

برآورد واریانس برآوردهای کالیبیره مجموع جامعه با مجموع جامعه کمکی نامعلوم

ابراهیم خدایی^۱، سیدروح‌الله شجاعی‌کیاسری^۲

^۱ دانشگاه تهران، سازمان سنجش آموزش کشور

^۲ بانک مرکزی جمهوری اسلامی ایران

تاریخ دریافت: ۱۳۹۰/۱۰/۳ تاریخ آخرین بازنگری: ۱۳۹۱/۵/۱۶

چکیده: به کارگیری متغیرهای کمکی برای اصلاح برآوردهای روشی متداول در آمار و به خصوص بررسی‌های نمونه‌ای است. به عنوان مثال می‌توان به برآوردهای نسبتی و رگرسیونی در نمونه‌گیری اشاره کرد. با فرض معلوم بودن مجموع جامعه کمکی و برقرار بودن یکسری شرایط، برآوردهای کالیبیره و واریانس آنها را می‌توان با استفاده از برآوردهای رگرسیونی تعیین یافته به دست آورد. در این مقاله، با فرض نامعلوم بودن مجموع متغیر کمکی در جامعه، برآوردهای کل و واریانس آن در جامعه هدف با روش رگرسیون تعیین یافته به دست آورده می‌شود. سپس نشان داده می‌شود برآوردهای ارائه شده برای مجموع کل جامعه از نظر کارایی بهتر از برآوردهای هورویتز-تاپسون است. آنگاه نظریه به دست آمده با شبیه‌سازی به روش MCMC در طرح نمونه‌گیری طبقه‌بندی مورد بررسی قرار می‌گیرد.

واژه‌های کلیدی: آماره کمکی، برآوردهای رگرسیونی تعیین یافته، برآوردهای کالیبیره، نمونه‌گیری طبقه‌بندی، روش‌های مونت کارلوی زنجیر مارکوفی.

آدرس الکترونیک مسئول مقاله: ابراهیم خدایی، khodaie@yahoo.com
کد موضوع‌بندی ریاضی (۲۰۰۰): ۰۵۶۲D

۱ مقدمه

فرض کنید هدف انجام نمونه‌گیری از جامعه‌ای متناهی باشد. شمول عضو k ام جامعه در نمونه تصادفی S , یک واقعه تصادفی است که می‌توان آن را بر اساس متغیر تصادفی نشانگر به صورت

$$I_k = \begin{cases} 1 & k \in S \\ 0 & k \notin S \end{cases}$$

نشان داد. منظور از S واقعه‌ای تصادفی است که نمونه تصادفی S شامل عضو k ام جامعه باشد. به این ترتیب احتمال شمول^۱ عضو k ام جامعه در نمونه تصادفی S به صورت $P(k \in S) = P(I_k = 1) = P(\pi_k)$ تعریف می‌شود. به همین ترتیب احتمال شمول توأم دو عضو ℓ و k در نمونه تصادفی S را به صورت $\pi_{k\ell} = Pr(k\&\ell \in S)$ نشان داده می‌شود. این احتمال‌های شمول با توجه به طرح نمونه‌گیری تعیین می‌شوند. همچنین معکوس احتمال شمول، $d_k = \frac{1}{\pi_k}$ ، وزن نمونه‌ای نامیده می‌شود.

براساس نظریه کالیبراسیون، وزن‌های نمونه‌ای با داشتن مجموع کل جامعه کمکی کالیبره می‌شوند. اولین نگاه جدی به کالیبره کردن وزن‌ها به عنوان یک روش برآورده کردن توسط دویل و سارندال (۱۹۹۲) انجام گرفت، که نشان دادند کلاس وسیعی از برآوردهای کالیبره با طرح‌های مختلف نمونه‌ای سازگار هستند. به علاوه تحت شرایطی به صورت مجذوب معادل برآوردهای روش رگرسیون تعیین یافته می‌باشند.

فرض اساسی در برآورد کردن پارامتر جامعه (مجموع کل جامعه هدف)، با روش رگرسیون تعیین یافته، معلوم بودن مجموع کل متغیرهای کمکی است. اگر این مجموع‌ها نامعلوم باشند، ممکن است ابتدا با استفاده از یک نمونه مقدماتی از مقادیر جامعه کمکی مقدار مجموع نامعلوم کمکی را برآورد نموده، سپس با زیر نمونه‌ای از آن، که شامل مقادیر توأم متغیر هدف و کمکی است، یا روش رگرسیونی مقدار نامعلوم مجموع جامعه هدف را برآورد کرد. سیتر (۱۹۹۷) با این روش که نمونه‌گیری مجدد نام دارد، برآوردهای را ارائه داد و واریانس آن را نیز به چند صورت نشان داد. با استفاده از ایده باز نمونه‌گیری محققه‌انی چون رائو و سیتر (۱۹۹۵)، سیتر (۱۹۹۷)، بیندر و همکاران (۲۰۰۶) و کیم و همکاران (۲۰۰۶) پارامتر جامعه را با استفاده از اطلاعات کمکی برآوردهای رگرسیونی و نسبتی برآورد نموده و واریانس‌هایی برای آنها ارائه داده‌اند. در این مقاله فرض بر این است که نمونه‌های S_1 و S ، به ترتیب، به حجم n_1 و n در دست هستند که S_1 فقط شامل مقادیر

^۱ Inclusion Probability

متغیرهای کمکی و S شامل مقادیر توانی از متغیر هدف و متغیرهای کمکی هستند. برای توجیه استفاده از نمونه S_1 به جای نمونه S در برآورد مجموع نامعلوم جامعه کمکی کمترین فرض این است که حجم S_1 از حجم S بزرگتر است، یعنی $n_1 > n$. با این نظر، برآوردهای برای مجموع کل جامعه هدف و فرمولی برای واریانس مجانبی آن ارائه و با سایر روش‌ها مقایسه می‌شود. برآوردهای برآوردهای به دست آمده در این مقاله نسبت به برآوردهای رگرسیون تعمیم‌یافته با فرض معلوم بودن جامعه کمکی کمتر کارا بوده ولی نسبت به برآوردهای هورویتز-تمپسون^۲ از کارایی بهتری برخوردار خواهد بود.

در بخش ۲ مقاله نظریه کالیبراسیون و روش رگرسیون تعمیم‌یافته مطرح می‌شود. در بخش ۳ برآوردهای مجموع کل جامعه هدف با فرض نامعلوم بودن مجموع متغیرهای کمکی به همراه واریانس آن ارائه می‌شود. در بخش ۴ صحبت نظریه‌های ارائه شده با شبیه‌سازی مورد بررسی قرار می‌گیرد. در بخش پایانی بحث و نتیجه‌گیری ارائه خواهد شد.

