



مقارنة بعض الطرق العقابية لتقدير واختيار متغيرات نموذج الانحدار الخطى آنياً فى ظل وجود التعدد الخطى: دراسة محاكاة

أ/ هبة خميس إبراهيم أحمد شركس
المعيدة بقسم الإحصاء والرياضية والتأمين
كلية التجارة - جامعة الإسكندرية

A Comparison of Some Penalized Methods for Simultaneous Estimation and Variable Selection of the Linear Regression Model under Multicollinearity:A Simulation Study

Abstract

The research introduces a comparison of some penalized methods for simultaneous variable selection and estimation of the linear regression model under multicollinearity. A simulation study was conducted to compare the performance of these methods including 120 different situations resulting from interaction of four factors: sample size, random error variance, degree of linear correlation among explanatory variables, and regression parameters of the true model. The simulation study shows that SEA-LASSO method outperforms SCAD and MCP methods in terms of percentage of selecting the true model, and competes favorably with them in terms of estimation accuracy.

ملخص البحث

يتناول البحث مقارنة بعض الطرق العقابية التي تستخدم في تقدير واختيار متغيرات نموذج الانحدار الخطى آنياً فى ظل وجود التعدد. وقد تم إجراء دراسة محاكاة لمقارنة أداء تلك الطرق العقابية اشتملت على ١٢٠ حالة مختلفة ناتجة من تفاعل مستويات أربعة عوامل وهى: حجم العينة، وتباعن حد الخطأ العشوائى، ودرجة الارتباط الخطى بين المتغيرات التفسيرية، وهىكل معالم انحدار النموذج الحقيقي. وقد تبين من نتائج دراسة المحاكاة أن طريقة **SEA-LASSO** تتفوق على الطريقتين **SCAD** و **MCP** من حيث النسبة المئوية للوصول إلى النموذج الحقيقي، كما أنها تُعد منافساً جيداً لهما من حيث دقة التقدير.

١ - مقدمة

وتتناول المشكلة الأساسية لهذه الدراسة

فى الإجابة عن التساؤل التالى:

ما هى أفضل طريقة عقابية يمكن استخدامها
لتقدير و اختيار متغيرات نموذج الانحدار الخطى آنیاً
مع علاج مشكلة التعدد الخطى؟

وتهدف الدراسة الحالية إلى:

١- استعراض مجموعة من أهم الطرق العقابية التي
تقوم بتقدير و اختيار متغيرات نموذج الانحدار
الخطى آنیاً.

٢- تقييم الأداء التجربى لبعض الطرق العقابية من
حيث فدرتها على اختيار المتغيرات و علاج
مشكلة التعدد الخطى وذلك من خلال دراسة
محاكاة موسعة.

٣- محاولة تلافي بعض نقاط الضعف التي
صاحبـتـ الكـثيرـ من دراسـاتـ المحاكـاةـ السـابـقةـ.

وقد تم تقسيم البحث كالتالى: يتناول المبحث
الثانى بعض الطرق العقابية المستخدمة فى تقدير
واختيار متغيرات نموذج الانحدار الخطى آنیاً وهى:
طريقة LASSO، وطريقة SCAD، وطريقة
"SEA- Adaptive LASSO" ، وحالة خاصة منها
LASSO، وطريقة MCP. أما المبحث الثالث فقد
تم تخصيصه لدراسة المحاكاة والتعليق على نتائج
هذه الدراسة. ويتناول المبحث الرابع بعض النقاط
المقترحة لبحوث مستقبلية.

**٤- بعض الطرق العقابية لتقدير و اختيار
متغيرات نموذج الانحدار الخطى آنیاً**

٤-١ طريقة LASSO

تعد طريقة (LASSO) Least Absolute Shrinkage and Selection Operator والتى قدمها Tibshirani (1996,1997) من أشهر

تعد مشكلة اختيار متغيرات نموذج الانحدار
الخطى من المشاكل الإحصائية التى نالت اهتمام
الإحصائيين بشدة حتى وقتنا الحاضر. وبعد اختيار
المتغيرات هاماً فى ظل وجود عدد كبير
من المتغيرات التفسيرية Explanatory Variables
للحصول على نموذج مبسط Parsimonious Model. وتمثل هذه المشكلة تحدياً كبيراً فى ظل
وجود التعدد (الازدواج) الخطى Multicollinearity
بين المتغيرات التفسيرية، حيث تصعب الفرقـةـ بينـ
تأثير كل متغير من المتغيرات التفسيرية المرتبطةـ
على متغير الاستجابة Response Variable، وقدـ
يؤدى ذلك إلى إسقاط بعض المتغيرات التفسيريةـ
الهامـةـ.

وبعد اختيار الفئة الجزئية Subset Selection
أسلوباً غير مستقر Unstable، وذلك لأن أي
تغيرات طفيفة في البيانات يمكن أن تؤدي إلى
تغيرات كبيرة في النموذج الذي يتم اختيارهـ
(Breiman, 1995, 1996; Zou, 2006)
أنـهـ غيرـ مـمـكـنـ حـاسـيـاـًـ فـيـ ظـلـ وـجـودـ عـدـدـ كـبـيرـ منـ
المتغيرات التفسيرية (Zou, 2006).

ولكـيـ يتمـ التـغلـبـ عـلـىـ العـيـوبـ السـابـقـ ذـكـرـهاـ
اقـرـحـ الـبـاحـثـونـ العـدـيدـ مـنـ الطـرـقـ العـقـابـيـةـ
Shrinking Penalized Methods والتى تقوم بتقليلـ
Mقدراتـ بـعـضـ معـالـمـ الانـحدـارـ Regression Parameters
والـصـفـرـ،ـ وـمـنـ ثـمـ تـمـكـنـ تـلـكـ الـطـرـقـ العـقـابـيـةـ مـنـ
تقـدـيرـ وـاـخـتـيـارـ مـتـغـيرـاتـ نـمـوذـجـ الانـحدـارـ الخطـىـ آـنـيـاـ
معـ عـلاـجـ مشـكـلـةـ التـعـدـدـ الخطـىـ.

• هو مجموع القيم المطلقة $\|\beta\|_1 = \sum_{j=1}^p |\beta_j|$

لمعامل الانحدار، ويُطلق عليه L_1 -norm للمتجه β .

Tuning Para- • $\lambda_1 \geq 0$ هي معلمة الضبط التي تتحكم في مقدار التقليل المطبق على مقدرات معالم الانحدار.

