

مقارنة الطريقة المقترحة (AUGJRR) مع الطرائق المتحيزة

لتقدير انحدار الحرف العامة بوجود التعدد الخطي*

أ.م.د سجي محمد حسين

sajamh@yahoo.com

جامعة بغداد - كلية الادارة والاقتصاد - قسم الإحصاء

حنين مراد يوسف

haneen_m31@yahoo.com

جامعة بغداد - كلية الادارة والاقتصاد - قسم الإحصاء

المستخلص:

ان تقدير معاملات الاالنموذج الخطي العام الذي يعاني من خرق في احدى فروضه وهو تعدد العلاقة الخطية (Multicollinearity) بين المتغيرات التوضيحية شبه التام يكون باستعمال طرائق تقدير انحدار الحرف العام والذي ستركز عليه اهتمامنا في هذا البحث مثل:

- Generalized Ridge Regression Estimator (GRRE).
- Modified Jackknife Ridge Regression (MJRRE).
- Generalized Jackknife Ridge Regression (GJRRE).
- Generalized Liu Estimator (GLE).
- Almost unbiased Generalized Liu (AUGLE).
- Generalized Ridge Regression Almost unbiased (AUGRRE).

بالاضافة الى الطريقة المقترحة:

- Almost unbiased Generalized Jackknife Ridge (AUGJRRE)

* بحث مستل من رسالة ماجستير [1]

حيث تم في هذا البحث اشتقاق طريقة (AUGJRR) لتقدير معاملات الانحدار الخطي الذي يعاني من مشكلة التعدد الخطي وتمت مقارنة الطريقة المقترحة مع الطرائق المذكورة اعلاه بالاضافة الى طريقة (OLS). وكانت النتيجة بان أفضل المقدرات هما المقدر (AUGLE) والمقدر المقترح (AUGJRRE) والمقدر (AUGRRE) حيث يمتلكون اقل متوسط مربعات خطأ (MSE) مقارنة مع مقدر المربعات الصغرى وبقيّة المقدرات المتحيزة الأخرى.

الكلمات الرئيسية: التعدد الخطي، مقدر انحدار الحرف العام (GRRE)، مقدر جاكنايف لانحدار الحرف العام (GJRRE)، مقدر جاكنايف لانحدار الحرف المعدل (MJRRE)، مقدر ليو العام (GLE)، مقدر ليو العام الغير متحيز على الاغلب (AUGLE) ومقدر انحدار الحرف العام الغير متحيز على الاغلب (AUGRRE)، مقدر جاكنايف لانحدار الحرف العام الغير متحيز على الاغلب (AUGJRRE).

1. المقدمة وهدف البحث

ان استعمال وتفسير انموذج الانحدار الخطي العام يعتمد على تقديرات معاملات الانموذج التالي:

$$\underline{Y} = X\underline{\beta} + \underline{U} \quad (1)$$

حيث ان :

\underline{Y} : متجه لملاحظات المتغير المعتمد ذو بعد $(n \times 1)$.

X : مصفوفة مشاهدات المتغيرات التوضيحية ذو رتبة $(n \times p)$.

$\underline{\beta}$: متجه المعلمات المطلوب تقديرها ذو بعد $(p \times 1)$

\underline{U} : متجه الاخطاء العشوائية ذو بعد $(n \times 1)$ حيث ان $\underline{U} \sim (0, \sigma^2 I_n)$

وكما هو معروف ان ظهور مشكلة التعدد الخطي (Multicollinearity) في مصفوفة البيانات وهي المشكلة التي تشير الى الحالة التي يرتبط فيها متغيرين او اكثر من المتغيرات التوضيحية في انموذج الانحدار العام بعلاقة خطية قوية اذ ان ظهورها له تاثير معنوي على نوعية واستقرار تلك المقدرات حيث تكون التقديرات غير دقيقة وذلك لتضخم التباين للمعلمات المقدرّة نتيجة ضالة قيمة محدد مصفوفة المعلومات $X'X$ لذا فان مقدر المربعات الصغرى الاعتيادية (OLS) يصبح تقدير غير

مستقر في حالة وجود هذه المشكلة. هناك عدة طرائق للكشف عن مشكلة التعدد الخطي ومنها طريقة فراير- كلوبر (Farrar-Gloubet)، مقياس العدد الشرطي ودليل الحالة (Condition number & Condition index) واختبار كلاين (Klein) وغيرها.

ظهرت طرائق عديدة لمعالجة مشكلة التعدد الخطي حسب نوع التعدد الخطي حيث يوجد نوعين اما تعدد خطي تام او تعدد خطي شبه تام، حيث تستعمل طريقة المركبات الرئيسية (principle component) او طريقة المربعات الصغرى الجزئية (Partial least squares) في حالة التعدد الخطي التام وتستعمل طريقة انحدار الحرف (Ridge regression) في حالة التعدد الخطي شبه التام والتي تركز عليها بحثنا، الكثير من الباحثين افترضوا مقدرات مختلفة للتعامل مع هذه المشكلة. بالرغم من ان هذه المقدرات اكثر استقرارا من مقدر الـ (OLS) الا انها مقدرات متحيزة. ومن هذه المقدرات مقدر انحدار الحرف العام (GRRE)، مقدر جاكنايف لانحدار الحرف العام (GJRRE)، مقدر جاكنايف لانحدار الحرف المعدل (MJRRE)، مقدر ليو العام (GLE)، مقدر ليو العام الغير متحيز على الاغلب (AUGLE) ومقدر انحدار الحرف العام الغير متحيز على الاغلب (AUGRRE).

اما الهدف من هذا البحث فهو اشتقاق طريقة تقدير مقترحة وهي Almost unbiased Generalized Jackknife Ridge (AUGJRRE) لتقدير معالمات نموذج الانحدار الخطي العام الذي يعاني من مشكلة التعدد الخطي ومن ثم مقارنة الطريقة المقترحة (AUGJRRE) مع طرائق التقدير الاخرى مثل (GRRE)، (MJRRE)، (GJRRE)، (GLE)، (AUGLE) و (AUGRRE) بالاضافة الى طريقة (OLS) عن طريق معيار المقارنة MSE من خلال تجربة محاكاة.

لقد اهتم الكثير من الباحثين في هذا الموضوع لذا ظهرت الكثير من الدراسات حيث ان اول من قام بدراسة هذه المشكلة عام 1934م العالم الإحصائي النرويجي (Ragner Frisch) [4]، من خلال تحليله لظاهرة السلاسل الزمنية إذ أوضح وجود عدد كبير جداً من المتغيرات التوضيحية مما ينتج بالضرورة ظهور مشكلة التعدد الخطي. وفي عام 1969م أوضح (Silvey) [18] أنه في حالة وجود علاقة (قوية) خطية تامة بين المتغيرات التوضيحية فإن الارتباط الخطي يكون تام وفي حالة كون العلاقة الخطية تقريبية بين المتغيرات فإن الارتباط الخطي يكون شبه تام. وقد قدم كل من (Hoerl & Kennard) في عام 1970م [9] طريقة لمعالجة مشكلة تعدد العلاقة الخطية شبه التامة بين المتغيرات التوضيحية وهي طريقة انحدار الحرف (Ridge Regression). وفي عام 1991م قام الباحث (Liu Kejian) [16] باقتراح مقدر يعتمد على دمج مزاي طريقتين وهما مقدر الحرف الاعتيادي (ORR) ومقدر (Stein) ويدعى بمقدر Liu. وكما قام كل من (Akdeniz & Kaciranlar) [6] في عام 1995م بتعديل على مقدر (Liu) العام (GL). وفي عام 2005م قامت الباحثة

النعي، أسوان محمد [2] بدراسة حول الكشف عن وجود مشكلة التعدد الخطي باستعمال مقياس عامل تضخيم التباين (VIF) و مقياس العدد الشرطي (C.N) وعولجت هذه المشكلة بطريقة انحدار الحرف الاعتيادي (ORR) وقد استعملت عدة طرائق لتعيين قيمة الثابت k المحصورة بين (0,1). كما قام الباحث (Feras) [12] في عام 2008م باقتراح مقدر جديد (MJRR)، ويعمل على تعديل مقدر (GRR) على نفس خطى (JRR) حيث يمتلك هذا المقدر اقل MSE من المقدرات المتحيزة الأخرى (GRR, JRR). وفي عام 2009م قام كل من جواد، نزار مصطفى وكمال، غفران إسماعيل [3]، بعمل مقارنة بين طرائق تقدير معاملات أنموذج الانحدار في حال ظهور مشكلة تعدد العلاقة الخطية ووجود القيم الشاذة ومنها الاعتيادية والحصينة مثل طريقة المربعات الصغرى المقيدة (LSE) وطريقة انحدار الحرف الاعتيادية (RR) وطريقة القيمة المطلقة الصغرى (RLAV) وطريقة الحرف الموزون (WRID) ومقدر انحدار الحرف الحصين المعتمد على مقدر (MM) الحصين والذي يرمز له بـ (RMM)، وأوضحوا أن طريقة (RMM) هي أفضل من الطرائق الأخرى وباستخدام المحاكاة. كما قام الباحثان (El-Dereny, Rashwan) [11] عام 2011م باستعمال عدة طرائق لانحدار الحرف لمعالجة مشكلة التعدد الخطي شبه التام منها طريقة (ORR) وطريقة (GRR) وطريقة انحدار الحرف المباشر (DRR). في عام 2012م قام الباحث (Abdalla) [5] باقتراح طريقة جديدة لاكتشاف الأزواج الخطي (التعدد الخطي) في نماذج الانحدار الخطي المتعدد وهي طريقة مجموع مربعات الانحدار، ومن ثم تتم معالجتها دون حذف أي من المتغيرات التوضيحية وذلك بطريقة انحدار الحرف الاعتيادي.