۲ کالیبره و برآوردهای رگرسیون تعمیم‌یافته

شرح کامل برآوردهای کالیبره توسط دویل و سارن‌دال (۱۹۹۲) ارائه شده است. در این روش برآوردهای کالیبره $\hat{t}_{yw} = \sum_S w_k y_k$ برای برآوردهای مجموع کل جامعه، $t_y = \sum_U y_k$ طوری ارائه می‌شود که وزن‌های w_k با توجه به قید

$$\sum_S w_k x_k = \sum_U x_k$$

به وزن‌های طرح نمونه‌ای، $d_k = \frac{1}{\pi_k}$ ، تا حد ممکن نزدیک باشند. فرض کنید U جامعه متناهی $\{(x_k, y_k), k = 1, \dots, N\}$ و S نمونه‌ای تصادفی به حجم n از جامعه U و π_k احتمال شمول عضو k ام جامعه در نمونه است. در این روش یکتابع فاصله دلخواه $G_k(w, d)$ تحت شرایط، به منظور حداقل کردن فاصله وزن‌های w_k به وزن‌های طرح نمونه‌ای d_k ، تعریف می‌شود.

شرط ۱: برای هر مقدار ثابت $0 < d$ ، تابع $G_k(w, d)$ نامنفی، نسبت به w مشتق‌پذیر، اکیداً محدب، روی بازه (d, D_k) است، تعریف شده باشد و داشته باشیم $G_k(d, d) = 0$.

^۲ Horitz-Thompson Estimator

شرط ۲: مشتق جزئی $g_k(w, d) = \partial G_k(w, d) / \partial w$ را روی بازه $D_k(d)$ پیوسته باشد و $g_k(w, d)$ تابعی اکیداً صعودی نسبت به w است و $g_k(d, d) = 0$.

بدیهی است که برای خانواده توابع فاصله‌ای $G_k(w, d)$, که در دو شرط ۱ و ۲ صدق کنند، خانواده‌ای از برآوردهای کالیبره پدید می‌آید که هر عضو آن، برآوردهای کالیبره متناظر با یک تابع فاصله از خانواده توابع فاصله $G_k(w, d)$ است. در این میان برآوردهای کالیبره‌ای که توسط تابع فاصله

$$G_k(w, d) = \sum_S \frac{(w_k - d_k)^2}{d_k q_k}$$

پدید می‌آید، همان برآوردهای رگرسیونی تعمیم یافته است.

۱.۲ برآوردهای رگرسیونی تعمیم یافته

بنابر تعریف سارن دال و همسکاران (۱۹۹۲)، بردار متغیرهای کمکی \mathbf{x} را در نظر بگیرید که مقدار آن برای k امین واحد جامعه $(x_{1k}, \dots, x_{jk})'$ است. هدف برآورد مقدار نامعلوم کل جامعه، $t_y = \sum_U y_k$ با استفاده از اطلاعات بردار متغیر کمکی \mathbf{x} است. با فرض آن که مقدار کل جامعه کمکی، یعنی بردار $\mathbf{t}_x = \sum_U \mathbf{X}_k$ ، معلوم است، نمونه S با طرح نمونه‌گیری (\cdot, p) از جامعه U استخراج می‌شود، که در آن (S, p) احتمال برآمد نمونه S در نمونه‌گیری از جامعه U است. در این مقاله صرفاً طرح‌های نمونه‌گیری اندازه‌پذیر مورد نظر است که احتمال‌های شمول $P(k \in S)$ و $\pi_{kl} = P(k \in S, l \in S)$ اکیداً برگتر از صفر هستند. به این ترتیب برآوردهای رگرسیونی تعمیم یافته برای مقدار کل y عبارت است از

$$\hat{t}_{y\pi} = \hat{t}_{y\pi} + \sum_{j=1}^J \hat{B}_j (t_{xj} - \hat{t}_{xj\pi}) \quad (1)$$

که در آن

$$\hat{t}_{y\pi} = \sum_S \frac{y_k}{\pi_k} = \sum_S d_k y_k = \sum_S \check{y}_k$$

برآوردهای هورویتز-تامپسون و $t_y = \sum_U y_k$

$$\hat{t}_{x_j\pi} = \sum_S \frac{x_{jk}}{\pi_k} = \sum_S d_k x_{jk} = \sum_S \check{x}_{jk}$$

به‌ازای هر $J = 1, \dots, n$ و برآورده‌گر هورویتز-ستامپسون مجموع (معلوم) جامعه x_{sj} و \hat{B}_j ها مؤلفه‌های بردار

$$\hat{B} = (\hat{B}_1, \dots, \hat{B}_J)' = \left(\sum_S \frac{x_k x'_k}{\sigma_k^2 \pi_k} \right)^{-1} \sum_S \frac{x_k y_k}{\sigma_k^2 \pi_k} \quad (2)$$

هستند، که در آن σ_k^2 واریانس متغیر تصادفی Y_k با برآمد y_k است. برآورده‌گر رگرسیونی تعیین‌یافته که خود عضوی از خانواده برآورده‌گرهای کالیبره است، در وضعیتی که حجم جامعه و نمونه بزرگ باشند و تحت شرایطی خاص، که در ادامه ذکر خواهد شد، به نوعی نقطه همگرایی همه اعضای خانواده برآورده‌گرهای کالیبره است (دویل و سارن‌دال، ۱۹۹۲). فرض کنید حجم جامعه N و به همراه آن حجم نمونه n به تدریج بزرگ شوند و برای هر بردار از مقادیر متغیر کمکی \mathbf{x} شرایط زیر برقرار باشند.

(1) حد $N^{-1} t_x$ موجود باشد.

(2) $N^{-1}(\hat{t}_x - t_x)$ در احتمال به صفر میل کند.

(3) $n^{\frac{1}{4}} N^{-1}(\hat{t}_x - t_x)$ در توزیع به نرمال چند متغیره $(\mathbf{o}, \mathbf{A}) \mathcal{N}$ میل کند.

