararası kabul edilmiş tanımlamaya göre bireyleri ve toplumu kapsayan sağlık hizmetlerinde kullanılan tüm ürünlerin ve hizmetlerin tüketiminin ölçülmesi olarak ifade edilmektedir [1]. Teknolojideki gelişmelerin sağlık hizmetlerine yansıyan maliyetleri, nüfusun yaşlanması, kronik hastalıkların artması, ilaç ve tıbbi malzeme fiyatlarının artması, ülkelerin ekonomik büyümeleri ve sağlık hizmetlerine erişimin artması gibi birçok faktör sağlık harcamalarında artışa neden olmaktadır.

Ülkeler milli gelirlerinden sağlık harcamalarına pay ayırarak sağlık hizmetlerine olan talepleri karşılamaktadırlar [2]. Sağlık harcamaları, ekonomik kalkınmanın temel taşlarından biri olup ülkelerin gelişmişlik seviyelerine göre değişiklik göstermektedir. Gelişmiş ülkelerde milli gelirden sağlık harcamalarına aktarılan bütçe, gelişmemiş ve gelişmekte olan ülkelere nazaran çok daha fazladır [3]. Türkiye ise gelişmekte olan ülkeler arasında olup yaklaşık son otuz yıldır sağlık harcamaları hızlı bir şekilde artmaktadır. Türkiye İstatistik Kurumunun (TÜİK) en son yayınladığı rapora göre 2021 yılında toplam sağlık harcaması bir önceki yıla göre %41,6 artarak 353 milyar 941 milyon TL'ye yükselmiştir [4].

Ülkelerin gelecekteki sağlık hizmetleri taleplerini dengelemek, karşılayabilmek ve planlamak için sağlık harcamaları artışı tahmin ve takip etmeleri gerekmektedir. Diğer bir deyişle, hükümetlerin, sigorta şirketlerinin, sağlık kuruluşlarının ve diğer paydaşların kaynakları daha iyi tahsis etmeleri ve gelecek için etkili bir planlama yapmaları için sağlık harcamalarının doğru bir şekilde tahmin edilmesi gerekmektedir.

Sağlık harcamalarının modellenmesi ve tahmini alanında literatürde yayınlanmış çok sayıda çalışma bulunmaktadır. Bu çalışmalar arasında, Chaabouni ve Abednadhher [5] yapay sinir ağı ve otoregresif dağıtılmış gecikme yöntemlerini kullanarak Tunus'un toplam sağlık harcamalarını 2007-2020 yılları için tahmin etmişlerdir. Gayri safi yurtiçi hâsıla, nüfus yaşlanması, tıbbi yoğunluk ve çevre kalitesi olmak üzere dört faktör yöntemlerin girdileri olarak kullanılmış ve bu girdilerin gelecek yıllardaki değerleri bir sabit büyüme senaryosu ile ele alınarak tahminler yapılmıştır. Guemmegne vd. [6] çalışmalarında kübik, lojistik, log-lojistik, Weibull, Gompertz ve üstel olmak üzere altı büyüme modelini kullanarak Amerika Birleşik Devletleri'nin toplam sağlık harcamalarının trend davranışını araştırmışlardır. Klazoglou ve Dritsakis [7] Amerika Birleşik Devletleri'nin gayri safi yurtiçi hasılasının bir payı olarak toplam sağlık harcamasını tahmin etmek için en uygun Otoregresif Bütünleşik Hareketli Ortalama (AutoRegressive Integrated Moving Average, ARIMA) modelini belirlemişlerdir. Özcan ve Tüysüz [8] tarafından yapılan çalışmada ise Türkiye'nin kişi başı sağlık harcamasının tahmini için Genetik Algoritma ile hem parametreleri hem de eğitim veri sayısı optimize edilmiş yuvarlanma mekanizmalı gri modeller önerilmiş ve performansları ARIMA modeli ile karşılaştırılmıştır. Wu vd. [9] çalışmalarında kesirli bir gri bir model önermişler ve bu model ile Çin'in 2017-2020 yıllarındaki toplam, kamu ve cepten yapılan sağlık harcamalarını tahmin etmişlerdir. Ramezani vd. [10] ARIMA metodunu kullanarak İran'ın 2016-2020 yılları içerisinde ki toplam, kamu ve cepten yapılan sağlık harcamalarını tahmin etmişlerdir. Atalan vd. [11] Ekonomik İş Birliği ve Kalkınma Teşkilatı ülkelerinin kişi başına düşen sağlık harcamalarını, doğrusal ve doğrusal olmayan regresyon yöntemlerini kullanarak 2018-2025 yılları için tahmin etmişlerdir. Sağlık harcamasıyla ilişkili diğer bir regresyona dayalı tahmin çalışması ise Atalan [12] tarafından yapılmıştır. Bu çalışmada, 2018-2020 yılları için Türkiye'nin gayri safi yurtiçi hasılasının bir payı olarak toplam sağlık harcaması tahmin edilmiştir. Zheng vd. [13] çalışmalarında,

Çin'in 2018-2020 yıllarındaki toplam, kamu, sosyal ve cepten yapılan sağlık harcamalarını ARIMA modelleri ile tahmin etmişlerdir. Ceylan ve Atalan [14] Türkiye'nin kişi başına düşen sağlık harcamasını tahmin etmeye yönelik yaptıkları çalışmada rastgele orman, yapay sinir ağı, çoklu doğrusal regresyon, destek vektör regresyonu ve ilişkili vektör makinesi olmak üzere beş yöntemin kapsamlı analizi yapmışlardır. Analiz için girdi değişkenleri olarak kişi başına düşen gayri safi yurtiçi hasıla, doğumda beklenen yaşam süresi, işsizlik oranı, doğum oranı, doktor sayısı ve hastane sayısı kullanılmıştır. Ayrıca, her bir yöntemin girdi değişkeni kümesi Genetik Algoritma tabanlı bir özellik seçim stratejisiyle belirlenmiştir. Güteryüz [15] tarafından yapılan çalışmada destek vektör regresyonu, regresyon ağacı ve Gauss süreç regresyonu yöntemleri kullanılarak Türkiye'nin kişi başı sağlık harcaması modellenmiş ve yöntemlerin tahmin performansları karşılaştırılmıştır. Kişi başı gayri safi yurtiçi hasıla, kentsel nüfus oranı, işsizlik oranı, 65 yaş ve üstü nüfus, ortalama yaşam süresi, hekim oranı ve toplam hastane yatak sayısı model girdi değişkenleri olarak kullanılmıştır. Jia vd. [16] çok değişkenli gri tahmin modelinin yeni yapısı adı verilen yeni bir gri tahmin modeli geliştirerek Çin'in toplam sağlık harcamasını modellemeyi amaçlamışlardır. Çin'in sağlık sektörünü etkileyen ana faktörler ekonomi, nüfus, sağlık hizmeti kullanımı ve politika dikkate alınarak belirlenmiş ve modelin girdi değişkenleri olarak kullanılmıştır. Kazemian vd. [17] vektör otoregresif regresyon ve sıradan en küçük kareler regresyon yöntemlerini kullanarak İran'ın kişi başı sağlık harcamasını 2017-2025 yılları için tahmin etmişlerdir. Luo [18], 2021-2025 yılları için Çin'in kamu, sosyal ve kişisel sağlık harcamaları miktarlarını klasik gri model kullanarak tahmin etmiştir.

İlgili literatür incelendiğinde, yapılan çalışmalarda Türkiye'nin toplam sağlık harcamasının modellenmesinin ve tahmininin yapılmadığı görülmüştür. Buna ek olarak, çalışmaların çoğunda regresyon modelleri, gri modeller, ARIMA modelleri ve makine öğrenmesi yöntemleri kullanılmış olup sağlık harcaması zaman serisinin ayrıştırılması temelli bir yöntemin kullanılmadığı gözlemlenmiştir. Bu iki motivasyonla, bu çalışmada Türkiye'nin toplam sağlık harcamasını modellemek ve tahmin etmek için ayrıştırma temelli bir yaklaşım önerilmiştir. Önerilen yaklaşım sağlık harcaması zaman serisinin yapısal karmaşıklığını azaltmak ve sistematik bir modelleme ile tahmin doğruluğunu arttırmak için zaman serisini trend ve artık olmak üzere iki bileşene ayırarak modelleme yapmaktadır. Önerilen yaklaşımda ilk olarak zaman serisinin trend bileşenini modellemek için polinomial regresyon yaklaşımı kullanılmıştır. Daha sonra ise artık (trendden arındırılmış) bileşenini modellemek için doğrusal parametreleri En Küçük Kareler Tahmin (Least Squares Estimation, LSE) yöntemiyle ve doğrusal olmayan parametreleri Sinir Ağı Algoritmasıyla (Neural Network Algorithm, NNA) optimize edilmiş bir artık modeli önerilmiştir. Bu çalışma sağlık harcaması tahmin alanına hem uygulamada hem de teoride önemli katkı sağlamakta ve Türkiye'nin sağlık hizmetlerinin sürdürülebilir finansmanı için kıymetli çıktılar üretmektedir.

