

N° 62M0004XCB au catalogue

Guide de l'utilisateur : fichier de microdonnées à grande diffusion

Enquête sur les dépenses des ménages, 2009

Juin 2011

**Division de la statistique du revenu
Statistique Canada, Ottawa, K1A 0T6
Téléphone : 613 951-7355**

This document is available in English

La « Division de la statistique du revenu, Statistique Canada » devrait être mentionnée lorsqu'une partie quelconque du présent document est reproduite ou citée.

Table des matières

Introduction	3
Contexte	3
Autres documents	3
Pour de plus amples renseignements	4
Caractéristiques techniques du fichier	5
Méthodologie de l'enquête	6
L'univers de l'enquête	6
Contenu de l'enquête et période de référence	6
L'échantillon	7
Collecte des données.....	7
Traitement des données et contrôle de la qualité	7
Pondération, repondération et révision historique de l'EDM en fonction du recensement.....	8
La qualité des données	10
Erreur d'échantillonnage	10
Erreur non due à l'échantillonnage	11
Erreur de couverture	11
Erreur de réponse	11
Erreur de non-réponse	12
Erreur de traitement	13
Effet des valeurs extrêmes.....	14
Comparabilité dans le temps.....	14
Lignes directrices pour la totalisation, l'analyse et la diffusion.....	15
Lignes directrices pour l'arrondissement.....	15
Lignes directrices pour la pondération de l'échantillon en vue de la totalisation.	16
Genres d'estimations : type nominal par opposition à quantitatives	17
Estimations de type nominal.....	17
Estimations quantitatives.....	18
Lignes directrices pour l'analyse statistique.....	18
Lignes directrices pour la diffusion	19
Calcul de CV approximatifs	20
Comment obtenir les limites de confiance.....	29
Comment effectuer un test Z.....	30
Confidentialité des microdonnées à grande diffusion	30
Annexes—Voir le fichier Excel d'accompagnement.....	32
Annexe A Comptes de fréquences	32
Annexe B Valeurs moyennes, totales, minimales et maximales	32
Annexe C Inclusion des articles de dépenses dans les fichiers de microdonnées antérieurs.....	32
Annexe D Coefficients de variation pour les données publiées provenant de l'EDM de 2009	32

Introduction

Contexte

Ce fichier de microdonnées à grande diffusion présente les données de l'Enquête sur les dépenses des ménages (EDM) de 2009 menée de janvier à mars 2010. Les renseignements sur les habitudes de dépenses, les caractéristiques du logement et l'équipement ménager des ménages canadiens pendant l'année 2009 ont été obtenus en demandant aux gens dans les 10 provinces et trois territoires de se rappeler les dépenses engagées au cours de l'année civile précédente (pour les habitudes de dépenses) ou l'information à la date de l'interview (pour les caractéristiques du logement et l'équipement ménager).

Menée depuis 1997, l'Enquête sur les dépenses des ménages tente de reprendre une bonne part du contenu de l'Enquête sur les dépenses des familles ainsi que du contenu de l'Enquête sur l'équipement ménager. Plusieurs données provenant de ces enquêtes sont comparables aux données de l'Enquête sur les dépenses des ménages. Cependant, certaines différences reliées à la méthodologie, à la qualité des données et aux définitions doivent être considérées lorsqu'on veut comparer ces données. Voir la section « Pour de plus amples renseignements ».

Autres documents

- Dictionnaire de données (spécifications des variables, ensembles de codes et autres renseignements) est disponible en format pdf.
- Cliché d'enregistrement est disponible en format Excel.
- Les annexes sont disponibles en format Excel.
 - L'annexe A présente les comptes de fréquence des variables non monétaires du fichier de microdonnées à grande diffusion. Ils sont inclus pour vous aider à vérifier vos totalisations.
 - L'annexe B présente les données sur les dépenses en utilisant le fichier de microdonnées à grande diffusion et la base de données interne de l'enquête. Elles sont incluses pour vous permettre de valider vos totalisations.
 - L'annexe C contient un tableau indiquant les variables de dépense présentées dans les fichiers de microdonnées à grande diffusion précédents de l'Enquête sur les dépenses des ménages et de l'Enquête sur les dépenses des familles.
 - L'annexe D présente les coefficients de variation pour les données publiées provenant de l'EDM de 2009.

Pour de plus amples renseignements

De l'information additionnelle au sujet de l'Enquête sur les dépenses des ménages peut maintenant être obtenue gratuitement sur le site Web de Statistique Canada (www.statcan.gc.ca). Voir particulièrement :

- Note aux anciens utilisateurs de données provenant de l'Enquête sur les dépenses des familles (62F0026MIF2000002)
- Note aux anciens utilisateurs de données provenant de l'Enquête sur l'équipement ménager (62F0026MIF2000003)
- Guide de l'utilisateur de l'Enquête sur les dépenses des ménages de 2009 (62F0026MIF2010006)
- La méthodologie de l'Enquête sur les dépenses des ménages (62F0026MIF2001003)
- Enquête sur les dépenses des ménages de 2008 — Indicateurs de qualité des données (62F0026MWF2010005)

Pour obtenir plus de renseignements au sujet des résultats de l'enquête actuelle et des produits et services connexes, ou pour s'informer sur les concepts, les méthodes ou la qualité des données de l'Enquête sur les dépenses des ménages, communiquez avec les Services aux clients (613-951-7355; 1-888-297-7355; télécopieur : 613-951-3012; revenu@statcan.gc.ca), Division de la statistique du revenu.

Caractéristiques techniques du fichier

Contenu : Les habitudes de dépenses des ménages, les caractéristiques des logements et l'équipement ménager, 2009

Source : Enquête sur les dépenses des ménages de 2009
Division de la statistique du revenu
Statistique Canada

Ensemble de données :

Nom de l'ensemble de données SHS2009.TXT

Nombre d'enregistrements 10 811

Structure

Taille de l'enregistrement 2 066

Méthodologie de l'enquête

(Pour de plus amples renseignements, veuillez consulter "La méthodologie de l'Enquête sur les dépenses des ménages" disponible gratuitement sur le site Internet de Statistique Canada au www.statcan.gc.ca)

L'univers de l'enquête

L'Enquête sur les dépenses des ménages de 2009 a été effectuée dans les ménages privés des 10 provinces¹ et trois territoires du Canada. La dernière fois que des ménages des territoires avaient été inclus dans l'échantillon était en 2007.

Les groupes suivants ont été exclus de l'enquête :

- les personnes qui vivent dans les réserves indiennes et les terres de la couronne (à l'exception des Territoires);
- les représentants officiels de pays étrangers qui vivent au Canada et leur famille;
- les membres d'ordres religieux et d'autres groupes vivant en communauté;
- les membres des Forces canadiennes vivant dans des camps militaires; et
- les personnes qui vivent à plein temps dans les institutions : par exemple, les détenus des pénitenciers et les malades chroniques qui vivent dans des hôpitaux et dans des établissements de soins de longue durée.

L'enquête englobe environ 98 % de la population dans les 10 provinces. Au Yukon, Territoires du Nord-Ouest et Nunavut, la population sondée représente près de 92%.

On a recueilli les données sur les dépenses pour tous les membres du ménage au moment de l'interview, y compris les personnes qui se sont jointes au ménage en 2009 ou 2010, et indépendamment du fait qu'il ait existé un ménage par le passé ou que la personne ait vécu seule. Les données n'ont pas été recueillies pour les personnes qui ont quitté le ménage en 2009 ou 2010. Par conséquent, une grande différence entre la méthodologie de l'Enquête sur les dépenses des ménages de 2006 à 2009 et celle des années antérieures est qu'on a écarté la distinction entre les ménages et leurs membres en occupation toute l'année et une partie de l'année.

Les personnes qui vivaient temporairement loin de leur famille (pour fréquenter l'université, par exemple) sont incluses dans le ménage pour ne pas être comptées en double.

Contenu de l'enquête et période de référence

Des renseignements détaillés au sujet des dépenses pour les produits et services de consommation, les variations de l'actif, les hypothèques et d'autres prêts, et le revenu annuel ont été recueillis. Ces renseignements furent recueillis pour l'année civile 2009 (l'année de référence de l'enquête). Nous avons aussi

1. Dans le but de réduire le fardeau de réponse pour les ménages du Nord, l'Enquête sur les dépenses des ménages est menée dans le Nord seulement tous les deux ans, débutant à partir de 1999.

recueilli des renseignements sur les caractéristiques des logements (p. ex., le type et l'âge de l'appareil de chauffage) et de l'équipement ménager (p. ex., les appareils ménagers, le matériel de communication et les véhicules). Pour ces données, la date de référence est celle de l'interview.

Comme l'Enquête sur les dépenses des ménages est conçue principalement pour donner des renseignements détaillés sur les dépenses autres que les dépenses alimentaires, seule une estimation globale de ces dépenses est indiquée. On peut trouver des renseignements détaillés sur ces dépenses dans l'Enquête sur les dépenses alimentaires, qui était menée tous les quatre à six ans jusqu'en 2001. En février 2003, les résultats ont été publiés dans **Dépenses alimentaires au Canada, 2001**, n° 62-554-XIF au catalogue.

