

## MÉTHODE DES MOINDRES CARRÉS GÉNÉRALISÉS (H3, J1)

(02 / 05 / 2020, © Monfort, Dicostat2005, 2005-2020)

La **méthode des moindres carrés généralisés** est une méthode générale d'estimation des paramètres d'un **modèle de régression**, linéaire ou non, à **perturbation** additive. Elle consiste à minimiser une **distance** (ou une **norme**) euclidienne entre la **variable endogène**  $y \in \mathbf{R}^N$  et le terme « certain »  $z$  (**espérance**) de la **régression** :  $z$  est astreint à parcourir une **partie** spécifiée de l'**espace d'observation**.

Cette méthode généralise la **méthode des moindres carrés ordinaires**. Elle s'analyse aussi comme une application du théorème de la projection dans un **espace de HILBERT** (cf **théorème de la projection orthogonale**).

(i) Ainsi,  $\mathbf{R}^N$  étant l'**espace d'observation** ambiant, la **méthode des moindres carrés généralisés (mcg)** (de A.C. AITKEN) appliquée au modèle de régression :

$$(1) \quad y = z + u, \quad \text{avec } E u = 0,$$

consiste, en supposant que  $\Sigma \in S_N(\mathbf{R})$  est une **matrice définie positive** ( $\Sigma \geq 0$ ), à minimiser la distance suivante :

$$(2) \quad \varphi_{\Sigma}(z) = \|y - z\|_{\Sigma}^2 = (y - z)' \Sigma^{-1} (y - z)$$

pr à  $z \in \mathcal{V}$ , où  $\mathcal{V} \subset \mathbf{R}^N$  est une sous-variété donnée (ie spécifiée par le **statisticien**).

On note  $b_g^{\wedge}$  ou  $b^{\wedge}$ , ou parfois  $\beta_g$ , la **solution des moindres carrés généralisés** ainsi définie.

Si la régression est une **régression linéaire**,  $z = X b$  représente l'équation paramétrée par  $b$  de la variété linéaire, de dimension  $K$ ,  $\mathcal{V} \triangleleft \mathbf{R}^N$  (**sous-espace vectoriel**). La méthode revient à minimiser pr à  $b \in \mathbf{R}^K$  la **forme quadratique** (non homogène) :

$$(3) \quad q_{\Sigma}(b) = \|y - X b\|_{\Sigma}^2 = (y - X b)' \Sigma^{-1} (y - X b).$$

Le fondement de la méthode est ainsi associé à l'hypothèse (stochastique) du second ordre selon laquelle  $\Sigma$  n'est autre que la **matrice de dispersion** de la **perturbation aléatoire**  $u$  :

$$(4) \quad V u = V y = \Sigma > 0.$$

La méthode équivaut donc à minimiser la forme quadratique  $q_{\Sigma}(b) = (y - X b)' (V u)^{-1} (y - X b)$  dans la **métrique** définie par la matrice  $\Sigma$ .

La solution  $b_g^{\wedge}$  ou  $b^{\wedge}$  s'appelle **estimateur des moindres carrés généralisés (mcg)**, ou **estimateur de A.C. AITKEN - C.F. GAUSS - A.A. MARKOV**, du paramètre  $b$ .

Il existe toujours un nombre réel  $\sigma > 0$  tq  $\Sigma = \sigma^2 \cdot \Omega$ , où  $\Omega$  est une matrice définie positive ( $\Omega > 0$ ). La méthode des moindres carrés ordinaires (mco) correspond au cas où  $\Omega = I_N$ . On suppose alors que (cf **trace**) :

$$(5) \quad \text{tr } \Omega = \text{rg } \Sigma = N.$$

(ii) Dans le cas d'un modèle de régression linéaire, on montre que :

(a) si  $\Omega$  est connue et régulière et si  $\text{rg } X = K$ , la solution de (2), appelée **estimateur des moindres carrés généralisés** (mcg) de  $b$ , est donnée par :

$$(6) \quad b_g^\wedge = (X' \Omega^{-1} X)^{-1} X' \Omega^{-1} y.$$

Cette solution vérifie les propriétés suivantes :

(a)<sub>1</sub>  $E b_g^\wedge = b$  (**estimateur sans biais**) (cf aussi **biais**) ;