Çalışmanın geri kalanı şu şekilde yapılandırılmıştır. İkinci bölümde, önerilen yaklaşım ve teorik alt yapısı sunulmuştur. Üçüncü bölümde, Türkiye'nin toplam sağlık harcamasının modelleme, tahmin ve karşılaştırmalı sonuçları verilmiştir. Dördüncü bölümde ise çalışmadan elde edilen sonuçlara ve gelecek çalışmalara yer verilmiştir.

2. Metodoloji (Methodology)

Bu bölüm, ilk olarak çalışmada kullanılan veri kümesini, ardından Türkiye'nin toplam sağlık harcamasının modellenmesi ve tahmini için önerilen metodolojiyi ve arkasındaki teoriyi detaylı olarak açıklamaktadır.

2.1. Veri Kümesi (Dataset)

Bu çalışmada kullanılan veri kümesi, Türkiye İstatistik Kurumunun (TÜİK) veri tabanından elde edilmiş olup 1999 yılından 2021 yılına kadar uzanan 23 yıllık değerden oluşmaktadır. Türkiye'nin yıllara göre toplam sağlık harcaması miktarları Şekil 1'de gösterilmiştir. Bu şekilden sağlık harcamasının yıllara göre yükselen bir trende sahip olduğu açıkça görülmektedir.

2.2. Önerilen Trend-Artık Ayırıştırma Temelli Model (The Proposed Trend-Residual Decomposition-Based Model)

Zaman serilerinin yapısal karmaşıklığını azaltmak ve sistematik bir modelleme ile tahmin doğruluğunu artırmak için zaman serileri genellikle trend/eğilim, mevsimsellik ve artık olmak üzere üç temel bileşene ayrıştırılarak analiz edilebilirler [19-21]. Bu çalışmada Türkiye'nin toplam sağlık harcaması, kullanılan verilerin yıllık bazda olmasından dolayı zaman serisinin trend ve artık (trendden arındırılmış) bileşenlerinin doğrusal kombinasyonu olarak Eş. 1'deki gibi ifade edilmiştir.

$$Y_{toplam} = Y_{trend} + Y_{artık} \quad (1)$$

Burada Y_{toplam} toplam sağlık harcamasına ilişkin zaman serisini, Y_{trend} trend serisini ve $Y_{artık}$ ise artık serisini temsil etmektedir.

Sağlık harcamasıyla ilişkili zaman serisinin bu iki bileşenini modellemek için iki aşamalı bir model önerilmiştir. Önerilen modelin, ilk aşaması trend modelleme ve ikinci aşaması ise artık modelleme olarak adlandırılmıştır.

2.2.1. Trend modelleme (Trend modeling)

Zaman serisinin trendini belirlemek için bir polinomial regresyon yaklaşımı kullanılmıştır. Bu yaklaşımın doğrusal ve doğrusal olmayan farklı trend varyasyonlarına imkân sağlaması ve kolay uygulanabilmesinden dolayı kullanıldığını belirtmekte fayda vardır. Sağlık harcamasına ilişkin trend, Eş. 2'de verildiği gibi zamanın ($t = 1, 2, \dots, n$) bir fonksiyonu olarak q . dereceden bir polinom ile modellenmektedir.

$$\hat{Y}_{trend}(t) = \alpha_0 + \alpha_1 t + \alpha_2 t^2 + \dots + \alpha_q t^q = \sum_{i=0}^q \alpha_i t^i \quad (2)$$

Eş. 2'de $\alpha = [\alpha_0 \alpha_1 \dots \alpha_q]^T$ LSE yöntemiyle kestirilen polinom katsayılar vektörüdür.

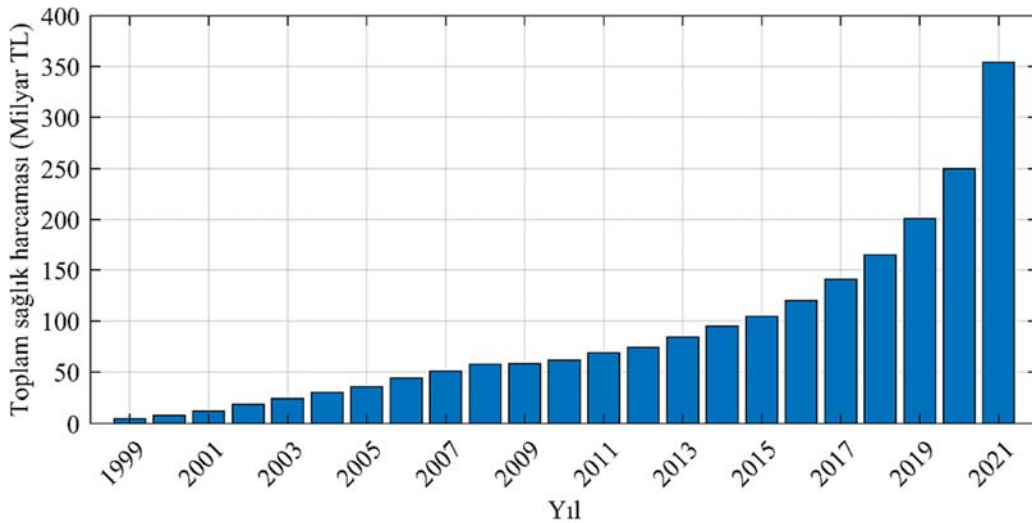
2.2.2. Artık modelleme (Residual modeling)

Önerilen modelin ikinci aşaması, gözlemlenen zaman serisinden kestirilen trend serisi çıkarılarak elde edilen artık serisini modellemek için tasarlanmıştır. Artık serisinin dalgalanmalı davranışını modellemek için Fourier serilerine dayalı artık modeli birçok çalışmada kullanılmıştır [22-24]. Bu çalışmada, Fourier artık modelinin tahmin doğruluğunu sınırlayan parametrik dezavantajlarını yok etmek için parametreleri LSE ve NNA ile optimize edilmiş genelleme yeteneğine sahip bir artık yaklaşılama modeli önerilmiştir. Önerilen artık modeli Eş. 3'teki gibi formüle edilmiştir.

$$\hat{Y}_{artık}(t) = \beta_0 + \sum_{i=1}^p [\beta_{2i-1} \cos(\omega_i t) + \beta_{2i} \sin(\omega_i t)] \quad (3)$$

Bu eşitlikte p trigonometrik fonksiyon çifti sayısını, $\beta = [\beta_0 \beta_1 \dots \beta_{2p}]^T$ modelin doğrusal parametreler vektörünü, $\omega = [\omega_1 \omega_2 \dots \omega_p]^T$ ise frekansla ilişkili modelin doğrusal olmayan parametreler vektörünü temsil etmektedir. Burada, önerilen artık modeli ile Fourier artık modelinin yapısal olarak birbirlerine benzerlik göstermelerine rağmen, sahip oldukları ω parametreleri bakımından matematiksel olarak ayrıldıklarını vurgulamakta fayda vardır. Fourier artık modelinde, n artık serisinin uzunluğu olmak üzere artık serisinin temel periyodu $T = n$ olarak ayarlanır ve her bir frekans parametresi $\omega_i = i \times 2\pi/T$ olarak belirlenir. Bu durumda artık serisinin gelecekte de aynı periyodik davranışı göstereceği kabul edilir. Bu çalışmada önerilen artık modelinde ise artık serisinin düzensiz dalgalanmalı davranışını modellemek için her ω_i parametresi NNA ile optimize edilir. Ayrıca $fix(\cdot)$ sifıra doğru yuvarlama fonksiyonu olmak üzere Fourier artık modelinde $p = fix((n-1)/2)$ olarak ayarlanmaktadır. Bu durumda bu model artık serisini neredeyse hatasız bir şekilde modellenmekte olup aşırı öğrenmeye sebep olmaktadır. Bu çalışmada ise p parametresinin belirlenmesi için bir test/doğrulama süreci gerçekleştirilerek önerilen artık modeline genelleme yeteneği kazandırılmaktadır.

