G E O D E

Echantillonnage spatial et production de données d'enquête à l'échelle intra-urbaine d'une ville moyenne. L'exemple de la capitale du Grand-Duché de Luxembourg

Géographie et Développement

Philippe GERBER
avec la collaboration de
Jean-Yves BIENVENUE

Cahier GEODE n°06 Differdange, septembre 2003

Géographie et Développement

E O D E

INSTEAD CEPS

Echantillonnage spatial et production de données d'enquête à l'échelle intra-urbaine d'une ville moyenne. L'exemple de la capitale du Grand-Duché de Luxembourg*

Philippe GERBER
Avec la collaboration de
Jean-Yves BIENVENUE

CEPS/INSTEAD, Grand-Duché de Luxembourg

Résumé

La Ville de Luxembourg a commandité une étude de grande envergure au CEPS/INSTEAD à partir d'une enquête de terrain. Elle concerne les personnes âgées de 60 ans ou plus vivant à leur domicile au sein de la capitale. Les thèmes que l'enquête aborde, nombreux, doivent être restitués à une échelle infra-communale. Cette contrainte ne facilite ni la méthode d'échantillonnage, ni l'obtention de résultats et de données statistiques robustes à cette échelle. Cet article présente les moyens et méthodes dont nous disposons pour contrecarrer ces problèmes. Ainsi, la méthode utilisée fait appel à un échantillonnage spatial stratifié qui se fonde sur une agrégation raisonnée des quartiers administratifs de la Ville de Luxembourg d'une part, et sur le contrôle *a priori* et *a posteriori* de variables auxiliaires (notamment démographiques) d'autre part. Sans s'attarder sur les résultats d'enquête eux-mêmes, cette étude expose la méthode utilisée et révèle les obstacles et les avantages de son application, tant à l'échelle de la ville que de ses quartiers résidentiels.

* Cet article a fait l'objet, sous une forme modifiée, d'une communication lors d'une école thématique : *Techniques d'enquêtes, actualité scientifique de la méthode et des outils*. Bitche, France, 15-19 septembre 2003. Nous souhaitons remercier la Ville de Luxembourg qui nous a confiés l'étude portant sur les personnes âgées, notamment l'échevin Claude Wiseler, et la responsable du Service Seniors, Franca Riolino-Steichen,.

Introduction

Quels que soient les pays de l'Union Européenne, le phénomène du vieillissement démographique de la population est patent[1]. Ainsi, au Luxembourg, nous passons de 64 949 personnes âgées de 60 ans ou plus en 1981 à 81 511 personnes vingt ans plus tard[2]. Ces changements démographiques s'accompagnent de mutations sociologiques et économiques majeures, comme la recherche d'une nouvelle image de l'âge, de meilleures conditions de ressources financières pour les plus de 60 ans, une meilleure santé, etc. Selon ces considérations, la Ville de Luxembourg a commandité au CEPS/INSTEAD une étude de grande envergure, fondée en partie sur une enquête visant à prendre en compte l'avis des personnes âgées de 60 ans ou plus vivant à domicile. Les thèmes que l'enquête aborde sont nombreux : l'état du logement, le niveau de santé, l'appréciation du quartier ou encore les réseaux sociaux, pour ne citer que les plus importants. La capitale du Grand-Duché souhaite obtenir, à *un niveau infra-communal*, les informations permettant d'apprécier les besoins réels et les souhaits de ces personnes âgées, en vue de forger une nouvelle politique sociale, en anticipant éventuellement la planification de nouvelles infrastructures.

Dans ce cadre, les aspects méthodologiques de la mise en place de l'enquête doivent être rigoureusement contrôlés afin de pouvoir fournir aux décideurs institutionnels des données précises à l'échelle intra-urbaine, tout en voulant :

- restituer l'avis de la population âgée tout en n'interrogeant qu'une partie d'entre elle (environ mille enquêtes possibles selon un type de sondage donné) ;
- assurer le maximum de représentativité au niveau infra-communal, donc avec une erreur d'échantillonnage[3] la plus faible possible, compte tenu des moyens budgétaires alloués ;
- assurer une totale comparabilité à ce niveau d'étude, donc en ayant une erreur d'échantillonnage du même ordre d'une zone résidentielle à une autre.

Dans le but de respecter ces exigences, la méthode statistique adéquate est le sondage aléatoire spatial stratifié, qui semble plus efficace que la technique d'échantillonnage aléatoire simple. Toutefois, la technique de stratification proposée implique trois contraintes (liées entre autres aux prérogatives financières) :

- géographique (choix de la taille des unités spatiales) ;
- démographique (une population des plus de 60 ans vivant à domicile peu nombreuse et une enquête reposant à la fois sur le ménage et l'individu) ;
- méthodologique (s'assurer de la comparabilité spatiale et minimiser l'erreur d'échantillonnage en fonction des trois exigences précédentes).

Nous explicitons plus précisément les exigences, contraintes et avantages de la méthode en trois parties distinctes, en y exposant clairement les forces de l'échantillon spatial stratifié par rapport à la procédure d'échantillonnage aléatoire simple : le contexte de l'étude, le tirage, et enfin les résultats de la passation associés à leurs corrections.

---

[1] De nombreux articles et ouvrages révèlent cet état de fait. Nous y reviendrons.
[2] STATEC, recensements de 1981 et de 2001.
[3] Les termes scientifiques liés aux techniques d'enquête peuvent trouver leur définition sous la référence suivante : [ARD 1994]. Cette référence et les suivantes renvoient à la bibliographie située en fin de texte.

1. Univers de référence et aires d'enquêtes

La phénomène du vieillissement[4] relaté auparavant ne doit pas masquer les disparités démographiques qui existent entre un pays et une ville, comme par exemple celle de Luxembourg. Les chiffres au niveau national l'ont soulevé : il existe certes un vieillissement généralisé à l'échelle du pays, mais par ailleurs une stagnation de la proportion de la population des plus de 60 ans au niveau de la capitale du Grand-duché (cf. figure 1). La capitale passe de 19,2 à 19 % pour les 60 ans ou plus, et leur nombre absolu baisse entre 1981 et 2001.

Figure 1 – Evolution de la population de la Ville de Luxembourg par tranches d'âges et nationalité entre 1981 et 2001

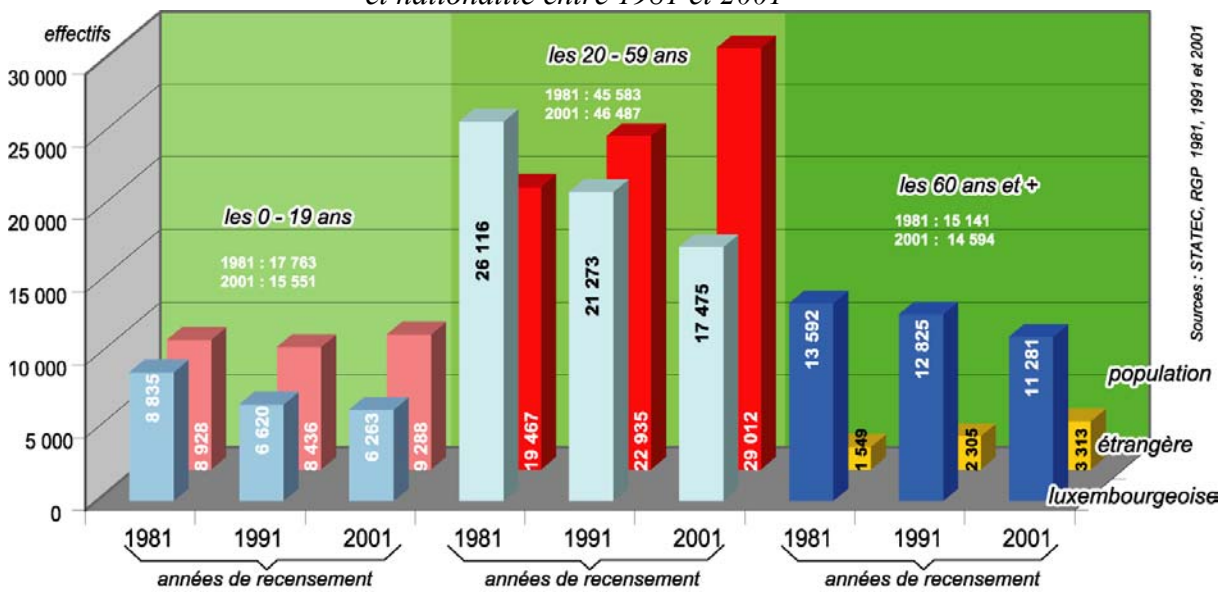

La relative stabilité de la part de la population âgée se retrouve dans de nombreuses villes européennes, notamment en France[5]. Mais la figure 1 apporte également une autre précision : c'est le nombre de personnes âgées de nationalité luxembourgeoise qui diminue et celui des personnes non luxembourgeoises qui a augmenté le plus fortement (plus du double en vingt ans).