• $\|\beta\|_1$ هي دالة عقاب L_1 -norm (ويُطلق عليها أيضاً دالة عقاب LASSO) والتي تُمكن طريقة LASSO - باختيار ملائم لقيمة معلمة الضبط λ_1 - من تقليل مقدرات بعض معالم الانحدار وجعل البعض الآخر مساوياً للصفر، وبذلك فهي تقوم بتقدير و اختيار متغيرات نموذج الانحدار الخطى آنها.

ويُلاحظ من المعادلة (2) أنه إذا تم وضع قيمة معلمة الضبط $\lambda_1 = 0$ يتم الحصول على مقدار Ordinary Least Sq- المربعات الصغرى العادي- β uares (OLS)

٢-٢ طريقة SCAD

اقتراح Fan and Li (2001) طريقة-(SCAD) Smo othly Clipped Absolute Deviation والتي تقوم بتقدير و اختيار متغيرات نموذج الانحدار الخطى آنهاً باستخدام دالة عقاب SCAD (Fan,1997; Fan and Li, 2001).

ويتم الحصول على مقدار SCAD من خلال تدنية دالة المربعات الصغرى العقابية (PLSF) التالية:

$$\hat{\beta}^{SCAD} = \arg \min_{\beta} [\|Y - X\beta\|^2 + \sum_{j=1}^p P_{\lambda, a}^{SCAD}] \quad (3)$$

وتأخذ دالة عقاب SCAD الصيغة التالية

:(Clarke et al., 2009)

الطرق العقابية المستخدمة في تقدير و اختيار متغيرات نموذج الانحدار الخطى آنهاً. كما استُخدمت دالة عقاب LASSO على نطاق واسع في كثير من التطبيقات الإحصائية- (Zheng, 2008; Nardi and Rinaldo, 2011; Bien et al., 2013; Kaul, 2014; Wu et al., 2014). وتقوم طريقة LASSO بتقليل مقدرات بعض معالم الانحدار وجعل البعض الآخر مساوياً للصفر، وبذلك فهي تقوم بتقدير و اختيار المتغيرات في خطوة واحدة آنهاً.

وبافتراض نموذج الانحدار الخطى المتعدد التالي:

$$Y = X\beta + \varepsilon \quad (1)$$

حيث:

Y متوجه الاستجابة Response أبعاده $1 \times n$. X مصفوفة التصميم Design Matrix أبعادها $n \times p$

β متوجه معالم الانحدار أبعاده $1 \times p$

ε متوجه حد الخطأ العشوائى Random Error أبعاده $1 \times n$ ، وتوقعه مساوى للصفر $[var(\varepsilon) = \sigma^2]$ يتم الحصول على مقدر LASSO من خلال تدنية دالة المربعات الصغرى العقابية التالية :Least Squares Function (PLSF)

$$\hat{\beta}^{LASSO} = \arg \min_{\beta} [\|Y - X\beta\|^2 + \lambda_1 \|\beta\|_1] \quad (2)$$

حيث:

$\|Y - X\beta\|^2 = (Y - X\beta)^T (Y - X\beta)$ هو مجموع مربعات الخطأ Sum of Squared Error (SSE)

ونظراً لتميز مقدر SCAD بخصائص نظرية جيدة فقد استخدمه Garcia *et al.* (2010) في ظل وجود بيانات مفقودة Missing Data. واستخدمه Liu *et al.* (2011) في النماذج الخطية الجزئية Semiparametric Addit-ive Partial Linear Models كما استخدمه Zhao *et al.* (2014) في نماذج المعاملات المتغيرة Varying Coefficients Models الخطية الجزئية شبه المعلمية. واستخدمه Qiu *et al.* (2015) في نماذج المعاملات المتغيرة بأخطاء مرتبطة ذاتياً Autoregressive Errors. وتتجدر الإشارة إلى أن جميع هذه الدراسات اتفقت على وضع قيمة معلمة الضبط $a = 3.7$ لدالة عقاب SCAD. بناءً على تلك الدراسات تم استخدام هذه القيمة لمعلمة الضبط a عند تفزيذ طريقة SCAD في دراسة المحاكاة الحالية.

٣-٢ طريقة Adaptive LASSO

أوضح Zou(2006) أن مقدر LASSO غير متسق في اختيار المتغيرات. وللتغلب على هذا القصور في طريقة LASSO، اقترح Zou (2006) طريقة Adaptive LASSO (AL). وتقوم طريقة Adaptive LASSO (AL) بوضع أوزان مرنة Adaptive Weights في دالة عقاب L_1 -norm لكى يصبح مقدار التقليص المطبق على مقدرات معالم الانحدار مختلفاً، وذلك على خلاف طريقة LASSO والتى تقوم بفرض نفس العقاب على مقدرات جميع معالم الانحدار. ويتم الحصول على مقدر AL على النحو التالى :

$$\hat{\beta}^{AL} = \arg \min_{\beta} [\|Y - X\beta\|^2 + \lambda_1 \sum_{j=1}^p \hat{w}_j |\beta_j|] \quad (8)$$

$$P_{\lambda_1, a}^{\text{SCAD}} = \begin{cases} \lambda_1 |\beta_j| & \text{if } |\beta_j| \leq \lambda_1 \\ \frac{(\beta_j^2 - 2a\lambda_1 |\beta_j| + \lambda_1^2)}{2(a-1)} & \text{if } \lambda_1 < |\beta_j| \leq a\lambda_1 \\ \frac{(a+1)\lambda_1^2}{2} & \text{if } |\beta_j| > a\lambda_1 \end{cases} \quad (4)$$

حيث: $\lambda_1 \geq 0$ و $a > 2$ معلمة الضبط. وقد قام Fan and Li (2001) بوضع قيمة معلمة الضبط $a = 3.7$

وتأخذ المشقة الأولى لدالة عقاب SCAD الصيغة التالية (Fan, 1997; Fan and Li, 2001):

$$P_{\lambda_1, a}^{\text{SCAD}} = \lambda_1 [I(|\beta_j| \leq \lambda_1) + \frac{(a\lambda_1 - |\beta_j|)_+}{(a-1)\lambda_1} I(|\beta_j| > \lambda_1)] \quad (5)$$

حيث: $I()$ دالة المؤشر Indicator Function. فعلى سبيل المثال؛ إذا كان g هو شرط معين، فإن دالة المؤشر $I(g) = 1$ إذا تحقق الشرط g ، بينما تكون $I(g) = 0$ إذا لم يتحقق الشرط g . ومن ثم فإن دالة المؤشر

$$I(|\beta_j| \leq \lambda_1) \text{ معرفة كما يلى:}$$

$$I(|\beta_j| \leq \lambda_1) = \begin{cases} 1 & \text{if } |\beta_j| \leq \lambda_1 \\ 0 & \text{if } |\beta_j| > \lambda_1 \end{cases} \quad (6)$$

