



## Araştırma Makalesi

Mersin Univ Sağlık Bilim Derg 2021;14(1):35-43

doi: 10.26559/mersinsbd.765329

### Türkiye genelinde renal replasman tedavisine ihtiyaç duyacak olan hasta sayısının GM (1,1) ve OGM (1,1) ile tahmin edilmesi

 Tezcan Şahin<sup>1</sup>,  Saffet Ocak<sup>1</sup>

<sup>1</sup>Muğla Sıtkı Koçman Üniversitesi, Sağlık Bilimleri Fakültesi, Sağlık Yönetimi Bölümü

#### Öz

**Amaç:** 2018-2023 yılları arasında Renal Replasman Tedavisi görmesi gereken hasta sayısını tahmin etmektir. **Yöntem:** Tahmin etme sürecinde genel olarak zaman serilerinin tahmin edilmesinde kullanılan bir yöntem olan gri tahmin etme yöntemleri kullanılmıştır. Gri sistemlerde tahmin edebilmek için çeşitli modeller geliştirilmiş olmakla birlikte bu çalışmada GM (1,1) ve OGM (1,1) modelleri kullanılmıştır. Verilerin analizinde Microsoft Excel 2016 tabanlı Genel İndirgenmiş Gradyan metodundan yararlanılmıştır. Araştırma verileri, 2006-2017 yılları arasında Türkiye’de Renal Replasman Tedavisi gören hasta sayılarından oluşmaktadır. Modellerin tahmin performansı ortalama mutlak yüzde hata (MAPE) ve kök ortalama kare hata (RMSE) ile ölçülmüştür. **Bulgular:** Karşılaştırmalar sonucunda OGM (1,1)’in (MAPE: %2.0 RMSE: 1484) GM (1,1) modeline (MAPE: %2.1 RMSE: 1740) göre daha iyi performans gösterdiği tespit edilmiştir. 2006-2017 verilerine dayanarak tahmin edilen ve gerçekleşen veriler bazında yakınsama oranları karşılaştırıldığında da OGM (1,1) modelinin daha başarılı olduğu belirlenmiştir. 2018-2023 yılları arasında RRT görececek hasta sayısındaki ortalama yıllık büyüme oranı, GM (1,1) modeline göre %4.12; OGM (1,1) modeline göre ise %4.64’tür. Bu modellere göre, hasta sayısı her yıl bir önceki yıla göre artış göstereceği tahmin edilmektedir. 2017’de 77311 olan hasta sayısı 2023 yılında OGM (1,1) modeline göre 104105’e ulaşacağı öngörülmektedir. **Sonuç:** Bu yükseliş nedeniyle insidansı gittikçe artma eğilimi gösteren kronik böbrek hastalığının önlenmesi ve topluma ve devlete sosyo-ekonomik yükünün azaltılması için etkili önlemler (renal transplantasyon, organ bağışının özendirilmesi vs.) alınması gerekliliği gün yüzüne çıkmaktadır.

**Anahtar Kelimeler:** Hasta tahmini, zaman serileri analizi, gri tahminleme yöntemi, renal replasman tedavisi

---

**Yazının geliş tarihi:** 06.07.2020

**Yazının kabul tarihi:** 16.11.2020

**Sorumlu yazar:** Saffet Ocak, Muğla Sıtkı Koçman Üniversitesi, Sağlık Bilimleri Fakültesi, Sağlık Yönetimi Bölümü, Kötekli, Menteşe-Muğla

Tel (iş): 0252 2113214 E-mail: saffetocak@mu.edu.tr

Bu çalışma, 3. Uluslararası 13. Ulusal Sağlık ve Hastane İdaresi kongresinde “Türkiye’de RRT Gören Hasta Sayısının GM (1,1) VE OGM (1,1) Modeli ile Tahmin Edilmesi” ismiyle sunulmuş bildirinin genişletilmiş halidir.

## Prediction of number of patients will need to renal replacement therapy in Turkey with GM (1,1) and OGM (1,1)

### Abstract

**Aim:** The main purpose of the study is to estimate the number of patients requiring Renal Replacement Therapy between 2018-2023. **Method:** In the estimation process, grey estimation methods, which are generally used for estimating time series, are used. Although various models have been developed to predict grey systems, GM (1,1) and OGM (1,1) models are used in this study. General Reduced Gradient method based on Microsoft Excel 2016 was used to analyze the data. Research data consists of the number of patients receiving Renal Replacement Therapy between the years 2006-2017 in Turkey. Estimated performance of the models was measured by mean absolute percent error (MAPE) and root mean square error (RMSE). **Results:** As a result of the comparisons, it was found that OGM (1,1) (MAPE: 2% RMSE: 1484) performed better than GM (1,1) (MAPE: 2.1% RMSE: 1740). When the convergence rates are compared on the basis of estimated and actual data based on 2006-2017, it is found that OGM (1,1) is more successful. The average annual growth rate of the number of patients who will see RRT between 2018-2023 is 4.12% according to GM (1,1) and 4.64% according to OGM (1,1). According to these data, the number of patients will increase each year compared to the previous year. The number of patients who were 77311 in 2017 will reach 104105 in 2023 according to OGM (1,1). **Conclusion:** Due to this increase, effective preventions (renal transplantation, promotion of organ donation, etc.) should be taken to prevent chronic kidney disease whose incidence tends to increase gradually and to reduce the socio-economic burden on society and the state.

