

آزمون نیکویی برآوردهای جدید آنتروپی

احسان زمانزاده
گروه آمار، دانشگاه اصفهان

تاریخ دریافت: ۱۳۹۲/۲/۲۷ تاریخ آخرین بازنگری: ۱۳۹۲/۵/۲۱

چکیده : در این مقاله، ابتدا دو برآوردهای جدید آنتروپی معرفی می‌شود. سپس آزمون نیکویی برآورش فرضیه نمایی بودن توزیع جامعه برمبانی برآوردهای جدید معرفی می‌شود و توان آن‌ها با توان سایر آزمون‌های برمبانی آنتروپی توزیع نمایی مورد مقایسه قرار می‌گیرد. نتایج مطالعات شبیه‌سازی نشان می‌دهد که برآوردهای پیشنهادی عموماً عملکرد بهتری در مقایسه با سایر برآوردهای آنتروپی و آزمون نیکویی برآورش دارند.

واژه‌های کلیدی : آنتروپی، آزمون نیکویی برآورش، فاصله کولبک لایبلر.

۱ مقدمه

فرض کنید X یک متغیر تصادفی پیوسته، با تابع چگالی احتمال $f(x)$ باشد، شانون (۱۹۴۸) آنتروپی این متغیر تصادفی را به صورت

$$H(f) = - \int_{-\infty}^{\infty} \log(f(x))f(x)dx \quad (1)$$

ادرس الکترونیک مسئول مقاله: احسان زمانزاده، E.Zamanzade@sci.ui.ac.ir
کد موضوع‌بندی ریاضی (۲۰۱۰): ۶۲B۱۰، ۶۲G۱۰

تعریف کرد. از آنجا که مفهوم آنتروپی کاربردهای فراوانی در مباحث آماری نظری نظریه اطلاع و آزمون نیکویی برآش دارد، مسئله برآورد $H(f)$ توسط محققین زیادی مورد بررسی قرار گرفته است. واسیچک (۱۹۷۶) برای نخستین بار، آزمون نیکویی برآش برای توزیع نرمال را بر مبنای برآوردهای جدیدی از آنتروپی پیشنهاد داد. نتایج شبیه‌سازی واسیچک نشان می‌داد که آزمون بر مبنای آنتروپی، علی‌رغم سادگی در محاسبه دارای توان‌های بسیار خوبی در مقایسه با آزمون پرتوان شاپیرو-ولیک (۱۹۶۵) برای توزیع نرمال است. از آن به بعد محققین زیادی سعی در بهبود برآوردهای آزمون پیشنهاد شده توسط واسیچک (۱۹۷۶) و تعمیم آن به سایر توزیع‌های آماری داشته‌اند.

واسیچک (۱۹۷۶) نشان داد که می‌توان رابطه (۱) را به صورت

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

بازنویسی کرد و با جایگزینیتابع توزیع F با توزیع تجربی F_n و استفاده از عملگر تفاضل به جای عملگر مشتق، برآوردهای آنتروپی خود را به صورت زیر معرفی کرد. فرض کنید X_1, \dots, X_n نمونه‌ای تصادفی از توزیع پیوسته F باشد، در این صورت برآوردهای آنتروپی واسیچک (۱۹۷۶) عبارتست از

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

که در آن $X_{(1)}, \dots, X_{(n)}$ آماره‌های مرتب، $m = 2m$ و i یک عدد مثبت کوچکتر یا مساوی با $\frac{n}{2}$ است. ضمناً به ازای $1 < i < n$ و به ازای $i > n$ $X_{(i)} = X_{(n)}$ می‌باشد.

واضح است که عبارت داخل لگاریتم در (۲)، هنگامی که $i \leq m$ یا $i \geq n - m$ تقریب مناسبی برای برآورد $\frac{d}{dp} F^{-1}(p)$ نیست. ابراهیمی و همکاران (۱۹۹۴) برآوردهای پیشنهادی خود را بر مبنای اصلاح ضرایب c_i ، هنگامی که $i \leq m$ یا $i \geq n - m$ است، به صورت

$$HE = \frac{1}{n} \sum_{i=1}^n \log\left(\frac{n}{c_i} (X_{(i+m)} - X_{(i-m)})\right) \quad (3)$$

ارائه کردند، که در آن

$$c_i = \begin{cases} m + i - 1, & 1 \leq i \leq m \\ 2m, & m + 1 \leq i \leq n - m \\ m + n - i, & n - m + 1 \leq i \leq n \end{cases}$$

به‌ازای $i < 1$ و $i > n$ $X_{(i)} = X_{(1)}$ است.

نتایج شبیه‌سازی ابراهیمی و همکاران (۱۹۹۴) برای سه توزیع نرمال، نمایی و یکنواخت نشان داد که برآوردگر پیشنهادی آن‌ها اربی و جذر میانگین مرربع خطای کمتری نسبت به برآورد پیشنهادی واسیچک (۱۹۷۶) به‌ازای حجم نمونه ۱۰ و ۲۰ و ۳۰ و مقادیر مختلف m دارد.