• المقدار $(a\lambda_1 - |\beta_j|)_+$ معرف كما يلى

$$(a\lambda_1 - |\beta_j|)_+ = \begin{cases} a\lambda_1 - |\beta_j| & \text{if } (a\lambda_1 - |\beta_j|) > 0 \\ 0 & \text{if } (a\lambda_1 - |\beta_j|) \leq 0 \end{cases} \quad (7)$$

وقد اهتم العديد من الباحثين بدراسة السلوك التقاري للمقدر SCAD، واتفقوا على أن مقدر SCAD يتميز بأنه أوراكل Oracle تقريباً⁽¹⁾ مع اختيار ملائم لقيمة معلمة الضبط λ_1 (Fan and Li, 2001; Fan and Peng, 2004; Kim *et al.*, 2008)

ونظراً لتميز المقدر AL بخصائص نظرية جيدة فقد تم استخدامه على نطاق واسع في كثير من التطبيقات الإحصائية (Zhang and Lu, 2007; Lian, 2012; Zeng *et al.*, 2014; Caner and Fan, 2015; Yang and Wu, 2016)

٤-٢ طريقة SEA-LASSO

يعتمد أداء طريقة AL من حيث اختيار المتغيرات على الأوزان المرنة \hat{W}_j ، وبالتالي فهو يعتمد على المقدر المبدئي المستخدم في حساب تلك الأوزان. وتطبيقياً، لحساب الأوزان المرنة استخدم Zou (2006) تقديرات المربعات الصغرى العادلة OLS. إلا أن مقدر OLS يعاني من قصور في الأداء في ظل وجود التعدد الخطى، مما يجعل الأوزان المرنة \hat{W}_j غير مستقرة، وينعكس ذلك سلباً على أداء طريقة AL. لذا اقترح Qian and Yang (2013) أن تؤخذ في الاعتبار الأخطاء المعيارية لمقدرات OLS عند حساب الأوزان المرنة لطريقة Standard Error Adjusted AL، وقدموا طريقة Adaptive LASSO (SEA-LASSO) SEA-LASSO.

- ويتم الحصول على مقدر SEA من خلال تدنية دالة المربعات الصغرى العقابية (PLSF) التالية:

$$\hat{\beta}^{SEA} = \arg \min_{\beta} \left[\|Y - X\beta\|^2 + \lambda_1 \sum_{j=1}^p \hat{w}_j^{SEA} |\beta_j| \right] \quad (10)$$

ويتم حساب الأوزان المرنة لمقدر SEA-LASSO على النحو التالي:

حيث: \hat{w}_j هي أوزان مرنة، اقترح Zou (2006) أن يتم حسابها كما يلى:

$$\hat{w}_j = \frac{1}{|\hat{\beta}_j^{initial}|^\gamma} \quad (9)$$

حيث:

- Estimator Initial $\hat{\beta}_j^{initial}$ هو مقدر مبدئي لمعلمة الانحدار β_j .
- $\gamma > 0$ معلمة الضبط.

وقد اتفقت الكثير من الدراسات الإحصائية التي تناولت طريقة AL على وضع قيمة معلمة الضبط $\gamma = 1$ ، على سبيل المثال: Zhang and Lu (2007)، Lian (2012)، Garcia *et al.* (2010)، و Zeng *et al.* (2014)، وأيضاً Huang *et al.* (2008)، و Oracle *et al.* (2008)، وأوضحاوا أنه يُعد أوراكل Tقارياً.

وقد تم دراسة المقدر AL من عدة جوانب مختلفة. فعلى سبيل المثال: انصب اهتمام Oracle (2008) على دراسة الخصائص التقاربية للمقدر AL وأوضحاوا أنه يُعد أوراكل Tقارياً. واستخدم Garcia *et al.* (2010) مقدر AL في ظل وجود بيانات مفقودة. وقام Lu *et al.* (2012) بدراسة سلوك مقدر AL في ظل خطأ توصيف النموذج، وأوضحاوا أن مقدر AL يظل أوراكل Oracle Tقارياً.

^(١) يطلق على المقدر العقابي Penalized Estimator أنه أوراكل Oracle تقريباً إذا توافرت فيه الخصائص التقاربية (Fan and Li, 2001; Zou, 2006).

أ- متسق في اختيار المتغيرات Selection
ب- معندي تقريباً Asymptotically Normal

وتأخذ دالة عقاب MCP الصيغة التالية:

$$P_{\lambda_1, a}^{MCP} = \lambda_1 \int_0^{\beta_j} \left| \beta_j \right| \left(1 - \frac{h}{a\lambda_1} \right)_+ dh \quad (13)$$

حيث: $a > 0$ معلمة الضبط. وفى دراسة المحاكاة
الحالية تم وضع $a = 3$.

٣- دراسة المحاكاة

تم مقارنة أداء الطرق العقابية: SCAD و MCP و SEA-LASSO باستخدام دراسة محاكاة اشتملت على 120 حالة مختلفة ناتجة من تفاعل مستويات أربعة عوامل. وقد تم استبعاد طريقة LASSO من دراسة المحاكاة نظراً لعدم تميزها بخصائص نظرية جيدة. ويتناول هذا المبحث العوامل المراد اختبار تأثير تغيير مستوياتها على أداء تلك الطرق العقابية، وبعض الجوانب البرمجية التي تم الاستناد إليها عند تطبيق دراسة المحاكاة، وكذلك تحديد قيمة معلمة الضبط λ ومعيار اختيار أفضل قيمة لها، والأسس التي تم الاستناد إليها لقيم أداء الطرق العقابية، وأخيراً تحليل نتائج دراسة المحاكاة.

١-٣ العوامل التي تم دراستها

١- حجم العينة:

تم اختيار أربعة مستويات من حجم العينة وهى: حجم عينة صغير $n = 25$ ، وحجم عينة متوسط $n = 50$ ، وحجم عينة كبير نسبياً $n = 200$ ، وحجم عينة كبير $n = 1000$. وقد تم تحديد مستويات هذا العامل استناداً إلى دراسة مبدئية قامت بها الباحثة سبقت دراسة المحاكاة، اتضحت منها وجود فروق جوهيرية تحدث في النتائج عند هذه المستويات من حجم العينة.

$$\hat{w}_j^{SEA} = \left(\frac{sd_j^{OLS}}{|\hat{\beta}_j^{OLS}|} \right)^\gamma \quad (11)$$

حيث:

- $\hat{\beta}_j^{OLS}$ هو مقدر المربعات الصغرى العادية لمعلمة الانحدار j .

