

MÉTHODE PAR CAPTURE ET LIBÉRATION (B3, M6)

(17 / 06 / 2020, © Monfort, Dicostat2005, 2005-2020)

(i) Une **méthode par capture et libération** est une méthode de **sondage** visant l'estimation du cardinal d'un **ensemble** fini d'éléments (**population**) : ces éléments sont, en général, des **unités statistiques** (**unité de sondage**, **unité expérimentale**) que l'on ne peut (ou ne veut) recenser dans leur ensemble (cf **recensement**).

Cette méthode procède en quatre étapes :

(a) **prélèvement** (capture) d'un **échantillon** d'unités ;

(b) « **marquage** » des unités prélevées (ie attribution d'une « **identité** » ou d'un **mode de repérage** : baguage, émetteur d'ondes, etc) ;

(c) **relâche** (libération) des unités marquées ;

(d) enfin, après une certaine **période d'attente**, **nouveau prélèvement** d'un échantillon.

La méthode de base suppose notamment :

(a) que le dernier échantillon prélevé contient des unités des deux types (donc certaines des unités précédemment marquées), ce qui suppose que la taille d'échantillon est suffisante par rapport à celle de la population ;

(b) que le délai d'attente n'est ni trop court (mélange par brassage insuffisant entre unités hétérogènes), ni trop long dans le cas d'une population biologique ou écologique (variations de population dues à des naissances, à des décès ou à des migrations).

On peut ainsi évaluer eg l'**effectif** total d'une **population** dont le recensement peut poser problème : ainsi (écologie), les animaux aquatiques, terrestres, arboricoles ou aériens se déplacent indépendamment des frontières institutionnelles dans l'**espace** (zones d'étude, frontières étatiques) et le suivi de leur population en est facilité par marquage (bagues, émetteurs, etc).

(ii) Soit Ω (avec $\text{Card } \Omega = M$) l'**ensemble** considéré, A le premier échantillon (avec $\text{Card } A = N_A$), qui est marqué, et B le second échantillon (avec $\text{Card } B = N_B$). On note N_B' le nombre d'éléments (unités) marqué(e)s de B, avec $0 \leq N_B' \leq \min(N_A, N_B)$. On suppose que chaque échantillon est un **échantillon aléatoire** et l'on veut estimer M.

(iii) Un **estimateur** de M est donné par :

$$(1) \quad M^* = (N_B' + 1)^{-1} \cdot (N_B + 1) \cdot N_A .$$

Par suite, si A est prélevé de façon exhaustive, ie si A est un **échantillon sans remise** des unités tirées (cf **tirage exhaustif**), on montre que :

(a) si B est prélevé avec remise (**échantillon avec remise**) :

$$(2) \quad E M^* = \{1 - (1 - (N_A / M))^{N(B) + 1}\} \cdot M \quad (\text{estimateur biaisé}),$$

où $N(B)$ désigne l'entier N_B . Le biais est faible si $N_A \gg 0$;

(b) si B est prélevé sans remise :

$$(3) \quad E M^* = \begin{cases} (N_A + 1)^{-1} \cdot N_A \cdot (M + 1), & \text{si } N_A + N_B \geq M, \\ (N_A + 1)^{-1} \cdot N_A \cdot \{1 - (C_1 / C_2)\} \cdot (M + 1), & \text{si } N_A + N_B \leq M - 1, \end{cases}$$

où $C_1 = C_{M - N(A)}^{N(B) + 1}$, $C_2 = C_{M + 1}^{N(B) + 1}$, et où, par commodité, $N(A)$ désigne l'entier N_A et $N(B)$ l'entier N_B .

(iv) Une variante de la méthode consiste à fixer a priori le nombre N_B' et à prélever l'échantillon de taille N_B suffisante. Une estimateur de M est alors donné par :

$$(4) \quad M^{**} = (N_B')^{-1} \cdot N_B \cdot N_A.$$

Si A est prélevé de façon exhaustive (ie sans remise des unités), on montre que :

(a) si B est prélevé avec remise, $E M^{**} = M$ (**estimateur sans biais**) ;

(b) si B est prélevé sans remise, $E M^{**} = (N_A + 1)^{-1} \cdot N_A \cdot M$ (estimateur biaisé). Ce biais est donc faible si $N_A \gg 0$.

(v) Le rapport $L = N_B' / N_A$, qui intervient dans la définition des estimateurs M^* ou M^{**} , est appelé **indice de F.C. LINCOLN**.

(vi) Ces méthodes de capture et relâche s'étendent, non seulement à des cardinaux d'unités, mais aussi à des valeurs correspondantes (**variables** mesurées sur les unités).

Ainsi, dans le cas d'un **caractère** scalaire, ie d'une **va** $\eta : \Omega \mapsto \mathbf{R}$, le total $T_M = \sum_{\omega \in \Omega} \eta(\omega)$ de ce caractère dans la population peut être estimé à l'aide eg la **va** (ou **statistique**) :

$$(5) \quad T_M^* = \{\sum_{\omega \in B'} \eta(\omega)\}^{-1} \cdot \{\sum_{\omega \in B} \eta(\omega)\} \cdot \sum_{\omega \in A} \eta(\omega),$$

où B' est l'ensemble des éléments de B qui sont marqués (avec $\text{Card } B' = N_B'$).

(vii) En **théorie des sondages**, il est parfois utile de procéder par sondage (capture) et re-sondage (recapture), eg pour assurer un **chaînage temporel** du **dispositif d'observation** (cas d'échantillons partiellement renouvelés) (cf **renouvellement, sondage renouvelé, système d'observation**).