



MÉTHODES D'IMPUTATION ALÉATOIRES ÉQUILIBRÉES

David Haziza
Université de Montréal

Travail joint avec Guillaume Chauvet et Jean-
Claude Deville

PLAN

- INTRODUCTION
- IMPUTATION DÉTERMINISTE VS. ALÉATOIRE
- VARIANCE DUE À L'IMPUTATION
- IMPUTATION ÉQUILIBRÉE
- ÉTUDE PAR SIMULATION
- TRAVAUX FUTURS

CONTEXTE

- Population finie U de taille N
- L'objectif est d'estimer le total dans la population

$$Y = \sum_{i \in U} y_i,$$

pour une variable d'intérêt y .

- On tire un échantillon aléatoire, s , de taille n , selon un plan de sondage $p(s)$.

ESTIMATION: RÉPONSE COMPLÈTE

- Un estimateur de Y est l'estimateur de Horvitz-Thompson

$$\hat{Y}_\pi = \sum_{i \in s} d_i y_i$$

- $d_i = 1/\pi_i$ désigne le poids de sondage de l'unité i
- π_i désigne la probabilité d'inclusion de l'unité i dans l'échantillon s $i = 1, \dots, N$.
- L'estimateur de HT est sans biais sous le plan de sondage:

$$E_p(\hat{Y}_\pi) = Y.$$

ESTIMATEUR IMPUTÉ

- En présence de non-réponse à la variable y , on définit un **estimateur imputé** de Y

$$\hat{Y}_I = \sum_{i \in s} d_i r_i y_i + \sum_{i \in s} d_i (1 - r_i) y_i^*,$$

où r_i est une variable indicatrice de réponse telle que

$$r_i = \begin{cases} 1 & \text{si l'unité } i \text{ a répondu à la variable } y \\ 0 & \text{sinon} \end{cases}$$

et y_i^* désigne la valeur imputée utilisée pour remplacer la valeur manquante y_i

MÉTHODES D'IMPUTATION

Les méthodes d'imputation peuvent être classées en deux groupes:

- Les méthodes dites **déterministes**: Méthodes qui fournissent une valeur fixe étant donné l'échantillon
- Les méthodes dites **stochastiques ou aléatoires**: Méthodes d'imputation ayant une composante aléatoire (et donc qui ne donnent pas nécessairement la même valeur étant donné l'échantillon si la méthode est répétée)

MÉTHODES D'IMPUTATION

- La plupart des méthodes d'imputation peut être représentée par le modèle suivant:

$$y_i = f(\mathbf{z}_i) + \sigma\sqrt{v_i}\varepsilon_i$$

- Les erreurs ε_i sont des variables aléatoires indépendantes de moyenne 0 et de variance 1 avec une distribution commune (L)
- Les quantités v_i sont supposées connues
- Le modèle peut également servir à motiver une imputation à l'intérieur de classes d'imputation

MÉTHODES D'IMPUTATION

- **Imputation déterministe:**

$$y_i^* = \hat{f}_r(\mathbf{z}_i)$$

- **Imputation aléatoire:** c'est une imputation déterministe à laquelle on ajoute un résidu aléatoire:

$$y_i^* = \hat{f}_r(\mathbf{z}_i) + \hat{\sigma} \sqrt{v_i} \varepsilon_i^*$$

- Les résidus ε_i^* sont tirés aléatoirement parmi l'ensemble des **résidus « standardisés »** observés chez les répondants:

$$\tilde{e}_j = \frac{1}{\hat{\sigma} \sqrt{v_j}} \left(y_j - \hat{f}_r(\mathbf{z}_i) \right) - \bar{e}_r, \quad j \in s_r$$

MÉTHODES D'IMPUTATION

- Les résidus aléatoires sont tirés de manière à respecter les probabilités suivantes:

$$P(\varepsilon_i^* = \tilde{e}_j) = \omega_j / \sum_{l \in s} \omega_l r_l$$

- Lorsque $\omega_j = 1$, on est en présence d'imputation aléatoire non-pondérée
- Lorsque $\omega_j = d_j$, on est en présence d'imputation aléatoire pondérée
- D'autres choix de pondération sont possibles (e.g., Haziza, 2009)

MÉTHODES DÉTERMINISTES

- Imputation par la régression:

$$f(\mathbf{z}_i) = \mathbf{z}'_i \boldsymbol{\beta} \text{ et } v_i = \boldsymbol{\lambda}' \mathbf{z}_i \Rightarrow y_i^* = \mathbf{z}'_i \hat{\mathbf{B}}_r$$

- Imputation par le ratio:

$$f(\mathbf{z}_i) = \beta z_i \text{ et } v_i = z_i \Rightarrow y_i^* = \hat{B}_r z_i = \frac{\bar{y}_r}{\bar{z}_r} z_i$$

