

̄'in μ ve β_1 'in $\hat{\beta}_1$ İÇİN EN İYİ MİNİMUM VARYANSLI
SAPMASIZ TAHMİNLEYİCİ (EMVST) OLMA DURUMU
ÜZERİNE BİR TARTIŞMA

H.OKUT¹

O.KARACA²

(DERLEME)

ÖZET

İki veya daha fazla değişken arasındaki matematiksel ifadeye regresyon denklemi denir. $\hat{Y}_i = \hat{\beta}_0 + \hat{\beta}_1 \hat{x}_i$ regresyon denkleminde, \hat{Y}_i , $\hat{\beta}_0$ ve $\hat{\beta}_1$ sırasıyla Y_i , β_0 ve β_1 'in tahminleyicileridir. Bu nedenle $\hat{Y}_i = \hat{\beta}_0 + \hat{\beta}_1 \hat{x}_i$ hatasızdır. Eğer parametre vektörüne $\theta(\beta_1, \beta_2, \dots, \beta_n)$ dersek, bunun tahminleyicisi de $\theta(\hat{\beta}_1, \hat{\beta}_2, \dots, \hat{\beta}_n)$ 'dir. Aynı şekilde örnek ortalaması \bar{x} olursa, temsil edeceği populasyonun ortalaması μ olur. İyi bir tahminleyici sapmasız, kararlı, yeterli ve etkin olmalıdır. En iyi tahminleyici belirlemeye bir çok metod geliştirilmiştir. Bunların içinde yaygın olarak en küçük kareler metodu ile en yüksek olasılık metodları kullanılmaktadır. Bu makalede \bar{x} 'in, μ için ve $\hat{\beta}_1$ 'in β_1 için en iyi minimum varyanslı sapmasız tahminleyicisi (EMVST) olduklarına dair metod ve teoremlerden bazıları tanıtılmıştır.

A DISCUSSION ON THE UNBIASED ESTIMATOR WITH THE BEST
MINIMUM VARIANCE OF \bar{x} FOR μ AND $\hat{\beta}_1$ FOR β_1

SUMMARY

1-Yüz.Yıl Üniv. Ziraat Fak. Zootekni Bölümü, Araş.Gör.

2-Yüz.Yıl Üniv. Ziraat Fak. Zootekni Bölümü, Yard.Doç.Dr.

A mathematical statement which determines the relation among two or more than two variables is called a regression equation. In the regression equation $\hat{y}_i = \hat{\beta}_0 + \hat{\beta}_1 x_1$, \hat{y}_i , $\hat{\beta}_0$ and $\hat{\beta}_1$ denote the estimators of y_i , β_0 and β_1 respectively. Therefore the equation $\hat{y}_i = \hat{\beta}_0 + \hat{\beta}_1 x_1$ is a statistic and it has no error. If we denote the parameter vector by $\theta(\beta_1, \beta_2, \dots, \beta_n)$ then its estimator is given as $\hat{\theta}(\hat{\beta}_1, \hat{\beta}_2, \dots, \hat{\beta}_n)$. Similarly, if the sample means is \bar{x} , the means of population represented by them would be μ . A good estimator must be unbiased, consistent, sufficient and efficient. The best estimator has developed different kinds of methods. Among them, least square and maximum likelihood methods are used commonly. In this paper, some methods and theorems that proves the best minimum variance unbiased estimator of \bar{x} for μ and $\hat{\beta}_1$ for β_1 are represented.

GİRİŞ

Basit olarak iki veya daha fazla değişken arasındaki ilişkinin matematik kurallara göre açıklanmasına "Regresyon Denklemi" denir (1). Bu ilişkiler doğrusal (Linear) ve doğrusal olmayan (Non-Linear) karaktere sahip olabilirler. Değişkenlerden bir tanesi bir veya daha fazla değişkenin fonksiyonu şeklinde olur. Bu fonksiyonel ilişkinin modeli parametrik katsayılarla ifade edilmiş ise bu katsayıların hatasız olduğunu kabul ediyoruz (1). Yani $\hat{y}_i = \hat{\beta}_0 + \hat{\beta}_1 x_i$ şeklinde yazılan bir modelde değişkenler arasında linear ve hatasız bir ilişki vardır ve x ile y değerleri (noktaları) aynı doğru üzerinde dizilirler. Ancak bu yazılan model matematiksel bir denklemdir. İstatistikte bir denklem yazılıncaya değişkenler arasındaki stokastik ilişki dikkate alındığı için modele hata teriminde ilave edilmesi gereklidir.

