

## مقایسه آزمون کاکس با آزمون وونگ و معیارهای انتخاب مدل در مدل‌های رگرسیونی خطی غیر آشیانه‌ای (غیر تودرتو) با خطای نرمال

اسداله فقیهی، عبدالرضا سیاره

گروه آمار، دانشگاه رازی

یکی از اساسی‌ترین مسائل بنیادی در انتخاب مدل بررسی دوری و نزدیکی مدل‌های پیشنهادی به مدل مولد داده‌ها یعنی  $h(\cdot)$  است. برای حالتی که دو مدل پیشنهادی وجود دارد بر اساس آزمون‌ها و معیارهای موجود تصمیم می‌گیریم که آیا این دو مدل را به‌عنوان دو مدل خوب در نظر بگیریم یا به‌عنوان دو مدل که برازش خوبی به داده‌ها ندارند. در فرآیند تصمیم‌گیری گاه دو مدل پیشنهادی را رد می‌کنیم. روش تصمیم‌گیری آزمون کاکس، رد یا پذیرش مدل‌های پیشنهادی بر اساس تعلق  $h(\cdot)$  به خانواده چگالی‌های پیشنهادی است. سوالی که مطرح می‌شود آن است که آیا این دو مدل، که توسط آزمون کاکس رد شده‌اند، دو مدل نزدیک به  $h(\cdot)$  بوده‌اند یا دو مدل دور از  $h(\cdot)$ . از طرفی آزمون وونگ براساس دوری و نزدیکی مدل‌ها به  $h(\cdot)$  طراحی شده است. بر این اساس در این مقاله با شبیه‌سازی مدل‌های رگرسیونی خطی غیر آشیانه‌ای با خطای نرمال به بررسی موضوعاتی از این نوع پرداخته‌ایم که از دو مدل پیشنهادی که توسط آزمون کاکس پذیرفته نشده‌اند کدام یک به  $h(\cdot)$  نزدیک‌تر بوده‌اند. از طرفی چنانچه آزمون وونگ یا معیارهای انتخاب مدل مانند  $KICc, KIC, AIC, BIC$ ، یکی از مدل‌های پیشنهادی را برگزینند آیا آن مدل توسط آزمون کاکس به‌عنوان یک مدل خوب-توصیف شده برگزیده می‌شود یا خیر. با بررسی این موضوعات می‌توان نتیجه گرفت که به دلیل حساسیت زیاد آزمون کاکس به ساختار مدل‌های پیشنهادی پذیرش مدل توسط آزمون کاکس به معنی پذیرش توسط همه معیارهاست، و معادل بودن دو مدل توسط آزمون وونگ به مفهوم رد هر دو توسط آزمون کاکس است. اما در مواردی که هر دو مدل توسط آزمون کاکس رد می‌شوند، آزمون وونگ و دیگر معیارها مدل نزدیکتر را برمی‌گزینند.

واژه‌های کلیدی: آزمون کاکس، آزمون وونگ،  $KICc, KIC, AIC, BIC$ ، مدل‌های غیر تودرتو، مدل‌های درست-توصیف شده، مدل‌های خطی.

## ۱ مقدمه

در بحث انتخاب مدل، آزمون‌ها، معیارها، و روش‌های متنوعی تا به حال پیشنهاد و به کار گرفته شده است. در واقع ضعف‌ها و توانایی‌های این معیارها و آزمون‌ها، پژوهشگران این حوزه را همواره برآن داشته تا به ملاک یا معیار جامع تری دست یابند. براین اساس در این مقاله دو نوع آزمون متفاوت از لحاظ ساختار و چهار معیار انتخاب مدل به طور هم‌زمان برای انتخاب مدل مورد بررسی قرار گرفته‌اند. همچنین استفاده‌های روزافزون از مدل‌های رگرسیونی خطی غیر تودرتو با خطای نرمال در مدل بندی پدیده‌های اقتصادی ما را برآن داشت تا در بررسی‌ها و شبیه سازی‌های این مقاله از این نوع مدل‌ها استفاده کنیم. شبیه سازی آماره کاکس به دو روش صورت گرفته است. روش اول با استفاده از آماره ارائه شده توسط پسران (۱۹۷۴) انجام گرفته که با نام شبیه سازی از آن یاد خواهیم کرد و دیگری به روشی که پسران و پسران (۱۹۹۳) ارائه کردند و در بخش‌های بعد به نام شبیه سازی تصادفی از آن نام برده شده است. در بخش (۲) به دلایل و ایده انجام این مقایسه‌ها پرداخته‌ایم. مدل‌های مورد بررسی و آماره آزمون کاکس در حالت رگرسیونی خطی در بخش (۳) آورده شده است. بخش (۴) شامل محاسبه آماره آزمون وونگ در حالت رگرسیونی خطی غیرتودرتو است. محاسبه معیارهای  $KICc$ ،  $KIC$ ،  $AIC$ ،  $BIC$  در بخش (۵) انجام گرفته است. در بخش (۶) نحوه شبیه سازی تصادفی و استفاده از آن در مدل‌های رگرسیونی خطی آورده شده است. نحوه شبیه سازی مدل‌ها در بخش (۷) مورد بحث قرار گرفته‌اند. بخش (۸) شامل بحث و نتیجه‌گیری در مورد جداول حاصل از شبیه سازی‌ها است و جداول حاصل از شبیه سازی‌ها در بخش (۹) آورده شده‌اند.

