

Comparison of some robust methods in the presence of problems of multicollinearity and high leverage points

المقارنة بين بعض الطرائق الحصينة في ظل وجود مشكلة تعدد العلاقة الخطية ونقاط الانعطاف العالية

أ.م. غفران اسماعيل كمال / كلية الادارة والاقتصاد / جامعة بغداد

ghufran62@gmail.com

الباحث / سيف الامام سعدي خزعل / كلية الادارة والاقتصاد / جامعة بغداد

OPEN  ACCESS



P - ISSN 2518 - 5764

E - ISSN 2227 - 703X

Received:27/11/2018

Accepted: 26/12/2018

مستخلص البحث

يعد أنموذج الانحدار الخطى المتعدد من نماذج الانحدار المهمة والمستعملة في تحليل البيانات لمختلف مجالات العلم وعلى نطاق واسع مثل الاعمال والاقتصاد والطب والعلوم الاجتماعية، ان تعدد العلاقة الخطية مشكلة كبيرة في الانحدار الخطى المتعدد اذ تؤدي في ابسط حالتها الى ابتعد معلمات الأنموذج المقدرة على خصائصها العلمية وغالباً ما تعطي استنتاجات مظللة، ايضاً هناك مشكلة هامة في تحليل الانحدار هو وجود نقاط الانعطاف العالية في البيانات مما تؤدي الى تأثيرات غير مرغوب بها على نتائج التحليل.

نستعرض في هذا البحث بعض الطرائق الحصينة في أنموذج الانحدار الخطى المتعدد ومن هذه الطرائق طريقة انحدار الحرف لمقدر ال جاكنایف (Jackknife Ridge Regression) (بالاعتماد على مقدر MM-estimator (MM) ومقدر (GM2)، ومن خلال استعمال المحاكاة بأسلوب مونت كارلو تمت اجراء المقارنة بين هاتين الطريقتين وفق معيار المقارنة متوسط مربعات الخطأ (MSE) وللحجم عينات ($n=20, n=50, n=100$) ونسبة تلوث مختلفة ($\tau = 5\%, 15\%$)، واتضح من خلال المقارنة ان طريقة (RJGM2) هي الافضل في تقدير معلمات أنموذج الانحدار الخطى المتعدد و يمتلك اقل قيمة لمتوسط مربعات خطأ (MSE) مقارنة مع بقية المقدرات الأخرى.

المصطلحات الرئيسية للبحث / الانحدار الخطى المتعدد، تعدد العلاقة الخطية، نقاط الانعطاف العالية، مقدر MM ، مقدر GM2 ، انحدار الحرف لـ جاكنایف .





المقارنة بين بعض الطرائق الحصينة في ظل وجود مشكلة تعددة العلاقة الخطية ونقط الانعطاف العالية

1- المقدمة Introduction

يستعمل أنموذج الانحدار الخطي المتعدد (MLR) في العديد من مجالات الدراسة مثل الاعمال والاقتصاد والطب والعلوم الاجتماعية، فعند دراسة أي ظاهرة يجب تحديد المتغيرات المؤثرة في تلك الظاهرة وصياغة العلاقة بين تلك المتغيرات على هيئة أنموذج، إن العلاقة الخطية بين عدة متغيرات أحدهما متغير معتمد (Dependent Variable) والباقي متغيرات توضيحية (Explanatory variables) يطلق عليها أنموذج الانحدار الخطي المتعدد (MLR)، أن مشكلة تعددة العلاقة الخطية أصبحت معروفة لدى العديد من الباحثين الإحصائيين وتمثل حالة انعدام الاستقلالية بين المتغيرات التوضيحية مما يسبب وجودها تأثيرات على تقديرات وبيانات المعاملات عند تطبيق طريقة المرربعات الصغرى الأعيادية (OLS) وبالتالي تظهر النتائج غير دقيقة، مشكلة مهمة أخرى في تحليل الانحدار هي وجود نقاط الانعطاف العالية (HLPs) (High Leverage Points) والتي تمثل (القياسات غير طبيعية في قيم المتغير x) والتي تسبب في ميل خط الانحدار نحوها بعيداً عن موقعه الحقيقي، وهي على نوعين الجيدة التي تتفق مع خط الانحدار وتساهم في كفاءة التقدير ومنها السينية التي تؤثر على القيم المحسوبة لمختلف التقديرات . [1]

ان نقاط الانعطاف العالية (HLPs) لها تأثيرات كبيرة على الأنموذج الخطي منها التسبب في تضليل البيانات وفشل التحليل كونها تعتبر مصدر اخر لمصادر تعددة العلاقة الخطية واظهرت نتائج دراسة المحاكاة لكل من الباحثان (Imon & Kamruzzaman) (عام 2002م) ان نقاط الانعطاف العالية يمكن ان تولد تعددآ خطيا كبيراً وأن درجته قد تزداد مع زيادة نسبتها في البيانات . [2]

(Kamruzzaman & Imon, 2002:P445) مما يستوجب استعمال طرائق بديلة عن الطرائق التقليدية لمعالجة تلك المشاكل تكون اكثراً كفاءة في التقدير والتي تدعى (بالطرائق التقدير الحصينة) (Robust estimation methods) حيث تتصف أنها قليلة الحساسية تجاه نقاط الانعطاف العالية (HLPs) اذ يتم الحصول عليها من خلال مقدرات حصينة تمتلك كفاءة عالية .

The problem of the research

2- مشكلة البحث

أن أنموذج الانحدار الخطي المتعدد (MLR) يتضمن عدد من المتغيرات التوضيحية التي تكون ذات أداء ضعيف للمقدرات لوجود علاقة خطية بين المتغيرات التوضيحية مما يؤدي لعواقب سينية مثل زيادة في تباينات المقدرات وانخفاض معامل الدقة غالباً ما تكون النتائج مربكة وتعطي استنتاجات مظللة، بالإضافة إلى ذلك وجود نقاط الانعطاف العالية (HLPs) في البيانات التي ستضاف من المشكلة .

