

## Sağlık Sayım Zaman Serilerinde Poisson Otoregresif Model için Hareketli Blok Bootstrap ile Belirsizlik Tahmini

Hayriye Esra Akyüz<sup>1</sup>

### Özet

Bu çalışmada, sağlık alanında sayıma dayalı olarak elde edilen anne ölüm sayıları, zaman serisi yöntemleri ile modellenerek bu model üzerinde Klasik Bootstrap ve Hareketli Blok Bootstrap yöntemlerinin performansları karşılaştırılmıştır. Çalışma zaman bağımlılığı içeren sağlık verilerinde bootstrap yöntemlerinin performans karşılaştırmasına yönelik metodolojik bir yaklaşıma dayalı olduğu için analizler tek bir sağlık göstergesi üzerinden gerçekleştirilmiştir. Elde edilen bulgulara göre; Hareketli Blok Bootstrap yönteminin sağlık zaman serisinde bağımlılık yapısını daha iyi koruduğu, bu sayede daha gerçekçi standart hatalar ve güven aralıkları ürettiği ve buna bağlı olarak Poisson Otoregresif modeli ve Klasik Bootstrap yöntemine kıyasla daha gerçekçi belirsizlik tahminleri sunduğu elde edilmiştir. Çalışmanın sonuçları, zaman bağımlılığı içeren sağlık verilerinin analizinde kullanılan istatistiksel yöntemin seçiminin, elde edilen çıkarımların doğruluğu ve güvenilirliği açısından kritik öneme sahip olduğunu göstermektedir.

### 1. Giriş

Veri, muhakeme, tartışma veya hesaplama için temel teşkil eden olgusal bilgiler olarak bilinir (Ranganathan ve Gogtay, 2019). Sadece bilgisayar tarafından işlenen bir girdi olmayıp arkasında insan emeği, disiplin kültürü ve bağlamın korunduğu bir rehber olan veri kavramı disiplinden disipline değişmektedir (Carlson ve Anderson, 2007). Verilerin daha kolay dijitalleştiği ve standartlaştığı alanlar olduğu gibi, verinin genellikle kişisel gözlemlere, mülakatlara veya fiziksel nesnelere dayandığı, bu nedenle dijitalleşme bağlamından koparılarak yeniden kullanılmasının zor olduğu alanlar da mevcuttur (Carlson ve Anderson,

1 Doç. Dr., Bitlis Eren Üniversitesi, Fen Edebiyat Fakültesi, İstatistik Bölümü, heakyuz@beu.edu.tr, ORCID ID: 0000-0002-1784-5910

2007). Veriler, kantitatif (nicel) ve kalitatif (nitel) olarak ikiye ayrılmakta ve daha detaylı olarak sürekli ve kategorik olarak sınıflandırılmaktadır. İstatistik veri toplama ile başlar. Uygulanacak istatistiksel testlerin seçimi doğrudan veri tipine ve verinin dağılımına bağlı olduğundan tüm araştırmaların bilimsel geçerliliği için veri sınıflandırılmasının doğru yapılması oldukça kritiktir (Sheats ve Pankratz, 2002; Marshall ve Jonker, 2010). Veriler toplanmaya başlanmadan önce istatistiksel analiz planının yapılması gerekmektedir. Bu plan, toplanan bilgilerin özetlenmesinden hipotezlerin test edilmesine kadar olan tüm sürece rehberlik etmektedir (Simpson, 2015).

Kesit veri, bireyler, hanehalkları, firmalar veya ülkeler gibi farklı birimlere ait gözlemlerin belirli bir zaman noktasında toplanmasıyla oluşan veri yapısıdır (Wooldridge, 2020). Zaman serisi, bir değişkene ait gözlemlerin zaman sırasına göre ardışık olarak kaydedilmesiyle oluşan veri yapısıdır (Box et al., 2015). Panel veri ise, aynı kesit birimlerinin birden fazla zaman döneminde gözlemlenmesiyle oluşur; böylece hem zaman hem de birimler arası değişimi eş zamanlı olarak analiz etmeye imkân tanır (Baltagi, 2021).

Sağlıkta zaman serisi verisi, bir sağlık göstergesine (örneğin hastalık insidansı, mortalite oranı veya hasta başvuruları) ait gözlemlerin belirli zaman aralıklarında ardışık olarak kaydedilmesiyle oluşan veri yapısını ifade eder (Diggle, 1990). Zaman serisi yönteminin temel amacı, bir değişkenin geçmiş davranışlarını analiz ederek gelecekteki değerlerini tahmin etmektir. Gözlemlerin geçmiş değerleri incelenir ve bu yapılar üzerinden geleceğe yönelik öngörüler yapılır (Yıldırım vd., 2012). Sağlık kurumları, gelecekte ortaya çıkabilecek durumlara yönelik planlama yapabilmek amacıyla kamu ve özel kesimde farklı ölçeklerde zaman serisi temelli talep öngörü yöntemlerini kullanmaktadır (Hanke ve Wichern, 2005). Sağlık yöneticileri ise toplumun sağlık düzeyini koruma ve geliştirme hedefleri doğrultusunda, geçmiş dönem verilerinin zamansal yapısını dikkate alan öngörü teknikleri aracılığıyla geleceğe ilişkin belirsizlikleri azaltmayı amaçlamaktadır (Özer ve Erkilet, 2012).

Zaman serisi yönteminin temel varsayımı, bir serinin gelecekteki değerlerinin geçmiş değerleri kullanılarak öngörülebilesidir. Zaman serileri; trend, mevsimsel, döngüsel ve rasgele değişimler olmak üzere dört ana bileşenle açıklanır (Box vd., 2015). Belirtilen bileşenler analiz ve tahminlerde önemli rol oynamaktadır. Trend ve mevsimsel değişim, gelecekteki verilerin tahmininde kullanılan modellerin belirlenmesine yardımcı olur (Topuz ve Arslan, 2025) ve ayrıca kısa/uzun dönemde artış, azalış veya tekrar eden değişimleri ifade eder (Yıldırım vd., 2012). Döngüsel ve rasgele değişim, zaman serisi verilerinin belirsizliği ve tahmin edilebilirliği hakkında daha fazla bilgi sağlar (Topuz ve Arslan, 2025). Zaman serileri analizleri bir çok alanda sıklıkla kullanılmaktadır.

Nasıl ki ekonomi alanında geleceğe yönelik tahminler önemli ise, sağlıkta planlama ve karar alma süreçlerinde de bu tahminler oldukça önem arzeder. Bu sebeple sağlık alanında da doğru ve güvenilir tahminlerin elde edilebilmesi için veri türünün doğru belirlenmesi gerekir. Bu alanda özellikle günlük, haftalık, aylık periyotta veriler kullanılmaktadır. Öte yandan, sağlık sistemi ve epidemiyoloji çoğu alanda olayların sayısına (hasta sayısı, vaka sayısı, hastane başvuru sayısı gibi odaklanmaktadır. Bu tür veriler istatistikte sayım verileri olarak karşımıza çıkar. Sayım verisi, bir olayın meydana gelme sayısını gösteren negatif olmayan tam sayı değerlerinden oluşan veri türüdür (Cameron ve Trivedi, 2013). Sayım verisinin doğru modellenmesi, sağlıkta kaynak planlaması, talep öngörüsü ve politika geliştirme süreçlerinde kritik rol oynar (Hilbe, 2011).

