

مجله علوم آماری، پاییز و زمستان ۱۳۹۴

جلد ۹، شماره ۲، ص ۱۶۷-۱۴۹

رگرسیون چندکی بیزی با تاوان لاسو و لاسوی تطبیق‌پذیر برای داده‌های طولی دودویی

علی آقامحمدی، سکینه محمدی

گروه آمار، دانشگاه زنجان

تاریخ دریافت: ۱۳۹۳/۳/۱۱ تاریخ آخرین بازنگری: ۱۳۹۳/۱۱/۴

چکیده: در بسیاری از مطالعات علوم پزشکی برای بیان سیر بیماری و تأثیر درمان از مطالعات طولی استفاده می‌شود، که در آن پاسخ‌ها به طور مکرر در طول زمان اندازه‌گیری می‌شوند. اما گاهی این پاسخ‌ها دو حالت و گستره هستند. در این مقاله مدل رگرسیون چندکی با تاوان لاسو و لاسوی تطبیق‌پذیر برای داده‌های طولی با پاسخ‌های دو حالت ارائه شده و هر دو روش از دیدگاه آمار بیزی مورد تحلیل قرار می‌گیرد. با توجه به این‌که در هر دو روش توزیع‌های پسینی پارامترها به شکل بسته قابل حصول نیستند، توزیع‌های پسینی شرطی کامل پارامترها محاسبه شده و از الگوریتم نمونه‌گیری گیبز برای استنباط استفاده می‌شود. برای مقایسه کارایی روش‌های ارائه شده با روش‌های متداول، مطالعه شبیه‌سازی انجام شده و در پایان نیز نحوه کاربری مدل‌ها در قالب مثال کاربردی شرح داده خواهد شد.

واژه‌های کلیدی: رگرسیون چندکی دودویی، تاوان لاسو، تاوان لاسوی تطبیق‌پذیر، داده‌های طولی، نمونه‌گیری گیبز، استنباط بیزی.

آدرس الکترونیک مسئول مقاله: علی آقامحمدی, Aghamohammadi.ali@znu.ac.ir

کد موضوع بنای ریاضی (۲۰۱۰): ۶۲۴۹۶، ۶۲۴۹۵

۱ مقدمه

در بسیاری از مطالعه‌های مربوط به علوم پزشکی و اجتماعی، متغیر پاسخ برای هر فرد در چندین نویست متوالی مشاهده می‌شود. برای مثال یک پزشک، سلامت بیماران را به طور هفتگی ارزیابی می‌کند تا دریابد، آیا داروی جدید موقتی داشته است یا خیر. به مطالعه‌ای که اندازه‌گیری مربوط به یک صفت در طول زمان مورد بررسی قرار می‌گیرد، مطالعه طولی^۱ گویند. ممکن است فاصله‌های زمانی که هر واحد آزمایشی مورد مشاهده قرار می‌گیرد، یکسان نباشد. مهمترین مزیت این نوع مطالعات تفکیک اثر زمان از تفاوت‌های فردی است که در مطالعه‌های مقطعی (پاسخ برای هر واحد آزمایشی، تنها یک بار مشاهده می‌شود) امکان پذیر نیست. لذا مطالعه‌های طولی نسبت به مطالعه‌های مقطعی دارای دقت بیشتری هستند (غلامی فشارکی و همکاران، ۱۳۹۲). گاهی پاسخ‌های ثبت شده به صورت کیفی، بهویژه دو حالته هستند. به عنوان مثال تأثیر یا عدم تأثیر یک داروی خاص روی نوعی بیماری. بدیهی است تحلیل این نوع داده‌ها با توجه به نوع متغیر پاسخ که دودویی است، روش‌های خاص خود را می‌طلبند. یکی از روش‌های تحلیل این متغیرها، رگرسیون چندکی^۲ دودویی است که مانند رگرسیون چندکی در مقایسه با روش رگرسیون میانگین دارای دو مزیت مهم است. نخست این که رگرسیون چندکی دودویی نسبت به ناپایداری واریانس و داده‌های دورافتاده حساس نیست و دوم این که اطلاعات جزئی تری نسبت به تأثیر متغیرهای توصیفی در چندک‌های مختلف توزیع متغیر پاسخ ارائه می‌دهد. به همین دلیل مطالعاتی نیز در زمینه تحلیل داده‌های طولی با پاسخ‌های دودویی صورت گرفته است. فیزماریس و لارد (۱۹۹۳) روشی بر پایه درستنمایی برای تحلیل داده‌های طولی با پاسخ‌های دو حالته ارائه کردند. سپس گانکلوز (۲۰۰۲) این روش را برای تحلیل داده‌های طولی گستته تعمیم داد. گانکلوز و آزلاینسی (۲۰۰۸) استفاده از زنجیرهای مارکوفی را در روش درستنمایی مورد مطالعه قرار دادند. در ادامه گانکلوز و همکاران (۲۰۱۲) روش رگرسیون لوژستیک را برای تحلیل داده‌های طولی با پاسخ‌های دودویی ارائه کردند. در مطالعه

^۱ Longitudinal study

^۲ Quantile regression

داده‌های طولی علاوه بر اثرات ثابت که تغییرات درون گروه‌ها (تغییرات در طول زمان) را کنترل می‌کند، اثرات تصادفی بین متغیرهای پاسخ نیز در مدل لحاظ می‌شود که در واقع تغییرات بین گروهی را کنترل می‌کند. در بسیاری از مسائل، تعداد مشاهدات از متغیر پاسخ نسبت به مشاهدات انجام گرفته در طول زمان از متغیر مربوطه، زیاد است. بنابراین در این مدل‌ها تعداد اثرات تصادفی (تعداد پارامترها) نیز خیلی زیاد شده و لذا تعبیر و تفسیر مدل مشکل می‌شود. کوئنکر (۲۰۰۴) رگرسیون چندکی را برای تحلیل این داده‌ها با افزودن توانان لاسو روی اثرات تصادفی را مورد بررسی قرار داد که با ایجاد توانان اثرهای تصادفی را به سمت صفر منقبض^۳ کرده و اثرهای کم اهمیت را از مدل حذف و مدلی تنک^۴ ایجاد می‌کند.