کوریا (۱۹۹۵) اصلاح دیگری از برآوردگر واسیچک (۱۹۷۶) ارائه کرد که میانگین مرربع خطای کمتری نسبت به برآورد پیشنهادی توسط واسیچک (۱۹۷۶) داشت. وی توجه کرد که می‌توان رابطه (۲) را به صورت

$$HV_{nm} = -\frac{1}{n} \sum_{i=1}^n \log\left(\frac{\frac{i+m}{n} - \frac{i-m}{n}}{X_{(i+m)} - X_{(i-m)}}\right) \quad (4)$$

بازنویسی کرد. اما عبارت داخل لگاریتم در رابطه (۴) در واقع شبیه خطی است که نقاط $(\hat{F}(X_{(i+m)}), X_{(i+m)})$ و $(\hat{F}(X_{(i-m)}), X_{(i-m)})$ را به یکدیگر متصل می‌کند. او پیشنهاد داد که این شبیب را با استفاده از رگرسیون خطی موضعی برحسب $\{X_{(i-m)}, \dots, X_{(i+m)}\}$ و با استفاده از تمام $1 + 2m$ نقطه، به‌جای تنها دو نقطه، برآورد کنیم. لذا با در نظر گرفتن رابطه

$$F(X_{(j)}) = \alpha + \beta X_{(j)} + \epsilon$$

و برآورد β با روش کمترین توان‌های دوم، برآورد خود را به صورت

$$HC_{nm} = -\frac{1}{n} \sum_{i=1}^n \log(b_i) \quad (5)$$

ارائه کرد، که در آن

$$b_i = \frac{\sum_{j=i-m}^{i+m} (X_{(j)} - \bar{X}_{(i)}) (\frac{j-i}{n})}{\sum_{j=i-m}^{i+m} (X_{(j)} - \bar{X}_{(i)})^2} \quad (6)$$

$X_{(i)} = X_{(n)}$ و به ازای $i < n$ و به ازای $i > n$ و $\bar{X}_{(i)} = \sum_{j=i-m}^{i+m} \frac{X_{(j)}}{m+1}$ می‌باشد.

مطالعه شبیه‌سازی برآوردهای کوریا (۱۹۹۵) و واسیچک (۱۹۷۶) نشان داد که این برآورده عموماً از میانگین توان دوم خطای کمتری نسبت به برآورده واسیچک (۱۹۷۶) در سه توزیع نرمال، نمایی و یکنواخت برخوردار است. کوریا (۱۹۹۵) هیچ مقایسه‌ای میان برآورده پیشنهادی خود، با برآورده پیشنهادی ابراهیمی و همکاران (۱۹۹۴) انجام نداده است.

یوسف‌زاده و ارقامی (۲۰۰۸) برآورده‌گری از آنتروپی بر مبنای برآورده جدیدی ازتابع توزیع جامعه ارائه دادند. آنها ابتدا برآورده‌گری ازتابع توزیع پیوسته به صورت

$$\hat{F}_y(t) = \begin{cases} \frac{n-1}{n(n+1)} \left(\frac{n}{n-1} + \frac{t-X_{(1)}}{X_{(r)}-X_{(1)}} + \frac{t-X_{(1)}}{X_{(r)}-X_{(1)}} \right), & X_{(1)} \leq t \leq X_{(r)} \\ \frac{n-1}{n(n+1)} \left(i + \frac{1}{n-1} + \frac{t-X_{(i-1)}}{X_{(i+1)}-X_{(i-1)}} + \frac{t-X_{(i)}}{X_{(i+1)}-X_{(i)}} \right) & X_{(i)} \leq t \leq X_{(i+1)} \\ \frac{n-1}{n(n+1)} \left(n-1 + \frac{1}{n-1} + \frac{t-X_{(n-1)}}{X_{(n)}-X_{(n-1)}} + \frac{t-X_{(n-1)}}{X_{(n+1)}-X_{(n-1)}} \right) & X_{(n-1)} \leq t \leq X_{(n)} \end{cases} \quad i = 1, \dots, n-2$$

معرفی کردند، که در آن $X_{(n+1)} = X_{(1)} - \frac{n}{n-1}(X_{(2)} - X_{(1)})$ و $X_{(1)} = X_{(n)} + \frac{n}{n-1}(X_{(n)} - X_{(n-1)})$ است. آنگاه برآورده

$$HY = \sum_{i=1}^n \log \left(\frac{X_{(i+m)} - X_{(i-m)}}{\hat{F}_y(X_{(i+m)}) - \hat{F}_y(X_{(i-m)})} \right) \frac{\hat{F}_y(X_{(i+m)}) - \hat{F}_y(X_{(i-m)})}{\sum_{i=1}^n (\hat{F}_y(X_{(i+m)}) - \hat{F}_y(X_{(i-m)}))} \quad (V)$$

را برای برآورده آنتروپی یک متغیر تصادفی پیوسته پیشنهاد دادند، که به ازای $i < n$ $X_{(i)} = X_{(1)}$ و به ازای $i > n$ $X_{(i)} = X_{(n)}$ می‌باشد. سپس در مطالعه شبیه‌سازی نشان دادند برآورده‌گر پیشنهادی آنان، دارای اریبی و میانگین توان دوم خطای کمتری نسبت به برآوردهای واسیچک (۱۹۷۶) و ابراهیمی و همکاران (۲۰۰۴) در سه توزیع نرمال، نمایی و یکنواخت است.

زمان‌زاده و ارقامی (۱۳۸۷)، دو اصلاح مختلف از برآورده کوریا (۱۹۹۵) پیشنهاد دادند: اصلاح اول بر مبنای این ایده بود که در محاسبه مقدار b_i در رابطه (۶)، هنگامی که $m \leq i \leq m+n-1$ یا $i \geq n-m+1$ است تقریب مناسبی برای شبیه خط نیست زیرا در این نقاط بیش از یک بار از $X_{(1)}$ و $X_{(n)}$ استفاده شده است. لذا آنان

اصلاح

$$HCZ_1 = -\frac{1}{n} \sum_{i=1}^n \log(b_i^*), \quad (8)$$

را پیشنهاد دادند، که در آن

$$b_i^* = \frac{\sum_{j=K_1(i)}^{K_1(i)} (X_{(j)} - \tilde{X}_{(i)}) (\hat{F}_n(X_{(j)}) - \tilde{F}_n(j))}{\sum_{j=K_1(i)}^{K_1(i)} (X_{(j)} - \tilde{X}_{(i)})^2}, \quad i = 1, \dots, n$$

$$k_1(i) = \begin{cases} 1, & 1 \leq i \leq m \\ i-m, & i \geq m+1 \end{cases}, \quad k_1(i) = \begin{cases} i+m, & 1 \leq i \leq n-m \\ n, & i \geq n-m+1 \end{cases}$$

\hat{F}_n و \tilde{F}_n برآورده‌گر تابع توزیع تجربی است.

