

## RÉGRESSION AVEC OBSERVATIONS MANQUANTES (J1, J5)

Il peut arriver que **l'inférence statistique** doive se réaliser alors qu'il existe des lacunes dans l'ensemble des observations utilisées (cf **censure, lacune, observation manquante**). Cette **situation statistique** (résultant d'un « *effet de masque* » ou « *effet d'occultation* ») nécessite une adaptation des **procédures statistiques** habituelles, notamment les procédures d'estimation des paramètres.

Dans le cas, important en pratique, de la **régression**, la loi de probabilité de l'ensemble des variables qui interviennent (loi multivariée) génère des « observations » de ces variables, dont certaines sont réellement observées, d'autres non.

On considère une **structure statistique**  $(\Omega, \mathcal{F}, \mathcal{P})$ , un **espace d'observation**  $(\mathcal{Y}_0, \mathcal{G}_0)$ , une **va** endogène  $\eta : \Omega \mapsto \mathcal{Y}_0$  et le **modèle d'échantillonnage**  $(\mathcal{Y}_0^N, \mathcal{G}_0^{\otimes N}, P^N)$  qui en résulte, où  $y : \Omega \mapsto \mathcal{Y}_0^N$  est le N-uple constitué des observations de  $\eta$ .

On note le **modèle de régression multiple** standard usuel selon :

$$(1) \quad E y = X b, \quad \text{avec } V y = \sigma^2 \cdot I_N,$$

où l'on suppose que  $\mathcal{Y}_0 = \mathbf{R}$ ,  $\mathcal{X} = M_{N \times K}(\mathbf{R})$  et  $b \in \mathbf{R}^K$ .

On dit que ce modèle représente une **régression avec observations manquantes**, ou **régression en présence d'observations manquantes**, ssi il existe une **partie** (en général connue)  $S_y$  (resp  $S_k$ ) de  $\mathbf{R}^N$  tq  $y_n$  (resp  $x_k$ ) est observée ssi  $y \in S_y$  (resp ssi  $x_k \in S_k$ ), non observée sinon (où  $k \in N_k^*$ ).

Dans le cas le plus simple, la matrice  $X = [x_1 \dots x_K]$  (vecteurs colonnes) est entièrement observée. On peut (à une permutation sur les observations  $(X_n, y_n)$  près) écrire :

$$(2) \quad y = X b + u,$$

où l'on note  $y = (y^1 \parallel y^2)^T$  et  $X = (X^1 \parallel X^2)^T$ , ie :

$$y = \begin{pmatrix} y^1 \\ y^2 \end{pmatrix}, \quad X = \begin{pmatrix} X^1 \\ X^2 \end{pmatrix}$$

où  $y^1$  est un vecteur aléatoire observé (observations présentes) et  $y^2$  un vecteur aléatoire non observé (observations manquantes, ou lacunes).

La **méthode des moindres carrés ordinaires** (mco) appliquée au modèle (2) consiste à résoudre le programme mathématique suivant (cf **programmation mathématique**) :

$$(3) \quad \min \|y - X b\|, \quad \text{sous } b \in \mathbf{R}^K \text{ et } y^2 \in \mathbf{R}^{N(2)},$$

où l'on suppose que  $y_1 \in \mathbf{R}^{N(1)}$ ,  $y_2 \in \mathbf{R}^{N(2)}$  et  $N_1 + N_2 = N$  (en notant, par commodité,  $N(i)$  pour désigner  $N_i$ ). Dans ce programme,  $y_2$  est considéré comme un paramètre supplémentaire (**paramètre importun**) à estimer.

