



Acil Servislerde Talebin Zaman Serileri Modelleri ile Tahmin Edilmesi

Time Series Modelling for Forecasting Demand in the Emergency

Görkem SARIYER *1

¹Yaşar Üniversitesi, İşletme Fakültesi, İşletme Bölümü, 35100 Bornova, İzmir, TÜRKİYE

Başvuru/Received: 02/09/2017

Kabul/Accepted: 04/12/2017

Son Versiyon/Final Version: 29/01/2018

Öz

Acil servislerde talebin etkin olarak yönetilmesi hastane yöneticilerinin (karar vericilerin) önemli bir görevi haline gelmektedir. Günümüzde, hastane yöneticileri, hasta akışının ve aşırı kalabalıklaşmanın en iyi şekilde yönetilebilmesi için strateji geliştirmeye odaklanmaktadır. Acil durumlarda zaman çok kritiktir ve yaşam ve ölüm arasındaki farkı ifade eder. Bu nedenle acil servislerde önemli oranda kaynak bulundurulması gerekmektedir, fakat kaynaklar sınırlıdır. Bu bağlamda, acil servislere talebin en az hata ile tahmin edilmesi, operasyonların planlanması ve yönetilmesinde büyük önem arz etmektedir. Bu çalışmanın amacı; İzmir, Türkiye’deki büyük ölçekli bir eğitim hastanesi acil servisinde talebi zaman serileri modelleri ile tahmin etmektir. Kış aylarında acil servis talebinde ciddi bir artış beklendiği için, talep tahminlemede kış aylarına odaklanılmıştır. Hastane veri tabanı kullanılarak, 1 Aralık 2016-28 Şubat 2017 arasında acil servise yapılan başvurular elde edilmiştir. 1 Aralık-14 Şubat arasındaki 76 günlük veri farklı otoregresif entegre(bütünlenen) hareketli ortalama (ARIMA) ve mevsimsel otoregresif entegre hareketli ortalama (SARIMA) modellerinin uygunluk ve test edilmesinde kullanılırken, kalan 14 günlük veri de uygun modellerin performanslarının karşılaştırılmasında kullanılmıştır. Günlük ve periyodik (8-saat aralıkları) tahminler elde edilmiş ve karşılaştırılmıştır. Bu çalışma acil servis hasta sayısının tahminlemede zaman serileri modellerinin uygun olduğunu göstermektedir.

Anahtar Kelimeler

“Acil servis, talep tahmin, ARIMA, hasta sayısı, aşırı yoğunluk”

Abstract

Managing demand efficiently in emergency departments (ED) has become an important task for decision makers of hospitals. Currently, decision makers focus on improving strategies for optimally managing flow of patients and overcrowding in EDs. Since time is very critical for emergency situations, and can generally mean the difference between life and death, EDs need substantial amount of resources which are indeed limited. In this context, forecasting demand in ED with a minimum error, has noticeable significance for hospitals in planning and managing operations. The objective of this paper was to develop time series models for forecasting demand at the ED of a large scaled training hospital in Izmir, Turkey. Since in winter periods, a significant increase is expected in demand, forecasting demand during winter period is focused. By using Electronic Health Record (EHR) of this hospital, demand in ED during 1st of December, 2016 to 28th of February, 2017 were obtained. First 76 days data (1st December to 14th February) were used to test appropriateness and accuracy of different autoregressive integrated moving average (ARIMA), and seasonal autoregressive integrated moving average (SARIMA) models, where remaining 14 days were used to test the performance of them. Daily and periodical (8-hour lengths) forecasts were evaluated and compared. This study shows how time series models are proper in forecasting patient volumes in EDs.

Key Words

“Emergency department, demand forecasting, ARIMA, patient volume, overcrowding”

1. GİRİŞ

Acil servisler hastalara anlık ve temel bakım hizmeti sunma özellikleri ile sağlık sistemlerinin vazgeçilmez bir bileşeni olmakla birlikte en fazla hasta yoğunluğuna sahip bölümdür. Acil servislerde aşırı yoğunluk, sistem için bir tehdit unsuru olmakta ve operasyonların etkin bir şekilde planlanması ve yönetilmesini zorunlu hale getirmektedir. Dünya çapında hemen hemen tüm acil servislerde karşılaşılan aşırı hasta yoğunluğunun başlıca sebepleri şu şekilde sıralanabilir: Yetersiz istihdam ve yatak kapasitesi (Cooke ve ark., 2004; Sun ve ark., 2006), insanların sağlık sistemlerinden beklentilerinin artması ile birlikte acil servis başvurularının artması (Howard ve ark., 2005), grip gibi salgın hastalıklar (Schull ve ark., 2005), yaşlı nüfusundaki artış (Derose ve ark., 2014; Sariyer ve ark., 2017a), ve acil servise başvuru yapan poliklinik hastaları ve servise girip hizmet almadan çıkan kişiler (Baker ve ark., 1991; Rowe ve ark., 2006). Bu ve benzeri sebeplerle hasta sayısındaki artış, bir çok ülkede acil servislerde aşırı yoğunluğa sebep olmakta, ve gerek sağlık sistemlerini, halk sağlığını, gerekse de hasta memnuniyetini ciddi oranda etkilemektedir (Kolker, 2008; Bair ve ark., 2010; Li ve ark., 2007).

Gün geçtikçe artan hasta sayısı ve aşırı kalabalıklaşma gibi faktörler acil servislerde yöneticilerin (karar vericilerin) operasyon yönetiminde karşılaştığı problemlerin başında gelmektedir. Bu problemle baş etmenin en etkin yolu, kısa dönemli tahminler üretmek (Kadri ve ark., 2014; Hertzum, 2017), ve kapasite planlamasını bu tahminler çerçevesinde dinamik bir şekilde yapmaktır (Sariyer ve ark., 2017b). Acil servislerde talebin minimum hata ile tahmin edilmesi ve operasyonların daha doğru planlanması, aşırı yoğunluk ile baş etmek için stratejiler geliştirilmesi ve hasta memnuniyetinin artması açısından önem arz etmektedir. Zaman serisi analizleri kısa-uzun dönem talep tahminlerinde hastane yöneticilerinin etkin şekilde kullanabileceği modellerdendir.