در این صورت برآورده‌گر کالیبره \hat{t}_{yw} ، به طور مجانبی با برآورده‌گر رگرسیونی \hat{t}_{yr} که در رابطه (1) معروفی شد، هم‌ارز است (به این مفهوم: $O_p(n^{-1})(\hat{t}_{yw} - \hat{t}_{yr}) = O_p(n^{-1})$). به عنوان یک نتیجه، دو برآورده‌گر، واریانس‌های مجانبی (AV) یکسان خواهند داشت. اما فرم خانوادگی برآورده‌گر رگرسیونی تعیین‌یافته به عنوان یک برآورده‌گر کالیبره عبارت است از

$$\hat{\mathbf{T}} = \sum_S \frac{\mathbf{x}_k \mathbf{x}'_k}{\sigma_k^2 \pi_k} \quad \text{که در آن } \hat{\mathbf{T}} = \sum_S \frac{q_{ks}}{\pi_k} y_k$$

$$g_{ks} = 1 + (t_x - \hat{t}_{x\pi})' \hat{\mathbf{T}}^{-1} x_k / \sigma_k^2 \quad (3)$$

۳ برآورده‌گر رگرسیونی تعیین‌یافته و کالیبره مجموع جامعه

در این بخش وضعیتی بررسی می‌شود که آماره کمکی مناسبی برای برآورد بهتر مجموع جامعه اصلی Y ، در دست است، اما مجموع این جامعه، t_x ، نامعلوم است. در اینصورت برآورده‌گر هدف، معمولاً با روش نمونه‌گیری مجدد انجام می‌شود. در اینجا به مسایلی پرداخته می‌شود که عملاً نمونه‌ای مناسب برای متغیرهای کمکی در دست است که برای

^۲ Asymptotic Variance

برآورده مجموع جامعه کمکی، نسبت به نمونه‌ای که محقق برای برآورده مجموع جامعه هدف، از جامعه کمکی و هدف تهیه می‌کند بهتر است. فرض بر این است که نمونه‌های S_1 و S با n_1 و n در اختیارند که S_1 تنها شامل مقادیر متغیرهای کمکی و S شامل مقادیر توأمی از متغیرهای هدف و کمکی هستند. ضمناً برای توجیه استفاده از نمونه S_1 به جای نمونه S در برآورده مجموع جامعه کمکی، کمترین فرض این است که $n_1 > n$.

تعريف ۱ : برآورده رگرسیونی تعمیم‌یافته برای مجموع جامعه اصلی Y , t_y , وقتی که مجموع جامعه کمکی X , t_x , نامعلوم است به صورت

$$\hat{t}_{y\pi_1} = \hat{t}_{y\pi} + (\hat{t}_{x\pi_1} - \hat{t}_{x\pi})' \hat{B} \quad (4)$$

است، که در آن \mathbf{x}_k/π_{1k} برآورده هورویتز-تامپسون مجموع جامعه کمکی از روی نمونه S_1 است و $\pi_{1k} = P(k \in S_1)$.

لم ۱ (سارندال و همکاران، ۱۹۹۲): برآورده رگرسیونی \hat{t}_{yr} که در رابطه (۱) معرفی شد، توسط خطی‌سازی تیلور^۴ به صورت

$$\hat{t}_{yr} = \hat{t}_{y\pi} + (\hat{t}_{x\pi_1} - \hat{t}_{x\pi})' B = \sum_U y_k^* + \sum_S \check{E}_k$$

تقریب می‌شود، که در آن $y_k^* = \mathbf{x}'_k \mathbf{B}$ و $E_k = y_k - y_k^*$ و $\check{E}_k = E_k/\pi_k$ و $B = (\sum_U \mathbf{x}_k \mathbf{x}'_k / \sigma_k^2)^{-1} \sum_U \mathbf{x}_k y_k / \sigma_k^2$. برآورده t_{yr} برای $t = \sum_U y_k$ تقریباً ناریب با واریانس تقریبی $AV(\hat{t}_{yr}) = \sum \sum_U \Delta_{kl} \check{E}_k \check{E}_\ell$ آن به صورت

$$\hat{V}(\hat{t}_{yr}) = \sum_S \sum_{kl} \check{\Delta}_{kl}(g_{ks} \check{e}_{ks})(g_{\ell s} \check{e}_{\ell s})$$

می‌باشد، که در آن $e_{ks} = y_k - \hat{y}_k$ و $\check{e}_{ks} = e_{ks}/\pi_k$ در رابطه (۳) داده شده است.

قضیه ۱ : واریانس مجانبی برآورده رگرسیونی تعمیم‌یافته (۴) به صورت

$$AV(\hat{t}_{y\pi_1}) = \sum_U \sum_{kl} \frac{\Delta_{kl}}{\pi_k \pi_\ell} E_k E_\ell + B' \left(\sum_U \sum_{kl} \frac{\Delta_{1kl}}{\pi_{1k} \pi_{1\ell}} x_k x'_\ell \right) B \quad (5)$$

است و برآورده آن نیز به صورت

$$\hat{A}(\hat{t}_{y\pi_1}) = \sum_S \sum_{kl} \frac{\Delta_{kl}}{\pi_{kl} \pi_k \pi_\ell} (g_{ks} e_{ks})(g_{\ell s} e_{\ell s}) + \hat{B}' \left(\sum_{s\ell} \sum_{kl} \frac{\Delta_{1kl}}{\pi_{1kl} \pi_{1\ell} \pi_{1k} \pi_{1\ell}} x_k x'_\ell \right) \hat{B} \quad (6)$$

^۴ Taylor linearization

$\hat{t}_{x\pi 1} = \sum_{S_1} \mathbf{x}_k / \pi_{1k} = P(k & \ell \in S_1) \pi_{1k} = P(k \in S_1)$ و $\pi_{1k} = P(k \in S_1)$ خواهد بود، که در آن برآورده‌گر هورویتز-تامپسون مجموع جامعه کمکی از روی نمونه S_1 است. $\hat{\mathbf{B}} = (\sum_U \mathbf{x}_k \mathbf{x}'_k / \sigma_k^2)^{-1} \sum_U \mathbf{f} \mathbf{x}_k y_k / \sigma_k^2$ نیز در رابطه (۲) تعریف شده است. همچنین $e_{ks} = y_k - \mathbf{x}'_k \hat{\mathbf{B}}$ و $E_k = y_k - \mathbf{x}'_k \mathbf{B}$ و نیز $\Delta_{1kl} = \pi_{1k} - \pi_{1k} \pi_{1l}$ و $\Delta_{kl} = \pi_{kl} - \pi_k \pi_l$ و g_{ks} نیز که در رابطه (۳) تعریف شده است.