De plus, et dans l'optique d'une analyse infra-communale statistiquement comparable, nous remarquons que les 24 quartiers administratifs existants sont fortement hétérogènes, ne serait-ce qu'au niveau de la population (figure 2).

[4] Nous pouvons citer, entre autres, [AGL 2002], [GUI 1999], [VIM 2000], [THE 1992], [ROC 2000], [WAT 1993].
[5] Cf. notamment [CON 2001].

Figure 2 – Répartition de la population résidante par quartier de la Ville de Luxembourg en 2001

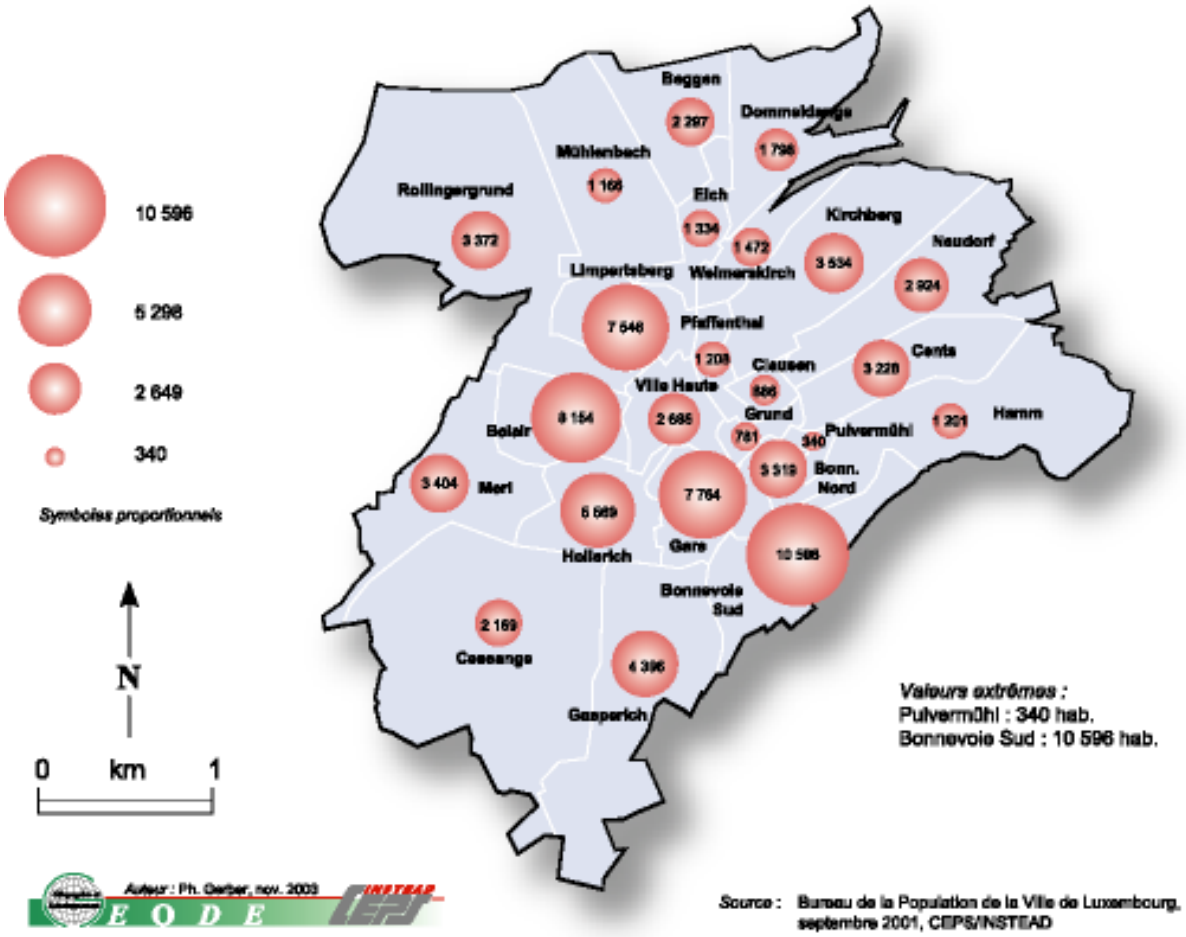

Les valeurs extrêmes sont à ce niveau éloquentes : le plus petit quartier (Pulvermühl) contient 340 habitants, alors que le plus grand (Bonnevoie Sud) dispose de près de 11 000 habitants.

Le deuxième problème est que ces quartiers n'offrent pas non plus une répartition homogène des personnes âgées de 60 ans ou plus, comme le montre clairement la figure 3. la répartition relative varie entre moins de 13 % (quartier Pulvermühl) à plus de 37 % (quartier Ville Haute) de personnes âgées de 60 ans ou plus dans chaque quartier.

Figure 3 – Répartition des personnes de 60 ans ou plus par quartier en 2001

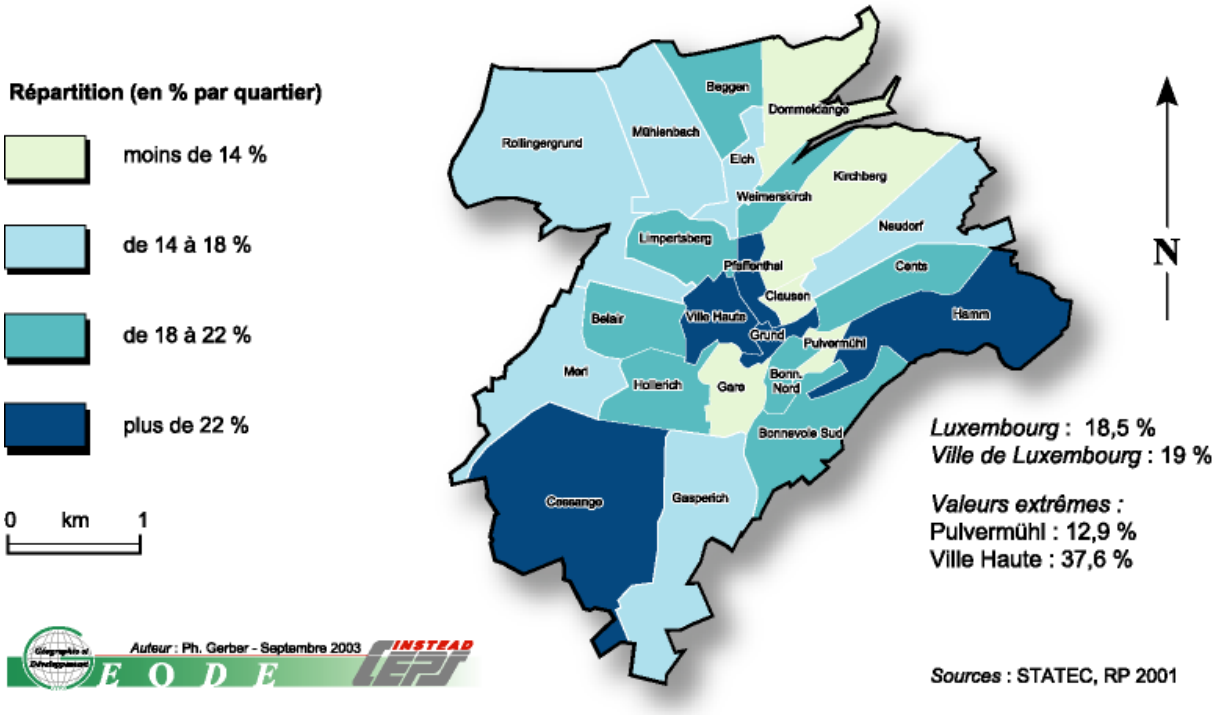

En tenant compte de ces deux facteurs, à savoir l'hétérogénéité du poids démographique et la répartition différenciée des personnes âgées au sein des 24 quartiers administratifs, la technique d'échantillonnage aléatoire simple ne donnerait pas de résultats suffisamment précis. En reprenant l'exemple du quartier de Pulvermühl, il n'y a « que » 12,9 % de personnes âgées en 2001, soit 44 personnes ! A moins de faire un recensement de toutes les personnes âgées de ce quartier, il y peu de chance de produire une évaluation chiffrée précise à cette échelle par la procédure d'échantillonnage aléatoire simple. Ces répartitions posent alors un problème pour le plan de sondage : si le découpage de 24 quartiers est conservé dans le but d'en constituer des strates pour y appliquer un échantillon aléatoire stratifié, la qualité des résultats ne pourrait être assurée pour chaque strate en raison de l'inférence statistique. Ces quartiers doivent donc être adaptés et redéfinis afin de faciliter l'échantillonnage et de contrôler l'analyse future des données.

