

Η από κοινού πιθανοθεωρητική συμπεριφορά 2 τ.μ., X και Y , εκφράζεται πλήρως από την από κοινού κατανομή τους, $F_{X,Y}(x, y)$. Η πιθανοθεωρητική συμπεριφορά της Y για συγκεκριμένη τιμή x της X ($X = x$) εκφράζεται πλήρως από τη δεσμευμένη κατανομή, $F_{Y|X}(y|x)$

$$(Y|X = x) \sim F_{Y|X=x}$$

Στο μάθημα αυτό θα ασχοληθούμε με την παλινδρόμηση, που αναφέρεται στη συμπεριφορά της μέσης τιμής και της διασποράς της 'απόκρισης', Y , σαν συνάρτηση της 'συμμεταβλητής' X . Θα μελετήσουμε το μοντέλο

$$(Y|X = x) \sim (\mu(x), \sigma^2(x)),$$

όπου καταχρηστικά θα χρησιμοποιούμε το σύμβολο \sim . Στη παραπάνω έκφραση απλά αναφέρουμε πως $\mu(x) = E(Y|X = x)$ και $\sigma^2(x) = Var(Y|X = x)$. Θα επικεντρωθούμε στην ειδική περίπτωση, όπου η διασπορά δεν εξαρτάται από τη τιμή της X , δηλαδή έχουμε

$$(Y|X = x) \sim (\mu(x), \sigma^2).$$

Η παλινδρόμηση λέγεται γραμμική όταν $\mu(x)$ είναι μια οποιαδήποτε γραμμική συνάρτηση των παραμέτρων $\beta_0, \beta_1, \dots, \beta_{p-1}$ (Δηλαδή είναι γραμμική ως προς 'τα β , όχι ως προς 'τα x ').

Τα παρακάτω μοντέλα είναι όλα παραδείγματα γραμμικών μοντέλων

$$(Y|X = x) \sim (\mu(x) = \beta_0 + \beta_1 x, \sigma^2)$$

$$(Y|X = x) \sim (\mu(x) = \beta_0 + \beta_1 x + \beta_2 x^2 + \beta_3 x^3, \sigma^2)$$

$$(Y|X = x) \sim (\mu(x) = \beta_0 + \beta_1 e^x, \sigma^2)$$

$$(Y|X = x) \sim (\mu(x) = \beta_0 + \beta_1 \ln x, \sigma^2), x > 0.$$

$$(Y|X = x) \sim (\mu(x) = \beta_0 + \beta_1 \frac{1}{x}, \sigma^2), x > 0.$$

Το παρακάτω μοντέλο δεν είναι γραμμικό (είναι 'μη γραμμικό')

$$(Y|X = x) \sim \left(\mu(x) = \frac{e^{\beta_0 + \beta_1 x}}{1 + e^{\beta_0 + \beta_1 x}}, \sigma^2 \right)$$

Μία ειδική περίπτωση των γραμμικών μοντέλων (που θα μελετήσουμε εκτενώς) υποθέτει κανονική κατανομή για την απόκριση για κάθε x , δηλαδή

$$(Y|X = x) \sim N(\mu(x), \sigma^2),$$

όπου $\mu(x)$ είναι μια γραμμική συνάρτηση των παραμέτρων $\beta_0, \beta_1, \dots, \beta_{p-1}$. Σε αυτή τη περίπτωση το σύμβολο \sim σημαίνει 'ακολουθεί την κατανομή'. Ένας ισοδύναμος τρόπος ορισμού ενός μοντέλου παλινδρόμησης προκύπτει ορίζοντας το 'σφάλμα' $\epsilon(x) = Y - \mu(x)$, και γράφοντας

$$Y = \mu(x) + \epsilon(x), \quad \epsilon(x) \sim (0, \sigma^2).$$

1 Εκτιμητής Ελαχίστων Τετραγώνων στην απλή γραμμική παλινδρόμηση

Στην απλή γραμμική παλινδρόμηση έχουμε $p = 2$, κι έτσι $\mu(x) = \beta_0 + \beta_1 x$. Δοθέντος ενός δείγματος $(Y_1, x_1), (Y_2, x_2), \dots, (Y_n, x_n)$ το απλό γραμμικό μοντέλο (απλή γραμμική παλινδρόμηση) για τα δεδομένα μας γράφεται ως:

$$Y_i = \beta_0 + \beta_1 x_i + \epsilon_i, \quad i = 1, \dots, n, \quad (1.1)$$

Y_i είναι η απόκριση της i -οστής παρατήρησης, x_i η τιμή της συμμεταβλητής της i -οστής παρατήρησης και ϵ_i είναι το σφάλμα (δηλαδή η απόκλιση της παρατήρησης Y_i από την μέση τιμή της, $E(Y_i) = \mu_i = \beta_0 + \beta_1 x_i$). Θεωρούμε τα x ως σταθερές τιμές κι όχι ως τ.μ.. Για τα σφάλματα υποθέτουμε πως είναι ομοσχεδαστικά ($var(\epsilon_i) = \sigma^2$) και ασυσχέτιστα ($cov(\epsilon_i, \epsilon_j) = 0$ για $i \neq j$).

Εναλλακτικά το μοντέλο μπορεί να γραφτεί ως:

$$\begin{aligned} Y_i | x_i &\sim (\mu_i, \sigma^2), \quad cov(Y_i, Y_j | x_i, x_j) = 0, \quad i \neq j \\ \mu_i &= \beta_0 + \beta_1 x_i, \quad i = 1, \dots, n, \end{aligned} \quad (1.2)$$

Οι εκτιμητές ελαχίστων τετραγώνων είναι:

$$\begin{aligned} \hat{\beta}_1 &= \frac{n \sum x_i y_i - (\sum x_i)(\sum y_i)}{n \sum x_i^2 - (\sum x_i)^2} \\ \hat{\beta}_0 &= \bar{y} - \hat{\beta}_1 \bar{x} \end{aligned} \quad (1.3)$$

Σημείωση: Από τα παραπάνω προκύπτει πως $\bar{y} = \hat{\beta}_0 + \hat{\beta}_1 \bar{x}$, κι άρα η ευθεία ελαχίστων τετραγώνων περνάει από το σημείο (\bar{x}, \bar{y}) .

Οι εκτιμητές ελαχίστων τετραγώνων ελαχιστοποιούν το άθροισμα των τετραγωνικών σφαλμάτων, ήτοι είναι οι λύσεις του μαθηματικού προβλήματος

$$\min_{\beta_0, \beta_1} \sum \epsilon_i^2(\beta_0, \beta_1) \Leftrightarrow \min_{\beta_0, \beta_1} \sum (y_i - \beta_0 - \beta_1 x_i)^2 \quad (1.4)$$

Παραγωγίζοντας καταλήγουμε πως οι εκτιμητές ελαχίστων τετραγώνων προκύπτουν ως λύσεις των εκτιμητικών εξισώσεων

$$\begin{aligned}\sum \epsilon_i(\beta_0, \beta_1) &= \sum (y_i - \beta_0 - \beta_1 x_i) = 0 \\ \sum x_i \epsilon_i(\beta_0, \beta_1) &= \sum x_i (y_i - \beta_0 - \beta_1 x_i) = 0\end{aligned}\quad (1.5)$$

(Απόδειξη:

$$\begin{aligned}\frac{d}{d\beta_0} \sum (y_i - \beta_0 - \beta_1 x_i)^2 &= -2 \sum (y_i - \beta_0 - \beta_1 x_i) = 0 \\ \frac{d}{d\beta_1} \sum (y_i - \beta_0 - \beta_1 x_i)^2 &= -2 \sum x_i (y_i - \beta_0 - \beta_1 x_i) = 0,\end{aligned}$$

από όπου προκύπτουν ως λύσεις οι εκτιμητές $\hat{\beta}_0, \hat{\beta}_1$. Για να δείξουμε ότι αυτές οι τιμές ελαχιστοποιούν τη συνάρτηση που έχουμε παίρνουμε τις 'δεύτερες' παραγώγους:

$$\begin{aligned}\frac{d^2}{d\beta_0^2} \sum (y_i - \beta_0 - \beta_1 x_i)^2 &= 2n \\ \frac{d^2}{d\beta_1^2} \sum (y_i - \beta_0 - \beta_1 x_i)^2 &= 2 \sum x_i^2 \\ \frac{d^2}{d\beta_0 d\beta_1} \sum (y_i - \beta_0 - \beta_1 x_i)^2 &= 2 \sum x_i\end{aligned}$$

Πρέπει να δείξω πως ο πίνακας με τις 'δεύτερες' παραγώγους, όταν εκτιμάται στα $\beta_0 = \hat{\beta}_0$ και $\beta_1 = \hat{\beta}_1$ είναι θετικά ορισμένος. Στη περίπτωση μας έχουμε τον πίνακα

$$2 \begin{bmatrix} n & \sum x_i \\ \sum x_i & \sum x_i^2 \end{bmatrix}$$

Αρκεί να έχω $n > 0$, $\sum x_i^2 > 0$ και η ορίζουσα > 0 . Η ορίζουσα ισούται με $2(n \sum x_i^2 - (\sum x_i)^2) = 2n(\sum x_i^2 - \frac{1}{n}(\sum x_i)^2) = 2n \sum (x_i - \bar{x})^2 > 0$. Άρα έχουμε τοπικό ελάχιστο στο $\beta_0 = \hat{\beta}_0$ και $\beta_1 = \hat{\beta}_1$.)