## ۲ انگیزه مقایسه‌ی آزمون‌ها و معیارهای انتخاب مدل

در آزمون‌های کلاسیک رد کردن فرض  $H_0$  به معنی پذیرش فرض مقابل است. در حالیکه در آزمون‌های انتخاب مدل ما با تصمیم‌گیری‌های متفاوتی در مورد دو مدل روبرو هستیم. در مواردی مایلیم مدلی را به عنوان مدل خوب بپذیریم ولی آزمون کاکس هر دو مدل را رد می‌کند، سوالی که مطرح می‌شود این است که در چنین مواردی چه باید کرد؟ می‌دانیم آزمون کاکس برتری نسبی مدل‌ها نسبت به یکدیگر را مشخص نمی‌کند. رد هر دو مدل توسط

آزمون کاکس نشان می‌دهد که هر دو مدل بد-توصیف<sup>۱</sup> شده هستند. در این موارد برای انتخاب یک مدل می‌توان از آزمون وونگ و معیارهای دیگر انتخاب مدل استفاده کرد. استفاده از آزمون کاکس ما را قادر می‌سازد که هر دو مدل پیشنهادی را پذیرفته و یا رد کنیم. در این مقاله پیشنهاد می‌کنیم اگر آزمون کاکس مدل‌های پیشنهادی را رد کرده باشد بر اساس آزمون وونگ و سایر معیارهای مناسب، مانند  $AIC$  از بین مدل‌های پیشنهادی بر اساس نتیجه آزمون کاکس مدل بهینه‌ای که به توزیع مولد داده‌ها نزدیکتر است را برگزینیم. تفاوت بین آزمون‌های کاکس و وونگ در این است که آزمون کاکس یکی از مدل‌های پیشنهادی را در فرض صفر قرار داده و به عنوان مدل درست می‌پذیرد در صورتی که فرض صفر در آزمون وونگ عدم اختلاف بین مدل‌ها از لحاظ نزدیکی به مدل مولد داده‌هاست. برگزیده شدن یک مدل توسط آزمون وونگ به معنی نزدیکتر بودن آن مدل به مدل مولد داده‌ها نسبت به مدل پیشنهادی دیگر است. معیار  $AIC$  به عنوان نمونه‌ای از معیارهایی که توسط آنها تنها یک عدد مطلق برای مقایسه ارائه می‌شود، در بحث انتخاب مدل فارغ از سطح  $\alpha$  بوده و مستقل از فرض صفر به شمار می‌روند. قابلیت دیگر آزمون وونگ نسبت به آزمون کاکس سادگی محاسبه آماره این آزمون است. از طرف دیگر با توجه به آزمون‌های یاد شده و معیاری مانند  $AIC$  این سوال مطرح می‌شود، زمانی که یک مدل توسط آزمون وونگ یا معیار  $AIC$  به عنوان مدل بهینه انتخاب شده است آیا این مدل انتخابی نسبت به دیگر مدل‌های پیشنهادی یک مدل خوب-توصیف<sup>۲</sup> شده هست یا نه؟ اگر تعلق مدل درست به خانواده‌ی مدل پیشنهادی<sup>۳</sup> به عنوان معیاری برای خوبی مدل در نظر گرفته شود، آنگاه آیا مدل انتخابی توسط معیار  $AIC$  و آزمون وونگ نیز مدل خوب محسوب می‌شود؟ برای پاسخ به این سوال آزمون کاکس را پیشنهاد می‌کنیم.

### ۳ آماره آزمون کاکس برای آزمون مدل‌های رگرسیونی خطی غیرتودرتو

تعریف ۱. دو مدل رگرسیونی با فرم تابعی و ساختارهای خطای یکسان غیرتودرتو هستند اگر فقط اگر حداقل یک ستون از ماتریس طرح یک مدل رگرسیونی را نتوان به صورت ترکیب خطی از ستون ماتریس طرح مدل رگرسیونی دیگر نوشت. (کلارک، ۲۰۰۲)

<sup>1</sup> Mis – Specified

<sup>2</sup> Correctly Specify

<sup>3</sup> Correctly Specification

**مثال ۱** دو مدل رگرسیونی خطی به این شکل در نظر می‌گیریم  $H_f : Y = \beta_1 X_1 + \beta_2 X_2 + \beta_3 X_3 + \epsilon_0$  و  $H_g : Y = \gamma_1 Z_1 + \gamma_2 Z_2 + \gamma_3 Z_3 + \epsilon_1$  همانطور که ملاحظه می‌شود با اعمال محدودیت بر روی بردار پارامترهای مدل  $g$  نمی‌توان به مدل  $f$  رسید. در واقع ماتریس طرح در مدل  $f$  زیر مجموعه‌ای از ماتریس طرح در مدل  $g$  نیست. در اینجا فرض‌های صفر و مقابل به شکل زیر هستند.

$$H_0 : Y = Xb_0 + u_0; u_0 \sim N(0, \sigma_0^2 I)$$

$$H_1 : Y = Zb_1 + u_1; u_1 \sim N(0, \sigma_1^2 I)$$

که در آن  $Y$  بردار  $n \times 1$  از مشاهدات متغیر وابسته،  $Z$  و  $X$  ماتریس‌های طرح بترتیب  $n \times k_1$  و  $n \times k_0$  و بردارهای ضرایب رگرسیونی  $1 \times k_1$  و  $1 \times k_0$ ،  $u_1$  و  $u_0$  بردارهای خطای  $n \times 1$  و  $I$  ماتریس واحد مرتبه  $n$  است.

بر اساس مقاله پسران (۱۹۷۴) آماره آزمون کاکس در حالت رگرسیونی خطی برای مدل‌های تحت  $H_0$  و  $H_1$  با فرض درستی مدل تحت  $H_0$  برابر است با  $N_0 = T_0 / [V_0(T_0)]^{1/2}$  که در آن  $T_0 = \frac{n}{2} \log \left( \frac{\hat{\sigma}_1^2}{\hat{\sigma}_0^2 + \frac{1}{n} \hat{b}'_0 X' M_z X \hat{b}_0} \right)$  همچنین  $\hat{V}_0(T_0) = \frac{\hat{\sigma}_0^2}{\hat{\sigma}_1^2} \hat{b}'_0 X' M_z M_x M_z X \hat{b}_0$  به طوری که  $M_x = I - X(X'X)^{-1}X'$  و  $M_z = I - Z(Z'Z)^{-1}Z'$  است.  $\hat{\sigma}_0^2$  و  $\hat{b}_0$  به ترتیب برآوردهای  $ML$ ،  $b_0$  و  $\sigma_0^2$  هستند و  $\hat{\sigma}_1^2$  عبارت است از توان دوم  $\hat{E}_0(\hat{\sigma}_1^2)$ . کاکس نشان می‌دهد با فرض درستی مدل تحت  $H_0$ ،  $N_0$  به طور مجانبی دارای توزیع نرمال استاندارد است.