L'échantillon

La taille de l'échantillon pour l'Enquête sur les dépenses des ménages de 2009 était de 16,758 ménages admissibles. L'échantillon est plus grand qu'en 2008, principalement à cause de l'ajout des ménages des territoires, mais demeure plus petit que lors des années précédentes. L'échantillon a été réduit en 2008 et 2009 afin de libérer des ressources pour élaborer l'Enquête sur les dépenses des ménages remaniée, qui remplacera l'enquête actuelle à compter de l'année de référence 2010.

L'échantillon régulier de l'Enquête sur les dépenses des ménages est un échantillon stratifié à plusieurs degrés et il a été choisi à partir de la base de sondage de l'Enquête sur la population active (EPA). La sélection de l'échantillon s'est faite en deux étapes : la sélection de grappes (petites aires géographiques) de la base de sondage de l'EPA et la sélection de logements dans les grappes choisies. La base de sondage de l'EPA utilise principalement la géographie du Recensement de 2001 et les dénombrements de la population de 2001.²

Collecte des données

L'Enquête sur les dépenses des ménages de 2009 s'est déroulée au cours des mois de janvier à mars 2010. La collecte des données s'est faite en mode IPAO (interview sur place assistée par ordinateur) et sur ordinateur portable. Un exemplaire de ce questionnaire est disponible sur le site Web de Statistique Canada (www.statcan.gc.ca).

Traitement des données et contrôle de la qualité

À cause du passage à un questionnaire électronique IPAO depuis l'année de référence 2006, nous avons modifié les mesures de traitement des données et de contrôle de la qualité.

Pour l'Enquête sur les dépenses des ménages de 2009, tout comme pour les trois années précédentes, les intervieweurs ont saisi les réponses sur ordinateur portable et procédé à une première vérification simultanément. Ainsi, les contrôles

2. Consulter la publication *Méthodologie de l'Enquête sur la population active du Canada* Statistique Canada, n° 71-526-XIF au catalogue, pour obtenir une description détaillée de la base de sondage de l'Enquête sur la population active.

d'intervalle, qui indiquent un montant minimal et maximal pour certains achats, ont permis d'identifier des montants inhabituels entrés par l'intervieweur. D'autres vérifications visaient les réponses incohérentes, comme par exemple, qu'un ménage occupait son logement en location, mais qu'aucun loyer n'était payé. En plus des contrôles automatiques intégrés au questionnaire électronique, un contrôle d'équilibre comparant les revenus totaux, les dépenses et les changements concernant l'actif et le passif a été effectué par l'intervieweur et a tenu lieu de contrôle de la qualité des données.

Ensuite, on a vérifié au bureau central s'il n'y avait pas d'incohérences ou de valeurs inhabituelles ou excessives et on a corrigé les réponses non valides.

Si le ménage indiquait des dépenses sans en préciser le montant, on remplaçait les réponses manquantes à l'aide de la méthode d'imputation du plus proche voisin. Le Système canadien de contrôle et d'imputation du recensement (SCANCIR) de Statistique Canada a été utilisé pour assigner des valeurs à partir d'enregistrements donneurs ayant des caractéristiques similaires. Le choix des caractéristiques est effectué en fonction de chaque variable. Par exemple, le revenu total a été utilisé pour la plupart des variables. Le type de logement, la taille du ménage et la province ont également été fréquemment utilisés.

Pour l'Enquête sur les dépenses des ménages de 2009, la totalisation a été effectuée par un système PC/client-serveur. Ce système fournit des outils (capacités d'interrogation, de recherche et de visualisation) pour déceler les erreurs systématiques.

Pondération, repondération et révision historique de l'EDM en fonction du recensement

Les utilisateurs devraient noter que les poids ont été révisés pour les années de référence EDM de 1997 à 2003. Les révisions ont été publiées en décembre 2006 en même temps que les résultats de l'enquête de 2005.

L'estimation de caractéristiques démographiques à partir d'une enquête par échantillon est fondée sur le postulat que chaque ménage échantillonné, outre lui-même, représente un certain nombre d'autres ménages. Ce nombre est désigné sous le nom de poids d'enquête de l'échantillon. Afin de rehausser la représentativité de l'échantillon, le poids est rajusté pour que les estimations découlant de l'échantillon correspondent aux chiffres de population, ou repères, provenant d'autres sources d'information indépendantes réputées fiables. Cette opération est appelée étalonnage des poids.

Dans le cas de l'EDM, l'étalonnage est effectué à l'aide de deux sources. La première, soit le Recensement de la population, fournit des repères démographiques. De 1997 à 2003, l'EDM s'est appuyée sur des repères provenant du Recensement de 1996. Comme le recensement est effectué tous les cinq ans, Statistique Canada fait des projections à partir des résultats du recensement pour les années subséquentes (jusqu'au moment présent), puis révisé ces estimations lorsque les données du recensement suivant deviennent disponibles. Les projections sont établies à l'aide de divers renseignements

secondaires, notamment des données administratives sur les naissances, les décès et la migration.

La seconde source d'information utilisée pour rajuster les poids de l'EDM sont les données T4 de l'Agence du revenu du Canada, qui permettent de faire en sorte que la distribution estimée des personnes gagnant un revenu calculée dans le cadre de l'enquête concorde avec celle observée dans la population canadienne.

Nous avons décidé de profiter de la révision historique en 2006 pour adopter une stratégie améliorée d'étalonnage des poids de l'EDM. Les améliorations apportées à la stratégie d'étalonnage ont été jugées nécessaires afin de mettre l'accent sur les besoins de l'EDM (tels que les groupes d'âge servant à l'étalonnage) et pour tenir compte de la qualité des repères. De plus, nous estimions que le nombre de repères était trop élevé et donc que les poids étaient soumis à un trop grand nombre de contraintes, ce qui produisait des résultats indésirables, tels que des poids négatifs, qui n'étaient pas acceptables.

La stratégie d'étalonnage actuellement employée pour les 10 provinces est la suivante :

- Âge
 - à l'échelon provincial, on compte 8 groupes d'âge à titre de contrôle (0-6, 7-17, 18-24, 25-34, 35-44, 45-54, 55-64 et 65 et plus);
 - au niveau des RMR, il y en a deux (0-17 et 18 et plus), exception faite de St. John's où l'étalonnage par rapport aux différents groupes d'âge a été éliminé : l'étalonnage est effectué par rapport au total de la population sans distinction d'âge.
- Il y a trois catégories de taille du ménage (une, deux et trois personnes et plus).
- On ajuste en fonction des données T4 les poids de la population pour le revenu sous forme de salaires et traitements (0-25^e, 25^e-50^e, 50^e-65^e, 65^e-75^e, 75^e-95^e et 95^e-100^e percentiles).

En raison de leur plus petite population, on a utilisé seulement deux groupes d'âge pour les trois territoires du Nord : le nombre de personnes de moins de 18 ans et le nombre de personnes de 18 ans et plus. Les poids sont aussi étalonnés aux totaux du nombre de ménages d'une seule personne, de deux personnes et de ménages de trois personnes ou plus excepté pour le Nunavut. En 2009, l'étalonnage par taille de ménage pour ce territoire était supprimé mais demeurerait pour le total du nombre de ménages.

On a appliqué les poids et la stratégie d'étalonnage pour les enquêtes des années 1997 et suivantes, et les estimations des dépenses des ménages ont donc été révisées pour toutes les années jusqu'en 2003. Les utilisateurs de ces données doivent s'assurer d'établir des comparaisons en utilisant les données repondérées.

La qualité des données

Pour de plus amples renseignements, veuillez consulter *Les indicateurs de la qualité des données de l'Enquête sur les dépenses des ménages*, qui sera bientôt disponible gratuitement sur le site Internet de Statistique Canada au www.statcan.gc.ca.

Erreur d'échantillonnage

Les erreurs d'échantillonnage résultent du fait que l'on tire certaines conclusions au sujet de l'ensemble de la population à partir des renseignements obtenus auprès de seulement un échantillon de cette population. L'importance de l'erreur d'échantillonnage est fonction du plan de sondage, de la variabilité des données et de la taille de l'échantillon. De plus, pour un plan d'échantillonnage donné, on obtiendra des erreurs d'échantillonnage différentes pour différentes méthodes d'estimation.

Le plan retenu pour l'Enquête sur les dépenses des ménages de 2009 était un échantillonnage stratifié à plusieurs degrés. Dans un échantillonnage à plusieurs degrés, les erreurs d'échantillonnage sont normalement plus importantes que dans un échantillonnage aléatoire simple de même taille. Toutefois, les avantages sur le plan opérationnel l'emportent sur cet inconvénient, et le fait que l'échantillon soit aussi stratifié améliore la précision des estimations.

La variabilité des données est la différence entre les unités de la population pour les dépenses relatives à un article ou la présence d'une caractéristique spécifique du logement ou d'une pièce d'équipement ménager. En général, plus ces différences sont grandes, plus l'erreur d'échantillonnage est élevée. Également, plus la taille de l'échantillon est grande, plus l'erreur d'échantillonnage est faible.

Erreur type et coefficient de variation

Une mesure courante de l'erreur d'échantillonnage est l'erreur type (ET). L'erreur type est le degré de variation que l'on observe dans les estimations par suite du choix d'un échantillon particulier plutôt qu'un autre de même taille et selon le même plan de sondage. Il a été démontré que la « vraie » valeur de la caractéristique d'intérêt se situe à l'intérieur de l'intervalle de ± 1 erreur type de l'estimation pour 68 % de tous les échantillons, et de ± 2 erreurs types de l'estimation pour 95 % de tous les échantillons.

