



استعمال طريقة انحدار لاسو البيانية الممكنة FGLasso لتقدير معالم نموذج الانحدار الخطي العام في ظل وجود بيانات عالية الأبعاد مع تطبيق

Using Feasible Graphical Lasso Regression Method to Estimate the Parameters of General Linear Regression Model Under High Dimensional Data with Application

أ.م. د. أحمد مهدي صالح⁽²⁾

محمد جاسم فرحان⁽¹⁾

Asst. Pro. Ahmed Mahdi Salih

Mohammed Jasim Farhan

كلية الإدارة والاقتصاد/ جامعة واسط

المستخلص

تعد مشكلة الأبعاد الكبيرة من المشاكل المهمة التي تعاني منها البيانات، فوجود بيانات عالية الأبعاد نموذج الانحدار الخطي العام تزداد صعوبة استعمال طرائق التقدير الكلاسيكية كطريقة الإمكان الأعظم أو طريقة العزوم، إذ تفقد هذه الطرائق إلى تقديرات متحيزة وغير كفوة لتقدير معالم النموذج. وهنا دعت الحاجة إلى استعمال طرائق أخرى لتقدير معالم نموذج الانحدار الخطي العام. وفي بحثنا هذا تم استعمال طريقتين هما: طريقة **Smooth Integration of Counting SICA** و **Absolute Deviation** ، وكذلك تم استعمال طريقة لاسو البيانية الممكنة FGLasso ، وتم استعمال بيانات محاكاة، وكذلك بيانات حقيقية تمثل مستوى التلوث في نهر دجلة. تمت مقارنة النتائج باستعمال متوسط مربعات الخطأ MSE، و أظهرت النتائج أفضلية مقدر FGLasso.

الكلمات المفتاحية :- لاسو البيانية الممكنة ، الأبعاد الكبيرة ، التلوث.

Abstract

The high dimensions problem is one of the important problems that affect the data, and with company of high dimensional data in the general linear regression model, it becomes very difficult to use classical estimation methods such as maximum likelihood method and moments

method because these methods lead to biased and inefficient estimates for parameters of the model. The necessity to use new methods to estimate the parameters of the general linear regression model. In this research, two methods were used, the **Smooth Integration of Counting Absolute Deviation SICA** method, as well as the **Feasible Graphical Lasso** method **FGLasso**. Simulation data were used, as well as real data representing the level of pollution in the Tigris River. The results compared using the **Mean Square Error MSE** and the results showed that the **FGLasso** estimator is the best.

Keywords:- Feasible Graphical Lasso, High Dimensions, Pollution

1- المقدمة

تعد مشكلة الأبعاد الكبيرة للعينات تحت الدراسة، عندما يكون عدد المتغيرات p أكبر من حجم العينة n إحدى المشاكل التي تواجه أي باحث إحصائي هذه المشكلة من التحديات على المستوى النظري، وكذلك العملي لكثير من الدراسات والبحوث. ويعتمد الباحثون إلى اختصار أو استبعاد مجموعة معينة من التغيرات ذات التأثير القليل أو غير المؤثر إحصائياً. في حين يرى الآخرون ضرورة أخذ التغيرات كلها تحت الدراسة، وتتبع بعض الأساليب النظرية لحل المشاكل الرئيسية التي تجلبها الزيادة الكبيرة في عدد المتغيرات نسبة إلى حجم العينة. وفي دراستنا هذا سنستخدم نموذج الانحدار الخطي العام [1].

$$Y = XB + \varepsilon \quad \dots(1)$$

إذ إن:

Y هو متجه $(n \times 1)$ يمثل المتغير المعتمد.

X تمثل مصفوفة $(n \times p)$ من المتغيرات التوضيحية، والتي تحتوي على كمية كبيرة من المتغيرات.