حال اگر آماره را با فرض درستی مدل تحت  $H_1$  به دست آوریم  $N_1 = T_1 / [V_1(T_1)]^{1/2}$  است. در سطح معناداری  $\alpha$  آزمون کاکس به یکی از حالت‌های زیر منتج خواهد شد.

$$1. \text{ پذیرش } H_0 \text{ و رد } H_1 \text{، هرگاه، } |N_1| \geq z_{\alpha/2} \text{ ، } |N_0| < z_{\alpha/2}$$

$$2. \text{ رد } H_0 \text{ و پذیرش } H_1 \text{، هرگاه، } |N_1| < z_{\alpha/2} \text{ ، } |N_0| \geq z_{\alpha/2}$$

$$3. \text{ رد هر دو مدل، هرگاه، } |N_1| \geq z_{\alpha/2} \text{ ، } |N_0| \geq z_{\alpha/2}$$

$$4. \text{ پذیرش هر دو مدل، هرگاه، } |N_1| < z_{\alpha/2} \text{ ، } |N_0| < z_{\alpha/2}$$

## ۴ آماره‌ی آزمون وونگ برای آزمون مدل‌های رگرسیونی خطی نرمال غیرتودرتو

آزمون وونگ که از لحاظ ساختار با آزمون کاکس متفاوت است، برای بررسی نزدیکی مدل‌های پیشنهادی به مدل درست توسط وونگ (۱۹۸۹) معرفی شد. این آزمون بر پایه اطلاع کولبک-لیبلرینا شده است و آماره‌ی این آزمون برای مدل‌های رگرسیونی خطی غیرتودرتو با خطای نرمال محاسبه شده است. در این آزمون با فرض این که مدل  $h(x)$  مدل مولد داده‌ها بوده و  $\mathcal{F}_\theta$  و  $\mathcal{G}_\gamma$  دو خانواده از مدل‌های پیشنهادی باشند، نزدیکی این دو مدل به مدل  $h(\cdot)$  مورد آزمون قرار می‌گیرد. فرض‌های صفر و مقابل در این آزمون به صورت زیر هستند.

$$H_0 : E_h \left\{ \log \frac{f(X; \theta_*)}{g(X; \gamma_*)} \right\} = 0 \quad (1)$$

$$H_f : E_h \left\{ \log \frac{f(X; \theta_*)}{g(X; \gamma_*)} \right\} > 0 \quad (2)$$

$$H_g : E_h \left\{ \log \frac{f(X; \theta_*)}{g(X; \gamma_*)} \right\} < 0 \quad (3)$$

رابطه (۱) به این معنی است که  $f(x, \theta)$  و  $g(x, \gamma)$  معادلند.  
رابطه (۲) به این معنی است که  $f(x, \theta)$  بهتر است از  $g(x, \gamma)$ .  
رابطه (۳) به این معنی است که  $f(x, \theta)$  بدتر است از  $g(x, \gamma)$ .  
که در آن  $\theta_*$  و  $\gamma_*$  مقدارهای شبه-درست  $\theta$  و  $\gamma$  هستند. اگر مدل‌های رگرسیونی را که در بخش قبل معرفی شدند در نظر بگیریم، تحت فرض  $H_0$  آزمون وونگ، توزیع آماره‌ی آزمون به توزیع نرمال استاندارد میل می‌کند. اگر آماره‌ی آزمون وونگ را با  $V_{fg}$  نشان دهیم داریم  $V_{fg} = n^{-1/2} \hat{L}_1(\hat{\alpha}_0, \hat{\alpha}_1) / \hat{\omega}_n$ . بنابراین برای محاسبه  $V_{fg}$  به محاسبه  $\hat{L}_1$  و  $\hat{\omega}_n$  نیاز داریم. لذا  $\hat{L}_1$  را می‌توان به صورت  $\hat{L}_1 = \frac{n}{3} \log \frac{(\sum_{i=1}^n \hat{e}_{1i}^2)}{(\sum_{i=1}^n \hat{e}_{0i}^2)}$  نوشت که در آن  $e_{0i}$  ها درآیه‌های بردار  $e_0 = M_x y$  و  $e_1 = M_z y$  هستند. براساس آماره‌ی وونگ (۱۹۸۹)  $\hat{\omega}_n^2$  برابر

است با  $\hat{\omega}_n^2 = \frac{n}{\bar{f}} \sum_{i=1}^n \left[ \frac{\hat{e}_{1i}^2}{\sum_{i=1}^n \hat{e}_{1i}^2} - \frac{\hat{e}_{0i}^2}{\sum_{i=1}^n \hat{e}_{0i}^2} \right]^2$  و لذا  $V_{fg}$  برابر خواهد شد با

$$V_{fg} = \frac{\log \left( \frac{\sum_{i=1}^n \hat{e}_{1i}^2}{\sum_{i=1}^n \hat{e}_{0i}^2} \right)}{\left[ \sum_{i=1}^n \left[ \frac{\hat{e}_{1i}^2}{\sum_{i=1}^n \hat{e}_{1i}^2} - \frac{\hat{e}_{0i}^2}{\sum_{i=1}^n \hat{e}_{0i}^2} \right]^2 \right]^{1/2}}$$

طبق وونگ (۱۹۸۹)، تحت فرض صفر،  $V_{fg} \xrightarrow{d} N(0, 1)$ . برای آزمون در سطح معنی داری  $\alpha$  اگر  $V_{fg} > z_{\alpha/2}$  باشد فرض صفر در مقابل فرض  $H_f$  برتری مدل  $f$  بر  $g$  رد می‌شود. و اگر  $V_{fg} < -z_{\alpha/2}$  آنگاه فرض صفر در مقابل فرض  $H_g$  برتری مدل  $g$  بر  $f$  پذیرفته می‌شود. در نهایت اگر  $|V_{fg}| \leq z_{\alpha/2}$  آنگاه نمی‌توان تفاوت معنی داری بین دو مدل قائل شد و فرض صفر به مفهوم معادل بودن دو مدل پذیرفته می‌شود.

