

## COEFFICIENT DE CORRÉLATION DES RANGS DE SPEARMAN

(14 / 01 / 2020, © Monfort, Dicostat2005, 2005-2020)

(i) Soit  $(\xi, \eta)$  un **couple aléatoire**, dont la **loi** est notée  $P^{(\xi, \eta)}$ ,  $(X, Y)$  ou  $((X_1, Y_1), \dots, (X_N, Y_N))$  un **N-échantillon** (non nécessairement indépendant) généré par ce couple,  $R = (R_1, \dots, R_N)$  et  $S = (S_1, \dots, S_N)$  les **statistiques de rang** resp associées à  $X = (X_1, \dots, X_N)$  et  $Y = (Y_1, \dots, Y_N)$ .

Le **coefficient de corrélation des rangs de SPEARMAN** (empirique) est défini comme le **coefficient de corrélation linéaire** (empirique) entre les vecteur de rangs  $R$  et  $S$  (cf **coefficient de corrélation des rangs**), ie comme **statistique** :

$$(1) \quad r_{XY}' = r_{RS} = \|\|P R\|\|^{-1} \|\|P S\|\|^{-1} R' P S,$$

dans laquelle  $P \in M_N(\mathbf{R})$  désigne **matrice de centrage** pr à chaque **moyenne empirique** (celle de  $R$  et celle de  $S$ ).

Ce coefficient, souvent aussi noté  $R_{S,N}$ , ou  $\rho_{XY}$  ou simplement  $\rho$  (« rho » de SPEARMAN), vaut :

$$(2) \quad r_{XY}' = 1 - 6 N^{-1} (N^2 - 1)^{-1} \sum_{n=1}^N D_n^2,$$

avec  $D_n = R_n - S_n$  (différence entre rangs), formule qui s'écrit aussi :

$$(2)' \quad r_{XY}' = 1 - 6 N^{-1} (N^2 - 1)^{-1} \|\|R - S\|\|^2.$$

(ii) Dans le cadre du **problème de l'indépendance**, ce coefficient sert de **statistique de test** pour l'hypothèse  $H_0$  d'**indépendance** (plus exactement, de non **corrélation**) entre  $\xi$  et  $\eta$ , ie :

$$H_0 : P^{(\xi, \eta)} = P^\xi \otimes P^\eta,$$

où  $P^\xi$  (resp  $P^\eta$ ) est la loi propre (ie la **loi marginale**) de  $\xi$  (resp  $\eta$ ), contre des hypothèses alternatives  $H_1$  de corrélation (positive ou négative).

Si l'on note  $T_N$  la statistique de test associée au **test de SPEARMAN**, le coefficient de SPEARMAN s'écrit :

$$(3) \quad r_{XY}' = 12 \cdot N^{-1} (N^2 - 1)^{-1} \{T_N - (1/4) N (N+1)^2\}.$$

On montre que, quelles que soient les lois  $P^\xi$  et  $P^\eta$ , la loi de  $r_{XY}'$  est une **loi symétrique** pr à 0. Par suite :

$$(4) \quad E_0 (r_{XY}')^j = 0, \quad \forall j \in 2 \mathbf{N} + 1 \text{ (impairs),}$$

$$V_0 (r_{XY}') = (N-1)^{-1}, \quad \forall N \in \mathbf{N}^* \setminus \{1\}.$$

La **distribution** de  $r_{XY}'$  sous  $H_0$  est tabulée.

De plus, on établit les **propriétés asymptotiques** suivantes, vraies sous  $H_0$  :

(a) convergence vers la loi normale (cf **normalité asymptotique**) :

$$(5) \quad \mathcal{L}\{(N-1)^{1/2} r_{XY}'\} \rightarrow_{N \rightarrow +\infty} \mathcal{N}(0, 1) \text{ (loi normale réduite) ;}$$

(b) **convergence en loi** vers la **loi de STUDENT** (à  $N - 2$  **degrés de liberté**). La statistique :

$$(4) \quad T_N = (N - 2)^{1/2} \cdot \{1 - (r_{XY}')^2\}^{-1/2} \cdot r_{XY}'$$

vérifie :

$$(5) \quad \mathcal{L}(T_N) \rightarrow_{N \rightarrow +\infty} \mathcal{S}_{N-2} .$$

Ces propriétés permettent de tester la non corrélation. Ainsi, lorsque l'**alternative**  $H_1$  suppose une corrélation positive, la **région critique** du test (asymptotique) correspondant est de la forme :

$$(3) \quad w = [r_{XY}' < q_{1-\alpha}] ,$$

où  $q_\alpha$  est le **quantile** d'ordre  $\alpha \in ]0, 1[$  ( $\alpha \ll 1$ ) de la loi ( $\mathcal{N}(0, 1)$  ou  $\mathcal{S}_{N-2}$ ) considérée.