Artık serisini modellemek için β ve ω vektörlerindeki parametrelerin optimum olarak bulunması gereklidir. Bu çalışmada, artık modelinin doğrusal parametreleri LSE yöntemiyle, doğrusal olmayan parametreleri ise NNA ile kestirilmiştir. Belirtmek gerekir ki, önerilen artık modeli ayrıştırılabilir bir yapıya sahip olduğundan dolayı bu iki yöntem kullanılmıştır. Böylece, NNA'nın doğrusal olmayan



Şekil 1. Türkiye'nin yıllara göre toplam sağlık harcaması (Türkiye's total healthcare expenditure by years)

parametreleri optimizasyon yeteneği ile LSE'nin doğrusal parametrelerin optimal değerini elde etme gücü birleştirilmiştir. Eş. 3'te verilen model, Eş. 4'te verildiği gibi ayrıştırılabilir bir kompakt forma sahiptir.

$$\hat{y}_{artık} = \Omega(\omega) \cdot \beta \quad (4)$$

Burada $\Omega(\omega)$ matrisi bilinmeyen doğrusal olmayan parametrelerin (ω) fonksiyonu olup Eş. 5'te verildiği gibi yazılabilir.

$$\Omega(\omega) = \begin{bmatrix} 1 & \dots & \cos(\omega_p) & \sin(\omega_p) \\ 1 & \dots & \cos(2\omega_p) & \sin(2\omega_p) \\ \vdots & \ddots & \vdots & \vdots \\ 1 & \dots & \cos(n\omega_p) & \sin(n\omega_p) \end{bmatrix} \quad (5)$$

Model matrisi $\Omega(\omega)$ ve artık serisi $y_{artık}$ olmak üzere herhangi bir ω vektörü için modelin doğrusal parametreleri LSE yöntemiyle Eş. 6 kullanılarak bulunabilir.

$$\beta = \left(\Omega(\omega)^T \Omega(\omega) \right)^{-1} \Omega(\omega)^T y_{artık} \quad (6)$$

Eş. 6'daki doğrusal olmayan parametreler ω ise Eş. 7'de verilen Hata Karelerinin Ortalamasının Kareköküne (Root Mean Square Error, RMSE) dayalı amaç fonksiyonunu en küçükleyecek şekilde NNA ile bulunmaktadır.

$$\min RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (y_{artık}(t) - \hat{y}_{artık}(t))^2} \quad (7)$$

Bu eşitlikte n modellemede kullanılan veri sayısını, $y_{artık}(t)$ ve $\hat{y}_{artık}(t)$ ise sırasıyla t anındaki gerçek ve modellenen artık değerlerini ifade etmektedirler.

2.2.2.1. Sinir ağı algoritması (Neural network algorithm, NNA)

Sadollah vd. [25] tarafından önerilen Sinir Ağı Algoritması biyolojik sinir sistemlerinden ve Yapay Sinir Ağlarından esinlenerek geliştirilen popülasyon tabanlı meta-sezgisel bir algoritmadır. Bu algoritma, kolay uygulanabilme, yüksek hesaplama zaman verimliliği ve doğrusal olmayan optimizasyon problemlerinin çözümünde etkili arama yeteneğine sahiptir. Bu avantajlarının yanı sıra birçok meta-sezgisel algoritmanın aksine popülasyon sayısı ve durdurma kriteri (maksimum iterasyon sayısı veya maksimum fonksiyon değerlendirmeye sayısı) dışında kendine özgü kontrol parametrelerine ihtiyaç duymayan NNA, parametresiz bir algoritmadır.

Yapay Sinir Ağları çoğu durumda tahmin araçları olarak kullanılırlar [26, 27] ve ağırlık değerlerini yinelemeli olarak değiştirerek tahmin edilen çözüm ile hedef çözüm (çıkış) arasındaki farkı kapatmaya çalışırlar. Buradan esinlenilerek geliştirmiş olan NNA ise popülasyondaki mevcut en iyi çözümü hedef çözüm olarak görür ve hedef çözüm ile popülasyondaki diğer çözümler arasındaki farkı kapatmayı amaçlar. NNA temel olarak aşağıdaki aşamaları içerir:

• Başlangıç popülasyonunu ve ağırlık matrisini oluşturma:

NNA, diğer popülasyon tabanlı meta-sezgisel algoritmalarda olduğu gibi D boyutlu çözüm uzayının sınırları içerisinde N tane bireyi (aday çözümü/arama ajanını) rastgele üretmek optimizasyon sürecine başlar. Bireylerin başlangıç konumları Eş. 8 kullanılarak belirlenir ve bu bireyleri içeren başlangıç popülasyonu Eş. 9'da verildiği gibi X^1 matrisi ile temsil edilir.

$$x_{i,j}^1 = l_j + U(0,1) \cdot (u_j - l_j), \quad \begin{cases} i = 1, 2, \dots, N \\ j = 1, 2, \dots, D \end{cases} \quad (8)$$

$$X^1 = \begin{bmatrix} x_1^1 \\ x_2^1 \\ \vdots \\ x_N^1 \end{bmatrix} = \begin{bmatrix} x_{1,1}^1 & x_{1,2}^1 & \dots & x_{1,D}^1 \\ x_{2,1}^1 & x_{2,2}^1 & \dots & x_{2,D}^1 \\ \vdots & \vdots & \ddots & \vdots \\ x_{N,1}^1 & x_{N,2}^1 & \dots & x_{N,D}^1 \end{bmatrix}_{N \times D} \quad (9)$$

Eş. 8'de $x_{i,j}^1$, i . bireyin j . değişkenin başlangıç konumunu, $U(0,1)$ 0 ile 1 arasında düzgün dağılımlı rastgele bir sayıyı, l_j ve u_j sırasıyla j . değişkenin alt ve üst sınır değerlerini ifade etmektedir.

Yapay Sinir Ağlarında olduğu gibi NNA'da da başlangıç ağırlıkları rastgele oluşturulur. Eş. 10 ve Eş. 11'de verilen koşullar dikkate alınarak oluşturulan başlangıç ağırlık matrisi (W^1) Eş. 12'de verilmiştir.

$$\sum_{j=1}^N w_{i,j}^1 = 1, \quad i = 1, 2, \dots, N \quad (10)$$

$$w_{i,j}^1 \in U(0,1), \quad i, j = 1, 2, \dots, N \quad (11)$$

$$W^1 = [w_1^1 \quad w_2^1 \quad \dots \quad w_N^1] = \begin{bmatrix} w_{1,1}^1 & w_{2,1}^1 & \dots & w_{N,1}^1 \\ w_{1,2}^1 & w_{2,2}^1 & \dots & w_{N,2}^1 \\ \vdots & \vdots & \ddots & \vdots \\ w_{1,N}^1 & w_{2,N}^1 & \dots & w_{N,N}^1 \end{bmatrix}_{N \times N} \quad (12)$$

Bu eşitliklerdeki $w_{i,j}^1$, i . bireyin j . ağırlığının başlangıç değerini göstermektedir.

• Popülasyonu güncelleme:

NNA algoritmasında, başlangıç popülasyonu ve ağırlık matrisi oluşturulduktan sonra yinelemeli bir süreç boyunca ($t = 1, 2, \dots, t_{max}$) popülasyon güncellemesi ve diğer aşamalar (ağırlık matrisini güncelleme, bias operatörü ve transfer operatörü) ardışık olarak gerçekleştirilir. t_{max} kullanıcı tarafından belirlenen maksimum iterasyon sayısı olup t . iterasyon için NNA'nın popülasyon güncelleme mekanizması Eş. 13 ve Eş. 14'te verildiği gibidir.

$$x_{W,j}^t = \sum_{i=1}^N w_{i,j}^t \cdot x_i^t, \quad i, j = 1, 2, \dots, N \quad (13)$$

$$x_i^{t+1} = x_i^t + x_{W,i}^t, \quad i = 1, 2, \dots, N \quad (14)$$

Bu eşitliklerde $x_{W,i}^t$ ve x_i^{t+1} sırasıyla ağırlıklandırılmış ve güncellenmiş i . bireyi ifade etmektedir.