- Imputation par la moyenne:

$$z_i = 1 \forall i, \quad f(z_i) = \beta \text{ et } v_i = 1 \Rightarrow y_i^* = \hat{B}_r = \bar{y}_r$$

MÉTHODES ALÉATOIRES

- Imputation par la régression aléatoire:

$$y_i^* = \mathbf{z}'_i \hat{\mathbf{B}}_r + \hat{\sigma} \sqrt{\lambda' \mathbf{z}_i} \varepsilon_i^*.$$

- Imputation par hot-deck aléatoire:

➤ On remplace la valeur manquante d'un receveur par celle d'un répondant (donneur) tiré au hasard dans l'ensemble des répondants

➤ Peut être vue comme de l'imputation par la moyenne à laquelle on a rajouté un résidu:

$$y_i^* = \bar{y}_r + \underbrace{(y_j - \bar{y}_r)}_{\tilde{e}_j}, \quad j \in S_r$$

PROPRIÉTÉS DES MÉTHODES D'IMPUTATION

- Estimation d'un total (ou moyenne): Les méthodes déterministes mènent à des estimateurs asymptotiquement sans biais
- Estimation d'un quantile (e.g., médiane): Les méthodes déterministes (exception: PPV) tendent à distordre la distribution des variables que l'on impute



Estimateurs de quantiles biaisés !

- Les méthodes aléatoires préservent les distributions au prix d'un terme de variance additionnel (variance due à l'imputation), due à la sélection aléatoire des résidus.

VARIANCE TOTALE

- Variance totale de l'estimateur imputé: Imputation aléatoire

$$\begin{aligned} V(\hat{Y}_I) &= V_p E_q E_I(\hat{Y}_I | s) + E_p V_q E_I(\hat{Y}_I | s) + E_p E_q V_I(\hat{Y}_I | s) \\ &= V_{SAM} + V_{NR} + V_{IMP} \end{aligned}$$

- Les trois termes sont du même ordre de grandeur
- En présence d'imputation aléatoire, l'estimateur imputé s'écrit comme:

$$\hat{Y}_I = \sum_{i \in S} d_i r_i y_i + \sum_{i \in S} d_i (1 - r_i) \hat{f}_r(\mathbf{z}_i) + \sum_{i \in S} d_i (1 - r_i) \hat{\sigma} \sqrt{v_i} \varepsilon_i^*$$

- La variance due à l'imputation provient du troisième terme

VARIANCE DUE À L'IMPUTATION

$$V_{IMP} = E_p E_q \left\{ \frac{\sum_{j \in s} d_j^2 (1 - r_j) v_j}{\sum_{j \in s} \omega_j r_j} \sum_{j \in s} \omega_j r_j \tilde{e}_j^2 \right\}$$

- V_{IMP} est petite lorsque:
 - le taux de réponse est élevé
 - le taux de réponse est faible
 - les résidus \tilde{e}_j sont petits (le modèle ajuste bien les données)

UN EXEMPLE

- Imputation par la régression linéaire simple aléatoire:


$$\mathbf{z}_i = (1, z_i)' \text{ et } v_i = 1.$$

- Échantillonnage aléatoire simple sans remise et mécanisme de non-réponse uniforme.


- Variance additionnelle (en %) relative due à l'imputation aléatoire:

$$\frac{V_A(\hat{Y}_I) - V_D(\hat{Y}_I)}{V_D(\hat{Y}_I)} \approx \frac{p(1-p)(1-\rho_{yz}^2)}{1-(1-p)\rho_{yz}^2}.$$

Variance additionnelle (en %) avec $\rho_{xy} = 0.8$.



Variance additionnelle (en %) avec $p = 0.5$



RÉDUIRE LA VARIANCE DUE À L'IMPUTATION

• Trois approches ont été proposées pour réduire/éliminer la variance due à l'imputation:

(1) **L'imputation fractionnelle:** (Kalton et Kish, 1981;1984; Fay, 1996; Kim et Fuller (2002); Fuller et Kim (2005))

- consiste à imputer M valeurs (méthode aléatoire)
- chaque valeur se voit attribuer un poids (habituellement, $1/M$)
- similaire à l'imputation multiple mais les procédures d'estimation sont différentes
- la variance due à l'imputation décroît à mesure que M croit.