En partant de tous les ménages de la Ville de Luxembourg (univers de référence), soit au total 47 068 ménages fiscaux[6], représentant 81 144 individus, la subdivision en strates géographiques de la capitale s'effectue alors en respectant une répartition équilibrée de la population, en se fondant sur plusieurs critères :

- un minimum de 2 000 personnes âgées de plus de 60 ans par strate, seuil établi à partir de critères statistiques de contrôle. Ces critères sont notamment liés aux découpages démographiques envisagés (trois catégories d'âge par exemple) dans l'exploitation future des résultats ;
- une contiguïté géographique des quartiers ;
- et une certaine homogénéité sociale de ces strates.

[6] Source : fichier de population de la Ville de Luxembourg, septembre 2001. Au moment de la mise en place de la méthode d'échantillonnage, nous ne disposions pas encore des chiffres du dernier recensement.

Après plusieurs tests[7], nous arrivons à un découpage en 6 zones ou strates, dont la répartition de la population varie peu, de 11 053 à 15 585 habitants (figure 4).

Figure 4 – Découpage de la Ville de Luxembourg en 6 strates ou zones résidentielles

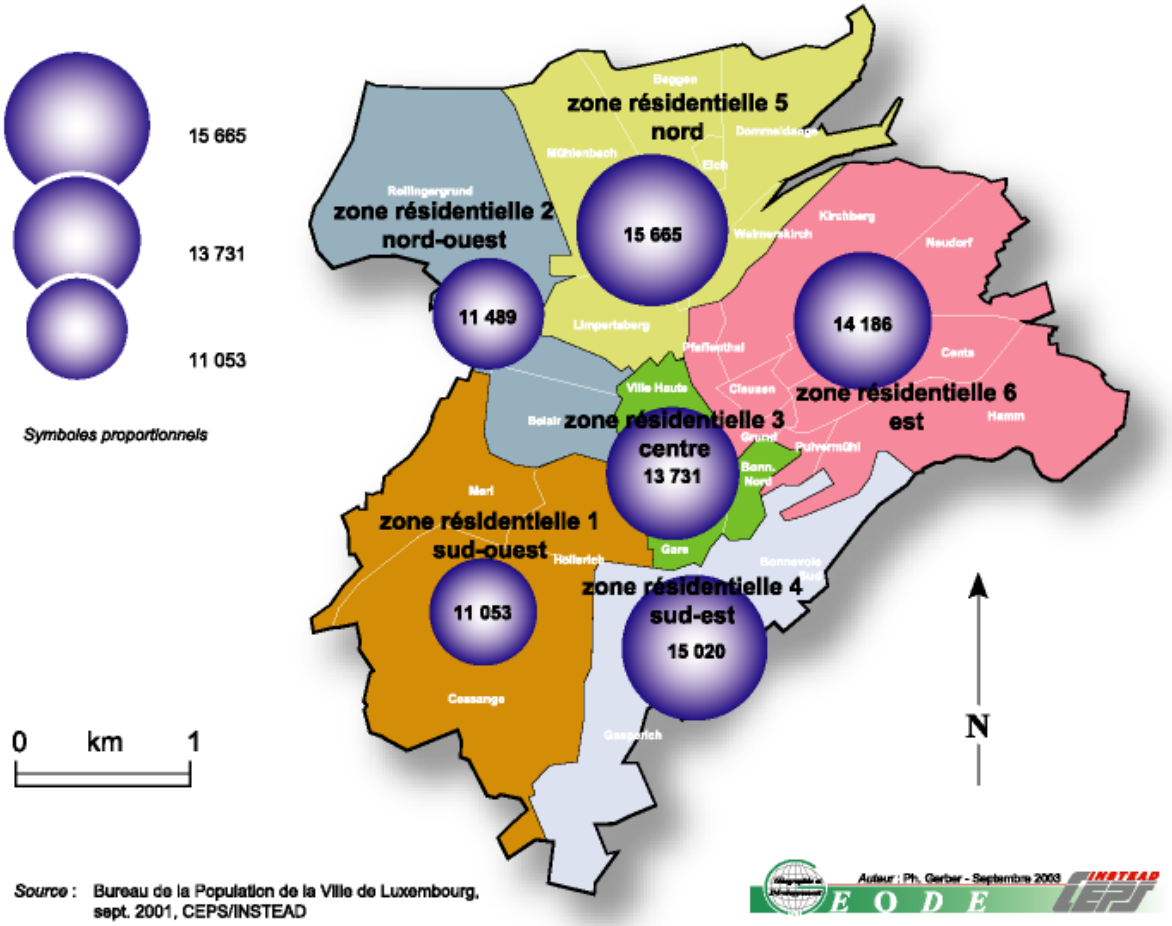

Ces zones doivent maintenant faire l'objet d'un tri entre univers de référence (ménages et habitants de la Ville de Luxembourg) et population mère, à savoir les ménages dont une personne a au moins 60 ans ou plus. Nous pouvons résumer cette étape par la figure 5 suivante.

[7] Inspirés de plusieurs techniques et méthodes, notamment celle de l'écologie urbaine factorielle, [BER 1970], [REY 1998], celle de la constitution pragmatique de quartiers [POU 1999].

