

انتخاب متغیر با استفاده از تابع تاوان

هادی موقری^۱، سید محمد ابراهیم حسینی نسب^۲

چکیده:

علی‌رغم کاربرد گسترده‌ی معیارهایی نظیر AIC و BIC در زمینه‌ی انتخاب متغیر، استفاده‌ی از آنها سبب بی‌شباتی می‌شود؛ یعنی تغییرات اندک در داده‌ها ممکن است نتیجه‌ی انتخاب متغیر را به طور فاحشی تغییر دهد. از روش‌هایی که اخیراً در زمینه‌ی انتخاب متغیر بسیار مورد توجه قرار گرفته است، استفاده از تابع تاوان می‌باشد. تابع تاوان SCAD، به دلیل ویژگی‌های بهینه‌ی برآورده‌گر حاصل، یکی از مقبول‌ترین توابع تاوان در زمینه‌ی انتخاب متغیر می‌باشد. در این مقاله علاوه بر معرفی اجمالی برخی از توابع تاوان و بسته‌های نرم‌افزاری مرتبط با آنها، تابع تاوان SCAD و عملکرد آن برای انتخاب متغیر را مورد ارزیابی قرار می‌دهیم. در انتهای نیز به تحلیل یک مجموعه داده‌ی واقعی پرداخته و نتایج را گزارش می‌کنیم.

واژه‌های کلیدی: انتخاب متغیر، تابع تاوان SCAD، AIC، BIC، LASSO

۱ مقدمه

در بسیاری از مسایل عملی، تحلیل‌گر با تعداد زیادی از متغیرهای توضیحی مواجه است که بنا به ضرورت باید تنها تعداد محدودی از آنها را جهت حضور در مدل انتخاب کند. زیرا اگر مدل حاوی متغیرهای زاید و بی‌همیت باشد یا به اصطلاح دچار بیش‌برآورده^۴ گردد، علاوه بر آنکه تعبیر و تفسیر چنین مدلی مشکل خواهد شد جمع‌آوری مشاهدات برای چنین مدلی مستلزم صرف وقت و هزینه‌ی زیاد می‌باشد. بر عکس اگر مدل دچار کم‌برآورده^۵ گردد در این صورت مدل حاصل، ممکن است داده‌های موجود را به خوبی توصیف نکند. پیشرفت روزافزون علوم مختلف و به وجود آمدن تکنیک‌های جدید این امکان را فراهم کرده است تا بتوان حجم وسیعی از داده‌ها در مورد متغیرهای مختلف را بدست آورد. وجود این داده‌های حجیم در اکثر شاخه‌ها از مطالعات بهداشتی گرفته تا مدیریت ریسک تفکر آماری را به طور کلی دگرگون کرده است. در این گونه موارد انتخاب متغیر^۳، خود را به عنوان یک ابزار بسیار توأم‌مند و حیاتی برای زمینه‌های اکتشافی در علوم مختلف مطرح کرده است. فن ولی [۹] به طور مفصل به بررسی اهمیت انتخاب متغیر در بسیاری از زمینه‌های علمی پرداختند.

^۱دانشکده علوم ریاضی، دانشگاه تربیت مدرس

^۲دانشکده علوم ریاضی، دانشگاه شهید بهشتی

^۳Variable Selection

^۴Overestimation

^۵Underestimation

می‌شود، نتیجه‌ی انتخاب مدل به طرز فاحشی تغییر کند. یک راه غلبه بر این مشکل استفاده از تابع توان^۸ برای انتخاب متغیر می‌باشد. لازم به ذکر است که معیارهای اطلاع نیز به نوعی با مفهوم توانیدن در ارتباط هستند [۱۲]. در صورت استفاده از تابع توان دو فرآیند انتخاب مدل و برآورد ضرایب رگرسیونی به طور همزمان صورت می‌پذیرد در حالی که این نکته در مورد معیارهایی نظری AIC صادق نیست و این باعث می‌شود برای مدل‌های با بعد نسبتاً بزرگ، فرآیند انتخاب متغیر بسیار وقت‌گیر باشد.

بخش دوم این مقاله به رابطه‌ی بین معیارهای اطلاع و مفهوم توانیدن می‌پردازد. بخش سوم به معرفی انواع توابع توان و امکانات نرم افزاری موجود برای استفاده از آنها اختصاص دارد. تابع توان SCAD^۹ در بخش چهارم معرفی می‌شود و در ادامه نیز روش‌های انتخاب پارامتر نظم در بخش پنجم بیان می‌شوند. همچنین مطالعات شبیه‌سازی، شامل مقایسه‌ی بین انواع روش‌های انتخاب متغیر و نیز بررسی تاثیر پارامتر نظم بر عملکرد تابع توان در بخش ششم آورده می‌شود. سرانجام در بخش هفتم روش‌های معرفی شده را بر روی یک مجموعه داده‌ی واقعی اجرا می‌کیم.

۲ معیار اطلاع و مفهوم توانیدن

تعداد زیادی از معیارهای انتخاب مدل بر اساس نظریه‌ی اطلاع پدید آمده‌اند. یکی از پرکاربردترین این معیارها،

(برای آشنایی با اثرات تخصیص مدل نادرست به رنچر و شالج [۱۷]، صفحات ۱۶۹–۱۷۸ مراجعه شود). پیدا کردن مدلی که گرفتار مسایل بیش برآورده و کم برآورده نباشد در حیطه‌ی مربوط به انتخاب متغیر قرار می‌گیرد. مدل رگرسیون خطی زیر را در نظر بگیرید:

$$y_i = \beta_1 x_{i1} + \dots + \beta_d x_{id} + \epsilon_i, \quad i = 1, \dots, n, \quad (1)$$

