

## Yoğun Bakım Ünitesinde Hasta Kalış Süresinin Karma Dağılım ile Modellenmesi

Selin SARAÇ GÜLERYÜZ\*<sup>1</sup> ORCID 0000-0002-4729-0637

<sup>1</sup>Toros Üniversitesi, Mühendislik Fakültesi, Endüstri Mühendisliği Bölümü, Mersin

Geliş tarihi: 18.03.2024 Kabul tarihi: 27.06.2024

Atıf şekli/ How to cite: SARAÇ GÜLERYÜZ, S., (2024). Yoğun Bakım Ünitesinde Hasta Kalış Süresinin Karma Dağılım ile Modellenmesi. Çukurova Üniversitesi, Mühendislik Fakültesi Dergisi, 39(2), 427-436.

### Öz

Yoğun bakım üniteleri sağlık sisteminde merkezi bir rol oynamaktadır. Hastanede kalış süresi, hastane yönetimi kalitesinin önemli bir göstergesidir. Simülasyon, çizelgeleme, planlama gibi alanlarda hasta kalış sürelerinin istatistiksel olarak tanımlanması gerekir. Ancak bu veriler oldukça çarpıktı ve bu nedenle istatistiksel modelleme zorlu bir iş olabilir. Karma dağılım modelleri, bu zorluğun üstesinden gelebilecek kabiliyete sahip modellerdir. Bu çalışmada, iki farklı yoğun bakım ünitesinde (genel cerrahi, koroner) gözlemlenen oldukça çarpık hasta kalış süresi verilerinin modellenmesi için karma dağılım yaklaşımı kullanılmıştır. Karma dağılım modellerini geliştirmek için dört farklı dağılım (normal, Weibull, gamma, lognormal) kullanılmıştır. Karma dağılımının optimal bileşen sayısı Bayes bilgi kriteri değeri yardımıyla belirlenmiş ve dağılım parametreleri beklenti-maksimizasyon algoritması kullanılarak tahmin edilmiştir. Bileşen ve parametre tahmini yapılan karma dağılımın model geçerliliği, ortalama mutlak yüzde hata ve  $R^2$  değeri kullanılarak değerlendirilmiş ve gerçek veri setlerini oldukça yüksek doğrulukla temsil ettiği görülmüştür.

**Anahtar Kelimeler:** Kalış süresi, Performans metrikleri, Karma dağılım, Tahmin, Yoğun bakım ünitesi

### Modeling the Length of Stay in the Intensive Care Unit by Using Mixture Distribution

#### Abstract

Intensive care units play a central role in the healthcare system, and the length of stay in hospitals serves as a significant indicator of hospital management quality. Statistical characterization of patient lengths of stay is essential in areas such as simulation, scheduling, and planning. However, these data are often highly skewed, making statistical modeling a challenging task. Mixture distribution models are capable of overcoming this challenge. In this study, a mixture distribution approach was employed to model the highly skewed patient length of stay data observed in two different intensive care units (general surgery, coronary). Four different distributions (normal, Weibull, gamma, lognormal) were used to develop mixture distribution models. The optimal number of components for the mixture distribution was determined using the Bayesian information criterion value, and distribution parameters were estimated using the expectation-maximization algorithm. The validity of the mixture distribution was evaluated using mean absolute

\*Sorumlu yazar (Corresponding Author): Selin SARAÇ GÜLERYÜZ, [selin.sarac@toros.edu.tr](mailto:selin.sarac@toros.edu.tr)

percentage error and R-squared value, demonstrating its ability to represent real datasets with high accuracy.

**Keywords:** Length of stay, Performance metrics, Mixture distribution, Prediction, Intensive care unit

## 1. GİRİŞ

Kalış süresi, hastanın hastaneye ilk yatışından taburculuk tarihine kadar geçen süre olarak tanımlanır [1]. Hasta kalış süresi, bakım hizmetlerinin kalitesini, hastane performansını ve hastane kaynak tüketimini değerlendirmek için temel göstergelerden biri olarak kabul edilir [2-6]. Hastanenin yatak kapasitesi, ekipman, personel ve zaman gibi kısıtlamalarını yönetmek için hasta kalış süresinin doğru bir şekilde belirlenmesi gerekir. Sadece hastane yönetimi değil, hasta ve sigorta şirketleri de bu öngörüyle bütçelerini yönetmek için kullanılabilir [7].

