

ARAŞTIRMA MAKALESİ

# RUH SAĞLIĞI VE HASTALIKLARI POLİKLİNİĞİNE OLAN TALEBİN ZAMAN SERİLERİ MODELLERİ İLE TAHMİNİ

TEZCAN ŞAHİN\*


## ÖZ

Bu çalışma, bir eğitim ve araştırma hastanesinin çocuk ve erişkin ruh sağlığı ve hastalıkları polikliniğine gelecek yıllarda oluşabilecek talebin belirlenmesini amaçlamaktadır. Bu amaca ulaşabilmek için Gri Tahmin Modeli  $GM(1,1)$ , Basit Üstel Düzeltme Modeli, Üstel Modelleme ve Doğrusal Regresyon Modeli kullanılmıştır. Araştırma verileri, 2012-2018 yılları arasında ortaya çıkan yedi yıllık talepten oluşmaktadır. Tahminde bulunulurken cinsiyet ve yaş değişkenleri aracılığı ile ayrıştırılmış tahminler yapılmıştır. Modellerin tahmin performansı ortalama mutlak hata yüzdesi (mean absolute percentage error-MAPE) ve kök ortalama kare hata (root mean square error-RMSE) ile ölçülmüştür. Karşılaştırmalar sonucunda  $GM(1,1)$ 'in (toplam için MAPE=8,82; RMSE=3487) diğer modellere göre daha iyi performans gösterdiği tespit edilmiştir. Bu nedenle gelecek tahmini  $GM(1,1)$  modeli ile gerçekleştirilmiştir. Sonuç olarak 2019-2023 yılları arasında belirtilen polikliniğe olan talebin cinsiyet bakımından hem kadın hem erkek; yaş bakımından hem 18 yaş altı hem de 18 yaş ve üstü ve toplam hasta sayısı bakımından da her geçen yıl artacağı, 2023'te 90.173 kişiye ulaşacağı öngörülmüştür.

**Anahtar Kelimeler:** Talep tahmini, gri tahminleme yöntemi, basit üstel düzeltme yöntemi, üstel modelleme, doğrusal regresyon modeli, ruh sağlığı ve hastalıkları

## MAKALE HAKKINDA

\*Dr. Öğretim Üyesi., Muğla Sıtkı Koçman Üniversitesi, Sağlık Bilimleri Fakültesi, Sağlık Yönetimi Bölümü, Menteşe, 48000 Muğla, tezcankasmer@mu.edu.tr

 [orcid.org/0000-0002-4712-4161](https://orcid.org/0000-0002-4712-4161)

Gönderim Tarihi: 27.02.2019

Kabul Tarihi: 13.11.2019

## Atıfta Bulunmak İçin:

Şahin, T. (2019). Ruh Sağlığı ve Hastalıkları Polikliniğine Olan Talebin Zaman Serileri Modelleri İle Tahmini. Hacettepe Sağlık İdaresi Dergisi, 22(4): 749-764.

## FORECASTING OF DEMAND TO THE PSYCHIATRIC OUTPATIENT CLINIC USING TIME SERIES MODELS

TEZCAN ŞAHİN\*


### ABSTRACT

This study aims to determine the demand that may occur in the child and adult psychiatric outpatient clinic of an education and research hospital in the following years. To achieve this goal, Grey Prediction Method GM(1,1), Simple Exponential Smoothing Model, Exponential Model and Linear Regression Model were used. The data consist of seven-year demand between the years 2012-2018. Forecasting were made through disaggregated estimates by gender and age. The estimation performance of the models was measured by the mean absolute percentage error (MAPE) and root mean square error (RMSE). As a result of the comparisons, it was found that GM(1,1) (for total MAPE=8.82; RMSE=3487) performed better than the other models. For this reason, the future forecasting was realized with GM(1,1) model. As a result, it was predicted that the demand for the psychiatric outpatient clinic between 2019 and 2023 will increase each passing year in terms of age (both under 18 years and above), gender (both men and women), total number of patients and will be to reach 90173 people in 2023.

**Keywords:** Demand forecasting, grey prediction model, simple exponential smoothing model, exponential model, linear regression model, psychiatry

### ARTICLE INFO

\* Muğla Sıtkı Koçman University, tezcankasmer@mu.edu.tr

 [orcid.org/0000-0002-4712-4161](https://orcid.org/0000-0002-4712-4161)

Received: 27.02.2019

Accepted: 13.11.2019

### Atıfta Bulunmak İçin:

Şahin, T. (2019). Ruh Sağlığı ve Hastalıkları Polikliniğine Olan Talebin Zaman Serileri Modelleri İle Tahmini. Hacettepe Sağlık İdaresi Dergisi, 22(4): 749-764.

## I. GİRİŞ

Sağlık hizmeti sunumunda çeşitli sağlık kurumları rol oynamakla birlikte, bunların içerisinde en fazla kaynak tüketen ve sağlık hizmeti arzında en yüksek paya sahip olanlardan biri hastanelerdir. Hastanelerin temel işlevi, hasta ve yaralıları ayakta veya yatış yoluyla tanı ve tedavi hizmetleri sunmaktır (Kavuncubaşı, Yıldırım 2012). Bu kurumlara başvuranların hizmetten yararlanması reddedilmez, ertelenemez ve ertelenmesi ise sakatlıktan ölüme kadar telafisi mümkün olmayan çok ciddi sorunlar doğurabilir. Dolayısıyla bu kurumlarda hizmetin kesintisiz biçimde devam etmesi ve talebe hızlı bir biçimde cevap verilmesi gerekir. Etkin bir sağlık hizmeti sunumu için de, hizmetin varlığının sebebi olan talebe ilişkin araştırmaların yapılmasına ihtiyaç vardır. Sağlık hizmetlerine olan talebin öngörülmesi ve belirlenebilmesi, sağlık hizmetlerinin iyi biçimde planlanması ve uygulanmasına olanak sağlaması nedeniyle hastane yönetimi bakımından oldukça önemli bir konudur (Abdel-Aal, Mangoud 1998). Tahmin etme konusunda tecrübe ve sezgi gibi nitel yöntemlerle birlikte ekonomik göstergeler ve istatistiksel tekniklerin dâhil olduğu nicel yöntemlerin de kullanıldığı görülmektedir. Bu çalışma, bir eğitim ve araştırma hastanesinin ruh sağlığı ve hastalıkları polikliniğine olan geçmiş yedi yıllık talep verilerinden yola çıkılarak gelecek beş yıl içerisinde karşılaşılabilecek talepleri GM(1,1) ve Basit Üstel Düzeltme Modeli, Üstel Modelleme ve Doğrusal Modelleme ile tahmin etmeyi amaçlamaktadır.

## II. SAĞLIK HİZMETLERİNDE TALEP TAHMİNİ

Etkili sağlık hizmeti sunum sistemleri, zaman içinde ortaya çıkan hizmet talepleri için kaynakları doğru kullanmayı amaçlar. Kaynak tahsis kararları stokastik belirsizlik altında yapılmaktadır (Jalalpour et al. 2015). Çünkü sağlık hizmet sunumu doğal belirsizlik içermekte, karmaşık ilişkiler sonucu ortaya çıkmakta ve toplumun bütününe ilgilendirmektedir. Bu nedenlerden dolayı talep tahmini ve kapasite yönetimi sağlık hizmetleri için oldukça önemli ve karmaşık görevlerdir (Barros et al. 2011). Sağlık hizmetleri sistemlerindeki verilerin doğru şekilde tahmin edilmesi, karar vericilerin hizmet ihtiyacını öngörmelerini ve zaman içinde kaynakları yönetme konusunda bilinçli kararlar almalarını sağlar (Jalalpour et al. 2015). Ayrıca güvenilir bir tahmin, yalnızca yöneticilerin gelecekteki fırsatları açıkça görmelerine yardımcı olmakla kalmaz, aynı zamanda potansiyel riskleri azaltmaya ve kaynakları etkin olarak kullanmaya da olanak sağlar (Dang et al. 2016).

