

## MAT7381 Chapitre 3 Le modèle linéaire général

### Définition du modèle

L'équation du modèle linéaire général est

$$y = \mathbf{X}\boldsymbol{\beta} + \boldsymbol{\varepsilon}$$

où  $y$  est un vecteur  $n \times 1$  d'observations aléatoires,  $\mathbf{X}$  est une matrice  $n \times q$  de constantes connues,  $\boldsymbol{\beta}$  est un vecteur  $q \times 1$  de paramètres inconnus et  $\boldsymbol{\varepsilon}$  est un vecteur  $n \times 1$  d'erreurs inobservables. On suppose généralement que

$$E(\boldsymbol{\varepsilon}) = \mathbf{0} \text{ et } \text{Var}(\boldsymbol{\varepsilon}) = \sigma^2 \mathbf{I}_n$$

Finalement, nous supposons que  $\mathbf{X}$  est de rang plein  $q$ .

Ces suppositions sont suffisantes pour obtenir des estimateurs ponctuels sans biais. Pour développer de procédures de test et des intervalles de confiance, nous ajouterons l'hypothèse que  $y$  est de loi normale multivariée.

### Estimateurs

Pour déterminer un estimateur pour le vecteur  $\boldsymbol{\beta}$ , nous utilisons le principe des moindres carrés, qui s'énonce comme ceci: l'estimateur des moindres carrés est la valeur  $\hat{\boldsymbol{\beta}}$  du vecteur  $\boldsymbol{\beta}$  qui minimise

$$Q = (y - \mathbf{X}\boldsymbol{\beta})'(y - \mathbf{X}\boldsymbol{\beta})$$

Il s'agit donc de trouver un vecteur  $\mathbf{X}\hat{\boldsymbol{\beta}} \in C(\mathbf{X})$ , pour lequel la longueur (au carré) du vecteur  $y - \mathbf{X}\hat{\boldsymbol{\beta}}$  est minimale. Il est géométriquement clair que ce vecteur  $\mathbf{X}\hat{\boldsymbol{\beta}}$  doit être la projection orthogonale de  $y$  sur  $C(\mathbf{X})$ , c'est-à-dire,

$$\mathbf{X}\hat{\boldsymbol{\beta}} = \mathbf{X}(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'y,$$

l'existence de  $(\mathbf{X}'\mathbf{X})^{-1}$  étant assurée par le fait que  $\mathbf{X}$  est de rang plein. Multipliant les deux membres de l'équation par  $\mathbf{X}'$  à gauche on a

$$\mathbf{X}'\mathbf{X}\hat{\boldsymbol{\beta}} = \mathbf{X}'\mathbf{X}(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'y = \mathbf{X}'y$$

ce qui entraîne

$$\hat{\boldsymbol{\beta}} = (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'y$$

Une démonstration plus formelle est également possible. Nous avons

$$Q = [y - \mathbf{X}\boldsymbol{\beta}]'[y - \mathbf{X}\boldsymbol{\beta}]$$

$$= [y - \mathbf{X}\hat{\boldsymbol{\beta}} + \mathbf{X}\hat{\boldsymbol{\beta}} - \mathbf{X}\boldsymbol{\beta}]'[y - \mathbf{X}\hat{\boldsymbol{\beta}} + \mathbf{X}\hat{\boldsymbol{\beta}} - \mathbf{X}\boldsymbol{\beta}].$$

Mais

$$\mathbf{X}\hat{\boldsymbol{\beta}} = \mathbf{X}(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'y = \mathbf{P}y \text{ et } y - \mathbf{X}\hat{\boldsymbol{\beta}} = y - \mathbf{P}y = (\mathbf{I} - \mathbf{P})y,$$

où  $\mathbf{P}$  est le projecteur orthogonal sur  $C(\mathbf{X})$ , soit

$$\mathbf{P} = \mathbf{X}(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'.$$

