

مقایسه چند روش برای برآورد ناحیه کوچک و کاربرد آن در برآورد متوسط هزینه خانوار در استان‌های کشور

پروین جلیلی، محمدرضا فقیهی

بانک مرکزی جمهوری اسلامی ایران

گروه آمار، دانشگاه شهید بهشتی

اهمیت و گستردگی برآورد برخی پارامترها برای ناحیه‌های کوچک، در طرح‌هایی مانند طرح بررسی هزینه و درآمد خانوار و طرح اشتغال و بیکاری که نتایج حاصل از آنها مبنای بسیاری از سیاست‌های مالی و اقتصادی دولت قرار می‌گیرند و اغلب برای ناحیه‌های کوچک در بردارنده تعداد نمونه کافی نیستند، سبب شده است روش‌های برآورد ناحیه کوچک به سرعت گسترش یابند. در مطالعات پیش از این در بسیاری از موارد برتری روش بیز سلسه مراتبی بر برخی روش‌ها، به اثبات رسیده است. در این مقاله با استفاده از مدل‌های سطح ناحیه، سه روش، ناپارامتری دو مرحله‌ای، بهترین پیشگوی ناریب خطی تجربی و بیز سلسه مقایسه‌ای مناسب بهترین روش انتخاب شده است. نتایج حاصل از مقایسه برتری روش بیز سلسه مراتبی در مقایسه با دو روش دیگر نشان می‌دهند. همچنین از روش بیز سلسه مراتبی برای برآورد متوسط هزینه خانوار در استان‌های کشور در سال ۸۵، بر اساس اطلاعات جمع‌آوری شده توسط بانک مرکزی جمهوری اسلامی ایران استفاده شده است.

واژه‌های کلیدی: برآورد ناحیه کوچک، مدل سطح ناحیه، رگرسیون ناپارامتری، برآوردگر ناداریا-واتسون، اعتبارسنجی متقابل، بهترین پیشگوی ناریب خطی تجربی، بیز سلسه مراتبی، نمونه‌گیری گیبس.

۱ مقدمه

در طرح‌های نمونه‌ای پیمایشی، اندازه نمونه برای ناحیه بزرگ (حوزه بزرگ) مانند کشور، استان و غیره تعیین می‌گردد. بنابراین اطلاعات جمع‌آوری شده برای استنباط در مورد حوزه بزرگ مناسب بوده و از دقت لازم برخوردار است. حال آنکه در اکثر موارد حوزه بزرگ شامل

زیرجامعه‌هایی است که کسب اطلاع در مورد ویژگی‌های این زیرجامعه‌ها برای ما مطلوب بوده ولی متناسبانه در اکثر موارد تعداد نمونه اخذ شده از زیرجامعه‌های مورد نظر کمتر از حد مورد نیاز برای انجام یک برآورد با دقت مناسب است. به این زیرجامعه‌ها در اصطلاح ناحیه‌های کوچک گفته می‌شود. از آنجا که بهینه کردن اندازه نمونه درسطح ناحیه‌های کوچک باعث افزایش قابل توجه هزینه آمارگیری می‌شود و همچنین استفاده از روش‌های مستقیم برآورد در مورد ناحیه‌های کوچک از دقت لازم برخوردار نخواهد بود، آمارشناسان سعی کرده‌اند با استفاده از اطلاعات کمکی برآوردگرهای مناسبی برای ناحیه‌های کوچک ارائه دهند.

در این راستا دو رویکرد مدل سطح ناحیه و مدل سطح واحد وجود دارد (رأیو ۲۰۰۳). در مدل سطح ناحیه علاوه بر اطلاعات کمکی اغلب از اثرهای ناحیه نیز برای برآورد پارامتر مورد نظر استفاده می‌شود.

در این مقاله از مدل سطح ناحیه استفاده می‌شود. مدل \bar{Y}_i -هربوت (فی-هربوت، ۱۹۷۹) یکی از معروف‌ترین مدل‌های سطح ناحیه است. هدف، استنباط درباره‌ی تابع مناسبی از میانگین‌های ناحیه کوچک i است. $\theta_i = \bar{Y}_i$ ، که m تعداد نواحی کوچک است)، یعنی به صورت $g(\bar{Y}_i) = \theta_i$ است که θ_i با بردار متغیرهای کمکی x_i به صورت زیر در ارتباط است.

$$\theta_i = x_i^T \beta + b_i \nu_i \quad i = 1, 2, \dots, m. \quad (1)$$

در این رابطه $x_i = (x_{i1}, \dots, x_{ip})^T$ یک بردار p -متغیره از متغیرهای کمکی ناحیه i ، $\beta = (\beta_1, \dots, \beta_p)^T$ بردار ضرایب رگرسیونی که نامعلوم است، b_i متغیر تصادفی اثر ناحیه i ، که فرض می‌شود، دارای میانگین صفر و واریانس، σ_b^2 است (معمولًاً فرض می‌شود $b_i \sim N(0, \sigma_b^2)$). ν_i نیز مقادیر ثابت، مثبت و معلومی هستند که معمولاً در نظر گرفته می‌شوند. و m نیز تعداد ناحیه‌های کوچک مورد بررسی هستند. برای استنباط در مورد میانگین ناحیه کوچک i ، (\bar{Y}_i) بر اساس مدل (1)، اگر \hat{Y}_i برآوردگر مستقیم میانگین ناحیه i باشد، فرض می‌کنیم:

$$\hat{\theta}_i = g(\hat{Y}_i) = \theta_i + e_i, \quad i = 1, 2, \dots, m. \quad (2)$$

در این رابطه e_i خطاهای نمونه‌گیری هستند. که فرض می‌شود مستقل از هم و دارای میانگین و واریانس به صورت زیر باشند.

$$E(e_i | \theta_i) = 0, \quad \text{Var}(e_i | \theta_i) = \psi_i$$

معمولاً فرض می‌شود واریانس‌های نمونه‌ای (σ_{ψ_i}) معلوم هستند.
از ترکیب دو رابطه‌ی (۱) و (۲)، داریم:

$$\hat{\theta}_i = \mathbf{x}_i^T \boldsymbol{\beta} + b_i \nu_i + e_i, \quad i = 1, 2, \dots, m. \quad (3)$$

در اکثر موارد فرض می‌شود ν_i ها و e_i ها از هم مستقل هستند.