• Ağırlık matrisini güncelleme:

t . iterasyonda bireylerin ağırlık vektörleri Eş. 15'te verilen formülasyona göre güncellenir.

$$w_i^{t+1} = |w_i^t + 2 \cdot \gamma_1 \cdot (w_{hedef}^t - w_i^t)|, \quad i = 1, 2, \dots, N \quad (15)$$

Burada w_i^{t+1} i . bireyin güncellenmiş ağırlık vektörünü, w_{hedef}^t t . iterasyondaki en iyi bireyin ağırlık vektörünü, γ_1 ise eleman değerleri 0 ve 1 arasında olan düzgün dağılımlı rastgele bir vektörü göstermektedir. Tüm bireylerin güncellenmiş ağırlık vektörlerinin Eş. 10'da verilen koşullu sağlanması gerektiğine dikkat edilmelidir.

• Bias operatörü:

Bias operatörü ve transfer operatörü sırasıyla NNA'nın global arama (keşif) ve yerel arama (sömürü) yapabilmesi için kullanılan iki temel bileşendir. Bu operatörlerin seçimi, modifikasyon faktörü (ζ) adı verilen bir değişken ile kontrol edilir. Diğer bir deyişle, modifikasyon faktörü değeri rastgele üretilen bir sayıdan büyük eşitse bias operatörü, aksi durumda ise transfer operatörü devreye girmektedir.

Modifikasyon faktörü Eş. 16 denklemi ile iteratif olarak güncellenir [25].

$$\zeta^{t+1} = \zeta^t \times 0,99 \quad (16)$$

Bias operatörü, etkili keşif yapmak ve olgunlaşmamış yakınsamayı engellemek için popülasyon ve ağırlık matrislerini mutasyona uğratmaya çalışır. Popülasyondaki bir bireye bias operatörü uygulanırsa, bu bireyin $N_p = \text{round}(\zeta^t \times D)$ tane değişkeni rastgele olarak belirlenir ve bu değişkenler alt ve üst sınırlar arasında rastgele olarak yerleştirilirler (Eş. 17).

$$x_{i,Q(s)}^{t+1} = l_{Q(s)} + U(0,1) \cdot (u_{Q(s)} - l_{Q(s)}), \quad s = 1, 2, \dots, N_p \quad (17)$$

Yukarıdaki eşitlikte Q rastgele olarak belirlenen değişkenler kümesidir.

Bias operatörü, diğer bir mutasyon işlemini ağırlık matrisinde gerçekleştirir. Bir bireyin ağırlık vektöründeki $N_w = \text{round}(\zeta^t \times N)$ tane elemanı rastgele olarak belirlenir ve bu elemanlar Eş. 18 kullanılarak güncellenir.

$$w_{i,R(r)}^{t+1} = U(0,1), \quad r = 1, 2, \dots, N_w \quad (18)$$

Eş. 18'de R rastgele olarak belirlenen ağırlık elemanları kümesidir. Bias operatörü uygulanan ağırlık vektörünün eleman değerlerinin toplamının bire eşit olduğuna dikkat edilmelidir.

• Transfer operatörü:

Mevcut çözümlerin hedef çözüme doğru yaklaştırılmasıyla daha kaliteli çözümler elde etmeyi amaçlayan bu operatör, algoritmanın sömürü görevini üstlenmektedir. Bu operatör ile elde edilen yeni birey aşağıdaki gibi ifade edilebilir:

$$x_i^{t+1} = x_i^{t+1} + 2 \cdot \gamma_2 \cdot (x_{\text{hedef}}^t - x_i^{t+1}), \quad i = 1, 2, \dots, N \quad (19)$$

Eş. 19'da x_{hedef}^t iterasyondaki en iyi bireyi yani hedef bireyi, γ_2 ise eleman değerleri 0 ve 1 arasında olan düzgün dağılımlı rastgele bir vektörü göstermektedir. Sinir Ağı Algoritmasının sözde kodu Tablo 1'de sunulmuştur.

Tablo 1. Sinir Ağı Algoritmasının sözde kodu (Pseudocode of Neural Network Algorithm)

```

1: Giriş:  $N, L_{\max}, D, l, u, \zeta^1 = 1$ 
2: Eş. 8'i kullanarak başlangıç popülasyonunu ( $X^1$ ) oluştur
3: Eş. 10 ve Eş. 11'i kullanarak ağırlık matrisini ( $W^1$ ) oluştur
4: Bireylerin uygunluk değerlerini hesapla
5: Popülasyondaki en iyi bireyi ( $x_{\text{hedef}}^1$ ) ve hedef ağırlığı ( $w_{\text{hedef}}^1$ ) belirle
6: for  $t = 1$  to  $t_{\max}$  do
7:   Eş. 13 ve Eş. 14'ü kullanarak popülasyonu güncelle ( $X^{t+1}$ )
8:   Eş. 15'i kullanarak ağırlık matrisini güncelle ( $W^{t+1}$ )
9:   for  $i = 1$  to  $N$  do
10:    if  $\text{rand} \leq \zeta^t$  then
11:      Eş. 17'yi kullanarak  $i$ . bireye bias operatörü uygula
12:      Eş. 18'i kullanarak  $i$ . bireyin ağırlığına bias operatörü uygula
13:    else
14:      Eş. 19'u kullanarak  $i$ . bireye transfer operatörü uygula
15:    end if
16:  end for
17:  Eş. 16 ile modifikasyon faktörünü güncelle ( $\zeta^{t+1}$ )
18:  Güncellenen tüm bireylerin uygunluk değerlerini hesapla
19:  En iyi bireyi ( $x_{\text{hedef}}^{t+1}$ ) ve hedef ağırlığı ( $w_{\text{hedef}}^{t+1}$ ) güncelle
20: end for
21: Çıkış: En iyi çözüm ( $x_{\text{hedef}}^{t+1}$ )

```

Türkiye'nin toplam sağlık harcamasının modellenmesi ve tahmini için önerilen yaklaşımın akış şeması Şekil 2'de verilmiştir.

3. Deneysel Sonuçlar ve Tartışmalar (Computational Results and Discussions)

Bu çalışmada 1999-2021 yıllarına ait Türkiye'nin toplam sağlık harcaması verileri kullanılarak 2022 yılından 2030 yılına kadar tahminler yapılmıştır. Tüm hesaplamalar, Intel Core I7 2.30 GHz işlemci, 8 GB RAM ve 64 bit Windows 10 işletim sistemine sahip bilgisayarda MATLAB (R2018a) platformunda gerçekleştirilmiş olup herhangi bir araç kutusu kullanılmamıştır. Bu bölümün geri kalan kısmında ilk olarak önerilen yaklaşım ile Türkiye'nin toplam sağlık harcamasının modellenmesine, ardından önerilen yaklaşımın ve literatürde sıklıkla kullanılan yöntemlerinin karşılaştırmalı sonuçlarına yer verilmiştir. Son olarak ise önerilen model ile elde edilen Türkiye'nin toplam sağlık harcamasının tahmin sonuçları sunulmuştur.

