

شواهد آماری^۱

قسمت دوم^۲ : قانون درستنماهی و معایب p-مقدار

به عنوان معیار پشتیبانی داده‌ها از فرضیه صفر

ناصر رضا ارقامی^۳ ، علی دست برآورده^۴ ، احسان زمان زاده^۵

چکیده:

همان‌گونه که در مقاله اول [۱] به آن اشاره شد، در این مقاله ابتدا عدم مشروعیت و مناسبت استفاده شواهدی از p-مقدار مورد بررسی قرار می‌گیرد. سپس بر مبنای قانون درستنماهی به معرفی معیاری مناسب و منطقی به منظور استفاده شواهدی از داده‌ها پرداخته می‌شود.

واژه‌های کلیدی: شواهد آماری، معیار پشتیبانی، p-مقدار، قانون درستنماهی.

۱ مقدمه

مناسب و منطقی به منظور استفاده شواهدی از داده‌ها p-مقدار یکی از پرکاربردترین مفاهیم در تحلیل آماری است. تقریباً در همه نرم افزارهای تحلیل آماری برای ارائه نتایج آزمون فرضیه‌ها از p-مقدار استفاده می‌کنند.

با وجود قاعده کلی و ساده‌ای که p-مقدار در انجام آزمون فرضیه‌ها ارائه می‌دهد، کاربران غیرمتخصص، اغلب آن را مورد استفاده و تفسیر نادرست قرار می‌دهند. در این مقاله ضمن ارائه تعریفی دقیق و کاملاً کلی از p-مقدار، معایب استفاده از p-مقدار به عنوان معیار پشتیبانی داده‌ها از فرضیه صفر مورد بررسی قرار می‌گیرد. سپس بر مبنای قانون درستنماهی به معرفی معیاری

۲ تعریف p-مقدار

تعریف ۱ فرض کنید $X \sim P_\theta$ ، $\theta \in \Theta$ و C کلاسی از آزمون‌ها (توابع آزمون) برای آزمون فرضیه $\theta \in \Theta_0$ باشد. در این صورت در مقابل فرضیه $\theta_1 \in \Theta_1$ باشد. در این صورت کلاس C را کامل^۶ گوییم، هرگاه در شرط زیر صدق کند:

$$\forall \alpha \in [0, 1] \quad \exists \varphi_\alpha \in C \quad s.t. \quad \alpha = \sup_{\theta \in \Theta_0} E_\theta(\varphi_\alpha(X)).$$

^۱ Statistical Evidence

^۲ مقاله دوم از سری مقاله‌هایی که طی آنها روش درست اندازه‌گیری میزان شواهد موجود در داده‌ها مورد بررسی قرار می‌گیرد.

^۳ استاد گروه آمار دانشگاه فردوسی

^۴ دانشجوی دکتری آمار دانشگاه فردوسی مشهد

^۵ دانشجوی دکتری آمار دانشگاه فردوسی مشهد

^۶ Complete

مشاهده شده x بر اساس کلاس C عبارت است از:

$$\hat{p}(x) = \inf \{ \alpha | E_\theta(\varphi(x)) \leq \alpha \quad \forall \theta \in \Theta \},$$

$$\varphi(x) = 1, \quad \varphi \in C\}.$$

و در حالتی که برای مشاهده x ، مجموعه

$$A = \{ \alpha | E_\theta(\varphi(X)) \leq \alpha \quad \forall \theta \in \Theta \},$$

$$\varphi(x) = 1, \quad \varphi \in C\}. \quad (1)$$

تهی باشد تعریف می‌کنیم:

$$\hat{p}(x) = 1.$$

به عبارت دیگر، p -مقدار کوچک‌ترین سطح آزمونی است که در آن مشاهده حاصل از نمونه با احتمال یک منجر به رد فرضیه صفر می‌شود.

نکته ۱ با توجه به این که اندازه‌ی آزمون کوچک‌ترین سطح آزمون است، اگر به جای سطح آزمون از اندازه‌ی آزمون جهت محاسبه p -مقدار استفاده شود تغییری در p -مقدار حاصل به وجود نمی‌آید. به عبارت دیگر، p -مقدار را به طور معادل می‌توان براساس اندازه آزمون تعریف کرد؛ یعنی

$$\hat{p}(x) = \inf \{ \alpha | \alpha = \sup_{\theta \in \Theta} E_\theta(\varphi_\alpha(X)) \},$$

$$\varphi_\alpha(x) = 1, \quad \varphi_\alpha \in C\}.$$

به عبارت دیگر، یک کلاس از آزمون‌ها را کامل می‌گوییم، هرگاه برای هر $1 \leq \alpha \leq \circ$ حداقل یک آزمون در اندازه α در این کلاس موجود باشد.

تعریف ۲ فرض کنید $X \sim P_\theta$ و $\theta \in \Theta$ کلاسی از آزمون‌ها برای فرضیه $H_0 : \theta \in \Theta$ در مقابل فرضیه $H_1 : \theta \in \Theta_1$ باشد. در این صورت، کلاس C را تو در تو^۷ می‌گوییم، هرگاه در شرط زیر صدق کند:

$$\alpha_1 < \alpha_2, \quad \varphi_{\alpha_1}, \varphi_{\alpha_2} \in C \Rightarrow \forall x \in S_X \quad \varphi_{\alpha_1}(x) \leq \varphi_{\alpha_2}(x).$$

که در آن S_X تکیه‌گاه متغیر تصادفی X است. در حالت خاص، اگر C کلاسی از آزمون‌های غیر تصادفی باشد، آنگاه به جای شرط فوق به طور معادل می‌توان نوشت:

$$\alpha_1 < \alpha_2 \Rightarrow R_{\alpha_1} \subseteq R_{\alpha_2}$$

که در آن R_α ناحیه‌ی رد آزمون در اندازه α است.

