

برآورد بیزی تابع توان در آزمون همگنی مدل‌های آمیخته

رحمان فرنوش^۱، افشین فلاح^۲، آرزو حاج رجبی^۱

^۱گروه آمار، دانشگاه علم و صنعت

^۲گروه آمار، دانشگاه بین‌المللی امام خمینی

تاریخ دریافت: ۱۷/۰۷/۱۳۸۷ تاریخ آخرین بازنگری: ۲۰/۱۲/۱۳۸۷

چکیده: برای آزمون فرضیه همگنی مدل‌های آمیخته، معمولاً از آزمون نسبت درستنمایی اصلاح شده که مبتنی بر افزودن یک تابع توان مناسب به تابع لگ درستنمایی می‌باشد، استفاده می‌شود. کارایی این آزمون به شدت تحت تأثیر شکل تابع توان انتخابی است. انتخاب تابع توان در این نوع آزمون معمولاً بر اساس پرهیز از پیچیدگی و میسر بودن برآورد پارامترها صورت می‌پذیرد، که لزوماً نتایج مطلوبی بدنبل ندارد. در این مقاله یک تابع توان جامع در نظر گرفته شده است، که دارای یک پارامتر تعیین کننده شکل است. سپس پارامتر تعیین کننده شکل این تابع توان و پارامترهای مدل آمیخته با در نظر گرفتن توزیع‌های پیشین مناسب برای آن‌ها با استفاده از رهیافت بیزی، بصورت پسینی برآورد شده‌اند. نشان داده شده است که رهیافت بیزی پیشنهادی در برآورد پارامترهای مدل، در مقایسه با رهیافت بسامدی، به مراتب کارایی مطلوب‌تری دارد. این کارایی خصوصاً در شرایط شناخت ناپذیری توسعه آمیخته که روش‌های بسامدی کارایی اندکی دارند، بیشتر است.

واژه‌های کلیدی: آزمون نسبت درستنمایی، تابع توان، الگوریتم EM ، زنجیرهای مارکوف مونت کارلوئی.

آدرس الکترونیک مسئول مقاله: رحمان فرنوش، rfarunoosh@iust.ac.ir
کد. موضوع بنای ریاضی (۶۲F۱۵): (۲۰۰۰)

۱ مقدمه

توزیع‌های آمیخته به دلیل انعطاف پذیر بودن در توصیف بسیاری از پدیده‌های تصادفی مفید هستند. پس از مقاله کارل پیرسون در دهه هشتاد این توزیع‌ها بطور گسترده‌ای در تحقیقات کاربردی و در زمینه‌های متفاوتی مانند ژنتیک، زیست‌شناسی، اقتصاد و غیره بکار گرفته می‌شوند. کاربرد توزیع‌های آمیخته معمولاً در مواردی است که جامعه‌ی آماری ناهمگن و ترکیبی از چند زیر جامعه است. در چنین حالتی مشاهداتی که از این جامعه بدست می‌آیند، می‌توانند با احتمال معینی به هر یک از این زیر جامعه‌ها تعلق داشته باشند. روش‌های مختلفی برای آزمون تعداد مؤلفه‌های یک توزیع آمیخته وجود دارد، که از آن جمله می‌توان به روش‌هایی بر پایه نظریه اطلاع، فاصله تواناییده، روش لگ درستنمایی تواناییده و روش بیزی اشاره نمود. آکائیک (۱۹۷۳) به کمک نظریه اطلاع، معیار اطلاع آکائیک را برای انتخاب تعداد مؤلفه‌های مدل آمیخته، از طریق مینیمم ساختن فاصله کولبک-لایبلر بین توزیع جامعه و توزیع مدل‌های پیشنهادی مورد مطالعه قرار داد. چن و کال فلیسک (۱۹۹۶) روشی را بر پایه مینیمم ساختن فاصله تواناییده بین تابع توزیع تجربی و تابع توزیع تجمعی برازش داده، ارائه دادند. چن و خلیلی (۲۰۰۶) روشی را بر پایه لگ درستنمایی تواناییده، برای انتخاب تعداد مؤلفه‌های مدل آمیخته معرفی کردند. ریچاردسون و گرین (۱۹۹۷) انتخاب تعداد مؤلفه‌های مدل آمیخته را از دیدگاه بیزی مورد مطالعه قرار دادند. مارین و همکاران (۲۰۰۵) دشواری‌های تحلیل بیزی مدل‌های آمیخته را بررسی نموده و نشان دادند که وقتی توزیع جامعه آمیخته است، کاربست روشهای معمول زنجیر مارکف مونت کارلویی برای نمونه‌گیری از توزیع پسین پارامترها با دشواری‌های زیادی روبرو است. آزمون فرضیه همگن بودن جامعه توسط محققان بسیاری مورد توجه قرار گرفته است. در حالت خاص، برای انتخاب یک مدل همگن در مقابل یک مدل آمیخته با دو مؤلفه، هارتیگان (۱۹۸۵) استفاده از آزمون نسبت درستنمایی را پیشنهاد نمود. ولی استفاده از این روش به دلیل پیچیدگی توزیع حدی آماره آزمون نسبت درستنمایی، عملأ امکان پذیر نیست. چن (۱۹۹۸) منابع بی‌نظمی مؤثر بر توزیع حدی آماره نسبت درستنمایی را مورد مطالعه قرار داد و بر این اساس آزمون نسبت درستنمایی اصلاح شده را معرفی نمود، که در آن با افزودن یک تابع توان به تابع لگ درستنمایی، توزیع حدی ساده‌ای برای آماره‌ی آزمون نسبت درستنمایی بدست می‌آید. یکی از محدودیت‌های این روش آن است که استفاده از آزمون نسبت درستنمایی اصلاح شده، منوط به برقراری برخی شرایط نظم است. بعلاوه توان این آزمون به شدت تحت تاثیر تابع توان انتخابی است. از اینرو لی و همکاران (۲۰۰۸) آزمون *EM* را بر اساس شکل دیگری از

رحمان فرنوش، افشین فلاح، آرزو حاجرجی ۲۳۱

تابع تاوان پیشنهادی توسط چن و همکاران (۲۰۰۱)، که مستقل از فرضیات لازم برای آزمون نسبت درستنمایی اصلاح شده است، مطرح نمودند.

