

المقارنة بين بعض المقدرات المتحيزة في الانحدار الخطي العام بوجود التعدد الخطي*

أ.م.د. سجي محمد حسين الباحثة: حنين مراد يوسف الصالحي

قسم الإحصاء / كلية الإدارة والاقتصاد / جامعة بغداد

تاريخ استلام البحث: 2014/1/7 تاريخ قبول النشر: 2014/2/19

المستخلص :-

أن مشكلة تعدد العلاقة الخطية أصبحت معروفة لدى العديد من الباحثين الإحصائيين وكذلك معرفة أثارها الإحصائية على معلمات أنموذج الانحدار الخطي المتعدد إذ تؤدي هذه المشكلة في ابسط حالتها إلى ابتعاد معلمات أنموذج الانحدار المقدر عن خصائصها العلمية المرجوة منها في تفسير الظاهرة العلمية بالأسلوب الصحيح ، حيث تعد هذه المشكلة من المشاكل القائمة الوجود في العديد من المجالات وان وجودها له تأثيرات على تقديرات وتباينات معاملات المربعات الصغرى الاعتيادية (OLS) ، لذا وجب تفادي هذه المشكلة ووضع الحلول المناسبة. وقد تم في هذا البحث

التطرق إلى عدة طرائق في التقدير وهي (Generalized Liu Estimator (GL)

و (Generalized Ridge Regression (GJR) ,Generalized Jackknife Ridge Regression (GRR)

Regression (GRR) للتغلب على هذه مشكلة ومن هنا تركز اهتمامنا في هذا البحث على

اختيار أفضل المقدرات لأنموذج الانحدار الخطي العام في حالة وجود مشكلة تعدد العلاقة الخطية

بين المتغيرات التوضيحية من خلال استخدام المحاكاة بأسلوب مونت كارلو، حيث تمت المقارنة

فيما بينها وفق معيار المقارنة متوسط مربعات خطأ (Mean Square Error (MSE)، وقد تبين

إن أفضل المقدرات هو المقدر GL حيث يمتلك اقل متوسط مربعات خطأ (MSE) مقارنة مع

مقدرات المربعات الصغرى وبقية المقدرات المتحيزة الأخرى .

المصطلحات: التعدد الخطي، مقدر انحدار الحرف العام (Generalized Ridge (GRR)

Regression، مقدر جاكنايف لانحدار الحرف العام (Generalized Jackknife (GJR)

مقدر Ridge Regression، مقدر (Generalized Liu (GL)

A Comparisons Among Some Biased Estimators in Generalized Linear Regression Model in present of Multicollinearity

Dr. Saja M. Hussein

Researcher: Haneen Mourad Yousif

Abstract: The Multicollinearity problem has currently became known by many researchers and knowledge of the statistical effects on parameters of the multiple linear regression model.

In a simple case this problem causes to move away the estimate of parameters in the regression model that he scientific capabilities that desired in interpretation of the phenomenon in a correct way.

This problem has been found in many areas that has been got negative effects on the estimates and variances of coefficients of (OLS). So we should avoid this problem and develop appropriate solution. In this article we will present some methods to estimate a (GRR, GJR, GL) to overcome this problem. The aim is to select the best estimator for the multiple linear regression model in case presence of Semi Perfect Multicollinearity among the explanatory variables by using Monte Carlo method. Then, We will compare among the estimators by using MSE. Finally, We conclude that (GL) is the best method.

Keywords: Multicollinaerity ,Generalized Ridge Regression (GRR), Generalized Jackknife Ridge Regression (GJR), Generalized Liu Estimator (GL).

المقدمة وهدف البحث :-

قد تعاني البيانات في العديد من الدراسات الاقتصادية من احد المشاكل التي تظهر عند الإخلال بفروض الانحدار ، ومن هذه الفروض هو " عدم وجود علاقة خطية تامة أو شبه تامة بين المتغيرات التوضيحية " فعند عدم تحقق هذا الفرض فإن النموذج يعاني من مشكلة تدعى بـ تعدد العلاقة الخطية (Multicollinaerity) ، وعند وجود هذه المشكلة فإن مقدرات المربعات الصغرى الاعتيادية (OLS) سوف تكون غير دقيقة أي لا تحقق خاصية أفضل تقدير خطي غير متحيز (BLUE) Best Linear Unbiased Estimator ، و لأجل معالجة هذه المشكلة فقد تم استعمال عدة طرق للمعالجة ، ومن هذه الطرق مقدر انحدار الحرف العام Generalized Ridge

Regression (GRR) و مقدر Generalized Jackknife Ridge Regression (GJR) و مقدر Generalized Liu Estimator (GL) وقد اهتم الكثير من الباحثين في هذا الموضوع

[4] [5]

ومن هذه الدراسات نذكر بعض منها: دراسة Hoerl & Kennard (عام 1970 a,b) حيث قدمنا من خلال بحثيين متتالين طريقة انحدار Ridge والتي تعالج مشكلة تعدد العلاقة الخطية وذلك بأخذ مصفوفة المتغيرات التوضيحية $(X'X)$ بعد أن يضاف الي عناصرها القطرية مقدار صغير موجب (K) ومن ثم معرفة تأثيره على مقدرات الانحدار حيث بين انه عند إضافة هذا

[15]

المقدار فإنه يعمل على تقليل (MES) ، كما أجرى Mason في عام (1977) مقارنة بين طريقة انحدار الحرف الاعتيادي و طريقة الجذور الصماء (Eigen values) ومقدرات المركبات الرئيسية (Principal Components) وركز على العلاقة بين مقدرات هذه الطريقة والطرق الأخرى وبين إن مقدرات طريقة انحدار الحرف (ORR) تمتلك اقل (MSE) من غيرها من

[10]

