

4<sup>ο</sup> μάθημα

25/10/21

①

Τυπική Ανάλυση της πρόβλεψης  $\hat{Y}_k$

α.γ.η. :  $Y_i = \beta_0 + \beta_1 X_i + \varepsilon_i$ , με  $i = 1, \dots, n$

Εκτιμώμενο Μοντέλο:  $\hat{Y} = \hat{\beta}_0 + \hat{\beta}_1 \cdot X$

Πρόβλεψη της  $Y$  για την τιμή  $(X_k)$  της  $X$  :  
 $\hat{Y}_k = \hat{\beta}_0 + \hat{\beta}_1 \cdot X$

Πόσο καλή είναι η πρόβλεψη  $\hat{Y}_k$ ?

Απρί να μπου να βρω την  $Var(\hat{Y}_k) = ?$

$$\left. \begin{aligned} \hat{Y}_k &= \hat{\beta}_0 + \hat{\beta}_1 \cdot X_k \\ \hat{\beta}_0 &= \bar{Y} - \hat{\beta}_1 \cdot \bar{X} \end{aligned} \right\} \hat{Y}_k = \bar{Y} + \hat{\beta}_1 \cdot (X_k - \bar{X}).$$

Πάλι να βρω την  $Var(\hat{Y}_k) = ?$

$$\left. \begin{aligned} Var(\hat{Y}_k) &= Var(\bar{Y} + \hat{\beta}_1 \cdot (X_k - \bar{X})) \\ Var\left(\sum_{i=1}^n a_i W_i\right) &= \sum_{i=1}^n a_i^2 Var(W_i) + \sum_{i=1}^n \sum_{\substack{j=1 \\ i \neq j}}^n a_i a_j Cov(W_i, W_j) \end{aligned} \right\}$$

• Αν οι  $W_i$  ανεξάρτες:  $Var\left(\sum_{i=1}^n a_i W_i\right) = \sum_{i=1}^n a_i^2 Var(W_i)$

$$\left. \begin{aligned} \Rightarrow Var(\hat{Y}_k) &= Var(\bar{Y}) + (X_k - \bar{X})^2 Var(\hat{\beta}_1) + \\ &+ (X_k - \bar{X}) \cdot Cov(\bar{Y}, \hat{\beta}_1) \quad (*) \end{aligned} \right\}$$

$$\begin{aligned} \text{Αλλά } Cov(\bar{Y}, \hat{\beta}_1) &= Cov\left(\frac{1}{n} \cdot \frac{\sum (X_i - \bar{X}) \cdot Var(Y_i)}{\sum (X_i - \bar{X})^2}\right) = \\ &= \sum_{i=1}^n \frac{1}{n} \cdot \frac{X_i - \bar{X}}{\sum (X_i - \bar{X})^2} \cdot Var(Y_i) = \frac{\sigma^2}{n} \cdot \frac{\sum_{i=1}^n (X_i - \bar{X})}{\sum (X_i - \bar{X})^2} = 0 \quad (***) \end{aligned}$$

Καθώς από Θ.Π.2. έχουμε ότι:

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

$$\underline{Y_{\text{new}}}: \sum_{i=1}^n \frac{X_i - \bar{X}}{\sum (X_i - \bar{X})^2} = \frac{1}{\sum (X_i - \bar{X})^2} \cdot \sum (X_i - \bar{X}) =$$

$$= \frac{1}{\sum (X_i - \bar{X})^2} (\sum X_i - n\bar{X}) = \frac{1}{\sum (X_i - \bar{X})^2} \cdot (n\bar{X} - n\bar{X}) = 0.$$



Από (\*), (\*\*) έχω:  $\text{Var}(\hat{Y}_k) = \text{Var}(\bar{Y}) + (X_k - \bar{X})^2 \text{Var}(\hat{\beta}_1)$

↓  
 και αυτό πρέπει να αλλάξει όταν  $X_k$  καταστούν

Αρα προβλέπω τιμές της  $X_k$  κατά στο  $\bar{X}$  συνιστώσας αν έχω μικρή διακρίση → θα έχω καλή πρόβλεψη.

Συμπερασματικά: Η πρόβλεψη είναι καλή αν η  $\text{Var}(\hat{Y}_k)$  είναι μικρή, δηλ. αν το  $(X_k - \bar{X})^2$  είναι μικρό. Αρα πρέπει να χρησιμοποιώ το καλύτερο της αχ.π. για πρόβλεψη για τιμές  $X_k$  της  $X$ , όχι μακριά από την  $\bar{X}$ .

