

ΑΣΚΗΣΕΙΣ ΣΤΗΝ ΓΡΑΜΜΙΚΗ ΠΑΛΙΝΔΡΟΜΗΣΗ

ΑΣΚΗΣΗ 1. Έστω το μοντέλο της απλής γραμμικής παλινδρόμησης $Y_i = \beta_0 + \beta_1 X_i + \varepsilon_i$, $i=1, \dots, n$, με τα σφάλματα $\varepsilon_i \sim N(0, \sigma^2)$ και ασυσχέτιστα ανά δύο. Ναδειχθεί ότι οι εκτιμητές ελαχίστων τετραγώνων των β_0 και β_1 του μοντέλου αυτού, συμπίπτουν με τους εκτιμητές μέγιστης πιθανοφάνειάς τους.

ΑΣΚΗΣΗ 2. Έστω το μοντέλο της απλής γραμμικής παλινδρόμησης $Y_i = \beta_0 + \beta_1 X_i + \varepsilon_i$, $i=1, \dots, n$, με $E(\varepsilon_i) = 0$, $Var(\varepsilon_i) = \sigma^2$ και τα ε_i , $i=1, \dots, n$, είναι ασυσχέτιστα. Αν $\hat{\beta}_0$ και $\hat{\beta}_1$ οι εκτιμητές ελαχίστων τετραγώνων των β_0 και β_1 , ναδειχθούν τα ακόλουθα:

$$\alpha) E(\hat{\beta}_0) = \beta_0, E(\hat{\beta}_1) = \beta_1, Var(\hat{\beta}_0) = \sigma^2 \left\{ \frac{1}{n} + \frac{\bar{X}^2}{\sum (X_i - \bar{X})^2} \right\} = \frac{\sigma^2 \sum X_i^2}{n \sum (X_i - \bar{X})^2}, Var(\hat{\beta}_1) = \frac{\sigma^2}{\sum_{i=1}^n (X_i - \bar{X})^2}.$$

$$\beta) \sum_{i=1}^n X_i \varepsilon_i = 0, \text{ με } \varepsilon_i = Y_i - \hat{Y}_i, i=1, \dots, n, \text{ τα υπόλοιπα.}$$

$$\gamma) Cov(\hat{\beta}_0, \hat{\beta}_1) = -\frac{\sigma^2 \bar{X}}{\sum_{i=1}^n (X_i - \bar{X})^2}.$$

ΑΣΚΗΣΗ 3. Τα παρακάτω δεδομένα αναφέρονται στην επίδραση της θερμοκρασίας στην απόδοση μιας χημικής αντίδρασης.

Θερμοκρασία	-5	-4	-3	-2	-1	0	1	2	3	4	5
Απόδοση	1	5	4	7	10	8	9	13	14	13	18

α) Αφού ορισθεί η εξαρτημένη και η ανεξάρτητη μεταβλητή να βρεθούν οι εκτιμητές ελαχίστων τετραγώνων των παραμέτρων του μοντέλου.

β) Να κατασκευαστεί ο πίνακας ΑΝΑΔΙΑ και να γίνει ένα αρχικό τεστ για τον έλεγχο της υπόθεσης $H_0: \beta_1 = 0$.

γ) Κάνοντας τις κατάλληλες υποθέσεις

ι) Να ελεγχθεί η υπόθεση $H_0: \beta_1 = 0$ σε επίπεδο σημαντικότητας $\alpha = 0.05$.

ii) Να βρεθεί ένα 95% διάστημα εμπιστοσύνης για το β_1 .

ΑΣΚΗΣΗ 4. Για το μοντέλο της απλής γραμμικής παλινδρόμησης $Y_i = \beta_0 + \beta_1 X_i + \varepsilon_i$, $i=1, \dots, n$, ναδειχθεί ότι:

α) $r_{\hat{Y}Y}^2 = R^2$, με r_{XY} το δειγματικό συντελεστή συσχέτισης του Pearson και R^2 το συντελεστή προσδιορισμού.

β) Αν $r_{Y\hat{Y}}$ είναι ο δειγματικός συντελεστής συσχέτισης του Pearson μεταξύ της παρατηρούμενης και της εκτιμώμενης τιμής του Y , ναδειχθεί ότι $r_{Y\hat{Y}}^2 = R^2$.

ΑΣΚΗΣΗ 5. Τα παρακάτω δεδομένα συγκεντρώθηκαν σε μια μελέτη που σκοπό είχε να εξετασθεί ποιοι παράγοντες επιδρούν στο βάρος ενός νεογέννητου μωρού.