Zaman serilerinde, değişkenler arası ortak dinamiklerin ve eşbütünleşme gibi uzun dönem ilişkilerin analiz edildiği durumlar olduğu gibi, tek bir seriye ait gözlemlerin dinamik veya zamana bağlı yapısının incelendiği durumlar da sözkonusu olabilir (Hamilton, 1994). Literatür incelendiğinde, anne ölümleri konusunda çeşitli istatistiksel yöntemlerin uygulandığı çalışmaların bulunduğu (Biliker, 2003; Betrán vd., 2005; Bozkurt vd., 2006; Karabulut vd., 2010; Üstün vd., 2012; Sajedinejad vd., 2015; Gülümser vd., 2019; Şenol vd., 2019; Sezer vd., 2022), ayrıca anne ölüm sayıları ve bu ölümlerin belirleyicilerine ilişkin nitel araştırmaların da gerçekleştirildiği görülmektedir (Ergöçmen ve Yüksel, 2006; Kaptanoğlu vd., 2024). Bununla birlikte, zaman serisi yöntemleri kapsamında yeniden örnekleme yaklaşımlarına (bootstrap, jackknife vb.) dayalı analizlerin kullanıldığı çalışmaların oldukça sınırlı olduğu gözlenmiştir.

Bootstrap yöntemleri yeniden örnekleme dayalı yöntemler olup, orijinal verilerin örnekleme dağılımını değiştirmeden örnek sayısını artırmak için atılan adımların bir özeti olarak tanımlanabilir. Bu yöntem, bağımsız değişkenlerin enterpolasyonu ve verilerdeki eksik gözlemlerin değiştirilmesi için esnek bir yöntemdir (Efron ve Tibshirani, 1993). Parametrik varsayımlara dayanmaksızın istatistiksel çıkarımlar elde edebilmek amacıyla yeniden örnekleme yöntemleri, mevcut örnek verilerin tekrar kullanılması ya da veri kümesinden alt örnekler türetilmesi yoluyla uygulanmaktadır. Parametrik varsayımların pratikte doğrulanması çoğu zaman mümkün olmamakta; büyük örneklemler dışında bu varsayımlara uyumun yeterince güçlü olmadığı ve birçok uygulamada geçerliliğini yitirdiği bilinmektedir. Bu bağlamda yeniden örnekleme yöntemleri, bir tahmincinin varyans ve yanlılığının tahmin edilmesi, güven ya da tahmin aralıklarının oluşturulması ve tahmin edilen parametreye ilişkin istatistiksel hipotezlerin test edilmesi amacıyla yaygın olarak kullanılmaktadır (Chernick, 2012a,b). Bu yöntemler, özellikle örnekleme büyüklüğünün sınırlı

olduğu ya da verilerin olasılık dağılımı hakkında kesin bilgilerin bulunmadığı durumlarda yaygın olarak tercih edilmektedir.

Bu çalışmada, zaman bağımlılığı gösteren anne ölüm sayıları, zaman serisi analiz yöntemleri kullanılarak modellenmiş; elde edilen bulgular, bağımlı veri yapısını dikkate almayan Klasik Bootstrap yaklaşımı ile zaman bağımlılığını koruyan Hareketli Blok Bootstrap yöntemine dayalı sonuçlarla karşılaştırmalı olarak değerlendirilmiştir.

## 2. Veri Seti ve Ekonometrik Yöntemler

Bu çalışmada kullanılan veriler Dünya Bankası Dünya Kalkınma Göstergeleri (World Development Indicators–WDI) veri tabanından elde edilmiştir. Çalışmada yıllık frekansta Türkiye’de 1985-2024 dönemlerine ait anne ölüm sayılarını gösteren zaman serisi verileri kullanılmıştır. Çalışmada anne ölüm sayılarının modellenmesinde Python 3.12.3 yazılımında “pandas”, “numpy”, “scipy”, “statsmodels” ve matplotlib kütüphanelerinden faydalanılmıştır. Bootstrap yöntemlerine dayalı sonuçlar ise manuel kodlanarak elde edilmiştir. Çalışmada ilk olarak anne ölüm sayılarına ilişkin tanımlayıcı istatistikler detaylı olarak incelenmiştir. Zaman yolu grafikleri incelenerek ardından aykırı gözlemler ve olası yapısal kırılmalar incelenmiştir. Serinin durağanlığı ve trend içerip içermediği belirlenmiştir. Zaman bağımlılığını test etmek için ACF ve PACF fonksiyonları değerlendirilerek lag-1 ve lag-2 otokorelasyon katsayıları raporlanmıştır. Elde edilen sonuçlara göre, anne ölüm sayısı Poisson otoregresif model (AR(1)) ile modellenmiştir. Daha sonra bu model üzerinde Klasik Bootstrap ve Hareketli Blok Bootstrap yöntemleri kullanılarak aralık tahminleri karşılaştırılmıştır. Hangi yöntemin zaman bağımlılığını daha iyi koruduğu belirlenerek, 2025-2030 yılları arasındaki anne ölüm sayılarının tahmini değerleri hem orijinal model hem de bootstrap yöntemlerine dayalı olarak elde edilmiştir.

### 2.1. Poisson Otoregresif Model

Klasik ARMA modelleri bazı model varsayımlarının sağlanması koşulu ile kullanılabilir. Ancak sayım verileri normal dağılımdan ziyade Poisson dağılım davranışı sergilemektedir. Bu durum, bu verilerin modellenmesinde daha özel zaman serisi modellerine olan ihtiyacı ortaya çıkarmıştır. İlk olarak 1711’de Abraham de Moivre tarafından “De Mensura Sortis” adlı çalışmada ve Nelder ve Wedderburn (1972) tarafından gerçekleştirilen çalışmalarda, Genelleştirilmiş Lineer Model teorisini incelenen ve poisson dağılımına ilişkin örnekler ile birlikte poisson regresyonunun temellerinin de atıldığı bilinmektedir. Poisson otoregresif modeller arasında en yaygın kullanımı olan model McKenzie (1985) ve Al-Osh ve Alzaid (1987) tarafından geliştirilen

Integer-Valued AR (INAR) yaklaşımına dayalı modeldir. Buna karşılık gözleme (Observation-Driven Model) ve parametreye (Parameter-Driven Model) dayalı alternatif formülasyonların geliştirildiği de bilinmektedir (Cox, 1981). Gözleme dayalı zaman serisi modelleri, ekonomik ve finansal zaman serilerindeki zaman değişimini tanımlamak için yaygın olarak kullanılmaktadır. Bu modeller, zaman serisinin geçmiş gözlenen değerleri tarafından yönlendirilen zamana göre değişen parametreler içerir. Bu, parametreye dayalı modellerin aksine, zamana göre değişen parametrelerin kendi hata kaynağına sahip stokastik süreçler tarafından yönlendirildiği durumdur (Cox, 1981).

