

ΕΡΩΤΗΣΕΙΣ ΠΟΛΛΑΠΛΗΣ ΕΠΙΛΟΓΗΣ

Θεωρήστε το απλό γραμμικό μοντέλο :

$$Y_i = \beta_0 + \beta_1 x_i + \epsilon_i, \quad i = 1, \dots, n, \quad (1)$$

Για τα σφάλματα ϵ_i υποθέστε πως έχουν μέση τιμή 0 και είναι ομοσκεδαστικά ($\text{var}(\epsilon_i) = \sigma^2$) και ασυσχέτιστα ($\text{cov}(\epsilon_i, \epsilon_j) = 0$ για $i \neq j$). Οι ερωτήσεις 1-5 αφορούν αυτό το μοντέλο.

1. Οι παράμετροι που πρέπει να εκτιμηθούν είναι:
 - a. (x_i, y_i) , $i = 1, \dots, n$.
 - b. ϵ_i , $i = 1, \dots, n$.
 - c. $\beta_0, \beta_1, E(\epsilon_i^2)$.
 - d. $\beta_0, \beta_1, E(\epsilon_i)$.
2. Η ευθεία ελαχίστων τετραγώνων 'περνάει' πάντα από το σημείο
 - a. 0
 - b. $(0, \bar{x})$
 - c. $(0, \bar{y})$
 - d. (\bar{x}, \bar{y})
3. Για τα υπόλοιπα της παλινδρόμησης, $\hat{\epsilon}_i = Y_i - \hat{\beta}_0 - \hat{\beta}_1 x_i$, ισχύει
 - a. $\text{var}(\hat{\epsilon}_i) = \sigma^2$
 - b. $\text{var}(\hat{\epsilon}_i) < \text{var}(\epsilon_i)$
 - c. $\text{var}(\hat{\epsilon}_i) > \text{var}(\epsilon_i)$
 - d. $\text{var}(\hat{\epsilon}_i) = \text{var}(\epsilon_i)$
4. Τι από τα παρακάτω ΔΕΝ ΙΣΧΥΕΙ απαραίτητα
 - a. $\sum x_i \hat{\epsilon}_i = 0$
 - b. $\sum x_i \hat{\epsilon}_i = E(\sum x_i \epsilon_i)$
 - c. $\sum x_i \hat{\epsilon}_i = \sum \hat{\epsilon}_i$
 - d. $\sum x_i \hat{\epsilon}_i > \sum \hat{\epsilon}_i$
5. Τι από τα παρακάτω ΔΕΝ ΙΣΧΥΕΙ απαραίτητα
 - a. Το 10% διάστημα πρόβλεψης σε τιμή $x = x_0$ είναι πλατύτερο από το αντίστοιχο 99,99% διάστημα εμιστοσύνης
 - b. Το 95% διάστημα πρόβλεψης σε τιμή $x = x_0$ είναι στενότερο από το 99% διάστημα πρόβλεψης
 - c. Το 95% διάστημα πρόβλεψης σε τιμή $x = x_0$ είναι πλατύτερο από το αντίστοιχο 95% διάστημα εμιστοσύνης

- d. Το 95% διάστημα πρόβλεψης σε τιμή $x = x_0$ είναι πλατύτερο από το αντίστοιχο 90% διάστημα εμιστοσύνης

Θεωρήστε το κανονικό γραμμικό μοντέλο :

$$\begin{aligned} \mathbf{Y} &= \mathbf{X}\boldsymbol{\beta} + \boldsymbol{\epsilon} \\ \boldsymbol{\epsilon} &\sim N(\mathbf{0}_n, \sigma^2 \mathbf{I}_n), \end{aligned} \quad (2)$$

όπου για τον $n \times p$ πίνακα συμμεταβλητών \mathbf{X} ισχύει $\text{rank}(\mathbf{X}) = p$, $\mathbf{0}_n$ είναι ένα $n \times 1$ διάνυσμα με μηδενικά, \mathbf{I}_n είναι ένας $n \times n$ ταυτοτικός πίνακας με μοναδες στην διαγώνιο και μηδενικά εκτος διαγωνίου. Οι ερωτήσεις 6-12 αφορούν αυτό το μοντέλο