ε يمثل متجه $(n \times 1)$ ، ويمثل الخطأ العشوائي، وفي حين B ، وهو متجه $(p \times 1)$ من المعالم المراد تقديرها، إذ إن تقدير هذا المعالم عادة يكون باستعمال طرائق التقدير الكلاسيكية مثل طريقة الإمكان الأعظم، ولكن لوجود مشكلة الأبعاد الكبيرة تلجأ إلى استعمال طرائق أكثر تطوراً التغلب على المشاكل التي تجلبها الأبعاد الكبير [3].

2- أهمية وهدف البحث:

تبرز أهمية البحث من خلال أهمية ظاهرة تلوث مياه الأنهار، وما لها من تأثير كبير في حياة الفرد، وكذلك مستقبل الأجيال اللاحقة. وتتنوع أسباب التلوث في العراق، وكذلك تتعدد أنواع الملوثات منها: العضوية (ناتج مخلفات الإنسان)، ومنها الصناعية (مخلفات المصانع)، وكذلك هناك ملوثات طبيعية بيئية. وتعد هذه الظاهرة جديرة بالدراسة والتحليل، واستعمال الأدوات، والأساليب الإحصائية؛ لتحليل بياناتها، ودراسة سلوكياتها الحالية، والتنبؤ بسلوك الظاهرة وحجمها مستقبلاً.

يهدف بحثنا هذا إلى استعمال نموذج الانحدار الخطي العام؛ لتحليل بيانات تلوث نهر دجلة، إذ إن العينة أساساً تعاني من مشكلة الأبعاد الكبيرة، أي إن عدد المتغيرات تحت الدراسة أكبر من حجم العينة. وهنا دعت الحاجة إلى استعمال طرائق جديدة لتقدير معالم نموذج الانحدار الخطي عالي الأبعاد، في ظل وجود هذه المشكلة والمقارنة بين هذه الطرائق؛ لاختيار الطريقة الأفضل في التقدير.

3- طريقة SICA : Smooth Integration of Counting Absolute Deviation

بشكل عام تأخذ طرائق الانحدار الجزائية أشكال عدّة، والهدف النهائي هو تقليل الأخطاء التجريبية، إذ تم استعمال تقنيات عدّة لتقليص متجه معالم الانحدار. وهنا قسم $Lv \delta Fan$ في عام 2009 طريقة جديدة تدعى طريقة *Smooth SICA* *Integration of Counting Absolute Deviation*، وتعتمد على تحويل معلّمة الجزء λ ؛ لكي تكون نسبية تحت شروط الأبعاد الكبيرة. وهذا العمل أساساً تم تقديمه من قبل [7] Nikolova، والتي اقترحت أن تكون دالة الجزء هي نسبية بين المجموع الطبيعي $Lp - Norms$ من الدرجة الأولى كما يأتي:

$$f(\lambda, \beta) = \lambda \frac{(a+1)\|\beta\|_1}{a+\|\alpha\|_1} \quad \dots (2)$$

إذ إن a هو ثابت أكبر من الصفر $a > 0$ ، وتمثل α مقدّرات مسبقة لمعالم الانحدار. قام [2] $Fan \delta lv$ باقتراح تعديل على مقام المعادلة (2) كما يأتي:

$$f(\lambda, \beta) = \lambda \frac{(a+1)\|\beta\|_1}{(a+\|\alpha\|_1)^2} \quad \dots (3)$$

وهنا كأنما أصبحت دالة الجزء هي نسبية بين مجموع الطبيعي من الدرجة الأولى والدرجة الثانية، واقتراح $Lv \delta Fan$ استعمال تقديرات المربعات الصغرى الآتية [6]:

$$\alpha = (X'X)^+ X'Y \quad \dots(4)$$

أذ إنّ (+) إشارة الى معكوس Moore – Penrose

وحيث إنّ [4]

$$\hat{\beta}_{SKA} = \arg_{\beta} \min (n^{-1} \epsilon' \epsilon + \lambda w \|\beta\|_1) \quad \dots(5)$$