$$y_i = \beta_0 + \beta_1 x_i + E_i, \quad y_i = \beta_0 + \beta_1 x_1 + \dots + \beta_n x_n + E_i \quad \text{veya} \quad y_i = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots +$$

$\beta_n x_n + \beta_{11} x_1^2 + \dots + \beta_{nn} x_n^2 + \beta_{12} x_1 x_2 + \dots + E_i$ şeklinde yazılabilen regresyon modellerini hata (E_i) terimi ilave edildiği takdirde, populasyonu temsil eden bu denklemlerin oluşmasında, değişkenler arasında stokastik ilişkilerde dikkate alındığını ifade eder.

Eğer modelde yer alan parametreleri populasyon düzeyinde belirleme imkanına sahip değilsek (hemen hemen bu durum olanaksız) bunların değerini istatistik olarak tahmin ederiz. Eğer parametreye vektörüne $\theta(\beta_1, \beta_2, \dots, \beta_n)$ dersek, bunun tahminleyicisi de $\hat{\theta}(\hat{\beta}_1, \hat{\beta}_2, \dots, \hat{\beta}_n)$ olur. θ 'nın $\hat{\theta}$ için iyi bir tahminleyici olabilirliği için (2, 3, 4, 5, 6, 7, 8):

a- Sapmasız (Unbiased) olmalı. Yani: θ 'nın tahminleyicisi olan $\hat{\theta}$ 'nın beklenen değeri sıfır olmalı $E(\theta)=0$

b- Kararlı (Consistent) olmalı. Her bir $E_i > 0$ durumunda $\hat{\theta}$ 'nın θ için kararlı bir tahminleyici olabilmesi için,

$$\lim_{n \rightarrow \infty} P(|\hat{\theta} - \theta| \geq E) = 0 \text{ olması gereklidir.}$$

c- Yeterlilik (Sufficiency) söz konusu olmalı. Eğer $\hat{\theta}$ şeklinde tanımlayacağımız gözlemlere ait bir fonksiyon bulunuyorsa ve $\hat{\theta}$ ifadesi örnekte, θ parametresine ait bütün bilgileri içeriyorsa bu durumda $\hat{\theta}$, θ için yeterlilik durumunu sağlar.

$$\frac{\partial \ln L}{\partial \theta}$$

$=$ yalnız θ için $\hat{\theta}$ 'nın bir fonksiyonudur.
 $\frac{\partial}{\partial \theta}$

d- Etkinlik (Efficiency). Tahminlemenin asıl amacı yüksek bir ihtimal ile θ tahminlemek olduğuna göre sapmasız minimum varyanslı tahminleri seçmek gereklidir. Eğer bağımsız değişkenlerin birlikte yoğunluk fonksiyonu $f(x_1)f(x_2)\dots f(x_n)$ olursa

ve $\frac{\partial \ln C}{\partial \theta} = \lambda(\theta)(\hat{\theta} - \theta)$ ise etkin bir tahminleyici vardır. Burada

C birleşik yoğunluk, $\lambda(\theta), \theta$ 'nin yaklaşık fonksiyonu ve $\hat{\theta}$ x 'in fonksiyonudur. Bu durumda minimum varyanslı sapmasız tahminleyici varyansı $1/\lambda(\theta)$ olur (3, 9, 10, 11).

Yukarıda ifade edilen en gerçekçi tahminleyici bulmada, hali hazırda birkaç metod kullanılmaktadır. Bunlardan en yaygın olanları:

- 1- Maksimum olasılık metodu,
- 2- En küçük kareler metodu,
- 3- Momentler metodu,
- 4- Bayesian metodudur (3, 6, 9).

Bu makalede \bar{X} 'in μ ve $\hat{\beta}_1$ 'in β_1 için en iyi doğrusal (linear) sapmasız tahminleyici olma durumu esas alınarak, bu iki tahminleyicinin, parametreleri için en iyi minimum varyanslı sapmasız tahminleyici (EMVST) olma durumu tartışılacaktır.

