

$$Y_i = \beta_0 + \beta_1 X_i + \varepsilon_i, \quad i=1, 2, \dots, n$$

ΕΕΤ $\hat{\beta}_0, \hat{\beta}_1$

Υποθέσεις για τα σφάλματα

Ευκλή: Τα σφάλματα είναι ανεξάρτητα ανα β_0 και $\varepsilon_i \sim N(0, \sigma^2), i=1, \dots, n$
 Οι υποθέσεις έχουν κάποιες συνέπειες στην $Y \Rightarrow Y_i$ ανεξάρτητες ανα β_0
 $Y_i \sim N(\beta_0 + \beta_1 X_i, \sigma^2) \quad i=1, \dots, n$

Θεώρημα:

Α Αν οι υποθέσεις για τα σφάλματα ικανοποιούνται τότε $\frac{SSres}{\sigma^2} \sim \chi_{n-1}^2$

Απόδειξη

$$Y_i \sim N(\beta_0 + \beta_1 X_i, \sigma^2) \quad i=1, \dots, n.$$

$$\frac{Y_i - (\beta_0 + \beta_1 X_i)}{\sigma} \sim N(0, 1) \Rightarrow \frac{(Y_i - (\beta_0 + \beta_1 X_i))^2}{\sigma^2} \sim N^2(0, 1) \equiv \chi_1^2$$

$$\xrightarrow{Y_i \text{ ανεξ.}} \sum_{i=1}^n \frac{(Y_i - (\beta_0 + \beta_1 X_i))^2}{\sigma^2} \sim \chi_{\sum_{i=1}^n 1}^2 = \chi_n^2$$

$$\text{Θ.ν.δ.ο} \quad \frac{\sum_{i=1}^n (Y_i - \hat{Y}_i)^2}{\sigma^2} = \frac{\sum_{i=1}^n (Y_i - (\hat{\beta}_0 + \hat{\beta}_1 X_i))^2}{\sigma^2} \sim \chi_{n-2}^2$$

Αν οι β_0 και β_1 αντικατασταθούν με τους ΕΕΤ $\hat{\beta}_0$ και $\hat{\beta}_1$ τότε

$$\sum_{i=1}^n \frac{(Y_i - (\hat{\beta}_0 + \hat{\beta}_1 X_i))^2}{\sigma^2} \sim \chi_{n-2}^2 \quad \text{όπου οι αρχικοί } n \text{ βαθμοί ελευθερίας της}$$

χ^2 μειώνονται κατά 2 λόγω των 2 δεσμεύσεων που οι εκτιμήσεις των ΕΕΤ επιβάλλουν στο σφάλμα

$\left\{ \begin{array}{l} \text{ο τύπος του } \hat{\beta}_0 \text{ που εξαρτάται με το } Y_i \\ \text{ } \Rightarrow \hat{\beta}_1 \text{ } \Rightarrow \end{array} \right.$

Έλεγχος υποθέσεων και διαστικάτα εμπιστοσύνης για τις παραμέτρους β_0 και β_1

τ.μ. $X \rightarrow$ κατανομή $f(x|\theta)$. θ : άγνωστη παράμετρος

Πρόβλημα: Εκτίμηση (προσέγγιση) της άγνωστης θ .

- (i) Εκτίμηση σε σημείο θ
- (ii) Εκτίμηση σε διαστικά εμπιστοσύνης για το θ
- (iii) Έλεγχος υποθέσεων.