3.1. Modelleme Sonuçları (Modeling Results)

3.1.1. Trend modelleme sonuçları (Trend modeling results)

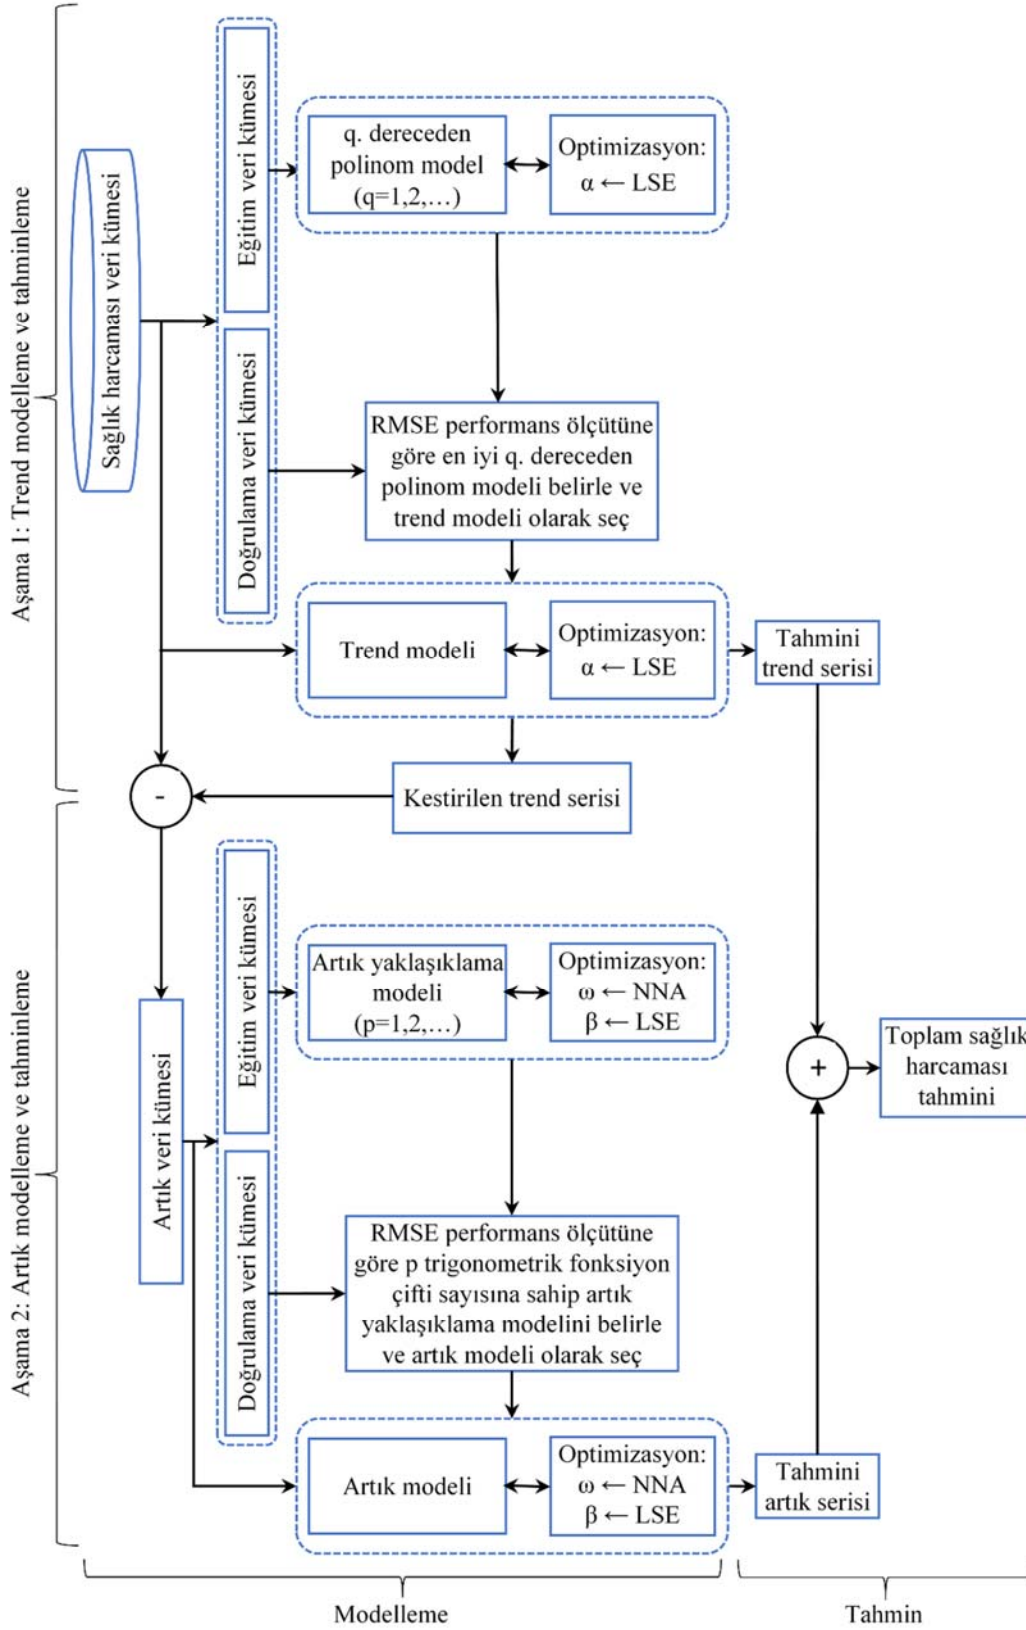
Metodoloji bölümünde belirtildiği gibi, önerilen yaklaşımın ilk aşaması Eş. 2 kullanılarak zaman serisinin trend bileşeninin modellenmesidir. Trendin belirlenmesinde kilit nokta, doğru polinom derecesinin belirlenmesidir. En uygun model derecesini belirlemek için model doğrulama (validasyon) süreci gerçekleştirilmiş olup veri kümesi iki gruba ayrılmıştır. Birinci grupta veri kümesinin yaklaşık %75'i modeli eğitmek için kullanılmıştır. Kalan veriler ise en uygun model derecesini belirlemek yani farklı derecelerden oluşan modellerin performansını test etmek için kullanılmıştır. Veri kümesi 1999-2021 yıllarını içerdiğinden 23 değere sahiptir. Gelecekle ilişkili tahmin söz konusu olduğundan, ilk 17 veri polinom modellerinin öğrenmesi için geri kalan 6 veri ise modellerin tahmin doğruluğunu test etmek için kullanılmıştır. Belirli bir trend modelinin performansını belirlemek RMSE performans ölçütü kullanılmıştır. 1'den 5'e kadar polinom dereceleri ($q = 1, 2, \dots, 5$) kullanılarak LSE yöntemiyle polinom katsayıları bulunmuştur. Bulunan polinom katsayılarına göre, doğrulama kümesi üzerinde modellerin RMSE değerleri hesaplanmıştır. Bu analizin sonuçları Tablo 2'de özetlenmiştir. Bu tablodan 4. dereceden polinom modelinin diğer modellere göre daha iyi performans gösterdiği görülmektedir. Bu nedenle 4. dereceden polinom model trend tahmin modeli olarak seçilmiştir. Ayrıca, altı ve daha yüksek polinom dereceleri için katsayı değerlendirme hesaplamalarının kararsız hale geldiğine dikkat edilmelidir.

Tablo 2. Trend modellerinin doğrulama kümesi üzerinde elde ettikleri RMSE değerleri

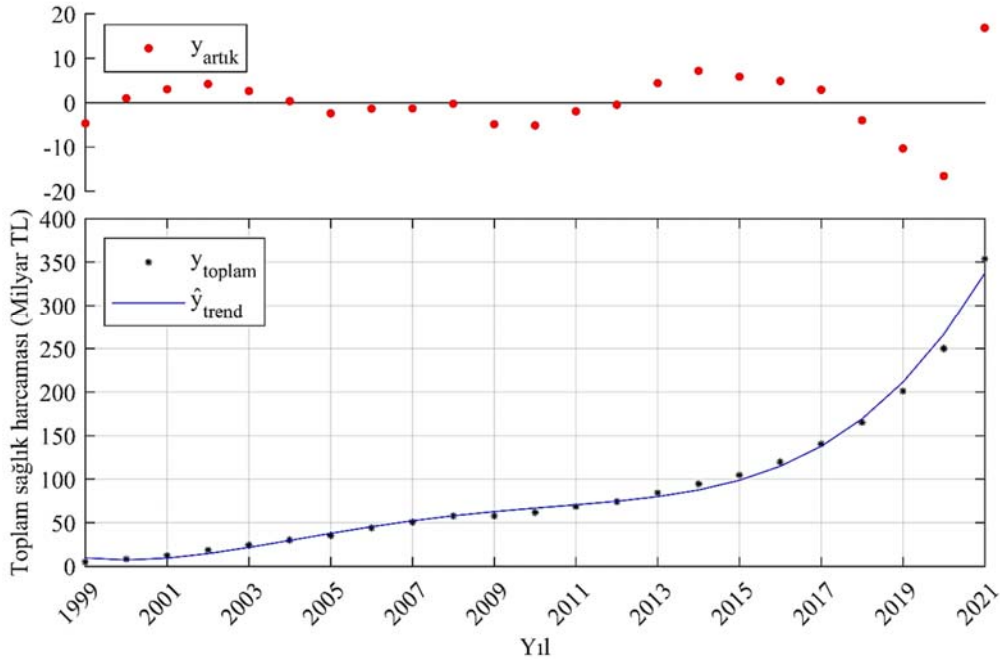
(RMSE values obtained by trend models on the validation set.)

q	1	2	3	4	5
RMSE	111,3056	101,9012	84,1169	17,2794	30,3331

Doğrulanmış polinom model derecesi ve mevcut tüm veriler kullanılarak nihai polinom katsayıları hesaplanmış ve ele alınan zaman serisinin trend bileşeni yaklaşık olarak bulunmuştur. Şekil 3'te sağlık harcaması için trend sonuçları verilmiştir. Bu şeklin alt kısmındaki siyah noktalar gerçek sağlık harcaması verilerini, eğri (kesintisiz çizgi) ise kestirilen trendi göstermektedir. Şekilden görüldüğü gibi, gerçek veriler ile trend modeli arasında iyi bir uyum vardır. İkisi arasındaki farklar, artık kısma ait değerler olup şeklin üst kısmında noktalar ile gösterilmiştir. Bu artık kısım, önerilen yaklaşımın ikinci aşamasının girdilerini oluşturmaktadır.



