

مدل‌بندی داده‌های شمارشی تحت تأثیر بیشپراکنش با مدل رگرسیون پواسون- بیرنباام ساندرز

رضا پورموسى و نرجس گیلانی

دانشگاه شهید باهنر کرمان، دانشکده ریاضی و کامپیوتر، بخش آمار
تاریخ دریافت: ۱۳۹۵/۱۰/۶ تاریخ آخرین بازنگری: ۱۳۹۶/۹/۲۵

چکیده: در این مقاله ابتدا به معرفی مدل‌های رگرسیون پواسون آمیخته پرداخته و در ادامه به معرفی یک مدل جدید به نام رگرسیون پواسون-بیرنباام ساندرز با هدف لحاظ کردن مسئله بیشپراکنش در مدل‌بندی داده‌های شمارشی پرداخته می‌شود. از آنجا که توزیع بیرنباام ساندرز آمیخته‌ای از دو توزیع گاووسی وارون تعییم‌یافته است، لذا می‌توان مدل معرفی شده دو پارامتری را تعییمی بر مدل‌های قبلی دانست که علاوه بر داشتن یک پارامتر کمتر نسبت به مدل رگرسیون پواسون گاووسی وارون تعییم‌یافته، دارای شکل بسته در تابع جرم احتمال حاشیه‌ای و گشتاورهای مربوطه است. برای برآورد پارامترهای این مدل از الگوریتم EM استفاده و در نهایت کارایی این مدل نسبت به مدل‌های موجود با استفاده از مطالعه شبیه‌سازی شده و یک مثال واقعی نشان داده شده است.

واژه‌های کلیدی: وزیع بیرنباام ساندرز، الگوریتم EM، داده‌های شمارشی، مدل‌های رگرسیون پواسون، بیشپراکنش، مدل رگرسیون پواسون آمیخته.

۱ مقدمه

رگرسیون پواسون نوعی از مدل‌های خطی تعییم‌یافته است که برای تحلیل داده‌های حاصل از شمارش به کار می‌رود. در این مدل متغیر پاسخ نشانگر تعداد اتفاقات در یک بازه زمانی است. در مدل‌های مبتنی بر توزیع نرمال، میانگین و واریانس معمولاً از هم مستقل هستند، در حالی‌که در بعضی از توزیع‌ها مانند

پواسون و دوجمله‌ای، میانگین و واریانس به هم وابسته‌اند. اگر مجموعه‌ای از مشاهدات y از توزیع پواسون پیروی کنند، انتظار آن است که واریانس آن‌ها برابر با میانگین باشد.

تحلیل آماری داده‌های شمارشی سابقه طولانی و غنی دارد و توزیع پواسون نقش کلیدی در تحلیل این نوع داده‌ها را ایفا می‌کند (جانسون و همکاران، ۱۹۹۲؛ تیلور و کارلین، ۱۹۹۴). یکی از ویژگی‌های کلیدی توزیع پواسون برابری میانگین و واریانس آن است:

$$E(Y) = Var(Y) = \mu.$$

چارچوب اصلی در مدل‌بندی داده‌های شمارشی، استفاده از مدل رگرسیون پواسون است (پاتیل، ۱۹۷۰)، اما به دلیل محدودیتی که در ساختار این توزیع وجود دارد (برابری واریانس با میانگین) محققان معمولاً به دنبال تعمیم مدل‌هایی برای مدل‌بندی داده‌های شمارشی بیش‌پراکنده هستند.

هایнд (۱۹۸۲) و کارلیس و زیکالکی (۲۰۰۵) به بررسی کارایی مدل رگرسیون پواسون، مسئله بیش‌پراکنش^۱ و کم‌پراکنش^۲ در داده‌های شمارشی پرداخته‌اند. هم‌چنین سائز کستیلو و کوند سانچز (۲۰۱۳) مدل‌های رگرسیون پواسون آمیخته و بعضی از ویژگی‌های آن‌ها را مورد مطالعه قرار داده‌اند. بیش‌پراکنش یک مسئله مهم در داده‌های شمارشی است که در ادبیات مدل‌های خطی تعمیم‌یافته راه حل‌های مختلفی برای آن پیشنهاد شده است. توزیع‌های جایگزین برای تحلیل داده‌های شمارشی توزیع‌های پواسون آمیخته هستند که به دلیل وجود پارامترهای بیشتر از انعطاف‌پذیری بالاتری نسبت به مدل پواسون برخوردار هستند.

وجود بیش‌پراکنش انگیزه‌ای است که به دنبال مدل‌های بهتری برای برآش این نوع داده‌ها باشیم. مدل‌های رگرسیون پواسون- گاما، پواسون- گاووسی وارون، پواسون- گاووسی وارون تعمیم‌یافته مثال‌هایی از این نتایج هستند (گاردن و همکاران، ۱۹۹۵؛ استین و جوریتز، ۲۰۰۷؛ رایگبی و همکاران، ۲۰۰۸).

مسئله بیش‌پراکنش زمانی رخ می‌دهد که پارامتر توزیع پواسون به تنها یک قادر به توصیف رخدادهای شمارشی نیست. در حالت کلی بیش‌پراکنش دارای دو منبع ناهمگنی جامعه و وجود بیش از حد صفر است. هدف این مقاله ارائه یک مدل رگرسیون پواسون آمیخته^۳ برای افزایش کارایی مدل در داده‌های بیش‌پراکنش است. برای این منظور در بخش‌های ۲ و ۳ مدل رگرسیون پواسون، توزیع پواسون آمیخته

¹Overdispersion

²Underdispersion

³Mixed Poisson regression models

و خواص آنها معرفی شده و مدل‌های رگرسیون پواسون- گاما^۴، پواسون- گاووسی وارون^۵ و پواسون- گاووسی وارون تعمیم‌یافته^۶ که از این خانواده نتیجه شده‌اند به همراه ویژگی‌های آنها تعریف شده‌اند. در بخش ۴ مدل جدیدی از رگرسیون پواسون آمیخته به نام پواسون- بیننام ساندرز^۷ معرفی و خواص آن مطرح می‌شود. سپس نشان داده می‌شود مدل معرفی شده می‌تواند برای مدل‌بندی داده‌های بیشپراکنش مورد استفاده قرار گیرد. در بخش ۵ برای برآورد پارامترهای مدل از الگوریتم EM استفاده و در نهایت در بخش ۶ کارایی این مدل در برآورد و پیش‌بینی نسبت به مدل‌های موجود با استفاده از یک مطالعه شبیه‌سازی شده و یک مثال با داده‌های واقعی نمایش داده شده است.

۲ مدل رگرسیون پواسون و تعمیم‌های آن

فرض کنید در n مشاهده مستقل i امین مشاهده با (y_i, \mathbf{x}_i) نمایش داده شود، که در آن y_i نشان دهنده تعداد وقوع یک پیشامد و \mathbf{x}_i بردار مستقل خطی است.

