

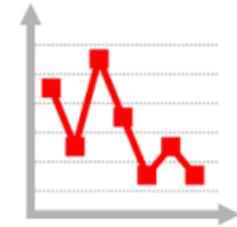


Choisir de répondre au recensement par internet : un essai de modélisation

Heidi Koumarianos
DMCSI



Plan

- Contexte et problématique
- Quel(s) modèles(s) ?
- Quelques résultats

Contexte


La collecte du recensement (1)

- Depuis 2004, la collecte est annuelle, réalisée par les communes en partenariat avec l'Insee
- Chaque année, les communes de plus de 10 000 habitants (un peu moins de 1 000 communes) effectuent une collecte auprès de 8 % des logements
- Chaque année, 20 % des petites communes de moins de 10 000 habitants (environ 7 000 chaque année) effectuent un recensement exhaustif de leur population, à un rythme quinquennal
- Environ 24 000 agents recenseurs en 2017 (en moyenne 200 logements par agent recenseur)

La collecte du recensement (2)

- Depuis 2015, chaque ménage peut choisir son mode de collecte (papier/internet)
- Les taux de réponse par internet sont très variables
 - Les communes et les zones de collecte diffèrent par leur composition socio-démographique
 - L'agent recenseur et la commune peuvent influencer le choix du mode de réponse, en privilégiant la proposition de l'un ou de l'autre.

Le taux de réponse par internet a progressé de 14 points en 2 ans



Le taux de réponse par internet reste plus élevé de 3 points en « petite » commune (moins de 10 000 habitants) qu'en « grande »



La problématique

Pourquoi étudier la propension à choisir un mode de réponse dans le recensement ?

- C'est la plus grosse enquête de l'Insee (plus de 4 millions de ménages tous les ans), et elle est multimode
- La mesure des biais de sélection est nécessaire pour estimer d'éventuels effets de mode
- La mesure des biais de sélection est nécessaire pour mettre en place des protocoles de collecte différenciés pour des sous populations

Les difficultés

- On constate de fortes disparités des taux de réponse internet par zone (zone de collecte, commune, région)
 - => on souhaite neutraliser cet effet zone
- Les bases de données sont volumineuses
 - => les choix de modélisation peuvent être contraints (4 millions de ménages, 24 000 zones de collecte, 8 000 communes et ... des outils limités)

La modélisation

Choix et construction des variables du modèle

- On dispose d'informations de niveau logement, ménage, et individus composant le ménage
 - statut d'occupation du logement (3 modalités)
 - taille du logement (surface par habitant, en tranche, 5 modalités)
 - type de ménage (5 modalités)
- Le choix du mode de collecte est fait pour un ménage : les informations de niveau individu doivent être agrégées.
 - moyenne d'âge des personnes majeures (en tranches, 6 modalités)
 - diplôme le plus élevé des personnes majeures (en 5 modalités)
 - présence d'au moins un actif occupé
- On peut construire des caractéristiques de zones, principalement les moyennes des caractéristiques individuelles, mais aussi :
 - le taux de collecte internet N-1 (en grande commune)
 - les revenus de la commune

On peut modéliser :

- La propension d'un ménage à répondre par internet
 - en fonction de ses caractéristiques propres
 - en fonction des caractéristiques de sa zone de collecte
 - en intégrant le niveau zone de collecte
 - en intégrant le niveau commune
- Le taux de réponse par internet pour une zone de collecte
 - en fonction des caractéristiques de la zone de collecte
 - en intégrant le niveau commune

Le modèle de Mundlak

- La probabilité qu'un ménage m_i appartenant à la zone de collecte ZC_j réponde par internet dépend entre autres :
 - De ses caractéristiques individuelles X_{ij}
 - De caractéristiques de sa zone de collecte, de façon générale les Y_j
 - Des moyennes des caractéristiques individuelles de la zone les $\bar{X}_{.j}$
 - D'une constante globale éventuelle K
 - D'une constante pour la zone éventuelle k_j

$$P(m_i \in ZC_j \text{ répond par internet}) \\ a_{ij} X_{ij} + b_j Y_j + c_{.j} \bar{X}_{.j} + K + k_j + e_{ij}$$

Les premiers résultats

Les résultats présentés portent sur les grandes communes de métropole

Quelles questions à ce stade ?