$\mathbf{P}$  et  $\mathbf{I} - \mathbf{P}$  sont symétriques et idempotentes. Nous avons donc

$$Q = [(\mathbf{I} - \mathbf{P})y + \mathbf{X}(\hat{\boldsymbol{\beta}} - \boldsymbol{\beta})]'[(\mathbf{I} - \mathbf{P})y + \mathbf{X}(\hat{\boldsymbol{\beta}} - \boldsymbol{\beta})]$$

$$= \mathbf{y}'(\mathbf{I} - \mathbf{P})(\mathbf{I} - \mathbf{P})\mathbf{y} + (\hat{\boldsymbol{\beta}} - \boldsymbol{\beta})'\mathbf{X}'\mathbf{X}(\hat{\boldsymbol{\beta}} - \boldsymbol{\beta}) + 2\mathbf{y}'(\mathbf{I} - \mathbf{P})\mathbf{X}(\hat{\boldsymbol{\beta}} - \boldsymbol{\beta}).$$

Mais

$\mathbf{y}'(\mathbf{I} - \mathbf{P})(\mathbf{I} - \mathbf{P})\mathbf{y} = \mathbf{y}'(\mathbf{I} - \mathbf{P})(\mathbf{I} - \mathbf{P})\mathbf{y} = \mathbf{y}'(\mathbf{I} - \mathbf{P})\mathbf{y}$ , puisque  $(\mathbf{I} - \mathbf{P})$  est symétrique et idempotente.

Et  $(\mathbf{I} - \mathbf{P})\mathbf{X} = (\mathbf{I} - \mathbf{P})\mathbf{X} = \mathbf{X} - \mathbf{P}\mathbf{X} = \mathbf{X} - \mathbf{X}(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{X} = \mathbf{X} - \mathbf{X} = \mathbf{0}$ .

$$\text{Donc } Q = \mathbf{y}'(\mathbf{I} - \mathbf{P})\mathbf{y} + (\hat{\boldsymbol{\beta}} - \boldsymbol{\beta})'\mathbf{X}'\mathbf{X}(\hat{\boldsymbol{\beta}} - \boldsymbol{\beta}).$$

Étant donné que le premier terme,  $\mathbf{y}'(\mathbf{I} - \mathbf{P})\mathbf{y}$ , ne dépend pas de  $\boldsymbol{\beta}$ , il s'agit de minimiser le deuxième,  $(\hat{\boldsymbol{\beta}} - \boldsymbol{\beta})'\mathbf{X}'\mathbf{X}(\hat{\boldsymbol{\beta}} - \boldsymbol{\beta})$ . Rappelons qu'une matrice de la forme  $\mathbf{X}'\mathbf{X}$  est toujours semi définie positive, et puisque  $\mathbf{X}$  est de rang plein,  $\mathbf{X}'\mathbf{X}$  est en fait *définie* positive. Donc  $(\hat{\boldsymbol{\beta}} - \boldsymbol{\beta})'\mathbf{X}'\mathbf{X}(\hat{\boldsymbol{\beta}} - \boldsymbol{\beta}) > 0$  pour tout  $\boldsymbol{\beta} \neq \hat{\boldsymbol{\beta}}$ , et par conséquent  $(\hat{\boldsymbol{\beta}} - \boldsymbol{\beta})'\mathbf{X}'\mathbf{X}(\hat{\boldsymbol{\beta}} - \boldsymbol{\beta})$  atteint son minimum de 0 si et seulement si  $\boldsymbol{\beta} = \hat{\boldsymbol{\beta}}$ .

### Distribution des estimateurs

1.  $\hat{\boldsymbol{\beta}}$  est un vecteur normal, puisqu'il est fonction linéaire d'un vecteur normal. Son espérance est

$$E(\hat{\boldsymbol{\beta}}) = E[(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{y}] = (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'E(\mathbf{y}) = (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{X}\boldsymbol{\beta} = \boldsymbol{\beta}$$

c'est-à-dire,  $\hat{\boldsymbol{\beta}}$  est un estimateur sans biais de  $\boldsymbol{\beta}$ . Sa variance est

$$\text{Var}(\hat{\boldsymbol{\beta}}) = (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\text{Var}(\mathbf{y})\mathbf{X}(\mathbf{X}'\mathbf{X})^{-1} = \sigma^2(\mathbf{X}'\mathbf{X})^{-1}$$