2. طرائق التقدير

هناك عدة طرائق لتقدير ومعالجة معاملات أنموذج الانحدار الخطي العام في حالة وجود مشكلة تعدد العلاقة الخطية شبه التامة بين المتغيرات التوضيحية، ومن هذه الطرائق أو المقدرات:

2.1 مقدر انحدار الحرف العام

(Generalized Ridge Regression Estimator) (GRR)

تم اقتراح هذا المقدر من قبل (Horal & Kennard) عام 1970م [10] حيث يعمل على تقليل التباين بالإضافة إلى تقليل التحيز لمقدر انحدار الحرف الاعتيادي ORR، وتتمثل بإضافة قيم مختلفة إلى عناصر القطر الرئيسي للمصفوفة المعلومات (X'X)، وتعتبر هذه المقدرات الحالة العامة لمقدرات الحرف الاعتيادية (ORR). لقد

افترض في هذا المقدر وجود مصفوفة P مصفوفة ذات درجة $(p \times p)$ وأعمدها تمثل المتجهات المميزة $(v_1, v_2, v_3, \dots, v_p)$ لمصفوفة $(X'X)$ ، أن $P'P = I$ ومن هنا فأن [11]:

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

P : تمثل مصفوفة متعامدة، أعمدها تمثل المتجهات المميزة المقابلة للجذور المميزة لمصفوفة المعلومات $(X'X)$. حيث ان:

$$P'P = PP' = I$$

الجذور المميزة لمصفوفة المعلومات $(X'X)$ ، $\lambda_i, i = 1, 2, \dots, p$ ،
 إذ بإمكاننا إعادة كتابة الأنموذج الخطي العام (1) بالشكل:

$$\underline{Y} = X^* \underline{\alpha} + \underline{\varepsilon} \quad (2)$$

$$\chi^* = XP \quad , \quad \underline{\alpha} = P' \underline{\beta} \quad \text{إذ أن:}$$

هذا الأنموذج يدعى بالأنموذج القانوني (Canonical Linear Model) أو نموذج المركبات غير مرتبطة (Uncorrelated components model)، وأن مقدرات الحرف الاعتيادية (ORR) α تعطى بالشكل:

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

إما مقدر انحدار الحرف العام (Generalized Ridge Regression Estimator) (GRR) α فيعطى بالصيغة الآتية:

$$\hat{\alpha}_{GRR} = (\chi^* \chi^{*'} + K)^{-1} \chi^{*'} y \\ = (I - KA^{-1}) \hat{\alpha}_{OLS} \quad (3)$$

حيث ان:

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

$$\hat{\alpha}_{ols} = (\chi^* \chi^{*'})^{-1} \chi^{*'} y \\ = \Lambda^{-1} \chi^{*'} y \quad (4)$$

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

$$\hat{\beta}_{GRR} = P \hat{\alpha}_{GRR}$$

إذ إن :

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 (Generalized Ridge Regression). وفي حالة كون K متساوية فأن مقدر الحرف العام (GRR) تتحول إلى مقدر (ORR).

$\hat{\sigma}^2$: مقدر المربعات الصغرى الاعتيادية لـ σ^2 .

$$\hat{\sigma}^2 = \frac{Y'Y - \hat{\alpha}'_{OLS} X'^* Y}{n - m - 1} \quad (5)$$

m: عدد المتغيرات التوضيحية

ومصفوفة متوسط مربعات الخطأ لمقدرات انحدار الحرف العام (GRR) بالشكل الآتي:

$$MSE(\hat{\alpha}_{GRR}) = Var(\hat{\alpha}_{GRR}) + (Bias(\hat{\alpha}_{GRR}))^2$$

$$MSE(\hat{\alpha}_{GRR}) = \hat{\sigma}^2 (C_K \Lambda^{-1} C'_K) + (C_K - I)\alpha\alpha'(C_K - I)' \quad (6)$$

$$C_k = (I + KA^{-1}) \quad \text{حيث ان}$$

$$MSE(\hat{\alpha}_{GRR}) = \hat{\sigma}^2 \sum_{i=1}^{\rho} \frac{\lambda_i}{(\lambda_i + K_i)^2} + \sum_{i=1}^{\rho} \frac{K_i^2 \alpha_i^2}{(\lambda_i + K_i)^2} \quad (7)$$

وقد أثبت كلا من (viond & ullah) [7] عام 1981م بأن:

$$MES((\hat{\alpha}_{GRR})) \leq MES((\hat{\alpha}_{OLS}))$$

2.2 مقدر (MJRR)

Modified Jackknife Ridge Regression

لتقليل التحيز في مقدر انحدار الحرف (Ridge Regression Estimator) تم اقتراح مقدر Jackknife Ridge Regression (JRR) من قبل Singh 1986 وآخرون [19] للنموذج (2) والذي يساوي:

$$\hat{\alpha}_{JRR} = (I + KA^{-1})\hat{\alpha}_{GRR}$$

$$=(I - K^2 A^{-2}) \hat{\alpha}_{OLS} \quad (8)$$

كما أوضحوا إن مقدر جاكنيف (JRR) له تباين أقل من تباين مقدر GRR، و في عام (2008) تم اقتراح مقدر جديد من قبل [12] (Batah et al)، حيث تقوم فكرته على تعديل (تطوير) مقدر الحرف العام (GRR) على نفس خطى مقدر الـ (JRR) المقترح من قبل (Singh) وآخرون عام 1986 م و يدعى هذا المقدر بـ (MJRR) (Modified Jackknife Ridge Regression) ويرمز له بالرمز $\hat{\alpha}_{MJ(K)}$ وصيغته كالآتي :

$$\begin{aligned} \hat{\alpha}_{MJ(K)} &= (I - K^2 A^{-2}) \hat{\alpha}_{GRR} \\ &= (I - K^2 A^{-2})(I - KA^{-1}) \hat{\alpha}_{OLS} \end{aligned} \quad (9)$$

$$\begin{aligned} \hat{\beta}_{MJ(K)} &= P \hat{\alpha}_{MJ(K)} \\ &= P(I - K^2 A^{-2})(I - KA^{-1}) \hat{\alpha}_{OLS} \end{aligned} \quad (10)$$

و أن: مصفوفة متوسط مربعات الخطأ للمقدر (MJRR) بالشكل الآتي :

$$\begin{aligned} \text{MSE}(\hat{\alpha}_{MJ(K)}) &= \text{Var}(\hat{\alpha}_{MJ(K)}) + \left(\text{Bias}(\hat{\alpha}_{MJ(K)})\right)^2 \\ &= \hat{\sigma}^2 W \Lambda^{-1} W' + K \phi A^{-1} \alpha \alpha' A^{-1} \phi' K \end{aligned} \quad (11)$$

$$\phi = (I + KA^{-1} - KA^{-2}K)$$

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

2.3 مقدر (GJRR)

(Generalized Jackknife Ridge Regression)

تم اقتراح هذا المقدر في عام 2011 م من قبل [14] (Batah)، وهو مقدر متحيز حيث تعتمد فكرته أيضا على دمج فكرة مقدر (Generalized Ridge Regression) (GRR) ومقدر (Jackknife Ridge Regression) (JRR)، ويعتبر الحالة العامة لمقدر (MJRR)، ويرمز له بالرمز $\hat{\alpha}_{GJRR}$ ويعرف للنموذج (2) بالشكل:

$$\hat{\alpha}_{GJR} = (I - K^2 A^{-2})(I - KA^{-1})^S \hat{\alpha}_{OLS}, S \geq 0 \quad (12)$$

$$\begin{aligned}\hat{\beta}_{GJR} &= P\hat{\alpha}_{GJR} \\ &= P(I - K^2A^{-2})(I - KA^{-1})^S \hat{\alpha}_{OLS}\end{aligned}\quad (13)$$

حيث أن $S \geq 0$ ، وانه في حالة $S = 0$ فإن مقدر (GJRR) يتحول إلى مقدر (JRR)، وكذلك عندما $S = 1$ فإن مقدر (GJRR) يتحول إلى مقدر (MJRR)، وأن مصفوفة متوسط مربعات الخطأ للمقدر (GJRR) هو بالشكل الآتي:

$$\begin{aligned}MSE(\hat{\alpha}_{GJR}) &= (\hat{\alpha}_{GJR}) + Var(Bias(\hat{\alpha}_{GJR}))^2 \\ &= \hat{\sigma}^2V \Lambda^{-1}V' + K\varphi A^{-1}\alpha\alpha' A^{-1}\varphi'K\end{aligned}\quad (14)$$

$$\begin{aligned}\varphi &= (KA^{-1})^{-1}[I - (I - KA^{-1})^S] + (KA^{-1})(I - KA^{-1})^S \\ V &= (I - K^2A^{-2})(I - KA^{-1})^S\end{aligned}$$

2.4 مقدر (GLE)

(Generalized Liu Estimator)

