

مروری بر آزمون های نیکویی برازش بر اساس آنتروپی نمونه

ناصررضا ارقامی، احسان زمان زاده

گروه آمار، دانشگاه فردوسی مشهد

سادگی برآوردگر آنتروپی بر اساس فاصله داده‌ها (بخصوص برآوردگر واسیچک (۱۹۷۶)) باعث شد که انواع آزمون های نیکویی برازش بر مبنای ماکسیمم آنتروپی و می نیموم متقاطع توسط مولفین مختلف ابداع و معرفی شود. در این مقاله تاریخچه تحول و آخرین روش های ابداع شده مورد بررسی قرار می گیرد.

واژه‌های کلیدی: آزمون نیکوی برازش، آنتروپی، فاصله کولبک- لایبلر.

۱ مقدمه

از آنجا که صحت نتایج بسیاری از استنباط‌های آماری پارامتری مبتنی بر صحت این فرض هستند که مشاهدات نمونه از چه توزیعی ناشی شده‌اند، آزمون‌های نیکویی برازش اهمیت فوق العاده‌ای دارند.

از این آزمون‌ها در جعبه ابزار آمارشناسان کاربردی بسیار وجود دارد. آزمون‌های χ^2 (پیرسون)، $K-S$ (کلموگروف-اسمیرنوف) و کرامر-وان میزس از معروفترین آن‌ها هستند و بعضی نیز مخصوص آزمون نرمال بودن توزیع می‌باشند. (مانند آزمون SW (شاپیرو-ویلک) و LS (لیلی-فورس)) پس از مقاله واسیچک (۱۹۷۶) که در آن یک آزمون برای نیکویی برازش توزیع نرمال بر مبنای آنتروپی نمونه ارائه نمود و با شبیه سازی نشان داد که از توان خوبی برخوردار است، آزمون‌های دیگری بر مبنای ماکزیمم آنتروپی و یا مینیموم فاصله کولبک-لایبلر توسط مولفین دیگر معرفی شد.

در بخش دوم این مقاله آزمون‌های نیکویی برازش مبتنی بر ماکزیمم آنتروپی (یا مینیموم فاصله کولبک-لایبلر) فهرست شده، ویژگی‌های آن‌ها مقایسه می‌شود. در بخش سوم آزمون‌های نیکویی برازشی که اخیرا ابداع شده‌اند، ارائه می‌گردد.

۲ آزمون‌های نیکویی برازش بر مبنای ماکزیمم آنتروپی (یا مینیموم فاصله کولبک - لایبلر)

۱-۲ آزمون واسیچک

زمانی که واسیچک آزمون نرمالیتی خود را ارائه داد، از این واقعیت استفاده کرد که توزیع نرمال در بین توزیع‌های با واریانس معلوم، دارای بیشترین آنتروپی است. وی ابتدا نشان داد که آنتروپی یک متغیر تصادفی پیوسته را که به صورت

$$H(f) = - \int f(x) \log(f(x)) dx$$

تعریف می‌شود، به صورت زیر نیز می‌توان نوشت

$$H(f) = \int_0^1 \log \left\{ \frac{dF^{-1}(p)}{dp} \right\} dp$$

که در آن F تابع توزیع توزیع مربوطه است. آنگاه با جایگزین کردن تابع توزیع تجربی به جای F و عملگر تفاضل به جای مشتق، برآورد آنتروپی یک توزیع را بر مبنای یک نمونه تصادفی X_1, \dots, X_n از آن توزیع به صورت

$$\hat{H}(f) = \frac{1}{n} \sum_{i=1}^n \log \left(\frac{2m}{n} (X_{(i+m)} - X_{(i-m)}) \right) \quad (1)$$

تعریف کرد که در آن $X_{(1)} \leq \dots \leq X_{(n)}$ آماره‌های مرتب نمونه است و $X_{(i)} = X_{(1)}$ به ازای $i < 1$ و $X_{(i)} = X_{(n)}$ به ازای $i > n$. در اینجا $m \leq \frac{n}{2}$ عددی است صحیح و مثبت و آن را اندازه پنجره نامند و بزرگتر بودن آن از یک به هموارتر بودن برآورد چگالی کمک می‌کند.