Hastanede kapasite; hasta ve hekimin karşılaştığı yerler (oda veya kabinler), ameliyathaneler ve yataklar gibi mevcut fiziksel tesisler ve teşhis ve tedavi sürecinde rol oynayan hekimler, hemşireler gibi insan kaynakları ile belirlenebilir. Bu kapasite, verilen bir hizmet seviyesini garanti altına almak ve kaynak kullanımını optimize etmek için planlanmalıdır. Bunun için, gelecekteki hasta sayısının ve türünün tahmin edilmesi gerekmektedir (Barros et al. 2011). Böylece toplumun sağlık gereksinimlerini karşılayacak hizmetlerin yeterli miktarda sunulması için gerekli kaynakların planlanması ve tahsis edilmesi sağlanmış olacaktır. Nihayetinde doğru yapılan sağlık hizmet planlaması sayesinde kaynak israfı ve verimsizlik gibi düşük performansla yol açan sorunların önüne geçilebilecektir.

Karar verme sürecinde değerli bilgiler, güvenilir bir tahmin modelinin çıktısı ile elde edilir ve bu nedenle tahmin için doğru modeli seçmek tüm tahmin süreci için çok önemlidir. Doğru model, karar vericilerin değişen gelecek trendlerini gerçekleştirmelerine yardımcı olmak için etkili bir araç olarak kullanılır. Uygun bir tahmin modelinin seçilmesine yardımcı olmak için kullanılan bazı kriterler vardır. Ancak, mevcut veriler ve veri özellikleri, model seçimini etkileyen çok önemli kriterlerdir (Dang et al. 2016).

Sağlık hizmetlerine ilişkin talep tahmininde bulunmak için çeşitli modeller kullanılmıştır. Örneğin, Wang ve diğerleri (2016) Tip 2 diyabette tokluk şekeri tahmin etmek için

geliştirilmiş GM(1,1) modelini araştırmayı amaçlamışlar ve sonuç olarak gelişmiş GM(1,1) modelinin, tokluk şekeri tahmininde mükemmel performansa sahip olduğunu tespit etmişlerdir. Iqelan (2017), GM(1,1) modelini, Filistin'de meme kanseri için başvuran toplam kadın sayısını tahmin etmek için kullanmıştır. Sonuçlar, GM(1,1) modelinin MAPE değerlerine göre iyi tahmin yeteneği sergilediğini göstermiştir. Jounini ve diğerleri (2016) yaşlı bireyler için akıllı ev e-sağlık yönetiminde önleyici sisteme yönelik tarihsel tıbbi sensör verilerini tahminlemeyi amaçlamışlardır. Bunun için toplanan verilere GM(1,1) tahminini uygulamışlar ve Box-Jenkins ARIMA<sup>3</sup>yla elde edilen sonuçları karşılaştırmışlardır. Simülasyon sonuçları, GM(1,1)'in daha doğru tahmin değerlerine sahip olması nedeniyle Box-Jenkins ARIMA'dan daha verimli olduğunu göstermiştir. Dang ve diğerleri (2016) çeşitli güncel tahmin yöntemlerinin öngörülen performansını belirlemek ve uygulamalarını incelemek amacıyla üstel düzeltme modeli, GM(1,1) ve değiştirilmiş Lotka Volterra modelini (L.V.)<sup>4</sup> kullanmışlardır. Amaçları, 2001'den 2013'e kadar Asya'daki altı (Tayland, Singapur, Malezya, Kore, Tayvan ve Hindistan) varış noktasına gelen medikal turist sayısına dayanarak gelecek yıllara ilişkin tahmin yapmaktır. Sonuçlar L.V. modelinin, diğer iki modelden daha yüksek tahmin gücüne sahip olduğunu göstermiştir. Wang ve diğerleri (2018) Çin'de hepatit B görülme oranının tahmini için ARIMA ve GM(1,1) modellerini karşılaştırmışlar ve ARIMA modelinin, daha iyi tahmin performansı gösterdiğini tespit etmişlerdir. Sarıyer (2018), bir eğitim hastanesi acil servisinde talebi zaman serileri modelleri ile tahmin etmeyi amaçlamış ve ARIMA ve SARIMA modellerini kullanmıştır. Kullanılan modellerin acil servise gelen hasta sayısını tahmin etmek için kullanılabilmesi ve bu modellerin iyi performans sergileyeceği sonucuna ulaşılmıştır. Abdullah ve diğerleri (2012), Kelantan'daki 2003-2010 yılları arasında tüberküloz vakalarının tespiti için en iyi zaman serisi modelini belirlemeyi ve gelecek 2 yıl için tüberküloz vakalarının sayısını tahmin etmeyi amaçladıkları çalışmalarında tek değişkenli modeller kullanmışlardır. Sonuç olarak çift üstel düzeltme tekniğinin, basit üstel düzeltmeyle karşılaştırıldığında en iyi zaman serisi modeli olduğunu tespit etmişlerdir. Jones ve diğerleri (2008) yaptıkları çalışmada üç farklı hastanenin acil servisindeki (AS) günlük AS hasta hacimlerini tahmin etmek için çeşitli istatistiksel tahmin yöntemlerinin kullanımını araştırmayı amaçlamışlardır. Yazarlar, her tesisteki günlük hasta hacimlerini tahmin etmek için mevsimsel otoregresif entegre hareketli ortalama, zaman serisi regresyonu, üstel düzeltme ve yapay sinir ağı modellerinin kullanımını değerlendirmişler ve sonuç olarak takvim değişkenlerine dayanan çoklu doğrusal regresyonun, AS'de günlük hasta hacimlerini tahmin etmede makul bir yaklaşım olduğunu tespit etmişlerdir. Thirunavukkarasu (2000), Hindistan'da yıllık tüberküloz hastalığı oluşumunun gelecekteki hastalık miktarını tahmin etmek için farklı düzeltme tekniklerini kullanmıştır. Sonuç olarak, Holt'un doğrusal modelinin Hindistan'daki tüberküloz vakalarının tespiti için en uygun model olduğu tespit edilmiştir.

Bu çalışmada ruh sağlığı ve hastalıkları polikliniğine ilişkin talep tahmini için GM(1,1), basit üstel düzeltme modeli, üstel modelleme ve doğrusal regresyon modeli tercih edilmiştir. Çünkü gri modelde matematiksel arka plan oldukça basittir ve tahmin performansı yüksek doğruluk içerebilir. Basit üstel düzeltme modeli ise az sayıda veri gereksinimi, basit hesaplamalar ve diğer modellerle karşılaştırıldığında en güncel bilgileri vurgular (Dang et al. 2016). Doğrusal regresyon modeli, sağlık verilerinde trendi tanımlamak için de kullanılan klasik bir yöntemdir (Özcan 2013). Üstel modelleme, doğrusal olmayan deterministik eğilimleri göz önünde bulundurması nedeniyle tahmin modeli geliştirmede önemli bir

<sup>3</sup> Box-Jenkins yöntemi, zaman serisi analiz yöntemi olup kesikli, doğrusal stokastik süreçlere dayanmaktadır. Başlıca Box-Jenkins tahmin modelleri otoregresif (autoregressive-AR) entegre(integrative-I) hareketli ortalama (moving average-MA) ve mevsimsel (seasonal-S) otoregresif entegre hareketli ortalama modelleridir (Sarıyer 2018).