در این مقاله آزمون فرض همگنی جامعه با در نظر گرفتن فرم جامعی برای تابع تاوان که به یک پارامتر شکل وابسته است، از دیدگاه بیزی مورد مطالعه قرار گرفته است. برای این منظور با در نظر گرفتن پیشینهای مناسب، پارامتر تعیین کننده شکل تابع تاوان و پارامترهای مدل آمیخته بصورت پسینی برآورد شده‌اند. در بخش ۲ آزمون نسبت درستنمایی و شکل اصلاح شده آن معرفی و مشکلات این نوع آزمونها مورد بررسی قرار گرفته است. در بخش ۳ چگونگی برآورد پارامترهای مدل با استفاده از الگوریتم EM شرح داده شده است. مسئله انتخاب تابع تاوان در بخش ۴ مورد بحث قرار گرفته و روشی برای برآورد پارامتر تعیین کننده شکل تابع تاوان به کمک رهیافت بیزی، پیشنهاد شده است. در بخش ۵ کارایی آزمون نسبت درستنمایی و روش بیزی پیشنهادی با استفاده از یک مطالعه شبیه‌سازی مورد ارزیابی قرار گرفته است.

۲ آزمون نسبت درستنمایی

متغیر تصادفی Y دارای توزیع آمیخته است، هرگاه تابع چگالی یا جرم احتمال آن بصورت

$$p_Y(y; \theta, p) = \sum_{j=1}^k p_j f_j(y|\theta_j), \quad y \in \mathcal{Y}, \quad 0 \leq p_j \leq 1, \quad j = 1, \dots, k, \quad \sum_{j=1}^k p_j = 1,$$

باشد، که در آن \mathcal{Y} تکیه‌گاه متغیر تصادفی Y را نشان می‌دهد و $\theta = (\theta_1, \dots, \theta_k)$ که j -امین پارامتر مؤلفه‌ی زام و $p = (p_1, \dots, p_k)$ که p_j نسبت آمیخته مؤلفه‌ی زام نامیده می‌شود. هنگامی که از یک توزیع آمیخته نمونه‌ای مشاهده می‌شود، از آنجا که مشخص نیست هر مشاهده مربوط به کدام زیر جامعه می‌باشد، مشاهدات بدست آمده را داده‌های ناقص گویند. در اینصورت تابع لگاریتم درستنمایی داده‌های ناقص بصورت

$$\ell_n(\theta, p) = \sum_{i=1}^n \log \left(\sum_{j=1}^k p_j f_j(y_i|\theta_j) \right),$$

است. داده‌های ناقص را می‌توان با در نظر گرفتن مجموعه‌ای از متغیرهای نشانگر که تعلق مشاهدات به زیر مجموعه‌ها را مشخص می‌سازند، به داده‌های کامل تبدیل نمود. تابع لگاریتم

۲۳۳ براورد بیزی تابع توان در آزمون همگنی مدل‌های آمیخته

درستنایی داده‌های کامل که معمولاً برای انجام استنباط مناسبتر می‌باشد، بصورت

$$\ell_n^c(z, \theta, p) = \sum_{i=1}^n \sum_{j=1}^k z_{ij} \{\log p_j + \log f_j(y_i | \theta_j)\},$$

است. درستنایی داده‌های کامل، تابعی از متغیرهای پنهان (z_1, \dots, z_n) و مشاهدات می‌باشد، که در آن (z_1, \dots, z_{ik}) و $z_{ij} = 1$ نشان دهنده تعلق مشاهده i به مؤلفه‌ی زام است. فرض کنید Y_1, \dots, Y_n نمونه‌ای تصادفی از توزیع آمیخته

$$pf_Y(y|\theta_1) + (1-p)f_Y(y|\theta_2), \quad (1)$$

باشد، که در آن $\Theta = \theta_1, \theta_2 \in \Theta$ زیرمجموعه‌ای فشرده از خط حقیقی است. هدف آزمون

$$\begin{cases} \mathcal{H}_0 : p(1-p)(\theta_1 - \theta_2) = 0 \\ \mathcal{H}_1 : p(1-p)(\theta_1 - \theta_2) \neq 0, \end{cases} \quad (2)$$

است، که در آن فرض صفر به معنی همگنی جامعه و فرض مقابل به معنی تشکیل جامعه از دو زیر جامعه ناهمگن مطابق رابطه (1) است. تابع لگاریتم درستنایی را می‌توان بصورت

$$\ell_n(p, \theta_1, \theta_2) = \sum_{i=1}^n \log\{pf(y_i|\theta_1) + (1-p)f(y_i|\theta_2)\},$$

نوشت. اگر $\hat{\theta}_0$ و $(\hat{p}, \hat{\theta}_1, \hat{\theta}_2)$ به ترتیب ماکسیمم کننده تابع درستنایی تحت فرض صفر و مقابل باشند، در اینصورت آماره آزمون نسبت درستنایی بصورت

$$R_n = 2\{\ell_n(\hat{p}, \hat{\theta}_1, \hat{\theta}_2) - \ell_n(0/5, \hat{\theta}_0, \hat{\theta}_0)\},$$

می‌باشد و مقادیر بزرگ این آماره منجر به رد فرض صفر می‌شوند. چن (۱۹۹۸) نشان داد دو منبع بی‌نظمی که توزیع حدی آماره آزمون نسبت درستنایی را به طور قابل ملاحظه‌ای پیچیده می‌سازند، یکی قرار داشتن نقاط $0 = p = 1$ در محدوده فرض صفر و دیگری شناخت ناپذیر بودن توزیع آمیخته (1) تحت فرض صفر است. وی پیشنهاد نمود برای برطرف کردن این مشکل، تابع توانی بر حسب p به صورت $T(p)$ که در شرایط

$$\lim_{p \rightarrow 0 \text{ or } 1} T(p) = -\infty, \quad \arg \max_{p \in [0, 1]} T(p) = 0/5, \quad (3)$$

صدق کند، به آماره آزمون نسبت درستنایی افروده شود. در اینصورت تابع لگاریتم درستنایی توانیده بصورت $T\ell_n(p, \theta_1, \theta_2) = \ell_n(p, \theta_1, \theta_2) + T(p)$ است و آماره آزمون نسبت درستنایی بصورت $M_n = 2\{T\ell_n(\hat{p}, \hat{\theta}_1, \hat{\theta}_2) - T\ell_n(0/5, \hat{\theta}_0, \hat{\theta}_0)\}$ اصلاح می‌شود.