در این مقاله برای برآورد میانگین‌های ناحیه‌های کوچک از سه روش، ناپارامتری دو مرحله‌ای، بهترین پیشگوی نااریب خطی تجربی (EBLUP) و بیز سلسله مراتبی (HB) استفاده می‌شود.

در بخش ۲ سه روش EBLUP، HB و ناپارامتری دو مرحله‌ای معرفی می‌شوند. که در مورد روش ناپارامتری دو مرحله‌ای در حالتی که یک متغیر کمکی در مدل حضور داشته باشد و حالتی که بیش از یک متغیر کمکی در مدل باشد، بحث می‌شود.

در بخش ۳ سه روش مذکور بالاستفاده از شبیه‌سازی در دو حالت وجود ارتباط خطی بین $\hat{\theta}_i$ و \mathbf{x}_i و حالت وجود ارتباط ناخطي بحث می‌شود. و با استفاده از یک معیار مقایسه مناسب، سه روش مقایسه شده و بهترین روش انتخاب می‌شود.

در بخش ۴ با استناد به نتایج بخش ۳ بهترین روش از بین سه روش معرفی شده جهت برآورد متوسط هزینه خانوار در استان‌های کشور براساس اطلاعات جمع‌آوری شده توسط بانک مرکزی جمهوری اسلامی ایران در سال ۸۵، مورد استفاده قرار می‌گیرد.

۲ معرفی سه روش HB، EBLUP و ناپارامتری دو مرحله‌ای

در این بخش سه روش HB، EBLUP و ناپارامتری دو مرحله‌ای معرفی می‌شوند. که روش ناپارامتری دو مرحله‌ای در حالتی که یک متغیر کمکی در مدل حضور داشته باشد و حالتی که بیش از یک متغیر کمکی در مدل باشد، مورد بررسی قرار می‌گیرد.

۱-۲ روش بهترین پیشگوی نااریب خطی تجربی

با توجه به آنکه مدل (۳) یک مدل آمیخته خطی است. هندرسون (۱۹۷۵)، با فرض معلوم بودن واریانس اثرهای ناحیه و واریانس خطای نمونه‌گیری، برآوردگر زیر را برای θ_i پیشنهاد

کرد.

$$\begin{aligned}\tilde{\theta}_i &= \mathbf{x}_i^T \tilde{\beta} + \gamma_i(\hat{\theta}_i - \mathbf{x}_i^T \tilde{\beta}) \\ &= \gamma_i \hat{\theta}_i + (1 - \gamma_i) \mathbf{x}_i^T \tilde{\beta}\end{aligned}$$

که در آن

$$\tilde{\beta} = \left(\frac{\sum_{i=1}^m \mathbf{x}_i \mathbf{x}_i^T}{\sigma_\nu^2 b_i^2 + \psi_i} \right)^{-1} \left(\frac{\sum_{i=1}^m \mathbf{x}_i \hat{\theta}_i}{\sigma_\nu^2 b_i^2 + \psi_i} \right).$$

در روابط فوق σ_ν^2 مجھول است، گوش و رائو (۱۹۹۴) با استفاده از گشتاورها و با فرض نرمال بودن خطای اثرا ناچیه، برآوردگر زیر را ارائه کرده‌اند.

$$\hat{\sigma}_\nu^2 = \frac{1}{m-p} \left(\sum_{i=1}^m (\hat{\theta}_i - \mathbf{x}_i^T \beta^*)^2 - \sum_{i=1}^m \psi_i \left(1 - \mathbf{x}_i^T \left(\sum_{i=1}^m \mathbf{x}_i \mathbf{x}_i^T \right)^{-1} \mathbf{x}_i \right) \right)$$

که در آن p بعد بردار ضرایب رگرسیونی است، β^* برآوردگر کمترین توان‌های دوم خطای m تعداد ناحیه‌های کوچک است.

۲-۲ روش بیز سلسله مراتبی

در این قسمت به منظور برآورد θ_i ‌ها، از روش بیز سلسله مراتبی با استفاده از روش نمونه‌گیری گیبس استفاده می‌کنیم (رائو، ۲۰۰۳). همانطور که ذکر شد معمولاً $b_i = 1$ در نظر گرفته می‌شود.