<sup>4</sup> Orjinal Lotka-Volterra modeli, 1950'lerde doğanın ekolojik yasasını belirlemek için A. Lotka ve V. Volterra tarafından önerilen avcı ve avın farklı denklemlerine dayanarak inşa edilmiştir. Esas olarak, bir ortamda iki veya daha fazla çeşitlendirilmiş rakip arasındaki etkileşimli ilişkiyi ele almaktadır. Son zamanlarda, toplum, ekonomi, işletme, pazarlama vb. konularla ilgili dinamik rekabetin analizinde de L.V. modeli kullanılmaktadır (Dang et al. 2016).

yöntemdir (Moffat et al. 2014). Modeller, bu özellikleri ile birlikte sağlık hizmetlerine ilişkin tahmin çalışmalarında da sıklıkla kullanıldığı, güncel yöntemler olduğu ve yüksek doğruluk içerdiği literatür çalışmalarından anlaşıldığı için bu çalışmada da tercih edilmiştir.

### III. TAHMİN MODELLERİNE GENEL BİR BAKIŞ

#### 3.1. GM(1,1) Yöntemi

Gri tahminleme, zaman serilerini tahmin etmenin bir yöntemidir, gri sisteme odaklanır ve 1980'lerde Prof. Deng tarafından geliştirilmiştir (Lei, Feng 2012). Gri sistem beyaz sistemden ve siyah sistemden farklıdır. Beyaz sistem, belli problemler anlamına gelir ve tüm bilgiler bilinir. Siyah sistemler, veriler hakkında hiçbir şey bilinmediği anlamına gelir. Gri sistem ise, belirsiz sorunlar ile birlikte eksik bilgiler olduğu anlamına gelir (Wang et al. 2018). Gri sistemlerde tahminlemede çeşitli modeller geliştirilmiştir. GM(1,1), gri Verhulst, DGM(1,1) bunlardan bazılarıdır. GM(1,1), temel gri tahmin modelinden biridir ve model ifadesi birinci dereceden denklem ve tek değişken anlamına gelir. GM(1,1) en yaygın kullanılan modeldir ve birçok uygulamada başarılı bir şekilde kullanılmıştır (Zhang et al. 2017). İşletmecilik (Rahman, Zahura 2018; Ayvaz ve diğerleri 2014), enerji tüketimi (Şahin 2018a; Şahin 2018b; Lei, Feng 2012; Pao et al. 2012; Lee, Tong 2011), hastalık tahmini (Wang et al. 2018; Iqelan 2017; Wang et al. 2016; Mondal, Pramanik 2015; Zhang et al. 2017) ve benzeri gibi alanlarda GM(1,1) modeliyle çok çeşitli problemler test edilmiştir.

GM(1,1)'in modellenmesi süreci aşağıdaki adımlarda özetlenebilir (Iqelan 2017; Jounini et al. 2016; Wang et al. 2016):

**1. Adım:** Orijinal zaman serisi verileri aşağıdaki gibi gösterilir ve burada üst simge (0) orijinal veri sırasını gösterir,  $x^{(0)}(k)$ , k zamanındaki zaman serisi verilerini temsil eder ve  $n \geq 4$  için  $k=1,2,\dots,n$ .

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

**2. Adım:** Bu adımda, kümülatif üretim operatörü (accumulated generation operator) kullanılarak  $x^{(1)}$  elde edilir:

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

Burada;

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

**3. Adım:** GM(1,1) modeli, birinci dereceden diferansiyel denklem ile sırasıyla şu şekilde tanımlanabilir:

$$\frac{dx^{(1)}}{dt} + ax^{(1)} = b \quad (4)$$

$$x^{(0)}(k) + az^{(1)}(k) = b, k = 2, 3, \dots, n. \quad (5)$$

GM(1,1) modelinin a ve b parametreleri sırasıyla gelişme katsayısı ve sürücü katsayısıdır. Burada  $z^{(1)}(k)$ ,  $X^{(1)}$ 'in ardışık ortalama dizisidir ve denklem (6)'da belirtilmektedir.

$$z^{(1)}(k) = 0.5x^{(1)}(k) + 0.5x^{(1)}(k-1), k = 2, 3, \dots, n. \quad (6)$$

**4. Adım:** Denklem (4)'te a ve b parametrelerinin çözümü için en küçük kareler yöntemi kullanılabilir ve bunun için aşağıdaki matris formları elde edilir:

$$Y = \begin{bmatrix} x^{(0)}(2) \\ x^{(0)}(3) \\ x^{(0)}(4) \\ \vdots \\ x^{(0)}(n) \end{bmatrix}, B = \begin{bmatrix} -z^{(1)}(2) & 1 \\ -z^{(1)}(3) & 1 \\ -z^{(1)}(4) & 1 \\ \vdots & \vdots \\ -z^{(1)}(n) & 1 \end{bmatrix}, v = \begin{bmatrix} a \\ b \end{bmatrix} \quad (7)$$

Bu matris formu şöyle yazılabilir:

$$Y = Bv \quad (8)$$

Burada B ve Y sırasıyla birikmiş  $n \times 2$  matrisi ve sabit  $n \times 1$  vektörüdür. v vektörü ise aşağıdaki formül kullanılarak tahmin edilebilir.

$$v = \begin{bmatrix} a \\ b \end{bmatrix} = (B^T B)^{-1} (B^T Y) \quad (9)$$

**5. Adım:** a ve b parametreleri elde edildikten sonra k zamanda  $X^{(1)}$ 'in çözümü için aşağıdaki denklem kullanılır:

$$\hat{x}^{(1)}(k) = \left( x^{(0)}(1) - \frac{b}{a} \right) e^{-\alpha(k-1)} + \frac{b}{a}, \quad k = 2, 3, \dots, n \quad (10)$$

Burada  $\hat{x}^{(1)}(k)$ , k zamanda  $x^{(1)}(k)$ 'nin tahmin edilen değeridir. Bu nedenle Denklem (10), GM(1,1) modelinin tahmin denklemi olarak da adlandırılır. Burada;

$$\hat{x}^{(0)}(1) = x^{(0)}(1) \quad (11)$$

$$\hat{x}^{(0)}(k) = \hat{x}^{(1)}(k) - \hat{x}^{(1)}(k-1), \quad k = 2, 3, \dots, n \quad (12)$$

Ayrıca, Denklem (12) aşağıdaki gibi de ifade edilebilir:

$$\hat{x}^{(0)}(k+1) = (1 - e^{-\alpha}) \left( x^{(0)}(1) - \frac{b}{a} \right) e^{-\alpha k}, \quad k = 2, 3, \dots, n \quad (13)$$

### 3.2. Basit Üstel Düzeltme Modeli

50 yıldan fazla yaygın kullanımın ardından üstel düzeltme, bugün halen mevcut en pratik ve en popüler tahmin yöntemlerinden biridir (Bergmeir et al. 2016). Bu yöntem, net bir eğilim veya mevsimsel düzen bulunmayan verileri tahmin etmek için uygundur (Hyndman, Athanasopoulos 2018). Yöntemin, sıklıkla tercih edilmesinin en önemli nedenleri; açık, anlaşılır, şeffaf olması ve birçok farklı duruma uyum yeteneğidir. Bu yöntemin üç temel bileşeni bulunmaktadır: hata, eğilim ve mevsimsellik değişkenleri (Yağimli, Ergin 2017). Üstel düzeltme modelinin temel düşünüşü, son gözlemlerin eski gözlemlere göre tahmin etmede etkili olduğu, yani daha fazla ağırlık almaları gerektiğidir (Bergmeir et al. 2016). Buna göre tahmin edilen yeni değer, önceki tahmin artı tahmin hatasının yüzdesi tarafından tahmin edilir ve bu modelin matematiksel formülü aşağıdaki gibi gösterilir (Dang et al 2016):

$$\bar{Y}_{i+1} = \alpha Y_i + (1 - \alpha) \bar{Y}_i \quad (14)$$

Burada;

$\hat{Y}_{i+1}$ :  $i + 1$  zaman aralığı için öngörülen değer

$\hat{Y}_i$ :  $i$  zaman aralığı için öngörülen değer

$\alpha$ : düzeltme katsayısı

Bu modelde,  $\alpha$  değeri 0 ile 1 arasındadır. Düzeltme katsayısı, tahmin başarısını belirleyen kilit bir faktördür ve 1'e yakın olduğunda, yeni tahmin, önceki tahmindeki hata için önemli bir düzeltme içerir, 0'a yakın olduğunda ise, yeni tahmin için çok az düzeltme gerçekleştirilir (Dang et al. 2016). Düzeltme katsayısının belirlenmesinde MAPE değerini en düşük yapan  $\alpha$  değeri kullanılır. Minimum hata ile en iyi tahmin modelini belirlemeye çalışmak için sürekli olarak 0'dan 1'e kadar farklı  $\alpha$  değerleri denenir (Ravinder 2016).