Gözleme dayalı model, koşullu yoğunluk fonksiyonu  $Y_t / F_{t-1} \sim \text{Poisson}(\lambda_t)$  olmak üzere model Eşitlik (1)'deki gibi verilir (Davis vd., 2003):

$$\log(\lambda_t) = \omega + \varphi \log(Y_{t-1} + 1) + \beta' Z_t \quad (1)$$

Bu modelde  $Y_t$ , t zamanda bağımlı değişkenin gözlenen değeri,  $\omega$  sabit terim,  $\varphi$  otoregresif katsayı,  $\log(Y_{t-1} + 1)$  gecikmeli değişkenin logaritmik dönüşümü ve  $Z_t$  dışsal açıklayıcı değişkendir.  $Y_t / \lambda_t \sim \text{Poisson}(\lambda_t)$  ve  $\log(\lambda_t) = \mu_t$  olmak üzere parametreye dayalı poisson modeli Eşitlik (2)'de yer almaktadır.

$$\mu_t = \varphi \mu_{t-1} + \eta_t \quad (2)$$

Bu modelde  $\varphi$  otoregresif katsayı ve  $\eta_t$  ise modelin hata kaynağıdır.  $\mu_t$  gözlemlenemeyen çevresel faktörler gibi gizli durum değişkenidir.

## 2.2. Klasik Bootstrap Yöntemi

Bootstrap metodu ilk olarak Efron(1979) tarafından parametrik olmayan bir yaklaşım olarak tanıtılmıştır. Genellikle parametre tahminlerinde örnekleme dağılımlarının kullanılmasına dayanan bootstrap yönteminde ilgilenilen yığından çok sayıda tekrarlanan örneğin çekilebileceği varsayılmaktadır. Bootstrap yöntemi, bir yığından çok sayıda tekrar örnek çekmenin maliyetli veya pratik olmadığı durumlarda, mevcut örnek verileri kullanarak istatistiğin örnekleme dağılımını tahmin etmeyi amaçlar. Mevcut veri üzerinde tekrar örnekleme yapılarak (bootstrap örnekleri), her örnekten istatistik hesaplanır ve bu değerlerin dağılımı istatistiğin bootstrap dağılımı olarak adlandırılır (Efron & Tibshirani, 1993). Verilerin dağılımı hakkında bilgi sahibi olunmadığında bile güvenilir sonuçlar veren (Hsueh & Wang, 2021) bootstrap yöntemi, varyans tahminleri yapmak ve güven aralıkları oluşturmak için etkili bir araçtır. Bu yöntem, özellikle model doğruluğunu artırmak ve tahminlerin belirsizliğini sistematik bir şekilde değerlendirmek amacıyla yaygın olarak kullanılmaktadır (Gilleland, 2020).

Zaman serileri analizlerinde yeniden örnekleme yöntemleri, bağımsız gözlemler için oluşturulan yeniden örnekleme yöntemlerinin genişletilmiş hali olduğu bilinmektedir. Verinin bağımsız ve özdeş dağılımlı olmaması durumunda, veri uygun bir model ile tahmin edilir ve elde edilen kalıntılar yeniden örneklenebilir (Beşer, 2006). Böyle bir uygulama yapılmasının sebebi modelin uyumunun iyi olması durumunda kalıntı temelli bootstrap metodlarının gerek örnek ortalaması gerekse daha karmaşık istatistikler için iyi bir şekilde çalışabileceği (Beşer, 2006), bunun yanı sıra Efron (1979)'un Klasik Bootstrap yöntemine yakın bir performans sergileyeceği belirtilmektedir (Politis, 2003).

İlgilenilen gözlemlerde bağımlılık yapısının sözkonusu olması durumunda, yeniden örneklenmiş verideki orijinal verinin bağımlılık yapısının giderebilmesi için bağımsız ve özdeş dağılımlı veri için yeniden örnekleme algoritmaları uygun bir biçimde değiştirilmelidir (Singh, 1981). Bunun için bir ayarlama sabiti gerekmektedir (Young, 1994).

### 2.3. Hareketli Blok Bootstrap Yöntemi

Parametrik olmayan bir yöntem olan Hareketli Blok Bootstrap yöntemi, “çakışan bloklar”, “overlapping blocks” veya “moving blocks bootstrap” olarak da bilinir. İlk olarak Carlstein (1986) tarafından çakışmayan bloklar mantığı ile geliştirilmiştir (Young, 1994) ve Künsch (1989) tarafından zaman serisi verileri için parametrik olmayan bir yöntem olarak genelleştirilmiştir. Carlstein (1986)'nın çakışmayan blok yönteminde blok uzunluğu değiştikçe tutarsız sonuçlar elde edilmekte ve buna karşılık Hareketli Blok Bootstrap yöntemi daha başarılı sonuçlar vermektedir (Li ve Maddala, 1997).

Bu yöntemde,  $n$  adet gözlem  $l$  genişliğindeki bloklara ayrılmakta ve tüm olası bloklar içinde yeniden örnekleme yöntemi ile iadeli olarak bu bloklardan  $b$  tanesi seçilmektedir.  $n = b \times l$  olduğunda; Carlstein (1986)'nın çakışmayan bloklar algoritmasına göre sadece  $b$  adet blok bulunmasına karşın Künsch (1989) algoritmasında  $n - l + 1$  adet blok bulunacaktır.  $L_k$ ,  $k$ . Blok elemanlarını göstermek üzere, bloklar  $L_k = \{X_k, X_{k+1}, \dots, X_{k+l-1}\}$ ,  $k=1, 2, \dots, (n-l+1)$  olacaktır. Buna bağlı olarak çakışmayan blok yönteminde tüm blokların kaçırılma olasılığı daha yüksek olduğundan çakışan yani Hareketli Blok Bootstrap yöntemi daha yaygın kullanılmaktadır (Beşer, 2006).

$n$ , örnek hacmi;  $b$ , blok uzunluğu ve  $B$ , bootstrap tekrar sayısı olmak üzere Hareketli Blok Bootstrap algoritmasına ilişkin adımlar aşağıdaki gibidir (Künsch, 1989):

1. İlk olarak orijinal zaman serisi  $b$  uzunluğunda çakışan bloklara ayrılır ve  $(n-b+1)$  adet blok elde edilir.

2. Optimal blok sayısı belirlenir.
3.  $(n-b+1)$  bloktan k adet blok rastgele seçilerek bootstrap örnekler oluşturulur.
4. Adım (3) B kez tekrarlanarak B adet bootstrap örnek oluşturulur.
5. Her bir bootstrap örneği için ilgilenilen istatistik hesaplanır.
6. Bootstrap dağılımından güven aralıkları, standart hatalar elde edilir.