2. La somme des carrés résiduelle est

$$\text{SCR} = (\mathbf{y} - \mathbf{X}\hat{\boldsymbol{\beta}})'\mathbf{y} - \mathbf{X}\hat{\boldsymbol{\beta}} = [(\mathbf{I} - \mathbf{P})\mathbf{y}]'[(\mathbf{I} - \mathbf{P})\mathbf{y}] = \mathbf{y}'(\mathbf{I} - \mathbf{P})\mathbf{y}$$

grâce à l'idempotence et la symétrie de  $\mathbf{P}$ . Il découle immédiatement des théorèmes sur les distributions de formes quadratiques que

$$\frac{\mathbf{y}'(\mathbf{I} - \mathbf{P})\mathbf{y}}{\sigma^2} \sim \chi_{n-q}^2$$

Le paramètre de non-centralité  $\lambda$  est nul car si  $E(\mathbf{y}) = \boldsymbol{\mu} = \mathbf{X}\boldsymbol{\beta}$ ,  $\lambda = \sigma^2\boldsymbol{\mu}'(\mathbf{I} - \mathbf{P})\boldsymbol{\mu} = 0$ , puisque  $\mathbf{P}\mathbf{X} = \mathbf{X}$  et donc  $(\mathbf{I} - \mathbf{P})\boldsymbol{\mu} = (\mathbf{I} - \mathbf{P})\mathbf{X}\boldsymbol{\beta} = \mathbf{0}$ .

3. On déduit aisément de 2 ci-dessus que  $\hat{\sigma}^2 = \text{SCR}/(n-q)$  est un estimateur sans biais de  $\sigma^2$ .
4. Les vecteurs  $\hat{\boldsymbol{\beta}} = (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{y}$  et  $(\mathbf{I} - \mathbf{P})\mathbf{y}$  sont indépendants puisque  $\text{Cov}[(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{y}; (\mathbf{I} - \mathbf{P})\mathbf{y}] = \sigma^2(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'(\mathbf{I} - \mathbf{P})' = \mathbf{0}$ . Donc  $\hat{\boldsymbol{\beta}}$  et  $\hat{\sigma}^2$  sont indépendants.
5. Si  $\boldsymbol{\ell}$  est un vecteur  $q \times 1$ , la variable  $\boldsymbol{\ell}'\hat{\boldsymbol{\beta}}$  suit une loi  $\mathcal{N}[\boldsymbol{\ell}'\boldsymbol{\beta}; \sigma_{\boldsymbol{\ell}'\hat{\boldsymbol{\beta}}}^2]$  où  $\sigma_{\boldsymbol{\ell}'\hat{\boldsymbol{\beta}}}^2 = \sigma^2\boldsymbol{\ell}'(\mathbf{X}'\mathbf{X})^{-1}\boldsymbol{\ell}$ . On a donc

$$\frac{\boldsymbol{\ell}'\hat{\boldsymbol{\beta}} - \boldsymbol{\ell}'\boldsymbol{\beta}}{\sigma_{\boldsymbol{\ell}'\hat{\boldsymbol{\beta}}}} \sim \mathcal{N}(0; 1)$$

Les résultats précédents nous permettent ensuite de conclure que

$$\frac{\boldsymbol{\ell}'\hat{\boldsymbol{\beta}} - \boldsymbol{\ell}'\boldsymbol{\beta}}{\hat{\sigma}_{\boldsymbol{\ell}'\hat{\boldsymbol{\beta}}}} \sim t_{n-q}$$

$$\text{où } \hat{\sigma}_{\boldsymbol{\ell}'\hat{\boldsymbol{\beta}}} = \hat{\sigma}\sqrt{\boldsymbol{\ell}'(\mathbf{X}'\mathbf{X})^{-1}\boldsymbol{\ell}}$$

6. Les résultats en 5 ont un analogue matriciel. Si  $\mathbf{L}$  est une matrice de constantes  $q \times r$  de rang  $r \times q$ , le vecteur aléatoire  $\mathbf{L}'\hat{\boldsymbol{\beta}}$  suit une loi  $\mathcal{N}_r[\mathbf{L}'\boldsymbol{\beta}; \sigma^2\mathbf{L}'(\mathbf{X}'\mathbf{X})^{-1}\mathbf{L}]$ . Donc

$$\frac{(\mathbf{L}'\hat{\boldsymbol{\beta}} - \boldsymbol{\delta})'[\mathbf{L}'(\mathbf{X}'\mathbf{X})^{-1}\mathbf{L}]^{-1}(\mathbf{L}'\hat{\boldsymbol{\beta}} - \boldsymbol{\delta})/r}{\sigma^2} \sim \chi_r^2$$

