

L'échantillonnage équilibré par la méthode du cube et la méthode réjective

Ibrahima Ousmane Ida et Louis-Paul Rivest

Université Laval

12 Octobre 2016

- 1 Contexte.
- 2 Qu'est-ce que l'échantillonnage équilibré?
- 3 La méthode du cube : une technique exacte.
- 4 Sélection par la méthode du cube : cas de l'enquête sur la pêche sportive en Gaspésie.
- 5 Quel choix entre la méthode du cube et la méthode réjective?
- 6 Conclusion.

- La pêche sportive, une activité qui contribue à l'essor des économies locales et nationale.
- Intérêt des enquêtes sur la pêche sportive.
- Difficultés des enquêtes sur la pêche sportive.
- Préoccupation : comment intégrer des contraintes dans le processus de sélection d'échantillon?

Qu'est-ce que l'échantillonnage équilibré?

Qu'est-ce que l'échantillonnage équilibré?

Notation

- Si x est une variable auxiliaire dont les valeurs sont connues pour toutes les unités de la population, le total t_x de cette variable est :

$$t_x = \sum_{i=1}^N x_i$$

- Noté \hat{t}_{xHT} , l'estimateur de Horvitz-Thompson du total de x est calculé :

$$\hat{t}_{xHT} = \sum_{i \in s} \frac{x_i}{\pi_i}$$

Qu'est-ce que l'échantillonnage équilibré?

Qu'est-ce qu'un plan de sondage équilibré?

- Un plan de sondage $p(s)$ est dit **équilibré** sur la variable x si et seulement si il permet de sélectionner d'un échantillon tel que :

$$\hat{t}_{xHT} = t_x$$

$$\sum_{i \in s} \frac{x_i}{\pi_i} = \sum_{i=1}^N x_i$$

- Objectif visé à travers l'équilibrage : tirer un échantillon dans le sous-espace des **contraintes** :

$$\mathcal{Q} = \left\{ s \in \mathcal{S} \left| \sum_{i \in s} \frac{x_i}{\pi_i} = \sum_{i=1}^N x_i \right. \right\}$$

Qu'est-ce que l'échantillonnage équilibré?

Quelques particularités d'échantillonnage équilibré

- L'équilibrage d'un plan peut se faire sur des variables **quantitatives** et aussi sur des variables **qualitatives**.
- C'est pourquoi on dit que l'échantillonnage équilibré est une **généralisation** de la stratification.
- Équilibrer un plan sur des variables x_h ($h = 1, \dots, H$) revient à faire de la stratification, si :


$$x_{hi} = \begin{cases} 1 & \text{si } i \in U_h \\ 0 & \text{si } i \notin U_h \end{cases} \quad i = 1, \dots, N$$

où U_h ($h = 1, \dots, H$) désignent des strates.

Méthode du cube : une technique exacte

Pourquoi l'appellation méthode du cube?

- C'est à cause de la **représentation géométrique** du plan de sondage. Par exemple, avec un tirage sans remise dans une population de taille $N = 3$, les échantillons possibles sont : $(0, 0, 0), \dots, (1, 1, 1)$.



- Elle a été proposée par Deville et Tillé (2004).

Méthode du cube : une technique exacte

Sur quoi se base-t-elle?

- Si un plan de sondage $p(s)$ est équilibré sur des variables x_1, \dots, x_p , alors on a :

$$\widehat{T}_{xHT} = T_x$$

$$\begin{pmatrix} \frac{x_{11}}{\pi_1} & \dots & \frac{x_{1i}}{\pi_i} & \dots & \frac{x_{1N}}{\pi_N} \\ \vdots & & \vdots & & \vdots \\ \frac{x_{p1}}{\pi_1} & \dots & \frac{x_{pi}}{\pi_i} & \dots & \frac{x_{pN}}{\pi_N} \end{pmatrix} \begin{pmatrix} Z_1 \\ \vdots \\ Z_N \end{pmatrix} = \begin{pmatrix} t_{x_1} \\ \vdots \\ t_{x_p} \end{pmatrix}$$

où $(Z_1, \dots, Z_N)' = s$ représente l'échantillon et Z_i des v.a. telles que $Z_i = 0$ ou 1.

- Le sous-espace des contraintes peut s'écrire :

$$\mathcal{Q} = \{s \in \mathcal{S} \mid A * s = T_x\}$$

- A est la **matrice des contraintes** d'équilibrage.

Comment fonctionne-t-elle?