Algoritma adımlarının gerçekleştirilmesi ile Hareketli Blok Bootstrap yöntemi serideki bağımlılığı koruyarak ardışık gözlemleri bloklar halinde örneklemiş olacaktır.

### 3. Ampirik Bulgular

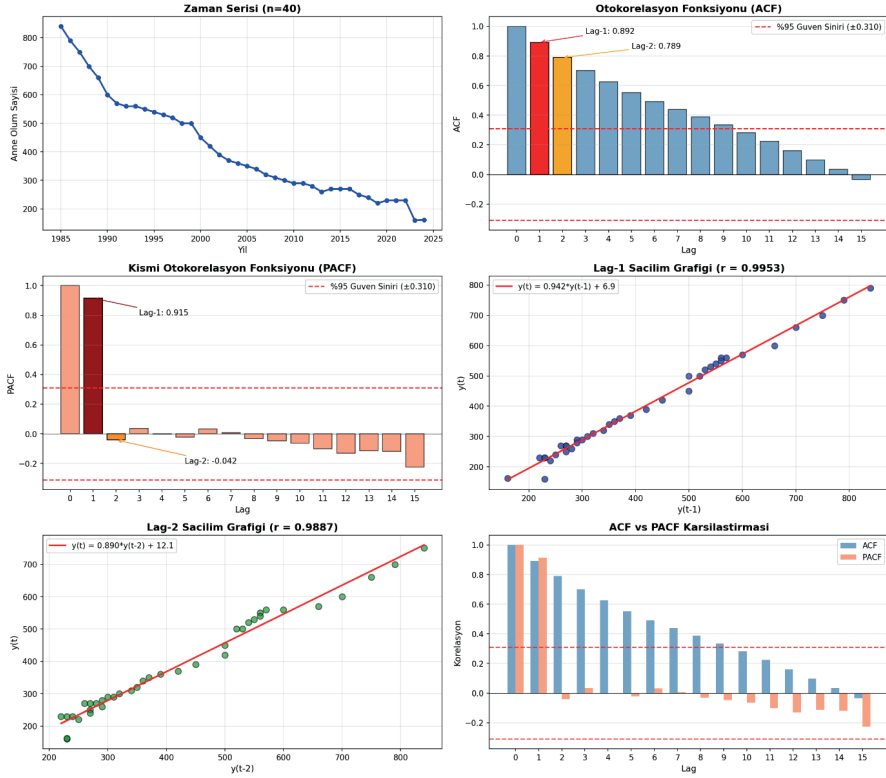
Bu bölümde, Türkiye’de 1985-2024 yılları arasındaki anne ölümlerine ilişkin zaman serisi verileri kullanılarak elde edilen Klasik Bootstrap ve Hareketli Blok Bootstrap tahminleri karşılaştırmalı olarak incelenmiştir. Bootstrap uygulamalarına geçilmeden önce, zaman serisinin yapısal özelliklerini belirlemek amacıyla ön analizler gerçekleştirilmiştir. Bu kapsamda serinin durağanlık durumu, olası trend ve zamansal bağımlılık yapısı değerlendirilmiş; elde edilen bulgular doğrultusunda uygun bootstrap yaklaşımının seçilmesine yönelik metodolojik gerekçeler ortaya konmuştur. Bootstrap yöntemlerde  $B=1000$  tekrar gerçekleştirilmiştir. Hareketli Blok Bootstrap yönteminde optimal blok uzunluğu, her bir blok uzunluğuna ilişkin standart hata değerleri de gözönünde bulundurularak  $4(n^{1/3})$  olarak belirlenmiştir (Künsch, 1989). Anne ölümlerine ilişkin bazı tanımlayıcı istatistikler Tablo 1’deki gibidir.

*Tablo 1. Türkiye’de Anne Ölümlerine İlişkin Tanımlayıcı İstatistikler*

İstatistik	Değer
Ortalama	410.8
Standart sapma	417.18
Minumum	160
Maksimum	840
Çarpıklık	0.71
Basıklık	-0.40
Değişim katsayısı	% 43.77

Tablo 1’de anne ölümlerine ilişkin tanımlayıcı istatistikler incelendiğinde; Türkiye’de 1985-2024 yılları arasındaki anne ölümleri ortalama 411’dir. Standart sapmanın ortalamadan büyük olması dikkat çeken bir bulgudur.

Minimum ve maksimum değerler arasındaki farkın büyük olması ve değişim katsayısının yaklaşık %44 olarak seyretmesi bu bulguyu destekler niteliktedir. Anne ölümleri incelenen dönemde oldukça fazla farklılık göstermiştir (Tablo 1).



Şekil 1. Anne Ölüm Sayılarının Otokorelasyon Yapısı ve Zaman Bağımlılığı Analizi

Şekil 1’de Türkiye’de 1985-2024 yılları arasında anne ölümlerinin seyri, otokorelasyon ve kısmi otokorelasyon fonksiyonları, bir dönem (lag-1) ve iki dönem (lag-2) öncesine ilişkin saçılım grafikleri verilmiştir. Tüm grafikler birarada değerlendirildiğinde; anne ölümlerinin durağan olmadığı, güçlü trend içerdiği ve belirgin biçimde AR(1) yapısına uygunluk gösterdiği söylenebilir.

Tablo 2. ACF ve PACF Değerleri

Gecikme	ACF	PACF	Anlamlılık
0	1.000	1.000	-
1	<b>0.8922</b>	<b>0.9151</b>	ACF, PACF
2	<b>0.7891</b>	-0.0415	ACF
3	<b>0.7022</b>	0.0344	ACF
4	<b>0.6248</b>	-0.0013	ACF
5	<b>0.5522</b>	-0.0216	ACF
6	<b>0.4918</b>	0.0328	ACF
7	<b>0.4393</b>	0.0073	ACF
8	<b>0.3876</b>	-0.0321	ACF
9	<b>0.3352</b>	-0.0477	ACF
10	0.2816	-0.0643	-
11	0.2235	-0.1019	-
12	0.1599	-0.1307	-
13	0.0963	-0.1131	-
14	0.0348	-0.1187	-
15	-0.0333	-0.2248	-

Tablo 2’de ACF ve PACF değerleri incelendiğinde;  $ACF(1)=0.8922$  ve  $PACF(1)=0.9151$  istatistiksel olarak anlamlı olup bu değerler ardışık yıllar arasında % 89 korelasyon olduğunu ve bir yılın anne ölüm sayısı yüksekse, sonraki yıl da yüksek olma eğiliminde olduğunu göstermektedir. Bu durum, serinin güçlü kalıcılık özelliği gösterdiğini ve AR(1) modelinin geçerliliğini kanıtlar niteliktedir. Öte yandan Lag-2 otokorelasyon değerleri incelendiğinde ACF(2) değeri hala çok yüksek ve anlamlı iken PACF(2) düşük ve istatistiksel olarak anlamlı değildir. Bu durum,  $y_{(t-2)}$ ’nin  $y_{(t)}$  üzerindeki görünür etkisinin aslında  $y_{(t-1)}$  üzerinden aktarıldığını göstermektedir. Yani 2 yıl önceki değer, bugünkü değeri doğrudan değil, geçen yıl üzerinden dolaylı olarak etkilemektedir (Tablo 2).

