

Συντελεστής Προσδιορισμού:

Γνωρίζω ότι $SS_{tot} = SS_{reg} + SS_{res}$.

Ο συντελεστής προσδιορισμού R^2 ορίζεται από τη σχέση $R^2 = \frac{SS_{reg}}{SS_{tot}}$ και έχει τις εξής ιδιότητες:

$$(α) \quad 0 \leq R^2 \leq 1$$

$$(β) \quad R^2 = (\text{μεταβλητή που οφείλεται στην παλινδρόμηση}) / (\text{ολική μεταβλητή}) \\ = \text{ποσοστό μεταβλητή που οφείλεται στην παλινδρόμηση}$$

$$(γ) \quad \begin{aligned} &\text{Μικρές τιμές του } R^2 \text{ παρέχουν ένδειξη "κακής" προσαρμογής.} \\ &\text{Μεγάλες τιμές του } R^2 \text{ δεν σημαίνουν κατ' ανάγκη "καλή" προσαρμογή.} \end{aligned}$$

Η τιμή του R^2 μπορεί να αυξηθεί εισάγοντας επιπλέον παραμέτρους στο μοντέλο.

ΠΧ. Έστω $R_1^2 = \frac{SS_{reg}^{(1)}}{SS_{tot}}$ που αντιστοιχεί στο μοντέλο $Y_i = \beta_0 + \beta_1 \cdot X_i + \varepsilon_i$ και

$R_2^2 = \frac{SS_{reg}^{(2)}}{SS_{tot}}$ που αντιστοιχεί στο μοντέλο $Y_i = \beta_0 + \beta_1 \cdot X_i + \beta_2 \cdot X_i^2 + \varepsilon_i$.

Έχω ότι $SS_{tot} = \sum_{i=1}^n (Y_i - \bar{Y})^2$ και

$$SS_{reg}^{(1)} = SS_{tot} - SS_{res}^{(1)} = SS_{tot} - \min_{\beta_0, \beta_1} \sum_{i=1}^n (Y_i - \beta_0 - \beta_1 \cdot X_i)^2$$

$$SS_{reg}^{(2)} = SS_{tot} - SS_{res}^{(2)} = SS_{tot} - \min_{\beta_0, \beta_1, \beta_2} \sum_{i=1}^n (Y_i - \beta_0 - \beta_1 \cdot X_i - \beta_2 \cdot X_i^2)^2$$

Αλλά, σταθεροποιώντας το $\beta_2 = 0$, έχουμε ότι

$$\min_{\beta_0, \beta_1} \sum_{i=1}^n (Y_i - \beta_0 - \beta_1 \cdot X_i)^2 \geq \min_{\beta_0, \beta_1, \beta_2} \sum_{i=1}^n (Y_i - \beta_0 - \beta_1 \cdot X_i - \beta_2 \cdot X_i^2)^2$$

$$\text{Άρα } SS_{reg}^{(2)} \geq SS_{reg}^{(1)} \Rightarrow R_2^2 \geq R_1^2.$$

Άλλος τρόπος για αύξηση της τιμής του R^2 είναι με μεγάλη διασπορά των X_i .

$$\Xi\acute{\epsilon}\rhoouμe ότι $R^2 = \frac{SS_{reg}}{SS_{tot}} = \frac{\sum_{i=1}^n (\hat{Y}_i - \bar{Y})^2}{\sum_{i=1}^n (Y_i - \bar{Y})^2} = \frac{\hat{\beta}_1^2 \cdot \sum_{i=1}^n (X_i - \bar{X})^2}{\sum_{i=1}^n (Y_i - \bar{Y})^2}.$$$

Άρα μεγάλες τιμές του R^2 είναι πιθανό να οφείλονται σε μεγάλες τιμές του $\sum_{i=1}^n (X_i - \bar{X})^2$.

Γενικά, για να εξετάσω γραμμική σχέση μεταξύ X και Y , μπορώ να θεωρήσω τον συντελεστή συσχέτισης $r = \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum_{i=1}^n (X_i - \bar{X})^2} \cdot \sqrt{\sum_{i=1}^n (Y_i - \bar{Y})^2}} = r(X, Y)$, που είναι εκτιμήτρια του $\rho = \frac{Cov(X, Y)}{\sigma_X \cdot \sigma_Y}$.

Για να δω αν υπάρχει γραμμική σχέση, θεωρώ τον έλεγχο $H_0 : \rho = 0$ προς $H_1 : \rho \neq 0$.

