

# 1 Πίνακες

## 1.1 Φασματική ανάλυση ενός πραγματικού συμμετρικού πίνακα

**Θεώρημα 1.** Έστω  $\mathbf{A}$  ένας πραγματικός  $n \times n$  συμμετρικός πίνακας. Ισχύει πως  $\mathbf{A} = \mathbf{P}\mathbf{\Lambda}\mathbf{P}^T$ , όπου  $\mathbf{\Lambda} = \text{diag}(\lambda_1, \lambda_2, \dots, \lambda_n)$  είναι ένας  $n \times n$  διαγώνιος πίνακας που περιέχει τις (πραγματικές) ιδιοτιμές του πίνακα  $\mathbf{A}$ , ενώ  $\mathbf{P} = [\mathbf{p}_1 \ \mathbf{p}_2 \ \dots \ \mathbf{p}_n]$  είναι ένας  $n \times n$  ορθοκανονικός πίνακας (δηλαδή  $\mathbf{P}\mathbf{P}^T = \mathbf{P}^T\mathbf{P} = \mathbf{I}_n$ ) που περιέχει τα  $n$  (πραγματικά) ιδιοδιανύσματα του  $\mathbf{A}$ .

**Θεώρημα 2.** Έστω  $\mathbf{\Sigma}$  ένας  $n \times n$  θετικά ορισμένος συμμετρικός πίνακας (positive definite, pd). Ισχύει πως  $\lambda_i > 0$  για κάθε  $i = 1, 2, \dots, n$ .

Απόδειξη. Καθότι  $\mathbf{\Sigma}$  είναι pd ισχύει εξ ορισμού πως  $\forall \mathbf{a} \neq \mathbf{0}_n$  έχουμε  $\mathbf{a}^T \mathbf{\Sigma} \mathbf{a} > 0$ . Επίσης έχουμε  $\mathbf{\Sigma} = \mathbf{P}\mathbf{\Lambda}\mathbf{P}^T \implies \mathbf{P}^T \mathbf{\Sigma} \mathbf{P} = \mathbf{\Lambda}$ .

Έστω  $\mathbf{b} \neq \mathbf{0}$ . Έχουμε  $\mathbf{b}^T \mathbf{\Lambda} \mathbf{b} = \mathbf{b}^T \mathbf{P}^T \mathbf{\Sigma} \mathbf{P} \mathbf{b} = (\mathbf{P} \mathbf{b})^T \mathbf{\Sigma} (\mathbf{P} \mathbf{b}) = \mathbf{a}^T \mathbf{\Sigma} \mathbf{a} > 0$ , όπου  $\mathbf{a} = \mathbf{P} \mathbf{b} \neq \mathbf{0}$  (καθότι  $\mathbf{P}$  έχει τάξη  $n$ ). Παίρνοντας  $\mathbf{b}^T = [1 \ 0 \ \dots \ 0]$  έχουμε  $\lambda_1 > 0$ . Παίρνοντας  $\mathbf{b}^T = [0 \ 1 \ \dots \ 0]$  έχουμε  $\lambda_2 > 0$ . κ.ο.κ..  $\square$

**Θεώρημα 3.** Έστω  $\mathbf{\Sigma}$  ένας  $n \times n$  θετικά ορισμένος συμμετρικός πίνακας. Ισχύει πως υπάρχει  $n \times n$  (pd) συμμετρικός πίνακας  $\mathbf{\Sigma}^{1/2}$ , ώστε  $\mathbf{\Sigma}^{1/2} \mathbf{\Sigma}^{1/2} = \mathbf{\Sigma}$ . Ο πίνακας  $\mathbf{\Sigma}^{1/2}$  λέγεται τετραγωνική ρίζα του  $\mathbf{\Sigma}$ .

Απόδειξη.  $\mathbf{\Sigma} = \mathbf{P}\mathbf{\Lambda}\mathbf{P}^T = \mathbf{P}\mathbf{\Lambda}^{1/2}\mathbf{\Lambda}^{1/2}\mathbf{P}^T = \mathbf{P}\mathbf{\Lambda}^{1/2}\mathbf{P}^T \mathbf{P}\mathbf{\Lambda}^{1/2}\mathbf{P}^T = \mathbf{\Sigma}^{1/2} \mathbf{\Sigma}^{1/2}$ , όπου  $\mathbf{\Sigma}^{1/2} = \mathbf{P}\mathbf{\Lambda}^{1/2}\mathbf{P}^T$  είναι  $n \times n$  pd πίνακας.  $\square$

**Θεώρημα 4.** Έστω  $\mathbf{A}$  ένας συμμετρικός  $n \times n$  ταυτοδύναμος πίνακας. Ο  $\mathbf{A}$  έχει ιδιοτιμές ίσες με 0 ή 1. Ο αριθμός των ιδιοτιμών που ισούνται με 1 είναι ίσος με  $\text{tr}(\mathbf{A}) = \text{rank}(\mathbf{A})$ .

Απόδειξη.  $\mathbf{A}^2 = \mathbf{A} \implies \mathbf{P}\mathbf{\Lambda}\mathbf{P}^T \mathbf{P}\mathbf{\Lambda}\mathbf{P}^T = \mathbf{P}\mathbf{\Lambda}\mathbf{P}^T \implies \mathbf{P}\mathbf{\Lambda}^2\mathbf{P}^T = \mathbf{P}\mathbf{\Lambda}\mathbf{P}^T \implies \mathbf{\Lambda}^2 = \mathbf{\Lambda} \implies \lambda_i = 0 \text{ ή } 1, i = 1, \dots, n$ . Ο αριθμός των μονάδων ισούται (προφανώς) με το άθροισμα των στοιχείων της διαγώνιου του  $\mathbf{\Lambda}$ , δηλαδή ισούται με το  $\text{tr}(\mathbf{\Lambda}) = \text{rank}(\mathbf{\Lambda})$ . Επίσης ισχύει  $\text{tr}(\mathbf{A}) = \text{tr}(\mathbf{P}\mathbf{\Lambda}\mathbf{P}^T) = \text{tr}(\mathbf{P}^T \mathbf{P} \mathbf{\Lambda}) = \text{tr}(\mathbf{\Lambda})$  και  $\text{rank}(\mathbf{A}) = \text{rank}(\mathbf{\Lambda})$ .  $\square$

## 2 Εφαρμογές Στατιστική

Λέμε πως το τυχαίο  $n \times 1$  διάνυσμα  $\mathbf{Y}$  ακολουθεί την πολυμεταβλητή κανονική κατανομή με μέσο  $\boldsymbol{\mu}$  και πίνακα διασπορών συνδιασπορών  $\boldsymbol{\Sigma}$ ,  $\mathbf{Y} \sim N(\boldsymbol{\mu}, \boldsymbol{\Sigma})$  αν η σ.π.π. του  $\mathbf{Y}$  είναι:

$$f_{\mathbf{Y}}(y_1, y_2, \dots, y_n) = f_{\mathbf{Y}}(\mathbf{y}) = \frac{e^{-\frac{1}{2}(\mathbf{y}-\boldsymbol{\mu})^T \boldsymbol{\Sigma}^{-1}(\mathbf{y}-\boldsymbol{\mu})}}{(2\pi)^{n/2} |\boldsymbol{\Sigma}|^{1/2}}$$

Στο μάθημα αυτό θα υποθέσουμε πως  $\boldsymbol{\Sigma}$  είναι  $n \times n$  (pd) πίνακας. Ισχύουν τα ακόλουθα.

1. Η ροπογεννήτρια του  $\mathbf{Y}$  είναι

$$M_{\mathbf{Y}}(\mathbf{t}) = E(e^{\mathbf{t}^T \mathbf{y}}) = e^{\mathbf{t}^T \boldsymbol{\mu} + \frac{1}{2} \mathbf{t}^T \boldsymbol{\Sigma} \mathbf{t}}.$$

2. Έστω  $\mathbf{K}$  ένας  $k \times n$  πίνακας. Τότε  $\mathbf{KY} \sim N(\mathbf{K}\boldsymbol{\mu}, \mathbf{K}\boldsymbol{\Sigma}\mathbf{K}^T)$ .

3. Γράφοντας

$$\mathbf{Y} = \begin{bmatrix} \mathbf{Y}_1 \\ \mathbf{Y}_2 \end{bmatrix} \sim N\left(\begin{bmatrix} \boldsymbol{\mu}_1 \\ \boldsymbol{\mu}_2 \end{bmatrix}, \begin{bmatrix} \boldsymbol{\Sigma}_{11} & \boldsymbol{\Sigma}_{12} \\ \boldsymbol{\Sigma}_{21} & \boldsymbol{\Sigma}_{22} \end{bmatrix}\right)$$

Έχουμε  $\mathbf{Y}_1 \sim N(\boldsymbol{\mu}_1, \boldsymbol{\Sigma}_{11})$ .

4. Έχουμε

$$\mathbf{Y}_1 | \mathbf{Y}_2 = \mathbf{y}_2 \sim N(\boldsymbol{\mu}_1 + \boldsymbol{\Sigma}_{12} \boldsymbol{\Sigma}_{22}^{-1}(\mathbf{y}_2 - \boldsymbol{\mu}_2), \boldsymbol{\Sigma}_{11} - \boldsymbol{\Sigma}_{12} \boldsymbol{\Sigma}_{22}^{-1} \boldsymbol{\Sigma}_{21})$$

Απλό παράδειγμα:

$$\mathbf{Y} = \begin{bmatrix} Y_1 \\ Y_2 \end{bmatrix} \sim N\left(\begin{bmatrix} 1 \\ 2 \end{bmatrix}, \begin{bmatrix} 4 & 2 \\ 2 & 9 \end{bmatrix}\right)$$

Έχουμε  $|\boldsymbol{\Sigma}| = 32$  και

$$\boldsymbol{\Sigma}^{-1} = \frac{1}{32} \begin{bmatrix} 9 & -2 \\ -2 & 4 \end{bmatrix}$$

$$-\frac{1}{2}(\mathbf{y} - \boldsymbol{\mu})^T \boldsymbol{\Sigma}^{-1}(\mathbf{y} - \boldsymbol{\mu}) = -\frac{1}{2} \frac{1}{32} [(y_1 - 1) \quad (y_2 - 2)] \begin{bmatrix} 9 & -2 \\ -2 & 4 \end{bmatrix} \begin{bmatrix} (y_1 - 1) \\ (y_2 - 2) \end{bmatrix}$$

$$\text{Άρα } -\frac{1}{2}(\mathbf{y}-\boldsymbol{\mu})^T \boldsymbol{\Sigma}^{-1}(\mathbf{y}-\boldsymbol{\mu}) = -\frac{1}{64}\{9(y_1-1)^2 - 4(y_1-1)(y_2-2) + 4(y_2-2)^2\}$$

$$f_{Y_1, Y_2}(y_1, y_2) = \frac{e^{-\frac{9}{64}(y_1-1)^2 + \frac{4}{64}(y_1-1)(y_2-2) - \frac{4}{64}(y_2-2)^2}}{(2\pi)\sqrt{32}}$$

Η τιμή της σ.π.π. στο σημείο  $(y_1, y_2) = (2, 3)$  ισούται με

$$\begin{aligned} f_{Y_1, Y_2}(2, 3) &= \frac{e^{-\frac{9}{64}(2-1)^2 + \frac{4}{64}(2-1)(3-2) - \frac{4}{64}(3-2)^2}}{(2\pi)\sqrt{32}} \\ &= 0.024444 \end{aligned}$$

Επίσης για τον υπολογισμό της ροπογεννήτριας έχουμε

$$\mathbf{t}^T \boldsymbol{\mu} = t_1\mu_1 + t_2\mu_2 = t_1 + 2t_2, \quad \mathbf{t}^T \boldsymbol{\Sigma} \mathbf{t} = \begin{bmatrix} t_1 & t_2 \end{bmatrix} \begin{bmatrix} 4 & 2 \\ 2 & 9 \end{bmatrix} \begin{bmatrix} t_1 \\ t_2 \end{bmatrix} = 4t_1^2 + 9t_2^2 + 4t_1t_2$$

Η ροπογεννήτρια ισούται με  $M_{\mathbf{Y}}(\mathbf{t}) = M_{Y_1, Y_2}(t_1, t_2) = e^{t_1 + 2t_2 + \frac{1}{2}(4t_1^2 + 9t_2^2 + 4t_1t_2)}$

$$Y_1|Y_2 = y_2 \sim N\left(1 + \frac{2}{9}(y_2 - 2), 4 - \frac{4}{9}\right), \text{ δηλαδή}$$

$$Y_1|Y_2 = y_2 \sim N\left(1 + \frac{2}{9}(y_2 - 2), \frac{32}{9}\right).$$

$$Y_1|Y_2 = 3 \sim N\left(\frac{11}{9}, \frac{32}{9}\right).$$

$$f_{Y_1|Y_2=3}(2) = \frac{1}{\sqrt{\frac{32}{9}}\sqrt{2\pi}} e^{-\frac{1}{2\frac{32}{9}}(2-\frac{11}{9})^2} = 0.1943$$

**Θεώρημα 5.** Έστω  $\mathbf{Y} \sim (\mathbf{0}_n, \mathbf{I}_n)$ , δηλαδή  $E(\mathbf{Y}) = \mathbf{0}_n$  και  $\text{Var}(\mathbf{Y}) = \mathbf{I}_n$ . Έστω  $\mathbf{P}$  ένας  $n \times n$  ορθογώνιος πίνακας (δηλαδή  $\mathbf{P}\mathbf{P}^T = \mathbf{P}^T\mathbf{P} = \mathbf{I}_n$ ). Τότε ισχύει πως  $\mathbf{Z} = \mathbf{P}\mathbf{Y} \sim (\mathbf{0}_n, \mathbf{I}_n)$

Απόδειξη.  $E(\mathbf{Z}) = E(\mathbf{P}\mathbf{Y}) = \mathbf{P}E(\mathbf{Y}) = \mathbf{0}_n$ ,  $\text{Var}(\mathbf{Z}) = \text{Var}(\mathbf{P}\mathbf{Y}) = \mathbf{P}\text{Var}(\mathbf{Y})\mathbf{P}^T = \mathbf{P}\mathbf{P}^T = \mathbf{I}_n$ ,  $\square$

Ένα επακόλουθο του παραπάνω είναι πως  $\mathbf{Y} \sim N(\mathbf{0}_n, \mathbf{I}_n) \implies \mathbf{Z} = \mathbf{P}\mathbf{Y} \sim N(\mathbf{0}_n, \mathbf{I}_n)$ .

