



ISSN:1306-3111

e-Journal of New World Sciences Academy
2011, Volume: 6, Number: 4, Article Number: 3A0043

PHYSICAL SCIENCES

Received: August 2011
Accepted: October 2011
Series : 3A
ISSN : 1308-7304
© 2010 www.newwsa.com

Hayrinisa Demirci Biçer
Cemal Atakan
Çenker Biçer
Ankara University
hdbicer@hotmail.com
Ankara-Turkey

**İKİ PARAMETRELİ WEİBULL DAĞILIMINA SAHİP KİTLELERDE DİSKRİMİNANT
ANALİZİ**

ÖZET

Weibull dağılımı, bir çok alanda istatistiksel sonuç çıkarımı yapmak için kullanılan çarpık bir dağılımdır. Bu çalışmada, tek değişkenli iki parametrelili Weibull dağılımına sahip kitlelerde sınıflandırma problemi, kitle parametrelerinin bilinip bilinmemesi durumları göz önüne alınarak incelenmiştir. Hata oranları önerilen sınıflandırma kuralları kullanılarak yeniden yerine koyma (resubstitution) tahmin edicisi ile elde edilmiştir.

Anahtar Kelimeler: Weibull Dağılımı, Sınıflandırma Kuralı,
Diskriminant Analizi, Hata Oranı,
Yeniden Yerine Koyma Tahmin Edicisi

**DISCRIMINANT ANALYSIS IN TWO PARAMETER WEIBULL DISTRIBUTION
POPULATIONS**

ABSTRACT

Weibull distribution is skewed distribution which is used to make statistical inferences in many areas. In this study, the classification problem in univariate two parameter Weibull populations is investigated which population parameters are considered known and unknown situation. Error rates are obtained by using the proposed classification rules with the resubstitution estimator.

Keywords: Weibull Distribution, Classification Rule,
Discriminant Analysis, Error Rate,
Resubstitution Estimator

1. GİRİŞ (INTRODUCTION)

Diskriminant analizi, araştırmacının bir birim üzerinde ölçümler yaptığında, bu ölçümlere bağlı olarak birimi bilinen gruplardan (kitlelerden) birine atanmasını gerçekleştiren istatistiksel bir yöntemdir. Bu çalışmada, işlem kolaylığı için grup sayısı iki olarak alınmıştır.

Π_1, Π_2 iki farklı kitle ve $\underline{X}=(X_1, X_2, \dots, X_p)'$ bireyler üzerinde ölçümlere karşılık gelen p boyutlu rasgele vektör olsun. \underline{X}, Π_j ($j=1,2$)'den bir rasgele vektör ise \underline{X} 'in olasılık yoğunluk fonksiyonu $f_j(\underline{x}; \underline{\theta}_j)$ dir. Burada $\underline{\theta}_j$ parametre vektörüdür.

\underline{X} rasgele vektörünün aldığı değerler, p boyutlu R^p örneklem uzayında olmak üzere sınıflandırma problemi, bu uzayı B_1 ve B_2 bölgelerine ayırmaktadır; öyle ki, \underline{X}_0 gözlem vektörü B_j de ise \underline{X}_0 'a ait \underline{x}_0 birimi Π_j 'ye atanır. Burada $B_1 \cup B_2 = R^p$ ve $B_1 \cap B_2 = \emptyset$ dir.

q_1 ve q_2 bir birimin sırasıyla Π_1 ve Π_2 kitlelerine ait olması olasılıkları (prior olasılıkları) ve Π_j 'ye ait bir birimin Π_i 'denmiş gibi hatalı atanmasının maliyeti, $c_{ij} = C(\underline{x}_0$ 'ın Π_i 'ye atanması | $\underline{x}_0 \in \Pi_j)$ olsun ($i=1,2, j=1,2, i \neq j$). Bu çalışmada hatalı sınıflandırma maliyetleri eşit alınarak ihmal edilmiştir ve prior olasılıkları q_1 ve q_2 'nin de eşit olduğu varsayılacaktır.