اقترح الباحثان (Akdeniz & Kaciranlar) [6] في عام 1995 م مقدر جديد يدعى (GL) ويعتبر الحالة العامة لمقدر (LE)، وهناك ميزة خاصة لمقدر (LE) يتغلب بها على مقدر (ORR) حيث أن دالة خطية بمعلمة التحيز d لذلك يكون من السهل حسابها أكثر من معلمة الحرف k لمقدر (ORR)، وأيضاً مقدر الحرف دالة متناقصة في K بينما مقدر (Liu) دالة متزايدة في d ، وتم تعريف مقدر (LE) للنموذج (2) لكل معلمة d حيث ان $0 < d < 1$ ، كما يأتي:

$$\hat{\alpha}_{LE} = (\Lambda + I)^{-1}(\Lambda + dI)\hat{\alpha}_{OLS}\quad (15)$$

ويرمز لمقدر (Liu) العام بالرمز $\hat{\alpha}_{GL}$. وصيغته كالآتي:

$$\begin{aligned}\hat{\alpha}_{GL} &= (\Lambda + I)^{-1}(X^{*'}Y + D\hat{\alpha}_{OLS}) \\ &= (I - (\Lambda + I)^{-1}(I - D))\hat{\alpha}_{OLS}\end{aligned}\quad (16)$$

$$D = \text{diag}(d_i) \quad , \quad 0 < d_i < 1$$

إذ أن :

D : تمثل مصفوفة قطرية بمعلمات التحيز d_i .

$$\begin{aligned}\hat{\beta}_{GL} &= P\hat{\alpha}_{GL} \\ &= P(I - (\Lambda + I)^{-1}(I - D))\hat{\alpha}_{OLS}\end{aligned}\quad (17)$$

ومصفوفة متوسط مربعات الخطأ لمقدر (GL) بالشكل الآتي :

$$MSE(\hat{\alpha}_{GL}) = Var(\hat{\alpha}_{GL}) + (Bias(\hat{\alpha}_{GL}))^2 \\ = \hat{\sigma}^2 (I - M)\Lambda^{-1}(I - M)' + M\alpha\alpha'M' \quad (18)$$

$M = (\Lambda + I)^{-1}(I - D)$
 وأن قيمة d معلمة التحيز المثلى التي تجعل قيمة MSE ($\hat{\alpha}_{GL}$) اقل ما يمكن هي [7]:

$$d_{iopt} = \left(\frac{\lambda_i(\hat{\alpha}_i^2 - \hat{\sigma}^2)}{(\lambda_i \hat{\alpha}_i^2 + \hat{\sigma}^2)} \right), \quad i = 1, 2, \dots, p \quad (19)$$

2.5 مقدر (AUGRR)

Almost Unbiased Generalized Ridge Regression

في عام 1986 م اقترح الباحث (Singh) وآخرون [19] مقدر (AUGRR) (Almost unbiased Generalized Ridge) ، وأشار (Singh) وآخرون في الدراسات السابقة بان مقدرات (GRR) تحمل قدراً كبيراً من التحيز وللتخفيف من هذا المقدار تم اقتراح مقدر (AUGRR) ، ويرمز لمقدر (AUGRR) بالرمز ($\tilde{\alpha}_{AUGRR}^*$) ، وصيغته للنموذج (2) هي بالشكل :

$$\tilde{\alpha}_{AUGRR}^* = [I + (\Lambda + K)^{-1}K] \hat{\alpha}_{GRR} \\ = [I - ((\Lambda + K)^{-1}K)^2] \hat{\alpha}_{OLS} \quad (20)$$

$$\hat{\beta}_{AUGRR} = P\tilde{\alpha}_{AUGRR}^* \\ = P [I - ((\Lambda + K)^{-1}K)^2] \hat{\alpha}_{OLS} \quad (21)$$

ومصفوفة متوسط مربعات الخطأ بالشكل الآتي :

$$M(\tilde{\alpha}_{AUGRR}^*) = Var(\tilde{\alpha}_{AUGRR}^*) + (Bias(\tilde{\alpha}_{AUGRR}^*))^2 \\ = \hat{\sigma}^2 (I - \Delta^2) \Lambda^{-1}(I - \Delta^2)' + \Delta^2 \alpha \alpha' \Delta^2 \quad (22)$$

وأن:

$$\Delta = (\Lambda + K)^{-1}K$$

حيث ان

Δ : مصفوفة قطرية عناصرها هي:

$$\delta_i = \frac{k_i}{(\lambda_i + k_i)}, \quad i = 1, 2, \dots, p$$

وقد أوضح (Nomura) 1988 [7] بان القيمة المثلى لـ K التي تجعل $MSE(\tilde{\alpha}_{AUGRR}^*)$ اقل ما يمكن هي :

$$\tilde{K}_{i(opt)} = \frac{\hat{\sigma}^2 + \sqrt{\lambda_i \hat{\alpha}_i^2 + \hat{\sigma}^2}}{\hat{\alpha}_i^2} \quad (23)$$

2.6 مقدر (Almost unbiased Generalized Liu) (AUGL) :

تم اقتراح هذا المقدر عام 1995م من قبل (Akdeniz & Kaciranlar) [6] ويقوم على نفس فكرة كل من الباحثان (Kadiyala) 1984 و (Ohtani) 1986، حيث تنص على تصحيح التحيز لمقدر Liu العام (GL) للمعلمة α في النموذج (2) الذي يعطى بالشكل التالي:

$$\hat{\alpha}_{GL}^* = \hat{\alpha}_{GL} + (\Lambda + I)^{-1}(I - D) \alpha \quad (24)$$

وفي حال ابدال المعلمة α بالمقدر المتحيز $\hat{\alpha}_{GL}$ فانه سوف يصبح لدينا مقدر جديد يدعى بمقدر (Almost unbiased Generalized Liu) (AUGL)، ويرمز له بالرمز $\tilde{\alpha}_{AUGL}^*$ [8]. حيث أن صيغة مقدر $\tilde{\alpha}_{AUGL}^*$ تكون بالشكل:

$$\begin{aligned} \tilde{\alpha}_{AUGL}^* &= (I + (\Lambda + I)^{-1}(I - D)) \hat{\alpha}_{GL} \\ &= (I - (\Lambda + I)^{-2}(I - D)^2) \hat{\alpha}_{OLS} \end{aligned} \quad (25)$$

$$\begin{aligned} \hat{\beta}_{AUGL} &= P \tilde{\alpha}_{AUGL}^* \\ &= P(I - (\Lambda + I)^{-2}(I - D)^2) \hat{\alpha}_{OLS} \end{aligned} \quad (26)$$

ومصفوفة متوسط مربعات الخطأ لمقدر (AUGL) بالشكل الآتي :

$$\begin{aligned} M(\tilde{\alpha}_{AUGL}^*) &= \text{Var}(\tilde{\alpha}_{AUGL}^*) + (\text{Bias}(\tilde{\alpha}_{AUGL}^*))^2 \\ &= \hat{\sigma}^2 (I - M^2) \Lambda^{-1} (I - M^2)' + M^2 \alpha \alpha' M^2 \end{aligned} \quad (27)$$

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

وقد تم إيجاد القيمة المثلى لـ di والتي تقلل من (MSE) لـ $(\tilde{\alpha}_{AUGL}^*)$ وبالشكل التالي : [7]

$$\tilde{d}_{iopt} = \left(1 - \sqrt{\frac{\hat{\sigma}^2(\lambda_i+1)^2}{\lambda_i \hat{\alpha}_i^2 + \hat{\sigma}^2}} \right) , i = 1, 2, \dots, p \quad (28)$$

2.7 المقدر المقترح (AUGJRR)

(Almost Unbiased Generalized Jackknife Ridge)

تم اقتراح هذا المقدر من قبل الباحثين حيث يقوم على تطبيق فكرة الباحثين (Kadiyala) 984 م و (Ohtani) 1986 أي مقدرات كل من (AUGRR) و (AUGL) على مقدر جاكنايف العام (GJRR) وذلك لغرض تقليل التحيز، وبالتالي يكون هذا المقدر ذو تحيز اقل من المقدرات (GRR, MJRR, GJRR)، وبالتالي اقل متوسط مربعات خطأ (MSE)، ويرمز له بالرمز $(\tilde{\alpha}_{AUGJRR}^*)$ ومختصراً (AUGJRR) و يحسب وفق النموذج (2) بالصيغة الآتية :

بتصحيح التحيز (the bias corrected) او تقليل التحيز لمقدر (GJRR)

$$\hat{\alpha}_{GJRR}^* = \hat{\alpha}_{GJRR} + K\varphi A^{-1}\alpha \quad (29)$$

حيث أن التحيز لمقدر (GJRR) يساوي:

$$\text{Bias}(\hat{\alpha}_{GJRR}) = -K\varphi A^{-1}\alpha$$

وبإبدال المعلمة α بالمقدر المتحيز $(\hat{\alpha}_{GJRR})$ نحصل على:

$$\begin{aligned} \tilde{\alpha}_{AUGJRR}^* &= \hat{\alpha}_{GJRR} + K\varphi A^{-1} \hat{\alpha}_{GJRR} \\ &= [I + K\varphi A^{-1}] \hat{\alpha}_{GJRR} \\ &= [I + K\varphi A^{-1}](I - K^2 A^{-2})(I - KA^{-1})^s \hat{\alpha}_{ols} , S \geq 0 \\ &= [(I - K^2 A^{-2})(I - KA^{-1})^s + K\varphi A^{-1}(I - K^2 A^{-2})(I - KA^{-1})^s] \hat{\alpha}_{ols} \\ &= v (I + K\varphi A^{-1}) \hat{\alpha}_{ols} \end{aligned} \quad (30)$$