Οι εκτιμητές ελαχίστων τετραγώνων μπορούν να εκφραστούν ως γραμμικοί

συνδυασμοί των Y :

$$\begin{aligned}\hat{\beta}_1 &= \sum c_i Y_i, \text{ με } c_i = \frac{x_i - \bar{x}}{S_{xx}} \\ \hat{\beta}_0 &= \sum d_i Y_i, \text{ με } d_i = \frac{1}{n} - \frac{(x_i - \bar{x})\bar{x}}{S_{xx}},\end{aligned}\quad (1.6)$$

όπου

$$S_{xx} = \sum (x_i - \bar{x})^2$$

Για τους συντελεστες c_i, d_i ισχύουν τα παρακάτω:

$$\begin{aligned}\sum c_i &= 0, \quad \sum c_i^2 = \frac{1}{S_{xx}}, \quad \sum c_i x_i = 1 \\ \sum d_i &= 1, \quad \sum d_i^2 = \frac{1}{n} + \frac{\bar{x}^2}{S_{xx}}, \quad \sum d_i x_i = 0 \\ &\quad \sum c_i d_i = -\frac{\bar{x}}{S_{xx}}\end{aligned}\quad (1.7)$$

(

$$\begin{aligned}\sum c_i d_i &= \sum \left(\frac{x_i - \bar{x}}{S_{xx}} \right) \left(\frac{1}{n} - \frac{(x_i - \bar{x})\bar{x}}{S_{xx}} \right) \\ &= \frac{1}{n} \sum \left(\frac{x_i - \bar{x}}{S_{xx}} \right) - \sum \left(\frac{x_i - \bar{x}}{S_{xx}} \right) \frac{(x_i - \bar{x})\bar{x}}{S_{xx}} \\ &= 0 - \frac{\bar{x}}{S_{xx}^2} \sum (x_i - \bar{x})^2 = -\frac{\bar{x}}{S_{xx}}\end{aligned}$$

)

Καθότι $Var(Y_i) = cov(Y_i, Y_i) = \sigma^2 \forall i$ και $Cov(Y_i, Y_j) = 0 \forall i \neq j$ έχουμε

$$\begin{aligned}E\left(\sum \alpha_r Y_r\right) &= \sum \alpha_r E(Y_r) \\ Cov\left(\sum \alpha_r Y_r, \sum \gamma_r Y_r\right) &= \sum_r \sum_s \alpha_r \gamma_s cov(Y_r, Y_s) \\ &= \sigma^2 \sum \alpha_r \gamma_r\end{aligned}\quad (1.8)$$

μπορούμε να αποδείξουμε πως

$$\begin{aligned} E(\hat{\beta}_0) &= \beta_0, \quad Var(\hat{\beta}_0) = \sigma^2 \left[\frac{1}{n} + \frac{\bar{x}^2}{S_{xx}} \right] \\ E(\hat{\beta}_1) &= \beta_1, \quad Var(\hat{\beta}_1) = \sigma^2 \frac{1}{S_{xx}} \\ Cov(\hat{\beta}_0, \hat{\beta}_1) &= -\sigma^2 \frac{\bar{x}}{S_{xx}}. \end{aligned} \quad (1.9)$$

Οι προσαρμοσμένες τιμές (fits) και τα υπόλοιπα ή κατάλοιπα (residuals) ισούνται με

$$\begin{aligned} \hat{Y}_i &= \hat{\beta}_0 + \hat{\beta}_1 x_i \\ \hat{\epsilon}_i &= Y_i - \hat{Y}_i. \end{aligned} \quad (1.10)$$

Η προσαρμοσμένη τιμή \hat{Y}_i είναι απλά η εκτίμηση της μέσης τιμής $\mu_i = \beta_0 + \beta_1 x_i$. Σύγχρονως είναι και πρόβλεψη της τιμής της απόκρισης Y για μια νέα παρατήρηση με τιμή της συμμεταβλητής ίση με x_i . Καθότι η ευθεία ελαχίστων τετραγώνων περνάει από το σημείο (\bar{x}, \bar{y}) , ισχύει πως $\sum \hat{Y}_i = \sum Y_i$. Επίσης από τις εκτιμητικές εξισώσεις (1.5) προκύπτει πως $\sum \hat{\epsilon}_i = 0$ και $\sum x_i \hat{\epsilon}_i = 0$

Οι προσαρμοσμένες τιμές και τα υπόλοιπα είναι γραμμικοί συνδυασμοί των παρατηρήσεων Y_1, \dots, Y_n :

$$\begin{aligned} \hat{Y}_i &= \hat{\beta}_0 + \hat{\beta}_1 x_i = \sum_{j=1}^n (d_j + x_i c_j) Y_j \\ \hat{\epsilon}_i &= Y_i - \hat{Y}_i = \sum_{j=1}^n [\delta_{[j=i]} - (d_j + x_i c_j)] Y_j, \end{aligned} \quad (1.11)$$

όπου $\delta_{[j=i]} = 1$ όταν $j = i$ και ισούται με 0 όταν $j \neq i$.

Χρησιμοποιώντας τα αποτελέσματα στις εξισώσεις (1.8) μπορούμε να δε-
ίξουμε πώς

$$\begin{aligned}
 E(\hat{Y}_i) &= \mu_i = \beta_0 + \beta_1 x_i \quad , \quad \text{var}(\hat{Y}_i) = \sigma^2 \left(\frac{1}{n} + \frac{(x_i - \bar{x})^2}{S_{xx}} \right) \\
 E(\hat{\epsilon}_i) &= 0 \quad , \quad \text{var}(\hat{\epsilon}_i) = \sigma^2 \left(1 - \frac{1}{n} - \frac{(x_i - \bar{x})^2}{S_{xx}} \right) \\
 \text{cov}(\hat{\epsilon}_i, \hat{\epsilon}_j) &= -\sigma^2 \left(\frac{1}{n} + \frac{(x_i - \bar{x})(x_j - \bar{x})}{S_{xx}} \right) \quad , \quad \text{cov}(\hat{\epsilon}_i, \hat{\beta}_0) = 0 \\
 \text{cov}(\hat{\epsilon}_i, \hat{\beta}_1) &= 0 \quad , \quad \text{cov}(\hat{\epsilon}_i, \hat{Y}_j) = 0 \quad \forall i, j \\
 \text{cov}(\hat{\epsilon}_i, \bar{Y}) &= 0 \quad , \quad \text{cov}(\hat{\beta}_i, \bar{Y}) = 0 \quad (1.12)
 \end{aligned}$$

Μια απερόληπτη εκτίμηση της διασποράς των σφαλμάτων δίνεται από την
 $s^2 = \frac{\sum \hat{\epsilon}_i^2}{n-2} = \frac{\sum (Y_i - \hat{Y}_i)^2}{n-2}$. Δηλαδή, ισχύει πως

$$E(s^2) = E\left(\frac{\sum \hat{\epsilon}_i^2}{n-2}\right) = E\left(\frac{\sum (Y_i - \hat{Y}_i)^2}{n-2}\right) = \sigma^2. \quad (1.13)$$

(Απόδειξη: Καταρχάς $E(\hat{\epsilon}_i) = E(Y_i - \hat{Y}_i) = E(Y_i) - E(\hat{Y}_i) = \mu_i - \mu_i = 0$

$$\begin{aligned}
 E\left(\sum \hat{\epsilon}_i^2\right) &= \sum E(\hat{\epsilon}_i^2) \\
 &= \sum (\text{Var}(\hat{\epsilon}_i) + (E(\hat{\epsilon}_i))^2) \\
 &= \sum \text{Var}(\hat{\epsilon}_i) \\
 &= \sigma^2 \left(n - 1 - \sum \frac{(x_i - \bar{x})^2}{S_{xx}} \right) \\
 &= \sigma^2(n - 2),
 \end{aligned}$$

και το αποτέλεσμα προκύπτει άμεσα.)