ثابت می‌شود کلاس آزمون‌های MP که در آن توزیع $f_1(x)/f_0(x)$ تحت فرضیه ساده H_0 پیوسته است همواره تو در تو خواهد بود. اما، اگر توزیع $f_1(x)/f_0(x)$ تحت فرضیه H_1 پیوسته نباشد لزومی ندارد که حتی کلاس آزمون‌های MP نیز تو در تو باشد. اما، در چارچوب لم نیمن-پرسون همواره زیرکلاسی از آزمون‌های MP وجود دارد که تو در تو باشد [۵].

تعریف ۳ فرض کنید $X \sim P_\theta$ و $\theta \in \Theta$ کلاسی از آزمون‌های تو در تو برای فرضیه $H_0 : \theta \in \Theta$ در مقابل $H_1 : \theta \in \Theta_1$ باشد، آنگاه p -مقدار به ازای مقدار

Nested^۷

در نتیجه، بر مبنای p -مقدار از آن جا که $1/0 < \hat{p}(3)$ با مشاهده $x = 3$ فرضیه صفر در سطح معنی داری $1/0$ رد می شود، در حالی که بر مبنای آزمون MP ای

$$\Pr_{p=1/0}(x) = \begin{cases} 1 & x = 2 \\ 0 & x = 1, 3 \end{cases}$$

مشاهده $x = 3$ در سطح معنی داری $1/0$ منجر به رد فرضیه صفر نمی شود.

۳ p-مقدار به عنوان معیار پشتیبانی داده ها از فرضیه صفر

با توجه به این که رد فرضیه صفر در سطح معنی داری کوچک تر حاکی از شواهد مقاعده کننده تری بر نادرستی فرضیه صفر می باشد، بنابراین p -مقدار کوچک تر حاکی از شواهد قوی تری بر نادرستی فرضیه صفر خواهد بود. لذا می توان p -مقدار را به عنوان معیاری برای پشتیبانی داده ها از فرضیه صفر در نظر گرفت (برای شرح بیشتر به مرجع [۲] می توان مراجعه کرد)؛ هر چند در ادامه نشان خواهیم داد که p -مقدار برای این کار ابزار مناسبی نیست.

۴ معایب p-مقدار به عنوان معیار پشتیبانی داده ها

اشکالاتی که بر p -مقدار (به عنوان معیار پشتیبانی از فرضیه صفر در مقابل فرضیه جانشین) وارد است،

عبارتند از:

نکته ۲ گرچه در تعریف p -مقدار، کامل نبودن کلاس آزمون ها اشکال منطقی (جهت ارائه نتیجه آزمون) ایجاد نمی کند؛ اما، منطقی تر این است که برای محاسبه p -مقدار، کلاس آزمون ها کامل باشد. علاوه بر این، اگر کلاس آزمون ها کامل باشد، آنگاه مجموعه A در رابطه (۱) هیچ کاه تهی نخواهد بود.^۸

نکته ۳ پرسش اساسی که مطرح می شود این است که چرا تو در تو بودن کلاس آزمون ها برای تعریف p -مقدار الزامی است. در جواب می توان این گونه بیان کرد: به صرف اینکه p -مقدار کوچک ترین سطح آزمونی است که در آن مشاهده حاصل از نمونه با احتمال یک منجر به رد فرضیه صفر می شود، نمی توان مطمئن بود که برای یک سطح آزمون بزرگ تر از p -مقدار نیز الزاماً فرضیه صفر با احتمال یک رد شود. اما تودرتو بودن کلاس آزمون ها این مطلب را تضمین می کند. برای درک بهتر موضوع به مثال زیر توجه کنید. در این مثال، تناقضی که عدم تو در تو بودن کلاس آزمون ها موجب می شود به خوبی نشان داده شده است.

مثال ۱ فرض کنید X متغیر تصادفی باشد که مقادیر $1, 2, \text{ و } 3$ را با احتمال های $1/0, 1/0, \text{ و } 1/0$ تحت فرضیه H_0 و احتمال های $1/0, 2/0, \text{ و } 1/0$ را تحت فرضیه H_1 اختیار می کند. براساس کلیه آزمون های MP برای مشاهده $x = 3$, p -مقدار آزمون عبارت است از

$$\hat{p}(3) = \inf \{\alpha | \varphi_\alpha(3) = 1\} = 0/05$$

^۸ در ادامه هرگاه سخن از p -مقدار شود منظور p -مقداری است که براساس کلاس کاملی از آزمون های تو در تو به دست آمده است

H_1 بسیار کم است اما در مقایسه با فرضیه H_0 بسیار محتمل تر است. لذا این مشاهده از فرضیه H_0 پشتیبانی بسیار بیشتری می‌کند (نادرستی قانون احتمال کم) (برای شرح بیشتر به مرجع [۸] مراجعه شود).

(۲) وابستگی به فضای نمونه (عدم وابستگی صرف به داده‌های مشاهده شده) یکی از ویژگی‌های مطلوب یک معیار پشتیبانی عدم وابستگی آن به فضای نمونه است. به عبارت دیگر، معیار پشتیبانی باید تنها به داده‌های مشاهده شده بستگی داشته باشد و نه به داده‌هایی که مشاهده نشده‌اند. p -مقدار به عنوان یک معیار پشتیبانی فاقد این ویژگی مهم است.

