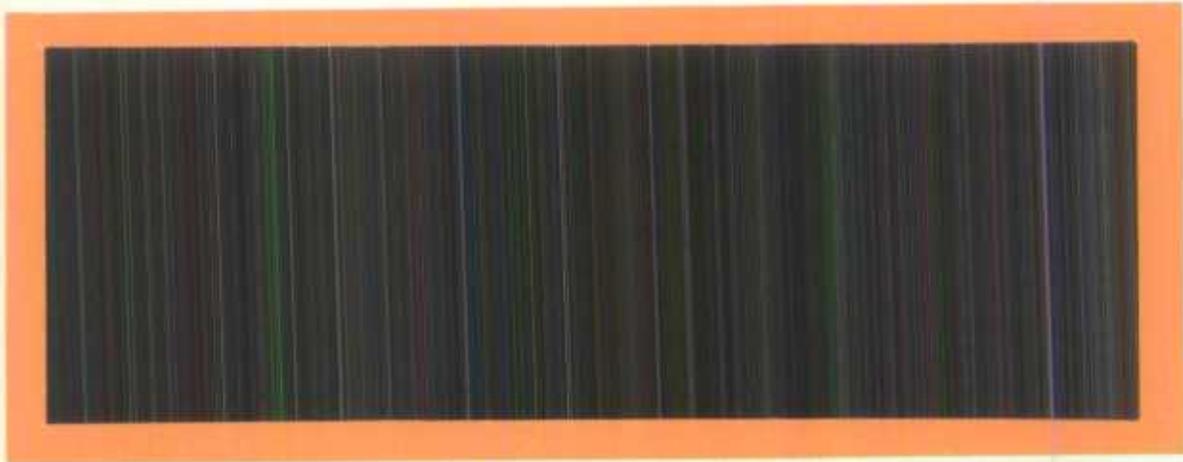


11-616F 20. 85-67
C.2



Statistics
Canada Statistique
Canada

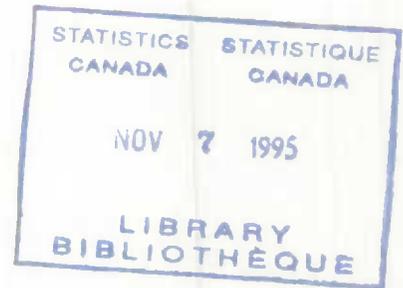


Methodology Branch

Census & Household Survey
Methods Division

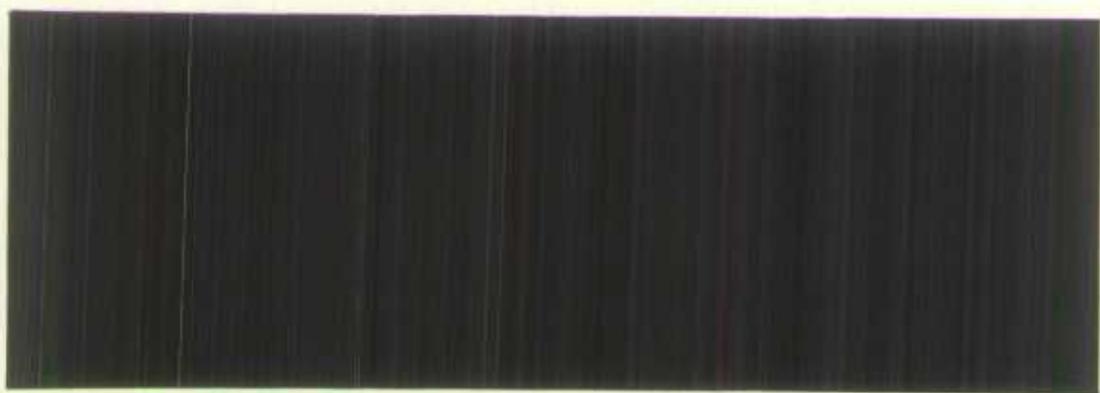
Direction de la méthodologie

Division des méthodes de recensement
et d'enquêtes ménages



11-616F
20. 85-67
C.2

Canada



#J0314

EVALUATION DE L'APPLICATION D'ESTIMATEURS COMPOSITES À
L'ENQUETE SUR LA POPULATION ACTIVE DU CANADA¹



S. Kumar et H. Lee²

Division des méthodes de recensement et d'enquêtes-ménages

Statistique Canada

Numéro: DMREM 85-067F

2007
10

2007-05-03
10:05 AM
100-05-1000

ÉVALUATION DE L'APPLICATION D'ESTIMATEURS COMPOSITES À L'ENQUÊTE SUR LA POPULATION ACTIVE DU CANADA¹

S. Kumar et H. Lee²

Cette étude porte sur l'applicabilité des techniques d'estimation composite à l'enquête sur la population active du Canada. On examine l'efficacité d'une classe d'estimateurs composites AK proposés en premier par Gurney et Daly dans l'estimation de plusieurs caractéristiques de la population active. L'estimateur composite ordinaire présente un biais considérable, mais l'estimateur composite AK permet de réduire ce biais. On compare des estimateurs composites à variance minimum et à erreur quadratique moyenne minimum.

1. INTRODUCTION

L'enquête sur la population active du Canada (EPA) est menée tous les mois par Statistique Canada pour produire des estimations de diverses caractéristiques de la population active. Le plan de sondage de l'EPA comprend un plan de renouvellement qui permet de remplacer un sixième des ménages de l'échantillon à chaque mois (voir [7]). L'échantillon est ainsi composé de six panels ou groupes de renouvellement et chaque panel est dans l'échantillon pendant six mois consécutifs.

Comme Bailar [1] l'a déjà souligné, un des principaux inconvénients de l'estimateur composite actuellement utilisé pour la U.S. Current Population Survey (CPS) en comparaison de l'estimateur simple par quotient est son biais. Ce biais découle des différences entre les groupes de renouvellement; c'est-à-dire que les estimations calculées à partir de données relatives à différents

¹ Exposé présenté aux "Joint Statistical Meetings of the American Statistical Association, the Biometric Society, the Institute of Mathematical Statistics et the Statistical Society of Canada", Toronto, août 1983.

² S. Kumar et H. Lee, Division des méthodes de recensement et d'enquêtes-ménages, Statistique Canada.

groupes de renouvellement au cours d'une même période peuvent ne pas avoir la même espérance mathématique. Ce phénomène, qu'on appelle souvent le biais de renouvellement, a déjà été étudié pour l'EPA (voir [2] et [6]). Récemment, Huang et Ernst [4] ont décrit les résultats de l'application à la CPS de l'estimateur composite AK, qui a été proposé par Gurney et Daly [3] (A et K sont des constantes dans l'équation qui définit cet estimateur composite). Leurs résultats indiquent que l'estimateur AK est supérieur aux estimateurs composites actuellement utilisés dans la CPS du point de vue de la variance et du biais.

La présente étude a pour objet d'évaluer l'applicabilité des techniques d'estimation composite à l'EPA. Les résultats de l'utilisation de différents estimateurs composites pour le calcul de totaux et de changements sont examinés dans le cas de cinq caractéristiques, soit la taille de la population active, le nombre de personnes occupées, le nombre de personnes occupées dans l'agriculture, le nombre de personnes occupées dans les secteurs non agricoles, et le nombre de chômeurs. Les estimations composites de ces caractéristiques sont comparées avec l'estimation simple par quotient qui est utilisée à l'heure actuelle dans l'EPA. Cette étude est basée sur les données de 1980 à 1981 concernant la province de l'Ontario.

2. DÉFINITIONS ET NOTATION

Nous voulons estimer Y_m le nombre de personnes dans la population qui ont une certaine caractéristique au mois m . Définissons les variables suivantes :

$y_{m,i}$ = un estimateur simple par quotient de Y_m calculé pour le i^e panel ($i = 1, 2, \dots, 6$). Ici le i^e panel correspond au sous-échantillon (groupe de renouvellement) qui fait partie de l'échantillon pour la i^e fois. On appellera ici cette variable l'estimateur relatif au i^e panel.

$d_{m,m-1}$ = l'estimateur du changement ($Y_m - Y_{m-1}$) survenu du mois ($m - 1$) au mois m dans l'ensemble des cinq panels qui faisaient partie de

$$\begin{aligned} & \text{l'échantillon à la fois au mois } m \text{ et au mois } (m - 1) \\ & = \sum_{j=2}^6 (y_{m,j} - y_{m-1,j-1})/5 \end{aligned} \quad (2.1)$$

y'_m = l'estimateur composite AK de Y_m défini par l'équation

$$\begin{aligned} y'_m &= (1 - K + A)y_{m,1}/6 + (1 - K - \frac{A}{5}) \sum_{j=2}^6 y_{m,j}/6 \\ &+ K(y'_{m-1} + d_{m,m-1}) \end{aligned} \quad (2.2)$$

où K et A sont des constantes et $0 \leq K < 1$.

L'équation (2.1) définit une classe d'estimateurs qui portent le nom d'estimateurs composites AK. Les estimateurs qu'on obtient lorsque $A = 0$ dans la formule (2.2) constituent des estimateurs composites K. L'estimateur simple par quotient, qu'on représente ici par \bar{y}_m , la moyenne des estimateurs relatifs aux six panels, est exprimé par la forme de l'équation (2.2) dans laquelle $A = 0$ et $K = 0$. Nous comparons plus bas les résultats de l'utilisation de l'estimateur composite AK optimal (selon un critère de variance minimum ou d'erreur quadratique moyenne minimum), de l'estimateur composite K et de l'estimateur simple par quotient.

Nous supposons que le biais de renouvellement $E(y_{m,i}) - Y_m$ est indépendant de m et qu'il varie en fonction de i . Ce biais est représenté par le symbole α_i .

Algébriquement,

$$\alpha_i = E(y_{m,i}) - Y_m. \quad (2.3)$$

Le calcul du biais de l'estimateur composite est présenté à l'annexe I.

3. HYPOTHÈSES

Le plan de renouvellement de l'échantillon de l'EPA peut être représenté schématiquement à l'aide du tableau 1, où au mois m le panel $i = (1, 2, \dots, 6)$, (qui est à son i^{e} mois d'inclusion dans l'échantillon) est le même que le panel $(i - j)$ au mois $(m - j)$, où $1 \leq (i - j) \leq 5$. Le panel i au mois m a été précédé immédiatement par le panel $(6 + i - j)$ au mois $(m - j)$, où $1 \leq (6 + i - j) \leq 6$. De même, le panel i au mois m a été précédé en deuxième lieu par le panel $(12 + i - j)$ au mois $m - j$, où $1 \leq (12 + i - j) \leq 6$. En général, le r^{e} prédécesseur du panel i au mois m correspond au panel $(i - j + 6r)$ au mois $m - j$. Notons que le 0^{e} prédécesseur du panel i représente le même panel de mois précédents.

L'expression de la variance de y'_m , c'est-à-dire $V(y'_m)$, est une fonction des variances et des covariances des divers estimateurs relatifs aux panels (voir l'annexe II). On suppose que la structure de ces variances et covariances a les propriétés suivantes, qui concordent avec le plan de renouvellement de l'EPA qui est résumé au tableau 1.

$$(i) \quad V(y_{m,i}) = \sigma^2 \text{ pour tout } m, i = 1, 2, \dots, 6$$

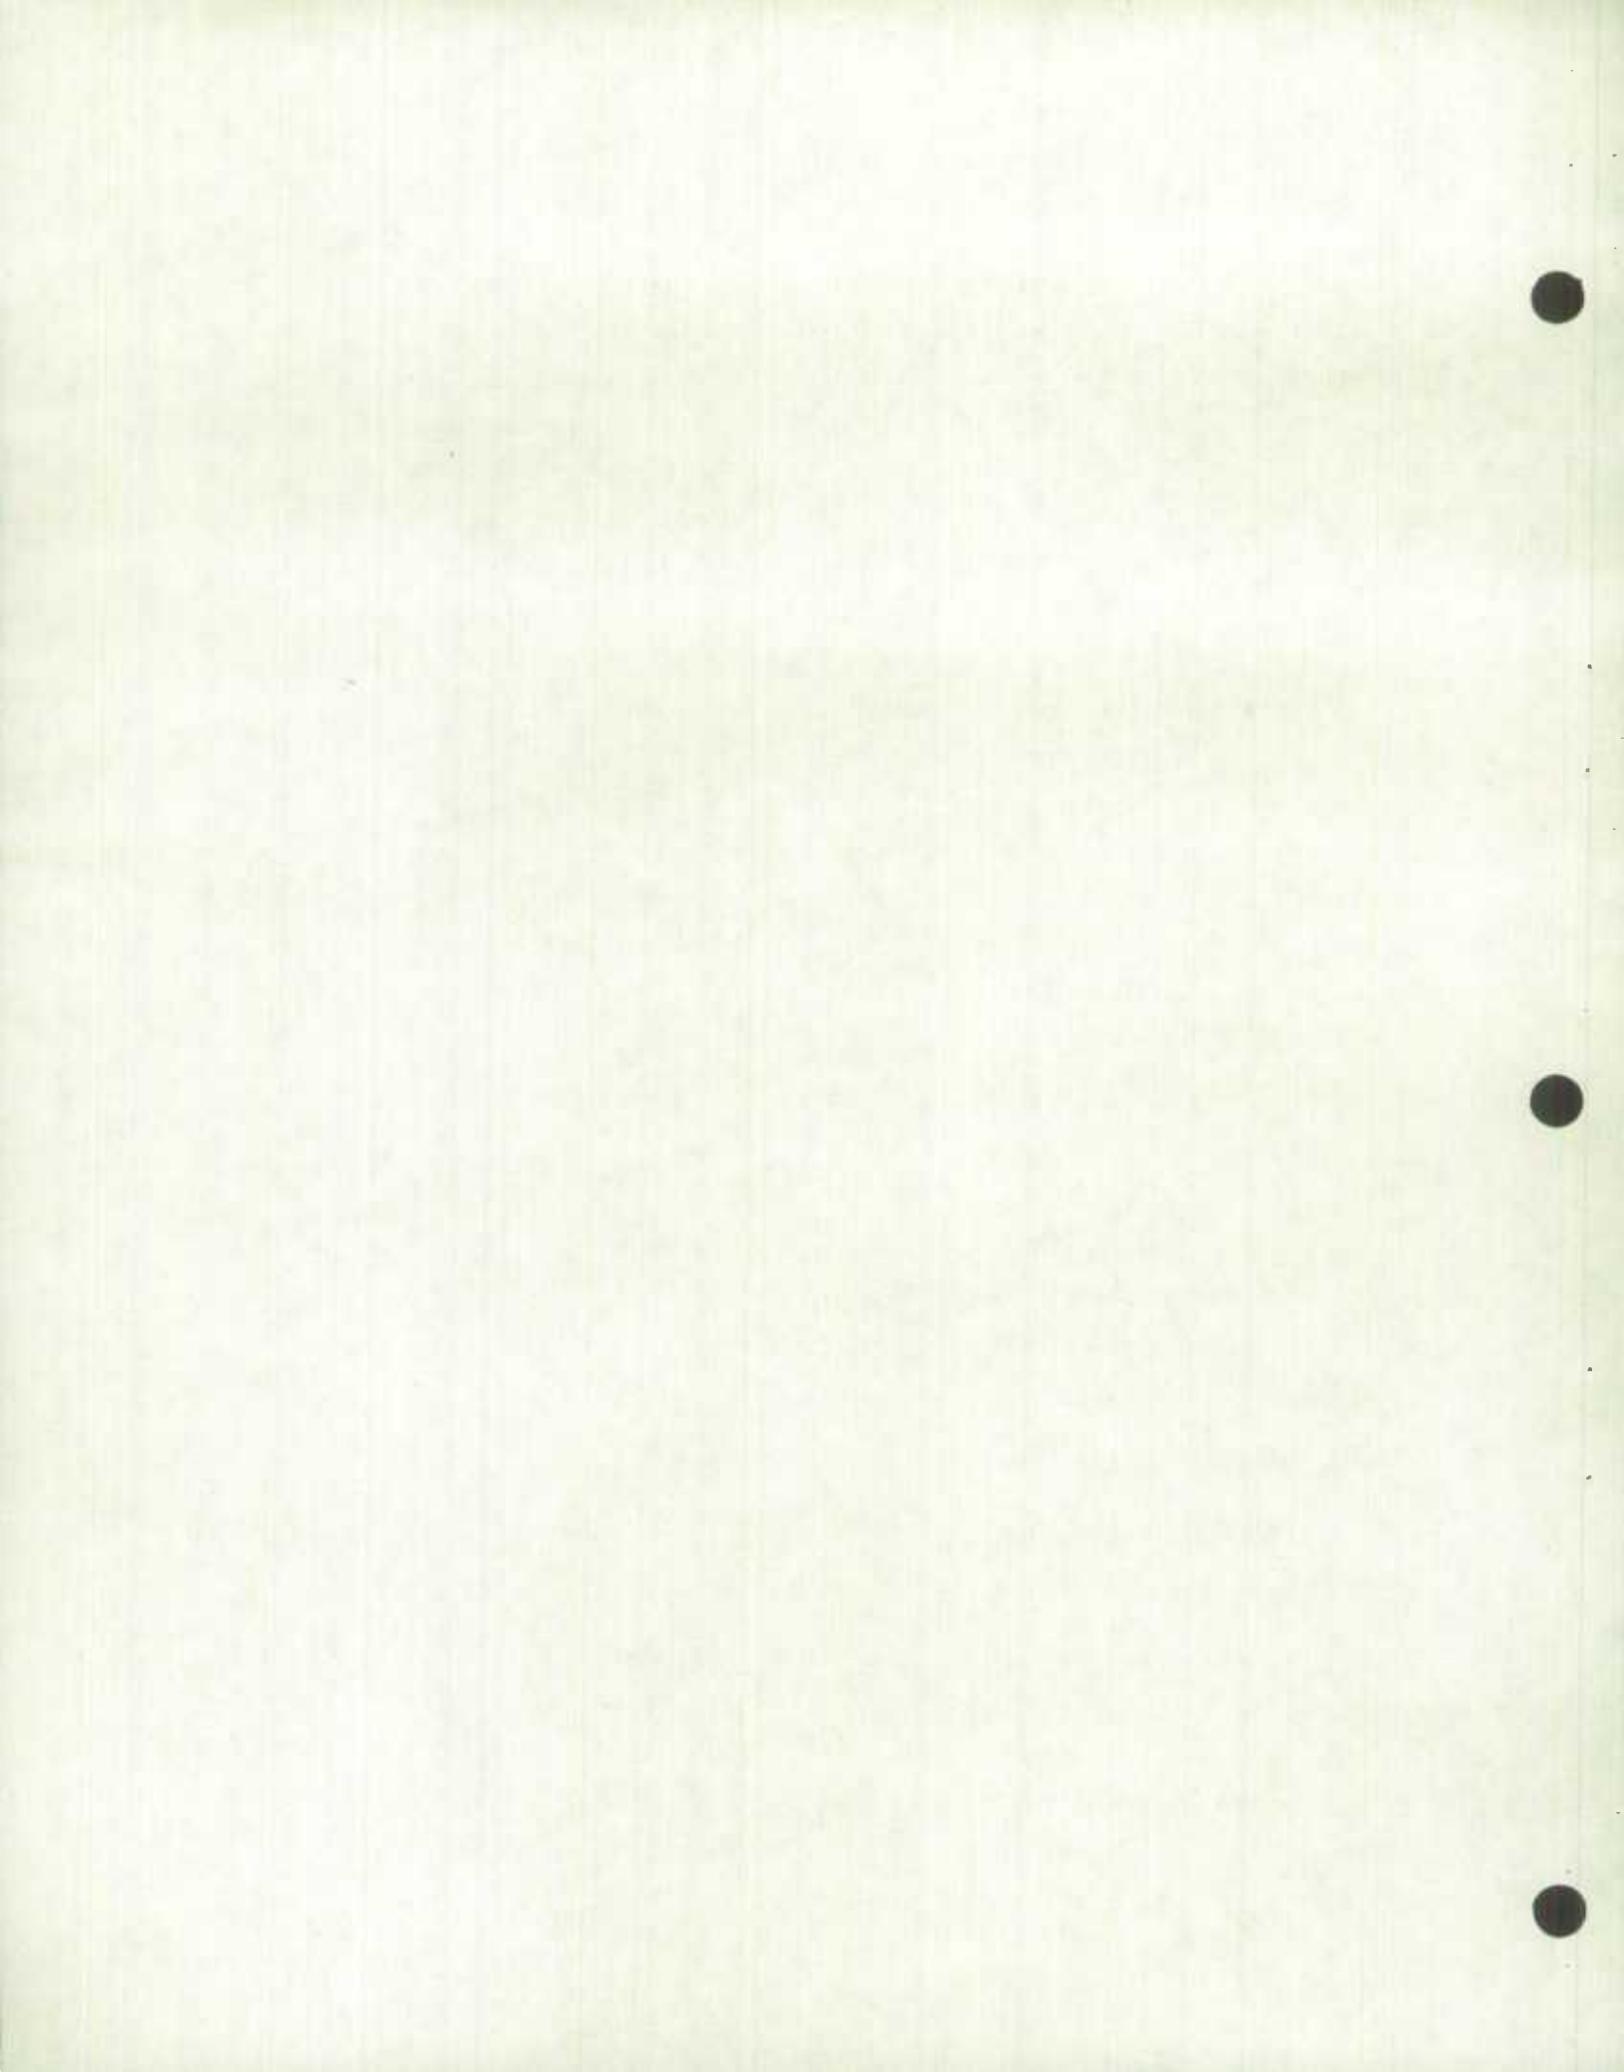
$$(ii) \quad \text{Cov}(y_{m,i}, y_{m-j, i-j+6r}) = \gamma_j^{(r)} \sigma^2, \text{ où } i = 1, 2, \dots, 6, j > 0 \quad \text{et} \\ r \geq 0, \text{ de sorte que } 6 \geq i - j + 6r \geq 1. \text{ Ici } r \text{ représente le nombre} \\ \text{de prédécesseurs du panel courant.}$$

