

## RÉGRESSIONS MULTIPLES (J9)

(09 / 01 / 2020, © Monfort, Dicostat2005, 2005-2020)

L'étude simultanée de plusieurs **modèles de régression apparemment sans relation** (A. ZELLNER) est parfois préférable à leur étude séparée : on peut alors prendre en compte des « **simultanités** », ie des **corrélations** éventuelles entre les **perturbations aléatoires** de ces modèles.

(i) Soit,  $\forall g \in \mathbf{N}_G^*$  :

$$(1) \quad y(g) = X(g) b(g) + u(g), \quad \text{avec } E u(g) = 0, \quad V u(g) = s_g^2 I_N,$$

un **modèle de régression linéaire** multiple, exprimé dans l'**espace des observations**, et dans lequel  $u(g)$  et  $y(g)$  sont des **va** à valeurs dans  $\mathbf{R}^N$  (même ensemble de valeurs),  $X(g) \in M_{NK(g)}(\mathbf{R})$  (avec  $K_g \geq 1$ ) et  $b(g) \in \mathbf{R}^{K(g)}$  est un paramètre d'intérêt (où  $K(g)$  désigne  $K_g$ ).

La n-ième équation (observation) de l'équation vectorielle (1) s'écrit donc sous forme bi-indicée (modèle à deux **indices**, n et g), ie :

$$(2) \quad y_n(g) = X_n(g) b(g) + u_n(g),$$

où  $X_n(g) = [x_{n1}(g), \dots, x_{nK(g)}(g)]$  est la n-ième ligne de  $X(g)$ .

La prise en compte de corrélations éventuelles entre les  $u(g)$  (donc entre les  $y(g)$ ) peut s'effectuer en complétant la **spécification** (1) ou (2) à l'aide d'une hypothèse tq :

$$(3) \quad C(u_\alpha(g), u_\beta(h)) = \delta_{\alpha\beta} \sigma_{gh}, \quad \forall (g, h) \text{ et } \forall (\alpha, \beta).$$

où  $\delta_{\alpha\beta}$  désigne le **symbole de KRONECKER**. Autrement dit, les perturbations relatives à une même observation  $\beta = \alpha = n$  sont seules corrélées.

(ii) L'écriture d'ensemble du modèle précédent s'obtient par « empilement » des équations (1), d'où la forme suivante, appelée **modèle de régressions multiples** (termes exprimés au pluriel), ou **modèle à équations sans relation apparente** :

$$(4) \quad y = X b + u, \quad \text{avec } E u = 0, \quad V u = \Sigma \otimes I_N,$$

où  $\Sigma = (\sigma_{gh})_{(g,h)} \in S_G(\mathbf{R})$  (**matrice symétrique**, supposée être une **matrice définie positive**),  $A \otimes B$  désigne le produit tensoriel des matrices A et B (cf **produit tensoriel algébrique**) et :

$$(5) \quad \begin{array}{lll} y = (y(1) \text{ /// } y(G))', & X = (X(1) \text{ /// } X(G))' & \text{(observables),} \\ b = (b(1) \text{ /// } b(G))', & (u(1) \text{ /// } u(G))' & \text{(inobservables),} \end{array}$$

où /// représente des sauts de lignes ou de colonnes, ie :

$$y = \begin{pmatrix} y(1) \\ \vdots \\ y(g) \\ \vdots \\ y(G) \end{pmatrix}, \quad X = \begin{pmatrix} X(1) & 0 & \dots & 0 \\ & \ddots & & \\ & & & \\ 0 & 0 & \dots & X(G) \end{pmatrix}, \quad b = \begin{pmatrix} b(1) \\ \vdots \\ b(g) \\ \vdots \\ b(G) \end{pmatrix}, \quad u = \begin{pmatrix} u(1) \\ \vdots \\ u(g) \\ \vdots \\ u(G) \end{pmatrix}$$

(iii) La forme (4) n'est ainsi autre que celle d'un modèle de régression linéaire multiple, assorti d'une hypothèse de **dispersion** non scalaire.

Un tel modèle peut donc s'analyser (estimation, tests) à l'aide de méthodes usuelles : **méthode de moindres carrés**, **méthode du maximum de vraisemblance**, etc. Le premier type de méthodes permet de calculer :

(a) soit l'**estimateur des moindres carrés ordinaires**  $\hat{b} = (X' X)^{-1} X' y$  de  $b$ , avec  $V \hat{b} = (X' X)^{-1} X' (\Sigma \otimes I_N) X (X' X)^{-1}$  ;

(b) soit l'**estimateur des moindres carrés généralisés**  $\hat{b}_g = \{X' (\Sigma^{-1} \otimes I_N) X\}^{-1} X' (\Sigma^{-1} \otimes I_N) y$  de  $b$ , avec  $V \hat{b}_g = \{X' (\Sigma^{-1} \otimes I_N) X\}^{-1}$ .

On montre que :

(a) si  $\Sigma$  est une **matrice diagonale**, alors  $\hat{b}_g = \hat{b}$  ;

(b) si  $X(g) = X(0)$ ,  $\forall g \in N_G^*$  (matrices identiques entre elles), on a encore  $\hat{b}_g = \hat{b}$ .

En général, cependant,  $\Sigma$  n'est pas connue et il est nécessaire de l'estimer (cf **méthode des moindres carrés généralisés**).

(iv) Le modèle de régressions multiples précédent {(4),(5)} contient un cas particulier important, celui du **modèle de régression multidimensionnel**, dans lequel  $X(g) = X(0)$ ,  $\forall g \in N_G^*$  (cf (iii) (b) ci-dessus).

(v) Certains résultats peuvent s'étendre :

(a) lorsque le nombre d'observations  $N$  peut différer d'une équation  $g$  décrite en (1) à une autre  $h$ , soit  $N_g$ ,  $\forall g \in N_G^*$  (même formalisme) ;

(b) en supposant les équations (1) non linéaires (pr aux paramètres  $b(g)$ ), ie :

$$(6) \quad y(g) = F_g(b(g)) + u(g), \quad \text{avec } E u(g) = 0, \quad V u(g) = \sigma_g^2 \cdot I_N.$$

(même démarche que pour une **régression non linéaire**).