برای دومین اصلاح چون در بهدست آوردن b_i از تعداد مساوی مشاهده استفاده شده است، همه b_i ‌ها از وزن‌های مساوی برخوردارند. اما در محاسبه HCZ_1 وقتی که $i \leq m$ و یا $i \geq n-m+1$ ، از مشاهدات کمتری برای بهدست آوردن b_i استفاده شده است، لذا منطقی به نظر می‌رسد که وزن‌های کمتری به این مشاهدات اختصاص داده شود. بر مبنای این ایده، اصلاح دوم به صورت

$$HCZ_2 = -\sum_{i=1}^n w_i \log(b_i^*) \quad (9)$$

ارائه شد، که در آن $w_i = \frac{\hat{F}(X_{(i+m)}) - \hat{F}_n(X_{(i+m)})}{\sum_{i=1}^n (\hat{F}_n(X_{(i+m)}) - \hat{F}_n(X_{(i+m)}))}$ است. مطالعه شبیه‌سازی

زمان‌زاده و ارقامی (۱۳۸۷) نشان داد که این برآورده‌گرها عملکرد خوبی در مقایسه با برآورده‌های آنتروپی و اسیچک (۱۹۷۶)، ابراهیمی و همکاران (۱۹۴۴) و کوریا (۱۹۹۵) در برآورد آنتروپی و آزمون نیکویی برازش دارند. علیزاده نوقابی و علیزاده نوقابی (۱۳۸۷) به مقایسه آزمون نیکویی برازش با سایر روش‌ها پرداختند و حبیبی‌راد و ارقامی (۱۳۸۶) آزمون تقارن توزیع را بر مبنای آنتروپی پیشنهاد دادند. کولبک و لایسلر (۱۹۵۱)، تابع اطلاع تشخیص^۱ را معرفی کردند، که یک معیار

^۱ Discrimination information function

مهم برای مقایسه دو توزیع است. به این تابع که براساس آنتروپی نیز می‌توان آن را بازنویسی کرد، آنتروپی متقاطع^۲ هم گفته می‌شود. فرض کنید بر مبنای مشاهده $X = x$ ، یکی از دو توزیع F یا G را به عنوان توزیع متغیر تصادفی X ، با تکیه‌گاه S مورد نظر باشد. در این صورت با توجه به قضیه بیز می‌توان نوشت:

$$\log\left(\frac{f(x)}{g(x)}\right) = \log\left(\frac{P(F|x)}{P(G|x)}\right) - \log\left(\frac{P(F)}{P(G)}\right)$$

که در آن $f(\cdot)$ و $g(\cdot)$ توابع چگالی احتمال، $P(\cdot|x)$ احتمال پسین و $P(\cdot)$ احتمال پیشین است، بنابراین $\log\left(\frac{f(x)}{g(x)}\right)$ را که در واقع تفاضل لگاریتم $\frac{P(F|x)}{P(G|x)}$ از لگاریتم $\frac{P(F)}{P(G)}$ است، می‌توان به عنوان میزان اطلاع موجود در مشاهده x ، در پشتیبانی از F در برابر G یا لگاریتم نسبت بخت‌های F نسبت به G تفسیر کرد.

حال اگر مشاهده $X = x$ متعلق به تکیه‌گاه S باشد، آنگاه متوسط اطلاع موجود در این مشاهده، در حمایت از F در مقابل G عبارتست از:

$$D(f, g) = \int \log\left(\frac{f(x)}{g(x)}\right) dF(x).$$

همچنین می‌توان نشان داد که $D(f, g) \geq 0$ و تساوی رخ می‌دهد اگر و تنها اگر $f \stackrel{a.s.}{=} g$

در بخش ۲ برآوردهای جدید آنتروپی به عنوان اصلاح برآوردهای یوسف‌زاده و ارقامی (۲۰۰۸) معرفی می‌شود. سپس در مطالعه‌ای شبیه‌سازی برآوردهای پیشنهادی با سایر برآوردهای آنتروپی مقایسه خواهد شد. در بخش ۳ آزمون نیکویی برآزش برای فرضیه‌های نمایی بودن توزیع جامعه بر اساس برآوردهای جدید آنتروپی معرفی می‌شود و توان این آزمون‌ها با سایر آزمون‌های نمایی بودن توزیع جامعه بر مبنای برآوردهای آنتروپی و اسیچک (۱۹۷۶)، کوریا (۱۹۹۵) یوسف‌زاده و ارقامی (۲۰۰۸) و زمان‌زاده و ارقامی (۱۳۸۷) مقایسه خواهد شد. بحث و نتیجه‌گیری نهایی در بخش ۴ آورده شده است.