- Pour tirer un échantillon s de $\mathcal{S} (\{0; 1\}^N)$, elle opère dans l'hypercube $\mathcal{C} ([0, 1]^N)$ et transforme le vecteur π des probabilités de sélection :

$$\pi(T) = \pi + \sum_{t=1}^T \delta(t)$$

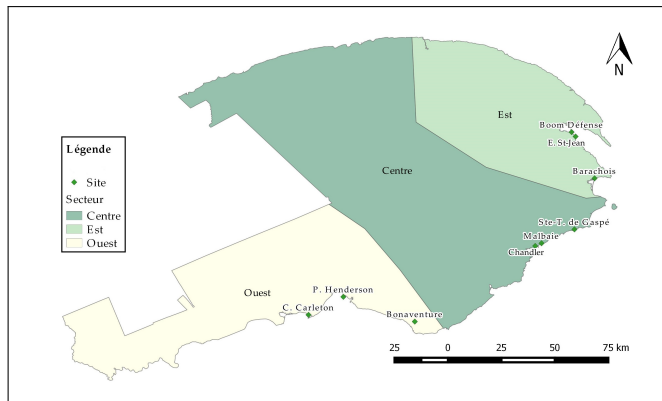
où $\delta(t)$ sont des vecteurs propres de la matrice A des contraintes d'équilibrage.

- Elle admet deux phases :
 - 1 Phase de **vol** pour chercher un échantillon exactement équilibré.
 - 2 Phase d'**atterrissage** pour trouver un échantillon approximativement équilibré. L'atterrissage se fait par **programmation linéaire** ou par **suppression** de variables.

Sélection par la méthode du cube : cas de l'enquête sur la pêche sportive en Gaspésie.

Sélection par la méthode du cube : cas de l'enquête sur la pêche sportive en Gaspésie

Zone de l'enquête



Sélection par la méthode du cube : cas de l'enquête sur la pêche sportive en Gaspésie

Plan d'échantillonnage

- Il s'agit d'un plan stratifié à trois degrés :
 - 1 Stratification : $h = 1, \dots, H$ représentent les jours et sont des strates;
 - 2 Degré 1 : $i = 1, \dots, I$ sont les secteurs;
 - 3 Degré 2 : $j = 1, \dots, J$ sont les périodes;
 - 4 Stratification : $k = 1, \dots, K$ représentent les sous-périodes et sont aussi des strates;
 - 5 Degré 3 : $\ell = 1, \dots, L$ sont les sites.
- Probabilités de sélection aux différents degrés :

$$\pi_{hi}^{(1)} = n_1 \frac{x_{i\bullet}}{x_{\bullet\bullet}}, \quad \pi_{j|i}^{(2)} = \frac{n_{2|1}}{J}, \quad \pi_{\ell|ijk}^{(3)} = n_{3|1,2} \frac{x_{i\ell}}{x_{i\bullet}}.$$

Sélection par la méthode du cube : cas de l'enquête sur la pêche sportive en Gaspésie

Contraintes d'équilibrage

- Les contraintes opérationnelles veulent que :
 - ① les visites de chaque secteur soient équitablement réparties entre les périodes;
 - ② les visites de chaque site soient équitablement réparties entre les sous-périodes;
 - ③ etc.
- Au total 77 contraintes ont été imposées au plan.
- Spécification des contraintes concernant les visites des secteurs pendant les différentes périodes :

$$\sum_{h,i,j} Z_{hi} Z_{j|hi} I_{hij}^{(\beta)} = H n_1 \frac{n_{2|1}}{J} = 22$$

Sélection par la méthode du cube : cas de l'enquête sur la pêche sportive en Gaspésie

Résultats après simulation de 10 000 échantillons

Table: Moyennes des visites des sites et espérances des visites

Secteur	Site	x_{il}	$E(n_{il})$	\bar{n}_{il}	$s_{\bar{n}_{il}}$
East ($i = 1$)	Boom Défense ($\ell = 1$)	2	20,308	20,286	0,850
	E. St-Jean ($\ell = 2$)	1	10,154	10,153	0,621
	Barachois ($\ell = 3$)	2	20,308	20,296	0,881
Centre ($i = 2$)	Ste-T. de Gaspé ($\ell = 4$)	1	10,154	10,176	0,865
	Malbaie ($\ell = 5$)	1	10,154	10,155	0,880
	Chandler ($\ell = 6$)	1	10,154	10,162	0,881
West ($i = 3$)	Bonaventure ($\ell = 7$)	2	20,308	20,311	1,004
	P. Henderson ($\ell = 8$)	1	10,154	10,153	0,681
	C. Carleton ($\ell = 9$)	2	20,308	20,309	1,016

Taille d'échantillon : $n = 132$.