Le coefficient de variation (CV) est l'erreur type exprimée en tant que pourcentage de l'estimation. Il est utilisé pour indiquer le degré d'incertitude associé à une estimation. Par exemple, si l'estimation du nombre de ménages pour une caractéristique du logement donnée est 10 000 ménages, et que le CV correspondant est de 5 %, la vraie valeur se situe entre 9 500 et 10 500 ménages, 68 % du temps, et entre 9 000 et 11 000 ménages, 95 % du temps.

Les erreurs types pour l'Enquête sur les dépenses des ménages de 2009 ont été estimées selon la méthode du « bootstrap ». Cette méthode permet l'estimation de la variance de statistiques non lisses comme les quantiles. Pour plus de renseignements sur les erreurs types et les coefficients de variation, voir la

publication de Statistique Canada intitulée *Méthodologie de l'enquête sur la population active du Canada*, n° 71-526-XIF au catalogue.

Les coefficients de variation sont disponibles sur demande (communiquez avec les Services aux clients, Division de la statistique du revenu, 1-888-297-7355; revenu@statcan.gc.ca).

Suppression de données

Pour des raisons de fiabilité, les données pour lesquelles les CV ont été estimés à plus de 33 % sont généralement supprimées. Puisque les CV ne sont pas calculés pour toutes les estimations, la suppression de données pour l'Enquête sur les dépenses des ménages a été fondée sur la relation entre le CV et le nombre de ménages qui déclaraient des dépenses pour un article. L'analyse d'enquêtes antérieures indique que les CV atteignent habituellement ce niveau lorsque le nombre de ménages qui déclarent un article chute à environ 30. Par conséquent, on a supprimé les dépenses moyennes des ménages et le pourcentage de ménages déclarants pour les articles déclarés par moins de 30 ménages.

Toutefois, les données relatives aux articles supprimés sont incluses dans les variables sommaires. Par exemple, les dépenses pour une catégorie particulière d'habillement pourraient être supprimées, mais ce montant fait partie de l'estimation des dépenses totales au titre de l'habillement.

La réduction de la taille d'échantillon de l'EDM de 2009 comparativement aux années précédentes aura un impact sur la qualité des données, en particulier dans la plupart des cas la variance sera supérieure à son niveau des années précédentes.

Erreur non due à l'échantillonnage

Les erreurs non dues à l'échantillonnage se produisent parce qu'il est difficile, en raison de certains facteurs, d'obtenir des réponses exactes ou de faire en sorte que ces réponses restent exactes suite à toutes les étapes du traitement. Contrairement à l'erreur d'échantillonnage, l'erreur non due à l'échantillonnage n'est pas facilement quantifiable. On peut dégager quatre sources d'erreurs non dues à l'échantillonnage : les erreurs de couverture, les erreurs de réponse, les erreurs de non-réponse et les erreurs de traitement.

Erreur de couverture

Les erreurs de couverture découlent d'une représentation inadéquate de la population observée. Ces erreurs peuvent survenir au cours de l'établissement du plan d'échantillonnage ou du tirage de l'échantillon, ou encore pendant la collecte ou le traitement des données.

Erreur de réponse

Les erreurs de réponse peuvent être attribuables à divers facteurs comme l'ambiguïté du questionnaire, une mauvaise interprétation des questions par les intervieweurs ou les répondants ou la déclaration de données inexacts par les répondants.

Plusieurs caractéristiques de l'enquête aident les répondants à se rappeler leurs dépenses de la façon la plus exacte possible. Premièrement, la période de l'enquête est l'année civile, car dans l'esprit des gens elle est probablement définie plus clairement que toute autre période de longueur semblable. Deuxièmement, les dépenses alimentaires peuvent être estimées comme étant des dépenses hebdomadaires ou mensuelles, selon les habitudes du répondant. Troisièmement, les dépenses pour de petits articles achetés à intervalles réguliers sont normalement estimées en fonction du montant et de la fréquence de l'achat. Les achats de gros articles (p. ex. une automobile) sont assez faciles à se rappeler, tout comme les dépenses au titre du loyer, des taxes foncières, et des versements mensuels pour emprunts hypothécaires. Toutefois, même dans le cas de ces articles, l'exactitude des données dépend de la capacité du répondant de se rappeler et de sa volonté de consulter des dossiers.

Dans l'Enquête sur les dépenses des ménages, on calcule la différence entre les rentrées et les sorties d'argent afin de vérifier la justesse des souvenirs des répondants. Cet important outil de contrôle de la qualité permet d'équilibrer les rentrées (revenus et autres sommes reçues par le ménage) et les sorties d'argent (dépenses totales plus la variable flux monétaires — actif, prêts et autres dettes) pour chaque questionnaire. Si la différence est supérieure à 30 % des rentrées ou des sorties d'argent, selon la somme la plus élevée des deux, on considère que l'enregistrement est inutilisable, et par conséquent il ne sera pas utilisé.

En 2007, afin de réduire le fardeau de réponse, de nouvelles questions de sélection ont été ajoutées à certaines catégories du questionnaire. Cette première série de questions de sélection était ambiguë et des changements s'avéraient nécessaires. Les modifications effectuées semblent avoir corrigé le problème en 2008; les mêmes questions ont donc été conservées en 2009.

Pour certaines catégories de dépenses³, les utilisateurs doivent savoir que les diminutions entre 2006 et 2007 et les augmentations entre 2007 et 2008 ou entre 2007 et 2009 sont vraisemblablement dues à la formulation de la question en 2007. Ainsi, ces changements doivent être ignorés. Cependant, la catégorie « cartes géographiques » semblent être l'exception, car pour cette catégorie la diminution s'est maintenue et traduit peut-être un réel changement dans les habitudes d'achat attribuable à la nouvelle technologie GPS.

Erreur de non-réponse

Les erreurs de non-réponse sont présentes dans toutes les enquêtes-échantillons, car ce ne sont pas tous les répondants éventuels qui acceptent de fournir l'information complète.

Une non-réponse totale survient si l'intervieweur se trouve devant l'impossibilité de contacter le répondant, si aucun membre du ménage n'est capable de fournir l'information recherchée, ou si le répondant refuse de participer à l'enquête. S'il s'agit d'une non-réponse totale, on ajuste le poids de base des ménages répondants afin de compenser pour les ménages qui n'ont pas répondu. Pour

3 Pour plus d'information, veuillez consulter le Guide des utilisateurs de l'Enquête sur les dépenses des ménages 2008, catalogue 62F0026MWF.

l'Enquête des dépenses des ménages de 2009, le taux global de réponse est 64,5 %. Consulter le tableau 1 pour le taux de réponse par province.

Dans la plupart des cas, on se trouve devant une non-réponse partielle à l'enquête lorsque le répondant ne comprend pas une question ou l'interprète mal, refuse d'y répondre, ou encore n'arrive pas à se souvenir des renseignements demandés. Ce type de non-réponse est compensé en imputant les valeurs manquantes.

L'importance de cette erreur est inconnue mais de façon générale cette erreur n'est pas négligeable lorsqu'un groupe de personnes possédant certaines caractéristiques communes refusent de participer à l'enquête et que ces caractéristiques exercent un effet déterminant sur les résultats de l'enquête.

Tableau 1
Taux de réponse, Canada, provinces et territoires, 2009

	Ménages admissibles ¹	Non- contactés	Ayant refusé de participer	Inutilisables ²	Utilisables	Taux de réponse ³
	Nombre					Pourcentage
Terre-Neuve et Labrador	1 347	113	207	19	1 008	74,8%
Île-du-Prince- Édouard	789	53	212	9	515	65,3%
Nouvelle-Écosse	1 515	167	369	51	928	61,3%
Nouveau- Brunswick	1 377	117	290	17	953	69,2%
Québec	2 040	167	505	63	1 305	64,0%
Ontario	2 582	371	579	93	1 539	59,6%
Manitoba	1 413	182	354	25	852	60,3%
Saskatchewan	1 345	114	249	26	956	71,1%
Alberta	1 572	196	336	89	951	60,5%
Colombie- Britannique	1 790	186	406	83	1 115	62,3%
Yukon	372	31	65	4	272	73,1%
Territoires du Nord-Ouest	376	82	53	11	230	61,2%
Nunavut	240	28	19	6	187	77,9%
Canada	16 758	1 807	3 644	496	10 811	64,5%
10 provinces	15 770	1 666	3 507	475	10 122	64,2%
Territoires	988	141	137	21	689	69,7%

1. Il n'y a plus aucune distinction entre les ménages constitués toute l'année et une partie de l'année.

2. Rejetées à l'étape de la vérification.

3. Utilisables/ménages admissibles x 100.

Erreur de traitement

Les erreurs de traitement peuvent survenir lors de toutes les étapes du traitement des données, par exemple durant la saisie, la vérification, la pondération et la totalisation. Consulter la section Traitement des données et contrôle de la qualité pour une description des moyens utilisés pour réduire l'erreur de traitement.

Effet des valeurs extrêmes

Dans tout échantillon, la présence ou l'absence de valeurs extrêmes au sein de l'échantillon peut avoir une influence sur les estimations. Ces valeurs extrêmes sont plus susceptibles d'être rencontrées au sein des populations affichant une répartition asymétrique positive. Or, de par sa nature même, l'Enquête sur les dépenses des ménages se prête à l'apparition de telles valeurs extrêmes. La présence ou l'absence de ces valeurs peut influencer fortement sur les estimations de totaux, de moyennes et d'erreurs types.