^۲ Cross entropy

۲ برآوردهای جدید آنتروپی

همان‌طور که در رابطه (۷) ملاحظه می‌شود، در برآوردهای یوسف‌زاده و ارقامی (۲۰۰۸)، همانند برآوردهای واسیچک (۱۹۷۶)، تنها از نقاط $(\hat{F}_y(X_{(i+m)}), X_{(i+m)})$ استفاده می‌شود و در واقع و $(\hat{F}_y(X_{(i-m)}), X_{(i-m)})$ استفاده می‌شود و در واقع در رابطه (۷) شیب خطی است که این نقاط را به یکدیگر $\frac{X_{(i+m)} - X_{(i-m)}}{\hat{F}_y(X_{(i+m)}) - \hat{F}_y(X_{(i-m)})}$ متصل می‌کند. اما همان‌طور که در برآوردهای کوریا (۱۹۹۵)، استفاده از تمامی نقاط $\{X_{(i-m)}, \dots, X_{(i+m)}\}$ به جای دو نقطه و کاربرد رگرسیون خطی موضعی، منجر به بهبود برآوردهای واسیچک (۱۹۷۶) شد، انتظار می‌رود که این روش، در اینجا نیز منجر به بهبود برآوردهای پیشنهادی یوسف‌زاده و ارقامی (۲۰۰۸) شود. لذا بر مبنای ایده زمان‌زاده و ارقامی (۱۳۸۷) بر مبنای اصلاح برآوردهای کوریا (۱۹۹۵) برآوردهای جدید به صورت

$$HYZ_1 = -\frac{1}{n} \sum_{i=1}^n \log(b_i^{**}), \quad (10)$$

$$HYZ_2 = - \sum_{i=1}^n w_i \log(b_i^{**}), \quad (11)$$

ارائه می‌شوند، که در آن w_i وزن‌های به کار رفته در HYZ_2 ضرایب معرفی شده در (۹) است با این تفاوت که از \hat{F}_y معرفی شده در رابطه (۷) به جای برآوردهای تابع توزیع تجربی استفاده شده است.

قضیه ۱ : فرض کنید X_1, \dots, X_n نمونه‌ای تصادفی از جامعه‌ای با آنتروپی (f) باشد و $Y_i = kX_i$ که در آن $k > 0$ و $i = 1, \dots, n$. همچنین فرض کنید که H^{kX} و HYZ_i^{kX} به ترتیب برآوردهای آنتروپی (f) و (g) باشند، که در آن g تابع چگالی kX است. در این صورت، روابط زیر برقرارند:

الف - $E(HYZ_i^{kX}) = E(HYZ_i^X) + \log(k)$

ب - $V(HYZ_i^{kX}) = V(HYZ_i^X)$

ج - $MSE(HYZ_i^{kX}) = MSE(HYZ_i^X)$

برهان : به سادگی می‌توان نشان داد $b_i^{**}(kX_i) = \frac{b_i^{**}(X_i)}{k}$. بنابراین با توجه به $\sum_{i=1}^n w_i$ نتیجه می‌شود که $i = 1, 2$ $HYZ_i^{kX} = HYZ_i^X + \log(k)$ و برهان قضیه کامل است.

در ادامه با مطالعه شبیه‌سازی، عملکرد برآوردهای پیشنهادی اصلاح شده با برآوردهای واسیچک (۱۹۷۶)، ابراهیمی و همکاران (۱۹۹۴)، کوریا (۱۹۹۵)، یوسفزاده و ارقامی (۲۰۰۸) و زمان‌زاده و ارقامی (۱۳۸۷) بر حسب جذر میانگین توان‌های دوم خطأ مورد مقایسه قرار می‌گیرد.

شایان ذکر است، انتخاب مقدار بهینه m ، که به‌ازای آن میانگین توان‌های دوم مینیمم شود، علاوه بر حجم نمونه (n)، به توزیع جامعه نیز بستگی دارد که در عمل نامعلوم است. ویزورکوسکی و گورزسکی (۱۹۹۹)، مقدار $[m = \sqrt{n} + 0.5]$ را برای برآوردهای آنتروپی پیشنهاد دادند که در آن [.] نماد جز صحیح است.

برای مقایسه برآوردهای مختلف آنتروپی، به‌ازای $m = 10, 20, 30$ تعداد ۱۰۰۰۰ نمونه از توزیع‌های نرم‌الاستاندارد، نمایی با میانگین ۱ و یکنواخت (۰، ۱) تولید و مقدار جذر میانگین توان‌های دوم خطای برآوردهای به‌ازای $m = [\sqrt{n} + 0.5]$ محاسبه شده و نتایج شبیه‌سازی در جدول ۱ ارائه گردیده‌اند. در هر ستون، اعداد ستاره‌دار نشان دهنده آن است که برآوردهای مزبور، دارای کمترین مقدار جذر میانگین توان‌های دوم خطأ است.

همان‌طور که ملاحظه شود، برآوردهای پیشنهادی به طور یکنواخت عملکرد بهتری نسبت به برآوردهای واسیچک (۱۹۷۶)، ابراهیمی و همکاران (۱۹۹۴) و کوریا (۱۹۹۵) در هر سه توزیع و حجم نمونه در نظر گرفته شده دارند. در توزیع نرم‌ال، برآوردهای پیشنهادی عملکرد بهتری نسبت به سایر برآوردهای دارند. در توزیع نمایی و یکنواخت، برآوردهای اول پیشنهادی و برآوردهای یوسفزاده و ارقامی (۲۰۰۸) عملکرد نسبتاً مشابهی دارند. علاوه بر این به‌طور کلی، در حجم نمونه ۱، ۲۰۰۸ برآوردهای اول پیشنهادی و برآوردهای یوسفزاده و ارقامی (۲۰۰۸) بهترین هستند، در حالی که در حجم‌های نمونه ۲۰ و ۳۰ برآوردهای اول سایر برآوردهای نسبتاً بهتر است. همچنین از مقایسه برآوردهای یوسفزاده و ارقامی (۲۰۰۸) با برآوردهای واسیچک (۱۹۷۶) و ابراهیمی و همکاران (۱۹۹۴) ملاحظه می‌شود که برآوردهای