Όταν ισχύει η κανονικότητα, ο έλεγχος πηλίκου πιθανοφάνειας είναι: $t = \frac{r}{\sqrt{\frac{(1-r)^2}{n-2}}} \sim t_{n-2}$, όταν ισχύει η H_0 .

Απορρίπτουμε την H_0 , σε επίπεδο σημαντικότητας α , όταν $|t| > t_{n-2, \alpha/2}$.

Γνωρίζουμε όμως ότι για το μοντέλο της απλής γραμμικής παλινδρόμησης, ο ίδιος έλεγχος είναι $H_0 : \beta_1 = 0$ προς $H_1 : \beta_1 \neq 0$ και απορρίπτουμε αν $|t^*| > t_{n-2, \alpha/2}$,

όπου $t^* = \frac{\hat{\beta}_1}{\sqrt{\hat{Var}(\hat{\beta}_1)}}$.

Θα δείξουμε ότι οι δύο ελέγχοι είναι ισοδύναμοι, δηλαδή ότι $t = t^*$.

$$\text{Παρατηρούμε ότι } R^2 = \frac{SS_{reg}}{SS_{tot}} = \frac{\hat{\beta}_1^2 \cdot \sum_{i=1}^n (X_i - \bar{X})^2}{\sum_{i=1}^n (Y_i - \bar{Y})^2}, \text{ αλλά } \hat{\beta}_1 = \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{\sum_{i=1}^n (X_i - \bar{X})^2}$$

$$\Rightarrow R^2 = \frac{\left[\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y}) \right]^2}{\sum_{i=1}^n (X_i - \bar{X})^2 \cdot \sum_{i=1}^n (Y_i - \bar{Y})^2} = r^2.$$

$$\text{Έχω επίσης ότι } \hat{Var}(\hat{\beta}_1) = \frac{SS_{res}}{(n-2) \cdot \sum_{i=1}^n (X_i - \bar{X})^2}.$$

$$\text{Αρα } t = \frac{\frac{\sum_{i=1}^n (\bar{X}_i - \bar{Y}) \cdot (\bar{Y}_i - \bar{Y})}{\sqrt{\sum_{i=1}^n (\bar{X}_i - \bar{Y})^2} \cdot \sqrt{\sum_{i=1}^n (\bar{Y}_i - \bar{Y})^2}}}{\sqrt{\frac{1-r^2}{n-2}}} = \frac{\sqrt{\frac{1-r^2}{n-2}}}{\sqrt{\frac{1-R^2}{n-2}}}.$$

$$\text{Άλλά } 1-R^2 = 1 - \frac{SS_{reg}}{SS_{tot}} = \frac{SS_{tot} - SS_{reg}}{SS_{tot}} = \frac{SS_{res}}{SS_{tot}}.$$

Οπότε:

$$t = \frac{\frac{\sum_{i=1}^n (\bar{X}_i - \bar{Y}) \cdot (\bar{Y}_i - \bar{Y})}{\sqrt{\sum_{i=1}^n (\bar{X}_i - \bar{Y})^2} \cdot \sqrt{\sum_{i=1}^n (\bar{Y}_i - \bar{Y})^2}}}{\sqrt{\frac{SS_{res}}{(n-2) \cdot SS_{tot}}}} = \frac{\frac{\sum_{i=1}^n (\bar{X}_i - \bar{Y}) \cdot (\bar{Y}_i - \bar{Y})}{\sqrt{\sum_{i=1}^n (\bar{X}_i - \bar{Y})^2}}}{\sqrt{\frac{SS_{res}}{(n-2)}}} =$$

$$= \frac{\frac{\sum_{i=1}^n (\bar{X}_i - \bar{Y}) \cdot (\bar{Y}_i - \bar{Y})}{\sqrt{\sum_{i=1}^n (\bar{X}_i - \bar{Y})^2}} \cdot \frac{1}{\sqrt{\frac{\sum_{i=1}^n (\bar{X}_i - \bar{Y})^2}{n}}}}{\frac{\sum_{i=1}^n (\bar{X}_i - \bar{Y})^2}{\sqrt{(n-2) \cdot \sum_{i=1}^n (\bar{X}_i - \bar{Y})^2}}} = \frac{\frac{\sum_{i=1}^n (\bar{X}_i - \bar{Y}) \cdot (\bar{Y}_i - \bar{Y})}{\sqrt{\sum_{i=1}^n (\bar{X}_i - \bar{Y})^2}}}{\sqrt{\frac{SS_{res}}{(n-2) \cdot \sum_{i=1}^n (\bar{X}_i - \bar{Y})^2}}} = \frac{\hat{\beta}_1}{\sqrt{\hat{Var}(\hat{\beta}_1)}} = t^*$$