De là, on peut déduire que la variable

$$\frac{(\mathbf{L}'\hat{\boldsymbol{\beta}} - \boldsymbol{\delta})'[\mathbf{L}'(\mathbf{X}'\mathbf{X})^{-1}\mathbf{L}]^{-1}(\mathbf{L}'\hat{\boldsymbol{\beta}} - \boldsymbol{\delta})/r}{\hat{\sigma}^2} \sim \mathcal{F}_{r,n-q}$$

### Intervalles de confiance

Si  $\ell$  est un vecteur  $q \times 1$ , on peut déterminer un intervalle de confiance pour  $\ell'\boldsymbol{\beta}$  en utilisant le résultat 5 ci-dessus. On obtient

$$\ell'\hat{\boldsymbol{\beta}} - t_{n-q,\alpha/2} \hat{\sigma}_{\ell'\hat{\boldsymbol{\beta}}} \leq \ell'\boldsymbol{\beta} \leq \ell'\hat{\boldsymbol{\beta}} + t_{n-q,\alpha/2} \hat{\sigma}_{\ell'\hat{\boldsymbol{\beta}}}$$

où  $t_{n-q,\alpha/2}$  est le point critique correspondant à une loi de Student à  $n - q$  degrés de liberté et  $\hat{\sigma}_{\ell'\hat{\boldsymbol{\beta}}} = \hat{\sigma} [\ell'(\mathbf{X}'\mathbf{X})^{-1}\ell]^{1/2}$  est l'estimateur de l'écart-type de  $\ell'\boldsymbol{\beta}$ . Ainsi, en prenant pour  $\ell'$  les vecteurs  $(1; 0; 0; \dots; 0); (0; 1; 0; \dots; 0); \dots; (0; 0; 0; \dots; 1)$ , nous pouvons déterminer un intervalle de confiance pour chacune des composantes de  $\boldsymbol{\beta}$ .

### Tests d'hypothèses linéaires

Une hypothèse linéaire générale est la suivante :

$$H_0: \mathbf{L}'\boldsymbol{\beta} = \boldsymbol{\delta}$$

où  $\mathbf{L}$  est une matrice  $q \times r$  ( $r \leq q$ ) de rang plein et  $\boldsymbol{\delta}$  est un vecteur  $r \times 1$  de constantes. Il est évident que le test d'une telle hypothèse devra être basé sur le vecteur aléatoire  $\mathbf{L}'\hat{\boldsymbol{\beta}} - \boldsymbol{\delta}$  dont l'espérance  $\mathbf{L}'\boldsymbol{\beta} - \boldsymbol{\delta}$  est nulle si et seulement si  $H_0$  est vraie. Donc la norme de  $\mathbf{L}'\hat{\boldsymbol{\beta}} - \boldsymbol{\delta}$  devrait être petite si  $H_0$  est vraie et grande sinon. La norme la plus naturelle, pour un vecteur normal, est définie par

$$\begin{aligned} \|\mathbf{L}'\hat{\boldsymbol{\beta}} - \boldsymbol{\delta}\|^2 &= (\mathbf{L}'\hat{\boldsymbol{\beta}} - \boldsymbol{\delta})' [\text{Var}(\mathbf{L}'\hat{\boldsymbol{\beta}} - \boldsymbol{\delta})]^{-1} (\mathbf{L}'\hat{\boldsymbol{\beta}} - \boldsymbol{\delta}) \\ &= (\mathbf{L}'\hat{\boldsymbol{\beta}} - \boldsymbol{\delta})' [\mathbf{L}'(\mathbf{X}'\mathbf{X})^{-1}\mathbf{L}]^{-1} (\mathbf{L}'\hat{\boldsymbol{\beta}} - \boldsymbol{\delta}) / \sigma^2 \end{aligned}$$

Cette forme quadratique suit une loi  $\chi_r^2(\lambda)$  avec

$$\lambda = (\mathbf{L}'\boldsymbol{\beta} - \boldsymbol{\delta})' [\mathbf{L}'(\mathbf{X}'\mathbf{X})^{-1}\mathbf{L}]^{-1} (\mathbf{L}'\boldsymbol{\beta} - \boldsymbol{\delta}) / \sigma^2$$

