

مدل رگرسیونی بیزی با متغیر پاسخ پواسون آمیخته متناهی دو متغیره

افشین فلاح، مهسا نادی‌فر، رامین کاظمی

گروه آمار، دانشگاه بین‌المللی امام خمینی

تاریخ دریافت: ۱۳۹۱/۱۰/۳ تاریخ آخرین بازنگری: ۱۳۹۲/۴/۳۰

چکیده: در این مقاله تحلیل رگرسیونی با متغیر پاسخ دارای توزیع پواسون دو متغیره آمیخته با رهیافت بیزی مورد بررسی قرار گرفته است. نشان داده شده است که به دلیل شکل پیچیده تابع درستنامایی ملتی بر توزیع پواسون دو متغیره، توزیع پسین فاقد شکل بسته بوده و پیچیده است. از این رو، توزیع‌های پسین شرطی کامل پارامترها محاسبه و الگوریتم گیز برای نمونه‌گیری از توزیع پسین ارائه شده است. به منظور ارزیابی مدل بیزی پیشنهادی، مطالعه‌ای شبیه‌سازی انجام شده و کارایی برآوردهای بیزی پیشنهادی برای پارامترهای مدل با همتای ساماندی آن‌ها مقایسه شده است. همچنین، نحوه کاربست رهیافت بیزی پیشنهادی در قالب یک مثال کاربردی شرح داده شده و کارایی آن مورد ارزیابی قرار گرفته است.

واژه‌های کلیدی: رگرسیون پواسون، توزیع آمیخته، الگوریتم EM، الگوریتم گیز.

مدل رگرسیون پواسون از تکنیک‌های بسیار پرکاربرد در زمینه تحلیل داده‌های شمارشی است. این مدل نمونه‌ای از مدل‌های خطی تعمیم‌یافته است، که در آن متغیر وابسته شمارشی بوده و از توزیع پواسون پیروی می‌کند. معادله رگرسیون پواسون، یک متغیر شمارشی با نرخ وقوع خاص را به مجموعه‌ای از متغیرهای تبیینی^۱ مربوط می‌سازد. برابری واریانس متغیر وابسته با میانگین آن یکی از مفروضات اصلی تحلیل رگرسیون پواسون است. اما در بسیاری از موارد مشاهدات پاسخ بیش پراکنده‌اند، به این معنی که واریانس مشاهدات به طور معنی‌داری از میانگین آن‌ها بزرگ‌تر است. در این شرایط برآش مدل رگرسیونی پواسون به داده‌ها مناسب نیست. در این موقع می‌توان از تحلیل رگرسیون دوجمله‌ای منفی کمک گرفت (گاردنر و همکاران، ۱۹۹۵). وجود صفرهای بیش از حد در مشاهدات متغیر پاسخ نیز یکی دیگر از مشکلات در تحلیل داده‌های شمارشی است. لمبرت (۱۹۹۲) مدل رگرسیون پواسون در صفر متورم^۲ را معرفی کرد. مدل رگرسیون دوجمله‌ای منفی در صفر متورم نیز توسط وانگ (۲۰۰۳) و گارای و همکاران (۲۰۱۱) مورد مطالعه قرار گرفته است. یکی از راه‌های مقابله با مشکل وجود صفرهای بیش از حد در مشاهدات پاسخ، استفاده از توزیع پواسون دو متغیره است. مدل‌های در صفر متورم در حالت دو متغیره توسط کارلیس و ان‌سوفراس (۲۰۰۳) و گورمو و والدر (۲۰۰۸) مورد مطالعه قرار گرفته‌اند. اخیراً بر مودز (۲۰۰۹) و بر مودز و کارلیس (۲۰۱۱) درباره نحوه استفاده از مدل‌های رگرسیون در صفر متورم دو و چندمتغیره برای رتبه‌بندی بیمه اتومبیل مطالعاتی انجام داده‌اند. آن‌ها مدل رگرسیون پواسون دو متغیره را برای بررسی همبستگی ذاتی دو ادعا در صنعت بیمه مورد استفاده قرار دادند. یکی از مزیت‌های استفاده از توزیع‌های دو متغیره این است که می‌توان همبستگی بین دو متغیر پاسخ مختلف را در نظر گرفت و به نتایج مطلوب‌تری دست یافت. گرچه این مدل‌ها برای داده‌های در صفر متورم مناسب هستند، اما برای مدل‌بندی مشاهداتی که بیش پراکنده نیز باشند، از کارایی مطلوبی

^۱ Explanatory^۲ Zero-inflated

برخوردار نیستند. از این رو، بر مودز و کارلیس (۲۰۱۲) مدل رگرسیون آمیخته متناهی پواسون دو متغیره را مطرح و نحوه برآورد پارامترهای مدل را بر اساس رهیافت بسامدی ماکسیمم درستنماهی و به کمک الگوریتم EM شرح دادند.

در این مقاله تحلیل رگرسیونی با متغیر پاسخ دارای توزیع پواسون آمیخته دو متغیره با رهیافت بیزی مورد توجه قرار گرفته است. برای این منظور، با در نظر گرفتن توزیع‌های پیشین مناسب برای پارامترها و بر اساس تابع درستنماهی داده‌های کامل، توزیع پسین پارامترهای مدل محاسبه شده است. نشان داده شده است که به دلیل شکل پیچیده تابع درستنماهی مبتنی بر توزیع پواسون دو متغیره، توزیع پسین فاقد شکل بسته بوده و پیچیده است. از این رو، توزیع‌های پسین شرطی کامل پارامترها محاسبه و الگوریتم گیبز برای نمونه‌گیری از توزیع پسین استفاده شده است. همچنین، کارایی مدل بیزی پیشنهادی در برآورد پارامترهای مدل در مقایسه با مدل بسامدی رقیب مورد ارزیابی قرار گرفته است.

در بخش ۲ مدل رگرسیون آمیخته متناهی پواسون دو متغیره و داده‌های ناقص و کامل به طور اجمالی معرفی و سپس رهیافت بسامدی برآورد پارامترهای مدل بر اساس روش ماکسیمم درستنماهی و الگوریتم EM، شرح داده شده است. در بخش ۳ رهیافت بیزی تحلیل رگرسیون آمیخته متناهی پواسون دو متغیره مورد بحث قرار گرفته و نحوه تعیین توزیع پیشین، محاسبه توزیع پسین، نمونه‌گیری از توزیع پسین و غیره شرح داده شده است. در بخش ۴، مطالعه‌ای شبیه‌سازی برای ارزیابی و مقایسه مدل رگرسیون آمیخته متناهی پواسون دو متغیره در رهیافت بسامدی و بیزی صورت پذیرفته است. در بخش ۵، نحوه کاربست رهیافت بیزی پیشنهادی در قالب یک مثال کاربردی درباره عوامل موثر بر بروز سرطان‌های معده و روده بزرگ، شرح داده شده است.

۲ مدل رگرسیون آمیخته متناهی پواسون دو متغیره

در حالت تک متغیره بهترین راه حل مشکل بیش‌پراکنش در مشاهدات پاسخ جایگزین کردن توزیع دو جمله‌ای منفی به جای توزیع پواسون می‌باشد، اما در

حالات چندمتغیره استفاده از این توزیع در عمل دشوار است (برمودز و کارلیس، ۲۰۱۱). یک راه حل معقول برای رفع مشکل بیشپراکنش، استفاده از مدل رگرسیون پواسون با متغیر پاسخ آمیخته است. توزیع پواسون دومتغیره به صورت

$$BP(y_1, y_r | \lambda_1, \lambda_r, \lambda_{\tau}) = e^{-(\lambda_1 + \lambda_r + \lambda_{\tau})} \frac{\lambda_1^{y_1}}{y_1!} \frac{\lambda_r^{y_r}}{y_r!} \sum_{s=0}^{\min(y_1, y_r)} \binom{y_1}{s} \binom{y_r}{s} s! (\frac{\lambda_{\tau}}{\lambda_1 \lambda_r})^s,$$

تعریف می‌شود. بر این اساس، مدل رگرسیون پواسون دومتغیره با متغیر پاسخ آمیخته متناهی را می‌توان به‌ازای $n, \dots, i = 1$ به صورت

$$\begin{aligned} Y_i | x_{1i}, x_{2i}, x_{3i} &\sim \sum_{j=1}^g \alpha_j BP(y_{1i}, y_{ri} | \lambda_{1j}(x_{1i}), \lambda_{rj}(x_{ri}), \lambda_{\tau j}(x_{\tau i})) \\ BP(y_i | x_{1i}, x_{2i}, x_{3i}) &= \sum_{j=1}^g [\alpha_j e^{-(\lambda_{1j}(x_{1i}) + \lambda_{rj}(x_{ri}) + \lambda_{\tau j}(x_{\tau i}))} \\ &\quad \times \frac{\lambda_{1j}^{y_{1i}}(x_{1i}) \lambda_{rj}^{y_{ri}}(x_{ri})}{y_{1i}! y_{ri}!} \\ &\quad \times \sum_{s_i=0}^{\min(y_{1i}, y_{ri})} \binom{y_{1i}}{s_i} \binom{y_{ri}}{s_i} s_i! (\frac{\lambda_{\tau j}(x_{\tau i})}{\lambda_{1j}(x_{1i}) \lambda_{rj}(x_{ri})})^{s_i}], \quad (1) \end{aligned}$$

