

COEFFICIENT D'ASSOCIATION (C5, D2)

(24 / 12 / 2019, © Monfort, Dicostat2005, 2005-2019)

Un **coefficient d'association** est un scalaire, généralement sans dimension pr aux **unités de mesure**, qui résume la « liaison » existant entre des **variables aléatoires** (cf **association**, **corrélation**, **dissimilarité**).

En général, les variables considérées sont des **variables qualitatives** : le coefficient d'association joue alors un rôle analogue à celui du **coefficient de corrélation** pour des **variables numériques**.

(i) Soit (Ω, \mathcal{F}, P) un **espace probabilisé**, $(\mathcal{Y}', \mathcal{G}')$ et $(\mathcal{Y}'', \mathcal{G}'')$ deux espaces non numériques, $\eta' : \Omega \mapsto \mathcal{Y}'$ et $\eta'' : \Omega \mapsto \mathcal{Y}''$ deux variables qualitatives.

On dit que η' et η'' sont des **variables associées** ssi le **coefficient de corrélation linéaire** ρ , liant un **codage** (numérique) ξ' de η' à un codage (numérique) ξ'' de η'' , n'est pas nul. S'il est positif (resp négatif), l'association est qualifiée conformément : resp **association positive**, **association négative**.

On obtient le schéma suivant :

$$(1) \quad \begin{array}{l} (\Omega, \mathcal{F}, P) \rightarrow (\eta') \rightarrow (\mathcal{Y}', \mathcal{G}') \rightarrow (c') \rightarrow (\mathcal{X}', \mathcal{B}') \\ (\Omega, \mathcal{F}, P) \rightarrow (\eta'') \rightarrow (\mathcal{Y}'', \mathcal{G}'') \rightarrow (c'') \rightarrow (\mathcal{X}'', \mathcal{B}'') \end{array} \rightarrow \rho,$$

(où les triplets symboliques $\rightarrow (\eta) \rightarrow$ et $\rightarrow (c) \rightarrow$ désignent les **applications** correspondantes), ainsi que la formule du **coefficient d'association (théorique)** :

$$(2) \quad \rho = \frac{(V \xi')^{-1/2} (V \xi'')^{-1/2} \cdot C(\xi', \xi'')}{(V c' \circ \eta')^{-1/2} (V c'' \circ \eta'')^{-1/2} \cdot C(c' \circ \eta', c'' \circ \eta'')}.$$

Le coefficient précédent dépend des codages c' et c'' choisis. Dans certains cas, le codage est « naturel » (eg utilise des **variables indicatrices** ou des **variables de comptage**). Dans d'autres cas, on doit chercher des codages adaptés au problème à résoudre.

(ii) La définition (2) s'applique de même à des observations (Y_n') et (Y_n'') relatives resp aux variables η' et η'' et à des observations (X_n') et (X_n'') relatives resp aux variables ξ' et ξ'' . Elles conduisent directement à la notion de **coefficient d'association (empirique)** (cf **statistique naturelle**).

(iii) L'étude d'un **tableau de contingence** conduit souvent à définir des **coefficients de contingence** (cf **contingence**, **test du chi-deux**) : ces derniers sont des coefficients d'association relatifs aux variables qualitatives (« critères ») définissant le tableau.

(iv) Dans le cas d'un (2,2)-tableau $T = \{(a, b), (c, d)\}$, croisant les variables η' et η'' , supposées chacune à deux modalités et codées avec le même codage c , à valeurs dans $N_1 = \{0, 1\}$, on peut interpréter l'élément courant de l'ensemble $\{a, b, c, d\}$ comme la **fréquence absolue** de la case (i, j) de T , ie comme le nombre d'observations $n \in N_N^*$ tq $\xi' = u$ et $\xi'' = v$, avec $(u, v) \in (N_1)^2$, ie :

$$T = \begin{array}{|c|c|c|} \hline & \xi'' = 0 & \xi'' = 1 \\ \hline \xi' = 0 & a & b \\ \hline \xi' = 1 & c & d \\ \hline \end{array}$$

On peut, dans ce **contexte statistique**, définir plusieurs coefficients d'association :

(a) le **coefficient de G.U. YULE** :

$$(3) \quad Y = \det T / (a d + b c) = (a b + b c)^{-1} \cdot (a d - b c) ;$$

(b) le **coefficient de « colligation »** :

$$(4) \quad C = \{1 - (a d)^{-1/2} (b c)^{1/2}\} / \{1 + (a d)^{-1/2} (b c)^{1/2}\} ;$$

(c) le **carré moyen de contingence** :

$$(5) \quad \Phi^2 = N^{-1} \cdot \mathcal{X}_2^2,$$

où \mathcal{X}_2^2 est la **statistique du chi-deux** calculée sur T .