The Aim of the Research

3- هدف البحث

الهدف من البحث هو الحصول على أفضل تقيير لمعلمات أنموذج الانحدار الخطي المتعدد (MLR) عند وجود مشكلة تعددة العلاقة الخطية ونقط الانعطاف العالية (HLPs) من خلال استعمال معيار المقارنة متوسط مربعات الخطأ (MSE) للحصول على أفضل مقدر بين المقدرات الأخرى .

4- الجانب النظري

يعطي تحليل الانحدار الاجابات على الاسئلة المتعلقة بالعلاقة الوظيفية للمتغير المعتمد (Y) مع واحد او اكثر من المتغيرات التوضيحية ($X's$)، يضاف مصطلح الخطأ العشوائي الى الأنموذج الاحصائي لحساب الفروق الفردية، أن الدالة الخطية بين Y و X تسمى أنموذج الانحدار الخطي المتعدد (MLR) ويمكن تعريفها على أنها :

$$Y_i = \beta_0 + \beta_1 X_{1i} + \beta_2 X_{2i} + \dots + \beta_k X_{ki} + \varepsilon_i \quad \dots \quad (1)$$

$i = 1, 2, \dots, n \quad j = 0, 1, \dots, K$

النموذج اعلاه يمكن كتابته بشكل مختصر وكالاتي :-



المقارنة بين بعض الطرائق الحصينة في ظل وجود مشكلاتي تعدد العلاقة الخطية ونقاط الانعطاف، العالية

$$Y_i = \sum_{j=0}^k B_j X_{ij} + \varepsilon_i \quad \dots (2)$$

وبدلالة المصفوفات يمكن صياغة أنموذج الخطى العام كما في الشكل الآتى :

$$\underline{y} = \underline{X}\underline{B} + \underline{\varepsilon} \quad \dots (3)$$

$$\begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_i \\ \vdots \\ y_n \end{bmatrix} = \begin{bmatrix} 1 & X_{11} & X_{12} & \cdots & X_{1j} & \cdots & X_{1k} \\ 1 & X_{21} & X_{22} & \cdots & X_{2j} & \cdots & X_{2k} \\ \vdots & \vdots & \vdots & \ddots & \vdots & \ddots & \vdots \\ 1 & X_{i1} & X_{i2} & \cdots & X_{ij} & \cdots & X_{ik} \\ \vdots & \vdots & \vdots & \ddots & \vdots & \ddots & \vdots \\ 1 & X_{n1} & X_{n2} & \cdots & X_{nj} & \cdots & X_{nk} \end{bmatrix} \begin{bmatrix} \beta_0 \\ \beta_1 \\ \vdots \\ \beta_j \\ \vdots \\ \beta_k \end{bmatrix} + \begin{bmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \vdots \\ \varepsilon_i \\ \vdots \\ \varepsilon_n \end{bmatrix}$$

\underline{Y} : موجه مشاهدات المتغير المعتمد من الدرجة ($n * 1$) .

\underline{X} : مصفوفة من الدرجة ($n * k + 1$) وتمثل مشاهدات المتغيرات التوضيحية علماً بأن العمود الاول من هذه المصفوفة يمثل الحد الثابت .

$\underline{\beta}$: موجه المعالم المطلوب تقديرها من الدرجة $1 * (k + 1)$.

k : عدد المتغيرات التوضيحية .

n : عدد المشاهدات .

$\underline{\varepsilon}$: موجه الاخطاء العشوائية من الدرجة ($1 * n$) .

لتقدير معلمات أنموذج الانحدار الخطى المتعدد (MLR) يتم الاعتماد على بعض المقدرات الحصينة وهي :
[3] (كاظم ومسلم، 2002 : 50)

5- بعض مقدرات الانحدار الحصينة

5-1- مقدر MM- estimator

أن مقدر (MM) في التسمية يشير الى استعمال لأكثر من عملية تقدير لمقدر M ، اقترح من الباحث (Yohai) عام (1987) م أن هذا المقدر له العديد من الخصائص الجيدة منها أن لها كفاءة عالية في حالة التوزيع الطبيعي للأخطاء مع نقطة الانهيار العالية، تعد طريقة (MM) واحدة من أكثر المقدرات شيوعاً التي تستعمل في مجال الانحدار الحصين ويكون وفقاً للخطوات التالية :-

1- يتم تحديد مقدر أولى ذو نقطة انهيار عالية، ولكن ليس بالضرورة أن يكون كفؤ، نرمز له بالرمز ($\hat{\beta}_s$) وباستخدامه يتم حساب الباقي الاولية وفقاً للصيغة التالية :-

$$r_i(\hat{\beta}_s) = y_i - x_i' \hat{\beta}_s \quad , \quad 1 < i < n \quad \dots (4)$$

2- يتم حساب مقدر M القياس (σ_n) للباقي الاولية ($r_i(\hat{\beta}_s)$) وفق معادلة M التقديرية لمعملة القياس وبالشكل الآتى :

$$\frac{1}{n} \sum_{i=1}^n p\left(\frac{r_i(\hat{\beta}_s)}{\sigma}\right) = 0,5 \quad \dots (5)$$



المقارنة بين بعض الطرائق الحصينة في ظل وجود مشكلاتي تعدد العلاقة الخطية ونقاط الانعطاف العالية

-3- مقدر $\hat{\beta}_{MM}$ يعرف كمقدار M لـ β باستعمال دالة (re-descending score) :

$$\psi_1(u) = \frac{\partial p_1(u)}{\partial u} \quad \dots \quad (6)$$

عليه فإن مقدر $\hat{\beta}_{MM}$ والذي نرمز له بالرمز $\hat{\beta}_{MM}$ يكون الحل للمعادلة التالية :

$$\sum_{i=1}^n X_{ij} \psi_1 \left(\frac{y_i - x_i' \beta}{\sigma_n} \right) = 0 \quad , \quad j = 1, 2, \dots, k \quad \dots \quad (7)$$

أن تقدير القياس σ_n يتم أيجاده في الخطوة (2) .
اذ أن :

$$r_i(\beta) = y_i - x_i' \beta$$

^[5] (Lukman, et.al, 2015:P58)

