



مقارنة بين طريقتي الابلاس ولاسو التكيفية لتحليل الانحدار التقسيمي المركب لا نموذج المؤشر الاحادي باستعمال اسلوب محاكاة

Comparison of the Laplace and Lasso adaptive methods for the analysis of the complex partitioning regression of the single-index model using a simulation approach

طارق عزيز صالح⁽²⁾

ايات جبار عبد⁽¹⁾

جامعة واسط /كلية الادارة واقتصاد

الملخص

تعد النماذج الإحصائية من بين اهم النماذج التي تعتمد عليها الدراسات الاقتصادية والطبية وغيرها وان الهدف من هذه النماذج الحصول على حلول دقيقة من خلال استعمال طرائق إحصائية ملائمة وقد لاحظ في الفترة الاخيرة ظاهرة بيانات عالية الابعاد حيث ان البيانات تعاني من مشاكل قياسية والتي يكون فيها عدد المتغيرات التنبؤ أكبر من حجم العينة

إذ تم في هذه الدراسة التعرف على بعض المفاهيم الاساسية الاحصاء مثل الانحدار التقسيمي الجزائي والانحدار التقسيمي المركب والنموذج المؤشر الاحادي إذ تم المقارنة بين الطرائق التقدير الجزائية في الانحدار التقسيمي المركب وهذه المقدرات (لاسو التكيفية ولابلاس) وباستعمال المعيارين الإحصائيين وهما (معدل متوسط مربعات الخطأ AMSE ومعدل متوسط النسبة المئوية MAPE) باستعمال توزيعين طبيعيي $N(0,1)$ و $N(0,1)$ واربعة احجام عينات $(200, 100, 50, 30)$ واثنين قيم، تمثل عدد المتغيرات $(p=10, 30)$ ، وتم استعمال اسلوب محاكاة مونت كارلو باستعمال برنامج الإحصائي R لمعرفة مدى كفاءة الطرائق الجزائية للانحدار التقسيمي المركب في ظل بيانات عالية الابعاد وظهرت النتائج تفوق طريقة الاسو التكيفية لأنها اقل AMSE و MAPE لذلك تعد الطريقة الأفضل لتحليل الانحدار التقسيمي المركب لا نموذج المؤشر الاحادي.

Abstract: -

Statistical models are among the most important models that economic, medical and other studies depend on. The goal of these models is to obtain accurate solutions

through the use of appropriate statistical methods. Recently, a phenomenon of high-dimensional data has been observed, as the data suffers from standard problems in which the number of predictive variables is greater than the sample size. In this study, some basic statistical concepts were identified, such as partial regression, complex partial regression and the single indicator model. A comparison was made between the partial estimation methods in complex partial regression and these estimators (adaptive Lasso and Laplace) and using the two statistical criteria, which are (the average mean square error AMSE and the average mean percentage MAPE) using two normal distributions ($N(0,1)$) and four sample sizes (30,50,100,200) and two values ($p=10,30$) and to know the efficiency of the partial methods for complex partial regression in light of high-dimensional data. The Monte Carlo simulation method was used using the statistical program R and the results showed the superiority of the method Adaptive EASO because it has lower AMSE and MAPE so it is the best method for complex segmentation regression analysis rather than single indicator model.

1. المقدمة :