به طوریکه $x_{id}, \dots, x_{i1}, y_i$ به ترتیب متغیر پاسخ و متغیر توضیحی مرتبط با آن در نمونه‌ی \mathcal{D} می‌باشند. علاوه بر آن، β_d, \dots, β_1 ضرایب رگرسیونی و ϵ_i ‌ها نیز خطای تصادفی مدل و مستقل از یکدیگر با میانگین صفر و واریانس σ^2 می‌باشند. هدف از انتخاب متغیر، تعیین زیر مجموعه‌ای از متغیرهای توضیحی x_1, \dots, x_d است به گونه‌ای که در توصیف متغیر پاسخ y بهترین عملکرد را در مقابل سایر مدل‌های زیر مجموعه داشته باشد. تا کنون معیارها و روش‌های متنوعی برای انتخاب متغیر ارایه شده‌اند که معروفترین آنها معیار اطلاع آکائیک (AIC)^۶ و معیار اطلاع بیزی (BIC)^۷ است که به ترتیب توسط آکائیک [۲] و شوارتز [۱۸] معرفی شدند. علی‌رغم کاربرد گسترده‌ای که این معیارها در زمینه‌ی انتخاب متغیر دارند استفاده‌ی از آنها باعث بی‌ثبتی در انتخاب متغیر می‌شود [۳]. زیرا در صورت استفاده از این معیارها در مورد هر ضریب رگرسیونی تنها قادر به اتخاذ دو تصمیم هستیم؛ یا متغیر مرتبط با آن ضریب در مدل حضور پیدا می‌کند یا نه و این باعث می‌شود زمانی که مجموعه‌ی داده‌ها دستخوش تغییرات اندک

Akaike Information Criterion^۶

Bayesian Information Criterion^۷

Penalty Function^۸

Smoothly Clipped Absolute Deviation^۹

۳ معرفی چند تابع تاوان

روش معمول برای برآورد ضرایب رگرسیونی در مدل (۱)، استفاده از توان‌های دوم باقیمانده می‌باشد که منجر به $y = X'X^{-1}y = \hat{\beta}_{ols}$ می‌گردد که در آن X و y به ترتیب ماتریس مشاهدات و بردار متغیر پاسخ هستند. اما زمانی که بین متغیرهای توضیحی همبستگی وجود داشته باشد، این برآوردهای ناقصی همراه خواهد شد که مهمترین آنها فاصله گرفتن $\hat{\beta}_{ols}$ از مقدار واقعی β و در نتیجه بزرگ شدن طول بردار $\hat{\beta}_{ols}$ است [۱۲]. برای رفع این مشکل هورل و کنارد [۱۳] استفاده از تابع هدف زیر را جهت برآورد ضرایب رگرسیونی پیشنهاد دادند:

$$\min_{\beta} \{(y - X\beta)'(y - X\beta)\} \quad s.t. \quad \sum_{j=1}^d \beta_j^2 < c. \quad (5)$$

در رابطه‌ی فوق β بردار ضرایب رگرسیونی است. شرط $\sum_{j=1}^d \beta_j^2 < c$ با کوچک کردن ضرایب رگرسیونی به سمت مبدأ، از بزرگ شدن طول بردار برآورد جلوگیری می‌کند. مساله‌ی مینیمم سازی مشروط فوق، معادل با مینیمم کردن تابع غیرشرطی زیر می‌باشد:

$$\min_{\beta} \{(y - X\beta)'(y - X\beta) + \lambda \sum_{j=1}^d \beta_j^2\}. \quad (6)$$

در عبارت فوق، λ را که متناظر با c و با استفاده از مشاهدات بدست می‌آید (مونت‌گمری [۱۶]، صفحات ۳۴۳–۳۴۹)، پارامتر نظم ${}^{\circ}$ می‌نامند. با استفاده از تابع (۶) برآوردهای $\hat{\beta}_{ridge} = (X'X + \lambda I)^{-1}X'y$ حاصل می‌شود که در آن I یک ماتریس واحد است. فرانک و فریدمن [۱۰]

است که به صورت زیر معرفی می‌شود [۲]:

$$AIC = -2\ell + 2p. \quad (2)$$

در رابطه‌ی فوق، ℓ لگاریتم تابع درستنمایی و p تعداد ضرایب رگرسیونی موجود در مدل می‌باشند. هر مدل زیر مجموعه با AIC کمتر، بر سایر مدل‌های زیر مجموعه برتری دارد. به دنبال معرفی AIC معیارهای متعدد دیگری پدید آمدند که معروفترین آنها معیار اطلاع شوارتز (SIC) یا معیار اطلاع بیزی (BIC) است و به صورت زیر تعریف می‌شود [۱۸]:

$$BIC = -2\ell + p \ln n. \quad (3)$$

در عبارت فوق n حجم نمونه است. برای آشنایی با سایر معیارهای اطلاع و نقش نظریه‌ی اطلاع در معرفی آنها به بورنهم و اندرسون [۱۴] مراجعه کنید. اگر جملات خطای مدل (۱) دارای توزیع نرمال باشند معیارهای (۲) و (۳)، به صورت مجموع توان‌های دوم باقیمانده‌ی تاوانیده‌ی زیر حاصل می‌شوند (با فرض معلوم بودن σ^2):

$$\frac{RSS_p}{\sigma^2} + pF, \quad (4)$$

که در آن RSS_p مجموع توان‌های دوم باقیمانده‌ی مدل با بعد p می‌باشد [۱۲]. F که یک مقدار از پیش تعیین شده است، میزان تاوانی است که برای بعد مدل در نظر گرفته می‌شود. واضح است که معیار اطلاع آکائیک و بیزی را می‌توان از رابطه‌ی (۴) به ترتیب با قرار دادن

$$F = \ln n \quad \text{و} \quad F = 2$$

tuning parametr ${}^{\circ}$
Ridge ^{۱۱}

متغیر را در مدل نهایی می‌دهد. این مشکل به وسیله‌ی زو و هستی [۲۲] رفع شده است. مشکل دیگر برآوردنگر LASSO ناسازگاری آن است. زو [۲۱] شرط لازم برای سازگاری این برآوردنگر را بیان و فرم اصلاح شده‌ای از برآوردنگر LASSO را که دیگر با مشکل ناسازگاری دست به گربیان نباشد، ارایه نمود.

