

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  $\beta$ , ' 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  $\epsilon_i$  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

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

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  $x_i$ . Καθоти 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 δείξουμε 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. )

Διάσπαση του αθροίσματος τετραγώνων: Ορίζουμε  $SSTO = \sum (Y_i - \bar{Y})^2$  (Sum of Squares Total),  $SSR = \sum (\hat{Y}_i - \bar{Y})^2$  (Sum of Squares Regression),  $SSE = \sum (Y_i - \hat{Y}_i)^2$  (Sum of Squares Error). Ισχύει πως  $SSTO = SSR + SSE$ . Ο συντελεστής προσδιορισμού ορίζεται ως

$$R^2 = \frac{SSR}{SSTO} = 1 - \frac{SSE}{SSTO}.$$

Για υπολογισμούς με το χέρι βολεύει η χρησιμοποίηση του τύπου  $SSR = \hat{\beta}_1^2 S_{xx}$ .

## 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:

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

όπου η 1η πρόταση παραπάνω απλά αναφέρει πως το  $2 \times 1$  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  $\Sigma$ , όπου

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

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

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

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  $\alpha$  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  $100(1 - \alpha)\%$  Διάστημα Εμπιστοσύνης για την μέση τιμή  $\mu_0 = \beta_0 + \beta_1 x_0$  δίνεται από

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

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

$$\begin{aligned} E(Y_0 - \hat{Y}_0) &= 0 \\ \text{Var}(Y_0 - \hat{Y}_0) &= \text{Var}(Y_0) + \text{Var}(\hat{Y}_0) = \sigma^2 \left(1 + \frac{1}{n} + \frac{(x_0 - \bar{x})^2}{S_{xx}}\right) \end{aligned} \quad (2.9)$$

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 $\chi^2$ , 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  $\chi_\nu^2$  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 (2.12) και (2.13) 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  $\epsilon_i$  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  $\alpha$  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,  $x_{ik}$  η τιμή της  $k$  συμμεταβλητής της  $i$ -οστής παρατήρησης και  $\epsilon_i$  είναι το σφάλμα (δηλαδή η απόκλιση της παρατήρησης  $Y_i$  από την μέση τιμή της  $\cdot$ ). Θεωρούμε τα  $x$  ως σταθερές τιμές κι 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 ασυσχέτιστα). 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 διαγώνιου 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  $\sigma^2$  δίνεται από

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

Αντικαθιστώντας το  $\sigma^2$  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  $\hat{\beta}$  κι 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

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

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

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

από όπου προκύπτει πως

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

Μπορεί να δειχθεί πως

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

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  $\alpha$  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  $\beta_i$

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

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  $\text{var}(Y_0 - \hat{Y}_0) = \sigma^2 + \sigma_{\hat{Y}_0}^2$  καταλήγουμε σε ένα  $100(1 - \alpha)\%$  Διάστημα Πρόβλεψης της  $Y_0$  :

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

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  $\text{rank}(\mathbf{R}) = q$ ,  $q \leq p$ , 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

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

Μπορεί να αποδειχθεί πως ισοδύναμα

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

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

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

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:

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

### 3.3 Πίνακες ANOVA

Πρότυπο:  $Y_i = \beta_0 + \beta_1 X_{i1} + \dots + \beta_{p-1} X_{i,p-1} + \epsilon_i$ ,  $i = 1, \dots, n$ ,  $\epsilon_1, \dots, \epsilon_n \sim iid N(0, \sigma^2)$