Θα αποδείξουμε ότι για το απλό γραμμικό μοντέλο, $\bar{Y}_i = \beta_0 + \beta_1 \cdot \bar{X}_i + \varepsilon_i$, ισχύει ότι $R^2 = r^2(\bar{Y}, \hat{Y})$, όπου

$$r(\bar{Y}, \hat{Y}) = \frac{\sum_{i=1}^n (\bar{Y}_i - \bar{Y}) \cdot (\hat{Y}_i - \bar{Y})}{\sqrt{\sum_{i=1}^n (\bar{Y}_i - \bar{Y})^2} \cdot \sqrt{\sum_{i=1}^n (\hat{Y}_i - \bar{Y})^2}} = \frac{\sum_{i=1}^n (\bar{Y}_i - \bar{Y}) \cdot (\hat{Y}_i - \bar{Y})}{\sqrt{\sum_{i=1}^n (\bar{Y}_i - \bar{Y})^2} \cdot \sqrt{\sum_{i=1}^n (\hat{Y}_i - \bar{Y})^2}}.$$

$$\begin{aligned} \text{Έχουμε ότι} \quad & \sum_{i=1}^n (\bar{Y}_i - \bar{Y}) \cdot (\hat{Y}_i - \bar{Y}) = \sum_{i=1}^n [(\bar{Y}_i - \hat{Y}_i) + (\hat{Y}_i - \bar{Y})] \cdot (\hat{Y}_i - \bar{Y}) = \\ & = \sum_{i=1}^n (\bar{Y}_i - \hat{Y}_i) \cdot (\hat{Y}_i - \bar{Y}) + \sum_{i=1}^n (\hat{Y}_i - \bar{Y})^2 = \sum_{i=1}^n e_i \cdot (\hat{Y}_i - \bar{Y}) + \sum_{i=1}^n (\hat{Y}_i - \bar{Y})^2 = \\ & = \sum_{i=1}^n e_i \cdot \hat{Y}_i - \bar{Y} \cdot \sum_{i=1}^n e_i + \sum_{i=1}^n (\hat{Y}_i - \bar{Y})^2 = \sum_{i=1}^n (\hat{Y}_i - \bar{Y})^2 \end{aligned}$$

$$\text{Αρα } r^2(Y, \hat{Y}) = \left[\frac{\sum_{i=1}^n (\hat{Y}_i - \bar{Y})^2}{\sqrt{\sum_{i=1}^n (Y_i - \bar{Y})^2} \cdot \sqrt{\sum_{i=1}^n (\hat{Y}_i - \bar{Y})^2}} \right]^2 = \frac{\sum_{i=1}^n (\hat{Y}_i - \bar{Y})^2}{\sum_{i=1}^n (Y_i - \bar{Y})^2} = R^2.$$

Ο έλεγχος της υπόθεσης $H_0 : \rho = 0$ προς $H_1 : \rho \neq 0$, μπορεί να γίνει και με το πηλίκο πιθανοφάνειας $\lambda(\underline{X}, \underline{Y}) = \frac{\sup_{H_0} L(\underline{\theta}/\underline{X}, \underline{Y})}{\sup_{\Theta} L(\underline{\theta}/\underline{X}, \underline{Y})}$, όπου $\underline{\theta} = (\mu_X, \mu_Y, \sigma_X, \sigma_Y, \rho)^T$.

Απορρίπτουμε την H_0 , αν $\lambda(\underline{X}, \underline{Y}) < c \Leftrightarrow \log[\lambda(\underline{X}, \underline{Y})] < c^*$.