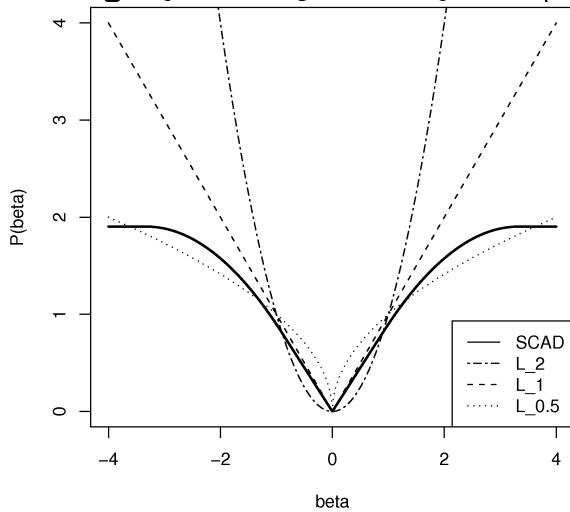
به موازات معرفی انواع توابع تاوان، الگوریتم‌ها و روش‌های مختلفی برای محاسبه‌ی برآوردنگرهای فوق ارایه شدند. به عنوان مثال شوتینگ الگوریتم^{۱۳} [۱۱] و رگرسیون کمترین زاویه^{۱۴} [۷] جهت محاسبه‌ی برآوردنگر LASSO مطرح شدند. الگوریتم تقریب درجه‌ی دوم موضعی (LQA)^{۱۵} نیز در رابطه با تابع تاوان SCAD، ایجاد بسته‌های مختلف امکان اجرای اکثر این الگوریتم‌ها را فراهم کرده‌اند. برای مثال، بسته‌ی brdgrun و lasso در نرم‌افزار S-Plus به ترتیب با استفاده از شوتینگ الگوریتم والگوریتم پیشنهادی تیب‌شیرانی [۱۹]، برای محاسبه‌ی برآوردنگر LASSO ایجاد شدند. بسته‌ی lars در نرم‌افزار R، برای استفاده از روش رگرسیون کمترین زاویه ایجاد شد. روش PROC SCADLS SAS امکان اجرای الگوریتم LQA را برای تابع تاوان SCAD فراهم کرده است [۶].

با استفاده از ایده‌ی به کار رفته در رگرسیون ستیغی،

$$\sum_{j=1}^d |\beta_j|^{\gamma} = L_{\gamma}$$
 خانواده‌ی توابع^{۱۶} را جهت برآورد β در تابع هدف (۶) معرفی کردند. واضح است که برآوردنگر ستیغی به ازای $\gamma = 2$ حاصل می‌شود. اما تابع L_{γ} تنها به ازای $1 \leq \gamma < 2$ توانایی انتخاب متغیر را دارد (۸) و (۱۹) یعنی با برابر صفر قراردادن ضرایب کم اهمیت و بی‌اهمیت سبب حذف آنها از مدل می‌شوند. بنابراین رگرسیون ستیغی نمی‌تواند به عنوان یک روش انتخاب متغیر مطرح باشد. تیب‌شیرانی [۱۹] تابع L_1 را جهت انتخاب متغیر در تابع هدف (۶) به کار برد و برآوردنگر حاصل از آن را تحت عنوان LASSO^{۱۲} معرفی نمود. روش LASSO پنجره‌ی جدیدی را به روی مبحث انتخاب متغیر گشود به طوری که بسیاری از روش‌های انتخاب متغیر که بعد از سال ۱۹۹۶ ارایه شدند به نوعی با LASSO در ارتباط هستند و هر یک با هدف اصلاح یکی از نقاط ضعف LASSO ایجاد شدند. به عنوان مثال، به دلیل اینکه در روش LASSO ضرایب بزرگ نیز تاوانیده می‌شوند (به سمت مبدا منقبض می‌شوند)، ضرایب کوچکتر فرصت حضور در مدل را پیدا می‌کنند و این سبب بیش برآورده می‌گردد. فن ولی [۸] برای رفع این نقیصه تابع تاوان SCAD را معرفی کردند (این تابع در بخش بعد معرفی می‌شود). مشکل عمدۀ دیگر در ارتباط با مسائلی است که در آنها تعداد متغیرهای توضیحی (d) بسیار بزرگتر از حجم نمونه (n) است. در این حالت LASSO اجازه‌ی حضور حداقل n

Least Absolute Shrikage and Selection Operotor^{۱۲}Shooting Algorithm^{۱۳}Least Angle Regression^{۱۴}Local Quadratic Approximation^{۱۵}

۱ را ببینید). در تابع (۷) دو پارامتر a و λ وجود دارد. فن ولی [۸] با یک مطالعه‌ی بیزی نشان دادند که مقدار $3/7$ برای a یک انتخاب مناسب است. به همین دلیل تابع SCAD را تنها با اندیس λ نشان‌گذاری می‌کنند.



شکل ۱. نحوه‌ی تاوانیدن ضرایب، توسط تابع تاوان مختلف.

فن ولی [۸] برای برآورد β از مجموع توان‌های دوم باقیمانده‌ی تاوانیده‌ی زیر:

$$\frac{1}{n}(\mathbf{y} - \mathbf{X}\beta)'(\mathbf{y} - \mathbf{X}\beta) + \sum_{j=1}^d P_\lambda(|\beta_j|), \quad (8)$$

یا به طور معادل

$$(\mathbf{y} - \mathbf{X}\beta)'(\mathbf{y} - \mathbf{X}\beta) + n \sum_{j=1}^d P_\lambda(|\beta_j|), \quad (9)$$

استفاده کردند. که در آنها $(|\beta_j|)P_\lambda(|\beta_j|)$ در (۷) تعریف شده است.