2 Κανονική Απλή Γραμμική Παλινδρόμηση

Το κανονικό απλό γραμμικό μοντέλο γράφεται ως

$$\begin{aligned} Y_i &= \beta_0 + \beta_1 x_i + \epsilon_i, \quad i = 1, \dots, n, \\ \epsilon_1, \epsilon_2, \dots, \epsilon_n &\sim^{iid} N(0, \sigma^2), \end{aligned} \quad (2.1)$$

ή εναλλακτικά

$$\begin{aligned} Y_i | x_i &\sim^{ind} N(\mu_i, \sigma^2), \quad i = 1, \dots, n, \\ \mu_i &= \beta_0 + \beta_1 x_i \end{aligned} \quad (2.2)$$

Η υπόθεση κανονικότητας μαζί με τα αποτελέσματα στο προηγούμενο κεφάλαιο συνεπάγονται τα εξής:

$$\begin{aligned} \hat{\beta} &\sim MVN(\beta, \Sigma) \quad , \\ \hat{\beta}_0 &\sim N\left(\beta_0, \sigma^2 \left[\frac{1}{n} + \frac{\bar{x}^2}{S_{xx}}\right]\right) \quad , \quad \hat{\beta}_1 \sim N\left(\beta_1, \sigma^2 \frac{1}{S_{xx}}\right), \end{aligned} \quad (2.3)$$

όπου η 1η πρόταση παραπάνω απλά αναφέρει πως το 2×1 διάνυσμα των εκτιμητριών

$$\hat{\beta} = \begin{bmatrix} \hat{\beta}_0 \\ \hat{\beta}_1 \end{bmatrix}$$

ακολουθεί πολυμεταβλητή κανονική κατανομή με μέση τιμή

$$\beta = \begin{bmatrix} \beta_0 \\ \beta_1 \end{bmatrix}$$

και πίνακα διακυμάνσεων-συνδιακυμάνσεων Σ , όπου

$$\Sigma = \begin{bmatrix} \text{var}(\hat{\beta}_0) & \text{cov}(\hat{\beta}_0, \hat{\beta}_1) \\ \text{cov}(\hat{\beta}_0, \hat{\beta}_1) & \text{var}(\hat{\beta}_1) \end{bmatrix} = \begin{bmatrix} \sigma_{\hat{\beta}_0}^2 & \sigma_{\hat{\beta}_0, \hat{\beta}_1} \\ \sigma_{\hat{\beta}_0, \hat{\beta}_1} & \sigma_{\hat{\beta}_1}^2 \end{bmatrix} = \begin{bmatrix} \sigma^2 \left[\frac{1}{n} + \frac{\bar{x}^2}{S_{xx}}\right] & -\sigma^2 \frac{\bar{x}}{S_{xx}} \\ -\sigma^2 \frac{\bar{x}}{S_{xx}} & \sigma^2 \frac{1}{S_{xx}} \end{bmatrix}$$

Μία άμεση συνέπεια του αποτελέσματος στην (2.3) είναι πως κάθε γραμμικός συνδυασμός των εκτιμητριών $\hat{\beta}_0$ και $\hat{\beta}_1$ ακολουθούν κανονική κατανομή. Συγκεκριμένα, έστω l_1, l_2 πραγματικοί αριθμοί (όχι και τα 2 ίσα μηδέν). Τότε

$$l_1 \hat{\beta}_0 + l_2 \hat{\beta}_1 \sim N(l_1 \beta_0 + l_2 \beta_1, l_1^2 \sigma_{\hat{\beta}_0}^2 + l_2^2 \sigma_{\hat{\beta}_1}^2 + 2l_1 l_2 \sigma_{\hat{\beta}_0, \hat{\beta}_1}), \quad (2.4)$$

από όπου προκύπτει πως

$$\frac{l_1 \hat{\beta}_0 + l_2 \hat{\beta}_1 - (l_1 \beta_0 + l_2 \beta_1)}{\sigma \sqrt{l_1^2 \left[\frac{1}{n} + \frac{\bar{x}^2}{S_{xx}}\right] + l_2^2 \frac{1}{S_{xx}} - 2l_1 l_2 \frac{\bar{x}}{S_{xx}}}} \sim N(0, 1). \quad (2.5)$$

Από τα αποτελέσματα στη (1.12) σε συνδυασμό με την υπόθεση κανονικότητας προκύπτει πως τα υπόλοιπα, $\hat{\epsilon}_i$, είναι στατιστικά ανεξάρτητα των εκτιμητριών, $\hat{\beta}_0$ και $\hat{\beta}_1$. Άρα τα υπόλοιπα, $\hat{\epsilon}_i$, είναι ανεξάρτητα και του γραμμικού συνδυασμού $l_1\hat{\beta}_0 + l_2\hat{\beta}_1$. Τέλος, καθότι $s^2 = \frac{\sum \hat{\epsilon}_i^2}{n-2}$ είναι συνάρτηση των υπολοίπων, $\hat{\epsilon}_i$, έχουμε πως $l_1\hat{\beta}_0 + l_2\hat{\beta}_1$ και s^2 είναι στατιστικά ανεξάρτητα.

Αργότερα θα δείξουμε πως, κάτω από την υπόθεση κανονικότητας των σφαλμάτων, έχουμε πως

$$(n-2) \frac{s^2}{\sigma^2} \sim \chi_{n-2}^2. \quad (2.6)$$

Από τα αποτελέσματα στις (2.5) και (2.6) έχουμε

$$\begin{aligned} & \frac{l_1\hat{\beta}_0 + l_2\hat{\beta}_1 - (l_1\beta_0 + l_2\beta_1)}{\sigma \sqrt{l_1^2[\frac{1}{n} + \frac{\bar{x}^2}{S_{xx}}] + l_2^2 \frac{1}{S_{xx}} - 2l_1l_2 \frac{\bar{x}}{S_{xx}}}} \\ & \quad \sqrt{(n-2) \frac{s^2}{\sigma^2} / (n-2)} \\ &= \frac{l_1\hat{\beta}_0 + l_2\hat{\beta}_1 - (l_1\beta_0 + l_2\beta_1)}{s \sqrt{l_1^2[\frac{1}{n} + \frac{\bar{x}^2}{S_{xx}}] + l_2^2 \frac{1}{S_{xx}} - 2l_1l_2 \frac{\bar{x}}{S_{xx}}}} \sim t_{n-2}. \end{aligned} \quad (2.7)$$

2.1 Συμπερασματολογία για παραμέτρους, Διάστημα εμπιστοσύνης, Διάστημα Πρόβλεψης

Βάσει του αποτελέσματος στην (2.7) ένα $100(1-a)\%$ διάστημα εμπιστοσύνης για τον γραμμικό συνδυασμό $l_1\beta_0 + l_2\beta_1$ δίνεται από:

$$l_1\hat{\beta}_0 + l_2\hat{\beta}_1 \pm t_{n-2; \frac{\alpha}{2}} s \sqrt{l_1^2[\frac{1}{n} + \frac{\bar{x}^2}{S_{xx}}] + l_2^2 \frac{1}{S_{xx}} - 2l_1l_2 \frac{\bar{x}}{S_{xx}}},$$

όπου $t_{n-2; \alpha/2}$ είναι τό άνω $\alpha/2$ ποσοστιαίο σημείο της t_{n-2} κατανομής.