3- \bar{X} 'in μ İçin En İyi Minimum Varyanslı Sapmasız Tahminleyici (EMVST) Olması

θ 'nın populasyon parametreler vektörü $(\theta_1, \dots, \theta_n)$ ve θ 'nında bu parametrelerin en iyi (Best) sapmasız min.-varyanslı tahminleyicileri $(\hat{\theta}_1, \dots, \hat{\theta}_n)$ olduğunu düşünürsek, bunun gerçekleşmesi için;

$$v(\theta) \geq \frac{(\theta)^2}{nE\left[\frac{\partial}{\partial \theta} \ln f(x_i, \theta)\right]^2} \Rightarrow v(\theta) \geq \frac{1}{nE\left[\frac{\partial}{\partial \theta} \ln f(x_i, \theta)\right]^2}$$

eşitsizliğini kullanmak gereklidir (11). Cramer-Rao eşitsizliği denilen bu formül normal populasyondan çekilmiş n birey içeren bir örneğe ait dağılışının fonksiyonunu tanımlamaktadır. Ancak bu eşitsizliğin geçerli olabilmesi için şu varsayımlar yapılmaktadır (9).

x_1, \dots, x_n şans örneği, $f(x_i, \theta)$ dağılışından çekilmiş olsun. $\hat{\theta}_1, \hat{\theta}_2, \dots, \hat{\theta}_n$ θ 'nin tahminleyicileri olursa;

$$\text{i- } \frac{\partial}{\partial \theta} \int \dots \int_{i=1}^n f(x_i, \theta) dx_1 \dots dx_n \text{ olur.}$$

$$\text{ii- } \frac{\partial}{\partial \theta} \ln f(x_i, \theta) \text{ türevi mevcuttur.}$$

$$\text{iii- } \frac{\int \dots \int \hat{\theta}_1 \hat{\theta}_2 \dots \hat{\theta}_n \frac{\partial}{\partial \theta} \prod f(x_i, \theta) dx_1 \dots dx_n}{E(\theta)}$$

$$\text{iv- } \theta E\left(\frac{\partial}{\partial \theta} \ln f(x_i, \theta)\right)^2$$

gibi varsayımlar geçerli olduğu taktirde Cramer-Rao eşitsizliği doğrudur (9, 11). Bu durumda $X \sim N(\mu, \sigma^2)$ karakterindeki bir populasyondan çekilen n bireyli örneğin ortalaması \bar{x} , bunun temsil ettiği populasyonun ortalaması μ ise, örnek ortalaması (\bar{x}), populasyon ortalamasının en iyi (best) sapmasız min.- varyansı tahminleyici olur.

$N(\mu, \sigma^2)$ gibi normal dağılıştan çekilmiş x_1, \dots, x_n şans değişkeni bulunsun. Bu durumda $\bar{x} \sim N(\mu, \frac{\sigma^2}{n})$ olan bir normal dağılış gösterir. Eğer \bar{x} , μ 'nin ESMV tahminleyicisi ise; $V(\bar{x}) = \frac{\sigma^2}{n}$ olması gereklidir.

$$f(x) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{(x-\mu)^2}{2\sigma^2}}$$

Normal dağılışın yoğunluk fonksiyonunda π ve e değerleri matematisel olarak sabit σ^2 ve N dağılışın parametreleri, x değeri ise $-\infty$ ile $+\infty$ arasında değerlere sahiptir. x'in herhangi bir k değerinde küçük olma alasılığı;

$\int_{-\infty}^k f(x) dx = \int_{-\infty}^k \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{1}{2} \left(\frac{x-\mu}{\sigma}\right)^2} dx$ olup $-\infty$ ile $+\infty$ arasındaki değerlerin oranı 1 olur (9, 12, 13).

$$\ln(f(x)) = -\frac{1}{2} - \frac{(x-\mu)^2}{2\sigma^2} \quad \ln\sigma = \ln\sqrt{2\pi}$$