*Tablo 3. Yapısal Kırılma Analizi*

Kırılma yılı	$n_1$	$n_2$	F-istatistiği	$p$ -değeri
1990	5	35	38.90	0.000
1995	10	30	31.89	0.000
2000	15	25	35.54	0.000
2005	20	20	42.53	0.000
2010	25	15	35.00	0.000
2015	30	10	19.43	0.000
2020	35	5	5.83	0.006

Tablo 3’de Chow testi sonuçları, 1990, 1995, 2000, 2005, 2010, 2015 yıllarında istatistiksel olarak anlamlı kırılmalar olduğunu göstermektedir ( $p < 0.01$ ). Bu sonuç, anne ölüm sayılarındaki düşüş hızının zaman içinde sabit olmadığını göstermektedir (Tablo 3).

*Tablo 4. Dönemsel Trend Analizi Sonuçları*

Dönem	Gözlem	Ortalama	Eğim	$R^2$
1985-1989	5	748	-45.0	0.999
1990-1999	10	543	-10.2	0.961
2000-2009	10	361	-15.6	0.958
2010-2019	10	264	-6.7	0.826
2020-2024	5	202	-20.6	0.743

Tablo 4’de yer alan bulgular dönem bazında incelendiğinde; ilk dönemde yılda ortalama 45 anne ölümünün azaldığı ve en yüksek dönem ortalamasının yine bu dönem için gerçekleştiği elde edilmiştir. Devamındaki dönemde düşüş hızının yavaşladığı fakat sonrasında 2000-2009 döneminde tekrar yükselişe geçtiği görülmüştür. Düşüş hızının en düşük seviyede olduğu dönem 2010-2019 dönemidir ve diğer dönemlere göre daha zayıf doğrusal ilişki mevcuttur (0.826). En zayıf doğrusal ilişki ise 2020-2024 dönemine aittir. Yılda ortalama 20 anne ölümünün azaldığı tespit edilmiştir. Tablo 4 genel olarak değerlendirildiğinde farklı dönemlerde farklı dinamiklerin olduğu açıktır (Tablo 4).

Tablo 5. ADF Birim kök testi sonuçları

Model	İstatistik	<i>p</i> -değeri
Sabit	-1.631	0.4672
Sabit&trend	-3.396	0.0519
Yok	-2.068	0.0370

Tablo 5’de birim kök testleri, sabit, sabit ve trend içeren ile sabit ve trend içermeyen modeller altında gerçekleştirilmiştir. ADF testi sonuçlarına göre; anne ölüm sayısının durağan olmadığı belirlenmiştir. Seri trend içermekte ve trend çıkarıldığında durağanlaşma eğilimi göstermektedir. %5 anlamlılık seviyesinde sabit&trend modelde ADF test istatistiği 0.05’e çok yakın olup 0.10 anlamlılık seviyesinde durağan kabul edilebilir. Bu belirsizlik, serinin “trend-durağan” olduğuna işaret etmektedir.

Tablo 6. Zivot-Andrews Birim kök testi

Model	İstatistik	<i>p</i> -değeri	Kırılma Yılı
Sabit	-4.838	0.0470	1999
Trend	-3.386	0.4185	2004
Sabit&trend	-3.586	0.7673	2000

Zivot-Andrews testi sonuçlarına göre ise; 2000 yılı kırılma noktası olarak tespit edilmiştir. Bu sonuç, Chow testi sonuçlarıyla tutarlılık göstermektedir (Tablo 6).

Tablo 7. Zaman bağımlılığının değerlendirilmesi

Test	Sonuç	Yorum
Ljung-Box (lag-1)	<i>p</i> -değeri=0.000	Otokorelasyon var
Ljung-Box (lag-10)	<i>p</i> -değeri=0.000	Uzun dönem bağımlılık var
Durbin Watson	0.157	Güçlü pozitif otokorelasyon (2’den çok uzak)
Runs testi	<i>p</i> -değeri=0.000	Seri rastgele değil

Tablo 7’de Ljung-Box (lag-1) testi sonuçlarına göre; “ $H_0$ : lag-1’e kadar otokorelasyon yoktur” hipotezi reddedilmiştir ( $p < 0.05$ ). Ardaşık yıllar arasında çok güçlü bağımlılık olduğu ve bir yılın anne ölüm sayısının, bir sonraki yılı doğrudan etkilediği elde edilmiştir. Ljung-Box Testi (lag-10) testine göre ise; sadece kısa dönemde değil, 10 yıl öncesine kadar bağımlılığın mevcut

olduğu belirlenmiştir. Durbin Watson test istatistiği değeri artıklar arasında çok güçlü pozitif otokorelasyon olduğunu göstermektedir. Runs testine göre ise; “ $H_0$ : Gözlemler rastgele sıralanmıştır” hipotezi 0.95 güven düzeyinde reddedilmiştir. Bu sonuç, anne ölüm sayısı serisinin rastgele değil, sistematik yapıya sahip olduğunu göstermektedir (Tablo 7).

Bu durumda anne ölüm sayısı için gözlemlerin bağımsız olduğunu varsayan modellerin kullanılması doğru olmayacaktır. Böyle durumlarda standart hatalar, güven aralıkları ve  $p$ -değerleri güvenilir olmayacaktır. Bu çalışmada, sayım ve zaman serisini birleştiren, zaman bağımlılığını dikkate alan ve otokorelasyonu yakalayabilen Poisson Otoregresif Model kullanılmış ve sonuçlar Tablo 8’de verilmiştir. Poisson otoregresif model aşağıdaki gibi belirlenmiştir (Brandt ve Williams, 2001):

$$\log_t = \alpha + \beta \log(Y_{t-1} + 1) + \gamma_t$$

Bu modelde  $t$  zaman indeksi olup;  $\alpha$  sabit terim,  $\beta$  otoregresif katsayı,  $\gamma$  trend katsayısı ve  $Y_{t-1}$  bir önceki dönem anne ölüm sayısıdır.

