

SONDAGE A DEUX DEGRÉS

- Population découpée en sous-populations dites unités primaires
- Définition: tirage de m unités primaires puis de n_i unités secondaires
- Avantages:
 - frais de déplacement réduits
 - absence de liste autorisée
- Mais:
 - précision moindre: effet de grappe.
 - Taille d'échantillon en général aléatoire

SONDAGE A DEUX DEGRÉS

- M unités primaires de taille N_i

$$N = \sum_{i=1}^M N_i \quad T_i = \sum_{j=1}^{N_i} Y_{ij} \text{ - total de l'UP n}^\circ i$$

- Tirage aléatoire simple à chaque degré.

$$\hat{T} = \frac{M}{m} \sum_{i \in s} \left(\frac{N_i}{n_i} \sum_{j \in \mathcal{S}_i} y_{ij} \right)$$

Remarque: inutile de connaître N pour estimer T .

$$V(\hat{T}) = \underbrace{M^2 \left(1 - \frac{m}{M}\right) \frac{S_1^2}{m}}_{\text{Variance inter UP}} + \underbrace{\frac{M}{m} \sum N_i^2 \left(1 - \frac{n_i}{N_i}\right) \frac{S_{2,i}^2}{n_i}}_{\text{Variance intra UP}}$$

$$S_1^2 = \frac{1}{M-1} \sum_{i=1}^M (T_i - \bar{T})^2$$

$$S_{2,i}^2 = \frac{1}{N_i-1} \sum_{j=1}^{N_i} (Y_{ij} - \bar{Y}_i)^2$$

SONDAGE A DEUX DEGRÉS

- S_1^2 estimé par $s_1^2 = \frac{1}{m-1} \sum_{i=1}^m \left(\hat{T}_i - \frac{\hat{T}}{M} \right)^2$ si $m > 1$
- idem pour $S_{2,i}^2$
- Si n_i proportionnel à N_i : taille d'échantillon aléatoire

$$n_i = n_0 \frac{N_i}{N}$$

$$E(n_s) = E\left(\sum_{i \in S_i} n_0 \frac{N_i}{N}\right) = \sum_{k \in U_i} n_0 \frac{N_i}{N} \frac{m}{M} = \frac{n_0 m}{M}$$

SONDAGE A DEUX DEGRÉS

- Sondage autopondéré:
 - m unités primaires tirées à probabilités proportionnelles à leur taille
 - tirage d'échantillons de taille fixe n_0
- probabilités d'inclusion constantes

$$\pi_i = \frac{N_j}{N} m \frac{n_0}{N_j} = \frac{mn_0}{N}$$

- Estimateur de la moyenne: N peut être inconnu

$$\hat{Y} = \bar{y}$$

SONDAGES A DEUX DEGRÉS

Comment améliorer la précision ?

- Avant tout, construire des UP le plus ressemblantes possible entre elles pour limiter les effets de grappes.
 - Exemple : l'unité ménage est intéressante pour estimer des variables comme le sexe, l'activité, l'âge, etc, mais elle est moins efficace pour étudier le niveau d'instruction, la CS , etc.
- Privilégier le nombre d'UP enquêtées plutôt que le nombre d'US
- Tirer les UP à probabilités inégales
- Stratifier au niveau des UP

CAS PARTICULIER: SONDAGE EN GRAPPES

- Définition: toutes les US sont observées dans les UP tirées.

« Recensement » au deuxième degré

Le tirage systématique est un tirage d'une grappe.



SONDAGE EN GRAPPES

- Cas général : tirage de grappes à probabilités inégales

- Estimation du total: $\hat{T} = \sum_{i=1}^m \frac{T_i}{\pi_i}$

- Estimation d'une moyenne $\hat{\bar{Y}} = \frac{1}{N} \sum_{i=1}^m \frac{N_i \bar{Y}_i}{\pi_i}$

pb si N inconnu: utiliser l'estimateur de Hajek

$$\widehat{\bar{Y}}_{Hajek} = \frac{\sum_{i=1}^m \frac{N_i \bar{Y}_i}{\pi_i}}{\sum_{i=1}^m \frac{N_i}{\pi_i}}$$