Comparabilité dans le temps

Menée depuis 1997, l'Enquête sur les dépenses des ménages reprend une bonne part du contenu de l'Enquête sur les dépenses des familles ainsi que du contenu de l'Enquête sur l'équipement ménager. De nombreuses variables provenant de ces enquêtes sont comparables à celles de l'Enquête des dépenses des ménages. Avant d'établir des comparaisons, on doit cependant tenir compte de certaines différences reliées à la méthodologie, à la qualité des données et aux définitions.

Pour plus d'information, veuillez vous référer à la *Note aux anciens utilisateurs de données provenant de l'Enquête sur les dépenses des familles*, n° 62F0026MIF2000002 au catalogue et la *Note aux anciens utilisateurs de données provenant de l'Enquête sur l'équipement ménager* n° 62F0026MIF2000003 au catalogue. Ces deux documents sont disponibles gratuitement, sur le site Internet de Statistique Canada (www.statcan.gc.ca).

Les données historiques des enquêtes sur les dépenses des ménages de 1997 à 2003 ont été pondérées de nouveau au moyen de la méthode de pondération décrite à la section Pondération. Les comparaisons historiques entre les données de ces enquêtes et les données des dernières années de l'Enquête sur les dépenses des ménages devraient, en général, se faire à partir de données repondérées, même si les différences entre les estimations de l'enquête établies au moyen de l'ancienne méthode et de la nouvelle méthode semblent être minimales au niveau sommaire. Certaines populations ou variables sont cependant susceptibles d'être plus fortement touchées que d'autres.

Débutant avec l'Enquête sur les dépenses des ménages de 1997, on a retranché des dépenses d'entretien, réparations et modifications payés par le locataire et des primes d'assurances des locataires le montant correspondant au pourcentage du loyer attribué à des fins commerciales. Ceci peut avoir un effet sur toutes comparaisons aux données antérieures.

Pour les années de référence de 2001 et 2005, on a ajouté des questions supplémentaires pour que les données de l'enquête puissent servir à la pondération de l'Indice des prix à la consommation. Ce changement peut nuire aux comparaisons historiques à l'égard de certaines variables. Par exemple, on a ajouté des questions à la rubrique « Produits de soins personnels » afin de recueillir des renseignements additionnels sur les produits capillaires, le maquillage, les parfums, les désodorisants et les produits pour l'hygiène buccale. Ainsi, il se peut que les répondants aient donné des renseignements plus précis et la hausse relative de l'estimation pour les dépenses en Produits de soins

personnels en 2001 et 2005 peut avoir été attribuée à la capacité accrue qu'ont les répondants de se souvenir de certains détails. L'effet des questions supplémentaires sur les estimations est difficile à quantifier. Cependant, en 2002 lorsque les questions additionnelles ont été enlevées, l'estimation pour les dépenses en soins personnels a diminué de nouveau. Pour l'EDM de 2006 et des années ultérieures, on a conservé les questions supplémentaires de 2005.

La section du questionnaire qui couvre les « Réparations et améliorations aux logements appartenant à l'occupant » a fait l'objet d'une importante révision. De 1997 à 2003, cette section avait trois grandes questions : « Ajouts, rénovations et autres modifications » ; « Remplacement ou nouvelle installation d'équipement, appareils et accessoires encastrés » ; « Réparations et entretien ». À partir de 2004, cette section de l'Enquête sur les dépenses des ménages comporte quatorze questions détaillées et deux colonnes, donnant ainsi aux répondants la possibilité de répartir les coûts pour chaque question entre « Réparations et entretien » et « Améliorations et modifications ».

À compter de l'EDM 2006, on a remplacé le questionnaire papier par un questionnaire électronique en mode IPAO (interviews sur place assistées par ordinateur). La description des membres du ménage, des caractéristiques du logement et de l'équipement ménager sont en date de l'interview au lieu du 31 décembre comme auparavant. On recueille des données sur les dépenses des ménages pour l'année de référence entière pour tous les membres à la date de l'interview, éliminant ainsi la distinction entre les ménages et leurs membres en occupation toute l'année et une partie de l'année.

En 2010, Statistique Canada a remplacé le terme « région urbaine » par « centre de population »⁴. Malgré le changement de terminologie, les concepts demeurent comparables. Il est ainsi possible de comparer les caractéristiques des ménages des « régions urbaines » des années précédentes avec celles des « centres de population » de 2009 diffusée en 2010.

Lignes directrices pour la totalisation, l'analyse et la diffusion

Cette section décrit les lignes directrices que doivent suivre les utilisateurs qui totalisent, analysent, publient ou diffusent des données tirées du fichier de microdonnées à grande diffusion.

Lignes directrices pour l'arrondissement

Afin que les estimations calculées à partir de ce fichier de microdonnées et destinées à la publication ou à toute autre forme de diffusion correspondent à celles qui seraient obtenues par Statistique Canada, nous conseillons vivement aux utilisateurs de se conformer aux lignes directrices suivantes pour l'arrondissement des estimations :

4. Des explications plus détaillées sont disponibles sur le site internet de Statistique Canada dans la section « Classifications géographiques » des « Définitions, sources de données et méthodes », sous l'intitulé « Des régions urbaines à centres de population » : <http://www.statcan.gc.ca/subjects-sujets/standard-norme/sgc-cqt/urban-urbain-fra.htm>

- a) Les estimations dans le corps d'un tableau statistique doivent être arrondies à la centaine près au moyen de la technique d'arrondissement classique. Selon cette technique, si le premier ou le seul chiffre à supprimer se situe entre 0 et 4, le dernier chiffre à conserver ne change pas. Si le premier ou le seul chiffre à supprimer se situe entre 5 et 9, on augmente de 1 la valeur du dernier chiffre à conserver. Par exemple, lorsqu'on veut arrondir à la centaine près de la façon classique, si les deux derniers chiffres se situent entre 00 et 49, il faut les remplacer par 00 et laisser le chiffre précédent (le chiffre des centaines) tel quel. Si les deux derniers chiffres se situent entre 50 et 99, on les remplace par 00 et on augmente de 1 le chiffre précédent.
- b) Les totaux partiels marginaux et les totaux marginaux des tableaux statistiques doivent être calculés à partir de leurs éléments correspondants non arrondis, puis arrondis à leur tour à la centaine près à l'aide de la technique d'arrondissement classique.
- c) Les moyennes, les proportions, les taux et les pourcentages doivent être calculés à partir d'éléments non arrondis (c'est-à-dire les numérateurs et/ou les dénominateurs), puis arrondis à une décimale au moyen de la technique d'arrondissement classique.
- d) Les sommes et les différences d'agrégats (ou de rapports) doivent être calculées à partir de leurs éléments correspondants non arrondis, puis arrondis à leur tour à la centaine près (ou à la décimale près) en employant la technique d'arrondissement classique.
- e) Si, en raison de limitations d'ordre technique ou de toute autre nature, on utilise une autre technique que l'arrondissement classique, de sorte que les estimations à publier ou à diffuser sous une forme quelconque diffèrent des estimations correspondantes qui seraient obtenues par Statistique Canada en utilisant ce fichier de microdonnées, nous conseillons vivement aux utilisateurs d'indiquer la raison de ces divergences dans le ou les documents à publier ou à diffuser.
- f) Des estimations non arrondies ne doivent en aucun cas être publiées ou diffusées de quelque façon que ce soit par les utilisateurs. Des estimations qui ne sont pas arrondies laissent faussement supposer qu'elles sont beaucoup plus précises qu'elles ne le sont en réalité.

Lignes directrices pour la pondération de l'échantillon en vue de la totalisation

Le plan d'échantillonnage utilisé pour l'EDM n'est pas autopondéré, c'est-à-dire que les ménages faisant partie de l'échantillon n'ont pas tous le même poids d'échantillonnage. Pour produire des estimations simples, y compris des tableaux statistiques standards, les utilisateurs doivent employer le poids d'échantillonnage approprié. Sinon, les estimations calculées à partir des fichiers de microdonnées ne pourront être considérées comme représentatives de la population observée et ne correspondront pas à celles qui seraient obtenues par Statistique Canada en utilisant ce fichier de microdonnées. Voir la section Pondération, repondération et révision historique de l'EDM en fonction du recensement.

Les utilisateurs doivent également noter qu'en raison de la manière dont ils traitent le champ du poids, il est possible que certains progiciels ne permettent pas d'obtenir des estimations qui correspondent exactement à celles de Statistique Canada en utilisant ce fichier de microdonnées.

Genres d'estimations : type nominal par opposition à quantitatives

Avant de discuter de la façon dont on peut totaliser et analyser les données de l'EDM, il est utile de décrire les deux principaux genres d'estimations qui peuvent être produites à partir du fichier de microdonnées de l'Enquête sur les dépenses des ménages.

Estimations de type nominal

Les estimations de type nominal sont des estimations du nombre ou du pourcentage de ménages dans la population visée par l'enquête qui possèdent certaines caractéristiques ou qui font partie d'une catégorie définie. Le nombre de ménages ayant déclaré une dépense particulière est un exemple d'estimation de ce genre.