Βάρος κατά τη γέννηση (gr)	1361	1588	1815	2087	2268	2404	3402	3629	3765	4083
Κοινωνικο-οικονομική κατάσταση	8	7	4	5	5	4	3	3	2	1
Σειρά γεννήσεως	4	3	4	3	2	2	2	1	1	1

ι) Να ορισθεί η εξαρτημένη και οι ανεξάρτητες μεταβλητές.

ii) Να βρεθούν οι πίνακες $X'X$, $(X'X)^{-1}$, $X'Y$.

iii) Να βρεθούν οι εκτιμητές ελαχίστων τετραγώνων του μοντέλου $Y_i = \beta_0 + \beta_1 X_{i1} + \beta_2 X_{i2} + \varepsilon_i$, και να δοθεί ο πίνακας διακυμάνσεων-συνδιακυμάνσεών τους. Να υπολογισθεί ο δειγματικός συντελεστής συσχέτισης μεταξύ των $\hat{\beta}_1$ και $\hat{\beta}_2$.

iv) Να δοθεί ο πίνακας ANADIA και να βρεθεί ένας αμερόληπτος εκτιμητής για τη διακύμανση σ^2 των σφαλμάτων του μοντέλου.

v) Υποθέτοντας ότι τα σφάλματα ακολουθούν κανονική κατανομή να ελεγχθούν οι υποθέσεις,

α) $\beta_1 = \beta_2 = 0$, β) $\beta_0 = 0$, γ) $\beta_1 = 0$, δ) $\beta_2 = 0$.

vi) Να δοθεί η φυσική ερμηνεία του εκτιμώμενου μοντέλου.

ΑΣΚΗΣΗ 6. Το γραφείο υποδοχής ασθενών ενός νοσοκομείου, θέλοντας να εξετάσει ποιοι παράγοντες μπορεί να επιδρούν στη διάρκεια παραμονής των ασθενών, που υποβάλλονται σε κάποιο είδος εγχείρησης στο νοσοκομείο, συγκέντρωσε τα παρακάτω δεδομένα για 20 τέτοιους ασθενείς.

A/A	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
Ημέρες παραμονής															
Μετά την εγχείρηση	6	6	11	9	16	16	4	8	11	13	13	9	17	17	12
Αριθ. Ιατρικών Προβλημάτων	1	2	2	1	3	1	1	3	2	3	1	1	3	2	4
Ημέρες Παραμονής															
Πρίν την εγχείρηση	1	1	2	3	3	5	1	1	2	2	4	2	3	4	1
	16	17	18	19	20										
	6	5	12	8	9										
	1	1	3	1	2										
	1	1	2	2	2										

Κάνοντας τις κατάλληλες υποθέσεις να αναλυθούν τα δεδομένα και να διατυπωθούν τα συμπεράσματα.

ΑΣΚΗΣΗ 7. Έστω Y_1 και Y_2 δύο ανεξάρτητες τυχαίες μεταβλητές με μέσες τιμές θ και 2θ αντίστοιχα, με θ πραγματικό αριθμό. Χρησιμοποιώντας το μοντέλο της γραμμικής παλινδρόμησης να προσδιορισθεί ο εκτιμητής ελαχίστων τετραγώνων της παραμέτρου θ και να υπολογισθεί το άθροισμα τετραγώνων των υπολοίπων.

ΑΣΚΗΣΗ 8. Για το μοντέλο της πολλαπλής γραμμικής παλινδρόμησης να δειχθεί ότι

$$(Y - X\beta)'(Y - X\beta) = (Y - X\hat{\beta})'(Y - X\hat{\beta}) + (\hat{\beta} - \beta)'X'X(\hat{\beta} - \beta).$$

ΑΣΚΗΣΗ 9. Αν σε ένα γραμμικό μοντέλο υπάρχει σταθερός όρος, τότε το άθροισμα των υπολοίπων ισούται με το μηδέν.

ΑΣΚΗΣΗ 10. Θεωρούμε το μοντέλο της πολλαπλής γραμμικής παλινδρόμησης $Y = X\beta + \epsilon$, με $\text{Rank}(X) = p + 1$. Να δειχθεί ότι,

$$\alpha) \sum_{i=1}^n \hat{Y}_i (Y_i - \hat{Y}_i) = 0, \text{ και } \beta) \sum_{i=1}^n \text{Var}(\hat{Y}_i) = \sigma^2 (p + 1).$$

ΑΣΚΗΣΗ 11. Για το μοντέλο $Y_i = \beta_0 + \beta_1 X_{i1} + \beta_2 X_{i2} + \epsilon_i$, $i=1, \dots, n$, με ϵ_i ανεξάρτητες $N(0, \sigma^2)$, δίνονται οι κανονικές εξισώσεις:

$$10\hat{\beta}_0 + 2\hat{\beta}_1 - 6\hat{\beta}_2 = 4$$

$$2\hat{\beta}_0 + 2\hat{\beta}_1 = 6$$

$$-6\hat{\beta}_0 + 5\hat{\beta}_2 = 7.$$

α) Αν $n=10$ και $\sum_{i=1}^n Y_i^2 = 107$, να υπολογισθούν ο εκτιμητής $\hat{\beta}$ και το MS_{res} .