مشکل استفاده از تابع تاوان SCAD عدم مشتق‌پذیری آن در مبدأ مختصات می‌باشد. به همین منظور فن ولی [۸] ابتدا تابع تاوان SCAD را با یک تابع درجه‌ی دوم تقریب زده و به دنبال آن با استفاده از الگوریتم تکراری نیوتن-

۴ تابع تاوان SCAD

فن ولی [۸] ویژگی‌های یک تابع تاوان خوب را به صورت (i) ناریبی، (ii) تنکی^{۱۶} و (iii) پیوستگی بیان کردند. هر کدام از این ویژگی‌ها در ارتباط با یکی از روش‌های معرفی شده‌ی قبلی می‌باشند. همانطور که در بخش سوم اشاره شد، روش LASSO با تاوانیدن ضرایب LASSO بزرگ سبب بیش‌برآورده می‌گردد و در نتیجه LASSO از ویژگی ناریبی بی‌بهره است. رگرسیون ستیغی از ویژگی تنکی بی‌بهره است زیرا توانایی خارج کرن ضرایب بی‌اهمیت از مدل را ندارد. ویژگی سوم نیز به معیارهایی نظیر AIC اشاره دارد که استفاده‌ی از آنها موجب بی‌ثباتی در انتخاب متغیر می‌شود [۳]. دلیل این بی‌ثباتی نیز عدم استفاده از یک تابع تاوان پیوسته است [۸].

با توجه به این سه ویژگی، فن ولی [۸] تابع تاوان SCAD را به صورت زیر معرفی کردند:

$$P_\lambda(|\beta_j|) = \begin{cases} \frac{\lambda|\beta_j|}{(a^r-1)\lambda^r - (|\beta_j|-a\lambda)^r} & 0 \leq |\beta_j| < \lambda \\ \frac{(a+1)\lambda^r}{r(a-1)} & \lambda \leq |\beta_j| < a\lambda \\ 0 & |\beta_j| \geq a\lambda \end{cases}, \quad (7)$$

به طوریکه $0 < \lambda < a$. پارامتر a شکل تابع تاوان SCAD را کنترل می‌کند به طوری که هر چه $a \rightarrow \infty$ شکل تابع SCAD به شکل L_1 می‌پیوندد و عملکرد تابع تاوان SCAD مشابه عملکرد LASSO خواهد شد. نمودار SCAD به همراه نمودار توابع L_1 ، L_2 و $L_{0.5}$ در شکل ۱ نشان داده شده است. تابع تاوان SCAD برخلاف LASSO، برای ضرایبی که از یک مقدار به خصوص $(a\lambda)$ بزرگتر باشند تاوان ثابتی را در نظر می‌گیرد (شکل

۱.۵ اعتبارسنجی متقابل

در روش اعتبارسنجی متقابل (CV) مشاهدات به دو گروه تقسیم می‌شوند. با کمک گروه اول، مدل را برازش داده و توسط گروه دوم، مدل برازش شده، ارزیابی می‌شود. به عنوان مثال اگر n مشاهده به صورت (x_i, y_i) موجود باشند و با استفاده از $(1 - n)$ تا از این مشاهدات، یک مدل برازش دهیم یا به عبارت دیگر تنها یکی از این مشاهدات را کنار بگذاریم، در این صورت معیار CV به صورت زیر تعریف می‌شود:

$$CV(\lambda) = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_{\lambda}^{-i})^2,$$

که در آن \hat{y}_{λ}^{-i} بیانگر مقدار برازش شده پس از کنار گذاشتن i -امین مشاهده است. در این صورت λ مورد نظر متناظر با λ ی خواهد بود که این معیار را می‌نیمم کند.

محاسبه‌ی $CV(\lambda)$ بسیار وقت‌گیر است. به همین دلیل کراون و واهب [۵] معیار اعتبارسنجی متقابل تعیین یافته (GCV) را به عنوان جایگزینی برای $CV(\lambda)$ به صورت زیر معرفی کردند:

$$GCV(\lambda) = \frac{(y - \hat{y}_{\lambda})'(y - \hat{y}_{\lambda})}{n(1 - \frac{\text{tr}(A(\lambda))}{n})^2}, \quad (11)$$

که در آن \hat{y}_{λ} بردار مقادیر برازش شده تحت ماتریس $A(\lambda)$ است که با توجه برآورده SCAD می‌آید:

$$\begin{aligned} \hat{y} &= X\hat{\beta} \\ &= X(X'X + n\Sigma_{\lambda})^{-1}X'y \\ &\equiv A(\lambda)y. \end{aligned} \quad (12)$$

رافسون به می‌نیمم کردنتابع هدف (۸) و یا به طور متناظرتابع هدف (۹) پرداختند. در مورد ویژگی‌های همگرایی این الگوریتم که با عنوان تقریب درجه‌ی دوم موضعی (LQA) شناخته می‌شود، به هانتر ولی [۱۴] مراجعه کنید. با استفاده از این الگوریتم برآورده SCAD در تکرار $(k+1)$ به صورت زیر حاصل می‌شود:

$$\beta^{(k+1)} = (X'X + n\Sigma_{\lambda}(\beta^k))^{-1}X'y, \quad (10)$$

$\Sigma_{\lambda}(\beta^{(k)}) = \text{diag}\left\{\frac{P'_{\lambda}(|\beta_1^{(k)}|)}{|\beta_1^{(k)}|}, \dots, \frac{P'_{\lambda}(|\beta_d^{(k)}|)}{|\beta_d^{(k)}|}\right\}$ که در آن $P'_{\lambda}(|\beta^{(k)}|)$ مشتق تابع تاوان SCAD در نقطه‌ی $\beta^{(k)}$ می‌باشد. این برآورده با برآورده‌گرستیغی شباهت زیادی دارد.

۵ انتخاب پارامتر نظم

اولین قدم در استفاده از هر تابع توانی انتخاب مقدار مناسب برای پارامتر نظم است. اگر مقدار پارامتر نظم خیلی بزرگ باشد متغیرهای بیشتری از مدل حذف می‌شوند که این، سبب کم برآورده مدل می‌شود. بر عکس، اگر مقدار پارامتر نظم خیلی کوچک باشد، باعث بیش برآورده خواهد شد (جدول ۱ را ملاحظه کنید). برخلاف معیارهای اطلاع که در آن تاوان بُعد (F) در رابطه‌ی \mathbb{F} ، یک مقدار ثابت و از پیش تعیین شده است، مقدار پارامتر نظم در روش‌هایی مانند LASSO با استفاده از مشاهدات محاسبه می‌شود. در این بخش دو روش را که کاربرد فراوانی برای این منظور دارند، معرفی می‌کنیم.

