

!! Επιλέξτε 4 Ζητήματα από τα 7 !!

ZΗΤΗΜΑ 1 (Βαθμ. 2.5)

- (α) Στο γενικό γραμμικό μοντέλο  $y = X\beta + \varepsilon$ ,  $\varepsilon \sim N_n(0, \sigma^2 I_n)$  ισχύει ότι η ε.ε.τ.  $\hat{\beta} = (X'X)^{-1}X'y$   $\sim N_p(\beta, \sigma^2(X'X)^{-1})$ , και  $\frac{SSE}{\sigma^2} \sim \chi_{n-p}^2$ , όπου  $X$  ο πίνακας σχεδιασμού και SSE το άθροισμα τετραγώνων λόγω σφάλματος. Δεδομένου ότι  $\hat{\beta}_j$  και  $\frac{SSE}{\sigma^2}$  είναι ανεξάρτητα, βρείτε ένα γ-διάστημα εμπιστοσύνης για τον άγνωστο συντελεστή  $\beta_j$  μιας μεταβλητής  $x_j$  του μοντέλου.
- (β) Έστω  $y = \beta_0 + \varepsilon \sim N(\beta_0, \sigma^2)$ , χωρίς επεξηγηματικές μεταβλητές, τότε με βάση τ.δ.  $y_1, y_2, \dots, y_n$ , ανεξαρτήτων παρατηρήσεων από την κατανομή αυτή, δείξτε με τη μεθοδο μέγιστης πιθανοφάνειας ότι  $\hat{\beta}_0 = \bar{y}$  και κατά συνέπεια  $SST = SSE$ .

ZΗΤΗΜΑ 2 (Βαθμ. 2.5)

Έστω το γενικό γραμμικό μοντέλο  $y = X\beta + \varepsilon$ .

- (i) Δείξτε ότι το άθροισμα τετραγώνων λόγω παλινδρόμησης είναι  $SSR = y'(H - \frac{1}{n}J_n)y$ , όπου  $H = X(X'X)^{-1}X'$  ο πίνακας προβολής και  $J_n$  ο πίνακας του οποίου όλα τα στοιχεία είναι 1.
- (ii) Δώστε τον ορισμό του συντελεστή προσδιορισμού  $R^2$ . Τι εκφράζει;
- (iii) Γράψτε το δειγματικό συντελεστή συσχέτισης  $r_{y,\hat{y}}$  μεταξύ των παρατηρήσεων  $y$  και  $\hat{y}$ . Όταν η σταθερά  $\beta_0$  περιλαμβάνεται στο μοντέλο παλινδρόμησης, ισχύει  $\sum_{i=1}^n e_i = 0$ . Στην περίπτωση αυτή δείξτε ότι  $r_{y,\hat{y}}^2 = R^2$ .
- (iv) Έστω  $k$  ο αριθμός των επεξηγηματικών μεταβλητών. Δείξτε ότι η ελεγχοσυνάρτηση για τον έλεγχο  $H_0: \beta_1 = \beta_2 = \dots = \beta_k = 0$  έναντι  $H_1$ : τουλ. ένα  $\beta_j \neq 0$ , γράφεται ως  $F = \frac{R^2/k}{(1-R^2)/(n-k-1)}$ .

ZΗΤΗΜΑ 3 (Βαθμ. 2.5)

- (α) Έστω το γενικό γραμμικό μοντέλο  $E(y) = X_1\beta_1 + X_2\beta_2$  (ο πρώτος όρος περιλαμβάνει τη σταθερά  $\beta_0$  και οι μεταβλητές, ο δεύτερος  $\beta_2$  μεταβλητές). Δείξτε πότε η ε.ε.τ.  $\hat{\beta}_1$  είναι αμερόληπτη εκτιμήτρια της  $\beta_1$  στην περίπτωση που ο δεύτερος όρος  $X_2\beta_2$  παραλείπεται από το μοντέλο, ενώ χρειάζεται.
- (β) Έστω υπόλοιπα  $e = y - \hat{y} \sim N_n(0, \sigma^2(I - H))$  ενός γενικού γραμμικού μοντέλου. Δώστε τον ορισμό δύο περιπτώσεων τυποποιημένων υπολοίπων. Πώς μας χρησιμεύουν;

ZΗΤΗΜΑ 4 (Βαθμ. 2.5)

