

!! Επιλέξτε 4 Ζητήματα από τα 7 !!

ZHTHMA 1

(α) Αφού διαιρεθούν όλοι οι όροι του προσαρμοσμένου απλού γραμμικού μοντέλου $\hat{y} = \hat{\beta}_0 + \hat{\beta}_1 x$, με τη δειγματική τυπική απόκλιση των y -παρατηρήσεων $\sqrt{S_{yy}/(n-1)}$ και μετασχηματιστεί το x ως $x' = x / \sqrt{S_{xx}/(n-1)}$, δείξτε ότι ο συντελεστής του νέου x' είναι απλά ο συντελεστής συσχέτισης r_{xy} του Pearson (S_{xx} και S_{yy} είναι τα αθροίσματα τετραγώνων των x και y παρατηρήσεων αντίστοιχα).

(β) Δείξτε ότι στο γενικό γραμμικό μοντέλο με τη σταθερά $E(y) = X\beta$, ισχύουν ότι

$$(i) \text{cov}(y_i, \hat{y}_i) = \sigma^2 h_{ii}, \text{ όπου } h_{ii} = x_i'(X'X)^{-1}x_i, \text{ τα διαγώνια στοιχεία του πίνακα } H = X(X'X)^{-1}X',$$

$$(ii) X'e = 0 \text{ και } (iii) \sum_{i=1}^n e_i = 0. \quad (\text{Βαθμ. 2.5})$$

ZHTHMA 2

(i) Δείξτε ότι η εκτιμήτρια μέγιστης πιθανοφάνειας της παραμέτρου β στο γενικό γραμμικό μοντέλο $y = X\beta + \epsilon$, $\epsilon \sim N_n(0, \sigma^2 I_n)$ είναι $\hat{\beta} = (X'X)^{-1}X'y$, και η αντίστοιχη της σ^2 είναι η $\hat{\sigma}^2 = SSE/n$, όπου X ο πίνακας σχεδιασμού και SSE το άθροισμα τετραγώνων λόγω σφάλματος.

(ii) Δείξτε ότι η μεγιστοποιημένη λογαριθμοποιημένη συνάρτηση πιθανοφάνειας για το γενικό γραμμικό μοντέλο είναι $\hat{l}(\hat{\beta}, \hat{\sigma}^2) = -\frac{n}{2} [\ln(2\pi SSE/n) + 1]$ και στη συνέχεια βρείτε το κριτήριο $AIC = -2\hat{l}(\hat{\beta}, \hat{\sigma}^2) + 2d$ για το μοντέλο αυτό, όπου d ο συνολικός αριθμός παραμέτρων στο μοντέλο.

(Βαθμ. 2.5)

ZHTHMA 3

Έστω δύο γενικά γραμμικά μοντέλα παλινδρόμησης M_0 και M_1 , όπου $M_0 \subset M_1$ και το μοντέλο M_0 με μια μεταβλητή λιγότερο.

(α) Εξηγείστε πώς θα επιλέξτε το καλύτερο μοντέλο από τα δύο, με βάση

(i) έναν έλεγχο F και (ii) το κριτήριο AIC .

(β) Δείξτε ότι $\bar{R}_1^2 > \bar{R}_0^2 \Leftrightarrow F = \frac{SSE_0 - SSE_1}{SSE_1/(n-p)} > 1$, όπου $\bar{R}_i^2 = 1 - \frac{SSE_i/(n-p)}{SST/(n-1)}$, ο διορθωμένος συντελεστής προσδιορισμού.

(Βαθμ. 2.5)

ZHTHMA 4

Εξετάζεται η γραμμική παλινδρόμηση της Y σε σχέση με τις επεξηγηματικές μεταβλητές X_1, X_2, X_3 . Με βάση τον παρακάτω πίνακα και για μέγεθος δειγματος $n=10$, να βρεθεί το καταλληλότερο μοντέλο, κάνοντας χρήση ενός ελέγχου F , καθώς και του κριτηρίου AIC , όπου κρίνετε ότι είναι απαραίτητο.

Πλήθος

μεταβλητών στο μοντέλο	R^2	\bar{R}^2	C_p (Mallows)	S	X_1	X_2	X_3
------------------------	-------	-------------	-----------------	-----	-------	-------	-------

$$\begin{array}{c} 1 \\ \rightarrow 2 \\ \rightarrow 3 \end{array} \quad \begin{array}{c} 87.7 \\ 64.7 \\ 96.3 \\ 90.3 \\ 97.1 \end{array} \quad \begin{array}{c} 86.1 \\ 60.3 \\ 95.2 \\ 87.5 \\ 95.7 \end{array} \quad \begin{array}{c} 19.7 \\ 67.5 \\ 3.7 \\ 16.2 \\ 4.0 \end{array} \quad \begin{array}{c} 3.0242 \\ 5.1207 \\ 1.7765 \\ 2.8699 \\ 1.6888 \end{array} \quad \begin{array}{c} X \\ X \\ X \\ X \\ X \end{array}$$

$(S = (e'e/(n-k-1))^{1/2})$ (Βαθμ. 2.5)

ZHTHMA 5

Κατασκευαστής θέλει να εξετάσει αν υπάρχουν διαφορές μεταξύ τεσσάρων τύπων λίπους, ως προς την απορροφητικότητά τους, κατά τη διάρκεια παρασκευής συγκεκριμένης τροφής. Κάθε τύπος χρησιμοποιήθηκε σε 5 τυχαία επιλεγμένα δείγματα τροφής από συνολικά 20 δείγματα, επίσης τυχαία επιλεγμένα.