Figure 5 – De l'univers de référence aux individus ciblés

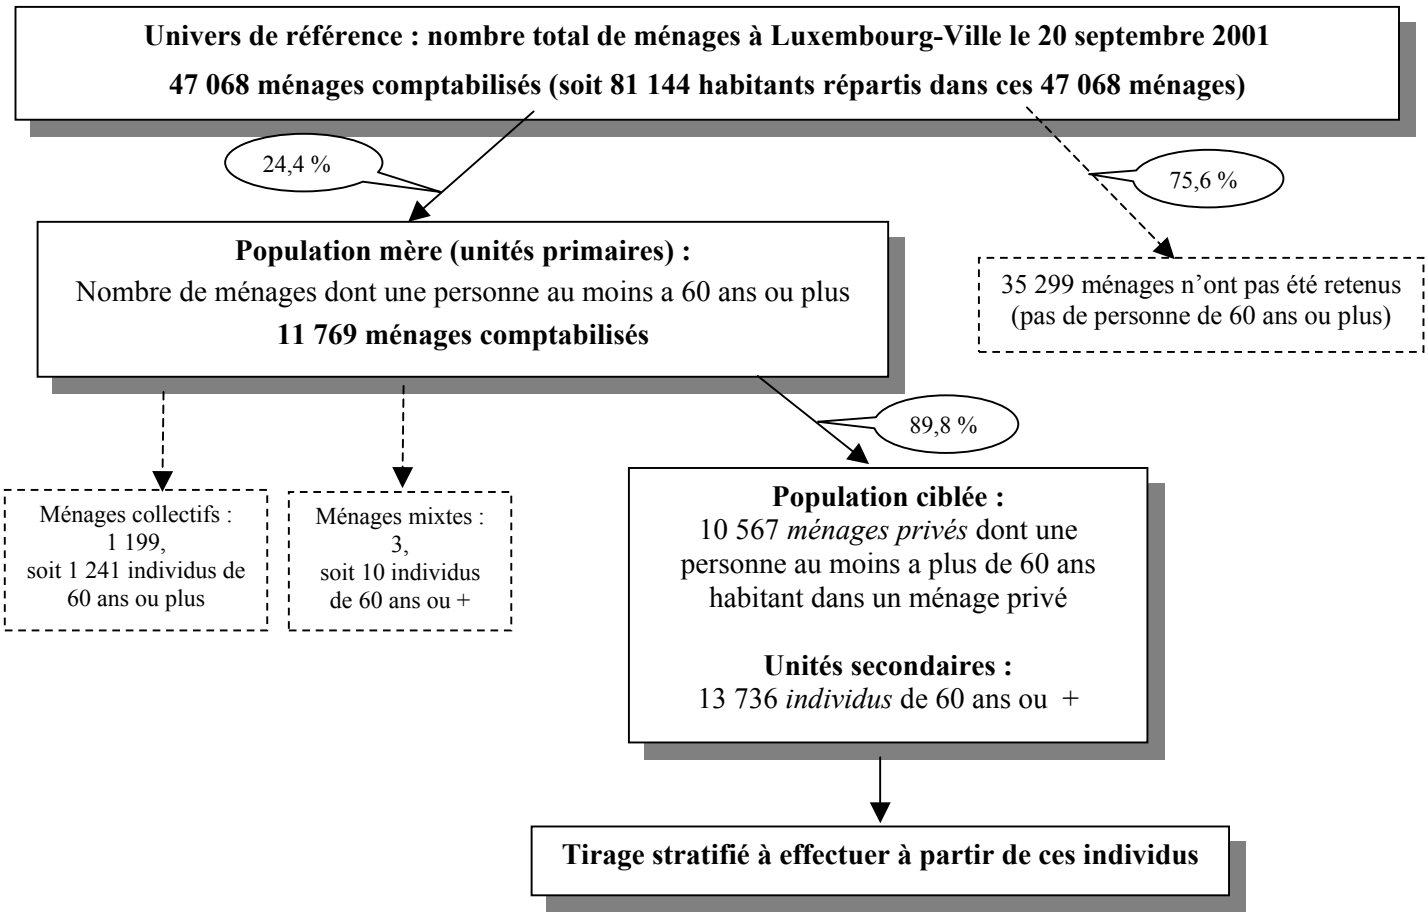

Source : Bureau de population de la Ville de Luxembourg (BPVdL), septembre 2001

La population mère comptabilise en tout 14 984 individus répartis dans 11 769 ménages. Mais elle ne correspond pas encore à la population ciblée de l'enquête : doivent en être éliminés les ménages collectifs. Nous arrivons ainsi à une population ciblée de 10 567 ménages habitant à domicile, soit 13 736 individus de 60 ans ou plus en septembre 2001, date de référence du fichier de population. Nous finalisons le plan de sondage en répartissant ces ménages, avec leurs individus respectifs, en fonction des 6 strates spatiales prédéfinies dans la table 1.

Table 1 – Plan de sondage : population mère et population ciblée en 6 strates

	Les 6 strates d'échantillonnage (zones résidentielles)	Population mère		**Population ciblée ou plan de sondage**	
		ménages	individus	**Ménages**	**Individus**
1	Cessange, Hollerich, Merl	1 654	2 596	**1 629**	**2 114**
2	Belair, Rollingergrund	1 722	2 629	**1 632**	**2 135**
3	Bonnevoie N, Gare, Ville-Haute	2 198	2 926	**1 575**	**1 945**
4	Bonnevoie S, Gasperich	2 013	3 173	**2 006**	**2 637**
5	Beggen, Dommeldange, Eich, Limpertsberg, Mühlenbach, Weimerskirch	2 104	3 337	**2 040**	**2 656**
6	Cents, Clausen, Grund, Hamm, Kirchberg, Neudorf, Pfaffenthal, Pülvermuhl	2 078	3 364	**1 685**	**2 249**
	Total	11 769	18 025	**10 567**	**13 736**

Source : BPVdL, sept. 2001

Ainsi, le lien de référence entre les quartiers, les adresses, les zones d'échantillonnage, les ménages et les individus étant établi, l'étape suivante consiste à tirer un échantillon aléatoire d'adresses au sein de chaque sous-ensemble territorial (plan de sondage en 6 strates) que nous allons détailler dans la prochaine partie.

2. Tirage et caractéristiques de l'échantillon

L'échantillonnage s'effectue en plusieurs étapes qu'il convient de bien préciser afin de comprendre le cheminement méthodologique nécessaire pour assurer des résultats de qualité, tant au niveau des zones résidentielles que des ménages et des personnes âgées.

2.1. La méthode de tirage

La méthode de tirage de l'échantillon utilisée, dans le cadre de cette enquête, repose sur une technique d'échantillonnage à deux phases[8] (ou étapes) :

- le tirage d'un échantillon aléatoire stratifié (en 6 zones résidentielles) de **ménages privés** possédant au moins une personne âgée de 60 ans ou plus ;
- la **sélection aléatoire** d'une personne âgée de 60 ans ou plus au sein de chaque ménage de l'échantillon.

Cette procédure de sélection permet de respecter les conditions décrites ci-après :

- le caractère représentatif des 10 567 ménages ciblés répartis dans les 6 zones résidentielles retenues dans l'étude ;
- l'estimation sans biais de tous les membres des ménages privés concernés (16 772 individus tout âge confondu) ;
- l'estimation sans biais des 13 736 personnes âgées de 60 ans ou plus résidant dans un des 10 567 ménages privés.

Ces conditions sont complétées en croisant ces variables par des variables auxiliaires telles que l'âge, le sexe, la nationalité et l'état civil. Nous allons détailler ces étapes de méthode de tirage en trois phases successives.

2.2. Sélection d'un premier échantillon aléatoire stratifié de ménages privés

La première étape consiste donc en la sélection d'un premier échantillon d'unités primaires de 1 500 ménages, puis de 3 000 ménages en prévision de l'élaboration d'une liste d'attente.

[8] Source générale : [SAR 1992].

Le tirage s'effectue selon un plan de sondage stratifié en fonction des six zones géographiques définies plus haut. Cela signifie que chaque strate possède son propre lot d'adresses tirées aléatoirement au sein de chaque strate. En fonction de deux facteurs, à savoir l'objectif d'atteindre 1 000 répondants et la passation de l'enquête, nous avons retenu au total 1 803 adresses effectivement utilisées sur le terrain.

Dès lors, afin de tester le degré de représentativité du premier échantillon, deux listes de variables de contrôle ont été retenues en fonction que l'on se situe au niveau du ménage privé ou au niveau des individus.

Par rapport aux ménages privés, nous avons privilégié les variables liées à la zone résidentielle et à la taille du ménage. Prenons l'exemple de la zone résidentielle (table 2).

Table 2 – Degré de représentativité de l'échantillon au niveau des ménages privés selon la zone résidentielle

Zones résidentielles ou strates	Strates des ménages privés (BPVdL)	Echantillon (nombre de ménages)	Poids de l'échantillon	Taux de sondage	Estimation pondérée (contrôlée)
1	1 628	**277**	5,88	0,170	1 628
2	1 631	**279**	5,85	0,171	1 631
3	1 569	**269**	5,83	0,171	1 569
4	2 008	**342**	5,87	0,170	2 008
5	2 044	**348**	5,87	0,170	2 044
6	1 687	**288**	5,86	0,171	1 687
Total	10 567	**1 803**		0,171	10 567

Source : BPVdL 2001, enquête Personnes Agées Ville de Luxembourg (PAVdL), 2002

Dans ce tableau, la variance est nulle (et non affichée), du fait que les strates assurent la base de contrôle (et de sondage) de l'enquête : l'échantillon tiré aléatoirement est donc parfaitement représentatif des zones résidentielles.

Au niveau des unités secondaires (tous les membres du ménage), l'âge, le sexe, la nationalité et l'état civil ont servi de variables de contrôle. Sans les détailler toutes, nous pouvons nous focaliser sur les deux premières d'entre elles (table 3).

Table 3 – Degré de représentativité de l'échantillon au niveau de tous les individus selon l'âge et le sexe

Sexe	Age	Nb de personnes des ménages (BPVdL)	Echantillon (nombre d'individus)	Estimation pondérée	Erreur d'échantillonnage		
					Borne inférieure	Borne supérieure	Coefficient de variation
Masculin	- de 60 ans	1 670	283	1 659	1 488	1 829	5,14
	60-64 ans	1 792	309	1 811	1 634	1 988	4,89
	65-74 ans	3 255	561	3 289	3 062	3 515	3,44
	75 ans ou +	2 955	508	2 977	2 759	3 195	3,66
Féminin	- de 60 ans	1 366	241	1 413	1 255	1 571	5,59
	60-64 ans	1 648	277	1 623	1 454	1 792	5,20
	65-74 ans	2 579	438	2 567	2 361	2 772	4,01
	75 ans ou +	1 507	253	1 484	1 322	1 646	5,46
Total		16 772	2 870	16 821			

Source : BPVdL 2001, enquête PAVdL, 2002

Malgré les variations dues aux erreurs d'échantillonnage[9], le tirage respecte les valeurs observées au niveau du fichier du Bureau de la Population de la Ville de Luxembourg car les bornes inférieures et supérieures intègrent les valeurs observées. Ce constat s'observe également pour les autres variables de contrôle utilisées (la nationalité et l'état civil).