Επίσης ο έλεγχος της μηδενικής υπόθεσης $H_o : l_1\beta_0 + l_2\beta_1 = r$ έναντι της δίπλευρης εναλλακτικής $H_a : l_1\beta_0 + l_2\beta_1 \neq r$, σε επίπεδο σημαντικότητας α απορρίπτει την μηδενική όταν

$$\frac{|l_1\hat{\beta}_0 + l_2\hat{\beta}_1 - r|}{s \sqrt{l_1^2[\frac{1}{n} + \frac{\bar{x}^2}{S_{xx}}] + l_2^2 \frac{1}{S_{xx}} - 2l_1l_2 \frac{\bar{x}}{S_{xx}}}} > t_{n-2; \frac{\alpha}{2}}.$$

Ειδικές περιπτώσεις ενδιαφέροντος:

1) Για την κλίση της ευθείας παλινδρόμησης παίρνουμε $l_1 = 0$ και $l_2 = 1$. Ειδικά, για να ελέγξουμε τη στατιστική σημαντικότητα της παλινδρόμησης κάνουμε τον έλεγχο $H_0 : \beta_1 = 0$ έναντι της δίπλευρης εναλλακτικής. Η μηδενική υπόθεση απορρίπτεται όταν

$$\frac{|\hat{\beta}_1|}{s\sqrt{\frac{1}{S_{xx}}}} > t_{n-2; \frac{\alpha}{2}}. \quad (2.8)$$

2) Για την μέση τιμή της απόκρισης σε καθορισμένη τιμή της συµμεταβλητής x_0 , δηλαδή για την $\mu_0 = \beta_0 + \beta_1 x_0$, παίρνουμε $l_1 = 1$ και $l_2 = x_0$. Έτσι για παράδειγμα, ένα 95% Διάστημα Εμπιστοσύνης για την μέση τιμή $\mu_0 = \beta_0 + \beta_1 x_0$ δίνεται από

$$\begin{aligned} \hat{\beta}_0 + \hat{\beta}_1 x_0 \pm t_{n-2; 0.025} s \sqrt{\frac{1}{n} + \frac{(x_0 - \bar{x})^2}{S_{xx}}} \\ \hat{Y}_0 \pm t_{n-2; 0.025} s \sqrt{\frac{1}{n} + \frac{(x_0 - \bar{x})^2}{S_{xx}}} \end{aligned}$$

Διάστημα Πρόβλεψης μιας καινούργιας τιμής της απόκρισης για συγκεκριμένη τιμή, x_0 , της συµμεταβλητής.

Έστω πως θέλουμε να προβλέψουμε μια νέα τιμή Y_0 δοθέντος συγκεκριμένης τιμής της συµμεταβλητής, x_0 . Π.χ. έστω πως θέλουμε να προβλέψουμε την τιμή της FEV για ένα παιδί με ύψος 65 ίντσες (εννοείται πως δεν αναφερόμαστε σε παιδί που ήδη παρατηρήσαμε την τιμή του, υπάρχει δηλαδή η παρατήρησή του στην βάση δεδομένων). Θέλουμε δηλαδή να προβλέψουμε την τυχαία μεταβλητή $Y_0 = \beta_0 + \beta_1 x_0 + \epsilon_0$. Μπορεί να αποδειχθεί πως η βέλτιστη γραμμική πρόβλεψη της Y_0 (με κριτήριο το μέσο τετραγωνικό σφάλμα πρόβλεψης) είναι η $\hat{Y}_0 = \hat{\beta}_0 + \hat{\beta}_1 x_0$. Η πρόβλεψη \hat{Y}_0 είναι προφανώς ανεξάρτητη της τ.μ. που θέλουμε να προβλέψουμε, Y_0 (γιατί;). Παρατηρούμε πως η πρόβλεψη της Y_0 είναι ίδια με την αμερόληπτη εκτίμηση της μέσης τιμής $\mu_0 = \beta_0 + \beta_1 x_0$.

Για το σφάλμα της της πρόβλεψης $Y_0 - \hat{Y}_0$ ισχύουν

$$E(Y_0 - \hat{Y}_0) = 0$$

$$Var(Y_0 - \hat{Y}_0) = Var(Y_0) + Var(\hat{Y}_0) = \sigma^2 \left(1 + \frac{1}{n} + \frac{(x_0 - \bar{x})^2}{S_{xx}}\right) \quad (2.9)$$

που μαζί με την υπόθεση κανονικότητας μας δίνει

$$\frac{Y_0 - \hat{Y}_0}{\sigma \sqrt{1 + \frac{1}{n} + \frac{(x_0 - \bar{x})^2}{S_{xx}}}} \sim N(0, 1). \quad (2.10)$$

Ισχύει πως $Y_0 - \hat{Y}_0$ και s^2 είναι ανεξάρτητα (καθώς $Y_0, \hat{\beta}_0, \hat{\beta}_1$ είναι ανεξάρτητα της s^2). Άρα, το αποτέλεσμα στην (2.10) σε συνδυασμό με το αποτέλεσμα στην (2.6) μας δίνει

$$\frac{Y_0 - \hat{Y}_0}{s\sqrt{1 + \frac{1}{n} + \frac{(x_0 - \bar{x})^2}{Sxx}}} \sim t_{n-2}, \quad (2.11)$$

από όπου προκύπτει πως ισχύει ότι

$$P(\hat{Y}_0 - t_{n-2; \frac{\alpha}{2}} s\sqrt{1 + \frac{1}{n} + \frac{(x_0 - \bar{x})^2}{Sxx}} < Y_0 < \hat{Y}_0 + t_{n-2; \frac{\alpha}{2}} s\sqrt{1 + \frac{1}{n} + \frac{(x_0 - \bar{x})^2}{Sxx}}) = 1 - \alpha.$$

Το διάστημα

$$\hat{Y}_0 \pm t_{n-2; \frac{\alpha}{2}} s\sqrt{1 + \frac{1}{n} + \frac{(x_0 - \bar{x})^2}{Sxx}}$$

λέγεται ένα $100(1 - \alpha)\%$ Διάστημα Πρόβλεψης της Y_0 .

2.2 Διάσπαση χ^2 , ANOVA

Λήμμα 1. Έστω $U = U_1 + U_2$. Αν $U \sim \chi_k^2$, $U_1 \sim \chi_l^2$, με $k > l$ και U_1 είναι ανεξάρτητη της U_2 , τότε $U_2 \sim \chi_{k-l}^2$

Απόδειξη. Για της ροπογεννήτριες των τ.μ. ισχύει, λόγω ανεξαρτησίας των U_1 και U_2

$$M_U(t) = M_{U_1}(t)M_{U_2}(t)$$

Η ροπογεννήτρια μιας τ.μ. με χ_ν^2 κατανομή ισούται με

$$M(t) = \frac{1}{(1 - 2t)^{\nu/2}}, \quad t, 1/2$$

και συνεπώς ισχύει

$$\frac{1}{(1 - 2t)^{k/2}} = \frac{1}{(1 - 2t)^{l/2}}(t)M_{U_2}(t),$$

κι άρα

$$M_{U_2}(t) = \frac{1}{(1 - 2t)^{(k-l)/2}}(t).$$

Καθώς η ροπογεννήτρια (όταν υπάρχει) καθορίζει την κατανομή, συμπεραίνουμε πως $U_2 \sim \chi_{k-l}^2$. □

Θεώρημα 2. Σε μία απλή γραμμική παλινδρόμηση με ομοσκεδαστικά και ασυσχέτιστα σφάλματα που ακολουθούν κανονική κατανομή ισχύουν:

$$\begin{aligned} (n-2) \frac{s^2}{\sigma^2} &\sim \chi_{n-2}^2 \Leftrightarrow \frac{SSE}{\sigma^2} \sim \chi_{n-2}^2 \\ \frac{\hat{\beta}_1^2 S_{XX}}{\sigma^2} &\sim_{H_0} \chi_1^2 \Leftrightarrow \frac{SSR}{\sigma^2} \sim_{H_0} \chi_1^2 \\ SSE &\perp SSR, \end{aligned}$$

όπου $H_0 : \beta_1 = 0$.