*Tablo 8. Poisson otoregresif model katsayıları*

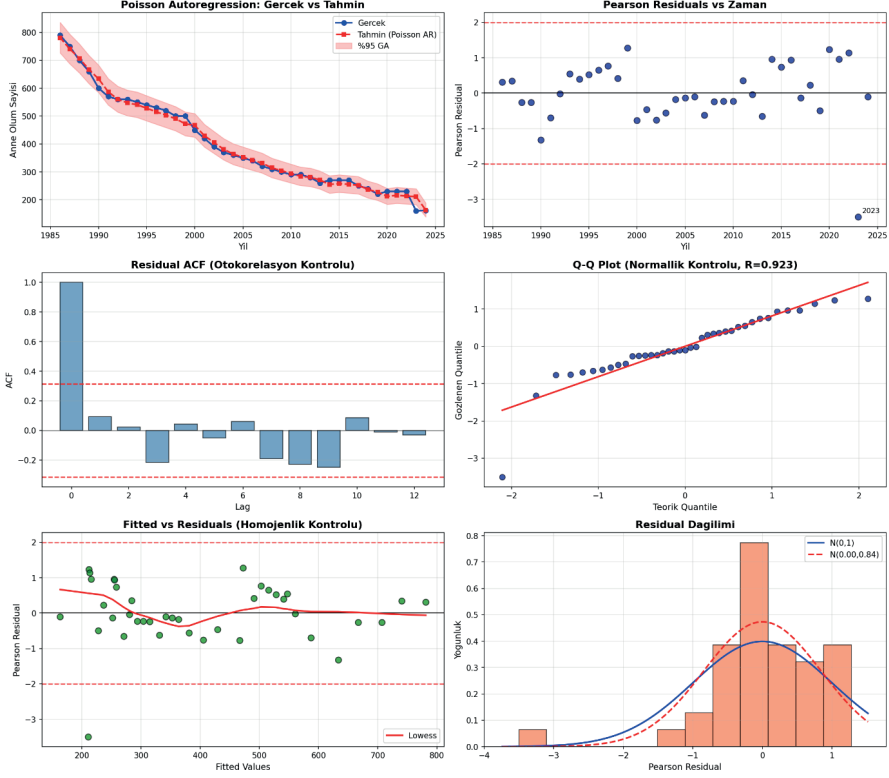
Değişken	Katsayı	Std.hata	z-değeri	p-değeri
Sabit	2.1258	0.9053	2.35	0.0189
$\log(Y_{t-1})$	0.6752	0.1353	4.99	0.0000
Trend	-0.0118	0.0051	-2.34	0.0195

AIC=336.70, Pearson  $\chi^2$ / sd=0.77,  
 Artıkların ortalaması= -0.0002,  
 Ljung-Box (Lag-1)  $p$ -değeri=0.52,  
 Ljung-Box (Lag-5)  $p$ -değeri=0.76

Tablo 8’de poisson otoregresif model parametre tahminleri incelendiğinde; önceki yılın anne ölüm sayısı %1 arttığında bu yıl beklenen sayı yaklaşık olarak % 0.68 artacaktır. Trend etkisi incelendiğinde her yıl beklenen anne ölüm sayısının yaklaşık % 1.2 azaldığı belirlenmiştir. Ljung-Box testine ilişkin 1 ve 5 gecikmeli  $p$ -değerlerine göre ise bu modelde artıklarda otokorelasyon probleminin kalmadığı görülmüştür.

Dispersiyon, sayım verisinde varyansın ortalamaya göre davranışını ifade eder. Poisson otoregresif modellerde dispersiyon, koşullu varyansın koşullu ortalamaya eşit olduğu varsayımının veri tarafından ne ölçüde sağlandığını ifade etmekte olup, bu varsayımın ihlali aşırı veya eksik dispersiyon olarak ortaya

çıkmaktadır. Çalışmada, dispersiyon parametresi, Pearson ki-kare istatistiğinin serbestlik derecesine oranı kullanılarak tahmin edilmiştir ve bu değer 0.77 olarak elde edilmiştir (Tablo 8).



Şekil 2. Poisson Otoregresif Model için Tamı Grafikleri

Şekil 2'de elde edilen grafikler Poisson otoregresif modelin anne ölümlerini modellemede ne kadar başarılı olduğunu göstermektedir. İlk grafikte anne ölümlerinin gerçek değerleri ile Poisson otoregresif modeline dayalı tahmini değerleri arasındaki uyum net bir şekilde görülebilmektedir ve %95 güven aralığı alt ve üst sınır aralığındadır. Küçük sapmalar ile birlikte model oldukça uygun görünmektedir. Artıklara ilişkin grafikte 2023 yılına ilişkin değer dikkat çekmektedir. Artıkların otokorelasyon grafiğinde neredeyse tüm gecikmelerin güven aralığı bandında yer aldığı, otokorelasyon ve değişen varyans problemlerinin mevcut olmadığı ve Normallik incelemesi için elde edilen Q-Q plot grafiğinde kuyruklarda hafif sapmalar olmakla birlikte artıkların dağılımında da sağ kuyrukta daha fazla gözlemin toplandığı belirlenmiştir (Şekil 2).

Tablo 9. Klasik Bootstrap ve Hareketli Blok Bootstrap ( $l=4$ ) karşılaştırması ( $B=1000$ )

Değişken	Standart hata			Yanlılık		% 95 güven aralıkları		
	Poisson AR(1)	Klasik Bootstrap	Blok Bootstrap	Klasik Bootstrap	Blok Bootstrap	Poisson AR(1)	Klasik Bootstrap	Blok Bootstrap
Sabit	0.9053	0.7558	<b>0.7376</b>					
$\log(Y_{t-1})$	0.1353	0.1129	<b>0.1101</b>	<b>0.0020</b>	0.0108	[0.4100, 0.9403]	[0.4404, 0.8974]	<b>[0.4825, 0.9048]</b>
Trend	0.0051	0.0042	<b>0.0041</b>	<b>0.0001</b>	0.0004	[-0.0217, -0.0019]	[-0.0205, -0.0034]	<b>[-0.0192, -0.0033]</b>

Hareketli Blok Bootstrap yöntemine dayalı standart hatalar daha düşük elde edilmiştir. bir dönem gecikmeli anne ölümlerinin ve trende ilişkin yanlılık değerleri oldukça küçük olmasına karşın Hareketli Blok Bootstrap yöntemine ilişkin yanlılık, Klasik Bootstrap yanlılık değerinden önemsiz derecede daha büyüktür. Modellere ilişkin güven aralıkları incelendiğinde ise; en dar güven aralıklarının Hareketli Blok Bootstrap yöntemi için elde edildiği belirlenmiştir (Tablo 9).