β) Να ελεγχθεί με τη βοήθεια ενός F -τεστ η μηδενική υπόθεση $H_0: \beta_1 = 2\beta_2$, σε επίπεδο $\alpha = 5\%$.

γ) Να κατασκευαστεί ένα t -τεστ για τον έλεγχο της υπόθεσης $H_0: \beta_1 = 2\beta_2$, σε επίπεδο $\alpha = 5\%$.

ΑΣΚΗΣΗ 12. Έστω το μοντέλο της απλής γραμμικής παλινδρόμησης $Y_i = \beta_0 + \beta_1 X_i + \epsilon_i$, με $\sigma^2 = \text{Var}(\epsilon_i)$, $\nu_i = E(Y_i)$, και $q_i = (Y_i - \hat{Y}_i) - (\nu_i - E(\hat{Y}_i))$, $i=1, \dots, n$. Να δειχθεί ότι

$$E\left(\sum_{i=1}^n q_i^2\right) = (n-2)\sigma^2.$$

ΑΣΚΗΣΗ 13. Έστω το μοντέλο της πολλαπλής γραμμικής παλινδρόμησης $Y = X\beta + \epsilon$, με $\text{Rank}(X) = p + 1$.

α) Να δειχθεί ότι, $SS_{res} = \hat{\beta}' X' Y - n\bar{Y}^2$.

β) Υπό την υπόθεση ότι το διάνυσμα των σφαλμάτων $\epsilon \sim N_n(0, \sigma^2 \mathbf{I}_n)$, να δειχθεί ότι οι εκτιμητές ελαχίστων τετραγώνων $\hat{\beta}$ των παραμέτρων β του μοντέλου, ταυτίζονται με τους εκτιμητές μέγιστης πιθανοφάνειας.

γ) Υπό την υπόθεση $\epsilon \sim N_n(0, \sigma^2 \mathbf{I}_n)$ να δειχθεί ότι $\frac{SS_{res}}{\sigma^2} \sim \chi_{n-p-1}^2$.

ΑΣΚΗΣΗ 14. Έστω το μοντέλο παλινδρόμησης

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

για το οποίο ισχύει ότι τα σφάλματα ϵ_i ακολουθούν κανονική κατανομή με

$$E(\epsilon_i) = 0, \text{ Var}(\epsilon_i) = \sigma^2 X_i \text{ και } \text{Cov}(\epsilon_i, \epsilon_j) = 0, \text{ για } i, j = 1, \dots, n, \quad i \neq j.$$

α) Να βρεθεί ο εκτιμητής μέγιστης πιθανοφάνειας (ή ο εκτιμητής ελαχίστων τετραγώνων) και να δειχθεί ότι είναι αμερόληπτος εκτιμητής του β .

β) Να δείξετε ότι οι $\beta^* = \frac{Y_1 + Y_2}{X_1 + X_2}$, $\beta^{**} = \frac{Y_n - Y_1}{X_n - X_1}$ και $\beta^{***} = \frac{X_1 Y_1 + X_2 Y_2}{X_1^2 + X_2^2}$ είναι επίσης

αμερόληπτοι εκτιμητές του β .

γ) Γιατί οι εκτιμητές του προηγούμενου ερωτήματος δεν είναι αποτελεσματικοί;

ΑΣΚΗΣΗ 15. Για το μοντέλο της απλής γραμμικής παλινδρόμησης

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

να δείξετε ότι

$$\text{i) } \sum_{i=1}^n \hat{Y}_i = \sum_{i=1}^n Y_i, \text{ και } \sum_{i=1}^n e_i = 0, \quad \text{ii) } \bar{\hat{Y}} = \bar{Y}, \quad \text{iii) } \bar{Y} = \hat{\beta}_0 + \hat{\beta}_1 \bar{X}, \quad \text{iv) } \sum_{i=1}^n \hat{Y}_i X_i = \sum_{i=1}^n Y_i X_i, \text{ και } \sum_{i=1}^n e_i \hat{Y}_i = 0,$$

$$\text{v) } \sum_{i=1}^n e_i X_i = 0.$$

ΑΣΚΗΣΗ 16. Έστω ότι $\hat{\beta}_0, \hat{\beta}_1, \dots, \hat{\beta}_p$ είναι οι εκτιμητές ελαχίστων τετραγώνων του μοντέλου πολλαπλής παλινδρόμησης

$$Y_i = \beta_0 + \beta_1 X_{i1} + \dots + \beta_p X_{ip} + \varepsilon_i, \quad i = 1, \dots, n.$$