رحمان فرنوش، افشنین فلاح، آرزو حاجرجی ۲۳۳

استفاده از این تابع تاوان موجب می‌شود مقادیر برازش داده شده p تحت درستنماهی اصلاح شده دور از صفر و یک واقع شوند. چن (۱۹۹۸) نشان داد که اگر برخی شرایط نظم روی هسته چگالی برقرار باشند، آنگاه توزیع مجانبی آماره آزمون نسبت درستنماهی اصلاح شده، آمیخته‌ای از دو توزیع با وزن‌های یکسان بصورت $\frac{1}{2}\chi^2 + \frac{1}{2}\chi^2$ می‌باشد، که در آن χ^2 توزیع تباهیده در نقطه صفر و χ^2 توزیع کای دو با درجه آزادی ۱ را نشان می‌دهند. نکته‌ی قابل توجه آن است که این توزیع حدی به فرم تابع تاوان انتخابی وابسته نیست.

۳ برآورد پارامترها با الگوریتم EM

برای یافتن برآورد ماکسیمم درستنماهی پارامترها در توزیع‌های آمیخته، معمولاً از الگوریتم تکراری EM استفاده می‌شود. که شامل دو مرحله امیدگیری E و ماکسیمم سازی M است. فرض کنید Y_1, \dots, Y_n نمونه‌ای تصادفی از توزیع آمیخته (۱) باشد، در این صورت تابع لگاریتم درستنماهی داده‌های کامل بصورت

$$\ell_n^c((\theta_1, \theta_2), p) = \sum_{i=1}^n [z_{i1} \{\log(p) + \log(f(y_i|\theta_1))\} + (1 - z_{i1}) \{\log(1-p) + \log(f(y_i|\theta_2))\}], \quad (4)$$

است. در مرحله E ، امید ریاضی

$$\begin{aligned} z_{i1}^{(t)} &= E(z_{i1}|y_i, \theta^{(t-1)}, p^{(t-1)}) \\ &= \frac{p^{(t-1)}f(y_i|\theta_1^{(t-1)})}{p^{(t-1)}f(y_i|\theta_1^{(t-1)}) + (1 - p^{(t-1)})f(y_i|\theta_2^{(t-1)})}, \quad i = 1, \dots, n, \end{aligned} \quad (5)$$

محاسبه و جایگزین z_{ij} ، $i = 1, \dots, n$ می‌شود. در مرحله M با قرار دادن مقادیر (۵) در تابع لگ درستنماهی داده‌های کامل و ماکسیمم کردن این تابع نسبت به پارامترهای مدل، داریم

$$p^{(t)} = \frac{1}{n} \sum_{i=1}^n z_{i1}^{(t)}$$

$$\begin{aligned} \theta_1^{(t)} &= \arg \max_{\theta_1 \in \Theta} \sum_{i=1}^n \{z_{i1}^{(t)} \log(f(y_i|\theta_1))\}, \\ \theta_2^{(t)} &= \arg \max_{\theta_2 \in \Theta} \sum_{i=1}^n \{(1 - z_{i1}^{(t)}) \log(f(y_i|\theta_2))\}. \end{aligned}$$

در این صورت، تکرار مراحل E و M تا حصول همگرایی، برآوردهای ماکسیمم درستنماهی پارامترها را بدست می‌دهد. برآورد p به انتخاب تابع تاوان بستگی دارد، چن و همکاران

۲۳۴ بروارد بیزی تابع توان در آزمون همگنی مدل‌های آمیخته

(۲۰۰۱) تابع توانی به صورت

$$T(p) = C \log(4p(1-p)), \quad (6)$$

را پیشنهاد نمودند، که در آن C ثابتی مثبت و تأثیرگذار بر میزان اصلاح تابع درستنمایی است. لی و همکاران (۲۰۰۸) نیز تابع توانی به فرم

$$T(p) = C^* \log(1 - |1 - 2p|), \quad (7)$$

را مورد استفاده قرار دادند. توابع توان (۶) و (۷) در شرایط (۳) صدق می‌کنند و به سادگی

می‌توان نشان داد که مقدار p در مرحله‌ی M از تکرار EM الگوریتم، برای این توابع به

$$\text{ترتیب بصورت } p^{(t+1)} = \frac{\sum_{i=1}^n z_i^{(t)} + C}{nC + n}$$

$$p^{(t)} = \begin{cases} \min\left\{\frac{\sum_{i=1}^n z_i^{(t)} + C^*}{n + C^*}, 0/5\right\} & \frac{\sum_{i=1}^n z_i^{(t)}}{n} < 0/5, \\ 0/5 & \frac{\sum_{i=1}^n z_i^{(t)}}{n} = 0/5, \\ \max\left\{\frac{\sum_{i=1}^n z_i^{(t)}}{n + C^*}, 0/5\right\} & \frac{\sum_{i=1}^n z_i^{(t)}}{n} > 0/5, \end{cases}$$

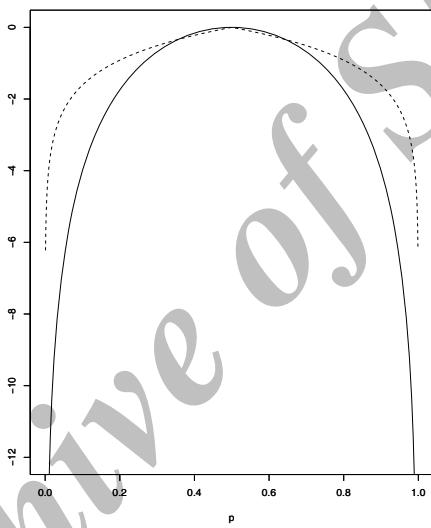
بدست می‌آیند.

