

série de  $n$  couples  $(x_i, y_j)$  avec  $i = 1$  à  $p$  et  $j = 1$  à  $q$  : - d'effectifs partiels notés  $n_{ij}$

(si caractères continus :  $x_i$  et  $y_j =$  centres de classes) - de fréquences partielles :  $f_{ij} = \frac{n_{ij}}{n}$

### 1. Distributions marginales - distributions conditionnelles

a) *tableau de contingence*

$$n_{i\bullet} = \sum_{j=1}^q n_{ij}$$

$$n_{\bullet j} = \sum_{i=1}^p n_{ij}$$

$x \backslash y$	$y_1$	$y_j$	$y_q$	somme
$x_1$	$n_{11}$	$n_{1j}$	$n_{1q}$	$n_{1\bullet}$
$x_i$	$n_{i1}$	$n_{ij}$	$n_{iq}$	$n_{i\bullet}$
$x_p$	$n_{p1}$	$n_{pj}$	$n_{pq}$	$n_{p\bullet}$
somme	$n_{\bullet 1}$	$n_{\bullet j}$	$n_{\bullet q}$	$n$

b) *distributions marginales*

- distribution marginale de  $x$  : valeurs  $x_i$ , effectif marginal de  $x_i = n_{i\bullet}$

- distribution marginale de  $y$  : valeurs  $y_j$ , effectif marginal de  $y_j = n_{\bullet j}$

- fréquence marginale de  $x_i$  :  $f_{i\bullet} = \frac{n_{i\bullet}}{n}$  et fréquence marginale de  $y_j$  :  $f_{\bullet j} = \frac{n_{\bullet j}}{n}$

$$n = \sum_{i=1}^p n_{i\bullet} = \sum_{j=1}^q n_{\bullet j} = \sum_{i=1}^p \sum_{j=1}^q n_{ij} \quad \text{et} \quad \sum_{i=1}^p f_{i\bullet} = \sum_{j=1}^q f_{\bullet j} = \sum_{i=1}^p \sum_{j=1}^q f_{ij} = 1$$

c) *distributions conditionnelles*

- distribution conditionnelle de  $x$  pour  $y = y_j$  : valeurs  $x_i$ , effectif =  $n_{ij}$  ( $j^{\text{ème}}$  colonne du tableau)

- distribution conditionnelle de  $y$  pour  $x = x_i$  : valeurs  $y_j$ , effectif =  $n_{ij}$  ( $i^{\text{ème}}$  ligne du tableau)

- fréquence conditionnelle de  $x_i$  si  $y = y_j$  :  $f_{i|j} = \frac{n_{ij}}{n_{\bullet j}}$  (% d'unités ayant  $x_i$  parmi ceux ayant  $y_j$ )

- fréquence conditionnelle de  $y_j$  si  $x = x_i$  :  $f_{j|i} = \frac{n_{ij}}{n_{i\bullet}}$  (% d'unités ayant  $y_j$  parmi ceux ayant  $x_i$ )

- propriétés :  $f_{ij} = f_{i|j} \times f_{\bullet j}$ ,  $f_{ij} = f_{j|i} \times f_{i\bullet}$ , et  $\sum_{i=1}^p f_{i|j} = \sum_{j=1}^q f_{j|i} = 1$

### 2. Caractéristiques des séries à 2 caractères

a) *caractéristiques des distributions marginales*

- moyenne de  $x$  :  $\bar{x} = \sum_{i=1}^p x_i f_{i\bullet} = \sum_{i=1}^p \sum_{j=1}^q x_i f_{ij}$       moyenne de  $y$  :  $\bar{y} = \sum_{j=1}^q y_j f_{\bullet j} = \sum_{i=1}^p \sum_{j=1}^q y_j f_{ij}$

- variance de  $x$  :  $\sigma_x^2 = \sum_{i=1}^p (x_i - \bar{x})^2 f_{i\bullet} = \overline{x^2} - \bar{x}^2$       et de  $y$  :  $\sigma_y^2 = \sum_{j=1}^q (y_j - \bar{y})^2 f_{\bullet j} = \overline{y^2} - \bar{y}^2$

b) caractéristiques des distributions conditionnelles

- moyenne de  $x$  si  $y_j$  :  $\bar{x}_j = \sum_{i=1}^p x_i f_{i|j}$       moyenne de  $y$  si  $x_i$  :  $\bar{y}_i = \sum_{j=1}^q y_j f_{j|i}$

variance de  $x$  si  $y_j$  :  $\sigma_j^2(x) = \sum_{i=1}^p (x_i - \bar{x}_j)^2 f_{i|j} = \overline{x_j^2} - \bar{x}_j^2$  et de  $y$  si  $x_i$  :  $\sigma_i^2(y) = \sum_{j=1}^q (y_j - \bar{y}_i)^2 f_{j|i} = \overline{y_i^2} - \bar{y}_i^2$

c) relations entre les caractéristiques marginales et conditionnelles

- sur les moyennes :  $\bar{x} = \sum_{j=1}^q \bar{x}_j f_{\bullet j}$        $\bar{y} = \sum_{i=1}^p \bar{y}_i f_{i \bullet}$