Nous pouvons ainsi considérer que le tirage respecte les proportions et répartitions démographiques des individus (unités secondaires) et des ménages âgés (unités primaires). Il n'existe pas de biais dans l'échantillon car les bornes inférieures et supérieures des intervalles de confiance figurant dans les tableaux incluent les chiffres réels du fichier de population de la Ville de Luxembourg.

2.3. Sélection d'un second échantillon d'individus âgés à partir du premier échantillon

Pour des raisons de rapidité et de coût de la passation de l'enquête, nous ne voulons interroger qu'une seule personne de 60 ans ou plus dans le ménage sélectionné lors de la première étape de l'échantillonnage. Or, comment sélectionner, de manière aléatoire, une seule personne de 60 ans ou plus, lorsqu'il existe par exemple deux personnes de 60 ans ou plus dans le même ménage ? La deuxième étape consiste alors en un échantillon aléatoire d'unités secondaires (ou individus âgés de 60 ans ou plus).

Ainsi, à partir de l'échantillon d'unités primaires (les ménages sélectionnés dans la première étape), nous constituons une population d'unités secondaires composés des 2 346 personnes âgées présentes dans les 1 803 ménages du premier échantillon. Afin de garder le caractère aléatoire[10] de la base de sondage, une personne âgée de 60 ans ou plus a été sélectionnée sur la base d'une procédure ou clé appelée Kish[11] au sein de chaque ménage du

[9] Par rapport aux calculs de variance, cf. [DEV 1999].
[10] Cela facilitera d'ailleurs le travail de terrain de l'enquêteur, qui saura exactement quelle personne du ménage interroger.
[11] Du nom d'un statisticien. Cf. [KIS 1965].

premier échantillon. La règle principale en est la suivante : est interrogée **la** personne d'un ménage du premier échantillon selon que cette personne doit avoir au moins 60 ans passés et que sa date d'anniversaire doit correspondre à celle qui est la plus proche de la date d'exécution du tirage.

Grâce au fichier de population de la Ville de Luxembourg, contenant la date de naissance de la personne, il a été possible de trier et de déterminer les personnes concernées. Au total, 1 803 personnes âgées résidant dans un des 1 803 ménages privés ont été listées (sur les 2 346 personnes âgées de 60 ans ou plus) et contactées sur le terrain.

Au niveau de l'échantillon Kish des personnes âgées, des défauts de représentativité n'ont pas été détectés, tant au niveau du sexe, de l'âge, que de la nationalité et de l'état civil. Nous reprenons l'exemple selon l'âge et le sexe (table 4).

Table 4 – Degré de représentativité de l'échantillon au niveau des individus Kish selon l'âge et le sexe

Sexe	Age	Nb de personnes des ménages (BPVdL)	Echantillon (nombre de ménages)	Estimation pondérée (individus)	Erreur d'échantillonnage		
					Borne inférieure	Borne supérieure	Coefficient de variation
Masculin	- de 60 ans						
	60-64 ans	1 792	232	1 834	1 608	2 060	6,17
	65-74 ans	3 255	431	3 336	3 051	3 620	4,26
	75 ans ou +	2 955	454	3 036	2 793	3 279	4,00
Féminin	- de 60 ans						
	60-64 ans	1 648	237	1 641	1 445	1 837	5,98
	65-74 ans	2 579	292	2 508	2 238	2 779	5,40
	75 ans ou +	1 507	157	1 396	1 182	1 609	7,64
Total		13 736	1 803	13 750			

Source : BPVdL 2001, enquête PAVdL, 2002

Certes, il existe des différences mais elles sont sans gravité car les bornes affichées incluent les valeurs observées du fichier de population.

Les deux étapes méthodologiques exposées restent encore relativement théoriques : il convient maintenant de les confronter au terrain, en y ajoutant quelques règles de passation, notamment en fonction de cas particuliers que les enquêteurs ou enquêtrices peuvent rencontrer auprès des ménages concernés.

2.4. Application de la procédure Kish sur le terrain

Il est possible de répartir la liste de personnes âgées à interroger dans chaque ménage privé en fonction des différents enquêteurs et enquêtrices. Cette liste spécifie les nom, prénom, adresse et date de naissance de la personne à interroger dans le ménage privé. Cependant, il a été prévu d'adapter l'utilisation de la méthode Kish en présence de 2 cas de figure de manière

à ne pas créer de biais de représentativité et de tenir compte des handicaps éventuels que connaissent certaines personnes âgées.

1. *Cas où le ménage à enquêter est composé de 2 ou 3 personnes :*

a) Si la personne de 60 ans ou plus, choisie selon la méthode Kish, n'est pas **apte à répondre** (absence, maladie, handicap), les enquêteurs ont pour consigne d'interroger une autre personne **vivant dans** le ménage : cette autre personne constitue alors une personne « d'approximation » (ou proxy), c'est-à-dire qu'elle répond **à la place** de la personne choisie au départ au hasard ;
b) Par contre, si la personne âgée, choisie selon la méthode Kish, **ne veut pas répondre** (refus), dans ce cas, **le ménage ne sera pas enquêté** (aucune personne), même si une autre personne (conjoint par exemple) est prête à y participer (résultats dans la dernière partie) ;
c) Si tous les membres du ménage **ne sont pas aptes** à répondre, alors qu'une autre personne le veut bien (un enfant qui se trouve en visite par exemple, ou une assistante sociale ou une infirmière… qui connaissent la personne tirée selon la procédure Kish), cette dernière personne, consentante, sera à son tour considérée comme personne « d'approximation » et répondra **à la place** de la personne tirée au hasard.

2. *Cas où le ménage est composé d'une seule personne :*

a) Si la personne de 60 ans ou plus ne **veut pas répondre** (refus), **le ménage ne sera pas enquêté**, même si une autre personne ne faisant pas partie du ménage (frère ou infirmière par exemple) est prête à participer ;
b) Si la personne de plus de 60 ans n'est pas **apte à répondre** (absence, maladie, décès), prendre si possible un personne « d'approximation ».

Ces contraintes déterminées, toutes les conditions sont maintenant réunies pour que les enquêteurs et enquêtrices se rendent sur le terrain. Nous pouvons ainsi développer les résultats de la passation de l'enquête par interview en vis-à-vis et les redressements afférents.

3. Passation de l'enquête et corrections statistiques

Une enquête de terrain suppose l'existence de certains aléas ou biais que l'organisateur et les enquêteurs et enquêtrices ne peuvent pas forcément maîtriser : il s'agit notamment des mauvaises adresses, des personnes qui refusent de répondre, etc. Ces biais doivent être répertoriés, contrôlés et apurés afin de garantir la fiabilité des résultats statistiques de l'enquête. Ainsi, après avoir développé les résultats de la passation de l'enquête, le deuxième paragraphe s'attardera sur les causes des principaux biais et le dernier abordera quelques exemples estimés de résultats d'enquête.

3.1. Résultats de la passation de l'enquête de terrain

En résumé, sur les 1 803 envois de courriers, deux grandes familles de réponse ont été répertoriées :

- *les répondants*. Ainsi, 997 ménages/individus kish constituent les répondants de l'enquête, soit 55,3 % des courriers. Parmi ces répondants, 94 ménages sont hors champs[12] (décès, maisons de retraite, déménagement hors de la captiale, 5,2 %). Les 903 autres ménages/individus correspondent aux questionnaires validés à partir desquels les résultats de l'enquête pourront être extrapolés ;
- *les non répondants*. 806 enquêtes non réalisées se sont partagées entre : 537 refus volontaires d'enquêtes (29,7 %) ; 67 mauvaises adresses (3,7 %) ; 31 refus pour incapacité de répondre (1,7 %) ; et 172 ménages toujours absents (9,6 %).