• sd_j^{OLS} هو الخطأ المعياري للمقدر $\hat{\beta}_j^{OLS}$. وقام Qian and Yang (2013) بوضع قيمة معلمة الضبط $\gamma = 1$. وقد تم استخدام هذه القيمة عند تطبيق طريقة SEA-LASSO فى دراسة المحاكاة الحالية. وبالنظر إلى المعادلة (10) يتضح أن مقدر SEA-LASSO ما هو إلا مقدر AL مع تعديل حساب الأوزان المرنة له. وقد أوضح Qian and Yang (2013) أنه باختيار ملائم لقيمة معلمة الضبط λ يتميز مقدر SEA-LASSO بأنه أوراكل Oracle تقريباً.

وتابع Algamal and Lee (2015) فكرة SEA-LASSO فى نموذج انحدار بواسون Poisson Regression Model على وضع قيمة معلمة الضبط $\gamma = 1$.

٥-٤ طريقة MCP

اقتصر Zhang (2010) طريقة Minimax Concave Penalty (MCP) والتى تقوم بتقدير و اختيار متغيرات نموذج الانحدار الخطى آنيناً باستخدام دالة عقاب MCP، وتتغلب على قصور طريقة LASSO من حيث عدم اتساقها فى اختيار المتغيرات.

ويتم الحصول على مقدر MCP كما يلى:

$$\hat{\beta}^{MCP} = \arg \min_{\beta} [\|Y - X\beta\|^2 + \sum_{j=1}^p P_{\lambda_1, a}^{MCP}] \quad (12)$$

$$\beta_j = 6 - j \quad \text{for } j = 1, 2$$

٤- تباين حد الخطأ العشوائى:

تم استخدام ثلاثة مستويات متدرجة لتباين حد الخطأ العشوائى وذلك لمقارنة أداء الطرق العقابية عند مستويات مختلفة من التشويش Noise وهى: مستوى منخفض من التشويش ($\sigma^2 = 0.25$)، ثم تشويش متوسط ($\sigma^2 = 1$)، وتشويش مرتفع ($\sigma^2 = 3$).

٣- درجة الارتباط الخطى بين المتغيرات التفسيرية:

تم استخدام خمسة مستويات متدرجة للارتباط الخطى بين المتغيرات التفسيرية (الموجودة وغير الموجودة فى النموذج资料) وهى: ارتباط متوسط ($\rho = 0.5$)، وارتباط قوى ($\rho = 0.7$)، وارتباط قوى جداً بمستويين ($\rho = 0.9$)، وارتباط حاد ($\rho = 0.95$)، وارتباط حاد ($\rho = 0.99$).

٤- هيكل معالم انحدار النموذج资料:

لم يحظ هذا العامل باهتمام كافٍ في دراسات المحاكاة السابقة. وقد تبين من خلال الدراسة المبدئية التي قامت بها الباحثة أن أداء الطرق العقابية قد يتاثر باختلاف أو تساوى معالم انحدار متغيرات النموذج資料. لذا تم استخدام مستويين لقيم معالم انحدار النموذج資料، وفي كل المستويين تم وضع عدد متغيرات النموذج資料 $p_1 = 2$ وعدد المتغيرات الكلى $p = 8$ وذلك على النحو التالي:

المستوى الأول: تساوى معالم انحدار متغيرات النموذج資料

$$\beta_j = 6 \quad \text{for } j = 1, 2$$

المستوى الثاني: اختلاف معالم انحدار متغيرات النموذج資料

٢-٣ بعض الجوانب البرمجية

قامت الباحثة بكتابة الكود البرمجى لتنفيذ دراسة المحاكاة باستخدام اللغة البرمجية R (الإصدار 3.2.1). وقد تم استخدام الحزمة

وبناءً على ذلك، تم استخدام المعيار BIC لاختيار قيمة معلمة الضبط λ_1 للطرق العقابية محل الدراسة، والذي تم حسابه - لكل عينة لكل حالة من حالات الدراسة - على النحو التالي:

$$BIC = \ln\left(\frac{\|Y - X\hat{\beta}\|^2}{n}\right) + \frac{\ln(n)}{n} \times df \quad (14)$$

حيث: اتفقت الكثير من الدراسات الإحصائية^(١) على وضع df مساوية لعدد التقديرات الغير صفرية لمعامل الانحدار.

ويتم اختيار أفضل قيمة لمعلمة الضبط λ_1 التي تجعل قيمة المعيار BIC أقل ما يمكن.

٤-٣ أسس التقييم

للمقارنة بين الطرق العقابية محل الدراسة تم الاستناد إلى أساسى تقييم لكل منها وظيفة معينة كما سينتضح عبر السياق التالى:

١- النسبة المئوية للوصول إلى النموذج الحقيقي

Percentage of True Model (PTM)

تساعد تلك النسبة فى تقييم سلوك الطرق العقابية من حيث مدى قدرتها على الوصول إلى النموذج الحقيقي في ظل حالة معينة، ويتم تعريفها كما يلى:

$$PTM = \frac{\text{عدد مرات الوصول إلى النموذج الحقيقي}}{\text{عدد العينات}} \times 100 \quad (15)$$

حيث: عدد العينات = 1000 عينة، و $0 \leq PTM \leq 100$

^(١) على سبيل المثال: دراسة Wang et al. (2009) ، Zeng et al. (2014) ، Qian and Yang (2013) .Caner and Fan (2015)

البرمجية glmnet للحصول على تقديرات طريقة SEA-LASSO، واستخدام الحزمة البرمجية ncvreg للحصول على تقديرات طريقة SCAD وطريقة MCP.

