

Covariance de deux variables aléatoires

Dans une urne contenant n jetons indiscernables au toucher ($n > 1$), on tire successivement deux jetons, et on considère les variables aléatoires X et Y qui prennent respectivement les valeurs successives des numéros obtenus.

Ainsi, si la suite de numéros est formée du couple $(1 ; 2)$, X vaut 1 et Y vaut 2.

Le but est d'évaluer la corrélation des variables X et Y en commençant par évaluer leur covariance.

Rappels :

La **covariance** de deux variables aléatoires réelles X et Y se définit comme étant :

$$\text{cov}(X ; Y) = E(X Y) - E(X) E(Y)$$

Elle permet de calculer le **coefficient de corrélation linéaire** des deux variables, défini par :

$$r(X ; Y) = \frac{\text{cov}(X Y)}{\sigma(X) \sigma(Y)}$$

où $\sigma(X)$ et $\sigma(Y)$ désignent les écarts types des variables.

1^{ère} étape : Loi de probabilité conjointe :

Pour résoudre l'exercice, il faut commencer par déterminer la loi de probabilité conjointe des variables X et Y , c'est-à-dire, pour tous les couples (i, j) d'entiers de $\llbracket 1; n \rrbracket$:

$$P((X = i) \cap (Y = j))$$

Or, le tirage se faisant sans remise :

$$\begin{aligned} \text{si } i \neq j : \quad & P((X = i) \cap (Y = j)) = \frac{1}{n(n-1)} \\ \text{si } i = j : \quad & P((X = i) \cap (Y = j)) = 0 \end{aligned}$$

2ème étape : Calcul de E(XY) :

Pour ce faire, nous allons dresser le tableau des résultats possibles de la variable $Z = XY$, selon les occurrences de X et de Y.

X\Y	1	2	3	j	n
1		2	3	j	n
2	2		...	2j	2n
3	3	6		⋮	⋮
⋮	⋮	⋮	⋮
i	i	2i	...	ij		...	in
⋮	⋮	⋮	...	⋮	...		⋮
n	n	2n	...	nj	

Notez alors que ce tableau est symétrique par rapport à sa diagonale descendante. Les cellules de couleur rouge correspondent à des occurrences impossibles pour le couple (i ; j)

Nous allons alors calculer l'espérance en utilisant la symétrie du tableau et en faisant une sommation par colonnes sur la partie en bleue du tableau :

X\Y	1	2	3	j	n
1		2	3	j	n
2	2		...	2j	2n
3	3	6		⋮	⋮
⋮	⋮	⋮	⋮
i	i	2i	...	ij		...	in
⋮	⋮	⋮	...	⋮	...		⋮
n	n	2n	...	nj	

Les colonnes étant indexées par j variant de 1 à (n-1), nous avons :

$$\begin{aligned}
 E(XY) &= 2 \sum_{j=1}^{n-1} \sum_{i=j+1}^n (ij P((X=i) \cap (Y=j))) \\
 &= 2 \sum_{j=1}^{n-1} \sum_{i=j+1}^n \left(ij \frac{1}{n(n-1)} \right) \\
 &= \frac{2}{n(n-1)} \sum_{j=1}^{n-1} \left(j \sum_{i=j+1}^n i \right)
 \end{aligned}$$

Or la somme sur i est une somme de termes consécutifs d'une suite arithmétique de raison 1 dont nous rappelons la formule :

$$\text{somme} = \frac{(\text{premier terme} + \text{dernier terme}) \times \text{nombre de terme}}{2}$$

On en déduit, le nombre de termes étant (n - j) :

$$\begin{aligned}
 E(XY) &= \frac{2}{n(n-1)} \sum_{j=1}^{n-1} \left(j \frac{(j+1+n)(n-j)}{2} \right) \\
 &= \frac{1}{n(n-1)} \sum_{j=1}^{n-1} (j(j+1+n)(n-j)) \\
 &= \frac{1}{n(n-1)} \sum_{j=1}^{n-1} (j(nj - j^2 + n - j + n^2 - nj))
 \end{aligned}$$

$$\begin{aligned}
&= \frac{1}{n(n-1)} \sum_{j=1}^{n-1} (-j^3 - j^2 + (n^2 + n)j) \\
&= \frac{-1}{n(n-1)} \sum_{j=1}^{n-1} j^3 - \frac{1}{n(n-1)} \sum_{j=1}^{n-1} j^2 + \frac{n+1}{n-1} \sum_{j=1}^{n-1} j
\end{aligned}$$

Rappelons alors les sommes remarquables :

$$\sum_{j=1}^N j = \frac{N(N+1)}{2}$$

$$\sum_{j=1}^N j^2 = \frac{N(N+1)(2N+1)}{6}$$

$$\sum_{j=1}^N j^3 = \left(\frac{N(N+1)}{2} \right)^2$$

On en déduit, en remplaçant N par $(n-1)$:

$$\begin{aligned}
E(XY) &= \frac{-1}{n(n-1)} \frac{(n(n-1))^2}{4} - \frac{1}{n(n-1)} \frac{n(n-1)(2n-1)}{6} + \frac{n+1}{n-1} \times \frac{n(n-1)}{2} \\
&= \frac{-n(n-1)}{4} - \frac{(2n-1)}{6} + \frac{n(n+1)}{2} \\
&= \frac{-3n(n-1) - 2(2n-1) + 6n(n+1)}{12}
\end{aligned}$$