- مقدر (GM2) GM2-estimator

اقتراح من قبل الباحثة (Bagheri) عام (2011) م، أن فكرة هذا المقدر تقوم على اساس التعديل لمقدر (GM) (Modified generalized M-estimator) للحصول على مقدر حصين ذو خصائص عالية الكفاءة وأكثر مقاومة لنقطات الانعطاف العالية (HLPs)، يتم تلخيص الطريقة من خلال عدة خطوات على النحو الآتي :

1- يتم حساب الباقي الاولية (r_i) من مقدر S ، ومن ثم أيجاد مقياس للباقي (\hat{t}) وكالآتي :

$$r_i = y_i - \hat{y}_i \quad , \quad i=1, 2, \dots, n \quad \dots \quad (8)$$

$$\hat{t} = 1.4826(1 + 5 / (n - p)) \text{ Median } |r_i| \quad \dots \quad (9)$$

2- يتم أيجاد مصفوفة الاوزان القطرية (W) ، وعناصر القطر هي الاوزان (w_i) من خلال المعادلة الآتية :

$$w_i = \min [1, \{ \frac{x_{0.95, p+1}^2}{RMD^2} \}] \quad , \quad i=1, 2, \dots, n \quad \dots \quad (10)$$

RMD : تمثل مسافة (مهن لوبيس) (Mahalanobis Distance) الحصينة بالاعتماد على المقدار الأدنى للمقياس الإلهي (MVE) .

3- حساب دالة التأثير Ψ^* للباقي المعيارية، وذلك بحل المعادلة الآتية :

$$A = diag \Psi^* \left(\frac{r_i}{\hat{t} * w_i} \right) \quad \dots \quad (11)$$

Ψ^* : مشتقة من دالة التأثير لـ (Huber's) .

4- عليه فإن مقدر (GM2) والذي نرمز له بالرمز $\hat{\beta}_{GM2}$ يمكننا الحصول عليه عن طريق اشتقاق خطوة واحدة لطريقة (Newton Raphson) ويكون بالصيغة الآتية :

$$\tilde{\alpha}_{GM2} = \hat{\beta}_0 + (X' A X)^{-1} X' W \Psi \left(\frac{r_i}{w_i \hat{t}} \right) \hat{t} \quad \dots \quad (12)$$

^[1] (Alguraibawi, et.al, 2015:P311)



المقارنة بين بعض الطرائق الخطية في ظل وجود مشكلاتي تعدد العلاقة الخطية وتقاط الانعطاف العالية

7- طرائق التقدير:

لتقدير معلمات أنموذج الانحدار الخطى المتعدد سيتم الاعتماد في هذا البحث على بعض الطرائق الخصبة :

1-7 طريقة (RJRR) :

A-Robust Jackknife Ridge Regression based on MM- estimator(RJRMM)

B -Robust Jackknife Ridge Regression based on GM2-estimator(RJRGM2)

نظرياً اقترح طريقة ال جاكنيف (Jackknife method) من الباحث (Quenouille) عام 1949 (م) لتقليل التحيز والتباين في التقدير، وان المبدأ الاساسي لهذه الطريقة هو استبعاد جزء من البيانات عند اجراء كل عملية تقدير بحيث أن الجزء المستبعد اما يهمل او يؤخذ بنظر العناية عند التقدير من خلال احتسابه، في عام (1986 م) أقترح (Singh) وأخرون أسلوباً للتحايل على التحيز في انحدار الحرف بالاعتماد على تقنية ال جاكنيف من خلال الصيغة الآتية :

$$y_{-i} = X_{-i}\beta + \varepsilon^* \quad \dots (13)$$

من خلال أنموذج الانحدار الخطى أعلاه بصيغة ال جاكنيف يتم استبعاد قيمة من المتجه y_{-i} يقابلها استبعاد صف بالكامل من المصفوفة X_{-i} حيث ليس من الضروري ان تكون المصفوفة X_{-i} كاملة الربطة للأعمدة، أما بالنسبة لـ β تمثل متجه المعلمات لأنموذج الانحدار .
 ε^* يمثل حد الخطأ العشوائي حيث ان :

$$E(\varepsilon^*) = 0$$

$$\text{Cov}(\varepsilon^*) = \sigma^2 I_{n-1}$$

هذا يكون الأنماذج المختزل لانحدار الحرف الاعتيادي (RR) لـ (B) بصيغة الآتية :

$$\hat{\beta}_{RR(-i)} = (X'_{-i} X_{-i} + kI_p)^{-1} X'_{-i} y_{-i} \quad \dots (14)$$

X_{-i} : الجزء او الصفر المستبعد من المصفوفة X .

y_{-i} : الجزء او القيمة المستبعدة من المتجه y .

بإمكاننا إعادة كتابة المعادلة (14) لأنماذج المختزل لانحدار الحرف الاعتيادي (RR) بالشكل القانوني لـ (α) (Canonical form) بالشكل الآتي :

$$\hat{\alpha}_{RR(-i)} = (Z'_{-i} Z_{-i} + kI_p)^{-1} Z'_{-i} Y_{-i} \quad \dots (15)$$

نأخذ كل من z_i ، y_i لمتجه الأعمدة Z و Y بالتنسيق، تكون الصيغة بالشكل الآتي :
 $\hat{\alpha}_{RR(-i)} = (Z'Z - z'_i z_i + kI)^{-1} (Z'y - z_i y_i) \quad \dots (16)$

[1] (Alguraibawi, et.al, 2015:PP308-309)



المقارنة بين بعض الطرائق الحصينة في ظل وجود مشكلاتي تعدد العلاقة الخطية وتقاط الانعطاف العالية

ومن خلال تطبيق نظرية Binomial Inverse Theorem) نحصل على :

$$\begin{aligned}
 &= \left[B^{-1} + \frac{B^{-1} z_i' z_i B^{-1}}{1 - z_i' B^{-1} z_i} \right] \times (Z'y - z_i y_i) \\
 &= (B^{-1} Z'y - B^{-1} z_i y_i + \frac{B^{-1} z_i' z_i B^{-1}}{1 - z_i' B^{-1} z_i} Z'y - \frac{B^{-1} z_i' z_i B^{-1}}{1 - z_i' B^{-1} z_i} z_i y_i) \\
 &= \hat{\alpha}_{RR} - B^{-1} z_i y_i \left(1 + \frac{z_i' B^{-1} z_i}{1 - z_i' B^{-1} z_i} \right) + \frac{B^{-1} z_i' z_i \hat{\alpha}_{RR}}{1 - z_i' B^{-1} z_i} \\
 &= \hat{\alpha}_{RR} - \frac{B^{-1} z_i (Y_i - z_i' \hat{\alpha})}{1 - z_i' B^{-1} z_i} \\
 \hat{\alpha}_{RR(-i)} &= \hat{\alpha}_{RR} - \frac{B^{-1} z_i e_i}{1 - h_i} \quad \dots (17)
 \end{aligned}$$