الطرائق الأخرى المتحيزة، كما قام الباحث Liu Kejian وفي عام (1993) باقتراح مقدر يعتمد على دمج مزايا طريقتي التقدير وهما مقدر الحرف الاعتيادي (Ordinary Ridge Regression (ORR) ومقدر Stein ، حيث يتفوق هذا المقدر على مقدر الحرف الاعتيادي (ORR) كونه يمثل دالة خطية بالمعلمة d ، وفي عام (2003) قام Kibria بدراسة حول مقدر الحرف العام (GRR) واقترح عدة طرائق لتقدير معلمة الحرف K وبين انه مقدر (GRR) يتغلب على جميع المقدرات المتحيزة وذلك تحت معيار (MSE) ، وكما قامت الباحثة المشهداني ، أيمن

[2]

محمد في عام (1994) بتشخيص مشكلة تعدد العلاقة الخطية ومعالجتها وذلك باستخدام طريقة المركبات الرئيسية ، وكذلك أوضحت أهم النقاط الأساسية الخاصة بها ، وبيان كفاءتها نسبة إلى طريقة المربعات الصغرى الاعتيادية و أيضا مقارنتها مع طريقة انحدار الحرف (RR) .

[8]

كما قام الباحث Feras في عام (2008) باقتراح مقدر جديد (Modified (MJR) Jackknife Ridge Regression ، حيث يعمل على تعديل مقدر Generalized Ridge Regression (GRR) على نفس خطى (JRR) Jackknife Ridge Regression و قيم أداء هذا المقدر من خلال معيار (MSE) حيث يمتلك هذا المقدر (MSE) اقل من المقدرات المتحيزة الأخرى (GRR, JRR) لقيم مختلفة من الثوابت المتحيزة .

هدف البحث

يهدف البحث إلى دراسة بعض طرائق التقدير المتحيزة عند وجود مشكلة تعدد العلاقة الخطية والمقارنة فيما بينها وذلك من خلال استخدام معيار المقارنة متوسط مربعات الخطأ (MES) للحصول على أفضل التقديرات والتي يتم من خلالها التغلب على مشكلة تعدد العلاقة الخطية .

الجانب النظري

من هذه الطرق التي تم تناولها البحث لمعالجة مشكلة التعدد الخطي للنموذج الخطي العام هي :

[12]

1- مقدر انحدار الحرف العام (GRR) Generalized Ridge Regression

تم اقتراح هذا المقدر من قبل Hoerl & Kennard عام 1970 للنموذج الخطي العام:

$$Y = X\beta + \varepsilon$$

... (1)

Y : يمثل متجه مشاهدات متغير الاستجابة من الرتبة $n \times 1$

X : يمثل مصفوفة المتغيرات التوضيحية من الرتبة $n \times p$

β : يمثل متجه المعلمات المجهولة من الرتبة $p \times 1$

ε : يمثل متجه الأخطاء العشوائية من الرتبة $n \times 1$ حيث أن $\varepsilon \sim N(0, \sigma^2 I_n)$

حيث ان مقدر انحدار الحرف العام (GRR) Generalized Ridge Regression (α) فيعطى بالصيغة الآتية :

$$\hat{\alpha}_{GRR} = (\chi^{*'} \chi^* + K)^{-1} \chi^{*'} y$$

or

$$\hat{\alpha}_{GRR} = (I - A^{-1}K) \hat{\alpha}_{OLS} \quad \dots \quad (2)$$

إذ أن :

$$A = (\Lambda + K)$$

$$\hat{\alpha}_{OLS} = (\chi^{*'} \chi^*)^{-1} \chi^{*'} y \quad \dots \quad (3)$$

$$= \Lambda^{-1} \chi^{*'} y$$

$$X^* = XP, \quad \alpha = P'\beta$$

$$P'(X'X)P = \Lambda = \text{diag}(\lambda_1, \lambda_2, \dots, \lambda_p)$$

P : مصفوفة ذات رتبة (P*P) وأعمدتها تمثل المتجهات المميزة $(v_1, v_2, v_3, \dots, v_p)$ لمصفوفة (X'X) وان $P'P = I$

K : تمثل مصفوفة قطرية بالمدخلات $(k_1, k_2, k_3, \dots, k_p)$ ، وهذه قيم الـ K تعمل على تقليل MSE لمقدر انحدار الحرف العام (GRR).

$$\hat{K}_i = \frac{\hat{\sigma}^2}{\hat{\alpha}_i^2} = \text{diag} \left(\frac{\hat{\sigma}^2}{\hat{\alpha}_1^2}, \frac{\hat{\sigma}^2}{\hat{\alpha}_2^2}, \dots, \frac{\hat{\sigma}^2}{\hat{\alpha}_p^2} \right)$$

$\hat{\alpha}_i$: تمثل مقدر المربعات الصغرى الاعتيادية لـ α

و أن مقدر الحرف العام هو متحيز للمعلمة الأصلية، وأن مقدار التحيز هو:

$$\begin{aligned} \text{Bias}(\hat{\alpha}_K) &= E(\hat{\alpha}_K) - \alpha \\ &= C_K \alpha - \alpha = (C_K - I) \alpha \end{aligned}$$

$$MSE(\hat{\alpha}_K) = \hat{\sigma}^2 \sum_{i=1}^p \frac{\lambda_i}{(\lambda_i + K_i)^2} + \sum_{i=1}^p \frac{K_i^2 \hat{\alpha}_i^2}{(\lambda_i + K_i)^2} \quad \dots \quad (4)$$

وقد أثبت كلاهما من [13] viond & ullah (1981) بأن

$$MES((\hat{\alpha}_K)) \leq MES((\hat{\alpha}))$$

: [8] **2-مقدر Generalized Jackknife Ridge Regression (GJR)**

تم اقتراح مقدر جاكنايف (JRR) من قبل Singh

(1986) وآخرون [12] ، و في عام (2008) تم اقتراح مقدر جديد من قبل Batah et al [8] ، حيث تقوم فكرته على تعديل مقدر الحرف العام GRR على نفس خطى مقدر الـ JRR المقترح من قبل Singh (1986) يدعى هذا المقدر بـ