در این حالت فرضیات مدل (۳) را با در نظر گرفتن یک توزیع مسطح برای β و با فرض $e_i \sim N(\mu, \sigma_\nu^2)$ و $\nu_i \sim N(0, \sigma_\nu^2)$ به صورت زیر در نظر می‌گیریم.

$$(i) \quad \hat{\theta}_i | \theta_i, \beta, \sigma_\nu^2 \sim N(\theta_i, \psi_i)$$

$$(ii) \quad \theta_i | \beta, \sigma_\nu^2 \sim N(\mathbf{x}_i^T \beta, \sigma_\nu^2)$$

$$(iii) \quad \pi(\beta) \propto 1$$

$$(iv) \quad \pi(\beta, \sigma_\nu^2) = \pi(\beta)\pi(\sigma_\nu^2) \propto \pi(\sigma_\nu^2)$$

$$(v) \quad \pi(\sigma_\nu^2) \propto IG(a, b)$$

در روابط بالا $\pi(\sigma_\nu)$ توزیع پیشین σ_ν است، که برای اجتناب از ناسره شدن، توزیع پیشین آن را گامای معکوس (IG) در نظر می‌گیریم، که ابرپارامترهای a و b اعدادی معلوم و مثبتی هستند که در اغلب موارد $a = b = 0.001$ در نظر گرفته می‌شود. مانند قبل فرض می‌شود ψ_i ها معلوم هستند، حالتی که در آن ψ_i ها نامعلوم هستند توسط زارعی و همکاران (1386) بحث شده است.

برآوردهای θ_i در روش $E(\theta_i|\hat{\theta})$ است. برای محاسبه امید باید چگالی‌های پسین را به دست آورد. این کار اغلب به انتگرال‌های دارای بعد زیاد می‌رسد که حل آن‌ها مشکل است. بنابراین برای به دست آوردن جواب‌ها از روش شبیه‌سازی مونت کارلوی زنجیر مارکوفی مانند نمونه گیری گیبس استفاده می‌کنند (گلفند و اسimit، ۱۹۹۰).

برای این منظور با استفاده از فرضیات (i) تا (v) توزیع‌های شرطی کامل محاسبه می‌شوند. پس از انجام محاسبات لازم خواهیم داشت:

$$\begin{aligned} (\theta_i|\beta, \sigma_\nu^2, \hat{\theta}) &\sim N(\gamma_i \hat{\theta}_i + (1 - \gamma_i) \mathbf{x}_i^T \beta, \gamma_i \psi_i), \\ (\beta|\theta, \sigma_\nu^2, \hat{\theta}) &\sim N_p \left(\left(\sum_{i=1}^m \mathbf{x}_i \mathbf{x}_i^T \right)^{-1} \left(\sum_{i=1}^m \mathbf{x}_i \theta_i \right), \sigma_\nu^2 \left(\sum_{i=1}^m \mathbf{x}_i \mathbf{x}_i^T \right)^{-1} \right), \\ (\sigma_\nu^2|\beta, \theta, \hat{\theta}) &\sim IG \left(\frac{m}{2} + a, b + \frac{1}{2} \sum_{i=1}^m (\theta_i - \mathbf{x}_i^T \beta)^2 \right). \end{aligned}$$

با در نظر گرفتن $(\beta, \theta, \sigma_\nu^2, \eta) = (\beta, \theta, \sigma_\nu^2)$ ، مراحل نمونه‌گیری گیبس را می‌توان به صورت زیر تشریح کرد.

- گام اول: انتخاب مقادیر اولیه $(\eta^{(0)})$.

- گام دوم: تولید $(\beta^{(k+1)}, \theta^{(k+1)}, \sigma_\nu^{(k+1)})$ به صورتی که برای تولید از توزیع شرطی

$$(\beta|\theta^{(k)}, \sigma_\nu^{(k)}, \hat{\theta}) \sim N_p \left(\left(\sum_{i=1}^m \mathbf{x}_i \mathbf{x}_i^T \right)^{-1} \left(\sum_{i=1}^m \mathbf{x}_i \theta_i^{(k)} \right), \sigma_\nu^{(k)} \left(\sum_{i=1}^m \mathbf{x}_i \mathbf{x}_i^T \right)^{-1} \right),$$

برای تولید $\theta^{(k+1)}$ از توزیع شرطی

$$(\theta_i|\beta^{(k+1)}, \sigma_\nu^{(k)}, \hat{\theta}) \sim N(\gamma_i^{(k)} \hat{\theta}_i + (1 - \gamma_i^{(k)}) \mathbf{x}_i^T \beta^{(k+1)}, \gamma_i^{(k)} \psi_i),$$

و برای تولید $\sigma_\nu^{(k+1)}$ از توزیع شرطی

$$(\sigma_\nu^2|\beta^{(k+1)}, \theta^{(k+1)}, \hat{\theta}) \sim IG \left(\frac{m}{2} + a, b + \frac{1}{2} \sum_{i=1}^m (\theta_i^{(k+1)} - \mathbf{x}_i^T \beta^{(k+1)})^2 \right).$$

استفاده می‌شود.

- گام سوم: تکرار گام‌های ۱ و ۲، تا زمانی که $|\eta^{(k+1)} - \eta^{(k)}|$ از مقدار از پیش تعیین شده δ کمتر شود.

در نهایت با فرض اینکه $\{\beta^{(k)}, \theta^{(k)}, \sigma_{\nu}^{(k, (K))}, k = d+1, \dots, d+D\}$ نمونه‌های تولید شده با استفاده از روش گیبس بعد از مرحله d و D تعداد تکرارهای نمونه‌گیری باشند، برآوردگر HB به صورت زیر بیان می‌شود.

$$\hat{\theta}_i^{HB} = \frac{1}{D} \sum_{k=d+1}^{d+D} \left(\gamma_i^{(k)} \hat{\theta}_i + (1 - \gamma_i^{(k)}) \mathbf{x}_i^T \boldsymbol{\beta}^{(k)} \right)$$

۳-۲ روش ناپارامتری دو مرحله‌ای

همانطور که ملاحظه شد در دو روش بیان شده با فرض خطی بودن رابطه‌ی $\hat{\theta}_i$ و x_i ، برآورد ناحیه کوچک حاصل گردید. در این زیر بخش سعی برآن است تا با استفاده از یک روش ناپارامتری که برآورد حاصل از آن کمتر تحت تاثیر نوع ارتباط $\hat{\theta}_i$ و x_i قرار می‌گیرد، برای برآورد ناحیه‌های کوچک ارائه کنیم. برای این منظور ابتدا حالتی را که یک متغیر در مدل حضور دارد را بررسی می‌کنیم.