Yoğun bakım üniteleri (YBÜ), kritik durumdaki hastalara yoğun ve özel tıbbi bakım sağlar [8]. Son on yılda, yoğun bakım ünitesine olan ihtiyaç artmıştır [9]. Hastane bütçesinin yaklaşık %15 - %20'si yoğun bakım hastalarına aittir [10]. Bu nedenle yoğun bakım ünitelerinden en verimli şekilde yararlanılmalıdır. Hasta kalış süresi için iyi bir tahmin, yatak kapasitesi, ekipman, personel ve zaman gibi ciddi şekilde sınırlı kaynakların daha iyi operasyonel planlaması anlamına gelir [6]. Ayrıca, hasta kalış süresi tahmini hastaların bekleme sürelerini azaltmaya yardımcı olur. Sonuç olarak, yoğun bakım ünitesindeki hasta kalış sürelerini önceden tahmin etmek hastane yönetimi, sigorta şirketleri ve hasta ailesi için son derece faydalıdır. Hasta kalış süresi genellikle çeşitli faktörlere bağlı olan oldukça çarpık veriler olması nedeniyle modellemeyi zorlaştırır [11]. Esneklikleri sayesinde, çarpık dağılımlar ve rastgele olaylar, karma dağılımlar ile modellenabilir [12]. Ancak, sınırlı sayıda çalışma, yoğun bakım ünitesinde hasta kalış süresini tahmin etmek için karma dağılım modeli kullanmıştır. Karma dağılımlar bileşenleri kısa, orta veya uzun vadeli hasta kalış süresini tanımlayabilir, böylece hastane yönetimi yatarak tedavi üzerindeki baskıyı takip edebilir [13]. Yoğun bakım ünitesinde uzun süreli kalış süresi, iyi geliştirilmiş bir hasta kalış süresi tahmin modelinin

yardımıyla belirlenebilir. Böylece, tahmin modeli klinik karar vermeyi geliştirmeye yardımcı olabilir. Bu çalışmada, her bir yoğun bakım ünitesi için hasta kalış süresini tahmin eden karma dağılım modeli oluşturmayı amaçlamaktadır. Bu amaçla dört farklı sürekli karma dağılım (normal, Weibull, gamma, lognormal) ele alınmıştır ve sonuçlar karşılaştırılmıştır.

Son on yılda sağlık verilerinin tahmini ve modellenmesi için çeşitli yöntemler kullanılmıştır. Bazı çalışmalar, makine öğrenimi yöntemlerine dayalı olarak hasta sayısı veya hastaların kalış süresini tahmin etmeye çalışmıştır [6,9,14-16]. Ancak karma dağılım modelleri, çarpık dağılımlardan oluşan verilerin modellenmesinde de oldukça etkili olduğu görülmüştür [17]. Karma dağılım modelleri, sadece ekonomi ve pazarlamada değil, aynı zamanda sağlık alanında; anatomi, biyoinformatik, hücre biyolojisi, kronik hastalıklar, genetik, geriatri, enfeksiyon hastalıkları, görüntü işleme, ortopedi, farmakoloji, beslenme, kadın hastalıkları, psikiyatri gibi bilim dallarının yanı sıra hastanede iş gücü ve sigorta bütçesinin planlanmasında da kullanılmıştır [18-21]. Hasta kalış süresi verileri bazı çalışmalarda normal, negatif binom, üstel, Weibull, Poisson ve lognormal karma dağılımlarına uyarlanmıştır [23-29].

## 2. YÖNTEM

Bu çalışmada, Adana'da bir araştırma hastanesinin bilgi sistemi veri tabanından toplanan bir yıllık kabul ve taburcu süresi verileri kullanılarak iki farklı yoğun bakım ünitesinin gün cinsinden hasta kalış süresini hesaplanmıştır. Planlama açısından, günlük tahmin modeli, saatlik tahminlerden daha faydalıdır [6]. Bu nedenle, bu çalışmada günlük tahmin modelleri benimsenmiştir. Tüm işlemler, 64 bit Windows 10 işletim sistemine sahip dizüstü bilgisayarda, RStudio (sürüm 4.1.2) kullanılarak hesaplanmıştır.

Karma oranı  $(\pi_1, \pi_2, \dots, \pi_k)$ , bileşen sayısı  $(k)$  ve dağılım parametreleri  $f_1(x; \theta_1), f_2(x; \theta_2), \dots, f_k(x; \theta_k)$  olmak üzere üç komponent ile tanımlanır.

$$f(x) = \pi_1 f_1(x; \theta_1) + \pi_2 f_2(x; \theta_2) + \dots + \pi_k f_k(x; \theta_k) \quad (1)$$

$$0 \leq \pi_i \leq 1 \quad i=1, 2, \dots, k \quad (2)$$

$$\sum_{i=1}^k \pi_i = 1 \quad (3)$$

Karma dağılımların genel bir gösteriminde parametreler için  $\psi$  sembolünü kullanılabilir. Karma dağılımlar için genelleştirilmiş gösterim Eşitlik 4'te verilmiştir.

$$f(x, \psi) = \sum_{i=1}^k \pi_i f(x; \theta_i) \quad (4)$$

Karma dağılım il veri modellemenin ilk zorluğu,  $k$  ile ifade edilen optimal bileşen sayısını belirlemektir. Optimal  $k$  sayısını bulmanın ana hedefi, verileri iyi ayrılmış kümelere bölmektir. Başka bir deyişle, heterojen veri setini, homojen parçalara ayırmaktır [31]. Akaike Bilgi Kriterleri (AIC) ve Bayesian Bilgi Kriterleri, modelin doğruluğu optimal bileşen sayısını olan  $k$  değerini belirlemen için yaygın olarak kullanılmaktadır [28,32].