Exemples de questions de type nominal :

Est-ce qu'un membre de votre ménage utilise Internet à la maison? oui non

Quand votre logement a-t-il été originellement construit?

- en 1945 ou avant
- 1946-1960
- 1961-1970
- 1971-1980
- 1981-1990
- 1991-2010

Votre logement est-il :

- Possédé sans hypothèque par votre ménage?
- Possédé avec une (des) hypothèque (s) par votre ménage?
- Loué par votre ménage?
- Occupé gratuitement par votre ménage?

Totalisation d'estimations de type nominal

On peut obtenir des estimations du nombre de personnes qui possèdent une caractéristique donnée à partir du fichier de microdonnées en additionnant les poids finaux de tous les enregistrements contenant la ou les caractéristiques voulues. On obtient les proportions et les rapports de la forme X/Y comme suit :

- a) en additionnant les poids finaux des enregistrements contenant la caractéristique voulue pour le numérateur X;
- b) en additionnant les poids finaux des enregistrements contenant la caractéristique voulue pour le dénominateur Y;
- c) en divisant l'estimation du numérateur par celle du dénominateur.

Estimations quantitatives

Les estimations quantitatives sont des estimations de totaux ou de moyennes, de médianes ou d'autres mesures de tendance centrale de quantités basées sur tous les membres de la population observée ou sur certains d'entre eux. Elles comprennent aussi explicitement des estimations de la forme X/Y où X est une estimation de la quantité totale pour la population observée et Y est une estimation du nombre de personnes dans la population observée qui contribuent à cette quantité totale.

Un exemple d'estimation quantitative est la dépense moyenne annuelle pour les soins personnels et de santé par ménage de la population cible. Le numérateur correspond à une estimation de la dépense totale annuelle pour les soins personnels et de santé, et le dénominateur à une estimation du nombre de ménages dans la population.

Exemple de question quantitative :

En 2009, combien votre ménage a-t-il dépensé pour les services téléphoniques?

Totalisation d'estimations quantitatives

On peut obtenir des estimations quantitatives à partir du fichier de microdonnées en multipliant la valeur de la variable voulue par le poids final de chaque enregistrement, puis en additionnant cette quantité pour tous les enregistrements qui nous intéressent. Par exemple, pour obtenir une estimation des dépenses totales en électricité pour les ménages qui étaient propriétaires à la date de l'interview, on multiplie la valeur déclarée à la question « En 2009, combien votre ménage a-t-il dépensé pour l'électricité? » par le poids final de l'enregistrement, puis on additionne ce résultat pour tous les enregistrements ayant une réponse positive à la question « Votre logement est-il : 'Possédé sans hypothèque par votre ménage' ou 'Possédé avec une (des) hypothèque(s) par votre ménage' ».

Afin d'obtenir une moyenne pondérée exprimée sous la forme X/Y , le numérateur X est calculé comme une estimation quantitative et le dénominateur Y comme une estimation de type nominal. Par exemple, pour estimer les dépenses moyennes des ménages en électricité par les propriétaires, il faut :

- a) estimer la dépense totale en électricité des ménages propriétaires de leur logement, selon la méthode décrite ci-haut;
- b) estimer le nombre de ménages propriétaires en additionnant les poids finaux de tous les enregistrements ayant une réponse positive à la question « Votre logement est-il : 'Possédé sans hypothèque par votre ménage' ou 'Possédé avec une (des) hypothèque(s) par votre ménage' »; puis,
- c) diviser l'estimation obtenue en a) par celle calculée en b).

Lignes directrices pour l'analyse statistique

L'Enquête sur les dépenses des ménages est basée sur un plan complexe qui comporte une stratification et de multiples degrés de sélection, ainsi que des probabilités inégales de sélection des répondants. L'utilisation de données provenant d'enquêtes aussi complexes pose des difficultés aux analystes, car le

plan d'enquête et les probabilités de sélection influent sur les méthodes d'estimation et de calcul de la variance à utiliser.

Bien que de nombreuses méthodes analytiques intégrées aux progiciels statistiques permettent d'utiliser des poids, le sens ou la définition du poids diffère de celui qui convient à une enquête par sondage. Par conséquent, même si les estimations faites au moyen de ces progiciels sont exactes dans bien des cas, **les variances calculées n'ont pratiquement aucune signification.**

Dans le cas de nombreuses techniques analytiques (p. ex., la régression linéaire, la régression logistique, l'analyse de variance), il existe un moyen de rendre l'application des progiciels courants plus significative. Si l'on transforme les poids des enregistrements contenus dans le fichier de manière à ce que le poids moyen soit de (1), les résultats produits par les progiciels courants seront plus justes et tiendront compte des probabilités inégales de sélection, bien qu'ils continueront à ne faire aucun cas de la stratification et de la répartition en grappes du plan d'échantillonnage. On peut effectuer cette transformation en employant dans l'analyse un poids égal au poids original divisé par la moyenne des poids originaux des unités d'échantillonnage (ménages) qui contribuent à l'estimateur en question. Cependant, parce que cette méthode ne tient toujours pas compte de la stratification et des grappes du plan d'échantillonnage, les estimations de la variance calculées de cette façon sont fort probablement des sous-estimations des vraies valeurs.

Lignes directrices pour la diffusion

Avant de diffuser et/ou de publier des estimations tirées du fichier de microdonnées, les utilisateurs doivent d'abord déterminer le niveau de fiabilité des estimations. La qualité des données est affectée par l'erreur d'échantillonnage et l'erreur non due à l'échantillonnage comme décrit précédemment. Cependant, le niveau de fiabilité des estimations est déterminé seulement sur la base des erreurs d'échantillonnage telles qu'évaluées par le coefficient de variation (CV) comme le montre le tableau ci-dessous. En plus de calculer les CVs, les utilisateurs devraient également lire la section de ce document concernant les caractéristiques de la qualité des données.

Quel que soit le CV obtenu pour une estimation tirée de ce fichier de microdonnées, les utilisateurs devraient déterminer le nombre de répondants échantillonnés qui contribuent au calcul de l'estimation. Si ce nombre est inférieur à 30, l'estimation pondérée ne devrait pas être diffusée quelle que soit la valeur du CV pour cette estimation. En ce qui concerne les estimations pondérées fondées sur des tailles d'échantillon de 30 ou plus, les utilisateurs devraient déterminer le CV de l'estimation arrondie en suivant les lignes directrices ci-dessous.

Tableau 2
Lignes directrices relatives à la variabilité de l'échantillonnage

Type d'estimation	CV (en %)	Lignes directrices
1. Acceptable	0,0 – 16,5	Les estimations peuvent être envisagées pour la diffusion générale sans restriction. N'exige aucune notation particulière.
2. Marginal	16,6 – 33,3	Les estimations peuvent être envisagées pour la diffusion générale sans restriction mais devraient être accompagnées d'un avertissement mettant les utilisateurs subséquents en garde contre la grande variabilité d'échantillonnage associée aux estimations. De telles estimations devraient être identifiées par la lettre M (ou d'une autre façon semblable).
3. Inacceptable	Supérieur à 33,3	Statistique Canada ne recommande pas de diffuser des estimations de qualité inacceptable. Cependant, si l'utilisateur choisit de le faire, les estimations devraient être marquées par la lettre I (ou d'une autre manière semblable) et l'avertissement suivant devrait accompagner les estimations : « On informe l'utilisateur que... (précisez les données)... ne satisfont pas aux normes de qualité de Statistique Canada pour ce programme statistique. Les conclusions fondées sur ces données ne seront pas fiables et seront fort probablement non valables.»

Calcul de CV approximatifs

Afin de fournir une façon d'évaluer la qualité des estimations, Statistique Canada a produit un tableau des coefficients de variation (tableau des CV) qui s'applique aux estimations de moyennes, de proportions et de totaux obtenus de ce fichier de microdonnées à grande diffusion pour les principales variables de l'EDM par province et à l'échelle du Canada (voir l'annexe D). Le CV d'une estimation est défini comme la racine carrée de la variance de l'estimation divisée par l'estimation elle-même; il est exprimé sous forme de pourcentage. Le numérateur du CV est une mesure de l'erreur d'échantillonnage de l'estimation, appelée l'erreur-type, et il est calculé à Statistique Canada au moyen de la méthode du « bootstrap ». Cette méthode exige, entre autres, certains renseignements au sujet des strates et des grappes qui ne peuvent pas être diffusés dans les fichiers de microdonnées à grande diffusion pour des raisons de confidentialité. Afin que les utilisateurs puissent estimer des CV pour des variables qui ne sont pas incluses dans les tableaux de CV, Statistique Canada a établi un ensemble de règles pour obtenir les CV approximatifs d'un grand nombre d'estimations. Il faut noter que ces règles fournissent des CV approximatifs, donc non officiels. Toutefois, la qualité de l'approximation est

assez satisfaisante, surtout dans le cas des estimations les plus fiables. Notons que la précision est moindre lorsque les domaines deviennent plus petits. Ainsi, l'utilisation de l'approximation du CV doit être utilisée avec prudence lorsque les domaines sont plus petits. Le document sur la qualité des données de l'enquête de 1997 renferme des résultats de l'évaluation de la performance de cette méthode d'approximation du CV.

