

ESTIMATEUR DE HOERL-KENNARD (H, J1)

(12 / 04 / 2020, © Monfort, Dicostat2005, 2005-2020)

En présence de **colinéarité** approchée, l'**estimateur « raccourci » de HOERL - KENNARD** constitue une méthode d'estimation du paramètre d'un **modèle de régression linéaire** : cette méthode recherche un compromis entre le **biais** et la **variance** de l'**estimateur des mco** de ce paramètre.

(i) Soit, dans un **espace de variables** :

$$(1) \quad \eta = \xi' b + \varepsilon, \quad \text{avec } E \varepsilon = 0, V \varepsilon = \sigma^2,$$

un **modèle de régression multiple** linéaire, « observé » (ie appliqué aux observations (X, y) d'un **espace d'observation**) selon :

$$(2) \quad y = X b + u, \quad \text{avec } E u = 0, V u = \sigma^2 \cdot I_N.$$

On suppose que $\text{rg } X = K$ mais que $X \in M_{NK}(\mathbf{R})$ est une **matrice** quasi-colinéaire (ou « mal conditionnée »), ie que $\text{Dét}(X' X)$ n'est pas nul mais quasi-nul (ie $|\text{Dét}(X' X)| \ll +\infty$) (cf **déterminant, rang, matrice singulière, quasi-colinéarité**).

L'estimateur des mco \hat{b} de b , dont la **matrice de dispersion** est $V \hat{b} = \sigma^2 (X' X)^{-1}$, possède un **écart quadratique moyen** (scalaire) tq :

$$(3) \quad E \|\hat{b} - b\|^2 = \sigma^2 \text{tr}(X' X)^{-1} = \sigma^2 \sum_k \lambda_k^{-1},$$

où les λ_k sont les **valeurs propres** de $X' X$.

Par suite :

$$(4) \quad E \|\hat{b} - b\|^2 \geq \sigma^2 \{\min_{k=1}^K \lambda_k\}^{-1}, \quad \text{ou} \quad E \|\hat{b}\|^2 \geq \|b\|^2 + (\min_{k=1}^K \lambda_k)^{-1} \sigma^2.$$

Si $\min_{k=1}^K \lambda_k$ est « négligeable » (ie $\min_{k=1}^K \lambda_k \ll +\infty$), cet écart quadratique moyen peut prendre des valeurs « importantes » (ie $E \|\hat{b} - b\|^2 \gg 0$). Autrement dit, l'une (au moins) des coordonnées $b_k^{\hat{}}$ de \hat{b} peut être éloignée de la coordonnée correspondante b_k de b .

(ii) En pratique, si X est une matrice « contrôlée » (eg dans le cadre d'un **plan d'expérience**), il est souvent possible de redéfinir le plan et de recommencer l'expérience (supposée renouvelable) pour corriger le défaut précédent (cf **renouvellement, plan répété**).

Dans le cas contraire, on peut décider qu'un estimateur biaisé de b est préférable à \hat{b} s'il n'est pas trop sensible à la quasi-colinéarité de X , ou à la quasi-singularité de $X' X$, ie à la quasi-nullité de $\text{Dét}(X' X)$ (cf **estimateur sans biais**).

Par suite, « raccourcir » la régression (2) consiste à remplacer \hat{b} par une famille $(b_{\alpha}^{\#})_{\alpha \geq 0}$ d'estimateurs biaisés de b possédant cependant un écart quadratique moyen inférieur à celui de \hat{b} . Si $X'X$ est quasi-singulière, alors $X'X + \alpha I_K$ sera « moins singulière » et l'estimateur « raccourci » de A.E. HOERL - R.W. KENNARD de b est défini en remplaçant l'équation normale usuelle :

$$(5) \quad X'X b = X' y$$

par l'équation « perturbée » (ie « à matrice $X'X$ perturbée ») suivante :

$$(6) \quad (X'X + \alpha I_K) b = X' y,$$

d'où la famille d'estimateurs de b suivante :

$$(7) \quad b_{\alpha}^{\wedge} = (X'X + \alpha I_K)^{-1} X' y, \quad \forall \alpha \in \mathbf{R}_+.$$