AIC,  $2k - 2\ln L(\psi)$ , BIC ise  $-\ln(n)k - 2\ln L(\psi)$  formülüyle hesaplanır [33,34]. Her iki formülde de  $L(\psi)$  karma dağılım modelinin olabilirlik tahminindeki değer ve  $k$  aday bileşen sayısını gösterir. BIC, AIC'den farklı olarak gözlem sayısı olan  $n$  değerini de hesaba katar ve daha tutarlı bir model seçimi yapabilir. Her iki yöntemde de en küçük değer en uygun modeli temsil etmektedir.

En uygun karma dağılım türü ve optimal bileşen sayısı bulunduğundan sonra karma dağılım parametreleri tahmin edilmelidir. Maksimum olabilirlik veya Beklenti Maksimizasyonu (EM) yöntemi, olasılığı maksimize eden veri seti parametrelerini bulmaya çalışan ve Dempster tarafından 1977 yılında önerilen bir algoritmadır.  $n$  gözlem tarafından oluşturulan  $k$  bileşenli bir karma dağılım modelinin tüm değerlerinde  $L(\psi)$ 'yi maksimize eden  $\theta(x_1, \dots, x_n)$  değerine  $\theta$ 'nin maksimum olabilirlik tahmini denir [35].

Tüm karma dağılım modelleri, farklı doğruluk dereceleriyle hasta kalış süresini tahmin edebilir. Önemli olan en yüksek doğrulukla hasta kalış süresini modelleyebilmektedir. Ortalama mutlak yüzde hatası (MAPE), tahmin performansını değerlendirmek için kullanılır [36]. MAPE, gerçek ( $y_i$ ) ve tahmin edilen değerler ( $\hat{y}_i$ ) arasındaki yüzde hatayı temsil eder ve  $100/n \sum_{i=1}^n |y_i - \hat{y}_i| / y_i$  formülüyle hesaplanır. MAPE değerinin düşük olması, daha doğru bir tahmine işaret eder. MAPE'nin %10 değerinin altında olması, oldukça doğru bir tahmin sonucu olarak kabul edilir [37]. R-kare ( $R^2$ ), gerçek ve tahmin edilen değerler arasındaki ilişkinin benzerliği ve gücü ile değerlendirilir [38].  $R^2$ , 0-1 arası değer alır ve 1'e ne kadar yakınsa model uyumu o kadar yüksektir.  $y_i$  gerçek,  $\hat{y}_i$  tahmin edilen ve  $\bar{y}$  hesaplanan gerçek ortalama değer olmak üzere;  $1 - \sum (y_i - \hat{y}_i)^2 / (y_i - \bar{y})^2$  formülüyle hesaplanır.

### 3. ARAŞTIRMA BULGULARI

Çalışmamızda bir Araştırma Hastanesi'nin genel cerrahi (GC) ve koroner (K) yoğun bakım üniteleri (YBÜ) olmak üzere iki farklı birim ele alınmıştır ve bir yıl boyunca kaydedilen geliş ve bu birimlerden çıkış zamanları kullanılmıştır. Veri içeriğinde hasta gizliliğinin sağlanması amacıyla kişisel bilgiler bulunmamaktadır. Çıkış ve giriş zamanları arasındaki fark alınarak ilgili birimde her bir hastanın kalış süresi hesaplanarak yeni bir veri seti oluşturulmuş ve bu veri seti çalışmada analiz edilmiştir.

Çizelge 1'de gözlem sayısı ( $n$ ), ortalama değer ( $\mu$ ), medyan, standart sapma ( $\sigma$ ) çarpıklık ve basıklık değerleri hesaplanmıştır ve genel cerrahi ve koroner yoğun bakım ünitelerinde hasta kalış süresinin betimleyici istatistikleri olarak Çizelge 1'de özetlenmiştir.