Πίνακας 1: ANOVA βασισμένος στα Adjusted Sum of Squares

Source	df	$SS_{adj}$	$MS$	$F$	$p$ -value
<i>Model</i>	$p - 1$	$SSR = SS(X_1, \dots, X_{p-1})$	$MS_{reg} = \frac{SSR}{p-1}$	$\frac{MS_{reg}}{MS_{error}}$	$p_0 = P(F_{p-1, n-p} > f_0)$
$X_1$	1	$SS_1 = SS(X_1 X_2, \dots, X_{p-1})$	$MS_1 = \frac{SS_1}{1}$	$F_1 = \frac{MS_1}{MS_{error}}$	$p_1 = P(F_{1, n-p} > f_1)$
$X_2$	1	$SS_2 = SS(X_2 X_1, X_3, \dots, X_{p-1})$	$MS_2 = \frac{SS_2}{1}$	$F_2 = \frac{MS_2}{MS_{error}}$	$p_2 = P(F_{1, n-p} > f_2)$
$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	
$X_k$	1	$SS_k = SS(X_k X_1, \dots, X_{k-1}, X_{k+1}, \dots, X_{p-1})$	$MS_k = \frac{SS_k}{1}$	$F_k = \frac{MS_k}{MS_{error}}$	$p_k = P(F_{1, n-p} > f_k)$
$X_{k+1}$	1	$SS_{k+1} = SS(X_{k+1} X_1, \dots, X_k, X_{k+2}, \dots, X_{p-1})$	$MS_{k+1} = \frac{SS_{k+1}}{1}$	$F_{k+1} = \frac{MS_{k+1}}{MS_{error}}$	$p_{k+1} = P(F_{1, n-p} > f_{k+1})$
$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	
$X_{p-1}$	1	$SS_{p-1} = SS(X_{p-1} X_1, \dots, X_{p-2})$	$MS_{p-1} = \frac{SS_{p-1}}{1}$	$F_{p-1} = \frac{MS_{p-1}}{MS_{error}}$	$p_{p-1} = P(F_{1, n-p} > f_{p-1})$
<i>Error</i>	$n - p$	$SSE = SST - SSR$	$MS_{error} = SSE/(n - p)$		
<i>Total</i>	$n - 1$	$SST$			

- Έλεγχος της  $H_0 : \beta_1 = \beta_2 = \dots = \beta_{p-1} = 0$  έναντι της  $H_1 : not H_0$ , σε επίπεδο σημαντικότητας  $\alpha$  (ισοδύναμα Reduced model:  $\mu_i = \beta_0$ , Full model:  $\mu_i = \beta_0 + \beta_1 X_{i1} + \dots + \beta_{p-1} X_{i,p-1}$ ) : Απορρίπτω την μηδενική υπόθεση αν  $p_0 < \alpha$ .
- Έλεγχος της  $H_0 : \beta_k = 0$  έναντι της  $H_1 : \beta_k \neq 0$ , σε επίπεδο σημαντικότητας  $\alpha$  (ισοδύναμα Reduced model:  $\mu_i = \beta_0 + \beta_1 X_{i1} + \dots + \beta_{k-1} X_{i,k-1} + \beta_{k+1} X_{i,k+1} + \dots + \beta_{p-1} X_{i,p-1}$ , Full model:  $\mu_i = \beta_0 + \beta_1 X_{i1} + \dots + \beta_{p-1} X_{i,p-1}$ ) : Απορρίπτω την μηδενική υπόθεση αν  $p_k < \alpha$ .

Πίνακας 2: ANOVA με τα Sequential Sum of Squares — Η σειρά μετράει!

Source	df	$SS_{seq}$	$MS$	$F$	$p-value$
<i>Model</i>	$p-1$	$SSR = SS(X_1, \dots, X_{p-1})$	$MS_{reg} = \frac{SSR}{p-1}$	$\frac{MS_{reg}}{MS_{error}}$	$p_0 = P(F_{p-1, n-p} > f)$
$X_1$	1	$SS_1 = SS(X_1)$	$MS_1 = \frac{SS_1}{1}$	$F_1 = \frac{MS_1}{MS_{error}}$	$p_1 = P(F_{1, n-p} > f_1)$
$X_2$	1	$SS_2 = SS(X_2 X_1)$	$MS_2 = \frac{SS_2}{1}$	$F_2 = \frac{MS_2}{MS_{error}}$	$p_2 = P(F_{1, n-p} > f_2)$
$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	
$X_k$	1	$SS_k = SS(X_k X_1, \dots, X_{k-1})$	$MS_k = \frac{SS_k}{1}$	$F_k = \frac{MS_k}{MS_{error}}$	$p_k = P(F_{1, n-p} > f_k)$
$X_{k+1}$	1	$SS_{k+1} = SS(X_{k+1} X_1, \dots, X_k)$	$MS_{k+1} = \frac{SS_{k+1}}{1}$	$F_{k+1} = \frac{MS_{k+1}}{MS_{error}}$	$p_{k+1} = P(F_{1, n-p} > f_{k+1})$
$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	
$X_{p-1}$	1	$SS_{p-1} = SS(X_{p-1} X_1, \dots, X_{p-2})$	$MS_{p-1} = \frac{SS_{p-1}}{1}$	$F_{p-1} = \frac{MS_{p-1}}{MS_{error}}$	$p_{p-1} = P(F_{1, n-p} > f_{p-1})$
<i>Error</i>	$n-p$	$SSE = SST - SSR$	$MS_{error} = SSE/(n-p)$		
<i>Total</i>	$n-1$	$SST$			