از طریق زیر نیز می‌توان به برآورد فوق رسید. چون

$$H(f) = -E_f(\log f(X))$$

است می‌توان آن را با میانگین نمونه یعنی $\frac{1}{n} \sum_{i=1}^n \log f(X_i)$ برآورد کرد. حال اگر به جای تابع چگالی مجهول f (که مشتق F نسبت به x است) از

$$f(x_i) = \frac{F(X_{(i+m)}) - F(X_{(i-m)})}{X_{(i+m)} - X_{(i-m)}}$$

استفاده کرده و بجای F نیز تابع توزیع تجربی $F_n(x_{(i)}) = \frac{i}{n}$ را قرار دهیم، همان برآورد (۱) بدست می آید.

حال فرض کنید می خواهیم فرضیه $f \in N(\mu, \sigma^2)$ را در مقابل نقیض آن آزمون کنیم و μ, σ^2 هر دو مجهول اند. $\hat{H}(f)$ نسبت به تبدیلات مکانی پایاست ولی نسبت به تبدیلات مقیاس پایانیست. برای پایا بودن آن تحت تبدیلات مقیاسی از آماره

$$T_v = \hat{H}(f) - \log(S)$$

که $S^2 = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2$ است، استفاده می کنیم و در نتیجه توزیع T_v به μ, σ^2 بستگی ندارد و مقادیر بحرانی آن را می توان به ازای $\mu = 0$ و $\sigma^2 = 1$ به کمک شبیه سازی به دست آورد. چون توزیع نرمال در بین همه توزیع های با واریانس معلوم، بیشترین آنتروپی را دارد، H_0 را به ازای مقادیر کوچک T_v (کوچکتر از مقدار بحرانی) رد می کنیم. واسیچک (۱۹۷۶) به کمک شبیه سازی نشان داد که آزمون نرمالیتی وی از توان خوبی نیز برخوردار است و نه تنها تقریباً به ازای همه توزیع های جانشین از آزمون $K-S$ (کلموگروف-اسمیرنوف) توان بیشتری دارد، بلکه، به ازای بعضی از توزیع های جانشین از آزمون پرتوان SW (شاپیرو-ویلک) نیز پرتوان تر است. خوبی عمده آزمون واسیچک (۱۹۷۶) در مقایسه با آزمون SW سادگی محاسبات آن است و برای محاسبه آماره آزمون نیازی به جداول مخصوص برای ضرایب لازم به ازای حجم نمونه های متفاوت ندارد.

۲-۲ آزمون نیکویی برآزش بر اساس مینیموم فاصله کولبک لایبلر

ذیلاً نشان می دهیم که آزمون واسیچک حالت خاصی از یک آزمون بسیار کلی تر است. (ارقامی و علیزاده ۲۰۱۰)

فرض کنید می خواهیم فرضیه $f \in G_\theta$ را در مقابل نقیض آن آزمون کنیم. فاصله کولبک-لایبلر بین f و هر عضو از خانواده G_θ عبارتست از

$$D(f||g_\theta) = \int \left[\log \frac{f(x)}{g_\theta(x)} \right] f(x) dx = E_f \left[\log \frac{f(x)}{g_\theta(x)} \right] = E_f [\log f(x)] - E_f [\log g_\theta(x)].$$

تعریف می کنیم

$$D_{Inf} = \text{Inf}_{\theta} D(f||g_{\theta})$$

با توجه به ویژگی فاصله کولبک-لایبلر داریم

$$D_{Inf} = 0 \Leftrightarrow f \in G_{\theta}$$

بنابراین اگر \hat{D}_{Inf} برآورد D_{Inf} باشد و H_0 را به ازای مقادیر بزرگ \hat{D}_{Inf} رد کنیم، آزمون معقولی خواهیم داشت. چون

$$D_{Inf} = E_f[\log f(x)] - \text{Sup}_{\theta} E_f[\log g_{\theta}(x)]$$

می توان نوشت

$$\hat{D}_{Inf} = -\hat{H}(f) - \text{Sup}_{\theta} \left[\frac{1}{n} \sum_{i=1}^n \log g_{\theta}(x_i) \right]$$