برهان: بنا بر لم ۱، برآورده‌گر (۴) را می‌توان به طور تقریبی به صورت

$$\hat{t}_{y_{r1}} \simeq \hat{t}_{y\pi} + (\hat{t}_{x\pi 1} - \hat{t}_{x\pi})' B$$

نوشت و واریانس مجانبی آن را به صورت

$$\begin{aligned} AV(\hat{t}_{y_{r1}}) &= Var[\hat{t}_{y\pi} + (\hat{t}_{x\pi 1} - \hat{t}_{x\pi})' B] \\ &= Var[\hat{t}_{y\pi} + (t_x - \hat{t}_{x\pi})' B + \hat{t}'_{x\pi 1} B] \\ &= Var[\hat{t}_{y_{r0}} + \hat{t}'_{x\pi 1} B] \end{aligned}$$

محاسبه کرد، که در آن $\hat{t}_{y_{r0}}$ تقریب خطی سازی تیبلور y_{r0} معرفی شده در رابطه (۱) است. اما با توجه به فرض مجزا بودن نمونه‌های S_1 و S و درنتیجه استقلال آماره‌های متناظرشان می‌توان نوشت

$$AV(\hat{t}_{y_{r1}}) = Var(\hat{t}_{y_{r0}}) + Var(\hat{t}'_{x\pi 1} B) = AV(\hat{t}_{y_{r0}}) + B' Var(\hat{t}'_{x\pi 1} B) \quad (V)$$

بنابر لم ۱

$$AV(\hat{t}_{y_{r0}}) = \sum_U \sum_{kl} \frac{\Delta_{kl}}{\pi_k \pi_l} E_k E_\ell$$

و چون $\hat{t}_{x\pi 1}$ برآورده‌گر هورویتز-تامپسون است، رابطه (V) را می‌توان به صورت

$$AV(\hat{t}_{y_{r1}}) = \sum_U \sum_{kl} \frac{\Delta_{kl}}{\pi_k \pi_l} E_k E_\ell + \hat{B}' (\sum_U \sum_{kl} \frac{\Delta_{1kl}}{\pi_{1k} \pi_{1l}} x_k x'_\ell) B.$$

ادامه داد. همچنین به منظور برآورد آن با استفاده از لم ۱ داریم

$$\hat{V}(\hat{t}_{y_{r1}}) = \sum_S \sum_{kl} \frac{\Delta_{kl}}{\pi_{kl} \pi_k \pi_l} (g_{ks} e_{ks}) (g_{ls} e_{ls}) + \hat{B}' (\sum_{S_1} \sum_{kl} \frac{\Delta_{1kl}}{\pi_{1kl} \pi_{1k} \pi_{1l}} x_k x'_\ell) \hat{B}$$

مثال ۱ : با طرح نمونه‌گیری تصادفی ساده بدون جایگذاری، برآورده رگرسیونی تعیین یافته به صورت $\hat{t}_{yr \setminus SI} = \hat{t}_{y\pi SI} + (\hat{t}_{x\pi \setminus SI} - \hat{t}_{x\pi SI})' \hat{B}$ یا به طور معادل به فرم

$$\hat{t}_{yr \setminus SI} = N(\bar{y}_n + (\bar{x}_n - \bar{x}_n) \hat{B})$$

است. واریانس مجانية و برآورد آن با توجه به روابط (۵) و (۶) به ترتیب به صورت

$$\begin{aligned} V(\hat{t}_{yr \setminus SI}) &= N^2 S_y^2 \left(\left(\frac{1}{n} - \frac{1}{N} \right) + \rho^2 \left(\frac{1}{n_1} - \frac{1}{n} \right) \right) \\ \hat{V}(\hat{t}_{yr \setminus SI}) &= N^2 S_y^2 \left(\left(\frac{1}{n} - \frac{1}{N} \right) + r^2 \left(\frac{1}{n_1} - \frac{1}{n} \right) \right) \end{aligned} \quad (۸)$$

هستند، که نمادها و اثبات (۸) در پیوست الف ارائه شده‌اند.

مثال ۲ : جامعه‌ای متشکل از H طبقه را در نظر بگیرید که هر طبقه شامل N_h واحد، $y_k, h = 1, \dots, H$ ، به صورت (y_k, x_k) است، که در آن x_k مقدار متغیر تک‌بعدی کمکی و y_k مقدار متغیر هدف هستند. با فرض آن که مجموع هر دو جامعه کمکی X و هدف Y نامعلوم هستند با استفاده از برآورده (۴)، مجموع جامعه هدف را برآورد می‌کنیم. در اولین گام برای مشخص شدن احتمال‌های شمول، طرح نمونه‌گیری طبقه‌بندی به روش تصادفی ساده بدون جایگذاری در نظر گرفته می‌شود. در این صورت

$$\hat{t}_{x\pi \setminus} = \sum_{h=1}^H \frac{N_h}{n_h} \sum_{S_h} x_k, \hat{t}_{x\pi} = \sum_{h=1}^H \frac{N_h}{n_h} \sum_{S_h} x_k, \hat{t}_{y\pi} = \sum_{h=1}^H \frac{N_h}{n_h} \sum_{S_h} y_k$$

که در آن‌ها اندیس h ، به منظور منتنسب کردن نماد مورد نظر به طبقه h است. سارن‌دال و همکاران (۱۹۹۲) نشان دادند

$$\hat{B} = \frac{\sum_{h=1}^H \frac{N_h}{n_h} \sum_{S_h} x_k y_k - \hat{t}_{x\pi} \hat{t}_{y\pi}}{\sum_{h=1}^H \frac{N_h}{n_h} \sum_{S_h} x_k^2 - (\hat{t}_{x\pi})^2}$$

به این ترتیب برآورده رگرسیونی تعیین یافته (۴) قابل محاسبه است و برای برآورد واریانس مجانية آن از روابط

$$Var(\hat{t}_{y\pi}) = Var\left(\sum_{h=1}^H \frac{N_h}{n_h} \sum_{S_h} y_k\right) = \sum_{h=1}^H N_h^2 \left(\frac{1}{n_h} - \frac{1}{N_h} \right) S_{y^h}^2$$

کمک گرفته می‌شود، که در آن

$$S_{y^h}^2 = \frac{1}{N_h - 1} \left\{ \sum_{U_h} y_k^2 - \left(\sum_{U_h} y_k \right)^2 / N_h \right\}$$