۴ انتخاب تابع توان

گرچه توزیع حدی آماره آزمون نسبت درستنمایی به فرم تابع توان انتخابی وابسته نیست، اما فرم تابع توان انتخاب شده بر توان آزمون تأثیرگزار است. آزمون اصلاح شده‌ای که از افزودن تابع توان (۶) به تابع لگاریتم درستنمایی حاصل می‌شود، مشکلات آزمون نسبت درستنمایی معمول را تحدیودی مرتفع می‌سازد. با این وجود گاهی حتی با وجود مشاهدات مشهود از توزیع آمیخته، آزمون نسبت درستنمایی اصلاح شده قادر به رد فرض H_0 نیست. دلیل این امر آن است که تابع توان (۶) به ازای نسبت‌های آمیخته نزدیک صفر یا یک، توان زیادی را روی تابع لگاریتم درستنمایی اعمال می‌کند. به همین دلیل به تابع توان معقول‌تری نیاز است، به نحوی که برای آن توان آزمون نسبت درستنمایی اصلاح شده، حتی در حالتی که نسبت‌های آمیخته به صفر و یک نزدیک هستند، افزایش یابد. تابع توان (۷) به این منظور پیشنهاد شده است. به سادگی ملاحظه می‌شود که بین دو تابع توان (۶) و (۷) نابرابری

$$\log(1 - |1 - 2p|) \leq \log(1 - |1 - 2p|^2) = \log(4p(1-p)),$$

برقرار است، که به ازای مقادیر نزدیک به $5/0$ نسبت آمیخته، این نابرابری به برابری تقریبی $|1 - 2p| \approx |1 - \log(1 - 1 - 2p)|$ تبدیل می‌شود. بنابراین توابع توان (۶) و (۷) به ازای مقادیر p نزدیک به $5/0$ تقریباً معادل‌اند، اما به ازای مقادیر p نزدیک به صفر یا یک، تفاوت قابل ملاحظه‌ای بین آنها وجود دارد. شکل ۱ نمودار این دو تابع توان را به ازای $C^* = 1$ نشان می‌دهد. ملاحظه می‌شود که تابع توان (۶) در نقطه $p = 0/5$ تقریباً مسطح می‌باشد و توانی را اعمال نمی‌کند، در حالی که تابع توان (۷) علاوه بر مرتفع‌تر بودن، به ازای مقادیر نزدیک به صفر و یک نیز توان بسیار کمتری را الحاظ می‌نماید.



شکل ۱: نمودار توابع توان (۶) (خط) و (۷) (نقطه چین).

با وجود اینکه تابع توان پیشنهادی لی و همکاران (۲۰۰۸)، دارای مزیت‌هایی می‌باشد و کارایی آزمون نسبت درستنمایی را افزایش می‌دهد، اما دلیلی مبنی بر بهینه بودن هیچ یک از این توابع توان وجود ندارد. بسادگی ملاحظه می‌شود که توابع توان (۶) و (۷) حالات خاصی از تابع توان کلی

$$g(p, h) = C \log(1 - |1 - 2p|^h), \quad 0 < h \leq 2 \quad (8)$$

هستند، که به ازای مقادیر $h = 1$ و $h = 2$ حاصل می‌شوند. انتخاب مقدار h به شکل تابع

۲۳۶ براورد بیزی تابع توان در آزمون همگنی مدل‌های آمیخته

توان و در نتیجه به استنباط‌های حاصل از آن به شدت تأثیر گذار است. در رهیافت بسامدی انتخاب مقادیر دیگری برای h به پیچیدگی تابع توان (λ) نتیجه می‌شود، که آن نیز به نوبه خود منجر به دشواری ماسکیسم سازی در مرحله M از الگوریتم EM می‌شود. با توجه به مشکلات رهیافت بسامدی در تعیین پارامترهای مدل و تابع توان، در این بخش این پارامترها در چارچوب رهیافت بیزی براورد می‌شوند. برای این منظور ابتدا برای پارامترهای مورد نظر، توزیع‌های پیشین مناسب در نظر گرفته و سپس براورد این پارامترها بصورت پسینی محاسبه می‌شوند. در حالت کلی، دامنه تغییرات پارامتر h در تابع توان (λ) مجموعه اعداد حقیقی مثبت است. با این وجود میزان توانی که این تابع اعمال می‌کند با بزرگ شدن h به صفر میل می‌نماید، به نحوی که برای مقادیر $1 > h$ میزان توان اعمال شده توسط این تابع اندک بوده و برای مقادیر $2 > h$ عملگر هیچ توانی اعمال نمی‌شود. از این رو برخی محققان مانند لی و همکاران (۲۰۰۸) مقداری در بازه‌ی $[1, 5]$ را برای این پارامتر پیشنهاد کرده‌اند. در این مقاله از توزیع $(0, 5)$ به عنوان توزیع پیشین برای پارامتر h استفاده شده است. به منظور حفظ بی طرفی، توزیع پیشین برای نسبت آمیخته $\varphi = U(0, 5)$ در نظر گرفته شده است. چون توابع هسته مختلف تشکیل دهنده یک توزیع آمیخته، دارای پارامترهای متفاوتی هستند، برای انجام تحلیل بیزی لازم است برای هر یک از این پارامترها نیز توزیع پیشین مناسبی لحاظ شوند. اگر Y_1, \dots, Y_n نمونه‌ای تصادفی از توزیع آمیخته، دارای پارامترهای نرمال باشد، در این صورت تابع درستنمایی توانیده که از ضرب تابع درستنمایی در تابع توان حاصل می‌شود، بصورت

$$L(y|\mu_1, \mu_2, p, h) \propto p^{n_1} (1-p)^{n_2} e^{-\frac{n_1}{\lambda}(\bar{y}_1 - \mu_1)} e^{-\frac{n_2}{\lambda}(\bar{y}_2 - \mu_2)} (1 - |1 - 2p|^h)$$