[2] (Duran & Akdeniz, 2010:P268)
أذ أن

$$h_i = z_i' (Z'Z)^{-1} z_i \quad , \quad e_i = (Y_i - z_i' \hat{\alpha})$$

موجة البوافي . e_i

عندما مقدر ال جاكنيف يكون وفق الشكل الآتي :

$$p_i = n \hat{\alpha}_{RR} - (n - 1) \hat{\alpha}_{RR(-i)} \quad \dots (18)$$

المعادلة أعلاه تسمى بالقيم غير الأكيدة (الوهمية) (Pseudo – values) لتقدير ال جاكنيف ، من المعادلة (17) و (18) يكون الوسط الحسابي لهذه التقديرات بالصيغة الآتية :

$$\bar{P} = \frac{1}{n} \sum_{i=1}^n P_i = \hat{\alpha}_{RR} + \frac{(n - 1)}{n} B^{-1} \sum_{i=1}^n \frac{z_i e_i}{(1 - h_i)} \quad \dots (19)$$

ان القيم غير الأكيدة في المعادلة (18) تعرف انها متماثلة فيما يتعلق بالمشاهدات ، في حين ان الأنماذج غير متوازن بشكل عام وينعكس نقص التوازن في المسافات (h_i) ، بالإضافة الى ان التباين دالة متزايدة لـ h_i ، يمكننا تعريف القيم غير الأكيدة الموزونة كما في الصيغة الآتية :



المقارنة بين بعض الطرائق الحديثة في ظل وجود مشكلاتي تعدد العلاقة الخطية وتقاط الانعطاف العالية

$$Q_i = \hat{\alpha}_{RR} + n(1 - h_i)(\hat{\alpha}_{RR} - \hat{\alpha}_{RR(-i)}) \quad \dots (20)$$

هنا تكون تقديرات (JRR) (Jackknife Ridge Regression) متماثلة، اي مقدر $\hat{\alpha}_{JRR}(k)$ يعطي وفق الصيغة الآتية :

$$\hat{\alpha}_{JRR}(k) = \bar{Q} = \frac{1}{n} \sum Q_i = \hat{\alpha}_{RR} + B^{-1} \sum z_i e_i \quad \dots (21)$$

[7] (Singh, et.al, 1986:344)

يمكن تبسيط الأنماذج (JRR) بالصيغة الآتية :

$$\begin{aligned} \hat{\alpha}_{JRR}(k) &= (I + kB^{-1})\hat{\alpha}_{RR}(k) \\ &= (I - k^2B^{-2})\hat{\alpha} \end{aligned} \quad \dots (22)$$

علما ان معاملات الانحدار الاصلية لـ (JRR) هي :

$$\hat{\beta}_{JRR} = \gamma \hat{\alpha}_{RR}(k)$$

وان مقدر (JRR) متحيز بالنسبة للمعلومة α ومقدار التحيز هو :

$$Bias(\hat{\alpha}_{JRR}(k)) = -k^2B^{-2}\hat{\alpha} \quad \dots (23)$$

ومصفوفة التباين لمقدر (JRR) كالاتي :

$$Var(\hat{\alpha}_{JRR}(k)) = \sigma^2(I - k^2B^{-2})\Lambda^{-1}(I - k^2B^{-2})' \quad \dots (24)$$

ومصفوفة متوسط مربعات الخطأ لمقدر (JRR) بالشكل الآتي :

$$\begin{aligned} MSE(\hat{\alpha}_{JRR}(k)) &= Var(\hat{\alpha}_{JRR}(k)) + [Bias(\hat{\alpha}_{JRR}(k))] [Bias(\hat{\alpha}_{JRR}(k))]' \\ &= \sigma^2(I - k^2B^{-1})\Lambda^{-1}(I - k^2B^{-1})' + k^4B^{-2}\hat{\alpha}\hat{\alpha}'B^{-2} \end{aligned} \quad \dots (25)$$

ان الصيغة العامة لمقدر (RJRR) يكون كالاتي :

$$\begin{aligned} \hat{\alpha}_{RJRR}(k) &= [I + kB]\tilde{\alpha}_{RR} \\ &= [I + kB^{-1}][I - kB^{-1}]\tilde{\alpha} \\ &= (I - k^2B^{-2})\tilde{\alpha} \end{aligned} \quad \dots (26)$$

وان :

$$k = \frac{P\tilde{\sigma}^2}{\tilde{B}'\tilde{B}} \quad \dots (27)$$

وان :

$$\tilde{\sigma}^2 = \frac{(Y - X\tilde{B})'(Y - X\tilde{B})}{\tilde{B}'\tilde{B}} \quad \dots (28)$$



المقارنة بين بعض الطرائق الحديثة في ظل وجود مشكلتي تعدد العلاقة الخطية ونقاط الانعطاف العالية

عما إن معاملات الانحدار الأصلية لمقدر (RJRR) لـ (α) تعطى بالشكل الآتي :

$$\hat{\beta}_{RJRR} = \gamma \hat{\alpha}_{RJRR}(k)$$

أن مقدر (RJRR) متحيز للمعلمة الأصلية، ومقدار التحيز هو :

$$\begin{aligned} Bias(\hat{\alpha}_{RJRR}(k)) &= E[\hat{\alpha}_{RJRR}(k)] - \alpha \\ &= E[(I - k^2 B^{-2})\tilde{\alpha}] - \alpha \\ &= (I - k^2 B^{-2})E[\tilde{\alpha}] - \alpha \\ &= (I - k^2 B^{-2})\alpha - \alpha \\ &= -k^2 B^{-2} \alpha \end{aligned} \quad \dots (29)$$