Υπόψη τ.δ. X_1, \dots, X_n

Κοινωνική κατανομή $N(\mu, \sigma^2)$

① Εκτιμητής της μ είναι \bar{X}

② Σ.Ε της μ $(\bar{X} - \frac{z_{\alpha} \sigma}{\sqrt{n}}, \bar{X} + \frac{z_{\alpha} \sigma}{\sqrt{n}})$ | σ^2 γνωστό
Αν είναι άγνωστο τότε $\sigma^2 = S^2$

③ Z-TEST για έλεγχο $H_0: \mu = \mu_0$ έναντι $H_a: \mu > \mu_0$
 $\mu < \mu_0$
 $\mu \neq \mu_0$

n ΣΣ. $Z = \frac{\bar{X} - \mu_0}{\sigma/\sqrt{n}} \sim N(0,1)$

υπό την H_0

κρίσιμη περιοχή

$$\begin{cases} Z \geq z_{\alpha} \\ Z \leq -z_{\alpha} \\ |Z| \geq z_{\alpha/2} \end{cases}$$

Τοπική απόκλιση του εκτιμητή

TEST ΟΜΟΙΟΤΗΤΑΣ / TEST κατά Wald.

Έστω τ.δ X_1, \dots, X_n από $f(x, \theta), \theta \in \Theta$

Έστω έλεγχος $H_0: \theta = \theta_0$ έναντι $H_a: \theta > \theta_0$
 $\theta < \theta_0$
 $\theta \neq \theta_0$

q) n Σ.Σ.Τ. $\Rightarrow \frac{\text{Εκτιμητής της } \theta - \theta_0}{\text{Τοπική απόκλιση του εκτιμητή}} \leftarrow$ Αν ο εκτιμητής είναι ο εμπέχει $N(0,1)$ υπό την H_0

β) Η κ.π. διαμορφώνεται από τη Σ.Σ.Τ. και την H_0, H_a .

δ) Το κρίσιμο σημείο προσδιορίζεται από $\alpha = P(A \text{ από } H_0 | H_0 \text{ αληθ})$

Έλεγχος υποθέσεων και διαστήματα εμπιστοσύνης για τους παραμέτρους β_0 και β_1

Ποια η πρακτική αξία στατιστικών tests, π.χ για την β_1 ?

① $H_0: \beta_1 = \beta_1^*$ (β_1^* γνωστό) έναντι $H_a: \beta_1 \neq \beta_1^*$

X = έσοδα διαφήμισης
 Y = έσοδα από την διαφήμιση

Το β_1 εκφράζει τη μεταβολή της Y στη μοναδιαία μεταβολή της X

② Αν $\beta_1^* = 0$, τότε η H_0 γίνεται $H_0: \beta_1 = 0$.

Αν δεν μπορού να απορρίψω την $H_0: \beta_1 = 0$, τότε \nexists πρακτική σχέση μεταξύ X και $Y \Rightarrow \nexists$ παραπομπή

Στατιστικό τεστ για έλεγχο της

$H_0: \beta_0 = \beta_0^*$ (β₀ γνωστό) έναντι $H_1: \beta_0 \neq \beta_0^*$

Ακολουθείται την τεχνική Wald.

Αξιολογώ του εκτιμητή $\hat{\beta}_0$ της β_0 για του οποίο έχουμε αρραβίσει οτι

$$\hat{\beta}_0 \sim N(\beta_0, \frac{\sum X_i^2}{n \sum (X_i - \bar{X})^2} \sigma^2) \text{ υπό την } H_0: \beta_0 = \beta_0^*$$

Άρα $\frac{\hat{\beta}_0 - \beta_0^*}{\sqrt{\frac{\sum X_i^2}{n \sum (X_i - \bar{X})^2} \sigma^2}} \sim N(0, 1)$

Η συνάρτηση αυτή θα μπορούσε να είναι στατιστική συνάρτηση του τεστ, περιέχει όμως το σ^2 που είναι άγνωστο. Άρα πρέπει το σ^2 με κάποιον τρόπο να απαλειφθεί.