$\ln\sigma = 1$ olduğundan;

$$\ln f(x) = -2\ln\sigma - \frac{1}{2} \left(\frac{x-\mu}{\sigma}\right)^2$$

$$\frac{\partial \ln f(x)}{\partial \mu} = \frac{x-\mu}{\sigma^2} \quad \text{olur.}$$

$$E \left[\left(\frac{\partial \ln f(x_i)}{\partial \mu} \right) \right] = \frac{1}{\sigma^2} E \left[\frac{(x_i - \mu)^2}{\sigma^2} \right] \Rightarrow \frac{1}{\sigma^2} \text{ olur (9).}$$

Cramer-Rao eşitsizliğinde,

$$V(\hat{\theta}) = \frac{(\theta)^2}{n E \left[\frac{\partial \ln f(x_i; \theta)}{\partial \theta} \right]} = \frac{1}{\sigma^2} \Rightarrow \frac{1}{\frac{n}{\sigma^2}} \Rightarrow \frac{\sigma^2}{n} \text{ olur.}$$

O halde \bar{x} μ 'nin ESMV tahminleyicisidir (9, 11).

$Y = \beta_0 + \beta_1 x_1 + e_i$ Doğrusal Modelde $\hat{\beta}_i$ 'nin β_1 İçin En İyi Minimum Varyanslı Sapmasız Tahminleyici (EMVST) Olma Durumu

$$E(E_i) = 0$$

$V(E) = \sigma^2$ varsayımlı geçerli ve $E \sim \mu(0, \sigma^2)$ dır (11). Aynı şekilde

$$V(Y) = \sigma^2 \quad \mu = \beta_1 x + \beta_0 \text{ olduğundan,}$$

$$\hat{\beta}_1 = \frac{(\sum w_i)(\sum w_i x_i y_i) - (\sum w_i x_i)(\sum w_i y_i)}{(\sum w_i)(\sum w_i x_i^2) - (\sum w_i x_i)^2}$$

$$\hat{\beta}_1 = \frac{\sum w_i y_i (x_i - \bar{x})}{\sum w_i (x_i - \bar{x})^2} = \frac{\sum w_i x_i y_i - (\sum w_i x_i)(\sum w_i x_i / \sum w_i)}{\sum w_i x_i^2 - (\sum w_i x_i)^2 / \sum w_i}$$

$$\text{Burada; } \bar{x} = \sum w_i x_i / \sum w_i$$

$$Y = \sum w_i y_i / \sum w_i$$

Bütün i 'ler için $V(Y_i) = \sigma^2$ dır. Basit olarak bu formül;

$$\hat{\beta}_1 = \frac{n \sum x_i y_i - (\sum x_i)(\sum y_i)}{n \sum x_i^2 - (\sum x_i)^2} = \frac{\sum i (x_i - \bar{x})}{\sum (x_i - \bar{x})^2} \text{ olur (1, 2, 5, 6, 8, 10, 14).}$$

$$(x_i - \bar{x}) = M_i \text{ dersek}$$

$$\hat{\beta}_1 = \frac{\sum M_i Y_i}{\sum M_i^2} \text{ olur ve } \frac{M_i}{\sum M_i^2} = k_i \text{ olursa } \hat{\beta}_1 = \sum k_i Y_i \text{ olur. } \hat{\beta}_i \text{ nin varyan-}$$

sını bulacak olursak;

$$V(\hat{\beta}_1) = V(k_i Y_i) = \sum k_i^2 V(Y_i)$$

Hatırlanacağı gibi $V(Y_i) = \sigma^2$ ve $Y_i \sim (\beta_0 + \beta_1 X_i; \sigma^2)$ olduğundan

$$V(\hat{\beta}_1) = \sigma^2 \sum k_i = \sigma^2 \sum \left(\frac{M_i}{\bar{M}} \right)^2 \text{ olur (9, 11). } \hat{\beta}_1 \text{'in } \beta_1 \text{ için ESMVT ola-}$$

bilmesi için $k_i^2 = \left(\frac{M_i}{\bar{M}} \right)^2$ 'nin minimum olması gereklidir. Bunu ise Gauss-Markov teoremi ile ispatlayabiliriz (11).