Cross Validation^{۱۷}
Generalized Cross Validation^{۱۸}

۶ مطالعات شبیه سازی

در این بخش با استفاده از شبیه سازی به مقایسه‌ی برخی از روش‌های انتخاب مدل می‌پردازیم. داده‌های مورد نیاز برای انجام شبیه‌سازی‌ها را از مدل زیر تولید کردیم:

$$\mathbf{y} = \mathbf{X}\beta_0 + \sigma\epsilon, \quad (14)$$

به طوریکه $\beta' = (3, 1.5, 0, 0, 2, 0, 0, 0, 0)$ و عناصر ماتریس \mathbf{X} و بردار ϵ از توزیع نرمال استاندارد تولید شده‌اند. ضمن اینکه برای حادتر کردن شرایط، همبستگی بین متغیرهای توضیحی x_i و x_j را برابر -0.5 قرار داده‌ایم. این شرایط را تیب‌شیرانی [۱۹] و فن و لی [۸] برای انجام شبیه سازی‌های خود به کاربردند. جهت مقایسه‌ی نتایج از سه شاخص Corr، Incorr و MRME استفاده نمودیم. Corr متوسط تعداد ضرایبی است که به درستی برابر صفر قرار می‌گیرند. از آنجایی که در بردار $\beta_0, \beta_1, \beta_2$ ضریب واقعاً برابر صفر هستند، لذا هر چه این شاخص به ۵ نزدیکتر باشد بهتر خواهد بود. به همین طریق Incorr متوسط تعداد ضرایبی است که به غلط برابر صفر قرار می‌گیرند. نزدیکی این شاخص به صفر، به منزله‌ی خوب بودن روش متناظر با آن از نظر شاخص Incorr می‌باشد. شاخص MRME نیز عبارتست از میانه‌ی مقادیر زیر که به ازای هر مجموعه داده‌ی تولید شده، محاسبه می‌گردد:

$$RME = \frac{(\hat{\beta}_{SCAD} - \beta_0)' \Sigma (\hat{\beta}_{SCAD} - \beta_0)}{(\hat{\beta}_{OLS} - \beta_0)' \Sigma (\hat{\beta}_{OLS} - \beta_0)},$$

به طوریکه RME ماتریس کوواریانس متغیرهای توضیحی است. $\hat{\beta}_{SCAD}$ نیز با استفاده از رابطه‌ی (۱۰) بدست

ماتریس $A(\lambda)$ را ماتریس تصویری 19 می‌گویند.

۲.۵ معیار BIC

لنگ و همکاران [۱۵] نشان دادند که اگر در روش LASSO پارامتر نظم با استفاده از معیارهایی نظری GCV انتخاب شود، برآوردگر حاصل ناسازگار خواهد بود. نکته‌ای مشابه با آن را ونگ و همکاران [۲۰] در مورد تابع تاوان SCAD بیان نمودند و نشان دادند که برآوردگر حاصل دچار بیش برآوردی می‌شود. آنها به جای بکارگیری معیار GCV، استفاده از معیار BIC را به صورت زیر پیشنهاد دادند:

$$BIC(\lambda) = -2\ell + DF_\lambda \ln n. \quad (12)$$

در اینجا نیز λ مورد نظر عبارت از λ ی خواهد بود که به ازای آن معیار فوق می‌نیمم می‌شود. نکته‌ی حائز اهمیت در مورد معیار (۱۲)، چگونگی تعریف DF_λ می‌باشد. اگر چه ونگ و همکاران [۲۰]، DF_λ را به صورت $(tr(A(\lambda)))$ تعریف کردند، با این حال اگر بخواهیم از تعریف معمول معیار BIC استفاده نماییم، DF_λ برابر تعداد ضرایب غیر صفر در برآوردگر SCAD می‌باشد [۶]. عملکرد این دو، در برآورد β تقریباً مشابه است. امکان استفاده از هر یک از این دو گزینه در روش PROC از نرم‌افزار SAS فراهم شده است.

^{۱۹} Projection Matrix
^{۲۰} Median of Relative Model Error

نتایج حاصل در جدول ۲ آورده شده است. ویژگی غالب توجه برآوردن SCAD این است که با انتخاب مناسب پارامتر نظم و نیز افزایش حجم نمونه، با احتمالی که به سمت یک میل می‌کند، ضرایبی که واقعاً برابر صفر هستند از مدل خارج می‌شوند [۸] البته برآوردن مطرح شده توسط زو [۲۱] نیز دارای این ویژگی می‌باشد. برای نشان دادن این ویژگی برآوردن SCAD، ضرایبی که در β برابر صفر بودند پیش‌پیش از مدل خارج شده و سایر ضرایب به وسیله کمترین توان‌های دوم باقیمانده برآورد شده‌اند. نتایج مربوط به این برآوردن در جدول ۲ با Oracle مشخص شده‌اند. همانطور که ملاحظه می‌شود با زیاد شدن حجم نمونه و نیز با کاهش واریانس خطای اعمکرد SCAD، AIC و BIC بهتر می‌شود؛ به طوریکه شاخص Corr افزایش می‌یابد و دو شاخص Incorr و MRME به تدریج کم می‌شوند. اما این نکته در مورد LASSO لزوماً برقرار نیست. به عنوان مثال شاخص MRME مربوط به این برآوردن به ازای هریک از مقادیر σ ، با افزایش حجم نمونه افزایش می‌یابد. SCAD و BIC اعمکرد مشابهی دارند به طوریکه به ازای هریک از مقادیر σ ، با زیاد شدن حجم نمونه نتایج مربوط به این دو، به نتایج بدست آمده از برآوردن Oracle نزدیک می‌شوند. شاخص Corr مربوط به برآوردن SCAD همواره بزرگتر از شاخص Corr مربوط به برآوردن LASSO می‌باشد و این برتری با زیاد شدن n بارزتر می‌گردد. شاخص Corr مربوط به معیار AIC همواره کوچکتر از شاخص Corr مربوط به معیار BIC می‌باشد و این نشان می‌دهد که معیار AIC در

می‌آید. RME در حقیقت نسبت خطای مدل برآوردن به خطای مدل برآوردن OLS است. علی‌رغم اینکه عملکرد توابع توان در درجه‌ی اول به پارامتر نظم وابسته است اما تا کنون هیچ گونه مطالعه‌ای بر اساس شبیه‌سازی در این زمینه انجام نشده است. به همین دلیل، در ابتدا جهت بررسی تاثیر مقدار پارامتر نظم بر عملکرد توابع توان SCAD و LASSO، 500 مجموعه‌ی داده از مدل (۱۴) به ازای $\sigma = 3$ تولید کرده و به ازای هریک از آنها سه مقدار متفاوت برای پارامتر نظم در نظر گرفته شد: i: $\lambda \in (1, 1/5)$; ii: $\lambda \in (1/5, 1/5)$; iii: $\lambda \in (1/5, 0)$ و در هریک از این حالات با استفاده از توابع توان SCAD و LASSO متغیرها انتخاب شدند.