في السنوات الأخيرة زاد الاهتمام بتحليل البيانات ذات الأبعاد العالية عندما تكون عدد المتغيرات التفسيرية أكبر من حجم العينة $n > p$ ، ويعرف تحليل الانحدار هو أحد الطرائق الإحصائية التي تستخدم في تحليل ودراسة العلاقة بين متغير واحد أو أكثر من المتغيرات التفسيرية ومتغير الاستجابة. وفي بعض الدراسات العلمية المختلفة، يمكن تقدير التوزيع الشرطي عند نقاط مختلفة، وذلك لا يتوفر في الانحدار الخطي الاعتيادي. ويمكن أن يكون البديل المناسب لطريقة المربعات الصغرى الاعتيادية (OLS) هو الانحدار التقسيمي (Quintile regression) الذي يعد من أكثر أنواع التحليل الانحدار المستخدمة في الإحصاء والقياس الاقتصادي وغيرها، ويكون امتدادا للانحدار الخطي ويمكن استعماله عندما تكون شروط الانحدار الخطي الاعتيادي صعبة التطبيق ولحل هذه المشكلة اقترح الباحثون أساليب علمية تساهم في تقليل تأثير مشكلة التعدد الخطي عن طريق تقدير معلمات النموذج ومن هذه الأساليب حذف المتغيرات التفسيرية التي تعتقد أنها سبب هذه المشكلة من خلال استخدام دوال الجزاء (lasso adaptive, LaPlace) ويمكن من خلاله تقليل المعلمة المرتبطة بمتغير غير مهم باستعمال المؤشر الأحادي الذي يعد أحد أنواع النماذج الإحصائية ويستعمل لتقليل الأبعاد عن طريق تحويل المتغيرات التفسيرية إلى متغير واحد، وقد اكتسب هذا النموذج اهتماما كبيرا في السنوات الأخيرة بسبب استخدامه في مجالات علمية مختلفة مثل الطب والاقتصاد وغيرها. ويستعمل في هذه الدراسة أسلوب جديد هو الانحدار التقسيمي المركب (Composite quantile regression) الذي يتميز بخصائص أكثر من الانحدار

التقسيمي الاعتيادي (QR)، وله القدرة على نمذجة عدد كبير من المتغيرات التفسيرية، والذي يساهم في تقليل تباين الأخطاء والمتغيرات التفسيرية في ان واحد.

2. هدف البحث

يهدف البحث إلى مقارنة بين طرائق التقدير الجزائية للانحدار التقسيمي المركب في ظل البيانات عالية الابعاد للمؤشر الأحادي باستعمال المقدرات الجزائية، adaptive lasso، (LaPlace)، وكذلك استعمال دراسة المحاكاة لمقارنة بين طرائق الجزائية باستعمال المعايير الإحصائية (MAPE، AMSE)، لمعرفة كفاءة افضل طريقة من بين الطرائق الجزائية

3. المشكلة البحث

صعوبة دراسة الانحدار التقسيمي المركب في حالة وجود عدد كبير من المتغيرات التفسيرية التي تفوق على حجم العينة ويمكن ان تصبح العملية معقدة عندما يكون هناك عدد كبير من المتغيرات التفسيرية، ويمكن ان تصبح بعض المتغيرات غير اساسيه لها تأثير على متغير الاستجابة، او يكون لها تأثيرات مشابهة لمتغيرات الأخرى. بالإضافة على ذلك فإن بعض هذه المتغيرات لها ارتباط داخلي مع بعض مما يؤدي إلى ظهور مشكلة التعدد الخطي ويكون تأثيرها غير معنوي ويؤدي ذلك إلى استبعاد بعض المتغيرات لزيادة دقة تنبؤ الانموذج .

4. الجانب النظري

1.4: الانحدار التقسيمي الجزائي

هو أحد انواع تحليل الانحدار الأكثر استخدام في الاحصاء ويكون غير مناسب عند وجود الزيادة في عدد المتغيرات التفسيرية، ولا يمكن من خلاله القيام بعملية اختيار المتغيرات التي تعتبر مهمه جدا في ظل وجود عدد كبير من المتغيرات التفسيرية، التي تسبب في تعقيد النموذج مما يؤدي إلى صعوبة تفسير بسهولة. الهدف من الانحدار التقسيمي الجزائي الحصول على نموذج مختصر ويكون هذا النموذج يمتلك اقل عدد من المتغيرات التفسيرية والتي تسمى بالنموذج المبعثر (sparse model) إذ يصعب عملية تحديد المتغيرات المعنوية التي تكون سبب في تعقيد النموذج (response variable) ويؤدي ذلك إلى اسقاط بعض من المتغيرات التفسيرية المهمة ويجب معالجة بعض من هذه المشاكل بشكل اوضح او صحيح بطريقة تكون مثالية لذلك يكون الانحدار التقسيمي الجزائي اداة مفيدة لمعالجة اغلب المشاكل عن طريق اضافة حد الجزاء إلى دالة الخسارة والهدف من الاضافة تقليل دالة الحذف التي تتألف من جزائين ويعبر عنهم بدالتين الجزاء والخسارة ويعبر عن ذلك وفقا للصيغة الانحدار التقسيمي الجزائي ويكون بالشكل التالي [1][2][3]

$$Q_t(\beta) = \sum_{i=1}^n \rho_{\theta}(y_i - X_i^T \beta) + \lambda \sum_{K=1}^P p_K |\beta_K| \quad \dots (1)$$

حيث ان:

(.) p_{λ} تمثل دالة جزاء

λ : تمثل معلمة الجزاء وان $0 \leq \lambda \leq 1$ وهي تعمل على الموازنة بين التحيز والتباين.

