

## RAPPORT DE CORRÉLATION (C5, D2)

(20 / 01 / 2020, © Monfort, Dicostat2005, 2005-2020)

(i) Soit  $(\Omega, \mathcal{F}, P)$  un **espace probabilisé** et  $(\xi, \eta) : \Omega \mapsto \mathbf{R}^2$  un **couple aléatoire** réel.

On appelle **rapport de corrélation (théorique)** de  $\eta$  pr (ou relatif) à  $\xi$ , ou de  $\eta$  conditionnel(lement) à  $\xi$  (ou de  $\eta$  sachant  $\xi$ , ou encore de  $\eta$  en  $\xi$ ), **simple** le nombre réel signé  $\rho_{\eta\xi}$ , dont le carré s'écrit :

$$(1) \quad \rho_{\eta/\xi}^2 = \{V_2 \eta - E_1 V(\eta/\xi)\} / V_2 \eta = V_1 E(\eta/\xi) / V_2 \eta,$$

**rapport** dans lequel  $V_2 \eta = V \eta$  désigne la **variance** propre (ie la variance marginale) de  $\eta$ ,  $V(\eta/\xi)$  la variance conditionnelle de  $\eta$  sachant  $\xi$ ,  $E_1$  l'opérateur espérance mathématique pr à  $\xi$ ,  $V_1$  la variance calculée pr à  $\xi$  et  $E(\eta/\xi)$  l'espérance conditionnelle de  $\eta$  sachant  $\xi$  (cf **caractéristique marginale**, **caractéristique conditionnelle**).

Le rapport  $\rho_{\eta/\xi}^2$  exprime un « **degré** » de **dépendance** de  $\eta$  pr à  $\xi$ , car il exprime la réduction relative de la variance de  $\eta$  lorsqu'on centre  $\eta$  pr à sa moyenne conditionnelle  $E(\eta/\xi)$  au lieu de sa propre moyenne  $E \eta = E_2 \eta$  (espérance marginale).

Par permutation des rôles de  $\xi$  et  $\eta$ , on définit un rapport de corrélation « dual »  $\rho_{\xi/\eta}^2 \leq 1$ , défini (par permutation de rôle) selon  $\rho_{\xi/\eta}^2 = (V \eta - E_2 V_1) / V \eta$ .

(ii) Le rapport de corrélation (simple) possède diverses propriétés, dont les suivantes :

(a) si  $V(\eta/\xi) = 0$ , alors  $V(\eta/\xi = x) = 0$  (P-p.s.),  $x \in \mathbf{R}$ . Autrement dit, à toute valeur de  $x$  ne correspond qu'une valeur  $E^\xi \eta$  de  $\eta$  (P-p.s.). Par suite,  $E_1(V^\xi \eta) = 0$  et  $\rho_{\eta/\xi}^2 = 1$ . Si  $\xi$  et  $\eta$  sont indépendantes,  $E(\eta/\xi) = E \eta$  (et ne dépend donc pas de  $\xi$ ) et  $V_1(E(\eta/\xi)) = 0$ . Par suite,  $\rho_{\eta/\xi}^2 = 0$ .

Cette situation correspond au cas où il existe une liaison « fonctionnelle »  $\varphi$  entre  $\eta$  et  $\xi$ , ie une fonction mesurable  $\varphi : \mathbf{R} \mapsto \mathbf{R}$  tq  $\eta = \varphi(\xi)$  (P-p.s.) (cf **application mesurable**). Dans ce cas,  $\rho_{\eta/\xi}^2 = 1$  ;

(b) en général,  $\rho_{\xi/\eta}^2 \neq \rho_{\eta/\xi}^2$  ;

(c) si  $\rho_{\xi\eta}^2$  désigne le carré du **coefficient de corrélation linéaire** entre  $\xi$  et  $\eta$ , on utilise parfois le rapport  $\rho_{\eta/\xi}^2 / \rho_{\xi\eta}^2$ , ou toute fonction adéquate de ce rapport, comme **indice de non linéarité**. Un exemple de telle fonction est  $(\rho_{\eta/\xi}^2 - \rho_{\xi/\eta}^2) / (1 - \rho_{\xi/\eta}^2)$ .