نوشت، که در آن $\lambda_{\ell j}(x_{\ell i}) = \exp(x'_{\ell i} \beta_{\ell j})$, $Y_i = (Y_{i1}, Y_{i2})'$
 $x'_{\ell i} = (x_{1\ell i}, \dots, x_{p\ell i})$, $j = 1, \dots, g$
 بردار متغیرهای تبیینی مربوط به ℓ امین پارامتر
 توزیع پواسون دومتغیره و $\beta'_{\ell j} = (\beta_{1\ell j}, \dots, \beta_{p\ell j})$ بردار ضرایب رگرسیونی مربوط
 به ℓ امین پارامتر توزیع پواسون دومتغیره و ℓ امین زیرجامعه است. مجموعه
 پارامترهای مدل رگرسیون پواسون دومتغیره با متغیر پاسخ آمیخته متناهی g مؤلفه‌ای
 به صورت

$$\Phi = \{\theta, \alpha\} = \{\{\beta_{1j}, \beta_{2j}, \beta_{rj}\}_{j=1}^g, (\alpha_1, \dots, \alpha_g)\}$$

و مشتمل بر $g + 3gp$ پارامتر است. فرض کنید نمونه‌ای تصادفی به حجم n
 به صورت $\mathcal{D} = \{(x_{1i}, x_{2i}, x_{3i})\}_{i=1}^n$ موجود است. چون از نحوه انتساب
 مشاهدات به زیرجامعه‌های توزیع آمیخته اطلاعاتی در دست نیست، چنین داده‌ای

را اصطلاحاً ناقص می‌نامند و تابع درستنماهی آنها به صورت

$$\begin{aligned} L(\theta, \alpha) &= \prod_{i=1}^n \left\{ \sum_{j=1}^g \alpha_j BP(y_{1i}, y_{\tau_i} | \lambda_{1j}(x_{1i}), \lambda_{\tau j}(x_{\tau_i}), \lambda_{\tau j}(x_{\tau_i})) \right\} \\ &= \prod_{i=1}^n \left\{ \sum_{j=1}^g [\alpha_j e^{-(\lambda_{1j}(x_{1i}) + \lambda_{\tau j}(x_{\tau_i}) + \lambda_{\tau j}(x_{\tau_i}))} \right. \\ &\quad \times \frac{\lambda_{1j}^{y_{1i}}(x_{1i})}{y_{1i}!} \frac{\lambda_{\tau j}^{y_{\tau i}}(x_{\tau_i})}{y_{\tau i}!} \\ &\quad \times \left. \sum_{s_i=0}^{\min(y_{1i}, y_{\tau i})} \binom{y_{1i}}{s_i} \binom{y_{\tau i}}{s_i} s_i! \left(\frac{\lambda_{\tau j}(x_{\tau_i})}{\lambda_{1j}(x_{1i}) \lambda_{\tau j}(x_{\tau_i})} \right)^{s_i}] \right\}, \end{aligned}$$

تعریف می‌شود. به کمک بردار متغیرهای گم شده $z = (z_{i1}, \dots, z_{ig})^T$ ، که نشان‌دهنده وضعیت انتساب هر مشاهده به مؤلفه‌های توزیع آمیخته است و به صورت

$$z_{ij} = \begin{cases} 1 & y_i = (y_{1i}, y_{\tau_i}) \\ 0 & \text{در غیر این صورت} \end{cases}$$

تعریف می‌شود، نسخه دیگری از داده‌ها که اصطلاحاً داده‌های کامل نامیده می‌شوند، ساخته می‌شود. چون هر مشاهده تنها می‌تواند به یک مؤلفه از توزیع آمیخته تعلق داشته باشد، بنا بر این روابط $\sum_{i=1}^n \sum_{j=1}^g z_{ij} = n$ و $\sum_{j=1}^g z_{ij} = 1$ برابر قرار است. بردارهای تصادفی z دارای توزیع چندجمله‌ای $\mathcal{M}(\alpha_1, \dots, \alpha_g)$ هستند. از این رو،

تابع درستنماهی داده‌های کامل به صورت

$$\begin{aligned} L_c(\theta, \alpha) &= P(\mathcal{D} | \theta, \alpha) \\ &= \prod_{i=1}^n \prod_{j=1}^g \{ [BP(y_{1i}, y_{\tau_i} | \beta_{1j} \beta_{\tau_j}, \beta_{\tau_j}, x_{1i}, x_{\tau_i}, x_{\tau_i})]^{z_{ij}} \alpha_j^{z_{ij}} \} \\ &= \prod_{i=1}^n \left(\prod_{j=1}^g [e^{-(\exp(x'_{1i} \beta_{1j}) + \exp(x'_{\tau_i} \beta_{\tau_j}) + \exp(x'_{\tau_i} \beta_{\tau_j}))} \right. \\ &\quad \times \frac{(\exp(x'_{1i} \beta_{1j}))^{y_{1i}}}{y_{1i}!} \frac{(\exp(x'_{\tau_i} \beta_{\tau_j}))^{y_{\tau i}}}{y_{\tau i}!} \\ &\quad \times \left. \sum_{s_i=0}^{\min(y_{1i}, y_{\tau i})} \binom{y_{1i}}{s_i} \binom{y_{\tau i}}{s_i} s_i! \right. \\ &\quad \times \left. \left(\frac{\exp(x'_{\tau_i} \beta_{\tau_j})}{\exp(x'_{1i} \beta_{1j}) \exp(x'_{\tau_i} \beta_{\tau_j})} \right)^{s_i} \right)^{z_{ij}} \prod_{j=1}^g \alpha_j^{s_i}, \end{aligned} \tag{۲}$$

خواهد بود، که در آن $\mathcal{D} = \{(y_{1i}), x_{1i}, x_{2i}, x_{3i}\}_{i=1}^n$ نشان‌دهنده مشاهدات و $\eta_j = \sum_{i=1}^n z_{ij}$ بیان‌گر تعداد مشاهدات مربوط به زیر‌جامعه z ام توزیع آمیخته است.

۱.۲ رهیافت بسامدی برآش مدل رگرسیون آمیخته پواسون دو متغیره

چون برآوردهای ماکسیمم درستنمایی پارامترهای مدل رگرسیون پواسون دو متغیره با متغیر پاسخ آمیخته متناهی فرم بسته ندارند، یکی از روش‌های رایج برای برآورد ماکسیمم درستنمایی پارامترهای این مدل، استفاده از الگوریتم EM است (دمپستر و همکاران، ۱۹۷۷). در این مدل بردار متغیرهای پنهان به صورت

$$\mathbf{b}_{ij} = (B_{1ij}, B_{2ij}, B_{3ij}) = (V_{1ij}, V_{2ij}, V_{3ij}),$$

تعریف می‌شود. با توجه به این که y_i بردار داده‌های مشاهده شده و z_i بردار متغیرهای گم شده است، بردار داده‌های کامل به صورت $(y_i, \mathbf{e}_{ij}, z_i) = (y_i, \mathbf{e}_{ij}, z_i)$ می‌باشد. بنابراین تابع درستنمایی داده‌های کامل به صورت

$$L_c(\boldsymbol{\Phi}) = \prod_{i=1}^n \prod_{j=1}^g \left(\alpha_j BP(y_{1i}, y_{2i} | \lambda_{1j}(x_{1i}), \lambda_{2j}(x_{2i}), \lambda_{3j}(x_{3i}))^{z_{ij}} \right),$$

به دست می‌آید، که در آن $(\{\beta_{1j}, \beta_{2j}, \beta_{3j}\}_{j=1}^g, (\alpha_1, \dots, \alpha_g))$. با فرض استقلال متغیرهای پنهان $V_{\ell ij}$ ، $i = 1, \dots, n$ ، $j = 1, \dots, g$ ، $\ell = 1, 2, 3$ ، لگاریتم درستنمایی داده‌های کامل برابر

$$\begin{aligned} \ell_c(\boldsymbol{\Phi}) &= \sum_{i=1}^n \sum_{j=1}^g z_{ij} \log \alpha_j \\ &+ \sum_{i=1}^n \sum_{j=1}^g z_{ij} \sum_{\ell=1}^3 (-\lambda_{\ell j}(x_{\ell i}) + v_{\ell ij} \log \lambda_{\ell j}(x_{\ell i}) - \log v_{\ell ij}), \quad (3) \end{aligned}$$

است. چون برآورد پارامتر $\lambda_{\ell j}$ مطرح است، می‌توان رابطه (4) را معادل

$$\ell_c(\boldsymbol{\Phi}) \propto \sum_{i=1}^n \sum_{j=1}^g (-z_{ij} \lambda_{\ell j}(x_{\ell i}) + z_{ij} v_{\ell ij} \log \lambda_{\ell j}(x_{\ell i})),$$

در نظر گرفت. بنابراین امید ریاضی تابع لگاریتم درستنمایی داده‌های کامل به صورت

$$E(\ell_c(\Phi)) = \sum_{i=1}^n \sum_{j=1}^g (-E(Z_{ij})\lambda_{\ell j}(x_{\ell i}) + E(Z_{ij}V_{\ell ij}) \log \lambda_{\ell j}(x_{\ell i})),$$

خواهد بود. چون z_{ij} یک متغیر تصادفی برآولی است، وقتی نامین مشاهده به زمین مؤلفه تعلق نداشته باشد، $v_{\ell ij}$ دارای مقدار صفر و در غیر این صورت دارای مقداری غیر صفر می‌باشد. بنا بر این می‌توان نوشت

$$E(Z_{ij}V_{\ell ij}) = p(z_{ij})E(V_{\ell ij} | z_{ij} = 1). \quad (4)$$

امید ریاضی سمت راست رابطه (5)، امید ریاضی متغیرهای پنهان به شرط تعلق نامین مشاهده به زمین مؤلفه توزیع آمیخته است. بنا بر این در مرحله E، تنها محاسبه $E(Z_{ij} | y_i, \lambda_{1j}(x_{1i}), \lambda_{2j}(x_{2i}), \lambda_{3j}(x_{3i}))$ و $E(V_{\ell ij} | y_i, z_{ij} = 1, \lambda_{1j}(x_{1i}), \lambda_{2j}(x_{2i}), \lambda_{3j}(x_{3i}))$ لازم است. به طور کلی مراحل الگوریتم EM به صورت زیر است:

۱) مقدار اولیه. مقادیر اولیه مناسبی را برای پارامترهای مدل در نظر بگیرید.