## ۵ محاسبه معیارهای $BIC$ ، $AIC$ ، $KIC$ ، $KICc$ در مدل های رگرسیونی خطی غیرتودرتو

آکائیک (۱۹۷۳) معیار  $AIC$  را به صورت  $AIC = -2 \log f(y; \hat{\alpha}_0) + 2k_0$  تعریف کرد این معیار در واقع برآورد اطلاع-کولبک-لیبلر است که به طور مجانبی می‌توان آن را نااریب در نظر گرفت.

کاوانوگ (۱۹۹۹) معیار  $KIC$  را به عنوان معیاری متقارن که برآورد حاصل جمع دو اطلاع-کولبک-لیبلر است را به صورت  $KIC = -2 \log f(y; \hat{\alpha}_0) + 3k_0$  معرفی کرد همچنین او در سال (۲۰۰۴) معیار  $KICc$  را به عنوان  $KIC$  تصحیح شده برای مدل های رگرسیونی خطی نرمال به صورت زیر ارائه کرد

$$KICc = -2 \log f(y; \hat{\alpha}_0) + n \log \left( \frac{n}{n - k_0} \right) + \frac{((n - k_0)(2k_0 + 3) - 2)}{(n - k_0 - 2)(n - k_0)}$$

معیار اطلاع بیزی  $BIC$  (معیار اطلاع شوارتز  $SIC$ ) توسط شوارتز (۱۹۷۸) ارائه گردید. می‌توان گفت  $BIC$  معیار ارزیابی مدل‌هایی است که بر حسب احتمال پیشین خود تعریف شده‌اند و بر خلاف بقیه معیارهای گفته شده بر اساس اطلاع-کولبک-لیبلر به دست نیامده است و به صورت  $BIC = -2 \log f(y; \hat{\alpha}_0) + k_0 \log n$  تعریف می‌شود.

## ۶ شبیه سازی تصادفی

محدودیت کاربرد آزمون کاکس در نتیجه مشتق‌های پیچیده‌ای است که در محاسبه‌های مربوط به صورت آماره کاکس در موقعیت‌های غیر رگرسیونی وجود دارد. پسران<sup>۴</sup> و پسران<sup>۵</sup> (۱۹۹۳) روش شبیه سازی تصادفی برای آماره کاکس را که راه حلی برای مسأله مذکور است ارائه کردند. این روش نیازی به محاسبه مشتق‌های تحلیلی برای به دست برآوردهای شبه-درست در آماره کاکس ندارد. ما از این روش شبیه‌سازی برای پاسخ به سوال‌های مطرح شده در بخش (۲) در مدل‌های رگرسیونی خطی استفاده کرده‌ایم.

### ۱-۶ آماره آزمون کاکس

در این بخش آماره کاکس به گونه‌ای آورده شده است که بتوان شبیه سازی را ساده‌تر تشریح کرد. فرض کنید  $N, Y_N, \dots, Y_1$  مشاهده مستقل و هم‌توزیع باشند. دو توزیع احتمال غیر تودرتو  $H_f: Y \sim f(y, \theta)$  و  $H_g: Y \sim g(y, \gamma)$  برای  $Y_t$ ها در نظر گرفته شده به طوری که  $\theta$  و  $\gamma$  به ترتیب بردارهای به ترتیب  $1 \times p$  و  $1 \times q$  از پارامترهای نامعلوم تحت  $H_f$  و  $H_g$  هستند. طبق آماره کاکس (۱۹۶۱، ۱۹۶۲)  $T_f(\hat{\theta}, \hat{\gamma}) = \bar{d} - \hat{E}_f(\bar{d})$  به طوری که  $E_f(\cdot)$  نشان دهنده امید ریاضی تحت  $H_f$ ،  $\bar{d} = N^{-1} \sum_{t=1}^N d_t$ ،  $d_t = \log f(Y_t, \hat{\theta}) - \log g(Y_t, \hat{\gamma})$  هستند.  $\hat{\theta}$  و  $\hat{\gamma}$  به ترتیب برآوردهای (ML)،  $\theta$  و  $\gamma$  تحت  $H_f$  و  $H_g$  هستند،  $T_f(\hat{\theta}, \hat{\gamma})$  برای نمونه‌های بزرگ دارای میانگین صفر است، (مک آلر و پسران، ۱۹۸۶).

اگر واریانس مجانبی  $\sqrt{n}T_f(\hat{\theta}, \hat{\gamma})$  تحت فرض  $H_f$  را با  $\nu_f^T(\theta_0, \gamma_*)$  نشان دهیم تحت شرایط نظم (وایت، ۱۹۸۲) آماره استاندارد شده کاکس  $N_f(\hat{\theta}, \hat{\gamma}) = \sqrt{N} \left( \frac{T_f(\hat{\theta}, \hat{\gamma})}{\hat{\nu}_f(\hat{\theta}, \hat{\gamma})} \right)$  مجانبی دارای توزیع  $N(0, 1)$  است و  $\hat{\nu}_f(\hat{\theta}, \hat{\gamma})$  برآورد سازگار  $\nu_f(\theta_0, \gamma_*)$  است.  $\hat{\nu}_f(\hat{\theta}, \hat{\gamma})$  را می‌توان به صورت  $d' = N^{-1} d' \left\{ I_N - R(\hat{\theta}) [R'(\hat{\theta})R(\hat{\theta})]^{-1} R'(\hat{\theta}) \right\}$  نوشت که در آن  $d' = (d_1, d_2, \dots, d_N)$  و  $R(\theta)$  ماتریس  $N \times (p+1)$  هستند که برای مدل‌های رگرسیونی