Il est nécessaire de regarder plus en détail les caractéristiques des ménages formant les non répondants. Car s'il existe des défauts de représentativité entraînant des biais dans les futurs résultats de l'enquête, il est important de les corriger. La démarche adoptée est de détecter les variables qui interviennent directement ou indirectement dans le processus de non-réponse d'abord, avant de voir le profil des répondants ensuite.

3.2. Détection des principaux biais

En fonction de la problématique posée, nous nous intéressons d'abord à la répartition des non répondants selon les zones résidentielles (cf. table 5). Ces strates ou zones, ayant servi de base de contrôle, à la fois de la procédure d'échantillonnage et de la passation du questionnaire, ne montrent guère de différences entre elles.

[12] Ces hors champs seront assimilés dans le processus de repondération à des répondants. En effet, ils ne sont plus concernés par le questionnaire, donc ils peuvent être considérés comme ne faisant plus partie de notre échantillon. Cependant, ces hors-champs nous donnent une information supplémentaire par rapport au fichier de population initial.

Table 5 – Répondants et non répondants au niveau des zones résidentielles

Classement par zones résidentielles	Population sensée être interrogée pondérée (%)	Pop. effectivement interrogée pondérée (%)	Non répondants (effectifs)	Répondants (effectifs)	Taux de non-réponse observé (%)
Zone 1	15,41	14,28	**135**	142	48,7
Zone 2	15,43	15,31	**126**	153	45,2
Zone 3	14,85	14,07	**128**	141	47,6
Zone 4	19	20,70	**136**	206	39,8
Zone 5	19,34	17,89	**170**	178	48,9
Zone 6	15,96	17,74	**111**	177	38,5
Total	100	100	**806**	997	44,7

Source : BPVdL 2001, enquête PAVdL, 2002

Les écarts pondérés ne sont guère importants, le plus grand ne dépassant pas les deux points. Cette remarque justifie à elle seule la méthode d'échantillonnage spatial utilisée car nous avons pu contrôler et assurer une comparabilité au niveau infra-communal. Malgré un taux de non-réponse observé variant entre 38,5 et 48,7 %, l'un des buts de l'enquête est d'ores et déjà atteint : disposer de résultats d'enquête pondérés comparables à l' échelle infra-communale.

En observant la répartition des non répondants selon la taille effective des ménages, nous remarquons que l'ensemble des non-réponses observé réside essentiellement au niveau des personnes isolées (table 6).

Table 6 – Répondants et non répondants selon la taille effective des ménages

Classement par taille de ménages	Population sensée être interrogée pondérée (%)	Pop. effectivement interrogée pondérée (%)	Non répondants (effectifs)	Répondants (effectifs)	Taux de non-réponse observé (%)
Ménages de 1 personne	56,22	54,96	**467**	548	46,0
Ménages de 2 personnes	33,6	34,91	**111**	348	24,2
Ménages de 3 personnes et +	10,17	10,13	**228**	101	69,3
Total	100	100	**806**	997	44,7

Source : BPVdL 2001, enquête PAVdL, 2002

En effet, 467 non-réponses proviennent de ce type de groupe de ménages, soit 57 % des non-réponses. Toutefois, il convient de relativiser cet aspect en ce sens que les ménages de une personne représentent également plus de 57 % de la population ciblée : il est donc normal de trouver un *nombre* de non-réponses fort, alors que le *taux* de non-réponse (46 %) est relativement plus bas que celui des ménages de deux ou trois personnes et plus (plus de 69 %)[13].

Nous avons associé ces variables à d'autres variables auxiliaires, à savoir l'âge, le sexe la nationalité, l'état civil, ainsi que les groupes d'enquêteurs classés par taux de réponse, au sein d'une régression logistique, afin d'analyser méthodiquement le comportement de (non) réponse[14] de l'enquête (tableau 7).

[13] Ce taux, relativement élevé, se justifie par le fait que les enfants des personnes âgées refusent souvent à
[14] Source : [DEV 1993a].

Tableau 7 – Variables utilisées dans la régression logistique

Variable²	Modalité	Modalité estimée	Erreur standard	Wald	S
Groupes d'enquêteurs par classe de taux de réponse (r)	r < 0,5	-1,27	0,20	39,64	***
	0,5 < r < 0,53	-0,85	0,21	16,78	***
	0,53 < r < 0,573	-0,69	0,22	10,14	**
	0,573 < r < 0,61	-0,60	0,22	7,68	**
	0,61 < r < 0,66	-0,39	0,21	3,44	*
	r > 0,66	0	,	,	,
Zones résidentielles	zone 1	0,00	0,1860	0,00	n.s.
	zone 2	-0,17	0,18	0,88	n.s.
	zone 3	-0,06	0,19	0,11	n.s.
	zone 4	0,08	0,18	0,19	n.s.
	zone 5	-0,11	0,18	0,40	n.s.
	zone 6	0	,	,	,
Taille des ménages	1 personne	-0,16	0,18	0,83	n.s.
	2 personnes	-0,05	0,17	0,09	n.s.
	3 personnes et +	0,00	,	,	,
Sexe par tranches d'âge	F de 60 à 64 ans	-0,09	0,22	0,17	n.s.
	F de 65 à 74 ans	0,00	0,20	0,00	n.s.
	F 75 ans et +	-0,19	0,20	0,93	n.s.
	M de 60 à 64 ans	-1,33	0,23	1,95	n.s.
	M de 65 à 74 ans	-0,15	0,2090	0,55	n.s.
	M 75 ans et +	0,00	,	,	,
Nationalité	Luxembourgeois	0,09	0,12	0,58	n.s.
	autres nationalités	0	,	,	,
Etat civil	célibataires, divorcés	0,07	0,1460	0,21	n.s.
	mariés, remariés	0,03	0,20	0,02	n.s.
	veufs	-1,27	0,20	39,64	,
Constante		1,12	0,32	12,19	0,0005

Source : BPVdL 2001, enquête PAVdL, 2002

Notes de lecture :
² : variable dépendante : répondants/non répondants au questionnaire
*** : variable significative au seuil de 1 %
** : variable significative au seuil de 5 %
* : variable significative au seuil de 10 %
n.s. : variable non significative

Cette méthode statistique permet d'identifier et de comparer entre elles les différentes variables qui influencent la propension à appartenir au groupe des répondants ou à celui des non répondants. Les résultats montrent que la variable « groupes d'enquêteurs par classe de taux de réponse » est celle qui présente le plus de degré de signification. Ainsi, toutes choses égales par ailleurs, les modalités liées aux enquêteurs expliquent la propension la plus forte des enquêtés à ne pas répondre au questionnaire. Les autres variables ne sont pas significatives par rapport au modèle présenté.

La correction de tous ces biais va s'effectuer à partir d'une procédure de re-pondération. Les facteurs intervenants d'extrapolation vont tenir compte des erreurs observées sur le terrain après l'enquête d'une part, et de la représentativité des estimations selon certaines

caractéristiques des ménages, des individus membres de ces ménages et des individus Kish, d'autre part. Ces biais vont être corrigés en fonction de différentes variables auxiliaires grâce à la méthode de calage sur marges, procédure de pondération utilisée à l'origine pour pondérer l'enquête du recensement français.

3.3. Détermination des résultats d'enquête par un estimateur de calage

Le redressement de l'échantillon vise non seulement à réduire le biais inhérent à la présence d'un comportement de réponse non homogène au sein de la population ciblée, mais également à améliorer la représentativité de l'échantillon des 997 répondants vis-à-vis d'un nombre de critères non pris en compte *a priori* lors du tirage de l'échantillon (sexe, âge, nationalité, état civil).

En tenant compte des biais détectés et en voulant nous approcher des informations liées au fichier de population, nous souhaitons caler nos estimations en fonction de ces deux types d'information. L'estimateur de calage[15] qui en découle est asymptotiquement équivalent à un estimateur de régression. Ainsi, l'estimation d'un effectif Y est donné par :

$$\hat{Y}_{cal} = \sum_{k=1}^{903} w_k y_k = \hat{Y}_{HT} + \hat{\beta}'(X - \hat{X}_{HT})$$

où :
$\hat{Y}$ = Y estimé et calé
w_k = poids d'estimation
y_k = variable mesurée au niveau de l'enquête
$\hat{\beta} = (X'DX)^{-1}(X'DY)$ et $D = diag\left(d_k \frac{1803}{903}\right)$, calcul matriciel où X est la matrice regroupant les variables qui ont servi à caler les poids.