۲) مرحله E. در مرحله tام مقادیر

$$\begin{aligned} w_{ij}^{(t)} &= E(Z_{ij} | y_i, \lambda_{1j}^{(t)}(x_{1i}), \lambda_{2j}^{(t)}(x_{2i}), \lambda_{3j}^{(t)}(x_{3i})) \\ &= \frac{\alpha_j^{(t)} P(y_i | \lambda_{1j}^{(t)}(x_{1i}), \lambda_{2j}^{(t)}(x_{2i}), \lambda_{3j}^{(t)}(x_{3i}))}{\sum_{j=1}^g \alpha_j^{(t)} P(y_i | \lambda_{1j}^{(t)}(x_{1i}), \lambda_{2j}^{(t)}(x_{2i}), \lambda_{3j}^{(t)}(x_{3i}))}, \\ b_{1ij}^{(t)} &= E(V_{1ij} | y_i, z_{ij} = 1, \lambda_{1j}^{(t)}(x_{1i}), \lambda_{2j}^{(t)}(x_{2i}), \lambda_{3j}^{(t)}(x_{3i})) \\ &= y_{1i} - b_{1ij}^{(t)}, \\ b_{2ij}^{(t)} &= E(V_{2ij} | y_i, z_{ij} = 1, \lambda_{1j}^{(t)}(x_{1i}), \lambda_{2j}^{(t)}(x_{2i}), \lambda_{3j}^{(t)}(x_{3i})) \\ &= y_{2i} - b_{2ij}^{(t)}, \end{aligned}$$

را محاسبه کنید، که در آن‌ها

$$b_{3ij}^{(t)} = E(V_{3ij} | y_i, z_{ij} = 1, \lambda_{1j}^{(t)}(x_{1i}), \lambda_{2j}^{(t)}(x_{2i}), \lambda_{3j}^{(t)}(x_{3i}))$$

$$= \begin{cases} \frac{BP[y_{\backslash i}-1, y_{\triangleright i}-1 | \lambda_{\backslash j}^{(t)}(\mathbf{x}_{\backslash i}), \lambda_{\triangleright j}^{(t)}(\mathbf{x}_{\triangleright i}), \lambda_{\triangleright j}^{(t)}(\mathbf{x}_{\triangleright i})]}{BP[y_{\backslash i}, y_{\triangleright i} | \lambda_{\backslash j}^{(t)}(\mathbf{x}_{\backslash i}), \lambda_{\triangleright j}^{(t)}(\mathbf{x}_{\triangleright i}), \lambda_{\triangleright j}^{(t)}(\mathbf{x}_{\triangleright i})]} \lambda_{\triangleright j}^{(t)}(\mathbf{x}_{\triangleright i}) & y_{\backslash i}y_{\triangleright i} > 0 \\ 0 & y_{\backslash i}y_{\triangleright i} = 0. \end{cases}$$

(۳) مرحله M. براساس مقادیر پارامترها در مرحله tام، برآورد پارامترها در مرحله

(t+1)ام را به صورت

$$\begin{aligned} \alpha_j^{(t+1)} &= \frac{\sum_{i=1}^n w_{ij}^{(t)}}{n} \\ \beta_{\backslash j}^{(t+1)} &= \hat{\beta}(y_{\backslash} - b_{\backslash j}^{(t)}, \mathbf{x}_{\backslash}, \mathbf{w}_j^{(t)}), \\ \beta_{\triangleright j}^{(t+1)} &= \hat{\beta}(y_{\triangleright} - b_{\triangleright j}^{(t)}, \mathbf{x}_{\triangleright}, \mathbf{w}_j^{(t)}), \\ \beta_{\triangleright j}^{(t+1)} &= \hat{\beta}(b_{\triangleright j}^{(t)}, \mathbf{x}_{\triangleright}, \mathbf{w}_j^{(t)}). \end{aligned}$$

محاسبه کنید، که در آن $b_{\triangleright j} = [b_{\backslash j}, \dots, b_{nj}]^T$ یک بردار $n \times 1$ بعدی و $\hat{\beta}(y, \mathbf{x}, \mathbf{w})$ برآوردگر ماکسیمم درستنمایی موزون پارامترهای یک مدل پواسون دو متغیره با بردار پاسخ y هستند.

(۴) همگرایی. مراحل E و M را تا همگرا شدن الگوریتم تکرار کنید.

انتخاب مقادیر اولیه مناسب و تعیین قاعده همگرایی الگوریتم، دو مساله مهم و تاثیرگذار بر دقت برآوردهای حاصل از الگوریتم EM هستند. پرای بررسی همگرایی الگوریتم EM قواعد مختلفی پیشنهاد شده است. به عنوان نمونه می‌توان از قاعده ساده‌ای به صورت

$$|\Phi^{(t+1)} - \Phi^{(t)}| \leq \xi,$$

استفاده کرد، که در آن ξ کمیت کوچکی است و آستانه همگرایی نامیده می‌شود (بوهینینگ و همکاران، ۱۹۹۴). انتخاب مقدار اولیه بر نرخ همگرایی الگوریتم تاثیرگذار است و اگر مقادیر اولیه نامناسبی اختیار شوند، الگوریتم همگرایی کندی خواهد داشت. معمولاً توصیه می‌شود مقادیر اولیه مختلفی مورد آزمایش قرار گیرند تا بهترین نرخ همگرایی و بازش حاصل شود (دمستر و همکاران، ۱۹۷۷).

به طور کلی، هنگامی که مدل پیچیده و تعداد پارامترها زیاد باشد، تعیین مقادیر اولیه مناسب برای پارامترها کار ساده‌ای نیست. از طرفی، چون خواص بهینگی برآوردگرهای ماکسیمم درستنمایی تنها برای نمونه‌های بزرگ بروز می‌کند، مدل بسامدی برای نمونه‌های کوچک از کارایی مطلوبی برخوردار نیست. از این رو، در بخش بعد توسعه رهیافت بیزی مساله به عنوان مدل جایگزین رهیافت بسامدی برموذز و کارلیس (۲۰۱۲) مطرح شده است.

۳ رهیافت بیزی برآش مدل رگرسیون آمیخته پواسون دو متغیره

به طور کلی تحلیل بیزی مدل‌های آمیخته دارای پیچیدگی‌های زیاد و دشواری‌های خاص خود است. توزیع پسین در این مدل‌ها عموماً پیچیده و فاقد فرم بسته است. به علاوه نمونه‌گیری مناسب از توزیع پسین اغلب امری دشوار و زمان‌بر است (مارین و همکاران، ۲۰۰۵). برآورد بیزی پارامترها در مدل‌های آمیخته بر اساس تابع درستنمایی داده‌های کامل صورت می‌پذیرد و از این نظر شبیه رهیافت بسامدی و استفاده از الگوریتم EM است.

۱.۳ توزیع‌های پیشین

برای مدل رگرسیون پواسون دو متغیره با متغیر پاسخ آمیخته متناهی g مؤلفه‌ای، توزیع پیشین پارامترها را می‌توان با فرض استقلال پیشینی ضرایب رگرسیونی و ضرایب آمیختگی به صورت

$$\pi(\Phi) = \prod_{j=1}^g [\pi(\beta_{1j}, \beta_{2j}, \beta_{3j})] \pi(\alpha_1, \dots, \alpha_g), \quad (5)$$

نوشت. عموماً برای ضرایب آمیختگی، $\alpha = (\alpha_1, \dots, \alpha_g)$ ، توزیع پیشین دیریکله به صورت

$$\begin{aligned} \pi(\alpha_1, \dots, \alpha_g) &= Dirichlet(c_1, \dots, c_g) \\ &= \frac{1}{B(c)} \prod_{j=1}^g \alpha_j^{c_j - 1} \end{aligned} \quad (6)$$

در نظر گرفته می‌شود. این انتخاب در ادبیات مدل‌های آمیخته، یکی از انتخاب‌های مرسوم و کلاسیک است (فرورس-شناصر، ۲۰۰۶). از آن‌جا که توزیع دیریکل‌هه تعییم‌یافته توزیع بتا است، بر اساس رابطه‌ای که بین توزیع بتا و (α, β) وجود دارد و به منظور پرهیز از پیش داوری معمولاً ابرپارامترهای توزیع پیشین به صورت آن‌گاه توزیع یکنواخت d -بعدی، $\text{Beta}(\alpha, \beta)$ حاصل می‌شود. البته فرض برابری ابرپارامترهای توزیع دیریکل‌هه زمانی مطلوب است که همه ضرایب آمیختگی با هم برابر باشند، به این معنی که تحلیل‌گر معتقد باشد، همه مؤلفه‌های توزیع آمیخته به یک اندازه در نمونه مشاهده شده سهم دارند. از این‌رو، باید تعلق مشاهدات به هریک از زیرجواب‌ها را در نظر گرفت. یک روش برای این‌منظور در حالت‌های یک و دو متغیره رسم نمودار مشاهدات و مقایسه فراوانی مشاهدات در مؤلفه‌های تشکیل‌دهنده توزیع آمیخته است. البته این کار در حالت‌های چندمتغیره دشوار است. به عنوان مثال، اگر در یک مدل آمیخته دو مؤلفه‌ای، فراوانی مشاهدات مربوط به مؤلفه اول از فراوانی مشاهدات مربوط به مؤلفه دوم کم‌تر (بیش‌تر) باشد، ابرپارامترهای توزیع دیریکل‌هه را باید به نحوی تعیین کرد که این توزیع چوله به راست (چپ) باشد.