است، که در آن n_1 تعداد مشاهدات متناسب به مؤلفه اول، n_2 تعداد مشاهدات متناسب به مؤلفه دوم، \bar{y}_1 میانگین مشاهدات متناسب به مؤلفه اول و \bar{y}_2 میانگین مشاهدات متناسب به مؤلفه دوم است. با فرض اینکه h و p بصورت پیشینی مستقل هستند و با در نظر گرفتن توزیع‌های پیشین نرمال $N(\delta, \frac{1}{\lambda})$ ، $j = 1, 2$ با $\delta \in R, \lambda > 0$ برای پارامترهای مکانی دو مؤلفه توزیع آمیخته نرمال، می‌توان نوشت

$$\begin{aligned} \pi(\mu_1, \mu_2) &\propto e^{-\frac{\lambda}{2}\{(\mu_1 - \delta)^2 + (\mu_2 - \delta)^2\}}, \\ \pi(h, p) &= \pi(h)\pi(p) = 1, \\ \pi(\mu_1, \mu_2, h, p) &\propto e^{-\frac{\lambda}{2}\{(\mu_1 - \delta)^2 + (\mu_2 - \delta)^2\}}, \\ \pi(\mu_1, \mu_2, h, p|y) &= f(y|\mu_1, \mu_2, p, h)\pi(\mu_1, \mu_2, h, p). \end{aligned}$$

رحمان فرنوش، افشنین فلاح، آرزو حاجرجی ۲۳۷.....

از این رو توزیع پسین را می‌توان بصورت

$$\pi(\mu_1, \mu_2, h, p|y) \propto p^{n_1} (1-p)^{n_2} e^{-\frac{n_1}{\tau}(\bar{y}_1 - \mu_1)} e^{-\frac{n_2}{\tau}(\bar{y}_2 - \mu_2)} (1 - |1 - 2p|^h) e^{-\frac{\lambda}{\tau} \{(\mu_1 - \delta)^2 + (\mu_2 - \delta)^2\}},$$

نوشت. به همین ترتیب، اگر Y_1, \dots, Y_n یک نمونه تصادفی از توزیع آمیخته متناهی دو مؤلفه‌ای پواسن باشد، در این صورتتابع درستنمایی توانیده از ضرب تابع درستنمایی در تابع توان بصورت

$$L(y|\lambda_1, \lambda_2, p, h) \propto p^{n_1} (1-p)^{n_2} \exp \{-n_1 \lambda_1 - n_2 \lambda_2 + n_1 \bar{y}_1 \ln \lambda_1 + n_2 \bar{y}_2 \ln \lambda_2\} (1 - |1 - 2p|^h),$$

حاصل می‌شود، که در آن n_1 تعداد مشاهدات مناسب به مؤلفه اول، n_2 تعداد مشاهدات مناسب به مؤلفه دوم، \bar{y}_1 میانگین مشاهدات مناسب به مؤلفه اول و \bar{y}_2 میانگین مشاهدات مناسب به مؤلفه دوم است. با فرض اینکه h و p بصورت پیشینی مستقل هستند و با در نظر گرفتن توزیع‌های پیشین گاما $\lambda_j \sim \Gamma(\alpha_j, \beta_j)$ ، $j = 1, 2$ ، با $\alpha_j > 0, \beta_j > 0$ برای پارامترهای λ در دو مؤلفه‌ای توزیع آمیخته‌ی پواسن، می‌توان نوشت

$$\begin{aligned} \pi(\lambda_1, \lambda_2) &\propto \lambda_1^{(\alpha_1-1)} e^{-\frac{1}{\beta_1} \lambda_1} \lambda_2^{(\alpha_2-1)} e^{-\frac{1}{\beta_2} \lambda_2}, \\ \pi(h, p) &= \pi(h)\pi(p) = 1, \\ \pi(\lambda_1, \lambda_2, h, p) &\propto \lambda_1^{(\alpha_1-1)} e^{-\frac{1}{\beta_1} \lambda_1} \lambda_2^{(\alpha_2-1)} e^{-\frac{1}{\beta_2} \lambda_2}, \\ \pi(\lambda_1, \lambda_2, h, p|y) &= f(y|\lambda_1, \lambda_2, p, h) \pi(\lambda_1, \lambda_2, h, p), \end{aligned}$$

از این رو توزیع پسین را می‌توان بصورت

$$\pi(\lambda_1, \lambda_2, h, p|y) \propto p^{n_1} (1-p)^{n_2} e^{\{-n_1 \lambda_1 - n_2 \lambda_2 + n_1 \bar{y}_1 \ln \lambda_1 + n_2 \bar{y}_2 \ln \lambda_2\}} (1 - |1 - 2p|^h) \lambda_1^{(\alpha_1-1)} e^{-\frac{1}{\beta_1} \lambda_1} \lambda_2^{(\alpha_2-1)} e^{-\frac{1}{\beta_2} \lambda_2},$$

نوشت. تحلیل بیزی مدل‌های آمیخته به دلیل پیچیدگی ذاتی این مدل‌ها، با دشواری‌های زیادی همراه است (دایبولت و رابرتس، ۱۹۹۰). معمولاً در این حالت توزیع پسین فاقد یک فرم بسته می‌باشد. از این رو برای انجام استنباط، به کمک الگوریتم‌های زنجیر مارکوف مونت کارلوئی (MCMC)، از توزیع پسین نمونه‌گیری می‌شود. الگوریتم‌های گیبز و مترو پولیس-هاستینگ، از جمله مهمترین الگوریتم‌ها در زمینه نمونه‌گیری از توزیع پسین هستند. اما، برای استفاده از الگوریتم گیبز لازم است توزیع‌های شرطی کامل پارامترها در دسترس باشند. بعلاوه نشان داده شده است که وقتی این الگوریتم برای برآورد پارامترهای توزیع‌های آمیخته به کار گرفته می‌شود، همگرای آن به مقادیر اولیه وابسته است. از این رو اگر مقادیر اولیه به ماکسیمم موضعی نزدیک باشند، ممکن است حتی برای تکرارهای بسیار زیاد