تعریف ۱: (مدل رگرسیون پواسون) فرض کنید Y_i دارای توزیع پواسون با میانگین μ_i باشد، آن‌گاه:

$$f_{Y_i}(y_i|\mathbf{x}_i) = \frac{e^{-\mu_i} \mu_i^{y_i}}{y_i!}, \quad \mu_i > 0, \quad y_i = 0, 1, \dots$$

و چون میانگین توزیع پواسون، نشان دهنده تعداد مورد انتظار پیشامدها و غیرمنفی است، از مدل لگاریتم میانگین به جای یک مدل خطی استفاده می‌شود، یعنی:

$$\log(\mu_i) = \mathbf{x}_i^T \boldsymbol{\beta}. \quad (1)$$

حال با نمایی کردن رابطه (1) یک مدل ضربی برای میانگین به صورت

$$E(Y_i|\mathbf{x}_i) = \mu_i = \exp(\mathbf{x}_i^T \boldsymbol{\beta}), \quad (2)$$

به دست می‌آید، که به آن مدل رگرسیون پواسون گویند. در رابطه (2)، $\boldsymbol{\beta}$ بردار پارامترهای رگرسیون، \mathbf{x}_i

⁴Poisson-Gamma

⁵Poisson- inverse Gaussian

⁶Poisson-generalized inverse Gaussian

⁷Poisson- Birnbaum Saunders

بردار متغیرهای تبیینی مستقل خطی به صورت

$$\boldsymbol{\beta}^T = [\beta_0, \dots, \beta_p], \quad \mathbf{x}_i^T = [1, \mathbf{x}_{i1}, \dots, \mathbf{x}_{ip}].$$

هستند. به منظور مدل‌بندی داده‌های شمارشی معمولاً فرض

$$Var(Y) = \phi E(Y) = \phi\mu,$$

به عنوان تناسب میانگین و واریانس در نظر گرفته می‌شود، که در آن اگر $1 = \phi$ باشد، آن‌گاه واریانس برابر با میانگین است و اگر $1 > \phi$ باشد، آن‌گاه نسبت به توزیع پواسون بیشپراکنش وجود دارد.

۳ توزیع‌های پواسون آمیخته

تعريف ۲: (توزیع پواسون آمیخته) فرض کنید با توجه به متغیر تصادفی λ که باتابع احتمال حاشیه‌ای $g_\lambda(\lambda)$ روی R^+ تعریف می‌شود، Y دارای توزیع پواسون با میانگین $\lambda\mu$ ، ($\mu > 0$) باشد، در این صورت توزیع حاشیه‌ای Y ، توزیع پواسون آمیخته باتابع چگالی

$$P_g(y|\phi) = \int_0^\infty \frac{e^{-\lambda}\lambda^y}{y!} dG(\lambda|\phi),$$

است، که در آن $G(\lambda|\phi)$ تابع توزیع متغیر تصادفی λ است.

گزاره ۱: اگر متغیر تصادفی Y دارای توزیع پواسون آمیخته باشد، آن‌گاه میانگین و واریانس آن عبارتند از

$$E(Y) = E(E(Y|\lambda)) = \mu E(\lambda),$$

$$Var(Y) = \mu E(\lambda) + \mu^2 Var(\lambda).$$

طبق رابطه (۲) چون پارامتر μ نقش مدل رگرسیون پواسون را به عهده دارد، لذا با استفاده از گزاره ۱، در توزیع‌های پواسون آمیخته، پارامترهای توزیع آمیزندۀ را طوری در نظر می‌گیرند که $1 = E(\lambda)$ شود. در

این صورت

$$E(Y) = \mu, \quad (3)$$

$$Var(Y) = \mu + \mu^\top Var(\lambda). \quad (4)$$

با توجه به رابطه (۴) واریانس توزیع پواسون آمیخته همواره بزرگتر از واریانس توزیع پواسون است. معمولاً توزیع‌های متعددی را به عنوان توزیع آمیزندۀ مورد آزمایش قرار داده‌اند، معروف‌ترین آن‌ها که در ادامه از آن‌ها استفاده شده، توزیع‌های گاما، $\Gamma(\alpha, \beta)$ ، گاوی وارون ($IG(\alpha, \beta)$) و گاوی وارون تعمیم‌یافته $GIG(\nu, \chi, \psi)$ هستند که تابع چگالی آن‌ها به ترتیب عبارتند از

$$\begin{aligned} f_Y(y) &= \frac{\beta^\alpha}{\Gamma(\alpha)} y^{\alpha-1} e^{-\beta y}, \quad y > 0, \\ f_Y(y) &= \sqrt{\frac{\beta}{2\pi y^3}} \exp\left\{-\frac{\beta(y-\alpha)^2}{2\alpha^2 y}\right\}, \quad y > 0, \\ f_Y(y) &= \frac{\left(\frac{\psi}{\chi}\right)^{\frac{\nu}{2}}}{\sqrt{K_\nu(\sqrt{\psi\chi})}} y^{\nu-1} \exp\left(-\frac{1}{2}(\chi y^{-1} + \psi y)\right), \quad y > 0. \end{aligned}$$

که در آن $(\cdot)_\nu$ تابع بسل تعمیم‌یافته نوع سوم است (گرادشتین و ریزهیک، ۲۰۰۰). با انتخاب توزیع‌های آمیزندۀ متفاوت، می‌توان توزیع‌های پواسون آمیخته جدیدی را تعریف نمود، اما تعداد زیادی از آن‌ها به دلیل نداشتن شکل بسته کاربرد چندانی در مدل‌های پواسون آمیخته ندارند. در ادامه چند مدل معروف از این خانواده که با توزیع‌های آمیزندۀ گاما، گاوی وارون و گاوی وارون تعمیم‌یافته تولید شده‌اند، معرفی می‌شوند.

تعريف ۳: (مدل رگرسیون پواسون-گاما، $PO - Gamma$) فرض کنید Y به شرط متغیر تصادفی مشاهده نشده λ دارای توزیع پواسون با میانگین $\mu\lambda$ باشد، که در آن $(\frac{1}{\sigma}, \frac{1}{\sigma})$ و $\mu = \exp(\mathbf{x}^T \boldsymbol{\beta})$ و $\lambda \sim \Gamma(\frac{1}{\sigma}, \frac{1}{\sigma})$. در این صورت تابع جرم احتمال حاشیه‌ای متغیر تصادفی Y (که همان توزیع دو جمله‌ای منفی است) به صورت

$$P(Y = y) = \frac{\Gamma(y + \frac{1}{\sigma})}{\Gamma(y + 1) \Gamma(\frac{1}{\sigma})} \left(\frac{\sigma\mu}{1 + \sigma\mu}\right)^y \left(\frac{1}{1 + \sigma\mu}\right)^{\frac{1}{\sigma}}, \quad y = 0, 1, \dots$$

با میانگین و واریانس

$$E(Y) = \mu, \quad Var(Y) = \mu(1 + \sigma\mu)$$

است. محققان بسیاری مانند میاوی (۱۹۹۴) و گاردنر و همکاران (۱۹۹۵) به مقایسه عملکرد مدل‌های رگرسیون پواسون و رگرسیون-گاما پرداخته‌اند.

تعريف ۴: (مدل رگرسیون پواسون-گاوی وارون، $PO - IG$) فرض کنید توزیع Y به شرط متغیر تصادفی مشاهده نشده λ پواسون با میانگین $\lambda\mu$ باشد، که در آن $\mu = \exp(\mathbf{x}^T \boldsymbol{\beta})$ و $\lambda \sim IG(1, \frac{1}{\sigma})$. در این صورت تابع جرم احتمال حاشیه‌ای Y بهصورت

$$P(Y = y) = \left(\frac{2\theta}{\pi}\right)^{\frac{y}{2}} \frac{\mu^y}{y!} e^{\frac{1}{\sigma}} \frac{K_{y-\frac{1}{2}}(\theta)}{(\theta\sigma)^y}, \quad y = 0, 1, \dots$$

است، که در آن $\theta^2 = \frac{1}{\sigma^2} + \frac{2\mu}{\sigma}$ و میانگین و واریانس آن عبارتند از

$$E(Y) = \mu, \quad Var(Y) = \mu(1 + \sigma\mu).$$

استین و جوریتز (۲۰۰۷) در مقاله خود به بررسی مدل‌های خطی با توزیع پواسون-گاوی وارون پرداخته‌اند.