Quel choix entre la méthode du cube et la méthode réjective?

Quel choix entre la méthode du cube et la méthode réjective?

Plan d'échantillonnage et méthode réjective

- Il s'agit d'un plan stratifié à deux degrés :
 - ① Stratification : $h = 1, \dots, H$ représentent les jours et sont des strates;
 - ② Degré 1 : $i = 1, \dots, I$ sont les secteurs;
 - ③ Degré 2 : $j = 1, \dots, J$ sont les sites.
- Au sens de Fuller (2009), ce plan est équilibré si et seulement si il permet de tirer d'un échantillon qui satisfait la condition :

$$Q_{p,n} = (\bar{n} - E(n_e))' [Var(\bar{n})]^{-1} (\bar{n} - E(n_e)) < \gamma^2$$

où \bar{n} est le vecteur des visites des sites, $E(n_e)$ vecteur des espérances des visites, γ^2 **tolérance** de sélection.

- $Q_{p,n}$ suit une χ_p^2 .

Quel choix entre la méthode du cube et la méthode réjective?

Résultats après simulation de 100 000 échantillons

Table: Comparaison des moyennes des visites des sites aux espérances des visites.

Site	$E(n_{ij})$	Méthode du Cube				Méthode de Fuller (taux de rejet = 95%)			
		\bar{n}_{ij}	$SE_{\bar{n}_{ij}}$	z	$2Pr > z $	\bar{n}_{ij}	$SE_{\bar{n}_{ij}}$	z	$2Pr > z $
$i = 1, j = 1$	3	3	0	na	na	3,0105	0,0020	5,2003	0
$i = 1, j = 2$	2	2	0	na	na	1,9543	0,0020	-22,5290	0
$i = 1, j = 3$	3	3	0	na	na	3,0100	0,0020	4,9411	0
$i = 2, j = 4$	2	1,9993	0,0004	-1,6687	0,0952	1,9540	0,0018	-25,2836	0
$i = 2, j = 5$	2	2,0007	0,0006	1,0999	0,2714	1,9563	0,0018	-23,9179	0
$i = 2, j = 6$	2	2,0003	0,0006	0,5978	0,5500	1,9527	0,0018	-25,9863	0
$i = 3, j = 7$	3	2,9975	0,0011	-2,2948	0,0217	3,0350	0,0018	18,9196	0
$i = 3, j = 8$	3	3,0020	0,0012	1,6343	0,1022	3,0365	0,0019	19,6968	0
$i = 3, j = 9$	4	4,0007	0,0010	0,6602	0,5091	4,0913	0,0019	47,0904	0

Taille d'échantillon : $n = 24$.

- La méthode du cube donne des estimations sans biais et **conserve** les probabilités de sélection.
- La méthode réjective **modifie** les probabilités de sélection et conduit souvent à des estimations biaisées.
- Dans le contexte d'enquête sur la pêche sportive, la sélection par la méthode du cube semble être une excellente alternative d'échantillonnage.

- Audrey-Anne Vallée, Bastien Ferland-Raymond, Louis-Paul Rivest, and Yves Tillé. Incorporating spatial and operational constraints in the sampling designs for forest inventories. *Environmetrics*, 26(8):557-570, 2015.
- Caren Hasler and Yves Tillé. Fast balanced sampling for highly stratified population. *Computational Statistics and Data Analysis*, 74:81-94, 2014.
- Guillaume Chauvet, David Haziza, and Éric Lesage. Examining some aspects of balanced sampling in surveys. *Statistica Sinica*, 2015.
- Ibrahima Ousmane Ida. L'échantillonnage équilibré par la méthode du cube et la méthode réjective. Mémoire de maîtrise, Université du Québec, 2016. URL <http://www.theses.ulaval.ca/2016/32818/32818.pdf>.
- Jean-Claude Deville and Yves Tillé. Efficient balanced sampling: the cube method. *Biometrika*, 91(4):893-912, 2004.
- Wayne A Fuller. Some design properties of a rejective sampling procedure. *Biometrika*, 96 (4):933-944, 2009.
- Yves Tillé. *Sampling algorithms*. Springer, New York, 2011.

Merci !