

All dyn - stat - dynamique = { residual -  $y^1, y^2$ , residual -  $y^1 - y^2, y^3$  }

1874

~~Exercice~~

Sup

avec  $\varepsilon_t \sim iid(0, \sigma_\varepsilon^2)$ ,  $\forall t \in \{1, \dots, T\}$  et  $t=1, \dots, T$

(1) On estime le modèle

$$y_t = c + u_t$$

Calculons l'estimateur des MCO de c

$$\hat{c} = \arg \min_{\{c\}} \sum_{t=1}^T (y_t - c)^2$$

on peut le programmer, puis résoudre  
 on, on trouve

$$\hat{c} = \frac{1}{T} \sum_{t=1}^T y_t = \bar{y}$$

(2) Calculons l'espérance de l'estimateur des MCO :

$$E[\hat{c}] = \frac{1}{T} \sum_{t=1}^T E[\mu_1 + \mu_2 \mathbb{1}_{\{t > k\}} + \varepsilon_t]$$

$$E[\hat{c}] = \frac{1}{T} \sum_{t=1}^T \mu_2 + \frac{1}{T} \sum_{t=k+1}^T \mu_1$$

Car  $E[\varepsilon_t] = 0 \forall t$

$$\Leftrightarrow E[\hat{c}] = \mu_2 + \frac{T-k}{T} \mu_1 \neq \mu_1 \text{ ou } \mu_2$$

(3) Quand T tend vers l'infini l'espérance tend vers  $\mu_1 + \mu_2$ .

$$V[\hat{c}] = V\left[\frac{1}{T} \sum_{t=1}^T (\mu_1 + \mu_2 \mathbb{1}_{\{t > k\}} + \varepsilon_t)\right]$$

$$= V\left[\frac{1}{T} \sum_{t=1}^T \varepsilon_t\right]$$

car la partie déterministe est de variance nulle

$$= \frac{1}{T} V[\sum \varepsilon_t]$$

$$= \frac{1}{T} \sum_{t=1}^T V[\varepsilon_t]$$

car  $\varepsilon_t$  iid

$$= \frac{\sigma_\varepsilon^2}{T} \xrightarrow{T \rightarrow \infty} 0$$

Ainsi lorsque T tend vers l'infini  $\hat{c}$  tend en probabilité vers  $\mu_1 + \mu_2$

~~Exercice~~

Sup

$$y_t = \mu_1 + \mu_2 \mathbb{1}_{\{t > k\}} + \varepsilon_t$$

avec  $\varepsilon_t \sim iid(0, \sigma_\varepsilon^2)$ ,  $t \in ]0, T]$  donc  $\hat{c}$  est une moyenne  $y_t = c + u_t$ . Comment le reporter de c ?

On a toujours  $C_T = \frac{1}{T} \sum_{t=1}^T y_t$ . Calculons l'espérance de l'estimateur des MCO :

$$E[C_T] = \frac{1}{T} \sum_{t=1}^T E[\mu_1 + \mu_2 \mathbb{1}_{\{t>T/2\}} + \varepsilon_t]$$

$$\Rightarrow E[C_T] = \mu_1 + \frac{1}{T} \sum_{t=[T/2]+1}^T \mu_2 \quad \text{car } E[\varepsilon_t] = 0$$

$$\Rightarrow E[C_T] = \mu_1 + \frac{T - [T/2]}{T} \mu_2$$

$$\Rightarrow \lim_{T \rightarrow \infty} E[C_T] = \mu_1 + (1-k)\mu_2$$

Le comportement de la variance reste identique puisque le seul changement est rapport à l'exercice 1 concerne la partie déterministe. Ainsi

$$C_T \xrightarrow{\text{prob}} \mu_1 + (1-k)\mu_2$$

Exercice 3

Soit le modèle empirique

$$y_i = \beta_0 + \beta_1 x_{1i} + \beta_2 x_{2i} + \dots + \beta_k x_{ki} + u_i$$

(1) Écrivons ce modèle matriciellement. On

pose  $Y = (y_1, y_2, \dots, y_N)'$  un vecteur  $N \times 1$

$x_{1i} = (1, x_{1i}, x_{2i}, \dots, x_{ki})$   $i = 1, \dots, N$   
des vecteurs  $1 \times (k+1)$

$X = (x_1', x_2', \dots, x_N')$  une matrice  $N \times (k+1)$

et  $u = (u_1, u_2, \dots, u_N)$  un vecteur  $N \times 1$

le modèle peut alors s'écrire de façon équivalente sous la forme

$$Y = X\beta + u \quad (*)$$

où  $\beta = (\beta_0, \beta_1, \dots, \beta_k)$  le vecteur  $(k+1) \times 1$

Remq Il est important de toujours bien vérifier les dimensions des matrices et vecteurs et que les membres de gauche et de droite de (\*) ont bien la même dimension.