Elle est donc centrale si et seulement si  $H_0$  est vraie. Puisque  $\sigma^2$  n'est pas connue, nous la remplaçons par  $\hat{\sigma}^2$  et nous divisons le numérateur par le nombre de degrés de liberté  $r$ . Nous obtenons le rapport

$$\frac{(\mathbf{L}'\hat{\boldsymbol{\beta}} - \boldsymbol{\delta})' [\mathbf{L}'(\mathbf{X}'\mathbf{X})^{-1}\mathbf{L}]^{-1} (\mathbf{L}'\hat{\boldsymbol{\beta}} - \boldsymbol{\delta}) / r}{\hat{\sigma}^2}$$

qui suit une loi  $F$  centrale à  $r$  et  $n - q$  degrés de liberté si et seulement si  $H_0$  est vraie.

### Différences de sommes de carrés résiduelles

Nous montrons ici que le numérateur de la statistique  $F$  peut s'exprimer comme une différence de deux sommes de carrés résiduelles  $SCR_0 - SCR$ , où  $SCR$  est la somme des carrés résiduelle sous le modèle et  $SCR_0$  est la somme des carrés résiduelle *sous le modèle réduit*, c'est-à-dire, sous  $H_0$ .

D'abord, le cas où  $\delta = \mathbf{0}$ .

**Cas  $\delta = \mathbf{0}$ .** Nous considérons donc l'hypothèse

$$H_0: \mathbf{L}'\boldsymbol{\beta} = \mathbf{0}$$

La somme des carrés résiduelle sous le modèle est

$$SCR = \mathbf{y}'(\mathbf{I} - \mathbf{P})\mathbf{y} \text{ où } \mathbf{P} = \mathbf{X}(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'$$

Nous devons déterminer maintenant  $SCR_0$ , la somme des carrés résiduelle sous l'hypothèse nulle. L'hypothèse  $\mathbf{L}'\boldsymbol{\beta} = \mathbf{0}$  est équivalente à

$$H_0: \boldsymbol{\beta} \in \mathcal{N}(\mathbf{L}')$$

Nous supposons sans perte de généralité que  $\mathbf{L}$  est de rang plein  $r$ , auquel cas la dimension de  $\mathcal{N}(\mathbf{L}')$  est  $q-r$ . Soit  $\mathbf{T}$  une matrice  $q \times (q-r)$  dont les colonnes constituent une base pour  $\mathcal{N}(\mathbf{L}')$ . C'est-à-dire,

$$\mathcal{C}(\mathbf{T}) = \mathcal{N}(\mathbf{L}')$$

L'hypothèse nulle  $\mathbf{L}'\boldsymbol{\beta} = \mathbf{0}$  est donc équivalente à

$$H_0: \boldsymbol{\beta} = \mathbf{T}\boldsymbol{\alpha}$$

Le modèle réduit est donc

$$\mathbf{y} = \mathbf{X}\mathbf{T}\boldsymbol{\alpha} + \boldsymbol{\varepsilon}$$

Par conséquent, la somme des carrés résiduelle pour le modèle réduit est

$$SCR_0 = \mathbf{y}'(\mathbf{I} - \mathbf{P}_0)\mathbf{y}$$

où

$$\mathbf{P}_0 = \mathbf{X}\mathbf{T}(\mathbf{T}'\mathbf{X}'\mathbf{X}\mathbf{T})^{-1}\mathbf{T}'\mathbf{X}'$$

Nous avons donc

$$SCR_0 - SCR = \mathbf{y}'(\mathbf{P} - \mathbf{P}_0)\mathbf{y}$$

Nous devons démontrer que cette forme quadratique est identique à celle présentée plus haut, soit

$$[\mathbf{L}'\hat{\boldsymbol{\beta}}]'[\mathbf{L}'(\mathbf{X}\mathbf{X})^{-1}\mathbf{L}]^{-1}\mathbf{L}'\hat{\boldsymbol{\beta}} = \mathbf{y}'\mathbf{P}_1\mathbf{y},$$

où

$$\mathbf{P}_1 = \mathbf{X}(\mathbf{X}\mathbf{X})^{-1}\mathbf{L}[\mathbf{L}'(\mathbf{X}\mathbf{X})^{-1}\mathbf{L}]^{-1}\mathbf{L}'(\mathbf{X}\mathbf{X})^{-1}\mathbf{X}',$$