Atama işlemi yapılırken, gözlem ait olduğu gerçek gruptan farklı bir gruba atanabilir. Bu durumda hatalı atama yapılmış olur. Yani gözlem gerçekte Π_j 'ye aittir ancak Π_i 'ye atanmış olabilir. Belirlenen B_1 ve B_2 bölgeleri için,

$$P(\underline{x}_0 \text{'in } \Pi_i \text{'ye atanması} | \underline{x}_0 \in \Pi_j) = \int_{R_i} f_j(\underline{x}, \underline{\theta}_j) d\underline{x} = p_{ij} \quad (1.1)$$

olasılığını, \underline{x}_0 ölçümlü birimin Π_j 'ye ait olduğu bilindiğinde Π_i 'denmiş gibi hatalı atanmasının koşullu olasılığıdır. Bu durumda \underline{x}_0 gözleminin Π_i 'ye hatalı atanması olasılığı,

$$P(\underline{x}_0 \text{'in } \Pi_i \text{'ye hatalı atanması}) = q_j p_{ij} \quad (1.2)$$

dir. Böylece iki grup olduğunda herhangi bir atama kuralı için hatalı sınıflandırmanın beklenen maliyeti (ECM)

$$ECM = \sum_{\substack{i=1 \\ i \neq j}}^2 q_j c_{ij} p_{ij}, \quad (j=1,2) \quad (1.3)$$

biçiminde tanımlanır. Diskriminant analizinde atama kurallarından biri, öyle B_1 ve B_2 bölgeleri seçilmelidir ki ECM minimum olsun.

Diğer bir atama kuralı, ECM kuralında hatalı sınıflandırma maliyetlerinin ihmal edilmesiyle elde edilen ve en iyi sınıflandırma kuralı olan toplam hatalı sınıflandırma olasılığının (TPM) minimizasyonu kuralıdır. Bu kural

$$P(TPM) = \sum_{i=1}^2 q_j p_{ij} \quad (1.4)$$

biçimindedir [1 ve 2].

$\underline{\theta}_1$ ve $\underline{\theta}_2$ bilindiğinde, ξ optimal sınıflandırma kuralı

$$\xi: \begin{cases} U = \frac{f(\underline{x}_0; \underline{\theta}_1)}{f(\underline{x}_0; \underline{\theta}_2)} > k & \text{ise } \underline{x}_0 \text{ } \Pi_1 \text{'e atanır} \\ \text{diğer durumda} & \text{ise } \underline{x}_0 \text{ } \Pi_2 \text{'ye atanır} \end{cases} \quad (1.5)$$

ile verilir ve $k = \frac{q_2 c_{1|2}}{q_1 c_{2|1}}$ dir [3 ve 4].

$\underline{\theta}_1$ ve $\underline{\theta}_2$ parametreleri bilinmediğinde, Π_1 ve Π_2 kitlelerinden alınan n_1 ve n_2 hacimli rasgele örneklemeler yardımıyla $\hat{\underline{\theta}}_1$ ve $\hat{\underline{\theta}}_2$ tahminleri elde edilir. Böylece örneklemelerden elde edilen tahminlere bağlı $\hat{\xi}$ optimal sınıflandırma kuralı

$$\hat{\xi}: \begin{cases} W = \frac{f(\underline{x}_0; \hat{\underline{\theta}}_1)}{f(\underline{x}_0; \hat{\underline{\theta}}_2)} > k & \text{ise } \underline{x}_0 \text{ } \Pi_1 \text{'e atanır} \\ \text{diğer durumda} & \text{ise } \underline{x}_0 \text{ } \Pi_2 \text{'ye atanır} \end{cases} \quad (1.6)$$

ile verilir [3 ve 5].

2. ÇALIŞMANIN ÖNEMİ (RESEARCH SIGNIFICANCE)

Literatürde genelde tek ve çok değişkenli normal dağılımlı kitlelerde sınıflandırma problemi ve hata oranları ayrıntılı olarak verilmektedir. Örneklemelerin alındığı kitlelerin dağılımları her zaman normal olamayacağından, normal dağılıma sahip olmayan kitleler arasında da sınıflandırma problemi ele alınmalıdır. Bu nedenle, Weibull dağılımına sahip kitleler arasındaki sınıflandırma problemi ele alınarak, farklı örneklem büyüklükleri ve farklı parametre değerleri için yeniden yerine koyma tahmin edicisi ile hata oranları elde edilmiştir.

3. DENEYSSEL YÖNTEM (EXPERIMENTAL METHOD)

3.1. Diskriminant Analizinde Hata Oranları (Error Rates in Discriminant Analysis)

Diskriminant kurallarına ilişkin optimal hata oranı, koşullu gerçek hata oranı, beklenen gerçek hata oranı gibi farklı hata oranları tanımlanmıştır. Parametrelerin bilindiği durumda (1.5)'deki ξ kuralı kullanıldığında Π_i 'den bir birimin hatalı atanması olasılığı $\alpha_i(\xi)$, ($i=1,2$) olarak gösterilsin.

$$\alpha_1(\xi) = P(U \leq k | \underline{X} \in \Pi_1) \quad (3.1)$$

ve

$$\alpha_2(\xi) = P(U > k | \underline{X} \in \Pi_2) \quad (3.2)$$

olmak üzere bu iki hata oranı optimal hata oranları olarak isimlendirilmektedir.