- Έλεγχος της  $H_0 : \beta_1 = \beta_2 = \dots = \beta_{p-1} = 0$  έναντι της  $H_1 : not H_0$ , σε επίπεδο σημαντικότητας  $\alpha$  (ισοδύναμα Reduced model:  $\mu_i = \beta_0$ , Full model:  $\mu_i = \beta_0 + \beta_1 X_{i1} + \dots + \beta_{p-1} X_{i,p-1}$ ) : Απορρίπτω την μηδενική υπόθεση αν  $p_0 < \alpha$ .
- Έλεγχος της  $H_0 : \beta_{k+1} = 0$  έναντι της  $H_1 : \beta_{k+1} \neq 0$ , στο μοντέλο  $Y_i = \beta_0 + \beta_1 X_{i1} + \dots + \beta_{k+1} X_{i,k+1} + \epsilon_i$ ,  $i = 1, \dots, n$ ,  $\epsilon_1, \dots, \epsilon_n \sim iid N(0, \sigma^2)$ , και σε επίπεδο σημαντικότητας  $\alpha$  (ισοδύναμα Reduced model:  $\mu_i = \beta_0 + \beta_1 X_{i1} + \dots + \beta_k X_{i,k}$ , Full model:  $\mu_i = \beta_0 + \beta_1 X_{i1} + \dots + \beta_{k+1} X_{i,k+1}$ ). **ΠΡΟΣΟΧΗ!!** Ο πίνακας "προτείνει" απόρριψη της μηδενικής υπόθεσης αν  $p_{k+1} < \alpha$ . **ΜΗΝ ΤΟ ΚΑΝΕΤΕ ΕΤΣΙ!!**, εκτός αν  $k+1 = p-1$ . Αυτός ο έλεγχος είναι έγκυρος μόνο όταν ισχύει επιπλέον πως  $\beta_{k+2} = \dots = \beta_{p-1} = 0$ . Αντί αυτού κάνετε τον *partial F* έλεγχο.
- *Partial F* έλεγχος της  $H_0 : \beta_{k+1} = 0$  έναντι της  $H_1 : \beta_{k+1} \neq 0$ , στο μοντέλο  $Y_i = \beta_0 + \beta_1 X_{i1} + \dots + \beta_{k+1} X_{i,k+1} + \epsilon_i$ ,  $i = 1, \dots, n$ ,  $\epsilon_1, \dots, \epsilon_n \sim iid N(0, \sigma^2)$ , και σε επίπεδο σημαντικότητας  $\alpha$  (ισοδύναμα Reduced model:  $\mu_i = \beta_0 + \beta_1 X_{i1} + \dots + \beta_k X_{i,k}$ , Full model:  $\mu_i = \beta_0 + \beta_1 X_{i1} + \dots + \beta_{k+1} X_{i,k+1}$ ).

Υπολογίζω τη σ.σ.ε. από τον παραπάνω πίνακα:  $F = \frac{SS_{k+1}}{SS_{k+2} + \dots + SS_{p-1} + SSE} \cdot \frac{1}{n-k-2}$ .

Απορρίπτω την μηδενική υπόθεση αν  $p-value = P(F_{1, n-k-2} > f) < \alpha$ , (όπου  $f$  είναι η παρατηρούμενη τιμή της σ.σ.ε.) .