Να βρεθούν συναρτήσει των $\hat{\beta}_0, \hat{\beta}_1, \dots, \hat{\beta}_p$ οι εκτιμητές ελαχίστων τετραγώνων του μοντέλου

$$Y_i = \beta_0 + \beta_1 Z_{i1} + \dots + \beta_p Z_{ip} + \varepsilon_i, \quad i = 1, \dots, n,$$

όπου $Z_{ij} = c_j X_{ij}$, $j = 1, \dots, p$, με c_j , $j = 1, \dots, p$, σταθερές και $i = 1, \dots, n$.

ΑΣΚΗΣΗ 17. Για το μοντέλο της απλής γραμμικής παλινδρόμησης

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

να δείξετε ότι οι εκτιμητές ελαχίστων τετραγώνων των β_0, β_1 είναι ασυσχέτιστοι αν $\sum_{i=1}^n X_i = 0$.

ΑΣΚΗΣΗ 18. Έστω το μοντέλο παλινδρόμησης

$$Y_i = \beta X_i + \varepsilon_i, \quad i = 1, \dots, n,$$

για το οποίο ισχύει ότι τα σφάλματα ε_i ακολουθούν κανονική κατανομή με

$$E(\varepsilon_i) = 0, \quad \text{Var}(\varepsilon_i) = \frac{\sigma^2}{X_i} \quad \text{και} \quad \text{Cov}(\varepsilon_i, \varepsilon_j) = 0, \quad \text{για } i, j = 1, \dots, n, \quad i \neq j.$$

Να βρεθεί ο γραμμικός αμερόληπτος εκτιμητής του β με την μικρότερη διακύμανση.

ΑΣΚΗΣΗ 19. Για το κλασικό μοντέλο απλής γραμμικής παλινδρόμησης

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

να βρείτε τις συνθήκες που πρέπει να ικανοποιούνται έτσι ώστε ένας γραμμικός εκτιμητής του β_i να είναι αμερόληπτος. Πότε αυτός είναι ο BLUE;

(Υπενθύμιση: Ένας εκτιμητής είναι γραμμικός όταν είναι της μορφής $\sum_{i=1}^n d_i Y_i$).

ΑΣΚΗΣΗ 20. Στο μοντέλο της πολλαπλής γραμμικής παλινδρόμησης $Y = X\beta + \varepsilon$, με $\text{Rank}(X) = p + 1$, τα μαθηματικοποιημένα υπόλοιπα ορίζονται

$$t_i = \frac{e_i}{\sqrt{MS_{res} \sqrt{1 - \rho_{ii}}}}, \quad i = 1, \dots, n,$$

με ρ_{ij} να συμβολίζει το στοιχείο της (i, j) -θέσης του πίνακα $P = X(X'X)^{-1}X'$. Να δειχθεί ότι

$$t_i \sim t_{n-p-1}.$$

ΑΣΚΗΣΗ 21. Έστω οι παρατηρήσεις $Y_1 = \alpha_1 + \varepsilon_1$, $Y_2 = 2\alpha_1 - \alpha_2 + \varepsilon_2$ και $Y_3 = \alpha_1 + 2\alpha_2 + \varepsilon_3$, με $\varepsilon = (\varepsilon_1, \varepsilon_2, \varepsilon_3)' \sim N_3(0, \sigma^2 \mathbf{I}_3)$. Με τη θεωρία των γραμμικών μοντέλων να ελεγχθεί η υπόθεση

$$H_0 : \alpha_1 = \alpha_2.$$

7/11/16

①

Παρασκευή 11/11/16

Μαθημα 15:00

Πολυπόλωση και αναλ

► Το F-test για έλεγχο πολυπόλωσης

ή το F-test για έλεγχο της $H_0: \beta_1 = 0$ έναντι $H_1: \beta_1 \neq 0$

Για τον έλεγχο αυτόν κατασκευάζουμε t-test ($H_0: \beta_0 = \beta_0^*$, β_1^* γνωστό)