$$(X_i, Y_i) \sim N_2 \left(\begin{pmatrix} \mu_X \\ \mu_Y \end{pmatrix}, \begin{pmatrix} \sigma_X^2 & \rho \cdot \sigma_X \cdot \sigma_Y \\ \rho \cdot \sigma_X \cdot \sigma_Y & \sigma_Y^2 \end{pmatrix} \right)$$

$$\text{Αρα, } f(\underline{\theta}/(X_i, Y_i)) = \frac{1}{2 \cdot \pi \cdot \sigma_X \cdot \sigma_Y \cdot \sqrt{1 - \rho^2}} \cdot e^{-\frac{1}{2(1-\rho^2)} \left[\frac{(X_i - \mu_X)^2}{\sigma_X^2} + \frac{(Y_i - \mu_Y)^2}{\sigma_Y^2} - 2 \cdot \rho \cdot \frac{(X_i - \mu_X)(Y_i - \mu_Y)}{\sigma_X \cdot \sigma_Y} \right]}$$

$$\begin{aligned} \text{Οπότε, } L(\underline{\theta}/\underline{X}, \underline{Y}) &= \prod_{i=1}^n f(\underline{\theta}/(X_i, Y_i)) = \\ &= \frac{1}{(2 \cdot \pi \cdot \sigma_X \cdot \sigma_Y \cdot \sqrt{1 - \rho^2})^n} \cdot e^{-\frac{1}{2(1-\rho^2)} \left[\frac{\sum_{i=1}^n (X_i - \mu_X)^2}{\sigma_X^2} + \frac{\sum_{i=1}^n (Y_i - \mu_Y)^2}{\sigma_Y^2} - 2 \cdot \rho \cdot \frac{\sum_{i=1}^n (X_i - \mu_X)(Y_i - \mu_Y)}{\sigma_X \cdot \sigma_Y} \right]} \end{aligned}$$

$$\begin{aligned} l(\underline{\theta}/\underline{X}, \underline{Y}) &= \log[L(\underline{\theta}/\underline{X}, \underline{Y})] = -n \cdot \log(2 \cdot \pi \cdot \sigma_X \cdot \sigma_Y \cdot \sqrt{1 - \rho^2}) - \\ &\quad \frac{1}{2 \cdot (1 - \rho^2)} \cdot \left[\frac{\sum_{i=1}^n (X_i - \mu_X)^2}{\sigma_X^2} + \frac{\sum_{i=1}^n (Y_i - \mu_Y)^2}{\sigma_Y^2} - 2 \cdot \rho \cdot \frac{\sum_{i=1}^n (X_i - \mu_X) \cdot (Y_i - \mu_Y)}{\sigma_X \cdot \sigma_Y} \right] \end{aligned}$$

Άρα, γενικά, παραγωγίζοντας την πιο πάνω παράσταση και θέτοντας την παράγωγο ίση με 0, έχουμε τις πιο κάτω εκτιμήσεις μεγίστης πιθανοθάνειας:

$$\hat{\mu}_X = \bar{X}, \hat{\mu}_Y = \bar{Y}, \hat{\sigma}_X^2 = \frac{1}{n} \cdot \sum_{i=1}^n (X_i - \bar{X})^2, \hat{\sigma}_Y^2 = \frac{1}{n} \cdot \sum_{i=1}^n (Y_i - \bar{Y})^2, \hat{\rho} = r = \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{n \cdot \sigma_X \cdot \sigma_Y}$$

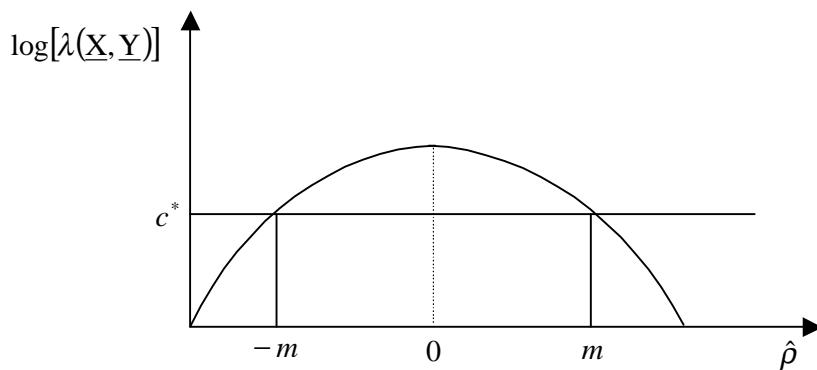
Όταν όμως ισχύει η $H_0 : \rho = 0$, έχουμε τις εκτιμήσεις:

$$\hat{\mu}_X = \hat{\mu}_x = \bar{X}, \hat{\mu}_Y = \hat{\mu}_Y = \bar{Y}, \hat{\sigma}_X^2 = \hat{\sigma}_Y^2 = \frac{1}{n} \cdot \sum_{i=1}^n (X_i - \bar{X})^2, \hat{\sigma}_Y^2 = \hat{\sigma}_Y^2 = \frac{1}{n} \cdot \sum_{i=1}^n (Y_i - \bar{Y})^2$$

Έχουμε ότι $\log[\lambda(\underline{X}, \underline{Y})] = \log \left[L\left(\hat{\theta}/\underline{X}, \underline{Y}\right) \right] - \log \left[L(\hat{\theta}/\underline{X}, \underline{Y}) \right] = \frac{n}{2} \cdot \log(1 - \hat{\rho}^2)$.