Pour $r = 0$, c'est-à-dire que $6 > i - j \geq 1$, soit $\gamma_j^{(r)} \sigma^2 = \rho_j$ (cas des panels inclus dans l'échantillon au mois m et au mois $m-j$).

Pour $r = 1$, c'est-à-dire que $6 \geq i - j + 6 \geq 1$, soit $\gamma_j^{(r)} = \gamma_j$ (cas du panel courant et de son prédécesseur immédiat j mois plus tôt).

Pour $r \geq 2$, c'est-à-dire que $6 \geq i - j + 6r \geq 1$, soit $\gamma_j^{(r)} = 0$ (cas du panel courant et de son r^{e} prédécesseur j mois plus tôt).

(iii) Le développement mathématique de la variance de l'estimateur compo-



site y_m doit tenir compte des coefficients de corrélation ρ_j et γ_j qui sont tous les deux supposés stationnaires: autrement dit, ces coefficients sont des fonctions de j et non de m . Il est raisonnable de supposer que les ρ_j et les γ_j sont tous positifs puisque les ρ_j correspondent à des caractéristiques de ménages qui sont dans l'ensemble les mêmes, tandis que les γ_j reflètent les caractéristiques de ménages inclus dans l'échantillon au mois courant et celles de leurs proches voisins (dans bien des cas leurs voisins de quartier) j mois plus tôt (sans mentionner l'effet du renouvellement des grappes).

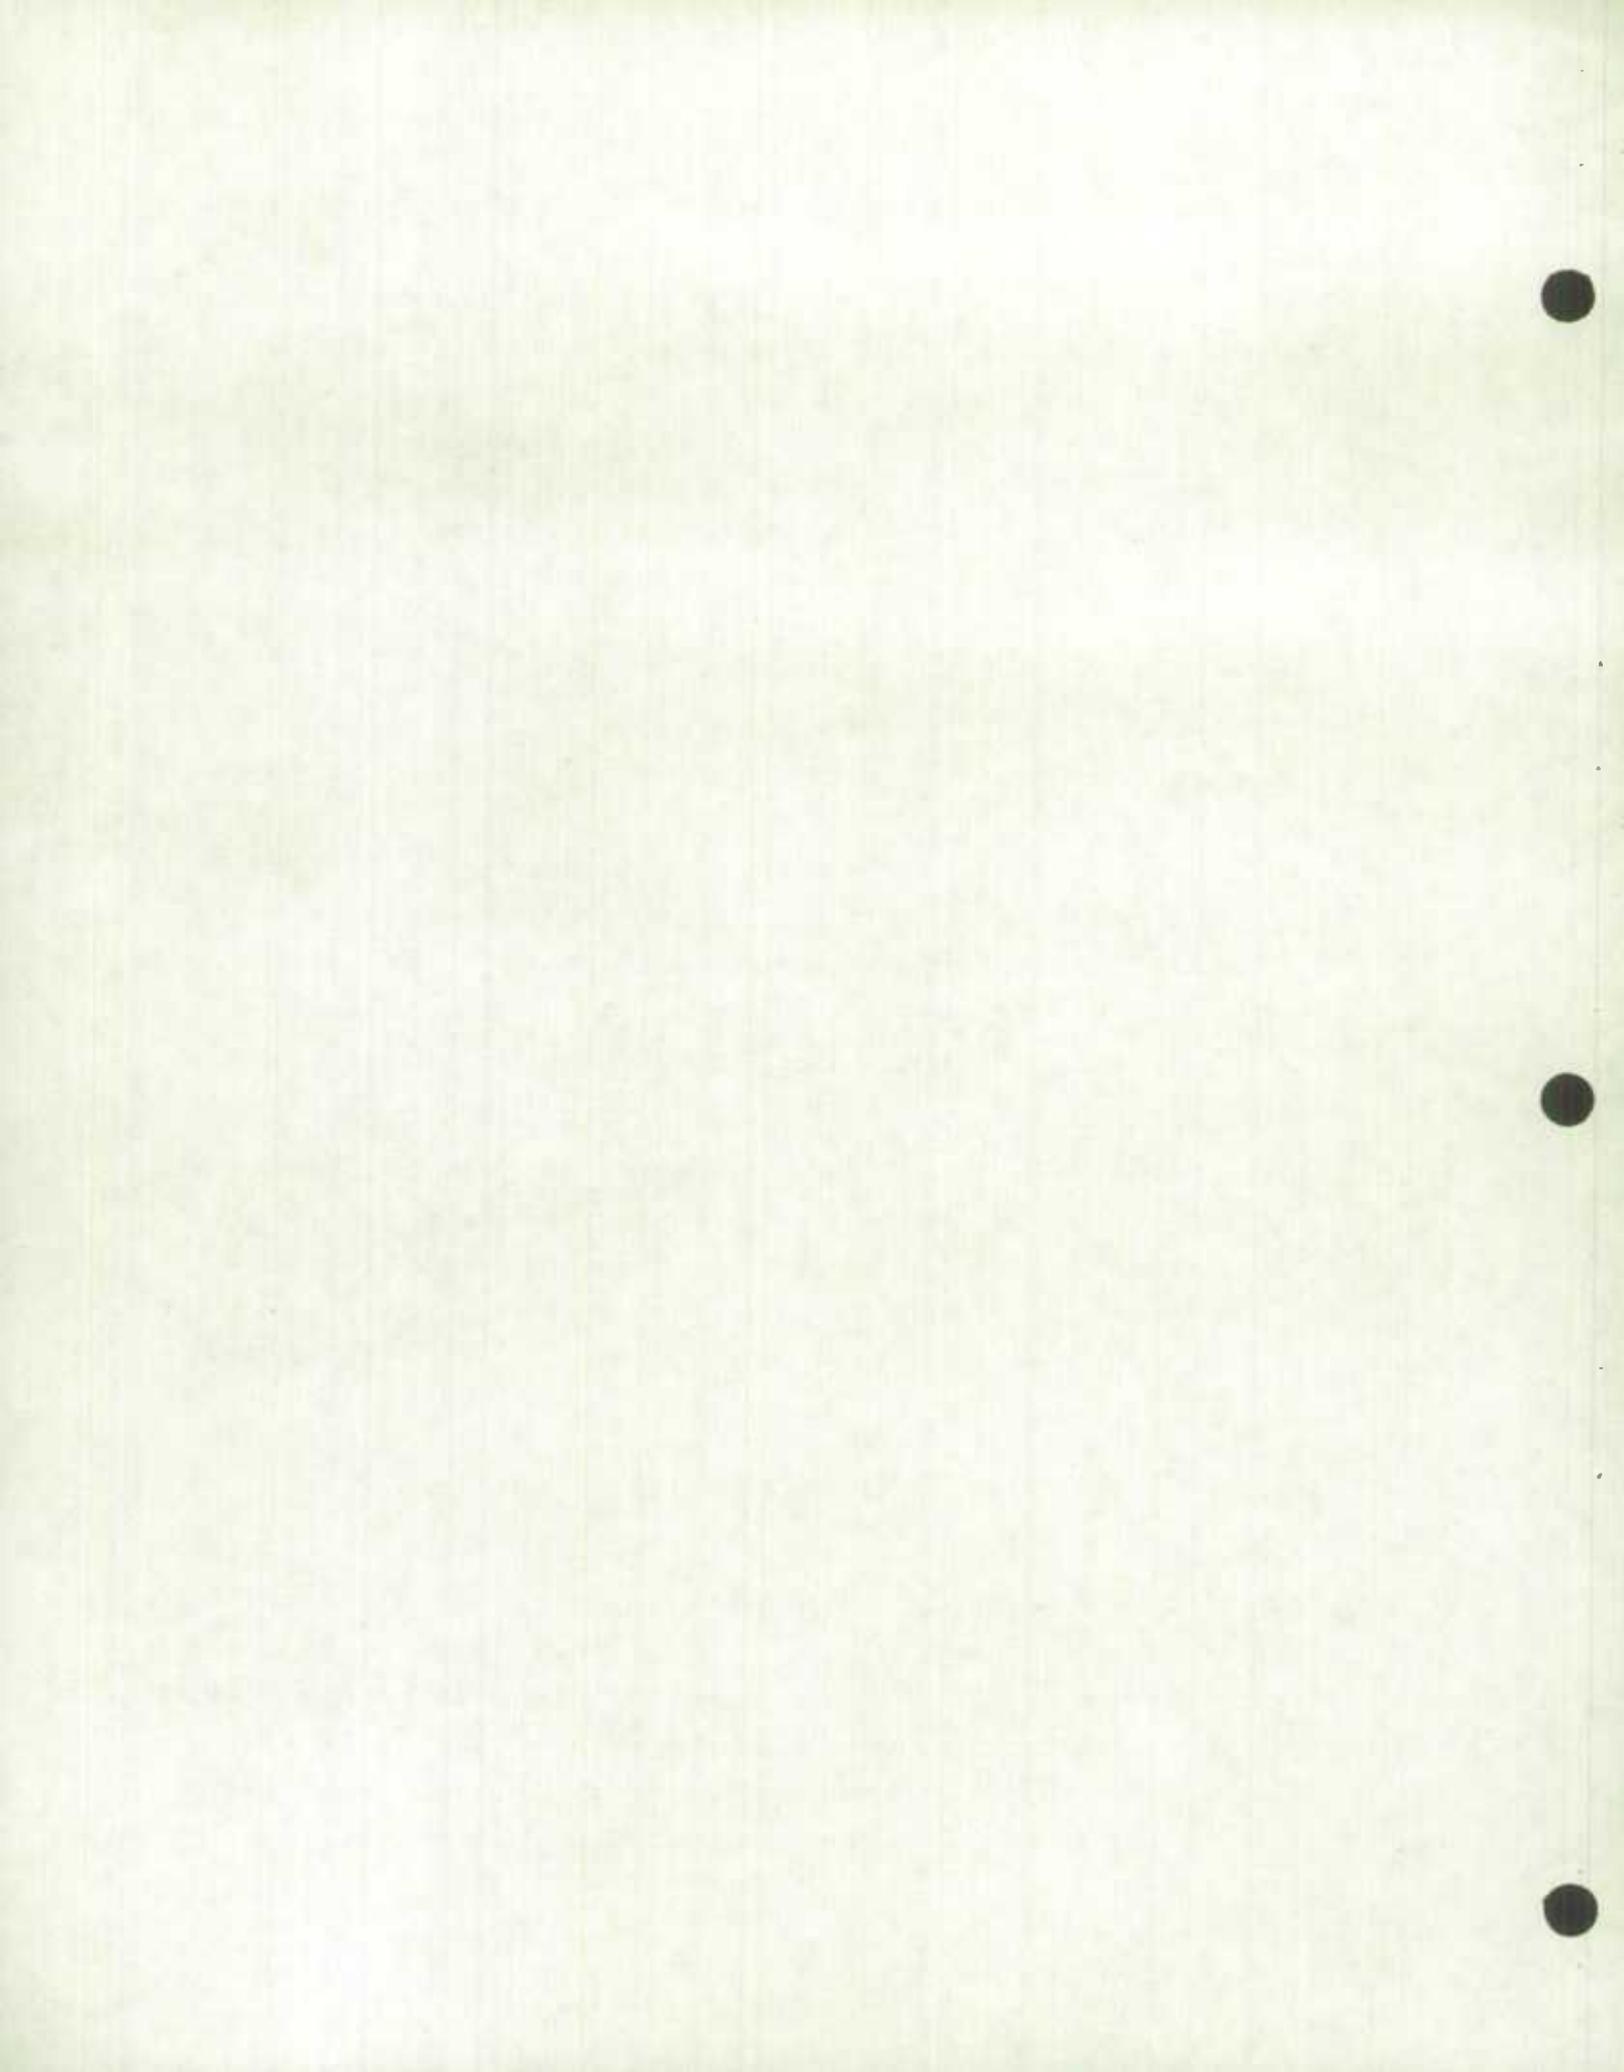
(iv) L'expression de $V(y'_m)$ comprend des termes de covariance qui ne font pas partie des hypothèses (ii) et (iii), comme, par exemple,

$Cov(y_{m,i}, y_{m,j})$ pour $i \neq j$, $Cov(y_{m,i}, y_{m-1,j})$ pour $i = 1, j \neq 6$ et $i \neq 1, j \neq i - 1$ et $Cov(y_{m,i}, y_{m-q,i})$ pour $q \geq 12$. Ces covariances et toutes les autres qui ne sont pas définies plus haut, y compris celles qui dépendent de $\gamma_j^{(2)}$ et qui sont incluses dans l'expression de $V(y'_m)$, sont supposées nulles.