<sup>4</sup>M.Hashem Pesaran

<sup>5</sup>Bahram Pesaran

گفته شده در بخش (۲) به شکل زیر به دست می آیند

$$R(\alpha_0) = \begin{bmatrix} 1 - \frac{1}{2\sigma_1^2} + \frac{1}{2\sigma_1^2}(y_1 - x_1 b_0)^2 & \dots & \frac{x_{k_0}}{\sigma_1^2}(y_1 - x_{k_0} b_0) \\ 1 - \frac{1}{2\sigma_2^2} + \frac{1}{2\sigma_2^2}(y_2 - x_2 b_0)^2 & \dots & \frac{x_{k_0}}{\sigma_2^2}(y_2 - x_{k_0} b_0) \\ \vdots & & \vdots \\ 1 - \frac{1}{2\sigma_n^2} + \frac{1}{2\sigma_n^2}(y_n - x_n b_0)^2 & \dots & \frac{x_{k_0}}{\sigma_n^2}(y_n - x_{k_0} b_0) \end{bmatrix},$$

که در آن  $x_i$  نشان دهنده  $i$ -امین سطر ماتریس طرح  $X$  است. سطر دوم ماتریس  $R(\alpha_0)$   $\partial \log f(Y_i, \theta) / \partial \sigma_i^2$  است و از سطر دوم به بعد  $\partial \log f(Y_i, \theta) / \partial b_{0i}$  برای  $i = 1, 2, \dots, k_0$  در این حالت

$$\bar{d} = -\frac{1}{\nu} \log \left( \frac{\sigma_1^2}{\sigma_0^2} \right) \quad \text{و} \quad d_t = -\frac{1}{\nu} \left[ \log \left( \frac{\sigma_t^2}{\sigma_0^2} \right) + \frac{1}{\sigma_t^2} (y_t - x_t b_0)^2 - \frac{1}{\sigma_1^2} (y_t - z_t b_1)^2 \right]$$

نیاز  $T_f(\hat{\theta}, \hat{\gamma})$  جهت محاسبه هستند.  $\frac{1}{\nu n} \sum_{t=1}^n \left[ \frac{1}{\sigma_t^2} (y_t - x_t b_0)^2 - \frac{1}{\sigma_1^2} (y_t - z_t b_1)^2 \right]$  به محاسبه  $\hat{E}_f(\bar{d})$  داریم. با استفاده از معیار کولبک-لیبلر داریم

$$E_f(\bar{d}) = C(\theta_0, \gamma_*) = \int \log \left\{ \frac{f(y, \theta_0)}{g(y, \gamma_*)} \right\} f(y, \theta_0) dy,$$

که برای مدل‌های رگرسیونی به این صورت به دست می آید

$$C_R(\hat{\alpha}_0, \hat{\alpha}_{1*}(R)) = -\frac{1}{\nu} \log \left[ \frac{\hat{\sigma}_0^2}{\hat{\sigma}_{1*}^2(R)} \right] - \frac{1}{\nu} \left[ \frac{\hat{\sigma}_0^2(R)}{\hat{\sigma}_0^2} - \frac{\hat{\sigma}_{1*}^2(R)}{\hat{\sigma}_{1*}^2(R)} \right]$$

$$\tilde{\sigma}_0^2(R) = \frac{1}{nR} \sum_{j=1}^R (y_j - \tilde{\sigma}_{1*}^2(R))' (y_j - Z \hat{b}_{1*}(R)) \quad \text{و} \quad \tilde{\sigma}_{1*}^2(R) = \frac{1}{nR} \sum_{j=1}^R (y_j - Z \hat{b}_{1*}(R))' (y_j - Z \hat{b}_{1*}(R))$$

وقتی که  $(y_j - X \hat{b}_0)$   $X \hat{b}_0$  هستند. جهت محاسبه  $R(\hat{\alpha}_0)$  و برآورد آماره‌های گفته شده نیاز به برآورد پارامترهای مدل رگرسیونی داریم که آن‌ها را به روش شبیه سازی تصادفی محاسبه می‌کنیم. در روش شبیه سازی جهت محاسبه  $(\hat{b}_{1*})$  و  $(\hat{\sigma}_{1*}^2)$  ابتدا نمونه‌های مستقل  $1 \times n$  از  $y$  با بردار میانگین  $(X \hat{b}_0)$  و واریانس  $(\hat{\sigma}_0^2 I)$  تولید می‌کنیم و اگر  $j$ -امین نمونه را با  $y_j$  ( $j = 1, 2, \dots, R$ ) نشان دهیم  $\hat{b}_{1j} = (Z'Z)^{-1} Z' y_j$  و  $\hat{\sigma}_{1j}^2 = n^{-1} (y_j' M_z y_j)$  و برآوردگرهای شبیه سازی شده از  $\hat{b}_{1*}(R) = \frac{1}{R} \sum_{j=1}^R \hat{b}_{1j} = (Z'Z)^{-1} Z' \left( \frac{1}{R} \sum_{j=1}^R y_j \right)$  و  $\hat{\sigma}_{1*}^2(R) = \frac{1}{R} \sum_{j=1}^R \hat{\sigma}_{1j}^2 = \frac{1}{nR} \left( \sum_{j=1}^R y_j' M_z y_j \right)$



## ۷ شبیه سازی

در این شبیه سازی فرض شده است که مدل  $h : Y = Hb_h + u_h$  با  $u_h \sim N(0, \sigma_h^2)$  مولد داده‌ها است. فرض می‌کنیم  $b'_h = (2, 5, 6, -8, 7)$ ،  $\sigma_h^2 = 1$  و ماتریس طرح  $H$  ماتریسی تصادفی و  $n \times 5$  در نظر گرفته شده است. همچنین دو مدل  $f : Y = Xb_o + u_o$  و  $Y = Zb_1 + u_1$  با  $u_1 \sim N(0, 3)$  و  $u_o \sim N(0, 2)$  برای  $n \times k$  های طرح  $X$  و  $Z$  هستند که آن‌ها نیز به طور تصادفی تولید شده و به ترتیب دارای بعد  $n \times k_1$  و  $n \times k_2$  هستند. این شبیه سازی در محیط S-plus برای آماره آزمون‌ها و معیارهایی که در بخش‌های قبل محاسبه شده‌اند انجام گرفته است و برای تعداد نمونه‌های مختلف کد نویسی شده است. در برنامه نوشته شده تعداد تکرارها برابر  $r = 1000$  و تعداد نمونه‌های تولید شده برابر  $n = 10, 30, 100, 200, 300, 500$  در نظر گرفته شده‌اند. فراوانی نسبی حالت‌های حاصل به عنوان خروجی در جدول‌های بخش (۹) ارائه شده است. همچنین لازم به ذکر است سطح معناداری برای آزمون‌های کاکس و وونگ ۵٪ در نظر گرفته شده است.