**Keywords:** Patient forecasting, time series analysis, grey prediction model, renal replacement therapy

### Giriş

Sağlık yöneticileri gelecekte neler olacağını bilmeden hemen hemen her gün kararlar alabilmektedirler. Tahminler, gelecekte neler olacağını öngörülmesini sağladığından sağlıklı bir planlama yapma olanağı sunmaktadırlar<sup>1</sup>. Geçmiş verilerden yararlanarak gelecek hakkında tahminde bulunmak, uygun yöntemler kullanıldığında belirsizliği azaltmak konusunda katkı sunabilmektedir. Ayrıca güvenilir bir tahmin, sadece yöneticilerin gelecekteki fırsatları açıkça görmelerine yardımcı olmakla kalmaz, aynı zamanda potansiyel riskleri azaltmaya ve kaynakları etkin olarak kullanmaya da olanak sağlar<sup>2</sup>. Sağlık hizmetlerinde geleceği tahmin edebilmek, sağlık yöneticilerinin planlama ve karar verme sürecinin önemli bir aşamasını oluşturmaktadır. Kronik böbrek yetmezliği, günümüzde medikal yönünün yanı sıra bireylerin sosyal, ekonomik ve psikolojik durumlarını da etkilemektedir. Dolayısıyla kronik böbrek yetmezliği olan hastalara sunulacak hizmetlere yönelik planlama ve kaynak tahsisinin yapılması önem arz etmektedir. Bu nedenle bu araştırmada

gelecek yıllarda Renal Replasman Tedavisine (RRT) tedavisine ihtiyacı olacak hasta sayısının tahmin edilmesi amaçlanmaktadır.

Kronik böbrek yetmezliği hem ülkemizde hem de dünyada oldukça yaygın olarak görülen kronik hastalıkların başında yer almaktadır<sup>3</sup> ve tüm dünya için önemli bir halk sağlığı sorunu olarak gündemdeki yerini korumaktadır<sup>4</sup>. Dünyada 1.5 milyon hasta hemodiyaliz, periton diyalizi ve böbrek transplantasyonu ile yaşamlarını sürdürebilmektedir. Gelecek 10 yıl içinde hasta sayısının 3 milyon olacağı ve böbrek transplantasyonu ve diyaliz işlemi maliyetinin 10 yıl içinde 1 trilyon ABD Dolarına ulaşacağı öngörülmektedir<sup>5</sup>. Bu duruma göre kronik böbrek yetmezliği tedavi maliyetlerinin ülkelerin bütçelerini zorlayacağı ortadadır. Özellikle gelişmekte olan ülkelerde böbrek hastalıklarının ekonomik yükünün çok ağır olacağı söylenebilir.

Ülkemizde son dönemlerde böbrek hastalığı insidansı her geçen gün giderek artmaya devam etmektedir. 2017 verilerine göre, ülkemizde RRT ihtiyacı olan son dönem böbrek hastalığı nokta prevalansı (çocuk

hastalar dahil) milyon nüfus başına 956.7'dir. RRT insidansı ise milyon nüfus başına 146.5 olarak bulunmuştur<sup>5</sup>. Türkiye'nin gelişmekte olan bir ülke olarak böyle bir ekonomik yükten ciddi bir düzeyde etkilenmesi muhtemeldir. Tüm bunlarla birlikte kronik böbrek hastalığı; hipertansiyon, anemi, kalp damar hastalıkları, kemik hastalığı gibi birçok hastalığın ortaya çıkmasına neden olabilmekte<sup>6</sup> ve bu hastalarda ölüm riskinin on kat daha fazla olduğu ileri sürülmektedir<sup>5</sup>.

Hem bir halk sağlığı sorunu hem de ekonomik sorun oluşturacak olan böbrek hastalıklarının RRT gerektiren hasta sayılarının gelecek yıllarda ne kadar olacağına öngörülmesi önem taşımaktadır. Bu çalışmada, Türkiye'de RRT görenlerin epidemiyolojik verilerine dayanarak RRT insidans eğilimini tahmin etmek ve politika geliştirmede yöneticilere referans sağlamak için GM (1,1) ve OGM (1,1) modelleri kullanılmıştır.

