

M1 IAD UE RFIDEC 2006-07

Corrigé du TD2

Exercice 1

1/ Calcul du coefficient de corrélation linéaire r entre X et Y .

Moyenne de X , $\bar{x} = 7.250$;

Variance de X , $s_x^2 = 2.187$; écart-type de X , $s_x = 1.479$

Moyenne de Y , $\bar{y} = 7.00$;

Variance de Y , $s_y^2 = 3.500$; écart-type de Y , $s_y = 1.871$

Covariance de X et Y , $cov(x,y) = 1.000$

Corrélation de X et Y , $r = 0.361$

2/ Appelons X' et Y' les rangs des modèles pour la tenue de route et le confort. On obtient le tableau suivant :

Marque	X'	Y'
Hyundai	3	4
FIAT	4	3
Peugeot	2	1
Renault	1	2

3/ Calcul du coefficient de corrélation des rangs de SPEARMAN r entre X et Y .

Moyenne de X' , $\bar{x}' = 2.500$;

Variance de X' , $s_{x'}^2 = 1.250$; écart-type de X' , $s_{x'} = 1.118$

Moyenne de Y' , $\bar{y}' = 2.500$;

Variance de Y' , $s_{y'}^2 = 1.250$; écart-type de Y' , $s_{y'} = 1.118$

Covariance de X' et Y' , $cov(x',y') = 0.750$

Corrélation des rangs de SPEARMAN entre X' et Y' , $\rho = 0.600$

Le coefficient de corrélation r basé sur des écarts numériques sans réelle signification, sous-estime la corrélation, en fait assez forte, entre les deux caractéristiques qui est bien mise en évidence par ρ .

Exercice 2

Si les chercheurs américains avaient utilisé le système métrique ils auraient trouvé exactement la même valeur pour le coefficient de corrélation.

En effet, la formule donnant le *coefficient de corrélation linéaire* est

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

Un changement d'unités entraîne le remplacement partout dans cette formule de x_i par $a x_i$ et celui de y_i par $b y_i$.

La moyenne de X , \bar{x} est multipliée par a , sa variance, s_x^2 , est donc multipliée par a^2 et son écart-type, s_x , par a

La moyenne de Y , \bar{y} est multipliée par b , sa variance, s_y^2 , par b^2 et son écart-type, s_y , par b

La covariance de X et Y , $cov(x,y)$ est donc multipliée par ab mais comme le dénominateur l'est aussi, r ne change pas.

Remarque : Des translations (changements d'origine) des variables ne changent pas non plus r ; donc r est en fait invariant par des transformations affines (linéaires plus constantes) opérées sur les variables.

Exercice 3

X : note de partiel ; Y : note globale.

1/ Calcul du coefficient de corrélation linéaire r entre X et Y .

Moyenne de X , $\bar{x} = 34.500$;

Variance de X , $s_x^2 = 152.250$; écart-type de X , $s_x = 12.34$

Moyenne de Y , $\bar{y} = 87.200$;

Variance de Y , $s_y^2 = 66.960$; écart-type de Y , $s_y = 8.18$

Covariance de X et Y , $cov(x,y) = 96.700$

Corrélation de X et Y , $r = 0.958$

2/ Le nuage de points est le suivant :

Les points sont assez proches d'être alignés.

On peut tracer à la main une droite dont les points du nuage sont les plus proches en moyenne.

En fait les droites les plus proches en moyennes verticalement et horizontalement, appelées *droites de régression* de X en Y et de Y en X , sont :

$$x = 34.50 + 1.444(y - 87.20)$$

$$y = 87.20 + 0.635(x - 34.50)$$

[on verra plus tard dans le cours leurs équations]

3/ Avec le 11^{ème} point la corrélation de X et Y n'est plus que , $r = 0.730$
 r a diminué parce que le nouveau point est plus éloigné des droites de régression que l'étaient en moyenne les 10 premiers points.

Exercice 4

Valeur du $\chi^2 = 9.117$

Exercice 5

Tableau de contingence 2×2

Y X	1	2	<i>marge</i>
1	<i>a</i>	<i>b</i>	<i>a + b</i>
2	<i>c</i>	<i>d</i>	<i>c + d</i>
<i>marge</i>	<i>a + c</i>	<i>b + d</i>	<i>a + b + c + d</i>

Le tableau de mêmes marges formé par les produits des marges est :

Y X	1	2	<i>marge</i>
1	$\frac{(a+b)(a+c)}{(a+b+c+d)}$	$\frac{(a+b)(b+d)}{(a+b+c+d)}$	<i>(a + b)</i>
2	$\frac{(c+d)(a+c)}{(a+b+c+d)}$	$\frac{(c+d)(b+d)}{(a+b+c+d)}$	<i>(c + d)</i>
<i>marge</i>	<i>(a + c)</i>	<i>(b + d)</i>	<i>a + b + c + d</i>

L'expression générale du χ^2 appliquée à un tableau 2×2 et à $n = a + b + c + d$ donne :

$$\chi^2 = \frac{(a+b)(a+c)}{(a+b+c+d)} \left[\frac{(a+b+c+d)a}{(a+b)(a+c)} - 1 \right]^2 + \frac{(a+b)(b+d)}{(a+b+c+d)} \left[\frac{(a+b+c+d)b}{(a+b)(b+d)} - 1 \right]^2 + \frac{(a+d)(a+c)}{(a+b+c+d)} \left[\frac{(a+b+c+d)c}{(a+d)(a+c)} - 1 \right]^2 + \frac{(c+d)(b+d)}{(a+b+c+d)} \left[\frac{(a+b+c+d)d}{(c+d)(b+d)} - 1 \right]^2$$

Dans le premier des 4 termes,
 $\frac{(a+b+c+d)a}{(a+b)(a+c)} - 1 = \frac{(ad-bc)}{(a+b)(a+c)}$;

transformant de façon analogue les 3 autres termes, on peut mettre $\frac{(ad-bc)^2}{(a+b+c+d)}$ en facteur dans l'expression de χ^2 ; en réduisant au même dénominateur le 2^{ème} facteur puis simplifiant on obtient l'expression cherchée.

Exercice 6

coefficients de corrélation des rangs

Spearman $\rho = 0.818$

Kendall $\tau = \frac{2}{3}$