(i) la **méthode de K.D. TOCHER** comporte trois étapes :

(a) estimation de  $b$  par la **méthode des moindres carrés ordinaires** sur le modèle avec mise à zéro de  $y_2$  :

$$(4) \quad (y^1 \parallel 0)^T = X b + u,$$

ie :

$$\begin{pmatrix} y^1 \\ 0 \end{pmatrix} = X b + u$$

d'où l'estimateur  $b_0^\wedge = (X^1 X^1)^{-1} (X^1)^T y^1$  ;

(b) calcul de l'« estimateur » (ou prévision) suivant(e) de  $y^2$  :

$$(5) \quad (y^2_0)^\wedge = \{I - X^2 (X^1 X^1)^{-1} (X^1)^T\} X^2 b_0^\wedge ;$$

(c) estimation de  $b$  par la **méthode des mco** sur le modèle (après estimation des lacunes  $y^2$ ) :

$$(6) \quad (y^1 \parallel (y^2_0)^\wedge)^T = X b + u,$$

ie :

$$\begin{pmatrix} y^1 \\ y^2_0 \end{pmatrix} = X b + u$$

ce qui fournit un pseudo-**estimateur des mco**  $b_{-}^\wedge$  de  $b$ .

Le nombre de **degrés de liberté** de la **forme quadratique**  $\|y - X b_{-}^\wedge\|^2$  ainsi obtenue est donc  $(N - N^2) - K$ . C'est ce nombre qui est à prendre en compte (eg pour effectuer des tests).

(ii) Dans le cas plus général où  $X$  est partiellement observé, on peut (à une **permutation** près sur les observations) écrire (1) sous la forme :

$$(7) \quad y = X b + u, \quad \text{avec } y = (y^1 \parallel y^2 \parallel y^3 \parallel y^4)^T \text{ et } X = (X^1 \parallel X^2 \parallel X^3 \parallel X^4)^T,$$

ie :

$$y = \begin{pmatrix} y^1 \\ y^2 \\ y^3 \\ y^4 \end{pmatrix}, \quad X = \begin{pmatrix} X^1 \\ X^2 \\ X^3 \\ X^4 \end{pmatrix}$$

Sous cette forme,  $y^1$  et  $y^3$  sont observées et  $y^2$  et  $y^4$  sont manquantes, tandis que (alternativement)  $X^1$  et  $X^2$  sont observées et  $X^3$  et  $X^4$  sont manquantes.

La **méthode de A.A. AFIFI - R.M. ELASHOFF** permet d'estimer (7) en trois étapes :

(a) estimation de  $b$  par la méthode des mco sur le modèle :

$$(8) \quad (y^1 \quad 0 \quad 0 \quad y^3 \quad 0)' = (X^1 \quad X^2 \quad 0 \quad 0)' b + u,$$

ie :

$$\begin{pmatrix} y^1 \\ 0 \\ y^3 \\ 0 \end{pmatrix} = \begin{pmatrix} X^1 \\ X^2 \\ 0 \\ 0 \end{pmatrix} b + u$$

d'où un estimateur, encore noté  $b_0^{\wedge}$ , de b (après mise à zéro de  $y^2$  et  $y^4$ ) :

(b) calcul de l'« estimateur »  $(y_0^2)^{\wedge}$  de  $y^2$  à l'aide de la formule (5) précédente, dans laquelle X est remplacée par la matrice du second membre de (8) (ie après mise à zéro de  $X^3$  et  $X^4$ ) :

(c) estimation de b par la méthode des mco sur le modèle :

$$(9) \quad (y^1 \quad (y_0^2)^{\wedge} \quad 0 \quad 0 \quad y^3 \quad 0)' = (X^1 \quad X^2 \quad 0 \quad 0)' b + u,$$

ie :

$$\begin{pmatrix} y^1 \\ \widehat{y_0^2} \\ y^3 \\ 0 \end{pmatrix} = \begin{pmatrix} X^1 \\ X^2 \\ 0 \\ 0 \end{pmatrix} b + u$$

(iii) Dans les modèles précédents, d'autres méthodes d'estimation de b généralement utilisées sont fondées sur la maximisation de la [vraisemblance](#), les observations manquantes figurant dans celle-ci jouant le rôle de [paramètres incidents](#) ou de [paramètres fantômes](#) (cf [paramètre importun](#)).

La [méthode du maximum de vraisemblance](#) ainsi adaptée doit, pour l'étude de ses propriétés asymptotiques, être assorties d'hypothèses tq la relation entre le nombre d'observations manquantes et le nombre total d'observations.