Modified Jackknife Ridge Regression (MJR) و في عام (2011) تم اقتراح

مقدر (GJR) من قبل Batah [9] ، حيث يعتبر الحالة العامة لمقدر MJR، ويرمز له بالرمز $\hat{\alpha}_{GJR}$ ويعرف بالشكل :-

$$\hat{\alpha}_{GJR} = (I - K^2 A^{-2})(I - KA^{-1})^s \hat{\alpha}_{OLS} \quad , \quad S \geq 0 \quad \dots (5)$$

حيث أن:

في حالة $S = 0$ فإن مقدر GJR يتحول إلى مقدر (JRR) Jackknife Ridge Regression ، وكذلك عندما $S = 1$ فإن مقدر GJR يتحول إلى مقدر MJR .
إذ أن :

$$\hat{\alpha}_{JRR} = (I - K^2 A^{-2}) \hat{\alpha}_{OLS}$$

$$\hat{\alpha}_{MJR} = (I - K^2 A^{-2})(I - KA^{-1}) \hat{\alpha}_{OLS}$$

و أن مقدار التحيز للمقدر (GJR) هو بالشكل الآتي :

$$Bias(\hat{\alpha}_{GJR}) = E(\hat{\alpha}_{GJR} - \alpha)$$

$$= -K\varphi A^{-1}\alpha$$

إذ أن :

$$\varphi = (KA^{-1})^{-1}[I - (I - KA^{-1})^s] + (KA^{-1})(I - KA^{-1})^s$$

كما يعرف التباين للمقدر (GJR) بالشكل الآتي :

$$Var(\hat{\alpha}_{GJR}) = \hat{\sigma}^2 V \Lambda^{-1} V'$$

حيث أن :

$$V = (I - K^2 A^{-2})(I - KA^{-1})^s$$

و يعرف متوسط مربعات الخطأ للمقدر (GJR) بالشكل الآتي :

$$MSE(\hat{\alpha}_{GJR}) = \hat{\sigma}^2 V \Lambda^{-1} V' + K \varphi A^{-1} \alpha \alpha' A^{-1} \varphi' K \quad \dots (6)$$

وقد أوضح [8] Nomura (1988) بأن القيمة المثلى لمعلمة التحيز (K) التي تجعل $MSE(\hat{\alpha}_{GJR})$ اقل ما يمكن هي :

$$\tilde{K}_{i(opt)} = \frac{\hat{\sigma}^2 + \sqrt{\lambda_i \hat{\alpha}_i^2 + \hat{\sigma}^2}}{\hat{\alpha}_i^2}$$

[3] [6] [10]

3- مقدر Generalized Liu Estimator (GL)

تم اقتراح هذا المقدر عام (1995) من قبل Akdeniz & Kaciranlar ، حيث يعتبر الحالة العامة لمقدر Liu (LE) ، حيث ان مقدر LE بشكل عام يتمتع بميزة خاصة و يتغلب بها على مقدر ORR حيث أن مقدر LE دالة خطية بمعلمة التحيز d لذلك يكون من السهل حسابها أكثر من معلمة الحرف k لمقدر ORR ، وان مقدر Liu (LE) موضح في الصيغة الآتية :

$$\hat{\alpha}_{LE} = (\Lambda + I)^{-1}(\Lambda + d)\hat{\alpha}_{ols}$$

ويرمز لمقدر Liu العام بالرمز $\hat{\alpha}_{GL}$ وصيغته كما يلي :-

$$\begin{aligned}\hat{\alpha}_{GL} &= (\Lambda + I)^{-1}(X^{*'}Y + D\hat{\alpha}_{ols}) \\ &= (\Lambda + I)^{-1}(\Lambda\hat{\alpha}_{ols} + D\hat{\alpha}_{ols}) \\ &= (\Lambda + I)^{-1}(\Lambda + D)\hat{\alpha}_{ols}\end{aligned}$$

والتي يمكن إعادة كتابتها كما يلي :

$$= (I - (\Lambda + I)^{-1}(I - D)) \hat{\alpha}_{OLS} \quad \dots (7)$$

$$D = \text{diag} (d_i)$$

حيث أن :

D : تمثل مصفوفة قطرية بمعلمات التحيز d_i .
و كان مقدار التحيز لمقدر GL هو :

$$\text{Bias}(\hat{\alpha}_{GL}) = -(\Lambda + I)^{-1}(I - D)\alpha$$

و التباين لمقدر GL بالشكل الآتي :

$$\text{Var}(\hat{\alpha}_{GL}) = \hat{\sigma}^2 (I - M)\Lambda^{-1}(I - M)'$$

حيث أن :

$$M = (\Lambda + I)^{-1}(I - D)$$

متوسط مربعات الخطأ لمقدر GL بالشكل الآتي :

$$\text{MSE}(\hat{\alpha}_{GL}) = \hat{\sigma}^2 (I - M)\Lambda^{-1}(I - M)' + M\alpha\alpha'M' \quad \dots (8)$$

حيث أن قيمة (D) معلمة التحيز المثلى التي تجعل قيمة $\text{MSE}(\hat{\alpha}_{GL})$ اقل مايمكن هي [3] :

$$D_{1opt} = \text{diag} \left(\frac{\lambda_i(\hat{\alpha}_i^2 - \hat{\sigma}^2)}{(\lambda_i \hat{\alpha}_i^2 + \hat{\sigma}^2)} \right)$$

الجانب التجريبي

المقدمة :

لغرض الحصول على أفضل المقدرات فقد تم استخدام المحاكاة بأسلوب مونت كارلو (Monte Carlo) للمقارنة بين المقدرات المذكورة مسبقاً وذلك من خلال استخدام معيار المقارنة متوسط مربعات الخطأ MSE ، وقد تم توليد البيانات بإحدى لغات البرمجة الإحصائية المتوفرة مجاناً وتقوم بمعالجة البيانات إحصائياً وهي لغة R (Ver.3.0.1) . حيث اختيرت ثلاث أحجام للعينة (n = 15, 60, 300) ، وقد تم استخدام الصيغة الآتية لتوليد

المتغيرات التوضيحية [11] :

$$X_{ij} = (1 - \rho^2)^{1/2} u_{ij} + \rho u_{iP} \quad , i = 1, 2, \dots, n \quad j = 1, 2, \dots, P$$

حيث أن :

u_{ij} : الإعداد العشوائية المولدة والتي تتبع التوزيع الطبيعي القياسي .

u_{ip} : يمثل قيم العمود الأخير من أعمدة المتغيرات المولدة .