نامعلوم است و منجر به نامعلوم بودن $Var(\hat{t}_{y\pi})$ می‌شود. برآورده‌گر نااریب $Var(\hat{t}_{y\pi})$ با قرار دادن برآورده‌گر نااریب

$$S_{yh}^2 = \frac{1}{n_h - 1} \left\{ \sum_{S_h} y_k^2 - \left(\sum_{S_h} y_k \right)^2 / n_h \right\}$$

$Var(\hat{t}_{x\pi})$ در فرمول S_{yh}^2 به دست می‌آید. به طور مشابه $Var(\hat{t}_{x\pi})$ و $Var(\hat{t}_{y\pi})$ نیز ارائه و برآورد می‌شوند. به علاوه

$$Cov(\hat{t}_{y\pi}, \hat{t}_{x\pi}) = \sum_{h=1}^H N_h^2 \left(\frac{1}{n_h} - \frac{1}{N_h} \right) S_{xyh}$$

که در آن

$$S_{xyh} = \frac{1}{N_h - 1} \left\{ \sum_{U_h} x_k y_k - \left(\sum_{U_h} y_k \right) \left(\sum_{U_h} x_k \right) / N_h \right\}$$

و به دلیل نامعلوم بودن، توسط برآورده‌گر نااریب نمونه‌ای آن، یعنی

$$S_{xyh} = \frac{1}{n_h - 1} \left\{ \sum_{S_h} x_k y_k - \left(\sum_{S_h} y_k \right) \left(\sum_{S_h} x_k \right) / n_h \right\}$$

برآورده می‌شود. از طرفی با توجه به لم ۱ برآورده‌گر رگرسیونی تعمیم‌یافته (۴) بر مبنای رابطه (۵) به صورت

$$\hat{t}_{yr} = \hat{t}_{y\pi} + (\hat{t}_{x\pi} - \hat{t}_{x\pi}) B$$

خواهد بود. همچنین مجزا بودن دو نمونه S_1 و S ، استقلال متغیر تصادفی $\hat{t}_{x\pi}$ از دو متغیر تصادفی $\hat{t}_{x\pi}$ و $\hat{t}_{y\pi}$ نتیجه می‌شود. پس

$$AV(\hat{t}_{yr}) = Var(\hat{t}_{y\pi}) + B^2 (Var(\hat{t}_{x\pi}) + Var(\hat{t}_{x\pi})) - 2BCov(\hat{t}_{y\pi}, \hat{t}_{x\pi})$$

که برآورده‌گر آن با استفاده از برآورده‌گرهای به دست آورده می‌شود.

تعريف ۲ : برآورده‌گر کالیبره برای مجموع جامعه اصلی Y ، وقتی که مجموع جامعه کمکی \mathbf{x}_t ، نامعلوم است عبارت است از

$$\hat{t}_{yw} = \sum_S w_{ik} y_k$$

که در آن وزن‌های w_{ik} ، $k = 1, \dots, N$ ، با مینیمم ساختن فاصله میان آنها با وزن‌های طرح $d_k = \frac{1}{\pi_k} \text{Var}(G_k(w, d))$ که در شرایط ۱ و ۲ بیان شده در بخش ۲ صدق کند به همراه قید $\sum_S w_{ik} \mathbf{x}_k = \hat{\mathbf{t}}_{x\pi}$ در تعریف ۱ معرفی شده است.

۴ شبیه‌سازی

برای بررسی صحبت نظریه ارائه شده، با استفاده از بسته نرم‌افزاری MATLAB، در محیط برنامه‌نویسی M-file، روش MCMC جامعه‌ای مشکل از پنج طبقه که هر طبقه آن از یک توزیع نرمال دو متغیره به خصوص (قابل مشخص‌سازی) با حجم‌های متفاوت تولید نموده‌ایم. شیوه نمونه‌گیری درون طبقه‌ها تصادفی ساده بدون جایگذاری است. برای نمونه اصلی S حجم نمونه در هر طبقه مشخص شده است، اما برای نمونه S_1 ، ابتدا به طور کلی حجم n_1 با شرط $n_1 > n$ مشخص شده و سپس با استفاده از رابطه

$$n_{1h} = [[n_h + \frac{N_h}{N}(n_1 - n)]]$$

حجم زیرنمونه‌های S_{1h} از طبقه‌ها به دست آمده است. منظور از $[[\cdot]]$ عملگری است که عددی حقیقی را به عنوان ورودی گرفته و نزدیکترین عدد صحیح به آن را به عنوان خروجی باز می‌گرداند. در هر تکرار برنامه شبیه‌سازی، مجموع کل جامعه هدف، $T = \sum_U y_k = \sum_h \sum_{U_h} y_k$

$$V(T) = \frac{N^2}{N-1} \left(\sum_U y_k^2 - \left(\sum_U y_k \right)^2 / N \right)$$

برآوردهای هورویتز-تامپسون، رگرسیون تعمیم‌یافته با فرض معلوم بودن مجموع جامعه کمکی و رگرسیونی تعمیم‌یافته با فرض نامعلوم بودن مجموع جامعه کمکی که در رابطه (۴) ارائه شده و برآورد واریانس آنها به ترتیب محاسبه شده است. فرایند تولید جامعه و نمونه‌گیری و محاسبه برآوردهای مورد نظر، ۱۰۰۰۰ بار تکرار شده و میانگین مقادیر برآوردهای با عنوان برآوردهای ریاضی آنها محاسبه شده است. در خروجی مخاطره نسبی^۵ برای سه برآوردهای مجموع کل جامعه هدف یعنی برآوردهای هورویتز-تامپسون، رگرسیونی تعمیم‌یافته با فرض معلوم بودن مجموع جامعه کمکی و رگرسیونی تعمیم‌یافته با فرض نامعلوم بودن مجموع جامعه کمکی نسبت به مجموع واقعی جامعه هدف ارائه شده‌اند. به علاوه کخاطرهای نسبی برآوردهای واریانس دو برآوردهای هورویتز-تامپسون و رگرسیونی تعمیم‌یافته با فرض نامعلوم بودن مجموع جامعه کمکی که در رابطه (۴) ارائه شده نسبت به برآورد واریانس برآوردهای رگرسیونی تعمیم‌یافته با فرض معلوم بودن مجموع جامعه کمکی ارائه شده‌اند.