Θεωρώ την σ.σ. t , $t = \frac{\hat{\beta}_0 - \beta_0^*}{\sqrt{\frac{\sum X_i^2}{n \sum (X_i - \bar{X})^2} \sigma^2}} = \frac{\hat{\beta}_0 - \beta_0^*}{\sqrt{\frac{SS_{res}}{n-2}}}$

$= \frac{\hat{\beta}_0 - \beta_0^*}{\sqrt{\frac{\sum X_i^2}{n \sum (X_i - \bar{X})^2} MS_{res}}}$ υπό την $H_0: \beta_0 = \beta_0^*$ $\sim \frac{N(0, 1)}{\sqrt{\frac{\chi_{n-2}^2}{n-2}}} \sim t_{n-2}$ (όταν η $N(0, 1)$ είναι ανεξάρτητη του $\sqrt{\frac{\chi_{n-2}^2}{n-2}}$)

Ισχύει γιατί $\hat{\beta}_0$ ανεξάρτητος του SS_{res}

Άρα η στατιστική συνάρτηση του τεστ είναι

$$t = \frac{\hat{\beta}_0 - \beta_0^*}{\sqrt{\frac{\sum X_i^2}{n \sum (X_i - \bar{X})^2} MS_{res}}}$$

με κατανομή t_{n-2} , υπό την $H_0: \beta_0 = \beta_0^*$

Άλλα $t = \frac{\hat{\beta}_0 - \beta_0^*}{\sqrt{\frac{\sum X_i^2}{n \sum (X_i - \bar{X})^2} MS_{res}}} = \frac{\hat{\beta}_0 - \beta_0^*}{\sqrt{\frac{\sum X_i^2}{n \sum (X_i - \bar{X})^2} \sigma^2}}$ γιατί $E[MS_{res}] = \sigma^2$

$= \frac{\hat{\beta}_0 - \beta_0^*}{\sqrt{Var(\hat{\beta}_0)}}$ όπου $Var(\hat{\beta}_0) = \frac{\sum X_i^2}{n \sum (X_i - \bar{X})^2} \sigma^2$

Αρα $t = \frac{\hat{\beta}_0 - \beta_0^*}{\sqrt{\text{Var}(\hat{\beta}_0)}}$ με κατανομή t_{n-2} υπό την $H_0: \beta_0 = \beta_0^*$
 όπου $\text{Var}(\hat{\beta}_0) = \frac{\sum x_i^2}{n \sum (x_i - \bar{x})^2} \text{MSres}$.

Διαφορετική κρίσιμη περιοχή

Η κ.π θα διακοπυθεί για μεγάλες τιμές της ΣΣΤ t , είτε θετικές είτε αρνητικές. Γιατί? Γιατί μεγάλες τιμές του t σημαίνει $\hat{\beta}_0$ πολύ διαφορετικό του β_0^* ή β_0 πολύ διαφορετικό του β_0^* (αφού το $\hat{\beta}_0$ είναι εκτίμηση της β_0). γεγονός που σημαίνει στην H_0 πρέπει να απορριφθεί. Αρα η κ.π έχει τη μορφή $t > c$ ή $t < -c$. Σημ. $|t| \geq c$.

Πως θα προσδιορίσω το κρίσιμο σημείο c ?

Το κ.σ πάλι υπολογίζεται από $\alpha = P(\text{Απορ } H_0 | H_0 \text{ αληθ})$

$$\alpha = P(\text{Απορ } H_0 | H_0 \text{ αληθ}) = P(|t| \geq c | H_0 \text{ αληθ}) = P(|t_{n-2}| \geq c) = P(t_{n-2} \geq c \text{ ή } t_{n-2} \leq -c) \stackrel{\text{ταυτότ.}}{=} 2P(t_{n-2} \geq c).$$

$$\Rightarrow P(t_{n-2} \geq c) = \frac{\alpha}{2} \Rightarrow c = t_{n-2, \frac{\alpha}{2}}.$$

Συγκεντρωτικά Για τον έλεγχο της $H_0: \beta_0 = \beta_0^*$ έναντι $H_1: \beta_0 \neq \beta_0^*$