Bu çalışmadaki temel amaç, İzmir’de büyük ölçekli bir üçüncü basamak eğitim hastanesinde talebin zaman serileri analizi kullanılarak tahmin edilmesidir. Çalışmada farklı otoregresif entegre hareketli ortalama (ARIMA) ve mevsimsel otoregresif entegre hareketli ortalama (SARIMA) modelleri test edilmiştir. Özellikle grip ve benzeri salgın hastalık sayısındaki artış baz alınarak, kış dönemine odaklanılmış ve hastane veri tabanından 1 Aralık 2016-28 Şubat 2017 dönemi hasta sayıları çekilmiştir. Çalışmada günlük talep tahminlemesinin yanında, 8 saat aralıkları göz önünde bulundurularak; [00:00-08:00), [08:00-16:00), [16:00-00), periyodik talep tahminleri de üretilmiştir. Veri setinin ilk 76 günlük kısmında (1 Aralık-14 Şubat) gün ve period bazlı uygun ARIMA ve SARIMA modelleri geliştirilmiş ve kalan 14 günlük veri (15 Şubat-28 Şubat), uygun bulunan modellerin performans testlerinde kullanılmıştır.

Çalışmanın sonucunda, önerilen modellerin hastane yöneticileri tarafından kullanılabilirliği ve bu şekilde talebin önceden etkin bir biçimde öngörülmesi ile kapasite ve kaynak planlamasının en uygun şekilde yapılabileceği gözlenmiştir. Bunun yanında, 8 saatlik periyodlar için üretilen tahminlerin günlük talep tahminlerine göre daha iyi sonuç vermesi (hatayı azaltması) göz önünde bulundurularak, acil servislerde dinamik planlamanın daha etkili olacağı sonucuna varılmıştır.

2. LİTERATÜR TARAMASI

Talep tahmini çalışmaları, istatistik ve operasyon yönetimi literatüründe önemli yer tutmaktadır. Birçok farklı alanda yapılan talep tahmin çalışmaları, son yıllarda özellikle gelişmiş ülkelerde acil servisler için de kullanılmaya başlanmıştır. Türkiye’de ise farklı sektörlerde talep tahminlemede zaman serileri modelleri kullanımı son yıllarda hızla artış gösterirken, sağlık sektörü üzerine uygulamalar literatürde henüz pek fazla yer almamaktadır. Bu kısımda ilk önce Türkiye’de zaman serileri modellerinin kullanıldığı çalışmaların bir kısmı özetlenecek, daha sonra da dünya literatüründe sağlık sektörü üzerine yapılan uygulamaların bazılarını değinilecektir.

Son yıllarda Türkiye’de zaman serileri kullanılarak farklı sektörler için yapılmış talep tahmin çalışmalarının bir kısmı şu şekilde özetlenebilir:

- Petrol talep tahminlemesi: Solak, 2013; Ediger ve Akar, 2007.
- Elektrik talebinin tahmin edilmesi: Dilaver ve Hunt (2011a ve 2011b); Albayrak, 2010; Erdoğan, 2007; Hamzaçebi ve Kutay, 2004.
- Dış ticaret hacmi projeksiyonu: Temuçin ve Temiz, 2016; Karahan, 2015.
- Turizm talep tahminlemesi: Çuhadar ve ark., 2009; Güngör ve Çuhadar, 2005.
- Finans sektöründe tahmin uygulamaları: Yıldız, 2001; Yasemin, 2002.
- Sağlık sektörü talep tahmini: Aydemir ve ark., 2014; Özüdoğru ve Görener, 2015; Özüdoğru ve Görener, 2016

Dünya literatüründe, sağlık sektörü talep tahminlemesinde zaman serileri modelleri kullanımı dikkat çekmektedir (Jones et al., 2008). Hareketli ortalama, üssel düzeltim, ve Holt-Winters literatürde sağlık sektörü ve acil servis talep tahminlemesinde sıklıkla kullanılan zaman serileri modellerinin arasında gelmektedir (örn: Lin, 1989; Jones ve ark., 2009; Bergs ve ark., 2014; Tandberg ve Qualls, 1994). Box-Jenkins metodu veya ARIMA-SARIMA modelleri de sağlık sektörü talep tahminlemesinde sıklıkla kullanılan modellerdendir (örn: Abdel-Aal ve Mangoud., 1998; Jones ve ark., 2002; De Gooijer ve Hyndman, 2006; Barışçı, 2008; Balaguer ve ark., 2008; Kennedy ve ark., 2013; Kim ve ark., 2014; Capan ve ark., 2016). Bu çalışmalar, sağlık sektöründe talep tahminleri üretilirken, özellikle kısa dönem tahminlerde, zaman serisi modellerinin iyi performans sergilediğini göstermişlerdir. Bunun yanında, durağan veri setlerinde, örneğin saat bazlı hasta sayısının tahmin edilmesinde, daha basit yöntemlerin dahi, hareketli ortalama ve üssel düzeltim, kullanılabilirliği sonucuna varılırken (Tandberg ve Qualls, 1994), trend ve mevsimsellik içeren veri setlerinde, Holt-Winters ve Box-Jenkins gibi, daha gelişmiş modellerin kullanılması gerektiği belirtilmiştir (Kim ve ark., 2014; Jones ve ark., 2008).

Bahsi geçen çalışmalar tahmin periyodu olarak, saat, gün, veya ay kullanılmaktadırlar. Örneğin, Tandberg ve Qualls (1994) ve Jones ve ark. (2009) her saat için acil servise gelen hasta sayısını tahmin ederken, Capan ve ark. (2016), günlük hasta sayısını tahmin eden modeller geliştirmiş, ve mevsimsellik periyodunu 7 olarak belirlemişlerdir. Bergs ve ark. (2013) ise ay bazlı tahminler geliştirmiş ve mevsimsellik periyodunu 12 olarak almışlardır. Kısa dönem tahminlerde, saat bazlı analizlerin talepteki varyansı azaltması, veriyi daha sabit hale getirmesi, sebebiyle, iyi performans gösterdiği düşünülebilir. Fakat, acil servislerde operasyonel açıdan bu tahminlerin kullanılması pek mümkün değildir. Çünkü, her saat başında personel sayısını değiştirmek, hastaların hikayesini yeni gelen personele aktarmak işleyişteki verimliliği ciddi ölçüde aksatabileceği gibi malpraktislere de sebep olabilir. Bu nedenle, bu çalışmada hasta sayısını acil servis literatüründe belirtilen ve birçok acil serviste uygulanan shiftler-vardiyalar bazında tahmin etmenin daha uygulanabilir ve gerçekçi olduğu düşünülmüştür. Ayrıca bilgimiz dahilinde, kış mevsiminde salgın hastalıklardaki artışı göz önünde bulundurarak, bu mevsim özelinde hasta sayısı tahmin eden modeller geliştiren bir çalışmaya rastlanmamıştır. Dolayısı ile, bu çalışma literatürde talep tahminlemede sıklıkla kullanılan modellerden yararlı olsa da, gerek veri toplamada Türkiye’de bir acil servisten yararlanılması, gerek periyod bazlı tahminler üretmesi, gerekse kış mevsimini kendi özelinde değerlendirmesi bakımından literatüre katkı sağlamaktadır.