مثال ۳ فرض کنید دستگاهی داریم که فشار هوا در آن دارای توزیع نرمال با میانگین θ و واریانس $H_0 : \theta = 100$ است و می‌خواهیم فرضیه $H_1 : \theta = 80$ را در مقابل $H_1 : \theta = 85$ آزمون کنیم. برای سنجش فشار هوای دستگاه از فشارسنجی استفاده می‌کنیم که در فشار بالاتر از 100 از کار می‌افتد. در این صورت، فشار هوایی که فشارسنج نشان می‌دهد دارای توزیع نرمال $N(\theta, 100)$ ، بریده شده در نقطه 100 خواهد بود. حال فرض کنید $x = 90$ را مشاهده کرده‌ایم. بنابراین p -مقدار عبارت است از

$$\hat{p}(90) = P_{H_0}(X \geq 90) = \frac{\Phi(2) - \Phi(1)}{\Phi(2)}.$$

(۱) اتكای p -مقدار به قانون نادرست احتمال کم در مقاله قبل به تفصیل به بیان قانون احتمال کم و چرایی نادرستی آن پرداختیم، اولین ایرادی که به p -مقدار وارد است اتكای این معیار به قانون احتمال کم می‌باشد. برای درک بهتر این مطلب، مثال زیر را در نظر گیرید.

مثال ۲ فرض کنید $x = 16$ یک تک مشاهده از متغیر تصادفی X با توزیع دوجمله‌ای $bin(40, p)$ باشد. می‌خواهیم میزان پشتیبانی داده‌ها از فرضیه $H_0 : p = \frac{1}{4}$ را در مقابل فرضیه $H_1 : p = \frac{3}{4}$ تعیین کنیم. p -مقدار حاصل عبارت است از:

$$\hat{p}(16) = P\left(X \geq 16 | p = \frac{1}{4}\right) \approx 0.026$$

حال اگر بخواهیم از p -مقدار فوق استفاده شوahدی بکنیم به این نتیجه می‌رسیم که مشاهده $x = 16$ قویاً از فرضیه H_1 پشتیبانی می‌کند. اما به طور منطقی و شهودی انتظار می‌رود که مشاهدات کمتر از 20 از فرضیه H_1 بیشتر از فرضیه H_0 پشتیبانی کنند، که p -مقدار خلاف این مطلب را نشان می‌دهد. همچنین اگر در این مثال H_0 نسبت احتمال مشاهده $x = 16$ تحت فرضیه H_1 به احتمال این مشاهده تحت فرضیه H_0 (نسبت درستنمایی) را محاسبه کنیم، خواهیم داشت:

$$\frac{P(X = 16 | H_0)}{P(X = 16 | H_1)} = 38$$

همان‌طور که ملاحظه می‌شود با وجود اینکه احتمال رخ دادن مشاهده $x = 16$ تحت فرضیه

در مقابل فرضیه $H_1 : p = \frac{3}{4}$ تعیین کنیم. فرض کنید در یک تحقیق از ۱۴ مورد مشاهده شده، ۶ مورد ویژگی مورد نظر را دارند. ابتدا فرض کنید که این مشاهده‌ها چنین به دست آمده که از یک نمونه تصادفی انتخاب شده به حجم ۱۴ از جامعه، ۶ مورد دارای ویژگی مورد نظر هستند، در این صورت اگر متغیر تصادفی X تعداد واحدهایی از نمونه باشند که دارای ویژگی مورد نظراند، آنگاه X دارای توزیع دوجمله‌ای $bin(14, \theta)$ است. بنابراین میزان پشتیبانی داده‌ها از فرضیه H_0 در مقابل فرضیه H_1 بر اساس معیار p-مقدار عبارت است از:

$$\hat{p}(1) = P_{H_0}(X \geq 6) \approx 0.788$$

بار دیگر فرض کنید که نمونه‌گیری از جامعه را تا آن جا ادامه داده‌ایم که ۶ مورد از واحدهای نمونه دارای ویژگی موردنظر باشند و چهاردهمین نمونه به دست آمده، ششمین نمونه دارای ویژگی موردنظر است؛ در این صورت، متغیر تصادفی Y ، تعداد نمونه‌های لازم تا مشاهده ۶ مورد دارای ویژگی موردنظر، دارای توزیع دوجمله‌ای منفی $Nbin(6, \theta)$ است. بنابراین میزان پشتیبانی داده‌ها از فرضیه H_0 در مقابل فرضیه H_1 بر اساس معیار p-مقدار عبارت است از:

$$\hat{p}(14) = P_{H_0}(Y \geq 14) \approx 0.29$$

همان‌طور که ملاحظه می‌شود میزان پشتیبانی داده‌ها از فرضیه H_0 در مقابل فرضیه H_1 بر اساس

در حالی که اگر ما از خراب بودن فشارسنج مطلع نباشیم، p-مقدار به صورت

$$\hat{p}(90) = P_{H_0}(X \geq 90) = 1 - \Phi(1).$$

محاسبه می‌شود. در این مثال بدیهی است که تفسیر مشاهده $90 = x$ ، نباید تحت تأثیر خرابی دستگاه باشد؛ چون $100 < 90$ است. ولی همان‌طور که مشاهده شد p-مقدار به خرابی دستگاه بستگی دارد و این نشان می‌دهد که p-مقدار به فضای نمونه بستگی دارد.

