1 Πίνακες

1.1 Φασματική ανάλυση ενός πραγματικού συμμετρικού πίνακα

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

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

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

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

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

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

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

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

2 Εφαρμογές Στατιστική

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

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

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

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

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

3. Γράφοντας

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

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

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

<u>Απλό παράδειγμα:</u>

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

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

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

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

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

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

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

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

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

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

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

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

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

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

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

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

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

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

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

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

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

1. *$\hat{\boldsymbol{\beta}}_{MLE} = \hat{\boldsymbol{\beta}}_{LS} = (\boldsymbol{X}^T\boldsymbol{X})^{-1}\boldsymbol{X}^T\boldsymbol{Y}$ (ο εκτιμητής ελαχίστων τετραγώνων).*
2. *$\hat{\sigma}^2 = \frac{(\boldsymbol{Y}-\boldsymbol{X}\hat{\boldsymbol{\beta}}_{LS})^T(\boldsymbol{Y}-\boldsymbol{X}\hat{\boldsymbol{\beta}}_{LS})}{n} = \frac{1}{n}\boldsymbol{Y}^T(\boldsymbol{I}-\boldsymbol{H})\boldsymbol{Y}$, όπου $\boldsymbol{H} = \boldsymbol{X}(\boldsymbol{X}^T\boldsymbol{X})^{-1}\boldsymbol{X}^T$ 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 $\boldsymbol{\Sigma} = \sigma^2\boldsymbol{I}$, $\boldsymbol{\mu} = \boldsymbol{X}\boldsymbol{\beta}$. Η πιθανοφάνεια $L(\boldsymbol{\beta}, \sigma^2)$ ισούται με

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

Ο λογάριθμος της πιθανοφάνειας ισούται με

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

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

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

Η δεύτερη παράγωγος της (2.1) ως προς σ^2 ισούται με

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

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:

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

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

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

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

Η εκτιμητική εξίσωση που προκύπτει είναι

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

Η δεύτερη παράγωγος είναι

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

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

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

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

□

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

1. $\hat{\boldsymbol{\beta}} \sim N(\boldsymbol{\beta}, \sigma^2(\boldsymbol{X}^T\boldsymbol{X})^{-1})$
2. $n\frac{\hat{\sigma}^2}{\sigma^2} = (n-p)\frac{s^2}{\sigma^2} \sim \chi^2_{n-p}$, *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* $\boldsymbol{R}$ *είναι ένας* $q \times p$ *πίνακας με* $rank(\boldsymbol{R}) = q \leq p$, *τότε*

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

Απόδειξη.

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

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

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

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

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

Έχουμε

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

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

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

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

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. □

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

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. (δ_1, δ_2 είναι οι δείκτες για μεσαίο και μεγάλο κατάστημα αντιστοιχα)

Το γραμμικό μοντέλο που χρησιμοποιήθηκε είναι:

$$\begin{aligned} Y_i &= \beta_0 + \beta_1 x_i + \beta_2 \delta_{1i} + \beta_3 \delta_{2i} + \beta_4 \delta_{1i} x_i + \beta_5 \delta_{2i} x_i + \epsilon_i \\ \epsilon_1, \ldots, \epsilon_{100} &\sim_{iid} N(0, \sigma^2) \end{aligned}$$

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 β_1.

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

  $$\begin{aligned} Y_i &= \beta_0 + \beta_2 + \beta_1 x_i + \beta_4 x_i + \epsilon_i \\ &= (\beta_0 + \beta_2) + (\beta_1 + \beta_4) x_i + \epsilon_i. \end{aligned}$$

  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

  $$\begin{aligned} Y_i &= \beta_0 + \beta_1 x_i + \beta_3 + \beta_5 x_i + \epsilon_i \\ &= (\beta_0 + \beta_3) + (\beta_1 + \beta_5) x_i + \epsilon_i. \end{aligned}$$

  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 $H_0: \ \boldsymbol{R\beta} = \boldsymbol{r}$, όπου $\boldsymbol{R}$ έχει q γραμμές και ισχύει $rank(\boldsymbol{R}) = q$. Επίσης γράψτε την σ.σ.ε και την κατανομή της κάτω από την μηδενική υπόθεση.