ابراهیم خدابنی، سید روح‌الله شجاعی کیاسری ۴۹

برای بررسی کارایی نظریه این برنامه را دو بار تحت دو گروه از اطلاعات ورودی الف و ب که به جز در مقدار ضریب همبستگی دو متغیر کمکی و هدف در مابقی اطلاعات یکسان استند اجرا شده است. در جداول ۱ و ۲ اطلاعاتی ورودی برنامه از $n_1 = 300$ ارائه شده‌اند. نتایج خروجی نیز در جدول ۳ برای هر دو گروه اطلاعات الف و ب نشان داده شده است.

جدول ۱ اطلاعات ورودی سری الف

پارامتر								
N_h	n_{1h}^*	n_h	μ_x	μ_y	σ_x^2	σ_y^2	ρ_{xy}	طبقه
۴۰۰	۵۸	۵۰	۵	۱۰	۲	۴	۰/۷۵	اول
۶۰۰	۶۸	۵۵	۱۰	۱۵	۴	۳	۰/۶۸	دوم
۳۰۰	۴۸	۴۲	۸	۳۰	۶	۶	۰/۷۲	سوم
۳۶۰	۵۵	۴۷	۱۵	۲۵	۸	۵	۰/۶۳	چهارم
۵۲۰	۷۱	۶۰	۲۰	۱۸	۱۰	۲	۰/۷۹	پنجم

جدول ۲ اطلاعات ورودی سری ب

پارامتر								
N_h	n_{1h}^*	n_h	μ_x	μ_y	σ_x^2	σ_y^2	ρ_{xy}	طبقه
۴۰۰	۵۸	۵۰	۵	۱۰	۲	۴	۰/۲	اول
۶۰۰	۶۸	۵۵	۱۰	۱۵	۴	۳	۰/۰۵	دوم
۳۰۰	۴۸	۴۲	۸	۳۰	۶	۶	۰/۱	سوم
۳۶۰	۵۵	۴۷	۱۵	۲۵	۸	۵	۰/۱۴	چهارم
۵۲۰	۷۱	۶۰	۲۰	۱۸	۱۰	۲	۰/۰۹	پنجم

جدول ۳ خروجی برنامه برای اطلاعات دریافتی از دو گروه الف و ب
گروه اطلاعاتی

ب	الف	کمیت‌ها
$4/026003e+4$	$4/026025e+4$	t_y
$4/025956e+4$	$4/026028e+4$	$\hat{t}_{y\pi}$
$4/025979e+4$	$4/026052e+4$	\hat{t}_{yr}
$4/026003e+4$	$4/026077e+4$	\hat{t}_{yr1}
$2/16525e+12$	$2/16523e+12$	واریانس کل تجربی
$6/003089e+4$	$6/010640e+4$	$Var(\hat{t}_{y\pi})$
$6/3027629e+4$	$2/654227e+4$	$A\hat{V}(\hat{t}_{yr})$
$6/889721e+4$	$4/6072240e+4$	مخاطره نسبی
$-0/00117e+0$	$2/326145e-4$	$\hat{t}_{y\pi} : t_y$
$-6/01664e-4$	$7/144844e-4$	مخاطره نسبی
$5/604501e-6$	$12/02818e-4$	$\hat{t}_{yr} : t_y$
$-4/82887e+0$	$64/482232e+0$	مخاطره نسبی
$9/2278239e+0$	$26/07801e+0$	$\hat{V}(\hat{t}_{y\pi}) : \hat{V}(\hat{t}_y)$ $A\hat{V}(\hat{t}_{yr1}) : A\hat{V}(\hat{t}_{yr})$

۵ بحث و نتیجه‌گیری

برآوردهای مجموع جامعه هدف Y با استفاده از اطلاعات جامعه کمکی X ، که مجموع آن نامعلوم است، ارائه شد. نمونه‌گیری مجدد توسط محققان بسیاری در وضعیت مشابه مورد تحلیل و بررسی قرار گرفته است. اما در عمل گاهی نمونه‌هایی مناسب شامل اطلاعات کمکی، که به هر دلیلی از قبیل گردآوری شده‌اند در دست است و دلیلی برای صرف هزینه اضافی برای استفاده از روش نمونه‌گیری مجدد وجود ندارد. تنها کافی است نمونه‌ای جدید از جامعه توان (X, Y) گرفته و با استفاده از برآوردهای که برای مجموع نامعلوم جامعه کمکی از روی نمونه گذشته صورت پذیرد، با روش برآوردهای رگرسیونی، مجموع کل Y برآورده شده است. به علاوه واریانس مجانی و برآوردهای واریانس آن نیز ارائه شد. کارایی این برآوردهای مطالعه‌ای شبیه‌سازی با برآوردهای هورویتز-تاپسون و برآوردهای رگرسیونی با فرض معلوم بودن مجموع کل X ، مورد مقایسه قرار گرفت.

برای انجام این مقایسه دو گروه اطلاعات برای جامعه در نظر گرفته شد که جز در مقادیر ضریب همبستگی کاملاً یکسان بوده‌اند. در نتایج گروه اطلاعاتی الف که ضریب همبستگی X و Y بیشتر از $7/5^\circ$ در نظر گرفته شده بود، ترتیب $\hat{V}(\hat{t}_{y\pi}) < \hat{V}(\hat{t}_{yr}) < A\hat{V}(\hat{t}_{yr})$ ملاحظه شد. یعنی برآوردهای پیشنهادی مطابق انتظار کارایی کمتری نسبت به برآوردهای رگرسیونی وقتی که مجموع کل X معلوم است دارد، اما نسبت به برآوردهای هورویتز-تاپسون که از اطلاعات کمکی استفاده نمی‌کنند کارایی بیشتری دارد.

در نتایج گروه اطلاعاتی ب که ضریب همبستگی X و Y ، کمتر از $2/5^\circ$ در نظر گرفته شده بود، ترتیب $\hat{V}(\hat{t}_{y\pi}) < A\hat{V}(\hat{t}_{yr}) < A\hat{V}(\hat{t}_{y\pi})$ ملاحظه شد، که به دلیل آن است که میزان همبستگی اطلاعات کمکی X با جامعه هدف Y کم می‌باشد و نمی‌توان از اطلاعات X به عنوان متغیر کمکی استفاده نمود.