(۳) بستگی داشتن به قاعده توقف نمونه‌گیری به طور کلی استنباط ما در مورد جامعه نباید به قاعده توقف نمونه‌گیری^۹ بستگی داشته باشد، برای درک بهتر حالتی را در نظر گیرید که متغیرهای تصادفی مستقل و هم‌توزیع پی‌درپی مشاهده می‌شوند، آیا اگر این متغیرها بدانند که چه برنامه‌ای برای متوقف کردن طرح نمونه‌گیری داریم، مقادیرشان را تغییر می‌دهند؟ مسلماً خیر. پس نوع و مقدار اطلاعی که در مقادیر مشاهده شده وجود دارد به قاعده توقف بستگی ندارد و بنابراین استنباط ما نیز نباید به قاعده توقف بستگی داشته باشد (برای شرح بیشتر به مرجع [۸] مراجعه شود).

مثال ۴ فرض کنید که θ نسبت یک ویژگی در جامعه باشد. همچنین فرض کنید می‌خواهیم میزان پشتیبانی داده‌ها را از فرضیه $H_0 : p = \frac{1}{4}$

⁹ Stopping rule

به طور کلی روش‌هایی که به فضای نمونه و یا قاعده توقف بستگی دارند در اصل درستنایی صدق نمی‌کنند.

(۵) فرضیه جانشین در p —مقدار نقش ثانویه دارد.
فرضیه جانشین در p —مقدار تنها در جهت تعیین شواهد آماری ایفای نقش می‌کند و تأثیری در تعیین شدت شواهد آماری ندارد.

مثال (۵) فرض کنید که $x = 0/75$ یک تک مشاهده از توزیع نرمال $N(\theta, 1)$ باشد، در این صورت منطقی به نظر می‌رسد که p -مقدار فرضیه $H_1 : \theta = 0^\circ$ در مقابل $H_0 : \theta = 100^\circ$ در خیلی بیشتر از p —مقدار فرضیه $H_1 : \theta = 0^\circ$ در مقابل $H_0 : \theta = 1^\circ$ باشد، اما p -مقدار این دو آزمون مساوی و برابر است با

$$\hat{p}(0/75) = P(X > 0/75 | \theta = 0^\circ) \approx 0/227.$$

(۶) p -مقدار نسبت به H_1 و H_0 متقارن نیست. یکی دیگر از ویژگی‌های مطلوب یک معیار پشتیبانی متقارن بودن آن نسبت به فرضیه‌های H_1 و H_0 است؛ به این معنی که با عوض شدن نقش فرضیه‌ها به عنوان فرضیه صفر یا فرضیه جانشین، میزان پشتیبانی داده‌ها از هر فرضیه تغییر نکند. بنابراین انتظار می‌رود که اگر \hat{p}_1 ، p -مقدار حاصل از آزمون فرضیه H_1 در مقابل H_0 و \hat{p}_0 ، p -مقدار حاصل از آزمون فرضیه H_0 در مقابل

معیار p —مقدار در دو آزمایش فوق با یکدیگر متفاوت است؛ در صورتی که داده‌های مشاهده شده در هر دو مورد یکی است. و این نشان می‌دهد که p —مقدار به قاعده توقف نمونه‌گیری بستگی دارد.

(۴) صدق نکردن در اصل درستنایی اصل درستنایی^{۱۰} که مورد قبول غالب قریب به اتفاق آماردانان، به عنوان یک اصل در استنباط آماری است، بیان می‌کند:

فرض کنید که $L_1(\theta)$ تابع درستنایی حاصل از مشاهده x از آزمایش E_1 و $L_2(\theta)$ تابع درستنایی حاصل از مشاهده y از آزمایش E_2 باشد که θ پارامتر مشترک در هر دو آزمایش است. اگر $L_1(\theta)/L_2(\theta)$ به θ بستگی نداشته باشد، آنگاه هرگونه استنباط در مورد θ از x و y باید یکسان باشد [۳].

به عبارت دیگر، اگر $L_1(\theta)/L_2(\theta)$ به θ بستگی نداشته باشد، در حقیقت میزان اطلاع مشاهده‌های x و y در مورد θ یکسان است. بنابراین منطقی به نظر می‌رسد که استنباط بر اساس x و y برای θ یکسان باشد.

اما همان‌طور که در مثال قبل دیدیم با اینکه $x = 14$ و $y = 6$ در دو طرح نمونه‌گیری از نظر درستنایی با یکدیگر معادل هستند اما، p -مقدار حاصل از آنها با یکدیگر تفاوت دارد. بنابراین p -مقدار در اصل درستنایی صدق نمی‌کند.

$$\hat{p}_{H_0}(x) = \Phi(\theta_0 - x).$$

که در آن Φ تابع توزیع نرمال استاندارد است.
بنابراین با وجود این که $H_0 \subset H_1$ است اما

$$\hat{p}_{H_0}(x) \geq \hat{p}_{H_1}(x)$$

(۸) وقتی H_1 به H_0 میل می‌کند، p-مقدار تغییر نمی‌کند.

وقتی H_1 به H_0 میل می‌کند، باید معیار پشتیبانی به سمت مقداری میل کند که نشان‌دهنده پشتیبانی یکسان از هر دو فرضیه است. p-مقدار به عنوان یک معیار پشتیبانی فاقد این ویژگی است.

مثال ۸ فرض کنید $X \sim N(\theta, 1)$. همچنانی فرض کنید $\theta = a$ ($a > 0$) و $H_1 : \theta = a$ در این صورت p-مقدار آزمون برای مقدار مشاهده شده x عبارت است از

$$\hat{p}(x) = P(X \geq x | \theta = a).$$

از آن‌جا که p-مقدار فوق به a بستگی ندارد بنابراین وقتی $a \rightarrow 0$ ، p-مقدار تغییر نمی‌کند.

علت این که p-مقدار فاقد این ویژگی است، ناشی از این موضوع است که فرضیه جانشین در تعیین شدت شواهدی که برآساس p-مقدار سنجیده می‌شود، تأثیر ندارد.