P : يمثل عدد المتغيرات المرتبطة ، مع العلم انه $j' < P$.

n : يمثل عدد المشاهدات .

ρ : يمثل قيمة الارتباط بين المتغيرات التوضيحية في النموذج المدروس ، والذي أخذنا القيم

$(\rho = 0.85, 0.99)$.

وللنموذج الآتي :

$$y_i = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \beta_3 x_{i3} + e_i$$

$$e_i \sim N(0, \sigma^2)$$

σ^2 : تباين الأخطاء العشوائية وقد تم استخدام قيم افتراضية عشوائية $(0.8, 0.5)$.

حيث تم تحديد قيم المعامل الافتراضية $P = 4$ هي :

$$\beta = (1, 0, 1) \quad , \quad \beta_0 = 0$$

وقد تم استخدام معيار المقارنة متوسط مربعات الخطأ MSE ، حيث كان عدد مرات تكرار التجربة $R = 1500$.

وقد تم حساب معاملات التحيز (الثوابت) وفق الصيغ التالية :

1. معلمة الحرف (k) :

❖ قدمت هذه الطريقة من قبل الباحثين ^[3] (Troskie & Chalton) عام 1978 م وصيغتها كالتالي :

$$a. \hat{K}_{TC} = \frac{\lambda_i \hat{\sigma}^2}{\lambda_i \hat{\alpha}_i^2 + \hat{\sigma}^2} = k1 \quad \dots \quad (9)$$

❖ وقدم ^[8] (Nomura) معلمة الحرف المثلى عام 1988 م التي تعمل على تقليل متوسط مربعات الخطأ إلى أقل ما يمكن وصيغتها بالشكل :

$$b. \tilde{K}_{i(opt)} = \frac{\hat{\sigma}^2 + \sqrt{\lambda_i \hat{\alpha}_i^2 + \hat{\sigma}^2}}{\hat{\alpha}_i^2} = K2 \quad \dots \quad (10) \quad \text{حيث أن :}$$

$\hat{\alpha}_i$ تمثل مقدر المربعات الصغرى الاعتيادية لـ α

$$\hat{\sigma}^2 = \frac{Y'Y - \hat{\alpha}_{ols} \chi^{*'} Y}{n - P - 1} \quad , \quad i = 1, \dots, P$$

وبإتباع ما جاء به الباحثان Akdeniz & Erol ^[3] يمكن الحصول على قيمة معلمة (Liu) عند تثبيت قيمة معلمة الحرف k_i 's ، حيث أن $0 < k_i < 1$ ،

$i = 1, 2, \dots, p$ وحسب الصيغة الآتية :

$$\tilde{d}_i = \frac{((1 - k_i)\lambda_i)}{(\lambda_i + k_i)} \quad \dots \quad (11)$$

2. معلمة (D) Liu :

$$a. D_{iopt} = \frac{\lambda_i(\hat{\alpha}_i^2 - \hat{\sigma}^2)}{(\lambda_i \hat{\alpha}_i^2 + \hat{\sigma}^2)} = D1 \quad \dots (12)$$

$$b. \tilde{D}_{iopt} = \left(1 - \sqrt{\frac{\hat{\sigma}^2(\lambda_i + 1)^2}{\lambda_i \hat{\alpha}_i^2 + \hat{\sigma}^2}}\right) = D2 \quad \dots (13)$$

كذلك وبعد حساب قيمة معلمة D_i Liu تثبت هذه القيمة ثم نحسب قيمة معلمة الحرف k بدلالتها حيث أن $0 < d_i < 1$ ، $i = 1, 2, \dots, p$ وحسب الأتي :

$$\tilde{K}_i = \frac{(1-d_i)\lambda_i}{(\lambda_i + d_i)} \quad \dots (14)$$

نتائج المحاكاة :

أظهرت نتائج الجدول (1-1) عندما ($p=4$, $n=15$, $\sigma^2=0.5$, $s=2$) وعند معلمتي الحرف $k1, K2$ كما في الصيغتين (9) و(10) على التوالي بان مقدر GL هو الأفضل عند قيمة الارتباط 0.85 حيث يمتلك اقل متوسط مربعات الخطأ MSE ، يليه بالمرتبة الثانية المقدر GJR و جاء المقدر GRR بالمرتبة الثالثة ونجد بان مقدر OLS قد جاء في المرتبة الأخيرة حيث امتلك اكبر MSE إما عند معلمتي Liu كما في الصيغتين (12) و(13) فقد كان في المرتبة الأولى المقدر (GL) مع تبادل المقدران (GRR, GJR) المراتب ، إما عند قيمة الارتباط 0.99 وعند المعلمة $K1$ نجد بان أفضل مقدر هو GJR تليه المقدرات حسب الترتيب (GRR, GL, OLS) إما بالنسبة للمعالم ($D1, D2$) نجد بان أفضل مقدر هو GL يليه المقدر (GRR) ثم المقدر (GJR) وأخيرا مقدر المربعات الصغرى (OLS) في حين وجدنا بان أفضل مقدر عند المعلمة $K2$ هو GRR والمقدرات الأخرى كانت بالترتيب الأتي) (GL, GJR, OLS).