► Ιδέα Γνωρίζουμε ότι $E(USSres) = \sigma^2$

Ισχύει
$$E(USSreg) = \sigma^2 + \beta_1^2 \sum_{i=1}^n (x_i - \bar{x})^2$$

[Πρόβλημα: $E(USSreg) = E\left(\frac{SSreg}{1}\right) = E(SSreg)$

$$= E\left(\beta_1^2 \sum_{i=1}^n (x_i - \bar{x})^2\right)$$

Εφόσον: $\text{Var}(w) = E(w^2) - (E(w))^2$ τα κριτήριο σταθερά

$$\longrightarrow = \sum_{i=1}^n (x_i - \bar{x})^2 E(\beta_1^2)$$

$$= \sum_{i=1}^n (x_i - \bar{x})^2 [\text{Var}(\beta_1) + E(\beta_1)^2]$$

$$= \sum_{i=1}^n (x_i - \bar{x})^2 [\sigma^2 + \beta_1^2 \sum_{i=1}^n (x_i - \bar{x})^2]$$

Οπότε Υπό την εσθνήση $H_0: \beta_1 = 0$, αν δηλαδή η υπόθεση είναι ισχύει τότε $E(USSreg) = E(USSres)$ ή $USSreg \approx USSres$

από προαρισμό λογισμό: Αν $A \Rightarrow B$ τότε $\sim B \Rightarrow \sim A$

Αν $USSres$ πολύ διαφορετικό (Οπότε ενο βρεθ ανάστα για εσθνήση)

$USSreg$

τότε η $H_0: \beta_1 = 0$ δεν ισχύει
αρα απορρ

Αρα ένα τεστ δια του έλεγχου της $H_0: \beta_1 = 0$ μπορεί να ~~επιλεγεί~~

στηριχτεί στην σύγκριση των MS_{reg} και MS_{res} - (και διαλέξω να συσχετίσω βάση το μήκος και όχι την διαφορά του διότι φέρω την κατανομή)

και προτιμώμενος ού $SS_{res}/\sigma^2 \sim \chi^2_{n-1}$ συσχετίσω τα MS_{reg} και MS_{res}

με βάση το μήκος τους: $MS_{reg}/MS_{res} = \frac{SS_{reg}/1}{SS_{res}/(n-2)}$

▶ οπότε αν θέλω να βρω κατανομή για SS_{reg} .

όρα $SS_{reg} = \hat{\beta}_1^2 \sum_{i=1}^n (x_i - \bar{x})^2$

Υπό τις υποθέσεις δια εσφαλμένα

$\hat{\beta}_1 \sim N(\beta_1, \frac{\sigma^2}{\sum_{i=1}^n (x_i - \bar{x})^2})$, υπό την $H_0: \beta_1 = 0$ έχω

$\hat{\beta}_1 \sim N(0, \frac{\sigma^2}{\sum_{i=1}^n (x_i - \bar{x})^2})$

⇓

$\frac{\hat{\beta}_1 - 0}{\sqrt{\frac{\sigma^2}{\sum_{i=1}^n (x_i - \bar{x})^2}}} \sim N(0, 1)$

⇓
 $\frac{\hat{\beta}_1 \sum_{i=1}^n (x_i - \bar{x})^2}{\sigma^2} \sim N(0, 1)$

⇓ και ορα

$\frac{SS_{reg}}{\sigma^2} \sim \chi^2_1$ υπό την συνθήκη $H_0: \beta_1 = 0$

Τελικά θεωρώ την σταθερά συνάρτηση

$F = \frac{MS_{reg}}{MS_{res}} = \frac{SS_{reg}/1}{SS_{res}/(n-2)} = \frac{(SS_{reg}/\sigma^2)/1}{(\sigma^2/\sum_{i=1}^n (x_i - \bar{x})^2)/(n-2)} = \frac{\chi^2_1/1}{\chi^2_{n-2}/(n-2)} \sim F_{1, n-2}$ υπό $H_0: \beta_1 = 0$

οπότε κατάφερα εμπειρικά να βρω την κατανομή

► Άρα ένα τεστ για τον έλεγχο της $H_0: \beta_1 = 0$ μπορεί να κατασκευαστεί

στηρίζεται στην εκτίμηση των MS_{reg} και MS_{res} (και διορθώνεται για ελευθέρους β.ε. βάση το πλήθος των ε.ε. στην διασπορά του διότι τέρμα την κατανομή)

και γνωρίζοντας ότι $SS_{res}/\sigma^2 \sim \chi^2_{n-1}$ ελευθέρων τα MS_{reg} και MS_{res}

με βάση το πλήθος τους: $MS_{reg}/MS_{res} = \frac{SS_{reg}/1}{SS_{res}/(n-2)}$

► οπότε αν θέλουμε να βρούμε κανονική διασπορά για SS_{reg} .