2.4: الانحدار التقسيمي المركب

هي طريقة إحصائية اقترحها الباحثان (Zou & yuan) في عام (2008) تصف العلاقة بين المتنبئين والكميات الشرطية المختلفة لنتائج الاهتمام [4]. وتعد بديلا مناسباً للانحدار التقسيمي (QR) للباحثين (koenker & Bassett) في عام 1978. يتمتع الانحدار التقسيمي المركب (CQR) بميزة القدرة على النمذجة المتغيرات العددية للنتائج [5]، وتعتبر متغيرات العدد (مجموعة فرعية من نماذج الانحدار) وهي نماذج مهمة قد تظهر في مجموعة من التطبيقات المختلفة في مجالات (الطب، الاقتصاد والعلوم الاجتماعية) ويمكن التعبير عن الانحدار التقسيمي كما يلي [6]

$$(\hat{b}_1, \hat{b}_2, \dots, \hat{b}_q, \beta^{CQR}) = \operatorname{argmin} \sum_{q=1}^Q [\sum_{i=1}^n \rho_{\tau_q}(y_i - b_q - X_i^T \beta)] \quad \dots(2)$$

وتمثل τ_q : الشرط التقسيمي وتعطى بالصيغة الآتية $\tau_q = \frac{q}{q+1}$ حيث ان $q=1, 2, \dots, Q$

كما يقوم الانحدار التقسيمي المركب بتقدير تسلسل للكميات الشرطية من خلال Q إلى Y بالنظر إلى X عند مستويات $0 < \tau_1 < \tau_2 < \dots < \tau_q < 1$ في ظل نفس النموذج الخطي كما يمكن إعطاء هذه الكميات الشرطية

$$B_0 + X_i^T \beta + b_q^\epsilon$$

إذ ان:

b : تمثل المستوى الفريد المفترض لتوزيع الخطأ E ويفترض مره أخرى انه مستقل عن X على عكس نماذج الانحدار التقسيمي المستقلة Q

3.4: النموذج المؤشر الأحادي

تعتبر تقنية المؤشر الأحادي من التقنيات الفعالة في التعامل مع مشاكل عالية الأبعاد في الانحدار المتوسط القياسي، الذي إشارته إليها الباحث (Zou وآخرون) في عام (2013) حيث اكتسب اهتمام كبير واسع في السنوات الأخيرة بسبب استخدامه في مجالات عدة مثل (تحليل الاختيار المنفصل في الاقتصاد، نماذج الاستجابة للجرعة في القياسات الحيوية) [7] وقد سمى هذا المؤشر بهذا الاسم لان جميع المتغيرات التوضيحية يمكن تلخيصها تحت مؤشر خطي واحد، كما اعتبر المؤشر الواحد من النماذج الشبه معلميه لأنه يجمع بين النماذج المعلميه المقيدة والنماذج اللامعلميه المرنة

$$Y=f(X_i^T\beta)+\epsilon$$

إذ إن:

Y : يمثل متغير الاستجابة احادي المؤشر.

X : متجه للمتغيرات المشتركة ذات الابعاد p .

$f(.)$: دالة الربط احادي المتغير غير معروفة.

β_0 : معامل المتجه الأحادي المؤشر وان $\beta = \|1\|$ وان المكون الأول من β_0 يكون موجب

ϵ : يمثل الخطأ العشوائي .