که در آن $\hat{H}(f)$ برآورد آنتروپی واسیچک است. بدیهی است که جمله دوم عبارت فوق به ازای $\theta = \hat{\theta}$ که $\hat{\theta}$ MLE می θ است، ماکزیمم می شود. پس

$$\begin{aligned} \hat{D}_{Inf} &= \frac{1}{n} \sum_{i=1}^n \frac{n}{m} (X_{(i+m)} - X_{(i-m)}) - \frac{1}{n} \sum_{i=1}^n \log g_{\hat{\theta}}(X_i) \\ &= \frac{1}{n} \left[\sum_{i=1}^n \hat{f}(X_i) - \sum_{i=1}^n \log g_{\hat{\theta}}(X_i) \right] = \frac{1}{n} \log \frac{\prod_{i=1}^n \hat{f}(X_i)}{\prod_{i=1}^n g_{\hat{\theta}}(X_i)} = \frac{1}{n} \log \lambda \end{aligned} \quad (2)$$

که $\lambda = \frac{\prod_{i=1}^n \hat{f}(X_i)}{\prod_{i=1}^n g_{\hat{\theta}}(X_i)}$. چون \hat{f} (برآورد تابع چگالی واسیچک) تابعی از تابع توزیع تجربی (F_n)

است و F_n برآورد درستنمایی ماکزیمم F می باشد، نتیجه می گیریم که λ آماره آزمون نسبت درستنمایی است. در حالت خاص که G_{θ} یک خانواده مکانی، مقیاسی یا مکانی-مقیاسی باشد، به راحتی می توان نشان داد که آماره آزمون فوق (\hat{D}_{Inf}) نسبت به تبدیلات به ترتیب مکانی، مقیاسی و مکانی-مقیاسی پایا است. لذا توزیع آماره به هیچ پارامتر مجهولی بستگی ندارد و مقادیر بحرانی را می توان به کمک شبیه سازی به ازای $\theta = \theta_0$ (که θ_0 یکی از مقادیر

فضای پارامتر تحت H_0 است.) به دست آورد و فرضیه H_0 به ازای مقادیر $\hat{D}_{Inf} > c$ رد می‌شود. اگر خانواده G_{θ} $N(\mu, \sigma^2)$ (هر دو مجهول) باشد، داریم

$$\log g_{\theta}(x) = -\frac{1}{2} \log 2\pi - \frac{1}{2} \log \sigma^2 - \frac{1}{2\sigma^2} (x - \mu)^2$$

حال اگر به جای σ^2 برآورد درست‌نمایی ماکزیمم آن، یعنی $S^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2$ را قرار دهیم، داریم

$$\frac{1}{n} \log g_{\theta}(x_i) = -\frac{1}{2} \log 2\pi - \frac{1}{2} \log S^2 - \frac{1}{2}$$

و در نتیجه

$$\hat{D}_{Inf} = -\hat{H}(f) + \log S + \left(\frac{1}{2} \log 2\pi + 1 \right)$$

که قسمت غیرثابت آن قرینه لگاریتم آماره آزمون واسیچک است. یعنی آزمون بر مبنای \hat{D}_{Inf} و آزمون واسیچک (که بر اساس ماکزیمم آنتروپی است) در واقع یک آزمون هستند. لازم به ذکر است این مطلب در مورد خاص آزمون نیکویی برازش توزیع نرمال توسط آریزونو و اوها (۱۹۸۱) ارائه شد.

۳-۲ آزمون نمایی بودن بر اساس مینیموم فاصله کولبک-لایپلر

ابراهیمی و همکاران (۱۹۹۲) آزمونی برای نیکویی برازش توزیع نمایی بر مبنای آنتروپی ارائه نمودند که آن نیز حالت خاصی از آزمون کلی فوق است.

$$H_0 : f \sim \text{Exp}(\theta)$$

$$H_1 : \sim H_0$$

آماره آزمون پیشنهادی آن‌ها به صورت زیر بود

$$-\hat{H}(f) - \log \bar{x} + 1 \quad (3)$$

حال اگر در فرمول (۲) به جای $g_{\theta}(x)$ عبارت $\frac{1}{\theta} e^{-\frac{x}{\theta}}$ را قرار دهیم، داریم

$$\hat{D}_{Inf} = -\hat{H}(f) - \log \hat{\theta} + \frac{\bar{x}}{\hat{\theta}}$$

که $\hat{\theta}$ برآورد درست‌نمایی ماکزیمم θ یعنی \bar{x} است. در نتیجه همان آماره (۳) به دست می‌آید.