تعريف ۵: (مدل رگرسیون پواسون-گاوی وارون تعمیم‌یافته، $PO - GIG$) فرض کنید توزیع Y به شرط متغیر تصادفی مشاهده نشده λ پواسون با میانگین $\lambda\mu$ باشد، که در آن $\mu = \exp(\mathbf{x}^T \boldsymbol{\beta})$ و $\lambda \sim GIG(\nu, \frac{1}{c\sigma}, \frac{c}{\sigma})$. در این صورت تابع جرم احتمال حاشیه‌ای Y بهصورت

$$P(Y = y) = \left(\frac{\mu}{c}\right)^y \frac{1}{(\theta\sigma)^{y+\nu} y!} \frac{K_{\nu+y}(\theta)}{K_{\nu}(\frac{1}{\sigma})}, \quad y = 0, 1, \dots$$

است، که در آن

$$\theta^2 = \frac{1}{\sigma^2} + \frac{2\mu}{c\sigma}, \quad c = R_{\nu}(\frac{1}{\sigma}) = \frac{K_{\nu+1}(\frac{1}{\sigma})}{K_{\nu}(\frac{1}{\sigma})}$$

و میانگین و واریانس آن عبارتند از

$$E(Y) = \mu, \quad Var(Y) = \mu(1 + \mu(\frac{2\sigma(\nu+1)}{c} + \frac{1}{c^2} - 1)).$$

رایگی و همکاران (۲۰۰۸) به معرفی ویژگی‌های توزیع پواسون-گاوی وارون تعمیم‌یافته و چارچوبی برای مدل‌بندی داده‌های شمارشی پرداخته‌اند.

۴ معرفی مدل رگرسیون پواسون-بیرنباام ساندرز

در این بخش مدلی از خانواده رگرسیون پواسون آمیخته به نام پواسون-بیرنباام ساندرز معرفی می‌شود، که در آن λ دارای توزیع آمیزندۀ بیرنباام ساندرز فرض شده است. این ایده از ارتباط توزیع گاوی وارون تعمیم‌یافته و توزیع بیرنباام ساندرز به دست آمده است. از مزیت‌های این مدل می‌توان به شکل بسته تابع احتمال آن و داشتن یک پارامتر کمتر نسبت به بعضی مدل‌های معرفی شده قبلی، اشاره کرد.

با توجه به این‌که توزیع بیرنباام ساندرز ترکیب خطی از دو توزیع گاوی وارون تعمیم‌یافته است، به نظر می‌رسد که انتخاب توزیع بیرنباام ساندرز به عنوان توزیع آمیزندۀ در ساخت مدل‌های رگرسیون پواسون آمیخته به دلیل داشتن شکل بسته و هم‌چنین داشتن واریانس بزرگ‌تر از میانگین، می‌تواند برای لحاظ کردن مسئله بیشپراکنش در داده‌های شمارشی مورد استفاده قرار گیرد. یک شبیه‌سازی با استفاده از بسته‌های نرم‌افزاری *bs* و *gamlss* در محیط *R* به منظور ارزیابی مدل پیشنهادی و مقایسه نظری آن با مدل‌های مرسوم استفاده شده است. معیار ارزیابی عملکرد مدل پیشنهاد شده، درصد قدرت تشخیص صحیح مدل است، یعنی از سری داده‌های شبیه‌سازی شده و آلوده کردن آن‌ها با مسئله بیشپراکنش، در چند درصد از موضع مدل پیشنهادی بهتر از سایر مدل‌های نامزد، عمل کرده است؟ هم‌چنین برای مقایسه نیکویی برآش مدل پیشنهادی و مدل‌های نامزد از ملاک *MSE* استفاده شده است.

اخيراً هاشيموتوا و همکاران (۲۰۱۳) یک مدل پواسون-بیرنباام ساندرز به منظور مدل‌بندی میزان بهبودی بقا و با این فرض که تعداد پیشامدها از توزیع پواسون و زمان پیشامدها از توزیع بیرنباام ساندرز پیروی می‌کنند، معرفی کردند. ایده ارائه شده توسط آن‌ها کاملاً متفاوت با ایده پیشنهادی در این مقاله است.

۱.۴ توزیع بیربنام ساندرز و خواص آن

بسیاری از فلزات به کار رفته در پل‌ها، خودروها، هوایپیماها و غیره در اثر اعمال بار به دفعات مکرر تحت تنش قرار گرفته و پس از یک دوره کار زیاد ترک خورده و کم کم می‌شکنند. این اتفاق معمولاً بدون اطلاع قبلی و غیر قابل رویت رخ می‌دهد. توزیع بیربنام ساندرز که برای نخستین بار توسط بیربنام و ساندرز (۱۹۶۹) معرفی شد به طور گستره‌های برای مدل‌بندی زمان شکست در آمار به کار برد می‌شود. زمان شکست همان زمان شروع ترک در فلزات تا رسیدن به شکست نهایی تلقی می‌شود. محققان بسیاری مانند دیازگارسیا و لیوا (۲۰۰۵)، فرام و لی (۲۰۰۶) و لیمونت و همکاران (۲۰۰۷) به بسط و تعمیم این توزیع پرداخته‌اند. همچنین کاندو و همکاران (۲۰۱۰) توزیع بیربنام ساندرز دو بعدی که دارای توزیع‌های حاشیه‌ای بیربنام ساندرز تک بعدی است را معرفی کرده‌اند. این توزیع از دیدگاه بیزی ابتدا توسط آچکار (۱۹۹۳) مورد بررسی قرار گرفت، همچنین نیل و رابرت (۲۰۰۸)، ژو و تانگ (۲۰۱۱) و وانگ و همکاران (۲۰۱۶) این توزیع را از دیدگاه بیزی مورد استنباط آماری قرار داده‌اند.

تعريف ۶: متغیر تصادفی W دارای توزیع بیربنام ساندرز $BS(\alpha, \beta)$ است، اگر تابع توزیع تجمعی آن به صورت

$$F_{BS}(w; \alpha, \beta) = \Phi\left[\frac{1}{\alpha}\left\{\left(\frac{w}{\beta}\right)^{\frac{1}{\alpha}} - \left(\frac{\beta}{w}\right)^{\frac{1}{\alpha}}\right\}\right], \quad w, \alpha, \beta > 0,$$

باشد، که در آن $\Phi(\cdot)$ تابع توزیع تجمعی نرمال استاندارد و α و β به ترتیب پارامترهای شکل و مقیاس هستند. در این صورت تابع چگالی احتمال w عبارت است از

$$f_{BS}(w; \alpha, \beta) = \frac{1}{2\sqrt{2\pi}\alpha\beta}\left[\left(\frac{\beta}{w}\right)^{\frac{1}{\alpha}} + \left(\frac{\beta}{w}\right)^{\frac{1}{\alpha}}\right]\exp\left[-\frac{1}{2\alpha^2}\left(\frac{w}{\beta} + \frac{\beta}{w} - 2\right)\right]. \quad (5)$$

گزاره ۲: امید ریاضی و واریانس توزیع بیربنام ساندرز عبارتند از

$$E(W) = \beta\left(1 + \frac{1}{2}\alpha^2\right), \quad Var(W) = (\alpha\beta)^2\left(1 + \frac{5}{4}\alpha^2\right).$$

یکی از خواص مورد توجه در توزیع بیربنام ساندرز این است که می‌توان آن را به صورت آمیخته‌ای از دو توزیع گاوی وارون تعمیم‌یافته مشخص کرد که در گزاره ۳ به آن پرداخته شده است.