Απόδειξη. Γράφουμε

$$\begin{aligned} \epsilon_i &= \hat{\epsilon}_i + (\epsilon_i - \hat{\epsilon}_i) \\ &= \hat{\epsilon}_i + (Y_i - \beta_0 - \beta_1 x_i - Y_i + \hat{\beta}_0 + \hat{\beta}_1 x_i) \\ &= \hat{\epsilon}_i + (\hat{\beta}_0 - \beta_0) + (\hat{\beta}_1 - \beta_1) x_i. \end{aligned} \quad (2.12)$$

Γνωρίζουμε πως

$$\begin{aligned} \bar{Y} &= \beta_0 + \beta_1 \bar{x} + \bar{\epsilon} \\ \bar{\hat{Y}} &= \hat{\beta}_0 + \hat{\beta}_1 \bar{x} \\ \implies &(\hat{\beta}_0 - \beta_0) = -(\hat{\beta}_1 - \beta_1) \bar{x} - \bar{\epsilon}. \end{aligned} \quad (2.13)$$

Από τις (2.13) και (;) προκύπτει

$$\begin{aligned} \epsilon_i &= \hat{\epsilon}_i + (\hat{\beta}_1 - \beta_1)(x_i - \bar{x}) - \bar{\epsilon} \implies \\ \epsilon_i^2 &= \hat{\epsilon}_i^2 + (\hat{\beta}_1 - \beta_1)^2 (x_i - \bar{x})^2 + \bar{\epsilon}^2 \\ &\quad + 2(\hat{\epsilon}_i(\hat{\beta}_1 - \beta_1)(x_i - \bar{x}) - \hat{\epsilon}_i \bar{\epsilon} - (\hat{\beta}_1 - \beta_1)(x_i - \bar{x})\bar{\epsilon}) \end{aligned} \quad (2.14)$$

. Από τις εκτιμητικές εξισώσεις στη (1.5) έχουμε πως

$$\begin{aligned} \sum \hat{\epsilon}_i &= 0 \\ \sum x_i \hat{\epsilon}_i &= 0 \\ \implies \sum (x_i - \bar{x}) \hat{\epsilon}_i &= 0 \end{aligned} \quad (2.15)$$

Από τις (2.14) και (2.15) παίρνουμε

$$\begin{aligned} \sum \epsilon_i^2 &= \sum \hat{\epsilon}_i^2 + (\hat{\beta}_1 - \beta_1)^2 \sum (x_i - \bar{x})^2 + n\bar{\epsilon}^2 \implies \\ \frac{\sum \epsilon_i^2}{\sigma^2} &= \frac{\sum \hat{\epsilon}_i^2}{\sigma^2} + \frac{(\hat{\beta}_1 - \beta_1)^2 S_{xx}}{\sigma^2} + \frac{n\bar{\epsilon}^2}{\sigma^2} \end{aligned} \quad (2.16)$$

. Καθότι τα ϵ_i είναι ένα τυχαίο δείγμα από την $N(0, \sigma^2)$ κατανομή έχουμε

$$\begin{aligned} \frac{1}{\sigma^2} \sum \epsilon_i^2 &\sim \chi_n^2 \\ \bar{\epsilon} &\sim N\left(0, \frac{\sigma^2}{n}\right) \implies \frac{1}{\sigma^2} n \bar{\epsilon}^2 \sim \chi_1^2. \end{aligned} \quad (2.17)$$

. Από την (2.3) έχουμε

$$\hat{\beta}_1 \sim N\left(\beta_1, \sigma^2 \frac{1}{S_{xx}}\right) \implies \frac{(\hat{\beta}_1 - \beta_1)^2 S_{xx}}{\sigma^2} \sim \chi_1^2. \quad (2.18)$$

Τα αποτελέσματα στη (1.12) μαζί με την υπόθεση κανονικότητας συνεπάγονται πως

$$\begin{aligned} \text{A)} \quad &\frac{\sum \hat{\epsilon}_i^2}{\sigma^2} \perp\!\!\!\perp \frac{(\hat{\beta}_1 - \beta_1)^2 S_{xx}}{\sigma^2} \\ \text{B)} \quad &\frac{\sum \hat{\epsilon}_i^2}{\sigma^2} \perp\!\!\!\perp \frac{n \bar{\epsilon}^2}{\sigma^2} \quad (\text{καθότι } \bar{\epsilon} = \bar{Y} - \beta_0 - \beta_1 \bar{x}) \\ \text{Γ)} \quad &\frac{(\hat{\beta}_1 - \beta_1)^2 S_{xx}}{\sigma^2} \perp\!\!\!\perp \frac{n \bar{\epsilon}^2}{\sigma^2}. \end{aligned}$$

Από τις τρεις παραπάνω προτάσεις προκύπτει πως $\frac{(\hat{\beta}_1 - \beta_1)^2 S_{xx}}{\sigma^2} + \frac{n \bar{\epsilon}^2}{\sigma^2} \sim \chi_2^2$ και χρησιμοποιώντας το Λήμμα παραπάνω παίρνουμε το πρώτο αποτέλεσμα του θεωρήματος. Το δεύτερο αποτέλεσμα προκύπτει από την (2.18) και το γεγονός πως η μηδενική υπόθεση λέει πως $\beta_1 = 0$. \square

Από το παραπάνω αποτέλεσμα προκύπτει ο F έλεγχος της στατιστικής σημαντικότητας της παλινδρόμησης, δηλαδή της $H_0 : \beta_1 = 0$ έναντι της δίπλευρης εναλλακτικής. Καθότι $\frac{SSR}{\sigma^2} \sim_{H_0} \chi_1^2$, $\frac{SSE}{\sigma^2} \sim \chi_{n-2}^2$, και $SSR \perp\!\!\!\perp SSE$ έχουμε πως

$$\frac{MSR}{MSE} = \frac{SSR/1}{SSE/n-2} \sim_{H_0} F_{1, n-2}, \quad (2.19)$$

με αποτέλεσμα η $H_0 : \beta_1 = 0$ να απορρίπτεται σε επίπεδο σημαντικότητας α όταν η παρατηρηθείσα τιμή της σ.σ.ε. $F = \frac{MSR}{MSE} > F_{1, n-2; \alpha}$. Μπορεί να δειχθεί πως ο παραπάνω έλεγχος είναι ισοδύναμος του ελέγχου στην (2.8).

3 Πολλαπλή Γραμμική Παλινδρόμηση

Θεωρούμε το πολλαπλό γραμμικό μοντέλο (πολλαπλή γραμμική παλινδρόμηση) με $p-1$ συμμεταβλητές :

$$Y_i = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \dots + \beta_{p-1} x_{i, p-1} + \epsilon_i, \quad i = 1, \dots, n, \quad (3.1)$$

Y_i είναι η απόκριση της i -οστής παρατήρησης, $x_{i,k}$ η τιμή της k συμμεταβλητής της i -οστής παρατήρησης και ϵ_i είναι το σφάλμα (δηλαδή η απόκλιση της παρατήρησης Y_i από την μέση τιμή της μ_i). Θεωρούμε τα x ως σταθερές τιμές και όχι ως τ.μ.. Για τα σφάλματα υποθέτουμε πως είναι ομοσκεδαστικά ($var(\epsilon_i) = \sigma^2$) και ασυσχέτιστα ($cov(\epsilon_i, \epsilon_j) = 0$ για $i \neq j$).

Εναλλακτικά το μοντέλο μπορεί να γραφτεί ως:

$$Y_i | x_{i1}, x_{i2}, \dots, x_{i,p-1} \sim (\mu_i, \sigma^2), \quad cov(Y_i, Y_j | x_{i1}, x_{i2}, \dots, x_{i,p-1}, x_{j1}, x_{j2}, \dots, x_{j,p-1}) = 0, \quad i \neq j$$

$$\mu_i = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \dots + \beta_{p-1} x_{i,p-1}, \quad i = 1, \dots, n, \quad (3.2)$$

Μπορούμε να γράψουμε το μοντέλο με χρήση πινάκων και διανυσμάτων, ορίζοντας

$$\mathbf{Y} = \begin{bmatrix} Y_1 \\ Y_2 \\ \vdots \\ Y_n \end{bmatrix}, \quad \mathbf{X} = \begin{bmatrix} 1 & x_{11} & x_{12} & \dots & x_{1,p-1} \\ 1 & x_{21} & x_{22} & \dots & x_{2,p-1} \\ \vdots & \vdots & \vdots & \dots & \vdots \\ 1 & x_{n1} & x_{n2} & \dots & x_{n,p-1} \end{bmatrix} = \begin{bmatrix} \mathbf{x}_1^T \\ \mathbf{x}_2^T \\ \vdots \\ \mathbf{x}_n^T \end{bmatrix}, \quad \boldsymbol{\beta} = \begin{bmatrix} \beta_0 \\ \beta_1 \\ \beta_2 \\ \vdots \\ \beta_{p-1} \end{bmatrix}, \quad \boldsymbol{\epsilon} = \begin{bmatrix} \epsilon_1 \\ \epsilon_2 \\ \vdots \\ \epsilon_n \end{bmatrix}$$

Στις παραπάνω εκφράσεις το διάνυσμα

$$\mathbf{x}_i = \begin{bmatrix} 1 \\ x_{i1} \\ x_{i2} \\ \vdots \\ x_{i,p-1} \end{bmatrix}$$

είναι το διάνυσμα με τις τιμές των συμμεταβλητών για την i παρατήρηση. Το μοντέλο για την i απόκριση γράφεται ως

$$Y_i = \mathbf{x}_i^T \boldsymbol{\beta} + \epsilon_i, \quad i = 1, \dots, n, \quad (3.3)$$