باشد آنگاه، $1 - \hat{p}_0 = 1 - \hat{p}_1$. متأسفانه

p-مقدار در این شرط صدق نمی‌کند.

مثال ۶ فرض کنید که $X \sim N(\theta, 1)$

$H_1 : \theta = 1$ و $H_0 : \theta = 0$ باشد. در این صورت،

برای مشاهده داده شده x

$$\hat{p}_0 = P(X \geq x | \theta = 0) = 1 - \Phi(x)$$

در صورتی که

$$\hat{p}_1 = P(X \leq x | \theta = 1) = \Phi(1 - x)$$

و البته بدیهی است که $\Phi(1 - x) \neq 1 - \Phi(x)$

p-مقدار منسجم نیست.

یکی از ویژگی‌های مطلوب یک معیار پشتیبانی انسجام ۱۲ آن است؛ به این معنی که اگر فرضیه H_0 فرضیه H_1 را دربر گیرد ($H_0 \subset H_1$)، آنگاه میزان پشتیبانی از فرضیه H_1 حداقل به میزان پشتیبانی از فرضیه H_0 باشد. اما p-مقدار به عنوان یک معیار پشتیبانی فاقد این ویژگی است [۱۰].

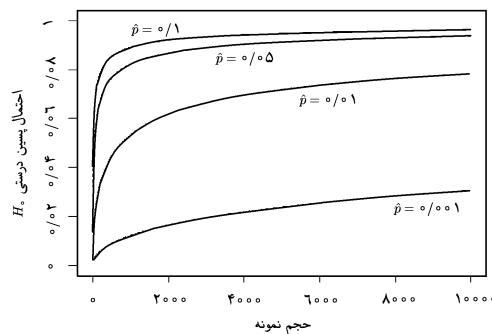
مثال ۷ فرض کنید $X \sim N(\theta, 1)$. همچنانی

فرض کنید $H_0 : \theta = \theta_0$ و $H_1 : \theta \leq \theta_0$. فرضیه H_0 را به ترتیب به صورت جانشین H_0' و H_1' در نظر گیرید. p-مقدار در حمایت از فرضیه H_1 را برای مقدار مشاهده شده x با $\hat{p}_{H_1}(x)$ نمایش می‌دهیم. فرض کنید $\theta_0 < \theta$ مشاهده شده باشد. در این صورت

$$\hat{p}_{H_0}(x) = 2\Phi(\theta_0 - x)$$

۱۱) با توجه به اینکه p-مقدار معیاری در بازه‌ی $[0, 1]$ است انتظار می‌رود که \hat{p}_0 و \hat{p}_1 نسبت به $1/2$ (پشتیبانی یکسان از هر دو فرضیه) متقاضی باشد؛ یعنی، $(1/2 - \hat{p}_0) = -(1/2 - \hat{p}_1)$. Coherence^{۱۲}

احتمال پسین درستی H_0 به سمت یک میل می‌کند، در صورتی که p -مقدار تغییر نمی‌کند. در این صورت اگر p -مقدار کوچک باشد نشان‌دهنده شواهد قوی برعلیه H_0 است، در صورتی که به احتمال قریب به یقین H_0 درست می‌باشد. توجه کنید که این مطلب به‌ازای هر $1 < \pi_0 < 0$ و τ^2 درست است.



شکل ۱. نمودار پارادوکس لیندلی

جدول (۱) و نمودار (۱) رفتار احتمال پسین درستی H_0 هنگام افزایش حجم نمونه را برای چند p -مقدار در مثال فوق نمایش می‌دهند (هنگامی که $\tau^2 = \sigma^2, \pi_0 = 1/2$).

(۱) p -مقدار کالیبره^{۱۴} نیست.

یکی دیگر از ویژگی‌های مطلوب یک معیار پشتیبانی کالیبره بودن آن است؛ به این معنی که مقادیر یکسان آن در موقعیت‌های مختلف معنی یکسان داشته باشند. به عنوان مثال دماسنجه را به عنوان یک ابزار سنجش دما کالیبره گوییم زیرا اگر در یک مکان دماسنجه اختلاف دمای بین

۹) p -مقدار با مشکل پارادوکس لیندلی^{۱۳} روی رو است.

به موجب این پارادوکس، برای یک توزیع پشین و p -مقدار ثابت، با افزایش حجم نمونه احتمال پسین درستی فرضیه صفر به عدد یک میل می‌کند [۶ و ۲].

مثال ۹ فرض کنید $X_1, \dots, X_n \stackrel{iid}{\sim} N(\theta, \sigma^2)$ با σ^2 معلوم باشند. فرضیه $H_0 : \theta = \theta_0$ در مقابل $H_1 : \theta \neq \theta_0$ را در اختیار داریم. آماره آزمون (متداول) و p -مقدار آزمون به ترتیب عبارتند از

$$\begin{aligned} T &= T(X) = \sqrt{n} |\bar{X} - \theta_0| / \sigma \\ \hat{p} &= \hat{p}(x) = 2(1 - \Phi(t)). \end{aligned}$$

همچنین فرض کنید $P(H_0) = \pi_0$ و $P(H_1) = 1 - \pi_0$. تحت فرضیه H_1 دارای توزیع $N(\theta_0, \tau^2)$ با τ^2 معلوم باشد. در این صورت احتمال پسین درستی H_0 عبارت است از

$$\begin{aligned} P(H_0 | x) &= \frac{1}{1 + \frac{1-\pi_0}{\pi_0} (1+c)^{-1/2} \exp\left\{-\frac{t^2}{2(1+1/c)}\right\}} \\ &= \frac{1}{1 + \frac{1-\pi_0}{\pi_0} (1+c)^{-1/2} \exp\left\{\frac{(\Phi^{-1}(1-\hat{p}/2))^2}{2(1+1/c)}\right\}} \end{aligned}$$