اولین بار تیبیشیرانی (۱۹۹۶) رگرسیون لاسو که با ایجاد توانان لاسو روی پارامترها انجام می‌شود را ارائه کرد. سپس زو (۲۰۰۶) رگرسیون لاسوی تطبیق‌پذیر^۵ را به منظور گسترش رگرسیون لاسو پیشنهاد کرد. در این روش برخلاف توانان لاسو که برای کلیه ضرایب مدل اندازه توانان را یکسان در نظر می‌گیرد، اندازه توانان‌های مختلفی برای ضرایب رگرسیونی متفاوت لحاظ می‌شود. بررسی‌های زو (۲۰۰۶) مشخص کرد که در رگرسیون با توانان لاسوی تطبیق‌پذیر اریبی در برآوردهای پارامترها در مقایسه با روش لاسو کمتر است. الهمزوی و همکاران (۲۰۱۲) نیز با تعریف توزیع پیشینی به صورت لاپلاس متقارن روی ضرایب رگرسیونی، مدل رگرسیون چندکی با توانان لاسوی تطبیق‌پذیر را برای داده‌های مقطعی مورد مطالعه قرار دادند. در این مقاله هدف بررسی رگرسیون چندکی با توانان لاسو و لاسوی تطبیق‌پذیر روی اثرات تصادفی در داده‌های طولی با پاسخ‌های دو حالته از دیدگاه آمار بیزی است. برای این منظور توانان لاسو و لاسوی تطبیق‌پذیر روی اثرات تصادفی در داده‌های طولی دودویی از طریق تعریف توزیع‌های پیشینی مناسب در نظر گرفته می‌شود و هر دو روش از دیدگاه آمار بیزی مورد تحلیل و ارزیابی قرار می‌گیرند. در بخش ۲ مطالب کلی در مورد مدل رگرسیون چندکی برای

^۳ Shrink

^۴ Sparse

^۵ Adaptive Lasso

داده‌های طولی بیان می‌شود. در بخش‌های ۳ و ۴ مدل رگرسیون چندکی دودویی با توان لاسو و لاسوی تطبیق‌پذیر از دیدگاه آمار بیزی ارائه می‌شود. در بخش ۵ در مطالعه‌ای شبیه‌سازی، کارایی مدل‌های ارائه شده با مدل‌های دیگر مورد مقایسه قرار می‌گیرد. بخش ۶ نیز شامل تحلیل داده‌های واقعی و ارزیابی کارایی مدل‌ها است.

۲ تعریف مدل

مدل رگرسیون خطی

$$y_i = x'_i \beta + \epsilon_i, \quad i = 1, \dots, n$$

را در نظر بگیرید، که در آن x_i بردار مربوط به متغیرهای توصیفی، β یک بردار $1 \times k$ بعدی از پارامترها و ϵ_i مولفه خطای است. در مدل رگرسیونی میانگین، هدف استنباط در مورد متوسط مقدار متغیر پاسخ به ازای مقادیر متفاوت متغیرهای توصیفی است، لذا $E(y_i|x_i) = x'_i \beta$ مورد توجه است. اما در رگرسیون چندکی،تابع چندک شرطی

$$Q_\tau(y_i|x_i) = x'_i \beta_\tau \quad i = 1, \dots, n$$

مورد توجه است، که در آن (\cdot) معکوس تابع توزیع تجمعی متغیر پاسخ y_i به شرط معلوم بودن بردار x_i است. به عبارت دیگر $x'_i \beta_\tau$ چندک τ ام شرطی متغیر y_i را نشان می‌دهد. در رگرسیون معمولی میانگین توزیع خطاهای صفر در نظر گرفته می‌شود، اما در رگرسیون چندکی، چندک τ ام ϵ_i ها برابر صفر هستند، یعنی $\int_{-\infty}^{\epsilon_i} f_\tau(\epsilon_i) d\epsilon_i = \tau$ یعنی پارامتر β_τ از مینیمم کردن رابطه

$$\Sigma_{i=1}^n \rho_\tau(y_i - x'_i \beta_\tau), \quad (1)$$

نسبت به β_τ برآورده می‌شود، که در آن $\rho_\tau(u) = \frac{|u| + (2\tau - 1)u}{2}$ تابع زیان است (کوئنکر و ماکادو، ۱۹۹۹). چون رابطه (1) نسبت به β_τ در مبدأ مشتق پذیر نیست، راه حل تحلیلی برای برآورد ضرایب رگرسیونی وجود ندارد. برای رفع این مشکل

کوئنکر و ماکادو (۱۹۹۹) استفاده از توزیع لاپلاس نامتقارن را پیشنهاد کردند. متغیر تصادفی Y را دارای توزیع لاپلاس نامتقارن^۶ (ALD) با پارامترهای τ , σ و μ گویند و با نماد $Y \sim ALD(\mu, \sigma, \tau)$ نشان می‌دهند، هر گاه تابع چگالی آن به صورت

$$f(y|\mu, \sigma, \tau) = \frac{\tau(1-\tau)}{\sigma} \exp\left\{-\rho_\tau\left(\frac{y-\mu}{\sigma}\right)\right\},$$

بشد، که در آن $1 < \tau < 0$ پارامتر چولگی، σ پارامتر مقیاس و $-\infty < \mu < +\infty$ پارامتر مکانی است. با فرض این که $(\tau, Y_i \sim ALD(x'_i \beta_\tau, \sigma, \tau))$, آن گاه تابع درستنمایی به صورت

$$L(\beta_\tau|y, x) \propto \left(\frac{1}{\sigma}\right)^n \exp\left\{-\sum_{i=1}^n \rho_\tau\left(\frac{y_i - x'_i \beta_\tau}{\sigma}\right)\right\}$$

به دست می‌آید، که ماقسیمیم کردن آن در حضور پارامتر مزاحم σ با مینیمم کردن رابطه (۱) نسبت به β_τ معادل است. به همین دلیل در بسیاری از موارد، تحلیل رگرسیون چندکی با استفاده از این توزیع مورد بررسی قرار می‌گیرد. مدل رگرسیون چندکی برای داده‌های طولی با اثرات تصادفی به صورت

$$y_{ij} = x'_{ij} \beta_\tau + \alpha_i + \epsilon_{ij}; \quad i = 1, \dots, n, \quad j = 1, \dots, n_i, \quad \sum_i n_i = N$$

تعريف می‌شود، که در آن y_{ij} زامین پاسخ اندازه‌گیری شده روی i -امین واحد آزمایشی و x_{ij} بردار مربوط به متغیرهای توصیفی و β_τ بردار $1 \times k$ بعدی از پارامترها و α_i اثر تصادفی مربوط به پاسخ y_{ij} را نشان می‌دهد. تابع چندک شرطی در این مدل به صورت $Q_\tau(y_{ij}|x_{ij}) = x'_{ij} \beta_\tau + \alpha_i$ بیان می‌شود. با فرض توان لاسو روی اثرات تصادفی به صورت $\alpha = \sum_{i=1}^n |\alpha_i| \varphi(\alpha)$ برآورد پارامترهای β_τ و $\alpha_1, \dots, \alpha_n$ از دیدگاه آمار بسامدی از مینیمم کردن تابع زیان

$$\sum_{i=1}^n \sum_{j=1}^{n_i} \rho_\tau(y_{ij} - x'_{ij} \beta_\tau - \alpha_i) + \lambda \sum_{i=1}^n |\alpha_i|$$

نسبت به α و β_τ به دست می‌آید (کوئنکر، ۲۰۰۴)، که در آن λ را پارامتر توانیابن گویند و میزان انقباض به سمت صفر پارامترهای α_i را کنترل می‌کند. هر چه مقدار

^۶ Asymmetrice Laplace Distribution

آن بزرگتر باشد، انقباض به صفر نیز بیشتر و اثرهای تصادفی زیادی از مدل حذف خواهند شد. در این رهیافت برآوردهای β_τ تحت تأثیر اندازه λ است که معمولاً از روش اعتبارسنجی متقابل^۷ محاسبه می‌شود.