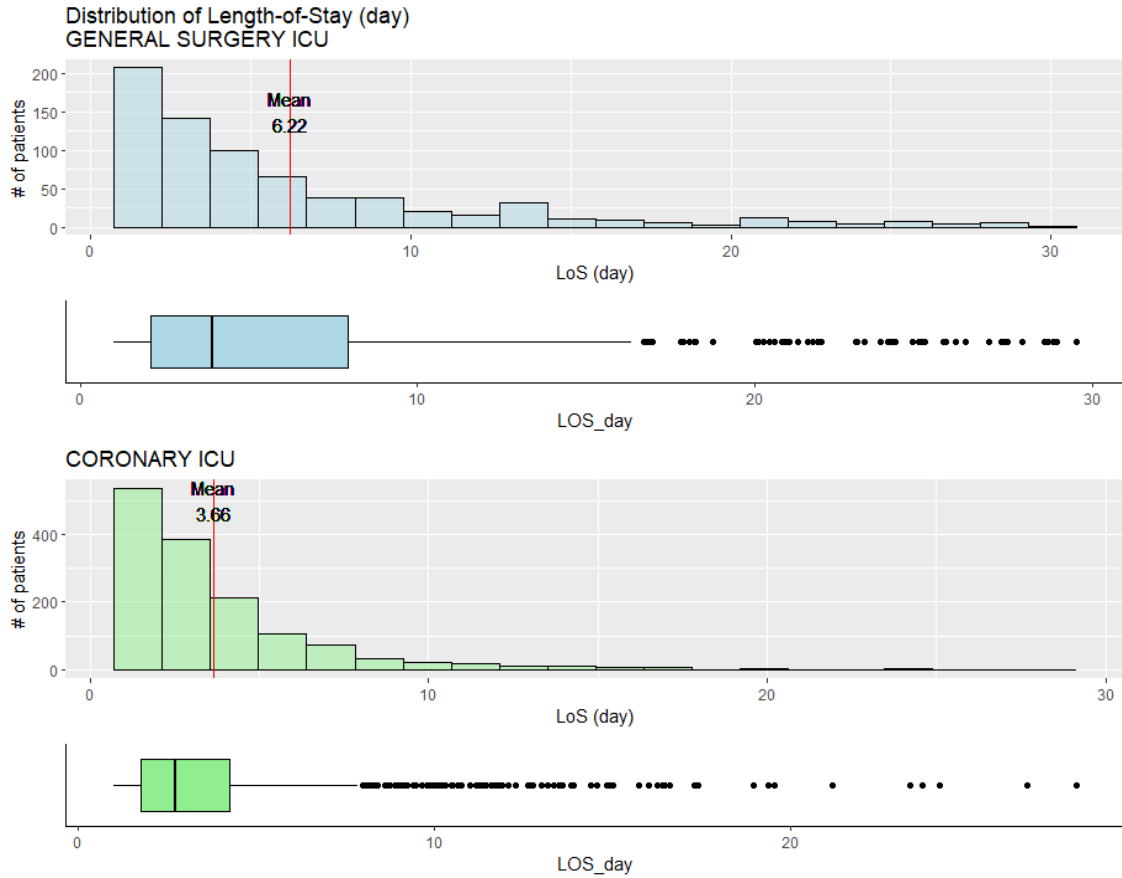
Genel Cerrahi YBÜ'de toplam 730, Koroner YBÜ'de ise 1421 hasta kaydedilmiştir. GC YBÜ'de hastaların ortalama kalış süresi 6.2 gün iken K YBÜ'de bu süre 3.6 gündür. Her iki YBÜ'de de standart sapma değerleri ortalama değerlere oldukça yakındır. Ortalama ve standart sapma değerlerine göre her iki YBÜ'de de hasta kalış

sürelerinin oldukça farklılık gösterdiği yorumu yapılabilir. Çarpıklık ve basıklık değerleri bir veri setinin değişkenliğini ölçmek için kullanılan önemli karakteristiklerden birisidir. İncelenen iki YBÜ’de de çarpıklık ve basıklık değerlerine göre, verilerin oldukça asimetrik olduğu görülmektedir. Asimetrik

davranışın izlenebileceği bir diğer kıyaslama ise ortalama ve medyan değerleridir. Bu iki değer eşit olması durumunda, gözlemlerin simetrik dağılım olduğu yorumu yapılabilir. Ancak ele alınan iki YBÜ’de de bu durum söz konusu değildir ve asimetrik bir davranış beklenmektedir.

**Çizelge 1.** Betimleyici istatistikler

YBÜ	Gözlem sayısı	Ortalama	Medyan	Standart sapma	Çarpıklık	Basıklık
Genel cerrahi	730	6.22	3.9	6.05	1.8	3.05
Koroner	1421	3.66	2.7	3.12	2.8	11.8



**Şekil 1.** Kalış süresi histogram ve kutu grafikleri

Şekil 1’de, çarpıklığı vurgulamak için histogramlar ve kutu grafikleri çizilmiştir. Ortalama ve medyan değerler arasındaki farklar kutu grafiklerinde açıkça görülür ve verilerin çarpıklığını destekler. Ayrıca kutu grafiklerinde gözlemlenen uzun kuyruklar

hasta kalış süresi dağılımlarının, her iki yoğun bakım hasta kalış süreleri için sağa çarpık dağılımı doğrular. Kutu dağılımında görülen siyah noktalar aykırı değerleri temsil eder. Betimleyici istatistikler, histogramlar ve kutu grafiklerinden

elde edilen bilgiler ışığında, her iki yoğun bakım ünitesinden elde edilen kalış süresi değerlerinin asimetrik, aykırı değerler içeren ve sağa çarpık dağılıma sahip olduğunu söylenebilir.

Bu özelliklere sahip bir veri setinin bilinen herhangi bir teorik saf dağılıma uyması genellikle mümkün değildir. Ancak zaman seri modelleme, simülasyon, çizelgeleme, planlama gibi pek çok uygulamada verilerin istatistiksel olarak temsil edilmesi gerekir [39,40].