- sur les variances :  $\sigma_x^2 = \sum_{j=1}^q \sigma_j^2(x) f_{\bullet j} + \sum_{j=1}^q (\bar{x}_j - \bar{x})^2 f_{\bullet j}$  et  $\sigma_y^2 = \sum_{i=1}^p \sigma_i^2(y) f_{i \bullet} + \sum_{i=1}^p (\bar{y}_i - \bar{y})^2 f_{i \bullet}$


(moyenne des variances conditionnelles + variance des moyennes conditionnelles)

d) covariance de  $x$  et  $y$

$$\text{Cov}(x, y) = \sum_{i=1}^p \sum_{j=1}^q (x_i - \bar{x})(y_j - \bar{y}) f_{ij} = \sum_{i=1}^p \sum_{j=1}^q x_i y_j f_{ij} - \bar{x} \bar{y} = \overline{xy} - \bar{x} \bar{y}$$

$$\text{Cov}(x, x) = \overline{x^2} - \bar{x}^2 = \sigma_x^2$$

3. Représentation graphique des séries à 2 caractères



4. Séries à caractères  $x$  et  $y$  indépendants


$$f_{i|j} = f_{i \bullet} \text{ et } f_{j|i} = f_{\bullet j}$$

d'où les conséquences :

- $f_{ij} = f_{i \bullet} \times f_{\bullet j}$  les fréquences marginales de  $x$  et  $y$  donnent la fréquence partielle de  $(x_i, y_j)$
- $\bar{x} = \bar{x}_j$  et  $\bar{y} = \bar{y}_i$  la courbe de régression  $C_{x|y}$  est verticale,  $C_{y|x}$  est horizontale
- $\overline{xy} = \bar{x} \bar{y}$  d'où  $\text{Cov}(x, y) = 0$  (attention : si  $\text{Cov}(x, y) = 0$ ,  $x$  et  $y$  peuvent être dépendants)

## 5. Ajustement, corrélation, régression

### a) ajustement linéaire - droites de régression



- angle entre D et D' :  $\theta = \text{Arc tan } \frac{1}{a'} - \text{Arc tan } a$
- $\theta$  mesure le degré de corrélation linéaire entre  $x$  et  $y$  :
  - $\theta = 0$  : D et D' confondues :  $x$  et  $y$  liés par une fonction linéaire
  - $\theta = \pi/2$  : D et D' perpendiculaires :  $x$  et  $y$  indépendants
- règle :  $0 \leq a a' \leq 1$  a pour conséquence que la droite D' est toujours plus pentue que D

### b) coefficient de corrélation linéaire

- $R = \frac{\overline{xy} - \bar{x}\bar{y}}{\sigma_x \sigma_y} = \frac{\text{Cov}(x, y)}{\sigma_x \sigma_y}$  avec  $-1 \leq R \leq 1$ ,  $R$  mesure le degré de corrélation linéaire entre  $x$  et  $y$
- $R = a a'$  : donc l'angle entre D et D' mesure aussi ce degré de corrélation linéaire

### c) corrélation non linéaire

- rapport de corrélation de y en x :

$$\eta_{y|x}^2 = \frac{\sum_{i=1}^p \sum_{j=1}^q n_{ij} (\bar{y}_i - \bar{y})^2}{\sum_{i=1}^p \sum_{j=1}^q n_{ij} (y_j - \bar{y})^2}$$

avec :  $0 \leq \eta_{y|x}^2 \leq 1$

- rapport de corrélation de x en y :

$$\eta_{x|y}^2 = \frac{\sum_{i=1}^p \sum_{j=1}^q n_{ij} (\bar{x}_i - \bar{x})^2}{\sum_{i=1}^p \sum_{j=1}^q n_{ij} (x_i - \bar{x})^2}$$

avec :  $0 \leq \eta_{x|y}^2 \leq 1$

- ces rapports mesurent le degré de corrélation directement sur les courbes de régression  $C_{y|x}$  et  $C_{x|y}$
- plus ces rapports sont proches de 1, plus la liaison est forte entre  $x$  et  $y$
- si  $\eta_{y|x}^2 = 0$  : alors  $\bar{y} = \bar{y}_i$ ,  $C_{y|x}$  est horizontale,  $y$  ne dépend pas de  $x$  (en général)
- si  $\eta_{x|y}^2 = 0$  : alors  $\bar{x} = \bar{x}_j$ ,  $C_{x|y}$  est verticale,  $x$  ne dépend pas de  $y$  (en général).