Tablo 10. 2025-2030 yılları anne ölüm sayıları için poisson AR(1) modeli ve bootstrap tahmin karşılaştırmaları ( $B=1000$ )

Yıl	Poisson AR(1)	Klasik Bootstrap	Klasik % 95 güven aralığı	Klasik Genişlik	Blok Bootstrap	Blok % 95 güven aralığı	Blok Genişlik
2025	162.7	162.8	[155.9, 169.4]	13.5	162.9	[156.5, 169.7]	13.2
2026	161.3	161.2	[150.2, 170.6]	20.4	161.5	[151.0, 171.8]	20.8
2027	158.4	158.2	[144.4, 169.3]	24.9	158.7	[145.6, 171.0]	25.4
2028	154.7	154.4	[138.7, 166.6]	27.9	155.0	[140.1, 168.9]	28.8
2029	150.5	150.1	[133.3, 163.3]	30.0	150.8	[135.0, 165.3]	30.3
2030	145.9	145.7	[128.2, 159.8]	31.6	146.5	[130.0, 162.0]	32.0

Tablo 10'da elde edilen sonuçlara göre; Klasik Bootstrap ve Hareketli Blok Bootstrap aralık tahminlerinin her ikisi de benzer sonuçlar vermektedir. Bu durum, çalışmada anne sayılarını poisson otoregresif model kullanılarak modellenmesinden kaynaklıdır. Zaman serisi yapısına uygun ve otokorelasyon varlığında daha güvenilir sonuçlar veren Hareketli Blok Bootstrap yöntemi daha sağlamdır. Çünkü Klasik Bootstrap yönteminde, her bir bootstrap tekrarında

artıklar bağımsız olarak örneklenir ve zaman bağımlılığı korunmamaktadır. Buna karşılık, Hareketli Blok Bootstrap yönteminde ise ardışık bloklar korunarak örnekleme yapılır. Güven aralıkları genişlikleri incelendiğinde; Hareketli Blok Bootstrap yönteminin zaman bağımlılığını da dikkate aldığı için belirsizliği daha iyi yakaladığı ve yansıttığı söylenir (Tablo 10).

#### 4. Sonuç

Araştırmalarda kullanılacak istatistiksel yöntemlerin doğru ve güvenilir bir şekilde belirlenebilmesi için verinin yapısına bağlı olarak belirli varsayımların sağlanması gerekmektedir. Bu varsayımların sağlanması, parametrik ve parametrik olmayan yöntemler arasında uygun seçim yapabilmek için araştırmacıları yönlendirmiş olacaktır. Sayım verileri, doğası gereği negatif olmayan tam sayılardan oluştuğu ve çoğu zaman sağa çarpık bir dağılıma sahip olduğu için sürekli veri varsayımına dayalı istatistiksel yöntemler ile birlikte kullanılabilmesi mümkün olmamaktadır. Sağlık alanında anne ölüm sayıları sayım verisi kapsamında olup zaman boyutuna sahiptir. Bu sebeple hem dağılım hem de zamana bağımlılık detaylı bir şekilde değerlendirilmelidir.

Zaman serisi bağlamında sayım verilerinin analizi, ardışık gözlemler arasındaki bağımlılık yapısının modellenmesini gerektirir. Bu amaçla Poisson Ototegresif Modeller sıklıkla kullanılmaktadır. Bu modeller, sayım verilerinin dağılım özelliklerini ve zamana bağlı korelasyonlarını açıklamada oldukça güvenilirdir. Örnek hacminin küçük olduğu durumlarda bootstrap yöntemler kullanılarak parametre tahminlerini elde etmek daha doğru ve güvenilir bir yaklaşım olacaktır. Klasik Bootstrap yöntemi, gözlemlerin bağımsız ve özdeş dağılımlı olduğu varsayımına dayandığından, zaman serisi yapısına sahip sayım verilerinde bağımlılık yapısını yeterince koruyamamaktadır. Bu problemin çözümü için Hareketli Blok Bootstrap yöntemi kullanılmaktadır.

Çalışmada elde edilen sonuçlara göre; zaman bağımlılığı içeren anne ölümü verilerinde Klasik Bootstrap doğru modelin seçiminden kaynaklı (Poisson AR(1)) otokorelasyonu yok saymamakla birlikte, hareketli blok bootstrap hem bağımlılık yapısını korumakta hem de daha gerçekçi standart hata ve güven aralıkları üretmektedir.

Sonuç olarak, zaman bağımlılığı içeren sayım verilerinin analizinde, yalnızca uygun zaman serisi modelinin seçilmesinin yeterli olmadığı aynı zamanda belirsizlik tahmininde kullanılan yöntemlerin de veri yapısına uygun olması gerektiği belirlenmiştir. Buna bağlı olarak; sayım verilerinin kullanıldığı çalışmalarda, zaman serisi modelleri ve bootstrap yöntemlerinin birlikte ele alınması, özellikle sağlık istatistiklerinde elde edilen sonuçların doğruluğunu ve bilimsel geçerliliğini artıran önemli bir metodolojik yaklaşım sunacaktır.

## Kaynaklar

- Al-Osh, M. A., & Alzaid, A. A. (1987). First-order integer-valued autoregressive (INAR (1)) process. *Journal of Time Series Analysis*, 8 (3), 261-275. <https://doi.org/10.1111/j.1467-9892.1987.tb00438.x>
- Baltagi, B. H. (2021). *Econometric analysis of panel data*, (6th ed.). Springer.
- Beşer, M. K. (2006). *Zaman serilerinde bootstrap çözümlenmeleri ve Türkiye’de tanzime etkisine uygulaması*, [Doktora Tezi, Marmara Üniversitesi].
- Betrán, A. P., Wojdyla, D., Posner, S. F., & Gülmezoglu, A. M. (2005). National estimates for maternal mortality: an analysis based on the WHO systematic review of maternal mortality and morbidity. *BMC Public Health*, 5 (1), 131. <https://doi.org/10.1186/1471-2458-5-131>
- Biliker, M. A. (2003). Maternal mortality in Turkey. *Journal of Perinatal Medicine*, 31(5), 380-385.
- Box, G. E., Jenkins, G. M., Reinsel, G. C., & Ljung, G. M. (2015). *Time series analysis: Forecasting and control*. John Wiley & Sons.
- Bozkurt, T., Özyüncü, Ö., & Ayhan, A. (2006). Maternal mortality rates at Hacettepe University Hospital/Turkey. *Journal of the Turkish-German Gynecological Association*, 7 (3), 206-209.
- Brandt, P. T., & Williams, J. T. (2001). A linear Poisson autoregressive model: The Poisson AR (p) model. *Political Analysis*, 9 (2), 164-184. <https://doi.org/10.1093/oxfordjournals.pan.a004869>
- Cameron, A. C., & Trivedi, P. K. (2013). *Regression analysis of count data* (No. 53). Cambridge university press.
- Carlson, S., & Anderson, B. (2007). What are data? The many kinds of data and their implications for data re-use. *Journal of Computer-Mediated Communication*, 12 (2), 635-651. <https://doi.org/10.1111/j.1083-6101.2007.00342.x>
- Carlstein, E. (1986). The use of subseries values for estimating the variance of a general statistic from a stationary sequence. *The Annals of Statistics*, 14 (3), 1171-1179.
- Chernick, M. R. (2012a). *Bootstrap methods: A guide for practitioners and researchers* (2nd ed.). Wiley.
- Chernick, M. R. (2012b). Resampling methods. *WIREs Data Mining and Knowledge Discovery*, 2 (3), 255-262.
- Cox, D. R. (1981). Statistical Analysis of Time Series: Some Recent Developments. *Scandinavian Journal of Statistics*, 8 (2), 93-115.
- Davis, R. A., Dunsmuir, W. T., & Streett, S. B. (2003). Observation-driven models for Poisson counts. *Biometrika*, 90 (4), 777-790. <https://doi.org/10.1093/biomet/90.4.777>
- Diggle, P. J. (1990). *Time series: A biostatistical introduction*. Oxford University Press.