Genel cerrahi ve koroner yoğun bakım ünitelerinde hastaların kalış süresi bilinen saf dağılımlarla uygunluğu ki-kare ( $\chi^2$ ) testiyle sınanmıştır.  $H_0$  hipotezi verilerin seçilen aday saf dağılımla uyumlu olduğunu kabul eder.  $\chi^2$  testiyle hesaplanan  $p$  değeri seçilen anlamlılık düzeyinin ( $\alpha = 0.05$ ) altında ise  $H_0$  reddedilir [41].  $\chi^2$  testi; Weibull, gamma, lognormal ve normal dağılımlar için test edilmiş ve test edilen tüm aday dağılımlar için  $p$  değeri 0.00 olarak hesaplanmıştır.

Bilinen herhangi bir saf dağılıma uymayan çarpık verilerin temsilinde oldukça iyi sonuçlar verdiği literatür ile desteklenmiş karma dağılım yaklaşımı kullanılabilir [27,39].

Karma dağılım ile modellemede ilk adım bileşen sayısı  $k$  değerinin belirlenmesidir ve AIC ile BIC değerleri kullanılır. Keribin makalesinde [42], BIC'nin karma dağılımlarının model seçiminde AIC'den daha doğru bir tahmin sağladığını göstermiştir. Bu bilgiler ışığında, bu çalışmada en uygun karma dağılım modellerini seçmek için BIC değeri kullanılmıştır. Çizelge 2.'de  $k = 2,3,4,5$  değerleri için model uygunluğu dört aday karma dağılım ile değerlendirilmiş ve en küçük BIC değerine sahip kombinasyon en uygun model olarak seçilmiştir. Buna göre, hem genel cerrahi hem de koroner yoğun bakım üniteleri için en uygun karma dağılım modeli üç bileşenli lognormal karma dağılımdır.

**Çizelge 2.** BIC değerine göre en iyi model seçimi

Model	BIC (Genel cerrahi)			
	$k = 2$	$k = 3$	$k = 4$	$k = 5$
Normal	4712.11	3974.394	4124.87	4137.91
Weibull	3987.09	3941.879	3937.54	3944.28
Gamma	3941.39	3921.717	3920.50	3933.23
Lognormal	3914.89	3907.893*	3908.87	3924.80
Model	BIC (Koroner)			
	$k = 2$	$k = 3$	$k = 4$	$k = 5$
Normal	6206.80	6010.978	5891.41	5897.27
Weibull	5990.96	5939.896	5887.64	5902.89
Gamma	5892.25	5711.206	5684.03	5709.576
Lognormal	5826.12	5659.703*	5663.96	5687.55

Çizelge 3'te karma dağılımlarının uygun parametrelerinin tahminlerini gösterilmiştir. Genel cerrahi yoğun bakımda kısa süreli yatan hastalar, yılda ortalama 2.04 gün ile nüfusun %36.9'unu oluşturmaktadır. Orta süreli yatan hastalar, yılda 7.47 gün, yani bir haftadan fazla olmak üzere, nüfusun %58.5'i ile yarıdan fazlasını oluştururken, uzun süreli yatan hastalar, üç haftanın üzerinde

24.07 gün, ve kalan popülasyon olan %4.6'yı oluşturmaktadır.


Benzer şekilde koroner yoğun bakımda popülasyon sırasıyla %11.8, %46.7 ve %41.4 kısa (1.11 gün), orta (2.41 gün) ve uzun (5.74 gün) yatan hastalar olmak üzere üç bölüme ayrılmıştır. Genel cerrahi yoğun bakımdan farklı olarak, koroner yoğun bakımda hastaların kalış süresi daha kısadır.

Çizelge 3. EM algoritması kullanılarak tahmin edilen parametreler

	Model	Parametreler			
		$k$	$\pi_k$	$\mu_k$	$\sigma_k$
Genel cerrahi	Lognormal	3	0.369	2.04	0.77
			0.585	7.47	5.23
			0.046	24.07	3.03
Koroner	Lognormal	3	0.118	1.11	0.077
			0.467	2.41	0.88
			0.414	5.74	3.66

Şekil 2’de BIC yardımıyla seçilen en uygun karma dağılım modeline göre yoğunluk grafikleri çizilmiş ve veriyle kıyaslanmıştır. Yoğunluk grafiklerine

bakılarak veri setinin karma dağılım ile oldukça iyi bir uyum yakaladığı görülmektedir.