F-τεστ για την παλινδρόμηση ή F-τεστ για τον έλεγχο της  $H_0: \beta_1 = 0$  (διστά αν  $\beta_1 = 0$  ή καλύτερο αχ.π)

Αποδεικνύουμε ότι:  $E(MS_{res}) = \sigma^2$

Θδο:  $E(MS_{reg}) = \sigma^2 + \beta_1^2 \sum (X_i - \bar{X})^2$

Απόδειξη:  $MS_{reg} = \frac{SS_{reg}}{1}$ , άρα  $E(MS_{reg}) = E(SS_{reg}) =$

$= E\left(\hat{\beta}_1^2 \sum_{i=1}^n (X_i - \bar{X})^2\right) = \sum_{i=1}^n (X_i - \bar{X})^2 \cdot E(\hat{\beta}_1^2) =$

$= \sum_{i=1}^n (X_i - \bar{X})^2 \cdot [\text{Var}(\hat{\beta}_1) + (E(\hat{\beta}_1))^2] =$

$= \sum_{i=1}^n (X_i - \bar{X})^2 \cdot \left[ \frac{\sigma^2}{\sum (X_i - \bar{X})^2} + \beta_1^2 \right] = \sigma^2 + \beta_1^2 \sum (X_i - \bar{X})^2$

- Αν η  $H_0: \beta_1 = 0$  είναι αληθής, τότε  $E(MS_{reg}) = E(MS_{res})$
- ή αν  $H_0: \beta_1 = 0$  είναι αληθής, τότε  $MS_{reg} \approx MS_{res}$



}  $\Rightarrow$  Ισχύει: Αν η πρόταση  $A \Rightarrow B$ , τότε  $\sim B \Rightarrow \sim A$

$\Rightarrow$  Αν  $MS_{reg}$  πολύ διαφορετικό από το  $MS_{res}$ , τότε  $\beta_1 \neq 0$   
και επομένως η  $H_0: \beta_1 = 0$  πρέπει να απορριφθεί

Αρα ένα test για τον έλεγχο της  $H_0: \beta_1 = 0$  μπορεί  
να στηριχτεί στη σύγκριση των  $MS_{reg}$  και  $MS_{res}$

Θα στηριχτώ για τη σύγκριση των  $MS_{reg}$  και  $MS_{res}$   
στο πηλίκο  $F = \frac{MS_{reg}}{MS_{res}}$

Χρειαζόμαστε κατανομή του  $F$  κάτω από την  $H_0$ .

Γνωρίζω:  $\frac{SS_{reg}}{\sigma^2} \sim \chi^2_{n-2}$

Διερεύνηση κατανομής του  $SS_{reg}$

$$SS_{reg} = \hat{\beta}_1^2 \cdot \sum (X_i - \bar{X})^2, \quad \hat{\beta}_1 \sim N\left(\beta_1, \frac{\sigma^2}{\sum (X_i - \bar{X})^2}\right)$$

$$\frac{\hat{\beta}_1 - \beta_1}{\sigma / \sqrt{\sum (X_i - \bar{X})^2}} \sim N(0, 1) \text{ και υπό την } H_0: \beta_1 = 0$$

$$\frac{\hat{\beta}_1}{\sigma / \sqrt{\sum (X_i - \bar{X})^2}} \sim N(0, 1) \Rightarrow \frac{\hat{\beta}_1^2}{\sigma^2 / \sum (X_i - \bar{X})^2} \sim \chi^2_1 \Rightarrow$$

$$\frac{\sum (X_i - \bar{X})^2 \cdot \hat{\beta}_1^2}{\sigma^2} \sim \chi^2_1 \Rightarrow \frac{SS_{reg}}{\sigma^2} \sim \chi^2_1 \text{ υπό } H_0: \beta_1 = 0$$

Επομένως:  $F = \frac{MS_{reg}}{MS_{res}} = \frac{SS_{reg}/1}{SS_{res}/(n-2)} = \frac{SS_{reg}/\sigma^2 \cdot 1}{SS_{res}/(\sigma^2(n-2))}$

$$= \frac{SS_{reg} / \sigma^2 \cdot 1}{SS_{res} / \sigma^2 \cdot (n-2)} \sim \frac{\chi^2_1 / 1}{\chi^2_{n-2} / (n-2)} \equiv F_{1, n-2}$$

με την προϋπόθεση ομοιογένειας και ομοσκεψής να είναι ανεξάρτητοι μεταξύ τους

Μορφή της Κ.Π. (Κρίσιμης Περιοχής) :

Πολύ διαφορετικές τιμές των  $MS_{reg}, MS_{res}$  ή πολύ μεγάλη τιμή του  $F = \frac{MS_{reg}}{MS_{res}}$  ή  $F \geq c$ .

