

ESTIMATEUR DE HORVITZ - THOMPSON (H, M3, M4)

(16 / 06 / 2020, © Monfort, Dicostat2005, 2005-2020)

L'estimateur de HORVITZ - THOMPSON est une notion importante généralement associée à un **plan de sondage**. La notion est présentée dans le cas d'un **sondage simple**.

(i) Soit Ω une **population** finie $\{\omega_1, \dots, \omega_M\}$ et Π un plan **sondage sans remise** dans Ω . On suppose que la **variable** étudiée est un **vecteur aléatoire** $\eta : \Omega \mapsto \mathbf{R}^G$.

Soit $A \in \mathcal{F}_N$ un **échantillon sans remise** de taille N . On note :

(a) $Y = (Y_1, \dots, Y_M)$, avec $Y_m = \eta(\omega_m)$, $\forall m \in N_M^*$, les **observations** (ou **mesures**) effectuées sur Ω ;

(b) $y = (y_1, \dots, y_N)$, avec $y_n = \eta(a_n)$, $\forall n \in N_N^*$ tq $a_n \in A$, les observations analogues effectuées sur A ;

(c) $T = \sum_{m=1}^M Y_m = e_M' Y$ le **total** inconnu à estimer, défini sur Ω .

L'estimateur de D.G. HORVITZ - D.J. THOMPSON de T est défini comme l'estimateur linéaire (en y) suivant :

$$(1) \quad T_N = t_N(y) = \sum_{n=1}^N \alpha_n \cdot y_n = \sum_{m=1}^M \alpha_m \cdot Y_m \cdot \mathbf{1}_A(\omega_m)$$

(où $\mathbf{1}_A$ est une **variable de CORNFIELD**). On suppose aussi que T_N est tq :

$$(2) \quad \alpha_m = \pi_m = \Pi(A \text{ f } \omega_m),$$

où π_m désigne la **probabilité d'inclusion** de l'unité ω_m dans A (ie la probabilité que l'échantillon aléatoire A contienne l'unité donnée ω_m), ie :

$$(3) \quad \pi_m = \Pi(A \ni \omega_m),$$

où le symbole \ni est un symbole de contenance : $A \ni \omega_m \Leftrightarrow \omega_m \in A$.

(ii) On appelle **sondage de D.G. HORVITZ - D.J. THOMPSON** le **plan de sondage** défini par le couple (Π, t_N) précédent.

(iii) Par construction, T_N est à la fois un estimateur linéaire et un **estimateur sans biais** de T . Sa **matrice des covariances** s'explicite selon :

$$(4) \quad V T_N = \sum_{m=1}^M \pi_m^{-1} (1 - \pi_m) Y_m Y_m' + \sum_{l=1}^M \sum_{m=1, m \neq l}^M (\pi_l \pi_m)^{-1} (\pi_{lm} - \pi_l \pi_m) Y_l Y_m',$$

où :

$$(5) \quad \pi_{lm} = \Pi \{(\omega_l, \omega_m) \in A^2\}$$

est la probabilité d'inclusion des unités données ω_l et ω_m ($m \neq l$) dans l'échantillon A.

Cette **dispersion** $V T_N$ est estimée sans biais par :

$$(6) \quad v(T_N) = (1/2) \sum_{\alpha=1}^N \sum_{\beta=1}^N (\beta \neq \alpha) \pi_{\alpha\beta}^{-1} (\pi_{\alpha} \pi_{\beta} - \pi_{\alpha\beta}) D_{\alpha\beta} D_{\alpha\beta}',$$

expression dans laquelle $D_{\alpha\beta} = (y_{\alpha} / \pi_{\alpha}) - (y_{\beta} / \pi_{\beta})$ ($\forall \beta \neq \alpha$).