À partir de ces hypothèses, on a formulé une expression pour la variance de l'estimateur composite AK en fonction des paramètres décrits plus haut. Les raisonnements mathématiques pour l'élaboration des expressions qui déterminent le biais et la variance de y'_m et la variance de $y'_m - y'_{m-1}$ figurent dans les annexes.

4. RÉSULTATS ET ANALYSE

Les variables σ^2 dans l'expression de $V(y'_m)$, σ^2 , ρ_j et γ_j , ont été remplacés par les estimations appropriées (pour une description des méthodes d'estimation des ρ et des γ , voir [5]). Notons que, dans l'EPA, les ρ_j n'existent pas pour $j \geq 6$ parce que aucun panel ne remonte si loin. Il n'y a pas non plus de γ pour $j \geq 12$ parce qu'on remonte alors aux prédécesseurs de deuxième rang ou plus du panel courant et on peut supposer que ce genre de corrélation

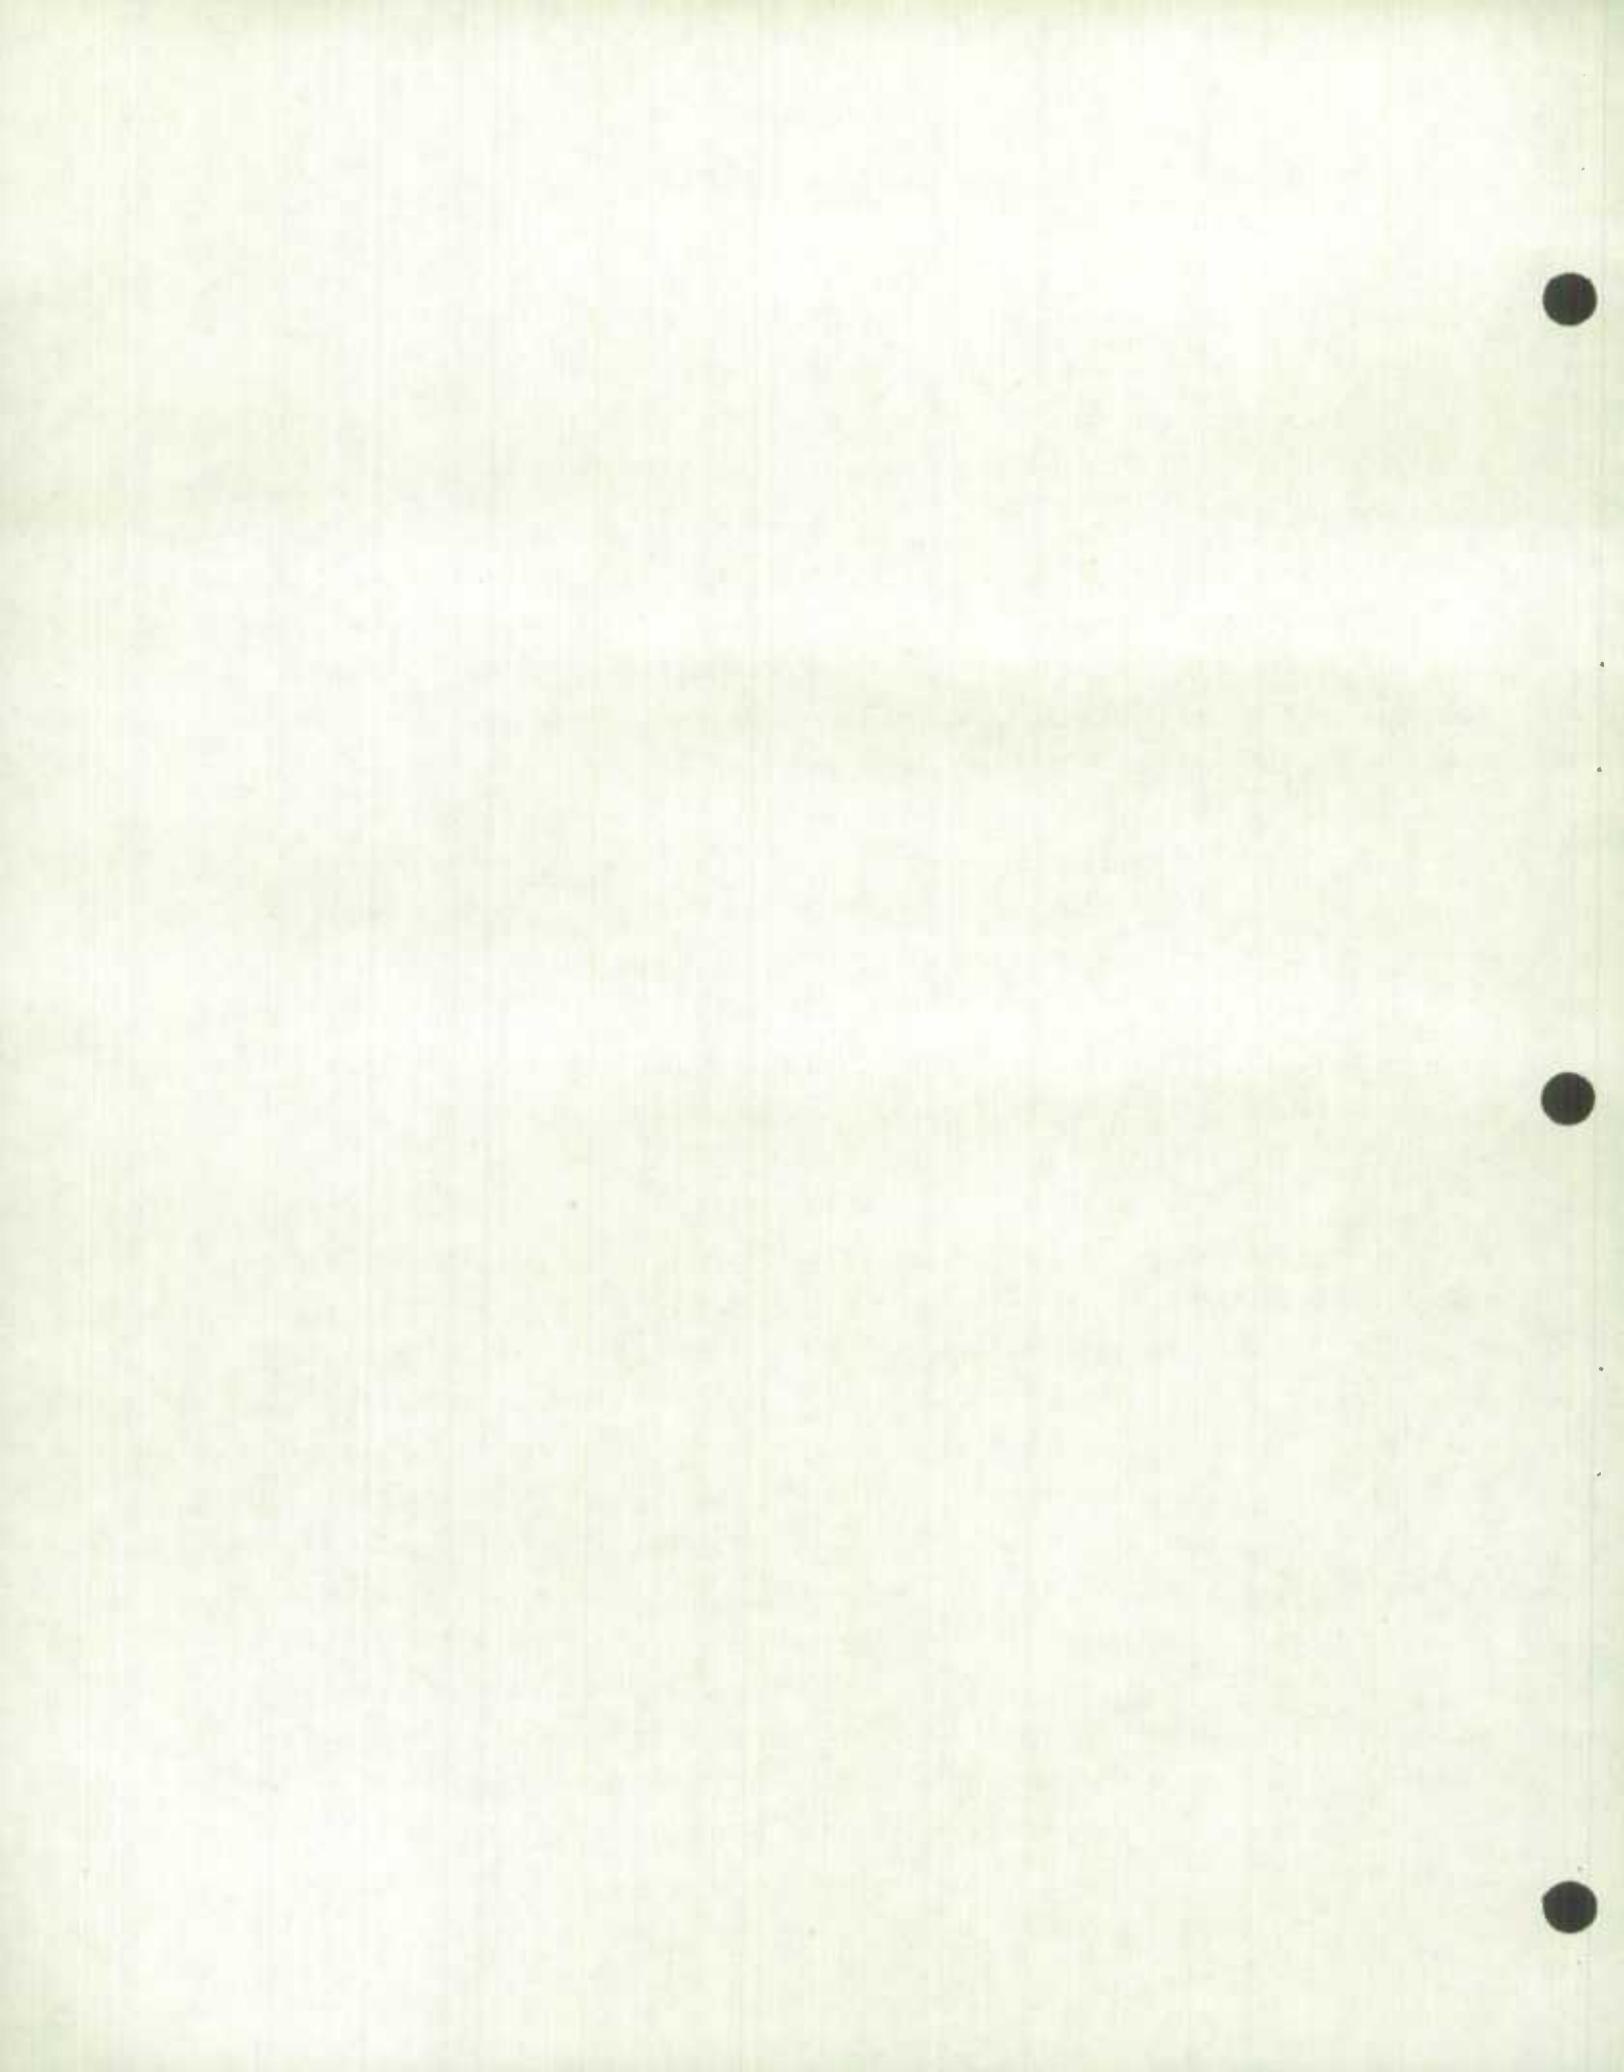


est nul dans les raisonnements mathématiques. Les estimations de ρ_j , à savoir $\hat{\rho}_j$, sont présentées au tableau 2. On a estimé ρ_5 en extrapolant à partir des autres ρ_j parce qu'il n'était pas possible de l'estimer directement pour l'échantillon. Notons que $\hat{\rho}_j$ ($j = 1, 2, \dots, 5$) est une fonction décroissante de j pour toutes les cinq caractéristiques d'intérêt. Ce résultat concorde avec nos intuitions au sujet de l'allure des ρ_j . En outre, les ρ_j ont une valeur élevée pour toutes les caractéristiques sauf le nombre de chômeurs.

Les estimations $\hat{\gamma}_j$, de γ_j , figurent au tableau 3. Les valeurs de $\hat{\gamma}_5$ et $\hat{\gamma}_{11}$ sont estimées respectivement par interpolation et extrapolation à partir d'autres valeurs de $\hat{\gamma}_j$. Intuitivement, on s'attend à voir les γ_j diminuer en fonction de j pour chaque caractéristique. Toutefois, on peut constater que ce n'est pas le cas des $\hat{\gamma}_j$. Bien que les $\hat{\gamma}_j$ ne semblent pas être des fonctions monotones décroissantes, on peut signaler que, quand l'écart ($\hat{\gamma}_{j+1} - \hat{\gamma}_j$) est positif, il est toutefois très petit. Le fait que cet écart puisse être positif est peut-être dû à la variabilité d'échantillonnage plutôt qu'à l'existence d'un écart réellement positif de ($\gamma_{j+1} - \gamma_j$).

Dans ce qui suit, le terme "efficacité relative" de l'estimateur composite AK (ou K) se rapporte à l'efficacité de cet estimateur par rapport à l'estimateur simple.

Les tableaux 4A et 4B présentent les résultats d'une comparaison des estimations de la variance de trois estimateurs, soit (i) l'estimateur composite AK optimal, c'est-à-dire l'estimateur qui a une variance minimum dans la classe d'estimateurs définis par l'équation (2.2), (ii) l'estimateur composite K optimal (qui correspond à la formule (2.2) avec $A = 0$ et qui a le minimum de variance dans cette sous-catégorie d'estimateurs) et (iii) l'estimateur simple par quotient. Pour $0 \leq K < 1$, ces deux tableaux indiquent également les valeurs presque optimales de K et de (K, A) (on a balayé cet intervalle en augmentant de 0.1 la valeur de K et la valeur optimale de A a été déterminée en fonction de K). Ici, un couple de valeurs (K, A) est considéré comme étant optimal si l'estimateur composite AK qui le contient a la variance la plus faible de tous les estimateurs composites AK définis par (2.2). Une défini-



tion semblable s'applique dans le cas de la valeur optimale de K. Les chiffres du tableau 4A sur l'efficacité relative (qui ont été calculés à partir des $\hat{\gamma}_j$ du tableau 3) montrent que, pour toutes les caractéristiques sauf le nombre de chômeurs, l'estimateur composite K offre un gain d'efficacité de 18 à 21 % par rapport à l'estimateur simple, tandis que l'estimateur composite AK permet d'accroître l'efficacité de 26 à 30 %.

Pour préciser l'effet des γ_j sur l'efficacité relative, on a annulé les γ_j dans l'expression de $V(y'_m)$ et calculé les valeurs optimales de K et (K, A), de même que l'efficacité relative des estimateurs composites. Les résultats figurent au tableau 4B. Notons que les valeurs optimales de K et (K, A) présentées aux tableaux 4A et 4B sont différentes. Une comparaison des indices correspondants d'efficacité relative dans ces deux tableaux révèle que les γ_j positifs ont un effet négatif sur la réduction de la variance; autrement dit, l'efficacité relative diminue. La plus grande baisse d'efficacité relative a lieu pour la caractéristique "nombre de personnes occupées dans l'agriculture". C'est cette caractéristique qui a des valeurs relativement élevées de $\hat{\gamma}_j$. Ainsi, si on suppose que les γ_j sont nuls alors qu'en réalité $\gamma_j > 0$, on risque de surestimer l'efficacité relative, et le degré de surestimation dépend de la grandeur des γ_j .

Tel qu'il a été mentionné dans l'introduction, un des inconvénients des estimateurs composites par rapport à l'estimateur simple par quotient est leur biais. Une comparaison des variances d'estimateurs biaisés peut parfois mener à des conclusions erronées au sujet de la qualité relative des estimateurs. Lorsque des estimateurs sont biaisés, il convient d'examiner l'erreur quadratique moyenne. L'expression du biais de y' (voir l'annexe I) comprend les valeurs de α_i (le biais de renouvellement). La variable $\hat{\alpha}_i = y_{m,i} - \hat{Y}_m$ est un estimateur sans biais de α_i si \hat{Y}_m est un estimateur sans biais de Y_m . Nous supposons que l'estimateur simple par quotient \bar{y}_m est un estimateur sans biais de Y_m , c'est-à-dire $\sum_{i=1}^6 \alpha_i = 0$. Les valeurs de $\hat{\alpha}_i$ ($i = 1, 2, \dots, 6$) pour les diverses caractéristiques sont présentées au tableau 5. On constate, pour chacune des trois caractéristiques "taille de la population active", "nombre de personnes occupées" et "nombre de personnes occupées dans les secteurs non

agricoles" (i) que $\hat{\alpha}_1$ est négatif alors que tous les autres $\hat{\alpha}_i$ sont positifs et (ii) que $|\hat{\alpha}_1|$ est grand en comparaison des autres $\hat{\alpha}_i$.