SONDAGE EN GRAPPES

- Tirage de grappes à probabilités égales

$$\pi_i = \frac{m}{M}$$

➤ taille d'échantillon aléatoire

$$E(n_s) = E\left(\sum_{i \in S_i} N_i\right) = \sum_{k \in U_i} N_i \frac{m}{M} = \frac{Nm}{M}$$

➤ Estimation

$$\hat{T} = \frac{M}{m} \sum_{i \in s} T_i$$

$$V(\hat{T}) = M^2 \left(1 - \frac{m}{M}\right) \frac{S_1^2}{m}$$

$$\hat{\bar{Y}} = \frac{M}{mN} \sum_{i=1}^m N_i \bar{Y}_i$$

SONDAGE EN GRAPPES

- Tirage de grappes à probabilités proportionnelles à la taille

$$\pi_i = m \frac{N_i}{N} \quad \hat{Y} = \frac{1}{m} \sum_{i=1}^m \bar{y}_i$$

$$\hat{V}(\hat{Y}) = \frac{1}{m(m-1)} \sum_{i=1}^m \left(1 - m \frac{N_i}{N}\right) (\bar{y}_i - \hat{y})^2$$

$$E(n_s) = E\left(\sum_{i \in S_i} N_i\right) = \sum_{i \in U_i} N_i \frac{N_i m}{N} = \frac{m}{N} \sum_{i=1}^M N_i^2$$

SONDAGE EN GRAPPES

conseils pratiques

- Faire des grappes homogènes en inter et hétérogènes en intra (contraire de la stratification).
- Faire beaucoup de grappes de tailles voisines et petites
- En tirer un maximum

Le tirage systématique

- Très utilisé à la place d'un tirage aléatoire à probabilités égales
- Soit N multiple de n . Par exemple on veut tirer 10 individus parmi 1000 : on commence par tirer au hasard un nombre entier entre 1 et 100, si ce nombre est 27, le premier individu sera le n°27, le deuxième le n°127 etc. jusqu'au n°927.
- De façon générale si on a tiré un entier h , les individus sélectionnés ont les numéros : $h, h+M, h+2M, \dots, h+(n-1)M$.
- **Tirage d'une seule grappe** parmi $M=N/n$ grappes.

Le tirage systématique

- L'estimateur de la moyenne est simplement la moyenne de la grappe sélectionnée et sa variance est

$$V(\hat{Y}) = M \sum_{i=1}^M \left(\frac{\bar{Y}_i N_i}{N} - \frac{\bar{Y}}{M} \right)^2$$

- Lorsque le fichier se trouve être trié selon un ordre proche de Y , la variance peut être notablement plus faible que pour le tirage aléatoire simple. Exemple $Y_i = i$
- Mais la variance n'est pas estimable .

- Voir formule

$$s_1^2 = \frac{1}{m-1} \sum_{i=1}^m \left(\hat{T}_i - \frac{\hat{T}}{M} \right)^2$$

- Il est incorrect d'utiliser la variance de l'estimateur du tirage aléatoire simple sauf si la base de sondage a été triée préalablement au hasard.

Tirage systématique: un exemple théorique

$Y_i=i$ Population triée par ordre croissant $N=Kn$

$$\bar{Y} = \frac{N+1}{2} \quad S^2 = \frac{(N+1)^2}{12}$$

• Tirage équiprobable sans remise :

$$V(\bar{y}_{sr}) = \left(1 - \frac{n}{N}\right) \frac{(N+1)^2}{12n} = \left(1 - \frac{1}{K}\right) \frac{(Kn+1)^2}{12n}$$

- Tirage systématique :

une grappe : $h, h+K, h+2K, \dots, h+(n-1)K$

$$\bar{Y}_h = h + \frac{n-1}{2} K$$

- Moyenne

$$E(\bar{Y}_h) = E(h) + \frac{n-1}{2} K = \frac{K+1}{2} + \frac{n-1}{2} K = \frac{nK+1}{2} = \frac{N+1}{2}$$

- Variance

$$V(\hat{Y}_{syst}) = V\left(h + \frac{n-1}{2} K\right) = V(h) = V(h) = \frac{K^2 - 1}{12}$$

$$V(\hat{Y}_{syst}) < V(\bar{y}_{sr})$$

Exemple $N=20$ $n=4$

$$V(\hat{Y}_{syst}) = 1.33$$

$$V(\bar{y}_{sr}) = 7.35$$