٣-٣ تحديد قيم معلمة الضبط λ_1 للطرق العقابية والمعيار المستخدم فى اختيارها

تم الاعتماد على قيم معلمة الضبط λ_1 التي تولدها الحزمتين البرمجيتين glmnet و ncvreg. وتعتمد الخصائص النظرية الجيدة للطرق العقابية محل الدراسة على الاختيار الملائم لقيمة معلمة الضبط λ_1 . وتوجد العديد من المعايير شائعة الاستخدام لاختيارها، وهى على سبيل المثال:

١- معيار الملاينة المقطوعية المعمم Generalized Cross-Validation (GCV) Carven and Wahba (1979)

٢- المعيار المعلوماتى Akaike Information Criterion (AIC) (Akaike, 1973)

٣- المعيار الباييزى Bayesian Information Criterion (BIC) (Schwarz, 1978)

وقد أوضح Wang et al. (2007) أنه إذا تم استخدام المعيار GCV لاختيار قيمة معلمة الضبط λ_1 لطريقة SCAD سيؤدى ذلك إلى Over-Fitted Models اختيار نماذج زائدة التوفيق لا يمكن تجااهلها حتى مع زيادة حجم العينة ($n \rightarrow \infty$). لذلك اقترحوا أن يتم استخدام المعيار BIC لاختيار قيمة معلمة الضبط λ_1 لطريقة SCAD لأنه سيكون قادرًا على اختيار النموذج الحقيقي. كما استخدم Qian and Yang (2013) المعيار BIC لاختيار قيمة معلمة الضبط λ_1 لطريقة SEA-LASSO

(١)). وقد كان هذا التفوق واضحاً في العينات الصغيرة والمتوسطة.

٢- تفوق طريقة SEA-LASSO على طريقة SCAD وطريقة MCP في ٥٤ حالة من بين ٦٠ حالة للمستوى الثاني للمتجه β (جدول .(٢)).

٣- يلاحظ تحسن النسبة PTM لطريقة SCAD وطريقة MCP مع زيادة حجم العينة.

٤- استطاعت طريقة SEA-LASSO تحقيق نسبة PTM = ١٠٠% في ٦٩ حالة من الحالات الكلية. علماً بأن طريقة SCAD وطريقة MCP لم تستطع الوصول إلى نسبة PTM = ١٠٠% في أي حالة من حالات الدراسة.

٢-٥-٣ دقة التقدير

١- تعطى طريقة SEA-LASSO أقل MSE في ٢٥ حالة من أصل ٣٠ حالة للعينات الصغيرة والمتوسطة عند المستوى الأول للمتجه β (جدول (١)).

٢- تعطى SEA-LASSO أقل MSE في ٢٥ حالة من بين ٣٠ حالة للعينات الصغيرة والمتوسطة عند المستوى الثاني للمتجه β (جدول (٢)).

٣- تُعد طريقة SEA-LASSO الأفضل في حالات العينات الكبيرة نسبياً ($n = 200$) في ظل التشوش المتوسط والمرتفع وذلك بغض النظر عن تساوي أو اختلاف معالم انحدار متغيرات النموذج الحقيقي (الجدولان ١ ، ٢).

٤- ظهر تفوق طريقة SCAD وطريقة MCP في حالات العينات الكبيرة ($n = 1000$)، وقد كان هذا التفوق واضحاً في الحالات الخاصة بالارتفاع الحاد (الجدولان ١ ، ٢).

ويتم تقسير تلك النسبة عندما تكون $PTM = 0$ بأن الطريقة العقابية لم تستطع الوصول إلى النموذج الحقيقي في جميع العينات. بينما يتم تقسير تلك النسبة عندما تكون $PTM = 100$ بأن الطريقة العقابية استطاعت الوصول إلى النموذج الحقيقي في جميع العينات. واستناداً إلى هذا الأساس فإن الطريقة العقابية التي تعطى أعلى نسبة PTM تكون هي الأفضل في ظل الحالة المعنية.

٢- متوسط مربعات الخطأ

تم الاستناد إلى متوسط مربعات الخطأ Mean of Squared Errors (MSE) لتقدير أداء الطرق العقابية من حيث دقة التقدير، وقد تم حسابه لكل حالة من حالات الدراسة على النحو التالي:

$$MSE = \frac{\sum_{r=1}^{1000} \|\hat{\beta}_r - \beta\|^2}{1000} \quad (16)$$

حيث: $\hat{\beta}_r$ هو تقدير متجه معالم الانحدار للعينة رقم r لطريقة عقابية ما.

واستناداً إلى هذا الأساس فإن الطريقة العقابية التي تعطى أقل متوسط مربعات خطأ MSE تكون هي الأفضل في ظل الحالة المعنية.

٣- تحليل نتائج دراسة المحاكاة

يتناول هذا المبحث التعليق على قدرة الطرق العقابية على الوصول إلى النموذج الحقيقي، وتقييم أداء الطرق العقابية من حيث دقة التقدير.

٣-٤-٣ قدرة الطرق العقابية على الوصول إلى النموذج الحقيقي

١- تفوق طريقة SEA-LASSO على طريقة SCAD وطريقة MCP في ٥٧ حالة من بين ٦٠ حالة للمستوى الأول للمتجه β (جدول

أن يكون الارتباط الخطى بين المتغيرات التفسيرية الموجودة بالنموذج الحقيقى فقط؛ أى أن:

$$\text{corr}(X_i, X_j) = \begin{cases} \rho & \text{for } i \neq j \in \{1, 2, \dots, p_1\} \\ 1 & \text{for } i = j \\ 0 & \text{otherwise} \end{cases}$$

ب- وضع الارتباط الخطى بين المتغيرين X_i, X_j مساوياً از- ρ .

٢- تقييم أداء الطرق العقابية فى ظل البيانات كثيرة الأبعاد High – Dimensional Data.

٣- تقييم أداء الطرق العقابية محل الدراسة فى ظل مشاكل إحصائية أخرى.

ويتضح من التحليل السابق أن طريقة SEA- LASSO تتrocق على الطريقتين MCP و SCAD من حيث القدرة على الوصول إلى النموذج الحقيقى - مقاسة بالنسبة PTM - كما أنها تعتبر منافساً جيداً لهما من حيث متوسط مربعات الخطأ MSE.

٤- بعض النقاط المقترحة لبحوث مستقبلية

توصى الباحثة بما يلى فى شأن البحوث المستقبلية:

١- تقييم أداء الطرق العقابية محل الدراسة فى ظل صيغ أخرى لمصفوفة الارتباط الخطى بين المتغيرات التفسيرية، على سبيل المثال:

جدول (١)

النسبة المئوية للوصول إلى النموذج الحقيقى PTM، ومتوسط مربعات الخطأ MSE للطرق العقابية MCP، SCAD، SEA-LASSO (SEA) عند المستوى الأول لهيكل معالم انحدار النموذج الحقيقى ومستويات عوامل الدراسة الأخرى: حجم العينة n ، وتباين حد الخطأ العشوائى σ^2 ، ودرجة الارتباط الخطى بين المتغيرات التفسيرية ρ .

