

## SONDAGE CONVERGENT (M6)

(16 / 03 / 2020, © Monfort, Dicostat2005, 2005-2020)

(i) Soit  $\Omega = \{\omega_1, \dots, \omega_M\}$  un ensemble fini (**population**),  $\Pi$  un **plan de sondage** sur  $\Omega$ ,  $(\mathcal{Y}, \mathcal{G})$  un **espace d'observation**,  $\eta : \Omega \mapsto \mathcal{Y}$  une **variable** (ou un **caractère observable**) et  $Y = (Y_1, \dots, Y_M)$  l'ensemble des valeurs prises par  $\eta$  dans la population  $\Omega$ , ie  $Y_m = \eta(\omega_m)$ ,  $\forall m = 1, \dots, M$ .

On note  $A = \{a_1, \dots, a_N\}$  un **N-échantillon aléatoire** tiré dans  $\Omega$  selon  $\Pi$  et  $y = (y_1, \dots, y_N)$  les valeurs prises par  $\eta$  sur l'échantillon  $A$ , ie  $y_n = \eta(a_n)$ ,  $\forall n = 1, \dots, N$ .

Soit  $(\mathcal{Z}^L, \mathcal{D}^{\otimes L})$  un **espace mesurable**,  $g : \mathcal{Y}^M \mapsto \mathcal{Z}^L$  ( $L \leq M$ ) une fonction donnée, et  $g(Y)$  un **paramètre d'intérêt**, déduit du « **paramètre** »  $Y$ .

Soit  $T_N = t_N(y)$  une **statistique** permettant de réaliser une inférence (eg estimation) sur  $g(Y)$ . On étudie la situation dans laquelle  $N \rightarrow +\infty$ .

(ii) Lorsque le sondage de  $A$  dans  $\Omega$  est sans remise (cf **sondage exhaustif, tirage exhaustif**), l'étude des **propriétés asymptotiques** de  $T_N$  nécessite que  $M \rightarrow +\infty$ , puisque  $1 \leq N \leq M$ . On peut donc définir une fonction  $\varphi : \mathbf{N}^* \mapsto \mathbf{N}^*$  tq  $M = \varphi(N)$  et que  $N \rightarrow +\infty \Rightarrow \varphi(N) \rightarrow +\infty$ . Une autre optique consiste seulement à faire tendre  $N$  vers  $M$ ,  $M$  restant fixe (optique à « distance finie »  $N \leq M$ , ou « avec grand échantillon » si  $M \gg 0$ );

(ii) Lorsque le sondage est avec remise (cf **sondage bernoullien, tirage bernoullien**), l'étude asymptotique de  $T_N$  ne suppose pas nécessairement que  $M \rightarrow +\infty$ , puisque les inégalités  $1 \leq N \leq M$  ne sont plus nécessaires. On peut cependant étendre le cas précédent en choisissant une fonction  $\varphi$  constante.

(iii) Les deux **sondages élémentaires** précédents montrent que l'étude asymptotique d'un sondage quelconque ( $\Pi, T_N$ ) doit supposer l'existence d'une fonction adéquate  $\varphi : \mathbf{N}^* \mapsto \mathbf{N}^*$  tq  $\varphi(N) = M$ .

Lorsque  $N$  ou  $M$  varie, on note  $\Omega_M$  ou  $\Omega_{\varphi(N)}$  au lieu de  $\Omega$ ,  $\Pi_M$  ou  $\Pi_{\varphi(N)}$  au lieu de  $\Pi$ , et  $Y(M)$  ou  $Y_{\varphi(N)}$  au lieu de  $Y$ . De même, on note  $A(N)$  au lieu de  $A$  et  $y(N)$  au lieu de  $y$ . Comme  $y$  varie avec  $N$ , on note aussi  $T_N = t_N(y(N))$  au lieu de  $t_N(y)$ . Enfin, comme  $Y$  varie avec  $N$  selon  $Y(\varphi(N))$ , la fonction  $g$  varie aussi avec  $N$ , et l'on note alors  $g_N(Y(\varphi(N)))$  le « paramètre » à estimer, paramètre dont la « dimension »  $L \leq N$  peut même, elle aussi, varier avec  $N$  (eg lorsqu'il existe une fonction  $\phi : \mathbf{N}^* \mapsto \mathbf{N}^*$  tq  $1 \leq L \leq \phi(N) \leq N$ ).

Par suite, l'analyse asymptotique d'un sondage consiste à étudier la **suite** (aléatoire)  $(T_N)_{N \in \mathbf{N}^*}$  constituée d'estimateurs  $T_N$  du « paramètre »  $g_N(Y(\varphi(N)))$ ; ce dernier définit lui-même une suite (non aléatoire, dans un cadre non bayésien) notée  $(g_N(Y(\varphi(N))))_{N \in \mathbf{N}^*}$ .

On dit alors que la suite  $(\Pi_{\varphi(N)}, T_N)_{N \in \mathbb{N}^*}$  est une **suite de sondages convergente**, ou simplement un **sondage convergent**, pour la suite  $(g_N)_{N \in \mathbb{N}^*}$  lorsque  $N$  tend vers l'infini ssi (**convergence en probabilité** généralisée) :

$$(1) \quad \forall \varepsilon > 0, \forall \eta > 0, \exists N_{\varepsilon, \eta} \text{ tq } N \geq N_{\varepsilon, \eta} \Rightarrow \Pi_{\varphi(N)} (\|T_N - g_N(Y(\varphi(N)))\| > \varepsilon) < \eta,$$

où  $(\mathcal{Z}^L, \|\cdot\|)$  est supposé être un **espace normé**. Autrement dit, pour tout  $\varepsilon > 0$ , l'expression  $\Pi_{\varphi(N)} (\|T_N - g_N(Y(\varphi(N)))\| > \varepsilon)$  tend vers 0 lorsque  $N$  tend vers l'infini.

(iv) On définit de même la **convergence en moyenne quadratique** du sondage (ou de la suite) précédent(e) en remplaçant (1) par :

$$(2) \quad \forall \varepsilon > 0, \forall \eta > 0, \exists N_{\varepsilon, \eta} \text{ tq } N \geq N_{\varepsilon, \eta} \Rightarrow E_N \|T_N - g_N(Y(\varphi(N)))\|^2 < \varepsilon.$$

Autrement dit,  $E_N \|T_N - g_N(Y(\varphi(N)))\|^2 \rightarrow 0$  lorsque  $N \rightarrow +\infty$ . Ici,  $E_N$  désigne l'**espérance mathématique** calculée avec le plan  $\Pi_{\varphi(N)}$ .