

Μάθημα : ΑΝΑΛΥΣΗ ΠΑΛΙΝΔΡΟΜΗΣΗΣ
ΣΧΟΛΗ ΕΦΑΡΜΟΣΜΕΝΩΝ ΜΑΘΗΜΑΤΙΚΩΝ ΚΑΙ ΦΥΣΙΚΩΝ ΕΠΙΣΤΗΜΩΝ
ΕΞΕΤΑΣΕΙΣ ΧΕΙΜΕΡΙΝΟΥ ΕΞΑΜΗΝΟΥ 2013-14

***** Διάρκεια Εξέτασης : 2.30 ώρες *****

ΖΗΤΗΜΑ 1

Έστω γενικό γραμμικό μοντέλο $y = X\beta + \varepsilon$, με $\varepsilon \sim N_n(0, \sigma^2 I_n)$, όπου X ο πίνακας σχεδιασμού με k επεξηγηματικές μεταβλητές.

(i) Να βρεθεί η διασπορά $V(\varepsilon_i)$ και συνδιακόμανση $\text{cov}(\varepsilon_i, \varepsilon_j)$, $i \neq j$, των υπολοίπων ε_i , $i=1, \dots, n$.

(ii) Κάνοντας χρήση της ιδιότητας $E(y' Ay) = \text{tr}(AV) + \mu' A \mu$, όπου $\mu = E(y)$, $V = V(y)$ και

$A = (I - H)$, $H = X(X'X)^{-1} X'$, δείξτε ότι $S^2 = \frac{SSE}{n-k-1}$ είναι μια αμερόληπτη εκτιμήτρια της σ^2 και

ότι για το απλό γραμμικό μοντέλο $E(y) = \beta_0 + \beta_1 x$ αυτή ανάγεται στην

$$S^2 = \frac{1}{n-2} \left\{ S_{yy} - \frac{S_{xy}^2}{S_{xx}} \right\} = \frac{1}{n-2} S_{yy} \{ 1 - r_{xy}^2 \}, \text{ όπου SSE το άθροισμα τετραγώνων λόγω σφάλματος}$$

από την προσαρμογή του μοντέλου.

(iii) Έστω το απλό γραμμικό μοντέλο $y_i = \beta_0 + \beta_1 x_i + \varepsilon_i$ με $V(\varepsilon_i) = \sigma^2 x_i^2$, $i=1, \dots, n$. Πώς θα μετασχηματίσουμε το μοντέλο έτσι ώστε να σταθεροποιηθεί η διασπορά του τυχαίου σφάλματος;

(Βαθμ. 3.0)

ΖΗΤΗΜΑ 2

(i) Να προσαρμοστεί το μοντέλο $E(y_x) = \beta_0 + \beta_1 x$ στα ακόλουθα δεδομένα και να βρεθεί ο συντελεστής προσδιορισμού R^2 .

X	1.6	1.8	1.4	2.0	1.2	2.2	1.0	2.4
Y	8.5	6.0	7.0	5.0	10.0	2.0	19	2.0

(ii) Να κατασκευαστεί ένα 0.99-διάστημα εμπιστοσύνης πρόβλεψης της $\mu_{x_0} = E(y_{x_0})$, όπου y_{x_0} μια νέα παρατήρηση, όταν $x_0 = (x_{00}, x_{01})' = (1, 1.5)'$. [Δίνεται $x_0'(X'X)^{-1}x_0 = 1/n + (x_{01} - \bar{x})^2 / S_{xx}$].

(iii) Με βάση ένα στατιστικό έλεγχο υποθέσεων και τους συντελεστές προσδιορισμού R^2 , θεωρείτε ότι βελτιώνεται η προσαρμογή αν στο μοντέλο εισαχθεί και η μεταβλητή x^2 ;

[Δίνεται $\sum_{i=1}^n x_i y_i = 84.4$, $\sum_{i=1}^n x_i^2 = 24.8$, $\sum_{i=1}^n y_i^2 = 651.25$. Δεδομένου ότι στο μοντέλο υπάρχει ήδη η μεταβλητή x , δίνεται ότι $\beta_2 = 7.515$, $\sqrt{c_{22}} = 1.93$ και $SSE = 26.537$].

(Βαθμ. 2.5)

$$\hat{y}_{x_0} \pm t_{n-2, \alpha/2} \sqrt{\frac{1}{n} + \frac{(x_0 - \bar{x})^2}{\sum (x_i - \bar{x})^2}}$$

ΖΗΤΗΜΑ 3

A) Δώστε μια σύντομη περιγραφή δύο διαδικασιών με βήματα για την επιλογή ενός μοντέλου παλινδρόμησης. Θα καταλήξουν στο ίδιο μοντέλο;

B) Εξετάζεται η γραμμική παλινδρόμηση της Y σε σχέση με τις επεξηγηματικές μεταβλητές X_1, X_2, X_3, X_4 . Με βάση τον παρακάτω πίνακα και για μέγεθος δείγματος $n=13$, να βρεθεί το καταλληλότερο μοντέλο, κάνοντας χρήση και ενός ελέγχου F , όπου κρίνετε ότι είναι απαραίτητος.

