

# Introduction à la théorie des sondages - Cours 6

Thomas Merly-Alpa  
thomas.merly-alpa@insee.fr

INSEE, département des méthodes statistiques

20 avril 2017



# Organisation

- 6 cours (avec des TD en fil rouge)
- 2 intervenants :
  - Thomas Merly-Alpa - [thomas.merly-alpa@insee.fr](mailto:thomas.merly-alpa@insee.fr)
  - Martin Chevalier - [martin.chevalier@insee.fr](mailto:martin.chevalier@insee.fr)
- Les slides et TD du cours sont à l'adresse <http://nc233.com/teaching> et sur moodle
- Notation : un devoir maison à rendre

# Sommaire

- 1 Méthodes de redressement
  - Redressement par le ratio
  - Redressement par post-stratification
  - Généralisation : Calage sur marges
- 2 Panorama de questions en sondages
  - Gestion de la collecte : suivi, multimode
  - Bases imparfaites et partage de poids
  - Tirage à probabilités inégales
  - Tirage équilibré
  - Unités influentes
  - Estimation sur des petits domaines

# Chapitre 1

## Méthodes de redressement

## 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.

## Partie 1

# Redressement par le ratio

## Définition

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

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  $X$  :

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

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

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

## Redressement par le ratio et repondération

**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.

## Partie 2

# Redressement par post-stratification

## Définition

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

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.


## Application : Enquête sur la fréquentation des cinémas

**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 :

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

**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.

# Application

## TD 4 - Exercice 2

## Partie 3

### 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 :  $F(x) = \frac{L(U-1) + U(L-1)\exp(Ax)}{U-1 + (1-L)\exp(Ax)}$   
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

Sexe \ IdF	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

Sexe \ IdF	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

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

× 20/18

× 40/42

### Étape 4

Sexe \ IdF	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)

× 40/39,36

× 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)

## Poids finaux

### Tableau final

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  $\varepsilon$  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.

## Chapitre 2

# Panorama de questions en sondages

## Partie 1

### Gestion de la collecte : suivi, multimode

## Mode de collecte

Une fois qu'un échantillon a été tiré, et avant de disposer des données, il faut que la collecte se déroule. Plusieurs modes de collecte :

- CAPI : enquêteur en face à face
- CATI : enquêteur par téléphone
- CAWI : collecte par Internet
- Papier : questionnaire auto-administré

Ces modes peuvent être proposés concurrentiellement ou séquentiellement.

# Multimode

Lorsque plusieurs modes sont proposés :

- Effet de mode :
  - On ne répond pas pareil au téléphone et sur papier
  - Biais de désirabilité
  - Exemple classique : consommation de drogues des adolescents
- Effet de sélection :
  - Ce ne sont pas les mêmes personnes qui répondent sur Internet sur papier
  - Personnes plus jeunes et plus diplômées, ayant accès à Internet
  - Grandes disparités dans les réponses au recensement

## Suivi de collecte

### Principe :

- Au cours de la collecte, on sait qui a répondu ou pas
- Les profils peuvent être équilibrés ou non
- On peut concentrer les relances, par exemple téléphoniques
- On peut même débloquer des échantillons dits de réserve

Dispositif mis en oeuvre par les prestataires de collecte, et certains instituts comme Statistiques Canada.

## Partie 2

# Bases imparfaites et partage de poids

## Base imparfaite

Retour sur la base de sondage parfaite :

- permet d'identifier les individus de façon non ambiguë
- est exhaustive (on parle sinon de défaut de couverture)
- est sans double compte
- contient de l'information auxiliaire (voir cours suivants)

Pas toujours le cas. Exemple : si l'on souhaite faire une enquête auprès des sans domicile ?

## Enquête Sans Domicile

Enquête menée par l'INSEE en 2001 et en 2012. Comment atteindre la population ?

- on liste les services d'aide aux SDF (hébergement, repas) ;
- on en échantillonne certains ;
- on se rend dans le centre ;
- on interroge une personne sur  $p$ .

Quel est le poids de sondage d'un individu ?

## Partage des poids

Supposons qu'un individu A est allé dans un centre d'hébergement une seule nuit. Un individu B lui par contre y dort tous les soirs. A t-on autant de chance de sélectionner A ou B ?

Idée : prendre en compte le nombre de nuits passées dans des centres ; c'est le nombre de **liens**. On utilise ensuite ce qu'on appelle le **partage des poids** : on divise le poids par le nombre de liens.

## Partie 3

# Tirage à probabilités inégales

## Probabilités de sélection

Rappel : le plan de sondage permet de déterminer des probabilités d'inclusion pour chaque unité de la population.

**Probabilité d'inclusion simple**  $\pi_k = \sum_{s \in \mathcal{S}} \delta_k p(s)$

**Probabilité d'inclusion double**  $\pi_{k,l} = \sum_{s \in \mathcal{S}} \delta_k \delta_l p(s)$

Ces probabilités peuvent être très différentes entre les individus.