1. H_0 : η εκστρατεία δεν ήταν αποτελεματική.

   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 $H_0: \boldsymbol{\beta} = \boldsymbol{0}_6$, κι έχουμε $\boldsymbol{R} = \boldsymbol{I}_6$. Βάσει του τελευταίου αποτελεσματος στο Θεώρημα (9) έχουμε

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

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 $H_0 : \boldsymbol{R\beta} = \mathbf{0}_4$, όπου

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

   Βάσει του τελευταίου αποτελεσματος στο Θεώρημα (9) έχουμε

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

   Παρατηρήστε εδώ πως $\boldsymbol{R}\hat{\boldsymbol{\beta}}$ είναι απλά το διάνυσμα $(\hat{\beta}_2\ \hat{\beta}_3\ \hat{\beta}_4\ \hat{\beta}_5)^T$, ενώ $\boldsymbol{R}(\boldsymbol{X}^T\boldsymbol{X})^{-1}\boldsymbol{R}^T$ είναι απλά ο 4×4 κάτω υποπίνακας του $(\boldsymbol{X}^T\boldsymbol{X})^{-1}$, (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 μεγέθος 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 $H_0 : \boldsymbol{R\beta} = \mathbf{0}_2$, όπου

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

   Βάσει του τελευταίου αποτελεσματος στο Θεώρημα (9) έχουμε

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

   Παρατηρήστε εδώ πως $\boldsymbol{R}\hat{\boldsymbol{\beta}}$ είναι απλά το διάνυσμα $(\hat{\beta}_4\ \hat{\beta}_5)^T$, ενώ $\boldsymbol{R}(\boldsymbol{X}^T\boldsymbol{X})^{-1}\boldsymbol{R}^T$ είναι απλά ο 2×2 κάτω υποπίνακας του $(\boldsymbol{X}^T\boldsymbol{X})^{-1}$, (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

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

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

   Βάσει του τελευταίου αποτελεσματος στο Θεώρημα (9) έχουμε

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

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

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

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

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

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

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

$\square$

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

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

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

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), $\boldsymbol{\beta}$ είναι το $p \times 1$ διάνυσμα παραμέτρων, και $\boldsymbol{\epsilon}$ είναι ένα $n \times 1$ διάνυσμα σφαλμάτων. Επίσης υποθέτουμε πως $rank(\boldsymbol{X}) = p$, δηλαδή ο $\boldsymbol{X}$ έχει γραμμικά ανεξάρτητες στήλες. Ισοδύναμα μπορούμε να γράψουμε το μοντέλο (2.3) ως

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

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

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

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

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

όπου

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

Είναι προφανές πως $Var(\boldsymbol{\epsilon}^*) = Var(\boldsymbol{\Sigma}^{-1/2}\boldsymbol{\epsilon}) = \boldsymbol{\Sigma}^{-1/2}\boldsymbol{\Sigma}\boldsymbol{\Sigma}^{-1/2} = \boldsymbol{I}_n$. 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

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

□

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

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

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

Για τον $\hat{\boldsymbol{\beta}}_{GLS}$ έχουμε

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

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

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

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

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

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

Ένδειξη: χρησιμοποιήσετε τη φασματική ανάλυση του $\boldsymbol{V}$ για να ορίσετε το $\boldsymbol{V}^{1/2}$ 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 ($i = 1, \ldots, n$).

$$\begin{aligned} Y_i &= \boldsymbol{x}_i^T \boldsymbol{\beta} + \epsilon_i \\ \epsilon_i &\sim^{ind} N(0, \sigma^2 \frac{1}{k_i}) \end{aligned}$$

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

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

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

Παράδειγμα 2: Παλινδρόμηση με AR(1) σφάλματα.

$$\begin{aligned} Y_t &= \boldsymbol{x}_t^T \boldsymbol{\beta} + \epsilon_t \\ \epsilon_t &= \phi \epsilon_{t-1} + \nu_t, \ \nu_t \sim^{iid} N(0, \sigma_\nu^2) \\ & -1 < \phi < 1 \end{aligned}$$

Εύκολα μπορεί να δειχθεί πως

$$\begin{aligned} \epsilon_t &\sim N(0, \frac{\sigma_\nu^2}{1-\phi^2}) \\ cov(\epsilon_t, \epsilon_{t-k}) &= \phi^k \frac{\sigma_\nu^2}{1-\phi^2} \end{aligned}$$

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

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

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

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

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

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

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

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

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

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

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

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

<u>Παράδειγμα 4:</u> Απλό γραμμικό μοντέλο με ένα σταθερό παράγοντα κι εναν τυχαίο παράγοντα (two way mixed effects model).