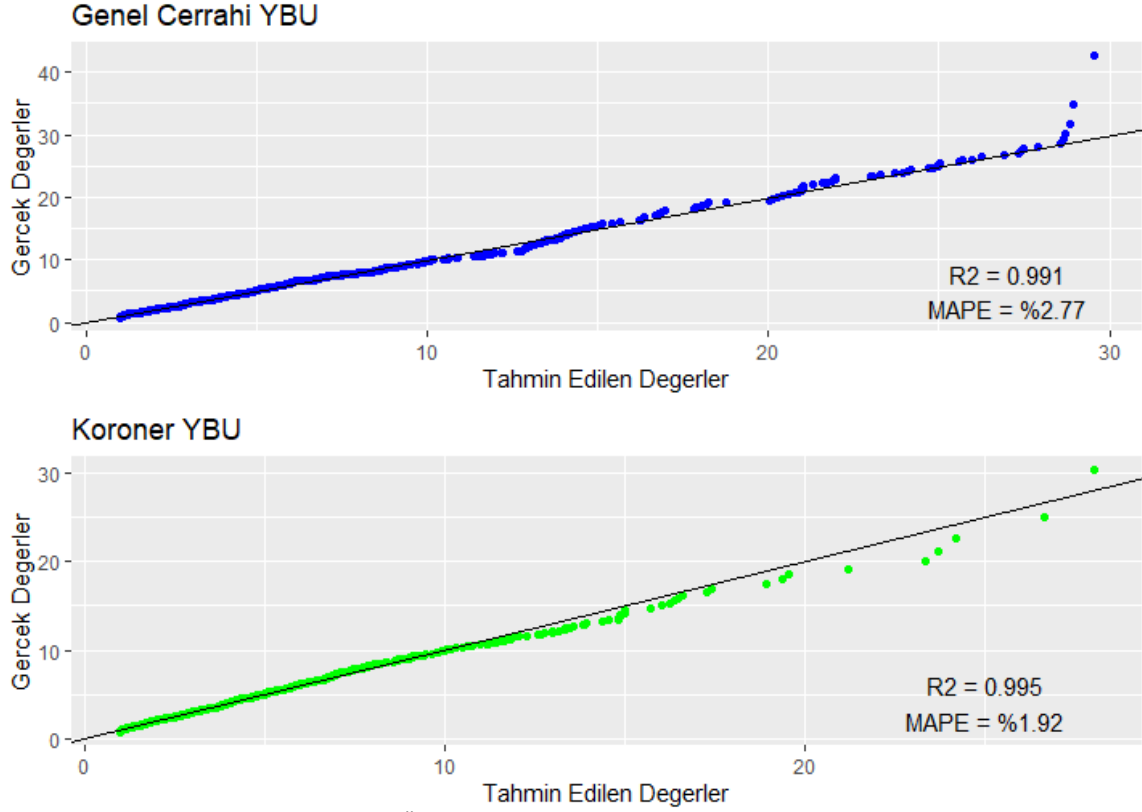


Şekil 2. Genel cerrahi ve koroner YBÜ karma dağılım yoğunluk grafikleri

Hem Genel cerrahi YBÜ’de hem de Koroner YBÜ’de kaydedilen hasta kalış süresi üç bileşenli karma dağılım ile temsil edilmiştir. Verinin karma dağılım yaklaşımıyla temsil gücünün test edilmesi için MAPE ve  $R^2$  değeri hesaplanmış ve sonuçlar Şekil 3’te paylaşılmıştır.

Açıkça görülebildiği gibi, karma dağılım modeli kullanılarak YBÜ kalış süresi modellemede yüksek doğruluk elde edilmiştir. MAPE, genel cerrahide %2.77, koronerde ise %1.92’dir ve bu da oldukça doğru tahmin olarak kabul edilir. Benzer şekilde,  $R^2$  değerlerine bakarak (genel cerrahide 0.991,

koronerde 0.995) karma dağılım ile kalış süresinin modellenmesinin yüksek güvenilirlikte olduğu söylenebilir.



Şekil 3. Genel cerrahi ve koroner YBÜ karma dağılım tahmin performansı

#### 4. SONUÇLAR

Yoğun bakım ünitesi hastanede pahalı ve sınırlı bir kaynaktır. Bir birimdeki hastaların kalış süresi yapısını anlamak, kaynak tahsisi de dahil olmak üzere planlama için oldukça önemlidir. Hastaların ünitelerdeki kalış sürelerinin doğru tahmini, hastane kaynaklarının daha iyi planlanmasına önemli ölçüde yardımcı olabilir. Ancak kalış süresi dağılımının oldukça çarpık olması istatistiksel olarak uymayı zorlaştırır.

Verilerin modellenmesinde karma dağılımının kullanılması, gerçek zamanlı verilerin daha doğru temsil edilmesine olanak tanır. Simülasyon modelinde girdi parametresi olarak karma dağılımını kullanarak hastaların kaynak tüketimini daha doğru bir şekilde takip edilebilir.

Karma dağılım modelinin temel faydası, bir birimdeki kalış süresi dönemlerini tanımlama yeteneğinde yatmaktadır. Karma dağılımının bileşenleri hastaların kalış süresi ortalamasının, standart sapmasının ve grup büyüklüğünün tanımlanmasını sağlar. Bu istatistikler daha sonra yönetim tarafından planlama için kullanılabilir. Ayrıca, karma dağılım yardımıyla, popülasyonu tek bir beklenen grup olarak ele almak yerine kısa, orta veya uzun dönemler daha doğru bir şekilde temsil edilebilir.