رقم الحالة	عوامل الدراسة			PTM			MSE		
	n	σ^2	ρ	SCAD	MCP	SEA	SCAD	MCP	SEA
1	25	0.25	0.5	70.3	60	100	0.0647	0.0733	0.0323
2	25	0.25	0.7	56.8	52.7	100	0.1309	0.1339	0.0497
3	25	0.25	0.9	54.1	54.1	100	0.3839	0.3837	0.1403
4	25	0.25	0.95	51.1	51.1	100	0.8025	0.8023	0.3436
5	25	0.25	0.99	54.2	54.4	97.7	3.7803	3.7688	3.7069
6	25	1	0.5	69.7	59.3	97.2	0.2626	0.3007	0.1343
7	25	1	0.7	59.4	53	98	0.5029	0.5274	0.2002
8	25	1	0.9	53.6	53.6	97	1.5719	1.5687	0.6550
9	25	1	0.95	53.1	53.2	93	3.2416	3.2300	1.6619
10	25	1	0.99	48	50.4	60.1	19.3654	17.7392	20.1899
11	25	3	0.5	71.3	61.4	71.2	0.7574	0.8578	0.6731
12	25	3	0.7	57.3	53	70.6	1.5328	1.5878	1.0822
13	25	3	0.9	50.7	50.6	71	4.6975	4.7018	3.1759
14	25	3	0.95	52.8	52.8	66.2	9.6111	9.5747	7.9505
15	25	3	0.99	19.1	35.2	20.9	71.5777	58.7080	64.2812
16	50	0.25	0.5	81.8	74.5	100	0.0253	0.0295	0.0179
17	50	0.25	0.7	75.4	70.4	100	0.0460	0.0492	0.0240
18	50	0.25	0.9	71.1	71.1	100	0.1450	0.1443	0.0752
19	50	0.25	0.95	71.2	71.3	100	0.2945	0.2935	0.1775
20	50	0.25	0.99	74.5	74.6	100	1.3243	1.3207	1.9221
21	50	1	0.5	81.7	74.2	100	0.1032	0.1167	0.0607
22	50	1	0.7	76.8	71.8	100	0.1839	0.1961	0.0869
23	50	1	0.9	72.8	72.7	100	0.5523	0.5490	0.2714
24	50	1	0.95	73.2	73.1	99.8	1.1191	1.1230	0.6497
25	50	1	0.99	69.4	69.5	85.3	5.8657	5.8189	8.0219

تابع جدول (١)

رقم الحالة	عوامل الدراسة			PTM			MSE		
	n	σ^2	ρ	SCAD	MCP	SEA	SCAD	MCP	SEA
26	50	3	0.5	83.2	76.4	90.7	0.2916	0.3338	0.2357
27	50	3	0.7	75.6	71.9	93.6	0.5480	0.5761	0.3319
28	50	3	0.9	70.4	70.3	90.6	1.7555	1.7600	1.0581
29	50	3	0.95	70.9	71.1	87.6	3.3680	3.3526	2.4607
30	50	3	0.99	52	63.7	50	30.7685	22.8570	31.6639
31	200	0.25	0.5	93.1	89.6	100	0.0046	0.0050	0.0069
32	200	0.25	0.7	89.2	87.7	100	0.0085	0.0089	0.0086
33	200	0.25	0.9	85.4	85.2	100	0.0276	0.0277	0.0214
34	200	0.25	0.95	87.9	87.9	100	0.0497	0.0496	0.0503
35	200	0.25	0.99	88.4	88.4	100	0.2297	0.2300	0.7791
36	200	1	0.5	93.9	91.2	100	0.0166	0.0181	0.0157
37	200	1	0.7	88.4	86.9	100	0.0351	0.0359	0.0242
38	200	1	0.9	87.1	87.1	100	0.1050	0.1050	0.0763
39	200	1	0.95	88.2	88.3	100	0.1903	0.1898	0.1765
40	200	1	0.99	87.8	87.8	99.7	0.9798	0.9797	2.0176
41	200	3	0.5	93.2	90.1	100	0.0540	0.0601	0.0447
42	200	3	0.7	89.3	87.8	100	0.0998	0.1053	0.0704
43	200	3	0.9	89.6	89.5	100	0.2680	0.2681	0.1970
44	200	3	0.95	88.6	88.6	100	0.5388	0.5388	0.4912
45	200	3	0.99	88.2	88.2	93.2	2.8919	2.8603	5.2444
46	1000	0.25	0.5	96.4	95.2	100	0.0008	0.0009	0.0039
47	1000	0.25	0.7	96.4	95.9	100	0.0013	0.0014	0.0042
48	1000	0.25	0.9	94.2	94.2	100	0.0041	0.0041	0.0067
49	1000	0.25	0.95	95.3	95.3	100	0.0070	0.0070	0.0122
50	1000	0.25	0.99	95.8	95.8	100	0.0343	0.0343	0.2971
51	1000	1	0.5	96.4	95	100	0.0032	0.0034	0.0057
52	1000	1	0.7	95	94.6	100	0.0056	0.0057	0.0075

تابع جدول (١)

رقم الحالة	عوامل الدراسة			PTM			MSE		
	n	σ^2	ρ	SCAD	MCP	SEA	SCAD	MCP	SEA
53	1000	1	0.9	95.8	95.8	100	0.0148	0.0147	0.0172
54	1000	1	0.95	94.8	94.9	100	0.0331	0.0330	0.0448
55	1000	1	0.99	94.9	94.9	100	0.1463	0.1463	0.6948
56	1000	3	0.5	96.9	95.7	100	0.0099	0.0104	0.0116
57	1000	3	0.7	94.5	93.7	100	0.0171	0.0175	0.0156
58	1000	3	0.9	96.5	96.4	100	0.0401	0.0403	0.0432
59	1000	3	0.95	95.1	95	100	0.0826	0.0830	0.1062
60	1000	3	0.99	95.4	95.4	100	0.4219	0.4219	1.3277

جدول (٢)

النسبة المئوية للوصول إلى النموذج الحقيقي PTM، ومتوسط مربعات الخطأ MSE للطرق العقابية SEA-LASSO و MCP SCAD و مستويات عوامل الدراسة الأخرى: حجم العينة n ، تباين الخطأ العشوائى σ^2 ، و درجة الارتباط الخطى بين المتغيرات التفسيرية ρ .