Άρα $\frac{d \log[\lambda(\underline{X}, \underline{Y})]}{d \hat{\rho}} = -n \cdot \frac{\hat{\rho}}{1 - \hat{\rho}^2}, |\hat{\rho}| < 1$.

Έτσι έχουμε το παρακάτω γράφημα:



Άρα απορρίπτουμε την H_0 , όταν $|\hat{\rho}| > m$.

Μέση Τιμή και Πίνακας Συνδιακύμανσης Τυχαίου Διανύσματος

Ορισμός:

Έστω X_1, X_2, \dots, X_n τυχαίες μεταβλητές.

Τότε το $(n \times 1)$ διάνυσμα $\underline{X} = \begin{pmatrix} X_1 \\ X_2 \\ \vdots \\ X_n \end{pmatrix}$ λέγεται n - διάστατο τυχαίο διάνυσμα.

Πιο γενικά μπορούμε να ορίσουμε τυχαίο πίνακα $\underline{X} = (X_{ij})$, όπου το (i, j) στοιχείο του είναι τυχαία μεταβλητή.

Ορισμός:

Η μέση τιμή του \underline{X} ορίζεται από το διάνυσμα $\underline{\mu} = E(\underline{X}) = \begin{pmatrix} E(X_1) \\ E(X_2) \\ \vdots \\ E(X_n) \end{pmatrix} = \begin{pmatrix} \mu_1 \\ \mu_2 \\ \vdots \\ \mu_n \end{pmatrix}$.

Ορισμός:

Ο πίνακας συνδιακύμανσης ενός $(n \times 1)$ τυχαίου διανύσματος \underline{X} ορίζεται ως $\Sigma = Cov(\underline{X}) = E[(\underline{X} - \underline{\mu}) \cdot (\underline{X} - \underline{\mu})^T]$.

Παρατηρήσεις:

(1) Αν $n = 2$, τότε:

$$\begin{aligned} (\underline{X} - \underline{\mu}) \cdot (\underline{X} - \underline{\mu})^T &= \begin{pmatrix} X_1 - \mu_1 \\ X_2 - \mu_2 \end{pmatrix} \cdot (X_1 - \mu_1, X_2 - \mu_2) = \\ &= \begin{bmatrix} (X_1 - \mu_1)^2 & (X_1 - \mu_1) \cdot (X_2 - \mu_2) \\ (X_1 - \mu_1) \cdot (X_2 - \mu_2) & (X_2 - \mu_2)^2 \end{bmatrix} \end{aligned}$$

$$\text{Άρα } Cov(\underline{X}) = \begin{bmatrix} Var(X_1) & Cov(X_1, X_2) \\ Cov(X_2, X_1) & Var(X_2) \end{bmatrix}.$$

Γενικότερα, αν το \underline{X} είναι n -διάστατο, τότε:

$$Cov(\underline{X}) = \begin{bmatrix} Var(X_1) & Cov(X_1, X_2) & Cov(X_1, X_3) & \dots & Cov(X_1, X_n) \\ Cov(X_2, X_1) & Var(X_2) & Cov(X_2, X_3) & \dots & Cov(X_2, X_n) \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ Cov(X_n, X_1) & Cov(X_n, X_2) & Cov(X_n, X_3) & \dots & Var(X_n) \end{bmatrix}$$

Άρα ο πίνακας συνδιακύμανσης είναι τετραγωνικός, συμμετρικός, με διαγώνια στοιχεία τις διακυμάνσεις των X_i .

(2) Αν οι τυχαίες μεταβλητές X_i είναι ασυσχέτιστες, τότε ο $\Sigma = Cov(\underline{X})$ είναι διαγώνιος.