موخپادهایی و مایتی (۲۰۰۴)، یک روش ناپارامتری دو مرحله‌ای را با استفاده از هموارساز هسته‌ی ناداریا-واتسون ارائه کرده‌اند که به صورت زیر تشریح می‌شود.
در این روش رابطه‌ی (۱) به صورت

$$\theta_i = f(x_i) + \nu_i \quad (4)$$

که f تابعی نامعلوم و هموار (دارای مشتق پیوسته از مرتبه دوم) است.
به منظور برآورد تابع $f(x_i)$ ، موخپادهایی و مایتی (۲۰۰۴)، برآوردگر هسته ناداریا-واتسون را پیشنهاد کرده‌اند که به صورت زیر محاسبه می‌شود.

$$\hat{f}_h(x) = \frac{\sum_{i=1}^m K_h(x - x_i) \hat{\theta}_i}{\sum_{i=1}^m K_h(x - x_i)} \quad (5)$$

که $(.)$ یک تابع هسته با پهنای نوار h است و

$$K_h(u) = \frac{1}{h} K\left(\frac{u}{h}\right).$$

که $(.) K(.)$ دارای ویژگی‌های زیر است

۱. $K(.)$ متقارن است.

۲. روی دامنه x کراندار و متقارن است.

$$\int_x K(u)du = 1. \quad (3)$$

برآوردگر (۵) را می‌توان به صورت $\hat{f}_h(x) = \frac{1}{m} \sum_{i=1}^m W_{hi}(x) \hat{\theta}_i$ بازنویسی کرد که

$$W_{hi} = \frac{K_h(x - x_i)}{1/m \sum_{i=1}^m K_h(x - x_i)}.$$

بر اساس بهترین برآورد ناحیه کوچک برای میانگین θ_i , با فرض معلوم بودن σ_ν^2 , می‌توان به صورت زیر نوشت.

$$E(\theta_i | \hat{\theta}_i) = \tilde{\theta}_i = \gamma_i \hat{\theta}_i + (1 - \gamma_i) \hat{f}_h(x_i).$$

که مانند قبل $\frac{\sigma_\nu^2}{\sigma_\nu^2 + \psi_i} = \gamma_i$. حال در مرحله دوم با برآورد σ_ν^2 داریم:

$$\hat{\theta}_i^{Non} = \hat{\gamma}_i \hat{\theta}_i + (1 - \hat{\gamma}_i) \hat{f}_h(x_i). \quad (6)$$

که $\hat{\gamma}_i = \frac{\hat{\sigma}_\nu^2}{\hat{\sigma}_\nu^2 + \psi_i}$. و $\hat{\sigma}_\nu^2$ یک برآوردگر سازگار برای σ_ν^2 است. موقایعی و مایتی (۴۰۰۲)، تحت مدل (۴) نشان داده‌اند $\hat{f}_h(x)$ در هر نقطه‌ی پیوستگی تابع f , در احتمال به $f(x)$ میل می‌کند و برای $\hat{\sigma}_\nu^2$, برآوردگر زیر را پیشنهاد کرده‌اند.

$$\hat{\sigma}_\nu^2 = \max \left\{ 0, \frac{1}{m-1} \sum_{i=1}^m W_{hi} \left(\hat{\theta}_i - \hat{f}_h(x_i) \right)^2 - \psi \right\}. \quad (7)$$

که در این برآوردگر واریانس خطاهای ناحیه‌ها ثابت و برابر ψ فرض شده است. برآوردگر پیشنهادی ممکن است منفی شود ولی ثابت می‌شود زمانی که $P(\sigma_\nu^2 < 0) \rightarrow 0$, $m \rightarrow \infty$. در برآوردگر (۵), h , تحت عنوان پهنانی نوار, پارامتر این هموارساز بوده و باید برآورد شود. در مورد انتخاب h , باید به این نکته توجه داشت که پهنانی نوار کوچک می‌تواند به تابع رگرسیون برآورده شده ناهمواری منجر گردد. در حالی که پهنانی نوار بزرگ می‌تواند سبب هموار شدن بیش از حد و حذف بعضی از تغییرات موضعی گردد. در حالت اول اربیی کاهش ولی واریانس افزایش می‌یابد و در حالت دوم اربیی افزایش ولی واریانس کاهش می‌یابد. بنابراین در انتخاب h باید تعادلی بین این دو حالت برقرار گردد. برای این منظور معمولاً از معیارهایی

استفاده می‌شود که سعی در برقراری این تعادل دارند، مانند معیار اعتبار سنجی متقابل CV . در محاسبه CV ، فرض کنید (x_i) و $\hat{f}^{[-i]}$ ، $i = 1, 2, \dots, m$ ، مدل برآش شده پس از کنار گذاشتن مشاهده i باشد، معیار اعتبار سنجی متقابل به صورت زیر تعریف می‌شود.

