

## APPARIEMENT (B2, F)

(23 / 09 / 2020, © Monfort, Dicostat2005, 2005-2020)

(i) On appelle **appariement**, ou **rencontre** (en anglais : **match**), entre deux (ou plusieurs) **unités statistiques** la situation selon laquelle ces unités possèdent (au sens strict ou, parfois, au sens large) les mêmes propriétés ou les mêmes **caractéristiques** (cf **problème des rencontres**).

En général, les propriétés sont définies à l'avance et les unités sont extraites (de façon aléatoire ou non) de **populations** distinctes (ie globalement différentes entre elles).

Ainsi, soit  $A = \{a_1, \dots, a_N\}$  et  $B = \{b_1, \dots, b_M\}$  deux **échantillons** ainsi extraits.

On dit que l'unité  $a_n \in A$  est appariée avec l'unité  $b_m \in B$  ssi :

(a) soit  $B \neq A$  et  $b_m = a_n$  (**appariement sur identités** des unités) ;

(b) soit  $B = A$  et  $m = n$  (**appariement sur identifiants** des unités) ou même  $b_m = a_n$  (**appariement sur identités** des unités).

(ii) Le plus souvent, on mesure, sur chaque unité, une ou plusieurs **variables**  $\zeta$  (**variables numériques** ou **variables qualitatives**), à valeurs dans un ensemble  $\mathcal{Z}$ .

On dit alors que deux (ou plusieurs) unités sont des **unités appariées**, ou sont des **unités accouplées**, ou qu'il y a **rencontre** entre elles, ou encore qu'elles se **rencontrent**, ssi elles sont égales (ou, parfois, seulement « comparables ») d'un point de vue défini par la considération de certaines des variables précédentes.

Ainsi, soit  $A = \{a_1, \dots, a_N\}$  et  $B = \{b_1, \dots, b_M\}$  deux **échantillons** extraits de populations données,  $Z^a_n = \zeta(a_n)$  la valeur observée pour  $\zeta$  sur l'unité  $a_n$  et  $Z^b_m = \zeta(b_m)$  la valeur observée pour  $\zeta$  sur l'unité  $b_m$ .

On dit que l'unité  $a_n \in A$  est appariée avec l'unité  $b_m \in B$  ssi :

(a) de façon stricte :  $m = n$  et  $Z^b_m = Z^a_n$  (**appariement sur identifiants et caractéristiques** des unités) ;

(b) de façon plus large :  $Z^b_m = Z^a_n$  (**appariement sur caractéristiques** des unités) ;

(c) de façon encore moins restrictive :  $d(Z^b_m, Z^a_n) < \varepsilon$  (distance « négligeable » entre valeurs), où  $d$  est une **distance** sur  $\mathcal{Z}$  et  $\varepsilon > 0$  un nombre tq  $\varepsilon \ll +\infty$ .

(iii) Dans le cadre du **problème à plusieurs échantillons** (échantillons d'**observations**), on note ces derniers resp  $X_i = (X_{i,1}, \dots, X_{i,N(i)})$ ,  $\forall i \in N_k^*$ , où  $X_{i,n(i)} = \xi_{\zeta}(a_{n(i)})$  est une observation effectuée sur l'unité  $a_{n(i)}$  extraite de la  $i$ -ième population ( $\forall i \in N_k^*$ ).

On dit alors eg que les unités  $a_{n(1)}, \dots, a_{n(k)}$  sont appariées ssi :

$$(1) \quad X_{1,n(1)} = \dots = X_{k,n(k)} .$$

De tels problèmes se posent souvent lorsque les  $\xi_i$  sont des **variables qualitatives**. Ils conduisent à la définition de **lp** variées, alors dites **lois d'appariement**.