إذ أن :

$$\begin{aligned} v &= (I - K^2 A^{-2})(I - KA^{-1})^s \\ \psi &= v (I + K\varphi A^{-1}) \\ \hat{\beta}_{AUGJRR} &= P \tilde{\alpha}_{AUGJRR}^* \\ &= Pv (I + K\varphi A^{-1}) \hat{\alpha}_{ols} \end{aligned} \quad (31)$$

وان توقع مقدر (AUGJRR) هو بالشكل :

$$\begin{aligned} E\tilde{\alpha}_{AUGJRR}^* &= v (I + K\varphi A^{-1}) E\hat{\alpha}_{OLS} \\ &= v (I + K\varphi A^{-1})\alpha \\ &= \psi \alpha \end{aligned} \quad (32)$$

و التحيز للمقدر المقترح (AUGJRR) بالشكل الآتي :

$$\begin{aligned} \text{Bias}(\tilde{\alpha}_{AUGJRR}^*) &= E(\tilde{\alpha}_{AUGJRR}^* - \alpha) \\ &= [v (I + K\varphi A^{-1})]\alpha - \alpha \\ &= [v (I + K\varphi A^{-1}) - I] \alpha \\ &= (\psi - I)\alpha \end{aligned} \quad (33)$$

والتباين لمقدر المقترح (AUGJRR) بالشكل الآتي :

$$\begin{aligned} \text{Var}(\tilde{\alpha}_{AUGJRR}^*) &= E [(\tilde{\alpha}_{AUGJRR}^* - E\tilde{\alpha}_{AUGJRR}^*)(\tilde{\alpha}_{AUGJRR}^* - E\tilde{\alpha}_{AUGJRR}^*)'] \\ &= v (I + K\varphi A^{-1}) \text{var}(\hat{\alpha}_{OLS}) (I + K\varphi A^{-1})' v' \\ &= \hat{\sigma}^2 v (I + K\varphi A^{-1}) \Lambda^{-1} (I + K\varphi A^{-1})' v' \\ &= \hat{\sigma}^2 \psi \Lambda^{-1} \psi' \end{aligned} \quad (34)$$

وان متوسط مربعات الخطأ لمقدر المقترح (AUGJRR) هو بالشكل الآتي :

$$\begin{aligned} \text{MSE}(\tilde{\alpha}_{AUGJRR}^*) &= \text{Var}(\tilde{\alpha}_{AUGJRR}^*) + (\text{Bias}(\tilde{\alpha}_{AUGJRR}^*))^2 \\ &= \hat{\sigma}^2 \psi \Lambda^{-1} \psi' + (\psi - I)\alpha\alpha'(\psi - I)' \end{aligned} \quad (35)$$

3. كيفية حساب معلمات التحيز (الثوابت) :

للوصول إلى أفضل قيمة لمعلمة التحيز هناك عدة طرائق، حيث تعتمد قيمة معلمة انحدار الحرف (K) و قيمة معلمة (D) Liu (D) بالأساس على مدى خبرة ومعرفة الإحصائي في كيفية اختيارها والتحكم بها ، وان هذه القيمة تعمل على تقليل متوسط مربعات الخطأ (MSE) ، وبالتالي سوف تكون المقدرات المحصل عليها هي الأفضل ، ومن هذه الطرائق المستعملة لحساب المعلمات هي:

معلمة الحرف (k) : هناك أكثر من طريقة لحساب هذه المعلمة ومنها :

(1) طريقة الباحثين (Hemmerle & Brantle) [7] ويرمز إلى هذه الطريقة بالرمز (HK)، و صيغتها كالاتي :

$$\hat{K}_i = \frac{\lambda_i \hat{\sigma}^2}{\lambda_i \hat{\alpha}_i^2 + \hat{\sigma}^2} = k1 \quad (36)$$

حيث أن :

λ_i : تمثل الجذور المميزة (Eigen values)
 (2) قدم (Nomura) [7] معلمة الحرف المثلى عام 1988 التي تعمل على تقليل متوسط مربعات الخطأ إلى اقل ما يمكن وصيغتها بالشكل :

$$\tilde{K}_{i(opt)} = \frac{\hat{\sigma}^2 + \sqrt{\lambda_i \hat{\alpha}_i^2 + \hat{\sigma}^2}}{\hat{\alpha}_i^2} = k2 \quad (37)$$

و أن :

$\hat{\alpha}_i$: تمثل مقدر المربعات الصغرى الاعتيادية لـ α ، $i=1,2,\dots,p$

$$\hat{\sigma}^2 = \frac{Y'Y - \hat{\alpha}'_{ols} \lambda^* Y}{n - m - 1} ,$$

معلمة (Liu (D) : كذلك هناك أكثر من طريقة لحساب هذه المعلمة ومنها :

(1) طريقة (Akdeniz & Kaciranlar) [7] وصيغتها هي :

$$D_{iopt} = \frac{\lambda_i (\hat{\alpha}_i^2 - \hat{\sigma}^2)}{(\lambda_i \hat{\alpha}_i^2 + \hat{\sigma}^2)} = D1 \quad (38)$$

(2) قدمت هذه الطريقة من قبل (Akdeniz) وآخرون [7] عام 1999 للحصول على القيمة المثلى للمعلمة d_i التي تجعل متوسط مربعات الخطأ اقل يمكن ، التي صيغتها كالآتي :

$$\tilde{D}_{iopt} = \left(1 - \sqrt{\frac{\hat{\sigma}^2 (\lambda_i + 1)^2}{\lambda_i \hat{\alpha}_i^2 + \hat{\sigma}^2}} \right) = D2 \quad (39)$$

وبإتباع ما جاء به الباحثان (Akdeniz & Erol) [8] يمكن الحصول على قيمة معلمة (Liu) عند تثبيت قيمة معلمة الحرف (ki's) ، إذ أن $(0 < k_i < 1)$ ، $i = 1, 2, \dots, p$ وحسب الصيغة الآتية [7] :

$$\tilde{d}_i = \frac{((1-k_i)\lambda_i)}{(\lambda_i + k_i)} \quad (40)$$

كذلك بعد حساب قيمة معلمة (Liu) D_i تثبت هذه القيمة ثم نحسب قيمة معلمة الحرف k بدالتها وحسب الآتي :

$$\tilde{K}_i = \frac{((1-d_i)\lambda_i)}{(\lambda_i + d_i)} \quad (41)$$

4. الجانب التجريبي

سيتم في هذا المبحث استعمال أهم أساليب المحاكاة وأكثرها شيوعاً في التحليل وهو أسلوب مونت كارلو (Monte Carlo) لدراسة ومعالجة تأثير الارتباطات المختلفة بين المتغيرات التوضيحية على الأنموذج المدروس في البحث، حيث تم توليد بيانات تعاني من وجود مشكلة التعدد الخطي بين متغيراتها التوضيحية ، وقد تم استعمال جميع المقدرات المذكورة في الجانب النظري في معالجة هذه المشكلة ، بالإضافة إلى ذلك تم استعمال المؤشر الإحصائي المتمثل بمتوسط مربعات الخطأ (MSE) كمعيار مقارنة واختبار كفاءة المقدرات ، وقد تمت الاستعانة بأحد البرامج الإحصائية الجاهزة والمعروف بلغة البرمجة R (Ver.3.0.1) .

4.1 توليد البيانات

تم توليد المتغيرات العشوائية التي تخضع للتوزيع الطبيعي القياسي وحسب المراحل الآتية :

المرحلة الأولى: وهي مرحلة تحديد القيم الافتراضية إذ تعد من أهم المراحل التي تعتمد عليها بقية المراحل وقد تم اختيار القيم الافتراضية كالتالي:

1. تحديد حجم العينة (n): وقد اختيرت ثلاثة أحجام للعينة وهي
(n = 20,60 ,,300)

2. تحديد قيم المعلمات الافتراضية: افتراضنا أن عدد المعلمات $P = 6$ ،
هي: $\beta_0 = 0$ ، $\beta = (1,0,1,1,1)$.

المرحلة الثانية: هي مرحلة توليد المتغيرات التوضيحية، حيث تم في هذه المرحلة توليد قيم المتغيرات التوضيحية X_{ij} ، والعمل على السيطرة على التذبذبات في قيم الارتباطات بين المتغيرات التوضيحية المرتبطة، وعملية التوليد والسيطرة تتم من خلال المعادلة الآتية [15]:

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

و أن :

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

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

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

i : يمثل عدد المشاهدات.

ρ : يمثل قيمة الارتباط بين المتغيرات التوضيحية في الأنموذج المدروس، الذي أخذنا القيم ($\rho = 0.85, 0.90, 0.99$) .

المرحلة الثالثة: وهي مرحلة حساب المتغير المعتمد، حيث تم حسابه من خلال الأنموذج الآتي :

$$y_i = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \beta_3 x_{i3} + \beta_4 x_{i4} + \beta_5 x_{i5} + e_i$$

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

وقد تم استعمال معيار المقارنة متوسط مربعات الخطأ للأنموذج (MSE) ، و كان عدد مرات تكرار التجربة $R = 1500$.