ή εναλλακτικά

$$Y_i | \mathbf{x}_i \sim (\mu_i, \sigma^2), \quad cov(Y_i, Y_j | \mathbf{x}_i, \mathbf{x}_j) = 0, \quad i \neq j$$

$$\mu_i = \mathbf{x}_i^T \boldsymbol{\beta}, \quad i = 1, \dots, n. \quad (3.4)$$

Το μοντέλο για όλες τις παρατηρήσεις γράφεται ως

$$\mathbf{Y} = \mathbf{X}\boldsymbol{\beta} + \boldsymbol{\epsilon}$$

$$\boldsymbol{\epsilon} \sim (\mathbf{0}_n, \sigma^2 \mathbf{I}_n), \quad (3.5)$$

όπου για τον $n \times p$ πίνακα συμμεταβλητών \mathbf{X} ισχύει $\text{rank}(X) = p$, $\mathbf{0}_n = E(\boldsymbol{\epsilon})$ 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. Καθότι υποθέτουμε ασυσχέτιστα και ομοσχεδαστικά σφάλματα ισχύει

$$\text{Var}(\boldsymbol{\epsilon}) = \begin{bmatrix} \text{var}(\epsilon_1) & \text{cov}(\epsilon_1, \epsilon_2) & \dots & \text{cov}(\epsilon_1, \epsilon_{n-1}) & \text{cov}(\epsilon_1, \epsilon_n) \\ \text{cov}(\epsilon_2, \epsilon_1) & \text{var}(\epsilon_2) & \dots & \text{cov}(\epsilon_2, \epsilon_{n-1}) & \text{cov}(\epsilon_2, \epsilon_n) \\ \vdots & \vdots & \dots & \vdots & \vdots \\ \text{cov}(\epsilon_{n-1}, \epsilon_1) & \text{cov}(\epsilon_{n-1}, \epsilon_2) & \dots & \text{var}(\epsilon_{n-1}) & \text{cov}(\epsilon_{n-1}, \epsilon_n) \\ \text{cov}(\epsilon_n, \epsilon_1) & \text{cov}(\epsilon_n, \epsilon_2) & \dots & \text{cov}(\epsilon_n, \epsilon_{n-1}) & \text{var}(\epsilon_n) \end{bmatrix} = \sigma^2 \mathbf{I}_n.$$

Ο εκτιμητής ελαχίστων τετραγώνων του διανύσματος συντελεστών $\boldsymbol{\beta}$ ελαχιστοποιεί το άθροισμα των τετραγωνικών σφαλμάτων, ήτοι είναι οι λύσεις του μαθηματικού προβλήματος

$$\min_{\boldsymbol{\beta}} \sum \epsilon_i^2(\boldsymbol{\beta}) \Leftrightarrow \min_{\boldsymbol{\beta}} \boldsymbol{\epsilon}^T(\boldsymbol{\beta})\boldsymbol{\epsilon}(\boldsymbol{\beta}) \Leftrightarrow \min_{\boldsymbol{\beta}} (\mathbf{Y} - \mathbf{X}\boldsymbol{\beta})^T(\mathbf{Y} - \mathbf{X}\boldsymbol{\beta}) \quad (3.6)$$

Παραγωγίζοντας καταλήγουμε πως οι εκτιμητές ελαχίστων τετραγώνων προκύπτουν ως λύσεις των εκτιμητικών εξισώσεων

$$\mathbf{X}^T(\mathbf{Y} - \mathbf{X}\boldsymbol{\beta}) = \mathbf{0}_p \quad (3.7)$$

Οι εκτιμητές ελαχίστων τετραγώνων προκύπτει ως λύση του παραπάνω γραμμικού συστήματος p εξισώσεων:

$$\hat{\boldsymbol{\beta}} = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{Y}. \quad (3.8)$$

Προφανώς για τα υπόλοιπα $\hat{\boldsymbol{\epsilon}} = \mathbf{Y} - \mathbf{X}\hat{\boldsymbol{\beta}}$ της προσαρμογής ισχύει

$$\mathbf{X}^T \hat{\boldsymbol{\epsilon}} = \mathbf{0}_p, \quad (3.9)$$

δηλαδή τα υπόλοιπα υπόκεινται σε p γραμμικούς περιορισμούς (και άρα δεν μπορεί να είναι στατιστικά συσχέτιστα). Προκύπτει άμεσα πως

$$\begin{aligned} E(\hat{\boldsymbol{\beta}}) &= E((\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{Y}) = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T E(\mathbf{Y}) = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{X} \boldsymbol{\beta} = \boldsymbol{\beta} \\ \text{Var}(\hat{\boldsymbol{\beta}}) &= \text{Var}((\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{Y}) = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \text{Var}(\mathbf{Y}) \mathbf{X} (\mathbf{X}^T \mathbf{X})^{-1} \\ &= (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \sigma^2 \mathbf{I}_n \mathbf{X} (\mathbf{X}^T \mathbf{X})^{-1} = \sigma^2 (\mathbf{X}^T \mathbf{X})^{-1}. \end{aligned} \quad (3.10)$$

Στα παραπάνω αποτελέσματα καταλήξαμε χρησιμοποιώντας το γεγονός πως αν \mathbf{U} είναι ένα $m \times 1$ τυχαίο διάνυσμα και \mathbf{C} ένας $k \times m$ πίνακας σταθερών, τότε $\mathbf{C}\mathbf{U}$ είναι ένα $k \times 1$ τυχαίο διάνυσμα με $E(\mathbf{C}\mathbf{U}) = \mathbf{C}E(\mathbf{U})$ και $\text{Var}(\mathbf{C}\mathbf{U}) = \mathbf{C}\text{Var}(\mathbf{U})\mathbf{C}^T$, ένας $k \times k$ πίνακας.

Ο $p \times p$ πίνακας διακυμάνσεων-συνδιακυμάνσεων του $\hat{\beta}$

$$Var(\hat{\beta}) = \sigma^2(\mathbf{X}^T \mathbf{X})^{-1} = \begin{bmatrix} var(\hat{\beta}_0) & cov(\hat{\beta}_0, \hat{\beta}_1) & cov(\hat{\beta}_0, \hat{\beta}_2) & \dots & cov(\hat{\beta}_0, \hat{\beta}_{p-1}) \\ cov(\hat{\beta}_1, \hat{\beta}_0) & var(\hat{\beta}_1) & cov(\hat{\beta}_1, \hat{\beta}_2) & \dots & cov(\hat{\beta}_1, \hat{\beta}_{p-1}) \\ cov(\hat{\beta}_2, \hat{\beta}_0) & cov(\hat{\beta}_2, \hat{\beta}_1) & var(\hat{\beta}_2) & \dots & cov(\hat{\beta}_2, \hat{\beta}_{p-1}) \\ \vdots & \vdots & \vdots & \dots & \vdots \\ cov(\hat{\beta}_{p-1}, \hat{\beta}_0) & cov(\hat{\beta}_{p-1}, \hat{\beta}_1) & cov(\hat{\beta}_{p-1}, \hat{\beta}_2) & \dots & var(\hat{\beta}_{p-1}) \end{bmatrix}$$

έχει στην διαγώνιο τις διασπορές των εκτιμητριών ($var(\hat{\beta}_i) = \sigma_{\hat{\beta}_i}^2$) και εκτός διαγωνίου τις συνδιασπορές μεταξύ των εκτιμητριών ($cov(\hat{\beta}_i, \hat{\beta}_j) = \sigma_{\hat{\beta}_i, \hat{\beta}_j}$).

Οι προσαρμοσμένες τιμές είναι

$$\begin{aligned} \hat{\mathbf{Y}} &= \mathbf{X}\hat{\beta} = \mathbf{X}(\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{Y} \\ &= \mathbf{H}\mathbf{Y}. \end{aligned} \quad (3.11)$$

Ο πίνακας $\mathbf{H} = \mathbf{X}(\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T$ είναι συμμετρικός και ταυτοδύναμος, δηλαδή ισχύει $\mathbf{H}^2 = \mathbf{H}$ (δείξτε το) και λέγεται Hat Matrix. Ισχύει πως

$$\begin{aligned} \mathbf{H}\mathbf{X} &= \mathbf{X}(\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{X} = \mathbf{X} \\ (\mathbf{I}_n - \mathbf{H})\mathbf{X} &= \mathbf{0} \end{aligned} \quad (3.12)$$

Τα υπόλοιπα είναι

$$\begin{aligned} \hat{\epsilon} &= \mathbf{Y} - \hat{\mathbf{Y}} = \mathbf{Y} - \mathbf{X}\hat{\beta} = \mathbf{Y} - \mathbf{X}(\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{Y} \\ &= (\mathbf{I}_n - \mathbf{H})\mathbf{Y} = (\mathbf{I}_n - \mathbf{H})\mathbf{X}\beta + (\mathbf{I}_n - \mathbf{H})\epsilon = (\mathbf{I}_n - \mathbf{H})\epsilon \end{aligned} \quad (3.13)$$

Ο πίνακας $(\mathbf{I}_n - \mathbf{H})$ είναι συμμετρικός και ταυτοδύναμος, δηλαδή ισχύει $(\mathbf{I}_n - \mathbf{H})^2 = (\mathbf{I}_n - \mathbf{H})$ (δείξτε το).