۲۳۸ براورد بیزی تابع تاوان در آزمون همگنی مدل‌های آمیخته

الگوریتم توانایی رهایی از جذب مаксیمم موضعی را نداشته باشد. به همین دلیل از الگوریتم مترو پولیس-هاستینگ که در هنگام کار با توزیع‌های آمیخته فاقد معایب الگوریتم گیز می‌باشد، برای براورد پارامترهای مدل استفاده شده است (مارین و همکاران، ۲۰۰۵). در این الگوریتم با ساختن زنجیر مارکف $\{\theta^{(t)}\}_{t=1}^N$ که دارای توزیع مانای $\pi(\theta|y)$ است، مقدار $E(g(\theta)|y)$ توسط براوردگر سازگار $\sum_{t=1}^N g(\theta^{(t)})$ تخمین زده می‌شود. فرض کنید Y_1, \dots, Y_n یک نمونه تصادفی از توزیع آمیخته دو مؤلفه‌ای باشد، شکل کلی الگوریتم متروپولیس-هاستینگ برای براورد پارامترهای مدل آمیخته و نیز پارامتر h بصورت زیر است:

- آ. مقادیر اولیه‌ی $\theta^{(0)}$ و $h^{(0)}$ را در نظر بگیرید.
- ب. مراحل زیر را تا رسیدن به توزیع مانای زنجیر مارکف $\{\theta^{(t)}\}_{t=1}^N$ تکرار کنید.
- پ. $(\tilde{\theta}, \tilde{p}, \tilde{h})$ را از توزیع پیشنهادی $(\theta^{(t-1)}, p^{(t-1)}, h^{(t-1)})$ تولید کنید.
- ت. مقدار r را محاسبه کنید،

$$r = \frac{f(y|\tilde{\theta}, \tilde{p}, \tilde{h}) \Pi(\tilde{\theta}, \tilde{p}, \tilde{h}) q(\theta^{(t-1)}, p^{(t-1)}, h^{(t-1)} | \tilde{\theta}, \tilde{p}, \tilde{h})}{f(y|\theta^{(t-1)}, p^{(t-1)}, h^{(t-1)}) \Pi(\theta^{(t-1)}, p^{(t-1)}, h^{(t-1)}) q(\tilde{\theta}, \tilde{p}, \tilde{h} | \theta^{(t-1)}, p^{(t-1)}, h^{(t-1)})}.$$

ث.) مشاهده‌ی u را از توزیع $(\theta^{(0)}, U)$ را در نظر بگیرید. اگر $u > r$ قرار دهید $(\tilde{\theta}, \tilde{p}, \tilde{h}) = (\theta^{(t)}, p^{(t)}, h^{(t)})$ و در غیر این صورت قرار دهید $(\theta^{(t)}, p^{(t)}, h^{(t)}) = (\theta^{(t-1)}, p^{(t-1)}, h^{(t-1)})$

۵ شبیه‌سازی

به منظور ارزیابی و مقایسه‌ی تأثیر توابع تاوان (۶) و (۷) بر آزمون نسبت درستنمایی اصلاح شده، یک مطالعه‌ی شبیه‌سازی اجرا شده است. برای این منظور آمیخته‌ای از دو توزیع پواسن با پارامترهای مختلف به نحوی در نظر گرفته شده است، که میانگین توزیع تحت فرض‌های H_0 و H_1 با یکدیگر مساوی و برابر با ۵ باشد. برای این منظور از روابط

$$\begin{aligned} E_{H_0}(Y) &= Var_{H_0}(Y), \\ E_{H_1}(Y) &= p\lambda_1 + (1-p)\lambda_2, \\ Var_{H_1}(Y) &= E_{H_1}(Y^2) - E_{H_1}^2(Y) \\ &= p(1-p)(\lambda_1 - \lambda_2)^2 + 5, \end{aligned}$$

استفاده شده است. بصورت مشابه آمیخته‌ای از توزیع نرمال با پارامترهای متفاوت نیز به نحوی در نظر گرفته شده است، که میانگین توزیع تحت فرض‌های H_0 و H_1 با یکدیگر

رحمان فرنوش، افشنین فلاح، آرزو حاجرجی ۲۳۹.....

مساوی و برابر با \circ باشد. برای این منظور روابط

$$\begin{aligned} E_{\mathcal{H}_0}(Y) &= \circ, \quad Var_{\mathcal{H}_0}(Y) = 1, \\ E_{\mathcal{H}_1}(Y) &= p\mu_1 + (1-p)\mu_2, \\ Var_{\mathcal{H}_1}(Y) &= E_{\mathcal{H}_1}(Y^2) - E_{\mathcal{H}_1}^2(Y) \\ &= p(1-p)(\mu_1 - \mu_2)^2 + 1, \end{aligned}$$

مورد استفاده قرار گرفته‌اند. مدل‌های حاصل از این انتخاب‌ها در جدول ۱ نشان داده شده‌اند.

جدول ۱: توزیع‌های آمیخته‌ی پواسن و نرمال با میانگین‌های برابر تحت فرض‌های \mathcal{H}_1 و \mathcal{H}_0 .

توزیع نرمال		توزیع پواسن		p	مدل
μ_2	μ_1	λ_2	λ_1		
۰/۱۱۵	-۲/۱۷۹	۵/۲۵۶	۰/۱۲۷	۰/۰۵	۱
۰/۱۶۷	-۱/۵۰۰	۵/۳۷۲	۱/۶۴۶	۰/۱۰	۲
۰/۲۸۹	-۰/۸۶۶	۵/۶۴۵	۳/۰۶۴	۰/۲۵	۳
۰/۵۰۰	-۰/۵۰۰	۶/۱۱۸	۳/۸۸۲	۰/۵۰	۴