η ΣΣΤ είναι $t = \frac{\hat{\beta}_0 - \beta_0^*}{\sqrt{\text{Var}(\hat{\beta}_0)}} \sim t_{n-2}$ υπό H_0 .

$$\text{Var}(\hat{\beta}_0) = \frac{\sum x_i^2}{n \sum (x_i - \bar{x})^2} \text{MSres}$$

και κ.π $|t| \geq t_{n-2, \frac{\alpha}{2}}$

Ευτελής ανάλυση (Άσκηση) Για τον έλεγχο $H_0: \beta_1 = \beta_1^*$ έναντι της $H_1: \beta_1 \neq \beta_1^*$

η ΣΣΤ είναι $t = \frac{\hat{\beta}_1 - \beta_1^*}{\sqrt{\text{Var}(\hat{\beta}_1)}}$ $\sim t_{n-1}$ υπό H_0 , $\text{Var}(\hat{\beta}_1) = \frac{1}{\sum (x_i - \bar{x})^2} \text{MSres}$

και η κ.π $|t| \geq t_{n-1, \frac{\alpha}{2}}$

Παρατήρηση:


- Ο έλεγχος έχει αζία γιατί; $H_0: \beta_1 = \beta_1^0$
- i) ελέγχει βίωθεν ότι η μεταβολή της Y είναι ίση με β_1^0 για μοναδιαία μεταβολή της X .
 - ii) Αν $\beta_1^0 = 0$ και η $H_0: \beta_1 = 0$ δεν μπορεί να απορριφθεί τότε \nexists κανένα α.β.π.

Διότιμα ελλοιστοαίμα για την β_0 :

Αντισπερτή πααίμα είναι η $t = \frac{\hat{\beta}_0 - \beta_0}{\sqrt{\hat{\text{Var}}(\hat{\beta}_0)}} \sim t_{n-2}$,

$$\hat{\text{Var}}(\hat{\beta}_0) = \frac{\sum X_i^2 \text{MSres.}}{n \sum (X_i - \bar{X})^2}$$

Αυτοο η t είναι αντισπερτή με κανοαίν η t_{n-2} , $\exists q_1, q_2$ ($q_1 \leq q_2$) κη $1 - \alpha = P(q_1 \leq t \leq q_2)$



$$= P\left(q_1 \leq \frac{\hat{\beta}_0 - \beta_0}{\sqrt{\hat{\text{Var}}(\hat{\beta}_0)}} \leq q_2 \right)$$

$$= P\left(\left\{ \hat{\beta}_0 - q_2 \sqrt{\hat{\text{Var}}(\hat{\beta}_0)} \leq \beta_0 \leq \left\{ \hat{\beta}_0 - q_1 \sqrt{\hat{\text{Var}}(\hat{\beta}_0)} \right\} \right\} \right)$$

Αρα ένα 100(1- α)% δ.ε για την β_0 είναι

$$\left(\hat{\beta}_0 - q_2 \sqrt{\hat{\text{Var}}(\hat{\beta}_0)}, \hat{\beta}_0 - q_1 \sqrt{\hat{\text{Var}}(\hat{\beta}_0)} \right)$$

Το δ.ε ελαίσουμκος για την β_0 προαίτηει για $q_1 = -t_{n-2, \frac{\alpha}{2}}$, $q_2 = t_{n-2, \frac{\alpha}{2}}$

Συμπερααακά: Το ΔΕ ελαίσουμκος για την β_0 με β.ε 100(1- α)% είναι

$$\left(\hat{\beta}_0 - t_{n-2, \frac{\alpha}{2}} \sqrt{\hat{\text{Var}}(\hat{\beta}_0)}, \hat{\beta}_0 + t_{n-2, \frac{\alpha}{2}} \sqrt{\hat{\text{Var}}(\hat{\beta}_0)} \right) \text{ όπου } \hat{\text{Var}}(\hat{\beta}_0) = \frac{\sum X_i^2 \text{MSres.}}{n \sum (X_i - \bar{X})^2}$$