1	2	3	4
64	78	75	55
72	91	93	66
68	97	78	49
56	85	63	57
95	77	76	45

Υιοθετώντας την κωδικοποίηση

$$x_1 = \begin{cases} 1, & \text{αν } \tauύπος 1 \\ 0, & \text{αλλιώς} \end{cases} \quad x_2 = \begin{cases} 1, & \text{αν } \tauύπος 2 \\ 0, & \text{αλλιώς} \end{cases} \quad x_3 = \begin{cases} 1, & \text{αν } \tauύπος 3 \\ 0, & \text{αλλιώς} \end{cases}$$

προσαρμόζεται στα δεδομένα το μοντέλο παλινδρόμησης $E(y) = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3$.

(i) Να γίνει ο έλεγχος $H_0: \beta_1 = \beta_2 = \beta_3 = 0$ με εναλλακτική H_1 : τουλάχιστον ένα $\beta_j \neq 0$.

[Δίνονται $\sum_{i=1}^c \sum_{j=1}^n y_{ij}^2 = 108152$, SSR=2603.6].

(ii) Να συμπληρωθεί και να ερμηνευτεί ο παρακάτω πίνακας

Μεταβλητές	$\hat{\beta}$	se($\hat{\beta}$)	t	p-τιμή
Σταθερά	54.400	4.833		
X_1	16.600	6.834		
X_2	31.200	6.834		
X_3	22.600	6.834		

(Βαθμ. 2.5)

ZHTHMA 6 Εξετάζεται η σχέση μεταξύ της παραγωγής ζαχαρότευτλου Y (x 1000 τόνους), του έτους παραγωγής X_2 και της αντίστοιχης για το έτος, μέσης θερμοκρασίας X_1 ($^{\circ}$ C). (i) Συμπληρώστε τον παρακάτω πίνακα. Σχολιάστε τα αποτελέσματά σας.

Το προσαρμοσμένο μοντέλο παλινδρόμησης είναι:

$$\hat{y} = 342 + 6.23 X_1 + 21.0 X_2$$

Μεταβλητές	$\hat{\beta}$	se($\hat{\beta}$)	t	p-τιμή	VIF
Σταθερά	341.950	85.280			
X_1	6.232	4.244			
X_2	20.977	3.996			

$$S = 33.1958, R^2 = \underline{\hspace{2cm}} \%, \bar{R}^2 = \underline{\hspace{2cm}} \%, r_{X_1 X_2} = -0.404$$

Ανάλυση Διασποράς

Πηγή	β.ε.	AT	MAT	F	p-τιμή
Παλινδρόμηση		30936			
Σφάλμα					
Σύνολο	9	38650			

(ii) Για το παραπάνω μοντέλο δίνεται ότι $h_{33} = 0.925$. Αποτελεί η τρίτη παρατήρηση σημείο επιρροής;

(iii) Να κατασκευαστεί ένα 0.99-διάστημα εμπιστοσύνης για το συντελεστή β_2 του έτους παραγωγής.

(Βαθμ. 2.5)

ZHTHMA 7

Έστω μοντέλο της κατανομής Poisson $f(y) = \frac{\exp(-\mu) \mu^y}{y!}, y=0,1,2,\dots$.

(i) Πώς μπορούμε να εισάγουμε συμμεταβλητές x σε αυτό το μοντέλο, ώστε στη συνέχεια να μπορεί να εξεταστεί πιθανή εξάρτηση της y από τις x .

(ii) Τι είναι μια συνάρτηση σύνδεσης και να δώθει αυτή για το μοντέλο της παλινδρόμησης Poisson.

(iii) Αναφέρετε δύο τεχνικές με τις οποίες μπορούμε να ελέγχουμε τη συμβολή μιας συμμεταβλητής x στο μοντέλο παλινδρόμησης Poisson.

(iv) Εξετάζεται η εξάρτηση του αριθμού Y αποζημιώσεων λόγω τροχαίων ατυχημάτων (ανά τύπο συμβολαίου), από την ηλικία του οδηγού και την κατηγορία οχήματος (0 ή 1). Να συμπληρωθεί ο παρακάτω πίνακας μετά από προσαρμογή ενός μοντέλου παλινδρόμησης Poisson στα δεδομένα και να ερμηνευτούν οι εκτιμημένοι συντελεστές $\hat{\beta}$.

Μεταβλητές	$\hat{\beta}$	se($\hat{\beta}$)	z	p-τιμή
Σταθερά	2.49828	0.08104	23.66	<0.001
Τύπος οχήματος (X_1)	-0.53749	0.03692		
Ηλικία (X_2)	0.83664	0.02067		

(v) Η τιμή της ελεγχοσυνάρτησης deviance για το μοντέλο M_0 που περιέχει μόνο τη συμμεταβλητή X_1 δίνεται ως $D_0 = 3535.4$ και η αντίστοιχη τιμή για το μοντέλο M_1 με την επιπλέον συμμεταβλητή X_2 , ως $D_1 = 3315.8$. Ελέγχετε τη σημαντικότητα της διαφοράς των τιμών αυτών και αν ο έλεγχος αυτός συμφωνεί με τα αποτελέσματα του παραπάνω πίνακα για την ηλικία.

(Βαθμ. 2.5)