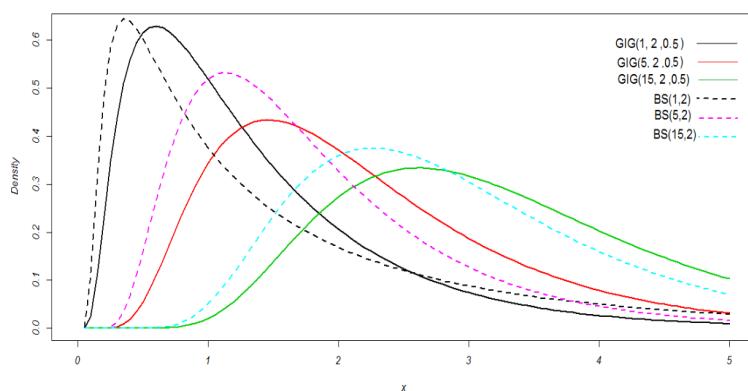
گزاره ۳: (کاندو و همکاران، ۲۰۱۰) اگر متغیر تصادفی W دارای توزيع $BS(\alpha, \beta)$ باشد، آنگاه W را می‌توان بهصورت آمیخته‌ای از دو متغیر تصادفی گاوسي وارون تعميم‌يافته مستقل از هم بهصورت

$$W \stackrel{d}{=} \begin{cases} X_1 & \text{با احتمال } \frac{1}{2} \\ X_2 & \text{با احتمال } \frac{1}{2} \end{cases}$$

نوشت، که در آن $(\frac{1}{\alpha}, \frac{\beta}{\alpha^2}, \frac{1}{\beta\alpha^2})$ و $X_1 \sim GIG(-\frac{1}{2}, \frac{\beta}{\alpha^2}, \frac{1}{\beta\alpha^2})$. در اين صورت

$$f_{BS}(w; \alpha, \beta) = \frac{1}{2} f_{GIG}(w; \frac{1}{2}, \frac{\beta}{\alpha^2}, \frac{1}{\beta\alpha^2}) + \frac{1}{2} f_{GIG}(w; -\frac{1}{2}, \frac{\beta}{\alpha^2}, \frac{1}{\beta\alpha^2}).$$

در شکل ۱ نمودار توزيع‌های گاوسي وارون تعميم‌يافته و بيرنام ساندرز برای چند تركيب مختلف از پaramترها مشخص شده است.



شکل ۱. نمودار تابع چگالی توزيع‌های گاوسي وارون تعميم‌يافته و بيرنام ساندرز برای چند تركيب مختلف از پaramترها

۲.۴ مدل رگرسيون پواسون-بيرنام ساندرز

در اين بخش مدل جديد رگرسيون پواسون-بيرنام ساندرز به منظور افزایش کارايی مدل رگرسيون پواسون توسط توزيع آميزنده بيرنام ساندرز به عنوان تركيب خطى از دو توزيع گاوسي وارون تعميم‌يافته برای مدل‌بندي داده‌های بيش‌پراكنش معرفی می‌شود.

قضیه ۱: فرض کنید Y به شرط متغیر تصادفی مشاهده نشده λ , دارای توزیع پواسون با میانگین و واریانس $\mu\lambda$ باشد که در آن $\mu = \exp(\mathbf{x}^T \boldsymbol{\beta})$ و λ دارای توزیع بیرنبا姆 ساندرز $BS(\alpha, \beta)$ است. در این صورت تابع چگالی حاشیه‌ای Y به صورت

$$f_Y(y) = \left(\frac{\mu\beta}{\alpha^\gamma\delta}\right)^y \frac{e^{\frac{1}{\alpha^\gamma}}}{\sqrt{2\pi y! \alpha}} [\alpha^{-1}\delta^{\frac{1}{\gamma}} K_{y+\frac{1}{\gamma}}(\delta) + \alpha\delta^{\frac{1}{\gamma}} K_{y-\frac{1}{\gamma}}(\delta)], \quad y = 0, 1, \dots \quad (6)$$

است، که در آن $\delta = \frac{1}{\alpha^\gamma} + \frac{\gamma\mu\beta}{\alpha^\gamma}$.

برهان: با توجه به رابطه (5) می‌توان نوشت:

$$\begin{aligned} f_Y(y) &= \int_0^\infty f(y|\lambda) g(\lambda) d\lambda \\ &= \int_0^\infty \frac{e^{-\mu\lambda}(\mu\lambda)^y}{y!} \frac{1}{\sqrt{2\pi\alpha\beta}} \left(\left(\frac{\beta}{\lambda}\right)^{\frac{1}{\gamma}} + \left(\frac{\beta}{\lambda}\right)^{\frac{\gamma}{\gamma}} \right) \exp\left\{-\frac{1}{2\alpha^\gamma}\left(\frac{\lambda}{\beta} + \frac{\beta}{\lambda} - 2\right)\right\} \\ &= \frac{\mu^y e^{\frac{1}{\alpha^\gamma}}}{\sqrt{2\pi\alpha\beta} y!} \left[\beta^{\frac{1}{\gamma}} \int_0^\infty \lambda^{y-\frac{1}{\gamma}} e^{\frac{-1}{\alpha^\gamma}[(\frac{1}{\beta\alpha^\gamma} + \gamma\mu)\lambda + \frac{\beta}{\alpha^\gamma}\lambda^{-1}]} d\lambda \right. \\ &\quad \left. + \beta^{\frac{\gamma}{\gamma}} \int_0^\infty \lambda^{y-\frac{\gamma}{\gamma}} e^{\frac{-1}{\alpha^\gamma}[(\frac{1}{\beta\alpha^\gamma} + \gamma\mu)\lambda + \frac{\beta}{\alpha^\gamma}\lambda^{-1}]} d\lambda \right] \end{aligned}$$

انتگرال‌های موجود در رابطه فوق بر اساس خواص تابع بسل تعیین یافته نوع سوم به صورت

$$\int_0^\infty \lambda^{y-\frac{1}{\gamma}} e^{\frac{-1}{\alpha^\gamma}[(\frac{1}{\beta\alpha^\gamma} + \gamma\mu)\lambda + \frac{\beta}{\alpha^\gamma}\lambda^{-1}]} d\lambda = 2\left(\frac{\alpha^\gamma\delta}{\beta}\right)^{-y-\frac{1}{\gamma}} K_{y+\frac{1}{\gamma}}(\delta)$$

به دست می‌آیند. همچنین

$$\int_0^\infty \lambda^{y-\frac{\gamma}{\gamma}} e^{\frac{-1}{\alpha^\gamma}[(\frac{1}{\beta\alpha^\gamma} + \gamma\mu)\lambda + \frac{\beta}{\alpha^\gamma}\lambda^{-1}]} d\lambda = 2\left(\frac{\alpha^\gamma\delta}{\beta}\right)^{-y+\frac{1}{\gamma}} K_{y-\frac{1}{\gamma}}(\delta),$$

که در آنها $\delta = \frac{1}{\alpha^\gamma} + \frac{\gamma\mu\beta}{\alpha^\gamma}$.

$$f_Y(y) = \frac{\mu^y e^{\frac{1}{\alpha^\gamma}}}{\sqrt{2\pi\alpha\beta} y!} \left[\frac{2\beta^{\frac{1}{\gamma}} K_{y+\frac{1}{\gamma}}(\delta)}{\left(\frac{\alpha^\gamma\delta}{\beta}\right)^{y+\frac{1}{\gamma}}} + \frac{2\beta^{\frac{\gamma}{\gamma}} K_{y-\frac{1}{\gamma}}(\delta)}{\left(\frac{\alpha^\gamma\delta}{\beta}\right)^{y-\frac{1}{\gamma}}} \right],$$

که از آن رابطه (۶) حاصل می‌شود.

در قضیه ۱ برای اعمال فرض $1 = E(\lambda)$ ، طبق رابطه (۳) بایستی پارامترهای α و β در توزیع بیننام ساندرز را به صورت $\alpha = \sigma^{\frac{1}{2}}$ و $\beta = \frac{2}{\sigma+2}$ در نظر گرفت.

قضیه ۲: مدل پواسون-بیننام ساندرز ارائه شده در رابطه (۶)، دارای ویژگی (۴) است.

برهان: طبق روابط (۳) و (۴) به سادگی می‌توان نشان داد:

$$\begin{aligned} E(Y) &= \mu, \\ Var(Y) &= \mu + \mu^2 \left(\frac{\sigma(4 + 5\sigma)}{(\sigma + 2)^2} \right). \end{aligned}$$

بنابراین این مدل ویژگی (۴) را دارد.