Ces estimateurs raccourcis $(b_{\alpha}^{\wedge})_{\alpha \geq 0}$ possèdent les propriétés suivantes :

(a) $b_0^{\wedge} = \hat{b}$ (estimateur des mco) ;

(b) $\forall \alpha > 0$, $b_{\alpha}^{\#}$ est biaisé et $E \|b_{\alpha}^{\wedge}\| < E \|\hat{b}\|$;

(c) si $\alpha \rightarrow +\infty$, on a $\forall b_{\alpha}^{\wedge} \rightarrow 0$ mais $E b_{\alpha}^{\wedge} - b \rightarrow +\infty$. De plus, $b_{\alpha}^{\wedge} \rightarrow 0$.

(iii) Le problème consiste alors à choisir un **facteur de raccourcissement** α qui soit « optimal ». La **représentation graphique** de la fonction vectorielle $\alpha \mapsto b_{\alpha}^{\wedge}$ peut être utilisée pour déterminer une valeur α^* de α à partir de laquelle toutes les (fonctions) coordonnées $\alpha \mapsto b_{k,\alpha}$ de $\alpha \mapsto b_{\alpha}^{\wedge}$ commencent à se stabiliser.

On montre que la valeur optimale de α , ie celle qui minimise l'**écart quadratique moyen** $E \|b_{\alpha}^{\wedge} - b\|^2$, est tq $(\alpha^*)^2 = K \cdot \sigma^2 / \|b\|^2$. Cette valeur peut être estimée par de l'estimateur suivant :

$$(8) \quad ((\alpha^*)^2)^{\wedge} = K \cdot (\sigma^2)^{\wedge} / \|\hat{b}\|^2,$$

où $(\sigma^2)^{\wedge} = \|y - X \hat{b}\|^2 / (N - K) = \|u^{\wedge}\|^2 / (N - K)$ est l'**estimateur des mco** usuel de σ^2 , obtenu par la **méthode des mco**, et où \hat{b} est l'estimateur des mco de b (estimateur qui peut éventuellement être remplacé par l'estimateur sur composantes principales de b) (cf **régression sur composantes principales**).

Si $K > 2$ et si $u \sim \mathcal{N}_N(0, \sigma^2 \cdot I_N)$ (**loi normale** centrée), on montre que :

$$(9) \quad E (\alpha^*)^{\wedge} \in [0, K / (K - 2)].$$

Par ailleurs, on montre qu'il existe une valeur $\alpha^{\sim} \in \mathbf{R}_+$ tq le problème d'optimisation (programme mathématique) suivant :

$$(10) \quad \inf \|y - X\beta\|^2 \text{ sous } \|\beta\|^2 = r^2 \text{ (donné)}$$

admette pour solution l'estimateur \hat{b}_{α} .

(iv) Dans ce qui précède, on peut supposer que X est une **matrice d'observation** de K **variables exogènes** normalisées, ie que $X = P T S^{-1}$, où T est la matrice d'observation des variables initiales (ie non normalisées), P la **matrice de centrage par rapport à la moyenne** empirique et S la **matrice diagonale** dont chaque terme s_k est l'**écart-type** empirique (non corrigé), ie tq $s_k^2 = N^{-1} \sum_{n=1}^N (t_{nk} - \bar{t}_k)^2$, avec $\bar{t}_k = N^{-1} \sum_n t_{nk}$ (**moyenne empirique**), $\forall k \in N_K^*$.

Un **estimateur raccourci généralisé** est défini en remplaçant dans (6) la matrice α I_K par une **matrice définie positive** D tq $X'X + D$ soit une **matrice régulière**.