### 3.3. Doğrusal Regresyon Modeli

Doğrusal regresyon modeli, geniş kullanım alanına sahip bir modelleme tekniğidir (Koyuncuğil, Özgülbaş 2009). Bu yöntem, verilerin dağılımını temsil eden bir doğrunun denkleminin bulunması için kullanılır ve en küçük kareler yöntemi olarak da adlandırılmaktadır. Bu yöntemle tahmin hatalarının kareleri toplamının minimize edilmesi mümkün hale gelir (Özcan 2013). Doğrusal regresyon modeline ait eşitlik Denklem (15)'te verilmektedir (Moffat, Akpan 2014; Özcan 2013).

$$y = a + bt \quad (15)$$

Burada,  $y$  bağımlı değişkeni (tahmin edilen hasta sayısı);  $t$  bağımsız değişkeni (zaman);  $a$ , sabit değeri ve  $b$ , regresyon katsayısını ifade etmektedir.

### 3.4. Üstel Modelleme

Zaman serileri analizinde, eğilim işlevini tahmin etmek zorunludur, çünkü zaman serilerinin temel özellikleri hakkında bilgi sağlar. Trendin tahmin edilmesinin bir yolu, trendin ortaya çıktığı herhangi bir formata uyum sağlayacak bazı işlevleri modellemektir. Önceki çalışmaların lineer deterministik ve stokastik trendler arasındaki ayrımcılığa daha fazla ilgi gösterdiği açıktır. Bununla birlikte, bazı çalışmalar doğrusal bir eğilim modellerken, doğrusal olmayan deterministik eğilim uygulamanın önemine dikkat çekmiş ve bu doğrusal olmayan deterministik trendlerin, kuadratik trend veya üstel trend şeklinde olabileceğini, dolayısıyla ikinci dereceden ve üstel eğilimleri göz önünde bulundurma gereğini vurgulamıştır. Üstel modele ait eşitlik Denklem (16)'da verilmektedir (Moffat, Akpan 2014; Şahin 2019).

$$y = a * \exp(bt) \quad (16)$$

Burada,  $y$  bağımlı değişken olup hasta sayısını;  $t$  bağımsız değişken olup yılı,  $a$  ve  $b$  ise modele ait katsayıları ifade etmektedir.

## IV. TAHMİN PERFORMANSINA İLİŞKİN DEĞERLENDİRMELER

Literatürde, tahmin modellerinin doğruluğunu tespit etmek için kullanılacak birçok farklı ölçüt bulunmaktadır. Bu çalışmada kullanılan modellerin tahmin performansları Ortalama Mutlak Hata Yüzdesi (MAPE) ve Hata Karelerinin Ortalama Kökü (RMSE) değerlerinin kullanılmasıyla ölçülmüştür. MAPE ve RMSE değerleri, tahmin etme yöntemlerinin performans karşılaştırılmasında yaygın bir biçimde kullanılan (Ayvaz,

Kusakci 2017; Li et al. 2019; Agrawal et al. 2019) kriterler olması sebebiyle bu çalışmada tercih edilmiştir. MAPE ve RMSE değerlerine ait formüller sırasıyla Denklem (17) ve Denklem (18)'de verilmektedir (Iqelan 2017; Dang et al. 2016).

$$MAPE (\%) = \frac{1}{n} \sum_{k=1}^n \frac{|x^{(0)}(k) - \hat{x}^{(0)}(k)|}{x^{(0)}(k)} * 100\% \quad (17)$$

$$RMSE = \sqrt{\frac{\sum_{k=1}^n (x^{(0)}(k) - \hat{x}^{(0)}(k))^2}{n}} \quad (18)$$

Burada;  $x^{(0)}(k)$ , k zamanındaki orijinal değeri,  $\hat{x}^{(0)}(k)$  tahmin değerini ve  $n$  gözlem sayısını belirtmektedir.

MAPE kriterine göre tahmin yöntemlerinin performans seviyesi Tablo 1'de verilmektedir.

**Tablo 1. GM(1,1) Modelinin Tahmin Seviyesini Değerlendirme Kriterleri**

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

**Kaynak:** Iqelan (2017)

RMSE, bir model tarafından tahmin edilen değerler ile gözlemlenen değerler arasındaki farkların ölçülmesinde sıklıkla kullanılmakla birlikte bu değer düşük olması arzu edilir (Falay et al. 2008). Bu çalışmada, kullanılan tahmin modelleri arasında en iyisinin belirlenmesinde en düşük MAPE ve RMSE değerine sahip olması kriteri göz önünde bulundurulmuştur (Ayvaz, Kusakci 2017; Agrawal et al. 2019).

## V. UYGULAMA ve BULGULAR


### 5.1. Araştırma Verileri ve Uygulamaları

Araştırmada ruh sağlığı ve hastalıkları polikliniğinin tercih edilmesinin bazı sebepleri vardır. Türkiye Ruh Sağlığı Profili Çalışmasının raporuna göre Türkiye'de nüfusun %18'i yaşam boyu bir ruhsal hastalık geçirmekte, çocuk ve ergenlerde klinik düzeyde sorunlu davranış oranı %11 düzeyindedir. Ayrıca ulusal düzeyde hastalık yükü nedenlerinin temel hastalık gruplarına göre dağılımı yapıldığında, kardiyovasküler hastalıklardan sonra %19 ile ikinci sırada psikiyatrik hastalık grubunun yer aldığı görülmektedir (Sağlık Bakanlığı 2011). Dünya nüfusunun artması ve bununla birlikte yaşanan nüfus oranının da artması (worldometers) bir diğer önemli faktördür. Bunlara ek olarak toplumda stres, saldırgan davranışlar, cinsel istismar, mobbing gibi kavramların daha fazla dile getirilemeye başlanması ve daha fazla vaka sayısı ile karşılaşılması diğer önemli sebeplerdir. Örneğin 2011 yılında 2.001 kişi, 2012 yılında 2.850 kişi, 2013 yılında 4.870 kişi, 2014 yılında 6.659 kişi, 2015 yılında 9.005 kişi ve 2016 yılında 12.877 kişi Mobbing ile Mücadele Derneğine başvuruda bulunmuştur (DHA 2017). Çocuk cinsel istismarı ile ilgili 2002 yılında 4.988 dava var iken 2015 yılında 16.957 dava açılmıştır (İHA 2018). Bu olguların ruh sağlığı hizmetlerine yönelik talepleri ne şekilde etkilediği ve dolayısıyla bu konuda gelecekte sağlık hizmetlerine ilişkin ne tür planlamalar yapılması gerektiği önemli bir husustur. Nitekim bu sağlık hizmeti sunacak olanların aslen hekimler ile birlikte diğer sağlık profesyonellerinin olduğu ve bu hizmetin sağlanabilmesi için de çeşitli kaynakların bu alana ayrılması gerekliliği ön plana çıkmaktadır.



