

Introduction à la théorie des sondages

Cours 5 : Méthodes de redressement

Martin Chevalier

`martin.chevalier@insee.fr`

`http://nc233.com/teaching`

INSEE, Département des méthodes statistiques

5 mars 2018

Chapitre 1

Rappel des épisodes précédents

Où en sommes-nous ?

La méthodologie d'Horvitz-Thompson permet d'obtenir un **estimateur sans biais** avec une **variance calculable**.

La **stratification** améliore l'estimation obtenue par sondage aléatoire simple en exploitant l'information auxiliaire de la base de sondage et **diminue la variance d'estimation**.

La **correction de la non-réponse** (imputation ou repondération) permet (dans la plupart des cas) de **neutraliser le biais** introduit par la non-réponse de certaines unités échantillonnées.

Ce qu'il reste à faire Améliorer encore l'estimateur en utilisant l'information auxiliaire **au moment de l'estimation**.

Objectifs des méthodes de redressement

- 1 Exploiter l'information auxiliaire qui n'a pas pu l'être au moment du tirage pour **améliorer la précision de l'estimateur**.
- 2 **Assurer la cohérence** entre les estimations produites par l'enquête et une ou plusieurs sources de référence.

En pratique Ajustement de l'estimateur d'Horvitz-Thompson...

- ... pour garantir une **estimation parfaite** de certaines variables...
- ... et ainsi **diminuer sa variance**...
- ... tout en gardant le caractère **sans biais**.

Remarque Dans l'ensemble de cette partie, le plan de sondage est un sondage aléatoire simple et il n'y a pas de non-réponse.

Application : Enquête sur la fréquentation des cinémas

Le distributeur d'un film souhaite connaître le **nombre d'entrées réalisées une semaine donnée**.

Habituellement des remontées sont effectuées tous les mois, mais il souhaite avoir une **information plus rapidement** pour ajuster sa campagne promotionnelle.

Pour ce faire, il interroge un **échantillon de 100 cinémas** (parmi les 2 020 exploitants en activité) tiré par sondage aléatoire simple.

La variable d'intérêt est le **nombre d'entrées réalisées par le film** pour la semaine du 20 au 27 février 2017.

L'estimateur d'Horvitz-Thompson obtenu est de **464 923** avec un **intervalle de confiance à 95 % de [243 061 ; 686 785]**.

Application : Enquête sur la fréquentation des cinémas

Le distributeur n'est **pas très satisfait** de cette fourchette extrêmement large.

Il envisage d'exploiter une information disponible quelques jours après l'enquête, le **nombre de projections du film** :

- sur l'ensemble de la France, le film a été projeté 5 061 fois ;
- à partir de l'échantillon, ce nombre est estimé à 3 333 fois.

Intuition

- Nombre de projections et nombre d'entrées étant **corrélées**, le distributeur pourrait être tenté de **redresser** l'estimateur du nombre d'entrées en le multipliant par $\frac{5061}{3333} = 1,52$.
- L'utilisation du nombre de projections comme information auxiliaire pourrait venir « **stabiliser** » l'estimateur.

Sommaire

- 1 Rappel des épisodes précédents
- 2 Redressement par le ratio
- 3 Redressement par post-stratification
- 4 Généralisation : Calage sur marges

Chapitre 2

Redressement par le ratio

Définition

L'estimateur par le ratio est utilisé quand la variable auxiliaire X est **quantitative**.

Exemple Nombre de projections pour estimer le nombre d'entrées réalisées par un film.

Sachant que le total de la variable auxiliaire $T(X)$ est connu, on définit l'**estimateur par le ratio du total de la variable Y** par :

$$\hat{T}_{ratio}(Y) = \hat{T}_{HT}(Y) \times \frac{T(X)}{\hat{T}_{HT}(X)}$$

Intuition Si $T(X) > \hat{T}_{HT}(X)$, l'estimateur par le ratio de Y est supérieur à l'estimateur d'Horvitz-Thompson.