جدول ۱: جذر میانگین توانهای دوم خطای برآوردگرها مختلف آنتروپی

HYZ_2	HYZ_1	HCZ_2	HCZ_1	HY	TC	HE	HV	توزیع	n
۰/۲۸۸*	۰/۲۹۴	۰/۳۵۲	۰/۳۴۵	۰/۳۱۹	۰/۴۶۳	۰/۴۰۶	۰/۶۲۰	$N(0, 1)$	
۰/۳۶۰	۰/۳۶۶	۰/۳۷۸	۰/۳۸۳	۰/۳۵۷*	۰/۴۴۳	۰/۴۶۶	۰/۵۶۶	$Exp(1)$	
۰/۱۷۶	۰/۱۶۸	۰/۱۹۰	۰/۱۹۰	۰/۱۶۶*	۰/۴۹۹	۰/۴۳۲	۰/۴۵۰	$U(0, 1)$	۱۰
۰/۲۷۶*	۰/۲۷۶*	۰/۳۰۶	۰/۳۰۶	۰/۲۸۰	۰/۴۵۱	۰/۴۳۴	۰/۵۴۵	میانگین	
۰/۱۹۴	۰/۱۸۸*	۰/۲۰۳	۰/۲۶۴	۰/۲۱۷	۰/۲۶۴	۰/۲۴۹	۰/۳۶۷	$N(0, 1)$	
۰/۲۳۶*	۰/۲۴۴	۰/۲۴۵	۰/۲۴۷	۰/۲۴۲	۰/۲۷۱	۰/۲۵۲	۰/۳۵۲	$Exp(1)$	
۰/۰۹۸	۰/۰۹۱*	۰/۰۹۲	۰/۰۹۳	۰/۰۹۱*	۰/۱۵۵	۰/۱۳۳	۰/۲۷۳	$U(0, 1)$	۲۰
۰/۱۷۶	۰/۱۷۴*	۰/۱۸۰	۰/۲۰۱	۰/۱۸۳	۰/۲۳۰	۰/۲۱۱	۰/۳۳۳	میانگین	
۰/۱۵۷	۰/۱۴۶*	۰/۱۵۴	۰/۱۹۴	۰/۱۷۷	۰/۱۹۴	۰/۲۰۴	۰/۲۷۹	$N(0, 1)$	
۰/۱۹۵*	۰/۱۹۸	۰/۱۹۶	۰/۱۹۸	۰/۱۹۶	۰/۲۱۱	۰/۲۰۴	۰/۲۹۱	$Exp(1)$	
۰/۰۷۳	۰/۰۶۸	۰/۰۶۵	۰/۰۶۴*	۰/۰۶۶	۰/۱۱۳	۰/۰۹۶	۰/۲۱۰	$U(0, 1)$	۳۰
۰/۱۴۱	۰/۱۳۷*	۰/۱۳۸	۰/۱۵۲	۰/۱۴۶	۰/۱۷۲	۰/۱۶۸	۰/۲۶۰	میانگین	

یوسف‌زاده و ارقامی (۲۰۰۸) به طور یکنواخت عملکرد بهتری نسبت به این برآوردگرها دارد که این مطلب را می‌توان به دلیل استفاده از برآوردگر بهتراز تابع توزیع، توجیه کرد.

۳ آزمون نمایی بودن جامعه

فرض کنید X_n, X_1, \dots, X_1 نمونه‌ای تصادفی با تابع چگالی f باشند. آزمون فرضیه

$$H_0 : f = f_\theta$$

را در نظر بگیرید، که در آن f_θ تابع چگالی توزیع نمایی، با میانگین مشبیت θ است. فاصله نامتقارن کولبک-لاپر f از f_θ عبارت است از

$$D(f, f_\theta) = \int_{-\infty}^{\infty} f(x) \log\left(\frac{f(x)}{f_\theta(x)}\right) d(x),$$

که می‌توان آن را به سادگی به صورت

$$D(f, f_\theta) = -H(X) + \log(\theta) + \frac{1}{\theta} E_f(X), \quad (12)$$

۷۰ آزمون نیکویی برازش توزیع نمایی بر مبنای برآوردهای آنتروپی

بازنویسی کرد، که مینیمم (12) نسبت به θ ، به ازای $(X) = E_f(\theta)$ حاصل می‌شود، لذا داریم:

$$D_{Inf} = Inf_\theta D(f, f_\theta) = -H(X) + \log(E_f(X)) + 1,$$

از طرفی $D_{Inf} = Inf_\theta D(f, f_\theta) = 0$ ، اگر و تنها اگر فرضیه نمایی بودن جامعه درست باشد. بنابراین می‌توان آماره‌های آزمون نمایی بودن جامعه را به صورت

$$TYZ_1 = -HYZ_1 + \log(\bar{X}) + 1, \quad TYZ_2 = -HYZ_2 + \log(\bar{X}) + 1,$$

پیشنهاد کرد و فرضیه نمایی بودن جامعه را به ازای مقادیر بزرگ آماره‌های آزمون رد کرد. توزیع آماره‌های آزمون به روش تحلیلی قابل محاسبه نیستند، بنابراین برای به دست آوردن نقاط بحرانی آزمون‌ها از روش شبیه‌سازی مونت‌کارلو استفاده می‌شود. شایان ذکر است که با اندکی محاسبه می‌توان نشان داد که آماره‌های آزمون فوق نسبت به تبدیلات مقیاسی ناوردا هستند. بنابراین نقاط بحرانی آن‌ها به پارامتر مجھول بستگی ندارد. برای محاسبه نقاط بحرانی ابتدا از توزیع نمایی با میانگین یک، نمونه‌ای به حجم n تولید و مقدار آماره آزمون محاسبه می‌شود. این کار ۱۰۰۰۰ دفعه تکرار می‌شود. مقادیر بحرانی آزمون با استفاده از چندک $\alpha - 1$ توزیع تجربی آماره آزمون به دست می‌آید.