Προσδιορισμός του κ.σ. c :

$$\alpha = P(\text{απορ. } H_0 \mid H_0 \text{ αληθής}) = P(F \geq c \mid F \sim F_{1, n-2}) = P(F_{1, n-2} \geq c) \Rightarrow c = F_{1, n-2, \alpha}$$

Για τον έλεγχο υπάρξης παλινδρόμησης, δηλ.  $H_0: \beta_1 = 0$  η  $\Sigma\Sigma T$  είναι  $F = \frac{MS_{reg}}{MS_{res}} \sim F_{1, n-2}$  υπό την  $H_0$ .  
 Στατ. Σω. Τελ.

Παρατήρηση : Για τον έλεγχο της  $H_0: \beta_1 = 0 \exists$  διαθέσιμο και το t-τεστ. Το t-τεστ και το F-τεστ είναι ισοδύναμα γιατί  $F = t^2$  και (το αντίστροφο ελαττωσιακό επίπεδο)  $F_{1, n-2, \alpha} = t^2_{n-2, \frac{\alpha}{2}}$ .

(στην πράξη χρησιμοποιείται το F γιατί είναι σταθμικά Ακόμα)

Δωτελεστικής Συσχέτισης Pearson :

X	$X_1, \dots, X_n$
Y	$Y_1, \dots, Y_n$






Ο δείκτης συσχέτισης συσχέτισης Pearson

$$r_{x,y} = r = \frac{\sum (X_i - \bar{X}) \cdot (Y_i - \bar{Y})}{\sqrt{\sum (X_i - \bar{X})^2 \cdot \sum (Y_i - \bar{Y})^2}}$$

Ιδιότητες:


- ① Ο  $r_{x,y}$  είναι αναλλοίωτος από μενόμενες μεταφάσεις
- ② Είναι συμμετρικός, δηλ.  $r_{x,y} = r_{y,x}$
- ③ Παιρνει τιμές :  $-1 \leq r_{x,y} \leq 1$   
 (ανδείξη μέσω ανισότητας Cauchy-Schwarz).



π.χ.

X	-3	-1	0	1	3
Y	9,54	9,95	10	9,95	9,54

Αν και οι πράξεις, βρίσκω  $r_{x,y} = 0$ . Αρα δεν μπορώ να υιοθετήσω γραμμική σχέση. Δηλ έχω  $X^2 + Y^2 = 100$ , άρα



όλα τα σημεία θα βρίσκονται εντός του κύκλου.

Νδo :  $b_0 \sim N\left(b_0, \sigma^2 \left\{ \frac{1}{n} + \frac{\bar{x}^2}{\sum (X_i - \bar{X})^2} \right\} = \frac{\sigma^2 \cdot \sum X_i^2}{n \sum (X_i - \bar{X})^2} \right)$

(7)

Μον:  $\hat{\beta}_0 = \bar{Y} - \hat{\beta}_1 \bar{X}$

Το  $\hat{\beta}_0 \sim \text{Normal}$  ως γραμμικός συνδυασμός των  $\bar{Y}$  και  $\hat{\beta}_1$  που έχουν κανονική κατανομή. Άρα:

$$\bullet E(\hat{\beta}_0) = E(\bar{Y} - \hat{\beta}_1 \bar{X}) = E(\bar{Y}) - \bar{X} \cdot E(\hat{\beta}_1) =$$

$$= E(\bar{Y}) - \bar{X} \cdot \beta_1$$

$$\bullet E(\bar{Y}) = E\left(\frac{1}{n} \sum Y_i\right) = \frac{1}{n} \sum E(Y_i) = \frac{1}{n} \sum (\beta_0 + \beta_1 X_i) =$$

$$= \beta_0 + \beta_1 \bar{X}$$

$$\Rightarrow E(\hat{\beta}_0) = \beta_0 + \beta_1 \bar{X} - \beta_1 \bar{X} = \beta_0$$

$$\text{Var}(\hat{\beta}_0) = \text{Var}(\bar{Y} - \hat{\beta}_1 \bar{X}) = \text{Var}(\bar{Y}) + \bar{X}^2 \cdot \text{Var}(\hat{\beta}_1) - \bar{X} \cdot \text{Cov}(\bar{Y}, \hat{\beta}_1)$$

$$= \text{Var}(\bar{Y}) + \bar{X}^2 \cdot \frac{\sigma^2}{\sum (X_i - \bar{X})^2} = \frac{\sigma^2}{n} + \frac{\sigma^2 \bar{X}^2}{\sum (X_i - \bar{X})^2}$$