۴-۲ آزمون یکنواختی

دادویچ و وندرمولن (۱۹۸۱) با استفاده از اینکه توزیع یکنواخت در بین همه توزیع‌های با تکیه‌گاه $[0, 1]$ دارای بیشترین آنتروپی است، آزمونی با آماره

$$T_{DV} = -\hat{H}(f)$$

معرفی کردند که به ازای مقادیر کوچک T_{DV} فرضیه $f \sim U(0, 1)$ را رد می‌کند.

۵-۲ آزمون نیکویی برازش نرمال معکوس

ماده‌الکار و تیال (۲۰۰۲) با استفاده از این واقعیت که آزمون گوسی معکوس $IG(\mu, \lambda)$ در بین همه توزیع‌ها با تکیه‌گاه $[0, \infty)$ ، تحت دو شرط $E(X^{-2}) = \mu$ و $E(X^2) = \frac{1}{\mu} + \frac{1}{\lambda}$ دارای بیشترین آنتروپی است، آزمونی با آماره

$$T_{MT} = \hat{H}(f) - \log\left(\frac{w}{\sqrt{2}}\right)$$

معرفی کردند که در آن

$$w^2 = \frac{\sum_{i=1}^n \left(\frac{1}{x_i^2} - \frac{n}{\sum_{i=1}^n \frac{1}{x_i^2}} \right)}{n-1}$$

و H_0 را به ازای مقادیر کوچک T_{MT} رد می‌کنند.

۶-۲ آزمون نیکویی برازش توزیع لاپلاس

چوی و کیم (۲۰۰۶) با استفاده از اینکه توزیع لاپلاس در بین همه توزیع‌های با تکیه‌گاه \mathcal{R} با میانگین معلوم دارای بیشترین آنتروپی است، آزمونی برای نیکویی برازش توزیع لاپلاس با آماره آزمون

$$T_{CK} = \frac{n}{2m\hat{\theta}} \prod_{i=1}^n (\tilde{Y}_{(i+m)} - \tilde{Y}_{(i-m)})$$

که در آن $\tilde{Y}_{(i)} = X_{(i)} - \text{median}(X_{(i)})$ و $\hat{\theta} = \frac{1}{n} \sum_{i=1}^n |\tilde{Y}_{(i)}|$ فرضیه $f \sim \text{Laplace}$: H_0 را به ازای مقادیر کوچک T_{CK} رد می‌کند. لازم به ذکر است که کلیه آزمون‌های نامبرده شده در بالا از طریق آزمون کلی براساس $D\hat{Inf}$ قابل حصول است.

۷-۲ آزمون نمایی بودن براساس داده‌های سانسور شده

پارک (۲۰۰۳) نشان داد که می‌توان آنتروپی آماره‌های مرتب $X_{(1)}, \dots, X_{(r)}$ ($r < n$)، از یک نمونه تصادفی به حجم n ، را برحسب تابع مخاطره $h(x)$ به صورت زیر نوشت

$$H_{1,2,\dots,r;n} = -(\log n + \dots + \log(n-r+1)) + r - n \int_{-\infty}^{+\infty} (1 - F_{r;n-1}(x)) f(x) \log h(x) dx$$

و براین اساس آزمون نمایی بودن براساس داده‌های سانسور شده نوع II را، با آماره

$$T(m, n, r) = -\bar{H}(m, n, r) + \frac{r}{n} \left(\log \left(\frac{1}{r} \left(\sum_{i=1}^r X_{(i)} (n-r) X_{(r)} \right) \right) + 1 \right)$$

که در آن $\bar{H}(m, n, r)$ برآورد آنتروپی داده‌های سانسور شده به صورت

$$\bar{H}(m, n, r) = \frac{1}{n} \sum_{i=1}^r \log \left\{ \frac{n}{2m} (X_{(i+m)} - X_{(i-m)}) \right\} - \left(1 - \frac{r}{n} \right) \log \left(1 - \frac{r}{n} \right)$$

است، معرفی کرد.