Μια αμερόληπτη εκτιμήτρια της διασποράς των σφαλμάτων σ^2 δίνεται από

$$\begin{aligned} s^2 &= \frac{1}{n-p} \sum (Y_i - \hat{Y}_i)^2 = \frac{1}{n-p} \sum \hat{\epsilon}_i^2 \\ &= \frac{1}{n-p} \hat{\epsilon}^T \hat{\epsilon} = \frac{1}{n-p} \mathbf{Y}^T (\mathbf{I}_n - \mathbf{H}) \mathbf{Y} \quad (= \frac{1}{n-p} \epsilon^T (\mathbf{I}_n - \mathbf{H}) \epsilon) \end{aligned} \quad (3.14)$$

Αντικαθιστώντας το σ^2 με την εκτιμήτρια s^2 στον $p \times p$ πίνακα διακυμάνσεων-συνδιακυμάνσεων του $\hat{\beta}$ παίρνουμε

$$\hat{Var}(\hat{\beta}) = s^2(\mathbf{X}^T \mathbf{X})^{-1} = \begin{bmatrix} \hat{var}(\hat{\beta}_0) & \hat{cov}(\hat{\beta}_0, \hat{\beta}_1) & \hat{cov}(\hat{\beta}_0, \hat{\beta}_2) & \dots & \hat{cov}(\hat{\beta}_0, \hat{\beta}_{p-1}) \\ \hat{cov}(\hat{\beta}_1, \hat{\beta}_0) & \hat{var}(\hat{\beta}_1) & \hat{cov}(\hat{\beta}_1, \hat{\beta}_2) & \dots & \hat{cov}(\hat{\beta}_1, \hat{\beta}_{p-1}) \\ \hat{cov}(\hat{\beta}_2, \hat{\beta}_0) & \hat{cov}(\hat{\beta}_2, \hat{\beta}_1) & \hat{var}(\hat{\beta}_2) & \dots & \hat{cov}(\hat{\beta}_2, \hat{\beta}_{p-1}) \\ \vdots & \vdots & \vdots & \dots & \vdots \\ \hat{cov}(\hat{\beta}_{p-1}, \hat{\beta}_0) & \hat{cov}(\hat{\beta}_{p-1}, \hat{\beta}_1) & \hat{cov}(\hat{\beta}_{p-1}, \hat{\beta}_2) & \dots & \hat{var}(\hat{\beta}_{p-1}) \end{bmatrix}$$

, που είναι η εκτίμηση του πίνακα διακυμάνσεων-συνδιακυμάνσεων του $\hat{\beta}$ και έχει στην διαγώνιο τις εκτιμήσεις των διασπορών των εκτιμητριών ($\hat{var}(\hat{\beta}_i) = s_{\hat{\beta}_i}^2$) και εκτός διαγωνίου τις εκτιμήσεις των συνδιασπορών μεταξύ των εκτιμητριών ($\hat{cov}(\hat{\beta}_i, \hat{\beta}_j) = s_{\hat{\beta}_i, \hat{\beta}_j}$).

3.1 Πολλαπλή Κανονική Γραμμική Παλινδρόμηση

Το μοντέλο για όλες τις παρατηρήσεις γράφεται ως

$$\begin{aligned} \mathbf{Y} &= \mathbf{X}\boldsymbol{\beta} + \boldsymbol{\epsilon} \\ \boldsymbol{\epsilon} &\sim N(\mathbf{0}_n, \sigma^2 \mathbf{I}_n), \end{aligned} \quad (3.15)$$

όπου για τον $n \times p$ πίνακα συμμεταβλητών \mathbf{X} ισχύει $rank(\mathbf{X}) = p$, $\mathbf{0}_n = E(\boldsymbol{\epsilon})$ 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.

Έχουμε πως

$$\hat{\boldsymbol{\beta}} \sim N(\boldsymbol{\beta}, Var(\hat{\boldsymbol{\beta}}) = \sigma^2(\mathbf{X}^T \mathbf{X})^{-1}), \quad (3.16)$$

από όπου προκύπτει πως κάθε γραμμικός συνδυασμός των εκτιμήσεων των συντελεστών στην παλινδρόμηση ακολουθεί κανονική κατανομή. Πιο συγκεκριμένα, αν πάρουμε ένα $p \times 1$ διάνυσμα $\mathbf{l} \neq \mathbf{0}_p$ (δηλαδή $\mathbf{l}^T = (l_0, l_1, l_2, \dots, l_{p-1}) \neq (0, 0, 0, \dots, 0)$) τότε

$$\mathbf{l}^T \hat{\boldsymbol{\beta}} \sim N(\mathbf{l}^T \boldsymbol{\beta}, Var(\mathbf{l}^T \hat{\boldsymbol{\beta}}) = \mathbf{l}^T Var(\hat{\boldsymbol{\beta}}) \mathbf{l} = \sigma^2 \mathbf{l}^T (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{l}), \quad (3.17)$$

από όπου προκύπτει πως

$$\frac{\mathbf{l}^T \hat{\boldsymbol{\beta}} - \mathbf{l}^T \boldsymbol{\beta}}{\sigma \sqrt{\mathbf{l}^T (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{l}}} \sim N(0, 1), \quad (3.18)$$

Μπορεί να δειχθεί πως

$$\begin{aligned} (n-p) \frac{s^2}{\sigma^2} &\sim \chi_{n-p}^2 \\ s^2 &\perp \hat{\boldsymbol{\beta}}. \end{aligned} \quad (3.19)$$

Άρα, εύκολα προκύπτει

$$\frac{\mathbf{l}^T \hat{\boldsymbol{\beta}} - \mathbf{l}^T \boldsymbol{\beta}}{s \sqrt{\mathbf{l}^T (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{l}}} \sim t_{n-p}. \quad (3.20)$$

3.2 Συμπερασματολογία για παραμέτρους, Διάστημα εμπιστοσύνης, Διάστημα Πρόβλεψης

Από την (3.19) προκύπτει πως ένα $100(1 - \alpha)\%$ Δ.Ε. για τον γραμμικό συνδυασμό $\mathbf{l}^T \boldsymbol{\beta}$ δίνεται από

$$\mathbf{l}^T \hat{\boldsymbol{\beta}} \pm t_{n-p; \frac{\alpha}{2}} \sqrt{\mathbf{l}^T \hat{Var}(\hat{\boldsymbol{\beta}}) \mathbf{l}},$$

όπου $t_{n-p; \alpha/2}$ είναι τό άνω $\alpha/2$ ποσοστιαίο σημείο της t_{n-p} κατανομής και $\hat{Var}(\hat{\boldsymbol{\beta}}) = s^2 (\mathbf{X}^T \mathbf{X})^{-1}$.