4.2 نتائج المحاكاة :

من خلال نتائج الجدول (1) وعندما ($P=6$, $n=20$, $\sigma^2=0.16$, $S=2$) نلاحظ بأن المقدر (AUGL) هو الأفضل عند جميع الارتباطات والمعاملات المدروسة باستثناء عند المعلمة D2 وقيمة الارتباط 0.90 حيث كانت الطريقة المقترحة هي الأفضل وكانت الطريقة المقترحة (AUGJRR) بالمرتبة الثانية عند اغلب المعلمات ولجميع الارتباطات باستثناء عند معلمة الحرف k1 وللارتباطين 0.90 و 0.85 وعند معلمة الحرف k2 وللارتباطين 0.90 و 0.99 فقد كانت بالمرتبة الثالثة. اما المقدر (AUGRR) فقد جاء على الاغلب بالمرتبة الثالثة . وتناوبت المقدرات الاخرى (GL, GJRR, MJRR, GRR, OLS) على المراتب الاخرى ونلاحظ بان المقدر (OLS) جاء في المرتبة الاخيرة .

كما أظهرت نتائج الجدول (1) وعندما ($P=6$, $n=20$, $\sigma^2=0.13$, $S=2$) أن أفضل المقدرات هو (AUGL) عند جميع المعلمات والارتباطات وتقاسم المقدرين المقترح (AUGJRR) والمقدر (AUGRR) المرتبتين الثانية والثالثة بالنصف وعند جميع المعلمات والارتباطات اما المقدرات الاخرى (GL, GJRR, MJRR, GRR, OLS) فقد تناوبت على المراتب الاخرى عند مختلف المعلمات والارتباطات ونلاحظ بان المقدرين (GRR) ومقدر المربعات الصغرى (OLS) قد جاءا في المراتب الاخيرة .

اظهرت نتائج الجدول (1) عندما ($P=6$, $n=20$, $\sigma^2=0.18$, $S=2$) أن أفضل المقدرات هو (AUGL) وعند اغلب المعلمات والارتباطات باستثناء عند المعلمة K1 وللارتباط $\rho = 0.85$ وعند المعلمة K2 وللارتباط 0.99 حيث جاء بالمرتبة الثانية وكان المقدر (AUGRR) بالمرتبة الاولى حيث امتلك اقل متوسط مربعات خطأ (MSE) وكذلك عند معلمة الحرف K2 وللارتباط $\rho = 0.85$ فقد كان المقدر المقترح (AUGJRR) بالمرتبة الاولى حيث جاء المقدر (AUGL) بالمرتبة الثانية. وجاء المقدر المقترح (AUGJRR) بالمرتبة الثانية على الاغلب باستثناء عند المعلمة K1 وللارتباطين 0.90, 0.85 و $\rho = 0.85$ وعند معلمة الحرف K2 وللارتباط $\rho = 0.99$ فقد جاء بالمرتبة الثالثة . وجاء المقدر (AUGRR) بالمرتبة الثالثة عند اغلب المعلمات والارتباطات وتناوبت المقدرات (GJRR, GL, MJRR, GRR, OLS)

على المراتب الاخرى ونلاحظ بان المقدر (OLS) في آخر المراتب حيث امتلاك اكبر متوسط مربعات خطأ (MSE).

كما نلاحظ من خلال نتائج الجدول (1) عندما ($P=6, n=60, \sigma^2 = 0.16, S=2$) وعند اغلب معاملات التحيز والارتباطات بان المقدر (AUGL) في المرتبة الاولى باستثناء عند المعلمة k_1 والارتباط 0.99 حيث تقدم عليه المقدر (AUGRR) وتقدم المقدر المقترح (AUGJRR) عند معلمة الحرف k_2 وللارتباط 0.99 . اما المرتبة الثانية فقد كانت على الاغلب من نصيب المقدر المقترح (AUGJRR) باستثناء عند المعلمة K_1 وللارتباط $\rho=0.85$ وعند المعلمة K_2 وللارتباطين $\rho=0.99, 0.90$ حيث جاء بالمرتبة الثالثة . وجاء المقدر (AUGRR) بالمرتبة الثالثة عند اغلب المعلمات والارتباطات وتناوبت المقدرات (GJRR, GL, MJRR, GRR, OLS) على المراتب الاخرى ونلاحظ بان المقدر (OLS) في آخر المراتب حيث امتلاك اكبر متوسط مربعات خطأ (MSE).

كما أظهرت نتائج الجدول (1) عندما ($P=6, n=60, \sigma^2 = 0.13, S=2$) بان أفضل مقدر (AUGL) لامتلاكه اقل متوسط مربعات خطأ (MSE) يليه بالمرتبة الثانية المقدر المقترح (AUGJRR) باستثناء معلمة Liu D1 وللارتباط 0.85 فقد جاء المقدر (AUGRR) بالمرتبة الثانية وكان ترتيب المقدر (AUGRR) على الاغلب بالمرتبة الثالثة ثم تلتها بقية الطرائق على الاخرى وفي المرتبة الأخيرة (OLS) .

أظهرت نتائج الجدول (1) عندما ($P=6, n=60, \sigma^2 = 0.18, S = 2$) بان مقدر (AUGL) هو الأفضل وعند اغلب معاملات التحيز ولجميع قيم الارتباط حيث يمتلك اقل متوسط مربعات خطأ (MSE) باستثناء عند معلمة liuD2 وعند الارتباط 0.85 وعند معلمة K_2 وللارتباط 0.90 فقد كان المقدر المقترح (AUGJRR) بالمرتبة الاولى وعند المعلمة k_2 والارتباط 0.99 فقد كان المقدر (AUGRR) بالمرتبة الاولى. اما المرتبة الثانية فكانت على الاغلب من نصيب المقدر المقترح (AUGJRR) باستثناء عند المعلمتين $D1, K_1$ والارتباط 0.85 وعند المعلمة k_1 وللارتباط 0.90 وعند D_2 والارتباط 0.99 فقد جاء المقدر المقترح بالمرتبة الثالثة. اما المرتبة الثالثة فقد كانت على الاغلب من نصيب المقدر (AUGRR) ثم تلتها بقية المقدرات وأخيراً مقدر المربعات الصغرى (OLS)

وعند زيادة حجم العينة الى $n=300$ ومن خلال نتائج الجدول (1) عندما ($P=6, \sigma^2 = 0.16, S=2$) تبين أن أفضل مقدر على الاغلب هو (AUGL) باستثناء عند معلمة الحرف K_2 , وقيمة الارتباط 0.85 حيث تصدر المقدر (AUGRR) وعند D_2 ولنفس الارتباط فقد تصدر المقدر المقترح (AUGJRR) وكذلك تصدر المقدر المقترح عند k_2 وللارتباط 0.99 ، اما المرتبة الثانية فقد كانت على الاغلب من نصيب المقدر المقترح (AUGJRR) باستثناء عند الارتباط 0.85 وعند k_2 وعند D_2 وللارتباطين 0.99, 0.90 فقد جاء المقدر في المرتبة الثالثة ، وجاء المقدر

(AUGRR) على الاغلب في المرتبة الثالثة ثم تناوبت بقية المقدرات على المراتب الاخرى وجاء مقدر (ols) في المرتبة الاخيرة.

كما أظهرت نتائج الجدول (1) عندما ($P=6$, $n=300$, $\sigma^2 = 0.13$, $S = 2$) بان مقدر (AUGL) هو الأفضل على الاغلب حيث يمتلك اقل متوسط مربعات خطأ (MSE) باستثناء عند k_2 وللاارتباط 0.85 وعند D_2 , D_1 , K_2 وللاارتباط 0.99 فقد كان المقدر المقترح بالمرتبة الاولى. وكذلك تصدر المقدر المقترح لبقية معلمات التحيز ولجميع الارتباطات في المرتبة الثانية باستثناء عند K_1 وللاارتباط 0.85 و D_2 وللاارتباط 0.90 حيث كان في المرتبة الثالثة. اما المرتبة الثالثة فقد كانت على الاغلب من نصيب المقدر (AUGRR) واحتلت المراتب الاخرى بقية المقدرات وكان نصيب المرتبة الاخيرة مقدر (ols).

أظهرت نتائج الجدول (1) عندما ($P=6$, $n=300$, $\sigma^2 = 0.18$, $S = 2$) بان المقدر (AUGL) هو الافضل على الاغلب حيث يمتلك اقل متوسط مربعات خطأ (MSE) باستثناء عند معلمة الحرف K_2 وللاارتباطين 0.85 , 0.99 فقد كان المقدر المقترح (AUGJRR) هو الافضل وعند معلمة الحرف K_1 وللاارتباطين 0.85 , 0.99 فقد كان المقدر (AUGRR) هو الأفضل وعند بقية الارتباطات والمعلمات فقد كان المقدر المقترح (AUGJRR) بالمرتبة الثانية باستثناء عند معلمة الحرف K_1 وللاارتباطين 0.85 , 0.99 ولللمعلمة D_1 وعند الارتباط 0.99 فقد كان في المرتبة الثالثة اما المرتبة الثالثة فقد كانت من نصيب المقدر (AUGRR) على الاغلب وجاءت المقدرات (GL, GJRR, GRR, MJRR, OLS) في المراتب الاخرى ونلاحظ بان المقدر ols جاء في اخر مرتبة .