Propriétés

- ① Asymptotiquement sans biais :

$$B(\hat{T}_{ratio}(Y)) \xrightarrow[n \rightarrow +\infty]{} 0$$

- ② Variance d'autant plus faible que Y est corrélée à X :

$$V(\hat{T}_{ratio}(Y)) \approx N^2 \left(1 - \frac{n}{N}\right) \frac{S_Y^2 + R^2 S_X^2 - 2RS_{X,Y}}{n}$$

avec $R = \frac{T(Y)}{T(X)}$

- ③ **Propriété de calage** $T(X)$ est estimé parfaitement :

$$\hat{T}_{ratio}(X) = \hat{T}_{HT}(X) \times \frac{T(X)}{\hat{T}_{HT}(X)} = T(X)$$

Application : Enquête sur la fréquentation des cinémas


Une fois les informations complètes sur le film remontées, le distributeur **évalue la pertinence d'un redressement par le ratio** en utilisant le nombre de projections comme variable auxiliaire.

Il tire 1 000 échantillons de taille 100 et calcule pour chacun la valeur de l'estimateur d'Horvitz-Thompson et celle de l'estimateur redressé par le ratio.

Exemple L'estimateur par le ratio associé au premier échantillon tiré donne :

$$\hat{T}_{ratio}(Y) = 464923 \times \frac{5061}{3333} = 705963$$

Application : Enquête sur la fréquentation des cinémas



Application : Enquête sur la fréquentation des cinémas

Valeur dans la population 731 892 entrées

Estimateur d'Horvitz-Thompson (1 000 simulations)

- moyenne empirique : 730 942
- écart-type empirique : 153 835

Estimateur redressé par le ratio (1 000 simulations)

- moyenne empirique : 730 299
- écart-type empirique : 16 039

Redressement par le ratio et repondération

L'estimation par le ratio peut être vue comme une repondération. En notant $d_k = \frac{1}{\pi_k}$ le poids de sondage de l'unité k , l'estimateur d'Horvitz-Thompson s'écrit en effet :

$$\hat{T}_{HT}(Y) = \sum_{k \in s} d_k y_k$$

Dès lors, on peut réécrire l'estimation par le ratio :

$$\hat{T}_{ratio}(Y) = \sum_{k \in s} d_k y_k \times \frac{T(X)}{\hat{T}_{HT}(X)} = \sum_{k \in s} \left(d_k \times \frac{T(X)}{\hat{T}_{HT}(X)} \right) \times y_k = \sum_{k \in s} w_k y_k$$

avec $\forall k \in s \quad w_k = d_k \times \frac{T(X)}{\hat{T}_{HT}(X)}$

En pratique Les redressements sont effectués **une fois pour toutes** au moment de la production d'une enquête. Un vecteur de **poids redressés** est ainsi produit et a vocation à être utilisé à la place des poids de sondage.

Chapitre 3

Redressement par post-stratification

Définition

L'estimateur post-stratifié est utilisé quand la variable auxiliaire X est **qualitative** (ou recodée en tranches).

Exemple Le fait pour une salle de cinéma d'être située dans une zone en période de vacances scolaires pour la semaine de référence ou non.

On peut alors définir H groupes d'unités (les **post-strates**) selon les modalités de cette variables et calculer l'estimateur post-stratifié :

$$\hat{T}_{post}(Y) = \sum_{h=1}^H \hat{T}_{h,HT}(Y) \frac{N_h}{\hat{N}_{h,HT}}$$

où N_h est le nombre d'unités de la population dans la post-strate h et $\hat{N}_{h,HT}$ son estimateur à partir de l'échantillon.

Remarque Quand le plan de sondage est stratifié selon X , $\hat{N}_{h,HT} = N_h$ et donc $\hat{T}_{post}(Y) = \hat{T}_{HT}(Y)$.

Propriétés

- 1 Sans biais si tous les N_h sont entiers.
- 2 Variance supérieure à celle d'un SAS stratifié avec allocation proportionnelle ;

$$V(\hat{T}_{post}(Y)) \approx \underbrace{N^2 \frac{1-f}{n} \sum_{h=1}^H \frac{N_h}{N} S_h^2}_{\text{Variance d'un SAS stratifié avec alloc. proportionnelle}} + \underbrace{N^2 \frac{1-f}{n^2} \sum_{h=1}^H \frac{N - N_h}{N} S_h^2}_{\text{Variance supplémentaire due à la post-stratification}}$$

- 3 **Propriété de calage** La taille des H post-strates est estimée parfaitement :

$$\forall h = 1, \dots, H \quad \hat{N}_{h,post} = N_h$$

Application : Enquête sur la fréquentation des cinémas

Le distributeur envisage également d'utiliser comme variable auxiliaire le fait que la zone dans laquelle sont situés les cinémas a été en **vacances scolaires** du 20 au 27 février.