## Gereç ve Yöntem

1980'lerde Julong Deng tarafından geliştirilen Gri tahmin etme yöntemleri genel olarak zaman serilerinin tahmin edilmesinde kullanılan bir yöntemdir<sup>7</sup> ve küçük örneklem, belirsiz bilgi, belirsiz sistem ve veri eksikliğiyle ilgili belirsizlik sorunlarını incelemek için büyük bir yetenek göstermektedir<sup>8</sup>. Gri sistem, beyaz ve siyah sistemlerden farklı olarak belirsiz sorunlar ve eksik bilgiler ile birlikte bilinen bazı alanların olduğu anlamına gelir<sup>7,9</sup>. Gri sistemlerde tahmin edebilmek için çeşitli modeller geliştirilmiş olmakla birlikte GM (1,1) modeli bunların en basit formudur ve literatürde birçok alanda kullanılmıştır<sup>10-12</sup>.

Sağlık hizmetlerini konu alan literatür incelendiğinde gri tahmin etme modellerinin; Çin'in gelecekteki yaşlı nüfusunda Alzheimer hastalığının yaygınlığını tahmin etmek ve Çin'deki ilgili halk sağlığı politikalarının oluşturulması ve uygulanması için referans sağlamak<sup>13</sup>, Türkiye'deki sağlık harcamalarının tahmininde<sup>14</sup>, ruh sağlığı ve hastalıkları polikliniğine gelecek yıllarda oluşabilecek talebin belirlenmesinde<sup>15</sup>, Çin'de tifo ve

paratifoid ateşlerin insidans eğilimini tahmin etmek<sup>8</sup>, hepatit B görülme oranını<sup>9</sup> meme kanseri için başvuran toplam kadın sayısını<sup>16</sup>, Tip 2 diyabette tokluk şekerini<sup>9</sup>, yaşlı bireyler için akıllı ev e-sağlık yönetiminde önleyici sisteme yönelik tarihsel tıbbi sensör verilerini<sup>17</sup> medikal turist sayısını<sup>2</sup>, tahmin etmek için kullanıldığı çeşitli çalışmalar bulunmaktadır.

**1. GM (1,1) Modeli:** yaygın biçimde kullanılan bir modeldir ve model ifadesi birinci dereceden denklem ve tek değişken anlamına gelir<sup>18</sup>. GM (1,1)'in modellenmesi sürecine ilk veri serisinin aşağıdaki olduğu varsayılmaktadır<sup>10,17</sup>.

$$x^{(0)}(k) = (x^{(0)}(1), x^{(0)}(2), \dots, x^{(0)}(n)) \quad (1)$$

Burada n, modelleme verilerinin toplam sayısıdır. İlk veri serisindeki gizli düzenli kalıbı öğrenmek için aşağıda tanımlanan kümülatif üretim operatörü (accumulated generation operator) kullanılması gerekir:

$$x^{(1)}(k) = (x^{(1)}(1), x^{(1)}(2), \dots, x^{(1)}(n)) \quad (2)$$

Burada;

$$x^{(1)}(k) = \sum_{i=1}^k x^{(0)}(i), \quad k = 1, 2, 3, \dots, n$$

Ayrıca,

$$Z^1(k) = \frac{1}{2}(x^1(k) + x^1(k-1)), \quad k = 2, 3, \dots, n \quad (3)$$

Bu nedenle,

$$B = \begin{bmatrix} -Z^{(1)}(2) & 1 \\ -Z^{(1)}(3) & 1 \\ -Z^{(1)}(4) & 1 \\ \vdots & \vdots \\ -Z^{(1)}(n) & 1 \end{bmatrix} Y = \begin{bmatrix} x^{(0)}(2) \\ x^{(0)}(3) \\ x^{(0)}(4) \\ \vdots \\ x^{(0)}(n) \end{bmatrix} \quad (4)$$

Hesaplama yapıldığında;

$$\hat{a} = [a, b]^T = (B^T B)^{-1} B^T Y \quad (5)$$

GM (1,1) modeli,  $x^1(k)$  için birinci dereceden bir diferansiyel denklem kurarak aşağıdaki gibi oluşturulabilir:

$$\frac{dx^1}{dt} + \alpha x^1 = b \quad (6)$$

a ve b parametreleri sırasıyla gelişim katsayısı ve gri girdisidir. En küçük kareler

yöntemini kullanarak Denklem (6)'nın çözümü şöyledir:

$$\hat{x}^{(1)}(k+1) = \left(x^{(0)}(1) - \frac{b}{a}\right)e^{-ak} + \frac{b}{a} \quad (7)$$

Ters birikmiş üretim işlemi (IAGO) uygulandığında, öngörülen denklem aşağıdaki gibi olacaktır:

$$\hat{x}^{(0)}(k) = \left(x^{(0)}(1) - \frac{b}{a}\right)(1 - e^{-a})e^{-a(k-1)} \quad (8)$$

Burada  $\hat{x}^{(0)}(n+i)$  GM (1,1) tahmin değerleri olarak adlandırılır.