Ayrıca;

$$\hat{\beta}_1 = - \frac{\sum (X - \bar{X}) Y_i}{\sum (X - \bar{X})^2} = L_i Y_i \implies L_i = \frac{X - \bar{X}}{E(X - \bar{X})^2} \text{ olsun}$$

Bu durumda;

$$\hat{\beta}_1 = M_i Y_i$$

$\hat{\beta}_1 = L_i Y_i$ olur ve $E(\hat{\beta}_1) = \beta_1$ (sapmasız olduğundan)

$d = \hat{\beta}_1 - \beta_1$ diyalim. Sapmasızlık varsayımdan $E(d) = 0$ olur.

$$d = \sum M_i Y_i - \sum L_i Y_i \implies \sum (M_i - L_i) Y_i$$

$$E(d) = \sum (M_i - L_i) E(Y_i) \implies E(Y_i) = \beta_0 + \beta_1 X_i \text{ olduğunda}$$

$$E(d) = E(M_i - L_i)(\beta_0 + \beta_1 X_i)$$

$E(d) = 0$ olması için

$\sum (M_i - L_i) = 0$ olmalı.

$$\begin{aligned} \text{Cov}(\hat{\beta}_1, d) &= \text{Cov}[\sum L_i Y_i, \sum (M_i - L_i) Y_i] \\ &= \sigma^2 [\sum L_i (M_i - L_i)] = \sigma^2 \frac{1}{\sum (X - \bar{X})^2} [(X - \bar{X})(M_i - L_i)] \end{aligned}$$

$\text{Cov}(\beta_1, d) = 0$ olur.

$$\hat{\beta}_1 = \beta_1 + (\hat{\beta}_1 - \beta_1) \implies (\hat{\beta}_1 - \beta_1) = d$$

$$V(\hat{\beta}_1) = V(\beta_1) + V(d) + 2\text{Cov}(\beta_1, d)$$

$V(\hat{\beta}_1) = V(\beta_1) + V(d) \geq V(\beta_1)$ olduğundan ve Gauss-Markov teoremi gereği,

$\hat{\beta}_1$, β_1 'in ESMV tahminleyicisi olur (9, 10, 11).

Sonuç olarak ortalaması sıfır, varyansı σ^2 olan μ 'nın $\mu \sim N(0, \sigma^2)$ EMVST \bar{x} olup bunun ortalaması μ ve varyansı σ^2/n dir. Keza $V(\hat{\beta}_1) = V(\beta_1) + V(d)$ olduğunda ve $E(d)=0$ olduğunda $\hat{\beta}_1$, β_1 'in EMVST olmaktadır.

YARARLANILAN KAYNAKLAR

1. DÜZGÜNEŞ, O., KESİCİ, T., KAVUNCU, O., GÜRBÜZ, F., Araştırma ve Deneme Metodları. A.Ü.Zir.Fak.Yay.No:1021, Ders Kitabı, 295, 1987, Ankara.
2. MOSTELLER, F., TUKEY, W.J., Data Analysis And Regression. Addison-Wesley Publishing Company. 1977. California.
3. GREEN, J.R. and MARGERISON, D., Statistical Treatment Of Experimental Data. Elsevier Scientific Publishing Company. 1978, New York.
4. SOKAL, R.R. and ROHLF, J.F., Biometry. New York, 1981.
5. STEEL, G.R., TORRIE, H.J., Principles And Procedures Of Statistics. McGraw-Hill Book Company. New York, 1980.
6. METER, J. and WASSERMAN, W., Applied Linear Statistical Models Richard D. Irwin, Inc. 1974. Illinois 60430.
7. WINER, J.R., Statistical Principles In Experiments Chapman And Hill, Limited 1952, London.
9. ÖZTÜRK, A., Matematiksel İstatistik Ders Notları. 1985, İzmir.
10. DRAPPER, N.R. and SMITH, H., Applied Regression Analysis. Wiley. 1982, New York.
11. ERGEN, Ö., Uygulamalı Regresyon Ders Notları. 1989, İzmir.
12. SEZGIN, F., İstatistik Ders Notları. 1980, Erzurum.
13. DÜZGÜNEŞ, O., KESİCİ, T., GÜRBÜZ, F., İstatistik Metodları I. A.Ü.Zir.Fak.Yay:861, Ders Kitabı:229, 1983, Ankara.
14. COCHRON, G.W., COX, M.G., Experimental Design Jhon Wiley And Sons 1976, New York.