Π_1 ve Π_2 kitleleri gelişigüzel seçildiğinden, sadece $\alpha_1(\xi)$ 'nin düşünülmesi yeterlidir. $\alpha_2(\xi)$ değeri $\alpha_1(\xi)$ 'ye benzer biçimde elde edilebilir. Böylece, bilinmeyen bir \underline{X}_0 gözleminin Π_1 'den geldiği bilindiğinde, Π_2 'ye hatalı sınıflandırılması olasılığı α 'nın indisi göz önüne alınmayıp,

$$\alpha(\xi) = P(U \leq k) \quad (3.3)$$

ile verilir.

Koşullu gerçek hata oranı (1.6)'daki $\hat{\xi}$ kuralı kullanıldığında Π_1 'den rasgele bir gözlemin hatalı atanması olasılığı olan,

$$\alpha(\hat{\xi}) = P(W \leq k) \quad (3.4)$$

değeridir. Bu hata oranı örneklemelerden elde edilen parametre tahminleri üzerine koşullandırılmıştır. $\alpha(\hat{\xi})$ koşullu gerçek hata oranına kısaca koşullu hata oranı da denmektedir.

Beklenen gerçek hata oranı olarak tanımlanan hata oranı, (3.4)'deki koşullu gerçek hata oranının tüm örneklemeler üzerinden, $E(\alpha(\hat{\xi})) = E(P(W \leq k))$ (3.5)

beklenen değeridir. $E(\alpha(\hat{\xi}))$ beklenen gerçek hata oranına koşulsuz hata oranı da denmektedir [2, 3, 5, 6, 7 ve 8].

Parametreler bilinmediğinde, örneklemelerden elde edilen tahminler kullanılarak oluşturulan örneklem diskriminant fonksiyonunun dağılımından yararlanarak hata oranları bulunabilir. Ancak örneklem diskriminant fonksiyonunun dağılımını elde etmek her zaman kolay değildir. Bu nedenle örneklem diskriminant fonksiyonunun dağılımı bilinmediğinde ya da analitik olarak elde edilemediğinde hata oranları için birçok tahmin edici söz konusudur.

Bu çalışmada, parametrik olmayan ve Smith (1947) tarafından önerilen yeniden yerine koyma (resubstitution) tahmin edicisi veya görünüşte (apparent) hata oranı olarak isimlendirilen R tahmin edicisi ile hata oranı tahmin edilecektir ve $\hat{\alpha}^R$ ile gösterilecektir. $\hat{\alpha}^R$ tahmin edicisi, Π_1 'den n_1 gözlem ve Π_2 'den n_2 gözlem alınarak oluşturulan diskriminant fonksiyonu kullanılarak n_1+n_2 gözlemin tekrar sınıflandırılmasıyla, Π_1 'den Π_2 'ye atananların sayısının n_1 'e ve Π_2 'den Π_1 'e atananların sayısının n_2 'ye oranlanması ile elde edilir [5 ve 9].

4. WEIBULL DAĞILIMINA SAHİP KİTLELERDE DİSKRİMİNANT ANALİZİ (DISCRIMINANT ANALYSIS IN WEIBULL POPULATIONS)

Π_1 ve Π_2 , μ_1 ve μ_2 ($\mu_1 < \mu_2$) konum parametrelili iki tek değişkenli kitle olmak üzere x_0 ölçümlü birim için R_N kuralı,

$$R_N: \begin{cases} x_0 < \frac{1}{2}(\mu_1 + \mu_2) & \text{ise } x_0 \text{ } \Pi_1\text{'e atanır} \\ \text{diğer durumda} & \text{ise } x_0 \text{ } \Pi_2\text{'ye atanır} \end{cases} \quad (4.1)$$

ile verilir. Parametrelerin bilinmediği durumda ise Π_1 ve Π_2 'den alınan n_1 ve n_2 hacimli örneklemelerden elde edilen örneklem atama kuralı $R_N(s)$,

$$R_N(s): \begin{cases} \bar{x}_1 < \bar{x}_2 \text{ ve } x_0 < \frac{1}{2}(\bar{x}_1 + \bar{x}_2) & \text{ise } x_0 \text{ } \Pi_1\text{'e atanır} \\ \bar{x}_1 < \bar{x}_2 \text{ ve } x_0 \geq \frac{1}{2}(\bar{x}_1 + \bar{x}_2) & \text{ise } x_0 \text{ } \Pi_2\text{'ye atanır} \end{cases} \quad (4.2)$$