بسیاری از محققان، از جمله گلمان و همکاران (۲۰۰۸)، استفاده از توزیع پیشین نرمال برای ضرایب مدل‌های رگرسیونی را در حالت کالی منطقی می‌دانند. بر این اساس، برای ضرایب رگرسیونی $(\beta_{1j}, \beta_{2j}, \dots, \beta_{rj}, g)$ ، توزیع نرمال چندمتغیره به صورت

$$\pi(\beta_{1j}, \beta_{2j}, \dots, \beta_{rj}, g) \sim N_{rp}(\mu_j, \Sigma_j), \quad j = 1, \dots, g. \quad (7)$$

به عنوان توزیع پیشین در نظر گرفته شده است. بردار میانگین و ماتریس کواریانس توزیع پیشین باید طوری در نظر گرفته شوند که حاوی اطلاعات مناسبی در مورد پارامترهای باشند و توزیع پیشین را به سمت برازش مناسب مدل هدایت کنند. با فرض مستقل بودن ضرایب رگرسیونی، ماتریس کواریانس توزیع پیشین قطری است. اکنون با انتخاب توزیع پیشین مناسب برای پارامترهای مدل و محاسبه توزیع

پسین، می‌توان به استنباط پسینی پیرامون پارامترها پرداخت.

۲.۳ توزیع پسین

با توجه به توزیع‌های پیشین (۷) و (۷)، توزیع پسین به صورت

$$\begin{aligned} \pi(Z, \theta, \alpha | \mathcal{D}) &\propto p(\mathcal{D} | \theta, \alpha) \cdot \pi(\theta) \cdot \pi(\alpha) \\ &= \prod_{i=1}^n \left\{ \prod_{j=1}^g [e^{-(\exp(x'_{ij}\beta_{1j}) + \exp(x'_{ri}\beta_{rj}) + \exp(x'_{ri}\beta_{rj}))} \right. \\ &\quad \times \frac{(\exp(x'_{ij}\beta_{1j}))^{y_{1i}}}{y_{1i}!} \frac{(\exp(x'_{ri}\beta_{rj}))^{y_{ri}}}{y_{ri}!} \\ &\quad \times \sum_{s_i=0}^{\min(y_{1i}, y_{ri})} \binom{y_{1i}}{s_i} \binom{y_{ri}}{s_i} s_i! \\ &\quad \times \left. \left(\frac{\exp(x'_{ri}\beta_{rj})}{\exp(x'_{ri}\beta_{1j}) \exp(x'_{ri}\beta_{rj})} \right)^{s_i} \right]^{z_{ij}} \alpha_j^{z_{ij}} \} \\ &\quad \times \prod_{j=1}^g [\pi(\beta_{1j}, \beta_{rj}, \beta_{rj})] (\prod_{j=1}^g a_j^{c_j - 1}), \end{aligned} \quad (8)$$

به دست می‌آید. به دلیل پیچیدگی توزیع پسین، امکان محاسبه ثابت چگالی ساز عملاً وجود ندارد. از این رو، توزیع پسین فاقد شکل بسته و شناخته شده است. بر این اساس، می‌توان از زنجیر مارکف مونت کارلویی برای نمونه‌گیری از این توزیع پسین استفاده کرد. سپس نمونه‌های حاصل را برای هر گونه استنباط پسینی پیرامون پارامترها به کار گرفت.

۱.۲.۳ توزیع‌های پسین شرطی کامل

در این بخش نحوه کاربست الگوریتم گیبز برای نمونه‌گیری از توزیع پسین (۸) شرح داده می‌شود. لازمه استفاده از الگوریتم گیبز شناخت توزیع‌های پسین شرطی کامل است. بنابراین در این بخش توزیع‌های پسین شرطی کامل برای ضرایب آمیختگی، ضرایب رگرسیون و متغیرهای گم شده z محاسبه می‌شوند. بر اساس

توزیع پسین (۸) و توزیع پیشین ضرایب آمیختگی در (۷)، توزیع پسین شرطی کامل ضرایب آمیختگی به صورت

$$\begin{aligned}\pi(\boldsymbol{\alpha} | \mathbf{Z}, \boldsymbol{\theta}, \mathcal{D}) &\propto \prod_{j=1}^g \alpha_j^{c_j - 1} \prod_{j=1}^g \alpha_j^{\sum_{i=1}^n z_{ij}} \\ &= \prod_{j=1}^g \alpha_j^{c_j + \eta_j - 1},\end{aligned}$$

محاسبه می شود. بنابراین، توزیع پسین شرطی کامل برای ضریب آمیختگی، توزیع دیریکله به صورت

$$\pi(\boldsymbol{\alpha} | \mathbf{Z}, \boldsymbol{\theta}, \mathcal{D}) = Dirichlet(c_1 + \eta_1, \dots, c_g + \eta_g),$$

است. به همین ترتیب توزیع پسین شرطی کامل ضرایب رگرسیونی $\boldsymbol{\theta} = \{\beta_{1j}, \beta_{2j}, \beta_{3j}\}_{j=1}^g$ به صورت

$$\begin{aligned}\pi(\boldsymbol{\theta} | \boldsymbol{\alpha}, \mathbf{Z}, \mathcal{D}) &= \int_0^1 \cdots \int_0^1 \pi(\boldsymbol{\theta}, \boldsymbol{\alpha} | \mathbf{Z}, \mathcal{D}) d\alpha_1 \cdots d\alpha_g \\ &\propto \prod_{i=1}^n \left(\prod_{j=1}^g [e^{-(\exp(\mathbf{x}'_{1i} \boldsymbol{\beta}_{1j}) + \exp(\mathbf{x}'_{ri} \boldsymbol{\beta}_{rj}) + \exp(\mathbf{x}'_{ri} \boldsymbol{\beta}_{rj}))} \right. \\ &\quad \times \frac{(\exp(\mathbf{x}'_{1i} \boldsymbol{\beta}_{1j}))^{y_{1i}}}{y_{1i}!} \frac{(\exp(\mathbf{x}'_{ri} \boldsymbol{\beta}_{rj}))^{y_{ri}}}{y_{ri}!} \\ &\quad \times \sum_{s_i=0}^{\min(y_{1i}, y_{ri})} \binom{y_{1i}}{s_i} \binom{y_{ri}}{s_i} s_i! \\ &\quad \times \left(\frac{\exp(\mathbf{x}'_{ri} \boldsymbol{\beta}_{rj})}{\exp(\mathbf{x}'_{ri} \boldsymbol{\beta}_{1j}) \exp(\mathbf{x}'_{ri} \boldsymbol{\beta}_{rj})} \right)^{s_i}]^{z_{ij}} \right) \\ &\quad \times \prod_{j=1}^g \varphi_{3p}((\beta_{1j}, \beta_{2j}, \beta_{3j}); \boldsymbol{\mu}_j, \boldsymbol{\Sigma}_j),\end{aligned}$$

است، که در آن $\varphi_{3p}(\cdot, \cdot, \cdot)$ تابع چگالی توزیع نرمال $p-3$ -بعدی است. توزیع پسین شرطی کامل متغیر نشانگر z_{ij} که وضعیت تعلق نامیں مشاهده به زامین مؤلفه را مشخص می سازد، به صورت

$$P(z_{ij} | \boldsymbol{\theta}, \boldsymbol{\alpha}, \mathcal{D}) = \frac{\alpha_j BP(y_{1i}, y_{ri} | \boldsymbol{\beta}_{1j}, \boldsymbol{\beta}_{2j}, \boldsymbol{\beta}_{3j}, \mathbf{x}_{1i}, \mathbf{x}_{ri}, \mathbf{x}_{ri})}{\sum_{j=1}^g \alpha_j BP(y_{1i}, y_{ri} | \boldsymbol{\beta}_{1j}, \boldsymbol{\beta}_{2j}, \boldsymbol{\beta}_{3j}, \mathbf{x}_{1i}, \mathbf{x}_{ri}, \mathbf{x}_{ri})} \quad (9)$$

است. بر اساس احتمال‌های پسین (۹)، توزیع پسین شرطی کامل
 $z_i = (z_{i1}, \dots, z_{ig})$ - جمله‌ای به صورت

$$\pi(z_i | \theta, \alpha, \mathcal{D}) = \mathcal{M}(1, Pr(z_{i1} | \theta, \alpha, \mathcal{D}), \dots, Pr(z_{ig} | \theta, \alpha, \mathcal{D})),$$

است. بنابراین، توزیع پسین شرطی کامل متغیرهای گم شده، ضرایب آمیختگی و
 ضرایب رگرسیونی، به ترتیب عبارتند از

$$\begin{aligned}\pi(z_i | \theta, \alpha, \mathcal{D}) &= \mathcal{M}(1, Pr(z_{i1} | \theta, \alpha, \mathcal{D}), \dots, Pr(z_{ig} | \theta, \alpha, \mathcal{D})), \\ \pi(\alpha | Z, \theta, \mathcal{D}) &= Dirichlet(c_1 + \eta_1, \dots, c_g + \eta_g), \\ \pi(\theta | \alpha, Z, \mathcal{D}) &\propto \prod_{i=1}^n \left(\prod_{j=1}^g [e^{-(\exp(\mathbf{x}'_{ij}\beta_{1j}) + \exp(\mathbf{x}'_{ij}\beta_{2j}) + \exp(\mathbf{x}'_{ij}\beta_{3j}))} \right. \\ &\quad \times \frac{(\exp(\mathbf{x}'_{ij}\beta_{1j}))^{y_{1i}}}{y_{1i}!} \frac{(\exp(\mathbf{x}'_{ij}\beta_{2j}))^{y_{2i}}}{y_{2i}!} \\ &\quad \times \sum_{s_i=0}^{\min(y_{1i}, y_{2i})} \binom{y_{1i}}{s_i} \binom{y_{2i}}{s_i} s_i! \\ &\quad \times \left. (\frac{\exp(\mathbf{x}'_{ij}\beta_{3j})}{\exp(\mathbf{x}'_{ij}\beta_{1j}) \exp(\mathbf{x}'_{ij}\beta_{2j})})^{s_i} \right]^{z_{ij}} \\ &\quad \times \prod_{j=1}^g \varphi_{3p}((\beta_{1j}, \beta_{2j}, \beta_{3j}); \mu_j, \Sigma_j).\end{aligned}$$