3. YÖNTEM

Çalışmada zaman serileri analizinde Box-Jenkins yöntemi kullanılmaktadır. Bu teknik 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. Bu modelin genel yapısı ARIMA $(p, d, q) * (P, D, Q)_s$ olarak gösterilmektedir. Burada p, d ve q mevsimsel olmayan birleşenin parametrelerini ifade ederken, P, D ve Q benzer şekilde mevsimsel birleşenin parametrelerini göstermekte ve s ’de mevsimsellik periyodunu ifade etmektedir. AR(p), MA(q) ve bunların birleşimi olan ARMA(p, q) modelleri mevsimsel olmayan durağan süreçler için kullanılırken, ARMA(p, q) * $(P, Q)_s$ mevsimsel ve durağan süreçler için kullanılmaktadır. Durağan ve mevsimsel olmayan süreçler ARIMA (p, d, q) modelleri ile ifade edilirken, durağan olmayan mevsimsel süreçler ARIMA $(p, d, q) * (P, D, Q)_s$ modelleri ile ifade edilmektedir (Box, Jenkins, ve Reinsel, 2008).

Bilinen tüm bu modellerle ilgili ayrıntıya burada yer verilmeyecektir. Sadece bahsi geçen modellerin temel matematiksel ifadeleri sırasıyla özetlenecektir.

- **AR(p)** modeli sezgisel olarak cazip bir model olarak ifade edilebilir, bir gözlem direk olarak kendisinden bir veya birkaç (p) dönem önceki değerlerin ve rassal hatanın doğrusal bir fonksiyonu olarak ifade edilmektedir. Dolayısı ile zaman serisindeki Y_t gözlemi, AR(p) modeline göre şu şekilde ifade edilmektedir:

$$Y_t = \sum_{i=1}^p \alpha_i Y_{t-i} + \varepsilon_t \quad (1)$$

Bir numaralı eşitlikte, Y_{t-i} terimleri geçmiş gözlemleri, α_i değerleri de bu gözlemler için katsayıları ifade eder ($i=1,..,p$). ε_t ise standart normal dağılıma sahip rassal hatayı ifade etmektedir; $\varepsilon_t \sim N(0, \sigma^2)$

- **MA(q)** modelinde ise Y_t değeri, serinin geriye doğru q period boyunca geçmiş hata terimlerinin ve ortalamasının doğrusal fonksiyonudur. Y_t gözleminin, MA(q) modeli ile ifadesi şu şekildedir:

$$Y_t = \varepsilon_t + \sum_{j=1}^q b_j \varepsilon_{t-j} \quad (2)$$

Benzer şekilde, iki numaralı eşitlikte ε_{t-j} terimleri mevsimsel olmayan geçmiş hata terimlerini gösterirken, b_j değerleri bu gözlemler için katsayıları ifade eder ($j=1,..,q$).

- **ARMA(p, q)** modeli geçmiş gözlem ve geçmiş hata terimlerinin doğrusal bir fonksiyonudur.

$$Y_t = \sum_{i=1}^p \alpha_i Y_{t-i} + \sum_{j=1}^q b_j \varepsilon_{t-j} + \varepsilon_t \quad (3)$$

Üç numaralı eşitlikte gösterilen parametreler, bir ve iki numaralı eşitliklerde tanımlanmıştır.

- **ARIMA(p, d, q)** modeli zaman serisinin durağan olmadığı durumlarda, diğer bir deyişle, serinin ortalama ve varyansında zamana bağlı değişim gözlemlendiğinde, kullanılmaktadır. Böyle durumlarda zaman serisinde fark alınarak, serinin durağanlaştırılması işlemi gerçekleştirilmektedir. Modeldeki d parametresi seride kaç kere fark alındığını ifade etmektedir. Zaman serisinde lineer bir trend var ise bir kere fark alınarak seri durağan hale getirilebilir. Eğer trend eğrisel ise farkların tekrar farkı alınarak, yani iki kere fark serisi oluşturularak, seri durağan hale getirilebilir. Seri durağan hale getirildikten sonra daha önce bahsedildiği şekliyle AR(p), MA(q), veya ARMA(p,q) modelleri uygulanır.

Zaman serileri analizinde lag operatörleri, B, kullanılmaktadır, ve bu operatör şu şekilde tanımlanmaktadır: $B^k Y_t = Y_{t-k}$. Bu operatör zaman serilerindeki gözlem üzerinde çalıştırılarak, bir önceki gözlemin elde edilmesini sağlamaktadır. Bu operatörün kullanılması ile üç numaralı eşitlik, şu şekilde yeniden gösterilebilir:

$$\Phi(B)Y_t = \theta(B)\varepsilon_t$$

$$\begin{aligned} \phi(B) &= (1 - a_1B - a_2B^2 - \dots - a_pB^p) \\ \theta(B) &= (1 - b_qB - b_qB^2 - \dots - b_qB^q) \end{aligned} \quad (4)$$

- Mevsimsellik içeren veri setlerinde de benzer mantıkla mevsimsellik periyodu uzaklıktaki gözlemler veya/ve bu gözlemlerdeki geçmiş hata terimleri de modele eklenir. En genel hali ile mevsimsel ARIMA modelleri aşağıdaki matematiksel ifadelerle gösterilmektedir:

$$\Phi_p(B^s)\phi_p(B)\nabla_s^D\nabla^dY_t = \theta_q(B)\theta_q(B^s)\varepsilon_t \quad (5)$$

Beş numaralı eşitlikte:

$\Phi_p(B^s) = (1 - \phi_1B^s - \dots - \phi_pB^{sP})$ parametresi P olan mevsimsel otopregresif operatörü

$\phi_p = (1 - \phi_1B - \dots - \phi_pB)$ parametresi p olan ve mevsimsel olmayan otopregresif operatörü