Le tableau 6 montre les valeurs optimales de K et du couple (K, A) et permet de comparer les erreurs quadratiques moyennes des estimations. La valeur optimale de K a été déterminée parmi les dix valeurs dans l'intervalle $K = 0(0.1)0.9$, comme aux tableaux 4A et 4B. Toutefois, la valeur optimale de (K, A) a été calculée d'une manière différente. Elle a été choisie parmi toutes les combinaisons possibles dans les intervalles $K = 0(0.1)0.9$ et $A = 0(0.1)1.0$ au lieu d'être déterminée en fonction de chaque valeur de K dans l'intervalle $K = 0(0.1)0.9$ (comme dans le cas des tableaux 4A et 4B). Deux critères d'optimalité ont été utilisés. Le premier est fondé sur la recherche de l'estimateur à variance minimum (comme aux tableaux 4A et 4B) et le deuxième sur le calcul de l'estimateur à erreur quadratique moyenne minimum.

On montre à l'annexe I que

$$E(y'_m) = Y_m + [A\alpha_1 + K(\alpha_6 - \alpha_1)]/[5(1 - K)].$$

Le biais de chaque estimation au tableau 6 est calculé en fonction des valeurs de $\hat{\alpha}_1$ et $\hat{\alpha}_6$ (qu'on trouve au tableau 5) au lieu de α_1 et α_6 , qui figurent dans la formule écrite plus haut. Nous abordons maintenant les résultats présentés au tableau 6.

L'estimateur composite K basé sur le critère d'optimalité à erreur quadratique moyenne minimum n'affiche qu'un léger gain d'efficacité par rapport à l'estimateur simple pour la caractéristique "nombre de personnes occupées dans l'agriculture" et un gain infime dans le cas du nombre de chômeurs. En outre, le biais des estimations relatives à ces deux caractéristiques est faible. Quant aux autres estimations, l'estimateur optimal produit le même résultat que l'estimateur K optimal.

L'efficacité relative des estimateurs composites K basés sur le critère d'optimalité à variance minimale (qui sont examinés au tableau 4A) est de moins de

10 % pour les trois caractéristiques "taille de la population active", "nombre de personnes occupées" et "nombre de personnes occupées ailleurs que dans l'agriculture". On peut attribuer ces piètres résultats à l'ampleur du biais. Quant aux deux autres caractéristiques, l'estimateur composite K ne présente qu'un faible avantage en comparaison de l'estimateur simple par quotient; en d'autres termes, le gain d'efficacité offert par l'estimateur K est négligeable. Les différences entre les indices d'efficacité relative des tableaux 4A et 6 sont dues au fait que l'efficacité relative n'est pas définie de la même manière dans ces deux tableaux. Au tableau 4A, l'efficacité relative est définie comme le rapport des variances appropriées, tandis qu'au tableau 6 on utilise les erreurs quadratiques moyennes au lieu des variances.

L'estimateur composite AK basé sur le critère d'optimalité à erreur quadratique moyenne minimum affiche un gain d'efficacité de 16 à 22 % par rapport à l'estimateur simple, pour toutes les caractéristiques sauf le nombre de chômeurs. En outre, le biais de l'estimation relative à chaque caractéristique est faible.

Par contre, l'estimateur composite AK basé sur le critère d'optimalité à variance minimum a, comme l'estimateur composite K, une efficacité relative très basse pour les caractéristiques "taille de la population active", "nombre de personnes occupées" et "nombre de personnes occupées dans les secteurs non agricoles" parce que le biais est assez grand dans ces cas. L'efficacité relative est assez bonne pour la caractéristique "nombre de personnes occupées dans l'agriculture", mais elle dépasse 100 de très peu dans le cas du nombre de chômeurs.

Les résultats montrent que, parmi les quatre estimateurs composites qui figurent au tableau 6, c'est l'estimateur composite AK optimal à erreur quadratique moyenne minimum qui a l'efficacité relative la plus élevée pour toutes les caractéristiques. Il sera question de la dernière colonne du tableau 6 un peu plus loin.

On peut noter, à partir de l'expression de $E(y'_m)$ qui est donnée plus haut, que $y'_m - y'_{m-1}$ est un estimateur sans biais de $Y_m - Y_{m-1}$, ce qui revient à dire que

les estimateurs composites K ou AK permettent de mesurer le changement sans biais. Le tableau 7 présente les valeurs optimales de K et (K, A) et montre l'indice d'efficacité relative des estimateurs composites K et AK relatifs aux changements. Les estimations des caractéristiques "taille de la population active", "nombre de personnes occupées", et "nombre de personnes occupées dans les secteurs non agricoles" affichent des gains d'efficacité de 46 à 55 % dans le cas des estimateurs composites K et AK. Quant au nombre de personnes occupées dans l'agriculture, les estimateurs composites AK et K ont le même résultat et la marge d'efficacité relative est d'environ 135 %. Ces deux estimateurs offrent un gain d'efficacité d'à peu près 6 % pour la caractéristique "nombre de chômeurs".

Il est important de souligner que la valeur optimale de K ou (K, A) varie en fonction de la caractéristique estimée. Or, la propriété additive des estimateurs n'est pas conservée quand on emploie différentes valeurs de K ou (K, A). Pour maintenir cette additivité, on a fixé des valeurs communes de $K = 0.4$ et $A = 0.4$ dans le calcul des estimations de totaux et de changements. Les observations suivantes portent sur les résultats obtenus à partir de l'estimateur AK pour les valeurs $K = 0.4$ et $A = 0.4$. La dernière colonne du tableau 6 montre que la marge d'efficacité relative des estimations composites AK de totaux est de 6 à 10 % pour toutes les caractéristiques sauf le nombre de chômeurs. Les résultats présentés au tableau 7 révèlent que la marge d'efficacité relative des estimations composites AK de changements varie de 12 à 15 % dans tous les cas à l'exception de la caractéristique "nombre de chômeurs". Le gain d'efficacité de l'estimateur composite AK de totaux et de changements par rapport à l'estimateur simple par quotient est de 2 à 3 % pour la caractéristique "nombre de chômeurs".

REMERCIEMENTS

Les auteurs aimeraient remercier D. Drew, G.B. Gray et M.P. Singh de Statistique Canada pour leurs remarques pertinentes pendant la préparation de ce travail, ainsi que l'arbitre dont les suggestions ont contribué à améliorer la présentation de ce document.

TABLEAU 1

Correspondance entre les panels dans l'échantillon de l'EPA au mois m
et les panels des mois m - j

Panels du mois m	m-1	m-2	m-3	m-4	m-5	m-6	m-7	m-8	m-9	m-10	m-11
1	(6)	(5)	(4)	(3)	(2)	(1)	((6))	((5))	((4))	((3))	((2))
2	1	(6)	(5)	(4)	(3)	(2)	(1)	((6))	((5))	((4))	((3))
3	2	1	(6)	(5)	(4)	(3)	(2)	(1)	((6))	((5))	((4))
4	3	2	1	(6)	(5)	(4)	(3)	(2)	(1)	((6))	((5))
5	4	3	2	1	(6)	(5)	(4)	(3)	(2)	(1)	((6))
6	5	4	3	2	1	(6)	(5)	(4)	(3)	(2)	(1)

Le coefficient de corrélation des panels qui font partie de l'échantillon aux mois m et m-j (les panels non entourés de parenthèses) est ρ_j .

Le coefficient de corrélation des panels du mois m et de leur premier prédécesseur (panel entouré d'une paire de parenthèses) au mois m - j est γ_j .

Le coefficient de corrélation des panels du mois m et de leur deuxième prédécesseur (panel entouré de deux paires de parenthèses) au mois m - j est $\gamma_j^{(2)}$. On suppose ici que tous les $\gamma_j^{(2)}$ sont nuls.

TABLEAU 2

Estimations des corrélations ρ (Ontario, 1980-1981)

Caractéristiques \ ρ	$\hat{\rho}_1$	$\hat{\rho}_2$	$\hat{\rho}_3$	$\hat{\rho}_4$	$\hat{\rho}_5$
Taille de la population active	.843	.782	.717	.674	.631
Nombre de personnes occupées	.852	.779	.709	.664	.619
Nombre de personnes occupées dans l'agriculture	.955	.926	.901	.861	.821
Nombre de personnes occupées dans les secteurs non agricoles	.861	.791	.724	.678	.632
Nombre de chômeurs	.580	.445	.334	.286	.238

TABLEAU 3

Estimations des corrélations γ (Ontario, 1980-1981)

Caractéristiques \ $\hat{\gamma}$	$\hat{\gamma}_1$	$\hat{\gamma}_2$	$\hat{\gamma}_3$	$\hat{\gamma}_4$	$\hat{\gamma}_5$	$\hat{\gamma}_6$	$\hat{\gamma}_7$	$\hat{\gamma}_8$	$\hat{\gamma}_9$	$\hat{\gamma}_{10}$	$\hat{\gamma}_{11}$
Taille de la population active	.161	.141	.128	.133	.135	.136	.125	.127	.124	.122	.127
Nombre de personnes occupées	.164	.136	.142	.142	.146	.149	.148	.150	.153	.141	.148
Nombre de personnes occupées dans l'agriculture	.477	.483	.474	.486	.480	.474	.459	.429	.394	.323	.252
Nombre de personnes occupées dans les secteurs non agricoles	.184	.150	.147	.157	.162	.167	.166	.169	.174	.156	.166
Nombre de chômeurs	.141	.074	.076	.063	.057	.051	.045	.060	.077	.136	.074

TARLEAU 4A & 4B
Valeurs optimales de (K, A) et K et indices d'efficacité relative des estimateurs composites K et AK

TARLEAU 4A
 $\gamma_i \neq 0$

Caractéristiques	Estimateur composite K		Estimateur composite AK		
	Val. opt. K	Efficacité relative	Val. opt. K	A	Efficacité relative
Taille de la population active	0.7	118.8	0.8	0.48	128.4
Nombre de personnes occupées	0.7	118.5	0.8	0.49	128.1
Nombre de personnes occupées dans l'agriculture	0.8	120.6	0.8	0.38	126.9
Nombre de personnes occupées dans les secteurs non agricoles	0.7	119.4	0.8	0.47	129.3
Nombre de chômeurs	0.3	102.8	0.5	0.38	105.2

TARLEAU 4B
 $\gamma_i = 0$ pour tous les i

Caractéristiques	Estimateur composite K		Estimateur composite AK		
	Val. opt. K	Efficacité relative	Val. opt. K	A	Efficacité relative
Taille de la population active	0.7	125.5	0.8	0.50	138.4
Nombre de personnes occupées	0.7	125.3	0.8	0.51	137.9
Nombre de personnes occupées dans l'agriculture	0.8	167.3	0.9	0.46	187.9
Nombre de personnes occupées dans les secteurs non agricoles	0.7	126.9	0.8	0.49	140.2
Nombre de chômeurs	0.4	104.4	0.6	0.51	108.4

L'efficacité relative compare la variance (V) de l'estimateur simple par quotient et celle de l'estimateur composite et se définit comme 100 fois le rapport $V(\text{estimateur simple})/V(\text{estimateur K ou AK})$.