والتبين لمقدر (RJRR) يعطى بالشكل الآتي :

$$\begin{aligned} \text{Var}(\hat{\alpha}_{RJRR}(k)) &= E[\hat{\alpha}_{RJRR}(k) - E(\hat{\alpha}_{RJRR}(k))][\hat{\alpha}_{RJRR}(k) - E(\hat{\alpha}_{RJRR}(k))]' \\ &= E[\hat{\alpha}_{RJRR}(k) - \alpha][(\hat{\alpha}_{RJRR}(k) - \alpha)']' \end{aligned} \quad \dots (30)$$

$$= (I - k^2 B^{-2}) \Omega (I - k^2 B^{-2})'$$

ومتوسط مربعات الخطأ (MSE) لمقدر (RJRR) يكون بالشكل الآتي :

$$MSE(\hat{\alpha}_{RJRR}(k)) = \text{Var}(\hat{\alpha}_{RJRR}(k)) + [Bias(\hat{\alpha}_{RJRR}(k))] [Bias(\hat{\alpha}_{RJRR}(k))]'$$

$$= (I - k^2 B^{-2}) \Omega (I - k^2 B^{-2})' + k^4 B^{-2} \alpha \alpha' B^{-2} \quad \dots (31)$$

من الصيغة (26) نعرض المعلمة ($\tilde{\alpha}$) بالمقدار (MM) الحصين حيث تكون الصيغة النهائية لمقدر كالتالي (RJMM) :

$$\begin{aligned} \hat{\alpha}_{RJMM}(k) &= [I + kB]\tilde{\alpha}_{MM} \\ &= [I + kB^{-1}][I - kB^{-1}]\tilde{\alpha}_{MM} \\ &= (I - k^2 B^{-2})\tilde{\alpha}_{MM} \end{aligned} \quad \dots (32)$$

وايضا من للمعادلة (26) نعرض المعلمة ($\tilde{\alpha}$) بالمقدار الحصين (GM2) و تكون الصيغة النهائية للمقدار كالتالي (RJGM2) :

$$\begin{aligned} \hat{\alpha}_{RJGM2}(k) &= [I + kB]\tilde{\alpha}_{GM2} \\ &= [I + kB^{-1}][I - kB^{-1}]\tilde{\alpha}_{GM2} \\ &= (I - k^2 B^{-2})\tilde{\alpha}_{GM2} \end{aligned} \quad \dots (33)$$

[¹] (Alguraibawi, et.al, 2015:PP309-313)



8- الجانب التجاري

1- مفهوم المحاكاة

The Concept of Simulation

بعد اسلوب المحاكاة من الاساليب العلمية الرصينة باعتباره اسلوبًا للاختبار يقوم على اساس اعطاء صورة طبق الاصل لظاهرة حقيقة قبل تطبيق التجربة على بيانات واقعية، لغرض الاستفادة من هذه الصورة في دراسة خواص تلك الظاهرة ومميزاتها، حيث يعتمد اسلوب المحاكاة على اثبات البرهان الرياضي نظريًا.^[1] (الجشعبي، 2007: 34)

ان اسلوب المحاكاة هو عملية تمثيل سلوك الظاهرة الحقيقة قيد الدراسة بشكل تمثل الانموذج المدروس الواقع الحقيقي ، و يمكن ان يعتمد اسلوب المحاكاة في اثبات صحة طريقة معينة يكون من الصعب اثبات صحتها نظرياً، وكلما كانت النتائج دقيقة دل ذلك على ان اسلوب المحاكاة يكون اكثر قرباً للواقع المدروس.^[2] (شهاب، 2017: 43)

2- مراحل تطبيق تجارب المحاكاة

Stages of the application of simulation experiments

لقد تضمنت تجارب المحاكاة لهذا البحث كتابة عدد من البرامج بلغة (R) في توليد البيانات، واقتصرت ثلاثة حجوم للعينة ($n=100$), ($n=50$), ($n=20$) ونسبة توث مختلفة ($\tau = 5\%$ ، 15%)^[1]، وقد تم استعمال الصيغة الآتية في توليد المتغيرات التوضيحية :-

$$X_{ij} = p v_{ik} + (1 - p^2)^{1/2} v_{ij}, \quad i = 1, 2, \dots, n, \quad j = 1, 2, \dots, k$$

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

v_{ik} : يمثل قيم العمود الأخير من اعمدة المتغيرات المولدة .

k : يمثل عدد المتغيرات المرتبطة .

i : يمثل عدد المشاهدات .

p : يمثل قيمة الارتباط بين المتغيرات التوضيحية في الانموذج المدروس، الذي يأخذ القيم $0.90, 0.95, 0.99$.^[1] (Alguraibawi, et.al, 2015:P313)

ويكون الانموذج كالتالي :

$$Y_i = \beta_0 + \beta_1 X_{i1} + \beta_2 X_{i2} + \dots + \beta_k X_{ik} + \varepsilon_i \quad .. (34) \quad i = 1, 2, \dots, n$$

يتم توليد الاخطاء العشوائية وفقاً للتوزيع الطبيعي بمتوسط (صفر) وتباين (σ^2) اي ان :
 $\varepsilon_i \sim (0, \sigma^2)$ ، $i = 1, 2, \dots, n$

وبالنسبة لقيمة الانحراف المعياري فهي $0.5, 1, 1.5, \dots, \sigma$.

يتم تحديد القيم الافتراضية للمعلمات من خلال دراسات سابقة وبافتراض أن عدد المعالم هي $k = 6$ وفقاً للقيم التالية :-

$$\beta_1 = 5, \beta_2 = 3, \beta_3 = \sqrt{6}, \beta_4 = 0, \beta_5 = 0, \beta_0 = 0 \quad .. [4] \quad (Kan, et.al, 2013:P648)$$

ثم يتم تقدير معلمات انموذج الانحدار الخطي المتعدد (MLR) وفق طرائق التقدير التي تم عرضها في الجانب النظري من البحث وهي كما يلي :-

1- طريقة انحدار الحرف (RR) لمقدر ال جاكنايف بالاعتماد على مقدر (RJMM) (MM) .