اکنون با در دست داشتن توزیع‌های شرطی کامل می‌توان از توزیع پسین توأم $\{\alpha, \theta, Z, \mathcal{D}\}$ به کمک الگوریتم نمونه برداری گیبس^۳ نمونه گیری نمود. همان‌طور که مشاهده می‌شود توزیع پسین شرطی کامل $\{\theta | Z, \alpha, \mathcal{D}\}$ صورت بسته و شناخته شده‌ای ندارد، بنابراین با استفاده از الگوریتم متروپولیس - هاستینگس^۴ از توزیع پسین شرطی کامل $\{\theta | Z, \alpha, \mathcal{D}\}$ نمونه تولید می‌شود. برای نمونه گیری از توزیع پسین به تلفیقی از الگوریتم‌های گیبس و متروپولیس - هاستینگس نیاز است. مراحل کلی الگوریتم گیبس برای نمونه گیری از توزیع پسین (۸) به شرح زیر است:

(۱) مقدار اولیه‌ی $\theta^{(0)}$ را برای $\alpha^{(0)}$ و $\theta^{(0)}$ در نظر بگیرید.

^۳ Gibbs sampling

^۴ Metropolis-Hastings

۹۰ مدل رگرسیونی بیزی پواسون آمیخته دو متغیره

(۲) در مرحله $t+1$ بر اساس مقادیر حاصل از مرحله t ام، Z ، α و θ را به صورت زیر به روز کنید:

$$\pi(Z_i^{(t+1)} | \theta^{(t)}, \alpha^{(t)}, \mathcal{D}) = \mathcal{M}(\mathbb{1}, P(z_i^{(t+1)} | \theta^{(t)}, \alpha^{(t)}, \mathcal{D}), \dots, P(z_{ig}^{(t+1)} | \theta^{(t)}, \alpha^{(t)}, \mathcal{D})),$$

$$\pi(\alpha^{(t+1)} | z^{(t+1)}, \theta^{(t)}, \mathcal{D}) = Dirichlet(c_1 + \eta_1^{(t+1)}, \dots, c_g + \eta_g^{(t+1)}),$$

$$\begin{aligned} \pi(\theta^{(t+1)} | \alpha^{(t+1)}, z^{(t+1)}, \mathcal{D}) &\propto \prod_{i=1}^n \left(\prod_{j=1}^g [e^{-(\exp(x'_{1i}\beta_{1j}^{(t)}) + \exp(x'_{2i}\beta_{2j}^{(t)}) + \exp(x'_{3i}\beta_{3j}^{(t)}))} \right. \\ &\times \frac{(\exp(x'_{1i}\beta_{1j}^{(t)}))^{y_{1i}}}{y_{1i}!} \frac{(\exp(x'_{2i}\beta_{2j}^{(t)}))^{y_{2i}}}{y_{2i}!} \sum_{s_i=0}^{\min(y_{1i}, y_{2i})} \binom{y_{1i}}{s_i} \binom{y_{2i}}{s_i} s_i! \\ &\times \left. \frac{\exp(x'_{3i}\beta_{3j}^{(t)})}{\exp(x'_{1i}\beta_{1j}^{(t)}) \exp(x'_{2i}\beta_{2j}^{(t)})} \right]^{z_{ij}^{(t+1)}} \prod_{j=1}^g \varphi_{\mathcal{P}}((\beta_{1j}^{(t)}, \beta_{2j}^{(t)}, \beta_{3j}^{(t)}); \mu_j, \Sigma_j). \end{aligned}$$

(۳) مرحله ۲ را تا رسیدن الگوریتم به حالت مانایی تکرار کنید.

در مرحله ۲ الگوریتم، برای نمونه‌گیری از توزیع پسین شرطی کامل $\{\theta | Z, \alpha, \mathcal{D}\}$ به دلیل بسته نبودن شکل توزیع، از الگوریتم متropolیس - هستینگس برای نمونه‌گیری از این توزیع استفاده می‌شود.

۴ مطالعه شبیه‌سازی

در این بخش مدل بیزی پیشنهادی که در بخش ۳ مورد بحث قرار گرفت، در چارچوب یک مطالعه‌ی شبیه‌سازی مورد ارزیابی قرار گرفته و کارایی آن با مدل بسامدی معروفی شده توسط برموذز و کارلیس (۲۰۱۲) مقایسه می‌شود. برای این منظور از یک طرح شبیه‌سازی مشابه آنچه در جرج و مکلاک (۱۹۹۳) و رفتری و همکاران (۱۹۹۷) برای ارزیابی مدل‌های رگرسیونی توصیه شده است، استفاده می‌شود. فرض کنید $p = 2 = g$. از این رو فضای پارامتری شامل ۱۳ پارامتر است و در این مطالعه مقادیر ضرایب رگرسیونی به صورت

$$\begin{aligned} \theta &= \{\beta_{110}, \beta_{111}, \beta_{210}, \beta_{211}, \beta_{310}, \beta_{311}, \beta_{120}, \beta_{121}, \beta_{220}, \beta_{221}, \beta_{320}, \beta_{321}\} \\ &= \{0/4, 0/4, 0/4, 0/4, 0/5, 0/5, 0/8, 0/8, 0/8, 0/8, 0/9, 0/9\} \end{aligned}$$

در نظر گرفته شده‌اند. به علاوه، به منظور ارزیابی نحوه اثرباری فراوانی مشاهدات مربوط به مؤلفه‌های تشکیل دهنده توزیع آمیخته بر کارایی مدل‌های مورد بحث، برای ضریب آمیختگی α مقادیر مختلف $(0.99, 0.95, 0.85, 0.75, 0.5)$ در نظر گرفته شده است. مقادیر متغیرهای تبیینی x_1, x_2, \dots, x_n و y_{1i}, y_{2i} از توزیع نرمال $N(\mu, \sigma^2)$ شبیه‌سازی شده‌اند. بر این اساس، با توجه به نرمال بودن ترکیب خطی متغیرهای نرمال و رابطه $y_i = \exp(x_i'\beta)$ ، متغیر تصادفی (X) دارای توزیع لگ نرمال $LN(\mu, \sigma^2)$ است. سپس مقادیر پاسخ (y_{1i}, y_{2i}) از طریق رابطه (۲) شبیه‌سازی شده است. در نهایت با فرض موجود بودن مشاهدات $\{x_i\}_{i=1}^n$ ضرایب رگرسیونی با رهیافت بسامدی (برموذز و کارلیس، ۲۰۱۲) و هم‌چنین رهیافت بیزی پیشنهاد شده در این مقاله، برآورد و میزان کارایی نسبی دو رهیافت در برآورد ضرایب رگرسیونی و پارامتر آمیختگی بر اساس معیار کمترین توان‌های دوم خطأ^۵ (MSE) به صورت

$$E(\hat{\beta}_{EM}, \hat{\beta}_B) = \frac{MSE(\hat{\beta}_B)}{MSE(\hat{\beta}_{ML})},$$

$$E(\hat{\alpha}_{EM}, \hat{\alpha}_B) = \frac{MSE(\hat{\alpha}_B)}{MSE(\hat{\alpha}_{ML})},$$

به دست آمده‌اند. در تمامی محاسبات به منظور لحاظ نمودن تغییرپذیری مشاهدات شبیه‌سازی شده، تعداد تکرار برابر با 500 در نظر گرفته شده است. نتایج به ازای مقادیر مختلف α و اندازه‌های نمونه‌ای متفاوت در جداول ۱ و ۲ ارائه شده‌اند. گرچه همگرایی یک زنجیر مارکف به توزیع مانای خود تحت شرایط معین تضمین شده است، اما چون هیچ راه نظری برای تعیین زمان همگرایی یک زنجیر مارکف وجود ندارد، معمولاً از نمودارهای اثر و خودهمبستگی برای تشخیص همگرایی استفاده می‌شود. به علاوه، برخی معیارهای عددی برای اطمینان بیش تر از همگرایی زنجیرهای مارکف، توسط محققانی مانند گلمن و روین (۱۹۹۲) پیشنهاد شده و بسته‌های نرم‌افزاری مناسبی برای این منظور تهیه شده است. در این مقاله از تابع *gelman.diag* در بسته *R* از نرم‌افزار *Coda* برای تشخیص همگرایی زنجیرهای مارکف استفاده شده است. نمودارهای اثر و خودهمبستگی برای یک نمونه نوعی

^۵ Mean square errors

شبیه‌سازی شده از توزیع پسین ضرایب رگرسیونی، در شکل ۱ رسم شده‌اند. این نمودارها به خوبی همگرایی زنجیرهای مارکف تولید شده از توزیع‌های پسین ضرایب رگرسیونی را نشان می‌دهند. البته با توجه به پیچیدگی مدل، همگرایی زنجیرهای مارکف خصوصاً برای نمونه‌های بزرگ، زمانبر است.