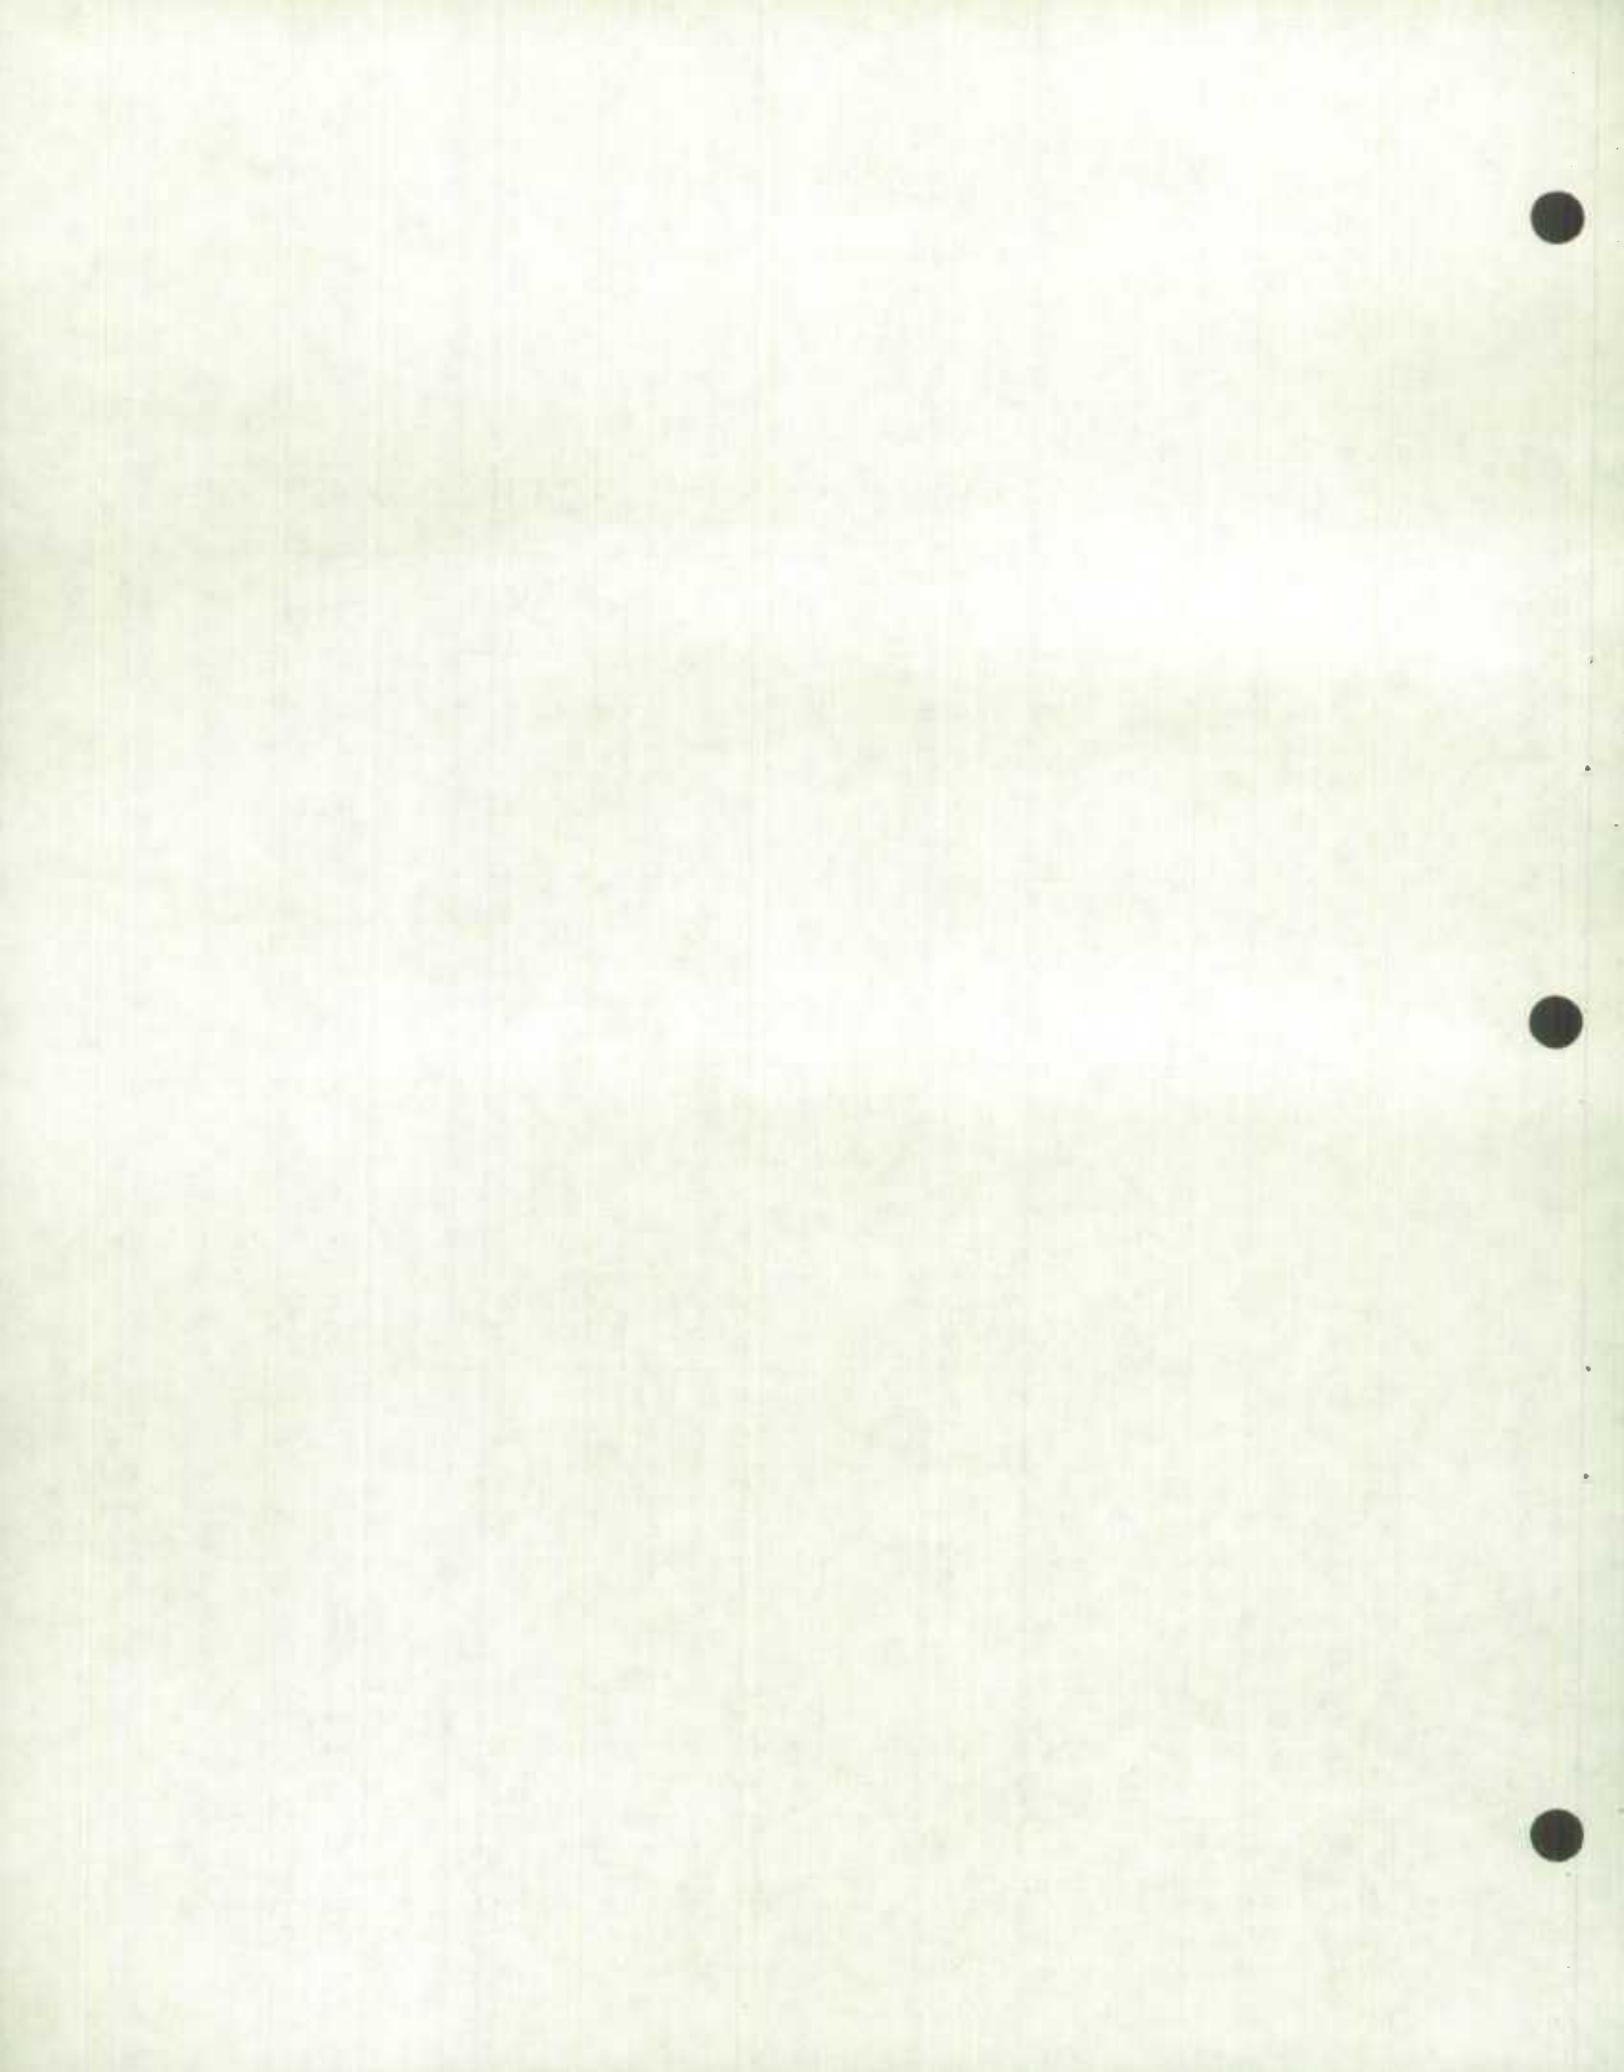


TABLEAU 5

Estimations (en milliers) du biais de renouvellement α_1

Caractéristiques	$\hat{\alpha}_1$	$\hat{\alpha}_2$	$\hat{\alpha}_3$	$\hat{\alpha}_4$	$\hat{\alpha}_5$	$\hat{\alpha}_6$
Taille de la population active	-135.3	39.8	41.1	31.1	15.4	7.9
Nombre de personnes occupées	-141.7	35.5	34.9	31.3	25.4	14.8
Nombre de personnes occupées dans l'agriculture	-4.2	-2.6	2.2	-0.1	4.2	0.5
Nombre de personnes occupées dans les secteurs non agricoles	-137.5	38.0	32.7	31.3	21.2	14.3
Nombre de chômeurs	6.4	4.3	6.2	-0.1	-9.9	-6.9

α_1 est défini comme $E(y_{m,i}) - Y_m$ et est estimé par $y_{m,i} - \frac{\sum_{i=1}^6 y_{m,i}}{6}$.

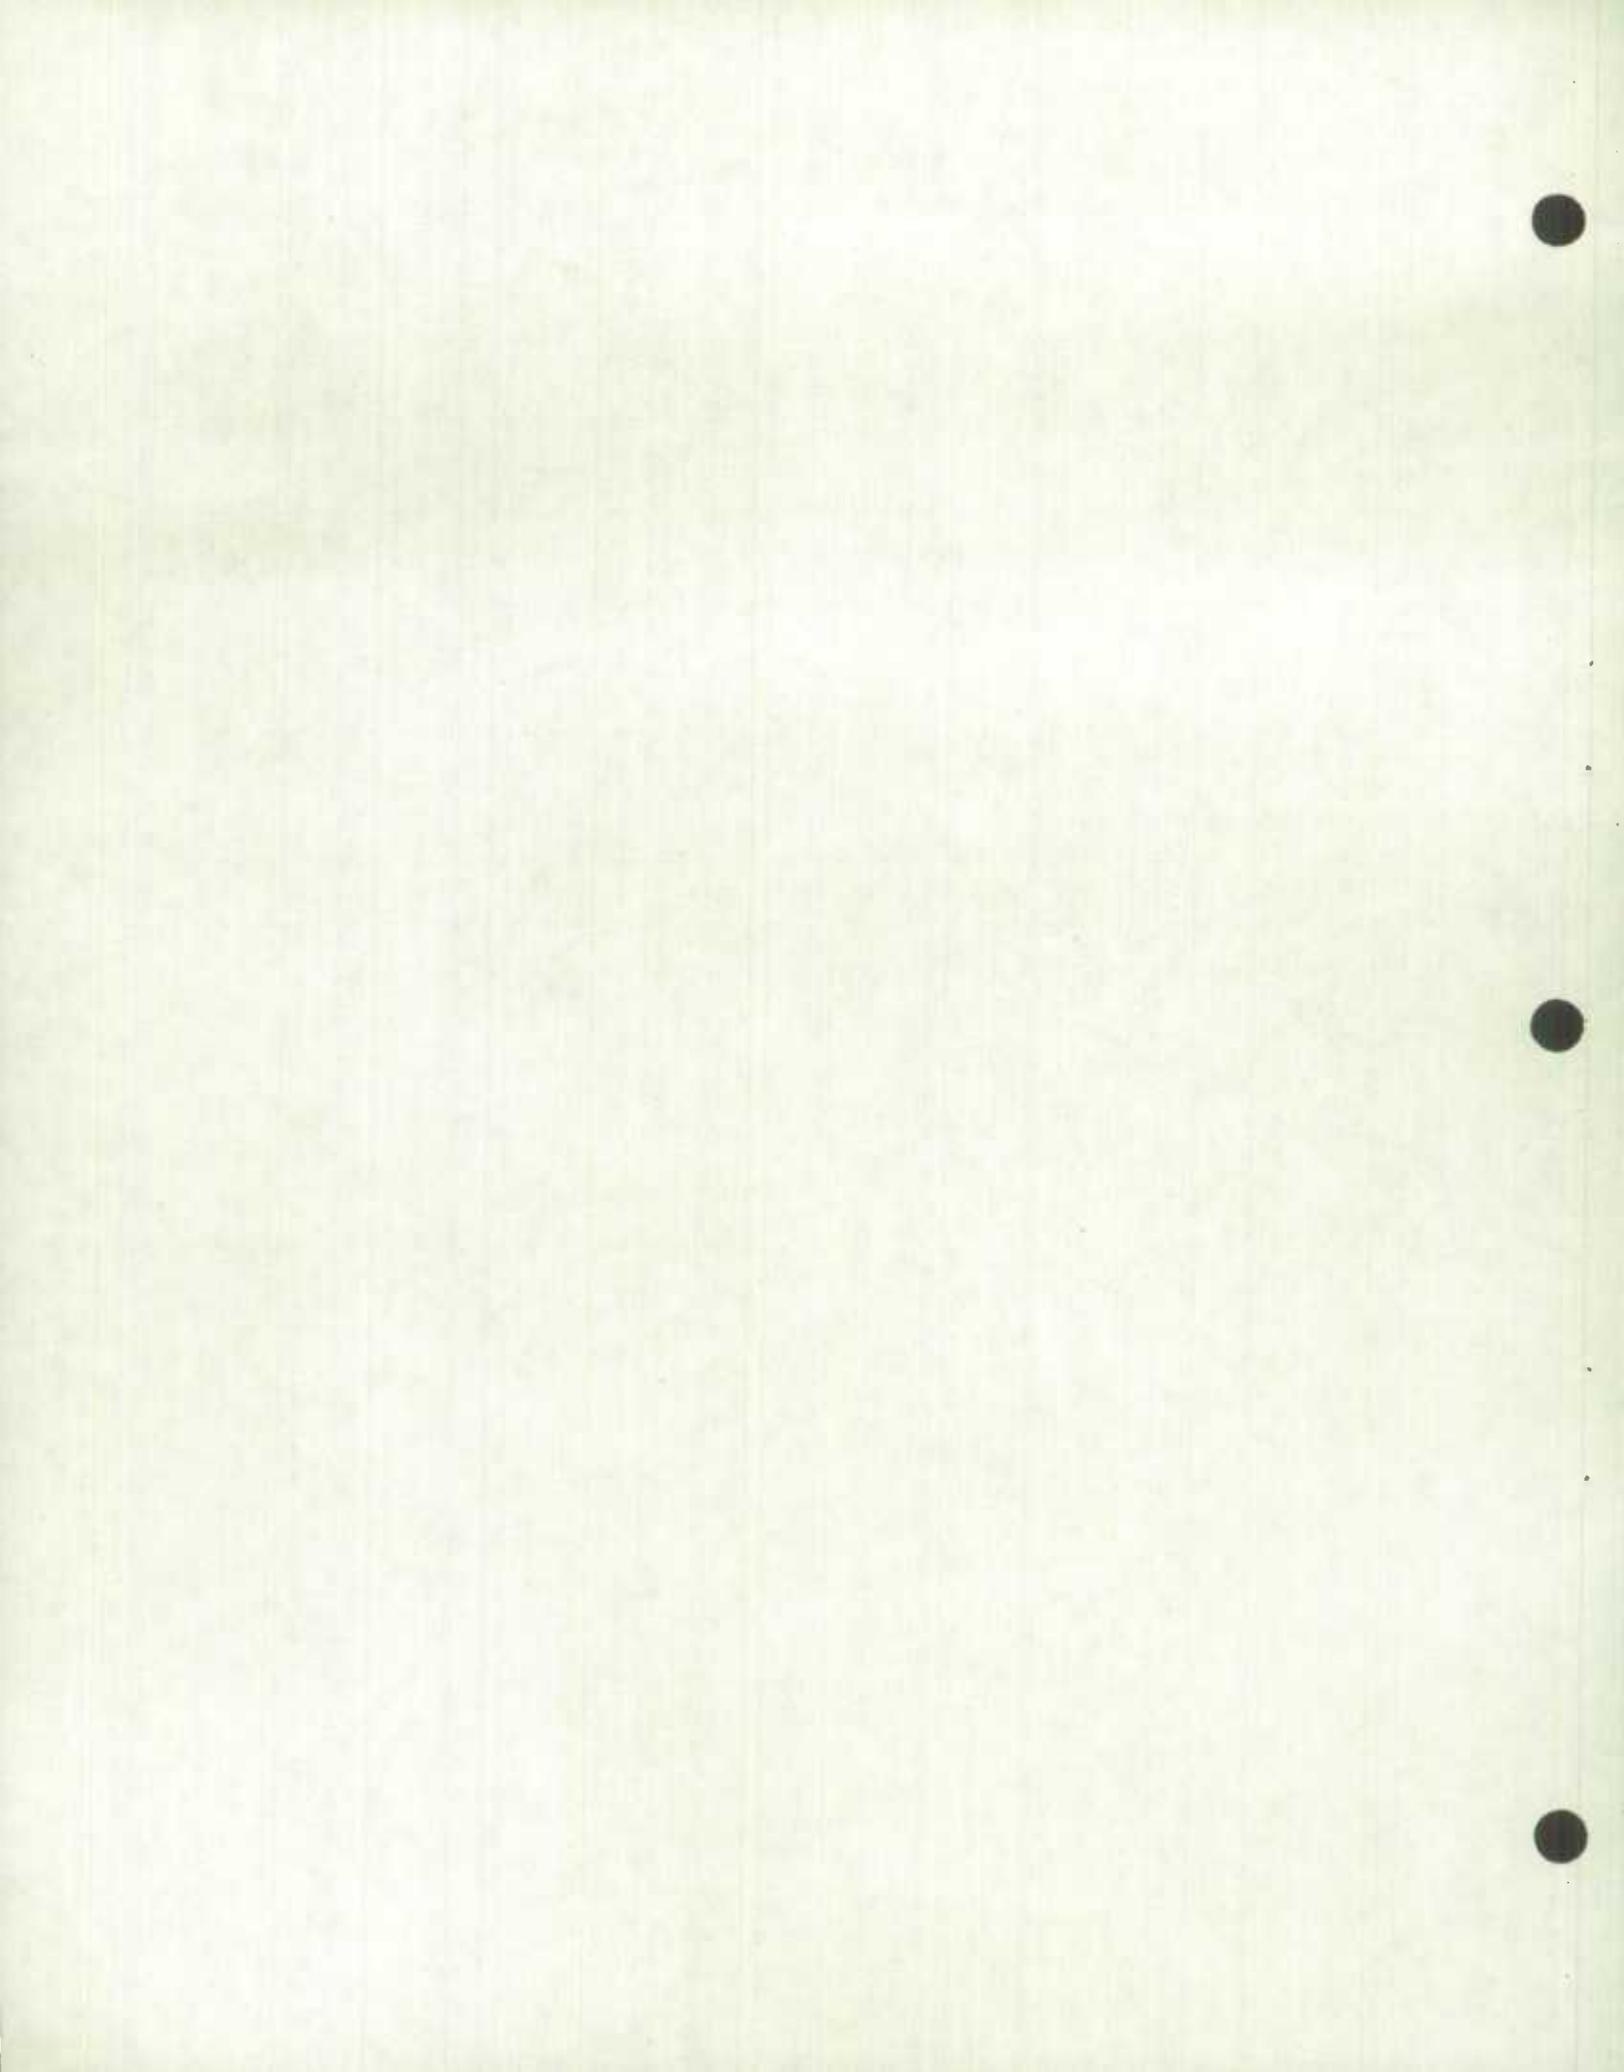


TABLEAU 6

Comparaison de la variance et de l'erreur quadratique moyenne
de l'estimateur simple, des estimateurs composites K et AK