كذلك من ملاحظ نتائج الجدول (2-1) عندما ($p=4$, $n=60$, $\sigma^2=0.5$, $s=2$) وعند معلم التحيز ($K1$) و قيمة الارتباط 0.85 نجد أن أفضل مقدر هو GJR كونه يمتلك اقل متوسط مربعات خطأ مقارنة مع بقية المقدرات يليه المقدر GRR ومن ثم المقدر GL وجاءت مقدرات المربعات الصغرى في المراتب الأخيرة إما عند حالة استعمال معلمة الحرف $K2$ نجد بان مقدر ال GRR قد تقدم على كل من المقدر GL, GJR حيث اخذ المرتبة الأولى و جاء المقدر GL في المرتبة الثانية والمقدر GJR بالمرتبة الثالثة ، إما عند قيمة الارتباط 0.99 ومعلمة الحرف $K1$ ومعلمتي Liu فقد كانت المقدرات بالترتيب الأتي (GL, GRR, GJR, OLS) في حين تقدم المقدر GRR عند المعلمة ($K2$) .

كما لاحظنا من خلال نتائج الجدول (3-1) عندما ($p=4$, $n=300$, $\sigma^2=0.5$, $s=2$) وعند معلمة الحرف $k1$ بان مقدر GRR هو الأفضل عند قيمة الارتباط 0.85 حيث يمتلك اقل متوسط مربعات الخطأ MSE ، يليه بالمرتبة الثانية المقدر GL وجاء المقدر GJR في المرتبة الثالثة ثم يليه المقدر OLS في آخر مرتبة ، في حين كان المقدر GL هو الأفضل عند المعالم ($K2, D1, D2$) ، وكما أظهرت النتائج أن أفضل المقدرات عند قيمة الارتباط 0.99 هو GL .

كما أظهرت نتائج الجدول (4-1) عندما ($p=4$, $n=15$, $\sigma^2=0.8$, $S=2$) وعند معلمة الحرف $k1$ صيغة رقم (9) وقيمة الارتباط 0.85 أن المقدر GL هو الأفضل يليه بالمرتبة الثانية المقدر GJR ثم جاء من بعده المقدر GRR في المرتبة الثالثة يليه المقدر OLS في المرتبة الأخيرة كما جاءت المقدرات بنفس الترتيب عند معلمة ($D1$ Liu) مع تبادل المراتب بالنسبة للمقدين GRR, GJR، إما عند المعلمتين ($K2, D2$) فقد كان المقدر GRR هو الأفضل يليه المقدر GL وفي المرتبة الأخيرة جاء المقدر OLS ، إما عند قيمة الارتباط 0.99 والمعلمة $K1$ تقدم المقدر GJR ومن بعده المقدر GRR ومن ثم GL، في حين تراجع مقدر GJR إلى المرتبة الثالثة وحل محله المقدر GL عند المعالم ($K2, D1, D2$).

كما أظهرت نتائج الجدول (5-1) عند ($p=4, n=60, \sigma^2 = 0.8, S=2$) وعند معلمتي الحرف k1 أن المقدر GJR هو الأفضل يليه بالمرتبة الثانية المقدر GRR ثم المقدر GL وجاء مقدر المربعات الصغرى OLS أخيرا، إما عند المعلمة K2 فقد تقدم المقدر GRR ، وأيضا جاءت المقدرات حسب الترتيب (GL,GRR,GJR,OLS) عند المعلمة D1 ، في حين كانت المقدرات عند المعلمة D2 حسب الترتيب الآتي (GRR,GL,GJR,OLS) ، إما عند استخدام معلمة الحرف K1 وعند قيمة الارتباط 0.99 فقد كان أفضل مقدر هو GRR يليه المقدر GL ومن ثم المقدر GJR ومقدر المربعات الصغرى أخيرا ، بينما كانت المقدرات حسب الترتيب الآتي (GL,GRR,GJR,OLS) وذلك عند معلمة الحرف k2 ومعلمتي Liu .

كما نلاحظ من خلال نتائج الجدول (6-1) وعندما ($p=4, n=300, \sigma^2 = 0.8, S=2$) وعند معلمة الحرف k1 ومعلمتي (Liu) D1 و D2 أن المقدر GL هو الأفضل حيث يمتلك أقل متوسط مربعات خطأ مقارنة مع بقية المقدرات المتحيزة يليه بالمرتبة الثانية المقدر GRR وجاءت المقدرات الأخرى (GJR, OLS) على التوالي وذلك عند ما تكن قيم الارتباط هي (0.85,0.99).

جدول رقم (1) يبين قيم متوسط مربعات الخطأ لأنموذج الانحدار الخطي العام عند استعمال بعض مقدرات انحدار الحرف العام عند معلمتي الحرف k1 و k2 ومعلمتي (Liu) D1 و D2 في حالة ($s=2, \sigma^2 = 0.5, n=15, p=4$) وعندما تكون قيمة الارتباط (0.85,0.99).