(2) Calculons l'estimateur des MCO, celui si est obtenu la somme des carrés des

résidus

$$\hat{\beta}_N = \arg \min_{\beta} \|Y - X\beta\|$$

l'objectif est bien un scalaire

$$\hat{\beta}_N = \arg \min_{\beta} (Y - X\beta)'(Y - X\beta)$$

$$\stackrel{\text{ne dépend pas de } \beta}{=} \arg \min_{\beta} (Y'Y - Y'X\beta - \beta'X'Y + \beta'X'X\beta)$$

$$= \arg \min_{\beta} \beta'X'X\beta - Y'X\beta - \beta'X'Y$$

$$= \arg \min_{\beta} \beta'X'X\beta - 2\beta'X'Y$$

car  $Y'X\beta = (Y'X\beta)'$ , un scalaire est toujours égal à sa transposée!

Comment écrire le CNO? Nous devons dériver l'objectif (scalaire),

$$S(\beta) = \beta'X'X\beta - 2\beta'X'Y$$

par rapport à  $\beta \dots$

On a:

$$dS = d\beta'X'X\beta + \beta'X'X d\beta - 2d\beta'X'Y$$

variation infinitésimale de l'objectif

Toujours en exploitant le fait qu'un scalaire est invariant par transposition, on a encore

$$dS = d\beta'X'X\beta - d\beta'X'Y$$

$$\Rightarrow dS = (d\beta'X'X\beta - d\beta'X'Y) \times 2$$

$$\Rightarrow \frac{dS}{d\beta'} = 2(X'X\beta - X'Y)$$

Le CNO qui nous permet d'identifier l'estimateur des moindres carrés est donc:

$$X'X\hat{\beta} - X'Y = 0$$

$$\Leftrightarrow \hat{\beta} = (X'X)^{-1}X'Y$$

On suppose que  $X'X$  est une matrice de plein rang.

Explicitons le contenu de cette expression matricielle, en faisant apparaître les observations.

$$XY = \begin{pmatrix} 1 & 1 & 1 & \dots & 1 \\ x_{k1} & x_{k2} & x_{k3} & \dots & x_{kn} \\ x_{21} & x_{22} & x_{23} & \dots & x_{2n} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ x_{j1} & x_{j2} & x_{j3} & \dots & x_{jn} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ x_{k1} & x_{k2} & x_{k3} & \dots & x_{kn} \end{pmatrix} \begin{pmatrix} y_1 \\ y_2 \\ y_3 \\ \vdots \\ y_n \end{pmatrix}$$

$$\begin{aligned} \Rightarrow XY &= \begin{pmatrix} y_1 + y_2 + \dots + y_n \\ x_{11}y_1 + x_{12}y_2 + x_{13}y_3 + \dots + x_{1n}y_n \\ x_{21}y_1 + x_{22}y_2 + x_{23}y_3 + \dots + x_{2n}y_n \\ \vdots \\ x_{j1}y_1 + x_{j2}y_2 + x_{j3}y_3 + \dots + x_{jn}y_n \\ \vdots \\ x_{k1}y_1 + x_{k2}y_2 + x_{k3}y_3 + \dots + x_{kn}y_n \end{pmatrix} \end{aligned}$$

$$\Rightarrow XY = \begin{pmatrix} \sum_{i=1}^n y_i \\ \sum_{i=1}^n x_{1i}y_i \\ \sum_{i=1}^n x_{2i}y_i \\ \vdots \\ \sum_{i=1}^n x_{ji}y_i \\ \vdots \\ \sum_{i=1}^n x_{ki}y_i \end{pmatrix}$$

[1]

Pour  $XX'$  c'est la même chose.

$$XX' = \begin{pmatrix} 1 & 1 & 1 & \dots & 1 \\ x_{11} & x_{12} & \dots & x_{1n} \\ \vdots & \vdots & \ddots & \vdots \\ x_{j1} & x_{j2} & \dots & x_{jn} \\ \vdots & \vdots & \ddots & \vdots \\ x_{k1} & x_{k2} & \dots & x_{kn} \end{pmatrix} \begin{pmatrix} 1 & x_{11} & \dots & x_{1n} \\ x_{12} & x_{11}^2 & \dots & x_{1n}x_{11} \\ \vdots & \vdots & \ddots & \vdots \\ x_{j2} & x_{j1}x_{j2} & \dots & x_{jn}x_{j2} \\ \vdots & \vdots & \ddots & \vdots \\ x_{k2} & x_{k1}x_{k2} & \dots & x_{kn}x_{k2} \end{pmatrix}$$