TAILLE DE LA POPULATION ACTIVE

		Estimateur simple	Estimateur composite K		Estimateur composite AK		Valeurs communes caractéristiques	
			(EQM min.) K=0	(Var. min.) K=0.7	(EQM min.) K=0.7 A=0.7	(Var. min.) K=0.8 A=0.5	K=0.4	A=0.4
Estimation du total mensuel	10^3	4480.7	4480.7	4547.5	4484.4	4527.6	4481.7	
Variance	10^6	432.0	432.0	363.8	358.1	336.5	391.8	
Biais	10^3	0	0	66.8	3.7	46.9	1.0	
Erreur quadratique moyenne	10^6	432.0	432.0	4284.5	371.5	2532.4	392.9	
Efficacité relative			100.0	9.0	116.3	17.1	110.0	

NOMBRE DE PERSONNES OCCUPÉES

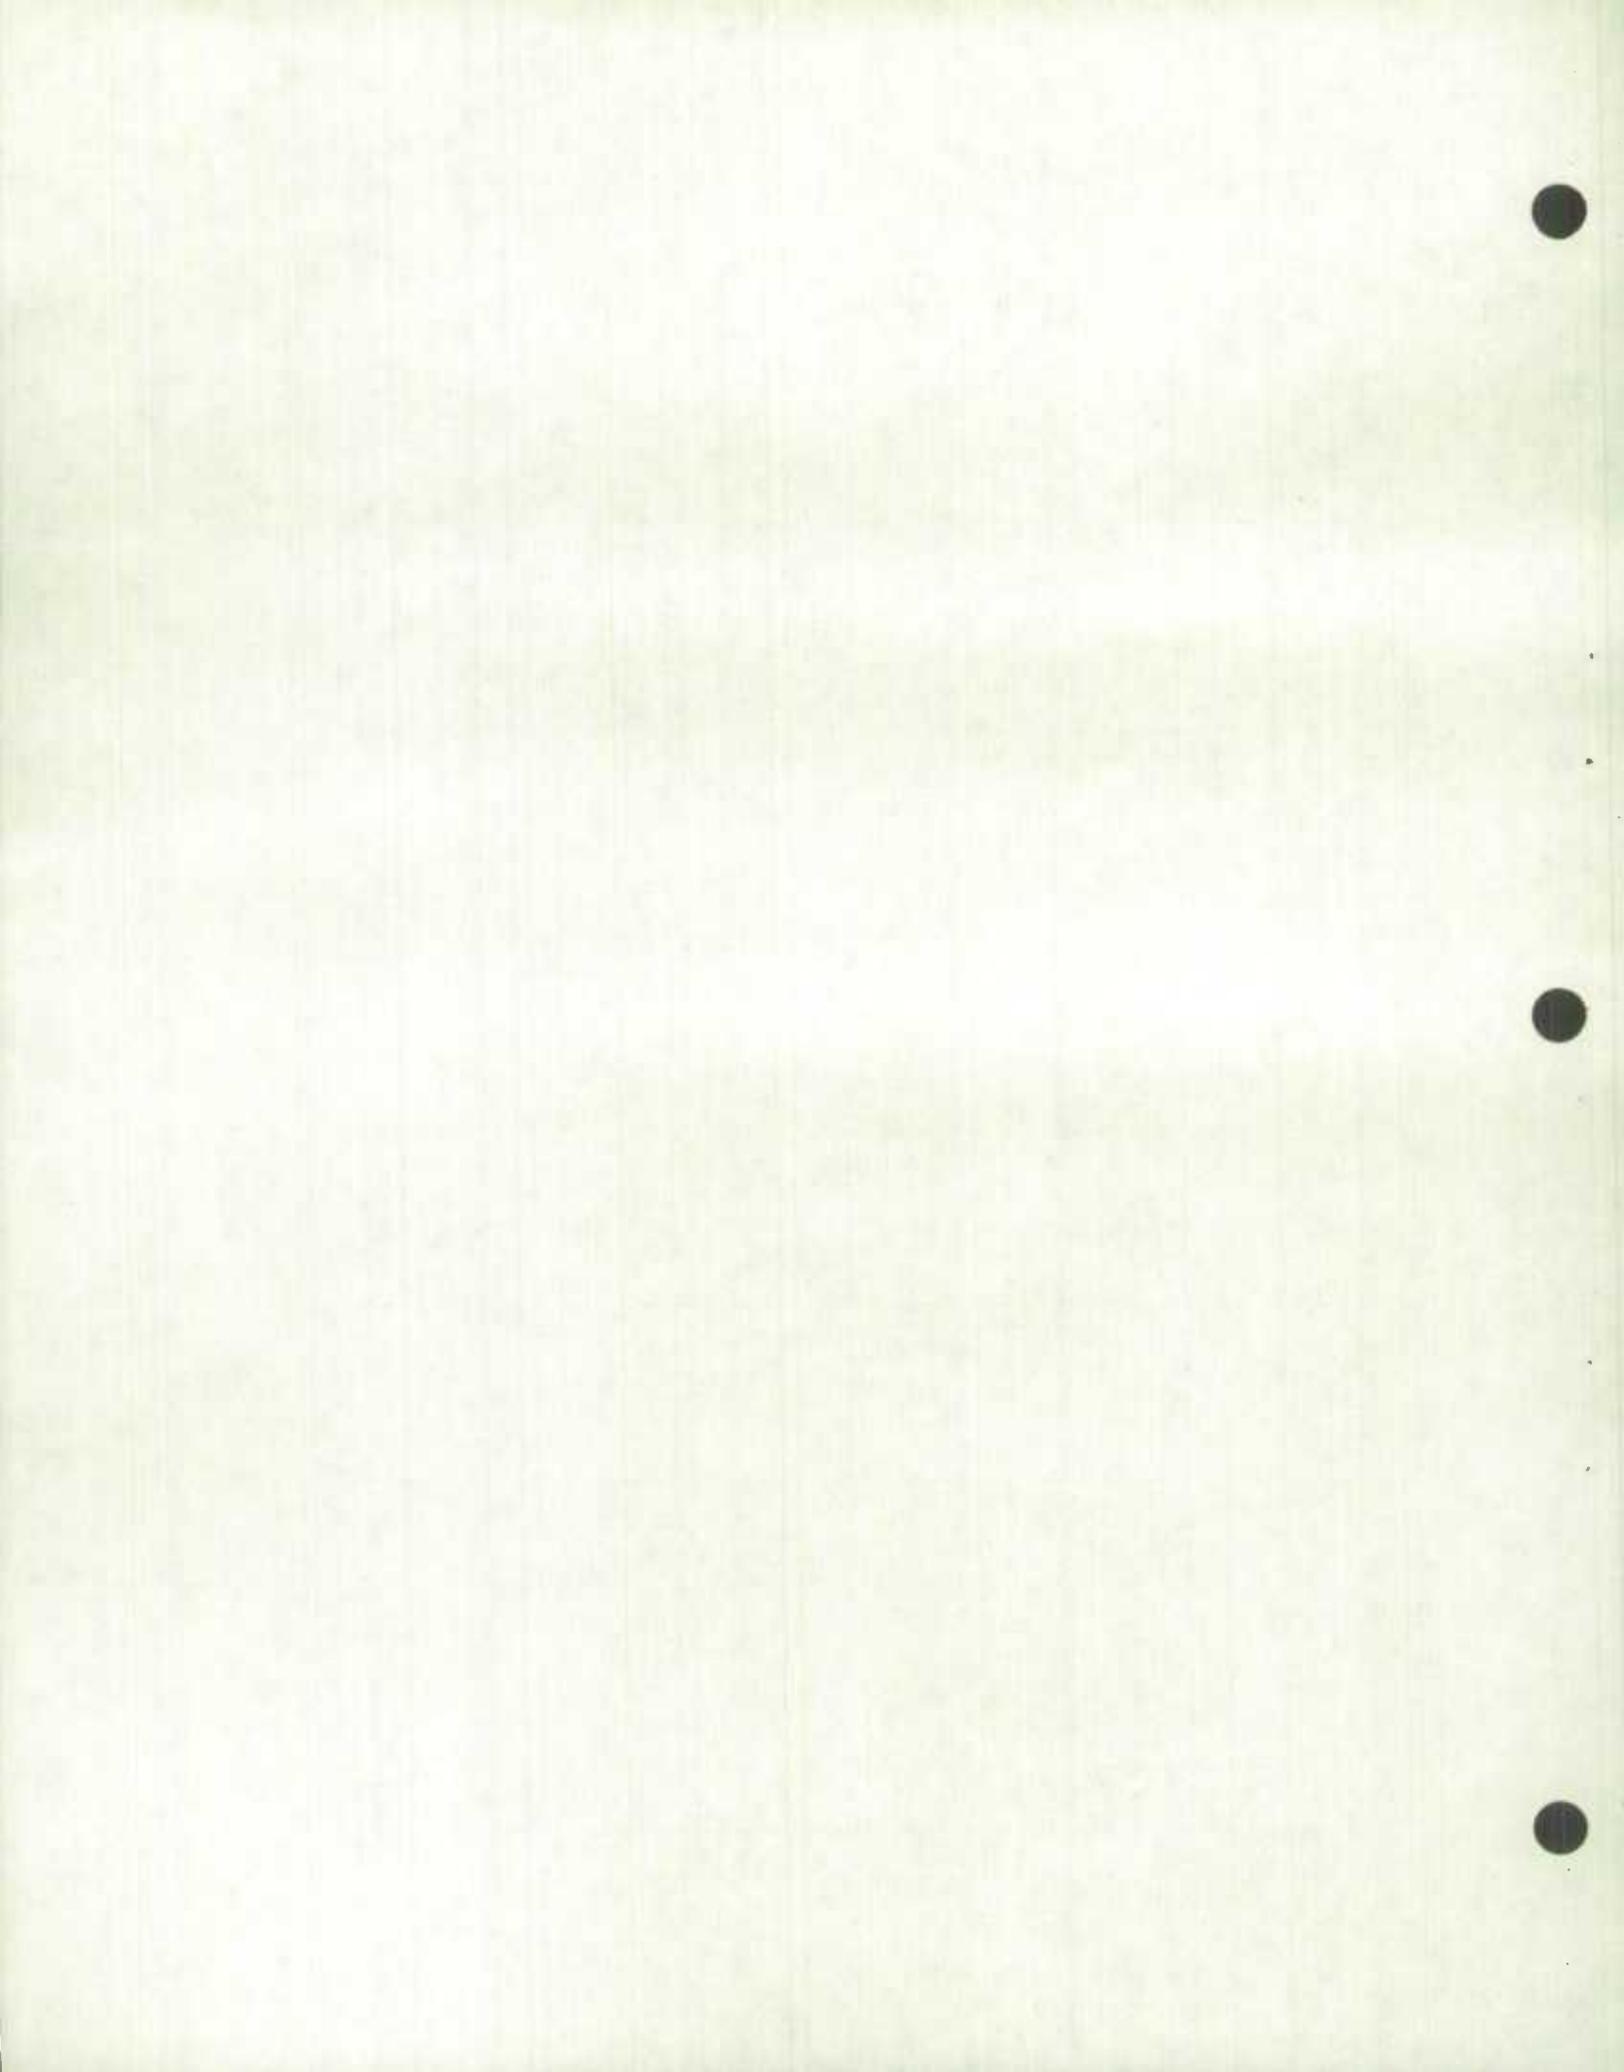
			K=0	K=0.7	K=0.7 A=0.7	K=0.8 A=0.5	K=0.4 A=0.4	
							K=0.4	A=0.4
Estimation du total mensuel	10^3	4186.0	4186.0	4259.0	4183.6	4240.3	188.0	
Variance	10^6	473.3	473.3	399.6	397.7	369.5	428.0	
Biais	10^3	0	0	73.0	-2.4	54.3	2.0	
Erreur quadratique moyenne	10^6	473.3	473.3	5732.2	403.2	3320.9	432.8	
Efficacité relative			100.0	8.3	117.4	14.3	109.4	

NOMBRE DE PERSONNES OCCUPÉES DANS L'AGRICULTURE (TABLEAU 6 suite)

		Estimateur simple	Estimateur composite K		Estimateur composite AK		Valeurs communes caractéristiques	
			(EQM min.) K=0.6	(Var. min.) K=0.8	(EQM min.) K=0.8 A=0.6	(Var. min.) K=0.8 A=0.4	K=0.4	A=0.4
Estimation du total mensuel	10^3	142.0	143.4	145.7	143.2	144.1	142.1	
Variance	10^6	85.7	75.6	71.1	68.7	67.6	80.8	
Biais	10^3	0	1.4	3.7	1.2	2.1	0.1	
Erreur quadratique moyenne	10^6	85.7	77.6	85.1	70.2	71.8	80.8	
Efficacité relative			110.5	110.7	122.2	119.4	106.1	

NOMBRE DE PERSONNES OCCUPÉES DANS LES SECTEURS NON AGRICOLES

			K=0	K=0.7	K=0.8 A=0.9	K=0.8 A=0.5	K=0.4	A=0.4
			Estimation du total mensuel	10^3	4043.9	4043.9	4114.7	4041.6
Variance	10^6	498.9	498.9	417.8	418.0	385.9	452.8	
Biais	10^3	0	0	70.8	-2.3	52.7	1.9	
Erreur quadratique moyenne	10^6	498.9	498.9	5436.1	423.3	3161.7	456.4	
Efficacité relative			100.0	9.2	117.9	15.8	109.3	



NOMBRE DE CHÔMEURS (TABLEAU 6 fin)

	Estimateur simple	Estimateur composite K		Estimateur composite AK		Valeurs communes caractéristiques	
		(EQM min.) K=0.2	(Var. min.) K=0.3	(EQM min.) K=0.4 A=0.4	(Var. min.) K=0.5 A=0.4	K=0.4	A=0.4
Estimation du total mensuel	10^3	294.8	294.1	293.7	293.9	293.2	293.9
Variance	10^6	117.5	114.9	414.3	112.5	111.7	112.5
Biais	10^3	0	-0.7	-1.1	-0.9	-1.6	-0.9
Erreur quadratique moyenne	10^6	117.5	115.4	115.7	113.3	114.4	113.3
Efficacité relative			101.9	101.6	103.7	102.7	103.7

Efficacité relative compare l'EMQ de l'estimateur simple par quotient et celle de l'estimateur composite et se définit comme 100 fois le rapport EQM(estimateur simple)/EQM(estimateur K ou AK).

TABEAU 7

Efficacité relative des estimateurs composites du changement mensuel

Caractéristiques	Estimateur composite K		Estimateur composite AK			Valeurs communes K = 0.4 A = 0.4
	Val. opt. K	Efficacité relative	Val. opt. K	A	Efficacité relative	Efficacité relative
Taille de la population active	0.9	146.6	0.9	0.1	147.9	113.3
Nombre de personnes occupées	0.9	151.0	0.9	0.1	152.3	114.1
Nombre de personnes occupées dans l'agriculture	0.9	234.7	0.9	0.0	234.7	112.3
Nombre de personnes occupées dans les secteurs non agricoles	0.9	154.0	0.9	0.1	155.2	114.1
Nombre de chômeurs	0.4	106.0	0.6	0.2	106.4	102.9

L'efficacité relative compare la variance (V) de l'estimateur simple par quotient et celle de l'estimateur composite et se définit comme 100 fois le rapport $V(\text{estimateur simple})/V(\text{estimateur K ou AK})$.

ANNEXE I

Calcul du biais de l'estimateur composite

Tel qu'il est défini dans l'équation (2.2), l'estimateur composite AK de Y_m s'écrit

$$y'_m = (1 - K + A)y_{m,1}/6 + (1 - K - A/5) \sum_{j=2}^6 y_{m,j}/6 + K(y'_{m-1} + d_{m,m-1}). \quad (A1.1)$$

Rappelons que l'estimateur simple actuellement utilisé dans l'EPA est la moyenne des estimateurs relatifs aux six panels définie par la formule :

$$\bar{y}_m = \frac{1}{6} \sum_{i=1}^6 y_{m,i} \quad (A1.2)$$

L'équation (2.3) précise que le biais de l'estimateur relatif au i^e panel est égal à α_i , de sorte que $E(y_{m,i}) = Y_m + \alpha_i$, où le biais est indépendant de m . Ainsi, on peut écrire

$$E(\bar{y}_m) = Y_m + \frac{1}{6} \sum_{i=1}^6 \alpha_i = Y_m + \bar{\alpha}, \text{ et on suppose dans les raisonnements}$$

subséquents que $\bar{\alpha} = 0$.