**Θεώρημα 6.** Έστω  $\mathbf{Y} \sim N(\mathbf{0}_n, \boldsymbol{\Sigma})$ , όπου  $\boldsymbol{\Sigma}$  είναι  $n \times n$  θετικά ορισμένος πίνακας. Τότε ισχύει πως  $\mathbf{Y}^T \boldsymbol{\Sigma}^{-1} \mathbf{Y} \sim \chi_n^2$ .

Απόδειξη.  $\mathbf{Y}^T \boldsymbol{\Sigma}^{-1} \mathbf{Y} = \mathbf{Y}^T \boldsymbol{\Sigma}^{-1/2} \boldsymbol{\Sigma}^{-1/2} \mathbf{Y} = \mathbf{Z}^T \mathbf{Z}$ , με  $\mathbf{Z} = \boldsymbol{\Sigma}^{-1/2} \mathbf{Y}$ , όπου  $\boldsymbol{\Sigma}^{-1/2} = (\boldsymbol{\Sigma}^{1/2})^{-1} = \mathbf{P} \boldsymbol{\Lambda}^{-1/2} \mathbf{P}^T$ . Καθότι  $E(\mathbf{Z}) = \mathbf{0}$ ,  $Var(\mathbf{Z}) = \boldsymbol{\Sigma}^{-1/2} \boldsymbol{\Sigma} \boldsymbol{\Sigma}^{-1/2} = \boldsymbol{\Sigma}^{-1/2} \boldsymbol{\Sigma}^{1/2} \boldsymbol{\Sigma}^{1/2} \boldsymbol{\Sigma}^{-1/2} = \mathbf{I}$ , έχουμε πως  $\mathbf{Z} \sim N(\mathbf{0}_n, \mathbf{I}_n)$ , κι άρα  $\mathbf{Y}^T \boldsymbol{\Sigma}^{-1} \mathbf{Y} = \mathbf{Z}^T \mathbf{Z} = \sum Z_i^2 \sim \chi_n^2$ .  $\square$

**Θεώρημα 7.** Έστω  $\mathbf{Y} \sim N(\mathbf{0}_n, \mathbf{I}_n)$  και  $\mathbf{A}$  είναι  $n \times n$  ταυτοδύναμος πίνακας. Τότε ισχύει πως  $\mathbf{Y}^T \mathbf{A} \mathbf{Y} \sim \chi_{rank(\mathbf{A})}^2$ .

Απόδειξη.  $\mathbf{A} = \mathbf{P} \boldsymbol{\Lambda} \mathbf{P}^T$ . Καθότι  $\mathbf{A}$  είναι ταυτοδύναμος και χωρίς βλάβη τις γενικότητας υποθέτουμε πως τα πρώτα  $rank(\mathbf{A})$  στοιχεία της διαγωνίου του  $\boldsymbol{\Lambda}$  είναι μονάδες με τα υπόλοιπα 0. Έχουμε  $\mathbf{Y}^T \mathbf{A} \mathbf{Y} = \mathbf{Y}^T \mathbf{P} \boldsymbol{\Lambda} \mathbf{P}^T \mathbf{Y} = \mathbf{Z}^T \boldsymbol{\Lambda} \mathbf{Z} = \sum_{i=1}^{rank(\mathbf{A})} Z_i^2 \sim \chi_{rank(\mathbf{A})}^2$ .  $\square$

**Θεώρημα 8.** Έστω  $\mathbf{Y} \sim N(\mathbf{X}\boldsymbol{\beta}, \sigma^2 \mathbf{I})$ , με  $\mathbf{X}$  έναν  $n \times p$  πίνακα με  $rank(\mathbf{X}) = p$ . Οι εκτιμητές μεγίστης πιθανοφάνειας των παραμέτρων είναι

1.  $\hat{\boldsymbol{\beta}}_{MLE} = \hat{\boldsymbol{\beta}}_{LS} = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{Y}$  (ο εκτιμητής ελαχίστων τετραγώνων).
2.  $\hat{\sigma}^2 = \frac{(\mathbf{Y} - \mathbf{X}\hat{\boldsymbol{\beta}}_{LS})^T (\mathbf{Y} - \mathbf{X}\hat{\boldsymbol{\beta}}_{LS})}{n} = \frac{1}{n} \mathbf{Y}^T (\mathbf{I} - \mathbf{H}) \mathbf{Y}$ , όπου  $\mathbf{H} = \mathbf{X} (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T$  είναι ο γνωστός *hat matrix*.
3. Η μέγιστη τιμή του λογάριθμου της πιθανοφάνειας ισούται με

$$-\frac{n}{2} \ln(2\pi) - \frac{n}{2} \ln(\hat{\sigma}^2) - \frac{n}{2}$$

Απόδειξη. Εδώ έχουμε  $\boldsymbol{\Sigma} = \sigma^2 \mathbf{I}$ ,  $\boldsymbol{\mu} = \mathbf{X}\boldsymbol{\beta}$ . Η πιθανοφάνεια  $L(\boldsymbol{\beta}, \sigma^2)$  ισούται με

$$L(\boldsymbol{\beta}, \sigma^2) = \frac{e^{-\frac{1}{2\sigma^2} (\mathbf{y} - \mathbf{X}\boldsymbol{\beta})^T (\mathbf{y} - \mathbf{X}\boldsymbol{\beta})}}{(2\pi)^{n/2} |\sigma^2 \mathbf{I}|^{1/2}} = \frac{e^{-\frac{1}{2\sigma^2} (\mathbf{y} - \mathbf{X}\boldsymbol{\beta})^T (\mathbf{y} - \mathbf{X}\boldsymbol{\beta})}}{(2\pi)^{n/2} (\sigma^2)^{n/2}}$$

Ο λογάριθμος της πιθανοφάνειας ισούται με

$$l(\boldsymbol{\beta}, \sigma^2) = -\frac{n}{2} \ln(2\pi) - \frac{n}{2} \ln(\sigma^2) - \frac{1}{2\sigma^2} (\mathbf{y} - \mathbf{X}\boldsymbol{\beta})^T (\mathbf{y} - \mathbf{X}\boldsymbol{\beta}) \quad (2.1)$$

Η μεγιστοποίηση της (2.1) είναι εύκολη. Παίρνουμε την παράγωγο ως προς  $\sigma^2$  και την θέτουμε ίση με το 0.

$$\begin{aligned}\frac{\partial l(\boldsymbol{\beta}, \sigma^2)}{\partial \sigma^2} &= -\frac{n}{2\sigma^2} + \frac{1}{2(\sigma^2)^2}(\mathbf{y} - \mathbf{X}\boldsymbol{\beta})^T(\mathbf{y} - \mathbf{X}\boldsymbol{\beta}) = 0 \\ \implies \tilde{\sigma}^2 &= \frac{(\mathbf{y} - \mathbf{X}\boldsymbol{\beta})^T(\mathbf{y} - \mathbf{X}\boldsymbol{\beta})}{n}\end{aligned}$$

Η δεύτερη παράγωγος της (2.1) ως προς  $\sigma^2$  ισούται με

$$\begin{aligned}\frac{\partial^2 l(\boldsymbol{\beta}, \sigma^2)}{\partial (\sigma^2)^2} \Big|_{\tilde{\sigma}^2} &= +\frac{n}{2(\sigma^2)^2} \Big|_{\tilde{\sigma}^2} - \frac{1}{(\sigma^2)^3}(\mathbf{y} - \mathbf{X}\boldsymbol{\beta})^T(\mathbf{y} - \mathbf{X}\boldsymbol{\beta}) \Big|_{\tilde{\sigma}^2} \\ &= -\frac{n}{2(\tilde{\sigma}^2)^2} < 0\end{aligned}$$

και άρα  $\tilde{\sigma}^2$  μεγιστοποιεί την πιθανοφάνεια για κάθε τιμή του  $\boldsymbol{\beta}$ .

Όσον αφορά την μεγιστοποίηση της (2.1) ως προς  $\boldsymbol{\beta}$ , αρκεί να ελαχιστοποιήσουμε το άθροισμα των τετραγωνικών σφαλμάτων, δηλαδή έχουμε το πρόβλημα ελαχιστοποίησης:

$$\min_{\boldsymbol{\beta}} (\mathbf{y} - \mathbf{X}\boldsymbol{\beta})^T(\mathbf{y} - \mathbf{X}\boldsymbol{\beta}) \quad (2.2)$$

Η λύση είναι εξ ορισμού ο εκτιμητής ελαχίστων τετραγώνων  $\hat{\boldsymbol{\beta}}_{LS}$ . Αμέσως συνεπάγεται πως ο εκτιμητής μεγίστης πιθανοφάνειας της διασποράς ισούται με  $\hat{\sigma}^2 = \frac{(\mathbf{Y} - \mathbf{X}\hat{\boldsymbol{\beta}}_{LS})^T(\mathbf{Y} - \mathbf{X}\hat{\boldsymbol{\beta}}_{LS})}{n}$ .

Για να βρούμε την μορφή του  $\hat{\boldsymbol{\beta}}_{LS}$ , δηλαδή την λύση του προβλήματος (2.2), παραγωγίζουμε την ποσότητα  $(\mathbf{y} - \mathbf{X}\boldsymbol{\beta})^T(\mathbf{y} - \mathbf{X}\boldsymbol{\beta})$  ως προς  $\boldsymbol{\beta}$ :

$$\begin{aligned}\frac{\partial}{\partial \boldsymbol{\beta}}(\mathbf{y} - \mathbf{X}\boldsymbol{\beta})^T(\mathbf{y} - \mathbf{X}\boldsymbol{\beta}) &= \frac{\partial}{\partial \boldsymbol{\beta}}(-\mathbf{y}^T \mathbf{X}\boldsymbol{\beta} - \boldsymbol{\beta}^T \mathbf{X}^T \mathbf{y} + \boldsymbol{\beta}^T \mathbf{X}^T \mathbf{X}\boldsymbol{\beta}) \\ &= \frac{\partial}{\partial \boldsymbol{\beta}}(-2\boldsymbol{\beta}^T \mathbf{X}^T \mathbf{y} + \boldsymbol{\beta}^T \mathbf{X}^T \mathbf{X}\boldsymbol{\beta}) \\ &= -2\mathbf{X}^T \mathbf{y} + 2\mathbf{X}^T \mathbf{X}\boldsymbol{\beta}.\end{aligned}$$

Η εκτιμητική εξίσωση που προκύπτει είναι

$$\mathbf{X}^T \mathbf{X}\boldsymbol{\beta} = \mathbf{X}^T \mathbf{y} \implies \hat{\boldsymbol{\beta}} = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{y}$$

Η δεύτερη παράγωγος είναι

$$\begin{aligned}\frac{\partial^2}{\partial \boldsymbol{\beta} \partial \boldsymbol{\beta}^T}(\mathbf{y} - \mathbf{X}\boldsymbol{\beta})^T(\mathbf{y} - \mathbf{X}\boldsymbol{\beta}) &= \frac{\partial}{\partial \boldsymbol{\beta}^T}(-2\mathbf{X}^T \mathbf{y} + 2\mathbf{X}^T \mathbf{X}\boldsymbol{\beta}) \\ &= 2(\mathbf{X}^T \mathbf{X})^T = 2(\mathbf{X}^T \mathbf{X})\end{aligned}$$

Καθότι  $\text{rank}(\mathbf{X}) = p$  ο πίνακας  $2(\mathbf{X}^T \mathbf{X})$  είναι θετικά ορισμένος και άρα το  $\hat{\boldsymbol{\beta}}$  δίνει τοπικό ελάχιστο. Σε συνδυασμό με το γεγονός πως  $(\mathbf{y} - \mathbf{X}\boldsymbol{\beta})^T (\mathbf{y} - \mathbf{X}\boldsymbol{\beta}) \rightarrow \infty$ , όταν  $\boldsymbol{\beta} \rightarrow \pm\infty$  έχουμε πως  $(\mathbf{y} - \mathbf{X}\boldsymbol{\beta})^T (\mathbf{y} - \mathbf{X}\boldsymbol{\beta})$  ελαχιστοποιείται στο  $\hat{\boldsymbol{\beta}}$ .