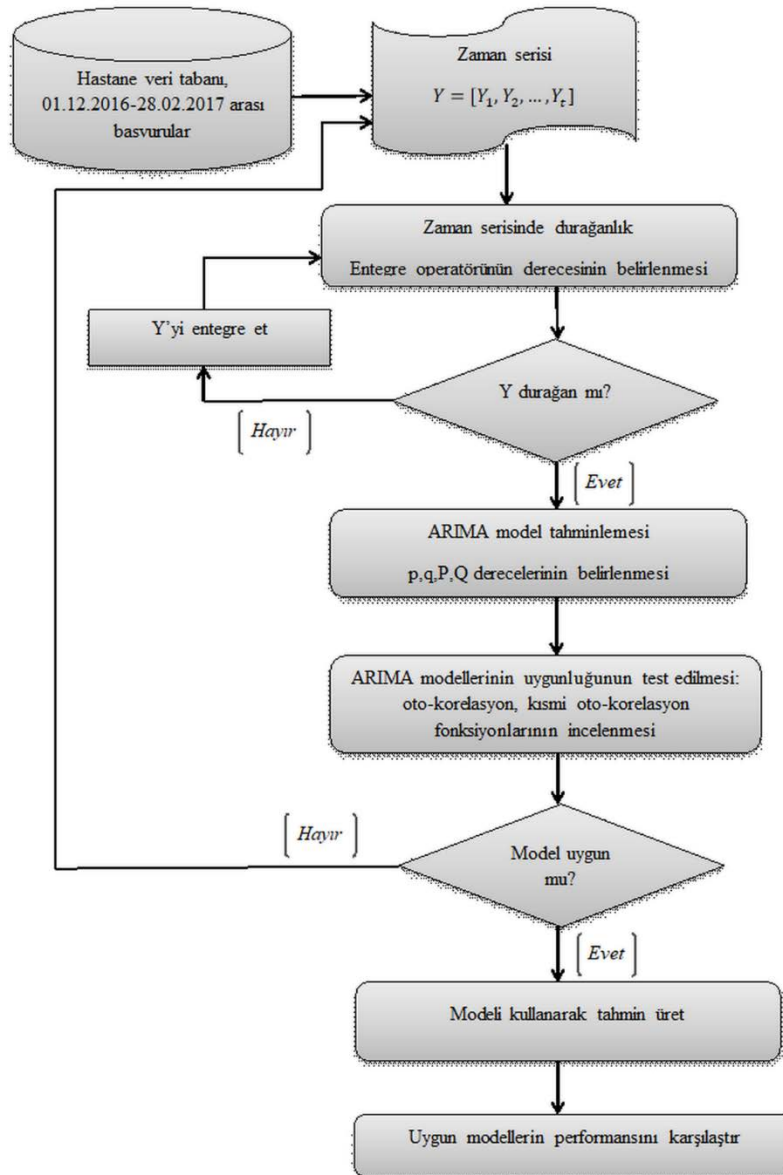
$\nabla_s^D = (1 - B^s)^D$ mevsimsel entegre operatörü

$\nabla^d = (1 - B)^d$ mevsimsel olmayan entegre operatörü

$\theta_q(B^s) = (1 - \theta_1B^s - \dots - \theta_qB^{sQ})$ parametresi Q olan mevsimsel hareketli ortalama operatörünü

$\theta_q(B) = (1 - \theta_1B - \dots - \theta_qB)$ parametresi q olan mevsimsel olmayan hareketli ortalama operatörünü göstermektedir.

Zaman serileri analizinde ARIMA $(p, d, q) * (P, D, Q)_s$ modellerinin kullanılmasındaki aşamalar Şekil 1’de özetlenmiştir.



Şekil 1: ARIMA modeli uygulama aşamaları

4. UYGULAMA

4.1. Çalışma Verisi

Araştırmada İzmir’de 3. basamak bir araştırma hastanesi acil servisine 01.12-2016-28.02.2017 tarihleri arasında yapılan başvurular kullanılmıştır. Bu başvurular hastanenin veri tabanından çekilmiştir. Araştırmanın amacı, gün ve periyod bazlı hasta sayısını tahmin etmek olduğu için, günlük toplam hasta sayısı ve her periyod başına düşen hasta sayısı veri olarak kullanılmıştır. Dolayısı ile, veri tabanından sadece bu tarihler arasında yapılan tüm başvuruların geliş gün ve saati çekilmiştir.

4.2. Veri Analizi

Çalışmada kış periyoduna düşen toplamda 90 günlük veri kullanılmıştır. Bu verinin ilk 76 günlük (01.12.2016-14.02.2017) kısmı uygun modelleri ve bu modellerin parametrelerini belirlemek için kullanılmıştır. Kalan 14 günlük veri ise (15.02.2017-28.01.2017) uygun görülen modellerin tahminleme performansını test etmek için kullanılmıştır. Performans değerlendirmede, diğer bir deyişle, uygulanan yöntemlerin tahmin doğruluğunu karşılaştırmada, *ortalama mutlak yüzde hata* (MAPE), istatistiğinden faydalanılmıştır. Farklı istatistikler olmasına karşın, MAPE’nin seçilme sebebi, bu istatistiğin hatayı yüzde olarak ifade etmesiyle tek başına da bir anlam ifade ediyor ve karşılaştırmayı mümkün kılıyor olmasıdır. Literatürde MAPE değeri %10’un altında olan modeller “çok iyi”, %10-%20 arasında olan modeller “iyi”, %20-%50 arasında olan modeller “kabul edilebilir”, ve %50’nin üzerinde olan modeller de “yanlış ve hatalı” olarak sınıflanmıştır (Lewis, 1982). MAPE istatistiği matematiksel olarak şu şekilde ifade edilmektedir:

$$MAPE = \frac{1}{n} \sum_{t=1}^n \frac{|Y_t - \hat{Y}_t|}{Y_t} * 100 \quad (6)$$


Altı numaralı eşitlikte Y_t t periyodunda gerçekleşen gözlemin değerini gösterirken, \hat{Y}_t , bu dönem için önceden yapılmış tahmini göstermektedir. Dolayısı ile, $|Y_t - \hat{Y}_t|$, yapılan tahminin mutlak hatasını ifade eder. Tahmin yapılan dönem sayısı n ile gösterilmektedir.

Çalışmada periyodlar için tahmin üretmek amacıyla, sağlık sektöründe vardiya (shift) saatlerine uygun tanımlamalar yapılmıştır. Gün 8’er saatlik üç periyoda bölünmüştür. İlk periyod, P1 olarak adlandırılmış, ve [00:00-08:00) zaman dilimini ifade etmiştir. Benzer şekilde P2: [08:00-16:00) periyodunu ifade ederken, P3: [16:00-00:00)’ı göstermiştir. Özetle, günlük toplam hasta sayısının yanında P1, P2, ve P3 periyodlarındaki hasta sayısını tahmin eden modeller de geliştirilmiştir.

Çalışmada verinin durağanlığını test ederken E-Views yazılımından yararlanılmıştır. ARIMA modellerinin uygulanmasında da MINITAB(17.00) yazılımı kullanılmıştır.

5. SONUÇLAR

Acil servise 01.12.2016-14.02.2017 tarihleri arasında günlük toplam ve periyodlara göre yapılan başvuru sayısı Şekil 2 de gösterilmiştir.