إذ إنّ W

$$W = \lambda \frac{a+1}{(a+\|\alpha\|_1)^2} \quad \dots(6)$$

و بحلّ المتباينة في معادلة (5)

$$L(\beta) = (Y - X\beta)' (Y - X\beta) + \lambda w c' \beta \quad \dots(7)$$

إذ إنّ C متجه أحادي بأبعاد $(\rho \times 1)$ ولتبسيط المعادلة [10]

$$L(\beta) = (Y'Y - 2\beta X'Y + \beta X'X\beta) + \lambda w c' \beta \quad \dots(8)$$

وباشتقاق المعادلة (8) بالنسبة إلى β ومساواته بالصفر

$$0 = -X'Y + X'X\beta + \lambda wc \quad \dots(9)$$

$$X'Y - \lambda wc = X'X\beta \quad \dots(10)$$

وباستعمال معكوس Moore – penrose اقترح *Moore – penrose* استعمال الصيغة الآتية في حالة الأبعاد الكبيرة كما يأتي [9]:

$$\beta^{SLCA} = (X'X)^+(X'Y - \lambda wc) \quad \dots(11)$$

إذ إن $0 < \lambda < 1$ ويُنم اقتراح قيمها من قبل الباحث [3].

Feasible Graphical Lasso

4- طريقة انحدار Lasso البيانية الممكنة

نم اقتراح الطريقة من قبل TAN وآخرون [7] في عام 2018. ويعتمد على تطوير مقدر المربعات الصغرى العامة GLS، الذي تم تقديمه أساساً من قبل Zellner [8] فبالعودة إلى النموذج (1) يكون مقدر GLS بالصيغة الآتية [5]:

$$\beta_{FGLS}^{\wedge} = (X'\Omega X)^{-1}X'\Omega Y \quad \dots(12)$$

إذ إن مصفوفة Ω تم تعريفها من قبل Zellner بالصورة الآتية [12]

$$\Omega = \begin{bmatrix} 1 & \rho & \rho^2 & \rho^3 & \dots & \rho^{n-1} \\ \rho & 1 & \rho & \rho^2 & \dots & \rho^{n-2} \\ \rho^2 & \rho & 1 & \rho & \dots & \rho^{n-3} \\ \rho^3 & \rho^2 & \rho & 1 & \dots & \rho^{n-4} \\ \vdots & \vdots & \vdots & \vdots & \ddots & \vdots \\ \rho^{n-1} & \rho^{n-2} & \rho^{n-3} & \rho^{n-4} & \dots & 1 \end{bmatrix}$$

يمثل ρ معامل الارتباط الخطي العام. تم اقتراح تطوير للمقدّر الموجود للمعادلة (12)، كما يأتي: وأطلق عليه تسمية مقدّر المربعات الصغرى الممكن بالصيغة الآتية:

$$\hat{\beta}_{FGLS} = (X' \Sigma^{-1} X)^{-1} X' \Sigma^{-1} Y \quad \dots (13)$$

إذ إنّ

$$\Sigma = \frac{1}{n} \epsilon' \epsilon$$

إذ إنّ ϵ يمثل المتجه الخطأ العشوائي

ويكون المقدّر في المعادلة (13) متحيزاً وغير مستقرّ في حالة الأبعاد الكبيرة. وهنا اقترح TAN

وآخرون تعديلاً على المقدّر في المعادلة (13) وكما يأتي [11]:

$$\hat{\beta}_{FGLasso} = (X' \hat{\Omega} X)^{-1} X' \hat{\Omega} Y \quad \dots (14)$$

إذ إنّ

$$\hat{\Omega} = tr(\Omega \Sigma) - \log \det(\Omega) + \lambda tr(\Omega' \Omega) \quad \dots (15)$$

وأطلق على المقدّر في المعادلة (14) بمقدّر Lasso البياني الممكن، ويكون مناسباً للعمل تحت شروط البيانات الكبيرة، عندما يكون عدد المتغيرات تحت الدراسة أكبر من حجم العينة، إذ إنّ $0 < \lambda < 1$ ، ويتم اقتراح قيمها من قبل الباحث.