Τέλος, Η μέγιστη τιμή του λογαριθμού της πιθανοφάνειας προκύπτει θέτοντας τις τιμές των εκτιμητών μεγίστης πιθανοφάνειας στη (2.1), δηλαδή έχουμε

$$\begin{aligned} \max_{\boldsymbol{\beta}, \sigma^2} l(\boldsymbol{\beta}, \sigma^2) &= -\frac{n}{2} \ln(2\pi) - \frac{n}{2} \ln(\hat{\sigma}^2) - \frac{1}{2\hat{\sigma}^2} (\mathbf{y} - \mathbf{X}\hat{\boldsymbol{\beta}})^T (\mathbf{y} - \mathbf{X}\hat{\boldsymbol{\beta}}) \\ &= -\frac{n}{2} \ln(2\pi) - \frac{n}{2} \ln(\hat{\sigma}^2) - \frac{n}{2} \end{aligned}$$

□

**Θεώρημα 9.** Έστω  $\mathbf{Y} \sim N(\mathbf{X}\boldsymbol{\beta}, \sigma^2 \mathbf{I})$ , με  $\mathbf{X}$  έναν  $n \times p$  πίνακα με  $\text{rank}(\mathbf{X}) = p$ . Για τους εκτιμητές μεγίστης πιθανοφάνειας των παραμέτρων ισχύει:

1.  $\hat{\boldsymbol{\beta}} \sim N(\boldsymbol{\beta}, \sigma^2 (\mathbf{X}^T \mathbf{X})^{-1})$
2.  $n \frac{\hat{\sigma}^2}{\sigma^2} = (n-p) \frac{s^2}{\sigma^2} \sim \chi_{n-p}^2$ , όπου  $s^2 = \frac{n}{n-p} \hat{\sigma}^2$  είναι ο αμερόληπτος εκτιμητής της διασποράς.
3.  $\hat{\boldsymbol{\beta}}$  και  $s^2$  είναι ανεξάρτητα.
4. Αν  $\mathbf{R}$  είναι ένας  $q \times p$  πίνακας με  $\text{rank}(\mathbf{R}) = q \leq p$ , τότε

$$\frac{(\mathbf{R}\hat{\boldsymbol{\beta}} - \mathbf{R}\boldsymbol{\beta})^T (\mathbf{R}(\mathbf{X}^T \mathbf{X})^{-1} \mathbf{R}^T)^{-1} (\mathbf{R}\hat{\boldsymbol{\beta}} - \mathbf{R}\boldsymbol{\beta})}{qs^2} \sim F_{q, n-p}$$

Απόδειξη.

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

Άρα χρησιμοποιώντας την ιδιότητα (2.) της Κανονικής κατανομής παραπάνω έχουμε  $\hat{\boldsymbol{\beta}} \sim N(\boldsymbol{\beta}, \sigma^2 (\mathbf{X}^T \mathbf{X})^{-1})$ ,

Έχουμε  $(n-p) \frac{s^2}{\sigma^2} = \frac{1}{\sigma^2} \mathbf{Y}^T (\mathbf{I} - \mathbf{H}) \mathbf{Y} = \frac{1}{\sigma^2} \mathbf{Y}^T (\mathbf{I} - \mathbf{H}) (\mathbf{I} - \mathbf{H}) \mathbf{Y}$ , καθότι  $(\mathbf{I} - \mathbf{H})$  είναι ταυτοδύναμος με  $\text{rank}(\mathbf{I} - \mathbf{H}) = \text{tr}(\mathbf{I} - \mathbf{H}) = n -$

$tr(\mathbf{X}(\mathbf{X}^T\mathbf{X})^{-1}\mathbf{X}^T) = n - tr(\mathbf{X}^T\mathbf{X}(\mathbf{X}^T\mathbf{X})^{-1}) = n - tr(\mathbf{I}_p) = n - p$ . Παρατηρούμε πως  $(\mathbf{I} - \mathbf{H})\mathbf{Y} = (\mathbf{I} - \mathbf{H})(\mathbf{Y} - \mathbf{X}\boldsymbol{\beta})$  καθότι  $(\mathbf{I} - \mathbf{H})\mathbf{X} = \mathbf{0}$ . Άρα

$$\begin{aligned} (n-p)\frac{s^2}{\sigma^2} &= \frac{1}{\sigma^2}(\mathbf{Y} - \mathbf{X}\boldsymbol{\beta})^T(\mathbf{I} - \mathbf{H})(\mathbf{I} - \mathbf{H})(\mathbf{Y} - \mathbf{X}\boldsymbol{\beta}) \\ &= \left(\frac{1}{\sigma}(\mathbf{Y} - \mathbf{X}\boldsymbol{\beta})\right)^T(\mathbf{I} - \mathbf{H})\left(\frac{1}{\sigma}(\mathbf{Y} - \mathbf{X}\boldsymbol{\beta})\right) \\ &= \mathbf{Z}^T(\mathbf{I} - \mathbf{H})\mathbf{Z}, \quad (\text{όπου } \mathbf{Z} \sim N(\mathbf{0}, \mathbf{I})) \\ &\sim \chi_{n-p}^2. \end{aligned}$$

Έχουμε

$$\begin{aligned} Cov((\mathbf{I} - \mathbf{H})\mathbf{Y}, \hat{\boldsymbol{\beta}}) &= Cov((\mathbf{I} - \mathbf{H})\mathbf{Y}, (\mathbf{X}^T\mathbf{X})^{-1}\mathbf{X}^T\mathbf{Y}) \\ &= (\mathbf{I} - \mathbf{H})Var(\mathbf{Y})((\mathbf{X}^T\mathbf{X})^{-1}\mathbf{X}^T)^T \\ &= \sigma^2(\mathbf{I} - \mathbf{H})\mathbf{X}(\mathbf{X}^T\mathbf{X})^{-1} = \mathbf{0}, \end{aligned}$$

και, λόγω κανονικότητας των  $(\mathbf{I} - \mathbf{H})\mathbf{Y}, \hat{\boldsymbol{\beta}}$  συμπεραίνουμε πως  $(\mathbf{I} - \mathbf{H})\mathbf{Y}, \hat{\boldsymbol{\beta}}$  είναι ανεξάρτητα. Τέλος καθότι  $s^2$  είναι συνάρτηση του  $(\mathbf{I} - \mathbf{H})\mathbf{Y}$ , προκύπτει πως  $\hat{\boldsymbol{\beta}}$  και  $s^2$  είναι ανεξάρτητα.

Έχουμε  $\hat{\boldsymbol{\beta}} \sim N(\boldsymbol{\beta}, \sigma^2(\mathbf{X}^T\mathbf{X})^{-1}) \implies \mathbf{R}\hat{\boldsymbol{\beta}} \sim N(\mathbf{R}\boldsymbol{\beta}, \sigma^2\mathbf{R}(\mathbf{X}^T\mathbf{X})^{-1}\mathbf{R}^T) \implies (\mathbf{R}\hat{\boldsymbol{\beta}} - \mathbf{R}\boldsymbol{\beta}) \sim N(\mathbf{0}, \sigma^2\mathbf{R}(\mathbf{X}^T\mathbf{X})^{-1}\mathbf{R}^T)$ . Από το Θεώρημα 6 προκύπτει πως  $\frac{1}{\sigma^2}(\mathbf{R}\hat{\boldsymbol{\beta}} - \mathbf{R}\boldsymbol{\beta})^T(\mathbf{R}(\mathbf{X}^T\mathbf{X})^{-1}\mathbf{R}^T)^{-1}(\mathbf{R}\hat{\boldsymbol{\beta}} - \mathbf{R}\boldsymbol{\beta}) \sim \chi_q^2$ . Εξετάζουμε το κλάσμα

$$\frac{\frac{1}{\sigma^2}(\mathbf{R}\hat{\boldsymbol{\beta}} - \mathbf{R}\boldsymbol{\beta})^T(\mathbf{R}(\mathbf{X}^T\mathbf{X})^{-1}\mathbf{R}^T)^{-1}(\mathbf{R}\hat{\boldsymbol{\beta}} - \mathbf{R}\boldsymbol{\beta})/q}{(n-p)\frac{s^2}{\sigma^2}/(n-p)}.$$

Ο αριθμητής είναι ανεξάρτητος του παρανομαστή (καθότι  $\hat{\boldsymbol{\beta}}$  και  $s^2$  είναι ανεξάρτητα) και από τον ορισμό της  $F$  κατανομής προκύπτει το ζητούμενο.  $\square$

Το τελευταίο αποτέλεσμα αποτελεί την βάση για τον έλεγχο της γενικής γραμμικής υπόθεσης  $\mathbf{R}\boldsymbol{\beta} = \mathbf{r}$ , όπου  $\mathbf{R}$  είναι  $q \times p$  πίνακας και ισχύει  $rank(\mathbf{R}) = q$ .

**Εφαρμογή:** Θεωρήστε μια έρευνα που επιδιώκει να εξετάσει την αποτελεσματικότητα μιας διαφημιστικής εκστρατείας όσον αφορά τις πωλήσεις ενός προϊόντος σε καταστήματα τροφίμων. Στην έρευνα επιλέχθηκε ένα απλό τυχαίο δείγμα από  $n = 100$  καταστήματα τροφίμων της πρωτεύουσας. Η μεταβλητές της έρευνας ήταν:

1. Σχετική αύξηση στον όγκο πωλήσεων του προϊόντος: (Πωλήσεις ένα μήνα μετά την εκστρατεία - Πωλήσεις ένα μήνα πριν την εκστρατεία)/ Πωλήσεις ένα μήνα πριν την εκστρατεία ( $Y$ ).

2. Μέσο οικογενειακό εισόδημα της περιοχής που ανήκει το κατάστημα ( $x$ )
3. Μέγεθος του καταστήματος: μικρό, μεσαίο, μεγάλο. ( $\delta_1, \delta_2$  είναι οι δείκτες για μεσαίο και μεγάλο κατάστημα αντιστοίχα)



Το γραμμικό μοντέλο που χρησιμοποιήθηκε είναι:

$$Y_i = \beta_0 + \beta_1 x_i + \beta_2 \delta_{1i} + \beta_3 \delta_{2i} + \beta_4 \delta_{1i} x_i + \beta_5 \delta_{2i} x_i + \epsilon_i$$

$$\epsilon_1, \dots, \epsilon_{100} \sim_{iid} N(0, \sigma^2)$$

Βάσει του παραπάνω μοντέλου έχω 3 μοντέλα, ένα για κάθε μέγεθος καταστήματος.

- Για τα μικρά καταστήματα:  $\delta_{1i} = 0$  και  $\delta_{2i} = 0$  κι έχουμε

$$Y_i = \beta_0 + \beta_1 x_i + \epsilon_i.$$

Στα μικρά καταστήματα, η επίδραση του μέσου οικογενειακού εισοδήματος στην μέση αύξηση των πωλήσεων εκφράζεται από τη παράμετρο  $\beta_1$ .

- Για τα μεσαία καταστήματα:  $\delta_{1i} = 1$  και  $\delta_{2i} = 0$  κι έχουμε

$$Y_i = \beta_0 + \beta_2 + \beta_1 x_i + \beta_4 x_i + \epsilon_i$$

$$= (\beta_0 + \beta_2) + (\beta_1 + \beta_4) x_i + \epsilon_i.$$

Στα μεσαία καταστήματα, η επίδραση του μέσου οικογενειακού εισοδήματος στην μέση αύξηση των πωλήσεων είναι  $\beta_1 + \beta_4$ .

- Για τα μεγάλα καταστήματα:  $\delta_{1i} = 0$  και  $\delta_{2i} = 1$  κι έχουμε

$$Y_i = \beta_0 + \beta_1 x_i + \beta_3 + \beta_5 x_i + \epsilon_i$$

$$= (\beta_0 + \beta_3) + (\beta_1 + \beta_5) x_i + \epsilon_i.$$

Στα μεγάλα καταστήματα, η επίδραση του μέσου οικογενειακού εισοδήματος στην μέση αύξηση των πωλήσεων είναι  $\beta_1 + \beta_5$ .

Γράψτε τις παρακάτω μηδενικές υποθέσεις στην μορφή  $H_0 : \mathbf{R}\boldsymbol{\beta} = \mathbf{r}$ , όπου  $\mathbf{R}$  έχει  $q$  γραμμές και ισχύει  $\text{rank}(\mathbf{R}) = q$ . Επίσης γράψτε την σ.σ.ε και την κατανομή της κάτω από την μηδενική υπόθεση.