Θεώρημα:

Αν $\underline{X}, \underline{Y}$ είναι $(n \times 1)$ τυχαία διανύσματα, $\mathbf{A}_{(m \times n)}$ πίνακας, $\underline{b}_{(m \times 1)}$ διάνυσμα, $\underline{\alpha}_{(n \times 1)}$ διάνυσμα και c πραγματική σταθερά, τότε ισχύουν:

- (α) $E(\underline{X} \pm \underline{Y}) = E(\underline{X}) \pm E(\underline{Y})$
- (β) $E(\mathbf{A} \cdot \underline{X} \pm \underline{b}) = \mathbf{A} \cdot E(\underline{X}) \pm \underline{b}$
- (γ) $E(\underline{\alpha}^T \cdot \underline{X}) = \underline{\alpha}^T \cdot E(\underline{X})$
- (δ) $E(c \cdot \underline{X}) = c \cdot E(\underline{X})$
- (ε) $Cov(c \cdot \underline{X} \pm \underline{\alpha}) = c^2 \cdot Cov(\underline{X})$
- (στ) Αν $\underline{X}, \underline{Y}$ ασυσχέτιστα, τότε: $Cov(\underline{X} \pm \underline{Y}) = Cov(\underline{X}) \pm Cov(\underline{Y})$
- (ζ) $Cov(\mathbf{A} \cdot \underline{X}) = \mathbf{A} \cdot Cov(\underline{X}) \cdot \mathbf{A}^T$
- (η) $Var(\underline{\alpha}^T \cdot \underline{X}) = \underline{\alpha}^T \cdot Cov(\underline{X}) \cdot \underline{\alpha}$

Απόδειξη:

Παραλείπεται.

Θεώρημα:

Έστω $\underline{X}_{(n \times 1)}$ τυχαίο διάνυσμα με $E(\underline{X}) = \underline{\mu}$ και $Cov(\underline{X}) = \Sigma$. Τότε:

- (α) $\Sigma \geq 0$ (θετικά ημιορισμένος)
- (β) $E(\|\underline{X}\|^2) = \|\underline{\mu}\|^2 + tr(\Sigma)$, όπου $tr(\Sigma)$ είναι το ίχνος του πίνακα (το άθροισμα των διαγώνιων στοιχείων του) και $\|\underline{X}\|^2 = (\underline{X}^T \cdot \underline{X}) = \sum_{i=1}^n X_i^2$.

Απόδειξη:

(α) Έχουμε ότι για κάθε $\underline{\alpha} \in R^n$, σχύει ότι $0 \leq Var(\underline{\alpha}^T \cdot \underline{X}) = \underline{\alpha}^T \cdot \Sigma \cdot \underline{\alpha} \Rightarrow \underline{\alpha}^T \cdot \Sigma \cdot \underline{\alpha} \geq 0 \Rightarrow \Sigma \geq 0$.

$$\begin{aligned} (\beta) \quad E(\|\underline{X}\|^2) &= E\left(\sum_{i=1}^n X_i^2\right) = \sum_{i=1}^n E(X_i^2) = \sum_{i=1}^n [E^2(X_i) + Var(X_i)] = \\ &= \sum_{i=1}^n E^2(X_i) + \sum_{i=1}^n Var(X_i) = \sum_{i=1}^n \mu_i^2 + \sum_{i=1}^n Var(X_i) = \|\underline{\mu}\|^2 + tr(\Sigma) \end{aligned}$$

Πλυδιάστατη Κανονική Κατανομή

Ορισμός:

Λέμε ότι το τυχαίο διάνυσμα \underline{X} ακολουθεί την πολυδιάστατη κανονική κατανομή, με μέση τιμή $\underline{\mu}$ και πίνακα διακυμάνσεων $\Sigma \geq 0$, αν

$$f_{\underline{X}}(\underline{x}) = \frac{1}{|\Sigma|^{1/2} \cdot (2 \cdot \pi)^{n/2}} \cdot e^{-\frac{1}{2}(\underline{x}-\underline{\mu})^T \Sigma^{-1}(\underline{x}-\underline{\mu})}. \quad \text{Συμβολικά, } \underline{X} \sim N_n(\underline{\mu}, \Sigma).$$

Ιδιότητες γραμμικών μετασχηματισμών:

(α) Άν $\underline{X} \sim N_n(\underline{\mu}, \Sigma)$, $A_{(p \times n)}$ πίνακας και $b \in R^n$, τότε:

$$A \cdot \underline{X} \pm b \sim N_n(A \cdot \underline{\mu} \pm b, A \cdot \Sigma \cdot A^T).$$

(β) Άν $\underline{X} \sim N_n(\underline{\mu}, \Sigma)$ και $c \in R$, τότε: $c \cdot \underline{X} \sim N_n(c \cdot \underline{\mu}, c^2 \cdot \Sigma)$.