نتایج حاصل در جدول ۱ آمده است.

همانطور که در جدول مذکور مشاهده می‌شود، با بزرگ شدن مقدار λ ، متناظر با افزایش شاخص Corr، شاخص Incorr نیز افزایش می‌یابد. این نتیجه به معنای آن است که با بزرگ شدن λ نه تنها ضرایب واقعاً صفر ($\beta_3, \beta_4, \beta_6, \beta_7, \beta_8$)، برابر صفر قرار می‌گیرند، بلکه ضرایب واقعاً مخالف صفر ($\beta_1, \beta_2, \beta_5$) نیز به غلط برابر صفر قرار می‌گیرند و این سبب کم برآورده می‌گردد.

اینک روش‌های مختلف انتخاب متغیر مقایسه می‌شوند. هرچند که این قسمت از شبیه‌سازی قبلاً به طور محدود توسط فن ولی [۸] انجام شده است ولی در اینجا، روش‌های مذکور به طور جامع‌تر و کامل‌تر با یکدیگر مقایسه می‌شوند. برای این منظور 500 مجموعه‌ی داده از مدل (۱۴) به ازای $\sigma = 6, 3, 1$ و حجم نمونه‌ی $n = 20, 40, 60$ تولید شدند و برای هر مجموعه‌ی داده، روش‌های مختلف انتخاب متغیر اعمال شدند.

مقایسه با معیار BIC تمایل به بیش برآورده دارد [۱۲].

جدول ۱. تاثیر پارامتر نظم بر انتخاب متغیر با استفاده ازتابع تاوان.

		$\lambda \in (0, 0/5)$		$\lambda \in (0/5, 1)$		$\lambda \in (1, 1/5)$	
		Corr	Incorr	Corr	Incorr	Corr	Incorr
$n = 20$	SCAD	۳/۱۶۲	۰/۴۹	۳/۹۶۲	۰/۶۸۲	۴/۳۸۲	۰/۸۸۶
	LASSO	۲/۲۱۸	۰/۲۲	۲/۷۱	۰/۲۲۶	۴/۱۸۶	۰/۵۹۴
$n = 40$	SCAD	۳/۸۸	۰/۱۸۴	۴/۴۲۶	۰/۲۷۲	۴/۵۸۸	۰/۵۲۸
	LASSO	۳/۳۵۲	۰/۰۵۴	۴	۰/۱۱	۴/۴۱۶	۰/۲۵۸
$n = 60$	SCAD	۴/۱۳۲	۰/۰۸۸	۴/۵۸	۰/۲۰۶	۴/۶۷۲	۰/۳۷۶
	LASSO	۳/۶۰۸	۰/۰۱	۴/۱۵۸	۰/۰۲۶	۴/۵۲۸	۰/۱۱۲

جدول ۲. مقایسه‌ی روش‌های انتخاب متغیر در مدل‌های رگرسیون خطی.

	$\sigma = 1$			$\sigma = 3$			$\sigma = 10$			
	Corr	Incorr	MRME $\times 100$	Corr	Incorr	MRME $\times 100$	Corr	Incorr	MRME $\times 100$	
$n = 20$	SCAD	۲/۹۹۲	۱/۱۲۸	۸۲/۲۰	۳/۶۶	۰/۹۹۴	۸۴/۸۲	۴/۹۴	۰/۰۱۲	۶۱/۸۳
	LASSO	۲/۸۸۴	۰/۷۹	۴۸/۴۴	۳/۱۶	۰/۲۴۴	۶۶/۴۵	۳/۰۱	۰/۰۰۲	۷۱/۹۱
	AIC	۳/۲۲۶	۱/۲۲۲	۸۷/۴۲	۳/۲۲۲	۰/۶۶	۹۱/۸۸	۳/۴۹	۰/۰۰۶	۸۰/۲۳
	BIC	۳/۹	۱/۶۱	۷۷/۳۷	۳/۹۳	۰/۸۱۸	۸۸/۱۹	۳/۹۸۴	۰/۰۱	۶۹/۵۲
	Oracle	۵	۰	۲۴/۶۹	۵	۰	۲۶/۱۸	۵	۰	۲۴/۵۶
$n = 40$	SCAD	۲/۷۷۸	۰/۸۱۸	۸۲/۲۲	۴/۱۵	۰/۲۸۲	۷۳/۵۷	۴/۷۷۶	۰	۳۹/۶۹
	LASSO	۳/۲۰۲	۰/۵۳۸	۶۱/۵۳	۳/۶۱۲	۰/۰۷۸	۶۸/۲۶	۳/۰۸۶	۰	۷۱/۲۷
	AIC	۳/۸۱۸	۰/۹۹	۹۱/۷۰	۳/۸۲۲	۰/۲۰۴	۸۰/۲۹	۳/۹۵۶	۰	۷۴/۴۱
	BIC	۴/۴۷	۱/۳۵۶	۸۹/۵۹	۴/۴۹۸	۰/۳۵۲	۶۹/۰۹	۴/۶۲۸	۰	۴۷/۷۹
	Oracle	۵	۰	۲۲/۷۸	۵	۰	۳۰/۲۵	۵	۰	۲۸/۸۳
$n = 60$	SCAD	۳/۱۹۴	۰/۵۷۴	۸۲/۲۲	۴/۳۸۸	۰/۱۶۴	۶۲/۲۸	۴/۸۲	۰	۳۸/۵۹
	LASSO	۳/۶	۰/۳۰۶	۶۵/۵۹	۳/۷۰۲	۰/۰۱۸	۷۲/۸۵	۳/۸۴	۰	۷۲/۸۹
	AIC	۳/۹۲۸	۰/۶۹۶	۸۹/۰۴	۳/۹۸۲	۰/۰۷۴	۷۴/۴۶	۴/۰۶۶	۰	۷۲/۱۲
	BIC	۴/۵۸۴	۱/۱۰۱	۹۱/۵۵	۴/۶۷۸	۰/۱۸۴	۵۲/۹۳	۴/۶۹	۰	۴۷/۰۸
	Oracle	۵	۰	۲۲/۹۳	۵	۰	۳۱/۸۹	۵	۰	۳۱/۷۹