1.  $H_0$  : η εκστρατεία δεν ήταν αποτελεσματική.

*Απάντηση:* Η μηδενική υπόθεση αναφέρει πως η μέση σχετική αύξηση στον όγκο πωλήσεων ήταν 0, ανεξάρτητα μεγέθους καταστήματος και περιοχής, δηλαδή  $H_0 : \beta_0 = \beta_1 = \beta_2 = \beta_3 = \beta_4 = \beta_5 = 0$ . Δηλαδή  $H_0 : \boldsymbol{\beta} = \mathbf{0}_6$ , κι έχουμε  $\mathbf{R} = \mathbf{I}_6$ . Βάσει του τελευταίου αποτελεσματος στο Θεώρημα (9) έχουμε

$$\frac{\hat{\boldsymbol{\beta}}^T (\mathbf{X}^T \mathbf{X}) \hat{\boldsymbol{\beta}}}{6s^2} \stackrel{H_0}{\sim} F_{6,94}$$

2.  $H_0$  : η εκστρατεία ήταν το ίδιο αποτελεσματική ανεξάρτητα του μεγέθους του καταστήματος.

Απάντηση: Ισοδύναμα,  $H_0 : \beta_2 = \beta_3 = \beta_4 = \beta_5 = 0$ . Δηλαδή  $H_0 : \mathbf{R}\boldsymbol{\beta} = \mathbf{0}_4$ , όπου

$$\mathbf{R} = \begin{bmatrix} 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 \end{bmatrix}, \mathbf{r} = \mathbf{0}_4$$

Βάσει του τελευταίου αποτελέσματος στο Θεώρημα (9) έχουμε

$$\frac{(\mathbf{R}\hat{\boldsymbol{\beta}})^T (\mathbf{R}(\mathbf{X}^T \mathbf{X})^{-1} \mathbf{R}^T)^{-1} (\mathbf{R}\hat{\boldsymbol{\beta}})}{4s^2} \stackrel{H_0}{\sim} F_{4,94}$$

Παρατηρήστε εδώ πως  $\mathbf{R}\hat{\boldsymbol{\beta}}$  είναι απλά το διάνυσμα  $(\hat{\beta}_2 \hat{\beta}_3 \hat{\beta}_4 \hat{\beta}_5)^T$ , ενώ  $\mathbf{R}(\mathbf{X}^T \mathbf{X})^{-1} \mathbf{R}^T$  είναι απλά ο  $4 \times 4$  κάτω υποπίνακας του  $(\mathbf{X}^T \mathbf{X})^{-1}$ , (δηλαδή συνδυάστε τις 4 τελευταίες γραμμές με τις 4 τελευταίες στήλες).

3.  $H_0$  : η επίδραση του μέσου οικογενειακού εισοδήματος στην αποτελεσματικότητα της εκστρατείας ήταν ίδια για κάθε μέγεθος καταστήματος.

Απάντηση: Η μηδενική υπόθεση λέει πως  $\beta_1 = \beta_1 + \beta_4 = \beta_1 + \beta_5$ . Ισοδύναμα,  $H_0 : \beta_4 = \beta_5 = 0$ . Άρα

$$\begin{bmatrix} 0 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} \beta_0 \\ \beta_1 \\ \beta_2 \\ \beta_3 \\ \beta_4 \\ \beta_5 \end{bmatrix} = \mathbf{0}_2.$$

Δηλαδή  $H_0 : \mathbf{R}\boldsymbol{\beta} = \mathbf{0}_2$ , όπου

$$\mathbf{R} = \begin{bmatrix} 0 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 \end{bmatrix}, \mathbf{r} = \mathbf{0}_2$$

Βάσει του τελευταίου αποτελέσματος στο Θεώρημα (9) έχουμε

$$\frac{(\mathbf{R}\hat{\boldsymbol{\beta}})^T (\mathbf{R}(\mathbf{X}^T \mathbf{X})^{-1} \mathbf{R}^T)^{-1} (\mathbf{R}\hat{\boldsymbol{\beta}})}{2s^2} \stackrel{H_0}{\sim} F_{2,94}$$

Παρατηρήστε εδώ πως  $\mathbf{R}\hat{\boldsymbol{\beta}}$  είναι απλά το διάνυσμα  $(\hat{\beta}_4 \hat{\beta}_5)^T$ , ενώ  $\mathbf{R}(\mathbf{X}^T \mathbf{X})^{-1} \mathbf{R}^T$  είναι απλά ο  $2 \times 2$  κάτω υποπίνακας του  $(\mathbf{X}^T \mathbf{X})^{-1}$ , (δηλαδή συνδυάστε τις 2 τελευταίες γραμμές με τις 2 τελευταίες στήλες).

4.  $H_0$  : η επίδραση του μέσου οικογενειακού εισοδήματος στην αποτελεσματικότητα της εκστρατείας ήταν ίδια για τα μεσαίου και μεγάλου μεγέθους καταστήματα.

Η μηδενική υπόθεση λέει πως  $\beta_1 + \beta_4 = \beta_1 + \beta_5$ , ή ισοδύναμα  $\beta_4 = \beta_5$ , δηλαδή  $\beta_4 - \beta_5 = 0$ . Ήτοι

$$[0 \ 0 \ 0 \ 0 \ 1 \ -1] \begin{bmatrix} \beta_0 \\ \beta_1 \\ \beta_2 \\ \beta_3 \\ \beta_4 \\ \beta_5 \end{bmatrix} = 0$$

$$\mathbf{R} = [0 \ 0 \ 0 \ 0 \ 1 \ -1], \mathbf{r} = 0$$

Βάσει του τελευταίου αποτελέσματος στο Θεώρημα (9) έχουμε

$$\frac{(\mathbf{R}\hat{\boldsymbol{\beta}})^T (\mathbf{R}(\mathbf{X}^T \mathbf{X})^{-1} \mathbf{R}^T)^{-1} (\mathbf{R}\hat{\boldsymbol{\beta}})}{s^2} \underset{H_0}{\sim} F_{1,94}$$

Το επόμενο Θεώρημα λέει πως σε ένα γραμμικό μοντέλο με ομοσκεδαστικά και ασυσχέτιστα σφάλματα ο εκτιμητής ελαχίστων τετραγώνων είναι βέλτιστος μέσα στην οικογένεια των γραμμικών κι αμερόληπτων εκτιμητών (Best Linear Unbiased Estimator, BLUE).

**Θεώρημα 10.** Έστω  $\mathbf{Y} \sim (\mathbf{X}\boldsymbol{\beta}, \sigma^2 \mathbf{I})$ , με  $\mathbf{X}$  έναν  $n \times p$  πίνακα με  $\text{rank}(\mathbf{X}) = p$ . Με άλλα λόγια  $E(\mathbf{Y}) = \mathbf{X}\boldsymbol{\beta}$ , και  $\text{Var}(\mathbf{Y}) = \sigma^2 \mathbf{I}$ . Δεν υποθέτουμε Κανονικότητα. Ο εκτιμητής ελαχίστων τετραγώνων είναι ο εκτιμητής με τον μικρότερο πίνακα διασπορών-συνδιασπορών μέσα στην οικογένεια των γραμμικών κι αμερόληπτων εκτιμητών.

Απόδειξη. Προφανώς ο εκτιμητής  $\hat{\boldsymbol{\beta}}_{LS} = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{Y}$  είναι γραμμικός (ως προς  $\mathbf{Y}$ ) κι έχουμε δείξει πως είναι αμερόληπτος. Επίσης έχουμε δείξει πως  $\text{Var}(\hat{\boldsymbol{\beta}}_{LS}) = \sigma^2 (\mathbf{X}^T \mathbf{X})^{-1}$ .

Έστω  $\tilde{\beta} = \mathbf{C}\mathbf{Y}$  ένας άλλος αμερόληπτος γραμμικός εκτιμητής. Καθότι ο  $\tilde{\beta}$  είναι αμερόληπτος έχουμε  $E(\tilde{\beta}) = E(\mathbf{C}\mathbf{Y}) = \mathbf{C}\mathbf{X}\beta = \beta$ ,  $\forall \beta$ , κι άρα ισχύει  $\mathbf{C}\mathbf{X} = \mathbf{I}$ . Προφανώς  $Var(\tilde{\beta}) = \sigma^2 \mathbf{C}\mathbf{C}^T$ .

Θεωρούμε την διαφορά  $\tilde{\beta} - \hat{\beta}_{LS}$ . Καθότι η διαφορά είναι τ.δ. ισχύει  $Var(\tilde{\beta} - \hat{\beta}_{LS}) \geq \mathbf{0}$ , δηλαδή ο πίνακας  $Var(\tilde{\beta} - \hat{\beta}_{LS})$  είναι μη αρνητικά ορισμένος. Άρα

$$\begin{aligned} Var(\tilde{\beta} - \hat{\beta}_{LS}) &= Var((\mathbf{C} - (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T) \mathbf{Y}) \\ &= \sigma^2 (\mathbf{C} - (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T) (\mathbf{C} - (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T)^T \\ &= \sigma^2 (\mathbf{C}\mathbf{C}^T - \mathbf{C}\mathbf{X}(\mathbf{X}^T \mathbf{X})^{-1} - (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{C}^T + (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{X} (\mathbf{X}^T \mathbf{X})^{-1}) \\ &= \sigma^2 \mathbf{C}\mathbf{C}^T - \sigma^2 (\mathbf{X}^T \mathbf{X})^{-1} \quad (\text{καθότι } \mathbf{C}\mathbf{X} = \mathbf{I}) \\ &= Var(\tilde{\beta}) - Var(\hat{\beta}_{LS}) \geq \mathbf{0} \implies Var(\tilde{\beta}) \geq Var(\hat{\beta}_{LS}) \end{aligned}$$

□

## 2.1 Εκτιμητής Γενικευμένων Ελαχίστων Τετραγώνων (Generalized Least Squares (GLS) estimator)

Θεωρήστε το γραμμικό μοντέλο (γραμμική παλινδρόμηση) με πιθανή έλλειψη ομοσκεδαστικότητας ή/και ύπαρξη αυτοσυσχέτισης των σφαλμάτων (και άρα και των παρατηρήσεων):

$$\mathbf{Y} = \mathbf{X}\beta + \epsilon, \quad \epsilon \sim (\mathbf{0}, \Sigma), \quad (2.3)$$

όπου  $\mathbf{Y}$  είναι ένα  $n \times 1$  διάνυσμα αποκρίσεων,  $\mathbf{X}$  ο  $n \times p$  πίνακας σχεδιασμού ή συμμεταβλητών (η πρώτη στήλη είναι ένα διάνυσμα μονάδων όταν έχουμε σταθερά (intercept) στην παλινδρόμηση),  $\beta$  είναι το  $p \times 1$  διάνυσμα παραμέτρων, και  $\epsilon$  είναι ένα  $n \times 1$  διάνυσμα σφαλμάτων. Επίσης υποθέτουμε πως  $rank(\mathbf{X}) = p$ , δηλαδή ο  $\mathbf{X}$  έχει γραμμικά ανεξάρτητες στήλες. Ισοδύναμα μπορούμε να γράψουμε το μοντέλο (2.3) ως

$$\mathbf{Y} \sim (\mathbf{X}\beta, \Sigma).$$

Ο Πίνακας  $\Sigma$  είναι ο  $n \times n$  πίνακας διακυμάνσεων-συνδυακυμάνσεων των σφαλμάτων, με  $i, j$  στοιχείο  $\sigma_{i,j} = cov(Y_i, Y_j)$ , όπου  $i = 1, \dots, n$  και  $j = 1, \dots, n$ . Υποθέτουμε πως ο  $\Sigma$  είναι θετικά ορισμένος (p.d.). Σημείωση: όταν  $\Sigma = \sigma^2 \mathbf{I}_n$  έχουμε την κλασσική παλινδρόμηση (δηλ. έχουμε ομοσκεδαστικά και ασυσχέτιστα σφάλματα).

Έχουμε δείξει πως ο εκτιμητής ελαχίστων τετραγώνων  $\hat{\beta}_{LS} = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{Y}$  είναι Βέλτιστος Γραμμικός Αμεροληπτος Εκτιμητής (BLUE) του  $\beta$  όταν  $\Sigma =$

$\sigma^2 \mathbf{I}_n$ . Το ερώτημα που θα απαντήσουμε τώρα είναι: ποιός είναι ο (BLUE) εκτιμητής του  $\boldsymbol{\beta}$  στην γενική περίπτωση.