6. Τι από τα παρακάτω ΔΕΝ ΙΣΧΥΕΙ

- $\mathbf{X}^T \mathbf{Y} = \mathbf{X}^T \hat{\mathbf{Y}}$
- $\mathbf{X} \mathbf{Y} = \mathbf{X} \hat{\mathbf{Y}}$
- $\sum \hat{\epsilon}_i = 0$
- $\sum_{i=1}^n x_{ij} \hat{\epsilon}_i = 0, \forall j$

7. Ισχύει πως

- $\frac{1}{\sigma^2} (\mathbf{Y} - \mathbf{X}\boldsymbol{\beta})^T (\mathbf{Y} - \mathbf{X}\boldsymbol{\beta}) \sim \chi_n^2$
- $\frac{1}{\sigma^2} (\mathbf{Y} - \mathbf{X}\hat{\boldsymbol{\beta}})^T (\mathbf{Y} - \mathbf{X}\hat{\boldsymbol{\beta}}) \sim \chi_n^2$
- $\frac{1}{\sigma^2} (\mathbf{Y} - \mathbf{X}\boldsymbol{\beta})^T (\mathbf{Y} - \mathbf{X}\boldsymbol{\beta}) \sim F_{p, n-p}$
- Τίποτα από τα παραπάνω

8. Μια αμερόληπτη εκτιμήτρια της σ^2 είναι

- $\frac{1}{n-p} (\mathbf{Y} - \mathbf{X}\hat{\boldsymbol{\beta}})^T (\mathbf{Y} - \mathbf{X}\hat{\boldsymbol{\beta}})$
- $\frac{1}{n-1} (\mathbf{Y} - \mathbf{X}\hat{\boldsymbol{\beta}})^T (\mathbf{Y} - \mathbf{X}\hat{\boldsymbol{\beta}})$
- $\frac{1}{n} (\mathbf{Y} - \mathbf{X}\hat{\boldsymbol{\beta}})^T (\mathbf{Y} - \mathbf{X}\hat{\boldsymbol{\beta}})$
- $\frac{1}{\sigma^2} (\mathbf{Y} - \mathbf{X}\boldsymbol{\beta})^T (\mathbf{Y} - \mathbf{X}\boldsymbol{\beta})$

9. Έστω πως $n = 100, p = 5$. Θέλουμε να ελέγξουμε ταυτόχρονα τις εξής 3 μηδενικές υποθέσεις: Α) $\beta_0 = 2$, Β) $\beta_1 = \beta_2$, Γ) $\beta_4 = 0$. Αυτό είναι ισοδύναμο με έλεγχο της μηδενικής υπόθεσης $H_0 : \mathbf{R}\boldsymbol{\beta} = \mathbf{r}$, όπου

a.

$$\mathbf{R} = \begin{bmatrix} 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 \end{bmatrix}, \mathbf{r} = \begin{bmatrix} 0 \\ 0 \\ 0 \end{bmatrix}$$

b.

$$\mathbf{R} = \begin{bmatrix} 0 & 1 & -1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 \\ 1 & 0 & 0 & 0 & 0 \end{bmatrix}, \mathbf{r} = \begin{bmatrix} 0 \\ 0 \\ 0 \end{bmatrix}$$

c.

$$\mathbf{R} = \begin{bmatrix} 0 & 1 & -1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 \\ 1 & 0 & 0 & 0 & 0 \end{bmatrix}, \mathbf{r} = \begin{bmatrix} 0 \\ 0 \\ 2 \end{bmatrix}$$

d.

$$\mathbf{R} = \begin{bmatrix} 1 & -1 & 0 \\ 0 & 0 & 1 \\ 1 & 0 & 0 \end{bmatrix}, \mathbf{r} = \begin{bmatrix} 0 \\ 0 \\ 2 \end{bmatrix}$$

10. (Συνέχεια της προηγούμενης.) Η κλασσική σ.σ.ε., έστω U , της μηδενικής υπόθεσης παραπάνω θα έχει ποιά κατανομή, κάτω από την μηδενική υπόθεση
- χ_{99}^2
 - $N(0, 1)$
 - $F_{3,95}$
 - t_{95}
11. (Συνέχεια της προηγούμενης.) Αν η τιμή της σ.σ.ε. παραπάνω, u , που παρατηρήσαμε ισούται με 4, τότε το p -value του παραπάνω ελέγχου είναι
- $P(U > 4|H_0)$
 - $2 \times P(U > 4|H_0)$
 - $P(U > 4|H_0) + P(U < -4|H_0)$
 - Τίποτα από τα παραπάνω