وتم التعرف على مقدرات معلمة الانحدار التقسيمي المركب احادي المؤشر من قبل الباحثان (ZOU & Yuan) على النحو التالي [8][9]:

$$(\hat{b}_1, \hat{b}_2, \dots, \hat{b}_q, \beta^{CQR}) = \operatorname{argmin}_{b_1, b_2, \dots, b_q, \beta} \sum_{q=1}^Q [\sum_{i=1}^n \rho_{\tau_q}[y_i - b_q - f(X_i^T\beta)]] \dots (3)$$

ρ_{τ_q} : تمثل دالة فقدان التحقق تدل على دالة المؤشر

b_q : تقاطع عند المستوى التقسيمي τ_q

$$Q, \dots, 2, \tau_q = \frac{q}{q+1} \quad q=1$$

$$I < 0, \rho_{\tau_q}(t) = t(\tau_q - I)$$

5: طرائق التقدير شبه المعلمي

ظهرت في الفترة الاخيرة العديد من الاساليب وطرائق التقدير لتحليل الانحدار التقسيمي المركب الانموذج المؤشر الاحادي ومن هذه طرائق :

1.5: طريقه Laplace التقسيمية المركبة لنماذج المؤشر الواحد

اقترحت دالة جزاء جديدة، تعرف باسم دالة جزاء (خطا لابلاس) من قبل الباحثان (Wen & Wang) في عام 2015 تكون هذه الدالة على عكس دوال الجزاء الأخرى، تم انشاؤها بشكل طبيعي كدالة سلسلة محدودة بدلا من خطوط متعددة التعريف [10]. حيث ان الدالة السلسلة ذات الحدود تكون منحنية بشكل مستمر ويمكن تميزها دون اجراء تغيرات مفاجئة عند نقاط التوقف، مما يوفر تمثيلا أكثر سلاسة للبيانات. على عكس ذلك، تكون للخطوط متعددة الجوانب ان تظهر تذبذبات

واهتزازات عند نقاط التوقف، مما يؤدي إلى نتائج غير مرغوب فيها. كما تعتبر دالة جزاء خطأ لابلاس أكثر سلاسة في التعامل معها مقارنة ببعض الدوال الجزائية مثل دالة جزاء scad، مما أدى على استخدامها مع نموذج الانحدار التقسيمي المركب للمؤشر الأحادي. [11]

وحصل على قيد دالة خطأ لابلاس من خلال الخطوات الآتية [12]...

نفرض ان الخطأ العشوائي يساوي..

$$e^x \leq \frac{1}{1-x \log e}$$

بما ان $y = -x \log e$ تكون $y \geq 0$ بناء على الافتراضات، نأخذ $\log$ على طرفين المترجحة $x \log e \leq$
 $y \geq \log(1 - x \log e)$ ثم نضرب ب (-1) على كلا الجانبين واستبدال y فنحصل على $y \geq \log(1 + y)$

(P₁) تكون $p_K(t)$ متماثل حول الصفر ويتم التحقق منه بسهولة عند $p_K(0) = 0$

(P₂) تكون $p_K(t)$ متزايدة بالنسبة ل متزايدة ، $t \in [0, \infty)$ ومن السهل ان نرى $p'(t) = -\log e(e^t)$ تكون موجبة ل
 $t \geq 0$ و $e \in (0, 1)$

(P₃) تكون $t > 0$ والدالة $g(t) = p(t) \setminus t$ تكون غير متزايدة عند $t > 0$

$$g'(t) = \frac{t(-(\log e)e^t - [1 - e^t])}{t^2}$$

$$g'(t) = \frac{e^t[1-t \log e]-1}{t^2} \quad \dots(4)$$

ونبين ان البسط $e^t [1-t \log e] - 1 \leq 0 \quad \text{for } t > K$

ويمكن تطبيق دالة جزاء خطأ لابلاس على نموذج الانحدار التقسيمي المركب للمؤشر الأحادي كما في الصيغة الآتية.

$$(\hat{\beta}_1, \hat{\beta}_2, \dots, \hat{\beta}_q, \beta^{CQR}) = \min_{\beta_1, \beta_2, \dots, \beta_q, \beta} \sum_{q=1}^Q [\sum_{i=1}^n P_{Tq}[y_i - \beta_q - f(X_i^T \beta)]] + \lambda \sum_{k=1}^p \left(1 - e^{-\frac{k}{|t|}}\right) \quad \dots(5)$$