**Θεώρημα 11.** Ο BLUE του  $\boldsymbol{\beta}$  ισούται με  $\hat{\boldsymbol{\beta}}_{GLS} = (\mathbf{X}^T \boldsymbol{\Sigma}^{-1} \mathbf{X})^{-1} \mathbf{X}^T \boldsymbol{\Sigma}^{-1} \mathbf{Y}$

Απόδειξη. Έχουμε δείξει πως η τετραγωνική ρίζα του p.d. πίνακα  $\boldsymbol{\Sigma}$  (με φασματική ανάλυση  $\boldsymbol{\Sigma} = \mathbf{P} \boldsymbol{\Lambda} \mathbf{P}^T$ ) υπάρχει, είναι μοναδικός, και δίνεται από τον τύπο  $\boldsymbol{\Sigma}^{1/2} = \mathbf{P} \boldsymbol{\Lambda}^{1/2} \mathbf{P}^T$ . Ο αντίστροφος του ισούται με  $\boldsymbol{\Sigma}^{-1/2} = \mathbf{P} \boldsymbol{\Lambda}^{-1/2} \mathbf{P}^T$ . Πολλαπλασιάζουμε από δεξιά τα δύο μέλη της εξίσωσης του μοντέλου στο (2.3) με τον πίνακα  $\boldsymbol{\Sigma}^{-1/2}$  κι έχουμε :

$$\mathbf{Y}^* = \mathbf{X}^* \boldsymbol{\beta} + \boldsymbol{\epsilon}^*, \quad \boldsymbol{\epsilon}^* \sim (\mathbf{0}, \mathbf{I}_n), \quad (2.4)$$

όπου

$$\begin{aligned} \mathbf{Y}^* &= \boldsymbol{\Sigma}^{-1/2} \mathbf{Y} \\ \mathbf{X}^* &= \boldsymbol{\Sigma}^{-1/2} \mathbf{X} \\ \boldsymbol{\epsilon}^* &= \boldsymbol{\Sigma}^{-1/2} \boldsymbol{\epsilon}. \end{aligned}$$

Είναι προφανές πως  $Var(\boldsymbol{\epsilon}^*) = Var(\boldsymbol{\Sigma}^{-1/2} \boldsymbol{\epsilon}) = \boldsymbol{\Sigma}^{-1/2} \boldsymbol{\Sigma} \boldsymbol{\Sigma}^{-1/2} = \mathbf{I}_n$ . Με αυτόν τον μετασχηματισμό καταλήγουμε από το μοντέλο στο (2.3) σε ένα μοντέλο κλασσικής παλινδρόμησης στο (2.4). Ο BLUE του  $\boldsymbol{\beta}$  προφανώς είναι ο εκτιμητής

$$\begin{aligned} \hat{\boldsymbol{\beta}}_{GLS} &= (\mathbf{X}^{*T} \mathbf{X}^*)^{-1} \mathbf{X}^{*T} \mathbf{Y}^* \\ &= (\mathbf{X}^T \boldsymbol{\Sigma}^{-1/2} \boldsymbol{\Sigma}^{-1/2} \mathbf{X})^{-1} \mathbf{X}^T \boldsymbol{\Sigma}^{-1/2} \boldsymbol{\Sigma}^{-1/2} \mathbf{Y} \\ &= (\mathbf{X}^T \boldsymbol{\Sigma}^{-1} \mathbf{X})^{-1} \mathbf{X}^T \boldsymbol{\Sigma}^{-1} \mathbf{Y}. \end{aligned} \quad (2.5)$$

□

Συνήθως γράφουμε τον πίνακα διακυμάνσεων-συνδιακυμάνσεων ως  $\boldsymbol{\Sigma} = \sigma^2 \mathbf{V}$ , όπου  $\sigma^2 > 0$ . Τότε έχουμε

$$\hat{\boldsymbol{\beta}}_{GLS} = (\mathbf{X}^T \mathbf{V}^{-1} \mathbf{X})^{-1} \mathbf{X}^T \mathbf{V}^{-1} \mathbf{Y} \quad (2.6)$$

2.1.1 Ιδιότητες του Εκτιμητή Γενικευμένων Ελαχίστων Τετραγώνων (GLS) - Σύγκριση με τον Εκτιμητή Ελαχίστων Τετραγώνων (LS)

Για τον  $\hat{\beta}_{GLS}$  έχουμε

$$\begin{aligned}
 E(\hat{\beta}_{GLS}) &= E((\mathbf{X}^T \boldsymbol{\Sigma}^{-1} \mathbf{X})^{-1} \mathbf{X}^T \boldsymbol{\Sigma}^{-1} \mathbf{Y}) \\
 &= (\mathbf{X}^T \boldsymbol{\Sigma}^{-1} \mathbf{X})^{-1} \mathbf{X}^T \boldsymbol{\Sigma}^{-1} E(\mathbf{Y}) \\
 &= (\mathbf{X}^T \boldsymbol{\Sigma}^{-1} \mathbf{X})^{-1} \mathbf{X}^T \boldsymbol{\Sigma}^{-1} \mathbf{X} \boldsymbol{\beta} = \boldsymbol{\beta} \\
 Var(\hat{\beta}_{GLS}) &= Var((\mathbf{X}^T \boldsymbol{\Sigma}^{-1} \mathbf{X})^{-1} \mathbf{X}^T \boldsymbol{\Sigma}^{-1} \mathbf{Y}) \\
 &= (\mathbf{X}^T \boldsymbol{\Sigma}^{-1} \mathbf{X})^{-1} \mathbf{X}^T \boldsymbol{\Sigma}^{-1} Var(\mathbf{Y}) ((\mathbf{X}^T \boldsymbol{\Sigma}^{-1} \mathbf{X})^{-1} \mathbf{X}^T \boldsymbol{\Sigma}^{-1})^T \\
 &= (\mathbf{X}^T \boldsymbol{\Sigma}^{-1} \mathbf{X})^{-1} \mathbf{X}^T \boldsymbol{\Sigma}^{-1} \boldsymbol{\Sigma} ((\mathbf{X}^T \boldsymbol{\Sigma}^{-1} \mathbf{X})^{-1} \mathbf{X}^T \boldsymbol{\Sigma}^{-1})^T \\
 &= (\mathbf{X}^T \boldsymbol{\Sigma}^{-1} \mathbf{X})^{-1} \mathbf{X}^T \boldsymbol{\Sigma}^{-1} \boldsymbol{\Sigma} \boldsymbol{\Sigma}^{-1} \mathbf{X} (\mathbf{X}^T \boldsymbol{\Sigma}^{-1} \mathbf{X})^{-1} \\
 &= (\mathbf{X}^T \boldsymbol{\Sigma}^{-1} \mathbf{X})^{-1} \mathbf{X}^T \boldsymbol{\Sigma}^{-1} \mathbf{X} (\mathbf{X}^T \boldsymbol{\Sigma}^{-1} \mathbf{X})^{-1} \\
 &= (\mathbf{X}^T \boldsymbol{\Sigma}^{-1} \mathbf{X})^{-1} \\
 &= \sigma^2 (\mathbf{X}^T \mathbf{V}^{-1} \mathbf{X})^{-1} \tag{2.7}
 \end{aligned}$$

Από την άλλη, για τον  $\hat{\beta}_{LS}$  έχουμε

$$\begin{aligned}
 E(\hat{\beta}_{LS}) &= \boldsymbol{\beta} \\
 Var(\hat{\beta}_{LS}) &= Var((\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{Y}) = (\mathbf{X}^T \mathbf{X})^{-1} (\mathbf{X}^T \boldsymbol{\Sigma} \mathbf{X}) (\mathbf{X}^T \mathbf{X})^{-1} \\
 &= \sigma^2 (\mathbf{X}^T \mathbf{X})^{-1} (\mathbf{X}^T \mathbf{V} \mathbf{X}) (\mathbf{X}^T \mathbf{X})^{-1} \tag{2.8}
 \end{aligned}$$

Στην περίπτωση κανονικού γραμμικού μοντέλου, δηλαδή αν  $\mathbf{Y} \sim N(\mathbf{X}\boldsymbol{\beta}, \boldsymbol{\Sigma})$ , έχουμε πως

$$\begin{aligned}
 \hat{\beta}_{GLS} &\sim N(\boldsymbol{\beta}, \sigma^2 (\mathbf{X}^T \mathbf{V}^{-1} \mathbf{X})^{-1}) \\
 \hat{\beta}_{LS} &\sim N(\boldsymbol{\beta}, \sigma^2 (\mathbf{X}^T \mathbf{X})^{-1} (\mathbf{X}^T \mathbf{V} \mathbf{X}) (\mathbf{X}^T \mathbf{X})^{-1}). \tag{2.9}
 \end{aligned}$$

**Άσκηση** (για το σπίτι).

Θεωρήστε το κανονικό γραμμικό μοντέλο  $\mathbf{Y} \sim N(\mathbf{X}\boldsymbol{\beta}, \sigma^2 \mathbf{V})$ , με  $\mathbf{V}$  γνωστό p.d. πίνακα. Βρείτε τους εκτιμητές μεγίστης πιθανοφάνειας των  $\boldsymbol{\beta}$  και  $\sigma^2$ .

Ένδειξη: χρησιμοποιήσετε τη φασματική ανάλυση του  $\mathbf{V}$  για να ορίσετε το  $\mathbf{V}^{1/2}$  και το Θεώρημα (8).

### 2.1.2 Παραδείγματα

Παράδειγμα 1:  $Y_i$  είναι δειγματικοί μέσοι που προκύπτουν από  $k_i$  ανεξάρτητες παρατηρήσεις στο  $i$ -οστό εργαστήριο ( $i = 1, \dots, n$ ).

$$Y_i = \mathbf{x}_i^T \boldsymbol{\beta} + \epsilon_i$$

$$\epsilon_i \sim^{ind} N(0, \sigma^2 \frac{1}{k_i})$$

$$\mathbf{X} = \begin{bmatrix} \mathbf{x}_1^T \\ \mathbf{x}_2^T \\ \vdots \\ \mathbf{x}_n^T \end{bmatrix} = \begin{bmatrix} 1 & x_{11} & x_{12} & \dots & x_{1,p-1} \\ 1 & x_{21} & x_{22} & \dots & x_{2,p-1} \\ \vdots & \vdots & \vdots & \dots & \vdots \\ 1 & x_{n1} & x_{n2} & \dots & x_{n,p-1} \end{bmatrix}$$

$$\boldsymbol{\Sigma} = \sigma^2 \begin{bmatrix} \frac{1}{k_1} & 0 & \dots & 0 \\ 0 & \frac{1}{k_2} & \dots & 0 \\ \vdots & \vdots & \dots & \vdots \\ 0 & 0 & \dots & \frac{1}{k_n} \end{bmatrix}$$

Εδώ ισχύει πως  $\mathbf{V}$  είναι γνωστός (πράγμα σπάνιο).

Παράδειγμα 2: Παλινδρόμηση με AR(1) σφάλματα.

$$Y_t = \mathbf{x}_t^T \boldsymbol{\beta} + \epsilon_t$$

$$\epsilon_t = \phi \epsilon_{t-1} + \nu_t, \nu_t \sim^{iid} N(0, \sigma_\nu^2)$$

$$-1 < \phi < 1$$

Εύκολα μπορεί να δειχθεί πως

$$\epsilon_t \sim N(0, \frac{\sigma_\nu^2}{1-\phi^2})$$

$$cov(\epsilon_t, \epsilon_{t-k}) = \phi^k \frac{\sigma_\nu^2}{1-\phi^2}$$

$$\boldsymbol{\Sigma} = \sigma_\nu^2 \begin{bmatrix} \frac{1}{1-\phi^2} & \frac{\phi}{1-\phi^2} & \frac{\phi^2}{1-\phi^2} & \dots & \frac{\phi^{n-1}}{1-\phi^2} \\ \frac{\phi}{1-\phi^2} & \frac{1}{1-\phi^2} & \frac{\phi}{1-\phi^2} & \dots & \frac{\phi^{n-2}}{1-\phi^2} \\ \vdots & \vdots & \dots & \vdots & \vdots \\ \frac{\phi^{n-1}}{1-\phi^2} & \frac{\phi^{n-2}}{1-\phi^2} & \frac{\phi^{n-3}}{1-\phi^2} & \dots & \frac{1}{1-\phi^2} \end{bmatrix}$$

Παράδειγμα 3: Απλό γραμμικό μοντέλο τυχαίων παραγόντων (one way random effects model).

$$\begin{aligned}
Y_{ij} &= \mu_i + \nu_{ij}, \nu_{ij} \sim^{iid} N(0, \sigma^2), j = 1, \dots, n_i \\
\mu_i &\sim^{iid} N(\mu, \sigma_\pi^2), i = 1, \dots, k \\
\nu_{ij} &\perp \nu_{i'j}, i \neq i' \\
\nu_{ij} &\perp \mu_i, \forall(i, j)
\end{aligned} \tag{2.10}$$

Ισοδύναμα, ορίζοντας  $\pi_i = \mu_i - \mu$ , γράφουμε το μοντέλο ως

$$\begin{aligned}
Y_{ij} &= \mu + \pi_i + \nu_{ij}, \nu_{ij} \sim^{iid} N(0, \sigma^2), j = 1, \dots, n_i \\
\pi_i &\sim^{iid} N(0, \sigma_\pi^2), i = 1, \dots, k \\
\nu_{ij} &\perp \nu_{i'j}, i \neq i' \\
\nu_{ij} &\perp \pi_i, \forall(i, j)
\end{aligned} \tag{2.11}$$