$$\sum_{i=1}^n 1$$

$$\begin{aligned} \Rightarrow XX' &= \begin{pmatrix} \sum_{i=1}^n 1 & \sum_{i=1}^n x_{1i} & \dots & \sum_{i=1}^n x_{ni} \\ \sum_{i=1}^n x_{1i} & \sum_{i=1}^n x_{1i}^2 & \dots & \sum_{i=1}^n x_{1i}x_{ni} \\ \vdots & \vdots & \ddots & \vdots \\ \sum_{i=1}^n x_{ji} & \sum_{i=1}^n x_{ji}x_{1i} & \dots & \sum_{i=1}^n x_{ji}^2 \\ \vdots & \vdots & \ddots & \vdots \\ \sum_{i=1}^n x_{ki} & \sum_{i=1}^n x_{ki}x_{1i} & \dots & \sum_{i=1}^n x_{ki}^2 \end{pmatrix} \end{aligned}$$

[2]

Cette matrice est bien symétrique.

On obtient l'estimateur  $\hat{\beta}$  en regroupant les expressions explicites obtenues en [1] et [2].

(3) Demons tre une plus expression de  $\hat{\beta}$  dans le cas  $K=1$  (une covariable et une variable explicative). En appliquant ce que nous avons obtenu plus haut :

$$\hat{\beta} = \begin{pmatrix} N \sum_{i=1}^N x_{1i} \\ \sum_{i=1}^N y_i \\ \sum_{i=1}^N x_{1i}^2 \\ \sum_{i=1}^N x_{1i} y_i \end{pmatrix}^{-1} \begin{pmatrix} \sum_{i=1}^N y_i \\ \sum_{i=1}^N x_{1i} y_i \end{pmatrix}$$

Il nous faut inverser une matrice  $2 \times 2$   $(XX')_{1,1}$  et :

$$|XX'| = N \sum_{i=1}^N x_{1i}^2 - \left( \sum_{i=1}^N x_{1i} \right)^2$$

On peut montrer que ce déterminant est strictement positif dès lors que  $N$  est plus grand que 1 (et que les observations sont non nulles). Il suffit de montrer que

$$\frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N (x_{1i} - x_{1j})^2 = N \sum_{i=1}^N x_{1i}^2 - \left( \sum_{i=1}^N x_{1i} \right)^2$$

C'est une somme de carrés et toujours

positive, cela implique que le déterminant doit être positif

Preuve

$$\begin{aligned} \sum_{i=1}^N \sum_{j=1}^N (x_{1i} - x_{1j})^2 &= \sum_{i=1}^N \sum_{j=1}^N (x_{1i}^2 + x_{1j}^2 - 2x_{1i}x_{1j}) \\ &= \sum_{i=1}^N \left( \sum_{j=1}^N x_{1i}^2 \right) + \sum_{i=1}^N \left( \sum_{j=1}^N x_{1j}^2 \right) - 2 \sum_{i=1}^N \sum_{j=1}^N x_{1i}x_{1j} \\ &= 2N \sum_{i=1}^N x_{1i}^2 - 2 \left( \sum_{i=1}^N x_{1i}^2 + 2 \sum_{i=1}^N \sum_{j=1}^N x_{1i}x_{1j} \right) \\ &= 2N \sum_{i=1}^N x_{1i}^2 - 2 \left( \sum_{i=1}^N x_{1i} \right)^2 \end{aligned}$$

q.e.d.

Ainsi

$$(XX')^{-1} = \frac{1}{N \sum_{i=1}^N x_{1i}^2 - \left( \sum_{i=1}^N x_{1i} \right)^2} \begin{pmatrix} \sum_{i=1}^N x_{1i}^2 & - \sum_{i=1}^N x_{1i} \\ - \sum_{i=1}^N x_{1i} & N \end{pmatrix}$$

la transposée (la matrice est symétrique) de la matrice des covariables

Il nous reste à postmultiplier par  $X^T Y$ :

$$\hat{\beta} = \frac{1}{N \sum_{i=1}^N x_{it}^2 - \left( \sum_{i=1}^N x_{it} \right)^2} \begin{pmatrix} \sum_{i=1}^N x_{it}^2 & - \sum_{i=1}^N x_{it} \\ - \sum_{i=1}^N x_{it} & N \end{pmatrix} \begin{pmatrix} \sum_{i=1}^N y_i \\ \sum_{i=1}^N x_{it} y_i \end{pmatrix}$$