2- طريقة انحدار الحرف لمقدر ال جاكنايف بالاعتماد على مقدر(GM2) (RJGM2) .

وقد تم الاعتماد على المقياس الاحصائي متواسط مربعات الخطأ(MSE) للانموذج لمعرفة اي النماذج افضل في تمثيل البيانات وكان عدد مرات تكرار التجربة (R=1000) مرة .



8—٣ تحليل نتائج تجربة المحاكاة

Analyzing the results of the simulation experiment

جدول (1) تقدير المعلمات و(MSE) للطريقتين ، وكافية حجم العينات عندما تكون نسبة التلوث ($\tau=5\%$) . وقيمة الانحراف المعياري ($\sigma = 1$) .

Coffe	N	Parameters Methods	$\hat{\beta}_1$	$\hat{\beta}_2$	$\hat{\beta}_3$	$\hat{\beta}_4$	$\hat{\beta}_5$	MSE
$\rho = 0.90$	n=20	RJMM	0.213876	0.20999	0.20863	0.10212	0.12416	0.014047
		RJGM2	0.31949	0.27230	0.24319	0.06064	0.06622	0.01249
	n=50	RJMM	0.25065	0.17109	0.05731	0.10252	0.09237	0.00957
		RJGM2	0.48167	0.29385	-0.0299	0.00786	0.02436	0.00753
	n=100	RJMM	0.12598	0.11411	0.11846	0.10658	0.10446	0.00582
		RJGM2	0.21053	0.15107	0.16763	0.09859	0.09065	0.00551
$\rho = 0.95$	n=20	RJMM	0.19441	0.21181	0.21690	0.11222	0.13002	0.01186
		RJGM2	0.29125	0.26430	0.24253	0.07102	0.07328	0.01119
	n=50	RJMM	0.24999	0.17245	0.06736	0.11688	0.10058	0.00883
		RJGM2	0.50334	0.30061	-0.0621	0.01252	0.02111	0.00728
	n=100	RJMM	0.12718	0.11955	0.12334	0.11595	0.11441	0.00541
		RJGM2	0.19522	0.14513	0.16643	0.10926	0.10178	0.00522
$\rho = 0.99$	n=20	RJMM	0.16647	0.23724	0.25986	0.10714	0.12521	0.01026
		RJGM2	0.289963	0.26008	0.26526	0.03962	0.07908	0.01018
	n=50	RJMM	0.28012	0.18168	0.05966	0.12924	0.09955	0.00810
		RJGM2	0.66635	0.37027	-0.2073	-0.02308	0.02941	0.00711
	n=100	RJMM	0.138178	0.13343	0.13719	0.13260	0.13108	0.00499
		RJGM2	0.18417	0.13747	0.17326	0.11980	0.10954	0.00496



المقارنة بين بعض الطرائق الحديثة في ظل وجود مشكلاتي تعدد العلاقة الخطية و نقاط الانعطاف العالية

جدول(2) تقدير المعلمات و (MSE) للطريقتين، ولكلفة حجم العينات عندما تكون نسبة التلوث ($\tau=5\%$) . وقيمة الانحراف المعياري ($\sigma = 1.5$) .

Coffe	N	Parameters Methods	$\bar{\beta}_1$	$\bar{\beta}_2$	$\bar{\beta}_3$	$\bar{\beta}_4$	$\bar{\beta}_5$	MSE
$\rho = 0.90$	n=20	RJMM	0.18473	0.19654	0.20110	0.07738	0.10546	0.01520
		RJGM2	0.28340	0.25953	0.23804	0.04137	0.05015	0.01266
	n=50	RJMM	0.12111	0.10701	0.10109	0.09288	0.09013	0.01596
		RJGM2	0.22294	0.15039	0.12809	0.09257	0.08784	0.01593
	n=100	RJMM	0.08740	0.07964	0.08395	0.07675	0.07484	0.00753
		RJGM2	0.15491	0.10867	0.13112	0.07943	0.07174	0.00711
$\rho = 0.95$	n=20	RJMM	0.17208	0.20816	0.22058	0.08088	0.10686	0.01611
		RJGM2	0.26637	0.26073	0.24855	0.04025	0.04742	0.01383
	n=50	RJMM	0.12702	0.11308	0.10811	0.10324	0.10132	0.01221
		RJGM2	0.22407	0.14417	0.12259	0.09836	0.09658	0.01156
	n=100	RJMM	0.09509	0.08913	0.09298	0.08756	0.08596	0.00673
		RJGM2	0.15100	0.10812	0.13389	0.08668	0.07878	0.00642
$\rho = 0.99$	n=20	RJMM	0.14250	0.25549	0.29369	0.05336	0.08750	0.01938
		RJGM2	0.28771	0.27179	0.30409	-0.03643	0.03812	0.01960
	n=50	RJMM	0.30866	0.16922	-0.0168	0.08828	0.04639	0.01259
		RJGM2	0.79406	0.42444	-0.3773	-0.11089	-0.11054	0.01111
	n=100	RJMM	0.10998	0.10489	0.10967	0.10491	0.10274	0.00695
		RJGM2	0.15097	0.10279	0.14727	0.09297	0.07936	0.00693



المقارنة بين بعض الطرائق الحديثة في ظل وجود مشكلاتي تعدد العلاقة الخطية و نقاط الانقطاع العالية

جدول (3) تقدير المعلمات و (MSE) للطريقتين ، ولكافحة حجوم العينات عندما تكون نسبة التلوث $\rho = 0.90$ وقيمة الانحراف المعياري $(\sigma = 1)$ و $(\tau = 15\%)$.