- Efron, B., & Tibshirani, R. J. (1993). *An introduction to the bootstrap*. Chapman & Hall/CRC.
- Efron, B., (1979). Bootstrap methods: Another look at the jackknife, *The Annals of Statistics*, 7(1), 1-26
- Ergöçmen, B. A., & Yüksel, İ. (2006). Türkiye’de ölüm kayıtlarına ilişkin sorunlar: Anne ölümleri özelinde niteliksel bir çalışma. *Nüfusbilim Dergisi*, 28 (1), 29-46.
- Gilleland, E. (2020). Bootstrap methods for statistical inference. Part I: Comparative forecast verification for continuous variables. *Journal of Atmospheric and Oceanic Technology*, 37 (11), 2117-2134. <https://doi.org/10.1175/JTECH-D-20-0069.1>
- Gülümser, C., Engin-Ustun, Y., Keskin, L., Celen, S., Sanisoglu, S., Karahmetoglu, S., ... & Sencan, I. (2019). Maternal mortality due to hemorrhage: population-based study in Turkey. *The Journal of Maternal-Fetal & Neonatal Medicine*, 32 (23), 3998-4004. <https://doi.org/10.1080/14767058.2018.1481029>
- Hamilton, J. D. (1994). *Time Series Analysis*. Princeton University Press.
- Hanke, J. E., & Wichern, D. W. (2005). *Business forecasting* (8th ed.). Pearson/Prentice Hall.
- Hilbe, J. M. (2011). *Modeling count data*. In *International encyclopedia of statistical science*, Springer, Berlin, Heidelberg.
- Hsueh, M.H., & Wang, Y.H. (2021). The selection of strategic alliance in IC packaging and testing industry with DEA resampling comparative evaluation. *Applied Sciences*, 11 (1), 204.
- Kaptanoğlu, İ.Y., Keskin, F., Yayla, Z., Koyuncu, Y., Barkçin, E. M., Güneş, K., & Koç, İ. (2024). Examining expert views on maternal mortality in Turkey: A qualitative study. *Public Health Nursing*, 41 (5), 1089-1097. <https://doi.org/10.1111/phn.13336>
- Karabulut, A., Çalışkan, A., Özcan, N., Sönmez, S., İstanbullu, B., Işık Balcı, Y., Karahan, T., & Kayan, S. (2010). Maternal Mortality in Denizli Region: Three Years Evaluation. *Journal of Clinical Obstetrics & Gynecology*, 20 (1), 29-34.
- Künsch, H. R. (1989). The jackknife and the bootstrap for general stationary observations. *The Annals of Statistics*, 17 (3), 1217-1241.
- Li, H., & Maddala, G. S. (1997). Bootstrapping cointegrating regressions. *Journal of Econometrics*, 80 (2), 297-318. [https://doi.org/10.1016/S0304-4076\(97\)00043-2](https://doi.org/10.1016/S0304-4076(97)00043-2)
- Marshall, G., & Jonker, L. (2010). An introduction to descriptive statistics: A review and practical guide. *Radiography*, 16 (4), e1-c7. <https://doi.org/10.1016/j.radi.2010.01.001>

- McKenzie, E. (1985). Some simple models for discrete variate time series I. *JAWRA Journal of the American Water Resources Association*, 21 (4), 645-650. <https://doi.org/10.1111/j.1752-1688.1985.tb05379.x>
- Nelder, J. A., & Wedderburn, R. W. (1972). Generalized linear models. *Journal of the Royal Statistical Society Series A: Statistics in Society*, 135 (3), 370-384. <https://doi.org/10.2307/2344614>
- Özer, Ö., & Erkilet, M. (2012). Talep analizi ve talep öngörüsü: Bir özel hastanede. *Dokuz Eylül Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 14 (3), 127-142.
- Politis, D.N., (2003). The impact of bootstrap methods on time series analysis, *Statistical Science*, 18 (2), 219-230.
- Ranganathan, P., & Gogtay, N.J. (2019). An introduction to statistics – data types, distributions and summarizing data. *Indian Journal of Critical Care Medicine*, 23, 169–170. <https://doi.org/10.5005/jp-journals-10071-23198>
- Sajedinejad, S., Majdzadeh, R., Vedadhir, A. et al. (2015). Maternal mortality: A cross-sectional study in global health. *Global Health*, 11 (4), . <https://doi.org/10.1186/s12992-015-0087-y>
- Sezer, Y., Üzüin, İ., Melez, İ. E., Ustun, Y., & Sanisoglu, S. (2022). Evaluation of demographic, clinical and autopsy data of autopsied maternal deaths in Turkey. *Journal of Contemporary Medicine*, 12 (5), 636-639. <https://doi.org/10.16899/jcm.1060754>
- Sheats, R. D., & Pankratz, V. S. (2002, June). *Understanding distributions and data types*. In *Seminars in Orthodontics* (Vol. 8, No. 2, pp. 62-66). WB Saunders.
- Simpson, S. H. (2015). Creating a data analysis plan: What to consider when choosing statistics for a study. *The Canadian Journal of Hospital Pharmacy*, 68 (4), 311. <https://doi.org/311-317>. 10.4212/cjhp.v68i4.1471
- Singh, K., (1981). On the asymptotic accuracy of Efron's bootstrap, *The Annals of Statistics*, 9(6), 1187-1195
- Şenol, O., Metin, A., & Korucu, K. S. (2019). Ülkelerin ölüm göstergeleriyle karşılaştırılması: Veri zarflama analizi. *Süleyman Demirel Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 33, 82-103.
- Topuz, S., & Arslan, H.M. (2025). Zaman serisi modelleri ile trafik kazası sayılarının tahmin edilmesi. *Sosyal Bilimlerde Nicel Araştırmalar Dergisi*, 5 (1), 14-30.
- Üstün, Y.E., Çelen, Ş., Özcan, A., Sanisoglu, S., Karaahmetoğlu, S., Gül, R., ... & Köse, M. R. (2012). Maternal mortality from cardiac disease in Turkey: A population-based study. *The Journal of Maternal-Fetal & Neonatal Medicine*, 25 (11), 2451-2453. <https://doi.org/10.3109/14767058.2012.703719>
- Wooldridge, J. M. (2020). *Introductory econometrics: A modern approach*, (7th ed.). Cengage Learning.

- Yıldırım, C., Yıldırım, S., & Arı, H. O. (2014). Sağlık kurumlarında talep öngörü yöntemleri. *Sağlık Performans ve Kalite Dergisi*, 8 (2), 77-92.
- Young, G.A., (1994). Bootstrap: More than a stab in the dark, *Statistical Science*, 9 (3), 382-395