برای مقایسه توان آزمون‌های مختلف آماره‌های آزمون به صورت

$$TV = -HV + \log(\bar{X}) + 1, \quad TC = -HC + \log(\bar{X}) + 1,$$

$$TY = -HY + \log(\bar{X}) + 1, \quad TCZ_1 = -HCZ_1 + \log(\bar{X}) + 1,$$

$$TCZ_2 = -HCZ_2 + \log(\bar{X}) + 1,$$

محاسبه می‌شوند. با شبیه‌سازی مونت‌کارلو و تعداد ۱۰۰۰۰ دفعه تکرار، توان آزمون‌های مختلف نمایی بودن توزیع جامعه تحت ۹ توزیع جانشین مختلف به دست آورده می‌شوند. برای این کار ابتدا تعداد ۱۰۰۰۰ نمونه به حجم‌های $n = 10, 20, 40$ تحت هر یک از توزیع‌های جانشین تولید شده و توان هر یک از آزمون‌ها از طریق، نسبت تعداد دفعاتی که آماره آزمون از مقدار بحرانی آن بیشتر است به کل تعداد تکرارها، برآورد می‌شوند.

برای مقایسه توانها، از توزیع‌های زیر به عنوان توزیع جانشین استفاده کرده‌ایم:

الف- توزیع وایبول با تابع چگالی:

$$f(x; \lambda, \beta) = \beta \lambda^\beta x^{\beta-1} \exp\{-(\lambda x)^\beta\}, \quad \beta > 0, \lambda > 0, x \geq 0;$$

ب- توزیع گاما با تابع چگالی:

$$f(x; \lambda, \beta) = \frac{\lambda x^{\beta-1} \exp\{-\lambda x\}}{\Gamma(\beta)}. \quad \beta > 0, \lambda > 0, x \geq 0;$$

ج- توزیع لگ‌نرمال با تابع چگالی:

$$f(x; \nu, \sigma^2) = \frac{1}{x \sigma \sqrt{2\pi}} \exp\left\{-\frac{1}{2\sigma^2} (\log(x) - \nu)^2\right\}, \quad -\infty < \nu < \infty, \sigma, x > 0;$$

به علاوه از توزیع نمایی مختلط برای مقایسه توان آزمون‌های مختلف استفاده شد اما توان کلیه آزمون‌ها در این خانواده بسیار کم حاصل شد.

توان آزمون‌های برمنای آنتروپی، به مقدار پارامتر m بستگی دارد، و مقدار بهینه m ، یعنی مقداری که به‌ازای آن توان آزمون ماکسیمم شود، علاوه بر حجم نمونه، به توزیع جانشین نیز وابسته است و چون توزیع جانشین در عمل نامعلوم است، نمی‌توان مقداری برای m پیشنهاد داد که به‌ازای آن، توان آزمون برای تمام توزیع‌های جانشینی ماکسیمم شود. به‌همین علت، مقادیر m برای n ‌های مختلف پیشنهاد داده می‌شود که آزمون‌های پیشنهادی دارای توان نسبتاً خوبی در تمام توزیع‌های جانشین باشند. این مقادیر به این صورت به دست آمدند که توان آزمون‌های پیشنهادی به‌ازای تمامی مقادیر $\frac{n}{3} \leq m$ و توزیع‌های جانشین شبیه‌سازی شده‌اند و مقادیری انتخاب شده‌اند که آزمون پیشنهادی دارای توان‌های خوبی برای تمامی توزیع‌های جانشین بوده است. از مقادیر m که در جدول ۲ ارائه شده‌اند برای آزمون‌های پیشنهادی و مقایسه آزمون‌های مختلف استفاده شده است. نتایج شبیه‌سازی مقایسه توان‌های آزمون‌های مختلف نمایی بودن توزیع جامعه در جدول ۲ ارائه شده‌اند. مقادیر ستاره‌دار در هر سطر نشانه آن است که آزمون مزبور، بیشترین توان را در مقایسه با سایر آزمون‌های آن سطر دارد.

ابراهیمی و همکاران (۱۹۹۴) نشان دادند که رابطه

$$HE = HV + \frac{2}{n} \left\{ m \log(m) - \log\left(\frac{(m-1)!}{(2m-1)!}\right) \right\}$$

بین برآوردهای پیشنهادی آنان با برآوردهای واسیچک (۱۹۷۶) برقرار است. لذا توان آزمون بر مبنای برآوردهای آنان با برآوردهای واسیچک (۱۹۷۶) برابر است.

جدول ۲: مقادیر پیشنهادی m برای آزمون نمایی بودن توزیع جامعه بر مبنای TYZ_1 و TYZ_2 ، به ازای مقادیر مختلف n

m	n
۲	$n \leq 8$
۳	$9 \leq n \leq 15$
۴	$16 \leq n \leq 35$
۵	$36 \leq n \leq 70$
۶	$71 \leq n \leq 100$
۷	$101 \leq n \leq 200$