## 2. OGM (1,1) Modeli:

Araştırmacılar<sup>19</sup> gri tahmin modelinde en iyi tahmin sonucunu verecek biçimde  $\lambda$  parametresini optimize etmişler ve bu modele optimize edilmiş GM (1,1) veya kısaca OGM (1,1) adı verilmiştir. GM (1,1) modelinin açıklanmasında kullanılan Denklem 3'te 0.5 olarak alınan sabit değer, optimize edilmiş bu modelde  $\lambda$  olarak değerlendirilir ve 0-1 arasında bir değer alır.  $\lambda$  değerinin seçim kriteri, en küçük tahmin hata oranını vermektir. Denklem 3'ün optimize edilerek uyarlanmış gösterimi aşağıdaki gibidir<sup>20-22</sup>:

$$Z^1(k) = \lambda x^1(k) + (1 - \lambda)x^1(k-1),$$

$$k = 2, 3, \dots, n \quad (9)$$

Bu çalışmada, kullanılan tahmin modelleri arasında en iyisinin belirlenmesinde en düşük MAPE ve RMSE değerine sahip olma kriteri esas alınmıştır<sup>23,24</sup>. RMSE, bir model tarafından tahmin edilen ile gözlemlenen değerler arasındaki farkların ölçülmesinde kullanılmaktadır ve bu değer düşük olması arzu edilir<sup>25</sup>. MAPE ve RMSE değerleri, tahmin etme yöntemlerinin performans karşılaştırılmasında yaygın bir biçimde kullanılan kriterler olması sebebiyle<sup>23-26</sup> bu çalışmada tercih edilmiştir. MAPE ve RMSE değerlerine ait formüller sırasıyla Denklem (10) ve Denklem (11)'de verilmektedir<sup>2,3</sup>.

$$\text{MAPE} (\%) = \frac{1}{n} \sum_{k=1}^n \frac{|x^{(0)}(k) - \hat{x}^{(0)}(k)|}{x^{(0)}(k)} * 100\% \quad (10)$$

$$\text{RMSE} = \sqrt{\frac{\sum_{k=1}^n (x^{(0)}(k) - \hat{x}^{(0)}(k))^2}{n}} \quad (11)$$

Hesaplamalarda;  $x^{(0)}(k)$ , k zamanındaki orijinal değerdir,  $\hat{x}^{(0)}(k)$  ise tahmin değeridir ve n gözlem sayısıdır.

MAPE kriterine göre tahmin yeteneğine ilişkin değerlendirmeler Tablo 1'de sunulmaktadır.

**Tablo 1.** GM (1,1) Modelinin tahmin yeteneğini değerlendirme kriterleri<sup>16</sup>

Tahmin Yeteneği	MAPE
Yüksek	≤ %10
İyi	%10-%20
Makul	%20-%50
Zayıf	> %50

## Bulgular

Araştırma, 2006-2017 yılları arasındaki 12 yıllık sürede Türkiye'de RRT gören hasta sayısı verileri üzerinden gerçekleştirilmiştir ve bu verilere ilişkin bilgiler Tablo 2'de sunulmuştur.

Modellerin tahmin performansı Tablo 3'te sunulan MAPE ve RMSE ile ölçülmüş olup karşılaştırmalar sonucunda OGM (1,1)'in GM (1,1) modeline göre daha iyi performans gösterdiği tespit edilmiştir.

Her iki modele ilişkin tahmin değerleri ile gerçekleşmiş veriler arası karşılaştırmalar Şekil 1 ve Şekil 2'de gösterilmekte olup OGM (1,1)'in gerçekleşmiş verilere yakınlığı dikkat çekicidir. Şekil 2'deki yakınsama oranları bakımından da karşılaştırma yapıldığında son üç yılda GM (1,1)'in gerçekleşmiş verileri daha iyi yakınsadığı ancak sekiz yıl için ise OGM (1,1)'in daha iyi yakınsama oranlarına sahip olduğu görülmektedir.

**Tablo 2.** 2006-2017 yılları arasında Türkiye’de RRT gören hasta sayısı5

Yıllar	RRT gören hasta sayısı
2006	42196
2007	51856
2008	50214
2009	54048
2010	57881
2011	60443
2012	61667
2013	66711
2014	71318
2015	73660
2016	74475
2017	77311

**Tablo 3.** İki modelin tahmin performansının karşılaştırılması

	OGM (1,1)	GM (1,1)
MAPE (%)	2.0	2.1
RMSE	1484	1740

2018-2023 yıllarına ilişkin tahmin verileri Şekil 3’te gösterilmektedir. Buna göre her iki modelin öngördüğü genel sonuç, RRT hastalarının sürekli artacağı yönündedir. Özellikle tahmin ve yakınsama performansı daha yüksek olan OGM (1,1) modeli, bu artışın çok daha yüksek oranda olacağını göstermektedir. Son gerçekleşmiş veri olan 2017 yılı ile karşılaştırıldığında 2023 yılında OGM (1,1)’e göre RRT görecektir hasta sayısı yaklaşık %35; GM (1,1)’e göre ise %27 artacaktır.