ya da

$$R_N(s): \begin{cases} \bar{x}_1 \geq \bar{x}_2 \text{ ve } x_0 \geq \frac{1}{2}(\bar{x}_1 + \bar{x}_2) & \text{ise } x_0 \text{ } \Pi_1\text{'e atanır} \\ \bar{x}_1 \geq \bar{x}_2 \text{ ve } x_0 < \frac{1}{2}(\bar{x}_1 + \bar{x}_2) & \text{ise } x_0 \text{ } \Pi_2\text{'ye atanır} \end{cases} \quad (4.3)$$

dir. R_N kuralı Fisher'in Diskriminant Fonksiyonu ile elde edilir [2 ve 10]. Π_1 ve Π_2 sırasıyla μ_1 ve μ_2 ortalamalı normal kitleler olduğunda R_N optimal kuraldır. Kitleler normal olmadığında R_N optimal bir kural olmayabilir. Bu çalışmada, Weibull kitleleri için optimal bir kural elde edilmeye çalışılmıştır.

4.1. Parametreler Bilindiğinde Weibull Kitleleri için Diskriminasyon (Discrimination in Weibull Populations with Known Parameters)

Π_1 ve Π_2 sırasıyla ortalamaları $\Gamma(1+1/\beta_1)/\theta_1$ ve $\Gamma(1+1/\beta_2)/\theta_2$ olan ve

$$f_{WE}(x; \beta_i, \theta_i) = \beta_i \theta_i x^{\beta_i - 1} e^{-\theta_i x^{\beta_i}}, \quad i=1,2 \quad (4.4)$$

olasılık yoğunluk fonksiyonlarına sahip Weibull dağılımlı iki kitle olmak üzere, bu iki yoğunluk fonksiyonunun oranı

$$\frac{f(x; \theta_1, \beta_1)}{f(x; \theta_2, \beta_2)} = \frac{\beta_1 \theta_1 x^{\beta_1 - 1} e^{-\theta_1 x^{\beta_1}}}{\beta_2 \theta_2 x^{\beta_2 - 1} e^{-\theta_2 x^{\beta_2}}} \quad (4.5)$$

olarak elde edilir. Elde edilen bu ifade, parametrelerin bilindiği durum için diskriminant fonksiyondur. Böylece sınıflandırma kuralı,

$$R_{WE} : \begin{cases} x_0^{\beta_1 - \beta_2} e^{-[\theta_1 x_0^{\beta_1} - \theta_2 x_0^{\beta_2}]} > \frac{\beta_2 \theta_2 q_2 c_{1/2}}{\beta_1 \theta_1 q_1 c_{2/1}} & \text{ise } \underline{x}_0 \text{ } \Pi_1 \text{'e atanır} \\ \text{diğer durumda} & \text{ise } \underline{x}_0 \text{ } \Pi_2 \text{'ye atanır} \end{cases} \quad (4.6)$$

olarak elde edilir. İki kitle için önsel olasılıkların ve hatalı sınıflandırma maliyetlerinin eşit olduğu varsayıldığında ($q_1 = q_2 = 1/2$ ve $c_{1/2} = c_{2/1}$) R_{WE} optimal kuralı,

$$R_{WE} : \begin{cases} x_0^{\beta_1 - \beta_2} e^{-[\theta_1 x_0^{\beta_1} - \theta_2 x_0^{\beta_2}]} > \frac{\beta_2 \theta_2}{\beta_1 \theta_1} & \text{ise } \underline{x}_0 \text{ } \Pi_1 \text{'e atanır} \\ \text{diğer durumda} & \text{ise } \underline{x}_0 \text{ } \Pi_2 \text{'ye atanır} \end{cases} \quad (4.7)$$

ile verilir.

Sınıflandırma kuralı, β_1 , β_2 , θ_1 ve θ_2 parametrelerinin farklı durumlarına göre aşağıdaki biçimlerde elde edilir.

Durum 1 (Case 1): $\beta_1 = \beta_2 = \beta$ ve $\theta_2 > \theta_1$ ise R_{WE} sınıflandırma kuralı,

$$R_{WE} : \begin{cases} x_0 > c_1 & \text{ise } \underline{x}_0 \text{ } \Pi_1 \text{'e atanır} \\ \text{diğer durumda} & \text{ise } \underline{x}_0 \text{ } \Pi_2 \text{'ye atanır} \end{cases} \quad (4.8)$$

olarak elde edilir ve burada $c_1 = \left[\frac{\log \theta_2 - \log \theta_1}{\theta_2 - \theta_1} \right]^{1/\beta}$ dir.