(a)<sub>2</sub>  $V b_g^\wedge = (X' \Sigma^{-1} X)^{-1} = \sigma^2 (X' \Omega^{-1} X)^{-1}$  (**matrice de dispersion**) ;

(a)<sub>3</sub> ( $b_g^\wedge$  vérifie) le **théorème de AITKEN-GAUSS-MARKOV** ;

(a)<sub>4</sub> si l'on pose  $y_g^\wedge = X b_g^\wedge = z_g^\wedge$  et  $u_g^\wedge = y - y_g^\wedge$ , la **statistique** :

$$(7) \quad (\sigma^2)_g^\wedge = (u_g^\wedge' \Omega^{-1} u_g^\wedge) / (N - K)$$

constitue un **estimateur sans biais** de  $\sigma^2$  (ie  $E (\sigma^2)_g^\wedge = \sigma^2$ ) ;

(a)<sub>5</sub> l'estimateur des mcg estimé sur le modèle :

$$(8) \quad y = X b + u, \quad \text{avec } E u = 0 \text{ et } V u = \Sigma = \sigma^2 \cdot \Omega,$$

est identique à l'estimateur des mco du **modèle « sphéricisé »** suivant :

$$(9) \quad y^\circ = X^\circ b + u^\circ, \quad \text{avec } E u^\circ = 0 \text{ et } V u^\circ = \sigma^2 I_N,$$

où  $y^\circ = \Omega^{-1/2} y$ ,  $X^\circ = \Omega^{-1/2} X$  et  $u^\circ = \Omega^{-1/2} u$  ;

(a)<sub>6</sub> si  $u \sim \mathcal{N}_N(0, \sigma^2 \Omega)$  (**loi normale multidimensionnelle** centrée), l'**estimateur du maximum de vraisemblance** de  $(b, \sigma^2)$  n'est autre que  $(b_g^\wedge, (\sigma^2)_{gc}^\wedge)$ , avec  $(\sigma^2)_{gc}^\wedge = \{N / (N - K)\} (\sigma^2)_g^\wedge$  (**variance « corrigée »**) ;

(a)<sub>7</sub> on a :

$$(10) \quad e_N' u_g^\wedge = 0 \text{ (P-p.s.)} \Leftrightarrow \Omega e_N \in \text{Im } X.$$

(b) si  $\Omega$  est inconnue et si l'on estime  $b$  à l'aide de l'**estimateur des mco**  $b^\wedge$  (au lieu de l'**estimateur des mcg**  $b_g^\wedge$ ), alors :

$$(11) \quad b^\wedge = b_g^\wedge \Leftrightarrow \text{Im } (\Omega X) \subset \text{Im } X.$$

Par suite, l'**efficacité relative** (scalaire) de  $\hat{b}$  pr à  $\hat{b}_g$  vaut :

$$(12) \quad e_N(\hat{b} / \hat{b}_g) = \text{Dét}(V \hat{b}_g) / \text{Dét}(V \hat{b}) = |X' X|^2 / (|X' \Omega^{-1} X| \cdot |X' \Omega X|) ;$$

(iii) Si  $\Omega$  est inconnue (cas général), plusieurs procédés d'estimation de  $b$  sont possibles :

a) la **méthode des mco** (cf infra). Celle-ci semble d'autant plus « efficace » que la « distance » entre  $\Omega$  et  $I_N$  (ou celle de  $\Sigma$  et  $\sigma^2 I_N$ ) est moindre ;

b) la **méthode du maximum de vraisemblance**. Celle-ci permet d'estimer le couple  $(b, \Sigma)$  dans lequel  $\Sigma$  joue le rôle de **paramètre importun**. Cette matrice dépend seulement de  $N(N+1)/2$  paramètres scalaires distincts au plus ;

c) la **méthode des moindres carrés quasi-généralisés** ;

d) une **méthode à distance minimale** (cf aussi **estimateur à distance minimum, méthode de moindre norme**).

(iv) Des considérations analogues aux précédentes peuvent être développées pour un modèle de **régression non linéaire** (pr à  $b$ ). On minimise alors (pr à  $b$ ) l'expression suivante :

$$(13) \quad q_\Sigma(b) = \|y - F(b)\|_\Sigma^2 = (y - F(b))' \Sigma^{-1} (y - F(b)).$$