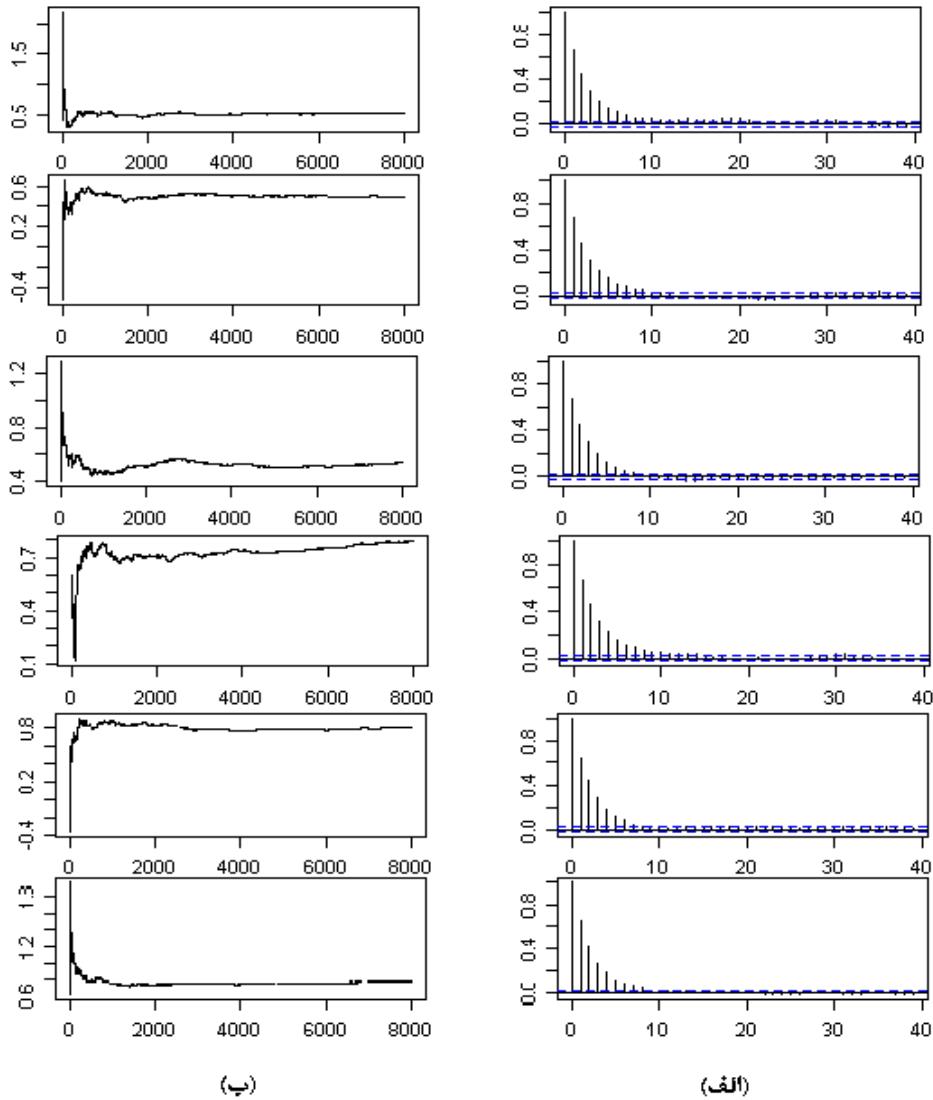
همان‌طور که ملاحظه می‌شود، میزان کارایی رهیافت بیزی در برآورد ضرایب رگرسیونی به‌ازای تمام مقادیر α و تمام اندازه نمونه‌های در نظر گرفته شده، از کارایی رهیافت بسامدی بیشتر است. برتری کارایی برآوردگر حاصل از مدل بیزی به برآوردگر بسامدی ماکسیمم درستنامایی به ویژه برای مقادیر ضریب آمیختگی نزدیک به $5/0$ کاملاً قابل توجه است. البته چنان‌چه انتظار می‌رود، کارایی برآوردگرهای ماکسیمم درستنامایی بر اساس خواص مجانی این نوع برآوردگرهای با افزایش اندازه نمونه بهبود می‌یابد. در مورد پارامتر ضریب آمیختگی، α ، که در تحلیل رگرسیونی مستقیماً مورد علاقه نیست، وضعیت تا حدودی متفاوت است. به‌گونه‌ای که رهیافت بیزی تنها به‌ازای مقادیر متوسط α برای تمام اندازه‌های نمونه‌ای از رهیافت بسامدی کارتر است (ردیف سوم جدول ۲). برای مقادیر α نزدیک به 0 یا 1 برتری کارایی رهیافت بیزی به بسامدی تنها برای نمونه‌های کوچک $\{50, 25\}$ صادق است و برآوردگر ماکسیمم درستنامایی ضریب آمیختگی برای نمونه‌های بزرگ بر اساس خواص مجانی خود، کارایی بیشتری دارد. موارد نادری ناپایداری در نتایج نیز مشاهده می‌شود که ناشی از حجم نمونه‌های کوچک و مشاهدات شبیه‌سازی شده است. تاکید بر نمونه‌های کوچک در مطالعه شبیه‌سازی به این دلیل است که بر اساس اصول استنباط بیزی، برای اندازه نمونه‌های بزرگ درستنامایی بر پیشین غلبه می‌کند و عملاً تفاوتی بین نتایج حاصل از تحلیل این مدل از دیدگاه بسامدی و بیزی وجود نخواهد داشت. از این‌رو، برای نمونه‌های بزرگ می‌توان مدل بسامدی و استفاده از الگوریتم EM را از نقطه نظر سادگی و سرعت عمل بیشتر، توصیه نمود.

جدول ۱: کارایی نسبی براوردگر بسامدی نسبت به براوردگر بیزی برای ضرایب رگرسیون بهازای مقادیر مختلف ضرایب آمیختگی مولفه اول

حجم نمونه	α	β_{ijk}		
۲۰۰	۱۰۰	۵۰	۲۵	
۰/۰۸۷۷	۰/۱۳۷۹	۰/۰۴۹۸	۰/۰۳۳۴	۰/۱
۰/۴۲۴۳	۰/۱۱۷۷	۰/۰۵۱۷	۰/۰۲۶۶	۰/۲۵
۰/۰۱۹۳	۰/۰۷۹۸	۰/۰۵۱۷	۰/۰۱۹۳	۰/۵
۰/۱۶۹۹	۰/۱۱۸۰	۰/۲۱۶۵	۰/۱۶۹۹	۰/۷۵
۰/۰۷۹۷	۰/۱۶۱۷	۰/۰۶۵۶	۰/۰۷۹۷	۰/۹۹
۰/۳۷۸۸	۰/۰۵۶۹	۰/۶۴۹۵	۰/۰۲۲۵	۰/۱
۰/۰۸۷۳	۱/۷۱۸۴	۰/۵۸۳۲	۰/۰۲۰۱	۰/۲۵
۰/۶۵۸۶	۰/۱۷۰۹	۰/۶۱۹۷	۰/۰۵۹۴	۰/۵
۰/۲۲۷۶	۰/۱۱۵۶	۰/۰۹۲۷	۰/۳۳۰۸	۰/۷۵
۰/۲۱۸۶	۰/۱۰۳۲	۱/۱۳۲۳	۰/۱۷۹۱	۰/۹۹
۰/۱۰۵۰	۰/۲۴۰۱	۰/۰۴۰۸	۰/۱۲۳۲	۰/۱
۰/۲۱۸۳	۰/۲۴۵۸	۰/۰۴۲۶۷	۰/۰۷۹۹	۰/۲۵
۰/۱۳۲۱	۰/۰۶۸۴	۰/۰۴۱۳	۰/۰۵۴۴	۰/۵
۰/۹۴۱۲	۰/۲۲۶۹	۰/۰۸۷۹	۰/۱۲۷۶	۰/۷۵
۰/۴۲۳۱	۰/۶۹۰۹	۰/۰۷۵۶	۰/۰۷۶۸	۰/۹۹
۰/۰۷۱۰	۰/۰۵۰۷	۰/۱۱۶۶	۰/۰۵۶۲	۰/۱
۰/۲۹۹۹	۰/۱۰۲۵	۰/۱۲۶۶	۰/۰۷۳۷	۰/۲۵
۰/۴۲۸۱	۰/۰۸۲۳	۰/۱۱۸۲	۰/۰۵۳۳	۰/۵
۰/۹۴۷۷	۰/۰۸۹۴	۰/۲۵۲۱	۰/۱۱۹۸	۰/۷۵
۰/۱۴۳۶	۰/۱۲۶۴	۰/۲۳۰۳	۰/۲۰۲۹	۰/۹۹
۰/۱۲۵۵	۱/۴۲۲۵	۰/۰۴۳۹	۰/۰۲۹۷	۰/۱
۰/۰۸۳۵	۰/۸۴۲۴	۰/۰۴۴۶	۰/۰۳۱۲	۰/۲۵
۰/۱۸۶۱	۰/۰۲۳۹	۰/۰۴۳۸	۰/۰۲۴۴	۰/۵
۰/۱۲۵۲	۰/۱۰۳۳	۰/۰۶۲۰	۰/۰۲۷۴	۰/۷۵
۰/۱۶۶۴	۰/۲۴۳۴	۰/۰۶۴۰	۰/۰۱۷۲	۰/۹۹
۰/۲۰۱۱	۰/۱۷۸۳	۰/۳۸۱۱	۰/۶۳۸۶	۰/۱
۰/۱۰۵۴	۰/۱۲۲۹	۰/۳۵۷۷	۰/۹۰۳۵	۰/۲۵
۰/۱۲۷۴	۰/۰۷۸۰	۰/۳۷۲۲	۰/۰۴۶۲	۰/۵
۰/۱۰۰۴	۰/۱۰۶۹	۰/۱۷۶۷	۰/۰۴۷۲	۰/۷۵
۰/۱۳۲۹	۰/۸۵۹۹	۰/۳۱۵۳	۰/۰۵۲۱	۰/۹۹

جدول ۲: کارایی نسبی برآوردگر بسامدی نسبت به برآوردگر بیزی برای ضرایب رگرسیون به ازای مقادیر مختلف ضرایب آمیختگی مولفه دوم