5- المحاكاة:

تمّ هناك توليد بيانات بمختلف أحجام العينات $n=10, 20, 30, 40, 50, 60, 70, 80$. وكذلك تمّ اختيار ثلاث قيم لمعلمة الجزء $\lambda = 0.3, 0.6, 0.9$. تمّ توليد البيانات بالاعتماد على مقاييس بيانات حقيقية بطريقة التحويل المعكوس حول

التلوث، إذ يمثل Y نسبة التلوث العامة، و X تمثل مجموعة متغيرات بعدد 80 تمثل الملوثات بأنواعها، وتمت المقارنة بين الطريقتين بالاعتماد على متوسط مربعات الخطأ MSE بالصيغة الآتية [11] .

$$MSE = \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 / n \quad \dots (16)$$

إذ كانت نتائج المحاكاة كالآتي:

الجدول رقم (1)

متوسط مربعات الخطأ للطريقتين $P=80$

	$\lambda = 0.3$		$\lambda = 0.6$		$\lambda = 0.9$	
n	SICA	FGLasso	SICA	FGLasso	SICA	FGLasso
10	27.45	33.24	23.45	30.11	23.34	29.43
20	22.01	21.90	21.90	21.88	21.33	21.55
30	20.13	18.92	20.00	18.65	19.30	18.33
40	19.10	17.81	18.80	17.23	18.39	17.11
50	18.02	17.93	17.77	16.22	17.50	16.01
60	17.76	15.00	17.04	14.89	16.88	14.66
70	17.05	14.11	16.80	14.00	16.13	13.55
80	16.51	12.83	16.03	12.54	15.92	12.23

من ملاحظة الجدول رقم (1) عندما يكون حجم العينة 10 (صغير بالنسبة إلى عدد المتغيرات) نلاحظ أنّ طريقة SICA كانت الأفضل، واستمرت أفضليتها حتى حجم عينة مساوٍ إلى 20 ، عندما $\lambda = 0.3$. وعندما يصل حجم العينة إلى 30 نلاحظ تفوق طفيف لمقدّر FGLasso . ويستمر هذا التفوق البسيط إلى حجم عينة 50. وعند الوصول إلى حجم عينة 60 نلاحظ أفضلية واضحة لمقدّر FGLasso إلى حين يساوي حجم العينة عدد المتغيرات، وكانت الأفضلية للمقدّرات عندما تكون معلّمة الجزاء أقرب إلى الواحد.

5- البيانات الحقيقية:

تم الحصول على عينة بحجم 40 تمثل كل مشاهدة فيها 10 سنتمتر مكعب من مياه نهر دجلة، تم فحصها في مختبرات دائرة مياه واسط. وتم تسجيل 80 ملوثا تمثل الأنواع المختلفة من الملوثات، كما هي مفصلة في الملحق وكانت النتائج كالآتي:

الجدول رقم (2)

قيمة متوسط مربعات الخطأ للبيانات الحقيقية $n=40$, $P=80$

	SICA	FGLasso
$\lambda = 0.3$	37.67	29.56
$\lambda = 0.6$	33.11	23.87
$\lambda = 0.9$	28.32	19.56

من الجدول رقم (2) يتبين لدينا أفضلية مقدر FGLasso على مقدر SICA بالنسبة للبيانات الحقيقية، وبالذات عندما تكون معلمة الجزء أكبر ما يمكن.

6- التوصيات:

من خلال ما تم عرضه من نتائج المحاكاة والبيانات الحقيقية نوصي باعتماد مقدر FGLasso لتقدير معالم نموذج الانحدار العام عالي الأبعاد بالذات، عندما يكون حجم العينة صغير نسبيا أو قريب إلى حجم العينة. كذلك نوصي باعتماد مقدر SICA عندما يكون حجم العينة صغير جدًا نسبة إلى عدد المتغيرات.

References.

- [1]. Buhlmann. P, Van De Geer. S, “ *Statistics for High-Dimensional Data: Methods, Theory and Applications*” Springer, 2011.
- [2]. Fan. Y, Lv. J, “Sure Independence Screening for Ultra-High Dimensional Feature Space” Royal Statistical Society, Vol. 70, Issue. 5, pp. 849-911, 2008.
- [3]. Hoerl. A, Kennard. R, ”Ridge Regression: Biased Estimation for Nonorthogonal Problems” *Technometrics*, Vol. 12, No. 1, pp. 55-67, 1970.