όπου $SS_{reg} = \hat{\beta}_1^2 \sum_{i=1}^n (x_i - \bar{x})^2$

Υπό τις υποθέσεις διασποράς

$\hat{\beta}_1 \sim N(\beta_1, \frac{\sigma^2}{\sum_{i=1}^n (x_i - \bar{x})^2})$, υπό την $H_0: \beta_1 = 0$ έχω

$\hat{\beta}_1 \sim N(0, \frac{\sigma^2}{\sum_{i=1}^n (x_i - \bar{x})^2})$

$\frac{\hat{\beta}_1 - 0}{\sqrt{\frac{\sigma^2}{\sum_{i=1}^n (x_i - \bar{x})^2}}} \sim N(0, 1)$

$\frac{\hat{\beta}_1 \sum_{i=1}^n (x_i - \bar{x})^2}{\sigma^2} \sim N(0, 1)$

↓ και άρα

$\frac{SS_{reg}}{\sigma^2} \sim \chi^2_1$ υπό την ελευθέρων $H_0: \beta_1 = 0$

Τελικά θεωρώ την παρακάτω αναγωγή

$F = \frac{MS_{reg}}{MS_{res}} = \frac{SS_{reg}/1}{SS_{res}/(n-2)} = \frac{(SS_{reg}/\sigma^2)/1}{(SS_{res}/\sigma^2)/(n-2)} = \frac{\chi^2_1/1}{\chi^2_{n-2}/(n-2)} \sim F_{1, n-2}$ υπό $H_0: \beta_1 = 0$

οπότε κατάφερα επιπλέον να βρω MS_{reg} και MS_{res} να βρω την κατανομή

► Για του έλεγχου της $H_0: \beta_1 = 0$ η εκασθενη συνάρτηση τεστ είναι $F = \frac{MS_{reg}}{MS_{res}}$ με κατανομή $F_{1, n-2}$ υπό H_0 και υ.π της κορης θεωρητικής τιμής του F δηλ $F \geq c$: υφιστη ενλεια

Χαι για να ολοκληρωσω βρισω το υφιστη ενλεια αντε Υποβαλετός

$$\alpha = P(\text{απορθη} / H_0 \text{ αληθη}) = P(F \geq c \mid F \sim F_{1, n-2}) \\ = P(F_{1, n-2} \geq c) = \boxed{c = F_{1, n-2, \alpha}}$$

δηλαδή $F \geq F_{1, n-2, \alpha}$

Παρατηρηση: Το F-test ισοδυναμει με +-test διαιτι:

$$\bullet F = \frac{MS_{reg}}{MS_{res}} = \frac{SS_{reg}}{MS_{res}} = \frac{\hat{\beta}_1^2 \sum (x_i - \bar{x})^2}{MS_{res}} \\ = \left(\frac{\hat{\beta}_1}{\sqrt{\frac{MS_{res}}{\sum (x_i - \bar{x})^2}}} \right)^2 = \left(\frac{\hat{\beta}_1 - 0}{\sqrt{Var(\hat{\beta}_1)}} \right)^2 = t^2$$

(δηλ παρόλου που εχα διαφορετικη προσέδωση για δύο τεστ τελικα αυτα είναι ισοδυναμια)


Συντελεστή Συνέλιξης Pearson

Γνωστική μορφή : Αν x, y είναι τ.β $\rho(x, y) = \frac{\text{Cov}(x, y)}{\sqrt{\text{Var}(x)} \sqrt{\text{Var}(y)}}$


ο Δεσφασμένη μορφή : Αν έχω τ.β : x_1, \dots, x_n y_1, \dots, y_n $\rho(x, y) = \frac{\sum (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum (x_i - \bar{x})^2} \sqrt{\sum (y_i - \bar{y})^2}}$

- Ιδιότητες :
1. είναι αριθμός
 2. συμμετρικός $\rho_{xy} = \rho_{yx}$
 3. $-1 \leq \rho_{xy} \leq 1$

