

réponses possibles.

Université de Nice
Département de Mathématiques
NOM :
PRENOM :
Machine n° (SSSMM) : 21601

LIMASS, année 2015-2016
Statistique

Date : 16.3.2016

Feuille-réponse 07 Covariance et corrélation

1 Calcul à la main

On pose $x = (0, 2, 4, 6)$ et $y = (2, 6, 4, 0)$. Calculer la matrice de variance-covariance Σ des échantillons x et y , ainsi que leur matrice de corrélation R . Ne manquez pas de vérifier le résultat de vos calculs à l'aide de R. Représentez en marge le "nuage" (x, y) et la droite de régression $y = ax + b$.

Moyennes :

$$\bar{x} = \frac{1}{4}(0 + 2 + 4 + 6) = \frac{1}{4}12 = 3$$

$$\bar{y} = \frac{1}{4}(2 + 6 + 4 + 0) = \frac{1}{4}12 = 3$$

Variances :

$$\text{var}(x) = \frac{1}{4-1} \left((0-3)^2 + (2-3)^2 + (4-3)^2 + (6-3)^2 \right) = \frac{1}{3}(9 + 1 + 1 + 9) = \frac{20}{3}$$

$$\text{var}(y) = \frac{1}{3} \left((2-3)^2 + (6-3)^2 + (4-3)^2 + (0-3)^2 \right) = \frac{20}{3}$$

Covariance :

$$\text{cov}(x, y) = \frac{1}{3} \left((0-3)(2-3) + (2-3)(6-3) + (4-3)(4-3) + (6-3)(0-3) \right) = \frac{1}{3} \left(+3 - 3 + 1 - 9 \right) = -\frac{8}{3}$$

$$\Sigma = \begin{pmatrix} \text{var}(x) & \text{cov}(x, y) \\ \text{cov}(y, x) & \text{var}(y) \end{pmatrix} = \begin{pmatrix} \frac{20}{3} & -\frac{8}{3} \\ -\frac{8}{3} & \frac{20}{3} \end{pmatrix}; \quad R = \begin{pmatrix} 1 & \text{cov}(x, y) \\ \text{cov}(x, y) & 1 \end{pmatrix} = \begin{pmatrix} 1 & -\frac{8}{3} \cdot \frac{3}{20} \\ -\frac{8}{3} \cdot \frac{3}{20} & 1 \end{pmatrix} = \begin{pmatrix} 1 & -\frac{2}{5} \\ -\frac{2}{5} & 1 \end{pmatrix}$$

Equation de la droite de régression :

$$a = \frac{\text{cov}(x, y)}{\text{var}(x)} = -\frac{8}{3} \cdot \frac{3}{20} = -\frac{2}{5} = -0,4$$

$$b = \bar{y} - a\bar{x} = 3 + \frac{2}{5} \cdot 3 = \frac{1}{5}(15 + 6) = \frac{21}{5} = \frac{42}{10} = 4,2$$

l'équation de la droite de régression est donc

$$y = -0,4x + 4,2$$

2 Reprise du cours 07

Former trois échantillons gaussiens simulés x , y , et z de taille 200, d'espérance respective 0, 2, et 2 et d'écart-type 1, 1, et 5. Afin de pouvoir reproduire exactement vos échantillons faites précéder vos trois appels de la fonction `rnorm` par l'instruction `set.seed(SSSMM)`, où SSSMM désigne le numéro de votre machine que vous aurez reproduit au début de votre copie, sous votre nom.

- Former un `data.frame` appelé `MesDonnées` regroupant x , y , et z ; quelles sont les trois premières lignes de `MesDonnées`

$$\begin{array}{l} x = \text{rnorm}(200, 0, 1) \\ y = \text{rnorm}(200, 2, 1) \\ z = \text{rnorm}(200, 2, 5) \end{array} \quad \left| \quad \begin{array}{l} \text{MesDonnées} = \text{data.frame}(x, y, z) \\ \text{head}(\text{MesDonnées}) \end{array} \right. \begin{array}{l} 1 \quad 0,0561.. \quad 0,3511.. \quad 0,46.. \\ 2 \quad -0,6772.. \quad 0,76.. \quad 3,80.. \end{array}$$


- Déterminer la moyenne et l'écart-type de vos trois échantillons x , y , et z . Ces nombre sont-ils égaux/proches de ceux que vous attendiez. Expliquez.