De manière générale, le plan d'échantillonnage et cette méthode de re-pondération définissent les formules qui devront être utilisées pour les estimations des résultats de l'enquête[16]. A titre indicatif, nous donnons quelques résultats estimés d'enquête illustrant l'aboutissement de ce cheminement méthodologique.

3.4. Des résultats estimés, extrapolés et situés dans des fourchettes d'évaluation

Alors que, selon le fichier de population, il existe 13 736 personnes âgées vivant à domicile au niveau de la Ville de Luxembourg en septembre 2001, le total défini après calage est extrapolé et estimé à 12 615 individus, selon un coefficient de variation général de 0,8 % (table 8).

[15] Sources : [DEV 1992], [DEV 1993b].
[16] Pour les explications de cette formule et de celles qui en découlent (notamment pour les calculs de variance), se référer au site du CEPS/INSTEAD, www.ceps.lu.

Table 8 – Estimation du total des individus de 60 ans ou plus et selon les strates

	Effectifs			Pourcentages			Coefficient de variation (%)
	Borne inférieure	Estimation	Borne supérieure	Borne inférieure	Estimation	Borne supérieure	
Zone 1	1 898	**1 967**	2 037	96,5	**100**	103,6	**1,8**
Zone 2	1 754	**1 854**	1 954	94,6	**100**	105,4	**2,7**
Zone 3	1 642	**1 739**	1 835	94,4	**100**	105,5	**2,8**
Zone 4	2 321	**2 413**	2 506	96,2	**100**	103,9	**1,9**
Zone 5	2 520	**2 606**	2 693	96,7	**100**	103,3	**1,7**
Zone 6	1 959	**2 036**	2 113	96,2	**100**	103,8	**1,9**
Total	12 401	**12 615**	12 830	98,3	**100**	101,7	**0,9**

Source : BPVdL 2001, enquête PAVdL, 2002

La différence entre les deux nombres représente l'estimation (environ 0,9 % d'écart) du nombre d'observations erronées du fichier de population (les hors champs estimés à l'échelle de la population âgée). L'estimation avancée peut donc varier de 2*0,9 % de la valeur des 12 615 individus, que ce soit de manière inférieure ou supérieure, mais l'avantage (et la rigueur statistique sous-jacente) est de pouvoir estimer cette marge d'erreur. Dans ce tableau sont également fournis les chiffres de la population âgée par strate. Les variations y sont très faibles et équivalentes ; c'était d'ailleurs l'un des objectifs de l'échantillonnage spatial réalisé. Ainsi, malgré des effectifs relativement réduits (en moyenne 150 interrogés par strate), nous arrivons à un coefficient de variation qui oscille entre 1,7 et 2,8 %.

En guise de comparaison, lorsque nous calculons les intervalles de confiance au niveau de l'âge en trois classes (table 9), ils sont équivalents à ceux des strates (environ 2,3 % en moyenne), alors que les effectifs interrogés par classe d'âge sont naturellement plus nombreux (en moyenne 300 interrogés par classe).

Table 9 - Estimation du total des individus de 60 ans ou plus selon les classes d'âge

	Effectifs			Pourcentages			Coefficient de variation (%)
	Borne inférieure	Estimation	Borne supérieure	Borne inférieure	Estimation	Borne supérieure	
60 à 64 ans	3 121	**3 272**	3 423	24,3	**25,9**	27,6	**2,3**
65 à 74 ans	5 125	**5 351**	5 576	39,9	**42,4**	44,9	**2,1**
75 ans et +	3 805	**3 993**	4 181	29,7	**31,7**	33,7	**2,4**
Total	12 401	**12 615**	12 830	98,3	**100**	101,7	**0,9**

Source : BPVdL 2001, enquête PAVdL, 2002

Les deux exemples précédents proviennent de variables auxiliaires sous contrôle, c'est-à-dire que les chiffres sont connus *a priori*, grâce au fichier de population. Qu'en est-il pour les variables d'intérêt de l'enquête elle-même, d'une part, et pour des cas où les effectifs interrogés sont peu nombreux d'autre part ? En fait, plus les effectifs se réduisent, plus les variations sont fortes. Une bonne illustration en est l'indicateur de dépendance, construit à partir de plusieurs questions de l'enquête[17]. L'indicateur de groupes iso-besoins (GIB,

[17] Pour la construction de cet indicateur, cf. [GER 2003] Vol. 2, annexes, partie 4.

tableau 10) est constitué de 4 niveaux : 1) GIB 0 : groupes de personnes entièrement valides, 2) GIB 1 : groupe de personnes présentant une faible dépendance ; GIB 2 : groupe de personnes de moyenne dépendance ; 4) GIB 3 : groupe de personnes à forte à très forte dépendance.

Tableau 10 - Estimation du total des individus de 60 ans ou plus selon les groupes iso-besoins

Groupes iso-besoins	Effectifs			Pourcentages			Coefficient de variation (%)
	Borne inférieure	Estimation	Borne supérieure	Borne inférieure	Estimation	Borne supérieure	
1) GIB 0	4 820	**5 226**	5 631	37,6	**41,4**	45,4	**3,9**
2) GIB 1	4 702	**5 116**	5 529	36,7	**40,6**	44,6	**4,0**
3) GIB 2	1 319	**1 606**	1 892	10,3	**12,7**	15,3	**8,9**
4) GIB 3	478	**669**	859	3,7	**5,3**	6,9	**14,2**
Total	12 401	**12 615**	12 830	98,3	**100**	101,7	**0,9**

Source : BPVdL 2001, enquête PAVdL, 2002

Les personnes du groupe iso-besoins 3 sont les moins nombreuses. Le coefficient de variation qui lui est associé est bien plus conséquent : il est de 14,2 % pour ce dernier groupe, alors qu'il n'est que de 3,9 % pour le GIB 0. En focalisant maintenant ces résultats par tranche d'âge, une des variables explicatives du phénomène de dépendance, le coefficient de variation sera de 18 % pour le GIB 3 et les 75 ans ou plus (tableau 11). Or, ce dernier coefficient se situe à la limite de l'intervalle acceptable des données, selon les critères standards de qualité statistique[18].

Tableau 11 - Estimation du total des individus de 75 ans ou plus selon les groupes iso-besoins

Population des 75 ans ou +	Effectifs			Pourcentages			Coefficient de variation (%)
	Borne inférieure	Estimation	Borne supérieure	Borne inférieure	Estimation	Borne supérieure	
GIB 0	1 065	**1 295**	1 525	25,5	**32,4**	40,1	**8,9**
GIB 1	1 360	**1 612**	1 865	32,5	**40,4**	49,0	**7,8**
GIB 2	256	**711**	896	6,1	**17,8**	23,6	**13,0**
GIB 3	239	**375**	510	5,7	**9,4**	13,4	**18,0**
Total	3 805	**3 993**	4 181	29,8	**31,6**	33,7	**2,4**

Source : BPVdL 2001, enquête PAVdL, 2002

Ces résultats illustratifs nous incitent à la prudence quant à la manipulation des petites populations où les coefficients de variation afférents peuvent subir des écarts relativement importants. Toutefois, la pondération pratiquée au sein de cette enquête, accompagnée de son processus de redressement, engendrent le calcul d'une variance qui permet de contrôler ces écarts d'estimation et ainsi d'en évaluer son degré de précision. Les résultats d'enquête y gagnent en fiabilité et en efficacité car la variance permettrait, par exemple, de fournir une limite d'exploitation géographique des découpages infra-communaux proposés.

[18] Au sujet de la qualité statistique, cf. [STA 2002].

Conclusion

A travers l'exemple d'une enquête sur les personnes âgées à domicile au niveau de la Ville de Luxembourg, la technique de l'échantillonnage spatial stratifié révèle de nombreux atouts. Cependant, elle suppose au préalable plusieurs exigences : des sources d'information de cadrage, une connaissance du terrain (et du sujet d'étude), certaines conditions préalables, et un suivi au niveau des strates.

Ainsi, la Ville de Luxembourg a fourni le fichier administratif de la population. Malgré certaines erreurs, cela nous a permis de créer, de contrôler et de gérer l'échantillon, en partant d'informations très récentes : ces données de cadrage ont permis notamment le découpage infra-communal.