۸-۲ آزمون براساس داده‌های سانسور شده پیشرونده

بالاکریشن، حبیبی و ارقامی (۲۰۰۹) آزمون فوق را به داده‌های سانسور شده پیشرونده تعمیم دادند. آماره این آزمون به صورت زیر است

$$T(w, n, m) = -H(w, n, m) + \frac{m}{n} \left[\log \left(\frac{1}{m} \sum_{i=1}^m (R_i + 1) X_{(i)} \right) + 1 \right]$$

۳ آزمون‌های جدید

۱-۳

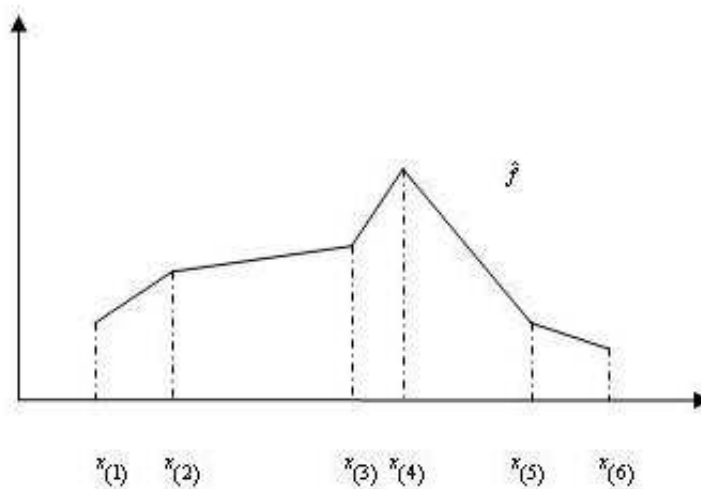
علیزاده (۲۰۱۰) برآوردی شبیه برآورد واسیچک ولی متفاوت از آن برای آنتروپی f به صورت زیر معرفی نمود

$$\hat{H}(f) = -\frac{1}{n} \sum_{i=1}^n \log \frac{\hat{f}(X_{(i+m)}) - \hat{f}(X_{(i-m)})}{2}$$

که در آن \hat{f} برآورد هسته تابع چگالی احتمال f است. وی نشان داد که با این برآورد آزمون نرمالیتی و نمایی بودن از توان بیشتری برخوردارند.

۲-۳

یوسف زاده و ارقامی (۲۰۰۸) برآورد جدیدی برای تابع چگالی احتمال به نام برآورد درستمایی ماکزیمم مقید شده معرفی کردند که در آن $\prod_{i=1}^n f(x_i)$ با شرط پیوسته بودن توزیع (با تابع چگالی احتمال خطی قطعه‌ای) ماکزیمم می‌شود. برآوردهای f و F به ترتیب عبارتند از



$$\hat{F}_n(x) = \begin{cases} 0 & x \leq x_0 \\ \frac{1}{n+1} - \frac{1}{n+1} \frac{x_{(1)} - x}{x_{(1)} - x_{(0)}} & x_0 \leq x \leq x_{(1)} \\ \frac{n-1}{n(n+1)} \left(i + \frac{1}{n-1} + \frac{x - x_{(i-1)}}{x_{(i+1)} - x_{(i-1)}} + \frac{x - x_{(i)}}{x_{(i+2)} - x_{(i)}} \right) & x_{(i)} \leq x \leq x_{(i+1)} \\ \frac{n}{n+1} - \frac{1}{n+1} \frac{x - x_{(n)}}{x_{n+1} - x_{(n)}} & x_{(n)} \leq x \leq x_{n+1} \\ 1 & x \geq x_{n+1} \end{cases}$$

که در آن $x_0 = x_{(1)} - \frac{n}{n-1}(x_{(2)} - x_{(1)})$, $x_{n+1} = x_{(n)} + \frac{n}{n-1}(x_{(n)} - x_{(n-1)})$

$$\hat{f}_i = \frac{\hat{F}_n(X_{(i+m)}) - \hat{F}_n(X_{(i-m)})}{X_{(i+m)} - X_{(i-m)}}$$

که در آن $X_{(1)} \leq \dots \leq X_{(n)}$ آماره‌های مرتب نمونه است و $X_{(i)} = X_{(1)}$ به ازای $i < 1$ و $X_{(i)} = X_{(n)}$ به ازای $i > n$.

آن‌ها بر اساس این برآوردها، آزمون‌های نرمال بودن و نمایی بودن را انجام داده و با شبیه‌سازی نشان دادند که این آزمون‌ها از توان خوبی نسبت به آزمون‌های قبلی برخوردارند.