پیوست الف:

برای اثبات رابطه (۸)، با تعریف نمادهای

$$\bar{x}_n = \frac{\sum_{S_1} x_k}{n_1}, \quad \bar{x}_n = \frac{\sum_S x_k}{n}, \quad \bar{y}_n = \frac{\sum_S y_k}{n}, \quad S_x^2 = \frac{\sum_U (x_k - \mu_x)^2}{(N-1)}$$

$$S_y^2 = \frac{\sum_U (y_k - \mu_y)^2}{(N-1)}, \quad S_{xy} = \frac{\sum_U (x_k - \mu_x)(y_k - \mu_y)}{(N-1)}$$

$$s_{xy} = \frac{\sum_S (x_k - \bar{x}_n)(y_k - \bar{y}_n)}{(n-1)}, \quad s_y^2 = \frac{\sum_S (y_k - \bar{y}_n)^2}{(n-1)}, \quad s_x^2 = \frac{\sum_S (x_k - \bar{x}_n)^2}{(n-1)}$$

$$\rho = \frac{S_{xy}}{(S_x^2 S_y^2)^{\frac{1}{2}}}, \quad \hat{B} = \frac{s_{xy}}{s_x^2}$$

و در نظر گرفتن برآوردگر میانگین جامعه به صورت

$$\bar{y}_{r \setminus SI} = \bar{y}_n + (\bar{x}_{n_1} - \bar{x}_n) \hat{B} \quad (4)$$

داریم

$$\hat{t}_{y_{r \setminus SI}} = N(\bar{y}_n + (\bar{x}_{n_1} - \bar{x}_n) \hat{B}) = N\bar{y}_{r \setminus SI} \quad (10)$$

بنابراین $\hat{B} = \frac{S_{xy}}{S_x^2}$ چون $Var(\hat{t}_{y_{r \setminus SI}}) = N^2 Var(\bar{y}_{r \setminus SI})$ اریب است، بنابراین برآوردگر (۹) نیز اریب است. با قرار دادن

$$\bar{x}_{n_1} = \mu_x + \varepsilon_1, \quad \bar{x}_n = \mu_x + \varepsilon_2, \quad s_x^2 = S_x^2 + \varepsilon_3, \quad s_{xy} = S_{xy} + \varepsilon_4 \quad (11)$$

و اینکه $B = \frac{S_{xy}}{S_x^2}$ مقداری ثابت است، داریم

$$\begin{aligned} \bar{y}_{r \setminus SI} &= \bar{y}_n + (\varepsilon_1 - \varepsilon_2) \frac{S_{xy}(1 + \varepsilon_4/S_{xy})}{S_x^2(1 + \varepsilon_3/S_x^2)} \\ &= \bar{y}_n + B(\varepsilon_1 - \varepsilon_2)(1 + \frac{\varepsilon_4}{S_{xy}})(1 - \frac{\varepsilon_3}{S_x^2})^{-1} \end{aligned}$$

از آنجا که $|\frac{\varepsilon_3}{S_x^2}| < 1$

$$\begin{aligned} \bar{y}_{r \setminus SI} &\simeq \bar{y}_n + B(\varepsilon_1 - \varepsilon_2)(1 + \frac{\varepsilon_4}{S_{xy}})(1 - \frac{\varepsilon_3}{S_x^2} + \dots) \\ &\simeq \bar{y}_n + B(\varepsilon_1 - \varepsilon_2 + \frac{\varepsilon_1 \varepsilon_4}{S_{xy}} - \frac{\varepsilon_2 \varepsilon_4}{S_{xy}} - \frac{\varepsilon_1 \varepsilon_3}{S_x^2} + \frac{\varepsilon_2 \varepsilon_3}{S_x^2} - \dots) \end{aligned}$$

چون $E(\varepsilon_1) = E(\varepsilon_2) = 0$ داریم

$$E(\bar{y}_{r \setminus SI}) \simeq (\bar{y}_n) + B(\frac{E(\varepsilon_1 \varepsilon_4)}{S_{xy}} - \frac{E(\varepsilon_2 \varepsilon_4)}{S_{xy}} - \frac{E(\varepsilon_1 \varepsilon_3)}{S_x^2} + \frac{E(\varepsilon_2 \varepsilon_3)}{S_x^2} - \dots) \quad (12)$$

اما با توجه به اینکه نمونه‌های S_1 و S تصادفی ساده مستقل از جامعه‌ای واحد هستند، داریم

$$E(\bar{y}_n) = \mu_y$$

$$E(\varepsilon_1 \varepsilon_4) = E[(\bar{x}_{n_1} - \mu_x)(s_{xy} - S_{xy})] = Cov(\bar{x}_{n_1}, s_{xy})$$

به همین ترتیب داریم

$$E(\varepsilon_1 \varepsilon_2) = Cov(\bar{x}_n, s_{xy}), \quad E(\varepsilon_1 \varepsilon_3) = Cov(\bar{x}_n, s_x^2), \quad E(\varepsilon_2 \varepsilon_3) = Cov(\bar{x}_n, s_x^2)$$

بنابراین

$$E(\bar{y}_{r \setminus SI}) \simeq \mu_y + B \left\{ \frac{Cov(\bar{x}_n, s_{xy}) - Cov(\bar{x}_n, s_{xy})}{S_{xy}} + \frac{Cov(\bar{x}_n, s_x^2) - Cov(\bar{x}_n, s_x^2)}{S_x^2} \right\}$$

جمله دوم در رابطه بالا معرف اربیی تقریبی $\bar{y}_{r \setminus SI}$ است. چون s_{xy} و s_x^2 از نمونه S به دست آمده‌اند، \bar{x}_n که از نمونه مستقل S محاسبه شده است، مستقل هستند. از طرفی در نمونه تصادفی S , \bar{x}_n و s_x^2 از \bar{x}_n مستقل هستند. بنابراین در عبارت بالا همه کوواریانس‌ها برابر صفر هستند. در نتیجه $\bar{y}_{r \setminus SI}$ برآوردهای نااریب میانگین جامعه Y است. برای محاسبه واریانس $\bar{y}_{r \setminus SI}$ رابطه (۶) را با توجه به روابط (۱۱) می‌توان به صورت

$$\bar{y}_{r \setminus SI} = \bar{y}_n + (\varepsilon_1 - \varepsilon_2) \hat{B}$$

نوشت. با توجه به نااریبی $\bar{y}_{r \setminus SI}$ داریم

$$V(\bar{y}_{r \setminus SI}) = E[(\bar{y}_{r \setminus SI} - \mu_y)^2] = E[(\bar{y}_n + \hat{B}(\varepsilon_1 - \varepsilon_2) - \mu_y)^2]$$

