

1 Εκτιμητής Ελαχίστων Τετραγώνων στην α-πλή γραμμική παλινδρόμηση

Θεωρούμε το απλό γραμμικό μοντέλο (απλή γραμμική παλιδρόμηση) :

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

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 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:

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

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

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

Οι εκτιμητές ελαχίστων τετραγώνων μπορούν να εκφραστούν ως γραμμικοί συνδυασμοί των Y :

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

όπου

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

Για τους συντελεστές c_i, d_i ισχύουν τα παρακάτω:

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

Χρησιμοποιώντας το γεγονός πως

$$\begin{aligned} E(\sum \alpha_r Y_r) &= \sum \alpha_r E(Y_r) \\ Cov(\sum \alpha_r Y_r, \sum \gamma_r Y_r) &= \sigma^2 \sum \alpha_r \gamma_r \end{aligned} \quad (1.8)$$

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 . Καθοτι 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 δεξιούμε πώς

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

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

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

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:

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

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

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

ακολουθεί πολυμεταβλητή κανονική κατανομή με μέση τιμή

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

και πίνακα διακυμάνσεων-συνδιακυμάνσεων Σ , όπου

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

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

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

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 $H_0 : l_1\beta_0 + l_2\beta_1 = r$ 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 $\mu_0 = \beta_0 + \beta_1x_0$, 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

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

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

Έστω πως θέλουμε να προβλέψουμε μια νέα τιμη 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 παρατηρησή 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 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 πρόβλεψης $Y_0 - \hat{Y}_0$ ισχύουν

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

που μαζί με την υπόθεση καινονικότητας μας δίνει

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

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. Εστω $U = U_1 + U_2$. Άντας $U \sim \chi_k^2$, $U_1 \sim \chi_l^2$, $\mu \epsilon k > l$ και U_1 είναι ανεξάρτητη της U_2 , τότε $U_2 \sim \chi_{k-l}^2$

Απόδειξη. Για της ροπογεννήτριας 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 $U_2 \sim \chi_{k-l}^2$. \square

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

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

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

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

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) παρνούμε

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

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

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

. Από την (2.3) έχουμε

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

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

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

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 παίρουμε 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). Θεωρούμε τα x ως σταθερές τιμές κι όχι ως τ.μ.. Για τα σφάλματα υποθέτουμε πως είναι ομοσκεδαστικά ($var(\epsilon_i) = \sigma^2$) και ασυγχέτιστα ($cov(\epsilon_i, \epsilon_j) = 0$ για $i \neq j$).

Εναλλακτικά το μοντέλο μπορεί να γραφτεί ως:

$$\begin{aligned} Y_i | x_{i1}, x_{i2}, \dots, x_{i,p-1} &\sim (\mu_i, \sigma^2), \quad cov(Y_i, Y_j | x_{i1}, x_{i2}, \dots, x_{i,p-1}, x_{j1}, x_{j2}, \dots, x_{j,p-1}) = 0, \quad i \neq j \\ \mu_i &= \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \dots + \beta_{p-1} x_{i,p-1}, \quad i = 1, \dots, n, \end{aligned} \quad (3.2)$$

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

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

Στις παραπάνω εκφράσεις το δίανυσμα

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

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

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

ή εναλλακτικά

$$\begin{aligned} Y_i | \mathbf{x}_i &\sim (\mu_i, \sigma^2), \quad cov(Y_i, Y_j | \mathbf{x}_i, \mathbf{x}_j) = 0, \quad i \neq j \\ \mu_i &= \mathbf{x}_i^T \boldsymbol{\beta}, \quad i = 1, \dots, n. \end{aligned} \quad (3.4)$$

Το μοντέλο για όλες τις παρατηρήσεις γράφεται ως

$$\begin{aligned} \mathbf{Y} &= \mathbf{X}\boldsymbol{\beta} + \boldsymbol{\epsilon} \\ \boldsymbol{\epsilon} &\sim (\mathbf{0}_n, \sigma^2 \mathbf{I}_n), \end{aligned} \quad (3.5)$$