۳ رگرسیون چندکی دودویی با توانان لاسو

یکی از روش‌های معمول برای تعریف مدل‌های رگرسیونی با پاسخ‌های دودویی استفاده از متغیرهای پنهان^۸ است (بنویت و همکاران، ۲۰۱۳). مدل رگرسیون چندکی دودویی در داده‌های طولی به صورت

$$y_{ij}^* = x'_{ij}\beta_\tau + \alpha_i + \epsilon_{ij}, \quad y_{ij} = g(y_{ij}^*), \quad i = 1, \dots, n, \quad j = 1, \dots, n_i, \quad (2)$$

تعریف می‌شود، که در آن $g(\cdot)$ تابع پیوند^۹ و به صورت $I(y_{ij}^* > 0)$ تعریف شده (($I(\cdot)$ تابع مشخصه است) و y_{ij} ، زامین پاسخ مشاهده شده برای α_i واحد آزمایشی و ϵ_{ij} متغیر پنهان و غیر قابل مشاهده است. چون چندک τ ام ϵ_{ij} ها برابر صفر فرض می‌شوند، $y_{ij}^* = x'_{ij}\beta_\tau + \alpha_i$ چندک τ ام y_{ij} خواهد بود. از آنجایی که تابع پیوند یک تابع یکنوا است، $y_{ij} = g(y_{ij}^*)$ چندک τ ام متغیر $y_{ij} = g(y_{ij}^*)$ است. بنابراین در این مدل تابع زیان با توانان لاسو روی اثرات تصادفی به صورت

$$\sum_{i=1}^n \sum_{j=1}^{n_i} \rho_\tau(y_{ij}^* - x'_{ij}\beta_\tau - \alpha_i) + \lambda \sum_{i=1}^n |\alpha_i| \quad (3)$$

به دست می‌آید. با فرض این‌که $\alpha_i \sim ALD(0, \sigma, \tau)$ و توزیع پیشینی برای α_i به صورت $\pi(\alpha_i | \lambda, \sigma) = \frac{\lambda}{\sqrt{2\pi}} \exp\left\{-\frac{\lambda|\alpha_i|}{\sqrt{\sigma}}\right\}$ در نظر گرفته شود، به ازای $\nu = \frac{\lambda}{\sqrt{\sigma}}$ توزیع پسینی α به صورت

$$\pi(\alpha | y, x, \sigma, \lambda, \beta_\tau) = \sigma^{-N} \exp\left\{-\sigma^{-1} \sum_{i=1}^n \sum_{j=1}^{n_i} \rho_\tau(y_{ij}^* - x'_{ij}\beta_\tau - \alpha_i)\right\} \prod_{i=1}^n \frac{\nu}{\Gamma} \exp\{-\nu|\alpha_i|\} \quad (4)$$

^۷ Cross validation

^۸ Hidden variable

^۹ Link function

به دست می‌آید. مینیمم کردن تابع هدف (۳) نسبت به α و β_τ معادل ماکسیمم کردن تابع درستنمایی (۴) در حضور پارامتر مزاحم σ است. بنابراین می‌توان توزیع لاپلاس نامتقارن را برای این مدل نیز مورد استفاده قرار داد. چون استفاده از تابع درستنمایی توزیع لاپلاس نامتقارن به دلیل وجود قدرمطلق آسان نیست، در تحلیل‌های بیزی معمولاً از شکل آمیخته این توزیع استفاده می‌شود. اگر $\sim ALD(0, \sigma, \tau)$ $u \sim$ و متغیرهای تصادفی z و e به ترتیب دارای توزیع نرمال استاندارد و نمایی با میانگین $\frac{\sigma}{\tau(1-\tau)}$ و مستقل از هم باشند، آنگاه

$$u = k_1 e + \sqrt{2\sigma} z$$

که در آن $k_1 = (1 - 2\tau)$ (کازومی و کابایاشی، ۲۰۱۱). با استفاده از این خاصیت توزیع لاپلاس نامتقارن و با توجه به این که $\sim ALD(0, \sigma, \tau)$ e_{ij} مدل رابطه (۲) به صورت

$$y_{ij}^* = x'_{ij}\beta_\tau + \alpha_i + k_1 e_{ij} + \sqrt{2\sigma} e_{ij} z_{ij} \quad (5)$$

خواهد بود، که در آن z_{ij} و e_{ij} به ترتیب دارای توزیع نرمال استاندارد و نمایی با میانگین $\frac{\sigma}{\tau(1-\tau)}$ و مستقل از هم هستند. چون توزیع پیشینی α_i لاپلاس متقارن است، می‌توان آن را به صورت توزیع آمیخته از دو توزیع

$$\alpha_i | s_i \sim N(0, s_i), \quad s_i | \nu^2 \sim Exp(\frac{\nu^2}{2}) \quad (6)$$

نوشت، که در آن $Exp(\frac{\nu^2}{2})$ توزیع نمایی با میانگین $\frac{2}{\nu^2}$ همان توزیع آمیختگی است (پارک و کسلا، ۲۰۰۸). چون هدف تحلیل بیزی است، برای ابرپارامتر ν^2 (به جای ν) توزیع پیشینی مزدوج نمایی به صورت $\phi \exp\{-\phi \nu^2\} = \phi \exp\{-\phi \pi(\nu^2|\phi)\}$ و برای σ و β_τ به ترتیب وارون گاما و توزیع نرمال چند متغیره در نظر گرفته می‌شود. حال با توجه به مدل رابطه (۵)، (۶) و توزیع‌های پیشینی تعریف شده، مدل سلسله مراتبی را می‌توان به صورت

$$y_{ij} = g(y_{ij}^*), \quad y_{ij}^* | e_{ij}, \beta_\tau, \sigma, \alpha_i \sim N(x'_{ij}\beta_\tau + \alpha_i + k_1 e_{ij}, 2\sigma e_{ij}), \\ e_{ij} | \sigma \sim Exp(\frac{\tau(1-\tau)}{\sigma}), \quad \beta_\tau | b_0, B_0 \sim N_k(b_0, B_0), \quad \alpha_i | s_i \sim N(0, s_i),$$

$$s_i | \nu^2 \sim Exp\left(\frac{\nu^2}{\chi}\right), \nu^2 | \phi \sim Exp(\phi), \pi(\phi) \propto \frac{1}{\phi}, \sigma | c_0, d_0 \sim IG(c_0, d_0),$$