Şekil 2. Türkiye'nin toplam sağlık harcamasının modellenmesi ve tahmini için önerilen yaklaşımın akış şeması (Flow chart of the proposed approach for modeling and forecasting Türkiye's total health expenditure)



Şekil 3. Trend sonuçları (Trend results)

3.1.2. Artık modelleme sonuçları (Residual modeling results)

Şekil 3'ün üst kısmında verilmiş olan artık serisi Eş. 3 yardımıyla modellenmektedir. Bu şekilden artık serisinin dalgalanmalı bir yapıda olduğu açıkça görülmekte olup önerilen artık modelinin bu dalgalanmayı dikkate alarak verileri modellemeye çalıştığını vurgulamakta fayda vardır. Artık modelindeki trigonometrik fonksiyon çifti sayısının (p) belirlenmesi tahmin doğruluğu ve güvenilirliği için oldukça önemlidir. Eğer p büyük seçilirse modelleme performansının yükselmesi, tahmin performansının düşmesine sebep olacağı muhtemeldir. Bu nedenle en uygun p değerini belirlemek için trend modellemede uygulanan doğrulama prosedürünün aynısı burada da uygulanmıştır. Diğer bir ifadeyle, artık serisinin yaklaşık ilk %75'lik bölümü eğitim, geri kalan %25'lik bölümü ise doğrulama için kullanılmıştır. Bu çalışmada en doğru p değerini belirlemek için p değeri 1'den 5'e kadar değiştirilmiştir. Her bir p değeri için model parametreleri LSE ve NNA ile bulunmuştur. NNA'da popülasyon büyüklüğü 50 ve maksimum iterasyon sayısı 10.000 olarak ayarlanmıştır. Algoritma her bir model için 30 kez çalıştırılmıştır. Birbiriyle tutarlı sonuçlar elde edilmiş, böylece bu parametrelerin uygunluğu doğrulanmıştır. Parametreleri optimize edilmiş modellerin RMSE ölçütüne dayalı tahmin performansları, doğrulama kümesi üzerinde kapsamlı olarak araştırılmıştır. Elde edilen sonuçlar Tablo 3'te verilmiştir. Bu tablodan iki trigonometrik fonksiyon çiftine sahip artık modelinin diğer modellere göre daha iyi tahmin performansı sergilediği görülmektedir. Bu nedenle, $p = 2$ artık modeli, artık tahmin modeli olarak seçilmiştir.

Tablo 3. Artık modellerinin doğrulama kümesi üzerinde elde ettikleri RMSE değerleri (RMSE values obtained by residual models on the validation set.)

p	1	2	3	4	5
RMSE	10,5106	8,9313	9,6908	9,8282	17,3496

Doğrulanmış p değeri ve tüm artık serisi kullanılarak model parametreleri LSE ve NNA ile bulunmuş ve böylece ele alınan zaman

serisinin artık bileşeni modellenmiştir. Şekil 4'te artık modelleme sonuçları verilmiştir. Bu şekilde kırmızı noktalar trendden arındırılmış artık serisini, eğri (kesintisiz çizgi) ise kestirilen artıkları göstermektedir. Artık serisi ile modellenen seri arasında iyi bir uyum olduğu bu şekilden görülmektedir.


Ayrıca bu çalışmada önerilen artık modeli, test veri kümesinde 8,9313 RMSE değerine sahipken; bu değer Fourier artık modeli ile 12,8683 olarak elde edilmiştir. Bu durum önerilen artık modelinin tahmin doğruluğunun Fourier artık modeline göre daha iyi olduğunu göstermektedir.

3.1.3. Toplam modelleme sonuçları (Total modeling results)

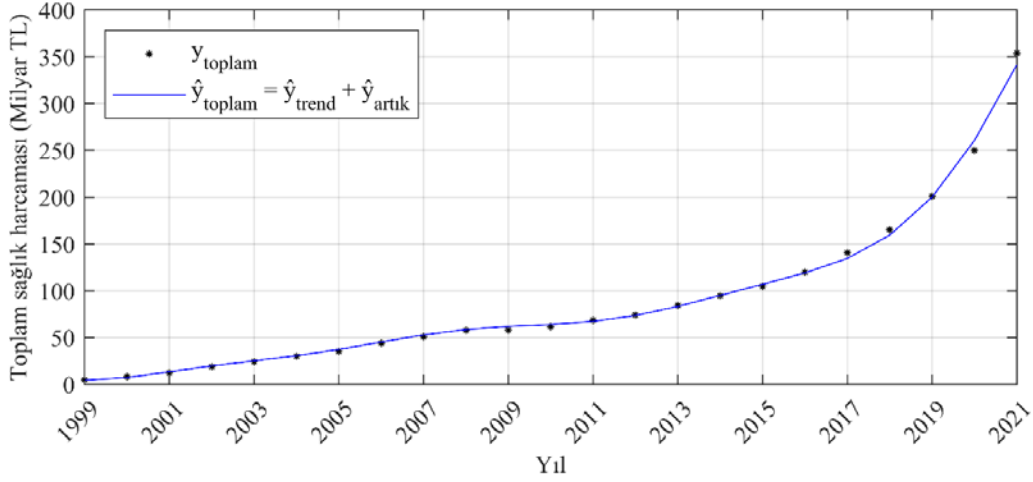
4. dereceden polinom trend modelinin ve iki trigonometrik fonksiyon çiftine sahip artık modelinin doğrusal kombinasyonu olarak modellenen toplam sağlık harcamasına ilişkin kestirim sonuçları Şekil 5'te gösterilmiştir. Bu şekilden, önerilen yaklaşımın gözlemlenen veri kümesini taklit etmede yüksek modelleme performansına sahip olduğu açıkça görülmektedir.

3.2. Karşılaştırmalı Sonuçlar (Comparative Results)

Sağlık harcaması tahminini yapmadan önce önerilen modelin tahmin performansı araştırılmış ve doğrulanmıştır. Bu amaçla, önerilen model gri modeller, regresyon modelleri, üstel yumuşatma modelleri ve ARIMA modelleri ile karşılaştırılmıştır. Gri Model (Grey Model, GM(1,1)) [28], Gri Verhulst Model (Grey Verhulst Model, GVM(1,1)) [29], homojen olmayan gri modeller (Non-homogeneous Grey Model, NGM(1,1, k) [30] ve NGM(1,1, k,c) [31]), Ayrık Gri Model (Discrete Grey Model, DGM(1,1)) [32], Homojen Olmayan Ayrık Gri Model (Non-homogeneous Discrete Grey Model, NDGM(1,1)) [33], Zamanla Değişen Ayrık Gri Model (Time-varying Discrete Grey Model, TDGM(1,1)) [34], Karesel Ayrık Gri Model (Quadratic Discrete Grey Model, QDGM(1,1)) [35] ve Kübik Ayrık Gri Model (Cubic Discrete Grey Model, CDGM(1,1)) [36] olmak üzere dokuz gri model karşılaştırma için kullanılmıştır. Ayrıca, birçok



Şekil 4. Artık sonuçları (Residual results)



Şekil 5. Toplam sağlık harcaması için modelleme sonuçları (Modeling results for total health expenditure)

tahmin çalışmasında [6, 37-39] kullanılan üstel, ters, kuvvet, logaritmik, birleşik, S, lojistik ve Gompertz regresyon modelleri de önerilen modelin performansını test etmek için kullanılmıştır. Üstel yumuşatma yöntemlerinden Basit Üstel Yumuşatma (Simple Exponential Smoothing, SES), Holt ve Hata-Trend-Mevsim (Error-Trend-Seasonal, ETS) modelleri de (ETS (A,A,N) ve ETS (A,M,N)) karşılaştırma için kullanılmıştır. Bu modeller hakkında detaylı bilgi için Hyndman vd. [40] incelenebilir. Son olarak ise önerilen yaklaşım ARIMA modelleriyle karşılaştırılmıştır. $p, d, q \in \{0, 1, 2, 3\}$ olmak üzere her bir ARIMA(p, d, q) modeli çalıştırılmış ve en uygun ARIMA modelini belirlemek için Akaike Bilgi Kriteri (Akaike Information Criterion, AIC), Schwartz Bayesci Bilgi Kriteri (Bayesian Information Criterion, BIC) ve Hannan-Quinn ölçütü (Hannan-Quinn Criterion, HQC) kullanılmıştır [21]. Bu kriterlere göre en uygun ARIMA modeli ARIMA (2,2,2) olarak bulunmuş ve önerilen modelle karşılaştırılmıştır.