Araştırma, 01.01.2012 ile 31.12.2018 tarihleri arasında bir eğitim ve araştırma hastanesinin çocuk ve yetişkin ruh sağlığı ve hastalıkları polikliniklerinde muayene olan toplam kişi sayısı verileri üzerinden gerçekleştirilmiştir. Dönemsellikten arındırılmış yıllık değişimleri göstermek için veriler aylık değil yıllık bazda analize dâhil edilmiştir. Araştırma verileri, hastane veri tabanından elde edilmiş ve yaş ve cinsiyet değişkenleri bakımından değerlendirme yapılmıştır. Çünkü nüfusun yaş ve cinsiyet bakımından bileşimi, sağlık talebini etkilemektedir (Mutlu, Işık 2005). Yaş bakımından veriler dönemsel özellikler dikkate alınarak; 18 yaş altı (çocukluk ve ergenlik), 18 ve üstü yaş (yetişkinlik ve yaşlılık) şeklinde kategorize edilmiştir. Araştırmada toplam 7 yıllık veri kullanılmıştır<sup>5</sup>. Bu dönemlere ait veriler Grafik 1’de sunulmuştur.

**Grafik 1. 2012-2018 Yılları Arası Çocuk ve Yetişkin Ruh Sağlığı ve Hastalıkları Polikliniklerine Olan Talepler**



Mevcut durum değerlendirildiğinde, 2019 Şubat ayı itibariyle araştırmanın yapıldığı hastanede toplam 7 yetişkin, 3 çocuk-ergen ruh sağlığı ve hastalıkları uzmanı bulunduğu hastane internet sitesinden tespit edilmiştir. Son veri olan 2018 yılına göre bir inceleme yapıldığında;

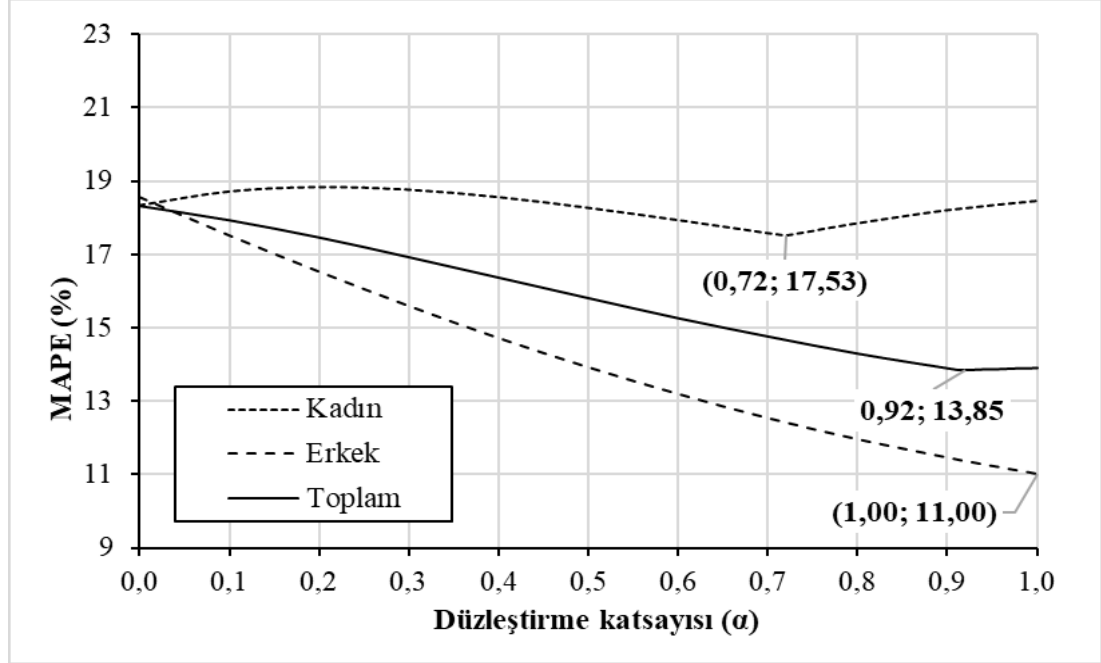
- 18 yaş altı toplam 12.533 hasta muayene olmuştur. Bu veri bakımından değerlendirildiğinde hekim başına düşen hasta sayısı yaklaşık ortalama 4177, 1000 kişi başına düşen uzman hekim ortalaması ise 0,2’dir.
- 18 ve üstü yaş aralığında ise toplam 40.155 hasta muayene olmuştur. Bu veri bakımından değerlendirildiğinde hekim başına düşen hasta sayısı yaklaşık ortalama 5736, 1000 kişi başına düşen uzman hekim ortalaması ise 0,17’dir.

<sup>5</sup> Araştırmada toplam 7 yıllık veri kullanılmasının sebebi, hastanenin 2012 yılında yeni bir bilgi işlem sistemi kullanmaya başlamış olmasıdır. 2012 yılı öncesi verilerin bu dönemden sonraki verilerle uyumsuzluğu araştırmada geniş çaplı veri kullanmayı kısıtlamıştır.

## 5.2. Model Karşılaştırmaları

Basit üstel düzeltme modelinin uygulanmasında  $\alpha$  değerinin tespit edilmesi sürecinde MAPE oranının en düşük olduğu noktadaki değer esas alınmış ve cinsiyet bakımından tespitine ilişkin örnek bir değerlendirme Grafik 2’de gösterilmiştir. Buna göre, kadın değişkeninde en düşük MAPE değeri olan 17,53 için  $\alpha$  değeri 0,72; erkek değişkeninde MAPE değeri 11,00 için  $\alpha$  değeri 1,00; toplam bakımından ise  $\alpha$  değeri 13,85 olarak bulunmuştur.

**Grafik 2. Basit Üstel Düzeltme Modelinde  $\alpha$  Değerinin Tespitine İlişkin Örnek Bir Değerlendirme**



Doğrusal ve üstel modellere ait Denklem (15) ve Denklem (16)’nın çözümü için regresyon analizi sonucu elde edilen katsayılar Tablo 2’de verilmektedir.

**Tablo 2. Doğrusal ve Üstel Modellere Ait Katsayılar**

Model	Yaş		Cinsiyet		Toplam
	18 yaş altı	18 yaş ve üstü	Kadın	Erkek	
Doğrusal regresyon modeli	$a = 6101$	$a = 16926$	$a = 11263$	$a = 11783$	$a = 23046$
	$b = 853.7$	$b = 2438.7$	$b = 1420.8$	$b = 1869.3$	$b = 3290.1$
Üstel modelleme	$a = 6472.8$	$a = 18532$	$a = 12075$	$a = 13037$	$a = 25140$
	$b = 0.0912$	$b = 0.0845$	$b = 0.0788$	$b = 0.0921$	$b = 0.0857$

Bu çalışmada kullanılan doğrusal regresyon modeli, üstel modelleme, basit üstel düzeltme ve GM(1,1) modellerinin tahmin performansları karşılaştırılması için bu modellere ait MAPE ve RMSE değerleri hesaplanmıştır. GM(1,1) modelinde tahmin edilen ilk değer, gerçekleşen ilk değere eşit kabul edildiği için bu çalışmada kullanılan tüm modellerde ilk değerlere ait MAPE ve RMSE değerleri göz önünde bulundurulmamıştır. Tablo 3’te bu çalışmada kullanılan modellere ait MAPE ve RMSE değerlerinin sonuçları verilmektedir. Buna göre, MAPE ve RMSE kriterleri bakımından GM(1,1) modeli, diğer modellerden daha iyi sonuçlar vermektedir. Buna ek olarak GM(1,1) modeli; erkek, 18 yaş altı ile toplam talep bakımından yüksek, kadın ile 18 yaş ve üstü bakımından iyi şekilde sınıflandırılan MAPE

değerlerine sahiptir. Bu nedenle gelecek tahminin yapılmasında GM (1,1) modeli kullanılarak öngörüle bulunulmuştur.