$$CV = \frac{1}{m} \sum_{i=1}^m \left(\hat{f}^{[-i]}(x_i) - \hat{\theta}_i \right)^2 \quad (8)$$

در واقع $\hat{f}^{[-i]}(x_i) - \hat{\theta}_i$ بیانگر خطای پیش‌بینی مشاهده i به عنوان مشاهده جدید حاصل از مدل برآش شده به کلیه مشاهدات بعد از کنار گذاشتن مشاهده i است و CV میانگین توان دوم این خطای را در مجموعه مشاهدات اندازه می‌گیرد. با کمی محاسبات جبری فرمول معادل زیر برای محاسبه CV حاصل می‌شود

$$CV(h) = \frac{1}{m} \sum_{i=1}^m \left(\frac{\hat{\theta}_i - \hat{f}(x_i)}{1 - s_{ii}} \right)^2$$

که s_{ii} عناصر قطری ماتریس هموارساز S_h هستند. ماتریس هموارساز S_h همان ماتریس تبدیل بردار $\hat{\theta}' = (\hat{\theta}_1, \dots, \hat{\theta}_m)$ به $\hat{f} = (\hat{f}(x_1), \dots, \hat{f}(x_m))^T$ است به طوری که داریم، $\hat{f} = S_h \hat{\theta}$. $tr(S_h)$ درجه آزادی هموارساز شناخته می‌شود که معیاری برای اندازه‌گیری همواری هموارساز است.

در حالتی که بیش از یک متغیر کمکی در مدل حضور دارد، مدل (۴) به صورت زیر بیان می‌شود.

$$\theta_i = f(x_i) + \nu_i$$

که $x_i = (x_{i1}, \dots, x_{ip})^T$ ، p تعداد متغیرهای کمکی موجود در مدل است. هر دل و مولر (۲۰۰۰)، برآوردگر زیر را برای $f(\cdot)$ پیشنهاد کرده‌اند.

$$\hat{f}_H(\mathbf{x}) = \frac{\sum_{i=1}^m \mathcal{K}_H(\mathbf{x}_i - \mathbf{x})\hat{\theta}_i}{\sum_{i=1}^m \mathcal{K}_H(\mathbf{x}_i - \mathbf{x})} \quad (9)$$

و در آن H به عنوان پهنه‌ای نوار و $H = diag(h_1, \dots, h_p)$ ، که h_i پهنه‌ای نوار مربوط به متغیر کمکی i است، و در صورتی که $\mathcal{K}_H(u) = (u_1, \dots, u_q)^T$ ، $u = (u_1, \dots, u_q)$ ، به صورت زیر تعریف می‌شود.

$$\mathcal{K}_H(u) = K_{h_1}(u_1) \cdots K_{h_q}(u_q)$$

¹Cross Validation

که $(.)_{h_i}$ ، تابع هسته با پهنه‌ای نوار h_i است. برای انتخاب پهنه‌ای نوار (H) ، نیز مانند قبل از معیار CV استفاده شده است که برای این برآوردهای به صورت زیر تعریف می‌شود.

$$\begin{aligned} CV(H) &= \frac{1}{m} \sum_{i=1}^m \left(\hat{\theta}_i - \hat{f}_H^{[-i]}(\mathbf{x}_i) \right)^2 \\ &= \frac{1}{m} \sum_{i=1}^m \left(\hat{\theta}_i - \hat{f}_H(\mathbf{x}_i) \right)^2 \left(1 - \frac{\mathcal{K}_H(\circ)}{\sum_{j=1}^m \mathcal{K}_H(\mathbf{x}_i - \mathbf{x}_j)} \right). \end{aligned}$$

برای محاسبه $\hat{\theta}_i^{Non}$ در این حالت کافی است در روابط (۶) و (۷) به جای $(.)_{h_i}$ ، $\hat{f}_H(\cdot)$ و W_{Hi} را قرار دهیم که

$$W_{Hi} = \frac{\mathcal{K}_H(\mathbf{x}_i - \mathbf{x})}{1/m \sum_{i=1}^m \mathcal{K}_H(\mathbf{x}_i - \mathbf{x})}.$$

در بخش بعد سه روش معرفی شده را با استفاده از شبیه‌سازی مقایسه می‌کنیم.

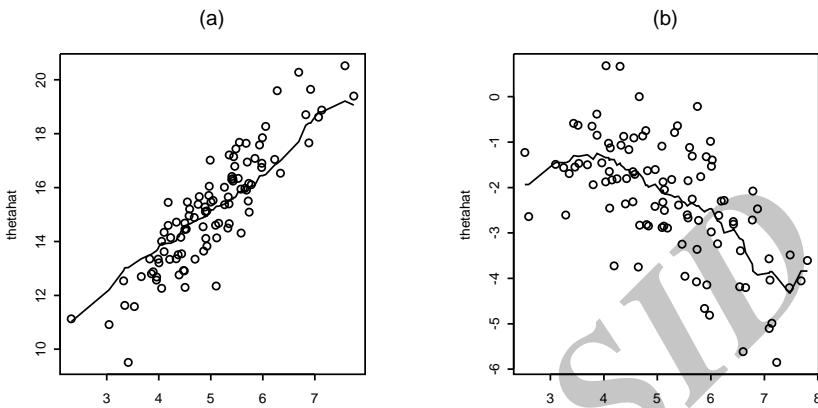
۳ شبیه‌سازی

به منظور مقایسه روش‌های معرفی شده، سه تابع میانگین به صورت زیر در نظر گرفته شده است.