R_{WE} kuralı kullanıldığında toplam hatalı sınıflandırma olasılığı

$$P(TPM | R_{WE}) = \frac{1}{2} [1 - \exp(-\theta_1 c_1^\beta) + \exp(-\theta_2 c_1^\beta)] \quad (4.9)$$

dir. R_{WE} deki WE harfi Weibull dağılımını göstermektedir.

Durum 2 (Case 2): $\theta_1 = \theta_2 = \theta$ ise R_{WE} sınıflandırma kuralı,

$$R_{WE} : \begin{cases} (\beta_1 - \beta_2) \log x_0 - \theta (x_0^{\beta_1} - x_0^{\beta_2}) > c_2 & \text{ise } \underline{x}_0 \text{ } \Pi_1 \text{'e atanır} \\ \text{diğer durumda} & \text{ise } \underline{x}_0 \text{ } \Pi_2 \text{'ye atanır} \end{cases} \quad (4.10)$$

olarak elde edilir ve burada $c_2 = (\log \beta_2 - \log \beta_1)$ dir.

R_{WE} kuralı kullanıldığında toplam hatalı sınıflandırma olasılığının hesaplanabilmesi için $(\beta_1 - \beta_2) \ln X - \theta (X^{\beta_1} - X^{\beta_2})$ rasgele değişkeninin dağılımının elde edilmesi gerekmektedir.

Durum 3 (Case 3): $\beta_1 = \beta_2 = 1$ ve $\theta_1 < \theta_2$ ise Weibull dağılımları, konum parametreleri θ_1 ve θ_2 olan üstel dağılımlara dönüşürler. Bu

durumda θ_1 ve θ_2 parametrelili üstel dağılıma sahip Π_1 ve Π_2 kitleleri için R_E optimal sınıflandırma kuralı

$$R_E : \begin{cases} x_0 > \left[\frac{(\log \theta_2 - \log \theta_1)}{\theta_2 - \theta_1} \right] & \text{ise } \underline{x}_0 \text{ } \Pi_1 \text{'e atanır} \\ \text{diğer durumda} & \text{ise } \underline{x}_0 \text{ } \Pi_2 \text{'ye atanır} \end{cases} \quad (4.11)$$

olarak elde edilir. R_E deki E harfi üstel dağılımı göstermektedir. Üstel dağılımlı kitlelerde diskriminasyon problemini Adegboye (1993) ayrıntılı olarak çalışmıştır.

4.2. Parametreler Bilinmediğinde Weibull Kitleleri için Diskriminasyon (Discrimination in Weibull Populations with Unknown Parameters)

Parametreler bilinmediğinde Π_1 ve Π_2 kitlelerinden alınan n_1 ve n_2 hacimli $X_{11}, X_{12}, \dots, X_{1n_1}$ ve $X_{21}, X_{22}, \dots, X_{2n_2}$ bağımsız rasgele örneklemeler yardımıyla bilinmeyen parametreler tahmin edilebilir. Parametrelerin bilindiği durumda elde edilen diskriminant kurallarında, bilinmeyen parametreler yerine, örneklemelerden elde edilen tahminlerinin direkt olarak kullanılmasıyla (plug-in), örneklemelere bağlı diskriminant kuralları elde edilmiş olur. Böylece örneklemelere bağlı $R_{WE}(s)$ sınıflandırma kuralı

$$R_{WE}(s) : \begin{cases} x_0^{\hat{\beta}_1 - \hat{\beta}_2} e^{-[\hat{\theta}_1 x_0^{\hat{\beta}_1} - \hat{\theta}_2 x_0^{\hat{\beta}_2}]} > \frac{\hat{\beta}_2 \hat{\theta}_2}{\hat{\beta}_1 \hat{\theta}_1} & \text{ise } \underline{x}_0 \text{ } \Pi_1 \text{'e atanır} \\ \text{diğer durumda} & \text{ise } \underline{x}_0 \text{ } \Pi_2 \text{'ye atanır} \end{cases} \quad (4.12)$$

ile verilir. Burada $\hat{\beta}_1$, $\hat{\beta}_2$, $\hat{\theta}_1$ ve $\hat{\theta}_2$ parametrelerin örneklemelerden elde edilen en çok olabilirlik tahminleridir.