لمعرفة تأثير الثابت S على النتائج عند زيادة قيمته تم اجراء تجربة ثانية تم الافتراض بان حجم العينة $n=15$ و $S=10$ وعدد المعلمات هي $p=4$ وكانت القيم الافتراضية كمايلي:

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

وكانت النتائج كما يظهر في الجدول (2) حيث نلاحظ وعند زيادة قيمة الثابت S وبارتباطات مختلفة وعند معلمتي الحرف (K_1 و K_2) ومعلمتي (D_1 , D_2) وباختلاف قيمة التباين وحجم العينة بان أفضل المقدرات هو (AUGL) حيث يمتلك اقل متوسط مربعات خطأ (MSE) يليه بالمرتبة الثانية المقدر المقترح وجاء بالمرتبة الثالثة المقدر (AUGRR) وكما كانت بالجدول السابقة باستثناء عند المعلمة K_2 فقد جاءت المقدرات حسب الأتي أولا المقدر المقترح (AUGJRR) ويليه المقدر (AUGL) ومن بعدهما جاء المقدر (AUGRR) عند جميع الارتباطات والتباينات باستثناء عند $\sigma^2 = 0.18$, $\rho = 0.85$ حيث كان المقدر (AUGRR) اولاً والمقدر (AUGL) ثانياً والمقدر المقترح ثالثاً. اما بقية المقدرات (GL, GJRR,)

(MJRR, GRR, OLS) فقد كانت في المراتب الاخرى وكان المقدر (OLS) في المرتبة الاخيرية.

5. الاستنتاجات

من خلال التحليل المستعمل في هذا البحث وبالاتماد على الجانب التجريبي فقد تم التوصل إلى بعض الاستنتاجات:

- (1) أظهرت نتائج المحاكاة إن أفضل المقدرات هما المقدر (AUGL) والمقدر المقترح (AUGJRR) والمقدر (AUGRR) حيث يمتلكون اقل متوسط مربعات خطأ (MSE) مقارنة مع مقدرات المربعات الصغرى وبقية المقدرات المتحيزة الاخرى وذلك في اغلب حالات معلمة الحرف (K1) وفي حالة معلمة الحرف (K2) وكذلك في حالة معلمتي Liu (D1,D2).
- (2) عند زيادة حجم العينة وبشكل كبير سوف نتوصل الى نفس النتائج التي تم الحصول عليها عند حجوم العينات الاقل.
- (3) كما أظهرت النتائج أن متوسط مربعات الخطأ (MSE) لمقدرات جاكنايف (MJRR,GJRR,AUGJRR) يزداد بزيادة قيمة (S) إلا في حالات قليلة.
- (4) ومن خلال ملاحظة نتائج الجانب التجريبي وجد أن أفضل المقدرات تكون في حال استخدام معلمة الحرف (K2) حيث تعطي مقدرات ذات متوسط مربعات خطأ اقل.

6. التوصيات

- (1) نوصي باستخدام المقدر المقترح (Generalized Jackknife Ridge Almost unbiased) وذلك عند وجود مشكلة التعدد الخطي شبه التام بين المتغيرات التوضيحية.
- (2) نوصي باستخدام طريقة Nomura صيغة رقم (19) في حساب معلمة انحدار الحرف K لكونها تعطي مقدرات ذات النتائج الأفضل.
- (3) من خلال المقارنة بين المقدرات المذكورة في الجانب النظري وجدنا أن المقدرات تعتمد على معلمتي التحيز (K,D) لذلك لا يزال هناك مجال لتحسين وتطوير دقة هذه المقدرات من خلال التحكم بكيفية حساب هذه المعلمات .

المصادر المصادر العربية:

- [1] الصالحي ، حنين مراد يوسف (2014) "مقارنة بين طرائق تقدير انحدار الحرف العامة في معالجة مشكلة التعدد الخطي شبه التام مع تطبيق عملي "رسالة ماجستير ، كلية الادارة والاقتصاد ،جامعة بغداد.
- [2] النعيمي، أسوان محمد طيب (2005)م ،"اختيار المتغيرات في انحدار الحرف"، رسالة ماجستير، كلية علوم الحاسبات والرياضيات (غير منشورة)، جامعة الموصل .
- [3] جواد، نزار مصطفى وكمال، غفران إسماعيل (2009)م، "مقارنة طرائق تقدير معلمات النموذج الانحدار في حالة ظهور مشكلة التعدد الخطي والقيم الشاذة"، مجلة العلوم الإدارية والاقتصادية، كلية الإدارة والاقتصاد، جامعة بغداد. المجلد 15، العدد 55.
- [4] كاظم ، أموري هادي ومسلم، باسم شلبية (2002)م، " القياس الاقتصادي المتقدم - النظرية والتطبيق"، مكتبة دنيا الامل ، بغداد.

المصادر الأجنبية:

- [5] Abdalla, M. EL-Habil (2012). "A Suggested Method of Detecting Multicollinearity in Multiple Regression Models". Tanmyat AL-Rafidain 106(34) , P.P [7-21] .
- [6] Akdeniz, F., Kacıranlar, S. (1995)." On the almost unbiased generalized Liu estimator and unbiased estimation of the bias and MSE". Commun. Statist. Theor. Meth. 24:1789–1797.
- [7] Akdeniz, F., Erol, H. (2003). "Mean squared error matrix comparisons of some biased estimators in linear regression", Commun. Statist. Theor. Meth. 32:2389–2413.
- [8] 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.
- [9] Arthur, E. Hoerl, Robert W. Kennard (1970-a), "Ridge Regression Biased Estimation for Nonorthogonal Problems"; Technometrics Vol. 12, No.1 , pp.55-60.

- [10] Arthur, E. Hoerl, Robert W. Kennard (1970-b), "Ridge Regression Applications to Nonorthogonal Problem"; *Technometrics* , Vol.12 , No.1 , pp.69-82 .
- [11] El-Dereny ,M. Rashwan, N., (2011)." Solving Multicollinearity Problem Using Ridge Regression Models", *Int. J. Contemp. Math. Sciences*, 12, 585 – 600.
- [12] Feras, SH. Batah, T. V. Ramnathan 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.
- [13] Feras ,SH. Batah and Sharad D. Gore.(2009)," Ridge Regression estimator: Combining Unbiased And Ordinary Ridge Regression Methods Of Estimation", *Surveys in Mathematics and its Applications* 1842-6298 .
- [14] Feras, SH. Batah, (2011), " A New Estimator by Generalized Modified Jackknife Ridge Regression Estimator". *Journal of Basrah Researches (Sciences)*, Volume 37. Number 4. C.
- [15] Kacıranlar, S., Sakallıglu, S., Akdeniz, F., Styan, G. P. H. Werner, H. J. (1999), "A new biased estimator in linear regression and a detailed analysis of the widely-analyzed dataset on Portland cement". *Sankhya: Indian J. Statist. B* 61:443–459.
- [16] Liu, Kejian (1993), "A new class of biased estimate in linear regression". *Communications in Statistics–Theory and Methods* 22, 393–402.
- [17] Sakallıglu, S., Kaçıranlar, S., (2008)," A new biased estimator based on ridge estimation", *Statist. Papers* 49 .669–689.
- [18] Silvey , S.D. , (1968) , "Multicollinearity and Imprecise estimation" , *Journal of Royal Statistical Society* , Vol.31, No. 3 , pp. 539-552.
- [19] 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.

جدول (1)

يبين قيم متوسط مربعات الخطأ عند استعمال المقدرات (GJRR, AUGRR, AUGJRR, GL, AUGL, OLS, GRR, MJRR) عند معلمتي الحرف (k1,k2) ومعلمتي (Liu) D1 وD2 و(عند $s=2, p=6$) وباحجام وارتباطات وتباينات مختلفة

المقدرات المعلمتات	OLS	GRR				MJRR				
		K1	K2	D1	D2	K1	K2	D1	D2	
N=20 $\sigma^2=.16$	P=.85	0.0359652	0.0289460	0.0153923	0.0176007	0.0431003	0.0271849	0.0090108	0.0107114	0.02991
	P=.90	0.0359571	0.0284851	0.0158658	0.0107696	0.0341290	0.0176565	0.009210	0.010842	0.03063
	P=.99	0.0359338	0.0109633	0.0154005	0.0173921	0.0439745	0.0061341	0.0088394	0.0101869	0.03025
N=20 $\sigma^2=.13$	P=.85	0.0358791	0.0348599	0.0152078	0.0196262	0.0247714	0.0311329	0.008856	0.017465	0.03981
	P=.90	0.0358738	0.0279350	0.0197259	0.0178945	0.0310069	0.0172067	0.009054	0.010605	0.03053
	P=.99	0.0358588	0.0107486	0.0152670	0.0172551	0.0338963	0.0059476	0.008696	0.010037	0.03014
N=20 $\sigma^2=.18$	P=.85	0.0360329	0.0312698	0.0155027	0.0177123	0.0431493	0.0305205	0.0091347	0.0108397	0.02999
	P=.90	0.0360224	0.0288791	0.0159795	0.0181626	0.0307176	0.0179837	0.0093352	0.0109001	0.02521
	P=.99	0.0359926	0.0111267	0.0155079	0.0175024	0.0340398	0.0062777	0.0089531	0.0103055	0.03034
N=60 $\sigma^2=.16$	P=.85	0.093216	0.081956	0.0717903	0.0900623	0.0566620	0.071536	0.042696	0.088114	0.03466
	P=.90	0.0932160	0.0170873	0.0074841	0.0124108	0.0560547	0.0063215	0.004816	0.007561	0.03405
	P=.99	0.0932268	0.0113309	0.0069294	0.0121148	0.0559438	0.0067165	0.004154	0.007407	0.03388
N=60 $\sigma^2=.13$	P=.85	0.0930033	0.0115037	0.0067278	0.0125987	0.0562380	0.0067083	0.003830	0.007655	0.03421
	P=.90	0.0930029	0.0110480	0.0066375	0.0119729	0.0556521	0.006381	0.004783	0.007120	0.03363
	P=.99	0.0930101	0.0109289	0.0064752	0.0117281	0.0555768	0.0063058	0.003711	0.007012	0.03350
N=60 $\sigma^2=.18$	P=.85	0.0933836	0.012310	0.0075304	0.0134232	0.0350064	0.0075013	0.004612	0.008471	0.02890
	P=.90	0.0933829	0.0118268	0.0074377	0.0127551	0.0563716	0.0071568	0.004564	0.007907	0.03438
	P=.99	0.0933965	0.0116515	0.0072838	0.0124255	0.0562379	0.0070420	0.004501	0.007722	0.03419