Comment obtenir des CV approximatifs

Les règles suivantes devraient permettre à l'utilisateur de déterminer les coefficients de variation approximatifs pour les estimations de totaux, de moyennes ou de proportions, de ratios et de différences entre ces estimations pour les sous-populations (domaines) pour lesquels le CV « Bootstrap » n'est pas fourni dans les tableaux de CV.

Important : Si le nombre d'observations sur lequel se fonde une estimation est inférieur à 30, l'estimation pondérée ne devrait pas être diffusée quelle que soit la valeur du CV pour cette estimation.

Règle 1 : Approximation de CV pour des estimations de totaux (agrégats)

Toutes les étapes décrites ci-dessous doivent être suivies afin d'obtenir un CV approximatif (CVA) pour l'estimation d'un total (soit un nombre de ménages possédant certaines caractéristiques (estimation catégorique) ou un total de certaines dépenses pour tous les ménages (estimation quantitative)) pour une sous-population (domaine) d'intérêt :

- 1) Créer une variable binaire pour chaque ménage, p. ex., I, qui est égale à 1 si le ménage fait partie du domaine d'intérêt, c.-à-d. possède la caractéristique désirée et 0 sinon;
- 2) Pour l'estimation d'une variable quantitative, créer une variable Y, représentant le produit de la variable binaire I et de la variable d'intérêt. Pour l'estimation d'une variable catégorique, créer une variable Z, qui est égale à 1 si la variable catégorique a la valeur d'intérêt et à 0 sinon, et définir la variable Y comme le produit de I et Z;
- 3) Effectuer les étapes (4) à (9) pour chaque province séparément;
- 4) Calculer la somme pour tous les ménages du produit du poids final (section Pondération), et Y; (notons que cette somme représente l'estimation du total pour le domaine d'intérêt dans la province traitée)
- 5) Calculer la somme pour tous les ménages du produit du poids final et de la taille du ménage;
- 6) Diviser le résultat obtenu à l'étape (4) par le résultat obtenu à l'étape (5);
- 7) Pour chaque ménage, multiplier le résultat obtenu à l'étape (6) par la taille du ménage;
- 8) Pour chaque ménage, définir une variable, p. ex., E, en soustrayant le résultat obtenu à l'étape (7) de Y;
- 9) Calculer la somme pour tous les ménages du produit du poids final moins 1, du poids final et de E au carré; (notons que cette somme représente l'estimation de la variance du total estimé à l'étape 4)
- 10) Additionner le résultat obtenu à l'étape (9) pour chaque province;
- 11) Le CVA est défini comme étant 100 fois la racine carrée du résultat obtenu à l'étape (10), divisée par l'estimation. L'estimation est la somme pour toutes les provinces du résultat obtenu à l'étape (4).

Plus formellement, les étapes 1 à 10 ci-dessus peuvent être obtenues au moyen de la formule suivante :

$$\sum_{p=1}^{12} \sum_{k \in S_p} (w_k - 1) w_k \left(Y_k - m_k \frac{\sum_{k \in S_p} w_k Y_k}{\sum_{k \in S_p} w_k m_k} \right)^2$$

où l'indice p correspond aux provinces, S_p est l'échantillon de répondants pour la province p , l'indice k correspond aux ménages, w_k est le poids final pour le k^{e} ménage, m_k est la taille du k^{e} ménage et Y_k est la valeur de la variable Y , définie à l'étape (2) ci-dessus, pour le k^{e} ménage. On notera que l'indice p , indicateur de la province, prend des valeurs allant de 1 à 12. On retrouve 12 codes de province distincts sur le fichier de microdonnées : un pour chacune des dix provinces, un pour l'ensemble des territoires, et un code de province « 00 » assigné à un ensemble d'enregistrements pour des raisons de confidentialité (Voir la section Confidentialité des microdonnées à grande diffusion.)

Important : Lors de l'estimation de la variance pour un domaine donné, on ne doit pas se limiter à utiliser seulement les unités faisant partie du domaine. L'estimation de la variance doit toujours se faire en utilisant la totalité de l'échantillon. Les unités ne faisant pas partie du domaine d'intérêt n'interviennent pas lors de l'estimation ponctuelle du total, mais contribuent lors de l'estimation de la variance.

Règle 2 : Approximation de CV pour des estimations des moyennes ou des proportions

On entend par estimation de moyennes ou proportions, le rapport entre deux estimations de totaux. Pour une proportion, le numérateur est l'estimation d'un sous-ensemble du dénominateur, p. ex., la proportion des dépenses des ménages au Manitoba par rapport aux ménages canadiens. Le CV d'une estimation d'une moyenne ou d'une proportion tend à être légèrement inférieur au CV correspondant du numérateur. Le CV d'une estimation d'une moyenne ou d'une proportion peut ainsi être approximé par le CV du numérateur et la technique décrite à la règle (1) peut être utilisée.

Règle 3 : Approximation de CV pour des estimations de ratios

On entend par ratio, le rapport entre deux estimations pour lesquelles la règle (2) ne s'applique pas. Le CV approximatif pour tout autre type de ratio peut être calculé avec la formule suivante :

$$CVA_R = \sqrt{CVA_N^2 + CVA_D^2}$$

où CVA_R est le CV approximatif du ratio, CVA_N est le CV approximatif du numérateur du ratio et CVA_D est le CV approximatif du dénominateur du ratio. La formule aura tendance à surestimer le CV si les deux estimations qui forment le ratio sont en corrélation positive, et à le sous-estimer si les deux estimations sont en corrélation négative.

Règle 4 : Approximation de CV pour des estimations de différences

Le CV approximatif d'une différence entre n'importe quelles estimations ($EST_{DIFF} = EST_1 - EST_2$) est déterminé par la formule suivante :

$$CVA_{DIFF} = \frac{\sqrt{(EST_1 CVA_1)^2 + (EST_2 CVA_2)^2}}{|EST_{DIFF}|}$$

où CVA_1 est le CV approximatif associé à EST_1 et CVA_2 est le CV approximatif associé à EST_2 . La formule aura tendance à surestimer le CV si les deux estimations impliquées dans la différence sont en corrélation positive, et à sous-estimer si les deux estimations sont en corrélation négative.

Exemples

Dans un premier temps, les détails du calcul des CV approximatifs pour l'estimation de totaux seront présentés à l'aide d'un cas fictif. Ensuite, des cas réels d'estimation de totaux, de moyennes (ou de proportions), de ratios et de différences, basés sur les données du fichier de microdonnées, seront présentés pour permettre à l'utilisateur de vérifier ses résultats et d'ainsi s'assurer de la validité de sa démarche.

Partie 1 : Cas fictif : Détails des calculs d'une approximation de CV pour l'estimation d'un total

A) Variable quantitative

Supposons que l'on veuille estimer le total pour une variable de dépense « X » (variable quantitative), pour les ménages comprenant au moins une personne de moins de 18 ans. Pour illustrer la procédure, on utilisera un échantillon fictif (voir tableau 3) et on présentera les détails des calculs (voir tableau 4) pour chacune des onze étapes décrites ci-haut. La procédure étant appliquée indépendamment à l'intérieur de chaque province, on se limitera à décrire les calculs pour une seule d'entre elles.

Supposons l'échantillon suivant en Ontario :

Tableau 3
Exemple fictif

Données de départ					
Identificateur	Province	Poids	Taille du ménage	Nombre d'enfants 0-17 ans	Variable d'intérêt "X"
00001	Ontario	5	3	2	30
00002	Ontario	20	5	3	0
00003	Ontario	25	2	1	20
00004	Ontario	5	4	2	50
00005	Ontario	15	3	0	20
00006	Ontario	10	1	0	10
00007	Ontario	15	4	0	15

À l'étape 1, on définit le domaine d'intérêt en créant une variable binaire, qui est égale à 1 pour toutes les unités faisant partie du domaine, les ménages

comprenant au moins un enfant âgé de 0 à 17 ans dans le cas présent. On procède ensuite aux étapes 2 à 9 pour obtenir l'estimation de la variance, qui nous conduira au calcul du CV. On obtient ainsi les résultats suivants :

Tableau 4
Détails des calculs pour l'approximation de CV d'un total (étapes 1 à 9)

	Étape 1	Étape 2	Étape 4	Étape 5	Étape 6	Étape 7	Étape 8	Étape 9
Ident.	Variable binaire "I"	Variable quantitative "Y"	Y pondéré	Variable "K"		Étape 6 * taille	(Y - étape 7)	(Poids - 1) * Poids * (Étape 8) ²
		(X * I)	(poids * Y)	(poids * taille)				
00001	1	30 * 1 = 30	5 * 30 = 150	5 * 3 = 15		3 * 3 = 9	30 - 9 = 21	(4 * 5 * 21 * 21) = 8 820
00002	1	0 * 1 = 0	20 * 0 = 0	20 * 5 = 100		3 * 5 = 15	0 - 15 = -15	(19 * 20 * (-15) * (-15)) = 85 500
00003	1	20 * 1 = 20	25 * 20 = 500	25 * 2 = 50		3 * 2 = 6	20 - 6 = 14	(24 * 25 * 14 * 14) = 117 600
00004	1	50 * 1 = 50	5 * 50 = 250	5 * 4 = 20		3 * 4 = 12	50 - 12 = 38	(4 * 5 * 38 * 38) = 28 880
00005	0	20 * 0 = 0	15 * 0 = 0	15 * 3 = 45		3 * 3 = 9	0 - 9 = -9	(14 * 15 * (-9) * (-9)) = 17 010
00006	0	10 * 0 = 0	10 * 0 = 0	10 * 1 = 10		3 * 1 = 3	0 - 3 = -3	(9 * 10 * (-3) * (-3)) = 810
00007	0	15 * 0 = 0	15 * 0 = 0	15 * 4 = 60		3 * 4 = 12	0 - 12 = -12	(14 * 15 * (-12) * (-12)) = 30 240
			Total: 900	Total: 300	900 / 300 = 3			Total = 288 860