## ۸ بحث و نتیجه گیری

تحلیل این جداول در جهت پاسخ به سوال‌هایی است که در بخش (۲) مطرح کردیم. در جداول  $R$  مخفف کلمه *Reject* به معنی رد شدن مدل و *equi.* مخفف *equivalent* به منظور معادل بودن دو مدل به کار رفته است. تمامی مدل‌های مورد بررسی در بخش (۷) تشریح شده‌اند، در این جداول تعداد پارامترهای هر مدل نسبت به تعداد پارامترهای مدل درست تغییر کرده است. همان‌طور که در بخش (۷) گفته شد تعداد پارامتر مدل درست، پنج است. مدل‌های مورد بررسی با تعداد پارامترهای نزدیک به پنج انتخاب شده است تا بتوان علاوه بر پاسخ به سوالات مطرح شده، تاثیر افزایش و کاهش تعداد پارامترها را در پذیرش و رد مدل‌ها بررسی کرد. در جدول (۱) مدل‌هایی با  $k_o = 3$  و  $k_1 = 8$  مورد بررسی قرار گرفته‌اند به طوری که هیچکدام درست-توصیف شده نیستند. این جدول برای پاسخ به این سوال آورده شده است که اگر آزمون کاکس هر دو مدل را رد کرد کدام مدل به مدل مولد داده‌ها نزدیکتر است؟ در جدول (۱) به دلیل این که هیچکدام از مدل‌ها درست-توصیف شده نیستند و همچنین تعداد پارامتر آن‌ها با تعداد پارامتر مدل درست متفاوت است با افزایش تعداد نمونه از  $n = 10$  به  $n = 500$  احتمال رد شدن هر دو مدل از  $517\%$  در  $n = 10$  به  $836\%$  در  $n = 500$  می‌رسد. اگر به سطر دوم جدول آزمون کاکس یعنی رد  $H_f$  نه  $H_g$  توجه کنید در  $n = 10$  این احتمال برابر  $443\%$  است که با افزایش نمونه به  $n = 500$  به مقدار  $162\%$  کاهش می‌یابد و این اتفاق در بقیه آماره‌ها نیز به نوعی رخ می‌دهد در آماره

وونگ در  $n = 10$  احتمال برتری  $f$  (۰/۲۹۲) کمتر از احتمال برتری  $g$  (۰/۴۹۲) است که با افزایش نمونه حتی از  $10$  به  $30$  این احتمالات تفاوت فاحشی پیدا می‌کنند، به طوری که در  $n = 500$  با احتمال  $0/947$  برتری  $f$  محسوس است. برای آماره  $AIC$  نیز روند مشابه‌ای تکرار می‌شود. اما در  $KICc$  حتی در  $n = 10$  فراوانی نسبی تعداد دفعاتی که  $KICc$  برای چگالی  $f$  کمتر از  $KICc$  برای چگالی  $g$  می‌شود، برابر  $0/996$  است. اما با افزایش تعداد نمونه و کاهش اثر جمله جریمه، مقدار این فراوانی نسبی کم می‌شود. اما باز اختلاف زیادی بین آن دو وجود دارد که موجب پذیرش مدل  $f$  می‌شود. در مابقی جدول‌های ارائه شده در این فصل مدل  $f$  درست-توصیف شده انتخاب شده است و برای مدل پیشنهادی دو حالت ۳ پارامتری و ۸ پارامتری در نظر گرفته شده است. این کار به این دلیل انجام گرفته است تا علاوه بر پاسخ به سوالات مطرح شده در بخش (۲) بتوان تأثیر کاهش یا افزایش تعداد پارامتر را نیز بررسی کرد. متأسفانه آزمون کاکس در این حالت نیز هر دو مدل را با احتمال بالاتری رد می‌کند، در صورتی که می‌بایست مدل درست-توصیف شده را بپذیرد به همین دلیل در این حالت برای نتیجه‌گیری و مقایسه از نتایج حاصل از شبیه‌سازی تصادفی آماره آزمون کاکس استفاده شده است. در جدول (۲) نتایج حاصل از شبیه‌سازی مدل درست-توصیف شده  $f$  در مقابل مدل ۳ پارامتری  $g$  آورده شده است. آماره آزمون کاکس در این حالت نتایج مورد انتظار را به دست نمی‌دهد. به همین دلیل برای نتیجه‌گیری و مقایسه از جدول (۳) که نتایج حاصل از شبیه‌سازی تصادفی است استفاده شده است که در همه آماره‌ها و آزمون‌ها برتری مدل  $f$  با احتمال بسیار بالا مشخص است. برای مثال در آزمون وونگ حتی برای  $n = 10$  احتمال برتری  $f$  برابر  $0/872$  است.