المقدرات المعلمت	OLS	GRR				GJR				GL				
		K1	K2	D1	D2	K1	K2	D1	D2	K1	K2	D1	D2	
$\rho = 0.85$	$\hat{\alpha}_1$	7.06 5e-01	0.0 50	0.5 46	0.4 78	0.3 21	- 0.0 23	0.4 70	0.34 5	0.12 6	0.06 5	0.5 45	0.48 2	0.3 2
	$\hat{\alpha}_2$	- 8.70 1e-02	1.7 55	1.5 71	1.5 59	1.2 37	1.6 57	1.4 82	1.45 8	0.85 9	1.76 1	1.5 83	1.57 5	1.2 4
	$\hat{\alpha}_3$	6.66 1e-01	0.6 96	0.5 51	0.3 18	0.1 79	0.5 37	0.3 22	0.07 5	0.01 4	0.73 8	0.5 17	0.30 1	0.1 69
MSE	0.05 31	0.0 19	0.0 21	0.0 17	0.0 36	0.0 14	0.0 14	0.02 7	0.05 2	0.01 1	0.0 14	0.01 72	0.0 36	
$\rho = 0.99$	$\hat{\alpha}_1$	9.61 3e-01	- 0.3 08	- 0.8 36	- 0.8 82	- 0.6 75	- 0.4 15	- 0.9 14	- 0.78 8	- 0.41 4	- 0.39 4	- 0.9 09	- 0.88 9	- 0.6 76
	$\hat{\alpha}_2$	- 2.76 1e-01	1.6 16	1.1 42	1.2 07	0.9 11	1.7 21	1.2 53	1.06 9	0.55 4	1.71 2	1.2 47	1.21 6	0.9 1
	$\hat{\alpha}_3$	6.39 8e-01	0.0 93	0.2 21	0.2 78	0.1 39	0.2 37	1.2 10	0.01 35	0.00 20	0.18 2	0.7 37	0.45 2	0.2 36
MSE	0.05 28	0.0 11	0.0 20	0.0 16	0.0 36	0.0 11	0.0 22	0.02 5	0.05 1	0.01 89	0.0 23	0.01 53	0.0 35	

جدول رقم (2-1) يبين قيم متوسط مربعات الخطأ لأنموذج الانحدار الخطي العام عند استعمال بعض مقدرات انحدار الحرف العام عند معلمتي الحرف k1 و k2 ومعلمتي (Liu) D1 و D2 في حالة ($s=2, \sigma^2 = 0.5, n = 60, p=4$) وعندما تكون قيمة الارتباط (0.85,0.99).

المقدرات المعلمت	OLS	GRR				GJR				GL			
		K1	K2	D1	D2	K1	K2	D1	D2	K1	K2	D1	D2

$\rho = 0.85$	$\hat{\alpha}_1$	7.690e-01	1.166	1.113	1.115	0.9847	1.174	1.103	1.094	0.841	1.154	1.104	1.109	0.98
	$\hat{\alpha}_2$	3.843e-02	0.819	1.025	0.993	0.832	0.804	0.991	0.9569	0.652	0.759	1.009	1.008	0.847
	$\hat{\alpha}_3$	5.832e-01	1.246	1.156	1.048	0.784	1.283	1.093	0.923	0.47	1.181	1.133	1.068	0.803
MSE		0.009874095	0.0019	0.0017	0.002	0.0043	0.0018	0.0021	0.0025	0.0006	0.0023	0.0001	0.0002	0.0004
$\rho = 0.99$	$\hat{\alpha}_1$	9.391e-01	1.156	1.110	1.107	0.984	1.139	1.096	1.089	0.849	1.157	1.108	1.108	0.987
	$\hat{\alpha}_2$	2.158e-01	0.866	1.029	1.012	0.853	0.844	1.013	0.979	0.673	0.884	1.033	1.017	0.857
	$\hat{\alpha}_3$	5.812e-01	1.897	2.169	1.291	0.765	1.321	1.269	0.353	0.084	1.822	1.454	0.866	0.507
MSE		0.009859014	0.0019	0.0017	0.00198	0.0004	0.0022	0.0002	0.0023	0.0006	0.0018	0.0018	0.0019	0.0003

جدول رقم (3) يبين قيم متوسط مربعات الخطأ لأنموذج الانحدار الخطي العام عند استعمال بعض مقدرات انحدار الحرف العام عند معلمتي الحرف k_1 و k_2 ومعلمتي D_1 و D_2 في حالة

المقدرات المعلمت	OLS	GRR				GJR				GL				
		K1	K2	D1	D2	K1	K2	D1	D2	K1	K2	D1	D2	
$\rho = 0.85$	$\hat{\alpha}_1$	6.497e-01	-1.020	-1.035	1.0358	-0.973	-1.0178	-1.033	1.030	0.908	1.017	1.046	1.045	0.983
	$\hat{\alpha}_2$	4.202e-02	1.190	1.174	1.1758	1.094	1.1879	1.1707	1.165	1.005	1.187	1.190	1.1877	1.106
	$\hat{\alpha}_3$	6.565e-01	0.9636	0.971	0.943	0.801	0.931	0.959	0.913	0.636	0.993	0.9849	0.961	0.815
MSE		0.00189	0.000419	0.00041	0.00042	0.00062	0.00043	0.00042	0.00044	0.0008	0.00042	0.00038	0.00039	0.0005
$\rho = 0.99$	$\hat{\alpha}_1$	5.483e-01	1.0239	1.043	1.042	0.984	1.021	1.039	1.038	0.922	1.022	1.042	1.042	0.988
	$\hat{\alpha}_2$	1.312e-01	1.195	1.161	1.158	1.079	1.1958	1.169	1.1642	1.004	1.2003	1.177	1.169	1.088
	$\hat{\alpha}_3$	6.289e-01	0.7425	0.9615	1.1255	0.8214	0.2562	0.5324	0.0890	0.019	0.4382	0.5676	0.2788	0.159
MSE		0.0018	0.00039	0.000398	0.00040	0.00058	0.000397	0.000392	0.00040	0.0007	0.00038	0.00038	0.00039	0.0005

(0.85,0.99) وعندما تكون قيمة الارتباط $(s=2, \sigma^2=0.5, n=300, p=4)$.