- [4]. James. W, Stein. C, “Estimation with Quadratic loss” Proceedings 4th Berkeley Symposium, pp. 361-379, 1961.
- [5]. Khorshed. E, Abood, S, “Comparison between the Methods of Ridge Regression and Liu Type to Estimate the Parameters of the Negative Binomial Regression Model Under Multicollinearity Problem by Using Simulation” *Journal of Economics and administrative Science*, Vol. 24, No. 109, pp. 515-534, 2018.
- [6]. Mohammed. L, Khadhm. S, “Estimate Kernel Ridge Regression Function in Multiple Regression” *Journal of Economics and administrative Science*, Vol. 24, No. 103, pp. 411-419, 2018.
- [7]. Nikolova. M, “Local Strong Homogeneity of Regularized Estimator” *SIAM Journal of Applied Mathematics*, Vol. 61, No. 1, pp. 633-658, 2000.
- [8]. Pesaran. M, Smith. R, “Signs of Impact Effects in Time Series Regression Models” *Economics Letters*, Vol. 122, pp. 150-153, 2014.
- [9]. Salih. A, Hmood. M, “Analyzing big data sets by using different panelized regression methods with
application: surveys of multidimensional poverty in Iraq” *Periodicals of Engineering and Natural Sciences*.
Vol. 8, No. 2, pp. 991-999, 2020.
- [10]. Salih. A, Hmood. M, “Big Data Analysis by Using One Covariate at a Time Multiple Testing (OCMT) Method: Early School Dropout in Iraq” *Int. J. Nonlinear Appl.* Issue. 12, No. 2, pp. 931-938, 2021.
- [11]. Van Der Vaart. A, “*Asymptotic Statistics*” Cambridge: Cambridge Series in Statistical and Probabilistic Mathematics, 1998.
- [12]. Xu. K, “A new nonparametric test for high-dimensional regression Coefficients’ *Journal of Statistical Computation and Simulation*, Vol. 5, pp. 855-867, 2017.

Appendix

Variables

no	Variable	no	Variable	No	Variable
Y	CPR	29	DO	57	¹³⁷Cs
1	SO₃	30	CODMn	58	⁹⁰Sr
2	SO₂	31	COD	59	Coliforms
3	Ph	31	BOD	60	Streptococci bacteria
4	<u>Turbidity</u> (NTU)	32	NH4-N	61	Phytoplankton
5	Electrical conductivity	33	TP	62	Zooplankton,
6	Alkalinity (CaCO₃)	34	TN	63	Zoobenthos,
7	Hardness (CaCO₃)	35	TCu	64	Macrophytes
8	Ammonia (N-NH₃)	36	TZn	65	PbH
9	Nitrate (N-NO₃⁻)	37	F⁻	66	H₂S₂
10	Apparent colors (HU)	38	TSe	67	AgS₂
11	Nitrite (N-NO₂⁻)	39	TAs	68	SO₂
12	Phosphorus (P)	40	THg	69	SO₄
13	Fluoride (F⁻)	41	TCd	70	ESP
14	Iron (Fe)	42	Cr6⁺	71	SAR

15	<u>Escherichia coli</u>	43	TPb	72	Hco3
16	PbO	44	TCN	73	Cl
17	CdO₃	45	V-ArOH	74	EC
18	HgO₂	46	Petroleum	75	P
19	AgO	47	Anionic surfactant	76	CIS
20	MgO	48	S2-	77	CO
21	KO	49	Sulphate	78	CO₃
22	Dissolved Metals	50	Mercury	79	KCl
23	Particulate Metals	51	Copper	80	MgCl
24	Exchangeable Metals	52	Zinc		
25	Residual Metals	53	PCB	-	
26	Essential Metals	54	HCH	-	
27	Dissolved oxygen	55	PAH	-	
28	Biochemical Oxygen	56	MgS	-	