Υποδιανύσματα, Ανεξαρτησία, Δεσμευμένες Κατανομές:

Έστω $\underline{X} \sim N_n(\underline{\mu}, \Sigma)$, $\underline{X} = \begin{pmatrix} \underline{X}_1 \\ \underline{X}_2 \end{pmatrix}$, $\underline{\mu} = \begin{pmatrix} \underline{\mu}_1 \\ \underline{\mu}_2 \end{pmatrix}$, $\Sigma = \begin{bmatrix} \Sigma_{11} & \Sigma_{12} \\ \Sigma_{21} & \Sigma_{22} \end{bmatrix}$, όπου $\underline{X}_1, \underline{\mu}_1$ είναι

p -διάστατα διανύσματα και Σ_{11} είναι $(p \times p)$ πίνακας. Τότε ισχύουν τα παρακάτω:

(1) $\underline{X}_1 \sim N_p(\underline{\mu}_1, \Sigma_{11})$, $\underline{X}_2 \sim N_{n-p}(\underline{\mu}_2, \Sigma_{22})$

(2) \underline{X}_1 και \underline{X}_2 είναι ανεξάρτητα $\Leftrightarrow \Sigma_{12} = 0$

(3) Άν $\Sigma_{22} > 0$, τότε: $\underline{X}_1 / \underline{X}_2 = \underline{x}_2 \sim N_p(\underline{y}_1, V_{11})$, όπου

$$\underline{y}_1 = \underline{\mu}_1 + \Sigma_{12} \cdot \Sigma_{22}^{-1} \cdot (\underline{x}_2 - \underline{\mu}_2) \quad \text{και} \quad V_{11} = \Sigma_{11} - \Sigma_{12} \cdot \Sigma_{22}^{-1} \cdot \Sigma_{21}.$$

Απόδειξη για το (3):

Αναζητούμε την κατανομή του $\begin{pmatrix} \underline{Y} \\ \underline{X}_2 \end{pmatrix}$, όπου $\underline{Y} = \underline{X}_1 - \Sigma_{12} \cdot \Sigma_{22}^{-1} \cdot \underline{X}_2$.

$$\text{Άλλα, } \begin{pmatrix} \underline{Y} \\ \underline{X}_2 \end{pmatrix} = \begin{bmatrix} \mathbf{I} & -\Sigma_{12} \cdot \Sigma_{22}^{-1} \\ 0 & \mathbf{I} \end{bmatrix} \cdot \begin{pmatrix} \underline{X}_1 \\ \underline{X}_2 \end{pmatrix}.$$

Επειδή είναι γραμμικός μετασχηματισμός του \underline{X} , από την ιδιότητα (α) των γραμμικών μετασχηματισμών, έχουμε ότι:

$$\begin{pmatrix} \underline{Y} \\ \underline{X}_2 \end{pmatrix} \sim N_n \left(\begin{pmatrix} \underline{\mu}_1 - \Sigma_{12} \cdot \Sigma_{22}^{-1} \cdot \underline{\mu}_2 \\ \underline{\mu}_2 \end{pmatrix}, \begin{bmatrix} \Sigma_{11} - \Sigma_{12} \cdot \Sigma_{22}^{-1} \cdot \Sigma_{21} & 0 \\ 0 & \Sigma_{22} \end{bmatrix} \right)$$

Άρα τα \underline{Y} και \underline{X}_2 είναι ανεξάρτητα και $\underline{Y} \sim N_p(\underline{\mu}_1 - \Sigma_{12} \cdot \Sigma_{22}^{-1} \cdot \underline{\mu}_2, \Sigma_{11} - \Sigma_{12} \cdot \Sigma_{22}^{-1} \cdot \Sigma_{21})$.

Άλλα, $\underline{Y} = \underline{X}_1 - \Sigma_{12} \cdot \Sigma_{22}^{-1} \cdot \underline{X}_2$.