Bu makale iki yoğun bakım ünitesinde (genel cerrahi ve koroner) hastaların kalış süresini tahmin etmek için karma dağılım modellerini kullanmaktadır. İlk olarak bileşen sayısı BIC değeri

kullanılarak seçilmiş daha sonra bileşen parametreleri EM algoritması yardımıyla hesaplanmıştır. MAPE ve  $R^2$ , karma dağılım modellerinin tahmin gücünü ölçmek için performans kriterleri olarak kullanılmıştır.

Sonuçlardan da anlaşılacağı üzere, yüksek derecede çarpık veriler, karma dağılım modelleri kullanılarak yüksek doğrulukla modellenebilmektedir.

Bu makale, sağlık hizmetlerinde verilerin modellenmesinin ve kaynak planlamasının geliştirilmesine katkıda bulunmaktadır. Gelecekteki araştırmalarda optimal personel ve ekipmanı belirlemek için karma dağılım yaklaşımı sağlık hizmetleri verilerine uygulanabilir. Ayrıca karma dağılım modeli simülasyon modellerinde girdi parametresi olarak kullanılabilir. Karma dağılım parametreleri cinsiyet, hasta öyküsü, sosyo-ekonomik durum, yaş gibi hasta özellikleri dikkate alınarak güncellenebilir ve hesaplanabilir.

## 5. KAYNAKLAR

1. Burchardi, H., Moerer, O., 2001. Twenty-four Hour Presence of Physicians in the ICU. *Critical Care*, 5(3), 131-137.
2. Mekhaldi, R.N., Caulier, P., Chaabane, S., Chraibi, A., Piechowiak, S., 2020. Using Machine Learning Models to Predict the Length of Stay in a Hospital Setting. *Trends and Innovations in Information Systems and Technologies*, 202-211.
3. Arkin, N., Zhao, T., Wang, L., 2024. Development and Validation of a Novel Risk Classification Tool for Predicting Long Length of Stay in NICU Blood Transfusion Infants. *Scientific Reports*, 4, 6877.
4. Lequertier, V., Wang, T., Fondrevelle, J., Augusto, V., Polazzi, S., Duclos, A., 2024. Length of Stay Prediction with Standardized Hospital Data from Acute and Emergency Care using a Deep Neural Network. *Medical Care* 62(4), 225-234.
5. Vasilakis, C., Marshall, A.H., 2005. Modelling Nationwide Hospital Length of Stay: Opening the Black Box. *Journal of the Operational Research Society*, 56(7), 862-869.
6. Johnson, K., Orfanos, A., Chen, E., Cohen, E., 2024. Machine Learning to Predict Length of Stay Following Revision Hip Arthroplasty. *Journal of Hip Surgery*.
7. Abd-Elrazek, M.A., Eltahawi, A.A., Abd Elaziz, M.H., Abd-Elwhab, M.N., 2021. Predicting Length of Stay in Hospitals Intensive Care Unit using General Admission Features. *Ain Shams Engineering Journal*, 12(4), 3691-3702.
8. Bahalkeh, E., Hasan, I., Yuehwern, Y., 2022. The Relationship between Intensive Care Unit Length of Stay information and its Operational Performance. *Healthcare Analytics* (2).
9. Meyer, A., Zverinski, D., Pfahringer, B., Kempfert, J., Kuehne, T., Sündermann, S., Eickhoff, C., 2018. Machine Learning for Real-Time Prediction of Complications in Critical Care: A Retrospective Study. *Lancet Respiratory Medicine*, 6(12), 905-914.
10. Marlene Gyldmark, C., 1995. A Review of Cost Studies of Intensive Care Units: Problems with the Cost Concept. *Critical Care Medicine*, 23(5), 964-972.
11. Shea, S., Sideli, R.V., Dumouchel, W., Pulver, G., Arons, R.R., Clayton, P.D., 1995. Computer-Generated Informational Messages Directed to Physicians: Effect on Length of Hospital Stay. *Journal of the American Medical Informatics Association*, 2(1), 58-64.
12. Quarmalah, N.M., Einbeck, J., Coolen, F.P., 2017. Mixture Models for Prediction Form Time Series with Application to Energy Use Data. *Archives of Data Science. Series A*, 2(1), 1-15.
13. Xiao, J., Lee, A., Vemuri, S., 1999. Mixture Distribution Analysis of Length of Hospital Stay for Efficient Funding. *Socio-Economic Planning Sciences*, 33(1), 39-59.
14. Wu, J., Lin, Y., Li, P., Hu, Y., Zhang, L., Kong, G., 2021. Predicting Prolonged Length of ICU Stay through Machine Learning. *Diagnostics*, 11(12), 2242.
15. Maharlou, H., Niakan Kalthori, S., Shahbazi, S., Ravangard, R., 2018. Predicting Length of Stay in Intensive Care Units after Cardiac Surgery: Comparison of Artificial Neural Networks and