Şekil 2: Gün ve periyodlara göre toplam hasta sayısı

Şekil 2 incelendiğinde, gerek günlük gerekse periyodlar bazında hasta sayısında mevsimsellik gözlenmiştir. Ayrıca, P1 periyodunda hasta sayısının her zaman en düşük olduğu, P3 periyodunda da en yüksek olduğu (31 Aralık hariç) gözlenmektedir. Veri setine uygun ARIMA modellerini test etmeden önce Figür 1 de gösterildiği üzere ilk önce verinin durağan olup olmadığını test etmek gerekmektedir. Bu amaçla, birim kök test olan Augmented Dickley Fuller (ADF) test kullanılmıştır. Birim kök testi için sıfır hipotezi şu şekilde ifade edilmektedir:

H_0 : Veri seti birim köke sahiptir.

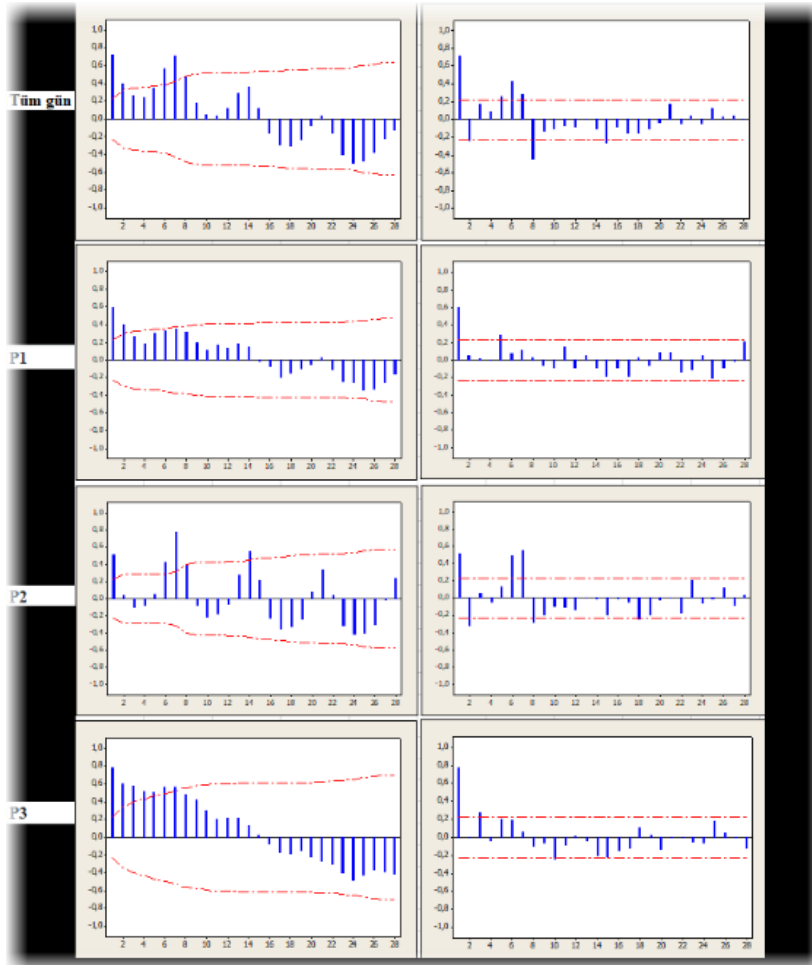
Sıfır hipotezinde belirtilen birim kök verinin durağanlığına zarar vermektedir, ve test sonucunda sıfır hipotezi reddedebilecek değerlere (test istatistiği, p-değeri) ulaşamıyorsa, veri durağan değildir, ve entegre edilmelidir sonucuna varılır. Günlük toplam hasta sayısı ve periyodlar için hasta sayıları veri setlerine uygulanan birim kök test sonuçları Tablo 1’de özetlenmiştir.

Tablo 1: Birim Kök Test Sonuçları

Veri seti	t-istatistik değeri	p-değeri	test sonucu
Tüm gün	-1.31	0.62	Entegre et
P1	-4.25	0.001	Veri durağan
P2	-1.21	0.70	Entegre et
P3	-3.77	0.04	Veri durağan

Tablo 1 de görüldüğü gibi, P1 ve P3 periyodlarını ifade eden veri setlerinin entegre edilmesine gerek yoktur. Tüm gün ve P2 periyodu veri setinin ise kaç kere entegre edilmesi gerektiğini görmek için, veri setleri birer kere entegre edildikten sonra birim kök testi tekrar uygulanmıştır. Tüm gün veri setinin bir kere entegre edilmiş haline test uygulandığında test istatistik değerinin -3.18, ve p değerinin 0.03 olduğu, benzer şekilde P2 verisinin entegre edilmiş setine birim kök test uygulandığında test istatistik değerinin -4.99 ve p değerinin 0.0001 olduğu gözlenmiştir. Bu sonuçlar dahilinde, tüm gün ve P2 veri setlerinde entegrasyon parametresinin $d=D=1$, P1 ve P3 veri setlerinde ise $d=D=0$ olarak belirlenmesine karar verilmiştir.

Tüm gün ve periyodlar için veri setlerinin korelogram grafikleri Şekil 3’de gösterilmiştir. Bu grafik de veri setleri için oto-korelasyon ve kısmi oto-korelasyon değerleri gözlenmektedir.



Şekil 3: Veri setleri için korelogram grafikleri

Şekil 3 incelendiğinde, tüm gün ve P2 veri setleri için yedinci laglerde yüksek korelasyon değerleri gözlenmiştir. Bu bilgi ışığında, bu veri setlerinin mevsimsel olduğu, ve mevsimsel oto regresif modellerinin bu veri setlerinde daha iyi performans göstereceği sonucuna varılmıştır.

Veri setlerinin yapısını analiz etmek amacıyla yapılan ön çalışmalar ışığında farklı ARIMA (p,d,q) ve ARIMA(p, d, q) * (P, D, Q)_s modelleri ilk 76 günlük veriler için denenmiştir. Her veri setinde farklı uygun modeller belirlenmiştir. Uygun modeller ile son 14 gün için tahminler üretilmiştir. Bu tahminlerde en iyi performansı sergileyen (en düşük MAPE değerine sahip) modeller MAPE değerleri ile birlikte Tablo 2’de özetlenmiştir.

Tablo 2: En iyi tahmin modelleri ve performansları

Veri seti	Model	MAPE
Tüm gün	ARIMA(1,1,1) * (1,0,0) ₇	8.16
P1	ARIMA(1,0,2) * (0,0,0) ₇	7.17
P2	ARIMA(0,1,1) * (1,0,0) ₇	6.64
P3	ARIMA(1,0,1) * (0,0,0) ₇	5.01

Tablo 2’de görülen modeller daha önceki bulgular ile paralellik göstermektedir. Şekil 3’deki korelogram grafiklerinde görüldüğü üzere, tüm gün ve P2 periyodu için veri setlerinde mevsimsel oto-regresif parametre aktiftir. Benzer şekilde durağanlık analizinde görüldüğü üzere, bu veri setleri için veri entegre edilmiştir. Önerilen modellerin, model çıktıları Tablo 3’de özetlenmiştir.