Συνεπώς,

$$(\underline{X}_1 / \underline{X}_2 = x_2) = \underline{Y} + \Sigma_{12} \cdot \Sigma_{22}^{-1} \cdot x_2 \sim N_p(\underline{\mu}_1 - \Sigma_{11} \cdot \Sigma_{22}^{-1} \cdot (x_2 - \underline{\mu}_2), \Sigma_{11} - \Sigma_{12} \cdot \Sigma_{22}^{-1} \cdot \Sigma_{21})$$

Παράδειγμα:

$$\text{Έστω } n = 2, \underline{X} = \begin{pmatrix} \underline{X}_1 \\ \underline{X}_2 \end{pmatrix}, \underline{\mu} = \begin{pmatrix} \underline{\mu}_1 \\ \underline{\mu}_2 \end{pmatrix}, \Sigma = \begin{bmatrix} \sigma_1^2 & \rho \cdot \sigma_1 \cdot \sigma_2 \\ \rho \cdot \sigma_1 \cdot \sigma_2 & \sigma_2^2 \end{bmatrix}.$$

Επειδή $|\Sigma| = \sigma_1^2 \cdot \sigma_2^2 \cdot (1 - \rho^2)$, για να είναι θετικά ορισμένος ο Σ , έχουμε τις ακόλουθες συνθήκες: $\sigma_1^2 > 0, \sigma_2^2 > 0, |\rho| < 1$.

$$\text{Οπότε, } \Sigma^{-1} = \frac{1}{1 - \rho^2} \cdot \begin{bmatrix} \frac{1}{\sigma_1^2} & -\frac{\rho}{\sigma_1 \cdot \sigma_2} \\ -\frac{\rho}{\sigma_1 \cdot \sigma_2} & \frac{1}{\sigma_2^2} \end{bmatrix}.$$

Άρα η διδιάστατη κανονική, έχει συνάρτηση πυκνότητας πιθανότητας:

$$f(x_1, x_2) = \frac{1}{2 \cdot \pi \cdot \sigma_1 \cdot \sigma_2 \cdot \sqrt{1 - \rho^2}} \cdot e^{-\frac{1}{2(1-\rho^2)} \left[\frac{(x_1 - \mu_1)^2}{\sigma_1^2} + \frac{(x_2 - \mu_2)^2}{\sigma_2^2} - 2 \cdot \rho \frac{(x_1 - \mu_1)(x_2 - \mu_2)}{\sigma_1 \cdot \sigma_2} \right]}$$

$$\text{Επιπλέον, } \underline{X}_1 / \underline{X}_2 = x_2 \sim N\left(\mu_1 + \rho \cdot \frac{\sigma_1}{\sigma_2} \cdot (x_2 - \mu_2), \sigma_1^2 \cdot (1 - \rho^2)\right).$$

Τετραγωνικές Μορφές:

$$\text{Αν } Z_1, Z_2, \dots, Z_n \sim N(0,1), \text{ ανεξάρτητες} \Rightarrow \sum_{i=1}^n Z_i \sim X_n^2.$$

$$\text{Άλλά, } \underline{Z} = \begin{pmatrix} Z_1 \\ \vdots \\ Z_n \end{pmatrix} \sim N_n(\underline{0}, \mathbf{I}) \text{ και } \sum_{i=1}^n Z_i = \underline{Z}^T \cdot \underline{Z} = \|\underline{Z}\|^2. \Sigma \text{υνεπώς, } \underline{Z}^T \cdot \underline{Z} \sim X_n^2.$$

Θεώρημα:

Αν $\underline{X} \sim N(\underline{\mu}, \Sigma)$, $\Sigma > 0$, τότε $(\underline{X} - \underline{\mu})^T \cdot \Sigma^{-1} \cdot (\underline{X} - \underline{\mu}) \sim X_n^2$.

Απόδειξη:

Αφού $\Sigma > 0$, υπάρχει Σ^{-1} και $\Sigma^{-1/2} : \Sigma^{-1} = \Sigma^{-1/2} \cdot \Sigma^{-1/2}$.

Θεωρώ $\underline{Z} = \Sigma^{-1/2} \cdot (\underline{X} - \underline{\mu})$.

Τότε $\underline{Z} \sim N_n(\underline{0}, \mathbf{I}) \Rightarrow \underline{Z}^T \cdot \underline{Z} \sim X_n^2$.

Συνεπώς, $\underline{Z}^T \cdot \underline{Z} = (\underline{X} - \underline{\mu})^T \cdot \Sigma^{-1/2} \cdot \Sigma^{-1/2} \cdot (\underline{X} - \underline{\mu}) = (\underline{X} - \underline{\mu})^T \cdot \Sigma^{-1} \cdot (\underline{X} - \underline{\mu})$