### Tartışma ve Sonuç

Böbrek hastalıkları tüm dünyada olduğu gibi Türkiye’de de önemli halk sağlığı sorunu olarak gündemdeki yerini korumaktadır. Hastalığın toplumda görülme sıklığının artması, yüksek morbidite ve

mortalite oranları, bireylerin yaşam kalitesini düşürmesi, farkındalığının az olması ve tedavisi için gereken RRT’nin yüksek maliyetleri nedeniyle toplumsal yükü fazla olan bir hastalıktır.

Bu çalışma, Türkiye genelinde RRT gören hasta sayıları üzerinden gelecekte Türkiye’de ne kadar hastanın RRT görebileceğini tahmin etmeye yönelik olarak gerçekleştirilmiştir. Tahmin etme sürecinde gri tahmin etme yöntemlerinden olan GM (1,1) ve OGM (1,1) kullanılmıştır. Birçok çalışmada<sup>12,19,27</sup> olduğu gibi bu çalışmada da elde edilen sonuçlara göre OGM (1,1) modeli daha iyi tahmin değerlerine sahiptir ve bu modele göre gelecek yıllarda RRT görecektir hasta sayısında sürekli bir artış yaşanacaktır.

Bu nedenle insidansı gittikçe artma eğilimi gösteren kronik böbrek hastalığının önlenmesi ve topluma ve devlete sosyo-ekonomik yükünün azaltılması için etkili önlemler (renal transplantasyon, organ bağışının özendirilmesi, sağlık eğitimi vs.) alınması gerekmektedir.

Bu tahminlerin Türkiye’de RRT gören hasta sayılarının zamanla değişimlerini göstermesi nedeniyle sağlık yöneticilerine, sağlık politikası ve strateji belirleyicilerine yön verebilecek bilgi kaynaklarından olduğu söylenebilir. Böylelikle, RRT hizmetlerinin tür ve miktarının belirlenmesi, gerekli alt yapı ve kaynakların (malzeme, ekipman, insan gücü, finansman) planlanması ve kararlaştırılması daha isabetli olacaktır.

Gri tahmin etme yöntemlerinden olan OGM (1,1) ile yapılan tahminleme sonucu Türkiye’de gelecek yıllarda RRT görecektir hasta sayısında artışların yaşanacağını göstermektedir. Dolayısıyla Türkiye’nin RRT hizmeti sunacak olan sağlık profesyonellerine (Nefrolog, nefroloji hemşiresi, diyaliz teknisyeni vb.), sağlık kurumlarına, nefroloji ünitelerine ve diğer kaynaklara olan ihtiyacının ortaya çıkmasının kaçınılmaz olduğu bir gerçektir. Bu ihtiyacın karşılanmaması ve planlamanın yapılmaması halinde aksaklıklar yaşanması muhtemel hale gelebilecektir.

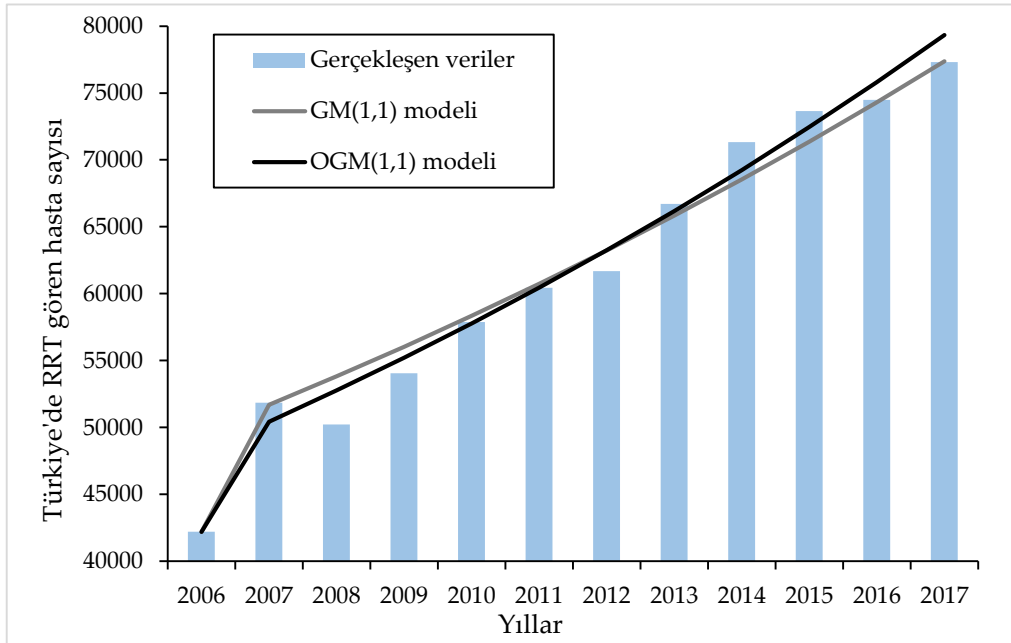
Ayrıca hangi teknik kullanılırsa kullanılsın tüm tahminlerin ortak noktasının,