المقدرات المعلميات	OL S	GRR				GJR				GL				
		K1	K2	D1	D2	K1	K2	D1	D2	K1	K2	D1	D2	
$\rho = 0.85$	$\hat{\alpha}_1$	7.03 3e-01	1.74 121	0.46 913 93	0.39 092 08	0.25 275 25	0.00 0951 5888	0.38 944 31	0.25 260 87	0.08 130 339	0.42 135 81	0.4 753 676	0.3 984 699	0.25 8
	$\hat{\alpha}_2$	- 1.41 5e-01	0.48 776 614 3	1.48 322 64	1.46 387 93	1.13 735 30	1.61 1426 4863	1.36 797 71	1.33 004 22	0.74 173 469	1.72 141 58	1.4 797	1.4 558 553	1.13 7
	$\hat{\alpha}_3$	6.13 8e-01	0.64 285 04	0.56 373 72	0.34 736 80	0.19 826 63	0.43 5625 453	0.38 442 96	0.10 873 64	0.02 262 699	0.63 270 11	0.5 929 216	0.3 670 467	0.20 705 20
MSE	0.05 839 898	0.02 665 001	0.02 492 268	0.02 889 922	0.04 631 154	0.02 4746 59	0.03 258 885	0.02 892 3	0.05 758 686	0.01 763 491	0.0 249	0.0 288 696	0.04 632 008	
$\rho = 0.99$	$\hat{\alpha}_1$	1.08 9e+00	- 0.29 087	- 0.82 29	- 0.78 88	-0.5 88	-0.28 8467 5	- 0.74 56	- 0.68 2	-0.3 31	- 0.19 0	- 0.8 2 72	0.7 9 42	- 0.58 7
	$\hat{\alpha}_2$	- 4.58 5e-01	1.70 29	1.18 35	1.14 35	0.84 76	1.72 1454 4	1.07 593 80	0.99 102 931	0.48 778 659 3	1.61 564 845	1.2 034 882	1.1 590 997	0.86 068 30
	$\hat{\alpha}_3$	6.05 3e-01	0.10 37	1.08 60	0.46 83	0.24 9	0.11 87	0.42 3	0.04 11	0.00 6	0.04 60	1.4 127	0.6 122	0.32 5
MSE	0.05 776	0.01 67	0.02 37	0.02 70	0.04 58	0.01 53	0.03 12	0.03 71	0.05 6	0.02 27	0.0 226	0.0 261	0.04 5	

جدول رقم (4) يبين قيم متوسط مربعات الخطأ لأنموذج الانحدار الخطي العام عند استعمال بعض مقدرات انحدار الحرف العام عند معلمتي الحرف k1 و k2 ومعلمتي (Liu) D1 و D2 في حالة

($s=2, \sigma^2 = 0.8, n=15, p=4$) وعندما تكون قيمة الارتباط (0.85,0.99).

جدول رقم (5) يبين قيم متوسط مربعات الخطأ لأنموذج الانحدار الخطي العام عند استعمال بعض مقدرات انحدار الحرف العام عند معلمتي الحرف k1 و k2 ومعلمتي (Liu) D1 و D2 في حالة

($s=2, \sigma^2 = 0.8, n=60, p=4$) وعندما تكون قيمة الارتباط (0.85,0.99).

المقدرات المعلميات	OL S	GRR				GJR				GL				
		K1	K2	D1	D2	K1	K2	D1	D2	K1	K2	D1	D2	
$\rho = 0.85$	$\hat{\alpha}_1$	7.59 6e-01	1.09 6	1.06 0	1.0 60	0.92 7	1.09 16	1.06 70	1.03 32	0.77 3	1.07 34	1.04 54	1.0 53 3	0. 92 1
	$\hat{\alpha}_2$	- 5.90 5e-02	0.73 1	0.87 2	0.8 38	0.68 3	0.72 3	0.86 3	0.80 2	0.50 5	0.67 2	0.85 12	0.8 48 9	0. 68 8
	$\hat{\alpha}_3$	5.13 2e-01	1.40 676 06	1.14 325 41	1.0 585 17	0.78 859 25	1.36 862 09	1.15 226 52	0.91 343 63	0.45 380 75	1.26 808 79	1.09 579 53	1.0 48 77	0. 78 4

MSE	0.0109	0.0039	0.0036	0.0042	0.0063	0.0038	0.0037	0.0048	0.0088	0.0043	0.0042	0.0042	0.0064
$\rho = 0.99$	$\hat{\alpha}_1$	1.031e+00	-1.0947	-1.068	-1.071	-0.934	1.0683	-1.04678	-1.038	-0.790	-1.061	-1.064	-1.0936
	$\hat{\alpha}_2$	-3.314e-01	0.8174915	0.9054	0.8654	0.7051	0.7589	0.8684	0.82083	0.5217	0.8045	0.8894	0.8819
	$\hat{\alpha}_3$	5.101e-01	2.0074	2.1964	1.1254	0.6871	1.8884	1.5375	0.5435	0.141	2.410	1.732	1.429
MSE	0.0109024	0.003	0.0036	0.004	0.00605	0.00416	0.0041	0.0045	0.00822	0.0036	0.0032	0.0039	0.0059

جدول رقم (6) يبين قيم متوسط مربعات الخطأ لأنموذج الانحدار الخطي العام عند استعمال بعض مقدرات انحدار الحرف العام عند معلمتي الحرف k_1 و k_2 ومعلمتي (Liu) D_1 و D_2 في حالة $(s=2, \sigma^2 = 0.8, n=300, p=4)$ وعندما تكون قيمة الارتباط $(0.85, 0.99)$.

