

## Συντελεστής (γραμμικής) συσχέτισης και Συνδιακύβανση

### ① Παράδειγμα

Πείραμα Τύχης: Επιλογή ατόμου από πληθυσμό

$X$  = Βάρος σε  $\text{kg}$

$Y$  = ύψος σε  $\text{m}$

$\text{Cov}[X, Y]$

Ένας άλλος μελετητής:

$X'$  = Βάρος σε  $\text{lb}$

$Y'$  = ύψος σε  $\text{ft}$

$\text{Cov}[X', Y']$

Γενικά  $\text{Cov}[X, Y] \neq \text{Cov}[X', Y']$

διότι  $X' = aX$

$a$ : σταθερά μετατροπής  $\text{kg} \rightarrow \text{lb}$

$Y' = cY$

$c$ : σταθερά μετατροπής  $\text{m} \rightarrow \text{ft}$

$$\text{Cov}[X', Y'] = \text{Cov}[aX, cY] = ac \text{Cov}[X, Y]$$

Ελάττωμα! της  $\text{Cov}$ : Εξάρτηση από τις μονάδες μετατροπής

### ② Ορισμός

Συντελεστής (γραμμικής) συσχέτισης των  $\text{c.f.}$   $X, Y$

ορίζεται:

$$\rho(x, y) = \frac{\overbrace{\text{Cov}[X, Y]}^{\sigma_{x,y}}}{\underbrace{\sqrt{\text{Var}[X]}}_{\sigma_x} \underbrace{\sqrt{\text{Var}[Y]}}_{\sigma_y}}$$

### ③ Ιδιότητες

$$\underline{1)} \rho(aX, bY) = \begin{cases} \rho(X, Y), & \text{αν } ab > 0 \\ -\rho(X, Y), & \text{αν } ab < 0 \end{cases}$$

$$\underline{2)} \rho(X, Y) \in [-1, 1] \quad \left( \begin{array}{l} -1 > \text{ακραίες} \\ 1 > \text{συνχετίσεις} \end{array} \right)$$

$$\underline{3)} X, Y \text{ αουοχετίσες} \Rightarrow \rho(X, Y) = 0$$

$$\underline{4)} \rho(X, Y) = 1 \Leftrightarrow Y = aX + b, \quad a > 0$$

$$\underline{5)} \rho(X, Y) = -1 \Leftrightarrow Y = aX + b, \quad a < 0$$

### 6). Προσοχή!

$$\text{Ενώ } \text{Cov}[X+Y, Z] = \text{Cov}[X, Z] + \text{Cov}[Y, Z]$$

$$\rho(X+Y, Z) \neq \rho(X, Z) + \rho(Y, Z)$$

Αποδείξεις:

$$\underline{1)} \rho(aX, bY) = \frac{\text{Cov}[aX, bY]}{\sqrt{\text{Var}[aX]} \sqrt{\text{Var}[bY]}} = \frac{ab \text{Cov}[X, Y]}{|ab| \sqrt{\text{Var}[X]} \sqrt{\text{Var}[Y]}}$$

"  $\rho(X, Y)$

$$= \begin{cases} \rho(X, Y), & \text{αν } ab > 0 \\ -\rho(X, Y), & \text{αν } ab < 0 \end{cases}$$

2)

$$\text{Var} \left( \frac{X}{\sigma_x} + \frac{Y}{\sigma_y} \right) \geq 0 \Rightarrow \text{Var} \left( \frac{X}{\sigma_x} \right) + \text{Var} \left( \frac{Y}{\sigma_y} \right) + 2 \text{Cov} \left[ \frac{X}{\sigma_x}, \frac{Y}{\sigma_y} \right] \geq 0$$

$$\Rightarrow \frac{1}{\sigma_x^2} \text{Var}[X] + \frac{1}{\sigma_y^2} \text{Var}[Y] + 2 \frac{\text{Cov}[X, Y]}{\sigma_x \sigma_y} \geq 0 \Rightarrow$$