رقم الحالة	عوامل الدراسة			PTM			MSE		
	n	σ^2	ρ	SCAD	MCP	SEA	SCAD	MCP	SEA
61	25	0.25	0.5	70	60.1	100	0.0651	0.0727	0.0305
62	25	0.25	0.7	57.2	52.7	100	0.1304	0.1339	0.0480
63	25	0.25	0.9	54.1	54.1	99.8	0.3841	0.3841	0.1347
64	25	0.25	0.95	51.1	51.1	99.6	0.8022	0.8009	0.2938
65	25	0.25	0.99	54.1	54.5	81.5	3.8186	3.7907	4.8587
66	25	1	0.5	69.9	59.5	82	0.2630	0.3006	0.1949
67	25	1	0.7	59.6	53	86.9	0.5019	0.5267	0.2828
68	25	1	0.9	53.7	53.6	83.6	1.5698	1.5688	0.9000
69	25	1	0.95	53.1	53.3	76.8	3.2550	3.2366	2.1703
70	25	1	0.99	35.1	40.3	39.2	22.7811	20.2298	21.2103
71	25	3	0.5	71	61.6	65.8	0.7581	0.8581	0.7103
72	25	3	0.7	57.8	53.3	63.4	1.5302	1.5851	1.1704

تابع جدول (٢)

رقم الحالة	عوامل الدراسة			PTM			MSE		
	n	σ^2	ρ	SCAD	MCP	SEA	SCAD	MCP	SEA
73	25	3	0.9	50.7	50.5	58.8	4.8317	4.8344	3.9204
74	25	3	0.95	48.1	49.1	51.2	11.6178	10.8531	10.3441
75	25	3	0.99	3.7	15.8	8.2	68.8175	55.7282	53.1747
76	50	0.25	0.5	81.5	74.5	100	0.0255	0.0296	0.0165
77	50	0.25	0.7	75.9	70.4	100	0.0458	0.0492	0.0231
78	50	0.25	0.9	71.1	71	100	0.1454	0.1447	0.0741
79	50	0.25	0.95	71.2	71.2	100	0.2945	0.2942	0.1636
80	50	0.25	0.99	74.6	74.7	96	1.3184	1.3187	2.1030
81	50	1	0.5	81.6	74.3	98.2	0.1035	0.1165	0.0656
82	50	1	0.7	76.3	71.7	98.9	0.1838	0.1966	0.0908
83	50	1	0.9	72.8	72.7	97.7	0.5504	0.5494	0.2908
84	50	1	0.95	73.3	73.1	94	1.1165	1.1220	0.6882
85	50	1	0.99	65.8	66.8	68.2	7.4348	6.8563	9.7659
86	50	3	0.5	83.2	75.9	80.2	0.2915	0.3366	0.2759
87	50	3	0.7	75.7	72	81.8	0.5468	0.5767	0.4220
88	50	3	0.9	70.5	70.4	80.2	1.7531	1.7561	1.3414
89	50	3	0.95	70.5	70.7	77.6	3.5359	3.5007	3.1179
90	50	3	0.99	22.3	38.4	25.6	35.0649	26.5534	32.3287
91	200	0.25	0.5	92.8	89.6	100	0.0046	0.0051	0.0055
92	200	0.25	0.7	89.3	87.7	100	0.0085	0.0089	0.0077
93	200	0.25	0.9	85.5	85.2	100	0.0275	0.0277	0.0275
94	200	0.25	0.95	87.9	87.9	100	0.0496	0.0496	0.0647
95	200	0.25	0.99	88.4	88.3	100	0.2297	0.2313	0.5727
96	200	1	0.5	94	91.3	100	0.0166	0.0181	0.0145
97	200	1	0.7	88.3	87	100	0.0352	0.0357	0.0231
98	200	1	0.9	87	87	100	0.1054	0.1054	0.0758
99	200	1	0.95	88.2	88.3	100	0.1903	0.1898	0.1692

تابع جدول (٢)

رقم الحالة	عوامل الدراسة			PTM			MSE		
	n	σ^2	ρ	SCAD	MCP	SEA	SCAD	MCP	SEA
100	200	1	0.99	87.8	87.8	95.2	0.9802	0.9800	2.2170
101	200	3	0.5	93.3	90.1	99.8	0.0541	0.0598	0.0437
102	200	3	0.7	89.3	87.8	99.7	0.0998	0.1051	0.0703
103	200	3	0.9	89.6	89.5	99.5	0.2686	0.2681	0.1901
104	200	3	0.95	88.7	88.7	99.1	0.5372	0.5372	0.4468
105	200	3	0.99	85.5	86.6	78.4	4.0356	3.5291	7.3190
106	1000	0.25	0.5	96.3	95.3	100	0.0008	0.0009	0.0026
107	1000	0.25	0.7	96.5	95.9	100	0.0013	0.0014	0.0034
108	1000	0.25	0.9	94.2	94.2	100	0.0040	0.0041	0.0137
109	1000	0.25	0.95	95.3	95.3	100	0.0070	0.0070	0.0388
110	1000	0.25	0.99	95.9	95.8	100	0.0341	0.0343	0.4451
111	1000	1	0.5	96.5	95.1	100	0.0032	0.0034	0.0045
112	1000	1	0.7	95	94.6	100	0.0056	0.0057	0.0067
113	1000	1	0.9	95.8	95.8	100	0.0148	0.0147	0.0218
114	1000	1	0.95	94.8	94.8	100	0.0332	0.0331	0.0630
115	1000	1	0.99	94.9	94.9	100	0.1463	0.1463	0.5359
116	1000	3	0.5	96.9	95.7	100	0.0099	0.0104	0.0103
117	1000	3	0.7	94.5	93.7	100	0.0171	0.0175	0.0146
118	1000	3	0.9	96.5	96.4	100	0.0401	0.0403	0.0441
119	1000	3	0.95	95	95	100	0.0830	0.0830	0.1074
120	1000	3	0.99	95.4	95.4	99.5	0.4219	0.4219	0.9848