Tablo 3: Model çıktı özeti

Veri seti	Çıktı
Tüm gün	Tür katsayı SE T P
	AR 1 0,7154 0,0856 8,36 0,000
	SAR 7 0,7723 0,0753 10,25 0,000
	MA 1 1,0093 0,0015 658,37 0,000
	Sabit -0,01799 0,05554 -0,32 0,747
Entegre: 1 kere	
Gözlem sayısı: Orjinal veri seti 76, entegre edildikten sonra 75	
Hatalar: SS = 345128	
MS = 4861 DF = 71	
P1	Tür katsayı SE T P
	AR 1 0,9501 0,0610 15,59 0,000
	MA 1 0,3946 0,1317 3,00 0,004
	MA 2 0,2775 0,1264 2,20 0,031
	Sabit 6,5563 0,7414 8,84 0,000
Ortalama 131,38 14,86	
Gözlem sayısı: 76	
Hatalar: SS = 24008,1	
MS = 333,4 DF = 72	
P2	Tür katsayı SE T P
	SAR 7 0,8773 0,0632 13,89 0,000
	MA 1 0,7021 0,0833 8,43 0,000
Entegre: 1 kere	
Gözlem sayısı: Orjinal veri seti 76, entegre edildikten sonra 75	
Hatalar: SS = 149965	
MS = 2054 DF = 73	


Tablo 3 (devam): Model çıktı özeti

P3	Tür	katsayı	SE	T	P
	AR 1	0,8037	0,0899	8,94	0,000
	MA 1	-0,0190	0,1462	-0,13	0,897
	Sabit	94,332	5,085	18,55	0,000
	Ortalama	480,67	25,91		

Gözlem sayısı: 76

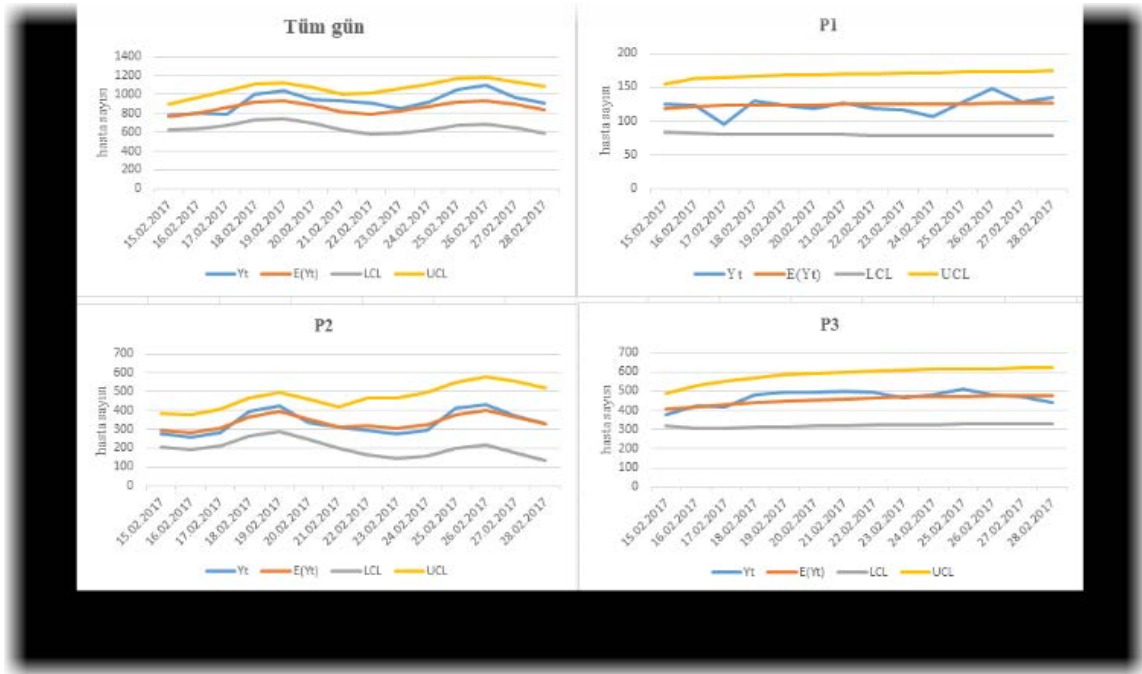
Hatalar: SS = 135679
MS = 1859 DF = 73

Veri setlerinde uygun görülen ARIMA modelleri uygulandıktan sonra hataların korelogram grafikleri Şekil 4'de verilmiştir.



Şekil 4: Uygun yöntemler denendikten sonra hataların korelogram grafikleri

Tablo 3’de parametrelerin istatistiksel anlamlılıkları analiz edildiğinde, önerilen modellerdeki parametrelerin istatistiksel olarak anlamlı olduğu ($p < 0.05$) gözlenmiştir. Bununla birlikte, Şekil 4’de korelogram diagramları incelendiğinde, hataların arasında korelasyon olmadığı, yani hataların rassal olduğu sonucuna varılmıştır (tüm zaman dilimleri için korelasyon değerleri kontrol limitleri arasında). Bu sonuçlar ışığında, önerilen modellerin tanımlı veri setleri için uygun ve en iyi tahmin edici modeller olduğu sonucuna varılmıştır. Son olarak, kullanılan veri setleri için 15-28 Şubat arası gerçek gözlemlenen hasta sayıları ve önerilen modeller ışığında tahmin edilen hasta sayıları Şekil 5’de verilmiştir.



Şekil 5: Tahmin edilen ve gerçekleşen hasta sayıları

6. ÇALIŞMANIN KISITLARI

Çalışmada kullanılan veri seti, büyük ölçekli ve merkezi bir hastaneden alınmış olsa da tek bir hastane verisinin kullanılmış olması, çalışmanın kısıtlarından biridir. Tek bir hastane verisi kullanılması, önerilen modellerin genellenebilirliğini engellemektedir. Fakat yine de, ele alınan hastane özelinde kullanılabilir modeller belirlenmektedir.

Bunun yanında tek bir kış veri setinin kullanılmış olması da çalışmanın diğer bir kısıtıdır. Tek bir senelik veri kullanılması, verideki (varsa) trend etkisini gözlemlemeyi ve modele eklemeyi engellemektedir. Fakat hastanenin Haziran 2016 tarihinde hasta kabul etmeye başladığı düşünüldüğünde birkaç senelik veri toplamanın şu aşamada mümkün olmadığı bilinmektedir. İleriki çalışmalarda, daha fazla hastaneden uzun süreli (en az beş yıl) veri seti toplayıp, bu veri setlerinin karşılaştırılması ve bütünsel olarak analiz edilmesi planlanmaktadır.