**Tablo 3. Kullanılan Modellerin Tahmin Performansının Karşılaştırılması**

Doğruluk Ölçüleri	Model	Yaş		Cinsiyet		Toplam
		18 yaş altı	18 yaş ve üstü	Kadın	Erkek	
MAPE (%)	Basit üstel düzeltme	14,79	18,24	17,53	11,00	13,85
	Doğrusal modelleme	8,57	14,23	12,48	8,05	9,93
	Üstel modelleme	8,41	12,57	11,89	6,65	8,89
	GM (1,1)	7,51	11,01	11,71	6,42	8,82
RMSE	Basit üstel düzeltme	1595	6251	3866	3419	7261
	Doğrusal modelleme	824	4095	2426	1940	4326
	Üstel modelleme	840	3956	2358	1805	4135
	GM (1,1)	823	3387	2051	1473	3487

### 5.3. Gelecek Talep Tahminine İlişkin Bulgular

Beş yıllık talep tahmini için kadın, erkek, 18 yaş altı, 18 yaş ve üstü ile toplam talep için aşağıdaki denklemler (19-23) kullanılarak GM(1,1) modelleri oluşturulmuştur.

$$\hat{x}^{(0)}(k)|_{Kadın} = \left(15284 - \frac{-0.1201}{9860.2}\right) e^{0.1201(k-1)} \cdot (1 - e^{0.1201}) \quad (19)$$

$$\hat{x}^{(0)}(k)|_{Erkek} = \left(16006 - \frac{-0.1241}{11290.8}\right) e^{0.1241(k-1)} \cdot (1 - e^{0.1241}) \quad (20)$$

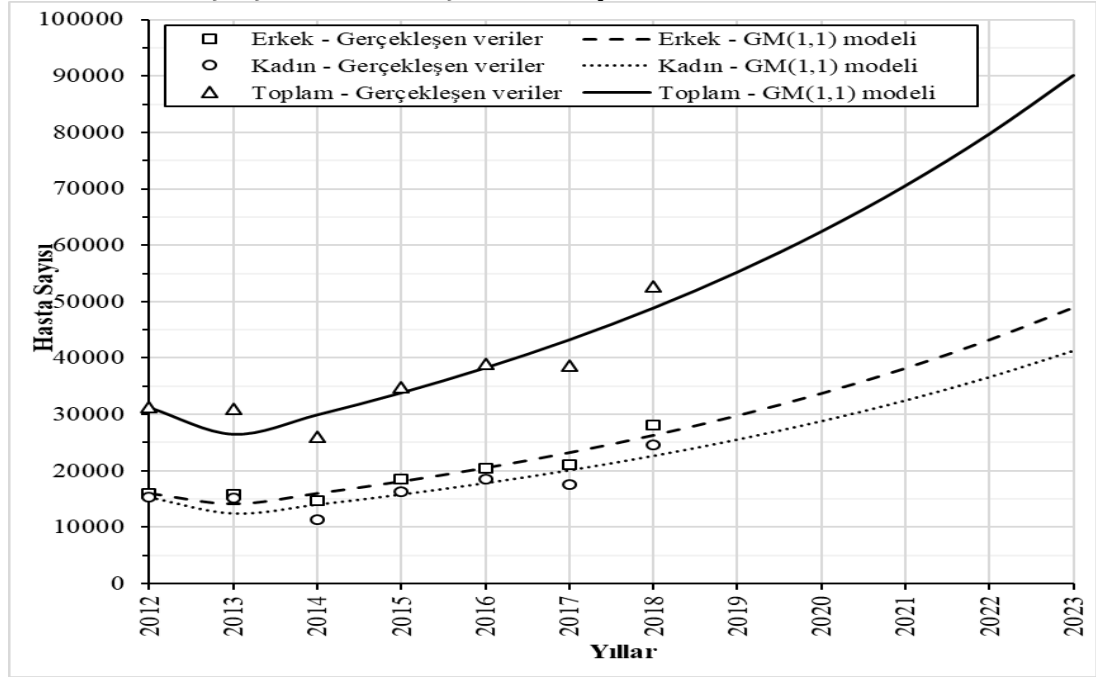
$$\hat{x}^{(0)}(k)|_{18\text{ yaş altı}} = \left(7794 - \frac{-0.1007}{6355.8}\right) e^{0.1007(k-1)} \cdot (1 - e^{0.1007}) \quad (21)$$

$$\hat{x}^{(0)}(k)|_{18\text{ yaş ve üstü}} = \left(23496 - \frac{-0.1308}{14708.8}\right) e^{0.1308(k-1)} \cdot (1 - e^{0.1308}) \quad (22)$$

$$\hat{x}^{(0)}(k)|_{Toplam} = \left(31290 - \frac{-0.1222}{21145.3}\right) e^{0.1222(k-1)} \cdot (1 - e^{0.1222}) \quad (23)$$

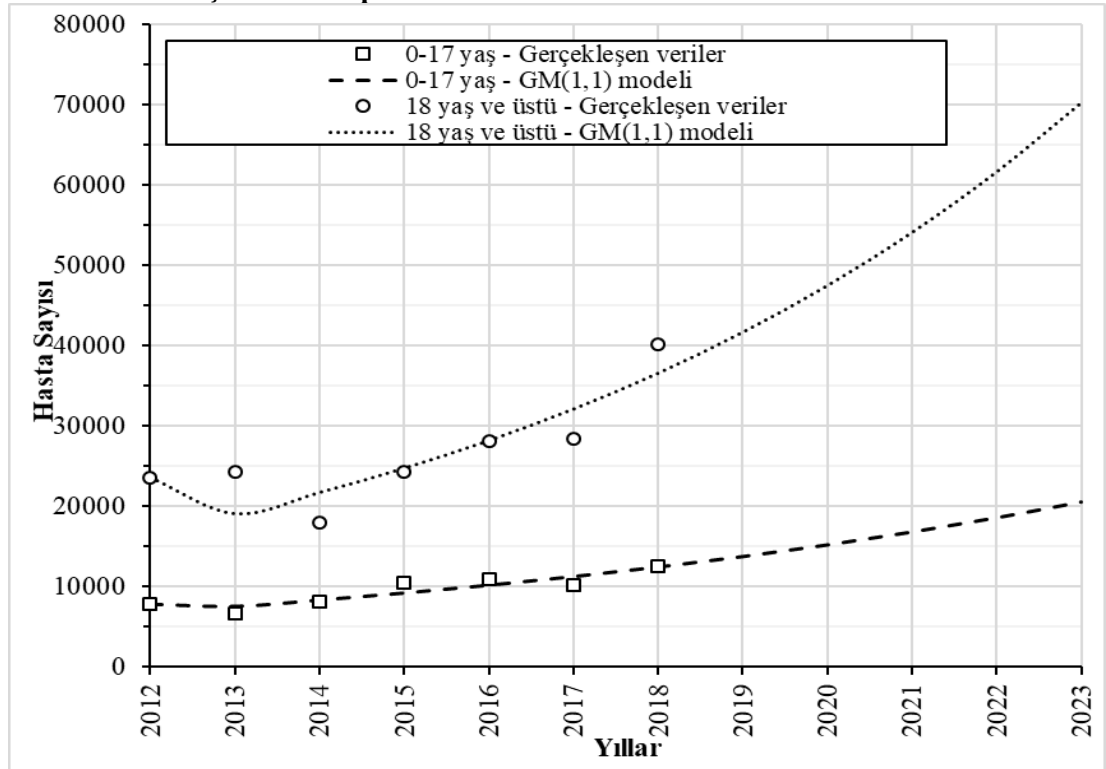
Cinsiyet bakımından 2012-2018 yılları arası tahmin edilen ve gerçekleşen veriler ile 2019-2023 yılları arası beş yılda ruh sağlığı ve hastalıkları polikliniğine ilişkin talep tahminleri Grafik 3'te sunulmaktadır. Bu verilere göre 2019 yılından itibaren talebin yükseleceği öngörülmektedir.