Parametreler bilinmediğinde, sırasıyla şekil parametrelerinin eşit ($\beta_1 = \beta_2 = \beta$) olduğu ve ölçek parametrelerinin eşit ($\theta_1 = \theta_2 = \theta$) olduğu durumlar gözönüne alınarak aşağıdaki biçimlerde örneklemelere bağlı diskriminant kuralları elde edilir.

Durum 4 (Case 4): $R_{WE}(s)$ örneklemelere bağlı sınıflandırma kuralı

$$R_{WE}(s) : \begin{cases} \bar{x}_1 < \bar{x}_2 \text{ ve } \underline{x}_0 < c'_1 & \text{ise } \underline{x}_0 \text{ } \Pi_1 \text{'e atanır} \\ \bar{x}_1 < \bar{x}_2 \text{ ve } \underline{x}_0 \geq c'_1 & \text{ise } \underline{x}_0 \text{ } \Pi_2 \text{'ye atanır} \end{cases} \quad (4.13)$$

veya

$$R_{WE}(s) : \begin{cases} \bar{x}_1 \geq \bar{x}_2 \text{ ve } \underline{x}_0 \geq c'_1 & \text{ise } \underline{x}_0 \text{ } \Pi_1 \text{'e atanır} \\ \bar{x}_1 \geq \bar{x}_2 \text{ ve } \underline{x}_0 < c'_1 & \text{ise } \underline{x}_0 \text{ } \Pi_2 \text{'ye atanır} \end{cases} \quad (4.14)$$

olarak elde edilir ve burada $c'_1 = \left[\frac{\log \hat{\theta}_2 - \log \hat{\theta}_1}{\hat{\theta}_2 - \hat{\theta}_1} \right]^{1/\hat{\beta}}$ ve $\hat{\beta} = (\hat{\beta}_1 + \hat{\beta}_2)/2$ dir.

Durum 5 (Case 5): $R_{WE}(s)$ sınıflandırma kuralı,

$$R_{WE}(s) : \begin{cases} \bar{x}_1 < \bar{x}_2 \text{ ve } \underline{x}_0 < c'_2 & \text{ise } \underline{x}_0 \text{ } \Pi_1 \text{'e atanır} \\ \bar{x}_1 < \bar{x}_2 \text{ ve } \underline{x}_0 \geq c'_2 & \text{ise } \underline{x}_0 \text{ } \Pi_2 \text{'ye atanır} \end{cases} \quad (4.15)$$

veya

$$R_{WE}(s) : \begin{cases} \bar{x}_1 \geq \bar{x}_2 \text{ ve } \underline{x}_0 \geq c'_2 & \text{ise } \underline{x}_0 \text{ } \Pi_1 \text{'e atanır} \\ \bar{x}_1 \geq \bar{x}_2 \text{ ve } \underline{x}_0 < c'_2 & \text{ise } \underline{x}_0 \text{ } \Pi_2 \text{'ye atanır} \end{cases} \quad (4.16)$$

olarak elde edilir ve burada $c'_2 = (\log \hat{\beta}_2 - \log \hat{\beta}_1)$ ve $\hat{\theta} = (\hat{\theta}_1 + \hat{\theta}_2)/2$ dir.


5. SİMÜLASYON ÇALIŞMASI (SIMULATION STUDY)

Tek değişkenli Weibull dağılımına sahip kitlelerde, farklı örneklem büyüklükleri ($n_1 = n_2 = n$) için β_1 , β_2 , θ_1 ve θ_2 parametrelerinin farklı değerleri ve sınıflandırma kurallarına göre hata oranları 1000 tekrar ile elde edilmiştir ve sonuçlar Tablo 1 ve Tablo 2' de verilmiştir.

Tablo 1. Durum 1 ve Durum 4
(Table 1. Case 1 and Case 4)

θ_1	θ_2	β	α	$n = 20$ $\hat{\alpha}^R$	$n = 40$ $\hat{\alpha}^R$	$n = 60$ $\hat{\alpha}^R$	$n = 100$ $\hat{\alpha}^R$
0.5	1	3.6	0.3750	0.3722	0.3740	0.3745	0.3749
0.5	2	3.6	0.2637	0.2616	0.2591	0.2625	0.2613
0.5	4	3.6	0.1749	0.1724	0.1735	0.1751	0.1747
0.5	6	3.6	0.1343	0.1331	0.1329	0.1319	0.1334
0.5	8	3.6	0.1104	0.1094	0.1088	0.1087	0.1106
0.5	10	3.6	0.0943	0.0936	0.0940	0.0944	0.0941
0.5	20	3.6	0.0565	0.0565	0.0565	0.0567	0.0564
2	4	3.6	0.3750	0.3751	0.3741	0.3760	0.3749
2	6	3.6	0.3075	0.3138	0.3098	0.3076	0.3078
2	8	3.6	0.2638	0.2654	0.2688	0.2646	0.2638
2	10	3.6	0.2325	0.2361	0.2362	0.2335	0.2322
2	20	3.6	0.1516	0.1540	0.1534	0.1506	0.1521
4	10	3.6	0.3371	0.3383	0.3378	0.3375	0.3372
4	20	3.6	0.2325	0.2350	0.2373	0.2343	0.2335
4	40	3.6	0.1516	0.1564	0.1525	0.1518	0.1524