$$\hat{\beta} = \frac{1}{N \sum_{i=1}^N x_{it}^2 - \left( \sum_{i=1}^N x_{it} \right)^2} \begin{pmatrix} \sum_{i=1}^N y_i \sum_{i=1}^N x_{it}^2 - \sum_{i=1}^N x_{it} \sum_{i=1}^N x_{it} y_i \\ N \sum_{i=1}^N x_{it} y_i - \sum_{i=1}^N x_{it} \sum_{i=1}^N y_i \end{pmatrix}$$

$$\Rightarrow \hat{\beta} = \frac{1}{N \sum_{i=1}^N x_{it}^2 - \left( \sum_{i=1}^N x_{it} \right)^2} \begin{pmatrix} N \bar{y} \sum_{i=1}^N x_{it}^2 - N \bar{x} \sum_{i=1}^N x_{it} y_i \\ N \sum_{i=1}^N x_{it} y_i - N \bar{x}_n N \bar{y} \end{pmatrix}$$

Remarque 1

$$\sum_{i=1}^N (x_{it} - \bar{x}_n)^2 = \sum_{i=1}^N x_{it}^2 + N \bar{x}_n^2 - 2 \bar{x}_n \sum_{i=1}^N x_{it}$$

$$\Rightarrow \sum_{i=1}^N (x_{it} - \bar{x}_n)^2 = \sum_{i=1}^N x_{it}^2 - N \bar{x}_n^2$$

En simplifiant par  $N$ , il vient donc:

$$\hat{\beta} = \frac{1}{\sum_{i=1}^N (x_{it} - \bar{x}_n)^2} \begin{pmatrix} \bar{y} \sum_{i=1}^N x_{it}^2 - \bar{x}_n \sum_{i=1}^N x_{it} y_i \\ \sum_{i=1}^N x_{it} y_i - N \bar{x}_n \bar{y} \end{pmatrix}$$

Remarque 2

$$\begin{aligned} \sum_{i=1}^N (x_{it} - \bar{x}_n)(y_i - \bar{y}) &= \sum_{i=1}^N x_{it} y_i - \bar{y} \sum_{i=1}^N x_{it} - \bar{x}_n \sum_{i=1}^N y_i + N \bar{x}_n \bar{y} \\ &= \sum_{i=1}^N x_{it} y_i - 2 N \bar{y} \bar{x}_n + N \bar{x}_n \bar{y} \\ &= \sum_{i=1}^N x_{it} y_i - N \bar{x}_n \bar{y} \end{aligned}$$

On a donc:

$$\hat{\beta} = \frac{1}{\sum_{i=1}^N (x_{it} - \bar{x}_n)^2} \begin{pmatrix} \bar{y} \left( \sum_{i=1}^N (x_{it} - \bar{x}_n)^2 + N \bar{x}_n^2 \right) - \bar{x}_n \left( \sum_{i=1}^N (x_{it} - \bar{x}_n)(y_i - \bar{y}) + N \bar{x}_n \bar{y} \right) \\ \sum_{i=1}^N (x_{it} - \bar{x}_n)(y_i - \bar{y}) \end{pmatrix}$$

$$\hat{\beta} = \begin{pmatrix} \bar{y} - \bar{x}_2 \frac{\sum_{i=1}^N (x_i - \bar{x}_1)(y_i - \bar{y})}{\sum_{i=1}^N (x_i - \bar{x}_1)^2} \\ \frac{\sum_{i=1}^N (x_i - \bar{x}_1)(y_i - \bar{y})}{\sum_{i=1}^N (x_i - \bar{x}_1)^2} \end{pmatrix}$$

estimateur de la pente

On a finalement

$$y_i = \hat{\beta}_0 + \hat{\beta}_1 x_{1i} + \hat{u}_i \quad (*)$$

avec  $\hat{\beta}_1 = \frac{\sum_{i=1}^N (x_i - \bar{x}_1)(y_i - \bar{y})}{\sum_{i=1}^N (x_i - \bar{x}_1)^2}$

et  $\hat{\beta}_0 = \bar{y} - \hat{\beta}_1 \bar{x}_1$

(4) On déduit directement que la somme des résidus estimés est nulle. En effet, en sommant (\*) sur  $i=1, \dots, N$ , il vient :

$$\sum_{i=1}^N y_i = N \hat{\beta}_0 + \hat{\beta}_1 \sum_{i=1}^N x_{1i} + \sum_{i=1}^N \hat{u}_i$$

$$\Leftrightarrow \sum_{i=1}^N \hat{u}_i = \sum_{i=1}^N y_i - N \hat{\beta}_0 - \hat{\beta}_1 \sum_{i=1}^N x_{1i}$$

$$\Leftrightarrow \sum_{i=1}^N \hat{u}_i = N(\bar{y} - \hat{\beta}_0 - \hat{\beta}_1 \bar{x}_1)$$

= 0 par définition de  $\hat{\beta}_0$ .

~~Exercice 4~~ Soit le modèle empirique

$$y_t = a + bt + u_t \quad t=1, \dots, T$$

avec  $u_t \sim iid(0, \sigma^2)$ . On obtient les estimateurs de MCO de  $a$  et  $b$  en suivant les  $m$  étapes que nous l'exercice 3.

$$\begin{pmatrix} \hat{a} \\ \hat{b} \end{pmatrix} = \begin{pmatrix} T & \sum_{t=1}^T t \\ \sum_{t=1}^T t & \sum_{t=1}^T t^2 \end{pmatrix}^{-1} \begin{pmatrix} \sum_{t=1}^T y_t \\ \sum_{t=1}^T t y_t \end{pmatrix}$$

On voit que

$$\sum_{t=1}^T t = \frac{T(T+1)}{2} \quad \text{et} \quad \sum_{t=1}^T t^2 = \frac{T(2T+1)(T+1)}{6}$$

et donc on factorise par  $T$ :

$$\begin{pmatrix} \hat{a} \\ \hat{b} \end{pmatrix} = \begin{pmatrix} 1 & \frac{T+1}{2} \\ \frac{T+1}{2} & \frac{(2T+1)(T+1)}{6} \end{pmatrix}^{-1} \begin{pmatrix} \bar{y} \\ \frac{1}{T} \sum_{t=1}^T t y_t \end{pmatrix}$$

$$\begin{pmatrix} \hat{a} \\ \hat{b} \end{pmatrix} = \frac{12}{(T+1)(T-1)} \begin{pmatrix} \frac{(2T+1)(T+1)}{6} & -\frac{T+1}{2} \\ -\frac{T+1}{2} & 1 \end{pmatrix} \begin{pmatrix} \bar{y} \\ \frac{1}{T} \sum_{t=1}^T t y_t \end{pmatrix}$$

$$\begin{pmatrix} \hat{a} \\ \hat{b} \end{pmatrix} = \frac{12}{(T+1)(T-1)} \begin{pmatrix} \frac{(2T+1)(T+1)}{6} \bar{y} - \frac{T+1}{2T} \sum_{t=1}^T t y_t \\ \frac{1}{T} \sum_{t=1}^T t y_t - \frac{T+1}{2} \bar{y} \end{pmatrix}$$

Bof

exercice 4

l'estimateur de la constante (ou l'exercice 1) et

$$\hat{c}_T = \frac{1}{T} \sum_{t=1}^T y_t \equiv \bar{y}_T$$

Pour étudier les propriétés de cet estimateur ( $\hat{c}_T$  est-il un estimateur sans biais de  $\mu_0$ ?) on substitue la DGP

$$y_t = \mu_0 + \mu_1 t + \varepsilon_t$$

dans l'expression de l'estimateur:

$$\begin{aligned} \hat{c}_T &= \frac{1}{T} \sum_{t=1}^T (\mu_0 + \mu_1 t + \varepsilon_t) \\ &= \mu_0 + \mu_1 \frac{1}{T} \sum_{t=1}^T t + \frac{1}{T} \sum_{t=1}^T \varepsilon_t \\ &= \mu_0 + \mu_1 \frac{T+1}{2} + \bar{\varepsilon} \end{aligned}$$

Ainsi

$$E[\hat{c}_T] = \mu_0 + \mu_1 \frac{T+1}{2} \neq \mu_0$$

$\hat{c}_T$  n'est pas un estimateur sans biais de  $\mu_0$  (l'espérance à l'origine). Le biais diverge (malgré le fait) quand le nombre de réalisations ( $T$ ) tend vers l'infini. Ce résultat tient à la non stationnarité de la variable observée ( $\rightarrow$



parler du biais de variable omise en général et de l'hypothèse d'orthogonalité entre la variable omise et les variables incluses).

Exercice 5(1) Nous souhaitons montrer que :

$$\begin{pmatrix} A_{11} & A_{12} \\ A_{21} & A_{22} \end{pmatrix}^{-1} = \begin{pmatrix} A_{11}^{-1}(I + A_{12}B_{21}A_{11}^{-1}) & -A_{11}^{-1}A_{12}B \\ -BA_{21}A_{11}^{-1} & B \end{pmatrix}$$

avec  $B = (A_{22} - A_{21}A_{11}^{-1}A_{12})^{-1}$

on suppose que  $A_{11}$  et  $A_{22} - A_{21}A_{11}^{-1}A_{12}$  sont inversibles. Il y a deux façons (ou moins) de le faire, en montrant que

$$\begin{pmatrix} A_{11} & A_{12} \\ A_{21} & A_{22} \end{pmatrix}^{-1} \begin{pmatrix} A_{11} & A_{12} \\ A_{21} & A_{22} \end{pmatrix} = \begin{pmatrix} I & 0 \\ 0 & I \end{pmatrix}$$

ou en cherchant les matrices  $B_{11}, B_{12}, B_{21}$  et  $B_{22}$  telles que

$$\begin{pmatrix} B_{11} & B_{12} \\ B_{21} & B_{22} \end{pmatrix} \begin{pmatrix} A_{11} & A_{12} \\ A_{21} & A_{22} \end{pmatrix} = \begin{pmatrix} A_{11} & A_{12} \\ A_{21} & A_{22} \end{pmatrix} \begin{pmatrix} B_{11} & B_{12} \\ B_{21} & B_{22} \end{pmatrix} = \begin{pmatrix} I & 0 \\ 0 & I \end{pmatrix}$$

(1) Si  $A_{12} = 0$  et  $A_{21} = 0$  alors on dit que la matrice est bloquée diagonale et on a directement (en appliquant le résultat obtenu plus haut) :

$$\begin{pmatrix} A_{11} & 0 \\ 0 & A_{22} \end{pmatrix}^{-1} = \begin{pmatrix} A_{11}^{-1} & 0 \\ 0 & A_{22}^{-1} \end{pmatrix}$$

C'est une généralisation du résultat bien connu pour les matrices diagonales.

Exercice (1) Si les variables dans  $X_1$  sont orthogonales aux variables dans  $X_2$  alors par définition on doit avoir  $X_1'X_2 = 0$  et  $X_2'X_1 = 0$  (peu que la covariance est nulle). On a alors :

$$X'X = \begin{pmatrix} X_1'X_1 & X_1'X_2 \\ X_2'X_1 & X_2'X_2 \end{pmatrix} = \begin{pmatrix} X_1'X_1 & 0 \\ 0 & X_2'X_2 \end{pmatrix}$$

On peut alors appliquer le résultat sur

l'inversion des matrices bloc diagonales (question 2 de l'exercice 5) pour calculer  $\hat{\beta}_1$  et  $\hat{\beta}_2$

$$\begin{pmatrix} \hat{\beta}_1 \\ \hat{\beta}_2 \end{pmatrix} = (X'X)^{-1}Y$$

$$\Leftrightarrow \begin{pmatrix} \hat{\beta}_1 \\ \hat{\beta}_2 \end{pmatrix} = \begin{pmatrix} (X_1'X_1)^{-1} & 0 \\ 0 & (X_2'X_2)^{-1} \end{pmatrix} \begin{pmatrix} X_1'Y \\ X_2'Y \end{pmatrix}$$

$$\Leftrightarrow \begin{cases} \hat{\beta}_1 = (X_1'X_1)^{-1}X_1'Y \\ \hat{\beta}_2 = (X_2'X_2)^{-1}X_2'Y \end{cases}$$

Autrement dit si on a deux groupes de variables orthogonales, on peut faire deux estimations séparées (pour chaque groupe de variables  $X_1$  et  $X_2$ ), ce sera équivalent à l'estimation de l'équation de toutes les variables. En creux, cela veut dire que si les variables dans  $X_2$  (par exemple) sont omises, l'estimateur de  $\hat{\beta}_1$  dans

$$Y = X_1\beta_1 + X_2\beta_2 + \varepsilon$$

sera toujours un estimateur sans biais. On peut le vérifier

$$\hat{\beta}_1 = (X_1'X_1)^{-1}X_1'Y$$

$$\Rightarrow \hat{\beta}_1 = (X_1'X_1)^{-1}X_1'(X_1\beta_1 + X_2\beta_2 + \varepsilon)$$

$$\Leftrightarrow \hat{\beta}_1 = \underbrace{(X_1'X_1)^{-1}X_1'X_1}_{=I}\beta_1 + \underbrace{(X_1'X_1)^{-1}X_1'X_2}_{=0}\beta_2 + (X_1'X_1)^{-1}X_1'\varepsilon$$

$$\Leftrightarrow \hat{\beta}_1 = \beta_1 + (X_1'X_1)^{-1}X_1'\varepsilon$$

$$\Rightarrow E[\hat{\beta}_1] = \beta_1 + E[(X_1'X_1)^{-1}X_1'\varepsilon]$$

Si  $X_1$  est déterministe (identique d'un échantillon à l'autre) ou si  $X_1$  est orthogonal à  $\varepsilon$ , alors l'estimateur est sans biais (le dernier terme est nul)

$$E[\hat{\beta}_1] = \beta_1$$

(2) Si  $X_1$  et  $X_2$  ne sont pas des matrices orthogonales, on ne peut plus utiliser la

particulier des matrices bloc diagonales pour inverser  $XX'$ , Calculons l'estimateur de  $\beta_1$  Par considération le modèle complet  $O_n$

$$\begin{pmatrix} \hat{\beta}_1 \\ \hat{\beta}_2 \end{pmatrix} = \begin{pmatrix} X_1'X_1 & X_1'X_2 \\ X_2'X_1 & X_2'X_2 \end{pmatrix}^{-1} \begin{pmatrix} X_1'Y \\ X_2'Y \end{pmatrix}$$

$$= \begin{pmatrix} (X_1'X_1)^{-1} [I + X_1X_2(X_2'X_2 - X_1X_2(X_1'X_1)^{-1}X_2'X_1)(X_2'X_2)^{-1}]^{-1} & - (X_1'X_1)^{-1}X_1'X_2(X_2'X_2 - X_1X_2(X_1'X_1)^{-1}X_2'X_1)^{-1} \\ -BX_2'X_1(X_1'X_1)^{-1} & B \end{pmatrix} \begin{pmatrix} X_1'Y \\ X_2'Y \end{pmatrix}$$

soit en considérant la première bloc de lignes:

$$\hat{\beta}_1 = \underbrace{(X_1'X_1)^{-1}X_1'Y + (X_1'X_1)^{-1}X_1'X_2}_{\text{Estimateur de } \beta_1 \text{ dans le cas où les variables } X_2 \text{ sont omises}} \underbrace{B(X_2'X_2 - X_1X_2(X_1'X_1)^{-1}X_2'X_1)^{-1}X_2'Y}_{\text{à priori non nul...}}$$

↳ Omettre les variables change l'estimateur de  $\beta_2$ .

Comment? Pour le voir plus simplement, notons que

$$\begin{pmatrix} \hat{\beta}_1 \\ \hat{\beta}_2 \end{pmatrix} = \begin{pmatrix} X_1'X_1 & X_1'X_2 \\ X_2'X_1 & X_2'X_2 \end{pmatrix}^{-1} \begin{pmatrix} X_1'Y \\ X_2'Y \end{pmatrix}$$

$$\Rightarrow \begin{pmatrix} X_1'X_1 & X_1'X_2 \\ X_2'X_1 & X_2'X_2 \end{pmatrix} \begin{pmatrix} \hat{\beta}_1 \\ \hat{\beta}_2 \end{pmatrix} = \begin{pmatrix} X_1'Y \\ X_2'Y \end{pmatrix}$$

$$\Rightarrow \begin{pmatrix} (X_1'X_1)\hat{\beta}_1 + X_1'X_2\hat{\beta}_2 \\ (X_2'X_1)\hat{\beta}_1 + (X_2'X_2)\hat{\beta}_2 \end{pmatrix} = \begin{pmatrix} X_1'Y \\ X_2'Y \end{pmatrix}$$

$$\begin{cases} (X_1'X_1)\hat{\beta}_1 + X_1'X_2\hat{\beta}_2 = X_1'Y \\ (X_2'X_1)\hat{\beta}_1 + (X_2'X_2)\hat{\beta}_2 = X_2'Y \end{cases}$$

$$\Rightarrow \hat{\beta}_1 = (X_1'X_1)^{-1}X_1'Y - (X_1'X_1)^{-1}X_1'X_2\hat{\beta}_2 \quad [1]$$

$$\hat{\beta}_2 = (X_2'X_2)^{-1}X_2'Y - (X_2'X_2)^{-1}X_2'X_1\hat{\beta}_1 \quad [2]$$

↳ estimateur de  $\beta_2$  dans le modèle avec variables omises

$$\Rightarrow \hat{\beta}_2 = (X_2'X_2)^{-1}X_2'Y - (X_2'X_2)^{-1}X_2'X_1\hat{\beta}_2$$

Omettre  $X_2$  ne change rien, car rapport à l'estimation du modèle complet, et seulement si  $X_1'X_2 = 0$

(Les variables omises sont orthogonales aux variables non omises) ou  $\beta_2 = 0$  (c'est à dire si  $Y$  n'est pas affecté par les variables omises, qui ne oeurent à rien).

(3) Les résidus estimés, dans le modèle complet, sont définis par:

$$\hat{u} = Y - X\hat{\beta}$$

soit on substituent l'expression de l'estimateur des MO :

$$\hat{u} = Y - X(X'X)^{-1}X'Y$$

$$\Leftrightarrow \hat{u} = (I - X(X'X)^{-1}X')Y$$

$$\Leftrightarrow \hat{u} = M.Y$$

(4) Montrons que la matrice  $M$  est idempotente :

$$M.M = (I - X(X'X)^{-1}X')(I - X(X'X)^{-1}X')$$

$$\Leftrightarrow M.M = I - X(X'X)^{-1}X' - X(X'X)^{-1}X' + X(X'X)^{-1}X'X(X'X)^{-1}X'$$

$$\Leftrightarrow MM = I - 2X(X'X)^{-1}X' + X(X'X)^{-1}X'$$

$$\Leftrightarrow M.M = I - X(X'X)^{-1}X' \quad \text{qfd}$$

(5) Montrons que  $M$  est orthogonale à  $X$ , c'est à dire que  $M.X = 0$

$$M.X = (I - X(X'X)^{-1}X')X$$

$$\Leftrightarrow M.X = X - \underbrace{X(X'X)^{-1}X'X}_I$$

$$\Leftrightarrow M.X = X - X$$

$$\Leftrightarrow M.X = 0 \quad \text{qfd}$$

(6) La prédiction sur la variable expliquée est

$$\hat{Y} = X\hat{\beta}$$

$$\Leftrightarrow \hat{Y} = X(X'X)^{-1}X'Y$$

$$\Leftrightarrow \hat{Y} = \underbrace{(I - M)}_H Y$$

La prédiction et l'élasticité en  $Y$ . On montre facilement que  $H$  est aussi idempotente

$$H \cdot H = (I - M)(I - M)$$

$$\Leftrightarrow H \cdot H = I - 2M + M \cdot M$$

$$\Leftrightarrow H \cdot H = I - 2M + M$$

$$\Leftrightarrow H \cdot H = I - M \equiv M$$

(7) En substituant [7] dans [2], on obtient une équation nous permettant d'identifier  $\hat{\beta}_2$

$$\hat{\beta}_2 = (X_2' X_2)^{-1} X_2' X_1 (X_1' X_1)^{-1} X_1' Y + (X_2' X_2)^{-1} X_2' X_1 (X_1' X_1)^{-1} X_1' X_2 \hat{\beta}_2$$

$$\Rightarrow (X_2' X_2) \hat{\beta}_2 = X_2' Y - X_2' X_1 (X_1' X_1)^{-1} X_1' X_2 \hat{\beta}_2$$

$$\Leftrightarrow X_2' (I - X_1 (X_1' X_1)^{-1} X_1') X_2 \hat{\beta}_2 = X_2' (I - X_1 (X_1' X_1)^{-1} X_1') Y$$

$$\Leftrightarrow (X_2' M_1 X_2) \hat{\beta}_2 = X_2' M_1 Y$$

$$\Leftrightarrow \hat{\beta}_2 = (X_2' M_1 X_2)^{-1} X_2' M_1 Y$$

où la matrice de projection  $M_2$

$$M_2 = I - X_1 (X_1' X_1)^{-1} X_1'$$

retourne les résidus de la régression de  $Y$  sur les variables  $X_1$ . Comme cette matrice est idempotente et symétrique, on a

$$\hat{\beta}_2 = (X_2' M_2 X_2)^{-1} X_2' M_2 Y$$

$$\Leftrightarrow \hat{\beta}_2 = (X_2' M_1 X_2)^{-1} X_2' M_1 Y$$

$$\Leftrightarrow \hat{\beta}_2 = ((M_1 X_2)' M_1 X_2)^{-1} (M_1 X_2)' M_1 Y$$

$$\Leftrightarrow \hat{\beta}_2 = (X_2' \tilde{X}_2)^{-1} X_2' \tilde{Y}$$

où  $\tilde{X}_2$  sont les résidus des régressions des variables  $X_2$  sur  $X_1$ , et  $\tilde{Y}$  le résidu de la régression de  $Y$  sur  $X_1$ .

On peut donc estimer  $\hat{\beta}_2$  en trois étapes:  
 (i) filtrer de l'effet de  $X_1$  sur  $X_2$  en calculant

les résidus des régressions de  $X_2$  sur  $X_1$  et  $\hat{u}_2$

(ii) Calculer les résidus de la régression de  $Y$  sur  $X_1$  et  $\hat{u}_1$

(iii) Estimer le modèle (par les mco)

$$\hat{u}_1 = \beta_2 \hat{u}_2 + v$$

L'estimation de  $\beta_2$  dans ce modèle est identique à celle que nous obtendrions dans le modèle complet (les propriétés statistiques de l'estimateur avar). C'est le théorème de Frisch-Waugh. d'intérêt de cette approche est que nous obtenons une estimation en n'ayant des plus petites matrices (c'était important il y a cinquante ans, mais aujourd'hui ce n'est plus un avantage décisif).