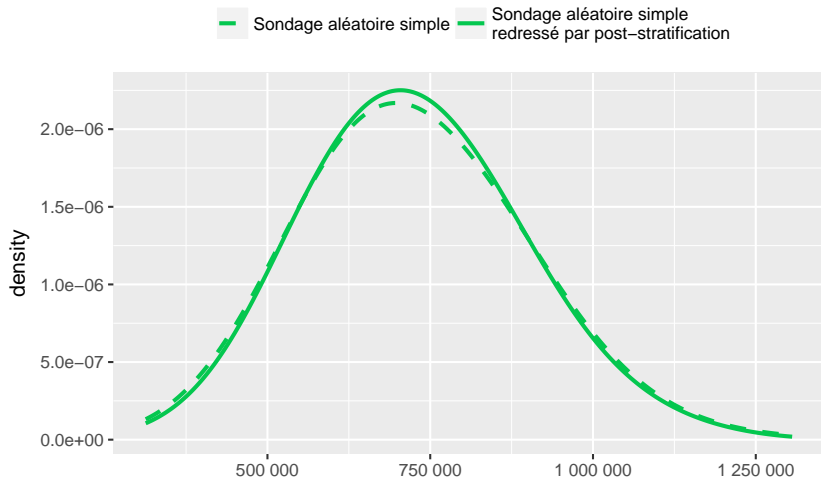
Il constitue donc **deux post-strates** et les utilise pour redresser l'estimateur d'Horvitz-Thompson. À nouveau l'évaluation de la performance de ce redressement est effectuée sur 1 000 simulations.

Exemple À partir du tout premier échantillon, on estime :

- le nombre de cinéma dans une zone en vacances scolaires à 1 192 (contre 1 244 dans la population) ;
- le nombre de cinéma dans une zone non en vacances scolaires à 828 (contre 776 dans la population).

$$\hat{T}_{post}(Y) = 443915 \times \frac{1244}{1192} + 21008 \times \frac{776}{828} = 483042$$

Application : Enquête sur la fréquentation des cinémas



Application : Enquête sur la fréquentation des cinémas

Valeur dans la population 731 892 entrées

Estimateur d'Horvitz-Thompson (1 000 simulations)

- moyenne empirique : 725 513
- écart-type empirique : 153 752

Estimateur redressé par le ratio (1 000 simulations)

- moyenne empirique : 725 812
- écart-type empirique : 145 332

Post-stratification et repondération

Comme pour l'estimation par le ratio, il est possible de réécrire l'estimateur post-stratifié sous la forme d'une répondération :

$$\hat{T}_{post}(Y) = \sum_{h=1}^H \sum_{k \in s_h} d_k y_k \frac{N_h}{\hat{N}_{h,HT}} = \sum_{k \in S} \left(d_k \times \underbrace{\frac{N_h}{\hat{N}_{h,HT}}}_{h|k \in s_h} \right) y_k = \sum_{k \in S} w_k y_k$$

avec $\forall k \in s \quad w_k = d_k \times \underbrace{\frac{N_h}{\hat{N}_{h,HT}}}_{h|k \in s_h}$

En pratique À nouveau, cette propriété permet de simplifier la mise en œuvre des redressements en calculant au moment de la production de l'enquête un **vecteur de poids redressés** à utiliser à la place des poids de sondage.

Chapitre 4

Généralisation : Calage sur marges

Redresser sur plusieurs variables simultanément

Le redressement par le ratio ou la post-stratification sont des méthodes simples et classiques pour utiliser de l'information auxiliaire au moment de l'estimation.

Néanmoins, elles présentent l'une et l'autre une limite principale : **elles ne peuvent intégrer l'information auxiliaire que d'une seule variable.**

Exemple On ne peut pas utiliser conjointement dans les redressements l'information sur le nombre de projections et les vacances scolaires.

Remarque Dans le cas de la post-stratification, une possibilité consiste à croiser les modalités de toutes les variables (qualitatives) que l'on souhaite utiliser, mais cela suppose d'avoir une **information auxiliaire sur leur distribution jointe.**

Calage sur marges : intuition et principe

Au moment de l'estimation on dispose des éléments suivants :

- pour chaque unité k de l'échantillon, un poids de sondage d_k ;
- p **variables de calage** formant la matrice $X = (x_1 \ x_2 \ \dots \ x_p)$ et renseignées pour chaque unité k de l'échantillon ;
- la valeur du total **dans la population** des p variables de calage : $T(X) = (T(x_1) \ T(x_2) \ \dots \ T(x_p))$

Intuition

- Utiliser les poids de sondage d_k **garantit une estimation sans biais** . . .
- . . . mais les modifier de façon à obtenir une estimation parfaite des marges de calage **améliore la précision des estimateurs**.