Πλήθος μεταβλητών στο μοντέλο

	R^2	C_p (Mallows)	S	X_1	X_2	X_3	X_4
+ 1	67.5	138.7	8.9639				X
1	66.6	142.5	9.0771		X		
+ 2	97.9	2.7 →	2.4063	X	X		
2	97.2	5.5	2.7343	X			X
+ 3	98.2	3.0 →	2.3087	X	X		X
3	98.2	3.0 →	2.3121	X	X	X	
4	98.2	5.0	2.4460	X	X	X	X

$$S = \left(\frac{e'e}{n-k-1} \right)^{1/2}$$

(Βαθμ. 2.5)

$$\hat{\beta}_2 = \frac{\sum xy}{\sum x^2} \quad \hat{\beta}_0 = y - \hat{\beta}_1 x$$


ΖΗΤΗΜΑ 4 (Επιλέξτε 1 από τα ακόλουθα 3 ερωτήματα)

(Βαθμ. 2.0)

A) Σε δεδομένα που αφορούν την ταχύτητα x δύο τύπων εργαλείων και την αντίστοιχη διάρκεια ζωής τους y (ώρες), προσαρμόζεται το μοντέλο $E(y_x) = \beta_0 + \beta_1 x + \beta_2 z + \beta_3 w$, όπου z μια δεικτρια μεταβλητή ($z=1$, όταν το εργαλείο είναι του τύπου A και $z=0$, όταν είναι του τύπου B) και $w=xz$ εκφράζει την αλληλεπίδραση μεταξύ των δύο τύπων εργαλείων και την ταχύτητά τους x .

(i) Πιστεύετε ότι διαφοροποιούνται οι κλίσεις των μοντέλων για τους δύο τύπους εργαλείων με την ταχύτητα x ; [Δίνονται $\hat{\beta}_3 = 0.002214$, $se(\hat{\beta}_3) = 0.009137$, $SSE(x, z, w) = 43.59$].

(ii) Θεωρώντας ότι δεν υπάρχει αλληλεπίδραση μεταξύ των δύο τύπων εργαλείων και την ταχύτητά τους x , υπάρχει διαφοροποίηση μεταξύ των δύο τύπων εργαλείων ως προς τη διάρκεια ζωής τους με δεδομένη τη συμμετοχή η x στο μοντέλο; Ερμηνεύστε το $\hat{\beta}_2$. Πιστεύετε ότι τα δεδομένα μπορούν να εκφραστούν μέσω ενός απλού γραμμικού μοντέλου; [Δίνονται $\hat{\beta}_2 = -12.643$ και $SSE(x, z) = 43.91$].



B) Τυχαία επιλεγμένο δείγμα 20 τούβλων από την ημερήσια παραγωγή ενός εργοστασίου καταμετρήθηκε τυχαία σε τέσσερις διαφορετικές συνθήκες αποθήκευσης. Μετά από ένα χρονικό διάστημα μετρήθηκε η επί τοις % περιεκτικότητά τους σε νερό

Συνθήκες αποθήκευσης			
1	2	3	4
7.4	7.0	7.9	8.1
8.3	5.4	9.6	6.4
7.6	7.2	10.0	7.1
8.3	6.4	9.1	6.7
8.2	5.9	8.5	7.7

Handwritten calculations for ANOVA:
 39,8
 37,9
 45,7
 36
 } 752,8
 22347,84
 7485
 27904
 SSR
 L
 SSE = 58
 1-p
 MSR ~ F_{4,16}(1-p)
 MSB

Υιοθετώντας την κωδικοποίηση

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

Στα δεδομένα προσαρμόστηκε το ακόλουθο 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 $\sum_{i=1}^c \sum_{j=1}^{n_i} y_{ij}^2 = 1194.1$, $SSR = 18.94$].

(ii) Να συμπληρωθεί και να ερμηνευτεί ο παρακάτω πίνακας

Μεταβλητές	$\hat{\beta}$	$se(\hat{\beta})$	t	p-τιμή
Σταθερά	7.20	0.3116	23,107	
X_1	0.76	0.4407	1,725	
X_2	-0.82	0.4407	-1,867	
X_3	1.82	0.4407	4,072	

Γ) Έστω μοντέλο της παλινδρόμησης Poisson $f(y) = \frac{\exp(-\mu_x) \mu_x^y}{y!}$, $y = 0, 1, 2, \dots$, με συνάρτηση σύνδεσης

$g(\mu_x) = \ln \mu_x = \beta'x$. (i) Δείξτε πώς προσαρμόζεται αυτό το μοντέλο στην περίπτωση που υπάρχουν 2 συμμεταβλητές x_1, x_2 . (ii) Δώστε τον ορισμό των υπολοίπων Pearson για ένα μοντέλο παλινδρόμησης Poisson. Σε τι μας χρησιμεύουν;