Το ρ_{xy} μετράει την διαφορά διασποράς



$$\rho_{xy} = 1$$



$$\rho_{xy} = -1$$

$\rho_{xy} = 0 \Leftrightarrow$ ορθογώνια σχέση μεταξύ των x, y




- Αν $r_{xy} = 0$ τότε \neq απαραιτητή σχέση κινούμενη όπως άλλου είδους σχέση

Παράδειγμα

X	-3	1	0		β
Y	9.54	9.97	10		9.97, 9.54

$r_{xy} = 0$ Άρα \neq απαραιτητή σχέση αλλά

$$\underline{\underline{X^2 + Y^2 = 100}}$$



Απειρίσιμη αν. φωνή

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

Ισχύουν οι υποθέσεις εφάρμοστα $\epsilon_i \sim N(0, \sigma^2)$

N.D.O ΕΕΤ = ΕΜΠ

Να βρεθεί ΕΜΠ της σ^2 (Αδυναμία διαίρεσης)

Σ (Στατιστική Στοιχειώδης): Έστω x_1, \dots, x_n τ.δ. από πληθυσμό με κατανομή $F(x_i, \theta)$

Ευαίτητος δια το θ

Ευαίτητη Μέγιστη Πιθανοφάνεια CEM.Π. δια το θ

Πιθανοφάνεια: $L = L(\theta) = \prod_{i=1}^n f(x_i, \theta)$

Ο ΕΜΠ $\hat{\theta}$ είναι εκείνος ο οποίος μεγιστοποιεί ως προς θ την L ή την $\log L$ δια βέβαιου $\log L$: $\frac{\partial L}{\partial \theta} = 0 \quad \hat{\theta} = \dots$

• ΕΕΤ προκύπτουν από ελαστικές των β_0, β_1 . $S = \sum_{i=1}^n e_i^2 = \sum (y_i - \beta_0 - \beta_1 x_i)^2$ (*)

• Πιθανοφάνεια: $L = L(\beta_0, \beta_1) = \prod f_{y_i}(y_i)$

$$Y_i \sim N(\beta_0 + \beta_1 x_i, \sigma^2)$$

$$f_{y_i}(y_i) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-1/2\sigma^2 (y_i - \beta_0 - \beta_1 x_i)^2}$$

$$L(\beta_0, \beta_1) = \prod_{i=1}^n \frac{1}{\sqrt{2\pi\sigma^2}} e^{-1/2\sigma^2 (y_i - \beta_0 - \beta_1 x_i)^2}$$

$$= \frac{1}{(2\pi\sigma^2)^{n/2}} e^{-1/2\sigma^2 \sum_{i=1}^n (y_i - \beta_0 - \beta_1 x_i)^2}$$

$$\log L(\beta_0, \beta_1) = -\frac{n}{2} \log(2\pi) - \frac{n}{2} \log \sigma^2 - \frac{1}{2\sigma^2} \sum (y_i - \beta_0 - \beta_1 x_i)^2$$

Μακρύτερα ποιοι όροι έχουν β_0, β_1 στα σημεία βελτιστοποίησης


ως προς β_0, β_1 το $\log L$ δηλ του όρου $-\frac{1}{2\sigma^2} \sum (y_i - \beta_0 - \beta_1 x_i)^2$

Άρα αρκεί να βελτιστοποιήσω το $-\sum_{i=1}^n (y_i - \beta_0 - \beta_1 x_i)^2$

Άρα αρκεί να βελτιστοποιήσω το $\sum_{i=1}^n (y_i - \beta_0 - \beta_1 x_i)^2$ (**)

από (*) και (**) \rightarrow ΕΕΤ = ΕΜΜ

$$\text{(για } \sigma^2 \text{ παίρνω } \frac{\partial}{\partial \sigma^2} \log L(\hat{\beta}_0, \hat{\beta}_1) = 0$$



$$\hat{\sigma}^2 = \frac{1}{n} S_{res} = \frac{n-2}{n} \mu_{res}, \text{ Παρατήρηση ο ΕΜΜ } \hat{\sigma}^2 \text{ του } \sigma^2 \text{ δα είναι αμερόληπτος}$$

Άσκηση 2

a. $\hat{\beta}_1 \sim N(\cdot)$, $\hat{\beta}_0 \sim N(\beta_0, \sigma^2 \left\{ \frac{1}{n} + \frac{\bar{x}^2}{\sum (y_i - \bar{x})^2} \right\}) = \frac{\sigma^2 \sum x_i^2}{n \sum (y_i - \bar{x})^2}$

↳ το έχουμε αποδείξει

Λύση

$\hat{\beta}_0 = \bar{y} - \hat{\beta}_1 \bar{x}$. Υπόθεση αρχικά β_0 και διασπορά σ^2