Coffe	N	Parameters Methods	$\hat{\beta}_1$	$\hat{\beta}_2$	$\hat{\beta}_3$	$\hat{\beta}_4$	$\hat{\beta}_5$	MSE
$\rho = 0.90$	n=20	RJMM	0.21387	0.20999	0.20863	0.10212	0.12416	0.01404
		RJGM2	0.31949	0.27230	0.24319	0.06064	0.06622	0.01249
	n=50	RJMM	0.25065	0.17109	0.05731	0.10252	0.09237	0.00957
		RJGM2	0.48167	0.29385	-0.0299	0.00786	0.02436	0.00753
	n=100	RJMM	0.12598	0.11411	0.11846	0.10658	0.10446	0.00582
		RJGM2	0.21053	0.15107	0.16763	0.09859	0.09065	0.00551
$\rho = 0.95$	n=20	RJMM	0.19441	0.21181	0.21690	0.11222	0.13002	0.01186
		RJGM2	0.29125	0.26430	0.24253	0.07102	0.07328	0.01119
	n=50	RJMM	0.24999	0.17245	0.06736	0.11688	0.10058	0.00883
		RJGM2	0.50334	0.30061	-0.0621	0.01252	0.02111	0.00728
	n=100	RJMM	0.12718	0.11955	0.12334	0.11595	0.11441	0.00541
		RJGM2	0.19522	0.14513	0.16643	0.10926	0.10178	0.00522
$\rho = 0.99$	n=20	RJMM	0.16647	0.23724	0.25987	0.10714	0.12521	0.01026
		RJGM2	0.28996	0.26008	0.26526	0.03962	0.07908	0.01018
	n=50	RJMM	0.28012	0.18168	0.05966	0.12924	0.09955	0.00810
		RJGM2	0.66635	0.37027	-0.2073	-0.02308	-0.02941	0.00711
	n=100	RJMM	0.13817	0.13343	0.13719	0.13260	0.13108	0.00499
		RJGM2	0.18417	0.13747	0.17326	0.11980	0.10954	0.00496



المقارنة بين بعض الطرائق الحديثة في ظل وجود مشكلاتي تعدد العلاقة الخطية و نقاط الانقطاع العالية

جدول (4) تقدير المعلمات و (MSE) للطريقتين ، ولكافحة حجوم العينات عندما تكون نسبة التلوث . وقيمة الانحراف المعياري ($\sigma = 1.5\%$) .

Coffe	N	Parameters Methods	$\hat{\beta}_1$	$\hat{\beta}_2$	$\hat{\beta}_3$	$\hat{\beta}_4$	$\hat{\beta}_5$	MSE
$\rho = 0.90$	n=20	RJMM	0.18504	0.19528	0.20032	0.07817	0.10580	0.02321
		RJGM2	0.28380	0.25765	0.23790	0.04353	0.04924	0.02215
	n=50	RJMM	0.21261	0.13888	0.02280	0.07539	0.06197	0.01385
		RJGM2	0.45060	0.26984	-0.0915	-0.01845	-0.00559	0.01145
	n=100	RJMM	0.08733	0.07976	0.08373	0.07653	0.07480	0.00776
		RJGM2	0.15466	0.10977	0.12987	0.12987	0.07952	0.00747
$\rho = 0.95$	n=20	RJMM	0.17286	0.20711	0.21896	0.08197	0.10722	0.02049
		RJGM2	0.26706	0.25900	0.24766	0.04342	0.04619	0.02019
	n=50	RJMM	0.23127	0.14732	0.02410	0.08570	0.06555	0.013187
		RJGM2	0.50844	0.29377	-0.1412	-0.02800	-0.01964	0.01123
	n=100	RJMM	0.09504	0.08914	0.09292	0.08743	0.08588	0.00735
		RJGM2	0.15087	0.10857	0.13355	0.08652	0.07867	0.00719
$\rho = 0.99$	n=20	RJMM	0.14458	0.25377	0.28908	0.05508	0.08939	0.01822
		RJGM2	0.29000	0.27218	0.29967	-0.03164	0.03520	0.01854
	n=50	RJMM	0.30642	0.16823	-0.0143	0.08929	0.04773	0.01259
		RJGM2	0.78643	0.41721	-0.3690	-0.10590	-0.10728	0.01113
	n=100	RJMM	0.10998	0.10489	0.10967	0.10491	0.10274	0.00695
		RJGM2	0.15097	0.10279	0.14727	0.09297	0.07936	0.00693



المقارنة بين بعض الطرائق الحديثة في ظل وجود مشكلتي تعدد العلاقة الخطية ونقطة الانعطاف العالية

9- مناقشة تجرب المحاكاة في حالة وجود تلوث ($\tau = 5\%$, $\sigma = 5\%$)

من خلال النتائج المبينة بالجدول (1) (2) (3) (4) نلاحظ ما يلي :-

1- يتضح لنا ان قيمة متوسط مربعات الخطأ (MSE) للأنموذج تتناقص كلما زاد حجم العينة ولجميع طرائق التقدير المدروسة .

2- في حالة في حالة وجود تلوث ($\tau = 5\%$) وتوزيع الاخطاء التوزيع الطبيعي بمتوسط (0) وانحراف معياري ($\sigma = \sigma$) نلاحظ من خلال مقياس المقارنة (MSE) للجدول (1) ان طريقة (RJGM2) افضل طريقة عند احجام العينات ($n=100$, $n=50$, $n=20$) وعندما تكون قيمة معامل الارتباط ($p = 0.99$, 0.90 , 0.95) وذلك لا نها حققت اقل قيمة ل(MSE) للأنموذج.

3- وايضاً عند وجود تلوث ($\tau = 5\%$) وتوزيع الاخطاء التوزيع الطبيعي بمتوسط (0) وانحراف معياري ($\sigma = 1.5$) للجدول (2) ومن خلال المقياس (MSE) للأنموذج نلاحظ ان طريقة (RJGM2) هي افضل طريقة عند احجام العينات ($n=100$, $n=50$, $n=20$) عندما تكون قيمة معامل الارتباط ($p = 0.90$, 0.95) ، ايضاً حققت طريقة (RJGM2) الافضلية من خلال معيار المقارنة (MSE) للأنموذج وعند احجام العينات ($n=100$, $n=50$, $n=20$) عندما تكون قيمة معامل الارتباط ($p = 0.99$) ، بينما حققت طريقة (RJMM) اقل قيمة ل (MSE) عند حجم العينة ($n=20$) .