Αντίστοιχα, ο έλεγχος της μηδενικής υπόθεση $H_0 : \mathbf{l}^T \boldsymbol{\beta} = r$ έναντι της δίπλευρης εναλλακτικής απορρίπτει την H_0 σε επίπεδο σημαντικότητας α όταν

$$\frac{|\mathbf{l}^T \hat{\boldsymbol{\beta}} - r|}{\sqrt{\mathbf{l}^T \hat{Var}(\hat{\boldsymbol{\beta}}) \mathbf{l}}} > t_{n-p; \frac{\alpha}{2}},$$

Ως παράδειγμα, αν πάρουμε \mathbf{l} νά έχει 1 στην $i+1$ θέση και 0 αλλού παίρνουμε ένα $100(1 - \alpha)\%$ Δ.Ε. για τον συντελεστή β_i

$$\hat{\beta}_i \pm t_{n-p; \frac{\alpha}{2}} s \hat{\beta}_i \quad (3.21)$$

Αν πάρουμε $\mathbf{l} = \mathbf{x}_0$, όπου

$$\mathbf{x}_0 = \begin{bmatrix} 1 \\ x_{01} \\ x_{02} \\ \vdots \\ x_{0,p-1} \end{bmatrix}$$

παίρνουμε ένα $100(1 - \alpha)\%$ Δ.Ε. για την μέση απόκριση $\mu_0 = \mathbf{x}_0^T \boldsymbol{\beta} = \beta_0 + \beta_1 x_{01} + \beta_2 x_{02} + \dots + \beta_{p-1} x_{0,p-1}$

$$\begin{aligned} & \hat{Y}_0 \pm t_{n-p; \frac{\alpha}{2}} s \hat{Y}_0 : \\ & \mathbf{x}_0^T \hat{\boldsymbol{\beta}} \pm t_{n-p; \frac{\alpha}{2}} \sqrt{\mathbf{x}_0^T \hat{Var}(\hat{\boldsymbol{\beta}}) \mathbf{x}_0} : \\ & \mathbf{x}_0^T \hat{\boldsymbol{\beta}} \pm t_{n-p; \frac{\alpha}{2}} s \sqrt{\mathbf{x}_0^T (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{x}_0} \end{aligned} \quad (3.22)$$

Χρησιμοποιώντας το γεγονός πως για μια καινούρια παρατήρηση Y_0 με τιμές συμμεταβλητών $(x_{01}, x_{02}, \dots, x_{0,p-1})$ ισχύει $var(Y_0 - \hat{Y}_0) = \sigma^2 + \sigma_{\hat{Y}_0}^2$ καταλήγουμε σε ένα $100(1 - \alpha)\%$ Διάστημα Πρόβλεψης της Y_0 :

$$\begin{aligned} & \mathbf{x}_0^T \hat{\boldsymbol{\beta}} \pm t_{n-p; \frac{\alpha}{2}} \sqrt{s^2 + \mathbf{x}_0^T \hat{Var}(\hat{\boldsymbol{\beta}}) \mathbf{x}_0} : \\ & \mathbf{x}_0^T \hat{\boldsymbol{\beta}} \pm t_{n-p; \frac{\alpha}{2}} s \sqrt{1 + \mathbf{x}_0^T (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{x}_0} \end{aligned} \quad (3.23)$$

Έστω πως θέλουμε να ελέγξουμε την γενική γραμμική υπόθεση,

$$\begin{aligned} H_0 &: \mathbf{R}\boldsymbol{\beta} = \mathbf{r} \\ H_1 &: \mathbf{R}\boldsymbol{\beta} \neq \mathbf{r}, \end{aligned} \quad (3.24)$$

όπου \mathbf{R} είναι ένας $q \times p$ πίνακας με $\text{rank}(R) = q$, $q \leq p$, και \mathbf{r} ένα $q \times 1$ διάνυσμα πραγματικών τιμών. Η σχέση $\mathbf{R}\boldsymbol{\beta} = \mathbf{r}$ επιβάλλει q περιορισμούς στις παραμέτρους στο $\boldsymbol{\beta}$.

Για παράδειγμα αν $p = 4$ και

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

, τότε η $H_0 : \beta_1 = \beta_2 = \beta_3 = 0$, και ο έλεγχος στην (3.24) είναι ο έλεγχος στατιστικής σημαντικότητας της πολλαπλής παλινδρόμησης .

Αν

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

τότε η $H_0 : \beta_2 = \beta_3 = 0$, και ο έλεγχος στην (3.24) είναι συνηθίζεται να λέγεται έλεγχος στατιστικής σημαντικότητας των συμμεταβλητών x_2, x_3 σε ένα μοντέλο όπου ήδη υπάρχει (έχει περιληφθεί) η x_1 .

Αν

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

τότε η $H_0 : \beta_1 = \beta_2, \beta_3 = 0$, και ο έλεγχος στην (3.24) είναι ένας έλεγχος υπόθεσης αν μπορούμε να χρησιμοποιήσουμε το πιο περιορισμένο Reduced μοντέλο $\mu_i = \beta_0 + \beta_1(x_{i1} + x_{i2})$, έναντι του πλήρους Full μοντέλου, $\mu_i = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \beta_3 x_{i3}$.

Πριν δώσουμε την στατιστική συνάρτηση ελέγχου για τον έλεγχο στην (3.24) θα αναφέρουμε ένα θεώρημα.

Θεώρημα 3. Έστω πως το $k \times 1$ τυχαίο διάνυσμα, \mathbf{Y} , έχει πολυμεταβλητή κανονική κατανομή $\mathbf{Y} \sim N(\boldsymbol{\mu}, \boldsymbol{\Sigma})$, όπου ο $k \times k$ πίνακας $\boldsymbol{\Sigma}$ είναι θετικά ορισμένος. Τότε

$$(\mathbf{Y} - \boldsymbol{\mu})^T \boldsymbol{\Sigma}^{-1} (\mathbf{Y} - \boldsymbol{\mu}) \sim \chi_k^2.$$

Καθότι $\mathbf{R}\hat{\boldsymbol{\beta}} - \mathbf{r} \sim N(\mathbf{R}\boldsymbol{\beta} - \mathbf{r}, \sigma^2 \mathbf{R}(\mathbf{X}^T \mathbf{X})^{-1} \mathbf{R}^T)$, απλή εφαρμογή του παραπάνω θεωρήματος μας δίνει το παρακάτω

$$\frac{1}{\sigma^2} (\mathbf{R}\hat{\boldsymbol{\beta}} - \mathbf{r})^T (\mathbf{R}(\mathbf{X}^T \mathbf{X})^{-1} \mathbf{R}^T)^{-1} (\mathbf{R}\hat{\boldsymbol{\beta}} - \mathbf{r}) \sim^{H_0} \chi_q^2,$$

που σε συνδυασμό με τα αποτελέσματα στη (3.19) μας δίνει πως

$$\begin{aligned}
 F &= \frac{(\mathbf{R}\hat{\boldsymbol{\beta}}-\mathbf{r})^T(\mathbf{R}(\mathbf{X}^T\mathbf{X})^{-1}\mathbf{R}^T)^{-1}(\mathbf{R}\hat{\boldsymbol{\beta}}-\mathbf{r})}{\frac{q}{s^2}} \\
 &= \frac{(\mathbf{R}\hat{\boldsymbol{\beta}}-\mathbf{r})^T(\mathbf{R}(\mathbf{X}^T\mathbf{X})^{-1}\mathbf{R}^T)^{-1}(\mathbf{R}\hat{\boldsymbol{\beta}}-\mathbf{r})}{\frac{SSE_{Full}}{n-p}} \sim^{H_0} F_{q,n-p}. \quad (3.25)
 \end{aligned}$$

Μπορεί να αποδειχθεί πως ισοδύναμα

$$\begin{aligned}
 F &= \frac{\frac{SSR_{Full}-SSR_{Red}}{q}}{\frac{SSE_{Full}}{n-p}} \\
 &= \frac{\frac{SSE_{Red}-SSE_{Full}}{q}}{\frac{SSE_{Full}}{n-p}} \sim^{H_0} F_{q,n-p}. \quad (3.26)
 \end{aligned}$$

Ως παράδειγμα θεωρήστε την πολλαπλή γραμμική παλινδρόμηση με $n = 100$, $p = 6$ και θέλουμε να ελέγξουμε την υπόθεση $H_0 : \beta_3 = \beta_4 = \beta_5 = 0$. Η σ.σ.ε. τότε ισούται με

$$F = \frac{SSR(X_3, X_4, X_5|X_1, X_2)}{\frac{3}{100-6}}, \quad (3.27)$$

όπου $SSR(X_3, X_4, X_5|X_1, X_2) = SSR(X_3, X_4, X_5, X_1, X_2) - SSR(X_1, X_2)$ είναι το άθροισμα τετραγώνων που 'εξηγούν' οι μεταβλητές X_3, X_4, X_5 πέρα των X_1, X_2 , και μπορεί να υπολογιστεί με τα Sequential Sum of Squares:

$$\begin{aligned}
 SSR(X_3, X_4, X_5|X_1, X_2) &= SSR(X_3|X_1, X_2) + SSR(X_4|X_1, X_2, X_3) + SSR(X_5|X_1, X_2, X_3, X_4) \\
 &= SSR(X_4|X_1, X_2) + SSR(X_3|X_1, X_2, X_4) + SSR(X_5|X_1, X_2, X_3, X_4) \\
 &= SSR(X_5|X_1, X_2) + SSR(X_4|X_1, X_2, X_5) + SSR(X_3|X_1, X_2, X_4, X_5) \\
 &= etc.. \quad (3.28)
 \end{aligned}$$