- $$E(\hat{\beta}_0) = E(\bar{y} - \hat{\beta}_1 \bar{x}) = E(\bar{y}) - \bar{x} E(\hat{\beta}_1)$$

$$= E\left(\frac{1}{n} \sum y_i\right) - \bar{x} \beta_1$$

$$= \frac{1}{n} E(\sum y_i) - \bar{x} \beta_1$$

$$= \frac{1}{n} \sum_{i=1}^n E(\beta_0 + \beta_1 x_i + \epsilon_i) - \bar{x} \beta_1$$

$$= \frac{1}{n} \sum_{i=1}^n (\beta_0 + \beta_1 x_i) - \bar{x} \beta_1$$

$$= \beta_0 + \beta_1 \bar{x} - \bar{x} \beta_1 = \beta_0$$

- $$Var(\hat{\beta}_0) = Var(\bar{y} - \hat{\beta}_1 \bar{x})$$

[Επειδή $Var(\sum_{i=1}^n a_i w_i) = \sum_{i=1}^n a_i^2 Var(w_i) + \sum_{i=1}^n \sum_{j=1, j \neq i}^n a_i a_j Cov(w_i, w_j)$

όπου

$$Var(\hat{\beta}_0) = Var(\bar{y}) + \bar{x}^2 Var(\hat{\beta}_1) - \bar{x} Cov(\bar{y}, \hat{\beta}_1)$$

$$= Var(\bar{y}) + \bar{x}^2 Var(\hat{\beta}_1)$$

- $$Var(\bar{y}) = \frac{\sigma^2}{n}$$

[Επειδή $Var(\bar{y}) = Var\left(\frac{1}{n} \sum y_i\right) = \frac{1}{n^2} Var(\sum y_i)$

y_i ανεξάρτητα $\frac{1}{n^2} \sum Var(y_i) = \frac{1}{n^2} \sum \sigma^2$

$$= \frac{n}{n^2} \sigma^2 = \frac{\sigma^2}{n}$$

όρα

$$\text{Var}(\hat{\beta}_0) = \frac{\sigma^2}{n} + \bar{x}^2 (\text{Var}(\hat{\beta}_1)) = \frac{\sigma^2}{n} + \bar{x}^2 \frac{\sigma^2}{\sum (x_i - \bar{x})^2}$$

$$= \sigma^2 \left\{ \frac{1}{n} + \frac{\bar{x}^2}{\sum (x_i - \bar{x})^2} \right\}$$

Το $\hat{\beta}_0 = \bar{y} - \hat{\beta}_1 \bar{x}$ είναι άρρηκώς συνδεδεμένος των αυθόρμητων μεταβλητών \bar{y} και $\hat{\beta}_1 \Rightarrow \hat{\beta}_0 \sim N(\mathbb{E}(\hat{\beta}_0), \text{Var}(\hat{\beta}_0))$

ⓑ να δείξω $\sum_{i=1}^n y_i e_i = 0 \quad (x \perp e)$

$$\begin{aligned} \bullet \sum_{i=1}^n x_i e_i &= \sum_{i=1}^n x_i (y_i - \hat{y}_i) = \sum_{i=1}^n x_i y_i - \sum_{i=1}^n x_i \hat{y}_i \\ &= \sum x_i y_i - \sum x_i (\hat{\beta}_0 + \hat{\beta}_1 x_i) \\ &= \sum x_i y_i - \hat{\beta}_0 \sum x_i - \hat{\beta}_1 \sum x_i^2 \quad (\text{το οποίο ευπρόσθως} \\ &\quad \text{όπως δειχνάει 'ο'}) \end{aligned}$$

όπως υπονοείται επίσης $\bullet \beta_0 \sum x_i + \beta_1 \sum x_i^2 = \sum x_i y_i$

το οποίο εναρμόζεται στο τα $\hat{\beta}_0, \hat{\beta}_1$,

$$\text{Από} \quad \underline{\sum x_i y_i - \hat{\beta}_0 \sum x_i - \hat{\beta}_1 \sum x_i^2 = 0}$$

$$\text{ⓓ} \quad \text{Cov}(\hat{\beta}_0, \hat{\beta}_1) = \text{Cov}(\bar{y} - \bar{x} \hat{\beta}_1, \hat{\beta}_1)$$

$$\begin{aligned} \text{Από} \quad \text{επειδή} \quad \text{Cov}(\hat{\beta}_0, \hat{\beta}_1) &= \text{Cov}(\bar{y}, \hat{\beta}_1) - \bar{x} \text{Cov}(\hat{\beta}_1, \hat{\beta}_1) \\ &= -\bar{x} \text{Var}(\hat{\beta}_1) \\ &= -\bar{x} \frac{\sigma^2}{\sum (x_i - \bar{x})^2} \end{aligned}$$