Το δε ελάχιστο μήκος για την b_1 με $\delta \in 100(1-\alpha)\%$ είναι

$$\left(b_1 - t_{n-2, \frac{\alpha}{2}} \sqrt{\text{Var}(b_1)}, b_1 + t_{n-2, \frac{\alpha}{2}} \sqrt{\text{Var}(b_1)} \right)$$

$$\text{όπου } \text{Var}(b_1) = \frac{1}{\sum (X_i - \bar{X})^2} \text{MSres}$$

Τοπική Απόκλιση της πρόβλεψης $\hat{Y}_k = b_0 + b_1 X_k$

Σκοπός είναι η εύρεση της $\text{Var}(\hat{Y}_k)$, αν είναι μικρή η πρόβλεψη Y_k είναι αξιόπιστη

$$\hat{Y}_k = b_0 + b_1 X_k = \bar{Y} - b_1 \bar{X} + b_1 X_k$$

$$\Rightarrow \hat{Y}_k = \bar{Y} + (X_k - \bar{X}) b_1$$

$$\text{Var}(\hat{Y}_k) = \text{Var}(\bar{Y} + (X_k - \bar{X}) b_1)$$

$$\text{Var}(\sum a_i W_i) = \sum a_i^2 \text{Var}(W_i) + \sum_{i=1}^n \sum_{\substack{j=1 \\ i \neq j}}^n a_i a_j \text{Cov}(W_i, W_j) \Rightarrow$$

$$\text{Var}(\hat{Y}_k) = \text{Var}(\bar{Y}) + (X_k - \bar{X})^2 \text{Var}(b_1) + (X_k - \bar{X}) \text{Cov}(\bar{Y}, b_1)$$

$$\text{Cov}(\bar{Y}, b_1) = \text{Cov}\left(\frac{1}{n} \sum Y_i, \sum \frac{X_i - \bar{X}}{\sum (X_i - \bar{X})^2} Y_i\right)$$

$$\text{Cov}\left(\sum_{i=1}^n a_i W_i, \sum_{i=1}^n b_i W_i\right) = \sum_{i=1}^n a_i b_i \text{Var}(W_i) \Rightarrow$$

~~$$\text{Var}(\hat{Y}_k) = \text{Cov}(\bar{Y}, b_1) = \sum_{i=1}^n \frac{1}{n} \frac{X_i - \bar{X}}{\sum (X_i - \bar{X})^2} \text{Var}(Y_i) = \frac{1}{n} \cdot \sigma^2 \sum \frac{(X_i - \bar{X})^2}{\sum (X_i - \bar{X})^2} = 0$$~~

$$\text{Άρα } \boxed{\text{Var}(\hat{Y}_k) = \text{Var}(\bar{Y}) + (X_k - \bar{X})^2 \text{Var}(b_1)}$$

~~[$\text{Cov}(\bar{Y}, b_1) = \sum_{i=1}^n \frac{1}{n} \frac{X_i - \bar{X}}{\sum (X_i - \bar{X})^2} \text{Cov}(\bar{Y}, Y_i) = \frac{1}{n} \sum \frac{(X_i - \bar{X})}{\sum (X_i - \bar{X})^2} \sum_{j=1}^n \text{Cov}(Y_i, Y_j) = \frac{1}{n} \sum \frac{(X_i - \bar{X})}{\sum (X_i - \bar{X})^2} \sum_{j=1}^n \text{Cov}(Y_i, Y_j) = 0$]~~

Παρατήρηση: Η διακύμανση \hat{Y}_k ελαττώνεται για $X_k = \bar{X}$

Άρα στην πράξη το μήκος της α.β.π πρέπει να χρησιμοποιείται για την πρόβλεψη της Y για τιμές της X κοντά στο \bar{X} , κοντά δηλ στη μέση των μετρήσεων της X .