Principe du calage sur marges Trouver le **vecteur de poids calés** w_k qui conduise à **estimer parfaitement les marges de calage** et qui soit **le plus proche possible de** d_k .

Calage sur marges : formulation du problème

D'un point de vue mathématique, ce problème se formule de la façon suivante :

$$\left\{ \begin{array}{l} \min_{w_k} \sum_{k \in S} d_k G\left(\frac{w_k}{d_k}\right) \\ \text{sous la contrainte } \sum_{k \in S} w_k X_k = T(X) \end{array} \right.$$

où G est une certaine **fonction de distance** entre les poids initiaux d_k et les poids finaux w_k :

- $G(1) = 0$;
- $G\left(\frac{w_k}{d_k}\right)$ est d'autant plus grand que $\frac{w_k}{d_k}$ est différent de 1.

Calage sur marges : fonction de distance et résolution

La résolution de ce problème fait intervenir la **fonction réciproque de la dérivée** de la fonction G , notée en général F .

La forme de la fonction F identifie la **méthode de calage** mise en œuvre, dont les propriétés diffèrent :

- méthode linéaire : $F(x) = 1 + x$
- méthode exponentielle (ou *raking ratio*) : $F(x) = \exp(x)$
- méthode logistique : $F(x) = \frac{L(U-1) + U(L-1)\exp(Au)}{U-1 + (1-L)\exp(Au)}$
avec L et U des bornes pour $\frac{w_k}{d_k}$ et A une constante
- méthode linéaire tronquée : $F(x) = 1 + x$ pour $x \in [L; U]$

Dans tous les cas, la résolution s'appuie sur un **algorithme itératif**.

Illustration : *Raking ratio* sur deux variables dichotomiques

Identifiant	Sexe	Île-de-France	Poids de sondage d_k
A	H	Oui	10
B	H	Non	10
C	H	Non	10
D	F	Oui	10
E	F	Oui	10
F	F	Non	10

Marges dans la population

- $T(\text{Sexe} = \text{H}) = 20$
- $T(\text{Sexe} = \text{F}) = 40$
- $T(\hat{\text{Île-de-France}} = \text{Oui}) = 40$
- $T(\hat{\text{Île-de-France}} = \text{Non}) = 20$

Illustration : *Raking ratio* sur deux variables dichotomiques

Étape 1

IdF \ Sexe	Oui	Non	Marge
H	10	20	30 (20)
F	20	10	30 (40)
Marge	30 (40)	30 (20)	60 (60)

× 20/30

× 40/30

Étape 2

IdF \ Sexe	Oui	Non	Marge
H	6,67	13,33	20 (20)
F	26,67	13,33	40 (40)
Marge	33,34 (40)	26,67 (20)	60 (60)

× 40/33,34

× 20/26,67

Illustration : *Raking ratio* sur deux variables dichotomiques

Étape 3

IdF \ Sexe	Oui	Non	Marge
H	8	10	18 (20)
F	32	10	42 (40)
Marge	40 (40)	20 (20)	60 (60)

$$\times 20/18$$

$$\times 40/42$$

Étape 4

IdF \ Sexe	Oui	Non	Marge
H	8,88	11,11	20 (20)
F	30,48	9,52	40 (40)
Marge	39,36 (40)	20,63 (20)	60 (60)

$$\times 40/39,36$$

$$\times 20/20,63$$

Illustration : *Raking ratio* sur deux variables dichotomiques

Étape 5

9,03	10,77	19,80 (20)
30,97	9,23	40,20 (40)
40 (40)	20 (20)	60 (60)

Étape 6

9,12	10,88	20 (20)
30,81	9,19	40 (40)
39,93 (40)	20,07 (20)	60 (60)

Étape 7

9,14	10,84	19,98 (20)
30,86	9,16	40,02 (40)
40 (40)	20 (20)	60 (60)

Étape 8

9,15	10,85	20 (20)
30,85	9,15	40 (40)
40 (40)	20 (20)	60 (60)

Détermination des poids finaux Multiplication du poids initial d_k par le rapport entre les totaux de chaque cellule après/avant l'algorithme de calage.