Tablo 1'den, θ_1 ve θ_2 parametreleri arasındaki fark arttıkça iki kitlenin birbirinden uzaklaştığı ve hata oranlarının da azaldığı gözlenmektedir. Bu sonucu Şekil 1'de desteklemektedir. θ_1 , θ_2 'nin belli bir katı olduğunda (4.9) eşitliği ile elde edilen optimal hata oranı α 'nın aynı olduğu görülmektedir. Örneğin, $\theta_1 = 0.5$ ve $\theta_2 = 1$ ile $\theta_1 = 2$ ve $\theta_2 = 4$ olarak seçildiğinde optimal hata oranı $\alpha = 0.3750$ olarak elde edilmektedir. Örneklem büyüklüğü n arttıkça, yeniden yerine koyma tahmin edicisi ile elde edilen hata oranı $\hat{\alpha}^R$ 'nin optimal hata oranı α 'ya yaklaştığı görülmektedir.

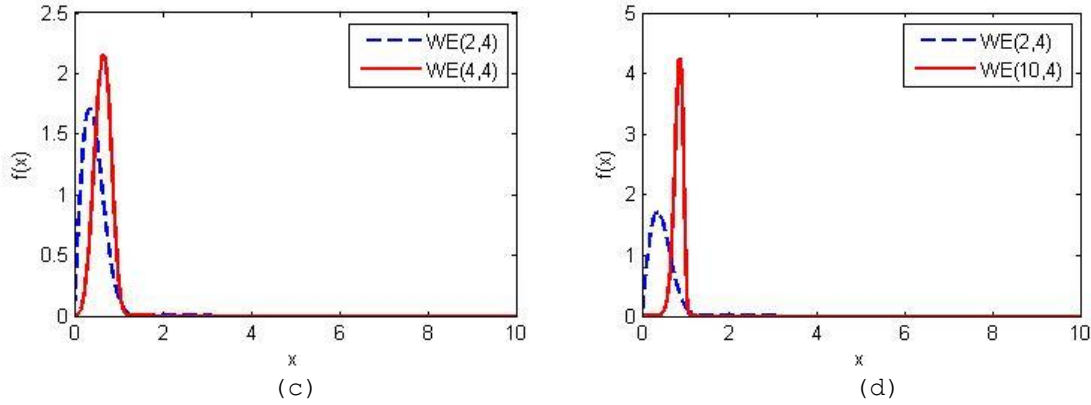


Şekil 1. (a) $WE(3.6,0.5)$ ve $WE(3.6,2)$ ile (b) $WE(3.6,0.5)$ ve $WE(3.6,20)$ dağılımlarının olasılık yoğunluk fonksiyonları
(Figure 1. The probability density functions of Weibull distributions with different parameter values (a) $WE(3.6,0.5)$ and $WE(3.6,2)$ with (b) $WE(3.6,0.5)$ and $WE(3.6,20)$)

Tablo 2. Durum 5
(Table 2. Case 5)

β_1	β_2	θ	$n = 20$ $\hat{\alpha}^R$	$n = 40$ $\hat{\alpha}^R$	$n = 60$ $\hat{\alpha}^R$	$n = 100$ $\hat{\alpha}^R$
4	2	4	0.2901	0.2903	0.2896	0.2899
6	2	4	0.1971	0.1963	0.1971	0.1982
8	2	4	0.1415	0.1418	0.1417	0.1419
10	2	4	0.1095	0.1111	0.1117	0.1120
20	2	4	0.0478	0.0482	0.0484	0.0488
8	4	4	0.2917	0.2914	0.2910	0.2903
10	4	4	0.2350	0.2355	0.2354	0.2350
20	4	4	0.1105	0.1115	0.1114	0.1115
12	6	4	0.2900	0.2907	0.2897	0.2899
20	6	4	0.1727	0.1735	0.1737	0.1743
16	8	4	0.2909	0.2908	0.2912	0.2910
24	8	4	0.1923	0.1923	0.1921	0.1926