c'est-à-dire, il faut montrer que

$$\mathbf{P} - \mathbf{P}_0 = \mathbf{P}_1$$

Étant donné que  $\mathbf{P} - \mathbf{P}_0$  et  $\mathbf{P}_1$  sont des projecteurs orthogonaux, il suffira de montrer que leurs colonnes engendrent le même espace. Pour montrer ceci, on montre que  $\mathcal{C}(\mathbf{P}_1) \subset \mathcal{C}(\mathbf{P} - \mathbf{P}_0)$  et ensuite que  $r(\mathbf{P} - \mathbf{P}_0) = r(\mathbf{P}_1)$ .

Il est clair que  $\mathbf{P}\mathbf{P}_1 = \mathbf{P}_1$ , puisque  $\mathbf{P}\mathbf{X} = \mathbf{X}$ , et on vérifie aisément  $\mathbf{P}_0\mathbf{P}_1 = \mathbf{0}$ , en utilisant le fait que  $\mathbf{T}'\mathbf{X}'\mathbf{X}(\mathbf{X}\mathbf{X})^{-1}\mathbf{L} = \mathbf{T}'\mathbf{L} = \mathbf{0}$ . Donc  $(\mathbf{P} - \mathbf{P}_0)\mathbf{P}_1 = \mathbf{P}_1$ , ce qui entraîne que  $\mathcal{C}(\mathbf{P}_1) \subset \mathcal{C}(\mathbf{P} - \mathbf{P}_0)$ .

Par l'idempotence de  $\mathbf{P} - \mathbf{P}_0$  et  $\mathbf{P}_1$ ,  $r(\mathbf{P} - \mathbf{P}_0) = r(\mathbf{P}_1)$  si et seulement si  $tr(\mathbf{P} - \mathbf{P}_0) = tr(\mathbf{P}_1)$ . Or

$$tr(\mathbf{P} - \mathbf{P}_0) = tr(\mathbf{X}(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}' - \mathbf{X}\mathbf{T}(\mathbf{T}'\mathbf{X}'\mathbf{X}\mathbf{T})^{-1}\mathbf{T}'\mathbf{X}') = tr((\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{X} - (\mathbf{T}'\mathbf{X}'\mathbf{X}\mathbf{T})^{-1}\mathbf{T}'\mathbf{X}'\mathbf{X}\mathbf{T}) = q - (q-r) = r$$

et

$$tr(\mathbf{P}_1) = tr(\mathbf{X}(\mathbf{X}\mathbf{X})^{-1}\mathbf{L}[\mathbf{L}'(\mathbf{X}\mathbf{X})^{-1}\mathbf{L}]^{-1}\mathbf{L}'(\mathbf{X}\mathbf{X})^{-1}\mathbf{X}') = tr(\mathbf{X}(\mathbf{X}\mathbf{X})^{-1}\mathbf{L}[\mathbf{L}'(\mathbf{X}\mathbf{X})^{-1}\mathbf{L}]^{-1}\mathbf{L}'(\mathbf{X}\mathbf{X})^{-1}\mathbf{X}')$$

sont des projecteurs orthogonaux sur le même espace et sont donc égaux par l'unicité des projecteurs orthogonaux.

Ceci complète la démonstration pour le cas où  $\delta = \mathbf{0}$ .

**Cas  $\delta \neq \mathbf{0}$ .** Pour passer au cas plus général, nous devons reformuler  $H_0$ . Si  $\mathbf{L}\boldsymbol{\beta} = \boldsymbol{\delta}$ , alors  $\boldsymbol{\beta} = \mathbf{T}\boldsymbol{\alpha} + \boldsymbol{\gamma}$ , où  $\mathbf{T}$  est définie comme ci-dessus [une matrice  $q \times (q - r)$  dont les colonnes sont une base de  $\mathcal{N}(\mathbf{L})$ ] et  $\boldsymbol{\gamma}$  satisfait  $\mathbf{L}\boldsymbol{\gamma} = \boldsymbol{\delta}$ . Le modèle réduit devient

$$\mathbf{y} = \mathbf{X}\mathbf{T}\boldsymbol{\alpha} + \mathbf{X}\boldsymbol{\gamma} + \boldsymbol{\varepsilon}$$

ou encore

$$\mathbf{y} - \mathbf{X}\boldsymbol{\gamma} = \mathbf{X}\mathbf{T}\boldsymbol{\alpha} + \boldsymbol{\varepsilon}$$

et la somme des carrés résiduelle sous cette hypothèse est

$$(\mathbf{y} - \mathbf{X}\boldsymbol{\gamma})'(\mathbf{I} - \mathbf{P}_0)(\mathbf{y} - \mathbf{X}\boldsymbol{\gamma})$$