Au niveau de la connaissance du terrain, notre commanditaire a fait appel au CEPS/INSTEAD qui dispose de l'expérience et du savoir-faire nécessaires pour mener à bien ce type d'enquête. Par rapport au sujet d'étude, les strates spatiales trouvent d'abord leur justification dans le but de l'enquête : dans notre cas, il était bien souligné la volonté d'obtenir des données comparables au niveau infra-communal ; cela suppose un rôle explicite des strates spatiales dans l'analyse postérieure des résultats dont nous avons fourni quelques illustrations. Néanmoins, il est évident que la thématique des personnes âgées devait être maîtrisée dès le départ, quel que soit le mode de tirage.

Une condition préalable est que ces strates, et leur population ciblée associée, doivent contenir un nombre de personnes à interroger suffisamment important pour l'inférence statistique (approximation normale…). En outre, les observations constituant une strate doivent tendre vers une certaine homogénéité (sociale par exemple), alors que les observations entre chaque strate doivent être hétérogènes. Ces deux conditions nous ont obligés à agréger les 24 quartiers administratifs de la Ville de Luxembourg en 6 zones résidentielles ou strates spatiales.

Par après, la stratification obtenue suppose un suivi au moment de la passation de l'enquête. Le but est de contrôler au fur et à mesure les réponses ou non-réponses par strate. Si une strate avait été par exemple sous-représentée au niveau de ses effectifs de répondants, il eût été possible de gérer ce biais en augmentant la taille de l'échantillon (adresses) grâce à la liste d'attente établie au moment du tirage de l'échantillon. Cette option n'a pas été nécessaire.

Malgré ces exigences, la méthode de stratification spatiale apporte indéniablement son lot d'avantages. Ainsi, grâce à la création des six zones résidentielles, la technique de l'échantillonnage aléatoire simple est surpassée. Ceci tant au niveau de la variance[19] calculée *a priori*, que du biais (une erreur d'observation) que l'on essaie de maîtriser *a posteriori*. Nous améliorons sensiblement la précision des résultats.

[19] Par la méthode de stratification spatiale, nous obtenons une erreur d'échantillonnage inférieure à la méthode d'échantillonnage simple entre les zones résidentielles.

De plus, sous la contrainte d'un nombre limité d'observations (pas plus de mille enquêtes), cette méthode offre un degré de précision - de même ordre au sein de chaque zone - qui a permis de faciliter la comparabilité des résultats au niveau infra-communal. Il n'existe donc pas de déséquilibre spatial, les résultats sont géographiquement valides. Par exemple, nous souhaitions connaître quels sont les commerces et services dont la personne âgée dispose à proximité de son domicile. Sans passer en revue tous les commerces concernés, nous notions un déficit évident pour la pharmacie, notamment dans les zones résidentielles est et sud-ouest. Selon nos résultats statistiques, découlant de l'appréciation des personnes interrogées, moins de 20 % des personnes de ces zones résidentielles disposent en 2002 d'une pharmacie à proximité de leur domicile, contre plus de 70 % pour les quatre autres secteurs. Après vérification sur le terrain, nous remarquons effectivement que les zones est et sud-ouest sont les moins bien pourvues en pharmacies. Ainsi, l'analyse des résultats d'enquête permet de détecter non seulement le type de commerces et services qui peut manquer au niveau de la Ville de Luxembourg, mais également leur répartition spatiale inégale à l'échelle des quartiers résidentiels.

Cet exemple illustre bien le genre de résultats susceptibles d'intéresser la Ville de Luxembourg, ou toute autre municipalité urbaine. Les données fiables transmises à l'échelle infra-communale sont essentielles pour les élus, à l'heure où les politiques cherchent de plus en plus à trouver des réponses locales à des phénomènes globaux, comme le vieillissement démographique de la population. Des solutions par rapport à la planification urbaine peuvent être étudiées et développées grâce à cette méthode d'échantillonnage. La fiabilité et le contrôle des chiffres exposés tendent à démontrer que les résultats de l'enquête, lorsqu'ils s'appuient sur une population interrogée relativement nombreuse, sont tout à fait comparables entre les strates, donc entre les zones résidentielles. En ce sens, la stratification spatiale n'est pas une fin en soi : elle permet de mieux contrôler les résultats *a priori* et *a posteriori* par rapport à un échantillon aléatoire simple à l'échelle intra-urbaine.

Bibliographie

[AGL 2002] - AGLIETTA M., BLANCHET D., HERAN F. (2002, coord.) : *Démographie et économie.* Rapport établi dans le cadre de la création du Conseil d'Analyse Economique, Ed. La Doc. Française, Paris, 343 p.

[ARD 1994] - ARDILLY P. (1994) : *Les techniques de sondage.* Ed. Technip, Paris, 393 p.

[BER 1970] - BERRY B.J.L., HORTON F.E. (1970) : *Geographic perspectives on urban systems (with integrated readings)*, Prentice Hall, Ed. Englewood-Cliffs, New Jersey, 564 p.

[CON 2001] - CONSEIL ECONOMIQUE ET SOCIAL (2001) : *Les personnes âgées dans la société.* Avis adopté par le C.E.S. au cours de la séance du 23 mai 2001, rapporteur Maurice BONNET, téléchargeable (novembre 2003) à : http://www.conseil-economique-et -social.fr/ces_dat2/24kiosq/rapan2001/Som1.htm. 60 p.

[DEV 1992] - DEVILLE J.-C., SARNDAL C.-E. (1993) : Calibration estimators in survey sampling. *Journal of the American statistical Association*, n° 87, pp. 376-382.

[DEV 1993a] - DEVILLE J.-C., DUPONT F. (1993) : Non réponse : principes et méthodes. *In* Actes des journées de méthodologie statistique des 15 et 16 déc. 1993. *INSEE Méthodes*, Ed. INSEE, Paris, pp. 53-70.

[DEV 1993b] - DEVILLE J.-C., SARNDAL C.-E., SAUTORY O. (1993) : Generalized raking procedure in survey sampling. *Journal of the American statistical Association*, n° 88, pp. 1 013-1 020.

[DEV 1999] - DEVILLE J.-C. (1999) : Estimation de la variance pour des statistiques et des estimateurs complexes : techniques de résidus et de linéarisation. *Techniques d'enquêtes*, n° 25, pp. 219-230.

[GER 2003] – GERBER P., BOUSCH P. (2003, coord.) : *Personnes Agées Ville de Luxembourg. Rapport établi à la demande de la Ville de Luxembourg. Volume 1 : analyses. Volume 2 : annexes.* Décembre 2003, Differdange.

[GUI 1999] - GUINCHARD-KUNSTLER P. (1999) : Vieillir en France. Enjeux et besoins d'une nouvelle orientation de la politique en direction des personnes âgées en perte d'autonomie. Rapport à Monsieur le Premier Ministre. Document téléchargeable (novembre 2003) à l'adresse : http://www.inserm.fr/serveur/vieil.nsf/(Web+Ressources+Attachments)/vieillir%20en%20France/$File/vieillir%20en%20France.pdf .102 p.

[KIS 1965] - KISH L. (1965) : *Survey Sampling*, Ed. J. Wiley and Sons, New York.

[POU 1999] - POULAIN M. (1999) : *Atlas géostatistique des quartiers*. Ed. UCL, Belgique, 64 p.

[ROC 2000] - ROCHEFORT R. (2000) : *Vive le papy-boom*. Ed. O. Jacob, Paris, 291 p.

[REY 1998] - REYMOND H., CAUVIN C., KLEINSCHMAGER R. (1998, coord.): *L'espace géographique des villes. Pour une synergie multistrates.* Ed. Anthropos, Economica, Coll. Villes, 557 p.

[SAR 1992] - SARNDAL C.-E., SWENSSON B., WRETMAN J.H. (1992) : Model assited survey sampling. Ed. Springer Verlag, New York, 695 p.

[STA 2002] - STATISTIQUE CANADA (2002) : *Le cadre d'assurance de la qualité de Statistique Canada.* Ed. Statistique Canada, 37 p. Téléchargeable (novembre 2003) : http://www.statcan.ca/francais/ freepub/12-586-XIF/12-586-XIF02001.pdf.

[THE 1992] - THEVENET A. (1992) : *Le quatrième âge*. Ed. PUF, Coll. Que Sais-Je ?, Paris, 128 p.

[VIM 2000] - VIMONT C. (2001) : *Le nouveau Troisième Age. Une société active en devenir.* Ed. Economica, Paris, 117 p.

[WAT 1993] - WATTIEZ-MANGELINCKX A. (1993) : *Le senior nouveau est arrivé*. Ed. Quorum, Ottignies (Belgique), 201 p.