تكملة جدول (1)

المعلومات		المقدرات	OLS	GRR				MJRR			
				K1	K2	D1	D2	K1	K2	D1	D2
N=300 $\sigma^2=.16$	P=.85	0.0017108	0.0004648	0.0005961	0.0004317	0.0052983	0.0004184	0.000400	0.000481	0.00300	
	P=.90	0.0017108	0.000701	0.0006185	0.0007244	0.0052013	0.0004631	0.000412	0.000480	0.00299	
	P=.99	0.0017109	0.0006538	0.0007270	0.0006871	0.0048706	0.0004450	0.000442	0.000472	0.00279	
N=300 $\sigma^2=.13$	P=.85	0.0017074	0.0006348	0.000529	0.0006567	0.0052226	0.0003948	0.000333	0.000412	0.00293	
	P=.90	0.0017074	0.0006294	0.0005515	0.0006525	0.0051249	0.0003928	0.000344	0.000410	0.00288	
	P=.99	0.0017075	0.0005798	0.0003737	0.000689	0.0047922	0.0003731	0.000721	0.000400	0.00269	
N=300 $\sigma^2=.18$	P=.85	0.0017135	0.0007616	0.000453	0.0008275	0.0059049	0.0005191	0.000492	0.000549	0.00336	
	P=.90	0.0017134	0.0008078	0.0005721	0.0006216	0.0058488	0.0005385	0.000449	0.000546	0.00333	
	P=.99	0.0017132	0.0007404	0.0003977	0.0007566	0.0056201	0.0005037	0.000543	0.000519	0.00318	

تكملة جدول (1)

المقدرات العملات		AUGJRR				GL				AUGL			
		K1	K2	D1	D2	K1	K2	D1	D2	K1	K2	D1	D2
N=20 $\sigma^2=.16$	P=.85	.020104	0.0045035	.006214	0.0171661	0.0261742	0.00808	0.009578	0.024592	0.010094	0.001594	0.002340	0.009532
	P=.90	.012204	0.0044378	.003867	0.008199	0.0153560	0.008388	0.009813	0.02525	0.003769	0.001541	0.002135	0.009637
	P=.99	.034948	0.0152489	.009148	0.0343571	0.0312324	0.005478	0.019465	0.039841	0.025145	0.004789	0.015875	0.034124
N=20 $\sigma^2=.13$	P=.85	.009772	0.0014329	.006029	0.0270719	0.0290469	0.007972	0.009479	0.024516	0.009560	0.001420	0.002159	0.009374
	P=.90	.011714	0.0042610	.002678	0.0280926	0.0147113	0.008278	0.009857	0.025152	0.003506	0.001372	0.001962	0.009478
	P=.99	.001951	0.001296	.005054	0.0235236	0.0056006	0.008023	0.008981	0.024668	0.000729	0.001219	0.001601	0.009001
N=20 $\sigma^2=.18$	P=.85	.010851	0.0016408	.002361	0.0272494	0.0304208	0.008330	0.00947	0.024718	0.010485	0.001731	0.002482	0.00965
	P=.90	.012563	0.0016769	.003021	0.0097290	0.0155012	0.008506	0.00971	0.025154	0.003968	0.001574	0.002271	0.00906
	P=.99	.002253	0.0041151	.001351	0.0247307	0.0059289	0.008239	0.00932	0.025007	0.001002	0.001490	0.001278	0.00926
N=60 $\sigma^2=.16$	P=.85	.003721	0.0032664	.004330	0.0051424	0.006718	0.004231	0.004484	0.030572	0.001904	0.001821	0.002341	0.007500
	P=.90	.002461	0.0013237	.002719	0.0071237	0.0067935	0.003700	0.007123	0.030307	0.001701	0.001311	0.002064	0.007059
	P=.99	.002789	0.0010434	.001652	0.0065138	0.006614	0.004025	0.007131	0.029617	0.001703	0.001324	0.001139	0.006986
N=60 $\sigma^2=.13$	P=.85	.002821	0.0010429	.003865	0.0080784	0.006618	0.006151	0.007121	0.030384	0.001388	0.000876	0.001899	0.007049
	P=.90	.001489	0.0010360	.003278	0.0067953	0.0064757	0.003561	0.006957	0.029434	0.001281	0.000874	0.001622	0.006618
	P=.99	.002380	0.0010568	.003065	0.0049752	0.0056426	0.003625	0.006170	0.029395	0.001277	0.001008	0.001720	0.004580
N=60 $\sigma^2=.18$	P=.85	.003613	0.0018080	.004691	0.0055120	0.0068841	0.004592	0.007697	0.030764	0.002159	0.001638	0.002685	0.00785
	P=.90	.003264	0.0016054	.003065	0.0074344	0.0068617	0.004651	0.007360	0.030448	0.002048	0.001635	0.002410	0.00740
	P=.99	.002530	0.0018315	.003759	0.0204564	0.0069512	0.004256	0.006455	0.030460	0.002038	0.001664	0.001468	0.00668

تكملة جدول (1)

المقدرات المعاملات		AUGJRR				GL				AUGL			
		K1	K2	D1	D2	K1	K2	D1	D2	K1	K2	D1	D2
N=300 $\sigma^2=.16$	P=.85	0.0002418	0.00021	0.0002595	0.0011786	.000198	.000486	.00051	0.002791	0.000113	0.000203	0.000219	0.000394
	P=.90	0.0002446	0.00021	0.0002631	0.0011659	.000476	.000383	.00050	0.006745	0.000214	0.000204	0.000221	0.000468
	P=.99	0.0002628	0.00011	0.0001295	0.0010577	.000398	.000510	.00042	0.002634	0.000221	0.000207	0.000233	0.000453
N=300 $\sigma^2=.13$	P=.85	0.0001731	0.0001394	0.0001509	0.0011044	.000366	.000326	.00038	0.002630	0.000144	0.000135	0.000151	0.000399
	P=.90	0.0001756	0.0001404	0.0001943	0.0010913	.000363	.000229	.00037	0.002688	0.000145	0.000135	0.000152	0.000397
	P=.99	.00019263	0.0001441	0.0002259	0.0009794	.000689	.000379	.00038	0.002500	0.000151	0.000137	0.000163	0.000382
N=300 $\sigma^2=.18$	P=.85	.00029532	0.0001975	0.0002431	0.0004367	.000505	0.00026	.00054	0.003113	0.000266	0.000257	0.000264	0.000543
	P=.90	.00028209	0.0002592	0.0002857	0.0001338	.000499	.000421	.00051	0.003063	0.000262	0.000256	0.000263	0.000130
	P=.99	.00028040	0.0002535	0.0002973	0.0002154	.000481	.000430	.00049	0.002968	0.000259	0.000251	0.000267	0.000209

تكملة جدول (1)

المقدرات المعلومات		GJRR				AUGRR			
		K1	K2	D1	D2	K1	K2	D1	D2
N=20 $\sigma^2=.16$	P=.85	0.0256917	0.008290	0.009741	0.0248602	.010235	0.0017189	0.0075278	0.0197410
	P=.90	0.015444	0.008692	0.009972	0.025431	.004122	0.001926	0.0054899	0.0099723
	P=.99	0.0057228	0.008032	0.009117	0.0247908	.008985	0.0104827	0.0320492	0.0394827
N=20 $\sigma^2=.13$	P=.85	0.025591	0.008190	0.010551	0.033049	.025347	0.0016201	0.0024140	0.0096262
	P=.90	0.015127	0.008591	0.00945	0.025340	.003935	0.0018307	0.0053845	0.0098575
	P=.99	0.005611	0.007950	0.009019	0.024710	.000792	0.0038399	0.0016414	0.0290191
N=20 $\sigma^2=.18$	P=.85	0.0266047	0.008370	0.009532	0.024933	.010471	0.0017277	0.0026174	0.0098325
	P=.90	0.0154352	0.008411	0.009697	0.0241779	.003922	0.0017223	0.0061896	0.0098976
	P=.99	0.0058093	0.008099	0.00948	0.025856	.004319	0.0014367	0.0019994	0.0294487
N=60 $\sigma^2=.16$	P=.85	0.04519	0.01939	0.045321	0.028703	.008247	0.0019169	0.0045008	0.0053219
	P=.90	0.006207	0.004534	0.007198	0.030046	.001838	0.0014350	0.0028714	0.0203899
	P=.99	0.006025	0.003809	0.006513	0.029580	.001368	0.0014912	0.0034518	0.0201421
N=60 $\sigma^2=.13$	P=.85	0.004283	0.001705	0.00507	0.028449	.007064	0.0012368	0.0019937	0.0205879
	P=.90	0.006308	0.00408	0.006890	0.029806	.001619	0.0012248	0.0039453	0.0068901
	P=.99	0.003781	0.001551	0.004266	0.027542	.008997	0.0012242	0.0106227	0.0062661
N=60 $\sigma^2=.18$	P=.85	0.004705	0.002122	0.005512	0.056993	.003068	0.0054425	0.0022133	0.0214135
	P=.90	0.006712	0.004485	0.007307	0.030236	.002125	0.0018001	0.0083481	0.0075070
	P=.99	0.006192	0.003981	0.006682	0.02975	.003113	0.0012048	0.0078187	0.00737