۵ برآورد ماکسیمم درستنمایی مدل پواسون-بیننام ساندرز

به دست آوردن برآورد ماکسیمم درستنمایی پارامترهای مدل رگرسیون پواسون-بیننام ساندرز مستلزم حل معادلات غیر خطی با روش‌های عددی تکراری است. الگوریتم امید-ماکسیمم^۸ EM یک روش عمومی برای محاسبه برآورد ماکسیمم درستنمایی در یک مسئله با داده‌های گم شده یا ناکامل است. الگوریتم EM توسط دمپستر و همکاران (۱۹۷۷) ارائه شده است. کارلیس (۲۰۰۵) و زی وی (۲۰۰۸) الگوریتم EM برای توزیع‌های پواسون آمیخته را مورد بررسی قرار دادند.

الگوریتم EM معمولاً برای مواردی که تابع درستنمایی شکل پیچیده‌ای دارد و برآورد بیشینه درستنمایی پارامترها با روش مستقیم کار غیر ممکنی است، مورد استفاده قرار می‌گیرد. در مدل رگرسیون پواسون بیننام ساندرز، فرض کنید $(\beta^T, \sigma^T) = \theta$ بردار پارامترهای نامعلوم، Y_{obs} نشان دهنده داده‌های مشاهده شده $\{\lambda_i; i = 1, \dots, n\}$ و $\{Y_i; i = 1, \dots, n\}$ از وزن‌ها باشند که به عنوان داده‌های گمشده Y_{mis} رفتار می‌کنند. به علاوه $(Y_c = (Y_{obs}, Y_{mis}))$ اشاره به مجموعه داده‌های کامل دارد. زمانی که ماکسیمم کردن $\log L(Y_{obs}|\theta)$ نسبت به θ آسان نیست، الگوریتم EM، آن را به وسیله تکرار ماکسیمم‌سازی ($E(\log L(Y_c|\theta))$ ، ماکسیمم می‌کند. الگوریتم EM یک لگوریتم تکرار شونده است که در آن هر تکرار شامل دو مرحله است. فرض کنید $(\theta^{(0)})$ مقادیر اولیه الگوریتم EM باشند.

⁸EM algorithm

۱. گام E، مرحله گرفتن امید ریاضی: امید ریاضی لگاریتم تابع درست‌نمایی داده‌های کامل به شرط داده‌های مشاهده شده و مقدار پارامتر جاری، یعنی $E(\log L(Y_c|\theta)|y_{obs}, \theta^{(k)}) = Q(\theta|\theta^{(k)})$ محاسبه می‌شود.

۲. گام M، مرحله ماکسیمم‌سازی: مقدار $\theta^{(k+1)}$ به گونه‌ای انتخاب می‌شود که تابع $Q(\theta|\theta^{(k)})$ برای هر θ ماکسیمم شود، به عبارت دیگر $\theta^{(k+1)} = \arg \max_{\theta} Q(\theta|\theta^{(k)})$.

گام‌های E و M تا زمانی که دنباله به همگرایی برسد تکرار می‌شوند، به عبارت دیگر تا زمانی که $\log L(Y_c|\theta^{k+1}) - \log L(Y_c|\theta^k)$ به کمترین مقدار دلخواه برسد. به طور کلی الگوریتم EM به نقطه اولیه حساس است و یک انتخاب نامناسب به عنوان نقطه اولیه موجب کاهش سرعت همگرایی الگوریتم EM می‌شود. برای انجام گام E نیاز به محاسبه امید ریاضی توابعی از متغیر تصادفی شرطی $y|Y = \lambda$ است، که برای این منظور از ویژگی خانواده سری‌های توانی^۹ استفاده می‌شود.

تعريف ۷: یک توزیع گسسته متعلق به خانواده توزیع‌های سری توانی نامیده می‌شود، اگر تابع جرم احتمال آن را بتوان به صورت

$$P(y|\lambda) = \frac{a_y \lambda^y}{A(\lambda)},$$

نشان داد، که در آن $a_y > 0$ و $A(\lambda)$ تابعی از λ است و به y بستگی ندارد. بسیاری از توزیع‌های گسسته شناخته شده مانند توزیع پواسون و دوجمله‌ای متعلق به این خانواده هستند. اگر پارامتر λ متغیر تصادفی باشد، یک سری توانی آمیخته با تابع احتمال زیر حاصل می‌شود.

$$P_g(y|\phi) = \int_0^\infty \frac{a_y \lambda^y}{A(\lambda)} g(\lambda|\phi) d\phi$$

لم ۱: (سایپاتیناس، ۱۹۹۵) اگر $\lambda|Y$ از توزیع‌های گسسته توانی پیروی کند و λ دارای تابع احتمال حاشیه‌ای $g(\lambda)$ باشد، آنگاه

$$E(\lambda^r|Y = y) = \frac{P_g(y+r|\phi)a_y}{P_g(y|\phi)a_{y+r}}.$$

⁹Power series family

قضیه ۳: فرض کنید Y به شرط λ دارای توزیع پواسون با میانگین $\mu\lambda$ و $\lambda \sim BS(\alpha, \beta)$ باشد، آنگاه

الف: تابع چگالی λ به شرط مشاهده y به صورت

$$f(\lambda|y) = c \left[\beta^{\frac{1}{\gamma}} \lambda^{y-\frac{1}{\gamma}} e^{\frac{-1}{\gamma}((\frac{1}{\beta\alpha^\gamma} + \gamma\mu)\lambda + \frac{\beta}{\lambda\alpha^\gamma})} + \beta^{\frac{\gamma}{\gamma}} \lambda^{y-\frac{\gamma}{\gamma}} e^{\frac{-1}{\gamma}((\frac{1}{\beta\alpha^\gamma} + \gamma\mu)\lambda + \frac{\beta}{\lambda\alpha^\gamma})} \right],$$

است، که در آن

$$c = \frac{1}{\gamma\beta} \left(\frac{\delta\alpha^\gamma}{\beta} \right)^y \left[(\delta\alpha^\gamma)^{\frac{-1}{\gamma}} K_{y+\frac{1}{\gamma}}(\delta) + (\delta\alpha^\gamma)^{\frac{1}{\gamma}} K_{y-\frac{1}{\gamma}}(\delta) \right]^{-1}.$$

ب: گشتاور r ام متغیر تصادفی λ به شرط مشاهده y برابر است با:

$$E(\lambda^r|Y=y) = \left(\frac{\beta}{\alpha^\gamma\delta} \right)^r \left[\frac{\alpha^{-1}\delta^{\frac{-1}{\gamma}} K_{y+r+\frac{1}{\gamma}}(\delta) + \alpha\delta^{\frac{1}{\gamma}} K_{y+r-\frac{1}{\gamma}}(\delta)}{\alpha^{-1}\delta^{\frac{-1}{\gamma}} K_{y+\frac{1}{\gamma}}(\delta) + \alpha\delta^{\frac{1}{\gamma}} K_{y-\frac{1}{\gamma}}(\delta)} \right]. \quad (4)$$

برهان: الف: با توجه به اینکه

$$f(\lambda|y) = \frac{f(y, \lambda)}{f(y)} = kf(y|\lambda)g(\lambda), \quad \int_0^\infty f(\lambda|y)d\lambda = 1$$