در نظر گرفت، که در آن $IG(a, b)$ توزیع وارون گاما با پارامترهای a و b است. با توجه به شکل سلسله مراتبی فوق، توزیع پسینی کلیه پارامترها و متغیرهای پنهان به صورت

$$\begin{aligned} \pi(y^*, \beta_\tau, \sigma, s, \nu^2, \alpha, \phi | y, x) &\propto \prod_{i=1}^n \prod_{j=1}^{n_i} \frac{1}{\sqrt{\varphi \sigma \pi e_{ij}}} \\ &\times \exp\left\{-\frac{1}{\varphi \sigma e_{ij}}(y_{ij}^* - x'_{ij} \beta_\tau - \alpha_i - k_1 e_{ij})^2\right\} \\ &\times \{I(y_{ij} = 0)I(y_{ij}^* \leq 0) + I(y_{ij} = 1)I(y_{ij}^* > 0)\} \\ &\times \left(\frac{1}{\sigma}\right)^N \exp\left\{-\sum_{i=1}^n \sum_{j=1}^{n_i} \frac{e_{ij}}{\sigma}\right\} \times \prod_{i=1}^n \frac{1}{\sqrt{2\pi s_i}} \exp\left\{-\frac{\alpha_i^2}{2s_i}\right\} \frac{\nu^2}{2} \exp\left\{-\frac{\nu^2 s_i}{2}\right\} \\ &\times \exp\left\{-\frac{1}{\sigma}(\beta_\tau - b_0)B_0^{-1}(\beta_\tau - b_0)\right\} \exp\{-\phi \nu^2\} \times \left(\frac{1}{\sigma}\right)^{c_0+1} \exp\left\{-\frac{d_0}{\sigma}\right\} \end{aligned}$$

به دست می‌آیند، که در آن $(s_1, \dots, s_n) = s$. ملاحظه می‌شود که توزیع پسینی کامل پارامترها و متغیرهای پنهان توزیع شناخته شده‌ای نیست. اما با اندکی محاسبات جبری توزیع‌های پسینی شرطی کامل متغیرهای پنهان و پارامترها به صورت

$$\pi(y_{ij}^* | y_{ij}, e_{ij}, \alpha, \beta_\tau) = \begin{cases} N(x'_{ij} \beta_\tau + \alpha_i + k_1 e_{ij}, 2\sigma e_{ij}) I(y_{ij}^* > 0), y_{ij} = 1 \\ N(x'_{ij} \beta_\tau + \alpha_i + k_1 e_{ij}, 2\sigma e_{ij}) I(y_{ij}^* \leq 0), y_{ij} = 0 \end{cases}$$

$$\pi(e_{ij} | .) \sim GIG\left(\frac{1}{\chi}, \hat{\gamma}_{ij}, \hat{\delta}_{ij}\right)$$

به دست می‌آیند، که در آن $\hat{\delta}_{ij}^2 = \frac{k_1^2}{\chi \sigma} + \frac{2\tau(1-\tau)}{\sigma}$ و $\hat{\gamma}_{ij}^2 = \frac{(y_{ij}^* - x'_{ij} \beta_\tau - \alpha_i)^2}{\chi \sigma}$ نشان‌دهنده توزیع تعمیم یافته وارون نرمال^{۱۰} با پارامترهای r و m و n است. تابع چگالی این توزیع به صورت

$$f(x | r, m, n) \propto x^{r-1} \exp\left\{-\frac{1}{\chi}(m^2 x^{-1} + n^2 x)\right\}, x > 0, -\infty < r < \infty, m, n > 0$$

است، که با استفاده از تابع `rgig()` در پکیج `ghyp` در نرم افزار `R` می‌توان از این توزیع نمونه تصادفی تولید کرد (لیزی و بریمن، ۲۰۱۴).

^{۱۰} Generalized Invers Gaussian

توزیع شرطی کامل σ نیز به صورت

$$\pi(\sigma|\cdot) \sim IG(\nu_1, w_1)$$

است، که در آن $w_1 = \sum_{i=1}^n \sum_{j=1}^{n_i} \left(\frac{(y_{ij}^* - x'_{ij}\beta_\tau - \alpha_i - k_1 e_{ij})^\top}{\epsilon_{e_{ij}}} + \tau(1 - \tau)e_{ij} \right) + d_0$ و $\pi(\alpha_i|\cdot) \sim N(\bar{\mu}_i, \tilde{\sigma}_i)$ همچنین $\nu_1 = \frac{\nu_N}{\tau} + c_0$.

$$\bar{\mu}_i = \tilde{\sigma}_i \left(\frac{1}{\tau \sigma} \sum_{j=1}^{n_i} \frac{(y_{ij}^* - x'_{ij}\beta_\tau - k_1 e_{ij})}{e_{ij}} \right), \quad \tilde{\sigma}_i = \left(\frac{1}{s_i} + \frac{1}{\tau \sigma} \sum_{j=1}^{n_i} \frac{1}{e_{ij}} \right)^{-1}$$

$$\pi(\phi|\cdot) \sim Exp(\nu^\tau), \quad \pi(s_i|\cdot) \sim GIG\left(\frac{1}{\tau}, \sqrt{\alpha_i^\tau}, \sqrt{\nu^\tau}\right),$$

به علاوه $\pi(\nu^\tau|\cdot) \sim G(n+1, \frac{\sum_{i=1}^n s_i}{\tau} + \phi)$ که در آن $G(a, b)$ نشان دهنده توزیع گاما با پارامترهای a و b است. بالاخره توزیع پسینی شرطی کامل β_τ به صورت

$$\pi(\beta_\tau|\cdot) \sim N_k(Bb, B)$$

به دست می آید، که در آن $b = \frac{1}{\tau \sigma} \sum_{i=1}^n \sum_{j=1}^{n_i} \frac{x_{ij}(y_{ij}^* - \alpha_i - k_1 e_{ij})}{e_{ij}} + B_0^{-1} b_0$ و $B^{-1} = \frac{1}{\tau \sigma} \sum_{i=1}^n \sum_{j=1}^{n_i} \frac{x_{ij}x'_{ij}}{e_{ij}} + B_0^{-1}$. حال با مشخص شدن توزیع پسینی پارامترها و متغیرهای پنهان می توان با روش نمونه گیری گیبز نمونه های کافی تولید کرده و استنباط ها را انجام داد.

۴ رگرسیون چند کی دودویی با توان لاسوی تطبیق پذیر

در این روش به منظور بسط روش قبل اندازه توان های متفاوتی روی هر یک از اثرات تصادفی مدل در نظر گرفته می شود. بنابراین تابع زیان در این مدل به صورت

$$\sum_{i=1}^n \sum_{j=1}^{n_i} \rho_\tau(y_{ij} - g(x'_{ij}\beta_\tau + \alpha_i)) + \sum_{i=1}^n \lambda_i |\alpha_i| \quad (\text{V})$$

تعریف می شود، که در آن عبارت سمت راست را توان لاسوی تطبیق پذیر گویند (زو، ۲۰۰۶). اگر در این مدل توزیع پیشینی برای α_i ها به صورت $\pi(\alpha_i|\lambda_i, \sigma) = \frac{\lambda_i}{\sqrt{\sigma}} \exp\left\{-\frac{\lambda_i |\alpha_i|}{\sqrt{\sigma}}\right\}$ آنگاه توزیع پسینی بردار α به صورت

$$\pi(\alpha|y, x, \sigma, \nu, \beta_\tau) =$$

$$(\sigma)^{-N} \exp\{-\sigma^{-1} \sum_{i=1}^n \sum_{j=1}^{n_i} \rho_\tau(y_{ij}^* - x'_{ij}\beta_\tau - \alpha_i)\} \prod_{i=1}^n \frac{\nu_i}{\sqrt{2}} \exp\{-\nu_i|\alpha_i|\}$$