که در آن $c = n (\tau^2 / \sigma^2)$ بدیهی است که $c \rightarrow \infty \Rightarrow c \rightarrow \infty \Rightarrow n \rightarrow \infty$. حال اگر $t = \sqrt{n}|\bar{x} - \theta_0|/\sigma$ ثابت بماند، افزایش یابد ولی

$$\begin{aligned}\hat{p}(x) &= P_{H_0} \left(\frac{f_1(X)}{f_0(X)} \geq \frac{f_1(x)}{f_0(x)} \right) \\ &= P_{H_0} (B \leq b) = F_{B|H_0}(b).\end{aligned}$$

که در آن $B = f_0(\mathbf{X})/f_1(\mathbf{X})$. در این صورت، اگر $f_0 \sim N(0, 1)$ و $f_1 \sim N(1, 1)$ باشد، آنگاه p -مقدار عبارت است از

$$\begin{aligned}\hat{p}(x) &= P_{H_0} \left(\exp \left\{ -X + \frac{1}{2} \right\} \leq b \right) \\ &= 1 - \Phi \left(\frac{1}{2} - \ln b \right).\end{aligned}$$

ولی اگر $f_0 \sim \exp(2)$ و $f_1 \sim \exp(1)$ باشد، آنگاه

$$\begin{aligned}\hat{p}(x) &= P_{H_0} \left(\frac{1}{2} \exp \{ X \} \leq b \right) \\ &= P_{H_0} (X \leq \ln(2b)) = 1 - \frac{1}{2b}.\end{aligned}$$

مالحظه می‌شود که در دو مسئله فوق \hat{p} توابعی متفاوت از b است؛ یعنی، ممکن است میزان پشتیبانی داده‌ها از فرضیه H_0 در مقابل H_1 بر اساس b یکسان باشد اما p -مقدارهای آنها متفاوت باشد و بالعکس، ممکن است که مقادیر p -مقدارها در دو آزمون یکسان باشد اما میزان پشتیبانی واقعی داده‌ها از فرضیه H_0 در مقابل H_1 یکسان نباشد؛ برای مثال، p -مقدار 0.03 در آزمون فرضیه اول به معنی 0.25 در آزمون فرضیه اول است؛ در حالی که، حمایت از H_1 در مقابل H_0 است؛ در حالی که، همین p -مقدار در آزمون فرضیه دوم به معنی 0.52 در حمایت از H_1 در مقابل H_0 است.

دوجسم را 10 درجه سانتی‌گراد نشان دهد، این میزان اختلاف دما را در هر زمان و مکان دیگری با همان 10 درجه سانتی‌گراد نشان خواهد داد. متأسفانه، این مطلب برای p -مقدار صادق نمی‌باشد؛ زیرا ممکن است در دو مساله متفاوت که شواهد واقعی یکسان هستند، p -مقدار دو مقدار متفاوت را ارائه دهد و بالعکس. ما در اینجا دو فرضیه را ساده فرض می‌کنیم و شواهد واقعی را عامل بیز^{۱۵} در نظر می‌گیریم (برای شرح بیشتر به مرجع [۸] مراجعه شود). عامل بیز که به صورت نسبت بخت پسین به بخت پیشین تعریف می‌شود $b = \frac{P(H_0|X=x)/P(H_1|X=x)}{P(H_0)/P(H_1)}$ مشاهده $X = x$ چند برابر نسبت بخت‌ها را افزایش (کاهش) می‌دهد. در حالتی که فرضیه‌های H_0 و H_1 ساده هستند عامل بیز همان نسبت درستنمایی دو فرضیه خواهد بود. مثال زیر به خوبی نشان می‌دهد که p -مقدار کالیبره نیست (البته، در مورد کالیبره کردن p -مقدار کوشش‌هایی به عمل آمده از آن جمله می‌توان به مرجع [۱۱] اشاره کرد).

مثال 10 فرض کنید که X_1, \dots, X_n یک نمونه تصادفی مستقل و هم توزیع از توزیع پیوسنه باشد. برای آزمون فرضیه $H_0 : f = f_0$ در مقابل $H_1 : f = f_1$ کلاس آزمون‌های MP و تو

$$\varphi(x) = \begin{cases} 1 & b \leq k \\ 0 & b > k \end{cases}$$

در توى که در آن $b = f_1(x)/f_0(x)$. در نتیجه p -مقدار آزمون عبارت است از:

۵ قانون درستنماهی

فرضیه H_0 پشتیبانی می‌کند و هر چه r بزرگ‌تر از یک باشد میزان پشتیبانی از فرضیه H_1 نیز بیشتر است. بنابراین می‌توان نسبت درستنماهی را به عنوان معیاری برای پشتیبانی داده‌ها از فرضیه صفر در مقابل فرضیه جانشین درنظر گرفت.

(۲) تعمیم درست اصل عکس نقیض است.

قانون درستنماهی می‌گوید: از دو فرضیه، فرضیه‌ای که احتمال بیشتری به مشاهده x نسبت می‌دهد از جانب x بیشتر پشتیبانی می‌شود و هر چه نسبت این دو احتمال بیشتر باشد، پشتیبانی x از آن فرضیه بیشتر است.

علاوه بر این، اگر $r = 1$ آنگاه، $P(X = x|H_0) > P(X = x|H_1)$ و در نتیجه $H_0 \sim H_1$. یعنی قانون درستنماهی در حالت خاص همان اصل "عکس نقیض" است (که در مقاله اول به آن اشاره شد).