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

Μπορώ να γράψω το μοντέλο ώς εξής:

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

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

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

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

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

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

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

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

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 $rank(\boldsymbol{X}) = n < n+1$. 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:

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

και

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

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

Με την υπόθεση κανονικότητας έχουμε

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

Η loglikelihood είναι:

$$l(\boldsymbol{Y},\boldsymbol{X};\boldsymbol{\beta},\sigma^2,\boldsymbol{\phi}) = -\frac{n}{2}ln2\pi - \frac{n}{2}ln\sigma^2 - \frac{1}{2}ln|\boldsymbol{V}(\boldsymbol{\phi})| - \frac{1}{2\sigma^2}(\boldsymbol{Y}-\boldsymbol{X\beta})^T\boldsymbol{V}^{-1}(\boldsymbol{\phi})(\boldsymbol{Y}-\boldsymbol{X\beta}) \tag{2.17}$$

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

Άρα αρκεί να μεγιστοποιήσουμε 'συγκεντρωμένη' πιθανοφάνεια

$$l_1(\sigma^2, \boldsymbol{\phi}) = -\frac{n}{2}ln2\pi - \frac{n}{2}ln\sigma^2 - \frac{1}{2}ln|\boldsymbol{V}(\boldsymbol{\phi})| - \frac{1}{2\sigma^2}(\boldsymbol{Y} - \boldsymbol{X}\hat{\boldsymbol{\beta}}_{GLS}(\boldsymbol{\phi}))^T\boldsymbol{V}^{-1}(\boldsymbol{\phi})(\boldsymbol{Y} - \boldsymbol{X}\hat{\boldsymbol{\beta}}_{GLS}(\boldsymbol{\phi})) \tag{2.18}$$

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

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

(γιατί;;).

Καθότι

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

έχουμε

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

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

$$\begin{aligned} l_1(\boldsymbol{\phi}) &= -\frac{n}{2}ln2\pi - \frac{n}{2}ln\hat{\sigma}^2(\boldsymbol{\phi}) - \frac{1}{2}ln|\boldsymbol{V}(\boldsymbol{\phi})| - \frac{1}{2\hat{\sigma}^2(\boldsymbol{\phi})}(\boldsymbol{Y} - \boldsymbol{X}\hat{\boldsymbol{\beta}}_{GLS}(\boldsymbol{\phi}))^T\boldsymbol{V}^{-1}(\boldsymbol{\phi})(\boldsymbol{Y} - \boldsymbol{X}\hat{\boldsymbol{\beta}}_{GLS}(\boldsymbol{\phi})) \\ &= -\frac{n}{2}ln2\pi - \frac{n}{2}ln\hat{\sigma}^2(\boldsymbol{\phi}) - \frac{1}{2}ln|\boldsymbol{V}(\boldsymbol{\phi})| - \frac{n}{2} \end{aligned} \tag{2.22}$$

Δηλαδή <u>ελαχιστοποιούμε</u> την ποσότητα

$$nln\hat{\sigma}^2(\boldsymbol{\phi}) + ln|\boldsymbol{V}(\boldsymbol{\phi})| \tag{2.23}$$

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

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

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

H loglikelihood είναι:

$$l(\boldsymbol{Y},\boldsymbol{X};\boldsymbol{\beta},\boldsymbol{\psi}) = -\frac{n}{2}ln2\pi - \frac{1}{2}ln|\boldsymbol{\Sigma}(\boldsymbol{\psi})| - \frac{1}{2}(\boldsymbol{Y}-\boldsymbol{X}\boldsymbol{\beta})^T\boldsymbol{\Sigma}^{-1}(\boldsymbol{\psi})(\boldsymbol{Y}-\boldsymbol{X}\boldsymbol{\beta}) \tag{2.25}$$