Tablo 2'den, β_1 ve β_2 parametreleri arasındaki fark arttıkça hata oranının azaldığı gözlenmektedir. Bu azalma Şekil 2'de de görülmektedir. Burada da, β_1 , β_2 'nin belli bir katı olduğunda $\hat{\alpha}^R$ hata oranından optimal hata oranının aynı olacağı söylenebilir. Örneğin, $\beta_1=4$ ve $\beta_2=2$, $\beta_1=12$ ve $\beta_2=6$ ile $\beta_1=16$ ve $\beta_2=8$ olarak seçildiğinde $\hat{\alpha}^R$ yaklaşık olarak 0.29 olarak elde edilmektedir.



Şekil 2. (c) $WE(2,4)$ ve $WE(4,4)$ ile (d) $WE(2,4)$ ve $WE(10,4)$ dağılımlarının olasılık yoğunluk fonksiyonları
(Figure 2. The probability density function of Weibull distributions with different parameter values (c) $WE(2,4)$ and $WE(4,4)$ with (d) $WE(2,4)$ and $WE(10,4)$)

6. SONUÇ (CONCLUSION)

Bu çalışmada, tek değişkenli Weibull dağılımına sahip kitleler için kitle parametrelerinin bilinip bilinmemesi durumları göz önüne alınarak diskriminasyon problemi ele alınmıştır.

Simülasyon çalışmaları sonucunda, her iki kitlenin şekil parametresinin birbirine eşit olduğu durumda ($\beta_1 = \beta_2 = \beta$), kitlelerin ölçek parametreleri θ_1 ve θ_2 değerlerinin birbirine yaklaştıkça $R_{WE}(\cdot)$ optimal sınıflandırma kuralından elde edilen hata oranlarının daha büyük olduğu Tablo 1'den gözlenmektedir. İki kitlenin ölçek parametreleri arasındaki fark arttığında ise, $R_{WE}(\cdot)$ sınıflandırma kuralı ile elde edilen hata oranlarının daha küçük olduğu gözlenmiştir.

Her iki kitlenin ölçek parametresinin birbirine eşit olduğu durumda ($\theta_1 = \theta_2 = \theta$) ise, parametrelerin bilindiği durum için $R_{WE}(\cdot)$ optimal sınıflandırma kuralında elde edilen rasgele değişkenin dağılımı analitik olarak elde edilemediğinden optimal hata oranı hesaplanamamıştır. Ancak yeniden yerine koyma tahmin edicisi $\hat{\alpha}^R$ ile hata oranları Tablo 2' de verildiği gibi elde edilmiştir.

Her iki durumda parametrelerin farklı değerlerinin tümü için iki kitle birbirine yakın olduğunda Şekil 1 (a) ve Şekil 2 (c) de olduğu gibi hata oranının diğer durumlara göre daha büyük olduğu gözlenmektedir. Şekil 1 (b) ve Şekil 2 (d) deki gibi iki kitle birbirinden uzaklaştıkça hata oranının azaldığı gözlenmektedir.

KAYNAKLAR (REFERENCES)

1. Lachenburch, P.A., (1975), Discriminant Analysis, Hafner: New York.
2. Seber, G.A.F., (1984), Multivariate Observations, John Wiley & Sons. Inc.
3. Anderson, T.W., (1984), Introduction to Multivariate Statistical Analysis, 2nd. Ed. Wiley: New York.
4. Welch, B.L., (1939), Note on Discriminant Functions, Biometrika, 31, 218-220.



5. Atakan, C. and Öztürk, F., (1997), The Optimal Classification Rule for Gamma Populations, Jour. of Inst. of Math&Comp. Sci., 10, 2, 131-140.
6. Hills, M., (1966), Allocation Rules and Their Error Rates, J. Roy. Stat. Soc. B, 28, 1-31.
7. Lachenburch, P.A. and Mickey, R., (1968), Estimation of Error Rates in Discriminant Analysis, Technometrics, 10, 1-11.
8. Snapin, S.M., (1983), An Evaluation of Smooted Error Rate Estimators in Discriminant Analysis, Institute of Statistics Miemeo Series, 1438.
9. Smith, C.A.B., (1978), Some Examples of Discrimination, Annals of Eugenics, 18, 272-282.
10. Fisher, R.A., (1936), The use of the multiple measurements in taxonomic problems, Annals of Eugenics, 7, 179-188.
11. Adegboye, O.S., (1993). The Optimal Classification Rule for Exponential Populations. Austral. J. Statist., Volume:35, pp.185-194.