(۳) سازگار است

به این معنی که هنگامی که H_0 درست است وقتی آنگاه، $n \xrightarrow{p} \infty$ و هنگامی که H_1 درست است وقتی $n \xrightarrow{p} \infty$ آنگاه، $r \xrightarrow{p} 1$.

۷ ویژگی‌های قانون درستنماهی

(۱) در اصل درستنماهی صدق می‌کند.

بدیهی است که قانون درستنماهی در این اصل صدق می‌کند، زیرا نسبت دوتابع درستنماهی است.

همان‌طور که در مقاله اول [۱] به آن اشاره شد، از نسبت درستنماهی دو فرضیه^{۱۶} می‌توان به عنوان معیاری برای اندزه‌گیری میزان پشتیبانی داده‌ها از یک فرضیه در مقابل فرضیه دیگر استفاده کرد. که از آن با نام "قانون درستنماهی" یاد می‌شود.

۶ توجیه قانون درستنماهی

(۱) برابری نسبت درستنماهی با عامل بیز

زمانی که فرضیه‌های H_0 و H_1 هر دو ساده هستند داریم

$$\begin{aligned} b &= \frac{P(H_0|X=x)/P(H_1|X=x)}{P(H_0)/P(H_1)} \\ &= \frac{\frac{P(X=x|H_0)}{P(X=x|H_1)} \frac{P(H_0)}{P(H_1)}}{\frac{P(H_0)}{P(H_1)}} \\ &= \frac{P(X=x|H_0)}{P(X=x|H_1)} = r \end{aligned}$$

که در آن r نسبت درستنماهی H_0 به H_1 است.

به عبارت دیگر، مشاهده $X = x$ نسبت بخت‌ها را با ضریبی برابر r افزایش (یا کاهش) می‌دهد. اگر $1 > r$ باشد در این صورت می‌توان نتیجه گرفت که داده‌ها از فرضیه H_0 بیشتر از فرضیه H_1 پشتیبانی می‌کند و هر چه r بزرگ‌تر از یک باشد میزان پشتیبانی از فرضیه H_0 نیز بیشتر است؛ و بالعکس، اگر $1 < r$ باشد در این صورت می‌توان نتیجه گرفت که داده‌ها از فرضیه H_1 بیشتر از

^{۱۶} در ادامه هر کجا سخن از فرضیه به میان آید منظور فرضیه ساده است.

۴) احتمال گمراه‌کنندگی قانون درستنمایی کم است

قضیه زیر این مطلب را تایید می‌کند [۸، ۹].

قضیه ۱ فرض کنید متغیر تصادفی X تحت فرضیه‌های H_0 و H_1 به ترتیب دارای توزیع‌های f_0 و f_1 باشد. در این صورت برای هر ثابت $k > 0$ داریم

$$P_{H_0}(R \geq k) \leq 1/k$$

و

$$P_{H_1}(R \leq k) \leq 1/k$$

که در آن

$$R = f_0(X)/f_1(X)$$

اثبات:

$$\begin{aligned} P_{H_0}(R \geq k) &= \int_{r \geq k} f_1(x) dx \\ &= \int_{f_0(x)/f_1(x) \geq k} f_1(x) dx \\ &\leq \frac{1}{k} \int_{f_0(x)/f_1(x) \geq k} f_0(x) dx \\ &\leq \frac{1}{k}. \end{aligned}$$

در حالتی که X گستته باشد کافی است در مراحل اثبات فوق نماد انتگرال را با نماد مجموع جایگزین نمائیم. اثبات نامساوی دیگر به طور مشابه می‌باشد.

روابط فوق، وقتی k بزرگ باشد، بیانگر این مطلب هستند که احتمال پشتیبانی قوی از فرضیه نادرست، بسیار کوچک است. حائز اهمیت است

۲) به فضای نمونه بستگی ندارد.

از آنجا که تابع درستنمایی تمها به مقدار مشاهده شده x بستگی دارد؛ بنابراین بدیهی است که قانون درستنمایی به فضای نمونه بستگی نداشته باشد.

۳) به قاعده توقف نمونه‌گیری بستگی ندارد.

فرض کنید دنباله متغیرهای تصادفی مستقل X_1, X_2, \dots, X_n را مشاهده کنیم تا براساس مقادیر مشاهده شده x_1, x_2, \dots, x_n نمونه‌گیری متوقف شود. در این صورت، تابع درستنمایی (در حالت گستته) عبارت است از

$$\begin{aligned} f(x_1, \dots, x_n, n; \theta) &= P(X_1 = x_1, \dots, X_n = x_n, N = n; \theta) \\ &= P(X_1 = x_1, \dots, X_n = x_n; \theta) \\ &= f_1(x_1; \theta) \dots f_n(x_n; \theta) \end{aligned}$$

که در آن $f_i(x_i; \theta)$ تابع چگالی متغیر تصادفی X_i است. تساوی دوم از آن جهت برقرار است که حجم نمونه براساس مقادیر مشاهده شده x_1, \dots, x_n تعیین شده است. یعنی،

$$\{N = n\} \subset \{X_1 = x_1, \dots, X_n = x_n\}.$$

اثبات در حالت پیوسته به طور مشابه است.

شایان ذکر است، از آنجا که قانون درستنمایی در اصل درستنمایی صدق می‌کند؛ لذا، به طرح نمونه‌گیری (فضای نمونه و قاعده توقف) نباید بستگی داشته باشد.