المقدرات المعلمتات	OLS	GRR				GJR				GL				
		K1	K2	D1	D2	K1	K2	D1	D2	K1	K2	D1	D2	
$\rho = 0.85$	$\hat{\alpha}_1$	5.675e-01	-0.9442	0.9547	0.9547	-0.875	0.9412	-0.941	-0.977	-0.808	0.9488	-0.945	-0.962	-0.887
	$\hat{\alpha}_2$	6.405e-02	1.1028	1.0704	1.0549	0.9750	1.0923	1.057	1.050	0.882	1.106	1.062	1.066	0.981
	$\hat{\alpha}_3$	5.913e-01	0.8219	0.81828	0.7732	0.631	0.786	0.798	0.733	0.464	0.8175	0.8109	0.78510	0.6403
MSE	0.0021	0.00086	0.00093	0.00097	0.0001	0.0008	0.00096	0.00099	0.00013	0.00085	0.00095	0.00094	0.0001	
$\rho = 0.99$	$\hat{\alpha}_1$	4.243e-01	-0.9556	0.9629	0.9552	-0.895	0.9499	-0.9539	-0.951	-0.820	0.9627	-0.9552	-0.9614	-0.9001
	$\hat{\alpha}_2$	2.007e-01	1.1043	1.0804	1.0569	0.9768	1.0991	1.05747	1.05003	0.882	0.4219	1.0649	1.0766	0.990
	$\hat{\alpha}_3$	5.680e-01	0.248	0.623	0.0597	0.029	0.120	0.215	0.0036	0.0005	1.114	0.278	1.0522	0.232
MSE	0.00213	0.0008	0.00086	0.00089	0.0001	0.00082	0.0008	0.0009	0.00012	0.0007	0.00088	0.0008	0.00010	

الاستنتاجات :

- 1- أظهرت نتائج المحاكاة إن أفضل مقدر هو GL حيث يمتلك اقل متوسط مربعات خطأ MSE مقارنة مع مقدر المربعات الصغرى وبقيّة المقدرات المتحيزة وفي بعض حالات معلمة الحرف K1 وفي حالة معلمة الحرف K2 وأيضاً في حالة معلمة D1 Liu و المعلمة D2 .
- 2- أظهرت النتائج أن جميع نماذج انحدار الحرف لها متوسط مربعات خطأ اقل من المربعات الصغرى الاعتيادية OLS ، وبالتالي فإنها أفضل من OLS في حالة وجود مشكلة تعدد العلاقة الخطية بين المتغيرات التوضيحية .
- 3- كما تبين من نتائج المحاكاة أن زيادة في تباين الخطأ العشوائي تؤدي إلى زيادة في قيمة متوسط مربعات الخطأ لجميع المقدرات .
- 4- كذلك أظهرت النتائج بزيادة قيمة الارتباط فأن المقدرات تصبح أفضل من مقدر المربعات الصغرى OLS وذلك من خلال ملاحظة نتائج معيار المقارنة MSE حيث يقل بزيادة الارتباط .
- 5- كما تبين من نتائج المحاكاة ان قيم متوسط مربعات الخطأ لتقدير معلمات الأنموذج الخطي العام تتناقص بزيادة حجم العينة ولكافة المقدرات المدروسة .

المصادر العربية

1. كاظم ، أموري هادي و مسلم ، باسم شلبية (2002) ، " القياس الاقتصادي المتقدم النظرية والتطبيق" ، مكتبة دنيا الامل ، بغداد.
2. المشهداني، أيمن محمد عبد الله (1994)، "استخدام المركبات الرئيسية في تشخيص ومعالجة مشكلة التعدد الخطي مع تطبيق عملي لبعض الظواهر الاقتصادية"، رسالة ماجستير، كلية الإدارة والاقتصاد، جامعة بغداد.

المصادر الأجنبية

3. Akdeniz, F., Erol, H. (2003). "Mean squared error matrix comparisons of some biased estimators in linear regression". *Commun. Statist. Theor. Meth.* 32:2389–2413.
4. Arthur E. Hoerl , Robert W. Kennard (1970-a) ,"Ridge Regression Biased Estimation for Nonorthogonal Problems" ; *Technometrics* Vol.12 , No.1 , pp.55-60.
5. Arthur E. Hoerl , Robert W. Kennard (1970-b) , "Ridge Regression Applications to Nonorthogonal Problem" ; *Technometrics* , Vol.12 , No.1 , pp.69-82 .
6. Alheety, M. I. and B. M. G. Kibria (2009)." On the Liu and almost unbiased Liu estimators in the presence of multicollinearity with heteroscedastic or correlated errors". *Surveys in Mathematics and its Applications*, 4, 155-167.
7. B. M. G. Kibria. (2003)," Performance of some new ridge regression estimators", *Communications in Statistics-Simulation and Computation*, 32 ,419-435.
8. Feras. SH. Batah, T. V. Ramanathan and S. D. Gore. (2008) ," The Efficiency of Modified Jackknife and Ridge Type Regression Estimators": A comparison, *Surveys in Mathematics and its Applications* 24 No.2 .
9. Feras. SH. Batah . (2011)," A New Estimator By Generalized Modified Jackknife Ridge Regression Estimator". *Journal of Basrah Researches ((Sciences))* Volume 37. Number 4. C.
10. Liu, Kejian (1993)." A new class of biased estimate in linear regression". *Communications in Statistics–Theory and Methods* 22, 393–402.
11. Mansson .K , Shuku.G and Kibria, B. M. G. (2010)." On some ridge regression estimators : A Monte Carlo Simulation Study Under Different Error

- Variances". *Communications in Statistics-Simulation and Computation* 17. pp. 1-22.
12. M. El-Dereny , N. I. Rashwan.(2011)." Solving Multicollinearity Problem Using Ridge Regression Models" , *Int. J. Contemp. Math. Sciences*, 12, 585 – 600.
13. Singh, B., Chaubey, Y. P,& Dwivedi, T. D. (1986)," An almost unbiased ridge estimator". *Sankhya: The Indian Journal of Statistics* vol .48,pp 342– 346.
<http://www.jstor.org/page/info/about/policies/terms.jsp> .
14. S. Sakallı̇glu, S. Kaçiranlar. (2008)," A new biased estimator based on ridge estimation", *Statist. Papers* 49 .669–689.
15. Mason , R.L , Gunst , R.F. & Webster , J.T. (1977), " Biased Estimation in Regression: An Evaluation Using Mean Squared Error" *Journal of the American Statistical Association*, Vol. 72, pp. 616-628.