عندما تكون (λ, t) معلمتين ضبط غير سالبتين عند $k \geq 1$

$$p_{\lambda t} \text{ is LEP } p_{\lambda t} = 1 - e^{-\frac{k}{|t|}}$$

y_i : متغير الاستجابة

$f(\cdot)$: دالة الارتباط غير معروفة

τ_q : تمثل التقاطع التقسيمي عند مستوى $\rho_{\tau q}$

$$Q, \dots, 2, q=1, \tau_q = \frac{q}{q+1}$$

2.5: طريقة لاسو التكميلية التقسيمية المركبة لنماذج المؤشر الواحد

تعتمد طريقة (lasso) على تعيين عدد صغير من المعاملات التي تساوي الصفر. ويتم تخفيض قيمة المعاملات الأخرى بمعدل ثابت بغض النظر عن عددها. ولذلك سيتم تخفيض قيمة عدد كبير من المعاملات، مما يؤدي إلى زيادة في انحياز تقديرات طريقة (lasso) في اعتمادها على استخدام معلمة التحكم (الضبط) أو التنظيم واحدة لكل من طريقة اختيار المتغيرات وتقدير المعاملات. إن اختيار المعلمة λ بطريقة (cross-validation) أو طريقة معايير المعلومات (information criteria) ينتج عنه نموذج تنبؤي مثالي. غالباً ما تكون قيمة المعلمة λ صغيرة في هذه الحالة، ومن ثم يتم استبعاد عدد صغير من المتغيرات. ومع ذلك، إذا كانت قيمة $\hat{\lambda}$ كبيرة فهذا يعني جعل عدد كبير من المعاملات يساوي الصفر ومن ثم استبعادها من النموذج. [13] [14] [15]:-

$$\sum_{k=1}^p \widehat{W}_K |\beta_K|$$

إذ إن:

$$\lambda > 0 \text{ معلمة الضبط وان الوزن } W_q > 0$$

وفي عام 2006 ، اقترح الباحث (Zou) استعمال القيمة التقديرية الآتية:

$$W_K = \frac{1}{|\widehat{\beta}_K|^\alpha}$$

إذ إن: $\alpha > 0$ وان $\widehat{\beta}_K$ تعتبر القيمة التقديرية الأولية أو الأساسية (initial) المقدرة للمعلمة β عادة يتم اختيار b لتصبح قيمة المعلمة من طريقه المربعات الصغرى أو طريقة لاسو واختيار قيمة الفا من خلال طريقة (k-fold cross validation) ومن ثم كمية الانكماش المقترحة للمعلمة تتناسب عكسياً مع حجم العينة أي كلما كانت المعالم كبيرة تنقلص بصورة قليلة ، وكلما كانت المعالم صغيرة تنقلص بصورة كبيرة في حاله $w_q = 1$ أي نحصل على طريقه $lasso$ ، كما تبين ان طريقه لاسو التكميلية تتميز بخصائص اوراقل.

خصائص (oracle) للأسو التكيفية (Kirkland 2014)

بما ان $\widehat{\beta}_K$ الأولية تكون مقدر متسق Consistent فيمتاز مقدر لأسو التكيفية بالخصائص الآتية:

$$\lim_{n \rightarrow \infty} Pr(Sn = S) = 1 \quad \text{الاتساق: أي ان} \quad -$$

$$\sqrt{n}(\widehat{\beta}_{ad.lasso} - \beta) \rightarrow^s N(0, \sigma^2 \Sigma_{11}^{-1}) \quad \text{التوزيع الطبيعي المحاذي} \quad -$$

إذ ان $\hat{S} = \{k: \hat{\beta}_k \neq 0\}$ تمثل متجه قيم معلمات المتغيرات الذي تكون غير صفيرية و S هي قيمة الحقيقية للمعلمة

ويمكن تصنيف دالة الجزاء (Adaptive lasso) على الاعداد التقسيمي المركب للمؤشر الاحادي

$$(\hat{b}_1, \hat{b}_2, \dots, \hat{b}_q, \beta^{CQR}) = \min_{b_1, b_2, \dots, b_q, \beta} \sum_{q=1}^Q [\sum_{i=1}^n \rho_{\tau q} [y_i - b_q - f(X_i^T \beta)]] +$$