L'estimateur composite peut se récrire de la manière suivante :

$$y'_m = y_m + K(y'_{m-1} + d_{m,m-1}), \quad (A1.3)$$

où

$$\begin{aligned} y_m &= (1 - K + A)y_{m,1}/6 + (1 - K - A/5) \frac{1}{5} \sum_{j=2}^6 y_{m,j}/6 \\ &= (1 - K)\bar{y}_m + A(y_{m,1} - \bar{y}_m)/5, \end{aligned}$$

donc

$$E(y_m) = (1 - K)Y_m + \bar{\alpha} + (A/5)(\alpha_1 - \bar{\alpha}), \quad (A1.4)$$

qu'on peut simplifier sous la forme de l'équation

$$E(y_m) = (1 - K)Y_m + (A/5)\alpha_1, \text{ quand } \bar{\alpha} = 0.$$

Utilisant la définition de $d_{m,m-1}$, donnée en (2.1), nous avons

$$E(d_{m,m-1}) = E\left[\frac{1}{5} \sum_{j=2}^6 (y_{m,j} - y_{m-1,j-1})\right]$$

$$= (Y_m - Y_{m-1}) + (\alpha_6 - \alpha_1)/5. \quad (A1.5)$$

On peut développer y'_m par l'application récursive de l'équation (A1.3) et pour un décalage de n mois :

$$y'_m = y_m + Ky_{m-1} + K^2y_{m-2} + \dots + K^{n-1}y_{m-n+1} + K^n y'_{m-n} \\ + Kd_{m,m-1} + K^2d_{m-1, m-2} + \dots + K^nd_{m-n+1, m-n}. \quad (A1.6)$$

L'espérance mathématique de y_m peut être facilement exprimée à partir des équations (A1.4) et (A1.6). Ainsi :

$$E(y'_m) = (1 - K)[Y_m + KY_{m-1} + K^2Y_{m-2} + \dots + K^{n-1}Y_{m-n+1}] + K^n E(y'_{m-n}) \\ + [(1 - K)\bar{\alpha} + (A/5)(\alpha_1 - \bar{\alpha})](1 - K^n)/(1 - K) \\ + K(Y_m - Y_{m-1}) + K^2(Y_{m-1} - Y_{m-2}) + \dots + K^n(Y_{m-n+1} - Y_{m-n}) \\ + [(\alpha_6 - \alpha_1)/5]K(1 - K^n)/(1 - K) \\ = Y_m + K^n[E(y'_{m-n}) - Y_{m-n}] \\ + [(1 - K)\bar{\alpha} + (A/5)(\alpha_1 - \bar{\alpha}) + K(\alpha_6 - \alpha_1)/5](1 - K^n)/(1 - K) \\ = Y_m + K^n[E(y'_{m-n}) - Y_{m-n} \\ + [(1 - K - A/5)\bar{\alpha} + (A/5)\alpha_1 + K(\alpha_6 - \alpha_1)/5](1 - K^n)/(1 - K)] \quad (A1.7)$$

qu'on peut simplifier de la manière suivante pour une valeur suffisamment grande de m et le cas où $\bar{\alpha} = 0$:

$$E(y'_m) = Y_m + [A\alpha_1 + K(\alpha_6 - \alpha_1)]/[5(1 - K)]. \quad (A1.8)$$

Comme le biais de y'_m dans le modèle construit ici est indépendant de m,

l'écart entre les estimations composites relatives à deux mois séparés par un intervalle r sont sans biais. Bref :

$$E(y'_m - y_{m-r}) = Y_m - Y_{m-r} \text{ pour tout } r. \quad (A1.9)$$

ANNEXE II

Calcul de la variance de l'estimateur composite

Nous supposons que les estimateurs composites (voir l'équation (2.2)) sont devenus assez stables d'une période à l'autre et que, par conséquent, $V(y'_{m-1}) = V(y'_m)$. Comme toutes les corrélations à douze mois ou plus d'intervalle sont nulles par hypothèse, nous supposons que les estimateurs composites de l'EPA se sont stabilisés après douze mois.

En prenant la variance des deux membres de (A1.3) et appliquant l'hypothèse susmentionnée, on peut calculer $V(y'_m)$ et obtenir le résultat suivant :

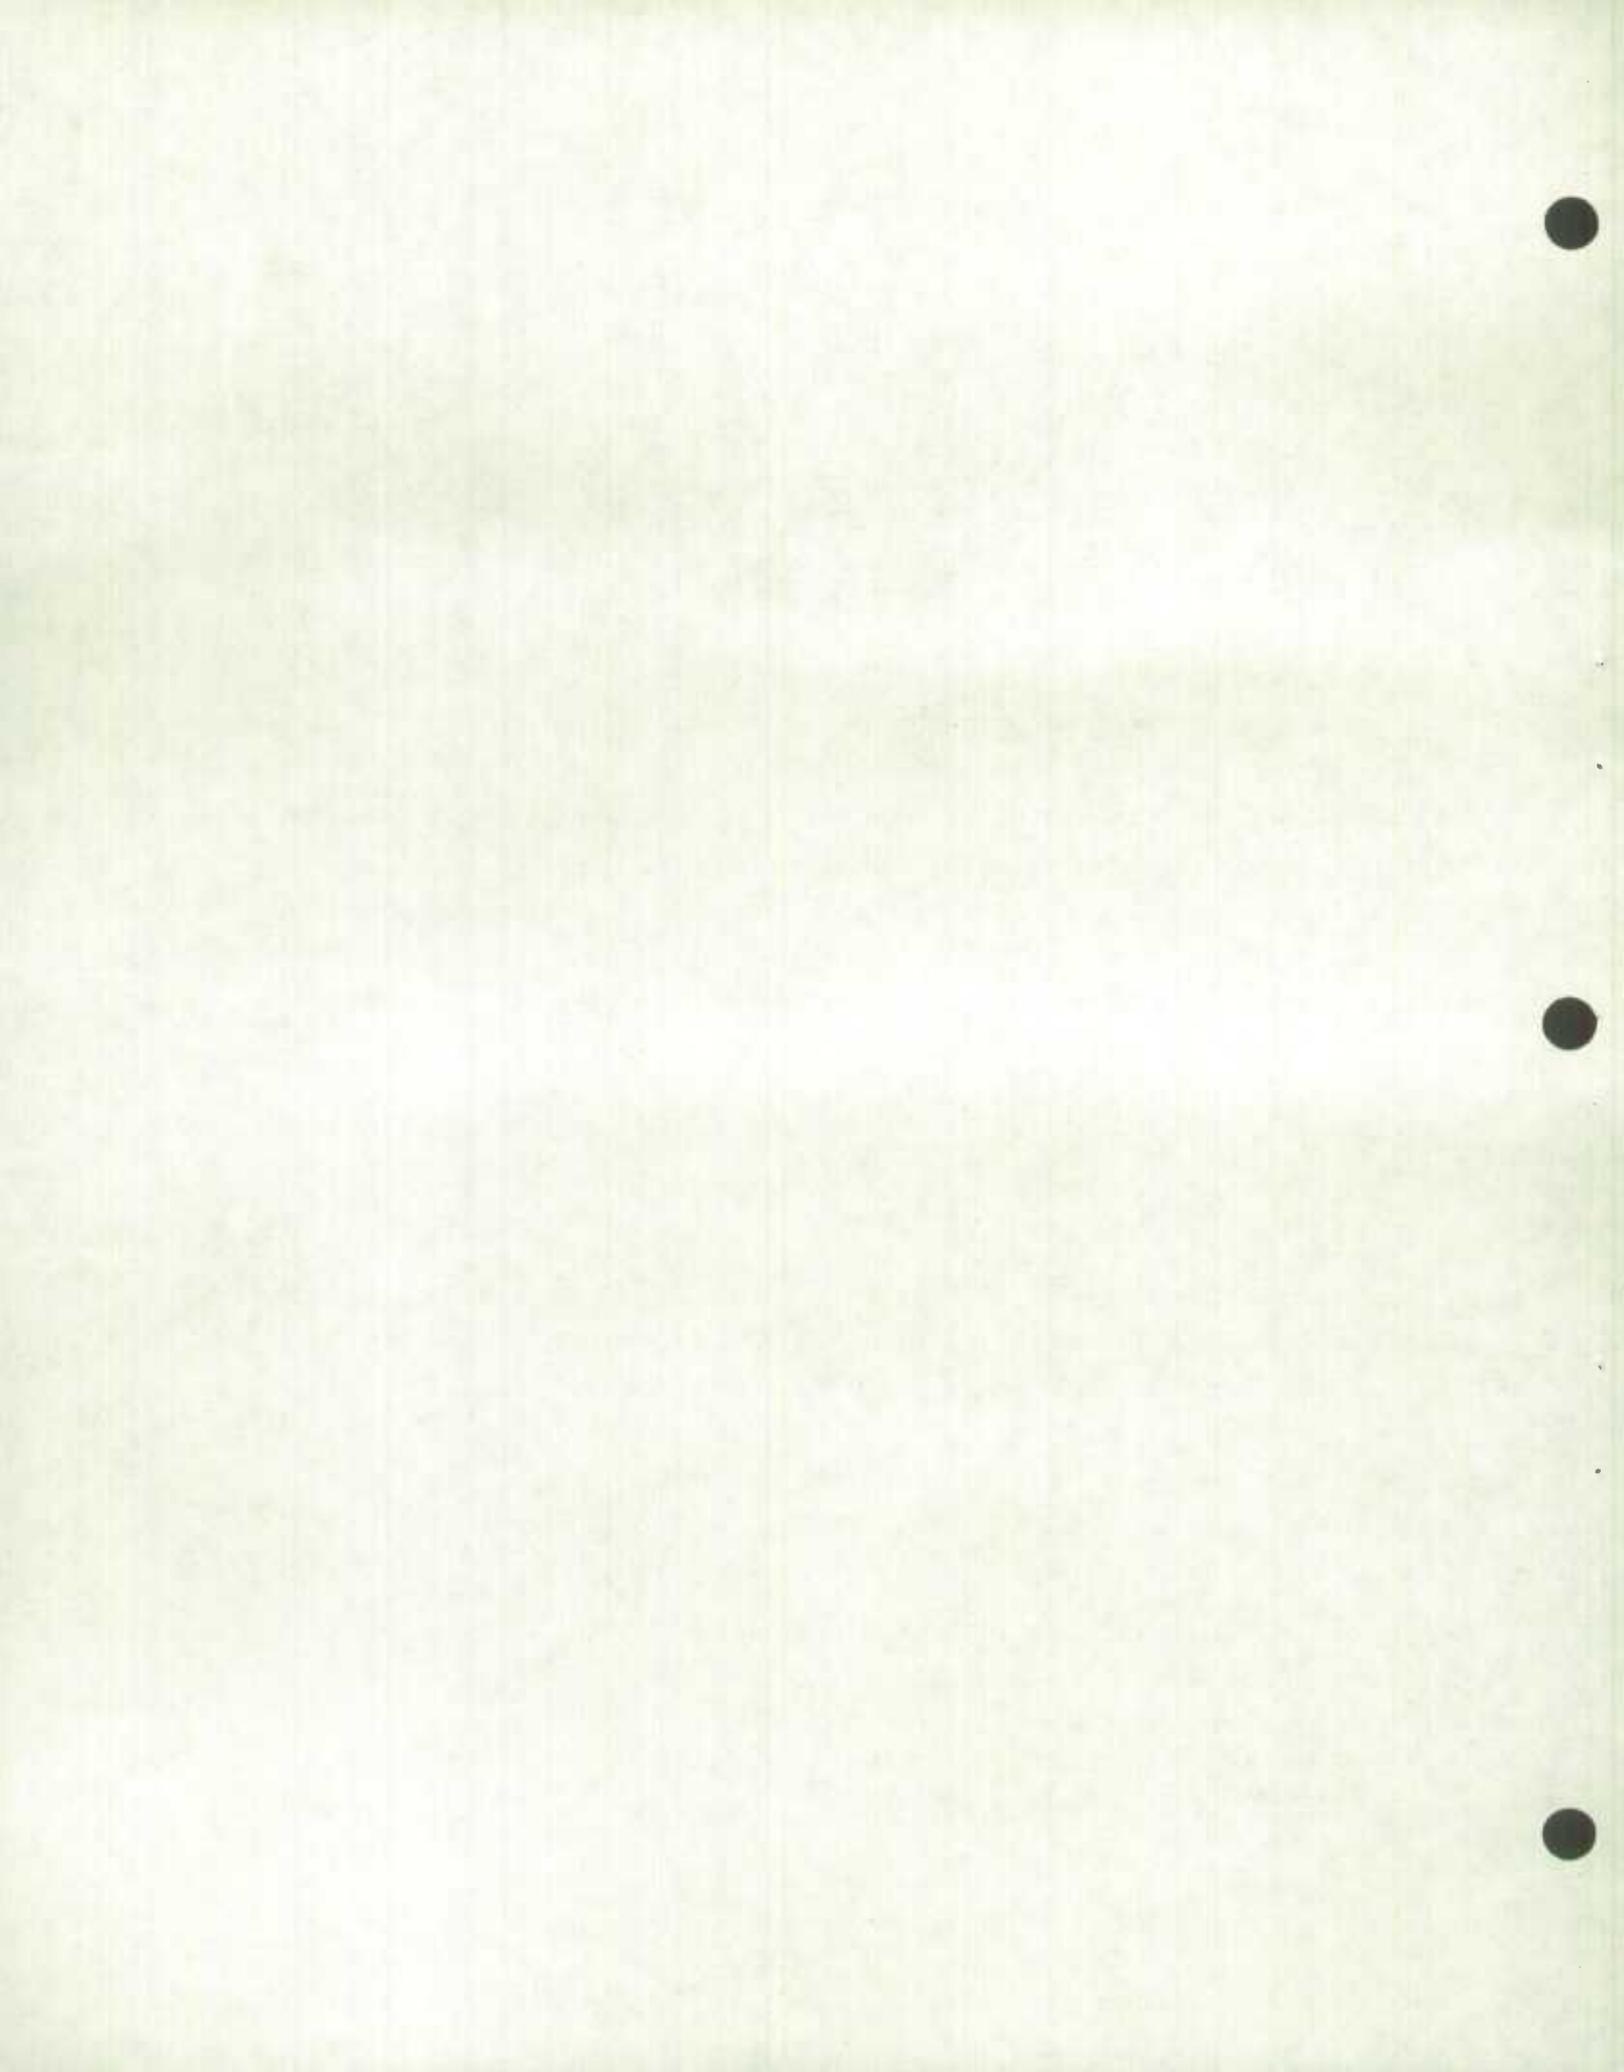
$$V(y'_m) = [V(y_m) + K^2 V(d_{m,m-1}) + 2K \text{Cov}(y_m, d_{m,m-1}) + 2K \text{Cov}(y_m, y'_{m-1}) + 2K^2 \text{Cov}(d_{m,m-1}, y'_{m-1})] / (1 - K^2). \quad (A2.1)$$

Pour éliminer y'_{m-1} du membre de droite de (A2.1), on peut prendre l'équation (A1.6), remplacer m par $(m - 1)$ et n par 12 pour obtenir :

$$y'_{m-1} = \sum_{g=1}^{12} (K^{g-1} y'_{m-g} + K^g d_{m-g,m-g-1}) + K^{12} y'_{m-13}. \quad (A2.2)$$

Si on reporte l'équation (A2.2) dans l'équation (A2.1) et qu'on supprime les termes nuls, le résultat est :

$$V(y'_m) = \{V(y_m) + K^2 V(d_{m,m-1}) + 2K \text{Cov}(y_m, d_{m,m-1})$$



$$\begin{aligned}
 & + 2 \sum_{q=1}^{12} K^q [\text{Cov}(y_m, y_{m-q}) + K \text{Cov}(d_{m,m-1}, y_{m-q}) \\
 & + K \text{Cov}(y_m, d_{m-q, m-q-1}) \\
 & + K^2 \text{Cov}(d_{m,m-1}, d_{m-q, m-q-1})] / (1 - K^2). \tag{A2.3}
 \end{aligned}$$

Les expressions qui définissent les variances et les covariances qui figurent dans le membre de droite de (A2.3) peuvent être facilement calculées à partir des équations (2.1) et (A1.3). Ainsi, on obtient

$$V(y_m) = [(1 - K^2/6 + A^2/30)\sigma^2], \tag{A2.4}$$

qui correspond simplement à $\sigma^2/6$ quand $A = K = 0$; par conséquent,

$$V(\bar{y}_m) = \sigma^2/6 \tag{A2.4a}$$

est la variance de l'estimateur utilisé actuellement dans l'EPA.

$$V(d_{m,m-1}) = 2\sigma^2(1 - \rho_1)/5. \tag{A2.5}$$

$$\text{Cov}(y_m, d_{m,m-1}) = (1 - K)(1 - \rho_1)\sigma^2/6 - A(1 - \rho_1)\sigma^2/30. \tag{A2.6}$$

Pour calculer les autres covariances de l'équation (A2.3) qui comportent un retard g , définissons une fonction indicatrice $I(a, b)$:

$$\begin{aligned}
 I(a, b) &= 1 \text{ si } a \leq b \\
 &= 0 \text{ autrement.}
 \end{aligned}$$