- (i) $f_1(x_1) = 5 + 2x_1$
- (ii) $f_2(x_1) = 0.01 + 0.2x_1 - 0.005x_1^3$
- (iii) $f_3(\mathbf{x}) = x_2 \exp(-0.5x_1)$.

که x_1 و x_2 دارای توزیع یکنواخت $(0, 10)$ ، برای 100 ناحیه کوچک R بار شبیه‌سازی شده است. که در این شبیه‌سازی برای توابع f_1 و f_2 ، $R = 500$ و برای تابع f_3 ، $R = 200$ در نظر گرفته شده است.

در نمودار (a) شکل (۱)، نمودار پراکنش x در مقابل $\hat{\theta}$ برای یک نمونه شبیه‌سازی شده به همراه منحنی برآورده ناداریا-واتسون برای $h = 2$ برای تابع f_1 رسم شده است و در نمودار (b) شکل (۱)، نیز نمودار پراکنش x در مقابل $\hat{\theta}$ برای یک نمونه شبیه‌سازی شده به



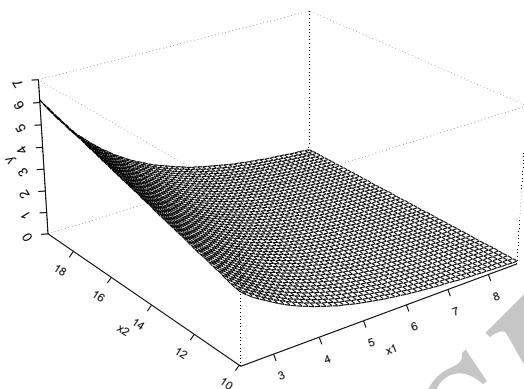
شکل ۱ : (a) نمودار پراکنش x در مقابل $\hat{\theta}$ برای یک نمونه شبیه‌سازی شده به همراه منحنی برآورده ناداریا-واتسون برای $m_1 = 2$ و (b) نمودار پراکنش x در مقابل $\hat{\theta}$ برای یک نمونه شبیه‌سازی شده به همراه منحنی برآورده ناداریا-واتسون برای $m_2 = 9$ برای تابع f_2

همراه منحنی برآورده ناداریا-واتسون برای $m_2 = 9$ برای تابع f_2 رسم شده است، و در شکل (۲) نیز، نمودار سطح شبیه‌سازی شده برای تابع f_2 و برای یک نمونه نوعی رسم شده است. از معیار

$$ASE(\hat{a}) = \frac{1}{m} \frac{1}{R} \sum_{i=1}^m \sum_{r=1}^R (\hat{a}_{ir} - a_i)^2$$

برای مقایسه سه روش استفاده شده است که در رابطه‌ی فوق $\hat{a} = (\hat{a}_1, \dots, \hat{a}_m)^T$ بردار برآوردهای حاصل برای هریک از روش‌های معرفی شده برای m ناحیه کوچک است. در جدول (۱)، مقادیر ASE حاصل از برآوردهای چهار روش مستقیم، ناپارامتری، $EBLUP$ و HB برای مشاهدات شبیه‌سازی شده براساس سه تابع f_1 ، f_2 و f_3 دیده می‌شود.

روش	مستقیم	ناپارامتری	$EBLUP$	HB
ASE_{f_1}	۰/۸۲۲	۰/۷۱۱	۰/۵۰۲	۰/۲۵۳
ASE_{f_2}	۷/۶۳۰	۷/۱۴	۷/۱۷۳	۶/۹۵۹
ASE_{f_3}	۴/۱۷۲	۳/۰۴۹	۳/۱۳۰	۲/۱۵۸



شکل ۲: نمودار سطح شبیه‌سازی شده برای یک نمونه

جدول ۱: مقادیر ASE ، حاصل از برآوردهای چهار روش مستقیم، ناپارامتری، HB و $EBLUP$ برای مشاهدات شبیه‌سازی شده براساستابع‌های f_1 ، f_2 و f_3 .

در جدول (۱) مقادیر ASE ، حاصل از برآوردهای چهار روش مستقیم، ناپارامتری، $EBLUP$ و HB برای مشاهدات شبیه‌سازی شده براساستابع‌های f_1 ، f_2 و f_3 دیده می‌شود. همانطور که ملاحظه می‌شود با توجه به خطی بودن تابع f_1 ، برآوردهای حاصل از روش ناپارامتری دو مرحله‌ای بعد از برآوردهای حاصل از روش مستقیم دارای بزرگترین مقدار از نظر معیار ASE است و برآوردهای حاصل از روش HB ، دارای کمترین مقدار از نظر این معیار است.

با خارج شدن فرم تابع از حالت خطی (f_2)، برآوردهای حاصل از روش ناپارامتری بهتر شده و مقادیر ASE آن از مقدار معیار $EBLUP$ روش ASE کمتر شده است. ولی همچنان برآوردهای حاصل از روش HB دارای کمترین مقدار ASE است. در مورد تابع دو متغیره‌ی f_3 نیز وضع به همین ترتیب است یعنی روش ناپارامتری بهتر از روش $EBLUP$ است ولی برآوردهای حاصل از روش HB دارای کمترین مقدار ASE است. به طور کلی با حرکت از حالت خطی به حالت ناخطي برآوردهای حاصل از روش ناپارامتری برآوردهای حاصل از روش $EBLUP$ از نظر معیار ASE پیشی می‌گیرد ولی در تمام حالات بررسی شده برآوردهای حاصل از روش HB بهترین برآوردهای در مقایسه با سه روش مستقیم، ناپارامتری و $EBLUP$ بود.