Finalement :

$E(XY) = \frac{3n^2 + 5n + 2}{12}$

3ème étape : Calcul de E(X) et de E(Y) :

Faisons le tableau de la loi conjointe des deux variables X et Y en notant :

$$p = \frac{1}{n(n-1)}$$

X\Y	1	2	3	j	n
1		p	p	p	p
2	p		...	p	p
3	p	p		⋮	⋮
⋮	⋮	⋮	⋮
i	p	p	...	p		...	p
⋮	⋮	⋮	...	⋮	...		⋮
n	p	p	...	p	

On en déduit facilement les lois marginales de X et Y :

En sommant les éléments de la ligne i du tableau, nous avons en effet :

$$P(X = i) = (n - 1) p = \frac{1}{n}$$

Et en sommant les éléments de la colonne j :

$$P(Y = j) = (n - 1) p = \frac{1}{n}$$

Les espérances s'en déduisent :

$$E(X) = \sum_{i=1}^n i P(X = i) = \frac{1}{n} \sum_{i=1}^n i = \frac{1}{n} \times \frac{n(n+1)}{2}$$

Soit :

$$E(X) = \frac{(n+1)}{2}$$

De même :

$$E(Y) = \sum_{j=1}^n j P(X = j) = \frac{(n+1)}{2}$$

4ème étape : Calcul de Cov(X ; Y):

$$\text{Cov}(X ; Y) = E(X Y) - E(X) E(Y)$$

$$\begin{aligned} \text{Cov}(X ; Y) &= \frac{3n^2 + 5n + 2}{12} - \frac{(n+1)^2}{4} \\ &= \frac{3n^2 + 5n + 2 - 3(n^2 + 2n + 1)}{12} \end{aligned}$$

finalement :

$$\text{Cov}(X ; Y) = \frac{-n-1}{12}$$

5ème étape : Calcul de V(X) et de V(Y) :

Commençons par l'espérance des carrés de X et Y :

$$E(X^2) = \sum_{i=1}^n i^2 P(X = i) = \frac{1}{n} \sum_{i=1}^n i^2 = \frac{1}{n} \times \frac{n(n+1)(2n+1)}{6}$$

$$E(X^2) = \frac{(n+1)(2n+1)}{6} = E(Y^2)$$

Les variances s'en déduisent :

$$\begin{aligned} V(X) &= E(X^2) - E(X)^2 \\ &= \frac{(n+1)(2n+1)}{6} - \frac{(n+1)^2}{4} \end{aligned}$$

$$= \frac{2(2n^2 + 3n + 1) - 3(n^2 + 2n + 1)}{12}$$

Finalemment :

$$V(X) = \frac{n^2 - 1}{12} = V(Y)$$

Les écarts types s'en déduisent :

$$\sigma(X) = \sqrt{\frac{n^2 - 1}{12}} = \sigma(Y)$$

6ème étape : Calcul du coefficient de corrélation linéaire :

$$r(X; Y) = \frac{\text{cov}(X; Y)}{\sigma(X) \sigma(Y)}$$

$$= \frac{\frac{-(n+1)}{12}}{\sqrt{\frac{n^2-1}{12}} \sqrt{\frac{n^2-1}{12}}}$$

$$= \frac{-(n+1)}{n^2-1}$$

$$= \frac{-(n+1)}{(n+1)(n-1)}$$

Finalemment :

$$r(X; Y) = \frac{-1}{(n-1)}$$

Nous voyons donc que les deux variables sont faiblement corrélées et négativement :

Pour $n = 2$, r vaut -50% et pour $n = 11$, -10% . Les deux variables sont d'autant moins corrélées que n est grand.

Le coefficient de corrélation tend vers 0 quand n tend vers l'infini. Pour des n suffisamment grands (supérieur à 11 environ) la corrélation est inférieure à 10 % en valeur absolue. Cela signifie que si on représentait un grand nombre de réalisations $(i ; j)$ par un nuage de points (i en abscisse et j en ordonnée), le nuage s'envelopperait dans une sorte de disque. Alors que pour corrélation de -50% , l'enveloppe serait une sorte d'ellipse dont le grand axe serait incliné vers le bas.

Rappelons qu'un coefficient de corrélation de 100% (1) donnerait un nuage de points alignés sur une droite de coefficient directeur strictement positif et un coefficient de -100% , un nuage de points alignés sur une droite de coefficient directeur strictement négatif, ce qui traduirait un lien affine entre les variables X et Y ($Y = aX + b$) mais ce n'était pas le cas traité dans notre exercice.