همان طور که در جدول ۳ ملاحظه می شود. هیچ یک از هفت آزمون به ازای هر سه توزیع جانشینی توان بیشتری نسبت به سایرین ندارند. اما آزمون های مبتنی بر برآوردهای واسیچک (۱۹۷۶)، برآوردهای دوم زمان زاده و ارقامی (۱۳۸۷) و برآوردهای دوم پیشنهادی توان های بهتری نسبت به سایر آزمون ها دارد. در حجم نمونه ۱۰، در توزیع های جانشینی از خانواده گاما و وایبول TYZ_2 و TCZ_2 بهترین آماره های آزمون هستند و در حالی که در خانواده توزیع لگنرمال، آماره آزمون واسیچک بهترین است. در حجم های نمونه بزرگ تر هنگامی که توزیع جانشینی، از خانواده گاما و وایبول است، آزمون مبتنی بر TYZ_2 عملکرد بهتری نسبت به سایر آزمون ها دارد در حالی که اگر توزیع جانشینی متعلق به خانواده لگنرمال باشد، آزمون مبتنی بر آماره TV بهترین است. به هر حال، در حجم نمونه کم آزمون مبتنی بر TCZ_2 و در حجم های نمونه متوسط و بزرگ آزمون مبتنی بر TYZ_2 در بیشتر حالات عملکرد بهتری نسبت به سایر آزمون ها دارد. بنابراین هیچ اطلاعاتی نسبت به توزیع جانشین نداشته باشیم، استفاده از این آزمون ها در عمل توصیه می شود. نکته جالب توجه این است که با اینکه برآوردهای واسیچک (۱۹۷۶) عملکرد خوبی در برآورد آنتروپی در

جدول ۳: توان آزمون‌های نمایی بودن به‌ازای ۰/۰۵

TYZ_2	TYZ_1	TY	TCZ_2	TCZ_1	TC	TV	توزيع جانشین	n
۰/۳۴۳	۰/۲۲۹	۰/۳۳۳	۰/۳۰۰*	۰/۳۱۹	۰/۳۳۲	۰/۳۲۵	$G(2, 2)$	
۰/۶۷۳*	۰/۶۴۶	۰/۶۵۷	۰/۶۶۹	۰/۶۱۶	۰/۶۳۶	۰/۶۳۴	$G(3, 3)$	
۰/۸۵۸	۰/۲۲۹	۰/۸۴۳	۰/۸۵۸	۰/۸۱۱	۰/۸۳۰	۰/۸۷۲*	$G(4, 4)$	
۰/۷۲۶	۰/۷۰۱	۰/۷۰۷	۰/۷۳۲*	۰/۶۸۲	۰/۷۰۲	۰/۶۹۰	$W(2, \Gamma(1 + \frac{1}{\gamma}))$	
۰/۹۹۰*	۰/۹۸۴	۰/۹۸۵	۰/۹۸۷	۰/۹۷۷	۰/۹۸۳	۰/۹۸۲	$W(2, \Gamma(1 + \frac{1}{\gamma}))$	۱۰
۰/۹۹۹*	۰/۹۹۹*	۰/۹۹۹*	۰/۹۹۹*	۰/۹۹۹*	۰/۹۹۹*	۰/۹۹۹*	$W(2, \Gamma(1 + \frac{1}{\gamma}))$	
۰/۱۲۶	۰/۱۴۴	۰/۱۷۰	۰/۱۳۳	۰/۱۳۷	۰/۱۴۱	۰/۱۰۴*	$LN(-2, 2)$	
۰/۴۴۷	۰/۴۹۲	۰/۵۱۶	۰/۴۹۹	۰/۴۹۹	۰/۵۰۱	۰/۵۹۱*	$LN(-\frac{1}{\gamma}, 2)$	
۰/۷۱۴	۰/۷۵۸	۰/۷۶۷	۰/۷۱۷	۰/۷۵۷	۰/۷۵۷	۰/۸۱۵*	$LN(-\lambda, 2)$	
۰/۶۱۸*	۰/۵۱۸	۰/۵۸۳	۰/۵۷۸	۰/۴۷۷	۰/۴۹۷	۰/۵۰۴	$G(2, 2)$	
۰/۹۴۵*	۰/۹۹۱	۰/۹۳۵	۰/۹۲۸	۰/۸۵۸	۰/۸۷۷	۰/۸۹۰	$G(3, 3)$	
۰/۹۹۵*	۰/۹۸۳	۰/۹۹۳	۰/۹۹۱	۰/۹۷۰	۰/۹۷۷	۰/۹۸۳	$G(4, 4)$	
۰/۹۶۴*	۰/۹۳۲	۰/۹۵۶	۰/۹۶۱	۰/۹۱۸	۰/۹۲۹	۰/۹۳۲	$W(2, \Gamma(1 + \frac{1}{\gamma}))$	
۱/۰۰۰*	۱/۰۰۰*	۱/۰۰۰*	۱/۰۰۰*	۰/۹۹۹	۰/۹۹۹	۰/۹۹۹	$W(2, \Gamma(1 + \frac{1}{\gamma}))$	۲۰
۱/۰۰۰*	۱/۰۰۰*	۱/۰۰۰*	۱/۰۰۰*	۱/۰۰۰*	۱/۰۰۰*	۱/۰۰۰*	$W(2, \Gamma(1 + \frac{1}{\gamma}))$	
۰/۶۱۲	۰/۰۸۰	۰/۶۶۵	۰/۶۱۲	۰/۵۷۸	۰/۵۸۳	۰/۶۰۴*	$LN(-2, 2)$	
۰/۹۴۹	۰/۹۵۰	۰/۹۵۰	۰/۹۴۸	۰/۹۴۹	۰/۹۴۸	۰/۹۸۷*	$LN(-\frac{1}{\gamma}, 2)$	
۰/۹۹۴	۰/۹۹۵	۰/۹۹۷	۰/۹۹۳	۰/۹۹۵	۰/۹۹۵	۰/۹۹۹*	$LN(-\lambda, 2)$	
۰/۱۴۹*	۰/۷۵۴	۰/۸۴۴	۰/۸۴۴	۰/۷۴۶	۰/۷۳۱	۰/۷۵۵	$G(2, 2)$	
۰/۹۹۸*	۰/۹۹۱	۰/۹۹۸*	۰/۹۹۷	۰/۹۹۰	۰/۹۸۸	۰/۹۹۱	$G(3, 3)$	
۱/۰۰۰*	۱/۰۰۰*	۱/۰۰۰*	۱/۰۰۰*	۰/۹۹۹	۱/۰۰۰*	۱/۰۰۰*	$G(4, 4)$	
۰/۹۹۹*	۰/۹۹۸	۰/۹۹۹*	۰/۹۹۹*	۰/۹۹۷	۰/۹۹۷	۰/۹۹۷	$W(2, \Gamma(1 + \frac{1}{\gamma}))$	
۱/۰۰۰*	۱/۰۰۰*	۱/۰۰۰*	۱/۰۰۰*	۱/۰۰۰*	۱/۰۰۰*	۱/۰۰۰*	$W(2, \Gamma(1 + \frac{1}{\gamma}))$	۳۰
۱/۰۰۰*	۱/۰۰۰*	۱/۰۰۰*	۱/۰۰۰*	۱/۰۰۰*	۱/۰۰۰*	۱/۰۰۰*	$W(2, \Gamma(1 + \frac{1}{\gamma}))$	
۰/۹۶۴	۰/۹۵۳	۰/۹۷۱*	۰/۹۶۲	۰/۹۵۲	۰/۹۵۳	۰/۹۶۷	$LN(-2, 2)$	
۰/۹۹۹	۰/۹۹۹	۱/۰۰۰*	۰/۹۹۹	۰/۹۹۹	۰/۹۹۹	۱/۰۰۰*	$LN(-\frac{1}{\gamma}, 2)$	
۱/۰۰۰*	۱/۰۰۰*	۱/۰۰۰*	۱/۰۰۰*	۱/۰۰۰*	۱/۰۰۰*	۱/۰۰۰*	$LN(-\lambda, 2)$	