۴ کاربرد

همانطور که در بخش قبل ملاحظه شد، با استناد به نتایج حاصل از شبیه‌سازی روش بیز سلسله مراتبی به عنوان بهترین روش در مقایسه با سه روش مستقیم، ناپارامتری دو مرحله‌ای و *EBLUP* شناخته شد. در این قسمت سعی بر آن است تا با استفاده از روش بیز سلسله مراتبی متوسط هزینه خانوار را در استان‌های کشور براساس اطلاعات جمع آوری شده توسط بانک مرکزی جمهوری اسلامی ایران در سال ۸۵، برآورد کنیم.

اصولاً یکی از اساسی‌ترین مطالعات آماری که به منظور نیل به اهداف مختلف اقتصادی و اجتماعی، در اغلب کشورهای جهان صورت می‌گیرد، بررسی بودجه خانوار است. از طریق این بررسی می‌توان به چگونگی هزینه‌ها و درآمدهای خانوارها و روند تغییرات آنها و نیز آمار و اطلاعات گوناگون دیگری پی برد.

بررسی هزینه و درآمد خانوار مناطق شهری ایران نیز یکی از اساسی‌ترین بررسی‌های آماری در ایران است و از آنجا که نتایج آن پایه بسیاری از محاسبات و تحقیقات اقتصادی و اجتماعی قرار می‌گیرد، حائز کمال اهمیت است.

این طرح یک طرح نمونه‌گیری است و چنانچه در برخی از استان‌ها، نمونه استفاده شده از نظر تعداد کمتر از سایر استان‌ها باشد روش بیز سلسله مراتبی بهتر از روش برآورد مستقیم عمل می‌کند. از این رو در این بخش سعی بر آن است تا با استفاده از اطلاعات کمکی موجود و روش بیز سلسله مراتبی، برآورد متوسط هزینه خانوار برای هر استان را با دقت قابل قبولی ارائه کنیم.

متغیر پاسخ مورد استفاده متوسط هزینه ناخالص خانوار است که شامل کلیه هزینه‌های خانوار به استثنای هزینه‌های شغلی و سرمایه‌گذاری است.

بعد از بررسی‌های مربوط به همبستگی و با استفاده از روش‌های رگرسیونی متغیرهای زیر به عنوان متغیرهای کمکی انتخاب شدند.

- درآمد ناخالص خانوار (شامل کلیه وجهه وارزش پولی کالاهایی که در مقابل کار انجام شده، سرمایه به کار افتاده و یا از محل سایر منابع مانند حقوق بازنیستگی، واگذاری املاک (اجاره) و مانند آن‌ها در دوره مورد بررسی به خانوار تعلق می‌گیرد.)

- تعداد اعضای شاغل خانوار

- تعداد اعضای باسوساد خانوار

با بررسی روی باقیمانده‌های مدل رگرسیونی، تبدیل لگاریتمی برای متوسط هزینه و متوسط درآمد هر استان مناسب تشخیص داده شد.

روش بیز معرفی شده با فرض معلوم بودن واریانس خطای نمونه‌گیری بیان شد به این منظور از برآورد واریانس نمونه‌گیری تصادفی ساده که به صورت

$$\hat{Var}(\bar{Y}_i) = \frac{S_i^2}{n_i}$$

استفاده شد. که S_i^2 واریانس نمونه‌ای ناحیه کوچک نام و n_i تعداد نمونه ناحیه کوچک نام است. همانطور که در بخش ۲.۲ بیان شد در فرض می‌شود $\sim IG(a, b)$ ، برای ابیارامترهای a و b نیز مقدار 100% در نظر گرفته شده است و تعداد تکرار نمونه‌گیری گیبس برابر 5000 انتخاب شد.

با انجام محاسبات نتایج زیر برای برآورد متوسط خانوار هر استان برای سال ۸۵ با استفاده از روش مستقیم و بیز سلسله مراتبی حاصل شد.

نام استان	روش مستقیم	روش HB	نام استان	روش مستقیم	روش HB
آذربایجان شرقی	۵۷۵۲۲۹۱۴	۶۰۶۹۱۲۷۱	فارس	۸۵۳۵۷۳۷	۸۳۳۲۱۲۸۶
آذربایجان غربی	۵۹۶۱۷۴۱۸	۶۳۵۲۲۲۳۶	قزوین	۸۰۸۰۷۱۸۱	۸۲۱۴۰۲۰۰
اریبل	۷۹۱۹۰۱۳۱	۷۱۷۵۹۲۶۶	قم	۵۳۰۸۵۶۹۶	۵۳۶۱۷۳۶۳
اصفهان	۷۸۳۲۲۷۷۸	۷۶۳۲۷۸۵۴	کردستان	۶۵۰۳۰۷۸۲	۶۲۵۸۱۴۲۴
ایلام	۸۵۱۹۵۹۰۴	۸۲۳۰۶۹۰۴	کرمان	۷۵۰۹۸۵۶۹	۷۳۰۹۲۹۹۶
بوشهر	۸۸۸۸۷۲۳۷۱	۸۵۲۷۹۲۲۸	کرمانشاه	۶۷۱۴۳۵۱۵	۶۶۸۴۹۲۲۶
تهران	۱۰۴۳۱۰۷۵۹	۱۰۳۶۹۶۷۵۱	کهکیلویه و بویراحمد	۹۶۲۱۵۳۵۷	۹۷۰۸۶۸۶
چهارمحال و بختیاری	۸۷۴۶۷۷۱۴	۸۵۹۲۶۲۶۴	گلستان	۶۸۰۱۷۷۴۷	۷۴۶۵۱۹۷۶
خراسان رضوی	۵۴۷۶۳۷۴۷	۵۶۱۸۲۵۱۸	گیلان	۷۶۱۶۶۵۶۸	۷۶۷۲۶۴۶۱
خراسان شمالی	۵۵۸۰۸۹۸۱	۵۵۶۵۲۵۷۱	لرستان	۶۳۷۲۶۸۵۷	۶۴۵۵۶۲۹۶
خراسان جنوبی	۶۵۹۸۱۷۷۸	۶۴۴۲۲۸۵۷	مازندران	۸۵۴۷۰۶۶۰	۸۳۷۱۰۶۷۹
خوزستان	۹۰۶۱۸۱۵۸	۹۲۰۷۹۶۸۰	مرکزی	۷۷۴۹۲۲۳۴	۷۰۳۶۱۷۱۵
زنجان	۶۸۶۷۲۵۶	۶۹۹۶۱۴۴۳	همزگان	۵۶۳۵۷۵۵	۶۱۱۶۴۵۸۰
سمنان	۶۹۵۹۵۹۲۲	۶۶۲۶۸۷۷۱	همدان	۷۰۳۰۷۳۴۲	۷۱۹۱۰۸۸۶
سیستان و بلوچستان	۵۲۵۴۳۲۲۳	۵۴۷۲۳۱۵۳۶	پزد	۷۸۲۳۸۱۲۱	۷۶۵۸۳۵۰۱