$$\Rightarrow 2 + 2\rho(X, Y) \geq 0 \Rightarrow \rho(X, Y) \geq -1$$

3) και

$$\text{Var}\left(\frac{X}{\sigma_x} - \frac{Y}{\sigma_y}\right) \geq 0 \Rightarrow \text{Var}\left(\frac{X}{\sigma_x}\right) + \text{Var}\left(\frac{Y}{\sigma_y}\right) - 2\text{Corr}\left[\frac{X}{\sigma_x}, \frac{Y}{\sigma_y}\right] \geq 0$$

$$\Rightarrow \frac{1}{\sigma_x^2} \text{Var}[X] + \frac{1}{\sigma_y^2} \text{Var}[Y] - 2 \frac{\text{Corr}[X, Y]}{\sigma_x \sigma_y} \geq 0 \Rightarrow$$

$$\Rightarrow 2 - 2\rho(x, y) \geq 0 \Rightarrow \rho(x, y) \leq 1$$

$$\left( E[(X - E[X])(Y - E[Y])] \right)^2 \leq E[(X - E[X])^2] E[(Y - E[Y])^2] \quad \text{C-S}$$

$$3) X, Y \text{ ασυσχετίσται} \Leftrightarrow \text{Corr}[X, Y] = 0 \Leftrightarrow \rho(x, y) = 0$$

$\Rightarrow$

$$5) \rho(x, y) = -1 \Rightarrow \text{Var}\left[\frac{X}{\sigma_x} + \frac{Y}{\sigma_y}\right] = 0 \Rightarrow \frac{X}{\sigma_x} + \frac{Y}{\sigma_y} = C, \text{ const}$$

$$\Rightarrow Y = -\frac{\sigma_y}{\sigma_x} X + C \sigma_y \Rightarrow Y = aX + b, a < 0$$

$\Leftarrow$

$$Y = aX + b, a < 0 \Rightarrow \rho(x, y) = \frac{\text{Cov}[X, Y]}{\sqrt{\text{Var}[X]} \sqrt{\text{Var}[Y]}}$$

$$= \frac{\text{Cov}[X, aX + b]}{\sqrt{\text{Var}[X]} \sqrt{\text{Var}[aX + b]}}$$

$$= \frac{a \text{Cov}[X, X]}{|a| \sqrt{\text{Var}[X]} \sqrt{\text{Var}[X]}} = -1$$

4) ΟΜΟΙΑ με το 5)

$$\rho(x, y) = 1 \Rightarrow \text{Var}\left[\frac{X}{\sigma_x} - \frac{Y}{\sigma_y}\right] = 0 \Rightarrow \dots \Rightarrow Y = aX + b, a > 0$$

Ξέρουμε:

$$E\left[\sum_{i=1}^n X_i\right] = \sum_{i=1}^n E[X_i]$$

$$\text{Var}\left[\sum_{i=1}^n X_i\right] = \sum_{i=1}^n \text{Var}[X_i] + 2 \sum_{1 \leq i < j \leq n} \text{Cov}[X_i, X_j]$$

$$\text{Cov}\left[\sum_{i=1}^n X_i, \sum_{j=1}^m Y_j\right] = \sum_{i=1}^n \sum_{j=1}^m \text{Cov}[X_i, Y_j]$$

④ Εφαρμογή: Εκτίμηση  $\mu = E[X]$ ,  $\sigma_x^2 = \text{Var}[X]$

$X_1, X_2, \dots, X_n$  η παρατηρήσεις, ανεξ. ισόνοτες

$$\mu = ? \quad \sigma_x^2 = ?$$

Για να εκτιμήσουμε το  $\mu$  χρησιμοποιούμε τον μέσο όρο των παρατηρήσεων.