Θεωρήστε το παρακάτω *output* από τη προσαρμογή μοντέλου παλινδρόμησης σε μη-καπνιστές. Η απόκριση είναι ο λογάριθμος της τιμής της σπιρομέτρησης και οι συμμεταβλητές είναι η ηλικία (*age*, σε έτη) το ύψος (*ht*, σε ίντσες) και το φύλο (*sex*: 0 για τα κορίτσια, 1 για τα αγόρια). Τα *Adj SS* αναφέρονται στο άθροισμα τετραγώνων που εξηγείται από έναν παράγοντα υπό την παρουσία όλων των υπολοίπων συμμεταβλητών, ενώ τα *Seq SS* είναι το άθροισμα τετραγώνων που εξηγείται από έναν παράγοντα υπό την παρουσία των προηγούμενων συμμεταβλητών που εισήχθησαν στο μοντέλο. Όπως αναφέρεται και στο *output* οι έλεγχοι στον πίνακα *Anova* βασίζονται στα *Seq SS*. Οι ερωτήσεις 12-18 αναφέρονται σε αυτό το *output*.

NON-SMOKERS

Regression Analysis: ln(FEV) versus age; ht; sex

Regression Equation

$$\ln(\text{FEV}) = -1,9059 + 0,02587 \text{ age} + 0,04178 \text{ ht} + 0,0290 \text{ sex}$$

Coefficients

Term	Coef	SE Coef	95% CI	T-Value	P-Value	VIF
Constant	-1,9059	0,0820	(-2,0670; -1,7448)	-23,23	0,000	
age	0,02587	0,00366	(0,01867; 0,03306)	7,06	0,000	2,92
ht	0,04178	0,00179	(0,03826; 0,04530)	23,30	0,000	2,99
sex	0,0290	0,0120	(0,0053; 0,0526)	2,41	0,016	1,05

Model Summary

S	R-sq	R-sq(adj)	PRESS	R-sq(pred)	AICc	BIC
0,142516	81,63%	81,54%	12,0567	81,36%	-617,50	-595,71

Analysis of Variance

Source	DF	Seq SS	Contribution	Adj SS	Seq MS	F-Value	P-Value
Regression	3	52,8000	81,63%	52,8000	17,6000	866,53	0,000
age	1	40,6713	62,88%	1,0122	40,6713	2002,44	0,000
ht	1	12,0111	18,57%	11,0290	12,0111	591,37	0,000
sex	1	0,1175	0,18%	0,1175	0,1175	5,79	0,016
Error	585	11,8819	18,37%	11,8819	0,0203		
Lack-of-Fit	309	6,3964	9,89%	6,3964	0,0207	1,04	0,365
Pure Error	276	5,4854	8,48%	5,4854	0,0199		
Total	588	64,6818	100,00%				