και η συγκεντρωμένη πιθανοφάνεια ισούται με

$$l_1(\boldsymbol{\psi}) = -\frac{n}{2}ln2\pi - \frac{1}{2}ln|\boldsymbol{\Sigma}(\boldsymbol{\psi})| - \frac{1}{2}(\boldsymbol{Y}-\boldsymbol{X}\hat{\boldsymbol{\beta}}_{GLS}(\boldsymbol{\psi}))^T\boldsymbol{\Sigma}^{-1}(\boldsymbol{\psi})(\boldsymbol{Y}-\boldsymbol{X}\hat{\boldsymbol{\beta}}_{GLS}(\boldsymbol{\psi})) \tag{2.26}$$

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

και ελαχιστοποιώ

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

2.3 Γενικευμένα Γραμμικά Μοντέλα (Generalized Linear Models)

Θεωρήστε τα παρακάτω μοντέλα με μια συμμεταβλητή:

- Απλή κλασσική Κανονική Γραμμική Παλινδρόμηση

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

- Απλή Λογιστική Παλινδρόμηση

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

Ως παράδειγμα, θεωρήστε ένα πείραμα σε ποντίκια εργαστηρίου που αφορά στην εξεύρεση 'κατάλληλης' δοσολογίας 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 $\ln(\frac{\pi_i}{1-\pi_i})$ παίρνει τιμές στο $(-\infty, +\infty)$.

Ισοδύναμα το μοντέλο μπορεί να γραφεί ως

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

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

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

- Απλή Poisson Παλινδρόμηση

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

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

$$\begin{array}{rcl} Y_i & \sim^{ind} & Poisson(\mu_i) \\ \mu_i & = & exp(\beta_0 + \beta_1 x_i), \;\; i = 1, \ldots, n. \end{array}$$

Τι κοινό έχουν αυτά τα 3 μοντέλα;

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

$$\begin{array}{rcl} Y_i & \sim^{ind} & F_{Y_i}(y_i) \\ g(\mu_i) & = & \beta_0 + \beta_1 x_i, \;\; i = 1, \ldots, n, \end{array} \tag{2.32}$$

όπου μ_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 $g(t) = ln(\frac{t}{1-t})$, 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

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

κι έχουμε

$$\begin{array}{rcl} Y_i & \sim^{ind} & F_{Y_i}(y_i) \\ g(\mu_i) & = & \boldsymbol{x}_i^T \boldsymbol{\beta}, \;\; i = 1, \ldots, n, \end{array} \tag{2.34}$$

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

Μπορεί να αποδειχθεί πως

$$
\begin{aligned}
E(Y_i) = \mu_i = \frac{\partial b(\gamma_i)}{\partial \gamma_i} \\
Var(Y_i) = \tau^2 \frac{\partial^2 b(\gamma_i)}{\partial \gamma_i^2} = \tau^2 v(\mu_i).
\end{aligned} \tag{2.35}
$$

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.

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

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

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 πιθανοφάνεις 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 τ γνωστό. Αυτό συμβαίνει στη λογιστική παλινδρόμηση και στην Poisson παλινδρόμηση. Ο MLE εκτιμητής του $\boldsymbol{\beta}$ είναι η λύση του παρακάτω προβλήματος:

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

ή ισοδύναμα

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

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

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

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

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

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

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

όπου ορίσαμε

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

Ορίζουμε τους δύο $n \times n$ διαγώνιους πίνακες $\boldsymbol{W}, \boldsymbol{\Delta}$, με $\boldsymbol{W}$ 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 $(\mu_1\ \mu_2 \ldots \mu_n)^T$, με i-οστό στοιχείο το $\mu_i = g^{-1}(\boldsymbol{x}_i^T\boldsymbol{\beta})$. Η εξίσωση (2.39) γράφεται πιο συνοπτικά ως

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

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

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

Άσκηση

1. Γράψτε αναλυτικά τις εκτιμητικές εξισώσεις για την απλή λογιστική παλινδρόμηση που πρέπει να λυθούν ως προς β_0, β_1.

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

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

και βάσει της (2.39) οι εκτιμητικές εξισώσεις γράφονται ως

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

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 μ_i δεν είναι γραμμικές συναρτήσεις των β_0, β_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 η παραπάνω εξίσωση είναι μη γραμμική ως προς τις παραμέτρους και λύνεται με αριθμητικές μεθόδους.