در جدول (۴) نتایج حاصل از شبیه‌سازی مدل درست-توصیف شده  $f$  در مقابل مدل ۸ پارامتری  $g$  آورده شده است. لازم به ذکر است به دلیل غیرمنطقی بودن نتایج آزمون کاکس از نتایج جدول (۵) استفاده می‌کنیم. با توجه به مقادیر جدول (۴) و (۵) دوباره برتری مدل  $f$  کاملاً مشخص است. می‌توان این نتیجه‌گیری را نیز داشت که افزایش تعداد پارامتر مدل رقیب، از ۳ به ۸ تأثیری در برگزیده شدن مدل درست-توصیف شده ندارد. به طور کلی در مورد مدل‌های رگرسیونی خطی غیرتودرتو با خطای نرمال می‌توان این نتیجه را گرفت که زمانی که آزمون کاکس هر دو مدل را به عنوان بد-توصیف شده تشخیص می‌دهد و هر دو مدل را رد می‌کند برای انتخاب مدل باید به نتایج آزمون وونگ و بقیه معیارهای موجود توجه کرد و مدل برگزیده شده توسط آن‌ها را به عنوان مدل بهتر انتخاب کرد. اگر سایر معیارها و آزمون وونگ نیز مدل‌ها را معادل تشخیص دادند تفاوت معناداری بین مدل‌ها وجود ندارد. اما باید به یاد داشت که در این حالت هر دو مدل بد-توصیف شده‌اند. در حالتی که آزمون کاکس مدلی را برمی‌گزیند آن مدل به طور حتم خوب-توصیف شده است و باید از آن در استنباط استفاده کرد. اگر چه آزمون وونگ و بقیه معیارها نیز آن مدل را با احتمال بالاتری انتخاب نمایند اما توجه ما در وحله اول به نتیجه آزمون کاکس خواهد بود. آزمون کاکس را می‌توان برای انتخاب مدل‌های خوب-توصیف شده به کار برد. اگر چه محاسبه آماره آزمون کاکس بسیار مشکل است اما معمولاً به کار گرفته می‌شود و در واقع می‌توان چنین نتیجه‌گیری کرد که مدل انتخابی توسط آزمون کاکس حداقل به خوبی سایر مدل‌های رقابتی است. محاسبه‌ی آماره آزمون وونگ ساده‌تر از محاسبه آماره آزمون کاکس است و به همین

دلیل هم فراگیری بیشتری نسبت به آزمون کاکس دارد. استفاده از معیارهای  $AIC$ ،  $BIC$ ،  $KICc$ ،  $KIC$  در کنار این دو آزمون نزدیکی مدل‌های انتخابی را به مدل مولد داده‌ها نشان می‌دهد و با توجه به محاسبه‌ی ساده این معیارها و نتایج مناسب آن‌ها حتی برای نمونه‌های کوچک می‌توان آن‌ها را به عنوان معیارهای مناسبی در انتخاب مدل به کار برد.

جدول ۱: جدول حاصل از شبیه‌سازی ( $k_0 = 3$ ,  $k_1 = 8$ )

Statistics	Conclusion	$n=10$	$n=30$	$n=100$	$n=200$	$n=300$	$n=500$
Cox	$R. H_g$ but not $H_f$	۰/۰۳۸	۰/۰۷۱	۰/۰۰۲	۰/۰۰۶	۰/۰۰۱	۰/۰۰۲
	$R. H_f$ but not $H_g$	۰/۴۴۳	۰/۵۱۲	۰/۳۷۲	۰/۲۳۷	۰/۲۱۲	۰/۱۶۲
	$R. both H_f$ and $H_g$	۰/۵۱۷	۰/۴۱۲	۰/۶۰۵	۰/۷۵۷	۰/۷۸۷	۰/۸۳۶
	$R. neither H_f$ or $H_g$	۰/۰۰۲	۰/۰۰۵	۰/۰۰۱	۰	۰	۰
Vuong	$f$ and $g$ are equi.	۰/۲۱۶	۰/۰۸۸	۰/۰۲۶	۰/۰۳۲	۰/۰۲۸	۰/۰۵۳
	$f$ is better than $g$	۰/۲۹۲	۰/۸۹۵	۰/۹۷۴	۰/۹۶۸	۰/۹۷۲	۰/۹۴۷
	$g$ is better than $f$	۰/۴۹۲	۰/۰۱۷	۰	۰	۰	۰
AIC	$AICf < AICg$	۰/۲۹۴	۰/۷۸۹	۰/۸۶۹	۰/۸۶۱	۰/۸۵۱	۰/۸۴۶
	$AICg < AICf$	۰/۷۰۶	۰/۲۱۱	۰/۱۳۱	۰/۱۳۹	۰/۱۴۹	۰/۱۵۴
KIC	$KICf < KICg$	۰/۴۹۸	۰/۹۲۱	۰/۹۷۲	۰/۹۳۷	۰/۹۶۸	۰/۹۷۱
	$KICg < KICf$	۰/۵۰۲	۰/۰۷۹	۰/۰۲۸	۰/۰۲۷	۰/۰۳۲	۰/۰۲۹
KICc	$KICcf < KICcg$	۰/۹۹۶	۰/۹۹۴	۰/۹۸۲	۰/۹۷۶	۰/۹۷۲	۰/۹۷۴
	$KICcg < KICcf$	۰/۰۰۴	۰/۰۰۶	۰/۰۱۸	۰/۰۲۴	۰/۰۲۸	۰/۰۲۶
BIC	$BICf < BICg$	۰/۳۶۸	۰/۹۵۷	۱	۱	۰/۹۹۹	۰/۹۹۹
	$BICg < BICf$	۰/۶۳۲	۰/۰۴۳	۰	۰	۰/۰۰۱	۰/۰۰۱

مراجع

- [1] Akaike, H. (1973). Information Theory and on Extension of the Likelihood Ratio Principle, In *2nd International Symposium on Information Theory*, eds B. N. Petrov & F. Csaki, Budapest: Akademiai Kiado, 267-281.

جدول ۲: جدول حاصل از شبیه سازی زمانی که مدل  $f$  درست-توصیف شده است. ( $k_0 = 5, k_1 = 3$ )