► Να υπολογιστεί η  $\text{Cov}(\hat{\beta}_0, \hat{\beta}_1) = ?$

Μον:  $\text{Cov}(\hat{\beta}_0, \hat{\beta}_1) = \text{Cov}(\bar{Y} - \hat{\beta}_1 \bar{X}, \hat{\beta}_1)$

$$\text{Ισχύει ότι } \text{Cov}\left(\sum_{i=1}^n \alpha_i Z_i, \sum_{i=1}^n \beta_i W_i\right) =$$

$$= \sum_{i=1}^n \sum_{j=1}^n \alpha_i \beta_j \text{Cov}(Z_i, W_j)$$

$$\text{Άρα: } \text{Cov}(\hat{\beta}_0, \hat{\beta}_1) = \text{Cov}(\bar{Y}, \hat{\beta}_1) - \bar{X} \cdot \text{Cov}(\hat{\beta}_1, \hat{\beta}_1) =$$

$$= 0 - \bar{X} \cdot \text{Var}(\hat{\beta}_1) =$$

$$= -\bar{X} \cdot \frac{\sigma^2}{\sum (X_i - \bar{X})^2}$$



Άσκηση 14 : Έστω το ματέλο α.χ.π.

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

Υποθέτουμε  $\epsilon_i \sim N(0, \sigma^2)$  με  $i=1, \dots, n$  αλληλεξάρτητα

α) ΝΔΟ Ε.Ε.Τ. των  $\beta_0, \beta_1$  εκφώνεται με Ε.Μ.Π των  $\beta_0, \beta_1$

β) Ο Ε.Μ.Π. της  $\sigma^2$  είναι :  $\hat{\sigma}^2 = \frac{SS_{res}}{n}$   
↓  
κοινή διακ/ση

Έστω τ.δ. μεγέθους  $n$  :  $X_1, \dots, X_n$  and  $f(x, \theta)$  με  $\theta \in \Theta$ ,  $\theta$  άγνωστο.

Πιθανοφαικίας :  $L(\theta) \stackrel{\text{op}}{=} \eta$  από κοινά κατανομή των δείγματος  $X_1, \dots, X_n =$   
 $= \prod_{\omega \in \Omega} f_{X_i}(X_i, \theta)$

Ε.Μ.Π :  $\hat{\theta} \stackrel{\text{op}}{=} \arg \max_{\theta \in \Theta} L(\theta)$

Ο Ε.Μ.Π  $\hat{\theta}$  προκύπτει από τη μεγιστοποίηση ως προς  $\theta$  της  $L(\theta)$  ή του  $\log L(\theta)$ .

Λύση : α) Ε.Ε.Τ ελαχιστοποιώ το  $S = \sum_{i=1}^n \epsilon_i^2$

- II - ως προς  $\beta_0, \beta_1$   $S = \sum_{i=1}^n (Y_i - \beta_0 - \beta_1 X_i)^2$

Πιθανοφαικία στο ματέλο της α.χ.π. είναι η από κοινά κατανομή των  $Y_1, \dots, Y_n$

Δηλ.  $L = L(\beta_0, \beta_1) = \prod_{\omega \in \Omega} f_{Y_1, \dots, Y_n}(Y_1, \dots, Y_n)$  και επειδή  
 $\frac{Y_1, \dots, Y_n}{\prod_{i=1}^n f_{Y_i}(Y_i)}$



Αλλά:  $Y_i \sim N(b_0 + b_1 \cdot X_i, \sigma^2)$ ,  $i = 1, \dots, n$

Άρα:  $f_{Y_i}(y_i) = \frac{1}{\sigma\sqrt{2\pi}} \cdot e^{-\frac{1}{2\sigma^2}(y_i - b_0 - b_1 \cdot X_i)^2}$

Επομένως:  $L = \prod_{i=1}^n \frac{1}{\sigma\sqrt{2\pi}} \cdot e^{-\frac{1}{2\sigma^2}(y_i - b_0 - b_1 \cdot X_i)^2} \Rightarrow$

$$L = \frac{1}{(\sigma\sqrt{2\pi})^n} \cdot e^{-\frac{1}{2\sigma^2} \sum_{i=1}^n (y_i - b_0 - b_1 \cdot X_i)^2}$$

- Οι ΕΜΠ των  $b_0, b_1$  προκύπτουν από τη μεγιστοποίηση ως προς  $b_0, b_1$  της  $L$
- ή από μεγιστοποίηση ως προς  $b_0, b_1$  της  $\log L$
- ή  $-||-$  του  $-n \cdot \log(\sigma\sqrt{2\pi}) - \frac{1}{2\sigma^2} \sum (y_i - b_0 - b_1 X_i)^2$
- ή από μεγ. ως προς  $b_0, b_1$  του  $-\sum_{i=1}^n (y_i - b_0 - b_1 X_i)^2$
- ή ελαχ. του  $\sum_{i=1}^n (y_i - b_0 - b_1 X_i)^2$

Παρατηρώ ότι οι Ε.Ε.Τ. και οι Ε.Μ.Π. προκύπτουν από ελαχιστοποίηση της ίδιας ποσότητας, άρα θα βρhnιστaυ.

β)  $\rightarrow$  2π1ε1.