۳-۳ یک آزمون کلی تر

علیزاده و ارقامی (۲۰۱۰) با تغییر کوچکی در آماره D_{Inf} آزمون کلی جدیدی معرفی کردند. از (۲) داریم

$$\hat{D}_{Inf} = \frac{1}{n} \sum_{i=1}^n \frac{n}{r_m} (X_{(i+m)} - X_{(i-m)}) - \frac{1}{n} \sum_{i=1}^n \log g_{\hat{\theta}}(X_i)$$

اگر در فرمول فوق به جای $g_{\hat{\theta}}(x)$ که مشتق $G_{\hat{\theta}}$ است از تفاضل $G_{\hat{\theta}}$ استفاده کنیم، یعنی اگر D_{Inf} را با $\frac{G_{\hat{\theta}}(X_{(i+m)}) - G_{\hat{\theta}}(X_{(i-m)})}{X_{(i+m)} - X_{(i-m)}}$ برآورد کنیم، برآورد دیگری به صورت زیر برای \hat{D}_{Inf} بدست می آید

$$\hat{D}_{Inf} = -\frac{1}{n} \sum_{i=1}^n \log \left[\frac{G_{\hat{\theta}}(X_{(i+m)}) - G_{\hat{\theta}}(X_{(i-m)})}{\frac{n}{r_m}} \right]$$

بدست می آید. برآورد جدید D_{Inf} به نظر می رسد که از برآورد قبلی بهتر عمل کند زیرا g_{θ} همانند f از یک رابطه تفاضلی به دست می آید و این دو برآورد بیشتر هم آهنگ هستند، مضافاً به اینکه در برآورد جدید $X_{(i+m)} - X_{(i-m)}$ که عامل بی ثباتی \hat{f} است، نیز وجود ندارد.

نتایج شبیه سازی این حدس را تایید می کند، یعنی آزمون نیکویی برازش بر مبنای \hat{D}_{Inf} عموماً از توان های بهتری (به خصوص در مقایسه با آزمون نمایی بودن ابراهیمی و همکاران (۱۹۹۲)) برخوردارند. امتیاز دیگر آزمون های بر مبنای \hat{D}_{Inf} در قضیه زیر بیان می شود.

قضیه ۱ اگر خانواده G_{θ} تحت گروه تبدیلات H پایا باشد، آنگاه \hat{D}_{Inf} نیز تحت همین گروه از تبدیلات پایا است.

(برای اثبات به علیزاده و ارقامی (۲۰۱۰) مراجعه شود)

معنی قضیه فوق این است که برخلاف آزمون های بر مبنای \hat{D}_{Inf} که فقط در خانواده های مکانی-مقاسی کاربرد دارند، آزمون های نیکویی برازش بر مبنای \hat{D}_{Inf} در هر خانواده گروهی کاربرد دارند.

آزمون نیکویی برازش توزیع وایبل

خانواده توزیع‌ها با تابع چگالی $f_\theta(x) = \theta x^{\theta-1} \exp(-x^\theta)$ معروف به خانواده وایبل است. به سادگی معلوم می‌شود که خانواده فوق تحت تبدیلات $Y = X^c$ پایا است. بنابراین اگر آزمون فرضیه $H_0: f \in W(\theta)$ را در مقابل نقیض آن به ازای مقادیر بزرگ \hat{D}_{Inf} رد کند، آماره آزمون به هیچ پارامتر مجهولی بستگی ندارد و می‌توان مقادیر بحرانی آزمون را به ازای $\theta = \theta_0$ (که هر مقدار خاصی از θ می‌تواند باشد) به وسیله شبیه‌سازی بدست آورد.