Tests use the sequential sums of squares

12. Στην παραπάνω έρευνα έλαβαν μέρος
- 584 άτομα
 - 585 άτομα
 - 589 άτομα
 - 588 άτομα
13. Από το output μπορούμε να πουμε πως προσεγγιστικά ισχύει
- $P(F > 2, 41) = 0,016$, όπου $F \sim F_{1,585}$.
 - $P(T > 2, 41) = 0,008$, όπου $T \sim t_{585}$.
 - $P(T > 2, 41) = 0,016$, όπου $T \sim t_{585}$.
 - $P(F > 5, 79) = 0,008$, όπου $F \sim F_{1,585}$.
14. Βάσει του μοντέλου ισχύει πως
- Με 95% εμπιστοσύνη τα αγόρια είναι κατά μέσο όρο από 0,03826 ως 0,04530 ίντσες ψηλότερα από συνομίλικα κορίτσια.
 - Με 95% εμπιστοσύνη τα αγόρια έχουν κατά μέσο όρο από 0,0053 ως 0,0526 ψηλότερη τιμή $\ln(\text{FEV})$ από συνομίλικα κορίτσια.
 - Με 95% εμπιστοσύνη τα αγόρια έχουν κατά μέσο όρο από 0,0053 ως 0,0526 ψηλότερη τιμή $\ln(\text{FEV})$ από κορίτσια του ίδιου ύψους.
 - Τίποτα από τα παραπάνω
15. Η τιμή της αμερόληπτης εκτιμήτριας της διασποράς των σφαλμάτων είναι
- 0,142516
 - 0,0203
 - 0,1175
 - 1,9059
16. Θεωρήστε το μοντέλο $E(\ln(\text{FEV})) = \beta_0 + \beta_1 \times \text{age} + \beta_2 \times \text{ht}$, και την μηδενική υπόθεση $H_0 : \beta_2 = 0$. Η τιμή του p -value του δίπλευρου ελέγχου της H_0 ισούται με
- $P(|T| > 23, 30)$, όπου $T \sim t_{585}$.
 - $P(T > 23, 30)$, όπου $T \sim t_{585}$.
 - $P(F > 591, 37)$, όπου $F \sim F_{1,586}$.
 - $P(F > 11, 0290)$, όπου $F \sim F_{1,585}$.
17. Θεωρήστε το μοντέλο $E(\ln(\text{FEV})) = \beta_0 + \beta_1 \times \text{age} + \beta_2 \times \text{ht}$. Μια αμερόληπτη εκτιμήτρια του β_1 ισούται με
- 0,029
 - 0,04178
 - 0,02587

- d. Τίποτα από τα παραπάνω
18. Θεωρήστε το πλήρες μοντέλο $E(\ln(FEV)) = \beta_0 + \beta_1 \times age + \beta_2 \times ht + \beta_3 \times sex$, και την μηδενική υπόθεση $H_0 : \beta_1 = \beta_2 = \beta_3 = 0$. Η τιμή του p -value του ελέγχου της H_0 ισούται με
- $P(|T| > 23, 23)$, όπου $T \sim t_{585}$.
 - $P(F > 866, 53)$, όπου $F \sim F_{1,585}$.
 - $P(F > 866, 53)$, όπου $F \sim F_{3,585}$.
 - $P(F > 866, 53)$, όπου $F \sim F_{2,586}$.
19. Σε ποιά από τα παρακάτω μοντέλα ΔΕΝ μπορείτε να εφαρμόσετε τις μεθόδους γραμμικής παλινδρόμησης που διδαχτήκατε στο μάθημα για την εκτίμηση των παραμέτρων
- $Y_i = \beta_0 + \beta_1 x_i^2 + \epsilon_i$, $\epsilon_1, \dots, \epsilon_n \sim^{iid} N(0, \sigma^2)$.
 - $Y_i = e^{\beta_0} e^{\beta_1 x_i + \epsilon_i}$, $\epsilon_1, \dots, \epsilon_n \sim^{iid} N(0, \sigma^2)$.
 - $Y_i = \frac{1}{e^{\beta_0 + \beta_1 x_i}} + \epsilon_i$, $\epsilon_1, \dots, \epsilon_n \sim^{iid} N(0, \sigma^2)$.
 - $Y_i = e^{\beta_0} e^{\beta_1 x_i^2 + \epsilon_i}$, $\epsilon_1, \dots, \epsilon_n \sim^{iid} N(0, \sigma^2)$.
20. Αν Z_α , $\chi_{n;\alpha}^2$, $t_{n;\alpha}$ και $F_{n_1, n_2; \alpha}$ είναι τα α -άνω ποσοστιαία σημεία των Z , χ_n^2 , t_n και F_{n_1, n_2} κατανομών αντίστοιχα ($\alpha < 0.5$), τότε τι από τα παρακάτω ΔΕΝ ισχύει
- $F_{n_1, n_2; \alpha} \rightarrow \chi_{n_2; \alpha}^2$, όταν $n_1 \rightarrow \infty$.
 - $F_{n_1, n_2; \alpha} \rightarrow \frac{1}{n_1} \chi_{n_1; \alpha}^2$, όταν $n_2 \rightarrow \infty$.
 - $t_{n; \alpha} \rightarrow Z_\alpha$ όταν $n \rightarrow \infty$.
 - $t_{n; \alpha} > t_{n+1; \alpha} \forall n$.

Σωστές Απαντήσεις: