

**IV.- Espérance mathématique de l'estimateur  $\hat{A}$  :**

Nous avons  $\hat{A} = A + (X'X)^{-1} X' \varepsilon$

alors l'espérance mathématique sera :  $E(\hat{A}) = E(A) + E[(X'X)^{-1} X' \varepsilon]$ ,

soit  $E(\hat{A}) = A + (X'X)^{-1} X' E[\varepsilon]$ , car A est une quantité certaine (non-aléatoire).

Par hypothèse fondamentale, on a  $E[\varepsilon] = 0$ ,

d'où  $E(\hat{A}) = A$ . L'estimateur  $\hat{A}$  est non-biaisé.

**V.- Matrice des variances-covariances de l'estimateur  $\hat{A}$  :**

La matrice  $\Omega_{\hat{A}}$  des variances-covariances de  $\hat{A}$  est définie par :

$$\Omega_{\hat{A}} = \begin{pmatrix} \text{Var}(\hat{a}_1) & \text{Cov}(\hat{a}_1, \hat{a}_2) & \cdots & \text{Cov}(\hat{a}_1, \hat{a}_k) \\ \text{Cov}(\hat{a}_2, \hat{a}_1) & \text{Var}(\hat{a}_2) & \cdots & \text{Cov}(\hat{a}_2, \hat{a}_k) \\ \vdots & \vdots & \ddots & \vdots \\ \text{Cov}(\hat{a}_k, \hat{a}_1) & \text{Cov}(\hat{a}_k, \hat{a}_2) & \cdots & \text{Var}(\hat{a}_k) \end{pmatrix}$$

$$\begin{aligned} \text{En remarquant que : } \text{Var}(\hat{a}_i) &= E[(\hat{a}_i - E(\hat{a}_i))^2] \\ &= E[(\hat{a}_i - a_i)^2] \text{ car } E(\hat{a}_i) = a_i \\ &= E[(\hat{a}_i - a_i)(\hat{a}_i - a_i)] \end{aligned}$$

$$\begin{aligned} \text{et que } \text{Cov}(\hat{a}_i, \hat{a}_j) &= E[(\hat{a}_i - E(\hat{a}_i))(\hat{a}_j - E(\hat{a}_j))] \\ &= E[(\hat{a}_i - a_i)(\hat{a}_j - a_j)] \end{aligned}$$

On peut mettre  $\Omega_{\hat{A}}$  sous forme :

$$\Omega_{\hat{A}} = E\left[ (\hat{A} - E(\hat{A}))(\hat{A} - E(\hat{A}))' \right]$$

$$\Omega_{\hat{A}} = E\left[ (\hat{A} - A)(\hat{A} - A)' \right]$$

$$\text{Or } \hat{A} - A = (X'X)^{-1} X' \varepsilon \quad \text{et} \quad [\hat{A} - A]' = [(X'X)^{-1} X' \varepsilon]'$$

$$[\hat{A} - A] = \varepsilon'(X')' [(X'X)^{-1}] = \varepsilon'X(X'X)^{-1} \quad \text{puisque} \quad [(X'X)^{-1}] = [(X'X)']^{-1} = [X'X]^{-1}$$

$$\Omega_{\hat{A}} = E\left\{[(X'X)^{-1}X'\varepsilon](\varepsilon'X(X'X)^{-1})\right\}$$

Alors, on aura :

$$\Omega_{\hat{A}} = (X'X)^{-1}X'E(\varepsilon\varepsilon')X(X'X)^{-1}$$

soit

Remplaçons  $E(\varepsilon\varepsilon')$  par sa valeur  $\sigma^2 I$ , on obtient:

$$\Omega_{\hat{A}} = (X'X)^{-1}X'\sigma^2IX(X'X)^{-1} = \sigma^2(X'X)^{-1}(X'X)(X'X)^{-1}$$

Enfinement :  $\Omega_{\hat{A}} = \sigma^2(X'X)^{-1}$

La matrice  $(X'X)^{-1}$  est une matrice symétrique de type  $(k,k)$ .

Pour que l'estimateur  $\hat{A}$  soit convergent, il est nécessaire que la matrice  $(X'X)^{-1}$  tend vers zéro lorsque le nombre d'observations  $n$  augmente indéfiniment. Habituellement, ceci se pose comme une hypothèse technique de la régression multiple.

#### VI.- Théorème de Gauss-Markov : L'estimateur $\hat{A}$ est « BLUE » :

$\hat{A} = [(X'X)^{-1}X']Y$   
 L'estimateur est un estimateur **BLUE** « Best Linear Unbiased Estimator » de  $A$ , c'est-à-dire que la variance de  $\hat{A}$  est la plus petite entre tous les estimateurs sans biais de  $A$ .

#### Démonstration :

Considérons un estimateur quelconque  $\alpha$  de  $A$ .

a) L'estimateur  $\alpha$  doit être linéaire en  $Y$  :

$$\alpha = MY$$

$A$  est de type  $(k,1)$ .  $Y$  est de type  $(n,1)$ . La matrice  $M$  est ainsi de type  $(k,n)$ .

Remplaçons  $Y$  par sa valeur, on obtient :  $\alpha = M(XA + \varepsilon)$

$$\alpha = MXA + M\varepsilon$$

b) Il faut montrer que  $M = (X'X)^{-1}X'$  :

Pour cela, on peut considérer l'expression :  $M = (X'X)^{-1}X' + N$  et montrer que la matrice  $N$ , de type  $(k,n)$  est égale à zéro :  $N = 0$ .

c) L'estimateur  $\alpha$  doit être non-biaisé, c'est-à-dire qu'il doit vérifier  $E(\alpha)=A$  :

$$E(MXA+M\varepsilon)=A \Rightarrow MXA+M E(\varepsilon)=A$$

$$\Rightarrow MXA=A \quad \text{puisque } E(\varepsilon)=0.$$

$$\text{C'est-à-dire la condition } MX=I.$$

$$\text{Ou encore } [(X'X)^{-1}X'+N]X=I \Rightarrow (X'X)^{-1}(X'X)+NX=I$$

$$\Rightarrow I+NX=I \Rightarrow NX=0$$

d) L'estimateur  $\alpha$  doit être de variance minimale :

$$\text{La matrice } \Omega_\alpha \text{ des variances-covariances de } \alpha \quad \Omega_\alpha = E\left[(\alpha - E(\alpha))(\alpha - E(\alpha))'\right]$$

$$\text{est : } \alpha = MXA + M\varepsilon$$

Mais

$$= IA + M\varepsilon$$

$$= A + M\varepsilon$$

$$= E(\alpha) + M\varepsilon$$

$$\Rightarrow \alpha - E(\alpha) = M\varepsilon$$

$$\Omega_\alpha = E\left[(M\varepsilon)(M\varepsilon)'\right] = E\left[M\varepsilon\varepsilon'M'\right] = ME(\varepsilon\varepsilon')M' = M\sigma^2IM'$$

$$\Rightarrow \Omega_\alpha = \sigma^2MM'$$

Cette expression peut aussi s'écrire :

$$\Omega_\alpha = \sigma^2\left[(X'X)^{-1}X'+N\right]\left[(X'X)^{-1}X'+N\right]'$$

$$= \sigma^2\left[(X'X)^{-1}X'+N\right]\left[X'(X'X)^{-1}+N'\right]$$

$$= \sigma^2\left[(X'X)^{-1}(X'X)(X'X)^{-1} + (X'X)^{-1}X'N' + NX(X'X)^{-1} + NN'\right]$$

$$= \sigma^2\left[(X'X)^{-1} + (X'X)^{-1}(NX)' + NX(X'X)^{-1} + NN'\right]$$

$$= \sigma^2\left[(X'X)^{-1} + NN'\right] \quad \text{puisque } NX=0$$

Les variances se trouvent sur la diagonale principale de  $\Omega_\alpha$ . Il faut minimiser ces termes. Mais,  $\sigma^2$  et  $(X'X)^{-1}$  étant des constantes, il faut donc minimiser les éléments de la diagonale de  $NN'$ . Ces éléments qui sont des variances, sont obligatoirement positifs ou nuls.

$$NN' = \begin{pmatrix} \omega_{11} & \omega_{12} & \cdots & \omega_{1n} \\ \vdots & & \ddots & \vdots \\ \omega_{k1} & \omega_{k2} & \cdots & \omega_{kn} \end{pmatrix} \begin{pmatrix} \omega_{11} & \cdots & \omega_{k1} \\ \omega_{12} & \cdots & \omega_{k2} \\ \vdots & \ddots & \vdots \\ \omega_{1n} & \cdots & \omega_{kn} \end{pmatrix} = \begin{pmatrix} \sum_{j=1}^n \omega_{1j}^2 & & & \\ & \ddots & & \\ & & \sum_{j=1}^n \omega_{ij}^2 & \\ & & & \ddots \\ & & & & \sum_{j=1}^n \omega_{kj}^2 \end{pmatrix}$$

Ils sont minimums lorsqu'ils sont nuls, c'est-à-dire  $\sum_{j=1}^n \omega_{ij}^2 = 0; \forall i$

Cette dernière relation est vérifiée si et seulement si  $\omega_{ij}=0$ , pour tout  $i$  et pour tout  $j$ , en d'autres termes si  $N=0$ .

Conclusion : L'estimateur  $\hat{A}$  est ainsi « BLUE » .

### VII.-Estimateur de $\sigma^2$ :

$\sigma^2$  est lui-même inconnu, alors on l'estime. On peut montrer que

$$\hat{\sigma}^2 = \frac{e' \cdot e}{n - k}$$

où  $e' \cdot e$  est la somme des carrés des résidus, c'est-à-dire :  $e' \cdot e = \sum_{i=1}^n e_i^2$  et  $(n-k)$  est le degré de liberté.

L'estimateur  $\hat{\sigma}^2$  est sans biais,  $E[\hat{\sigma}^2] = \sigma^2$ .

On peut montrer aussi que :

$$\hat{\sigma}^2 = \frac{Y' \Gamma Y}{n - k} \quad \text{avec} \quad \Gamma = I - X(X'X)^{-1}X'$$

$\Gamma$  est une matrice carrée d'ordre  $n$  (c'est la différence de deux matrices), symétrique ( $\Gamma'=\Gamma$ ) et idempotente ( $\Gamma^2=\Gamma$ ). Bien sur,  $Y' \Gamma Y = e' \cdot e = \sum e_i^2$ .

### VIII.-Formule de l'analyse de la variance, coefficient de détermination et coefficient de corrélation linéaire multiple empirique :

#### 1) Formule de l'analyse de la variance :

D'après les hypothèses de la régression et comme on a vu dans le chapitre précédent :

$$\left( \begin{array}{c} \text{Variance} \\ \text{totale} \end{array} \right) = \left( \begin{array}{c} \text{Variance} \\ \text{expliquée} \end{array} \right) + \left( \begin{array}{c} \text{Variance} \\ \text{résiduelle} \end{array} \right)$$

Cette même relation, on peut l'exprimer par :

$$(Y'Y) = (\hat{A}'X'Y) + (Y'\Gamma Y)$$

#### 2) Coefficient de détermination $R^2$ :

Par définition, on appelle coefficient de détermination, noté  $R^2$  le rapport :

$$R^2 = \frac{\text{Variance expliquée}}{\text{Variance totale}} = \frac{\hat{A}'X'Y}{Y'Y}$$

$R^2$  représente la proportion de la variance de Y expliquée par l'influence linéaire des variables exogènes X.

On rappelle aussi que :  $0 \leq R^2 \leq 1$ .

Il est autant proche de 1 que le « nuage de points » est plus allongé et étiré. Néanmoins, ce coefficient dépend essentiellement de l'échantillon observé, d'où l'adjectif « empirique ». En effet,  $R^2$  est une variable aléatoire puisqu'il dépend d'un échantillon aléatoire.

Ainsi, l'information fournie par  $R^2$  n'est pas primordiale pour l'étude du modèle considéré.

#### 3) Coefficient de corrélation linéaire empirique multiple R :

La racine carrée du coefficient de détermination  $R^2$  est le coefficient de corrélation linéaire multiple R.

Comme on a déjà vu  $-1 \leq R \leq 1$ .

Le coefficient R est lui-même empirique car il dépend de l'échantillon aléatoire choisi.

## IX.- Utilisation des tests statistiques :

La théorie statistique classique des tests consiste en établir une hypothèse au paravent. Le vecteur aléatoire  $\varepsilon$  suit une loi normale de moyenne nulle et de variance  $\sigma^2 I$ .

$$\varepsilon \rightarrow N(0; \sigma^2 I)$$

Mais, nous avons vu que  $\hat{A}$  dépend linéairement de  $\varepsilon$ . En effet,

$$\hat{A} = A + (X'X)^{-1} X' \varepsilon$$

avec  $E(\hat{A})=A$  et  $\Omega_{\hat{A}} = \sigma^2 (X'X)^{-1}$ . Donc  $\hat{A} \rightarrow N(A; \sigma^2 (X'X)^{-1})$ .

Il est possible, alors, de construire par les méthodes usuelles de l'analyse de la variance un test de signification des coefficients estimés précédemment.

Les tests « classiques » sont les tests de t de Student et celui de F de Fisher-Snedecor.

### 1) Test de t de Student :

Il consiste en tester si  $a_i = 0$  (un seul parmi  $i=1, 2, \dots, k$ )

On calcul l'indicateur (ou la statistique) :

$$t = \frac{\hat{a}_i - a_i}{\sigma_{\hat{a}_i}}$$

où  $\sigma_{\hat{a}_i}$  est l'écart-type estimé, obtenu à partir de la matrice des variances-covariances

$\Omega_{\hat{A}} = \sigma^2 (X'X)^{-1}$  ainsi  $\sigma_{\hat{a}_i} = \sigma \sqrt{v_{ii}}$  où  $v_{ii}$  est l' $i^{\text{ème}}$  terme de la diagonale de la

matrice  $(X'X)^{-1}$  et  $\sigma$  est estimé par  $\hat{\sigma}^2 = \frac{e' \cdot e}{n-k}$

on compare  $t$  avec  $t_\alpha$  lue dans la table de la loi de Student, pour un seuil (ou niveau de confiance)  $\alpha$ , et  $n-k-1$  degré de liberté.

Si  $|t| > t_\alpha$  alors ce  $a_i$  est différent de zéro.

Si  $|t| < t_\alpha$  alors ce  $a_i$  est égale à zéro.

## 2) Test de F de Fisher-Snedecor:

Il consiste en tester si  $a_1 = a_2 = \dots = a_i = \dots = a_k = 0$  (tous).

On calcul l'indicateur (ou la statistique) : 
$$F = \frac{R^2/k}{(1-R^2)/(n-k-1)}$$

Où  $R^2$  est le coefficient de détermination.

On compare la valeur de  $F$  avec une valeur  $F_\alpha$  lue dans la table de Fisher à un seuil  $\alpha$  et en fonction des degrés de liberté  $k$  et  $(n-k-1)$ .

Si  $F > F_\alpha$  alors au moins un des coefficients  $a_i$  est différent de zéro.

On peut aussi utiliser le tableau de l'analyse de la variance (pour ce cas de régression linéaire multiple) :

Source de variation	Somme des carrés	Degré de liberté	Moyenne des carrés
Régression	$\sum \hat{Y}_i^2$	$k$	$MCR = \left( \sum \hat{Y}_i^2 / k \right)$
Résidus	$\sum e_i^2$	$n-k-1$	$MCE = \left( \sum e_i^2 / (n-k-1) \right)$
Total	$\sum Y_i^2$	$n-1$	

$$F = \frac{MCR}{MCE} = \frac{\sum \hat{Y}_i^2 / k}{\sum e_i^2 / (n-k-1)}$$

On calcul

Que l'on compare avec  $F_\alpha$  lue dans la table de Fisher.

Si  $F > F_\alpha$ , alors cela veut dire qu'il existe au moins un des  $a_i$  qui est différent de zéro.