

## 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  $\epsilon_i$  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.  $\epsilon_i$ ,  $i = 1, \dots, n$ .
  - 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  $\sigma^2$  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
- a.  $\chi_{99}^2$
  - b.  $N(0, 1)$
  - c.  $F_{3,95}$
  - d.  $t_{95}$
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
- a.  $P(U > 4|H_0)$
  - b.  $2 \times P(U > 4|H_0)$
  - c.  $P(U > 4|H_0) + P(U < -4|H_0)$
  - d. 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 συνομιλικά κορίτσια.
  - Με 95% εμπιστοσύνη τα αγόρια έχουν κατά μέσο όρο από 0,0053 ως 0,0526 ψηλότερη τιμή  $\ln(\text{FEV})$  από συνομιλικά 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  $\beta_1$  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  $Z_\alpha$ ,  $\chi_{n;\alpha}^2$ ,  $t_{n;\alpha}$  και  $F_{n_1, n_2; \alpha}$  είναι τα  $\alpha$ -άνω ποσοστιαία σημεία των  $Z$ ,  $\chi_n^2$ ,  $t_n$  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:

1. c
2. d
3. b
4. d
5. a
  
6. b
7. a
8. a
9. c
10. c
11. a
  
12. c
13. b
14. d
15. b
16. c
17. d
18. c
  
19. c
20. a