Puisque la somme des carrés résiduelle  $\mathbf{y}'(\mathbf{I} - \mathbf{P})\mathbf{y}$  sous le modèle peut aussi s'écrire sous la forme

$$\text{SCR} = (\mathbf{y} - \mathbf{X}\boldsymbol{\gamma})'(\mathbf{I} - \mathbf{P})(\mathbf{y} - \mathbf{X}\boldsymbol{\gamma})$$

(le vecteur  $\mathbf{X}\mathbf{T}$  étant annulé par  $\mathbf{I} - \mathbf{P}$ ), la différence  $\text{SCR}_0 - \text{SCR}$  s'écrit

$$\text{SCR}_0 - \text{SCR} = (\mathbf{y} - \mathbf{X}\boldsymbol{\gamma})'(\mathbf{P} - \mathbf{P}_0)(\mathbf{y} - \mathbf{X}\boldsymbol{\gamma})$$

Cette forme quadratique doit être comparée au numérateur

$$(\mathbf{L}'\hat{\boldsymbol{\beta}} - \boldsymbol{\delta})'[\mathbf{L}'(\mathbf{X}'\mathbf{X})^{-1}\mathbf{L}]^{-1}(\mathbf{L}'\hat{\boldsymbol{\beta}} - \boldsymbol{\delta})$$

de la statistique  $F$ . Le facteur  $\mathbf{L}'\hat{\boldsymbol{\beta}} - \boldsymbol{\delta}$  qui y apparaît peut s'écrire comme

$$\begin{aligned} \mathbf{L}'\hat{\boldsymbol{\beta}} - \boldsymbol{\delta} &= \mathbf{L}'(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{y} - \mathbf{L}'\boldsymbol{\gamma} \\ &= \mathbf{L}'(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{y} - \mathbf{L}'(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{X}\boldsymbol{\gamma} \\ &= \mathbf{L}'(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'(\mathbf{y} - \mathbf{X}\boldsymbol{\gamma}), \end{aligned}$$

et la forme quadratique au numérateur est donc

$$(\mathbf{y} - \mathbf{X}\boldsymbol{\gamma})'\mathbf{X}(\mathbf{X}'\mathbf{X})^{-1}\mathbf{L}[\mathbf{L}'(\mathbf{X}'\mathbf{X})^{-1}\mathbf{L}]^{-1}\mathbf{L}'(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'(\mathbf{y} - \mathbf{X}\boldsymbol{\gamma}) = (\mathbf{y} - \mathbf{X}\boldsymbol{\gamma})'\mathbf{P}_1(\mathbf{y} - \mathbf{X}\boldsymbol{\gamma})$$

Ceci complète la démonstration, puisque nous avons déjà démontré que les matrices  $\mathbf{P} - \mathbf{P}_0$  et  $\mathbf{P}_1$  sont identiques.

### Le théorème de Gauss-Markov

Nous avons obtenu l'estimateur  $\hat{\boldsymbol{\beta}} = (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{y}$  par la méthode des moindres carrés, qui n'est qu'un critère parmi d'autres pour choisir un estimateur. Les autres critères mènent-ils au même estimateur? La réponse est oui, la plupart des critères connus mènent à l'estimateur  $\hat{\boldsymbol{\beta}}$ . L'un est la méthode du maximum de vraisemblance : si le vecteur  $\mathbf{y} \sim \mathcal{N}(\mathbf{X}\boldsymbol{\beta}; \sigma^2\mathbf{I})$ , la valeur de  $\boldsymbol{\beta}$  qui maximise la fonction de vraisemblance est  $\hat{\boldsymbol{\beta}}$ . Un autre critère consiste à choisir, dans une classe restreinte d'estimateurs, le « meilleur » estimateur. Une façon de restreindre la classe des estimateurs est d'exiger un estimateur *linéaire*. On restreint la classe encore plus en exigeant un estimateur sans biais. Il se peut que dans cette classe restreinte, il existe un seul « meilleur » estimateur. Quel sens donne-t-on à « meilleur »? Habituellement, lorsqu'il s'agit d'un estimateur scalaire, un estimateur est le « meilleur » s'il a la plus petite variance. Mais lorsque l'estimateur est un vecteur, la notion de « meilleur » se généralise difficilement. Le cas présent, cependant, est un des cas relativement rares où la généralisation se fait de façon particulièrement satisfaisante. L'énoncé exact est dans le *théorème de Gauss-Markov*.