این چهار مدل از دو توزیع آمیخته‌ی پواسن و نرمال بصورتی در نظر گرفته می‌شود که $p = ۰/۰۵, ۰/۱, ۰/۰۵, ۰/۵$ انتخاذ شود و واریانس برای مدل‌های آمیخته $۱/۲۵$ برابر واریانس تحت مدل همگن باشد و میانگین نیز برای مدل‌های آمیخته برابر با میانگین تحت مدل همگن باشد. سپس از هر یک از این مدل‌ها نمونه‌ای به حجم $n = ۲۰۰$ شبیه سازی شده و فرض همگنی (۲) به کمک آزمون نسبت درستنمایی اصلاح شده و با در نظر گرفتن توابع توان (۶) و (۷) در سطح $۰/۰۵$ آزمون شده است. نتایج حاصل که در جدول ۲ خلاصه شده‌اند، نشان می‌دهند که وقتی مدل آمیخته به سمت شناخت ناپذیری میل می‌کند، استفاده از تابع توان (۷) به جای تابع توان (۶) در آزمون نسبت درستنمایی اصلاح شده، منجر به افزایش توان آزمون و دقت برآوردها با استناد به معیار میانگین توانهای دوم خطای می‌شود. همچنین، با استفاده از رهیافت بیزی، پارامترهای مدل آمیخته و نیز پارامتر شکل تابع توان برای توزیع آمیخته نرمال و پواسن برآورد شده‌اند، جداول ۳ و ۴ مقادیر میانگین توانهای دوم خطای برآوردهای حاصل از دو رهیافت بسامدی و بیزی را نشان می‌دهند. در رهیافت بسامدی از الگوریتم EM برای برآورد پارامترهای مدل آمیخته و از تابع توان (۷)

۲۴۰ براورد بیزی تابع توان در آزمون همگنی مدل‌های آمیخته

جدول ۲: براورد پارامترهای میانگین توان دوم خطای مقدار آماره و توان آزمون نسبت درستنمایی اصلاح شده، برای توابع توان چن و لی.

مدل	تابع توان	براورد	MSE			آماره ازمون	توان ازمون
			\hat{p}	$\hat{\lambda}_2$	$\hat{\lambda}_1$		
(درصد)							
۸۷/۲ ۹۷/۴	۶۲/۵۰۷ ۶۲/۶۰۰	۰/۰۱۶ ۰/۰۰۳	۰/۰۸ ۰/۴۳۱	۱۸۹۰ ۰/۴۳۹	۰/۱۲۱ ۰/۰۷	۰/۲۸۵ ۰/۲۰۳	۰/۸۵۰ ۰/۷۳۳
۹۲/۱ ۹۲/۲	۴۷/۰۱۰ ۴۷/۹۹۵	۰/۰۷۳ ۰/۰۴۸	۰/۲۸ ۰/۲۰۱	۲/۱۰۳ ۲/۱۶۶	۰/۳۴۵ ۰/۲۶۱	۰/۸۱ ۰/۶۶۴	۲/۹۳۹ ۲/۰۷۱
۹۳/۸ ۹۳/۹	۴۲/۳۰۷ ۴۲/۳۰۷	۰/۰۴۵ ۰/۰۴۵	۰/۲۵۲ ۰/۲۵۲	۰/۶۷۴ ۰/۶۷۴	۰/۴۵۳ ۰/۴۵۲	۶/۰۱۱ ۶/۰۱۱	۳/۸۱۷ ۳/۸۱۷
۹۳/۵ ۹۳/۴	۲۷/۶۹۱ ۲۷/۵۸۸	۰/۰۰۳ ۰/۰۰۵	۰/۱۶۵ ۰/۲۱۶	۰/۱۴۵ ۰/۱۸۲	۰/۰۵ ۰/۴۹۹	۶/۰۸۲ ۶/۰۹۰	۳/۹۱۹ ۳/۹۱۱
						چن	آسی
						چن	آسی
						چن	آسی
						چن	آسی
						چن	آسی

جدول ۳: میانگین توان دوم خطای براوردگرهای بیزی و بسامدی.

پارامترهای مدل					مدل پواسن	براوردگر	مدل
\hat{h}	\hat{p}	$\hat{\lambda}_2$	$\hat{\lambda}_1$				
-	۰/۰۰۵۰	۰/۱۰۱۰	۱/۰۹۷۰	$\hat{\theta}_{ML}$		۱	
۰/۰۴۸۹	۰/۰۰۰۴	۰/۰۲۴۰	۰/۱۰۷۰	$\hat{\theta}_B$			
-	۰/۰۳۴۰	۰/۱۸۰۰	۱/۹۱۵۰	$\hat{\theta}_{ML}$		۲	
۰/۰۵۴۰	۰/۰۰۰۴	۰/۰۲۱۰	۰/۰۹۹۰	$\hat{\theta}_B$			
-	۰/۰۰۲۲	۰/۰۲۴۰	۰/۰۷۲۰	$\hat{\theta}_{ML}$		۳	
۰/۰۷۳۰	۰/۰۰۰۷	۰/۰۲۳۰	۰/۰۴۵۰	$\hat{\theta}_B$			
-	۰	۰/۰۰۳۱۰	۰/۰۴۰۶	$\hat{\theta}_{ML}$		۴	
۰/۰۵۵۰	۰/۰۰۰۸	۰/۰۴۳۰	۰/۰۷۱۰	$\hat{\theta}_B$			

رحمان فرنوش، افشنین فلاح، آرزو حاجرجی ۲۴۱

استفاده شده، در صورتی که در رهیافت بیزی از الگوریتم متروپولیس - هاستینگ برای برآورد پارامترهای مدل آمیخته و نیز پارامتر h استفاده شده است. همانطور که مشاهده می‌شود، زمانی که مدل آمیخته به سمت شناخت ناپذیری میل می‌کند، استفاده از رهیافت بیزی در برآورد پارامترهای مدل به مراتب از رهیافت بسامدی مطلوب‌تر است. به منظور ارزیابی میزان

جدول ۴: میانگین توان دوم خطای برآوردگرهای بیزی و بسامدی.