RÉDUIRE LA VARIANCE DUE À L'IMPUTATION

(2) Procédure d'ajustement des valeurs imputées: Chen, Rao et Sitter (2000)

- on commence par utiliser l'imputation par hot-deck aléatoire
- ensuite, on ajuste les valeurs imputées de manière à éliminer le troisième terme. Autrement dit, on veut satisfaire:

$$\sum_{i \in S} d_i (1 - r_i) \hat{\sigma} \sqrt{v_i} \varepsilon_i^* = 0 \quad \Leftrightarrow \quad \bar{y}_m^* = \bar{y}_r$$

- Chen, Rao et Sitter (2000) ont montré que cette procédure permet de préserver la distribution des variables que l'on impute

RÉDUIRE LA VARIANCE DUE À L'IMPUTATION

(3) Imputation équilibrée:

➤ on sélectionne les résidus aléatoires de manière à satisfaire (au moins approximativement)

$$\sum_{i \in S} d_i (1 - r_i) \hat{\sigma} \sqrt{v_i} \varepsilon_i^* = 0$$

➤ cette idée n'est pas nouvelle: Kalton et Kish (1981, 1984) et Deville (2006).

➤ on utilise la méthode du Cube (Deville et Tillé, 2004) proposée dans le contexte de l'échantillonnage équilibré.

AVANTAGES DE L'IMPUTATION ÉQUILBRÉE

- Simplicité pour les utilisateurs car **un seul fichier** est créé (la majorité des enquêtes utilisent l'imputation simple)
- **Aucun ajustement** des valeurs imputées n'est nécessaire. Les procédures d'estimation habituelles peuvent être appliquées.
- Peut être utilisée pour des **variables continues ou catégorielles**
- **La distribution** des variables que l'on impute **est préservée**:

$$\hat{F}_I(t) \xrightarrow{p} F_N(t)$$

ÉTUDE PAR SIMULATION

- Population extraite d'un échantillon de l'Enquête Canadienne sur la Santé de taille $N = 10000$
- La population a été stratifiée par province (11 strates)
- De la population, 1000 échantillons de taille $n = 500$ ont été tirés selon un plan stratifié aléatoire simple sans remise avec répartition proportionnelle
- Dans chaque échantillon, la non-réponse a été générée selon un mécanisme uniforme à l'intérieur des strates ($p_h = 0.6$ ou $p_h = 0.7$)
- 3 méthodes d'imputation à l'intérieur des classes: imputation par la moyenne, imputation par hot-deck aléatoire et imputation équilibrée

ÉTUDE PAR SIMULATION

- **Note:** l'imputation équilibrée consiste à tirer des donneurs pour imputer les receveurs tel que $\bar{y}_{mh}^* = \bar{y}_{rh}$ dans la strate h
- On s'intéresse à deux variables:
 - Le poids en kg d'un individu (y_1)
 - La présence ou absence d'asthme (y_2): $y_2 = 1$ si l'individu souffre d'asthme et $y_2 = 0$, sinon
- On cherche à estimer :
 - \bar{Y}_1 et $F_1(t)$ (fonction de répartition de la variable « poids »)
 - \bar{Y}_2 : la proportion d'individus souffrant d'asthme

MESURES MONTE CARLO

- Biais relatif monte carlo (en %)

$$RB_{MC}(\hat{\theta}) = \frac{E_{MC}(\hat{\theta}) - \theta}{\theta} \times 100$$

- Erreur quadratique moyenne monte carlo:

$$EQM_{MC}(\hat{\theta}) = E_{MC}(\hat{\theta} - \theta)^2$$

- Efficacité relative (imputation par hot-deck aléatoire utilisé comme référence):

$$ER = \frac{EQM_{MC}(\hat{\theta}_{(.)})}{EQM_{MC}(\hat{\theta}_{(HD)})}$$

EFFICACITÉ RELATIVE MONTE CARLO

- Le biais relatif des estimateurs imputés de \bar{Y}_1 et \bar{Y}_2 est négligeable dans tous les scénarios


<i>ER</i>	Moyenne	Hot-deck aléatoire	Équilibrée
y_1	0.80	1	0.82
y_2	0.82	1	0.86

FONCTION DE RÉPARTITION


Biais relatif et EQM pour $F_1(t)$

$F_1(t)$	Biais relatif (en %)			ER	
	Moyenne	Hot-deck	Équilibrée	Moyenne	Équilibrée
0.25	-29.03	0.18	0.25	9.52	0.90
0.5	-16.30	-0.11	-0.02	11.02	0.90
0.75	8.94	0.03	0.01	7.90	0.87


FDR dans la population




FDR: imputation par la
moyenne



FDR: imputation par hot
deck aléatoire



FDR: imputation
équilibrée



TRAVAUX FUTURS

- Estimation de la variance:
 - Si les contraintes d'équilibrage sont exactement satisfaites, on peut utiliser n'importe quelle méthode d'estimation de la variance
 - Sinon, il y a une certaine variance due à la phase d'atterrissage
- L'imputation équilibrée peut être utilisée pour imputer dans le cas de coefficients bivariés (exemple: coefficient de corrélation)