*Théorème de Gauss-Markov.* Soit  $\hat{\boldsymbol{\beta}} = (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{y}$  l'estimateur des moindres carrés. Soit  $\tilde{\boldsymbol{\beta}} = \mathbf{A}\mathbf{y}$  un autre estimateur linéaire sans biais pour  $\boldsymbol{\beta}$ . Alors

$$\text{Var}(\tilde{\boldsymbol{\beta}}) - \text{Var}(\hat{\boldsymbol{\beta}}) \text{ est semi-définie positive.}$$









### Données centrées

Il est parfois commode de « centrer » les données, c'est-à-dire, de soustraire de chacune la moyenne de la variable, car alors l'espérance des observations ne dépend plus de  $\beta_0$ , ce qui permet de se concentrer sur les autres composantes de  $\beta$ . Ceci équivaut à multiplier les colonnes de données par une certaine matrice  $\mathbf{C}$  définie par  $\mathbf{C} = \mathbf{I} - \mathbf{e}\mathbf{e}'/n$ . Soit  $\mathbf{X} = [\mathbf{e} \mid \mathbf{X}_1]$ . On peut donc écrire le modèle sous la forme  $\mathbf{y} = \beta_0\mathbf{e} + \mathbf{X}_1\beta_1 + \boldsymbol{\varepsilon}$ . Sous forme centrée, le modèle devient  $\mathbf{u} = \mathbf{Z}\beta_1 + \boldsymbol{\delta}$ , où  $\mathbf{u} = \mathbf{C}\mathbf{y}$ ,  $\mathbf{Z} = \mathbf{C}\mathbf{X}_1$  et  $\boldsymbol{\delta} = \mathbf{C}\boldsymbol{\varepsilon}$ . Remarquez que  $\boldsymbol{\delta}$  est de matrice de covariance  $\sigma^2\mathbf{C}$ , une matrice singulière :  $\mathbf{C}$  est de rang  $n-1$ . Néanmoins, tout se déroule comme dans le modèle linéaire avec matrice de covariance scalaire :  $\hat{\beta}_1 = (\mathbf{Z}'\mathbf{Z})^{-1}\mathbf{Z}'\mathbf{y} = (\mathbf{X}_1\mathbf{C}\mathbf{X}_1)^{-1}\mathbf{X}_1\mathbf{C}\mathbf{y}$ , de variance  $\text{Var}(\hat{\beta}_1) = \sigma^2(\mathbf{Z}'\mathbf{Z})^{-1} = \sigma^2(\mathbf{X}_1\mathbf{C}\mathbf{X}_1)^{-1}$ .

On développe ces propriétés en définissant une transformation équivalente mais non singulière. Puisque  $\mathbf{C}$  est idempotente et symétrique elle peut s'écrire sous la forme  $\mathbf{E}\mathbf{E}'$  où  $\mathbf{E}$  est de dimensions  $n \times (n-1)$  et  $\mathbf{E}'\mathbf{E} = \mathbf{I}_{n-1}$  (les colonnes de  $\mathbf{E}$  sont orthonormales). On définit la transformation  $\mathbf{E}'\mathbf{y} = \mathbf{E}'\mathbf{X}_1\beta_1 + \boldsymbol{\eta}$  où  $\boldsymbol{\eta} = \mathbf{E}'\boldsymbol{\varepsilon}$  est de moyenne nulle et de matrice de covariance  $\sigma^2\mathbf{I}_{n-1}$ . Ce modèle est alors le modèle classique avec matrice de covariance scalaire.