

CONTINGENCE (D2, D3, K1)

(26 / 08 / 2020, © Monfort, Dicostat2005, 2005-2020)

La **contingence** est une notion de base dans l'analyse d'un **tableau de contingence**.

(i) Soit $(\Omega, \mathcal{F}, P)$ un **espace probabilisé**, $A' = (A'_i)_{i \in I}$ et $A'' = (A''_j)_{j \in J}$ deux **suites** finies d'**événements** définis sur Ω .

Le triplet $(A' \times A'', P(A'_i)_{i \in I}, P(A''_j)_{j \in J})$ associe de façon probabiliste les événements de chaque type A'_i et A''_j (cf aussi **structure produit**).

On appelle :

(a) **contingence (théorique)** entre A' et A'' le nombre :

$$(1) \quad \kappa^2(A', A'') = \sum_{i \in I} \sum_{j \in J} \{P(A'_i) P(A''_j)\}^{-1} \cdot \{P(A'_i \cap A''_j) - P(A'_i) P(A''_j)\}$$

(ou aussi sa racine carrée), généralement appelé « chi-deux ».

Ce nombre est une somme de Card $I \times$ Card J **quotients**. Chaque « case » (i, j) associée contient le **rapport** entre :

(a)₁ l'**écart** $P(A'_i \cap A''_j) - P(A'_i) P(A''_j)$, qui exprime une « distance probabiliste » pr à l'**indépendance** ;

(a)₂ l'expression probabiliste $P(A'_i) P(A''_j)$ de indépendance elle-même.

Par suite, si les **variables qualitatives** $\eta' : \Omega \mapsto A'$ et $\eta'' : \Omega \mapsto A''$ définissant le tableau considéré sont indépendantes, alors $\kappa^2(A', A'') = 0$. Il est équivalent de dire que, si A' et A'' sont indépendantes (en probabilité), alors $\kappa^2(A', A'') = 0$.

(b) **matrice de contingence (théorique)** associée au scalaire $\kappa^2(A', A'')$ la matrice (certaine) d'élément général (cf aussi **loi multivariée**) :

$$(2) \quad \kappa^2_{ij}(A', A'') = \{P(A'_i) P(A''_j)\}^{-1} \cdot \{P(A'_i \cap A''_j) - P(A'_i) P(A''_j)\}, \quad \forall (i, j) \in I \times J.$$

(i) Soit $N = (n_{ij})_{(i,j) \in I \times J}$ un tableau constitué d'entiers $n_{ij} \in \mathbf{N}$, et dont au moins une case (i, j) comporte un **effectif (fréquence absolue)** non nul(le). Ce tableau peut provenir de dénombrements divers.

Pour tout $(i, j) \in I \times J$, on appelle :

(a) **contingence (empirique)** associée à la case (i, j) de N la **statistique** :

$$(3) \quad c_{ij} = n_{ij} - (n_{i.})^{-1} (n_{.j});$$

(b) **matrice de contingence (empirique)** associée à N la matrice (aléatoire) :

$$(4) \quad C = (c_{ij})_{(i,j) \in I \times J} = N - (e_m' N e_n)^{-1} (N e_n e_m' N),$$

avec $m = \text{Card } I$ et $n = \text{Card } J$.

La matrice des **fréquences relatives** :

$$(5) \quad F = (f_{ij})_{(i,j) \in I \times J} = (e_m' N e_n)^{-1} N, \quad \text{avec } f_{ij} = n_{ij} / n_{..},$$

conduit aux écritures équivalentes suivantes :

$$(6) \quad \begin{aligned} c_{ij} &= n_{..} (f_{ij} - f_{i.} f_{.j}), \\ C &= (e_m' N e_n) (F - F e_n e_m' F). \end{aligned}$$

La **statistique du chi-deux** (à deux critères) $X^2(C, F)$, aussi notée X^2 , d'une matrice de contingence est définie par la formule :

$$(7) \quad X^2 = \sum_{i \in I} \sum_{j \in J} (n_{ij} - c_{ij})^{-1} c_{ij}^2.$$

On appelle alors **coefficient de contingence** (empirique) associé à N toute **statistique** dépendant de X^2 , eg :

(a) le **coefficient de K. PEARSON** :

$$(8) \quad C_P = \{X^2 / (n_{..} + X^2)\}^{1/2};$$

(b) le **coefficient de A.A. CHUPROV** :

$$(9) \quad C_T = \{X^2 / (n_{..} (m - 1)^{1/2} (n - 1)^{1/2})\}^{1/2}.$$

Ces coefficients mesurent le degré de la liaison (ou du **lien**) entre les deux **critères** (ou **caractères**) qui constituent le tableau N.

(iii) Les notions précédentes s'étendent directement à des tableaux de contingence à plus de deux critères. Ainsi, dans le cas de trois critères croisés, on transpose (1) selon :

$$(1)' \quad c_{ijk} = (n_{ijk} - n_{i..} n_{.j.} n_{.k.}) / n_{...}.$$