Karşılaştırma için 1999-2017 yıllarına ait sağlık harcaması verileri tüm modellerin eğitiminde, 2018-2021 yılları ise modellerin tahmin performansını test etmede kullanılmıştır. Çalışmada önerilen model, doğrulama sürecine ihtiyaç duyması bakımından diğer karşılaştırma modellerinden farklıdır. Bu nedenle öncelikle önerilen modeldeki hem trend modelinin derecesini hem de artık modeldeki trigonometrik fonksiyon çifti sayısını belirlemek amacıyla bir doğrulama süreci gerçekleştirilmiştir. Bu doğrultuda, 1999-2014 yıllarına ait veriler

eğitim, 2015-2017 yıllarına ait veriler ise doğrulama kümesi olmak üzere ikiye ayrılmıştır. Doğrulama kümesi üzerinde trend modellerinin ve artık modellerinin elde ettikleri RMSE değerleri Tablo 4'te verilmiştir. Bu tablodaki sonuçlara göre $q = 4$ trend modeli ve $p = 2$ artık modelinden oluşan model tahmin modeli olarak belirlenmiştir.

Tablo 4. Trend ve artık modellerinin doğrulama kümesi üzerinde elde ettikleri RMSE değerleri (RMSE values obtained by trend and residual models on the validation set.)

q/p	1	2	3	4	5
Trend	137,8488	130,9690	116,0168	42,1945	161,9513
Artık	1,1405	0,5038	1,3269	2,4525	3,2978

Önerilen modeldeki trend modelinin derecesi ve artık modeldeki trigonometrik fonksiyon çifti sayısının belirlenmesinden sonra, tüm modeller 1999-2017 yıllarına ait veriler kullanılarak eğitilmiş ve 2018-2021 yıllarına ait sağlık harcaması miktarları tahmin edilmiştir. Modellerin performansları RMSE ve Ortalama Mutlak Yüzdese Hata (Mean Absolute Percentage Error, MAPE) ölçütleri kullanılarak karşılaştırılmıştır. Önerilen modelin ve karşılaştırılan modellerin eğitim ve test kümeleri üzerinde elde ettikleri RMSE ve MAPE değerleri Tablo 5'te verilmiştir. Bu tablodan önerilen yöntemin hem modellemeye hem de tahmin etmede diğer modellerden daha iyi performans sergilediği görülmektedir.

Tablo 5. Önerilen modelin ve karşılaştırılan modellerin eğitim ve test kümesi üzerinde elde ettikleri RMSE ve MAPE değerleri (RMSE and MAPE values of the proposed model and the compared models on the training and test set.)

Model	Eğitim (1999-2017)		Test (2018-2021)	
	RMSE	MAPE	RMSE	MAPE
GM(1,1)	5,9925	19,0401	67,9099	16,7085
GVM(1,1)	56,5349	82,0599	204,7301	79,7716
NGM(1,1,k)	6,3859	11,1751	106,5068	33,4432
NGM(1,1,k,c)	5,0401	8,5629	97,8315	29,8460
DGM(1,1)	6,1411	19,3212	67,3566	16,4105
NDGM(1,1)	4,2344	9,0902	93,5474	27,6101
TDGM(1,1)	2,8055	6,8674	68,7580	18,7759
QDGM(1,1)	1,3481	2,6969	35,8451	7,5546
CDGM(1,1)	1,0834	2,2356	47,1839	11,7633
Üstel	5,7204	28,1207	72,7945	19,4813
Ters	28,7787	100,4642	183,8627	67,5273
Kuvvet	5,7024	12,4594	112,4472	35,1338
Logaritmik	18,1270	65,9722	158,9829	55,9589
Birleşik	5,7204	28,1207	72,7944	19,4813
S	5,7204	28,1207	72,7945	19,4813
Lojistik	5,4210	23,5085	95,1879	27,6724
Gompertz	5,0146	19,1348	96,1715	28,3551
SES	5,7462	10,4804	134,5738	42,7754
Holt	3,0241	3,8963	69,8591	16,8095
ETS (A,A,N)	3,0162	3,5348	70,3099	16,9764
ETS (A,M,N)	3,0787	4,5029	45,2960	9,4289
ARIMA(2,2,2)	2,5020	3,0088	67,9406	16,4872
Önerilen model	0,6786	1,6155	32,8571	6,1643

3.3. Tahmin Sonuçları (Forecasting Results)

Önerilen yaklaşım ile Türkiye'nin 2022-2030 yıllarına ait toplam sağlık harcaması tahmin sonuçları Tablo 6'da listelenmiştir. Bu tablodan, sağlık harcaması miktarının gelecekte artacağı görülmektedir. 2030 yılında ise yaklaşık 2 trilyon 202 milyar TL değerine ulaşacağı beklenmektedir.

Tablo 6. Türkiye'nin 2022-2030 yıllarına ait toplam sağlık harcaması tahmin sonuçları (Türkiye's total health expenditure forecasting results for the years 2022-2030)

Yıl	Sağlık harcaması miktarı (Milyar TL)
2022	439,7
2023	552,5
2024	680,3
2025	829,2
2026	1009,4
2027	1232,3
2028	1505,5
2029	1830,2
2030	2202,8

4. Sonuçlar (Conclusions)

Bu çalışmada Türkiye'nin toplam sağlık harcamasını modellemek ve tahmin etmek için trend-artık ayrıştırması temelli bir model önerilmiştir. 1999-2021 yıllarına ait sağlık harcaması verileri kullanılarak önerilen model gri modeller, regresyon modelleri, üstel yumuşatma modelleri ve ARIMA modelleri ile kapsamlı olarak karşılaştırılmış ve diğer modellerden daha iyi performans sergilediği görülmüştür. 2022-2030 yılları için Türkiye'nin toplam sağlık harcaması önerilen model ile tahmin edilmiştir. 2022'den 2030 yılına kadar sağlık harcamalarının yaklaşık beş kat artacağı ve 2030 yılında

ise 2,2 trilyon TL değerine ulaşacağı tahmin edilmiştir. Bu çalışmada önerilen yöntemin literatüre sağladığı katkılarının yanında, çalışmanın çıktılarını politika yapıcılar, sağlık hizmeti sağlayıcıları ve sigorta şirketleri gibi karar vericiler için de kaynak tahsisi, bütçe düzenleme, teklif verme vb. konularda planlama yapma ve bilinçli kararlar alma konularında yararlı olabilir.

Bu çalışma, gelecekteki çalışmalar için yeni fikirlere ve gelişime pek çok yönden açıktır. Önerilen trend-artık ayrıştırması temelli model Türkiye dışında da diğer ülkelerin sağlık harcamalarını tahmin etmek için kullanılabilir. Aynı zamanda bu model, tek değişkenli yapıya sahip olduğu için sağlık harcaması gibi birçok belirsizliği içeren durağan olmayan farklı zaman serilerine uygulanabilir. Ayrıca, önerilen model trigonometrik fonksiyonlara sahip olması nedeniyle mevsimsellik davranışına sahip zaman serilerine de uygulanabilir ve performansı incelenebilir. Önerilen modelde yer alan artık modeli ise birçok modelin tahmin doğruluğunu arttırmak için kullanılabilir. Hem doğrusal hem de doğrusal olmayan parametrelere sahip gerçek hayat optimizasyon problemlerinin çözümünde de LSE ve NNA'nın birleşiminden oluşan melez bir optimizasyon yöntemi kullanılabilir. Son olarak, gelecek yıllarda yeni verilerin oluşması ile önerilen yöntemin sağlamlığı kontrol edilebilir ve daha uzun zaman aralığı için tahminler yapılabilir.

Teşekkür (Acknowledgement)

Bu çalışma Pamukkale Üniversitesi Fen Bilimleri Enstitüsü Biyomedikal Mühendisliği Anabilim Dalı'nda "Sağlık Harcamalarının Tahminine Yönelik Ayrıştırma Temelli Yeni Bir Model" başlıklı yüksek lisans tezinden hazırlanmıştır.