۷ مثال کاربردی

در اینجا با یک مجموعه داده‌ی واقعی، نحوه‌ی بکارگیری روش‌های مختلف انتخاب متغیر را در عمل نشان می‌دهیم. داده‌های این مثال از ۱۸۰ دانش آموز دختر دوره‌ی راهنمایی شهر سمنان در سال تحصیلی ۱۳۸۶-۱۳۸۷ جمع‌آوری شده‌اند [۱]. هدف از این مطالعه بررسی تاثیر سبک‌های فرزند پروری و انواع عزت نفس بر عملکرد تحصیلی دانش آموزان می‌باشد. برای این منظور دو پرسشنامه‌ی عزت نفس آليس پوپ و سبک‌های فرزند پروری دیانا بامریند به ترتیب توسط دانش آموزان و والدین آنها تکمیل شد و با مقیاس بندی‌های به کار رفته معلوم گردید که هر دانش

علوه بر متغیرهای X_1, \dots, X_8 , اثرات متقابل X_6X_7 و X_7X_8 نیز به عنوان متغیرهای توضیحی در فرآیند انتخاب متغیر وارد مدل شدند. نتایج انتخاب

آموز به چه میزان از انواع عزت نفس (X_1 : عمومی، X_2 : تحصیلی، X_3 : خانوادگی، X_4 : اجتماعی و X_5 : جسمانی) و والدین آنها به چه میزان از انواع سبک‌های فرزند پروری (X_6 : آسان گیرانه، X_7 : مستبدانه و X_8 : مقتدرانه) برخوردار بودند. به منظور بررسی تاثیر متغیرهای توضیحی فوق بر عملکرد تحصیلی دانش آموزان، معدل نیمسال تحصیلی آنها به عنوان متغیر پاسخ در نظر گرفته شد.

[۳] نشان داده است، معیارهای اطلاع در مقابل تغییرات ناچیز داده‌ها بی ثبات هستند. برای مشاهده موردی در این رابطه می‌توان، به ونگ و همکاران [۲۰]، صفحه ۵۶۴، مراجعه نمود.

با توجه به اینکه هدف از انتخاب متغیر، تعیین متغیرهایی است که در مدل نهایی حضور پیدا می‌کنند و از طرفی عرض از مبدأ عملاً به عنوان یک متغیر توضیحی در نظر گرفته نمی‌شود، دو روش PROC SCADLS و PROC SCADLS گفته نمی‌شود، دو روش PROC SCADLS و PROC SCADLS ابتدا متغیرهای توضیحی را استاندارد کرده و پس از انتخاب متغیر، ضرایب را به مقیاس اصلی بر می‌گردانند.

متغیر در جدول ۳ آمده است. اعداد داخل پرانتز برآورد انحراف استاندارد ضرایب را نشان می‌دهد. خروجی مربوط به دو معیار AIC و BIC با استفاده از روش PROC GLMSELECT و خروجی مربوط بهتابع توان SCAD با بکارگیری روش PROC SCADLS (هر دو از نرم افزار SAS) بدست آمده‌اند. خروجی مربوط به OLS نیز با استفاده از روش PROC REG حاصل شده است. همانطور که در جدول ۳ مشاهده می‌شود، معیار AIC مدل پیچیده‌تری را نسبت به معیار BIC انتخاب کرده است که این نکته با ویژگی تمایل AIC به بیش‌برآورده، همخوانی دارد. همچنین نتیجه‌ی حاصل از SCAD و BIC یکسان می‌باشد اما به هر حال همانطور که بریمن

جدول ۳. برآورد ضرایب و انحراف استاندارد آنها در داده‌های عزت نفس و سبک‌های فرزند پروری.

	OLS	AIC	BIC	SCAD
Intercept	۱۴/۸۹۵ (۱/۴۷۵)	۱۴/۶۷۷ (۰/۷۷۶)	۱۳/۴۳۰ (۰/۲۴۷)	۱۲/۴۳۰ (۰/۲۴۶)
X_1	۰/۰۲۷ (۰/۰۳۴)	۰ (-)	۰ (-)	۰ (-)
X_2	۰/۰۹۲ (۰/۰۲۹)	۰/۱۱۳ (۰/۰۲۱)	۰/۱۲۱ (۰/۰۲۰)	۰/۱۲۱ (۰/۰۲۰)
X_3	۰/۰۹۶ (۰/۰۲۷)	۰/۱۱۴ (۰/۰۲۱)	۰/۱۲۱ (۰/۰۲۱)	۰/۱۲۱ (۰/۰۲۱)
X_4	۰/۰۲۰ (۰/۰۳۱)	۰ (-)	۰ (-)	۰ (-)
X_5	۰/۰۰۳ (۰/۰۲۴)	۰ (-)	۰ (-)	۰ (-)
X_6	-۰/۰۵۳ (۰/۰۷۶)	-۰/۰۵۹ (۰/۰۳۲)	۰ (-)	۰ (-)
X_7	-۰/۰۶۹ (۰/۰۴۳)	-۰/۰۵۹ (۰/۰۳۲)	۰ (-)	۰ (-)
X_8	۰/۰۲۹ (۰/۰۴۹)	۰/۰۵۱ (۰/۰۱۲)	۰/۰۵۴ (۰/۰۰۹)	۰/۰۵۴ (۰/۰۰۹)
$X_1 X_7$	۰/۰۰۳ (۰/۰۰۲)	۰/۰۰۴ (۰/۰۰۲)	۰ (-)	۰ (-)
$X_1 X_8$	۰/۰۰۰ (۰/۰۰۲)	۰ (-)	۰ (-)	۰ (-)
$X_7 X_8$	۰/۰۰۱ (۰/۰۰۱)	۰ (-)	۰ (-)	۰ (-)