Statistics	Conclusion	$n=10$	$n=20$	$n=100$	$n=200$	$n=300$	$n=500$
Cox	$R. H_g \text{ but not } H_f$	۰/۳۶۴	۰/۳۶۴	۰/۲۱۷	۰/۱۶۸	۰/۱۲۴	۰/۱۲۳
	$R. H_f \text{ but not } H_g$	۰/۰۰۴	۰	۰	۰	۰	۰
	$R. \text{ both } H_f \text{ and } H_g$	۰/۶۲۸	۰/۶۳۶	۰/۷۸۳	۰/۸۳۲	۰/۸۷۶	۰/۸۷۷
	$R. \text{ neither } H_f \text{ or } H_g$	۰/۰۰۴	۰	۰	۰	۰	۰
Vuong	$f \text{ and } g \text{ are equi.}$	۰/۱۲۸	۰/۰۱۹	۰/۰۱۰	۰/۰۰۶	۰/۰۰۸	۰/۰۰۶
	$f \text{ is better than } g$	۰/۸۷۲	۰/۹۸۱	۰/۹۹۰	۰/۹۹۴	۰/۹۹۲	۰/۹۹۴
	$g \text{ is better than } f$	۰	۰	۰	۰	۰	۰
AIC	$AIC_f < AIC_g$	۱	۱	۱	۱	۱	۱
	$AIC_g < AIC_f$	۰	۰	۰	۰	۰	۰
KIC	$KIC_f < KIC_g$	۱	۱	۱	۱	۱	۱
	$KIC_g < KIC_f$	۰	۰	۰	۰	۰	۰
KICc	$KIC_{cf} < KIC_{cg}$	۰/۷۵۵	۱	۱	۱	۱	۱
	$KIC_{cg} < KIC_{cf}$	۰/۲۴۵	۰	۰	۰	۰	۰
BIC	$BIC_f < BIC_g$	۱	۱	۱	۱	۱	۱
	$BIC_g < BIC_f$	۰	۰	۰	۰	۰	۰

جدول ۳: جدول حاصل از شبیه سازی تصادفی زمانی که مدل  $f$  درست-توصیف شده است. ( $k_0 = 5, k_1 = 3$ )

Statistics	Conclusion	$n=10$	$n=20$	$n=100$	$n=200$	$n=300$	$n=500$
Cox	$R. H_g \text{ but not } H_f$	۰/۹۷۲	۰/۹۹۷	۱	۱	۱	۱
	$R. H_f \text{ but not } H_g$	۰	۰	۰	۰	۰	۰
	$R. \text{ both } H_f \text{ and } H_g$	۰/۰۲۸	۰/۰۰۲	۰	۰	۰	۰
	$R. \text{ neither } H_f \text{ or } H_g$	۰	۰	۰	۰	۰	۰

جدول ۴: جدول حاصل از شبیه سازی زمانی که مدل  $f$  درست-توصیف شده است. ( $k_0 = 5, k_1 = 8$ )

Statistics	Conclusion	$n=10$	$n=30$	$n=100$	$n=200$	$n=300$	$n=500$
Cox	$R. H_g$ but not $H_f$	۰/۴۴۰	۰/۵۷۵	۰/۳۸۸	۰/۲۴۴	۰/۲۴۸	۰/۱۷۹
	$R. H_f$ but not $H_g$	۰/۰۷۱	۰	۰	۰	۰	۰
	$R. both H_f$ and $H_g$	۰/۳۹۰	۰/۴۲۵	۰/۶۱۲	۰/۷۵۶	۰/۷۵۲	۰/۸۲۱
	$R. neither H_f$ or $H_g$	۰/۰۹۹	۰	۰	۰	۰	۰
Vuong	$f$ and $g$ are equi.	۰/۱۹۹	۰/۰۱۴	۰/۰۰۹	۰/۰۱۴	۰/۰۰۸	۰/۰۰۷
	$f$ is better than $g$	۰/۸۰۱	۰/۹۸۶	۰/۹۹۱	۰/۹۸۶	۰/۹۹۲	۰/۹۹۳
	$g$ is better than $f$	۰	۰	۰	۰	۰	۰
AIC	$AIC_f < AIC_g$	۰/۹۹۱	۱	۱	۱	۱	۱
	$AIC_g < AIC_f$	۰/۰۰۹	۰	۰	۰	۰	۰
KIC	$KIC_f < KIC_g$	۰/۹۹۳	۱	۱	۱	۱	۱
	$KIC_g < KIC_f$	۰/۰۰۷	۰	۰	۰	۰	۰
KICc	$KIC_{cf} < KIC_{cg}$	۱	۱	۱	۱	۱	۱
	$KIC_{cg} < KIC_{cf}$	۰	۰	۰	۰	۰	۰
BIC	$BIC_f < BIC_g$	۰/۹۹۱	۱	۱	۱	۱	۱
	$BIC_g < BIC_f$	۰/۰۰۹	۰	۰	۰	۰	۰

جدول ۵: جدول حاصل از شبیه سازی تصادفی زمانی که مدل  $f$  درست-توصیف شده است. ( $k_0 = 5, k_1 = 8$ )

Statistics	Conclusion	$n=10$	$n=30$	$n=100$	$n=200$	$n=300$	$n=500$
Cox	$R. H_g$ but not $H_f$	۰/۹۷۴	۱	۱	۱	۱	۱
	$R. H_f$ but not $H_g$	۰	۰	۰	۰	۰	۰
	$R. both H_f$ and $H_g$	۰/۰۲۶	۰	۰	۰	۰	۰
	$R. neither H_f$ or $H_g$	۰	۰	۰	۰	۰	۰

- [2] Cavanaugh, J.E. (1999). A Large-Sample Model Selection Criterion Based on Kullback's Symmetric Divergence, *Statistics & Probability Letters*, **42**, 333-343.
- [3] Cavanaugh, J.E. (2004). Criterion for Linear Model Selection Based on Kullback's Symmetric Divergence, *Statistics & Probability Letters*, **63**, 262-279.
- [4] Cox, D.R. (1962). Further Results on Tests of Separate Families of Hypotheses, *Journal of the Royal Statistical Society*, **24**, 406-424.
- [5] Lien, D. and Vuong, Q.H. (1989). Selection the Best Linear Regression Model: A Classical Approach, *Social Science Working Paper 606* .
- [6] Pesaran, M.H. (1974). On the General Problem of Model Selection, *The Review of Economic Studies*, Vol. 41, NO. 2, pp: 153-171.
- [7] Pesaran, M.H. and Pesaran, B. (1993). A Simulation Approach to the Problem of Computing Cox's Statistic for Testing Nonnested Models, *Journal of Econometrics* , **57**, 377-392.
- [8] Vuong, Q.H. (1989). Likelihood Ratio Tests for Model Selection and Non-Nested Hypotheses, *Econometrica* , Vol. 57, NO. 2, pp: 307-333.