نسبت درستنمایی دارای این ویژگی هست.
به عبارت دیگر، فرض کنید $\theta = \theta_0$ و H_0 : $\theta = \theta_1$. در این صورت

$$\theta_1 \rightarrow \theta_0 \Rightarrow r \rightarrow 1$$

(۸) نسبت درستنمایی کالیبره است.

از آن جا که نسبت درستنمایی برابر عامل بیز است،
لذا کالیبره نیز می‌باشد.

۸ نتیجه‌گیری

(۱) باید توجه داشت، علیرغم این که p -مقدار یک معیار پشتیبانی داده‌ها از فرضیه صفر می‌باشد اما معیار دقیقی نیست.

(۲) منطقی به نظر می‌رسد که برای اندازه‌گیری میران شواهد موجود در داده‌ها در حمایت از یک فرضیه ساده در مقابل فرضیه ساده دیگر از نسبت درستنمایی آن دو فرضیه استفاده کنیم.

در مقاله سوم اندازه‌گیری میزان شواهد موجود در داده‌ها را در حالت فرضیه‌های مرکب مورد بررسی قرارخواهیم داد.

۹ قدردانی

بدین وسیله از داور محترم مقاله که با نکاتی که مطرح نمودند بر کیفیت این مقاله افزودند تشکر و قدردانی می‌گردد.

که توزیع‌های متغیر تصادفی X تحت فرضیه‌های H_0 و H_1 هر چه باشند، روابط فوق برقرار هستند.
به همین دلیل روابط فوق را "کران‌های جهانی" ^{۱۷} می‌نامند (برای شرح بیشتر در این مورد مراجع [۸، ۹] ملاحظه شود).

هچنین ثابت می‌شود که اگر کاربری عمداً بخواهد نمونه‌گیری را آنقدر ادامه دهد تا نتیجه $r \leq 1/k$ حاصل شود؛ اگر H_0 درست باشد، احتمال اینکه وی موفق شود بیشتر از $1/k$ نیست [۷].

(۵) قانون درستنمایی به فرضیه جانشین بستگی دارد.
در قانون درستنمایی برخلاف p -مقدار، فرضیه جانشین نه تنها در تعیین جهت، بلکه در میزان شواهد موجود در داده‌ها به نفع (یا بر علیه) یک فرضیه نیز موثر است.

(۶) قانون درستنمایی نسبت به H_0 و H_1 متقارن است.
اگر r_0 ، نسبت درستنمایی فرضیه H_0 در مقابل H_1 ، و r_1 ، نسبت درستنمایی فرضیه H_1 در مقابل H_0 باشد، آنگاه $1/r_0 = r_1$. در نتیجه اگر جای H_0 و H_1 را عوض کنیم، میران پشتیبانی داده‌ها از فرضیه‌ها تغییر نمی‌کند.

(۷) وقتی H_1 به H_0 میل می‌کند باید معیار پشتیبانی به سمت مقداری میل کند که نشان‌دهنده پشتیبانی یکسان از هر دو فرضیه است.

جدول ۱. جدول پارادوکس لیندلی (برگرفته از [۲])

\hat{p}	۱	۱۰	۲۰	۵۰	۱۰۰	۱۰۰۰	۱۰۰۰۰	n
۰/۱	۰/۴۲	۰/۴۷	۰/۵۶	۰/۶۵	۰/۷۲	۰/۸۹	۰/۹۶	
۰/۰۵	۰/۳۵	۰/۳۷	۰/۴۲	۰/۵۲	۰/۶۰	۰/۸۲	۰/۹۴	
۰/۰۱	۰/۲۱	۰/۱۴	۰/۱۶	۰/۲۲	۰/۲۷	۰/۵۳	۰/۷۸	
۰/۰۰۱	۰/۰۸۶	۰/۰۲۴	۰/۰۲۶	۰/۰۳۴	۰/۰۴۵	۰/۱۲۴	۰/۳۰۹	

مراجع

- [۱] ارقامی، ن.ر.، زمان زاده، ا. و راحتنی، س. (۱۳۸۷)، شواهد آماری، قسمت اول: تفسیر نتایج آزمون‌های آماری کلاسیک، اندیشه آماری، سال ۱۳، شماره ۱، ۳-۱۰.
- [۲] Berger, J.O. and Sellke, T. (1987), Testing a point null hypothesis: The irreconcilability of P values and evidence, *Jurnal of the American Statistical Association*, 82(397), 112-122.
- [۳] Casella, G. and Berger, R.L. (2002), *Statistical Inference*, 2nd Ed., Duxbury Press, the University of Michigan.
- [۴] Lehmann, E.L. and Casella, G. (1998), *Theory of Point Estimation*, 2nd Ed. Springer, New York.
- [۵] Lehmann, E.L. and Romano, J.P. (2005), *Testing Statistical Hypotheses*, 3rd Ed. Springer, New York.
- [۶] Lindley, D.V. (1975), A statistical paradox, *Biometrika*, 44, 187-192.
- [۷] Robbins, H. (1970), Statistical methods related to the law of the iterated logarithm, *Annals of Mathematical Statistics*, 41(5), 1397-1409.
- [۸] Royall, R. (1997), *Statistical Evidence: A Likelihood Paradigm*, Chapman and Hall/CRC, Florida.
- [۹] Royall, R. (2000), On probability of observing misleading statistical evidence, *Jurnal of the American Statistical Association*, 95(451), 760-768.

- [10] Schervish, M.J. (1996), P-values: What they are and what they are not, *The American Statistician*, 50(3), 203-206.
- [11] Sellke, T. and Bayarri, M.J. and Berger, G. (2001), Calibration of P-values for testing precise null hypotheses, *The American Statistician*, 55(1), 62-71.