$$\lambda \sum_{k=1}^p \widehat{w}_k |\beta_k|$$

y_i :- قيمة متغير تابع

$f(\cdot)$:- دالة الارتباط غير معروفة

b_q :- تمثل التقاطع التقسيمي عند مستوى $\rho_{\tau q}$

P :- متغير مشترك الابعاد $(x_1, x_2, \dots, x_p)$

$$\tau_q(t) = t(\tau_q - I), I < 0$$

$$Q, \dots, 2, q=1, \tau_q = \frac{q}{q+1}$$

λ :- معلمة الضبط $\lambda > 0$

w_k : تمثل الوزن $w_k > 0$

تم شرح خوارزمية دالة الجزاء (Adaptive lasso) على النحو التالي

المرحلة الاولى :- افترض مصفوفة X ذات المتغيرات القياسية تحتوي على اعمدة

$$p, \dots, 3, 2, k=1, X_k^* = \frac{X_k}{w_k}$$

المرحلة الثانية :- حل مشكلة (lasso) لجميع قيم λ الممكنة

$$(\hat{b}_1, \hat{b}_2, \dots, \hat{b}_q, \beta^{CQR}) = \min_{b_1, b_2, \dots, b_q, \beta} \sum_{q=1}^Q [\sum_{i=1}^n \rho_{\tau q} [y_i - b_q - f(X_i^T \beta)]] + \lambda \sum_{k=1}^p \hat{w}_k |\beta_k|$$

المرحلة الثالثة :- احسب حل طريقة (Adaptive lasso)

$$\hat{\beta}_{k^{**}} = \frac{\hat{\beta}_k^*}{\hat{w}_k}$$

6. جانب التجريبي

في هذا الجزء تم استعمال اسلوب محاكاة باستعمال برنامج الإحصائي (R) للمقارنة بين طرائق التقدير شبه المعلمي الانحدار التقسيمي المركب لأنموذج المؤشر الواحد وتحليل وعرض نتائج المحاكاة في تقدير باستعمال اربعة حجوم عينات (30، 50، 100، 200) وعدد المتغيرات التفسيرية (p=10، 30) وثلاثة قيم ل (0.75، 0.50، T=0.25) واخذ توزيع الطبيعي (N(0، 1) للطريقتين تقدير وهما (Ad.Lasso، Laplac) وباستعمال معيارين مقارنة (معدل متوسط مربعات الخطأ و متوسط الخطأ النسبي المطلق) لمعرفة الطريقة الافضل.

جدول (1) يمثل MAPE، MSE باستعمال طريقتين تقدير عندما 0.5، Tau=0.25، p10 0.75 لأنموذج الانحدار التقسيمي المركب. عندما N(0، 1)

		AMSE		MAPE	
T	N	Laplace	Ad.Lasso	Laplace	Ad.Lasso
0.25	30	0.2140	0.2080	41.1030	44.5570
	50	0.1270	0.1130	32.5900	31.5190
	100	0.0630	0.0560	26.8860	22.4820
	200	0.0290	0.0270	21.7930	17.3780
	30	0.2130	0.2040	42.3720	43.5900

0.5	50	0.1240	0.1080	32.1940	30.7190
	100	0.0610	0.0550	26.5020	21.8640
	200	0.0290	0.0270	21.2930	17.3830
0.75	30	0.2100	0.1960	40.6710	40.0050
	50	0.1250	0.1130	31.6660	31.1150
	100	0.0610	0.0570	26.7660	21.8910
	200	0.0290	0.0260	21.0140	16.6960

جدول (2) يمثل MSE، MAPE باستعمال طريقتين تقدير عندما $\tau=0.25$ ، 0.5، 0.75 p30 لأنموذج الانحدار التقسيمي المركب. عندما $N(0,1)$

		AMSE		MAPE	
T	N	Laplace	Ad.Lasso	Laplace	Ad.Lasso
0.25	30	0.2550	0.3850	22.0570	38.8880
	50	0.1510	0.1360	20.3960	30.9460
	100	0.0820	0.0610	18.7940	19.5760
	200	0.0450	0.0300	13.3490	13.8650
0.5	30	0.2480	0.4550	21.0000	44.7520
	50	0.1570	0.1380	19.5580	32.4110
	100	0.0860	0.0570	17.8920	13.9220
	200	0.0450	0.0290	11.9940	11.8710

0.75	30	0.2530	0.4060	22.5200	45.5410
	50	0.1650	0.1430	21.2930	19.0090
	100	0.0840	0.0600	19.9020	17.4160
	200	0.0420	0.0280	14.7470	12.0570