7. TARTIŞMA VE SONUÇ

Geçmiş verinin istatistiksel olarak analiz edilmesi, operasyon yönetimi açısından çok önemlidir. Bu analizlerin kullanılması, gerek şirketlerde gerekse kamu kuruluşlarında karar vericilerin daha doğru kararlar vermesini ve daha efektif planlar yapmasını sağlamaktadır.

Bu çalışmada büyük ölçekli bir hastane acil servisinin talebinin gelişmiş istatistiksel yöntemlerle tahmin edilmesi amaçlanmıştır. Hatayı en iyileştiren (en aza indiren) tahmin modellerinin kullanılması acil servis operasyon yönetimi ve kaynak planlaması açısından ciddi bir öneme sahiptir. Firma veya diğer kamu kuruluşlarından farklı olarak, acil servislerde kaynağın yetersiz planlanması, sadece kar (veya müşteri) kaybı ile değil, can kaybı ile bile sonuçlanabilir. Bu nedenle, gelecek ile ilgili doğru tahminler oluşturabilmek, eldeki kaynakların en verimli şekilde kullanılmasını ve operasyonel aksaklıklardan kaynaklanan kaybın en aza indirgenmesini sağlayacaktır.

Kış periyotlarında salgın hastalıklardan kaynaklanan talepteki artış bilinmektedir. Fakat, hastane acil servislerinde yarı zamanlı personel çalıştırmak gibi alternatifler pek mümkün olmadığı için, elde var olan kaynağın en verimli şekilde kullanılması, talebin en yoğun olduğu bu dönemlerde daha da önemli bir hale gelmektedir. Bu nedenle, bu çalışmada talebin periyodlara göre tahmin

edilmesi amaçlanmıştır. Yapılan veri analizinde de, talebin günün farklı periyodlarına göre eşit dağılmadığı gözlenmiştir (Şekil 2). Dolayısıyla, periyod bazlı tahminler yapıp, kaynak planlama ve çizelgelemesinin bu tahminler ışığında yapılmasının acil servis operasyonlarının daha iyi yönetilmesine katkı sağlayacağı düşünülmektedir.

Çalışmada ele alınan dört veri seti bulunmaktadır. Bu veri setleri ayrı ayrı incelendiğinde otokorelogram diagramları ve veri yapılarında benzerlikler olduğu gibi farklılıklar da gözlenmiştir (Tablo 1, Şekil 3). Bu bilgiler ışığında da veri setlerini tahmin etmede önerilen model tanımlarının birbirinden farklılık göstermiştir (Tablo 2). Kullanılan modellerin performans test sonuçları incelendiğinde, tüm gün için yapılan tahminlerin periyod bazlı yapılan tahminler kadar başarılı olmadığı sonucuna varılmıştır (Tablo 2, Şekil 5). Genel olarak bakıldığında ise literatürde zaman serileri modellemesinde sıklıkla kullanılan ARIMA, SARIMA modellerinin acil servise gelen hasta sayısını tahmin etmek için de kullanılabileceği ve bu modellerin iyi performans sergileyeceği gözlenmiştir.

Sonuç olarak, acil servise gelen hasta sayısının zaman serileri şeklinde modellenebileceği, fakat günü bir bütün olarak değerlendirmek yerine, çalışma vardiya saatlerine göre değerlendirmenin hem teorik hem de uygulama açısından, operasyonların daha iyi planlanmasını ve yönetilmesini sağlayacağı öngörülmektedir.

REFERANSLAR

Abdel-Aal, R. E., & 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(3), 235-247.

Albayrak, A. S. (2010). ARIMA forecasting of primary energy production and consumption in Turkey: 1923-2006. *Enerji, piyasa ve düzenleme*, 1(1), 24-50.

Aydemir, E., Karaatlı, M., Yılmaz, G., & Aksoy, S. (2014). 112 acil çağrı merkezine gelen çağrı sayılarını belirleyebilmek için bir yapay sinir ağları tahminleme modeli geliştirilmesi. *Pamukkale Üniversitesi Mühendislik Fakültesi Dergisi* 20(5):145-149

Bair, A. E., Song, W. T., Chen, Y. C., & Morris, B. A. (2010). The impact of inpatient boarding on ED efficiency: a discrete-event simulation study. *Journal of medical systems*, 34(5), 919-929.

Baker, D. W., Stevens, C. D., & Brook, R. H. (1991). Patients who leave a public hospital emergency department without being seen by a physician: causes and consequences. *Jama*, 266(8), 1085-1090.

Balaguer, E., Palomares, A., Soria, E., & Martín-Guerrero, J. D. (2008). Predicting service request in support centers based on nonlinear dynamics, ARMA modeling and neural networks. *Expert Systems with Applications*, 34(1), 665-672.

Barişçi, N. (2008). The adaptive ARMA analysis of EMG signals. *Journal of medical systems*, 32(1), 43-50.

Bergs, J., Heerinckx, P., & Verelst, S. (2014). Knowing what to expect, forecasting monthly emergency department visits: A time-series analysis. *International emergency nursing*, 22(2), 112-115.

Box, G. E., Jenkins, G. M., Reinsel, G. C., & Ljung, G. M. (2015). *Time series analysis: forecasting and control*. John Wiley & Sons.

Capan, M., Hoover, S., Jackson, E. V., Paul, D., & Locke, R. (2016). Time series analysis for forecasting hospital census: Application to the Neonatal Intensive Care Unit. *Applied clinical informatics*, 7(2), 275.

Cooke, M. W., Wilson, S., Halsall, J., & Roalfe, A. (2004). Total time in English accident and emergency departments is related to bed occupancy. *Emergency Medicine Journal*, 21(5), 575-576.

Çuhadar, M., Güngör, İ., & Göksu, A. (2009). Turizm talebinin yapay sinir ağları ile tahmini ve zaman serisi yöntemleri ile karşılaştırmalı analizi: Antalya iline yönelik bir uygulama. *Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 14(1).

Derose, S. F., Gabayan, G. Z., Chiu, V. Y., Yiu, S. C., & Sun, B. C. (2014). Emergency department crowding predicts admission length-of-stay but not mortality in a large health system. *Medical care*, 52(7), 602.

Dilaver, Z., & Hunt, L. C. (2011a). Industrial electricity demand for Turkey: a structural time series analysis. *Energy Economics*, 33(3), 426-436.

Dilaver, Z., & Hunt, L. C. (2011b). Modelling and forecasting Turkish residential electricity demand. *Energy Policy*, 39(6), 3117-3127.