در صورتی که N بزرگ باشد، می‌توان قرار داد $\hat{B} \simeq \hat{B}$. بنابراین

$$\begin{aligned} AV(\bar{y}_{r \setminus SI}) &= E[(\bar{y}_n + B(\varepsilon_1 - \varepsilon_2) - \mu_y)^2] \\ &= E(\bar{y}_n - \mu_y)^2 + B^2 E(\varepsilon_1 - \varepsilon_2)^2 + 2BE[(\bar{y}_n - \mu_y)(\varepsilon_1 - \varepsilon_2)] \end{aligned}$$

در نمونه‌گیری تصادفی ساده داریم $E(\bar{y}_n - \mu_y)^2 = V(\bar{y}_n) = (\frac{1}{n} - \frac{1}{N}) S_y^2$. از طرفی با توجه به مقادیر ε_1 و ε_2

$$\begin{aligned} E(\varepsilon_1 - \varepsilon_2)^2 &= E(\bar{x}_n - \mu_x)^2 + E(\bar{x}_n - \mu_x)^2 - 2E(\bar{x}_n - \mu_x)(\bar{x}_n - \mu_x) \\ &= (\frac{1}{n_1} - \frac{1}{N}) S_x^2 + (\frac{1}{n} - \frac{1}{N}) S_x^2 - 2E(\bar{x}_n - \mu_x)(\bar{x}_n - \mu_x) \end{aligned}$$

چون نمونه‌های n_1 و n مستقلند در نتیجه \bar{x}_n و \bar{x}_n نیز مستقل هستند، بنابراین

$$E(\bar{x}_n - \mu_x)(\bar{x}_n - \mu_x) = 0 \quad (13)$$

پس

$$E(\varepsilon_1 - \varepsilon_2)^2 = (\frac{1}{n_1} - \frac{1}{N}) S_x^2 + (\frac{1}{n} - \frac{1}{N}) S_x^2 = (\frac{1}{n_1} + \frac{1}{n} - \frac{2}{N}) S_x^2$$

بنابراین جمله دوم طرف راست (۱۳) برابر $(S_x^2 + \frac{1}{n} - \frac{\bar{x}^2}{N})B^2$ است. در مورد جمله سوم طرف راست (۱۳) داریم

$$E[(\bar{y}_n - \mu_y)(\varepsilon_1 - \varepsilon_2)] = E[(\bar{y}_n - \mu_y)(\bar{x}_n - \mu_x)] - E[(\bar{y}_n - \mu_y)(\bar{x}_n - \mu_x)] \quad (14)$$

این بار استقلال دو نمونه S_1 و S استقلال \bar{x}_n و \bar{y}_n را نتیجه می‌دهد و جمله اول طرف راست (۱۴) برابر صفر می‌شود. برای جمله دوم طرف راست (۱۴) داریم

$$E[(\bar{y}_n - \mu_y)(\bar{x}_n - \mu_x)] = Cov(\bar{x}_n, \bar{y}_n) = (\frac{1}{n} - \frac{1}{N})S_{xy}$$

بنابراین جمله سوم طرف راست (۱۴) عبارت خواهد شد از

$$2BE[(\bar{y}_n - \mu_y)(\varepsilon_1 - \varepsilon_2)] = -2B(\frac{1}{n} - \frac{1}{N})S_{xy}$$

با منظور کردن مقادیر محاسبه شده در (۱۲)، نتیجه می‌شود

$$\begin{aligned} AV(\bar{y}_{r \setminus SI}) &= (\frac{1}{n} - \frac{1}{N})S_y^2 + B^2(\frac{1}{n_1} + \frac{1}{n} - \frac{2}{N})S_x^2 - 2B(\frac{1}{n} - \frac{1}{N})S_{xy} \\ &= (\frac{1}{n} - \frac{1}{N})S_y^2 + \frac{S_{xy}}{S_x^2}(\frac{1}{n_1} - \frac{1}{n}) \\ &= S_y^2[(\frac{1}{n} - \frac{1}{N}) + \rho^2(\frac{1}{n_1} - \frac{1}{n})] \end{aligned}$$

که در آن $\rho = \frac{S_{xy}}{(S_x^2 S_y^2)^{\frac{1}{2}}}$ بنابراین با استفاده از (۱۰) می‌توان نوشت

$$AV(t_{yr \setminus SI}) = N^2 S_{yy}[(\frac{1}{n} - \frac{1}{N}) + \rho^2(\frac{1}{n_1} - \frac{1}{n})]$$

معمولًا مقادیر S_{yy} و ρ نامعلومند و از روی مشاهدات نمونه S به ترتیب به صورت $r = \frac{s_{xy}}{(s_x^2 s_y^2)^{\frac{1}{2}}}$ و $s_{xy} = \frac{1}{n-1} \sum_S (x_k - \bar{x}_n)(y_k - \bar{y}_n)$ برآورده می‌شوند.

تقدیر و تشکر

نویسنده‌گان این مقاله از داوران و سردبیر محترم مجله به خاطر ارائه پیشنهادهای ارزنده تشکر و قدردانی را دارند.

مراجع

- Binder, D. A., Babyak, C., Brodeur, M., Hidiroglou, M., and Jocelyn, W. (2000), Variance Estimation for Two-Phase Stratified Sampling, *Journal of The Canadian Statistics*, **28**, 751-764.
- Cochran, W. G. (1977), *Sampling Techniques*, 3rd edition, New York: Wiley.
- Devile, J. C. and Särndal, C. E., (1992), Calibration Estimators in Survey Sampling, *Jornal of American Statistical Association*, **87**, 376-382.
- Horvitz, D. G., and Thompson, D. J. (1952), A Generalization of Sampling Without Replacement from a Finite Universe. *Jornal of American Statistical Association*, **47**, 663-685.
- Kim, J. K., Navarro, A. and Fuller, W. A. (2006), Replication Variance Estimation for Two-phase Sampling Stratified Sampling, *Jornal of American Statistical Association*, **101**, 312-320.
- Rao, J. N. K. and Sitter, R. R. (1995), Variance Estimation under Two-phase Sampling with Application to Imputation for Missing Data, *Biometrika*, **82** 453-460.
- Särndal, C. E., Swensson, B. and Wretman. J. (1992), *Model Assisted Survey Sampling*, Springer, NewYork.
- Sitter, R. R. (1997), Variance Estimation for the Regression Estimator in Two-phase Sampling, *Jornal of American Statistical Association*, **92**, 780-787.
- Valliant, R., Dorfman, A. H. and Royall, R. M., (2000), *Finite Population Sampling and Inference: A Prediction Approach*, Wiley Series in Probability and Statistics, Survey Methodology Section. Wiley, New York.