نموذج الانحدار الكمي المركب الأحادي المؤشر يكون سهل الاستخدام وخصوصاً مع كبر حجم عدد المتغيرات المستقلة في الدراسة لذلك كانت النتائج مقاربة في ما بعضها

اظهرت النتائج في جدول (1) وعندما $p=10$ اظهرت طريقة Ad.Lasso هي الأفضل في كافة حجوم العينات هي الافضل واقل معدل متوسط مربعات خطأ ومتوسط النسبة المئوية المطلقة وتأتي طريقة بعدها طريقة Laplace

وظهرت النتائج في جدول (2) وعندما $p=30$ اظهرت طريقة Laplace هي الافضل واقل معدل متوسط مربعات خطأ ومتوسط النسبة المئوية مطلق عند حجم عينة (30) وعند حجوم عينات (50،100،200) ظهرت طريقة Ad.Lasso هي الافضل واقل معدل متوسط مربعات خطأ ومتوسط النسبة المئوية المطلق وتأتي بعده طريقة Laplace

7. الاستنتاجات

نموذج الانحدار الكمي المركب الأحادي المؤشر يكون سهل الاستخدام وخصوصاً مع كبر حجم عدد المتغيرات المستقلة في الدراسة. وكذلك لها دور كبيراً في تقليل تأثير من مشكلة تعدد الخطي لكونه يجعل مجموعة متغيرات في دالة واحدة تسمى دالة الربط. وهما طريقتان الجزائية المستخدمة (Ad.lasso،laplace). أعطت لنا نتائج متفاوتة وكانت طريقة (Ad.lasso) هي الافضل لتحليل الانحدار التقسيمي المركب الانموذج المؤشر الاحادي لأنها اقل معدل متوسط مربعات خطأ ومتوسط النسبة المئوية المطلق .

8. المصادر

1. Lee، E. R.، Noh، H.، & Park، B. U. (2014). Model selection via Bayesian information criterion for quantile regression models. *Journal of the American Statistical Association*، 109(505)، 216-229.
2. Fan، J.، & Li، R. (2001). Variable selection via nonconcave penalized likelihood and its oracle properties. *Journal of the American statistical Association*، 96(456)، 1348-1360.
3. Wu، Y.، & Liu، Y. (2009). Variable selection in quantile regression. *Statistica Sinica*، 801-817.

4. Zou, H., & Yuan, M. (2008). Composite quantile regression and the oracle model selection theory.
5. Koenker, R., & Bassett Jr, G. (1978). Regression quantiles. *Econometrica: journal of the Econometric Society*, 33-50.
6. Song, Y., Li, Z., & Fang, M. (2022). Robust variable selection based on penalized composite quantile regression for high-dimensional single-index models. *Mathematics*, 10(12), 2000.
7. Fan, Y., Härdle, W. K., Wang, W., & Zhu, L. (2013). Composite quantile regression for the single-index model.
8. Vettam, S., & John, M. (2019). Regularized deep learning with nonconvex penalties. *arXiv preprint arXiv:1909.05142*.
9. Naik, P. A., & Tsai, C. L. (2001). Single-index model selections. *Biometrika*, 88(3), 821-832.
10. Wahid, A., Khan, D. M., & Hussain, I. (2017). Robust Adaptive Lasso method for parameter's estimation and variable selection in high-dimensional sparse models. *PLoS one*, 12(8), e0183518.
11. Fan, J., & Li, R. (2001). Variable selection via nonconcave penalized likelihood and its oracle properties. *Journal of the American statistical Association*, 96(456), 1348-1360.
12. John, M., & Vettam, S. (2024). A few theoretical results for Laplace and arctan penalized ordinary least squares linear regression estimators. *Communications in Statistics-Theory and Methods*, 53(13), 4819-4840.
13. Genç, M., & Özkale, M. R. (2024). Lasso regression under stochastic restrictions in linear regression: An application to genomic data. *Communications in Statistics-Theory and Methods*, 53(8), 2816-2839.
14. Wang, X., Jiang, Y., Huang, M., & Zhang, H. (2013). Robust variable selection with exponential squared loss. *Journal of the American Statistical Association*, 108(502), 632-643.
15. Zou, H., & Yuan, M. (2008). Composite quantile regression and the oracle model selection theory.