Το μοντέλο μπορεί να γραφεί ως Γενικό, Γραμμικό μοντέλο, δηλαδή στην μορφή (2.3). Ορίζω  $\epsilon_{ij} = \pi_i + \nu_{ij}$ . Έχουμε

$$\begin{aligned}
var(\epsilon_{ij}) &= \sigma_\pi^2 + \sigma^2 \\
cov(\epsilon_{ij}, \epsilon_{i'j'}) &= \sigma_\pi^2, j \neq j' \\
cov(\epsilon_{ij}, \epsilon_{i'j'}) &= 0, i \neq i'
\end{aligned} \tag{2.12}$$

Εδώ  $\mathbf{Y} = (Y_{11}, \dots, Y_{1n_1}, Y_{21}, \dots, Y_{2n_2}, \dots, Y_{k1}, \dots, Y_{kn_k})^T$ ,  $\boldsymbol{\beta} = \mu$ ,  $\mathbf{X} = \mathbf{1}_N$ , όπου  $\mathbf{1}_N$  είναι ένα διάνυσμα με  $N = n_1 + \dots + n_k$  μονάδες,  $\boldsymbol{\epsilon} = (\epsilon_{11}, \dots, \epsilon_{1n_1}, \epsilon_{21}, \dots, \epsilon_{2n_2}, \dots, \epsilon_{k1}, \dots, \epsilon_{kn_k})^T$  και  $var(\boldsymbol{\epsilon}) = \boldsymbol{\Sigma}^*$  δίνε-  
ται από

$$\boldsymbol{\Sigma}^* = \begin{bmatrix} \boldsymbol{\Sigma}_1 & \mathbf{0} & \dots & \mathbf{0} \\ \mathbf{0} & \boldsymbol{\Sigma}_2 & \dots & \mathbf{0} \\ \vdots & \vdots & \dots & \vdots \\ \mathbf{0} & \mathbf{0} & \dots & \boldsymbol{\Sigma}_k \end{bmatrix} = \sigma^2 \begin{bmatrix} \mathbf{V}_1 & \mathbf{0} & \dots & \mathbf{0} \\ \mathbf{0} & \mathbf{V}_2 & \dots & \mathbf{0} \\ \vdots & \vdots & \dots & \vdots \\ \mathbf{0} & \mathbf{0} & \dots & \mathbf{V}_k \end{bmatrix} = \sigma^2 \boldsymbol{\mathcal{V}}$$

όπου  $\boldsymbol{\Sigma}_i = var(\boldsymbol{\epsilon}_i)$  είναι ένας  $n_i \times n_i$  πίνακας συνδιακυμάνσεων των παρατηρήσεων από το  $i$ -οστό εργαστήριο και δίνεται από

$$\boldsymbol{\Sigma}_i = \begin{bmatrix} \sigma_\pi^2 + \sigma^2 & \sigma_\pi^2 & \dots & \sigma_\pi^2 \\ \sigma_\pi^2 & \sigma_\pi^2 + \sigma^2 & \dots & \sigma_\pi^2 \\ \vdots & \vdots & \dots & \vdots \\ \sigma_\pi^2 & \sigma_\pi^2 & \dots & \sigma_\pi^2 + \sigma^2 \end{bmatrix} = \sigma^2 \begin{bmatrix} 1 + \phi & \phi & \dots & \phi \\ \phi & 1 + \phi & \dots & \phi \\ \vdots & \vdots & \dots & \vdots \\ \phi & \phi & \dots & 1 + \phi \end{bmatrix}$$



όπου  $\phi = \frac{\sigma_\alpha^2}{\sigma^2} > 0$

Παράδειγμα 4: Απλό γραμμικό μοντέλο με ένα σταθερό παράγοντα κι έναν τυχαίο παράγοντα (two way mixed effects model).

$$\begin{aligned}
 Y_{ij} &= \mu + \alpha_i + \beta_j + \nu_{ij}, \nu_{ij} \sim^{iid} N(0, \sigma^2), j = 1, \dots, n \\
 \alpha_i &\sim^{iid} N(0, \sigma_\alpha^2), i = 1, \dots, m \\
 \nu_{ij} &\perp \nu_{i'j}, i \neq i' \\
 \nu_{ij} &\perp \alpha_i, \forall (i, j)
 \end{aligned} \tag{2.13}$$

Μπορώ να γράψω το μοντέλο ως εξής:

$$\begin{aligned}
 Y_{ij} &= (\mu + \beta_j) + \alpha_i + \nu_{ij}, \nu_{ij} \sim^{iid} N(0, \sigma^2), j = 1, \dots, n \\
 \alpha_i &\sim^{iid} N(0, \sigma_\alpha^2), i = 1, \dots, m \\
 \nu_{ij} &\perp \nu_{i'j}, i \neq i' \\
 \nu_{ij} &\perp \alpha_i, \forall (i, j),
 \end{aligned} \tag{2.14}$$

όπου ο όρος  $(\mu + \beta_j)$  είναι σταθερός.

Το μοντέλο το γράφω σαν κανονικό Γενικό γραμμικό μοντέλο ( $\mathbf{Y} = \mathbf{X}\boldsymbol{\beta} + \boldsymbol{\epsilon}$ ,  $\boldsymbol{\epsilon} \sim N(\mathbf{0}, \boldsymbol{\Sigma})$ ),

$$\mathbf{Y} = \begin{bmatrix} Y_{11} \\ Y_{12} \\ \vdots \\ Y_{1n} \\ - \\ Y_{21} \\ Y_{22} \\ \vdots \\ Y_{2n} \\ - \\ \vdots \\ \vdots \\ - \\ Y_{m1} \\ Y_{m2} \\ \vdots \\ Y_{mn} \end{bmatrix} = \begin{bmatrix} \mu + \beta_1 \\ \mu + \beta_2 \\ \vdots \\ \mu + \beta_n \\ - \\ \mu + \beta_1 \\ \mu + \beta_2 \\ \vdots \\ \mu + \beta_n \\ - \\ \vdots \\ \vdots \\ - \\ \mu + \beta_1 \\ \mu + \beta_2 \\ \vdots \\ \mu + \beta_n \end{bmatrix} + \begin{bmatrix} \alpha_1 \\ \alpha_1 \\ \vdots \\ \alpha_1 \\ - \\ \alpha_2 \\ \alpha_2 \\ \vdots \\ \alpha_2 \\ - \\ \vdots \\ \vdots \\ - \\ \alpha_m \\ \alpha_m \\ \vdots \\ \alpha_m \end{bmatrix} + \begin{bmatrix} \nu_{11} \\ \nu_{12} \\ \vdots \\ \nu_{1n} \\ - \\ \nu_{21} \\ \nu_{22} \\ \vdots \\ \nu_{2n} \\ - \\ \vdots \\ \vdots \\ - \\ \nu_{m1} \\ \nu_{m2} \\ \vdots \\ \nu_{mn} \end{bmatrix}$$

Εδώ  $\boldsymbol{\beta} = (\mu, \beta_1, \dots, \beta_n)^T$ . Άρα ο  $mn \times (n+1)$  Πίνακας σχεδιασμού είναι

$$\mathbf{X} = \begin{bmatrix} 1 & 1 & 0 & \dots & 0 \\ 1 & 0 & 1 & \dots & 0 \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ 1 & 0 & 0 & \dots & 1 \\ - & - & - & - & - \\ 1 & 1 & 0 & \dots & 0 \\ 1 & 0 & 1 & \dots & 0 \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ 1 & 0 & 0 & \dots & 1 \\ - & - & - & - & - \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ - & - & - & - & - \\ 1 & 1 & 0 & \dots & 0 \\ 1 & 0 & 1 & \dots & 0 \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ 1 & 0 & 0 & \dots & 1 \end{bmatrix}$$

και ο πίνακας διασποράς είναι ο  $mn \times mn$  πίνακας

$$\boldsymbol{\Sigma}^* = \begin{bmatrix} \boldsymbol{\Sigma} & \mathbf{0} & \dots & \mathbf{0} \\ \mathbf{0} & \boldsymbol{\Sigma} & \dots & \mathbf{0} \\ \vdots & \vdots & \dots & \vdots \\ \mathbf{0} & \mathbf{0} & \dots & \boldsymbol{\Sigma} \end{bmatrix} = \sigma^2 \begin{bmatrix} \mathbf{V} & \mathbf{0} & \dots & \mathbf{0} \\ \mathbf{0} & \mathbf{V} & \dots & \mathbf{0} \\ \vdots & \vdots & \dots & \vdots \\ \mathbf{0} & \mathbf{0} & \dots & \mathbf{V} \end{bmatrix} = \sigma^2 \boldsymbol{\Psi}$$

όπου  $\boldsymbol{\Sigma}$  είναι ένας  $n \times n$  πίνακας συνδιακυμάνσεων των παρατηρήσεων από το  $i$ -οστό εργαστήριο και δίνεται από

$$\boldsymbol{\Sigma}_i = \begin{bmatrix} \sigma_\alpha^2 + \sigma^2 & \sigma_\alpha^2 & \dots & \sigma_\alpha^2 \\ \sigma_\alpha^2 & \sigma_\alpha^2 + \sigma^2 & \dots & \sigma_\alpha^2 \\ \vdots & \vdots & \dots & \vdots \\ \sigma_\alpha^2 & \sigma_\alpha^2 & \dots & \sigma_\alpha^2 + \sigma^2 \end{bmatrix} = \sigma^2 \begin{bmatrix} 1 + \phi & \phi & \dots & \phi \\ \phi & 1 + \phi & \dots & \phi \\ \vdots & \vdots & \dots & \vdots \\ \phi & \phi & \dots & 1 + \phi \end{bmatrix}$$

όπου  $\phi = \frac{\sigma_\alpha^2}{\sigma^2} > 0$

Προσοχή εδώ  $\text{rank}(\mathbf{X}) = n < n+1$ . Κανένα πρόβλημα! (;). Παραμετροποιώ το μοντέλο ορίζοντας  $\mu_j = \mu + \beta_j$ , κι έχω ως  $\boldsymbol{\beta} = (\mu_1, \dots, \mu_n)^T$ . Δηλαδή

δουλεύω με το ισοδύναμο μοντέλο:

$$\begin{aligned}
 Y_{ij} &= \mu_j + \alpha_i + \nu_{ij}, \nu_{ij} \sim^{iid} N(0, \sigma^2), j = 1, \dots, n \\
 \alpha_i &\sim^{iid} N(0, \sigma_\alpha^2), i = 1, \dots, m \\
 \nu_{ij} &\perp \nu_{i'j}, i \neq i' \\
 \nu_{ij} &\perp \alpha_i, \forall (i, j)
 \end{aligned} \tag{2.15}$$

και

$$\mathbf{X} = \begin{bmatrix} 1 & 0 & \dots & 0 \\ 0 & 1 & \dots & 0 \\ \vdots & \vdots & \vdots & \vdots \\ 0 & 0 & \dots & 1 \\ - & - & - & - \\ 1 & 0 & \dots & 0 \\ 0 & 1 & \dots & 0 \\ \vdots & \vdots & \vdots & \vdots \\ 0 & 0 & \dots & 1 \\ - & - & - & - \\ \vdots & \vdots & \vdots & \vdots \\ \vdots & \vdots & \vdots & \vdots \\ - & - & - & - \\ 1 & 0 & \dots & 0 \\ 0 & 1 & \dots & 0 \\ \vdots & \vdots & \vdots & \vdots \\ 0 & 0 & \dots & 1 \end{bmatrix}$$

## 2.2 Εκτίμηση με την μέθοδο της μέγιστης Πιθανοφάνειας (Maximum Likelihood Estimation (MLE) )

Με την υπόθεση κανονικότητας έχουμε

$$\mathbf{Y} | \mathbf{X} \sim N(\boldsymbol{\mu} = \mathbf{X}\boldsymbol{\beta}, \boldsymbol{\Sigma}(\sigma^2, \boldsymbol{\phi}) = \sigma^2 \mathbf{V}(\boldsymbol{\phi})). \tag{2.16}$$

Η loglikelihood είναι:

$$l(\mathbf{Y}, \mathbf{X}; \boldsymbol{\beta}, \sigma^2, \boldsymbol{\phi}) = -\frac{n}{2} \ln 2\pi - \frac{n}{2} \ln \sigma^2 - \frac{1}{2} \ln |\mathbf{V}(\boldsymbol{\phi})| - \frac{1}{2\sigma^2} (\mathbf{Y} - \mathbf{X}\boldsymbol{\beta})^T \mathbf{V}^{-1}(\boldsymbol{\phi}) (\mathbf{Y} - \mathbf{X}\boldsymbol{\beta}) \tag{2.17}$$

Δοθέντος  $\phi$  (και  $\sigma^2$ ), η loglikelihood μεγιστοποιείται ως προς  $\beta$  στην τιμή  $\hat{\beta}_{GLS}(\phi) = (\mathbf{X}^T \mathbf{V}^{-1}(\phi) \mathbf{X})^{-1} \mathbf{X}^T \mathbf{V}^{-1}(\phi) \mathbf{Y}$ . (γιατί;;)

Άρα αρκεί να μεγιστοποιήσουμε 'συγκεντρωμένη' πιθανοφάνεια

$$l_1(\sigma^2, \phi) = -\frac{n}{2} \ln 2\pi - \frac{n}{2} \ln \sigma^2 - \frac{1}{2} \ln |\mathbf{V}(\phi)| - \frac{1}{2\sigma^2} (\mathbf{Y} - \mathbf{X} \hat{\beta}_{GLS}(\phi))^T \mathbf{V}^{-1}(\phi) (\mathbf{Y} - \mathbf{X} \hat{\beta}_{GLS}(\phi)) \quad (2.18)$$

Δοθέντος  $\phi$  η  $l_1(\sigma^2, \phi)$  μεγιστοποιείται ως προς  $\sigma^2$  στην τιμή

$$\hat{\sigma}^2(\phi) = \frac{(\mathbf{Y} - \mathbf{X} \hat{\beta}_{GLS}(\phi))^T \mathbf{V}^{-1}(\phi) (\mathbf{Y} - \mathbf{X} \hat{\beta}_{GLS}(\phi))}{n}, \quad (2.19)$$

(γιατί;;).