(iii) Soit  $(\Omega, \mathcal{F}, P)$  un **espace probabilisé** et  $(\xi, \eta) : \Omega \mapsto \mathbf{R}^K \times \mathbf{R}$  un **couple aléatoire** réel dans lequel  $\xi =$  est un **vecteur aléatoire** réel, à valeurs dans  $\mathbf{R}^K$ . On considère une sous-suite  $(k_1, \dots, k_m)$  de  $(1, \dots, K) = N_K^*$  composée d'indices distincts deux à

deux (ie  $k_i'' \neq k_i'$  si  $j'' \neq j'$ ) ainsi que la sous-suite  $\xi(m) = (\xi_{k(1)}, \dots, \xi_{k(m)})$  correspondante, où  $k(i)$  désigne, par commodité,  $k_i$  (tout  $i = 1, \dots, m$ ).

On appelle **rapport de corrélation (théorique)** de  $\eta$  pr (ou relatif) à  $\xi(m)$ , ou de  $\eta$  conditionnel(ement) à  $\xi(m)$  (ou de  $\eta$  sachant  $\xi(m)$ , ou encore de  $\eta$  en  $\xi(m)$ ), **multiple d'ordre  $(k_1, \dots, k_m)$**  le nombre réel signé  $\rho_{\eta / \xi(m)}$ , dont le carré s'écrit :

$$(2) \quad \rho_{\eta / \xi(m)}^2 = \frac{\{V_{k(1)\dots k(m)} (E (\eta / \xi(m)))\} / V_2 \eta = V_1 E (\eta / \xi(m)) / V_2 \eta,}{1 - \{E_{k(1)\dots k(m)} (V (\eta / \xi(m)))\} / V_2 \eta,}$$

pour toute partie  $\{k_1, \dots, k_m\} \subset \{1, \dots, K\}$  tq  $j'' \neq j' \Rightarrow k_i'' \neq k_i'$ .

Il existe donc  $K(2^{K-1} - 1)$  rapports de corrélation multiples (théoriques) possibles de  $\eta$  pr à  $\xi(m) = (\xi_{k(1)}, \dots, \xi_{k(m)})$ , avec  $\{k_1, \dots, k_m\} \subset \{1, \dots, K\}$ .

(v) On montre alors que (extensions des propriétés précédentes) :

(a)  $0 \leq \rho_{\eta / \xi(m)}^2 \leq 1$ , pour toute suite  $(k_1, \dots, k_m)$  définie comme précédemment et tout  $m \in \mathbb{N}_K^*$  ;

(b)  $\eta$  est non corrélée avec  $\xi(m)$  ssi  $\rho_{\eta / \xi(m)}^2 = 0$  ;

(c)  $\eta$  est liée fonctionnellement à  $\xi(m)$  ssi  $\rho_{\eta / \xi(m)}^2 = 1$  (auquel cas  $V (\eta / \xi(m)) = 0$ ).

(v) Le **rapport de corrélation empirique (simple)** se définit, de façon analogue, à l'aide d'un **échantillon aléatoire**  $((X_1, Y_1), \dots, (X_N, Y_N))$  dont la **variable parente** est le couple  $(\xi, \eta)$ , ie à l'aide de la **fonction de répartition empirique** fondée sur cet échantillon (cf **statistique naturelle**).

C'est une **statistique** (non paramétrique) qui permet de tester le caractère non linéaire d'une régression (cf **régression non linéaire**).

De même, le **rapport de corrélation empirique (multiple)** se définit, de façon analogue, à l'aide d'un **échantillon aléatoire**  $((X_1(m), Y_1), \dots, (X_N(m), Y_N))$  issu du couple  $(\xi(m), \eta)$ , ie à l'aide de la fr empirique fondée sur cet échantillon.