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 $n \times n$ ταυτοικός πίνακας με μοναδες στην διαγώνιο και μηδενικά εκτος διαγωνίου. Καθότι υποθέτουμε ασυσχέτιστα και ομοσκεδαστικά σφάλματα ισχύει

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

Ο εκτιμητής ελαχίστων τετραγώνων του διανύσματος συντελεστών β ελαχιστοποιεί το άθροισμα των τετραγωνικών σφαλμάτων, ήτοι είναι οι λύσεις του μαθηματικού προβλήματος

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

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

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

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

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

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

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

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

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

Στα παραπάνω αποτελέσματα καταλήζαμε 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 $Var(\mathbf{C}\mathbf{U}) = \mathbf{C}Var(\mathbf{U})\mathbf{C}^T$, 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

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

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. Τα υπόλοιπα είναι

$$\begin{aligned}\hat{\boldsymbol{\epsilon}} &= \mathbf{Y} - \hat{\mathbf{Y}} = \mathbf{Y} - \mathbf{X}\hat{\boldsymbol{\beta}} = \mathbf{Y} - \mathbf{X}(\mathbf{X}^T\mathbf{X})^{-1}\mathbf{X}^T\mathbf{Y} \\ &= (\mathbf{I}_n - \mathbf{H})\mathbf{Y}.\end{aligned}\quad (3.12)$$

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

$$\begin{aligned}s^2 &= \frac{1}{n-p} \sum (Y_i - \hat{Y}_i)^2 = \frac{1}{n-p} \sum \hat{\epsilon}_i^2 \\ &= \frac{1}{n-p} \hat{\boldsymbol{\epsilon}}^T \hat{\boldsymbol{\epsilon}} = \frac{1}{n-p} \mathbf{Y}^T (\mathbf{I}_n - \mathbf{H}) \mathbf{Y}\end{aligned}\quad (3.13)$$

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

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

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

$$\begin{aligned}\mathbf{Y} &= \mathbf{X}\boldsymbol{\beta} + \boldsymbol{\epsilon} \\ \boldsymbol{\epsilon} &\sim N(\mathbf{0}_n, \sigma^2 \mathbf{I}_n),\end{aligned}\quad (3.14)$$

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 $n \times n$ ταυτοικός πίνακας με μοναδες στην διαγώνιο και μηδενικά εκτος διαγωνίου.

Έχουμε πως

$$\hat{\boldsymbol{\beta}} \sim N(\boldsymbol{\beta}, Var(\hat{\boldsymbol{\beta}}) = \sigma^2(\mathbf{X}^T \mathbf{X})^{-1}), \quad (3.15)$$

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

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

από όπου προκύπτει πως

$$\frac{\mathbf{l}^T \hat{\boldsymbol{\beta}} - \mathbf{l}^T \boldsymbol{\beta}}{\sigma \sqrt{\mathbf{l}^T (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{l}}} \sim N(0, 1), \quad (3.17)$$

Μπορεί να δειχθεί πως

$$(n-p) \frac{s^2}{\sigma^2} \sim \chi_{n-p}^2$$

$$s^2 \perp\!\!\!\perp \hat{\boldsymbol{\beta}}. \quad (3.18)$$

Άρα, εύκολα προκύπτει

$$\frac{\mathbf{l}^T \hat{\boldsymbol{\beta}} - \mathbf{l}^T \boldsymbol{\beta}}{s \sqrt{\mathbf{l}^T (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{l}}} \sim t_{n-p}. \quad (3.19)$$

3.2 Συμπερασματολογία για παραμέτρους, Διάστημα εμπιστοσύνης, Διάστημα Πρόβλεψης

Από την (3.18) προκύπτει πως ένα $100(1 - \alpha)\%$ Δ.Ε. για τον γραμμικό συνδυασμό $\mathbf{l}^T \boldsymbol{\beta}$ δίνεται από

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

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

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

$$\hat{\beta}_i \pm t_{n-p; \frac{\alpha}{2}} s_{\hat{\beta}_i}$$

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

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