Kaynaklar (References)

1. Organization for Economic Co-operation and Development. OECD Database. <https://data.oecd.org/>. May 8, 2023
2. Mechanic D. and Rochefort D. A., Comparative Medical Systems, Annual Review of Sociology, 22 (1), 239-270, 1996
3. Akar S., An Investigation of The Relationship among Health Expenditures, Relative Price of Health Expenditures and Economic Growth in Türkiye, Journal of Management and Economics, 21 (1), 311-322, 2014
4. Turkish Statistical Institute. Health Spending Statistics 2021. <https://data.tuik.gov.tr/Bulten/Index?p=Sağlık-Harcamaları-Istatistikleri-2021-45728>. Published December 7, 2022. Date accessed May 8, 2023.
5. Chaabouni S. and Abednadhher C., Modelling and forecasting of Tunisia's health expenditures using artificial neural network and ARDL models, International Journal of Medical Science and Public Health, 2 (3), 495-504, 2013.
6. Guemmegne J.T., Kengwoung-Keumo J-J., Tabotabai M.A. and Singh K.P., Modeling the dynamics of the U.S. healthcare expenditure using a hyperbolic function, Advances and Applications in Statistics, 42 (2), 95-117, 2014.
7. Klazoglou P. and Dritsakis N., Modeling and forecasting of us health expenditures using ARIMA models, Advances in Panel Data Analysis in Applied Economic Research, Editor: Nicholas Tsounis, Aspasia Vlachvei, Springer International Publishing, 457-472, 2018.
8. Özcan T. and Tüysüz F., Healthcare expenditure prediction in Türkiye by using genetic algorithm based grey forecasting models, Operations Research Applications in Health Care Management, Editor: Cengiz Kahraman, Y. İlker Topçu, Springer International Publishing, 159-190, 2018.
9. Wu W., Ma X., Zhang Y., Wang Y. and Wu X., Analysis of novel FAGM (1,1, t²) model to forecast health expenditure of China, Grey Systems: Theory and Application, 9 (2), 232-250, 2019.
10. Ramezani M., Haghdoost A., Mehroolhassani M.H., Abolhallaje M., Dehnavieh R., Najafi B. and Fazaeli A.A., Forecasting health expenditures in Iran using the ARIMA model (2016-2020), Medical Journal of the Islamic Republic of Iran (MJIRI), 33 (25), 1-4, 2019.

11. Atalan A., Çınar Z. and Çınar M., A trendline analysis for healthcare expenditure per capita of OECD members, *Sigma Journal of Engineering and Natural Sciences*, 11 (1), 23-35, 2020.
12. Atalan A., Forecasting for healthcare expenditure of Türkiye covering the years of 2018-2050, *Gümüşhane University Journal of Health Sciences*, 9 (1), 8-16, 2020.
13. Zheng A., Fang Q., Zhu Y., Jiang C., Jin F. and Wang X., An application of ARIMA model for predicting total health expenditure in China for 1978-2022, *Journal of Global Health*, 10 (1), 1-8, 2020.
14. Ceylan Z and Atalan A., Estimation of expenditure per capita of Türkiye using artificial intelligence techniques with genetic algorithm-based feature selection, *Journal of Forecasting*, 40 (2), 279-290, 2021.
15. Gülerüz D., Predicting health spending in Türkiye using the GPR, SCR, DT models, *Acta Infologica*, 5 (1), 155-166, 2021.
16. Jia H., Jiang H., Yu J., Zhang J., Cao P. and Yu X., Total health expenditure and its driving factors in China: A grey Theory analysis, *Healthcare*, 9 (2), 2021.
17. Kazemian M., Abdi Z. and Meskarpour-Amiri M., Forecasting Iran national health expenditures: General model and conceptual framework, *Journal of Education and Health Promotion*, 11 (87), 1-7, 2022.
18. Lou M., Prediction of hospital health expenditure based on GM (1.1) grey clustering model, 2nd International Conference on Business Administration and Data Science (BADs 2022), Atlantis Press, 1164-1169, 2023.
19. Song J., Zhang L., Jiang Q., Ma Y., Zhang X., Xue G., Shen X. and Wu X., Estimate the daily consumption of natural gas in district heating system based on a hybrid seasonal decomposition and temporal convolutional network model, *Applied Energy*, 309, 118444, 2020.
20. Cekim H. O., Tekin S. and Özel G., Prediction of the earthquake magnitude by time series methods along the East Anatolian Fault, Turkey, *EARTH Science Informatics*, 14 (3), 1339-1348, 2021.
21. Kaytez F., A hybrid approach based on autoregressive integrated moving average and least-square support vector machine for long-term forecasting of net electricity consumption, *Energy*, 197, 117200, 2020.
22. Dejamkhooy A., Dastfan A. and Ahmadyfard A., Modeling and Forecasting monstationary voltage fluctuation based on grey system theory, *IEEE Transactions on Power Delivery* 32 (3), 1212-1219, 2014.
23. Wang Z-X., A genetic Algorithm-based grey method for forecasting food demand after snow disasters: an empirical study, *Natural Hazards*, 68, 675-686, 2013.
24. Hu Y-C., Forecasting tourism demand using fractional grey prediction models with Fourier series, *Annals of Operations Research*, 300 (2), 467-491, 2021.
25. Sadollah A., Sayyaadi H., Yadav A., A dynamic metaheuristic optimization model inspired by biological nervous systems: Neural Network Algorithm, *Applied Soft Computing*, 71, 747-782, 2018.
26. Balıkcı V., Gemici Z., Taner T., Dalkılıç A.S., Forecasting natural gas demand in Istanbul by artificial neural networks method and planning of city gate stations, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 39 (2), 1017-1027, 2024.
27. Sebatlı Sağlam A., Çavdur F., Earthquake intensity estimation via an artificial neural network: Examination of different network designs and training algorithms, *Journal of the Faculty of Engineering Architecture of Gazi University*, 37 (4), 2133-2145, 2022.
28. Ju-Long D., Control problems of grey systems, *Systems & Control Letters*, 1 (5), 288-294, 1982.
29. Zhang F.S., Liu F., Zhao W.B., Sun Z.A. and Jiang G.Y., Application of grey Verhulst model in middle and long term load Forecasting, *Power Sytem Technology*, 27 (5), 37-29, 2003.
30. Cui J., Liu S.F., Zeng B. and Xie N., A novel grey forecasting model and its optimization, *Applied Mathematical Modelling*, 37 (6), 4399-4406, 2013.
31. Chen P.Y. and Yu H.M., Foundation settlement prediction based on a novel NGM model, *Mathematical Problems in Engineering*, 2014.
32. Xie N.M. and Liu S.F., Discrete grey forecasting model and its optimization, *Applied Mathematical Modelling*, 33 (2), 1173-1186, 2009.
33. Xie N.M., Liu S.F., Yang Y.J. and Yuan C.Q., On novel grey forecasting model based on non-homogeneous index sequence, *Applied Mathematical Modelling*, 37 (7), 5059-5068, 2013.
34. Zang K. and Liu S.F., Linear time-varying parameters discrete grey forecasting model, *Sytems Engineering-Theory & Practice*, 30 (9), 1650-1657, 2010.
35. Wu L.Y., Wu Z.P. and Li M., Quadratic time-varying parameters discrete grey model, *Sytems Engineering-Theory & Practice*, 33 (11), 2887-2893, 2013.
36. Jiang S.Q., Liu S., Li Z.X. and Fang Z.G., Cubic time-varying parameters discrete grey forecasting model and its properties, *Control and Decision*, 31 (2), 279-286, 2016.
37. Saeid M., Zeinoddini-Meymand H., Kamel S. and Khan B., Interaction of transformer oil parameters on each other and on transformer health index using curve estimation regression method, *International Transactions on Electrical Energy Systems*, 2022.
38. Aydin G., Forecasting natural gas production using various regression models, *Petroleum Science and Technology*, 33 (15-16), 1486-1492, 2015.
39. Mutlu Gülüm N., Altuntaş S., Monitoring technological changes with statistical control charts based on patent data, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 36 (4), 1875-1892, 2021.
40. Hyndman R.J., Koehler A.B., Ord J.K. and Snyder R.D., Forecasting with exponential smoothing: the state space approach., Springer, ISBN: 978-3-540-71918-2, Berlin, Germany, 2008.