- (α) Ερευνάται η σχέση μεταξύ  $y$  και  $x_1$  και έστω δείκτρια μεταβλητή  $x_2$  ( $x_2 = 0$  αν τα δεδομένα είναι της κατηγορίας A και  $x_2 = 1$ , αν είναι της κατηγορίας B). Περιγράψτε πώς μέσω αυτής της  $x_2$  στο μοντέλο  $y = \beta_0 + \beta_1x_1 + \beta_2x_2 + \beta_3x_3 + \varepsilon$ , μπορούμε να ελέγχουμε αν χρειάζεται να προσαρμοστούν (I) δύο διαφορετικές ευθείες (II) δύο παράλληλες ευθείες ή (III) μια κοινή ευθεία και για τις δύο κατηγορίες, όπου  $x_3 = x_1x_2$ , η μεταβλητή που εκφράζει την αλληλεπίδραση μεταξύ των μεταβλητών  $x_1$  και  $x_2$ .
- (β) Να γίνουν αυτοί οι έλεγχοι στην περίπτωση που  $y$  = ρυθμός φωτοσύνθεσης,  $x_1$  = ηλιακή ακτινοβολία και  $x_2$  = διαθεσιμότητα του νερού,  $x_2 = 0$  (αν χαμηλή), ενώ  $x_2 = 1$  (αν υψηλή), με βάση τα ακόλουθα αποτελέσματα:

**Regression Analysis:**  $y$  με  $x_1, x_2, x_3$

The regression equation is

$$y = 114 + 43.5 x_1 - 25.9 x_2 - 20.6 x_3$$

Predictor	Coef	SE Coef	T	P
Constant	113.88	29.47	3.86	0.003
$x_1$	43.480	3.213		
$x_2$	-25.94	44.620		
$x_3$		4.188		

$$S = 33.4748 \quad R-Sq = 96.8\% \quad R-Sq(adj) = 95.8\%$$

**Analysis of Variance**

Source	DF	SS
Regression		338736
Residual Error		11206
Total	13	349942

**Regression Analysis:  $y$  με  $x_1$ ,  $x_2$**

The regression equation is

$$y = 214 + 31.3x_1 - 224x_2$$

Predictor	Coef	SE Coef	T	P
Constant	214.40	37.49	5.72	<0.001
$x_1$		3.636		
$x_2$	-224.39	33.71		

$$R-Sq = 89.0\% \quad R-Sq(\text{adj}) = 87.0\%$$

**Analysis of Variance**

Source	DF	SS
Regression		
Residual Error	11	38358
Total	13	349942

**Regression Analysis:  $y$  με  $x_1$**

The regression equation is


$$y = 186 + 22.8x_1$$

Predictor	Coef	SE Coef	T	P
Constant	186.48	79.98	2.33	0.038
$x_1$		7.308		

$$S = 126.769 \quad R-Sq = 44.9\% \quad R-Sq(\text{adj}) = 40.3\%$$

**Analysis of Variance**

Source	DF	SS
Regression	1	157098
Residual Error		
Total	13	349942



### ZHTHMA 5 (Βαθμ. 2.5)

Κατασκευαστής λάστιχων αυτοκινήτου θέλει να εξετάσει αν υπάρχουν διαφορές μεταξύ των τεσσάρων θέσεων τροχού ενός οχήματος, ως προς τη φθορά λάστιχων, για την ίδια απόσταση. Σε κάθε θέση χρησιμοποιήθηκαν 5 τυχαία επιλεγμένα λάστιχα αυτοκινήτου από συνολικά 20 κομμάτια, επίσης τυχαία επιλεγμένα.

Θέση 1	Θέση 2	Θέση 3	Θέση 4
20.94	18.28	28.54	20.18
19.01	21.20	27.99	18.79
20.33	19.39	30.07	19.20
17.12	14.82	37.23	34.34
15.92	11.28	38.85	34.71

Υιοθετώντας την κωδικοποίηση

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

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

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

$$[\text{Δίνονται } \sum_{i=1}^c \sum_{j=1}^n y_{ij}^2 = 12176.7, S = 5.368, S = \left( \frac{\text{SSE}}{(n-k-1)} \right)^{1/2}].$$

ii) Να συμπληρωθεί και να ερμηνευτεί ο παρακάτω πίνακας

Μεταβλητές	$\hat{\beta}$	$se(\hat{\beta})$	t	p-τιμή
Σταθερά	25.444			
$X_1$	-6.78	3.4		
$X_2$	-8.45	3.4		
$X_3$	7.09	3.4		

#### ΖΗΤΗΜΑ 6 (Βαθμ. 2.5)


Για τη λειτουργία μιας μονάδας παραγωγής επί 21 ημέρες, εξετάζεται η γραμμική εξάρτηση της διαρροής αμμώνιας  $Y$  (σε log), από τις μεταβλητές  $X_1$  (ταχύτητα λειτουργίας της μονάδας) και  $X_2$  (θερμοκρασία νερού, °C).

(i) Συμπληρώστε τον παρακάτω πίνακα. Σχολιάστε τα αποτελέσματά σας.