**Grafik 3. Cinsiyet Bakımından Gerçekleşen Veriler İle GM(1,1) Modelinin Karşılaştırılması ve Beş Yıllık Talep Tahmini**



Yaşa bağlı olarak gerçekleşen ve tahmin edilen veriler ile gelecek beş yıl için talep tahminleri Grafik 4'te sunulmuş olup her iki yaş grubu için de talepte artış yaşanması öngörülmektedir. Özellikle 18 yaş ve üstü hastalarda bu artışın daha büyük oranda olacağı tahmin edilmektedir.

**Grafik 4. Yaş Bakımından Gerçekleşen Veriler İle GM(1,1) Modelinin Karşılaştırılması ve Beş Yıllık Talep Tahmini**



Tablo 4’te yıllar bazında öngörülen talep miktarları cinsiyet, yaş ve toplam hasta sayısı bakımından sunulmaktadır. Buna göre gelecek beş yılda erkek hasta sayısının, kadın hasta sayısından hep daha fazla olacağı tahmin edilmektedir. Yaş bakımından ise 18 yaş ve üstü hastaların, talep yoğunluğunu oluşturacağı öngörülmektedir. Bununla birlikte her yıl hasta sayısı, geçen yıllara göre artış gösterirken 2023’te toplam hasta sayısının 90173 olacağı, başka bir ifade ile 2018 yılına göre %84 artacağı tahmin edilmektedir.

**Tablo 4. Cinsiyet ve Yaş Bakımından GM(1,1) Modeline Göre Beş Yıllık Talep Tahmini**

Yıllar	Yaş		Cinsiyet		Toplam hasta sayısı
	18 yaş altı hasta sayısı	18 yaş ve üstü hasta sayısı	Kadın hasta sayısı	Erkek hasta sayısı	
2019	13.749	41.634	25.538	29.762	55.302
2020	15.206	47.450	28.796	33.695	62.492
2021	16.818	54.079	32.470	38.146	70.617
2022	18.600	61.635	36.612	43.186	79.798
2023	20.571	70.246	41.282	48.891	90.173

## VI. TARTIŞMA VE SONUÇ

Karmaşıklığın ve değişimin sürekli arttığı bir yaşam sürecinde toplumların sağlık göstergeleri de değişim göstermektedir. Çünkü birey ve toplum sağlığı çok fazla etkileyeni olan bağımlı bir değişkendir. Yaşanan değişim içerisinde yöneticilerin belirsiz alanları önceden görmesi ve bu alanları etkin bir biçimde yönetmesi beklenir. Sağlık politikaları belirleyicileri ve sağlık kurumları yöneticileri bu süreci, hem mantıksal araçlar hem kendi deneyimlerinden beslenerek yönetmeye çalışırlar. Bu noktada mantıksal boyutta değerlendirmeye yardımcı olacak çeşitli matematiksel modeller ve istatistiksel teknikler geçmişten günümüze geliştirilmeye çalışılmıştır ve her geçen gün yeni teknik ve modeller geliştirilerek en iyi çözüme ulaşılmaya çalışılmaktadır. Hedef, gerçeğe en yakın tahminde bulunabilmektir.

Bu çalışmada toplumun sağlık gereksinmelerini karşılamada önemli bir sağlık hizmeti olan ruh sağlığı ve hastalıkları polikliniğine gelecek beş yıl içerisinde oluşabilecek talep GM(1,1), Basit Üstel Düzeltme, Üstel Model ve Doğrusal Regresyon Modeli ile tahmin edilmeye çalışılmıştır. Modellerin tahmin performansı değerlendirilmiş ve GM(1,1) Modelinin Basit Üstel Düzeltme Modeline göre daha iyi sonuçlar verdiği ve iyi ve yüksek arasında bir performansa sahip olduğu tespit edilmiştir. Dolayısıyla gelecek tahmini, GM(1,1) Modeli ile gerçekleştirilmiştir. Elde edilen sonuçlara göre hem yaş hem cinsiyet hem de toplam hasta sayısı bakımından her gelecek yılda geçmiş yıllara göre artış yaşanacağı öngörülmektedir.

Gelecek tahminleri ile bugünün olanakları karşılaştırıldığında, gelecekte sağlık hizmeti sunumunun en önemli unsuru olan hekimler boyutunda hastanenin insan kaynakları planlaması yapması gerekliliği ortadadır. Ayrıca diğer sağlık profesyonelleri ve yeni kaynak ihtiyacının ortaya çıkmasının kaçınılmaz olduğu bir gerçektir. Bu ihtiyacın karşılanmaması durumunda sağlık hizmetlerinde aksaklıklar yaşanması muhtemel hale gelebilecektir.

Bu çalışmada, tek bir poliklinik üzerinden tahmin etmenin önemine vurgu yapılmıştır. Ancak hastanelerin yapısal karmaşıklığı, birçok hastalığın teşhis ve tedavisine yönelik çeşitli uzmanlıkları bir arada barındırıyor olması ve ortak bir alanda tüm hepsinin eşgüdümlü bir şekilde yönetilmesi gerektirmektedir. Bununla birlikte hastanelerde sağlık hizmeti sunumunda işlevsel bağımlılıkların yüksek olması, bir yerde yaşanan sorunların diğer birimlerdeki sağlık hizmet sunumunu aksatma ihtimalinin yüksek olması, planlama konusunda bugün ve gelecek kararlarının verilmesinde bilimsel araştırmaları gerekli hale

getirmektedir. Nihayetinde hastanelerde mekândan, zamana tüm kaynaklar ortak bir biçimde kullanılmaktadır.

Çalışmanın gerçekleştirilmesinde bazı sınırlılıklar söz konusudur. Bunlar; çalışmanın bir poliklinik üzerinden gerçekleştirilmesi, sadece bir hastanenin verilerinden yararlanılması ve tahmin etmek için kullanılan verilerin son yedi yıl ile sınırlandırılmasıdır.

Bu çalışma, sağlık hizmetlerinin planlanmasına vurgu yapmakla birlikte plan yapılması sürecinde tahmin etmede kullanılabilecek alternatif bir model sunuyor olması sebebi ile 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 performansı değerlendirilebilir. Ayrıca farklı hastanelerde, farklı poliklinik veya polikliniklerde, farklı tahmin etme modelleri kullanılarak tahminleme yapılabilir ve tahmin etme yöntemleri karşılaştırılarak tahmin performansları değerlendirilebilir.

