

Cours 07
Variance, covariance, corrélation

1 Définitions et propriétés élémentaires

Définition : Soient $x = (x_1, x_2, \dots, x_n)$ et $y = (y_1, y_2, \dots, y_n)$ deux échantillons de même taille n et de moyenne respective $\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i$ et $\bar{y} = \frac{1}{n} \sum_{i=1}^n y_i$.

On appelle *covariance* (estimée¹) de x avec y et on note $\text{cov}(x, y)$ le nombre

$$\text{cov}(x, y) = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y}).$$

On appelle *variance* (estimée) de x et on note $\text{Var}(x)$ le nombre

$$\text{Var}(x) = \text{cov}(x, x) = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2,$$

et $\sqrt{\text{Var}(x)}$ s'appelle *l'écart-type* de l'échantillon x . On appelle *corrélation* de x avec y et on note $\text{cor}(x, y)$ le nombre

$$\rho = \text{cor}(x, y) = \frac{\text{cov}(x, y)}{\sqrt{\text{Var}(x)}\sqrt{\text{Var}(y)}}.$$

Proposition 1 Soient $x, x', x'', y, y',$ et y'' des échantillons de même taille n . Notons $\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i$ et $\bar{y} = \frac{1}{n} \sum_{i=1}^n y_i$ la moyenne de x et de y . Soient λ, λ' et λ'' des nombres. Les relations suivantes sont satisfaites :

1. $\text{cov}(\lambda'x' + \lambda''x'', y) = \lambda' \text{cov}(x', y) + \lambda'' \text{cov}(x'', y)$ (Bilinéarité : linéarité à gauche)
2. $\text{cov}(x, \lambda'y' + \lambda''y'') = \lambda' \text{cov}(x, y') + \lambda'' \text{cov}(x, y'')$ (Bilinéarité : linéarité à droite)
3. $\text{cov}(y, x) = \text{cov}(x, y)$ (Symétrie)
4. $\text{Var}(\lambda x) = \lambda^2 \text{Var}(x) \geq 0$ (Homogénéité de degré 2)
5. *Formules de Huygens :*

$$\text{cov}(x, y) = \frac{1}{n-1} \sum_{i=1}^n x_i y_i - \frac{n}{n-1} \bar{x} \bar{y}, \text{ et } \text{Var}(x) = \frac{1}{n-1} \sum_{i=1}^n x_i^2 - \frac{n}{n-1} \bar{x}^2.$$

6. *Inégalité de Cauchy-Schwarz :* $(\text{cov}(x, y))^2 \leq \text{Var}(x) \text{Var}(y)$, et donc $\rho^2 \leq 1$.

2 Relation avec la régression linéaire, interprétation géométrique

Lors du cours 06 nous avons déterminé l'équation $y = ax + b$ de la droite de régression linéaire de l'échantillon y sur l'échantillon de même taille x . Les valeurs de la pente a de cette droite et son ordonnée à l'origine b sont donnés par $a = \frac{\sum_{i=1}^n x_i y_i - n \bar{x} \bar{y}}{\sum_{i=1}^n x_i^2 - n \bar{x}^2}$ et $b = \bar{y} - a \bar{x}$, où \bar{x} et \bar{y} désignent la moyenne de x et y . En divisant par $n-1$ le numérateur et le dénominateur de l'expression donnée de a et en appliquant la formule de Huygens, on voit que $a = \frac{\text{COV}(x, y)}{\text{Var}(x)}$.

Vision géométrique : $\text{Var}(x)$ mesure l'inertie $\sum_{i=1}^n (x_i - \bar{x})^2$ des n points x_i par rapport au point \bar{x} , l'inertie $\sum_{i=1}^n (x_i - x')^2$ par rapport à tout autre point x' étant nécessairement supérieure. Cette inertie n'est nulle que si tous les x_i sont égaux, et ce qu'il est convenu d'appeler l'échantillon centré ${}^c x = x - \bar{x}$ caractérise la dispersion de x , alors que la moyenne \bar{x} est le nombre unique résumant le mieux l'échantillon. L'écart-type $\sqrt{\text{Var}(x)}$ mesure la dispersion ${}^c x$ de l'échantillon, de façon homogène par rapport au choix de l'unité utilisée pour former x , puisque pour tout $\lambda > 0$, $\sqrt{\text{Var}(\lambda x)} = \lambda \sqrt{\text{Var}(x)}$ (en passant du mètre au centimètre, l'écart-type est multiplié par le même nombre, 100, que les mesures relevées). On se débarrasse de la question du choix de l'unité en considérant l'échantillon centré-réduit ${}^{cr} x = {}^c x / \sqrt{\text{Var}(x)}$: c'est une direction dans \mathbf{R}^n indépendante des unités choisies, et $\rho = \text{cor}(x, y) = \text{cor}({}^{cr} x, {}^{cr} y)$ est le cosinus de l'angle que font les deux directions ${}^{cr} x$ et ${}^{cr} y$ dans le plan de \mathbf{R}^n qu'elles déterminent. Si $\rho = 1$ c'est que ces deux variabilités ont des directions parfaitement égales (et $\rho = -1$ c'est que ces deux variabilités ont des directions parfaitement opposées). Dans les deux cas la connaissance de x équivaut à la connaissance de y : les résidus $\epsilon_i = y_i - ax_i - b$ pour la régression de y sur x sont tous nuls!

1. Nous adoptons ici les définitions pratiquées par les commandes `var`, `sd`, et `cov` de R fondée sur l'estimateur sans biais de ces grandeurs pour un échantillon dont l'espérance (estimée par `mean`) n'est pas connue à priori. Ceci explique que le lecteur pourra aussi trouver parfois un n à la place du dénominateur $n-1$ des définitions adoptées ici.

3 Matrice de variance-covariance

On appelle matrice de variance-covariance de x et y la matrice symétrique $\begin{pmatrix} \text{Var}(x) & \text{cov}(x, y) \\ \text{cov}(y, x) & \text{Var}(y) \end{pmatrix}$. On appelle matrice de corrélation de x et y la matrice symétrique $\begin{pmatrix} 1 & \text{cor}(x, y) \\ \text{cor}(y, x) & 1 \end{pmatrix}$.

Si on a m échantillons x^1, \dots, x^m de même taille on définit leur matrice de variance-covariance Σ et leur matrice de corrélation R par

$$\Sigma = \begin{pmatrix} \text{Var}(x^1) & \cdots & \text{cov}(x^1, x^k) & \cdots & \text{cov}(x^1, x^m) \\ \vdots & \ddots & \vdots & & \vdots \\ \text{cov}(x^k, x^1) & \cdots & \text{Var}(x^k) & \cdots & \text{cov}(x^k, x^m) \\ \vdots & & \vdots & \ddots & \vdots \\ \text{cov}(x^m, x^1) & \cdots & \text{cov}(x^m, x^k) & \cdots & \text{Var}(x^m) \end{pmatrix}$$
$$\text{et } R = \begin{pmatrix} 1 & \cdots & \text{cor}(x^1, x^k) & \cdots & \text{cor}(x^1, x^m) \\ \vdots & \ddots & \vdots & & \vdots \\ \text{cor}(x^k, x^1) & \cdots & 1 & \cdots & \text{cor}(x^k, x^m) \\ \vdots & & \vdots & \ddots & \vdots \\ \text{cor}(x^m, x^1) & \cdots & \text{cor}(x^m, x^k) & \cdots & 1 \end{pmatrix}.$$