[Δίνεται:  $S = 0.172$ ,  $r_{X_1 X_2} = 0.782$ ,  $SST = 5.482$ ,  $AIC = -2\hat{\ell} + 2d = n \ln(2\pi) + n + 2 + n \ln(SSE/n) + 2p$  ]

Μεταβλητές	$\hat{\beta}$	$se(\hat{\beta})$	t	p-τιμή	VIF
Σταθερά	-0.752	0.273	-2.75	0.013	
$X_1$	0.035	0.007			
$X_2$	0.063	0.020			


$$R^2 = \underline{\hspace{2cm}} \%, \quad C_p = \frac{SSE(p)}{SSE_{\text{πλήρες}} / (n-p)} + 2p - n = \underline{\hspace{2cm}}, \quad AIC = \underline{\hspace{2cm}}$$



(ii) Για το παραπάνω μοντέλο δίνεται ότι  $h_{21,21} = 0.276$ . Αποτελεί η παρατήρηση 21 σημείο επιφροής του μοντέλου;

(iii) Δεδομένου ότι στο μοντέλο υπάρχουν οι μεταβλητές  $X_1$  και  $X_2$  θεωρείται ότι το μοντέλο βελτιώνεται με την προσθήκη της  $X_1^2$ ;  $SSE_{\text{πλήρες}} = 0.3858$ ,  $R^2 = \underline{\hspace{2cm}} \%$ ,  $C_p = \underline{\hspace{2cm}}$ ,  $AIC = \underline{\hspace{2cm}}$

(iv) Εξετάστε εκ νέου αν η παρατήρηση 21 αποτελεί σημείο επιφροής για το μοντέλο (iii) ( $h_{21,21} = 0.288$ ).



ZHTHMA 7 (Βαθμ. 2.5)

Έστω μοντέλο παλινδρόμησης Poisson  $f(y) = \frac{\exp(-\mu)}{y!} \mu^y$ ,  $y=0,1,2, \dots$ , με συνάρτηση σύνδεσης  $g(\mu_x) = \ln(\mu_x) = \beta'x$  και με

$$\text{ελεγχοσυνάρτηση Deviance} = -2(\hat{\ell}_0 - \hat{\ell}_{\text{κορ}}) = 2 \sum_{i=1}^n [y_i \ln(y_i/\hat{\mu}_i) - (y_i - \hat{\mu}_i)].$$

(α) Δώστε τον ορισμό των υπολοίπων Pearson και Deviance για το μοντέλο αυτό. Πώς τα χρησιμοποιούμε;

(β) Προσαρμόζοντας μοντέλα της παλινδρόμησης Poisson σε δεδομένα 44 ορυχείων μιας περιοχής, εξετάζεται η σχέση του αριθμού ρωγμών σε οροφή ορυχείου ( $Y$ ), με τις συμμεταβλητές  $X_1$  και  $X_2$  (χαρακτηριστικά των στρωμάτων του ορυκτού) καθώς και με τη  $X_3$  (έτη λειτουργίας του ορυχείου).

Αφού συμπληρωθούν οι παρακάτω πίνακες να ερμηνευτούν οι εκτιμημένες ποσότητες  $\exp(\hat{\beta}_j)$  και η γραφική παράσταση των υπολοίπων Deviance του τελικού μοντέλου. Συμφωνούν οι έλεγχοι Wald, Deviance και τα κριτήρια AIC;

ΜΟΝΤΕΛΟ: 3 Μεταβλητές	$\hat{\beta}_j$	$se(\hat{\beta}_j)$	$z_j$	p-τιμή	$\exp(\hat{\beta}_j)$
Σταθερά	-3.39	0.9842	-3.445	<0.001	-
$X_1$	0.05860	0.0117			
$X_2$	-0.00376	0.0049			
$X_3$	-0.03408	0.0147			

Ελεγχοσυνάρτηση deviance δίνεται ως  $D_3=41.329$  και η τιμή του κριτηρίου AIC<sub>3</sub>=145.6

ΜΟΝΤΕΛΟ: 2 Μεταβλητές	$\hat{\beta}_j$	$se(\hat{\beta}_j)$	$z_j$	p-τιμή	$\exp(\hat{\beta}_j)$
Σταθερά	-3.599	0.9440	-3.813	<0.001	-
$X_1$	0.05874	0.0117			
$X_3$	-0.03563	0.0148			

Ελεγχοσυνάρτηση deviance δίνεται ως  $D_2=41.952$  και η τιμή του κριτηρίου AIC<sub>2</sub>=144.22

ΜΟΝΤΕΛΟ: 1 Μεταβλητές	$\hat{\beta}_j$	$se(\hat{\beta}_j)$	$z_j$	p-τιμή	$\exp(\hat{\beta}_j)$
Σταθερά	-3.32859	0.90886	-3.662	<0.001	-
$X_1$	0.05234	0.01109			

Ελεγχοσυνάρτηση deviance δίνεται ως  $D_1=48.620$  και η τιμή του κριτηρίου AIC<sub>1</sub>=148.89