Καθότι

$$\begin{aligned} & (\mathbf{Y} - \mathbf{X} \hat{\beta}_{GLS})^T \mathbf{V}^{-1}(\phi) (\mathbf{Y} - \mathbf{X} \hat{\beta}_{GLS}) = \\ & (\mathbf{Y} - \mathbf{X} (\mathbf{X}^T \mathbf{V}^{-1} \mathbf{X})^{-1} \mathbf{X}^T \mathbf{V}^{-1} \mathbf{Y})^T \mathbf{V}^{-1} (\mathbf{Y} - \mathbf{X} (\mathbf{X}^T \mathbf{V}^{-1} \mathbf{X})^{-1} \mathbf{X}^T \mathbf{V}^{-1} \mathbf{Y}) \\ & = \mathbf{Y}^T (\mathbf{I} - (\mathbf{X}^T \mathbf{V}^{-1} \mathbf{X})^{-1} \mathbf{X}^T \mathbf{V}^{-1})^T \mathbf{V}^{-1} (\mathbf{I} - \mathbf{X} (\mathbf{X}^T \mathbf{V}^{-1} \mathbf{X})^{-1} \mathbf{X}^T \mathbf{V}^{-1}) \mathbf{Y} \\ & = \mathbf{Y}^T (\mathbf{V}^{-1} - \mathbf{V}^{-1} \mathbf{X} (\mathbf{X}^T \mathbf{V}^{-1} \mathbf{X})^{-1} \mathbf{X}^T \mathbf{V}^{-1}) \mathbf{Y} \end{aligned} \quad (2.20)$$

έχουμε

$$\hat{\sigma}^2(\phi) = \frac{1}{n} \mathbf{Y}^T (\mathbf{V}^{-1}(\phi) - \mathbf{V}^{-1}(\phi) \mathbf{X} (\mathbf{X}^T \mathbf{V}^{-1}(\phi) \mathbf{X})^{-1} \mathbf{X}^T \mathbf{V}^{-1}(\phi)) \mathbf{Y} \quad (2.21)$$

Άρα αρκεί να μεγιστοποιήσουμε 'συγκεντρωμένη'-'συγκεντρωμένη' πιθανοφάνεια.

$$\begin{aligned} l_1(\phi) &= -\frac{n}{2} \ln 2\pi - \frac{n}{2} \ln \hat{\sigma}^2(\phi) - \frac{1}{2} \ln |\mathbf{V}(\phi)| - \frac{1}{2\hat{\sigma}^2(\phi)} (\mathbf{Y} - \mathbf{X} \hat{\beta}_{GLS}(\phi))^T \mathbf{V}^{-1}(\phi) (\mathbf{Y} - \mathbf{X} \hat{\beta}_{GLS}(\phi)) \\ &= -\frac{n}{2} \ln 2\pi - \frac{n}{2} \ln \hat{\sigma}^2(\phi) - \frac{1}{2} \ln |\mathbf{V}(\phi)| - \frac{n}{2} \end{aligned} \quad (2.22)$$

Δηλαδή ελαχιστοποιούμε την ποσότητα

$$n \ln \hat{\sigma}^2(\phi) + \ln |\mathbf{V}(\phi)| \quad (2.23)$$

ως προς  $\phi$  και παίρνουμε  $\hat{\phi}_{MLE}$ . κι έχουμε

$$\begin{aligned} \hat{\beta}_{MLE} &= \hat{\beta}_{GLS}(\hat{\phi}_{MLE}) \\ \hat{\sigma}_{MLE}^2 &= \hat{\sigma}^2(\hat{\phi}_{MLE}) = \frac{(\mathbf{Y} - \mathbf{X} \hat{\beta}_{GLS}(\hat{\phi}_{MLE}))^T \mathbf{V}^{-1}(\hat{\phi}_{MLE}) (\mathbf{Y} - \mathbf{X} \hat{\beta}_{GLS}(\hat{\phi}_{MLE}))}{n} \end{aligned} \quad (2.24)$$

Εναλλάκτικα μπορώ να δουλέψω χωρίς να ξεχωρίζω το  $\sigma^2$ , δηλαδή με το  $\Sigma(\boldsymbol{\psi})$ . Εδώ  $\boldsymbol{\psi}$  είναι όλες οι παράμετροι στον πίνακα διασποράς συνδιασποράς.

Η loglikelihood είναι:

$$l(\mathbf{Y}, \mathbf{X}; \boldsymbol{\beta}, \boldsymbol{\psi}) = -\frac{n}{2} \ln 2\pi - \frac{1}{2} \ln |\Sigma(\boldsymbol{\psi})| - \frac{1}{2} (\mathbf{Y} - \mathbf{X}\boldsymbol{\beta})^T \Sigma^{-1}(\boldsymbol{\psi}) (\mathbf{Y} - \mathbf{X}\boldsymbol{\beta}) \quad (2.25)$$

και η συγκεντρωμένη πιθανοφάνεια ισούται με

$$l_1(\boldsymbol{\psi}) = -\frac{n}{2} \ln 2\pi - \frac{1}{2} \ln |\Sigma(\boldsymbol{\psi})| - \frac{1}{2} (\mathbf{Y} - \mathbf{X}\hat{\boldsymbol{\beta}}_{GLS}(\boldsymbol{\psi}))^T \Sigma^{-1}(\boldsymbol{\psi}) (\mathbf{Y} - \mathbf{X}\hat{\boldsymbol{\beta}}_{GLS}(\boldsymbol{\psi})) \quad (2.26)$$

όπου  $\hat{\boldsymbol{\beta}}_{GLS}(\boldsymbol{\psi}) = (\mathbf{X}^T \Sigma^{-1}(\boldsymbol{\psi}) \mathbf{X})^{-1} \mathbf{X}^T \Sigma^{-1}(\boldsymbol{\psi}) \mathbf{Y}$ ,  
και ελαχιστοποιώ

$$l_1(\boldsymbol{\psi}) = \ln |\Sigma(\boldsymbol{\psi})| + (\mathbf{Y} - \mathbf{X}\hat{\boldsymbol{\beta}}_{GLS}(\boldsymbol{\psi}))^T \Sigma^{-1}(\boldsymbol{\psi}) (\mathbf{Y} - \mathbf{X}\hat{\boldsymbol{\beta}}_{GLS}(\boldsymbol{\psi})) \quad (2.27)$$

## 2.3 Γενικευμένα Γραμμικά Μοντέλα (Generalized Linear Models)

Θεωρήστε τα παρακάτω μοντέλα με μια συμμεταβλητή:

- Απλή κλασσική Κανονική Γραμμική Παλινδρόμηση

$$\begin{aligned} Y_i &\sim^{ind} N(\mu_i, \sigma^2) \\ \mu_i &= \beta_0 + \beta_1 x_i, \quad i = 1, \dots, n. \end{aligned} \quad (2.28)$$

- Απλή Λογιστική Παλινδρόμηση

$$\begin{aligned} Y_i &\sim^{ind} Bernoulli(\pi_i) \\ \ln\left(\frac{\pi_i}{1 - \pi_i}\right) &= \beta_0 + \beta_1 x_i, \quad i = 1, \dots, n. \end{aligned} \quad (2.29)$$

Ως παράδειγμα, θεωρήστε ένα πείραμα σε ποντίκια εργαστηρίου που αφορά στην εξεύρεση 'κατάλληλης' δόσολογίας ενός ποντικοφάρμακου. Η βιολόγος κάνει ένεση ποντικοφάρμακου σε επίπεδο δόσης  $x_i$ , στο τυχαία επιλεγμένο ποντίκι  $i$  και παρατηρεί αν το ποντίκι πέθανε σε χρονικό διάστημα 10 λεπτών. Η απόκριση,  $Y_i$ , παίρνει τη τιμή 1 αν το ποντίκι πεθάνει, αλλιώς παίρνει τη τιμή 0. Η παράμετρος  $\pi_i = \pi(x_i)$  είναι η πιθανότητα θανάτου μέσα σε δέκα λεπτά όταν η δόση ισούται με  $x_i$ . Ο λόγος  $\frac{\pi_i}{1 - \pi_i}$  είναι τα *odds* θανάτου του ποντικιού σε δόση  $x_i$  του δηλητηρίου. Σημειώστε πως  $\ln\left(\frac{\pi_i}{1 - \pi_i}\right)$  παίρνει τιμές στο  $(-\infty, +\infty)$ .

Ισοδύναμα το μοντέλο μπορεί να γραφεί ως

$$\begin{aligned} Y_i &\sim^{ind} Bernoulli(\pi_i) \\ \pi_i &= \frac{\exp(\beta_0 + \beta_1 x_i)}{1 + \exp(\beta_0 + \beta_1 x_i)}, \quad i = 1, \dots, n. \end{aligned}$$

Θυμηθείτε πως για μια *Bernoulli* τ.μ. ισχύει  $E(Y_i) = \mu_i = \pi_i$  ( επίσης  $Var(Y_i) = \mu_i(1 - \mu_i) = \pi_i(1 - \pi_i)$  ) κι άρα μπορούμε να γράψουμε το μοντέλο κι ως

$$\begin{aligned} Y_i &\sim^{ind} Bernoulli(\mu_i) \\ \ln\left(\frac{\mu_i}{1 - \mu_i}\right) &= \beta_0 + \beta_1 x_i, \quad i = 1, \dots, n. \end{aligned} \quad (2.30)$$

- Απλή Poisson Παλινδρόμηση

$$\begin{aligned} Y_i &\sim^{ind} Poisson(\mu_i) \\ \ln \mu_i &= \beta_0 + \beta_1 x_i, \quad i = 1, \dots, n. \end{aligned} \quad (2.31)$$

Για παράδειγμα  $Y_i$  μπορεί να είναι ο αριθμός εισαγωγών στο ΑΧΕΠΑ λόγω κορονοϊού κατά την ημέρα  $i$  και  $x_i$  μια μέτρηση του επιπέδου του covid19 στα αστικά λύμματα της Θεσσαλονίκης 7 μέρες πριν.

Η Απλή Poisson Παλινδρόμηση μπορεί να γραφεί ισοδύναμα ως

$$\begin{aligned} Y_i &\sim^{ind} Poisson(\mu_i) \\ \mu_i &= \exp(\beta_0 + \beta_1 x_i), \quad i = 1, \dots, n. \end{aligned}$$

Τι κοινό έχουν αυτά τα 3 μοντέλα;

Παρατηρούμε πως και στα 3 ορίζουμε πρώτα την κατανομή της απόκρισης και μετά 'συνδεούμε' τον μέσο της κατανομής με την συμμεταβλητή. Με άλλα λόγια έχουν τη γενική μορφή

$$\begin{aligned} Y_i &\sim^{ind} F_{Y_i}(y_i) \\ g(\mu_i) &= \beta_0 + \beta_1 x_i, \quad i = 1, \dots, n, \end{aligned} \quad (2.32)$$

όπου  $\mu_i$  είναι ο μέσος της τ.μ.  $Y_i$  (ισοδύναμα της κατανομής  $F_i$ ). Στην απλή κανονική γραμμική παλινδρόμηση έχουμε  $g(t) = t$ , στην λογιστική παλινδρόμηση έχουμε  $g(t) = \ln\left(\frac{t}{1-t}\right)$ , και στην Poisson παλινδρόμηση έχουμε  $g(t) = \ln(t)$ .