Si on est intéressé au CV pour l'Ontario, on procède au calcul suivant :

$$CV_{ONT} = 100 * \frac{\sqrt{Variance_{ONT}}}{Estimation_{ONT}} = 100 * \frac{\sqrt{Étape 9_{ONT}}}{Étape 4_{ONT}} = 100 * \frac{\sqrt{288860}}{900} = 59,7$$

Si on est intéressé au CV pour le Canada, on procède de façon similaire, en totalisant les résultats pour chaque province. Autrement dit,

$$CV_{CAN} = 100 * \frac{\sqrt{Variance_{CAN}}}{Estimation_{CAN}}$$

$$= 100 * \frac{\sqrt{Variance_{T-N-L} + \dots + Variance_{C-B} + Variance_{TERR} + Variance_{PROV 00}}}{Estimation_{T-N-L} + \dots + Estimation_{C-B} + Estimation_{TERR} + Estimation_{PROV 00}}$$

B) Variable qualitative (catégorique)

Il est à noter que dans le cas de l'estimation d'une variable catégorique, les étapes pour le calcul du CV approximatif seraient les mêmes que dans l'exemple présenté pour le cas d'une variable quantitative. Au lieu d'une valeur quantitative pour la variable d'intérêt X, on créerait une variable dichotomique, qui serait égale à 1 si le ménage possède la caractéristique que l'on désire estimer, et serait égale à 0 sinon.

Pour l'estimation de variables catégoriques, différentes approches sont possibles lors de la définition du domaine et de la variable d'intérêt, procurant toutes le même résultat.

Supposons que l'on veuille estimer le nombre de ménages composés de plus d'une personne et habitant une maison individuelle. On pourrait procéder de différentes façons :

- 1) La variable binaire « I » est égale à 1 pour tous les ménages, et la variable X est égale à 1 pour les ménages composés de plus d'une personne et habitant une maison individuelle.
- 2) La variable binaire « I » est égale à 1 pour tous les ménages composé de plus d'une personne, et la variable X est égale à 1 pour tous les ménages habitant une maison individuelle.
- 3) La variable binaire « I » est égale à 1 pour tous les ménages habitant une maison individuelle, et la variable X est égale à 1 pour tous les ménages composés de plus d'une personne.
- 4) La variable binaire « I » est égale à 1 pour tous les ménages composés de plus d'une personne habitant une maison individuelle, et X est égale à 1 pour tous les ménages.

Peu importe l'approche utilisée, la variable « Y » qui en résultera (étape 2) sera égale à 1 si le ménage possède toutes les caractéristiques (plus d'une personne et habitant une maison individuelle), et sera à égale à zéro sinon. Les résultats en terme d'estimation ponctuelle et d'estimation de la variance (CV) seront donc les mêmes.

Partie 2 : Cas réels basés sur le fichier de microdonnées

Exemple 1a : Approximation de CV pour l'estimation de totaux (variable quantitative)

Supposons qu'on ait estimé que les dépenses en ameublement et équipement ménager pour les ménages composés d'une seule personne au Manitoba totalisent 152 936 305 \$. On doit estimer le CV approximatif pour cette estimation. L'utilisateur doit donc suivre les étapes (1) à (11) de la règle 1.

- 1) Il faut d'abord créer une variable binaire I dont la valeur est 1 si le ménage n'est composé que d'une seule personne et réside au Manitoba, sinon I vaut 0.
- 2) Y est défini pour chaque ménage comme étant le produit de la variable binaire I et de la variable « total des dépenses en ameublement et équipement ménager ».

Notons que l'estimation des dépenses en ameublement et équipement ménager est obtenue en sommant le produit de la variable Y définie en 2) et du poids final du ménage.

Le tableau 5 donne les résultats de quelques étapes du calcul du CV approximatif.

Tableau 5

Calcul du CVA

Étape	Total des dépenses en ameublement et équipement ménager pour les ménages composés d'une personne au Manitoba
4	152 936 305
5	1 102 009
6	138,78
9	$6,1164 \times 10^{14}$
10	$6,1164 \times 10^{14}$
11	16,17

Exemple 1b : Approximation de CV pour l'estimation de totaux (variable qualitative)

Supposons maintenant que l'on veuille estimer le nombre total de ménages canadiens composés d'une personne, ainsi que le nombre total de ménages canadiens composés d'une personne habitant différents types de logement.

Dans ce cas, la variable I est définie comme ayant la valeur 1 si le ménage est composé d'une personne et 0 sinon. Il faut créer 5 variables Z, Z1 étant une variable valant 1 pour tous les ménages, Z2 vaut 1 si le type de logement occupé est « maison individuelle » et 0 sinon, Z3 vaut 1 si le type de logement occupé est « maison jumelée » et 0 sinon, Z4 vaut 1 si le type de logement occupé est « maison en rangée » et 0 sinon et finalement Z5 vaut 1 si le type de logement occupé est « autre » et 0 sinon. Y1 est définie comme étant le produit de I et de Z1, Y2 comme le produit de I et Z2 etc.

Les estimations obtenues sont de 3 838 683 pour l'ensemble des ménages composés d'une personne, de 1 236 001 pour les maisons individuelles⁵, 125 141 pour les maisons jumelées⁶, 207 383 pour les maisons en rangée⁷ et 2 270 158 pour les autres.⁸ On veut calculer les CV approximatifs de ces estimations.

Le tableau 6 donne les résultats de quelques étapes du calcul du CV approximatif. Les résultats présentés pour les étapes 4 à 9 sont les résultats pour le Manitoba (présentés à titre d'exemple, pour une province, ils serviront à titre de comparaison dans l'exemple suivant), tandis que ceux présentés pour les étapes 10 et 11 sont les résultats au niveau du Canada.

5. Maison individuelle = individuelle non attenante

6. Maison jumelée = double

7. Maison en rangée = en rangée

8. Autre = duplex, appartement, hôtel, maison mobile, autre

Tableau 6
Calcul du CVA

Étape	Nombre de ménages composés d'une personne	Nombre de ménages composés d'une personne habitant dans une maison individuelle	Nombre de ménages composés d'une personne habitant dans une maison jumelée	Nombre de ménages composés d'une personne habitant dans une maison en rangée	Nombre de ménages composés d'une personne habitant dans d'autres logements
4	144 953	61 986	1 114	6 285	75 568
5	1 102 009	1 102 009	1 102 009	1 102 009	1 102 009
6	0,13	0,06	0,001	0,01	0,07
9	121 454 322	50 908 123	1 239 842	4 666 565	57 514 889
10	12 611 713 216	3 287 891 943	400 769 596	553 624 073	7 321 383 909
11	2,93	4,64	16,00	11,35	3,77

Exemple 1c : Approximation de CV pour l'estimation de totaux servant au calcul d'une dépense moyenne

Supposons que l'on veuille estimer les dépenses moyennes en ameublement et équipement ménager pour les ménages composés d'une personne au Manitoba. Pour ce faire, on devra estimer le nombre de ménages composés d'une personne au Manitoba, ainsi que le total de leurs dépenses en ameublement et équipement ménager.

Tableau 7
Calcul du CVA

Étape	Nombre de ménages composés d'une personne au Manitoba	Total des dépenses en ameublement et équipement ménager pour les ménages composés d'une personne au Manitoba
4	144 953	152 936 305
5	1 102 009	1 102 009
6	0,13	138,78
9	121 454 322	$6,1164 \times 10^{14}$
10	121 454 322	$6,1164 \times 10^{14}$
11	7,60	16,17

L'estimation de la moyenne serait égale à $152\,936\,305\ \$ / 144\,953 = 1\,055,08\ \$$. Comment déterminer le CV de cette estimation?

La règle (2) devrait être appliquée dans ce cas. Ainsi, le CV de cette moyenne peut donc être approximé par le CV du numérateur, soit le total des dépenses en ameublement et équipement ménager pour les ménages composés d'une personne au Manitoba. Celui-ci est 16,17%.

Exemple 2 : Approximation de CV pour l'estimation de ratios

Supposons que l'on veuille estimer le ratio entre les dépenses totales en ameublement et équipement ménager pour les ménages composés de conjoints sans enfant dans les centres de population et en milieu rural au Manitoba.

Tableau 8
Calcul du CVA

Étape	Total des dépenses en ameublement et équipement ménager pour les ménages de conjoints sans enfant et sans personne additionnelle au Manitoba (centres de population)	Total des dépenses en ameublement et équipement ménager pour les ménages de conjoints sans enfant et sans personne additionnelle au Manitoba (milieu rural)
4	192 893 173	58 646 563
5	1 102 009	1 102 009
6	175,04	53,22
9	$6,3894 \times 10^{14}$	$1,7673 \times 10^{14}$
10	$6,3894 \times 10^{14}$	$1,7673 \times 10^{14}$
11	13,10	22,67

L'estimation du ratio serait égale à $192\,893\,173\ \$ / 58\,646\,563\ \$ = 3,30$ (les ménages de conjoints sans enfant dans les centres de population dépensent environ 3,3 fois plus en ameublement que ceux en milieu rural). Comment déterminer le CV de cette estimation?