**Δειγματικός μέσος** ← μέσος του δείγματος

$$\bar{X} = \bar{X}_n = \frac{X_1 + X_2 + \dots + X_n}{n} = \frac{\sum_{i=1}^n X_i}{n}$$

$$\mu = E[X_i] \leftarrow \text{μέσος του πληθυσμού}$$

Είναι σωστό να χρησιμοποιούμε το  $\bar{X}$  για να εκτιμήσουμε το  $\mu$ ;

Πρέπει  $E[\bar{X}] = \mu$ ,  $\text{Var}[X] \searrow$  ως προς  $n$  (φθίνουσα) και φθίσιμα  $\rightarrow 0$

Πράγματι,

$$E[\bar{X}] = E\left[\frac{\sum_{i=1}^n X_i}{n}\right] = \frac{1}{n} \sum_{i=1}^n E[X_i] = \mu \quad \checkmark$$

$$\text{Var}[X] = \text{Var}\left[\frac{\sum_{i=1}^n X_i}{n}\right] \stackrel{\text{Ανεξ.}}{\downarrow} = \frac{1}{n^2} \sum_{i=1}^n \text{Var}[X_i] = \frac{n \sigma_x^2}{n^2} = \frac{\sigma_x^2}{n} \downarrow 0$$

**Ερώτηση!** Πώς να εκτιμήσουμε το  $G_x = E[(x-\mu)^2]$  ;

Κατά τη βοήθεια του δείγματός μας μέσω μια εκτίμησης (τυχαία μεταβλητή) για το  $G_x^2$  μέσω του δείγματος είναι η

$$T = \frac{(X_1 - \bar{X})^2 + (X_2 - \bar{X})^2 + \dots + (X_n - \bar{X})^2}{n}$$

Είναι η  $T$  καλή εκτίμηση του  $G_x^2$  ;

Για να είναι η  $T$  καλή εκτίμηση του  $G_x^2$  πρέπει:

$$E[T] = G_x^2$$

$\text{Var}[T] \rightarrow 0$  για  $n \rightarrow \infty$

$$\begin{aligned} E[T] &= E\left[\frac{\sum_{i=1}^n (X_i - \bar{X})^2}{n}\right] = \frac{1}{n} E\left[\sum_{i=1}^n (X_i - \bar{X})^2\right] = \\ &= \frac{1}{n} \sum_{i=1}^n E[(X_i - \bar{X})^2] = \frac{1}{n} \sum_{i=1}^n E[(X_i - \mu + \mu - \bar{X})^2] = \\ &= \frac{1}{n} \sum_{i=1}^n \left( E[(X_i - \mu)^2] + E[2(X_i - \mu)(\mu - \bar{X})] + E[(\mu - \bar{X})^2] \right) \\ &= \frac{1}{n} \left( \sum_{i=1}^n (E[(X_i - \mu)^2]) + 2n \sum_{i=1}^n \frac{(X_i - \mu)(\mu - \bar{X})}{n} + n E[(\mu - \bar{X})^2] \right) \\ &= \frac{1}{n} \left( n G_x^2 + 2n E\left[\frac{\sum_{i=1}^n X_i - n\mu}{n} (\mu - \bar{X})\right] + n E[(\mu - \bar{X})^2] \right) \\ &= \frac{1}{n} \left( n G_x^2 - 2n \text{Var}[\bar{X}] + n \text{Var}[\bar{X}] \right) \\ &= \frac{1}{n} \left( n G_x^2 - n \frac{G_x^2}{n} \right) = \frac{(n-1) G_x^2}{n} \end{aligned}$$

Η  $T$  δεν είναι «καλή» διότι  $E[T] = \frac{(n-1) G_x^2}{n} \neq G_x^2$

Αν θέσω  $S = \frac{n}{n-1} \cdot T = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$  τότε

$$E[S] = \frac{n}{n-1} E[T] = G_x^2$$

Αποδεικνύεται ότι  $\text{Var}[S] \rightarrow$  καθώς  $n \rightarrow \infty$

Άρα για την εκτίμηση

$\mu = E[X_i]$  χρησιμοποιούμε  $\bar{X} = \frac{\sum_{i=1}^n X_i}{n}$  Δειγμ. μέσος

$S^2 = \text{Var}[X_i]$  — " —  $S = \frac{\sum_{i=1}^n (X_i - \bar{X})^2}{n-1}$  Απερ. δειγμ. διασπορά