Στην γενική περίπτωση, και γράφοντας τη σ.π.π. της κατανομής  $F_{Y_i}(y_i)$  ως  $f_{Y_i}(y_i)$ , υποθέτουμε πως η κατανομή ανήκει στην εκθετική οικογένεια κατανομών, δηλαδή η σ.π.π είναι της μορφής

$$f_{Y_i}(y_i) = \exp\left[\frac{\gamma_i y_i - b(\gamma_i)}{\tau^2} - c(y_i, \tau)\right], \quad (2.33)$$

και έχουμε

$$\begin{aligned} Y_i &\sim^{ind} F_{Y_i}(y_i) \\ g(\mu_i) &= \mathbf{x}_i^T \boldsymbol{\beta}, \quad i = 1, \dots, n, \end{aligned} \quad (2.34)$$

όπου το διάνυσμα  $\mathbf{x}_i^T = (1 \ x_{i1} \ x_{i2} \ \dots \ x_{i,p-1})$  περιέχει τις τιμές των συμμεταβλητών για την παρατήρηση  $i$ . Η συνάρτηση  $g()$  λέγεται συνάρτηση σύνδεσης (link function).

Μπορεί να αποδειχθεί πως

$$E(Y_i) = \mu_i = \frac{\partial b(\gamma_i)}{\partial \gamma_i}$$

$$Var(Y_i) = \tau^2 \frac{\partial^2 b(\gamma_i)}{\partial \gamma_i^2} = \tau^2 v(\mu_i). \quad (2.35)$$

Η συνάρτηση  $v(\mu_i) = \frac{\partial^2 b(\gamma_i)}{\partial \gamma_i^2}$  καλείται συνάρτηση διασποράς (variance function).

### Άσκηση

1. Δείξτε πως οι σ.π.π. σε κάθε ένα από τα 3 παραδείγματα ανήκουν στη εκθετική οικογένεια.

Για τη λογιστική παλινδρόμηση θα δείξουμε ότι η *Bernoulli* ανήκει στην εκθετική οικογένεια.

$$\begin{aligned} f_Y(y) &= \pi^y (1 - \pi)^{1-y}, \quad y = 0, 1 \\ &= \left(\frac{\pi}{1 - \pi}\right)^y (1 - \pi) \\ &= \exp\left[\ln\left(\frac{\pi}{1 - \pi}\right)^y + \ln(1 - \pi)\right] \\ &= \exp\left[y \ln\left(\frac{\pi}{1 - \pi}\right) + \ln(1 - \pi)\right] \end{aligned}$$

ανήκει στη εκθετική οικογένεια, με  $\tau = 1$ ,  $c(y_i, \tau) = 0$ ,  $\gamma = \ln\left(\frac{\pi}{1 - \pi}\right)$ ,  $b(\gamma) = -\ln(1 - \pi)$ .

2. Για κάθε παράδειγμα βρείτε την variance function.

Για τη λογιστική παλινδρόμηση ξέρουμε  $Var(Y) = \pi(1 - \pi) = \mu(1 - \mu)$ , κι άρα  $v(\mu) = \mu(1 - \mu)$ .



### 2.3.1 Εκτίμηση των παραμέτρων με την μέθοδο Μεγίστης πιθανοφάνειας

Η πιθανοφάνεια δίνεται από

$$\begin{aligned} L(\boldsymbol{\beta}, \tau) &= \prod_{i=1}^n f_{Y_i}(y_i; \boldsymbol{\beta}, \tau) \\ &= \prod_{i=1}^n \exp \left[ \frac{\gamma_i y_i - b(\gamma_i)}{\tau^2} - c(y_i, \tau) \right]. \end{aligned}$$

Ο λογάριθμος της πιθανοφάνειας ισούται με

$$\begin{aligned} l(\boldsymbol{\beta}, \tau) &= \ln L(\boldsymbol{\beta}, \tau) \\ &= \sum_{i=1}^n \frac{\gamma_i y_i - b(\gamma_i)}{\tau^2} - \sum_{i=1}^n c(y_i, \tau). \end{aligned}$$

Για την ώρα ας θεωρήσουμε το  $\tau$  γνωστό. Αυτό συμβαίνει στη λογιστική παλινδρόμηση και στην Poisson παλινδρόμηση. Ο MLE εκτιμητής του  $\boldsymbol{\beta}$  είναι η λύση του παρακάτω προβλήματος:

$$\max_{\boldsymbol{\beta}} \frac{1}{\tau^2} \sum_{i=1}^n (\gamma_i y_i - b(\gamma_i)), \quad (2.36)$$

ή ισοδύναμα

$$\max_{\boldsymbol{\beta}} \sum_{i=1}^n (\gamma_i y_i - b(\gamma_i)), \quad (2.37)$$

Οι εκτιμητικές εξισώσεις για το  $\boldsymbol{\beta}$  προκύπτουν θέτοντας την παράγωγο, ως προς  $\boldsymbol{\beta}$ , του  $\sum_{i=1}^n (\gamma_i y_i - b(\gamma_i))$  ίσο με  $\mathbf{0}_p$ . Έχουμε

$$\begin{aligned} \frac{\partial}{\partial \boldsymbol{\beta}} \sum_{i=1}^n (\gamma_i y_i - b(\gamma_i)) &= \sum_{i=1}^n y_i \frac{\partial \gamma_i}{\partial \boldsymbol{\beta}} - \frac{\partial b(\gamma_i)}{\partial \boldsymbol{\beta}} \\ &= \sum_{i=1}^n y_i \frac{\partial \gamma_i}{\partial \boldsymbol{\beta}} - \frac{\partial b(\gamma_i)}{\partial \gamma_i} \frac{\partial \gamma_i}{\partial \boldsymbol{\beta}} \\ &= \sum_{i=1}^n (y_i - \mu_i) \frac{\partial \gamma_i}{\partial \boldsymbol{\beta}} \\ &= \sum_{i=1}^n (y_i - \mu_i) \frac{\partial \gamma_i}{\partial \mu_i} \frac{\partial \mu_i}{\partial \boldsymbol{\beta}} \end{aligned} \quad (2.38)$$

Για να υπολογίσουμε τις παραγώγους στην τελευταία έκφραση της (2.38) έχουμε

$$\begin{aligned}
\frac{\partial \mu_i}{\partial \gamma_i} &= \frac{\partial^2 b(\gamma_i)}{\partial \gamma_i^2} = v(\mu_i) \\
\implies \frac{\partial \gamma_i}{\partial \mu_i} &= \left(\frac{\partial \mu_i}{\partial \gamma_i}\right)^{-1} = \frac{1}{v(\mu_i)} \\
\frac{\partial \mu_i}{\partial \boldsymbol{\beta}} &= \frac{\partial \mu_i}{\partial g(\mu_i)} \frac{\partial g(\mu_i)}{\partial \boldsymbol{\beta}} \\
&= \left(\frac{\partial g(\mu_i)}{\partial \mu_i}\right)^{-1} \frac{\partial \mathbf{x}_i^T \boldsymbol{\beta}}{\partial \boldsymbol{\beta}} \\
&= \frac{1}{g_\mu(\mu_i)} \mathbf{x}_i,
\end{aligned}$$

όπου ορίζουμε  $g_\mu(\mu_i) = g'(\mu_i)$ , και  $\mathbf{x}_i$  είναι το  $p \times 1$  διάνυσμα με τις τιμές των συμμεταβλητών για την  $i$ -οστή παρατήρηση. Άρα έχουμε

$$\begin{aligned}
\frac{\partial}{\partial \boldsymbol{\beta}} l(\boldsymbol{\beta}, \tau) &= \frac{1}{\tau^2} \sum_{i=1}^n (y_i - \mu_i) \frac{\partial \gamma_i}{\partial \mu_i} \frac{\partial \mu_i}{\partial \boldsymbol{\beta}} \\
&= \frac{1}{\tau^2} \sum_{i=1}^n \frac{(y_i - \mu_i)}{v(\mu_i) g_\mu(\mu_i)} \mathbf{x}_i \\
&= \frac{1}{\tau^2} \sum_{i=1}^n (y_i - \mu_i) w_i g_\mu(\mu_i) \mathbf{x}_i, \tag{2.39}
\end{aligned}$$

όπου ορίσαμε

$$w_i = \frac{1}{v(\mu_i) g_\mu^2(\mu_i)}.$$

Ορίζουμε τους δύο  $n \times n$  διαγώνιους πίνακες  $\mathbf{W}$ ,  $\boldsymbol{\Delta}$ , με  $\mathbf{W}$  να έχει ως  $i$ -οστό διαγώνιο στοιχείο το  $w_i$ , και  $\boldsymbol{\Delta}$  να έχει ως  $i$ -οστό διαγώνιο στοιχείο το  $g_\mu(\mu_i)$ . Επίσης ορίζουμε  $\boldsymbol{\mu} = \boldsymbol{\mu}(\boldsymbol{\beta})$  το  $n \times 1$  διάνυσμα  $(\mu_1 \ \mu_2 \ \dots \ \mu_n)^T$ , με  $i$ -οστό στοιχείο το  $\mu_i = g^{-1}(\mathbf{x}_i^T \boldsymbol{\beta})$ . Η εξίσωση (2.39) γράφεται πιο συνοπτικά ως

$$\frac{\partial}{\partial \boldsymbol{\beta}} l(\boldsymbol{\beta}, \tau) = \frac{1}{\tau^2} \mathbf{X}^T \mathbf{W} \boldsymbol{\Delta} (\mathbf{y} - \boldsymbol{\mu}) \tag{2.40}$$

και ο εκτιμητής μεγίστης πιθανοφάνειας προκύπτει ως λύση των  $p$  εκτιμητικών εξισώσεων

$$\begin{aligned}
\mathbf{X}^T \mathbf{W} \boldsymbol{\Delta} (\mathbf{y} - \boldsymbol{\mu}) &= \mathbf{0}_p \\
\iff \mathbf{X}^T \mathbf{W} \boldsymbol{\Delta} \mathbf{y} &= \mathbf{X}^T \mathbf{W} \boldsymbol{\Delta} \boldsymbol{\mu} \tag{2.41}
\end{aligned}$$

### Άσκηση

1. Γράψτε αναλυτικά τις εκτιμητικές εξισώσεις για την απλή λογιστική παλινδρόμηση που πρέπει να λυθούν ως προς  $\beta_0, \beta_1$ .

Για απλή λογιστική παλινδρόμηση έχουμε  $\mathbf{x}_i = (1 \ x_i)^T$ ,  $v(\mu_i) = \mu_i(1 - \mu_i)$ ,  $g(\mu_i) = \ln \frac{\mu_i}{1 - \mu_i} \implies g_\mu(\mu_i) = \frac{1 - \mu_i}{\mu_i} \frac{1}{(1 - \mu_i)^2} = \frac{1}{\mu_i(1 - \mu_i)}$ . Άρα

$$w_i = \frac{1}{\mu_i(1 - \mu_i) \left(\frac{1}{\mu_i(1 - \mu_i)}\right)^2} = \mu_i(1 - \mu_i)$$

και βάσει της (2.39) οι εκτιμητικές εξισώσεις γράφονται ως

$$\begin{aligned} \sum_{i=1}^n (y_i - \mu_i) w_i g_\mu(\mu_i) \mathbf{x}_i &= \mathbf{0}_2 \implies \\ \sum_{i=1}^n (y_i - \mu_i) \mu_i (1 - \mu_i) \frac{1}{\mu_i(1 - \mu_i)} \mathbf{x}_i &= \mathbf{0}_2 \implies \\ \sum_{i=1}^n (y_i - \mu_i) \mathbf{x}_i &= \mathbf{0}_2 \implies \\ \sum_{i=1}^n (y_i - \mu_i) \begin{bmatrix} 1 \\ x_i \end{bmatrix} &= \begin{bmatrix} 0 \\ 0 \end{bmatrix}. \end{aligned}$$

Οι 2 εκτιμητικές εξισώσεις είναι

$$\begin{aligned} \sum_{i=1}^n (y_i - \mu_i) &= 0 \\ \sum_{i=1}^n x_i (y_i - \mu_i) &= 0. \end{aligned}$$

Βλέπουμε πως η μορφή των δύο εκτιμητικών εξισώσεων στην απλή λογιστική παλινδρόμηση είναι ίδια με τη μορφή που έχουμε στην κλασσική απλή κανονική γραμμική παλινδρόμηση, δηλαδή το άθροισμα των υπολοίπων ισούται με 0 και το άθροισμα των γινομένων των υπολοίπων με τη συμμεταβλητή ισούται με 0. Όμως σε αντίθεση με τη κλασσική απλή κανονική γραμμική παλινδρόμηση το σύστημα των 2 εξισώσεων δεν είναι γραμμικό ως προς τις παραμέτρους. Αυτό οφείλεται στο ότι τα  $\mu_i$  δεν είναι γραμμικές συναρτήσεις των  $\beta_0, \beta_1$ . Η πλήρης

μορφή των 2 εξισώσεων είναι:

$$\sum_{i=1}^n \left( y_i - \frac{\exp(\beta_0 + \beta_1 x_i)}{1 + \exp(\beta_0 + \beta_1 x_i)} \right) = 0$$
$$\sum_{i=1}^n x_i \left( y_i - \frac{\exp(\beta_0 + \beta_1 x_i)}{1 + \exp(\beta_0 + \beta_1 x_i)} \right) = 0.$$

Φαίνεται καθαρά πως το παραπάνω σύστημα είναι μη γραμμικό ως προς τις παραμέτρους και λύνεται αποκλειστικά με αριθμητικές μεθόδους.