geçmişte yaşanan gelişmelerin gelecekte de devam edeceğinin varsayılmasıdır<sup>1</sup>. Özellikle sağlık hizmetlerine olan talebin belirsiz ve rastlantısal özellik taşıması nedeniyle hatalar ortaya çıkabilir. Diğer bir ifade ile tahmin edilen sonuçlar ile gerçekleşen sonuçlar arasında farklılıklar olabilir. Dolayısıyla sağlık yöneticileri, en güvenilir tahmin yapılsa dahi, tecrübe ve yargılarını planlama ve karar alma sürecinde kullanmalıdırlar.

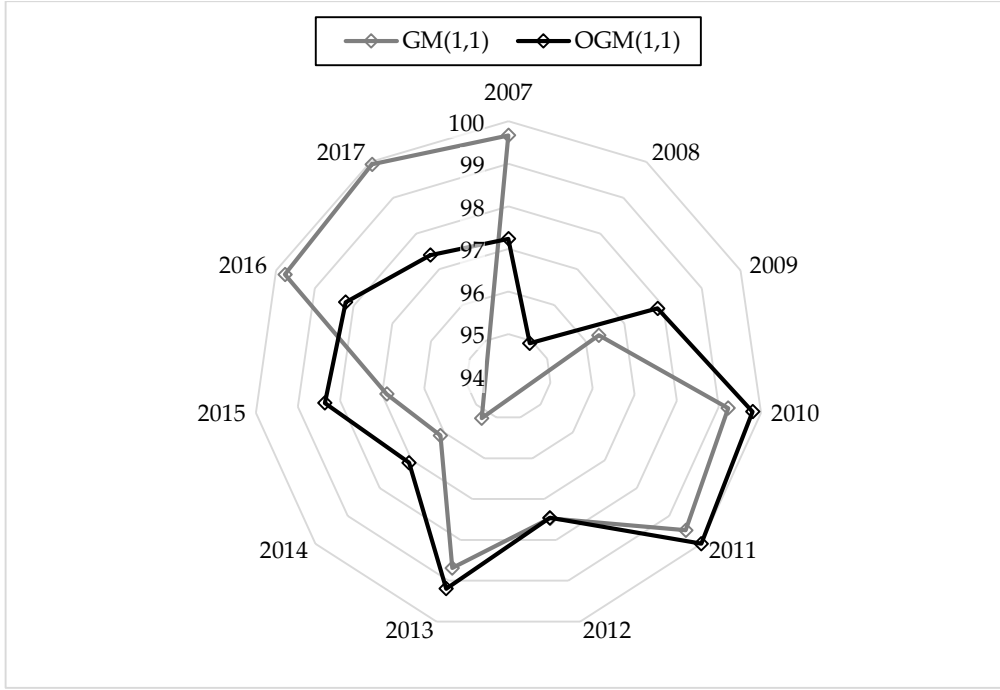
Bu tür tahmin etme teknikleri aracılığıyla toplumun sağlık gereksinimlerini karşılayacak hizmetlerin yeterli miktarda sunulması için gerekli kaynakların planlanması ve tahsis edilmesi konusunda sağlık yöneticilerinin verdikleri kararların doğruluk payı artacaktır. Nihayetinde doğru yapılan sağlık hizmet planlaması sayesinde kaynak israfı ve verimsizlik gibi düşük performansa yol açan sorunların önüne geçilebilecektir. En önemlisi de toplumun

sağlık seviyesine de olumlu katkılar sağlayacaktır.