Exemple $d_B = 10$, $sexe_B = H$ et $idf_B = Non$

- total final/initial de la cellule : $10,85/20$
- poids final $w_b = 10 \times 10,85/20 = 5,425$

Illustration : *Raking ratio* sur deux variables dichotomiques

Identifiant	Sexe	Île-de-France	d_k	Poids calé w_k
A	H	Oui	10	9,150
B	H	Non	10	5,425
C	H	Non	10	5,425
D	F	Oui	10	15,425
E	F	Oui	10	15,425
F	F	Non	10	9,150

Vérification des contraintes de calage

- $\hat{T}(\text{Sexe} = \text{H}) = 9,150 + 5,425 + 5,425 = 20 = T(\text{Sexe} = \text{H})$
- $\hat{T}(\text{Sexe} = \text{F}) = 15,425 + 15,425 + 9,150 = 40 = T(\text{Sexe} = \text{F})$
- $\hat{T}(\text{Idf} = \text{Oui}) = 9,150 + 15,425 + 15,425 = 40 = T(\text{Idf} = \text{Oui})$
- $\hat{T}(\text{Idf} = \text{Non}) = 5,425 + 5,425 + 9,150 = 20 = T(\text{Idf} = \text{Non})$

Propriétés de l'estimateur obtenu par calage

- 1 Quelle que soit la méthode, asymptotiquement sans biais :

$$B(\hat{T}_{calage}(Y)) \xrightarrow[n \rightarrow +\infty]{} 0$$

- 2 Quelle que soit la méthode, variance **approximativement égale** et qui s'exprime en fonction d'un résidu :

$$V(\hat{T}_{calage}(y)) \approx V(\hat{T}_{calage}(\varepsilon))$$

où ε est le **résidu de la régression (linéaire) de Y sur les variables de calage**.

Moralité Plus les variables de calage X sont corrélées à Y , plus le résidu de la régression de Y sur X est faible et plus la variance de l'estimateur du total de Y est elle-même faible.


Application : Enquête sur la fréquentation des cinémas

Le distributeur souhaite **exploiter conjointement** l'information auxiliaire sur le nombre de projections et les périodes de vacances scolaires.

Pour ce faire, il introduit ces deux variables dans un calage sur marges par la **méthode exponentielle** (ou méthode du *raking ratio*).

À nouveau, il évalue les propriétés de l'estimateur en **répliquant 1 000 fois** l'ensemble des opérations (tirage puis redressement) et en représentant la **distribution des estimations ainsi obtenues**.

Application : Enquête sur la fréquentation des cinémas



Application : Enquête sur la fréquentation des cinémas

Biais Moyenne empirique sur 1 000 simulations

- Valeur dans la population : 731 892 entrées
- Estimateur d'Horvitz-Thompson : 733 832
- Estimateur par le ratio : 730 299
- Estimateur par post-stratification : 725 812
- Estimateur par calage sur marges : 731 625

Précision Écart-type empirique sur 1 000 simulations

- Estimateur d'Horvitz-Thompson : 153 932
- Estimateur par le ratio : 16 039
- Estimateur par post-stratification : 145 332
- Estimateur par calage sur marges : 13 607

Le calage sur marges en pratique

La plupart des enquêtes par sondage font l'objet d'un calage sur marges sur les **grandes structures de la population**.

En effet, une telle opération **ne peut qu'améliorer la précision** et garantit la **cohérence avec des sources extérieures à l'enquête**.

Est ainsi diffusé dans le fichier de l'enquête non pas le poids de sondage mais le **poids calé** sur de nombreuses marges.

En pratique, le calage sur marges est implémenté dans de nombreux logiciels :

- SAS : macro *%calmar* ;
- R : *packages* `sampling` et `icarus`.

En guise de conclusion

Les méthodes de redressement cherchent à **exploiter l'information auxiliaire disponible** au moment de l'estimation pour **améliorer la précision**.

Les estimateurs par le **ratio** et **post-stratifié** présentent une **variance plus faible** que l'estimateur d'Horvitz-Thompson pour autant que la variable d'intérêt soit **bien corrélée** à la variable explicative utilisée.

La méthode du **calage sur marges** généralise ce principe et permet de tirer parti de plusieurs variables auxiliaires simultanément.