

VARIABLE DE CORNFIELD (C1, M3)

(09 / 10 / 2020, © Monfort, Dicostat2005, 2005-2020)

La notion de **variable de CORNFIELD** intervient notamment en **théorie des sondages**, eg dans le cas d'un **sondage exhaustif**.

(i) Soit $\Omega = \{\omega_1, \dots, \omega_M\}$ une **population** finie et $A = \{a_1, \dots, a_N\}$ un **échantillon** de taille N extrait de Ω selon un **plan de sondage** Π .

On appelle **variable de J. CORNFIELD** attachée à une **unité de sondage** ω_m de Ω la **variable indicatrice** c_m tq $c_m = 1$ si $\omega_m \in A$ et $c_m = 0$ sinon.

Autrement dit :

$$(1) \quad c_m = \mathbf{1}_A(\omega_m) = \begin{cases} 1 & \text{si } \omega_m \in A, \\ 0 & \text{si } \omega_m \notin A, \end{cases}$$

où $\mathbf{1}_A : \Omega \mapsto \{0, 1\}$ est la variable indicatrice associée à l'échantillon A ($\mathbf{1}_A$ est donc aléatoire parce que A est tiré dans Ω selon le plan Π).

(ii) Si $(\mathcal{Y}, \mathcal{G})$ est un **espace d'observation** et $\eta : \Omega \mapsto \mathcal{Y}$ la variable étudiée (**caractère** associé à chaque unité), on pose :

$$(2) \quad \begin{aligned} Y &= (Y_1, \dots, Y_M), & \text{avec } Y_m &= \eta(\omega_m) (\forall m), \\ y &= (y_1, \dots, y_N), & \text{avec } y_n &= \eta(a_n) (\forall n). \end{aligned}$$

Par suite, si l'on pose $c = (c_1, \dots, c_M)$, le M -uplet c est aléatoire puisqu'il dépend de A , qui est un échantillon (d'unités) aléatoire. La **loi de probabilité** de c détermine donc celle du caractère η observé sur l'échantillon A , ie détermine la loi de y .

(iii) Certaines **caractéristiques** « empiriques » (aléatoires) de A peuvent souvent être exprimées à partir de (1). Ainsi, lorsque $(\mathcal{Y}, \mathcal{G}) = (\mathbf{R}, \mathcal{B}_{\mathbf{R}})$ (caractère numérique scalaire), on peut exprimer (la sommation portant sur la population) :

(a) la **moyenne empirique** \bar{y}_N selon :

$$(3) \quad \bar{y}_N = N^{-1} \cdot \sum_{n=1}^N y_n = (\sum_{m=1}^M c_m)^{-1} \cdot \sum_{m=1}^M c_m Y_m,$$

avec $\sum_{m=1}^M c_m = \sum_{m=1}^M \mathbf{1}_A(\omega_m) = N$;

(b) la **variance empirique** selon :

$$(4) \quad s_N^2 = (N-1)^{-1} \sum_{n=1}^N (y_n - \bar{y}_N)^2 = (N-1)^{-1} \sum_{m=1}^M c_m (Y_m - \bar{y}_N)^2,$$

où \bar{y}_N est défini en (3).

Dans le cas où A est un échantillon sans remise (ie $A \in \mathcal{J}_N$), on établit que :

$$e_M' c = N,$$

$$(5) \quad E c_m = E c_m^2 = N / M \quad (m = 1, \dots, M),$$

$$E c_i c_m = M^{-1} (M-1)^{-1} N (N-1) \quad (\text{si } m \neq i).$$

On en déduit les formules classiques :

$$(6) \quad E \bar{y}_N = \bar{Y} \quad (\text{moyenne théorique, ie moyenne sur la population}),$$

$$V \bar{y}_N = N^{-1} (N-1)^{-1} (M-N) \cdot \sigma^2,$$

où $\sigma^2 = S_M^2 = M^{-1} \cdot \sum_{m=1}^M (Y_m - \bar{Y}_M)^2$ est la **variance** théorique (non corrigée).