## Tirage selon une variable $X$

Une méthode classique : le sondage à probabilités inégales selon une variable  $X$  disponible dans la base de sondage. On veut ici que  $\pi_k$  et  $X_k$  soient proportionnels : plus  $X$  est fort, plus il y a de chances qu'on sélectionne un individu. On a :

$$\pi_k = \frac{X_k}{\sum_{k \in U} X_k}$$

Propriété de ce plan de sondage : on estime parfaitement le total de la variable  $X$  :

$$\hat{X}_{HT} = \sum_{k \in S} \frac{X_k}{\pi_k} = \sum_{k \in U} X_k$$

## Sondage auto-pondéré

On souhaite interroger des salariés d'entreprises, et on veut qu'ils aient tous la même chance d'être sélectionnés :

- 1 On échantillonne des entreprises à probabilités inégales selon  $X$ , le nombre de salariés ;
- 2 On sélectionne 5 salariés dans l'entreprise.

Pourquoi ils ont la même chance ?

- Une entreprise de 10 salariés a une chance sur 20 d'être sélectionnée. Ensuite, chaque salarié a une chance sur 2 : au total, une chance sur 40.
- Une entreprise de 100 salariés a une chance sur 2 d'être sélectionnée. Ensuite, chaque salarié a une chance sur 20 : au total, une chance sur 40.

## Partie 4

# Tirage équilibré

## Retour sur l'échantillon "représentatif"

Lorsque l'on réalise un sondage aléatoire simple, on ne connaît pas la structure de l'échantillon obtenu : ratio homme/femme, etc.

Pour pallier ce problème, on peut stratifier.

Mais comment faire si l'on souhaite une structure précise pour :

- Sexe ;
- Âge ;
- Région. . .

## Tirage équilibré

Cela demanderait trop de strates : à chaque fois qu'on rajoute un critère, il faut le croiser avec tous les autres, ce qui augmente très rapidement le nombre de strates.

Une autre méthode est possible : l'échantillonnage équilibré

- On choisit des variables  $X$  pour la structure : qualitatives ou quantitatives
- On sélectionne un échantillon  $s$  qui est correct sur ces variables  $X$ , c'est à dire que :

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

- Si ce n'est pas possible, on cherche à être le plus proche possible.


## En pratique

### Comment utiliser le tirage équilibré en pratique ?

- Méthode réjective : tirer des échantillons jusqu'à obtenir un échantillon qui convienne. Problème : quelles sont les vraies probabilités de sélection ?
- Méthode du Cube, qui respecte les  $\pi_j$ . Méthode assez complexe, qui est implémentée :
  - en SAS, via la macro Cube :  
<https://www.insee.fr/fr/information/2021904>
  - en R, par exemple dans les packages *sampling* et *BalancedSampling*.

## Équilibrage spatial

On peut même chercher à répartir dans l'espace les points choisis, par exemple pour des sondages forestiers ou agricoles.



## Partie 5

# Unités influentes

## Valeurs aberrantes

On obtient parfois des réponses étonnantes :

- Erreur de compréhension de la question ;
- Erreur d'unité (€ contre k€)
- Mensonge

On peut corriger ces erreurs par des contrôles ou en recontactant la personne.

## Unités influentes

Mais ces réponses peuvent être valides !

- Erreur de classification dans la base ;
- Évolution de l'unité (*strata jumper*) ;
- Manque d'information auxiliaire.

Problème : si quelqu'un a répondu 1 000 000 au milieu de répondants à 1 ou 2, son impact sur l'estimation est énorme.

## Compromis biais-variance

On peut être tenté de le retirer de l'échantillon, en se disant qu'il est trop atypique. Mais cela crée du biais !

Une autre idée est de ne pas le retirer, mais de réduire son poids de sondage. En effet, l'impact sur l'estimation HT dépend de la valeur de  $w_i y_i$  ; réduire le poids diminue l'influence.

Quand on fait cela, on introduit du biais mais on réduit la variance. Idée : choisir le seuil de  $w_i y_i$  à partir duquel on réduit le poids pour limiter au maximum la variance sans introduire trop de biais. La méthode usuelle : la **winsorisation**.

## Partie 6

# Estimation sur des petits domaines

# Domaines

Rappel : un domaine  $d$  est un sous-ensemble de la population  $U$ .

Par exemple :

- Les hommes ou les femmes ;
- Les entreprises d'un secteur particulier.

Lorsque l'on veut estimer le total de  $Y$  sur le domaine  $d$  :

- La taille totale de l'échantillon  $n$  ne joue pas.
- C'est le nombre d'unités de l'échantillon qui sont dans le domaine  $d$ .
- Il est aléatoire, sauf si le domaine  $d$  est une strate.

## Petits domaines

On souhaite parfois obtenir des résultats sur des domaines  $d$  qui sont de très petite taille. Par exemple :

- Les habitants d'un département ou d'une ville spécifique ;
- Les spectateurs d'une chaîne télé spécialiste ;
- Les salons de coiffure.

Quand la taille de l'intersection entre l'échantillon et le domaine  $n_d$  est très petite, il est difficile d'estimer avec précision. La solution optimale est souvent d'augmenter cette taille en amont du sondage, mais ce n'est pas toujours possible.

## Estimation sur petits domaines

Il existe néanmoins des méthodes pour obtenir des estimations avec une précision correcte sur ces petits domaines. L'idée est la suivante :

- 1 On détermine un lien entre des variables  $X$  et les  $Y$  observés sur la population entière, par exemple par régression linéaire ;
- 2 On calcule via le modèle sur les  $X$  (connus) du domaine  $d$  une valeur de  $Y_d$ .

Rien ne garantit que le modèle calculé à l'étape 2 soit valide pour le domaine sur lequel nous travaillons ; il convient donc de traiter les résultats obtenus avec précaution.