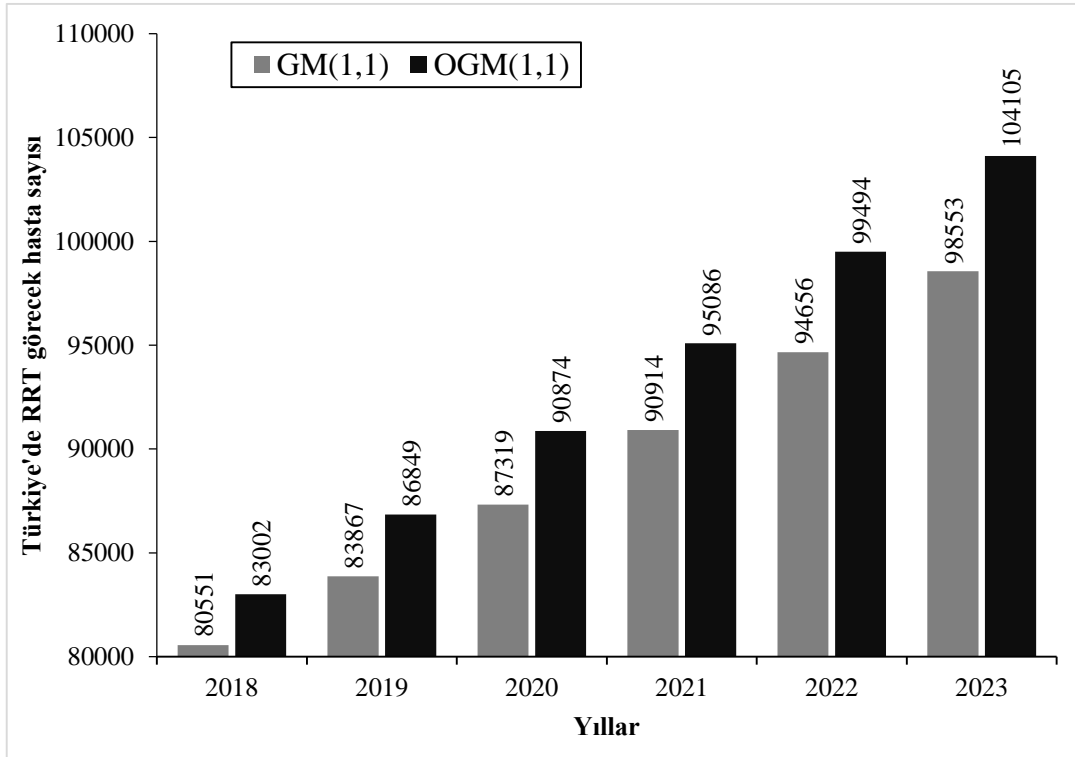
Bu çalışma, sağlık hizmetleri alanında tahmin etmede kullanılabilecek alternatif bir model sunuyor olması nedeniyle hem ilgili literatüre katkı sağlayacağı hem de karar vericilere ışık tutacağı düşünülmektedir. Gelecek çalışmalarda, bugün tahmin edilen bu veriler, gelecekte fiili veriler elde edildikten sonra tekrar karşılaştırılabilir ve tahmin başarısı değerlendirilebilir. Ayrıca farklı ülkelerin aynı hastalık verileri üzerinden, aynı tahmin etme modelleri kullanılabileceği gibi, farklı tahmin etme modelleri kullanılarak da tahminleme yapılabilir ve tahmin etme yöntemleri kıyaslanarak tahmin başarıları değerlendirilebilir.



**Şekil 1.** 2006-2017 Yılları arası gerçekleşen ile GM (1,1) ve OGM (1,1) modelleri aracılığı ile tahmin edilen RRT gören hasta sayıları



**Şekil 2.** 2007-2017 Yılları arasında RRT gören hasta sayısının GM (1,1) ve OGM (1,1) ile yakınsanma oranları



**Şekil 3.** GM (1,1) ve OGM (1,1) ile 2018-2023 yıllarına ilişkin RRT görece hasta sayısı tahminleri

#### Araştırmanın sınırlılıkları

Çalışmanın gerçekleştirilmesinde bazı sınırlılıkların varlığından söz edilebilir.

Bunlar; çalışmanın sadece bir hastalık üzerinden gerçekleştirilmesi, sadece bir ülkenin (Türkiye) verilerinden yararlanılması ve tahmin etmek için

kullanılan verilerin 12 yıl ile sınırlandırılmasıdır.

**Yazar katkıları:** Fikir/kavram: Araştırmanın konusunun oluşturulması; Tezcan Şahin, Saffet Ocak, Tasarım: Saffet Ocak, Tezcan Şahin, Veri toplama ve işleme: Saffet Ocak, Tezcan Şahin, Yorumlama: Tezcan Şahin, Saffet Ocak