حجم نمونه				α	$\beta_{\ell_{jk}}$
۲۰۰	۱۰۰	۵۰	۲۵		
۰/۱۰۳۱	۰/۱۷۵۱	۰/۱۲۹۰	۱/۲۰۶۷	۰/۱	
۰/۰۷۹۳	۰/۱۵۱۶	۰/۱۲۲۰	۰/۲۳۴۰	۰/۲۵	
۰/۰۹۴۴	۰/۰۷۸۹	۰/۱۱۹۹	۰/۱۵۲۹	۰/۵	
۰/۰۶۳۵	۰/۰۷۲۲	۰/۰۹۹۳	۰/۰۴۴۸	۰/۷۵	
۰/۰۴۵۴	۰/۰۳۰۸	۰/۱۸۱۳	۰/۰۵۷۴	۰/۹۹	
۰/۱۴۱۸	۰/۰۵۴۵۱	۰/۱۵۲۲	۰/۱۱۹۷	۰/۱	
۰/۰۸۸۹	۰/۳۲۴۲	۰/۱۴۹۷	۰/۰۵۴۱	۰/۲۵	
۰/۰۸۰۱	۱/۰۶۲۹	۰/۱۴۹۴	۰/۰۴۵۸	۰/۵	$\beta_{1,2}$
۰/۰۵۹۵	۰/۰۴۷۳	۰/۰۵۰۲	۰/۰۲۶۱۲	۰/۷۵	
۰/۱۰۷۴	۰/۱۱۷۱	۰/۰۶۲۱	۰/۰۲۰۳	۰/۹۹	
۰/۱۲۳۶	۰/۲۱۰۲	۰/۰۵۵۹	۱/۰۵۰۷۶	۰/۱	
۰/۴۵۵۴	۰/۲۸۲۴	۰/۰۵۰۱	۰/۰۸۰۵	۰/۲۵	
۰/۱۲۷۹	۰/۱۱۲۰	۰/۰۵۲۹	۰/۰۶۱۳	۰/۵	$\beta_{1,1}$
۰/۲۷۰۸	۰/۰۶۹۱	۰/۰۴۸۷	۰/۴۲۰۱	۰/۷۵	
۰/۰۴۱۱	۰/۰۴۳۱	۰/۰۲۰۷	۰/۰۵۶۱	۰/۹۹	
۱/۰۴۲۸	۰/۱۱۰۲	۰/۱۲۰۱	۰/۶۵۰۳	۰/۱	
۰/۱۰۳۱	۰/۰۸۸۹	۰/۱۱۶۸	۰/۱۶۵۸	۰/۲۵	
۰/۰۸۱۰	۰/۰۵۰۰	۰/۱۲۲۹	۰/۱۱۶۲	۰/۵	$\beta_{1,11}$
۰/۱۲۷۴	۰/۰۲۳۱	۰/۰۴۹۸	۰/۰۳۷۱	۰/۷۵	
۱/۸۸۶۹	۰/۰۲۸۸	۰/۰۲۷۵	۰/۰۳۶۷	۰/۹۹	
۰/۰۶۶۰	۰/۰۹۵۴	۰/۰۷۵۶	۰/۲۷۲۱	۰/۱	
۰/۰۷۲۷	۰/۰۸۶۷	۰/۰۷۸۸	۱/۷۵۹۹	۰/۲۵	
۰/۱۳۶۲	۰/۱۰۰۱	۰/۰۷۹۵	۰/۱۴۱۱	۰/۵	$\beta_{1,10}$
۰/۱۳۹۹	۰/۰۵۸۷	۰/۰۶۰۲	۰/۰۵۴۸۹	۰/۷۵	
۰/۰۳۵۸	۰/۰۴۴۲	۰/۰۵۹۲	۰/۰۳۸۴	۰/۹۹	
۰/۰۹۴۳	۰/۱۳۰۲	۰/۱۳۹۴	۰/۰۹۲۸	۰/۱	
۰/۰۶۴۳	۰/۱۵۲۳	۰/۱۳۵۱	۰/۱۲۳۱	۰/۲۵	
۰/۱۰۳۷	۰/۱۲۹۵	۰/۱۳۱۶	۰/۰۶۷۸	۰/۵	$\beta_{1,11}$
۰/۰۷۰۱	۰/۰۴۶۲	۰/۲۳۱۴	۰/۰۳۹۳	۰/۷۵	
۰/۰۳۹۲	۰/۰۴۵۴	۱/۹۵۴۸	۰/۰۳۷۴	۰/۹۹	



شکل ۱: نمودارهای خودهمبستگی (الف) و اثر (ب) نمونه‌های حاصل از توزیع‌های پسین ضرایب رگرسیونی β_{111} (ردیف اول)، β_{211} (ردیف دوم)، β_{321} (ردیف سوم)، β_{121} (ردیف چهارم)، β_{221} (ردیف پنجم) و β_{321} (ردیف ششم)

جدول ۳: کارایی نسبی برآوردهای سامدی به برآوردهای بیزی برای ضرایب آمیختگی به ازای مقادیر مختلف این پارامتر.

حجم نمونه				α
۲۰۰	۱۰۰	۵۰	۲۵	
۳/۲۱۲۲	۳/۴۱۴۳	۰/۸۲۶۴	۰/۶۱۸۹	۰/۱
۳/۸۳۳۹	۳/۱۰۹۴	۰/۴۲۴۰	۰/۰۶۹۷	۰/۲۵
۰/۰۰۲۹	۰/۰۰۳۳	۰/۰۰۴۶	۰/۰۰۸۶	۰/۵
۳/۱۸۲۳	۴/۱۰۴۵	۰/۱۵۰۱	۰/۳۱۶۸	۰/۷۵
۳/۵۹۷۶	۵/۰۶۷۴	۰/۳۸۲۷	۰/۱۷۸۰	۰/۹۹

۵ تحلیل داده‌های سرطان روده و معده

در این بخش نحوه کاربریست دو رهیافت سامدی و بیزی پیشنهادی در قالب یک مثال کاربردی شرح داده شده و کارایی آن مورد ارزیابی قرار گرفته است. برای این منظور از مجموعه داده‌های مربوط به تعداد کل موارد بروز سرطان‌های روده بزرگ و معده در ۲۴ استان کشور طی سال‌های ۱۳۸۷ تا ۱۳۸۳ که در جدول ۴ ارائه شده‌اند، استفاده شده است. در این جدول ستون اضافه وزن نشان‌دهنده درصد افرادی است که شاخص BMI برای آن‌ها بیشتر از ۲۵ است. ستون کم تحرکی نیز درصد افرادی را نشان می‌دهد که دارای فعالیت فیزیکی کم تر از ۶۰ هفته هستند. بر اساس آمارهای موجود تعداد موارد ابتلا به این دو نوع سرطان که از نظر علم پژوهشی دارای رابطه معنی‌داری هستند، به شدت رو به افزایش است. عوامل مختلفی بر بروز این نوع سرطان‌ها موثر هستند که از آن جمله می‌توان به مصرف سیگار، اضافه وزن، کم تحرکی و میزان مصرف میوه و سبزیجات، اشاره کرد. در این مطالعه، هدف بررسی رابطه بین بروز سرطان‌های معده و روده بزرگ با اضافه وزن و کم تحرکی است. از این‌رو، متغیرهای مربوط به اضافه وزن و کم تحرکی به عنوان مستخیرهای تبیینی در نظر گرفته شده‌اند. با توجه به مقادیر میانگین و واریانس متغیرهای پاسخ که در جدول ۵ ارائه شده‌اند، فرض نابرابری میانگین و واریانس مشاهدات پاسخ که یکی از مفروضات اصلی تحلیل رگرسیون پواسون معمول است، برقرار نیست و مشاهدات بسیار بیش پراکنده‌اند. از این‌رو، مدل رگرسیون پواسون

جدول ۴: تعداد کل موارد بروز سرطان‌های معده و روده بزرگ در سال‌های ۱۳۸۳ و ۱۳۸۷ و عوامل خطر مورد مطالعه برای سرطان‌ها در سال ۱۳۸۷

ردیف	نام استان	سرطان معده	سرطان روude بزرگ	اضافه وزن کم تحرکی
۱	اردبیل	۸۲۳	۶۱۷	۴۶/۲۸
۲	اصفهان	۹۶۳	۵۱۶	۴۷/۱۷
۳	ایلام	۱۱۰	۲۰۸	۳۵/۳۵
۴	بوشهر	۷۵	۴۹	۴۱/۵۱
۵	چهارمحال و بختیاری	۲۵۸	۱۲۹	۳۹/۶۲
۶	خراسان جنوبی	۸۲	۱۷۴	۴۱/۰۲
۷	خراسان شمالی	۱۵۸	۴۱	۴۳/۲۵
۸	خوزستان	۵۷۴	۵۹۱	۴۶/۰۳
۹	زنجان	۴۱۱	۶۰۷	۳۵/۱۷
۱۰	سمنان	۲۳۰	۱۰۶	۴۰/۲۲
۱۱	سیستان و بلوچستان	۱۶۶	۱۰۸	۴۴/۸۳
۱۲	فارس	۸۷۷	۱۲۵	۴۶/۱۷
۱۳	قزوین	۳۶۲	۲۱۰	۴۵/۳۹
۱۴	قم	۲۹۲	۲۰۶	۳۸/۰۲
۱۵	کردستان	۷۳۵	۱۹۷	۴۸/۶۷
۱۶	کرمان	۴۲۴	۳۲۱	۴۴/۵۱
۱۷	کرمانشاه	۵۱۶	۳۶۹	۴۵/۸۹
۱۸	کهگیلویه و بویراحمد	۲۰۹	۷۵	۴۵/۸۸
۱۹	گلستان	۵۲۰	۳۲۷	۵۳/۸۵
۲۰	لرستان	۵۰۶	۲۲۹	۴۴/۶۹
۲۱	مرکزی	۳۱۹	۲۲۳	۳۸/۵۰
۲۲	هرمزگان	۱۱	۱۲۲	۴۷/۳۱
۲۳	همدان	۴۶۶	۲۶۶	۲۹/۷۷
۲۴	یزد	۱۷۹	۲۱۵	۴۱/۰۱