Si on examine la définition de y_m dans l'équation (A1.3) et de $d_{m,m-1}$ dans l'équation (2.1) et les expressions correspondantes pour le mois $(m - g)$, on peut conclure que les covariances suivantes sont nécessaires pour calculer les autres covariances de (A2.3) :

$$\text{Cov}(\bar{y}_m, \bar{y}_{m-g}) = (\sigma^2/36)[(6 - g)\rho_g I(g, 5) + (6 - |7 - 6|)\gamma_g],$$

$$\text{Cov}(\bar{y}_m, y_{m-q-1}) = (\sigma^2/6)[\rho_q I(q, 5) + \gamma_q I(6, q)],$$

$$\text{Cov}(y_{m,1}, \bar{y}_{m-q}) = (\sigma^2/6)\gamma_q I(q, 6),$$

$$\text{Cov}(y_{m,1}, y_{m-q,1}) = \sigma^2 I(q, 6) I(6, q) \gamma_6 \text{ (expression nulle sauf quand } q = 6\text{).}$$

$$\text{Cov}(y_{m-1,6}, \bar{y}_{m-g}) = (\sigma^2/6)[\rho_{q-1} I(q, 6) + \gamma_{q-1} I(7, g)],$$

$$\text{Cov}(y_{m-1,6}, y_{m-q-1}) = \sigma^2 [\rho_{q-1} I(q, 6) I(6, q)],$$

$$\text{Cov}(\bar{y}_m, y_{m-q-1,6}) = (\sigma^2/6)\gamma_{q+1} I(q, 5),$$

$$\text{Cov}(y_{m,1}, y_{m-g-1,6}) = \sigma^2 \gamma_1 I(q, 0) I(0, q) \text{ (expression nulle pour } q \geq 1\text{)} \quad (\text{A2.7})$$

Les quatre covariances de (A2.3) qui comprennent le retard q peuvent alors être définies comme suit :

$$\begin{aligned} \text{Cov}(y_m, y_{m-q}) &= \sigma^2 \rho_q I(q, 5) [(1 - K)^2 (6 - q)/36 \\ &\quad + A(1 - K)(q - 3)/90 - gA^2/900] \\ &\quad + \sigma^2 \gamma_g [(1 - K)^2 (6 - |g - 6|)/36 \\ &\quad + A(1 - K)(|g - 6| - 3)/90 - |g - 6|A^2/900] \\ &\quad + \sigma^2 \gamma_q I(q, 6) I(6, g) A(1 - K + A)/30. \end{aligned} \quad (\text{A2.8})$$

$$\begin{aligned} \text{Cov}(d_{m,m-1}, y_{m-g}) &= \sigma^2 (\rho_q - \rho_{q-1}) I(q, 5) [(1 - K)(6 - g)/30 + gA/150] \\ &\quad + \sigma^2 (\gamma_g - \gamma_{q-1}) [(1 - K)(6 - |q - 6|)/30 + |q - 6|A/150 \\ &\quad - (1 - K + A) I(q, 6)/30]. \end{aligned} \quad (\text{A2.9})$$

$$\text{Cov}(y_m, d_{m-g,m-g-1}) = \sigma^2 (\rho_q - \rho_{q+1}) I(q, 5) (1 - K - A/5)(5 - q)/30,$$

$$+ \sigma^2(\gamma_q - \gamma_{q+1})[(1 - K - A/5)(6 - I(6, q) - (q - 6)/30 + AI(q, 5)/25], \quad (A2.10)$$

$$\text{Cov}(d_{m,m-1}, d_{m-q, m-q-1}) = \sigma^2[(5 - q)(2\rho_q - \rho_{q-1} - \rho_{q+1})I(q, 5) + 5 - (q - 6)(2\gamma_q - \gamma_{q-1} - \gamma_{q+1})]/25. \quad (A2.11)$$

On peut donc exprimer $V(y'_m)$ sous la forme d'une équation de type $aA^2 + bA + c = f(A)$, où a , b et c sont des fonctions de K , des ρ et des γ . On peut démontrer que $a \geq 0$. La valeur de A qui réduit au minimum la variance de l'estimateur AK a été déterminé pour $K = 0(0.1)0.9$. Parmi toute la série de couples (A, K) dans cet intervalle, la valeur optimale de (A, K) a été choisie et c'est ce couple qui est présenté au tableau 4A.

ANNEXE III

Calcul de la variance de $y'_m - y'_{m-1}$

Prenons l'équation (A1.3) :

$$y'_m = y_m + K(y'_{m-1} + d_{m,m-1}), \text{ qu'on peut récrire de la manière suivante :}$$

$$y'_m - Ky'_{m-1} = y_m + Kd_{m,m-1},$$

d'où il découle que

$$(1 + K^2)V(y'_m) - 2KCov(y'_m, y'_{m-1}) = V(y_m) + 2KCov(y_m, d_{m,m-1}) + K^2V(d_{m,m-1}).$$

Quand $K \neq 0$, on peut obtenir l'expression de $Cov(y'_m, y'_{m-1})$ à partir de l'équation ci-dessus et, en faisant des substitutions à l'aide des équations (A2.4),

(A2.5) et (A2.6) et en utilisant le fait que $V(y'_m - y'_{m-1}) = 2V(y'_m) - 2Cov(y'_m, y'_{m-1})$, on obtient le résultat suivant pour $K \neq 0$:

$$V(y'_m - y'_{m-1}) = \sigma^2[A^2/30 - (1 - \rho_1)KA/15 + (1 - K)^2/6 + (1 - \rho_1)K(K + 5)/15]/K - (1 - K)^2V(y'_m)/K. \quad (A3.1)$$

Quand $K = 0$,

$$y'_m = (1 - A/5)\bar{y}_m + Ay_{m,1}/5, \text{ et}$$

$$Cov(y'_m, y'_{m-1}) = Cov[(1 - A/5)\bar{y}_m + Ay_{m,1}/5, (1 - A/5)\bar{y}_{m-1} + Ay_{m-1,1}/5]. \quad (A3.2)$$

Ainsi, pour $K = 0$:

$$V(y'_m - y'_{m-1}) = \sigma^2[(1/15 + \rho_1/450 + \gamma_1/90)A^2 + 2(\rho_1 - \gamma_1)A/45 + 1/3 - (5\rho_1 + \gamma_1)/18]. \quad (A3.3)$$

BIBLIOGRAPHIE

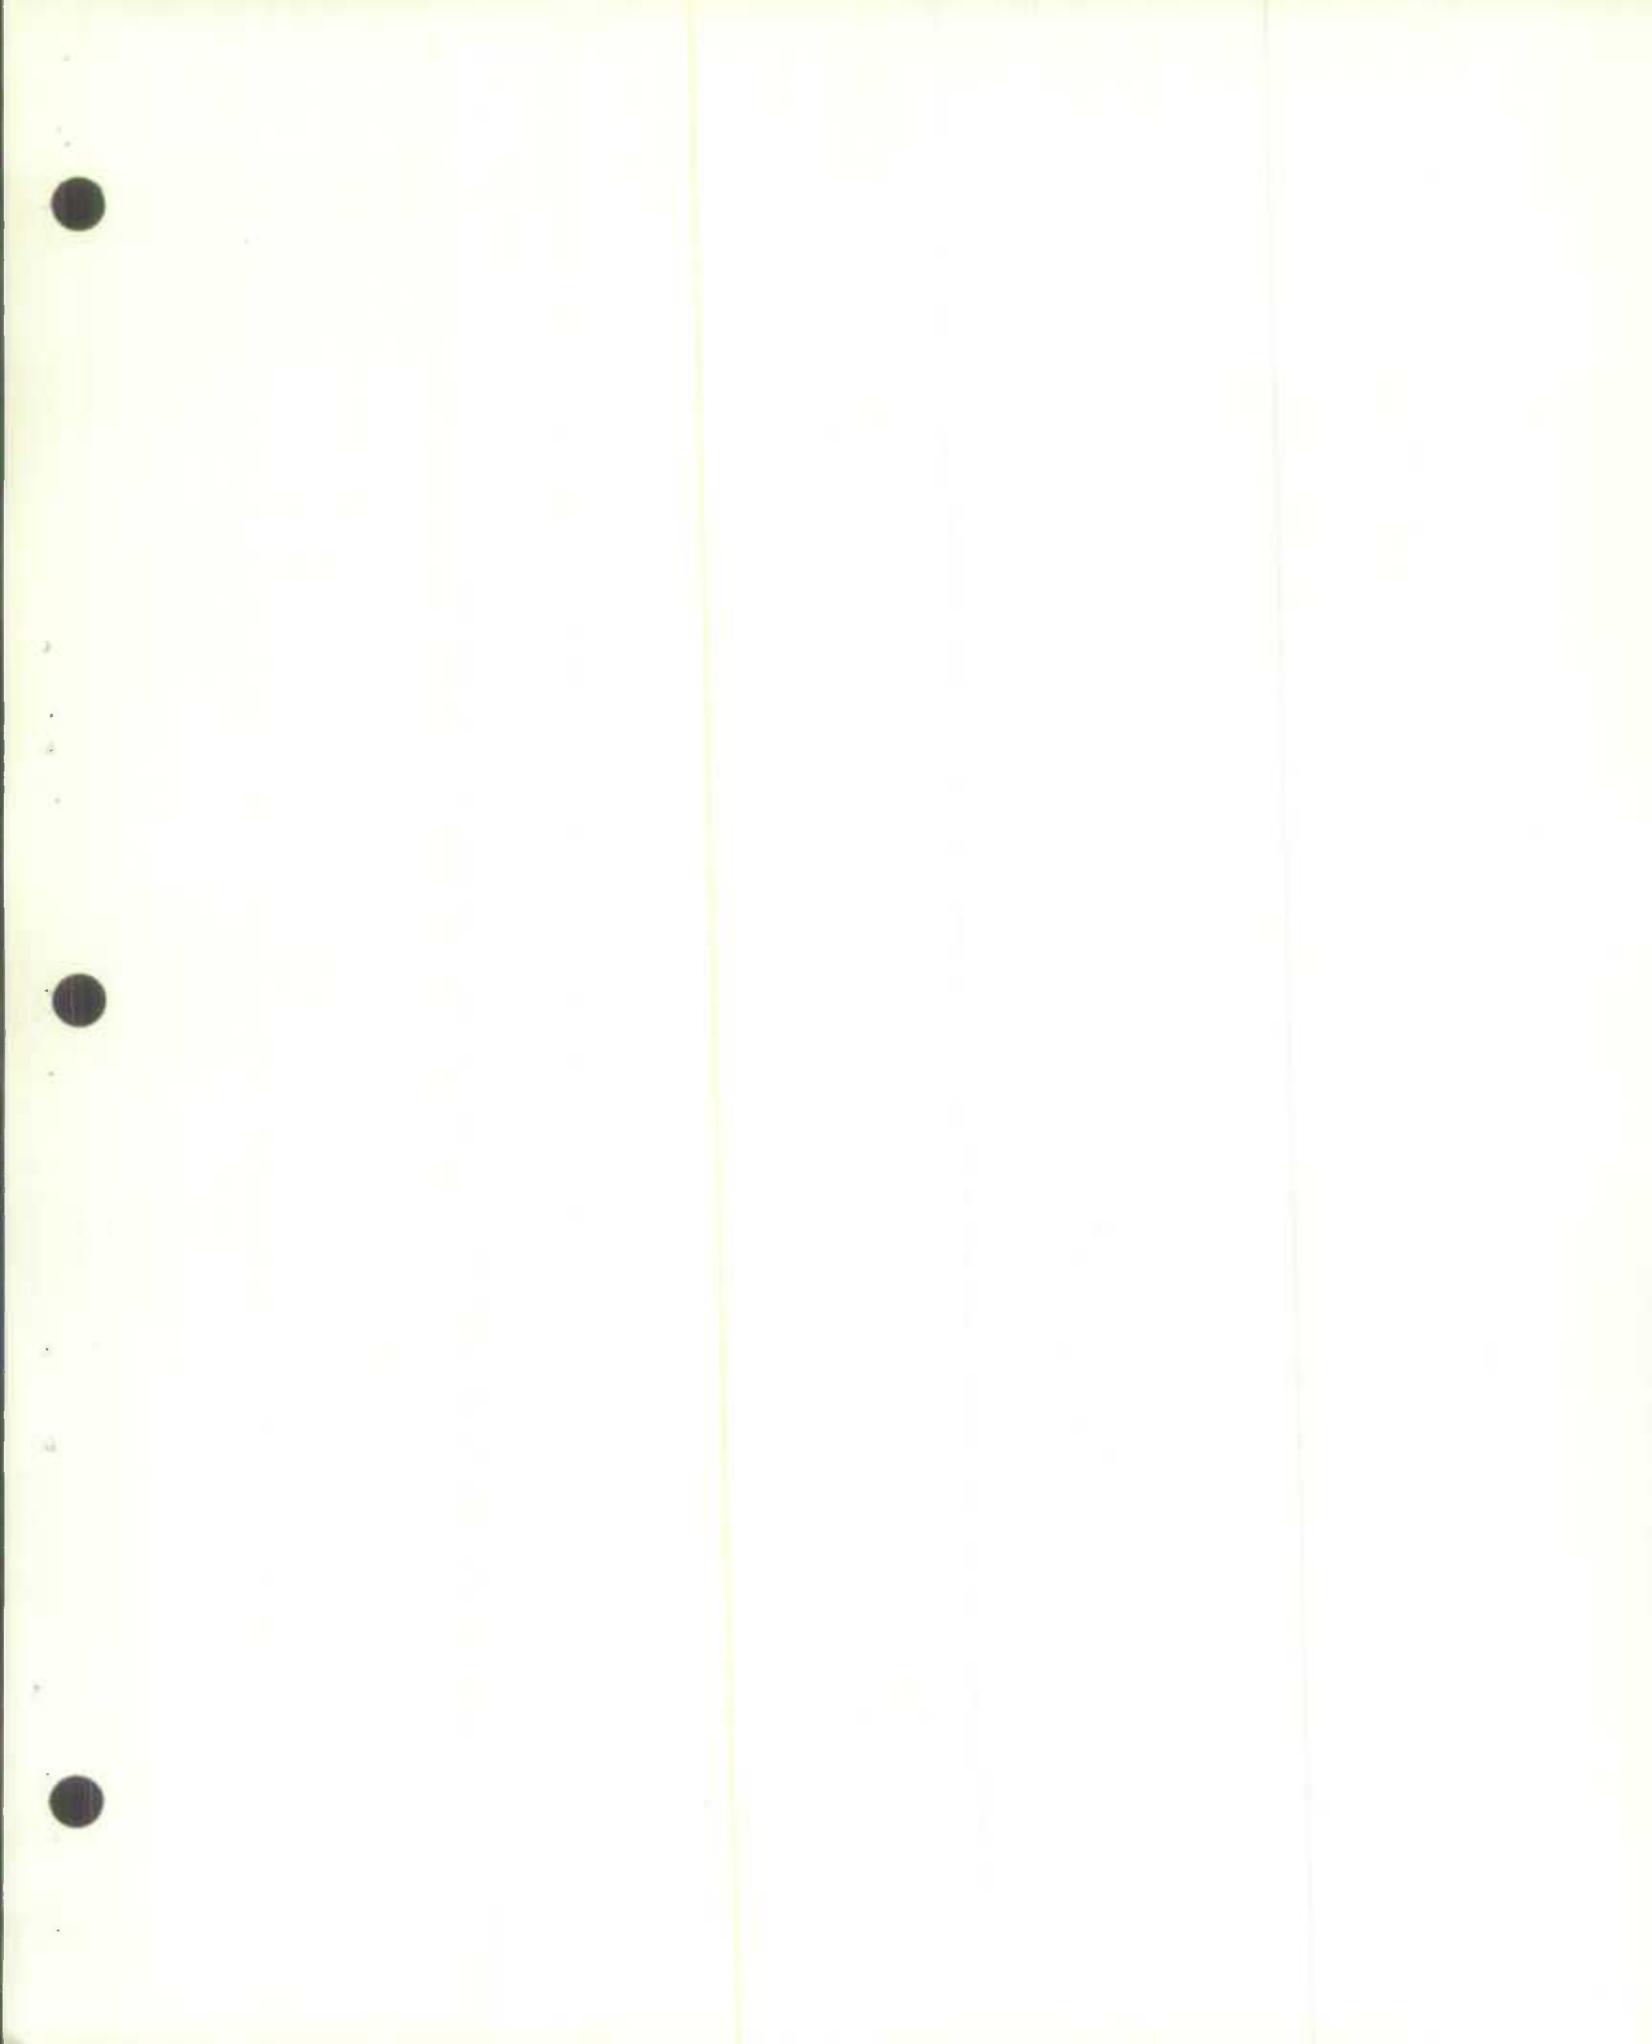
- [1] Bailar, B.A., "The Effects of Rotation Group Bias on Estimates from Panel Surveys", Journal of the American Statistical Association, 70, 23-29, 1975.
- [2] Ghangurde, P.D., "Le biais de renouvellement de l'échantillon dans les estimations de l'EPA", Techniques d'enquête, 8, 86-101, 1982.
- [3] Gurney, M. et Daly, J.F., "A Multivariate Approach to Estimation in Periodic Sample Surveys", Proceedings of the Social Statistics Section, American Statistical Association, 242-257, 1965.

Ca 008

STATISTICS CANADA LIBRARY
BIBLIOTHÈQUE STATISTIQUE CANADA



1010148740



[Redacted]