**Çıkar çatışması:** Bu çalışma ile ilgili çıkar çatışması bulunmamaktadır.

**Mali destek:** Hiçbir kurum ya da kişiden mali destek alınmamıştır.

### Kaynaklar

- Özcan Y. Sağlık Kurumları Yönetiminde Sayısal Yöntemler, Kavuncubaşı Ş, Yıldırım S, Çev. Ankara, Türkiye: Siyasal Kitabevi; 2013.
- Dang HS, Huang YF, Wang CN, Nguyen TMT. An Application of the Short-Term Forecasting with Limited Data in the Healthcare Traveling Industry. *Sustainability* 2016; 8(1037):1-14.
- Eggers PW. Has the incidence of end-stage renal disease in the USA and other countries stabilized?, *Curr Opin Nephrol Hypertens* 2011; 20(3):241-245.
- Crews DC, Bello AK, Saadi G. Burden, Access, and Disparities in Kidney Disease, *Turk Journal of Nephrology* 2019;28(1): 1-7.
- Türk Nefroloji Derneği, 2017 Yılı Türk Böbrek Kayıt Sistemi Raporu, Erişim: <http://www.nefroloji.org.tr/folders/file/TND-2017-Kayit-Sistemi-Verileri.pdf> Erişim Tarihi: 10.06.2019.
- Satman I, Omer B, Tutuncu Y, et al. TURDEP-II Study Group: Twelve-year trends in the prevalence and risk factors of diabetes and prediabetes in Turkish adults, *Eur J Epidemiol* 2013;28 (2): 169-180.
- Lei M, Feng Z. A Proposed grey model for short-term electricity price forecasting in competitive power markets, *International Journal of Electrical Power & Energy Systems* 2012;43(1): 531-538.
- Yang X, Zou J, Kong D, Jiang G. The analysis of GM (1, 1) grey model to predict the incidence trend of typhoid and paratyphoid fevers in Wuhan City, China. *Medicine (Baltimore)* 2018; 97(34): 1-5.
- Wang YW, Shen ZZ, Jiang Y. Comparison of ARIMA and GM (1,1) models for prediction of hepatitis b in china, *PLoS ONE* 2018; 13(9):e0201987. <https://doi.org/10.1371/journal.pone.0201987>.
- Şahin U. Forecasting of Turkey's electricity generation and consumption with grey prediction method. *Mugla Journal of Science and Technology* 2018; 4(2): 205-209.
- Lin C.S., Liou F.M., Huang C.P. Grey forecasting model for CO2 emissions: A Taiwan study. *Applied Energy* 2011; 88(11): 2816-3820.
- Huang Y.L. Forecasting the demand for health tourism in Asian countries using a GM (1,1)-alpha model. *Tourism and Hospitality Management* 2012; 18(2): 171-181.
- Zang P, Jin Z. Prediction analysis of the prevalence of alzheimer's disease in china based on meta analysis. *Open Access Library Journal* 2020; (7): 1-13. doi: 10.4236/oalib.1106375.
- Öztürk Z, Bilgil H. Mathematical estimation of expenditures in the health sector in turkey with grey modeling. *Erciyes Üniversitesi Fen Bilimleri Enstitüsü Dergisi* 2019;35(3): 52-58.
- Şahin T. Ruh sağlığı ve hastalıkları polikliniğine olan talebin zaman serileri modelleri ile tahmini. *Hacettepe Sağlık İdaresi Dergisi* 2019a;22(4): 749-764.
- Iqelan BM. Forecasts of female breast cancer referrals using grey prediction model GM (1,1). *Applied Mathematical Sciences* 2017;11(54): 2647-2662.
- Jounini R, Lemlouma T, Maalaoui K. Employing grey model forecasting GM (1,1) to historical medical sensor data towards system preventive in smart home e-health for elderly person, *International Wireless Communications*



- and Mobile Computing Conference (IWCMC), 2016;1086-1091.
18. Zhang L, Wang L, Zheng Y, Wang K, Zhang X, Zheng Y. Time prediction models for echinococcosis based on gray system theory and epidemic dynamics, *Int J Environ Res Public Health* 2017;14(262): 1-14.
  19. Ene S., Öztürk N. Grey modelling based forecasting system for return flow of end-of-life vehicles. *Technological Forecasting & Social Change* 2017; 115: 155-166.
  20. Ma W, Zhu X, Wang M. Forecasting iron ore import and consumption of China using greymodel optimized by particle swarm optimization algorithm, *Resources Policy* 2013; 38 (2013): 613-620.
  21. Şahin U. Forecasting of Turkey's greenhouse gas emissions using linear and nonlinear rolling metabolic grey model based on optimization. *Journal of Cleaner Production* 2019b; 239: 118079.
  22. Şahin U. Future of renewable energy consumption in France, Germany, Italy, Spain, Turkey and UK by 2030 using optimized fractional nonlinear grey Bernoulli model. *Sustainable Production and Consumption* 2021; 25: 1-14.
  23. Ayvaz B, Kusakci AO. Electricity consumption forecasting for turkey with nonhomogeneous discrete grey model. *Energy Sources, Part B: Economics, Planning, and Policy* 2017;12(3): 260-267.
  24. Agrawal RK, Muchahary F, Tripathi MM. Ensemble of relevance vector machines and boosted trees for electricity price forecasting. *Applied Energy* 2019;250(C): 540-548.
  25. Falayi EO, Adepitan JO, Rabiun AB. Empirical models for the correlation of global solar radiation with meteorological data for Iseyin, Nigeria. *International Journal of Physical Sciences* 2008;3(9): 210-216.
  26. Li Y, Shi H, Han F, Duan Z, Liu H. Smart wind speed forecasting approach using various boosting algorithms, big multi-step forecasting strategy. *Renewable Energy* 2019;135: 540-553.
  27. Wen J.C., Huang K.H., Wen K.L. The study of  $\alpha$  in GM (1,1) model. *Journal of the Chinese Institute of Engineers* 2000; 23(5): 583-589.