دو متغیره آمیخته از طریق دو رهیافت بیزی و بسامدی به داده‌ها برآش داده شده و برآورد پارامترها در جدول ۶ ارائه شده‌اند. برای مقایسه‌ی نتایج حاصل از برآش

جدول ۵: خلاصه آماره‌ای توصیفی متغیرهای پاسخ و تبیینی

متغیر	کمینه	چارک اول	میانه	میانگین سوم	چارک بیشینه	انحراف معیار	۲۵۹/۰۵۹۵
سرطان معده	۷۵	۱۷۵/۸	۳۴۰/۷۵	۳۹۰/۲	۵۱۷	۹۶۳	۱۵۹/۰۵۹۵
سرطان روده	۴۱	۱۲۸	۲۰۷	۲۲۳/۳	۲۷۹/۸	۶۱۷	۱۵۹/۲۰۹۹
اضافه وزن	۲۹/۷۷	۴۰/۰۷	۴۴/۶	۴۲/۰۵	۴۶/۲	۵۳/۸۵	۵/۶۰۷۸۰
کم تحرکی	۲۱/۵۷	۳۱/۸۰	۳۸/۱۸	۳۸/۱۰	۴۴/۵۰	۵۳/۷۵	۸/۵۸۶۰۲

جدول ۶: برآورد پارامترهای مدل رگرسیون پواسون دو متغیره آمیخته

پارامتر						رهیافت
β_{212}	β_{211}	β_{212}	β_{211}	β_{112}	β_{111}	
۰/۵۲۰۹	۰/۴۵۲۹	۰/۵۰۲۰	۰/۴۷۱۸	۰/۴۶۱۹	۰/۵۰۸۸	بیزی
۰/۷۸۸۵	۰/۷۸۴۵	۰/۸۰۰۷	۰/۷۹۲۰	۰/۸۲۸۵	۰/۷۴۶۴	بسامدی
β_{222}	β_{221}	β_{222}	β_{221}	β_{122}	β_{121}	
-۰/۶۴۰۰	-۰/۴۰۴۶	۰/۵۱۱۸	۲/۲۵۷۴	۰/۴۲۳۷	۱/۶۸۱۶	بیزی
-۰/۳۷۶۶	۰/۵۰۲۱	۰/۱۸۹۵	-۰/۴۹۰۷	۰/۴۲۸۴	-۱/۰۹۷۴	بسامدی

مدل رگرسیون پواسون دو متغیره آمیخته در دو رهیافت بیزی و بسامدی، از معیار ارزیابی متقابل^۲ $CV = \frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_{-i})^2$ استفاده شده است، که در آن Y_i مقدار متغیر پاسخ نام و \hat{Y}_{-i} مقدار پیش‌بینی شده این مشاهده بر اساس تمام مشاهدات به جز خود مشاهده است. مقدار آماره CV برای پیش‌بینی‌های حاصل از دو رهیافت بیزی و بسامدی در جدول ۷ ارائه شده‌اند. ملاحظه می‌شود که مقدار این آماره برای رهیافت بیزی پیشنهاد شده در این مقاله، به صورت قابل توجهی از مقدار متناظر برای رهیافت بسامدی کوچک‌تر است. با توجه به کوچکی حجم نمونه در این مثال، بار دیگر نتیجه حاصل از مطالعه شبیه‌سازی در بخش قبل مبنی بر این که مدل

بسامدی توسعه داده شده توسط برمودز و کارلیس (۲۰۱۲) نمی‌تواند برای مطالعاتی که در آن‌ها حجم نمونه بزرگ نیست به نتایج رضایت‌بخشی منجر شود، مورد تایید قرار می‌گیرد.

جدول ۷: مقدار آماره ارزیابی متقابل برای پیش‌بینی‌ها

بسامدی	۱۹/۷۲	بیزی	۳/۴۰	سرطان معده	رهیافت
	۱۶/۹۲	۳/۹۸			

۶ بحث و نتیجه‌گیری

استفاده از مدل رگرسیون پواسون آمیخته دو متغیره یکی از راه حل‌های ارائه شده جدید برای مواجهه با مشکلات بیش‌پراکنش و تورم مشاهدات در صفر، در تحلیل رگرسیونی داده‌های شمارشی است. با این مدل می‌توان همبستگی‌های ذاتی متغیرهای پاسخ را در فرایند مدل‌سازی لحاظ نمود و به مدل دقیق‌تری دست یافت. گرچه کاربست این مدل از هر دو دیدگاه بسامدی و بیزی به دلیل پیچیدگی‌های ذاتی مدل‌های آمیخته نیازمند استفاده از الگوریتم‌های تکراری بوده و با پیچیدگی‌های خاص خود همراه است، اما نتایج حاصل از شبیه‌سازی و نیز مثال کاربردی ارائه شده در این مقاله نشان می‌دهد که میزان کارایی رهیافت بیزی در برآورد ضرایب رگرسیونی، دست کم به‌ازای اندازه نمونه‌های کوچک، به طور قابل ملاحظه‌ای از کارایی رهیافت بسامدی بیش‌تر است. به علاوه، استفاده از رهیافت بسامدی از طریق کاربست الگوریتم EM با مسائلی مانند تعیین مقادیر اولیه مناسب برای پارامترهای مدل مواجه است، که به دلیل پیچیدگی مدل و زیاد بودن تعداد پارامترهای آن کار ساده‌ای نیست. به طور کلی، تنها برای اندازه نمونه‌های بزرگ است که به دلیل بروز خواص مجانبی برآوردگرهای ماکسیمم درستنمایی، می‌توان رهیافت بسامدی را در تحلیل رگرسیون پواسون آمیخته دو متغیره توصیه نمود.

تقدیر و تشکر

نویسنده‌گان از پیشنهادهای ارزشمند داوران محترم که موجب ارتقای سطح کیفی
مقاله شد، سپاس‌گزاری می‌کنند.

مراجع

- Bermúdez, L. (2009), A Priori Ratemaking Using Bivariate Poisson Regression Models. *Insurance: Mathematics and Economics*, **44**, 135-141.
- Bermúdez, L. and Karlis, D. (2011), Bayesian Multivariate Poisson Models for Insurance Ratemaking, *Insurance: Mathematics and Economics*, **48**, 226-236.
- Bermúdez, L. and Karlis, D. (2012), Mixture of Bivariate Poisson Regression Models with an Application to Insurance Ratemaking, *Computational Statistics and Data Analysis*, **56**, 3988-3999.
- Böhning, D., Dietz, E., Schaub, R., Schlattmann, P. and Lindsay, B. (1994), The Distribution of the Likelihood Ratio for Mixtures of Densities from the One-parameter Exponential Family, *Annals of the Institute of Statistical Mathematics*, **46**, 373-388.
- Dempster, A. P., Laird, N. M. and Rubin, D. B. (1977), Maximum Likelihood from Incomplete Data Via the EM Algorithm, *Journal of Royal Statistical Society, B*, **39**, 1-38.
- Frühwirth-Schnatter, S. (2006), *Finite Mixture and Markov Switching Models*, Springer Series in Statistics, Springer, New York.
- Garay, A. M., Hashimoto, E. M., Ortega, E. M. M. and Lachos, V. H. (2011), On Estimation and Influence Diagnostics for Zero-inflated

- Negative Binomial Regression Models, *Computational Statistics and Data Analysis*, **55**, 1304-1318.
- Gardner, W., Mulvey E. P. and Shaw, E. C. (1995), Regression Analyses of Counts and Rates: Poisson, Overdispersed Poisson and Negative Binomial Models, *Psychological Bulletin*, **118**, 392-404.
- Gelman, A., Jakulin, A., Grazia Pittau, M. and Su, Y. (2008), A Weakly Informative Default Prior Distribution for Logistic and Other Regression Models, *The Annals of Applied Statistics*, **4**, 1360-1383.
- Gelman, A. and Rubin, D. B. (1992), Inference from Iterative Simulation Using Multiple Sequences, *Statistical Science*, **7**, 457-511.
- George, E. L. and McCulloch, R. E. (1993), Variable Selection Via Gibbs Sampling, *Journal of American Statistical Association*, **88**, 881-890.
- Gurmu, S. and Elder, J. (2008), A Bivariate Zero-inflated Count Data Regression Model with Unrestricted Correlation, *Economics Letters*, **100**, 245-248.
- Karlis, D. and Ntzoufras, I. (2003), Analysis of Sports Data by Using Bivariate Poisson Models, *Journal of the Royal Statistical Society: Series D (The Statistician)*, **52**, 381-393.
- Lambert, D. (1992), Zero-Inflated Poisson Regression with an Application to Defects in Manufacturing, *Technometrics*, **34**, 1-14.

- Marin, J. M., Mengerson, K. and Robert, C. (2005), *Bayesian Modelling and Inference on Mixtures of Distributions*, In Rao, C. and Dey, D., Editors, *Handbook of Statistics*, 25, Springer-Verlag, New York.
- Raftery, A. E., Madigan, D. and Hoeting, J. (1997), Bayesian Model Averaging for Linear Regression Models, *Journal of the American Statistical Association*, **92**, 179-191.
- Wang, P. (2003), A Bivariate Zero-inflated Negative Binomial Regression Model for Count Data with Excess Zeros, *Economics Letters*, **78**, 373-378.
- Wang, P., Cockburn, I. M. and Puterman, M. L. (1998), Analysis of Patent Data: A Mixed Poisson Regression Model Approach, *Journal of Business and Economic Statistics* , **6**, 27-36.