مقایسه با سایر برآوردهای آنتروپی ندارد اما آزمون نیکویی برازش توزیع برمنای این برآوردهای آنتروپی توان‌های نسبتاً خوبی دارد و در برخی از موارد (توزیع لگ‌نرمال) بهترین است.

بحث و نتیجه‌گیری

دو برآوردهای جدید آنتروپی برمنای اصلاح برآوردهای یوسف‌زاده و ارقامی (۲۰۰۸) پیشنهاد گردید. در مطالعه شبیه‌سازی مقایسه عملکرد برآوردهای نشان داد که برآوردهای پیشنهادی به طور یکنواخت از برآوردهای واسیچک (۱۹۷۶)،

ابراهیمی و همکاران (۱۹۹۴) و کوریا (۱۹۹۵) بهتر هستند و همچنین عملکرد خوبی نسبت به سایر برآوردهای آنتروپی دارند. مقایسه توان آزمون‌های نمایی بودن جامعه بیانگر آن است که آزمون‌های بر مبنای برآوردهای واسیچک (۱۹۷۶)، برآوردهای دوم زمان‌زاده و ارقامی (۱۳۸۷) و برآوردهای دوم پیشنهادی در توزیع‌های مختلف جانشین بهترین آزمون‌ها هستند، هرچند به طور کلی بر حجم نمونه کوچک آزمون مبتنی بر $T CZ_2$ و در حجم‌های نمونه متوسط و بزرگ آزمون مبتنی بر $TY Z_2$ بهتر از سایر آماره‌های آزمون است.

لازم به ذکر است که انتخاب مقدار بهینه پارامتر m در برآورد آنتروپی و آزمون نیکویی برآذش مرتبط با آن و بررسی رفتار مجانبی برآوردهای کوریا و اصلاحات آن نیازمند مطالعات جدید است.

تقدیر و تشکر

نویسندهای از پیشنهادات داوران محترم که باعث اصلاحات سازنده در این مقاله شده است، کمال تشکر و سپاسگزاری را دارند.

مراجع

حیبی‌راد، آ.، ارقامی، ن. ر. (۱۳۸۶)، آزمون متقاضیان بودن توزیع براساس آنتروپی، مجله علوم آماری، جلد ۱، ۱۰۹-۱۲۰.

زمان‌زاده، ا.، ارقامی، ن. ر. (۱۳۸۷)، آزمون نیکویی برآذش توزیع‌های نرم‌آل و نمایی بر مبنای برآوردهای جدید آنتروپی، مجله علوم آماری، جلد ۲، ۱۷۹-۲۰۰.

علیزاده نوقابی، ه.، علیزاده نوقابی، ر. (۱۳۸۷)، مقایسه توان آزمون‌های نیکویی برآذش بر مبنای آنتروپی با سایر روش‌ها، مجله علوم آماری، جلد ۲، ۹۷-۱۱۳.

Ebrahimi, N., Habibullah, M. and Soofi, E. (1994), Two Measures of Sample Entropy, *Statistics and Probability Letters*, **20**, 225-234.

- Correa, J. C. (1995), A New Estimator of Entropy, *Communications in Statistics Theory and Methods*, **24**, 2439-2449.
- Kullback, S. and Leibler, R. A. (1951), On Information and Sufficiency, *The Annals of Mathematical Statistics*, **22**, 79-86.
- Shanon, C. E. (1948), A Mathematical Theory of Communicatiois, *Bell System Thechnical Journal*, **27**, 379-423; 623-656.
- Shapiro, S. S. and Wild, M. B. (1965), An Analysis of Variance Test for Normality (Complete Sample), *Biometrika*, **52**, 591-611.
- Vasicek, O. (1976), A Test fo Normality Based on Sample Entropy, *Journal of Royal Statistical Society, B*, **38**, 54-59.
- Wieczorkowski, P. and Grzegorzewsky, P. (1999), Entropy Estimator Improvements and Comparisons, *Communications in Statistics-Computation and Simulation*, **28**, 541-567.
- 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.