- Les effets commune et zone de collecte sont-ils avérés ?
- Y a-t-il des effets des moyennes socio-démographiques par zone ?
- Quelles sont les caractéristiques qui jouent le plus sur le choix du mode ?

Les niveaux commune et ZC sont explicatifs du choix du mode

- Test d'un modèle « vide » : les niveaux commune et zone de collecte expliquent respectivement **9 % et 12 %** de la variance (coefficient de corrélation intra classe)
- Lorsqu'on introduit d'autres variables explicatives (de niveau ménage et moyennes de zone), les coefficients sont de 5 % (commune) et **15 %** (zone de collecte)
 - L'effet commune et l'effet zone de collecte sont en partie captés par l'introduction du taux internet de l'année précédente

Limites du modèle à 3 niveaux

- Le modèle comprenant les niveaux ménage, zone de collecte et commune est trop important pour tourner sur la France entière
- Le niveau commune est bien moins explicatif que le niveau zone de collecte (estimation faite sur 5 régions)
- L'application aux petites communes est plus délicat
=> Par la suite on privilégie un modèle à deux niveaux (ménage et zone de collecte), que l'on peut estimer sur l'ensemble des communes (on distingue toutefois grandes et petites communes)

Les caractéristiques socio-démographiques des zones sont peu explicatives

- Certaines caractéristiques ressortent parfois, lorsque le modèle porte sur un nombre plus réduit d'observations (une ou deux régions seulement)
- En général, il s'agit de caractéristiques de zones plutôt défavorisées : part de logements HLM, de ménages sans actif occupé, de ménages complexes
 - Hypothèse : il s'agirait de zones plus « difficiles » à collecter ?

Des effets individuels connus


		Modalité de référence	Odd ratio
Age moyen : 80 ans	vs	Age moyen : 40 ans	0,13
Pas de diplôme	vs	Diplôme le plus élevé : baccalauréat	0,42
Personne seule	vs	Couple avec enfant	0,53

Age moyen : 30 ans	vs	Age moyen : 40 ans	1,15
Diplôme le plus élevé : supérieur long	vs	Diplôme le plus élevé : baccalauréat	1,31

- Les diplômés et les jeunes choisissent plus souvent internet
- Les plus âgés, et sans diplôme préfèrent le papier


Une prédiction ... approximative

Prédiction par zone de collecte, sans prise en compte de l'effet zone




Le modèle multi niveaux neutralise bien l'effet zone lorsqu'il est présent

Prédiction par zone de collecte, avec prise en compte de l'effet zone



Un effet non significatif pour 38 % des zones de collecte

Effet par zone de collecte



Le modèle multi niveaux nous apprend :

- Qu'il y a bien un effet zone de collecte, explicatif du choix du mode de réponse
- Que cet effet est significatif pour plus de la moitié des zones de collecte
- Que cet effet est bien pris en compte en utilisant un modèle multiniveaux

Suite des travaux

- Poursuivre l'analyse sur l'ensemble de la France pour les petites communes
- On peut alors estimer pour chaque ménage :
 - La probabilité de répondre par internet en prenant en compte l'effet zone de collecte
 - La probabilité de répondre par internet en neutralisant l'effet zone de collecte
- Cela permet d'essayer de quantifier les effets de mesure liés au mode
 - pour la non réponse partielle,
 - Ou pour le classement des individus en population municipale

Références

- Diaporama de bilan de collecte 2017 – Pôle RP de Lyon
- Les modèles multiniveaux, Document de travail M2016/05, P. Givord et M. Guillerm

Titre de la présentation

Merci de votre attention

Avez-vous des questions ?

Insee
www.insee.fr

Heidi.koumarios@insee.fr