Pour x , y , et z on s'attend à des moyennes proches, respectivement, de 0, 2, et 2. On trouve $\text{mean}(x) = 0,006..$ proche (à $6 \cdot 10^{-3}$) de 0
 $\text{mean}(y) = 1,865278$
 $\text{mean}(z) = 1,8684$ proches de 2, mais seulement à $4 \cdot 10^{-2}$
Il est surprenant que $\text{mean}(y) = 1,86$ soit beaucoup plus loin de 2 que $\text{mean}(x)$ de 0 puisque les échantillons ont le même écart-type...

3. Quelle est la matrice de variance-covariance Σ de vos échantillons x , y , et z (arrondir à 3 chiffres après le point décimal)

$$\Sigma = \text{var}(\text{MesDonnées}) = \begin{pmatrix} 0,957, & 0,030, & 0,046, \\ 0,030, & 1,024, & -0,225, \\ 0,046, & -0,225, & 21,882, \end{pmatrix}$$

4. Faites tracer à l'écran puis esquissez (en marge de cette page) le nuage des x et y . Comment se manifeste que les échantillons x et y sont indépendants?



Je ne perçois aucune relation entre x et y plot(x,y)


5. Comment se manifeste la différence de moyenne de x et y ?

Les abscisses (x) se distribuent autour de 0 alors que les ordonnées se distribuent autour de 2.

6. Comment se manifeste que ces échantillons suivent une loi normale?


On perçoit une plus forte concentration autour de (0,2)

7. Faites tracer le nuage des x et z . Comment se manifeste la différence d'écart-type de x et z ? Les deux nuages se présentent pourtant de façon similaire : commentez.



Les x sont compris entre -3 et $+3$ alors que les z vont de -10 à $+13$, $(3 - (-3)) = 6 \ll 23 = (13 - (-10))$

8. Faites ajouter en rouge (avec points) le nuage des x et y . Esquissez en marge de cette page la figure obtenue à l'écran.



points(x,y, col="red", pch=3)

On voit que les y sont plus proches de leur moyenne que les z ↑ les points sont représentés par des "+"

9. On forme les échantillons $u=x+z$ et $v=x-z$. Représenter le nuage des u et v . Qu'observez-vous?

Je compare cette nouvelle figure avec la figure de la question 7. Je note qu'à présent les abscisses u ont également une amplitude de l'ordre de 23. De ce fait, ce nouveau nuage apparaît comme allongé le long d'une droite "descendante"

10. Former le data.frame MD2 des u et v . Donner la matrice de variance-covariance $\Sigma(u,v)$ des u et v et leur matrice de corrélation $R(u,v)$. Que vaut $\rho = \text{cor}(u,v)$? Commentez.

MD2 = data.frame(u,v)

$$\Sigma(u,v) = \text{var}(\text{MD2}) = \begin{pmatrix} 22,93, & -20,92, \\ -20,92, & 22,74, \end{pmatrix} \left\{ \begin{array}{l} \rho = \text{cor}(u,v) = -0,916, \\ \rho \text{ est négatif (chaîne descendante)} \\ |\rho| \text{ est proche de 1 (nuage bien allongé)} \end{array} \right.$$

11. Quelle est l'équation $v = au + b$ de la droite de régression des v sur les u ? (Indication : utiliser lm et coef). Ajoutez cette droite à votre croquis de la question 9.

Reg v sur u = lm(v ~ u)

coef(Reg sur u) donne $a = -0,912,$

abline(Reg sur u).

$$v = -0,912, u - 0,17,$$

12. Comment peut-on retrouver la pente a de la droite de régression à partir de la matrice de variance-covariance? Vérifiez que vous retrouvez bien le même résultat que celui donné par R.

$$\text{On a vu en cours que } a = \frac{\text{cov}(u,v)}{\text{var}(u)} = \frac{-20,92,}{22,93,} = -0,9124,$$

$$a \leftarrow \text{cov}(u,v) / \text{var}(u) = \text{idem question 11}$$

13. Comment peut-on retrouver l'ordonnée à l'origine b . Vérifiez que vous retrouvez bien le même résultat que celui donné par R.

$$\text{On a vu en cours que } b = \bar{v} - a\bar{u} = \text{mean}(v) - a * \text{mean}(u) = -0,1762, = \text{idem question 11.}$$