۳-۴ آزمون نیکویی برازش بر اساس تبدیل متغیرها

علیزاده و ارقامی (۲۰۱۰) با توجه به اینکه تابع چگالی و تابع توزیع $U(0, 1)$ به ترتیب برابر $f_0(x) = x$ و $F_0(x) = x$ است، آماره

$$T_v = \frac{1}{n} \sum_{i=1}^n |x_i \hat{f}(x_i) - F_0(x_i)|$$

را، که در آن

$$\hat{f}(x) = \frac{1}{nh} \sum_{i=1}^n K\left(\frac{x - x_i}{h}\right)$$

برآورد هسته‌ای تابع چگالی احتمال است، برای آزمون یکنواختی توزیع با تکیه‌گاه $[0, 1]$ مورد استفاده قرار دادند. شبیه‌سازی‌ها نشان دادند که گرچه آزمون فوق به‌ازای بعضی از توزیع‌های جانشین بر سایر آزمون‌های یکنواختی از نظر توان، ترجیح دارد اما به خوبی آزمون یکنواختی دادویچ و وندرمولن (۱۹۸۱) نیست. ولی آزمون نمایی بودن که براساس آزمون فوق و به شرح زیر معرفی می‌شود، نسبت به آزمون‌های رقیب به خصوص آزمون نمایی بودن ابراهیمی و همکاران (۱۹۹۲) از توان بسیار بالاتری برخوردار است. فرض کنید که X_1, \dots, X_n یک نمونه تصادفی از توزیع پیوسته با تکیه‌گاه $(0, \infty)$ است. در این صورت الزیاد و الاوش (۱۹۹۲) نشان دادند که هریک از متغیرهای تصادفی

$$Y_{ij} = \frac{X_i}{X_i + X_j} \quad i \neq j$$

دارای توزیع یکنواخت است اگر و تنها اگر توزیع مشترک X_i ها نمایی باشد. علیزاده و ارقامی (۲۰۱۰) از قضیه فوق استفاده کرده و آماره زیر را برای آزمون فرضیه صفر $H_0: X_i \sim \exp(\theta) \quad i = 1, \dots, n$ بر اساس آماره

$$T_E = \frac{1}{n(n-1)} \sum |y_{ij} \hat{f}(y_{ij}) - F_0(y_{ij})|$$

معرفی نمودند و با شبیه‌سازی نشان دادند که این آزمون سازگار است و توان این آزمون به میزان قابل ملاحظه‌ای از توان آزمون نمایی بودن ابراهیمی و همکاران (۱۹۹۲) بیشتر است.

مراجع

- [1] Alizadeh Noughabi, H. and Arghami, N.R. (2010). Testing exponentiality using transformed data, *To appear in Journal of Statistical Computation and Simulation*.
- [2] Alizadeh Noughabi, H. (2010). A new entropy estimator and its application in testing normality, *To appear in Journal of Statistical Computation and Simulation*.
- [3] Alizadeh Noughabi, H. and Arghami, N.R. (2010). General treatment of goodness of fit tests based on kullback-liebler information, *Submitted*.
- [4] Alzaid, A.A. and Al-Osh, M.A (1992). Characterization of probability distributions based on the relation $Y = U(X_1 + X_2)$, *Sankhya*, Ser B **53**, 188-190.
- [5] Arizono, I. and Ohta, H. (1989). A test for normality based on kullback-liebler information, *The American Statistician*, **43**, 20-22
- [6] Balakrishnan, N. and Habibi Rad, A. and Arghami, N.R, (2007). Testing exponentiality Based on Kullback-Leibler information with progressively type II censored data, *IEEE Trans on Rel* **53**, 349-356.
- [7] Choi, B. and Ki, K (2006). Goodness of fit test for laplace distribution based on maximum entropy, *Statistics* **40**, 517-531.
- [8] Dudewicz, E.J and Van der Meulen, E.C. (1981), Entropy-Based Tests of Uniformity, *JASA* **76**, 967-974.

- [9] Ebrahimi, N and Soofi., E.S. and Habibullah, M., (1992), Testing Exponentiality Based on Kullback-Leibler Information , *JRSS*, Ser B, **54**, 739-748.
- [10] Mudholkar, G. S. and Tian, L., (2002) An entropy characterization of the inverse Gaussian distribution and related goodness-of-fit test , *J. Statist. Plan. Infer*, **102**, 211-221.
- [11] Park, S. (2005), Testing Exponentiality Based on the Kullback-Leibler Information With the type II Censored Data , *IEEE Transaction on Reliability*, **54**, 22-26.
- [12] Vasicek, O. (1976), A test for Normality Based on Sample Entropy , *JRSS*, Ser B **38**, 54-59.
- [13] Yousefzadeh F and Arghami, N.R (2008), Testing Exponentiality Based on Type II Censored Data and a New cdf Estimator, *Communications in Statistics-Simulation and Computation* **37**, 1479-1499.