مراجعة الدراسة

- [1] Akaike, H. (1973), "Information Theory as an Extension of the Maximum Likelihood Principle," in *B.N. Petrov, and F.Caski, Second International Symposium on Information Theory*. Akademiai Kiado, Budapest, pp.267-281.
- [2] Algamal, Z.Y. and Lee, M.H. (2015), "Adjusted Adaptive LASSO in High-Dimensional Poisson Regression Model," *Modern Applied Science*, **9**, pp.170-177.
- [3] Bien, J., Taylor, J., and Tibshirani, R. (2013), "A LASSO for Hierarchical Interactions," *The Annals of Statistics*, **41**, pp.1111-1141.
- [4] Breiman, L. (1995), "Better Subset Regression Using the Nonnegative Garrote," *Technometrics*, **37**, pp.37-3-384.
- [5] Breiman, L. (1996), "Heuristics of Instability and Stabilization in Model Selection," *The Annals of Statistics*, **24**, pp.2350-2383.
- [6] Caner, M. and Fan, Q.(2015), "Hybrid Generalized Empirical Likelihood Estimators: Instrument Selection with Adaptive LASSO," *Journal of Econometrics*, **187**, pp.2-56-274.
- [7] Carven, P. and Wahba, G. (19-79), "Smoothing Noisy Data with Spline Functions: Estimating the Correct Degree of Smoothing by the Method of Generalized Cross-Validation," *Numerische Mathematik*, **31**, p.377-403.
- [8] Clarke, B., Fokoue, E., and Zh-ang, H.H. (2009), *Principles and Theory for Data Mining and Machine Learning*, Springer, New York.
- [9] Fan, J. (1997), "Comments on 'Wavelets in Statistics: A Review' by A. Antoniadis," *Journal of the Italian Statistical Society*, **2**, pp.13-1-138.
- [10] Fan, J. and Li, R. (2001), "Variable Selection via Nonconcave Penalized Likelihood and its Oracle Properties," *Journal of the American Statistical Association*, **96**, pp.1348-1360.
- [11] Fan, J. and Peng, H. (2004), "Nonconcave Penalized Likelihood with a Diverging Number of Parameters," *The Annals of Statistics*, **32**, pp.-928-961.
- [12] Garcia, R.I., Ibrahim, J.G., and Zhu, H. (2010), "Variable Selection for Regression Models with Missing Data," *Statistica Sinica*, **20**, pp.149-165.
- [13] Hallawa, A.M. and Azzam, A. H. (1995), "A New Method for Generating the Design Matrix of a Linear Regression Model," *The Egyptian Statistical Journal ISSN*, **39**, pp.106-119.
- [14] Huang, J., Ma, S., and Zhang, C-H. (2008), "Adaptive LASSO for Sparse High-Dimensional Regression Models," *Statistica Sinica*, **18**, pp.1-603-1618.
- [15] Kaul, A. (2014), "LASSO with Long Memory Regression Errors," *Journal of Statistical Planning and Inference*, **153**, pp.11-26.

- [16] Kim, Y., Choi, H., and Oh, H-S. (2008), "Smoothly Clipped Absolute Deviation on High Dimensions," *Journal of the American Statistical Association*, **103**, pp.1665-1673.
- [17] Lian, H. (2012), "Variable Selection in High-Dimensional Partly Linear Additive Models," *Journal of Nonparametric Statistics*, **24**, pp. 82-5-839.
- [18] Liu, X., Wang, L., and Liang, H. (2011), "Estimation and Variable Selection for Semiparametric Additive Partial Linear Models," *Statistica Sinica*, **21**, pp.1225-1248.
- [19] Lu, W., Goldberg, Y., and Fine, J.P. (2012)," On the Robustness of the Adaptive LASSO to Model Misspecification," *Biometrika*, **99**, pp. 717-731.
- [20] Nardi, Y. and Rinaldo, A. (2011), "Autoregressive Process Modeling via the LASSO Procedure," *Journal of Multivariate Analysis*, **102**, pp. 528-549.
- [21] Qian, W. and Yang, Y. (2013), "Model Selection via Standard Error Adjusted Adaptive LASSO," *Annals of the Institute of Statistical Mathematics*, **65**, pp.295-318.
- [22] Qiu, J., Li, D., and You, J. (2015), "SCAD-Penalized Regression for Varying-Coefficient Models with Autoregressive Errors," *Journal of Multivariate Analysis*, **137**, pp.10-0-118.
- [23] Schwarz, G.(1978), "Estimating the Dimension of a Model," *The Annals of Statistics*, **6**, pp.461-464.
- [24] Tibshirani, R. (1996), "Regression Shrinkage and Selection via the LASSO," *Journal of the Royal Statistical Society, Series B*, **58**, pp.267-288.
- [25] Tibshirani, R.(1997), "TheLASSO Method for Variable Selection in the Cox Model," *Statistics in Medicine*, **16**, pp.385-395.
- [26] Wang, H., Li, B., and Leng, C. (2009), "Shrinkage Tuning Parameter Selection with a Diverging Number of Parameters," *Journal of the Royal Statistical Society, Series B*, **71**, pp.671-683.
- [27] Wang, H., Li, R., and Tsai, C-L. (2007),"Tuning Parameter Selectors for the Smoothly Clipped Absolute Deviation Method," *Biometrika*, **94**, pp. 553–568.
- [28] Wu, L., Yang,Y., and Liu,H. (2014),"Nonnegative-LASSOandApplication in Index Tracking," *Computational Statistics and Data Analysis*, **70**, pp.116-126.
- [29] Yang, Y. and Wu, L. (2016), "Nonnegative Adaptive LASSO for Ultra-High Dimensional Regression Models and a Two-Stage Method Applied in Financial Modeling," *Journal of Statistical Planning and Inference*, **174**, pp.52-67.
- [30] Zeng, P., Wei, Y., Zhao, Y., Liu, J., Liu, L., Zhang, R., Gou, J., Huang, S., and Chen, F. (2014), "Variable Selection Approach for Zero-Inflated Count Data via Adaptive LASSO," *Journal of Applied Statistics*, **41**, pp. 879-894.

- [31] Zhang, C-H. (2010), "Nearly Unbiased Variable Selection under Minimax Concave Penalty," *The Annals of Statistics*, **38**, pp.894-942.
- [32] Zhang, H.H. and Lu, W. (2007), "Adaptive LASSO for Cox's Proportional Hazards Model," *Biometrika*, **94**, pp. 691-703.
- [33] Zhao,W., Zhang, R., Liu, J., and Lv, Y. (2014), "Robust and Efficient Variable Selection for Semiparametric Partially Linear Varying Coefficient Model Based on Modal Regression," *Annals of The Institute of Statistical Mathematics*, **66**, pp.-165-191.
- [34] Zheng, S. (2008), "Selection of Components and Degrees of Smoothing via LASSO in High Dimensional Nonparametric Additive Models," *Computational Statistics and Data Analysis*, **53**, pp.164-175.
- [35] Zou, H. (2006), "The Adaptive LASSO and its Oracle Properties," *Journal of the American Statistical Association*, **101**, pp.1418-1429.