که در آن k تابعی از y و مستقل از λ است. بنابراین

$$\begin{aligned} \int_0^\infty f(y|\lambda)d\lambda &= k \int_0^\infty f(y|\lambda)g(\lambda)d\lambda \\ &= k \int_0^\infty \frac{e^{-\mu\lambda}(\mu\lambda)^y}{y!} \frac{1}{\gamma\sqrt{2\pi}\alpha\beta} \left[\left(\frac{\beta}{\lambda} \right)^{\frac{1}{\gamma}} + \left(\frac{\beta}{\lambda} \right)^{\frac{\gamma}{\gamma}} \right] \exp \left[-\frac{1}{\gamma\alpha^\gamma} \left(\frac{\lambda}{\beta} + \frac{\beta}{\lambda} - \gamma \right) \right] d\lambda \\ &= \frac{k\mu^y e^{\frac{1}{\alpha^\gamma}}}{\gamma\sqrt{2\pi}\alpha\beta y!} \int_0^\infty e^{-\mu\lambda} \lambda^y \left[\left(\frac{\beta}{\lambda} \right)^{\frac{1}{\gamma}} + \left(\frac{\beta}{\lambda} \right)^{\frac{\gamma}{\gamma}} \right] \exp \left[-\frac{1}{\gamma\alpha^\gamma} \left(\frac{\lambda}{\beta} + \frac{\beta}{\lambda} \right) \right] d\lambda \\ &= k' \left[\beta^{\frac{1}{\gamma}} \int_0^\infty \lambda^{y-\frac{1}{\gamma}} e^{\frac{-1}{\gamma}((\frac{1}{\beta\alpha^\gamma} + \gamma\mu)\lambda + \frac{\beta}{\lambda\alpha^\gamma})} d\lambda \right] \end{aligned}$$

$$+\beta^{\frac{r}{\alpha}} \int_0^\infty \lambda^{y-\frac{1}{\alpha}} e^{\frac{-1}{\alpha}((\frac{1}{\beta\alpha^r}+2\mu)\lambda+\frac{\beta}{\lambda\alpha^r})} d\lambda] = 1$$

با توجه به خواص تابع بسل تعیین‌یافته نوع سوم می‌توان نوشت:

$$c = k' = \frac{1}{2\beta} \left(\frac{\delta\alpha^r}{\beta} \right)^y [(\delta\alpha^r)^{\frac{-1}{\alpha}} K_{y+\frac{1}{\alpha}}(\delta) + (\delta\alpha^r)^{\frac{1}{\alpha}} K_{y-\frac{1}{\alpha}}(\delta)]^{-1}$$

بنابراین

$$f(\lambda|y) = c[\beta^{\frac{1}{\alpha}} \lambda^{y-\frac{1}{\alpha}} e^{\frac{-1}{\alpha}((\frac{1}{\beta\alpha^r}+2\mu)\lambda+\frac{\beta}{\lambda\alpha^r})} + \beta^{\frac{r}{\alpha}} \lambda^{y-\frac{r}{\alpha}} e^{\frac{-1}{\alpha}((\frac{1}{\beta\alpha^r}+2\mu)\lambda+\frac{\beta}{\lambda\alpha^r})}].$$

برای اثبات (ب) می‌توان از قضیه ۳ یا ویژگی خانواده سری‌های توانی استفاده کرد. با توجه به این‌که توزیع پواسون متعلق به خانواده توزیع‌های سری توانی با $A(\lambda) = e^{\mu\lambda}$, $a_y = \frac{\mu^y}{y!}$ است، با استفاده از لم ۱ اثبات به سادگی انجام می‌شود.

رابطه (۷) برای برآوردهای مدل رگرسیون پواسون-بیرنbaum ساندرز به کمک الگوریتم EM مورد استفاده قرار می‌گیرد. تابع درستنمایی یک نمونه از توزیع پواسون-بیرنbaum ساندرز با پارامترهای $\theta = (\beta^T, \sigma)^T$ به صورت

$$\log L_Y(\theta) = \sum_{i=1}^n \log f_{y_i}(y_i; \theta).$$

است. تابع درستنمایی داده‌های کامل به صورت

$$\begin{aligned} \log L_{Y,\lambda}(\theta) &= \log \prod_{i=1}^n f_{Y_i|\lambda_i}(y_i; \theta) f_{\lambda_i}(\lambda_i, \theta) \\ &= \sum_{i=1}^n \log f_{Y_i|\lambda_i}(y_i; \theta) + \sum_{i=1}^n \log f_{\lambda_i}(\lambda_i; \theta) \\ &= L_{Y_n|\lambda_n}^{(1)}(\theta) + L_{\lambda_n}^{(2)}(\theta), \end{aligned}$$

است، که در آن $\lambda_n = (\lambda_1, \dots, \lambda_n)$ و $Y_n = (Y_1, \dots, Y_n)$ همچنین

$$\begin{aligned} L_{Y_n|\lambda_n}^{(1)}(\theta) &= \sum_{i=1}^n \log f_{Y_i|\lambda_i}(y_i; \theta) \\ &= -\sum_{i=1}^n \exp(x_i^T \beta) \lambda_i + \sum_{i=1}^n y_i (x_i^T \beta) \\ &\quad + \sum_{i=1}^n y_i \log(\lambda_i) - \sum_{i=1}^n \log y_i! \\ L_{\lambda_n}^{(2)}(\theta) &= -n \log(4\sqrt{2}\pi) + n \log(\sigma + 2) - \frac{n}{2} \log \sigma + \frac{n}{2} \log 2 \\ &\quad - \frac{3n}{2} \log(\sigma + 2) - \frac{3}{2} \sum_{i=1}^n \log \lambda_i + \sum_{i=1}^n \log((\sigma + 2)\lambda_i + 2) \\ &\quad - \sum_{i=1}^n \frac{\lambda_i(\sigma + 2)}{4\sigma} - \sum_{i=1}^n \frac{1}{\sigma(\sigma + 2)\lambda_i} + \frac{n}{\sigma} \end{aligned}$$

این روابط در الگوریتم EM مورد استفاده قرار می‌گیرند.

۶ مثال‌های کاربردی

در این بخش ابتدا به شبیه‌سازی از مدل پواسون-بیرنبا姆 ساندرز معرفی شده در بخش ۵ پرداخته می‌شود. سپس با آنده کردن یک داده تولید شده از مدل پواسون توسط داده‌های بیش‌پراکنش، کارایی این مدل با سایر مدل‌ها مقایسه می‌شود. در ادامه نیز از این مدل برای تحلیل داده‌های واقعی استفاده می‌شود.
الگوریتم ۱: شبیه‌سازی و تولید داده از مدل پواسون-بیرنبا姆 ساندرز با پارامترهای معلوم μ و σ به کمک قضیه ۱

گام ۱: تولید یک نمونه تصادفی n تایی از توزیع $BS(\sigma^{\frac{1}{2}}, \frac{2}{\sigma+2})$ و نشان دادن آنها با λ_i برای $i = 1, \dots, n$

گام ۲: محاسبه مقادیر λ_i برای مقدار معلوم μ و هر مقدار شبیه‌سازی شده λ_i .

گام ۳: تولید مقداری تصادفی از توزیع پواسون با پارامتر $\mu \lambda_i$ برای $i = 1, \dots, n$.

لازم به ذکر است برای انجام گام ۱ می‌توان از روش‌های متعددی استفاده کرد. به عنوان نمونه می‌توان به بسته‌های bs و $GIGrvg$ در نرم‌افزار R اشاره نمود.

برای بررسی کارایی مدل پیشنهادی ابتدا نمونه‌های تصادفی 50 ، 100 و 300 تایی از مدل پواسون با $\lambda = 1$ شبیه‌سازی شده است. سپس 30 درصد از داده‌ها به تصادف حذف شده و با نمونه‌ای تصادفی از توزیع پواسون با $\lambda = 20$ ، که واریانس بزرگتری نسبت به داده‌های موجود دارد، تعویض شده‌اند. معیار ارزیابی عملکرد مدل پیشنهادی درصد قدرت تشخیص صحیح مدل در نظر گرفته شده است. همچنین برای بررسی عملکرد مدل، مقادیر واقعی با مقادیر پیش‌بینی شده توسط مدل برتر بر اساس ملاک MSE مقایسه شده‌اند. با استفاده از نرم‌افزار R و بسته $gamlss$ مدل‌های مورد نظر به داده‌ها برازش داده شده و نتایج در جدول ۱ ارائه شده‌اند. همان‌طور که ملاحظه می‌شود با افزایش حجم نمونه کارایی مدل پیشنهادی

