

CALMAR 2 :
une nouvelle version
de la macro Calmar
de redressement
d'échantillon par calage

Josiane Le Guennec (Cepe-Ensai)

Olivier Sautory (Cepe-Insee)

Calages simultané

Le problème

Collecte d'informations à différents niveaux d'observation :

- ménages, individus, individus-Kish
- entreprises, établissements.

+ information auxiliaire disponible pour chaque niveau.

Que faire ?

- calages indépendants sur les différents niveaux d'observation ;
- calages simultanés :
 - mêmes poids pour tous les individus (établissements) d'un(e) même ménage (entreprise)
 - cohérence entre les statistiques provenant des différents fichiers de l'enquête.

La méthode

Principe :

calage réalisé au niveau le plus élevé, en "remontant" les variables, et l'information, auxiliaires relatives aux niveaux inférieurs.

Exemple : enquête ménages (échantillon S_M) + tous les individus du ménage (échantillon S_I)

Pondération du ménage m : $d_m = 1 / \pi_m$

Pondération de l'individu i du ménage m : $d_{m,i} = d_m \forall i \in \text{men}_m$

X_m = vecteur des variables auxiliaires connues pour tout ménage m de S_M

$X = \sum_{m \in U_m} X_m$ = vecteur des totaux sur la population U_M , connus

$Z_{m,i}$ = vecteur de variables auxiliaires connues pour tout individu (m,i) de S_I

$Z = \sum_{i \in U_I} Z_i$ = vecteur des totaux sur la population U_I , connus

On calcule les **totaux par ménage** : $z_m = \sum_{(m,i) \in \text{men}_m} z_{m,i}$
 (on a : $Z = \sum_{m \in U_M} z_m$)

Vecteur de variables de calage pour le ménage m : (x_m, z_m)

Vecteur des totaux : (X, Z)

Équations de calage :

$$\sum_{m \in S_M} \frac{F(x'_m \lambda + z'_m \mu)}{\pi_m} (x_m, z_m) = (X, Z) \rightarrow \text{pondérations } w_m$$

w_m = pondération du ménage m dans S_M

$w_{m,i} = w_m$ = pondération de l'individu (m,i) du ménage m dans S_I

$$\text{On a bien : } \sum_{i \in S_I} w_{m,i} z_{m,i} = \sum_{m \in S_M} w_m \sum_{(m,i) \in \text{men}_m} z_{m,i} = \sum_{m \in S_M} w_m z_m = Z$$

***Calmar 2 permet de réaliser de tels
calages simultanés.***

***L'utilisateur doit fournir les différentes tables en
entrée et les tables des marges correspondantes : le
programme réalise toutes les opérations nécessaires
pour se ramener à un calage unique, et affecte les
pondérations adéquates dans les différentes tables.***

Calage et colinéarités

La résolution des équations de calage nécessite l'inversion d'une matrice de la forme : $\Phi = \sum_{k \in S} \mathbf{x}_k \mathbf{x}'_k$

→ **les variables de calage ne doivent pas être colinéaires.**

Le programme élimine automatiquement les colinéarités structurelles qui apparaissent lorsque plusieurs variables catégorielles figurent dans les variables de calage.

D'autres colinéarités entre variables de calage peuvent apparaître.

Exemple :

calage d'une enquête ménages sur deux répartitions "croisées" :

taille du ménage \times *région* et *CS du chef de ménage* \times *région*

→ une équation redondante par région

2 solutions

- on redéfinit les variables de calage ;
- on utilise la technique des **matrices inverses généralisées**.

Cette dernière option est disponible dans Calmar 2.

**Une nouvelle fonction
de distance**

Une nouvelle fonction de distance est proposée dans Calmar2, la fonction *sinus hyperbolique généralisée* :

$$G_{\alpha}(r) = \frac{1}{2\alpha} \int_1^r \text{sh}\left[\alpha\left(t - \frac{1}{t}\right)\right] dt \quad \text{où } \alpha \text{ est un coefficient positif}$$

Caractéristiques de la méthode :

- poids toujours positifs ;
- distributions de poids moins étendues qu'avec la méthode exponentielle du côté des poids élevés ;
- possibilité de réduire l'étendue de la distribution des poids grâce au coefficient α .

**Le traitement de la
non-réponse totale
par calage généralisé**

Équations de calage

$$\sum_{k \in \mathcal{I}} d_k F(z'_k, \lambda) \mathbf{x}_k = X$$

où F est l'une des fonctions habituelles de calage.

Propriétés de la méthode

- permet une correction de la non-réponse même lorsque les variables qui l'expliquent ne sont connues que sur les répondants
- traite en particulier le cas où les variables facteurs de la non-réponse sont des variables d'intérêt (*mécanisme de réponse non ignorable*)
- produit une réduction du biais dû à la non-réponse grâce aux variables Z_k et une diminution de la variance grâce aux variables X_k
- si F linéaire : estimation par régression avec variables instrumentales (Z_k)

$\hat{Y}_{\text{calé}} = \hat{Y}_{\text{HT}} + (X - \hat{X}_{\text{HT}})' \tilde{b}$, où \tilde{b} solution des équations normales :

$$\sum_{k \in \mathcal{R}} d_k z_k (y_k - x_k' b) = 0$$

Cette méthode est programmée dans Calmar 2.