به دست می آید. مینیمم کردن رابطه (۷) با ماکسیمم کردن توزیع پسینی α در حضور پارامتر مزاحم σ معادل است. لذا در این مدل نیز می توان از توزیع لاپلاس نامتقارن استفاده کرد. اگر توزیع پیشینی α_i به شکل آمیخته از دو توزیع

$$\alpha_i|s_i \sim N(0, s_i), \quad s_i|\nu_i \sim Exp\left(\frac{\nu_i}{2}\right)$$

در نظر گرفته شود، با استفاده از شکل آمیخته توزیع لاپلاس نامتقارن، مدل را می توان مانند بخش ۳ به صورت سلسله مراتبی زیر نوشت:

$$\begin{aligned} y_{ij} &= g(y_{ij}^*), \quad y_{ij}^*|\beta_\tau, \sigma, e, \alpha_i \sim N(x'_{ij}\beta_\tau + \alpha_i + k_1 e_{ij}, 2\sigma e_{ij}) \\ e_{ij}|\sigma &\sim Exp\left(\frac{\tau(1-\tau)}{\sigma}\right), \quad \beta_\tau|b_0, B_0 \sim N_k(b_0, B_0), \quad s_i|\nu_i \sim Exp\left(\frac{\nu_i}{2}\right) \\ \alpha_i|s_i &\sim N(0, s_i), \quad \nu_i|\phi \sim Exp(\phi), \quad \pi(\phi) \propto \frac{1}{\phi}, \quad \sigma|c_0, d_0 \sim IG(c_0, d_0). \end{aligned}$$

توزیع پسینی کامل پارامترها و متغیرهای پنهان در این مدل نیز به شکل بسته قابل حصول نیستند. اما توزیع پسینی شرطی کامل پارامترها و متغیرهای پنهان قابل محاسبه‌اند. توزیع‌های پسینی y^* , β_τ , α و σ مانند بخش ۳ می‌باشد. اما توزیع‌های پسینی برای سایر پارامترها در این مدل به صورت

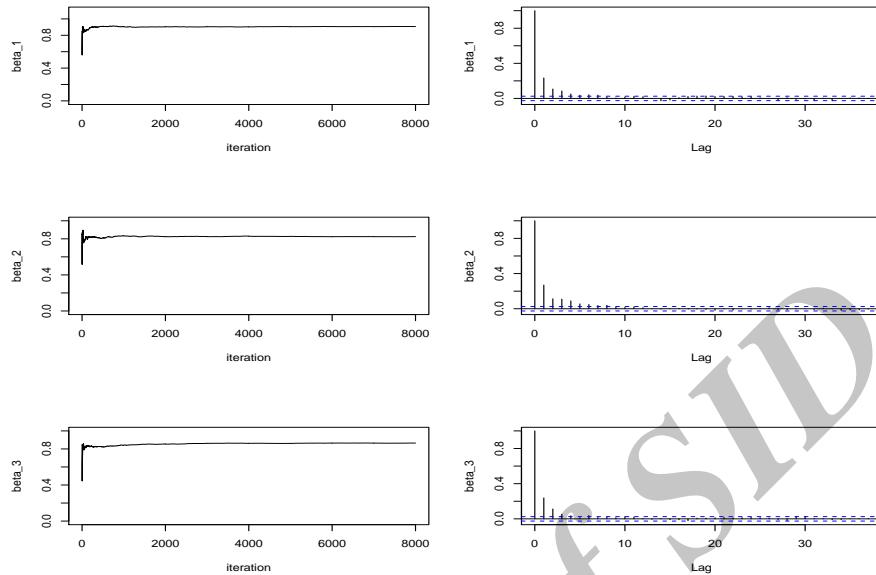
$$\begin{aligned} \pi(\nu_i|\cdot) &\sim G(2, \frac{s_i}{2} + \phi), \quad \pi(\phi|\cdot) \sim G(n, \Sigma_{i=1}^n \nu_i^2), \\ \pi(s_i|\cdot) &\sim GIG\left(\frac{1}{2}, \sqrt{\alpha_i^2}, \sqrt{\nu_i^2}\right), \end{aligned}$$

به دست می‌آیند. در این روش نیز با مشخص شدن توزیع پسینی هر یک از پارامترها و متغیرهای پنهان می‌توان با روش نمونه گیری گیبز، نمونه‌های کافی تولید کرده و استنباط‌ها را انجام داد.

۵ مطالعه شبیه‌سازی

در این بخش برای مقایسه کارایی روش‌های ارائه شده با روش‌های متداول دیگر مطالعه‌ای شبیه‌سازی انجام می‌پذیرد. مدل به صورت

$$y_{ij}^* = x_{ij}^1\beta_1 + x_{ij}^2\beta_2 + x_{ij}^3\beta_3 + x_{ij}^4\beta_4 + x_{ij}^5\beta_5 + x_{ij}^6\beta_6 + \alpha_i + \epsilon_{ij}$$



شکل ۱: نمودار اثر و تابع خودهمبستگی در روش رگرسیون چندکی با توانان لاسو
($\tau = ۰/۵$)

در نظر گرفته شده است، که در آن $\beta_i \sim N(0, 1), i = 1, \dots, 5$ و $\beta_j = 0$. توجه شود که تعداد متغیرهای پاسخ در مقایسه با متغیرهای توصیفی زیاد است. متغیرهای توصیفی یعنی x_{ij}^k ها به صورت $x_{ij}^k \sim N(0, 1)$ برای $k = 1, \dots, 6$ تولید کرده و توزیع اثرهای تصادفی به صورت $\alpha_i \sim N(0, ۴)$ فرض شده است. برای β_τ نیز بردارهای

$$\beta_\tau = (0.5, 0, 0, 0, 0, 1), \quad \beta_\tau = (0.3, 0.1/5, 0, 0, 0, 1),$$

$$\beta_\tau = (0/85, 0/85, 0/85, 0/85, 0/85, 0/85)$$

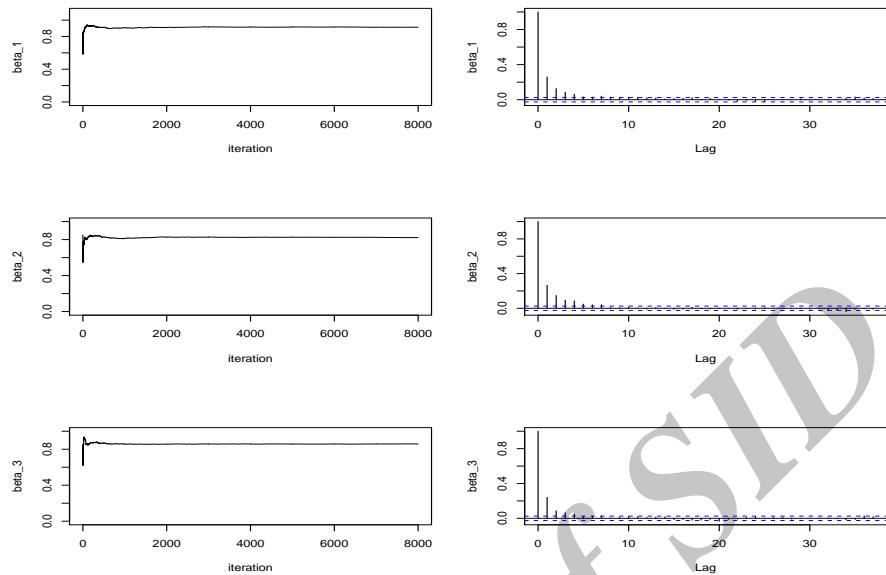
در نظر گرفته شده است، که در آن بردار اول متناظر با یک مدل کاملاً تنک است. برای مولفه خطای نیز توزیع های نرمال استاندارد، تی با سه درجه آزادی و توزیع لاپلاس متقارن در نظر گرفته شده است. به منظور کاهش حساسیت مدل به توزیع های پیشینی برای پارامتر β_τ توزیع پیشینی را $N_6(0, 100I)$ و برای ابرپارامتر σ توزیع پیشینی تخت^{۱۱} به صورت $IG(1/10, 1/10)$ فرض می شود. روش