Ediger, V. Ş., & Akar, S. (2007). ARIMA forecasting of primary energy demand by fuel in Turkey. *Energy Policy*, 35(3), 1701-1708.

- Erdogdu, E. (2007). Electricity demand analysis using cointegration and ARIMA modelling: A case study of Turkey. *Energy policy*, 35(2), 1129-1146.
- Hamzaçebi, C., & Kutay, F. (2004). Yapay sinir ağları ile Türkiye elektrik enerjisi tüketiminin 2010 yılına kadar tahmini. *Gazi Üniversitesi Mühendislik-Mimarlık Fakültesi Dergisi*, 19(3).
- Hertzum, M. (2017). Forecasting Hourly Patient Visits in the Emergency Department to Counteract Crowding. *The Ergonomics Open Journal*, 10(1).
- Howard, M. S., Davis, B. A., Anderson, C., Cherry, D., Koller, P., & Shelton, D. (2005). Patients' perspective on choosing the emergency department for nonurgent medical care: a qualitative study exploring one reason for overcrowding. *Journal of Emergency Nursing*, 31(5), 429-435.
- De Gooijer, J. G., & Hyndman, R. J. (2006). 25 years of time series forecasting. *International journal of forecasting*, 22(3), 443-473.
- Güngör, İ., & Çuhadar, M. (2005). Antalya İline Yönelik Alman Turist Talebinin Yapay Sinir Ağları Yöntemiyle Tahmini. *Gazi Üniversitesi Ticaret ve Turizm Eğitim Fakültesi Dergisi*, 1, 84-99.
- Jones, S. S., Thomas, A., Evans, R. S., Welch, S. J., Haug, P. J., & Snow, G. L. (2008). Forecasting daily patient volumes in the emergency department. *Academic Emergency Medicine*, 15(2), 159-170.
- Jones, S. A., Joy, M. P., & Pearson, J. (2002). Forecasting demand of emergency care. *Health care management science*, 5(4), 297-305.
- Jones, S. S., Evans, R. S., Allen, T. L., Thomas, A., Haug, P. J., Welch, S. J., & Snow, G. L. (2009). A multivariate time series approach to modeling and forecasting demand in the emergency department. *Journal of biomedical informatics*, 42(1), 123-139.
- Kadri, F., Harrou, F., Chaabane, S., & Tahon, C. (2014). Time series modelling and forecasting of emergency department overcrowding. *Journal of medical systems*, 38(9), 107.
- Karahan, M. (2015). Yapay Sinir Ağları Metodu İle İhracat Miktarlarının Tahmini: ARIMA ve YSA Metodunun Karşılaştırmalı Analizi. *Ege Academic Review*, 15(2).
- Kennedy, K., Salzillo, M., Olinsky, A., & Quinn, J. (2013). Forecasting patient volume for a large hospital system: A comparison of the periodicity of time series data and forecasting approaches. In *Advances in Business and Management Forecasting* (pp. 33-44). Emerald Group Publishing Limited.
- Kim, K., Lee, C., O'Leary, K., Rosenauer, S., & Mehrotra, S. (2014). *Predicting patient volumes in hospital medicine: A comparative study of different time series forecasting methods*. Tech. rep., Northwestern University.
- Kolker, A. (2008). Process modeling of emergency department patient flow: Effect of patient length of stay on ED diversion. *Journal of Medical Systems*, 32(5), 389-401.
- Lewis, C. D. (1982). *Industrial and business forecasting methods: A Radical guide to exponential smoothing and curve fitting*. Colin David.
- Li, G., Lau, J. T., McCarthy, M. L., Schull, M. J., Vermeulen, M., & Kelen, G. D. (2007). Emergency department utilization in the United States and Ontario, Canada. *Academic Emergency Medicine*, 14(6), 582-584.
- Lin, W. T. (1989). Modeling and forecasting hospital patient movements: Univariate and multiple time series approaches. *International Journal of Forecasting*, 5(2), 195-208.
- Özudođru, A. G., & Görener, A. (2015). Sağlık sektöründe talep tahmini üzerine bir uygulama. <http://hdl.handle.net/11467/940>.
- Özudođru, A. G., & Gorener, A. (2016). Method Selection for Demand Forecasting: Application in a Private Hospital. *International Journal of Decision Sciences & Applications-IJDSA*, 1(1), 22-34.
- Rowe, B. H., Channan, P., Bullard, M., Blitz, S., Saunders, L. D., Rosychuk, R. J., ... & Holroyd, B. R. (2006). Characteristics of patients who leave emergency departments without being seen. *Academic Emergency Medicine*, 13(8), 848-852.
- Sariyer, G., Ataman, M. G., Sofuođlu, T., & Sofuođlu, Z. (2017a). Does ambulance utilization differ between urban and rural regions: a study of 112 services in a populated city, Izmir. *Journal of Public Health*, 1-7.
- Sariyer, G., Ataman, M. G., Akay, S., Sofuođlu, T., & Sofuođlu, Z. (2017b). An analysis of Emergency Medical Services demand: Time of day, day of the week, and location in the city. *Turkish Journal of Emergency Medicine*, 17(2), 42-47.

- Schull, M. J., Mamdani, M. M., & Fang, J. (2005). Influenza and emergency department utilization by elders. *Academic emergency medicine, 12*(4), 338-344.
- Solak, A. O. (2013). Türkiye'nin Toplam Petrol Talebi ve Ulaştırma Sektörü Petrol Talebinin Arıma Modeli İle Tahmin Edilmesi. *Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi, 18*(3).
- Sun, B. C., Mohanty, S. A., Weiss, R., Tadeo, R., Hasbrouck, M., Koenig, W., ... & Asch, S. (2006). Effects of hospital closures and hospital characteristics on emergency department ambulance diversion, Los Angeles County, 1998 to 2004. *Annals of emergency medicine, 47*(4), 309-316.
- Tandberg, D., & Qualls, C. (1994). Time series forecasts of emergency department patient volume, length of stay, and acuity. *Annals of emergency medicine, 23*(2), 299-306.
- Temuçin, T., & Temiz, İ. (2016). Türkiye dış ticaret ihracat hacminin projeksiyonu: Holt-Winters ve Box-Jenkins modellerinin bir kıyaslaması. *Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi, 21*(3).
- Yasemin, B. E. N. L. (2002). Finansal Başarısızlığın Tahmininde Yapay Sinir Ağı Kullanımı ve MKB'de Bir Uygulama. *Muhasebe Bilim Dünyası Dergisi, 17*-30.
- Yıldız, B. (2001). Finansal başarısızlığın öngörülmesinde yapay sinir ağı kullanımı ve halka açık şirketlerde ampirik bir uygulama. *İMKB Dergisi, 17*, 51-67.