#### KAYNAKÇA

1. Abdel-Aal R.E. and Mangoud A.M. (1998) Modeling and Forecasting Monthly Patient Volume at a Primary Health Care Clinic Using Univariate Time-Series Analysis. **Computer Methods and Programs in Biomedicine** 56(1998): 235–247.
2. Abdullah S., Sapii N., Dir S. and Jalal T.M.T. (2012) Application of univariate forecasting models of tuberculosis cases in Kelantan. **2012 International Conference on Statistics in Science, Business and Engineering (ICSSBE)** 10-12 Sept. 2012, Langkawi, Malaysia.
3. Agrawal R.K., Muchahary F. and Tripathi M.M. (2019) Ensemble of Relevance Vector Machines and Boosted Trees for Electricity Price Forecasting. **Applied Energy** 250: 540-548.
4. Ayvaz B. and Kusakci A.O. (2017) Electricity Consumption Forecasting for Turkey with Nonhomogeneous Discrete Grey Model. **Energy Sources, Part B: Economics, Planning, and Policy** 12(3): 260-267.
5. Ayvaz B., Boltürk E. ve Kaçtıoğlu S. (2014) A Grey System for the Forecasting of Return Product Quantity in Recycling Network. **International Journal of Supply Chain Management** 3(3):105-112.
6. Barros O., Weber R., Revenco C., Ferro E. and Julio C. (2011) **Demand Forecasting and Capacity Management for Hospitals. Documentos de Trabajo, Serie Gestion**, <http://www.dii.uchile.cl/~ceges/publicaciones/ceges%20123%20OB.pdf> Erişim Tarihi: 08.01.2019.
7. Bergmeir C., Hyndman R. J. and Benitez J. M. (2016) Bagging Exponential Smoothing Methods using STL Decomposition and Box-Cox Transformation. **International Journal of Forecasting** 32(2016):303–312.
8. Dang H.S., Huang Y.F., Wang C.N. and Nguyen T.M.T. (2016) An Application of the Short-Term Forecasting with Limited Data in the Healthcare Traveling Industry. **Sustainability** 8(1037):1-14.
9. DHA (2017) **6 yılda 32 bin 262 Kişi Mobbinge Uğradı. 31.08.2017 Haberi.** <http://www.hurriyet.com.tr/6-yilda-32-bin-262-kisi-mobbinge-ugradi-40566418>, Erişim Tarihi: 06.02.2019.

10. Falayi E.O., Adepitan J.O., and Rabiu A.B. (2008) Empirical Models for the Correlation of Global Solar Radiation with Meteorological Data for Iseyin, Nigeria. **International Journal of Physical Sciences**, 3(9):210-216.
11. Hyndman R.J. and Athanasopoulos G. (2018) **Forecasting: Principles and Practice**. OTexts, BC.
12. İHA (2018) **Cinsel İstismar Dava İstatistikleri Paylaşıldı. 20.02.2018 Haberi**. <https://www.memurlar.net/haber/729816/cinsel-istismar-dava-istatistikleri-paylasildi.html>, Eriřim Tarihi: 06.02.2019.
13. İqelan B.M. (2017) Forecasts of Female Breast Cancer Referrals Using Grey Prediction Model GM(1,1). **Applied Mathematical Sciences** 11(54):2647-2662.
14. Jalalpour M., Gel Y. and Levin S. (2015) Forecasting Demand for Health Services: Development of a Publicly Available Toolbox. **Operations Research for Health Care** 5(2015):1-9.
15. Jones S.S., Thomas A., Evans R.S., Welch S.J., Haug P. J. and Snow G. L. (2008) Forecasting Daily Patient Volumes in the Emergency Department. **Academic Emergency Medicine** 15(2):159-170.
16. Jounini R., Lemlouma T. and Maalaoui K. (2016) 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)**, 1086-1091.
17. Kavuncubaşı Ő. ve Yıldırım S. (2012) **Hastane ve Saęlık Kurumları Yönetimi**. 3. Baskı, Siyasal Kitabevi, Ankara.
18. Koyuncugil A.S. ve Özgülbaş N. (2009) Veri Madencilięi: Tıp ve Saęlık Hizmetlerinde Kullanımı ve Uygulamaları. **Biliřim Teknolojileri Dergisi** 2(2): 21-32.
19. Lee Y.S. and Tong L.I. (2011) Forecasting Energy Consumption Using a Grey Model Improved by Incorporating Genetic Programming. **Energy Conversion and Management** 52(1):147-152.
20. Lei M. and Feng Z. (2012) A Proposed Grey Model for Short-Term Electricity Price Forecasting in Competitive Power Markets. **International Journal of Electrical Power & Energy Systems** 43(1):531-538.
21. Li Y., Shi H., Han F., Duan Z. and Liu H. (2019) Smart Wind Speed Forecasting Approach Using Various Boosting Algorithms, Big Multi-Step Forecasting Strategy. **Renewable Energy**, 135: 540-553.
22. Moffat I.U. and Akpan E.A. (2014) Modeling and Forecasting Trend Function of a Discrete-Time Stochastic Process. **American Journal of Scientific and Industrial Research** 5(6):195-202.
23. Mondal K. and Pramanik S. (2015) The Application of Grey System Theory in Predicting the Number of Deaths of Women by Committing Suicide- A Case Study. **Journal of Applied Quantitative Methods** 10(1): 48-55.
24. Mutlu A. ve Iřık A. K. (2005) **Saęlık Ekonomisine Giriř**. 2. Basım, Ekin Kitabevi Yayınları, Bursa.

25. Özcan A.Y. (2013) **Sağlık Kurumları Yönetiminde Sayısal Yöntemler**. (Çev. Kavuncubaşı Ş. ve Yıldırım S.), Siyasal Kitabevi, Ankara.
26. Pao H.T., Fu H.C. and Tseng C.L. (2012) Forecasting of CO<sub>2</sub> Emissions, Energy Consumption and Economic Growth in China Using an Improved Grey Model. **Energy** 40(2012):400-409.
27. Rahman A.U. and Zahura M.T. (2018) A Grey Approach for the Prediction of Supply Chain Demand. **American Journal of Industrial Engineering** 5(1):25-30.
28. Ravinder H.V. (2016) Determining The Optimal Values of Exponential Smoothing Constants – Does Solver Really Work? **American Journal of Business Education** 9(1):1-14.
29. Sağlık Bakanlığı (2011) **Ulusal Ruh Sağlığı Eylem Planı (2011-2023)**. Yayın no: 847, Ankara.
30. Şahin U. (2018a) Forecasting of Primary Energy Consumption of Turkey and Some European Countries with GM (1,1) Model. **3rd International Energy & Engineering Congress Proceedings Book**, 18-19 October 2018, Gaziantep University, Turkey.
31. Şahin U. (2018b) Forecasting of Turkey's Electricity Generation and Consumption with Grey Prediction Method. **Mugla Journal of Science and Technology** 4(2):205-209.
32. Şahin U. (2019) Forecasting of Turkey's Electricity Generation and CO<sub>2</sub> Emissions in Estimating Capacity Factor. **Environmental Progress and Sustainable Energy** 38(1):56-65.
33. Sarıyer G. (2018) Acil Servislerde Talebin Zaman Serileri Modelleri ile Tahmin Edilmesi. **Uluslararası Mühendislik Araştırma ve Geliştirme Dergisi** 10(1):66-77.
34. Thirunavukkarasu M.J. (2000) Exponential Smoothing Modeling and Forecasting for Incidence of Tuberculosis in India. **Global and Stochastic Analysis Special Issue: 25th International Conference of Forum for Interdisciplinary Mathematics**, MUK Publications.
35. Wang Y., Wei F., Sun C. and Li Q. (2016) The Research of Improved Grey GM (1,1) Model to Predict the Postprandial Glucose in Type 2 Diabetes. **Hindawi Publishing Corporation BioMed Research International** 2016:1-6.
36. Wang Y.W., Shen Z.Z. and Jiang Y. (2018) Comparison of ARIMA and GM (1, 1) Models for Prediction of Hepatitis B in China. **PloS ONE** 13(9).
37. Worldometers (2019) **World Population (2019 and historical)** <http://www.worldometers.info/world-population/#pastfuture>, Erişim Tarihi: 06.02.2019.
38. Yağımlı M. ve Ergin H. (2017) Türkiye'de İş Kazalarının Üstel Düzeltme Metodu ile Tahmin Edilmesi. **Marmara Fen Bilimleri Dergisi** 29(4): 118-123.
39. Zhang L., Wang L., Zheng Y., Wang K., Zhang X. and Zheng Y. (2017) Time Prediction Models for Echinococcosis Based on Gray System Theory and Epidemic Dynamics. **International Journal of Environmental Research and Public Health** 14(262): 1-14.