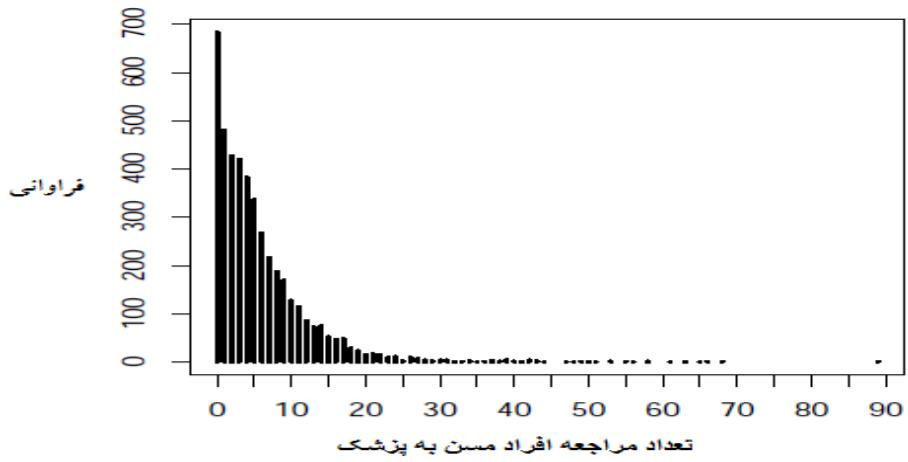
جدول ۱. مقادیر درصد قدرت تشخیص مدل و ملاک MSE با حجم نمونه‌های مختلف.

حجم نمونه	PO-BS	PO-GIG	PO-Gamma	PO	مدل
۵۰	۰/۵۹۷	۰/۶۰۳	۰/۷۴۱	۰/۰۳	
۱۰۰	۰/۸۳۹	۰/۸۳۹	۰/۸۸۳	۰/۱۱	درصد تشخیص صحیح مدل
۳۰۰	۰/۹۳۱	۰/۹۲۷	۰/۹۱۹	۰/۰۹	
۵۰	۰/۱۵۹	۰/۱۴۳	۰/۱۳۹	۰/۸۹	
۱۰۰	۰/۱۲۳	۰/۱۲۳	۰/۱۲۵	۰/۴۷	میانگین MSE مدل
۳۰۰	۰/۰۸۲	۰/۰۸۴	۰/۰۸۷	۰/۳۹	

از مدل‌های مرسوم بهتر می‌شود.

مثال ۱: (تقاضا برای مراقبت‌های پزشکی توسط افراد مسن) مجموعه داده‌های این مثال شامل اطلاعات مربوط به ۴۶ فرد ۶۶ ساله و بیشتر است که در یک برنامه بیمه عمومی پوشش داده شده و توسط دب و تریودی (۱۹۹۷) مورد تحلیل قرار گرفته‌اند و توسط زیلیس و کلیبر (۲۰۰۸) با عنوان داده‌های $DebTrivedi.rdi$ در پایگاه داده نرم‌افزار R بارگذاری شده‌اند.

برای مدل‌بندی میزان تقاضای مراقبت‌های پزشکی، تعداد مراجعه به پزشک به عنوان متغیر وابسته و تعداد اقامت در بیمارستان، وضعیت سلامت (ضعیف، متوسط و عالی)، تعداد بیماری‌های مزمن، جنسیت (زن و مرد)، تعداد سال تحصیلات و بیمه خصوصی (بلی و خیر) به عنوان متغیرهای توضیحی در نظر گرفته شده‌اند. نمودار فراوانی مراجعت بیماران به پزشک در شکل ۲ نشان داده شده است.



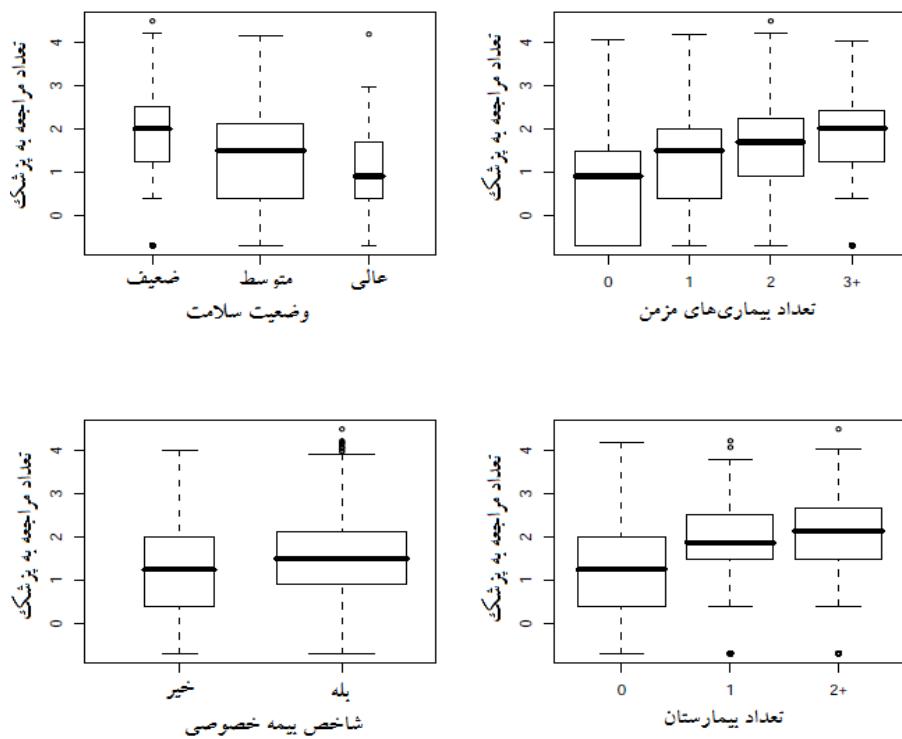
شکل ۲. فراوانی تعداد مراجعه به پزشک.

مقادیر میانگین و واریانس متغیر پاسخ به ترتیب $5/774$ و $45/687$ مشاهده شده‌اند که بیانگر بیش‌پراکنش داده‌ها است. بنابراین برای مدل‌بندی تعداد مراجعه افراد مسن به پزشک می‌توان از مدل‌های پواسون آمیخته استفاده کرد. همان‌طور که از شکل ۳ مشخص است متغیر پاسخ در مقابل متغیرهای توضیحی رفتاری صعودی یا نزولی از خود نشان داده است.
برای انتخاب بهترین مدل قابل برآذش به داده‌ها، مدل‌های رگرسیون پواسون، پواسون-گاما، پواسون-گاوی وارون و پواسون-بیرنbaum ساندرز به داده‌ها برآذش داده شده و با ملاک MSE و معیار اطلاع AIC مورد مقایسه قرار گرفته‌اند.

جدول ۲. مقادیر معیارهای MSE و AIC برای مدل‌های برآذش شده

مدل	تعداد پارامترها	MSE	AIC
پواسون	۱	۲/۹۸	۳۵۹۵۹/۲۳
دو جمله‌ای منفی	۲	۲/۰۲	۲۴۳۵۹/۱۱
پواسون-گاوی وارون	۲	۲/۱۶	۲۴۴۲۶/۹۳
پواسون-بیرنbaum ساندرز	۲	۱/۹۶	۲۴۱۹۶/۷۲

با توجه به مقادیر MSE و معیار اطلاع اکائیکه در جدول ۲، مدل پواسون-بیرنbaum ساندرز برآذش بهتری را نسبت به سایر مدل‌ها از خود نشان داده است. در جدول ۳ ضرایب برآورده شده از مدل پواسون-



شکل ۳. رفتار متغیر وابسته در مقابل متغیرهای توضیحی

بیرنبا姆 ساندرز ارائه شده‌اند.