4- وفي حالة وجود التلوث ($\tau = 15\%$) وتوزيع الاخطاء بالتوزيع الطبيعي بمتوسط (0) وانحراف معياري ($\sigma = 1$) نلاحظ من خلال مقياس المقارنة (MSE) للجدول (3) ان طريقة (RJGM2) افضل طريقة عند احجام العينات ($n=100$, $n=50$, $n=20$, $n=20$) عندما تكون قيمة معامل الارتباط ($p = 0.99$, 0.95 , 0.90) وذلك لا نها حققت اقل قيمة ل (MSE) للأنموذج ، ايضاً حققت طريقة (RJGM2) للجدول (4) الافضلية لا قل قيمة لمعيار المقارنة (MSE) عند احجام العينات ($n=20$, $n=50$, $n=100$) عند قيمة معامل الارتباط ($p = 0.90$, 0.95) ، وايضاً الافضلية عندما تكون قيمة معامل الارتباط ($p = 0.99$) لا حجام العينات ($n=50$, $n=100$) ، بينما حققت طريقة (RJMM) الافضلية عند حجم العينة ($n=20$) كونها حققت اقل قيمة لمتوسط مربعات الخطأ (MSE) .

10- الاستنتاجات والتوصيات

1- الاستنتاجات

1- اظهرت نتائج المحاكاة لهذا البحث ان طريقة (RJGM2) هي الافضل، و تمتلك اقل قيمة لمتوسط مربعات الخطأ (MSE) مقارنة مع الطريقة الاخرى .

2- ايضاً اثبتت طريقة (RJGM2) اكبر كفاءة في حالة زيادة حجم العينات ونسب التلوث العالية .

3- اثبتت طريقة (RJMM) كفاءتها عند حجم العينات الصغيرة .

2- التوصيات

1- استعمال طريقة (RJGM2) في تقدير معلمات أنموذج الانحدار الخطي المتعدد (MLR) وباختلاف احجام العينات لما تبديه من كفاءة ومرنة في التطبيق .

2- اعتماد طريقة (RJGM2) في تقدير معلمات أنموذج الانحدار الخطي المتعدد (MLR) في حالة احجام العينات الكبيرة ونسب تلوث العالية .

3- اعتماد طريقة (RJMM) عند حجم العينات الصغيرة .



المقارنة بين بعض الطرائق الحصينة في ظل وجود مشكلاتي تعدد العلاقة الخطية ونقاط الانعطاف العالية

11- المصادر العربية

1. الجشعبي، حسين علي عبد الله 2007 م، " مقارنة بعض المقدرات الحصينة لمعالم النماذج اللاخطية " اطروحة دكتوراه في الاحصاء كلية الادارة والاقتصاد الجامعة المستنصرية .
2. شهاب ، ضميماء حامد (2017) م، " مقارنة بعض طرائق التقدير الحصينة مع أسلوب بيز في تقدير دالة الانحدار اللوجستي مع تطبيق عملي " اطروحة دكتوراه في الاحصاء كلية الادارة والاقتصاد الجامعة المستنصرية .
3. كاظم، اموری هادی و مسلم، باسم شلبيه 2002م، " القياس الاقتصادي المتقدم النظرية والتطبيق" ، مكتبة دنيا الامل ، بغداد .

12- المصادر الاجنبية

- 1.Alguraibawi‘ M., Midi‘ H., & Rana‘ L. S. (2015) “Robust Jackknife Ridge Regression to Combat Multicollinearity and High Leverage Points in Multiple Linear Regressions” Economic Computation and Economic Cybernetics Studies and Research, NO. 4، PP 305-322.
- 2.Duran, E. A ., and Akdeniz, F. (2010) “Efficiency of the Modified Jackknifed Liu-Type Estimator” Statistical Papers, NO. 53, PP 265-280.
- 3.Kamruzzaman, MD, and Imon, A.H.M.R. (2002) “High leverage point, another source of multicollinearity” Pakistanian Journal of Statistics·NO. 18,PP 435-448.
- 4.Kan‘ B., Alpu, Ö., & Yazıcı B. (2013) “Robust Ridge and Robust Liu Estimator for Regression Based on the LTS Estimator” Journal of Applied Statistics, NO. 40 (3),PP 644-655.
- 5.Lukman, A. F., Osowole‘ O. I. & Ayinde, K.(2015) “Two Stage Robust Ridge Method in a Linear Regression Model” Journal of Modern Applied Statistical Methods, NO. 14(2), PP 53-67.
- 6.Midi, H., and Mohammed .M.A (2015) “The Identification of Good and Bad High Leverage Points in Multiple Linear Regression Model” Mathematical Methods and System in Science and Engineering, PP 147-153.
- 7.Singh, B., Chaubey, Y. P., & Dwivedi, T. D. (1986) “An almost unbiased ridge estimator” The Indian Journal of Statistics, NO.48 (3), PP 342-346.



Comparison of some robust methods in the presence of problems of multicollinearity and high leverage points

Ghufran Ismail Kamal / Assistant Prof- College Of Administration & Economics- University Of Baghdad-Statistics section - ghufran62@gmail.com .

Researcher Saif alelam saadi khazaal / College Of Administration & Economics- University Of Baghdad-Statistics section- saif.alemams@gmail.com

Abstract

The multiple linear regression model of the important regression models used in the analysis for different fields of science Such as business, economics, medicine and social sciences high in data has undesirable effects on analysis results . The multicollinearity is a major problem in multiple linear regression. In its simplest state, it leads to the departure of the model parameter that is capable of its scientific properties, Also there is an important problem in regression analysis is the presence of high leverage points in the data have undesirable effects on the results of the analysis , In this research , we present some of the robust methods in the multiple linear regression model These methods include the (Jackknife Ridge regression) methods based on the (MM) estimator and the (GM2) estimator (Modified Generalized M-estimator) . Using the Monte Carlo simulation, the two methods were compared in accordance with the comparison criterion, the mean squares error (MSE) and sample sizes ($n = 20, n = 50, n = 100$) and different pollution ratios ($\tau = 5\%, 15\%$) , The comparison shows that (RJGM2) is the best method for estimating the parameters of the multiple linear regression model, which has the lowest value for mean squares error (MSE) compared with the rest of the other estimations.

Keywords : Multiple Linear Regression , Multicollinearity, high leverage point,

Jackknife ridge regression, MM-estimator, GM2-estimator.