پارامترهای مدل				
\hat{h}	\hat{p}	$\hat{\mu}_2$	$\hat{\mu}_1$	مدل نرمال برآوردگر
-	۰/۰۵۷۰	۰/۰۶۸۰	۲/۵۲۳۰	$\hat{\theta}_{ML}$
۰/۰۰۹۴	۰/۰۰۴۴	۰/۰۰۴۵	۰/۲۴۳۰	$\hat{\theta}_B$
-	۰/۰۱۶۷	۰/۰۲۱۰	۰/۱۵۰۵	$\hat{\theta}_{ML}$
۰/۱۹۴۳	۰/۰۰۲۵	۰/۰۰۰۲	۰/۰۰۳۱	$\hat{\theta}_B$
-	۰/۰۶۱۰	۰/۰۰۲۱	۰/۳۲۱۲	$\hat{\theta}_{ML}$
۰/۰۲۹۰	۰/۰۰۲۲	۰/۰۰۰۶	۰/۰۰۸۱	$\hat{\theta}_B$
-	۰	۰/۰۳۸۰	۰/۰۰۰۲	$\hat{\theta}_{ML}$
۰/۰۱۶۵	۰/۰۰۰۹	۰/۰۲۶۰	۰/۰۰۰۴	$\hat{\theta}_B$

برازش مدل‌هایی که از رهیافت بیزی برآورد شده‌اند، معیار نیکویی برازش کیش و آکائیک محاسبه و نتایج آن در جدول ۵ ارائه شده است. نکته حائز اهمیت آن است که گرچه مقادیر کوچک این معیارهای نیکویی برازش به معنی برازش دقیق مدل برآورد شده به داده‌ها نیست، اما مقادیر بزرگ آن گواهی روشن بر نامناسب بودن مدل برآورد شده برای داده‌ها است (هاسمر و لیشاو، ۲۰۰۰). معیار نیکویی برازش کیش و آکائیک به ترتیب از روابط

$$D = -2\ell_n(\hat{\theta}, \hat{p}),$$

$$AIC = -2\ell_n(\hat{\theta}, \hat{p}) + 2t,$$

محاسبه می‌شوند، که در آن $\ell_n(\hat{\theta}, \hat{p})$ تابع لگ درستنمایی و t تعداد پارامترهای مدل می‌باشد. نتایج ارائه شده در جدول ۵ نشان می‌دهند که در هر دو مورد توزیع‌های آمیخته‌ی پواسن و نرمال با دو مؤلفه ($k=2$) در مقابل مدل همگن ($k=1$)، برازش به مراتب بهتری به داده‌هایی دارند که از همان توزیع‌ها شبیه‌سازی شده‌اند.

جدول ۵ مقادیر معیارهای نیکویی برازش آکائیک و کیش.

مدل	k	توزیع نرمال		توزیع پواسن	مدل	k		
		$D(\theta)$	AIC				$D(\theta)$	AIC
۱۴۴۶/۸۰۰	۱۴۴۸/۸۰۰	۹۷۵/۹۰۰	۹۷۷/۰۰۰	۱	۱			
۱۳۹۶/۰۸۰	۱۴۰۴/۰۸۰	۹۵۶/۸۰۰	۹۶۴/۸۰۰	۲				
۱۳۹۸/۲۹۵	۱۴۰۰/۲۹۵	۹۳۴/۰۷۱	۹۳۹/۰۸۴	۱	۴			
۱۳۹۲/۰۰۵	۱۳۰۰/۰۰۵	۹۲۷/۴۸۳	۹۳۵/۴۱۸	۲				

۶ بحث و نتیجه‌گیری

کارایی آزمون نسبت درستنمایی اصلاح شده به شدت تحت تأثیر شکل تابع توان انتخابی است. از طرفی هیچ دلیلی مبنی بر بهینه بودن هیچ یک از این توابع توانی که در منابع مختلف ارائه شده‌اند، وجود ندارد. استفاده از رهیافت بیزی هم در برآورد پارامترهای مدل آمیخته و هم برای تعیین شکل بهینه تابع توان خصوصاً در شرایطی که مدل آمیخته به سمت شناخت ناپذیری میل می‌کند، به مراتب از رهیافت بسامدی مطلوب‌تر است. آزمون همگنی توزیعهای آمیخته، عمدهاً به منظور تشخیص آمیخته بودن یا نبودن توزیع جامعه صورت می‌پذیرد. تعیین تعداد مؤلفه‌های توزیع آمیخته در مرحله بعدی قرار دارد.

مراجع

- Akaike, H. (1973), Information Theory and an Extension of the Maximum Likelihood Principle, *In Second International Symposium on Information Theory*, B. N. Petrov and F. Csaki (Eds). Budapest: Akademiai Kiado, 261-281.
- Chen, H., Chen, J. and Kalbfleish, D. (2001), The Likelihood Ratio Test for Homogeneity in Finite Mixture Models, *Journal of the Royal Statistical Society*, **63**, 19-29.
- Chen, J., (1998), Penalized Likelihood Ratio Test for Finite Mixture Models with Multinomial Observations, *Canadian Journal of Statistics*, **26**, 583-599.

رحمان فرنوش، افشین فلاح، آرزو حاجرجی ۲۴۳

- Chen, J. and Kalbfleisch, J. D. (1996), Penalized Minimum-Distance Estimates in Finite Mixture Models, *Canadian Journal of Statistics*, **24**, 167-175.
- Chen, J. and Khalili, A. (2006), Order Selection in Finite Mixture Models, *Working Paper 2006-03*, Department of Statistics and Actuarial Science, University of Waterloo.
- Diebolt, J. and Robert, C. (1990), Bayesian Estimation of Finite Mixture Distribution, Part i: Theoretical Aspects. *Technical Report 110*, LSTA, Universite Paris VI, Paris.
- Hartigan, J. A. (1985), A Failure of Likelihood Asymptotics for Normal Mixtures, *Proceedings of conference in Honor of J. Neyman and Kiefer*, Volume 2, eds L. LeCam and R. A. Olshen, 807-810.
- Hosmer, D. W. and Lemeshow, S. (2000), *Applied Logistic Regression*, Wiley, Inc., New York.
- Li, P. Chen, J. and Marriott, P. (2008), Non-Finite Fisher Information and Homogeneity: The EM Approach, *Biometrika*. **96**, 411-426.
- Marin, J.-M., Mengerson, K. and Robert, C. (2005), Bayesian Modelling and Inference on Mixture of Distributions, *Handbook of Statistics*, **25**, 459-507, DOI: 10.1016/S0169-7161(05)25016-2.
- Richardson, S. and Green, P. J. (1997), On Bayesian Analysis of Mixtures with an Unknown Number of Components, *Journal of the Royal Statistical Society, B*, **59**, 731-792.