با توجه به مقادیر t در جدول ۳ تأثیر متغیرهای توضیحی بر متغیر پاسخ کاملاً مشخص است. طبق رابطه (۲) و جدول ۳ و با توجه به این‌که $E(\lambda) = 1$ فرض شده است، مدل برازش شده برای μ توسط رگرسیون پواسون-بیرنبا姆 ساندرز به صورت

$$E(Y_i|x_i) = \mu_i = \exp(0.867 + 0.205x_1 + 0.261x_2 - 0.254x_3 + 0.195x_4 - 0.146x_5 + 0.26x_6 + 0.235x_7)$$

نوشته می‌شود، که در آن x_1 تعداد روز اقامت در بیمارستان، x_2 وضعیت سلامت ضعیف، x_3 وضعیت

جدول ۳. ضرایب برآورد شده از برازش مدل رگرسیون-پواسون بیرنبام ساندرز

ضرایب	برآورد	انحراف معیار t -مقدار	ضرایب
۱۸/۷۲۵	۰/۰۵۲	۰/۸۶۷	β_0
۱۰/۹۵۳	۰/۰۱۹	۰/۲۰۵	β_1
۶/۷۸۳	۰/۰۴۴	۰/۲۶۱	β_2
-۵/۷۶۲	۰/۰۵۸۹	-۰/۳۵۴	β_3
۱۵/۲۳۱	۰/۰۱۲	۰/۱۹۵	β_4
-۳/۸۵۶	۰/۰۳۱	-۰/۱۴۶	β_5
۶/۰۵۴	۰/۰۰۴	۰/۰۲۶	β_6
۶/۵۴۲	۰/۰۳۹	۰/۲۳۵	β_7

سلامت عالی، x_4 تعداد بیماری‌های مزمن، x_5 جنسیت مرد، x_6 تعداد سال تحصیلات و x_7 شاخص بیمه خصوصی بلی است. همچنین $\hat{\sigma} = ۲/۴۲۱۵$.

بحث و نتیجه‌گیری

در این مقاله مدل رگرسیون پواسون-بیرنبام ساندرز معرفی شد که می‌تواند برای لحاظ مسئله بیش‌پراکنش در داده‌های شمارشی مورد استفاده قرار گیرد. از آنجا که توزیع بیرنبام ساندرز آمیخته‌ای از دو توزیع گاوی وارون تعمیم‌یافته با مقادیر ثابت $\pm \frac{1}{\sqrt{n}}$ است، بنابراین یک پارامتر کمتر نسبت به توزیع گاوی وارون تعمیم‌یافته دارد. این مدل دو پارامتری کارایی خود را با یک پارامتر کمتر نسبت به مدل‌های قبلی بر اساس معیارهای AIC و MSE نشان داد. لذا استفاده از این مدل برای برازش و پیش‌بینی داده‌های شمارشی بیش‌پراکنش توصیه می‌شود.

تقدیر و تشکر

نویسنده‌گان از نظرات ارزشمند داوران محترم در بهبود کیفیت مقاله و همچنین از سردبیر، هیئت تحریریه و ویراستار مجله به خاطر مطالعه دقیق و ویرایش ادبی مقاله تقدیر و تشکر به عمل می‌آورند.

مراجع

- Achcar, J. A. (1993), Inferences for the Birnbaum–Saunders Fatigue Life Model Using Bayesian Methods, *Computational Statistics and Data Analysis*, **15**, 367–380.
- Birnbaum, Z. W. and Saunders, S. C. (1969), A New Family of Life Distribution, *Journal of Applied Probability*, **6**, 319–327.
- Deb, P. and Trivedi, P. K. (1997), Demand for Medical Care by the Elderly: A Finite Mixture Approach, *Journal of Applied Econometrics*, **12**, 313–336.
- Dempster, A. P., Laird, N. M. and Rubin, D. B. (1977), Maximum Likelihood from Incomplete Data via the EM Algorithm, *Journal of the Royal Statistical Society, Series B*, **39**, 1–38.
- Díaz-García, J. A. and Leiva, V. (2005), A New Family of Life Distributions Based on Elliptically Contoured Distributions, *Journal of Statistical Planning and Inference*, **128**, 445–457.
- From, S. G. and Li, L. X. (2006), Estimation of the Parameters of the Birnbaum Saunders Distribution, *Communications in Statistics, Theory and Methods*, **35**, 2157–2169.
- 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.
- Gradshteyn, I. S. and Ryzhik, I. M. (2000), *Table of Integrals, Series and Products*, 6th Edt., Academic Press, San Diego.
- Hashimotoa, E. M., Ortegaa, E. M. M., Cordeirob, G. M. and Canchoc, V. G. (2013), The Poisson Birnbaum–Saunders Model with Long-term Survivors, *A Journal of Theoretical and Applied Statistics*, **48**, 1394–1413.
- Hinde, J. (1982), *Compound Poisson Regression Models*, In: Gilchrist, R. (Ed.), GLIM 82, Proceedings of the International Conference on Generalised Linear Models, Springer, New York, 109–121.
- Johnson, N. L., Kotz, S. and Kemp, A. W. (1992), *Univariate Distributions*, 2nd Edt., John Wiley, New York.
- Karlis, D. (2005), EM Algorithm for Mixed Poisson and Other Discrete Distributions, *Astin Bulletin*, **35**, 3–24.
- Karlis, D. and Xekalaki, E. (2005), Mixed Poisson Distributions, *International Statistical Review*, **73**, 35–58.

- Kundu, D. N., Balakrishnan, N. and Jamalizadeh, A. (2010), Bivariate Birnbaum-Saunders Distribution and Associated Inference, *Journal of Multivariate Analysis*, **101**, 113-125.
- Lemonte, A. J., Cribari-Neto, F. and Vasconcellos, K. L. P. (2007), Improved Statistical Inference for the Two-Parameter Birnbaum-Saunders Distribution, *Computational Statistics and Data Analysis*, **51**, 4656-4681.
- Neal, P. and Roberts, G. (2008), Optimal Scaling for Random Walk Metropolis on Spherically Constrained Target Densities, *Methodology and Computing in Applied Probability*, **10**, 277-297.
- Miaou, S. P. (1994), The Relationship Between Truck Accidents and Geometric Design of Road Sections: Poisson Versus Negative Binomial Regressions, *Accident Analysis and Prevention*, **26**, 471-482.
- Patil, G. P. (1970), *Random Counts in Models and Structures*, Pennsylvania State University Press, University Park, London.
- Rigby, R. A., Stasinopoulos, D. M. and Akantziliotou, C. (2008), A Framework for Modelling Overdispersed Count Data, Including the Poisson-shifted Generalized Inverse Gaussian Distribution, *Statistics and Data Analysis*, **53**, 381-393.
- Saez-Castillo, A. J. and Cond-Sanchez, A. (2013), A Hyper-Poisson Regression Model for Overdispersed and Underdispersed Count Data, *Computational Statistics and Data Analysis*, **61**, 146-157.
- Sapatinas, T. (1995), Identifiability of Mixtures of Power-series Distributions and Related Characterizations, *Annals of the Institute of Statistical Mathematics*, **47**, 447-459.
- Stein, G. Z. and Juritz, J. M. (2007), Linear Models with an Inverse Gaussian Poisson Error Distribution, *Communications in Statistics, Theory and Methods*, **17**, 557-571.
- Taylor, H. M. and Karlin, S. (1994), *An Introduction to Stochastic Modelling*, Revised Edition, Academic Press, San Diego and New York.
- Wang, M., Sun, X. and Park, C. (2016), Bayesian Analysis of Birnbaum-Saunders Distribution via the Generalized Ratio-of-Uniforms Method, *Computational Statistics*, **31**, 207-225.
- Xie, F. C. and Wei, B. C. (2008), Influence Analysis for Poisson Inverse Gaussian Regression Models Based on the EM Algorithm, *Metrika*, **67**, 49-62.
- Xu, A. and Tang, Y. (2011), Bayesian Analysis of Birnbaum-Saunders Distribution with Partial Information, *Computational Statistics and Data Analysis*, **55**, 2324-2333.

۲۶۲ مدل‌بندی داده‌های شمارشی تحت تأثیر بیشپراکنش

Zeileis, A. and Kleiber, C. (2008), **AER**: *Applied Econometrics with R*, R Package Version 0.9-0, URL <http://CRAN.R-project.org/package=AER>.