- Adaptive Neuro-fuzzy System. *Healthcare Informatics Research*, 24(2), 109-117.
16. Çiftçi, S., Batur Sir, G.D., 2023. Acil Servise Başvuru Sayısının Zaman Serisi Analiz ve Makine Öğrenmesi Yöntemleri ile Tahmin Edilmesine Yönelik Bir Uygulama. *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, 29(7), 667-679.
  17. Papi, M., Pontecorvi, L., 2015. Hospital Resource Consumption Modelling. *Research in Business and Management*, 1(1), 105-122.
  18. Frühwirth-Schnatter, S., 2011. Markov Chain Monte Carlo Estimation of Classical and Dynamic Switching and Mixture Models. *Journal of the American Statistical Association*, 96(453), 194-204.
  19. Ng, S.K., Xiang, L., Yau, K.K., 2019. *Mixture Modelling for Medical and Health Sciences*. CRC Press, Boca Raton, 314.
  20. Millard, P., 1988. *Geriatric Medicine: A New Method of Measuring Bed Usage a Theory for Planning*. Yüksek Lisans Tezi. Londra Üniversitesi.
  21. Lee, A., Xiao, J., Codde, J., Ng, A., 2002. Public Versus Private Hospital Maternity Length of Stay: A Gamma Mixture Modelling Approach. *Health Services Management Research*, 15(1), 46-54.
  22. Deb, P., Trivedi, P., 1998. Demand for Medical Care by the Elderly: A Finite Mixture Approach. *Journal of Applied Econometrics*, 12(3), 313-336.
  23. Cleary, P.G., 1991. Variations in Length of Stay and Outcomes for Six Medical and Surgical Conditions in Massachusetts and California. *JAMA*, 266(1), 73-79.
  24. McClean, S., Millard, P., 1993. Patterns of Length of Stay after Admission in Geriatric Medicine: An Event History Approach. *Statistician*, 42(3), 263-274.
  25. Quantin, C., Entezam, F., Brunet-Lecomte, P., Lepage, E., Guy, H., Duserre, L., 1999. High Cost Factors for Leukaemia and Lymphoma Patients: A New Analysis of Costs within these Diagnosis Related Groups. *Journal of Epidemiology and Community Health*, 53(1), 24-31.
  26. Wang, K., Yau, K., Lee, A., 2002. A Hierarchical Poisson Mixture Regression Model to Analyse Maternity Length of Hospital Stay. *Statistics in Medicine*, 21(23), 3639-3654.
  27. Atienza, N., Garcia-Heras, J., Munoz-Pichardo, J., Villa, R., 2008. An Application of Mixture Distributions in Modelization of Length of Hospital Stay. *Statistics in Medicine*, 27(9), 1403-1420.
  28. Garg, L., McClean, S., Meenan, B., El-Darzi, E., Millard, P., 2009. Clustering Patient Length of Stay using Mixtures of Gaussian Models and Phase Type Distributions. *22<sup>nd</sup> IEEE International Symposium on Computer-Based Medical Systems*, 1-7.
  29. Singh, C., Ladusingh, L., 2010. Inpatient Length of Stay: A Finite Mixture Modeling Analysis. *The European Journal of Health Economics*, 11(2), 119-126.
  30. Titterton, D., Smith, A., Makov, U., 1985. *Statistical Analysis of Finite Mixture Distributions*. Wiley, New York, 243.
  31. Fraley, C., Raftery, A.E., 1998. How Many Clusters? Which Clustering Method?-Answers via Model-Based Cluster Analysis. *The Computer Journal*, 41(8), 578-588.
  32. Sin, C.Y., White, H., 1996. Information Criteria for Selecting Possibly Misspecified Parametric Models. *Journal of Econometrics*, 71(1-2), 207-225.
  33. Akaike, H., 1974. A New Look at the Statistical Model Identification. *IEEE Transactions on Automatic Control*, 19(6), 716-723.
  34. Schwarz, G., 1978. Estimating the Dimension of a Model. *Annals of Statistics*, 6(2), 461-464.
  35. Dempster, A., Laird, N., Rubin, D., 1977. Maximum Likelihood from Incomplete Data via the EM Algorithm (with Discussion). *Journal of the Royal Statistical Society Series B (Methodological)* 39(1), 1-38.
  36. McLachlan, G., Peel, D., 2000. *Finite Mixture Models*. John Wiley & Sons, Inc, New York, 464.
  37. Lewis, C.D., 1982. *Industrial and Business Forecasting Methods*. Butterworths, Londra, 40.

38. Steel, R.G, Torrie, J.H., 1960. Principles and Procedures of Statistics with Special Reference to the Biological Sciences. McGraw Hill, New York, 481.
39. Nas, S., Koyuncu, M., 2019. Emergency Department Capacity Planning: A Recurrent Neural Network and Simulation Approach. Computational and Mathematical Methods in Medicine.
40. Antmen, F.Z., Oğulata, S.N., 2013. The Capacity Planning of Intensive Care Units via Simulation: A Case Study in University Hospital. International Journal of Applied Mathematics and Statistics, 51(21), 214-235.
41. Snedecor, G.W., Cochran, W.G., 1991. Statistical Methods, 8<sup>th</sup> Edition. Iowa State University Press, Ames, 524.
42. Keribin, C., 2000. Consistent Estimation of the Order of Mixture Models. The Indian Journal of Statistics, Series A, 62(1), 49-66.