جدول ۲: مقادیر برآورد متوسط هزینه خانوار استان‌ها با استفاده از روش مستقیم و روش بیز سلسله مراتبی.

در جدول (۲)، مقادیر برآورد متوسط هزینه خانوار استان‌ها با استفاده از روش مستقیم و روش بیز سلسله مراتبی دیده می‌شود، همانطور که ملاحظه می‌شود تفاوت وضعیت استان‌ها از نظر متوسط هزینه خانوار در روش مستقیم با روش بیز سلسله مراتبی کاملاً مشخص است. اگر استان‌های کشور را براساس بزرگی مقادیر برآورد روش مستقیم نسبت به مقادیر برآورد روش بیز سلسله مراتبی به سه دسته تقسیم کنیم، دسته‌ای از استان‌ها که مقدار برآورد روش مستقیم آنها بزرگتر از مقدار برآورد حاصل از روش HB است، به ترتیب بزرگی اختلاف

شامل استان‌های اردبیل، بوشهر، سمنان، کردستان، مرکزی، فارس، کرمان، اصفهان، ایلام، مازندران، یزد، خراسان جنوبی و چهارمحال بختیاری می‌شود. استان‌های تهران، کرمانشاه، خراسان شمالی، قم، گیلان، لرستان، کهگیلویه و بویراحمد نیز دسته‌ای از استان‌ها را شامل می‌شوند که مقدار برآورد روش مستقیم آنها نزدیک به مقدار برآورد روش HB است. و در آخر دسته‌ای از استان‌ها که مقدار برآورد روش مستقیم آنها کمتر از مقدار برآورد روش HB است عبارتند از:

گلستان، هرمزگان، آذربایجان غربی، آذربایجان شرقی، سیستان و بلوچستان، خوزستان، همدان، خراسان رضوی، زنجان و قزوین.

۵ تیجه‌گیری

در این مقاله با استفاده از مدل‌های سطح ناحیه، سه روش، ناپارامتری دو مرحله‌ای، بهترین پیشگویی نالریب خطی تجربی و بیز سلسله مراتبی، تحت دو ساختار خطی و ناخطي را با یکدیگر مقایسه شده و با توجه به ملاک مقایسه‌ای ASE ، بهترین روش انتخاب شد. به طور کلی با حرکت از حالت خطی به حالت ناخطي برآورده حاصل از روش ناپارامتری بر برآورده حاصل از روش $EBLUP$ از نظر معیار ASE پیشی می‌گیرد ولی در تمام حالات بررسی شده برآورده حاصل از روش HB بهترین برآورده در مقایسه با سه روش مستقیم، ناپارامتری و $EBLUP$ بود.

مراجع

- [1] Fay, R. E and Herriot, R. A. (1979). Estimation of income from small places: an application of James-Stein procedures to census data. *J. Amer. Stat. Assoc.* **74**, 269-277.

- [2] Gelfand, A. E. and Smith, A. F. M. (1990). Smpling based approaches to calculating marginal densities. *J. Amer. Stat. Assoc.* **85**, 398-409.
- [3] Ghosh, M. and Rao, J. N. K. (1994). Small ares estimation: an appraisal (with discussion). *Stat. Sci.* **9**, 55-93.
- [4] Härdle, W. and Müller, M. (2000). *Multivariate and Semiparametric kernel regression*. Wiley, NewYork.
- [5] Henderson, C. R. (1975). Best linear unbiased estimation and prediction under a selection model. *Biometrics*. **31**, 423-447.
- [6] Mukhopadhyay, P. and Maiti, T. (2004). Two stage non-parametric approach for small area estimation. *ASA Section on Survey Research Methods*.
- [7] Rao, J. N. K. (2003). *Small Area Estimation*. Wiley, New York.
- [۸] زارعی، ش.، گرامی، ع. و جعفری خالدی، م. (۱۳۸۶). مقایسه‌ی برآورد ناحیه‌ی کوچک متوسط درآمد خانوار در برخی از استان‌های کشور با روش بیز سلسله مراتبی. *پژوهش‌های آماری ایران*، **۴**. ۷۱-۹۰.