^{۱۱} Flat

رگرسیون چندکی دودویی با تاوان لاسو (BL) و روش رگرسیون چندکی دودویی با تاوان لاسوی تطبیق‌پذیر (BAL) برای داده‌های طولی، با دو روش بیزی و بسامدی مورد مقایسه قرار می‌گیرد. روش اول (بنویت و همکاران، ۲۰۱۳) مدل رگرسیون چندکی دودویی با تاوان لاسو از دیدگاه آمار بیزی برای داده‌های مقطعی است که تاوان لاسو روی اثرات ثابت اعمال شده و اثرات تصادفی در مدل لحاظ نمی‌شود، این مدل به اختصار مدل BA نامیده می‌شود. روش دوم (گانکلوز و همکاران، ۲۰۱۲) مدل رگرسیون لوژستیک برای داده‌های طولی با پاسخ‌های دودویی (به اختصار RLG) است که پکیج محاسبه آن (bild) در نرم‌افزار R موجود است.

برای برآورد پارامترها با روش نمونه‌گیری گیز، ۸۰۰۰ نمونه از توزیع‌های پسینی شرطی کامل پارامترها تولید کرده و ۲۰۰۰ نمونه اول به عنوان دوره همگرایی مطلوب کنار گذاشته شده است. برای ارزیابی همگرایی زنجیر و تعیین تقریبی تعداد نمونه‌ها به عنوان همگرایی مطلوب از آماره \hat{R} که توسط گلمن و همکاران (۱۹۹۵) ارائه شده استفاده می‌شود. برای کلیه روش‌ها تقریباً بعد از ۲۰۰۰ نمونه اولیه، همگرایی مطلوب رخ می‌دهد که شکل ۱ نمودارهای اثر وتابع خود همبستگی نمونه‌ای زنجیر را برای روش رگرسیون چندکی با تاوان لاسو و شکل ۲ این نمودارها را برای روش رگرسیون چندکی با تاوان لاسوی تطبیق‌پذیر برای نشان می‌دهند. هر دو نمودار به خوبی همگرایی زنجیرهای مارکف تولید شده از توزیع‌های پسینی ضرایب را نشان می‌دهند. با توجه به نمودارهای اثر نیز در هر دو روش می‌توان گفت که تقریباً بعد از ۲۰۰۰ تکرار، همگرایی مطلوب رخ داده است. جدول ۱ برآورد پارامتر β_7 برای چهار روش را در مقایسه با مقدار واقعی β_7 نشان می‌دهد. همان‌طور که مشاهده می‌شود روش‌های ارائه شده عملکرد بهتری در برآورد پارامتر β_7 در مقایسه با مقدار واقعی دارند. برای مقایسه کارایی چهار روش عنوان شده و به منظور لحاظ کردن تغییرپذیری نتایج حاصل از شبیه‌سازی، ۲۰۰ مرتبه روند شبیه‌سازی را تکرار کرده و سه معیار اریبی^{۱۲} پارامترها، متوسط قدر مطلق خطأ^{۱۳} و مجدور

^{۱۲} Bias^{۱۳} Mean absolute error



شکل ۲: نمودار اثر وتابع خودهمبستگی در روش رگرسیون چندکی با توان
لاسوی تطبیق‌پذیر ($\tau = ۰/۵$)

متوجه توان دوم خط^{۱۴} به صورت

$$\begin{aligned} Bias(\hat{\beta}_k) &= \frac{1}{200} \sum_{i=1}^n (\hat{\beta}_{ik} - \beta_k), \\ MAE(\hat{\beta}_k) &= \frac{1}{200} \sum_{i=1}^n |\hat{\beta}_{ik} - \beta_k|, \\ RMSE(\hat{\beta}_k) &= \sqrt{\frac{1}{200} \sum_{i=1}^n (\hat{\beta}_{ik} - \beta_k)^2} \end{aligned}$$

محاسبه می‌شود. واضح است هر چه اندازه این معیارها کوچک باشد، حاکی از کارایی بالای مدل می‌باشد. چون نوشتمن تمام مقادیر با توجه به وجود چهار مدل، سه روش برآورد برای سه توزیع خط و هجده پارامتر در قالب جدول امکان‌پذیر نیست، بنابراین نتایج در قالب نمودارهای جعبه‌ای خلاصه شده که نتایج آن در شکل‌های شماره ۳، ۴ و ۵ ارائه شده است. هر چه نمودارهای جعبه‌ای کوچکتر و

^{۱۴} Root mean square error

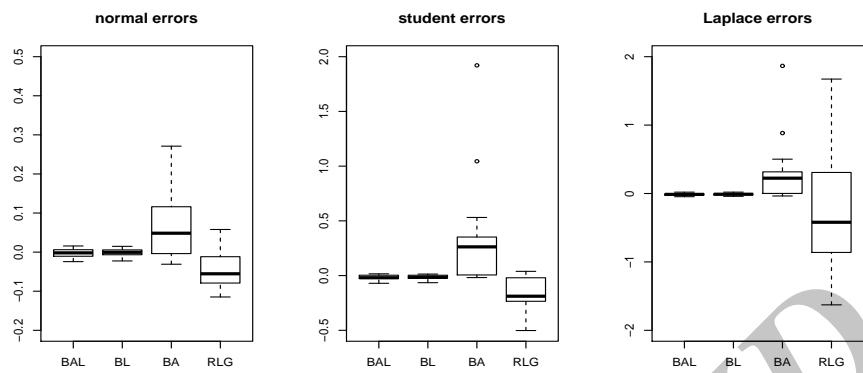
جدول ۱: میانگین پسینی پارامترها با توزیع خطاهای نرمال و $\tau = 0/5$