On a déjà calculé les CV de chacune des deux estimations impliquées dans l'estimation du ratio. On doit appliquer la règle (3) afin d'obtenir le CV voulu :

$$CVA_R = \sqrt{CVA_N^2 + CVA_D^2} = \sqrt{13,10^2 + 22,67^2} = 26,18$$

Il faut noter qu'un tel CV devrait porter la mention « Marginal » (voir la section Lignes directrices pour la diffusion) puisqu'il est assez élevé, se situant entre 16,6% et 33,3%.

Exemple 3 : Approximation de CV pour l'estimation de différences

Supposons qu'un utilisateur veuille estimer la différence entre le total des dépenses en ameublement et équipement ménager en Alberta et au Manitoba, ainsi que le CV de cette différence.

On estime le total des dépenses en ameublement et équipement ménager, ainsi que leur CV respectif, pour le Manitoba (total = 885 500 504 \$; CV = 5,61) et pour l'Alberta (total = 2 784 615 270 \$; CV = 5,76).

L'estimation de la différence est donc de $2\,784\,615\,270\ \$ - 885\,500\,504\ \$ = 1\,899\,114\,766\ \$$. La règle (4) peut être appliquée afin d'obtenir le CV voulu :

$$CVA_{DIFF} = \frac{\sqrt{(EST_1 CVA_1)^2 + (EST_2 CVA_2)^2}}{|EST_{DIFF}|}$$

$$= \frac{\sqrt{(2\,784\,615\,270 * 5,76)^2 + (885\,500\,504 * 5,61)^2}}{|1\,899\,114\,766|} = 8,84$$

Comment obtenir les limites de confiance

Bien que les coefficients de variation soient communément utilisés, une mesure intuitivement plus utile de l'erreur d'échantillonnage est l'intervalle de confiance d'une estimation. Un intervalle de confiance constitue une indication du niveau de confiance selon lequel la vraie valeur de la population se situe à l'intérieur d'un intervalle déterminé de valeurs. Par exemple, un intervalle de confiance de 95% peut être décrit de la façon suivante.

Si l'échantillonnage d'une population est répété un grand nombre de fois, et que chaque échantillon mène à un nouvel intervalle de confiance pour une estimation, alors pour 95% des échantillons l'intervalle couvre la vraie valeur de la population.

Au moyen du CV d'une estimation, on peut obtenir ces intervalles de confiance en supposant que dans le cas d'échantillonnage répété, les différentes estimations sont normalement réparties autour de la vraie valeur. En utilisant cette hypothèse, les probabilités sont d'environ 68 sur 100 que la différence entre une estimation d'échantillon et la vraie valeur de la population soit inférieure à un écart-type, d'environ 95 sur 100 que la différence soit inférieure à deux écarts-types, et d'environ 99 sur 100 que la différence soit inférieure à trois écarts-types. Ces différents degrés de confiance sont désignés par niveaux de confiance.

Les intervalles de confiance d'une estimation, EST, sont en général exprimés comme deux chiffres, un inférieur à l'estimation et l'autre supérieur à l'estimation, comme (EST - k, EST + k) où k est déterminé selon le niveau de confiance voulu et l'erreur d'échantillonnage de l'estimation.

Les intervalles de confiance pour une estimation peuvent être calculés d'abord en déterminant le CVA de l'estimation puis en utilisant la formule suivante afin de passer à un intervalle de confiance (IC) :

$$(EST - z \times EST \times CVA / 100, EST + z \times EST \times CVA / 100)$$

où

- z = 1 si l'on veut obtenir un intervalle de confiance de 68%,
- z = 1,6 si l'on veut obtenir un intervalle de confiance de 90%,
- z = 2 si l'on veut obtenir un intervalle de confiance de 95%,
- z = 3 si l'on veut obtenir un intervalle de confiance de 99%.

Nota : Les lignes directrices relatives à la diffusion qui s'appliquent à l'estimation s'appliquent aussi à l'intervalle de confiance. Par exemple, si l'estimation ne peut pas être diffusée, l'intervalle de confiance ne peut pas être diffusé non plus.

Exemple 4

Un intervalle de confiance de 95% de la moyenne estimée des dépenses en ameublement et équipement ménager pour les ménages composés d'une personne au Manitoba serait calculé de la manière suivante :

$$EST = 1\,055,08 \$$$

$$z = 2$$

$$CVA = 16,17$$

$$IC = (1\,055,08 - 2 \times 1\,055,08 \times 16,17/100; 1\,055,08 + 2 \times 1\,055,08 \times 16,17/100) \\ = (713,87 \$, 1\,396,29 \$)$$

Comment effectuer un test Z

Les coefficients de variation peuvent aussi être utilisés afin d'effectuer une vérification d'hypothèse, une procédure servant à distinguer entre les paramètres de la population au moyen d'estimations de l'échantillon. Les estimations de l'échantillon peuvent être des totaux, des moyennes, des ratios, etc. Les tests peuvent être effectués à différents niveaux de confiance où un niveau de confiance est la probabilité de conclure que les caractéristiques sont différentes quand, en fait, elles sont identiques.

Supposons que EST_1 et EST_2 sont des estimations d'échantillon pour deux caractéristiques d'intérêt. Supposons que le CV approximatif de la différence $EST_1 - EST_2$ soit CVA_{DIFF} .

Si $z = 100 / CVA_{DIFF}$ est plus petit que 2, aucune conclusion au sujet de la différence entre les caractéristiques n'est justifiée au niveau de confiance de 5%. Toutefois, si ce ratio est supérieur à 2, la différence observée est significative au niveau de 5%.

Exemple 5

Supposons que l'on veuille tester, au niveau de confiance de 5%, l'hypothèse selon laquelle il n'y a pas de différence entre le total des dépenses en ameublement et équipement ménager en Alberta et le même total au Manitoba. De l'exemple 3, on a trouvé que le CV approximatif de la différence entre ces deux estimations est de 8,84, et donc $z = 11,31$. Comme cette valeur est supérieure à 2, on doit conclure qu'il y a une différence significative entre les deux estimations au niveau de confiance de 0,05.

Confidentialité des microdonnées à grande diffusion

Le fichier de microdonnées « à grande diffusion » diffère à bien des égards du fichier « principal » de l'enquête conservé par Statistique Canada. Ces écarts sont dus aux mesures prises pour protéger l'anonymat des répondants à l'enquête.

La confidentialité du fichier à grande diffusion est assurée principalement par la réduction de l'information, c'est-à-dire la suppression de variables ou de certains détails qu'elles comprennent, ou encore le regroupement de ces détails.

Pour protéger la confidentialité

- Toutes les données d'identification explicites, comme les numéros d'identification, ont été supprimées du fichier (les noms et adresses ne sont pas des données saisies).
- Le *code de la province* de 329 enregistrements a été fixé à 0 en raison de caractéristiques particulières telles des valeurs excessivement élevées ou faibles. Ces enregistrements ont été pondérés de nouveau.
- Le code de centre de population et la taille de la région de résidence ont été fixés à 0, ou d'autres variables ont été modifiées, pour 322 autres enregistrements en raison de caractéristiques particulières.
- Quelques enregistrements ont également été pondérés de nouveau pour des fins de confidentialité.
- Il y a eu *plafonnement* et *regroupement* des ensembles de valeurs pour des variables non liées aux dépenses.
- Les valeurs du revenu du ménage, de la personne de référence et du (de la) conjoint(e) de la personne de référence ont été *arrondies* de la façon suivante :
 - Pour des valeurs de revenu entre 1 \$ et 9 999 \$: arrondissement aux 100 \$ les plus près
 - Pour des valeurs de revenu entre 10 000 \$ et 99 999 \$: arrondissement aux 1 000 \$ les plus près
 - Pour des valeurs de revenu entre 100 000 \$ et 999 999 \$: arrondissement aux 10 000 \$ les plus près
 - Pour des valeurs de revenu entre 1 000 000 \$ et 9 999 999 \$: arrondissement aux 100 000 \$ les plus près
 - Pour des valeurs de revenu entre 10 000 000 \$ et 99 999 999 \$: arrondissement aux 1 000 000 \$ les plus près (on ne retrouve pas de telles valeurs dans le fichier de 2009).
- Les variables « Prix d'achat du logement » et « Prix de vente du logement » ont également été arrondies et plafonnées à 999 000 \$.

Annexes—Voir le fichier Excel d'accompagnement

Annexe A Comptes de fréquences

Annexe B Valeurs moyennes, totales, minimales et maximales

Partie 1 de 2 - Fichier de microdonnées à grande diffusion

Partie 2 de 2 - Fichier d'enquête non supprimé

Annexe C Inclusion des articles de dépenses dans les fichiers de microdonnées antérieurs

Annexe D Coefficients de variation pour les données publiées provenant de l'EDM de 2009

Partie 1 de 3 - Dépenses moyennes par ménage, Canada et les provinces

Partie 2 de 3 - Dépenses médianes par ménage déclarant, Canada et les provinces

Partie 3 de 3 - Caractéristiques du logement et l'équipement ménager, Canada et les provinces