تكملة جدول (1)

المقدرات المعلمات		GJRR				AUGRR			
		K1	K2	D1	D2	K1	K2	D1	D2
N=300 $\sigma^2=.16$	P=.85	0.000464	0.000365	0.000728	0.002739	.000199	.0001703	.0001858	0.000431
	P=.90	0.000709	0.000668	0.000723	0.002970	.000474	.0004644	.0004814	.0007235
	P=.99	0.000696	0.000675	0.000709	0.002773	.000509	.0005008	.0005171	.0007096
N=300 $\sigma^2=.13$	P=.85	0.000383	0.000331	0.000396	0.002701	.000145	.0001435	.0002517	.0003968
	P=.90	0.000674	0.000234	0.000689	0.002933	.000440	.0004303	.0004479	.0006893
	P=.99	0.000679	0.000607	0.000613	0.002756	.000499	.0004939	.0005052	0.000366
N=300 $\sigma^2=.18$	P=.85	0.000446	0.000392	0.000436	0.003014	.000207	.0006484	.0001575	0.001354
	P=.90	0.000294	0.000410	0.000272	0.002778	.000322	.0005531	.0004929	.0002021
	P=.99	0.000375	0.000290	0.000378	0.002843	.000147	.0002457	.0002475	.0003780

جدول (2)

يبين قيم متوسط مربعات الخطأ عند استعمال المقدرات (GJRR, AUGRR, AUGJRR, GL, AUGL, OLS, GRR, MJRR) عند معلمتي الحرف (k1,k2) ومعلمتي (Liu) D1 و D2 في حالة (s=10,n=15,p=4) وبارتباطات وتباينات مختلفة.

المعلمت	المقدرات		GRR				MJRR			
	OLS		K1	K2	D1	D2	K1	K2	D1	D2
$\sigma^2=0.16$ $\rho=0.85$	0.0432428	0.05611337	0.04663047	0.04349438	0.02075344	0.0444294	0.0382702	0.0415218	0.0233427	0.0432428
$\sigma^2=0.16$ $\rho=0.90$	0.0426445	0.05611228	0.04987677	0.01816946	0.04901995	0.0520217	0.0327256	0.0172815	0.0447607	0.0426445
$\sigma^2=0.16$ $\rho=0.99$	0.0502618	0.05609781	0.02827541	0.02734456	0.04984103	0.0414088	0.0265418	0.0257239	0.0406236	0.0502618
$\sigma^2=0.13$ $\rho=0.85$	0.0430887	0.05592178	0.02843236	0.2822141	0.0333793	0.0441811	0.0279484	0.0240726	0.0230262	0.0430887
$\sigma^2=0.13$ $\rho=0.90$	0.0518563	0.05592093	0.02990662	0.02853045	0.04209	0.0434179	0.0183914	0.0167630	0.022414	0.0518563
$\sigma^2=0.13$ $\rho=0.99$	0.0500817	0.05591107	0.02543381	0.02409698	0.01798619	0.0516174	0.0162016	0.0150589	0.0202579	0.0500817
$\sigma^2=0.18$ $\rho=0.85$	0.0434654	0.05626374	0.02335529	0.01938667	0.055153	0.0533806	0.0185294	0.0148429	0.0536000	0.0434654
$\sigma^2=0.18$ $\rho=0.90$	0.0392171	0.05626255	0.02605344	0.02204819	0.05522662	0.0427965	0.0179931	0.0176571	0.0530379	0.0392171
$\sigma^2=0.18$ $\rho=0.99$	0.0404178	0.05624466	0.01844332	0.01833652	0.01803839	0.0415557	0.0168132	0.0162067	0.0209140	0.0404178

تكملة جدول (2)

المقدرات العملات	AUGJRR				GL				AUGL			
	K1	K2	D1	D2	K1	K2	D1	D2	K1	K2	D1	D2
$\sigma^2=0.16$ $\rho=0.85$	0.00821	0.0028732	0.00638	0.00738	0.01611	0.03912	0.02013	0.04397967	0.00403	0.00405	0.00590	0.007018
$\sigma^2=0.16$ $\rho=0.90$	0.00931	0.00804744	0.00695	0.00992	0.01590	0.01574	0.01993	0.04515864	0.00397	0.00378	0.00628	0.0097004
$\sigma^2=0.16$ $\rho=0.99$	0.00435	0.0033753	0.00576	0.00651	0.01461	0.01416	0.01792	0.04172915	0.00452	0.00356	0.00483	0.008066
$\sigma^2=0.13$ $\rho=0.85$	0.00676	0.00508561	0.00823	0.00745	0.01588	0.01524	0.01981	0.0439222	0.00365	0.00328	0.00650	0.009857
$\sigma^2=0.13$ $\rho=0.90$	0.00726	0.00204401	0.00244	0.01700	0.01541	0.01414	0.01948	0.04304836	0.00358	0.00312	0.00657	0.019354
$\sigma^2=0.13$ $\rho=0.99$	0.00230	0.00229759	0.00767	0.01659	0.01431	0.01307	0.01744	0.01771142	0.00313	0.00348	0.00542	0.011289
$\sigma^2=0.18$ $\rho=0.85$	0.00568	0.004885	0.03242	0.01734	0.01644	0.01473	0.02039	0.04406047	0.00433	0.00410	0.00720	0.020445
$\sigma^2=0.18$ $\rho=0.90$	0.00438	0.003984	0.04456	0.01687	0.01613	0.01223	0.01990	0.04323199	0.00428	0.00414	0.00730	0.019976
$\sigma^2=0.18$ $\rho=0.99$	0.00242	0.002242	0.04167	0.16468	0.01510	0.01187	0.04841	0.04178483	0.00382	0.00361	0.00614	0.018348

تكملة جدول (2)

المقدرات المعاملات	GJRR				AUGRR			
	K1	K2	D1	D2	K1	K2	D1	D2
$\sigma^2=0.16$ $\rho=0.85$	0.0464279	0.0409906	0.0183274	0.0402224	0.0045734	0.0039581	0.0066261	0.0207534
$\sigma^2=0.16$ $\rho=0.90$	0.0305260	0.01107843	0.042787	0.0419859	0.0040726	0.0035163	0.0074171	0.0190199
$\sigma^2=0.16$ $\rho=0.99$	0.0140120	0.0121988	0.03779978	0.0387761	0.0049630	0.0044675	0.0159715	0.0178410
$\sigma^2=0.13$ $\rho=0.85$	0.0154796	0.0109818	0.0181903	0.0392598	0.0059070	0.0057025	0.0070727	0.0050379
$\sigma^2=0.13$ $\rho=0.90$	0.0165892	0.14107663	0.01938643	0.0299269	0.0041458	0.0040505	0.0095503	0.0200520
$\sigma^2=0.13$ $\rho=0.99$	0.0140734	0.0131565	0.01791099	0.0488166	0.0031685	0.0035087	0.0056528	0.0179861
$\sigma^2=0.18$ $\rho=0.85$	0.0174196	0.0159966	0.05129074	0.0292003	0.0031825	0.0030774	0.0061677	0.0195153
$\sigma^2=0.18$ $\rho=0.90$	0.0155115	0.0147968	0.04923301	0.037 9 618	0.0042469	0.0479837	0.0063776	0.0192266
$\sigma^2=0.18$ $\rho=0.99$	0.0139998	0.1102284	0.0175252	0.038 7 528	0.0039257	0.0035924	0.0057601	0.0180383

Compared the Proposed Method (AUGJRR) with Biased Methods to Estimate the Generalized Ridge Regression of the Existence of Multicollinearity

Assistant Prof. Dr. Saja M. Hussein

sajamh@yahoo.com

Baghdad University - College of Administration and Economics - Statistics Department

Haneen M. Yousif

haneen_m31@yahoo.com

Baghdad University - College of Administration and Economics - Statistics Department

Abstract: *The estimate the parameters of the General linear model, which suffers from a breach in one of the assumptions which is semi multicollinearity between the explanatory variables be using methods of estimating generalized Ridge regression which it will focus our attention in this research such as Generalized Ridge Regression Estimator (GRRE), Modified Jackknife Ridge Regression (MJRRE), Generalized Jackknife Ridge Regression (GJRRE), Generalized Liu Estimator (GLE), Almost unbiased Generalized Liu (AUGLE), Almost unbiased Generalized Ridge Regression (AUGRRE) addition to the proposed method Almost unbiased Generalized Jackknife Ridge Regression (AUGJRRE) Where in this research to derive the*

proposed method (AUGJRRE) to estimate the parameters of the model, which suffers from the problem of multicollinearity and the proposed method were compared with the methods mentioned above as well as the method (ols).

Keywords: multicollinearity , Generalized Ridge Regression Estimator (GRRE), Modified Jackknife Ridge Regression (MJRRE) , Generalized Jackknife Ridge Regression (GJRRE), Generalized Liu Estimator (GLE), Almost unbiased Generalized Liu (AUGLE) , Almost unbiased Generalized Ridge Regression (AUGRRE), Almost unbiased Generalized Jackknife Ridge(AUGJRRE).