β_6	β_5	β_4	β_3	β_2	β_1	مدل
۱	۰	۰	۰	۰	۵	β_{True}
۰/۸۶۳	۰/۰۶۸	۰/۰۱۴	۰/۰۴۸	-۰/۰۰۲	۵/۰۲۵	BAL
۰/۸۶۱	۰/۰۸۶	-۰/۰۰۲	۰/۰۵۵	-۰/۰۰۷	۵/۰۱۲	BL
۰/۶۸۲	-۰/۳۸۶	۰/۲۳۰	۰/۱۹۸	-۰/۲۲۱	۴/۵۶۴	BA
۱/۰۳۱	۰/۰۰۱	-۰/۲۵۴	۰/۰۳۳	۰/۰۹۱۳	۴/۸۳۰	RGL
۱	۰	۰	۰	۱/۵	۳	β_{True}
۱/۰۵۷	-۰/۰۴۲	۰/۰۴۶	-۰/۲۰۲	۱/۵۲۳	۳/۰۸۵	BAL
۱/۲۲	-۰/۱۴۶	۰/۰۸۶	-۰/۰۷۴	۱/۵۷	۳/۱۷	BL
۰/۹۹۶	-۰/۱۸۳	-۰/۳۵۰	-۰/۰۵۸	۱/۲۲	۲/۱۱۵	BA
۱/۰۹۱	۰/۰۰۱	-۰/۲۵۴	۰/۰۳۳	۰/۰۹۱۳	۳/۰۷۱	RGL
۰/۸۵	۰/۸۵	۰/۸۵	۰/۸۵	۰/۸۵	۰/۸۵	β_{True}
۰/۸۲۴	۰/۰۸۰	۰/۹۴۴	۰/۸۷۳	۰/۸۸۱	۰/۸۹۰	BAL
۰/۸۱۷	۰/۰۸۰	۰/۹۴۳	۰/۸۶۷	۰/۸۷۴	۰/۸۸۹	BL
۰/۶۷۲	۰/۰۵۱	۰/۸۲۳	۰/۶۶۸	۰/۸۷۳	۰/۹۲۷	BA
۰/۴۵۰	۱/۱۲۰	۰/۹۷۶	۰/۶۳۹	۱/۰۰۱	۰/۷۶۵	RGL

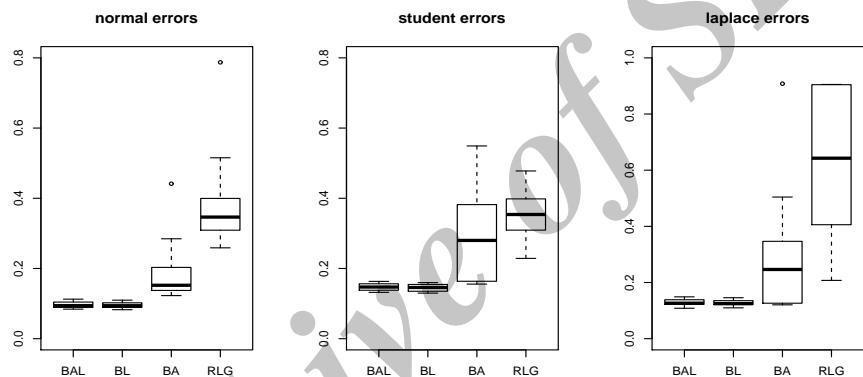
نزدیک صفر باشد، نشان دهنده اریبی کمتر و برآورده بیشتر پارامترها است. شکل ۳ عملکرد روش‌ها را از نقطه نظر اریبی مورد مقایسه می‌دهد. با توجه به این شکل دو روش BAL و BL در تمامی توزیع‌های فرض شده برای خطاهای عملکرد بیشتری نسبت به سایر روش‌ها دارد. اما این دو روش تقریباً عملکرد یکسانی در برآورده پارامترها دارند. شکل‌های ۴ و ۵ نیز عملکرد روش‌ها را به لحاظ معیارهای RMSE و MAE مورد بررسی قرار می‌دهد. با توجه به این دو شکل نیز مشاهده می‌شود که همانند نمودارهای اریبی، در این نمودارها نیز روش‌های ارائه شده برآورده بیشتری از پارامترها در تمامی توزیع‌های فرض شده برای خطاهای دارند.

۶ تحلیل داده‌های واقعی

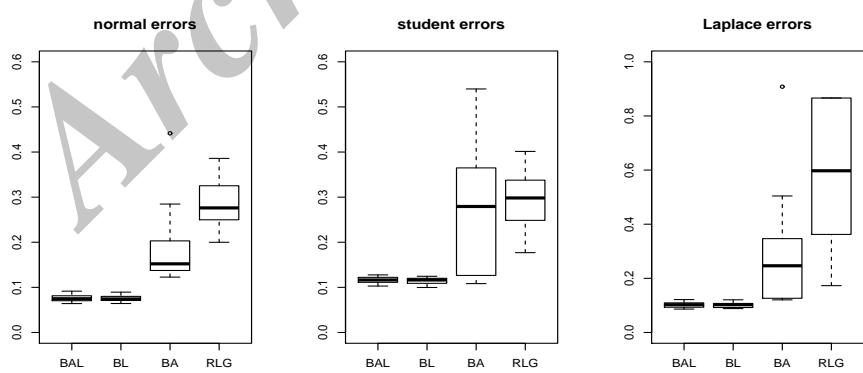
داده‌های واقعی شامل رشد ۵۰ کودک در شهرستان زنجان، از بدو تولد تا دوسالگی است که از درمانگاه‌های شهرستان به تصادف انتخاب شده‌اند. هدف بررسی تأثیر



شکل ۳: عملکرد روش‌ها به لحاظ معیار اربیتی در چند کوچک



شکل ۴: عملکرد روش‌ها به لحاظ معیار RMSE در چند کوچک



شکل ۵: عملکرد روش‌ها به لحاظ معیار MAE در چند کوچک

برخی عوامل بر رشد کودک در طول زمان می‌باشد. این عوامل عبارت‌اند از قد، وزن و دور سر کودک که در فواصل زمانی بدو تولد، ۲، ۴، ۶، ۹، ۱۲، ۱۸ و ۲۴ ماهگی کودکان اندازه‌گیری شده است. متغیر پاسخ نیز به صورت صفر و یک در همین فواصل زمانی است که عدد یک نشان دهنده رشد مناسب و عدد صفر نشان دهنده رشد نامناسب کودک است. برای برآورد پارامترها با استفاده از روش نمونه‌گیری گیبز، 80% نمونه از توزیع‌های پسینی شرطی کامل پارامترها تولید کرده و 20% نمونه اول را به عنوان دوره همگرایی مطلوب کنار می‌گذاریم. در جدول ۲ برآورد ضرایب رگرسیونی برای سه چندک ($\tau = 0/25, 0/5, 0/75$) برای سه روش بیزی محاسبه شده است. همچنین با مدل برازش شده، متغیرهای پاسخ z_{ij} برای کلیه داده‌ها که تعداد آن‌ها برابر 400 مشاهده است، برآورده شده و تعداد پاسخ‌های برآورده شده که با پاسخ‌های واقعی مطابقت دارد در سطرهای آخر جدول ۲ (سطر مربوط به y_{True}) ارائه شده است. در جدول ۳ نیز برآورده پارامترها و تعداد پاسخ‌های برآورده شده که با پاسخ‌های واقعی مطابقت دارد با روش RLG آمده است. با توجه به این دو جدول ملاحظه می‌شود که هر دو روش ارائه شده در چندک‌های پایین بخصوص برای چندک $5/0$ از دو مدل دیگر عملکرد بهتری داشته‌اند. ولی برای چندک بالا ($\tau = 0/75$) مدل غیر بیزی RLG عملکرد بهتری نسبت به مدل‌های بیزی دارد.