۸ بحث و نتیجه‌گیری

که در مقایسه با سایر توابع توان دارد، به طور خاص مورد بررسی قراردادیم. بر اساس نتایج بدست آمده از مطالعات شبیه‌سازی، تابع توان SCAD در مقایسه با LASSO از برتری قابل توجه‌ای برخوردار است (جدول ۲ را ببینید) همچنین بر اساس نتایج مندرج در جدول ۱، عملکرد توابع توان تحت تاثیر مقدار پارامتر نظم قرار

با توجه به اهمیت روزافزون مبحث انتخاب متغیر در علوم مختلف، همواره روش‌های جدیدی برای این منظور ارایه می‌گردد. در این بین استفاده از تابع توان، بسیار مورد توجه قرار گرفته است. در این مقاله علاوه بر معرفی اجمالی برخی از توابع توان و بسته‌های نرم‌افزاری مرتبط با آنها، تابع توان SCAD را، به دلیل ویژگی‌های بهینه‌ای

دارد؛ بنابراین انتخاب مناسب پارامتر نظم در درجه‌ی اول اهمیت، برای استفاده از هر تابع تاوانی قرار دارد.

قدردانی

نویسنده‌گان مقاله از جناب آقای مهدی حسین‌پوری، به دلیل فراهم نمودن امکان استفاده از داده‌های مربوط به بخش مثال کاربردی، کمال تشکر را دارند.

مراجع

- [1] قاسمی، ح. (۱۳۸۷)، بررسی رابطه‌ی چندگانه‌ی سبک‌های فرزند پروری و انواع عزت نفس با عملکرد تحصیلی دانش آموزان دختر دوره‌ی راهنمایی شهر سمنان در سال تحصیلی ۱۳۸۶-۸۷، پایان نامه کارشناسی، دانشگاه سمنان.
- [2] Akaike, H. (1973). Information Theory and an Extension of the Maximum Likelihood Principle. *Proceeding 2nd Inter Symposium on Information Theory*, 267-281, Budapest.
- [3] Breiman, L. (1996). Heuristics of Instability and Stabilization in Model Selection, *the Annals of Statistics*, 24, 6, 2350-2383.
- [4] Burnham, K.P. and Anderson, D.R. (2002). *Model selection and multimodel inference: a practical information-theoretic approach*, Springer.
- [5] Craven, P. and Wahba, G. (1979). Smoothing Noisy Data With Spline Functions: Estimating the Correct Degree of Smoothing by the Method of Generalized Cross-Validation, *Numerische Mathematika*, 31, 377-403.
- [6] Dziak, J. J., Lemmon, D. R., and Li, R. (2008). PROC SCADLS User's Guide (version 1.0.5 beta). State College, PA: The Methodology Center, Pennsylvania State University.
- [7] Efron, B., Hastie, T., Johnstone, I. and Tibshirani, R. (2004). Least angle regression, *Annals of statistics*, 32, 407-451.

- [8] Fan, J. and Li, R. (2001). Variable Selection Via Nonconcave Penalized Likelihood and its Oracle Properties, *Journal of the American Statistical Association*, **96**, 1348-1360.
- [9] Fan, J. and Li, R. (2006). Statistical challenges with high dimensionality: Feature selection in knowledge discovery, *Proceedings of the International Congress of Mathematicians*, (M. Sanzsole, J. Soria, J.L. Varona, J. Verdera, eds.) Vol. III, 595-622.
- [10] Frank, I.E. and Friedman, J.H. (1993). A Statistical View of Some Chemometrics Regression Tools, *Technometrics*, **35**, 109-148.
- [11] Fu, W.J. (1998). Penalized Regression: The Bridge Versus the LASSO, *Journal of Computational and Graphical Statistics*, **7**, 397-416.
- [12] George, E. I. (2000). The Variable Selection Problem, *Journal of the American Statistical Association*, **95**, 452, 1304-1308.
- [13] Hoerl, A.E. and Kennard, R. (1970). Ridge Regression: Biased Estimation for Nonorthogonal Problems, *Technometrics*, **12**, 55-67.
- [14] Hunter, D.R. and Li, R. (2005). Variable Selection Using MM Algorithms, *The Annals of Statistics*, **33**, 1617-1642.
- [15] Leng, C., Lin, Y. and Wahba, G. (2006). A Note on the lasso and Related Procedures in Model Selection, *Statistica Sinica*, **16**, 1273-1284.
- [16] Montgomery, D.C and Peck, E.A (1992). *Introduction to Linear Regression Analysis*, 2nd Ed., Wiley: New York.
- [17] Rencher, A.C. and Schaalje, G.B. (2008). *Linear Models in Statistics*, 2nd ed, John Wiley and Sons.
- [18] Schwarz, G. (1978), Estimating the Dimension of a Model, *Annals of Statistics*, **6**, 461-464.
- [19] Tibshirani, R.J. (1996). Regression Shrinkage and Selection Via the LASSO, *Journal of the Royal Statistical society Ser B*, **58**, 267-288.

- [20] Wang, H., Li. R. and Tsai, C. L. (2007). Tuning Parameters Selectors for Smoothly Clipped Absolute Deviation Method, *Biometrika Trust*, **94**, 553-568.
- [21] Zou, H. (2006). The Adaptive Lasso and Its Oracle Properties, *Journal of the American Statistical Association*, **101**, (476), 1418-1429.
- [22] Zou, H. and Hastie, T. (2005). Regularization and variable selection via the elastic net, *Journal of the Royal Statistical Society Series B*, **67**, 2, 301-320.