بحث و نتیجه‌گیری

در مطالعات طولی علاوه بر اثرات ثابت که تأثیر هر یک از متغیرهای توصیفی را بر متغیر پاسخ بیان می‌کند، اثرات تصادفی نیز در مدل لحاظ می‌شود. این اثرات تعییرات بین متغیرهای پاسخ (تعییرات بین گروهی) را کنترل می‌کند. در مطالعاتی که تعداد مشاهدات از متغیر پاسخ زیاد است، لذا اثرات تصادفی نیز زیاد شده و پارامترهای زیادی وارد مدل شده و بنابراین دقت مدل کم و تفسیر آن مشکل می‌شود. در این مقاله با ایجاد تاوان لاسو و لاسوی تطبیق‌پذیر روی اثرات تصادفی آن‌ها را به سمت صفر منقبض کرده و اثرات کم اهمیت از مدل حذف شدند. هر دو

جدول ۲: برآورد ضرایب رگرسیونی در چندک‌های متفاوت

مدل	$\circ/75$	$\circ/5$	$\circ/25$	
BAL				
	$0/0214$	$0/0096$	$0/0167$	β_1
	$0/1534$	$0/0820$	$0/1289$	β_2
	$0/0057$	$0/0164$	$0/00231$	β_3
	۲۵۰	۳۵۰	۳۰۰	\hat{y}_{True}
BL				
	$0/00035$	$0/0090$	$0/0158$	β_1
	$0/0505$	$0/0826$	$0/1222$	β_2
	$0/0277$	$0/0167$	$0/00361$	β_3
	۲۵۰	۳۵۰	۳۰۰	\hat{y}_{True}
BA				
	$0/0149$	$0/0128$	$0/1502$	β_1
	$0/9062$	$0/0241$	$0/2100$	β_2
	$0/0226$	$0/03107$	$0/25411$	β_3
	۲۷۵	۲۸۵	۲۴۹	\hat{y}_{True}

جدول ۳: برآورد ضرایب رگرسیونی با استفاده از مدل رگرسیون لوژستیک

مدل	\hat{y}_{True}	β_3	β_2	β_1
RGL	۲۸۵	$0/0495$	$0/0499$	$0/0236$

نوع توان با تعریف توزیع‌های پیشینی لایپلاس متفاوتان که تابع چگالی آن در نقطه صفر نوک‌دار است، در مدل لحاظ شده و هر دو مدل از دیدگاه آمار بیزی مورد بررسی قرار گرفتند. نتایج حاصل از شبیه‌سازی و تحلیل داده‌های واقعی نشان داد که روش‌های ارائه شده در چندک $\circ/5$ نسبت به روش بیزی (بنویت و همکاران، ۲۰۱۳) که اثرات تصادفی و توان روی آنها را در مدل لحاظ نمی‌کند و همچنین روش بسامدی که اثرات تصادفی را در مدل لحاظ می‌کند، ولی هیچ گونه توانی روی آنها قرار نمی‌دهد، در برآورد ضرایب رگرسیونی عملکرد بهتری دارد. نتایج حاصل از تحلیل داده‌های واقعی نشان داد که روش‌های ارائه شده در چندک‌های $\circ/25$ و $\circ/5$ دقت بالایی نسبت به دو روش دیگر دارند، اما در چندک بالا ($\tau = 0/75$) رهیافت بسامدی تا حدودی از روش‌های بیزی عملکرد بهتری

دارد. اما از آنجایی که مدل‌های ارائه شده بر اساس روش رگرسیون چندکی است، لذا در مقایسه با مدل بسامدی که بر اساس روش رگرسیون میانگین است، نسبت به داده‌های پرت و توزیع خطاهای استوار است. بنابراین استفاده از مدل‌های ارائه شده در تحلیل داده‌های واقعی توصیه می‌شود.

تقدیر و تشکر

نویسندهای از داوران و سردبیر محترم مجله به خاطر ارایه پیشنهادات ارزنده که سبب بهبود مقاله گردید، کمال تشکر و قدردانی را دارند.

مراجع

غلامی فشارکی، م.، کاظم نژاد، ا. و زاییری، ف. (۱۳۹۲)، تحلیل دو سطحی با اثرات تصادفی چوله نرمال و مدل‌بندی داده‌های طولی، مجله علوم آماری، ۷، ۲۴۸-۲۳۳.

Alhamzawi, R., Yu, K. and Benoit, D. F. (2012), Bayesian Adaptive Lasso Quantile Regression, *Statistical Modeling*, **12**, 279-297.

Benoit, D. F., Alhamzawi, R. and Keming, Y. U. (2013), Bayesian Lasso Binary Quantile Regression, *Computational Statistics*, **28**, 2861-2873.

Fitzmaurice, G. M. and Laird, N. M. (1993), A Likelihood-Based Method for Analyzing Longitudinal Binary Responses, *Biometrika*, **80**, 141-151.

Gelman, A., Carlin, J. B., Stern, H. S. and Rubin, D. B. (1995), *Bayesian Data Analysis*, Chapman and Hall, London.

Goncalves, M. H. (2002), *Likelihood Methods for Discrete Longitudinal Data*, Ph.D. Thesis, University of Lisbon.

علی آقامحمدی، سکینه محمدی ۱۶۷

- Goncalves, M. H. and Azzalini, A. (2008), Using Markov Chains for Marginal Modeling of Binary Longitudinal Data in Exact Likelihood Approach, *Metron*, **LXVI**, 157-181.
- Goncalves, M. H., Cabral, M. S. and Azzalini, A. (2012), The R Package *Bild* for the Analysis of Binary Longitudinal Data, *Journal of Statistical Software*, **46**, 1-17.
- Koenker, R. (2004), Quantile Regression for Longitudinal Data, *Journal of Multivariate Analysis*, **91**, 74-89.
- Koenker, R. and Machado, J. (1999), Goodness of Fit and Related Inference Processes for Quantile Regression, *Journal of the American Statistical Association*, **94**, 1296-1310.
- Kozumi, H. and Kabayashi, G. (2011), Gibbs Sampling Methods for Bayesian Quantile Regression, *Journal of Statistical Computation and Simulation*, **81**, 1565-1578.
- Luethi, D. and Breyman, W. (2014), A Package on the Generalized Hyperbole Distribution and Its Special Classes, R Package Version 1.5.6, URL <http://www.r-project.org>
- Park, T. and Casella, T. (2008), The Bayesian Lasso, *Journal of the American Statistical Association*, **103**, 681-686.
- Tibshirani, R. (1996), Regression Shrinkage and Selection Via the Lasso, *Journal of the Royal Statistical Society, B*, **58**, 267-288.
- Zou, H. (2006), The Adaptive Lasso and Its Oracle Properties, *Journal of the American Statistical Association*, **101**, 1418-1429.