

AL-Rafidain
University College

PISSN: (1681-6870); EISSN: (2790-2293)

مجلة كلية الرافدين الجامعية للعلومAvailable online at: <https://www.jrucs.iq>**JRUCS**Journal of AL-Rafidain
University College
for Sciences**ترجح طريقة GM6 لتقدير معلمات عالية الحسانة لنموذج الانحدار الخطى المتعدد**

أ.م.د. حسن سامي عربى	نور علوان عوده
hassan.uraibi@qu.edu.iq	noor.alwan2@qu.edu.iq

قسم الاحصاء، كلية الادارة و الاقتصاد، جامعة القادسية، القادسية، العراق

معلومات البحث**تاریخ البحث:**

تاریخ تقديم البحث: 23/2/2024
 تاریخ قبول البحث: 12/4/2024
 تاریخ رفع البحث على الموقـع: 31/12/2024

الكلمات المفتاحية:GM6, MM, IDRGP, RMVN,
HLP**للمراسلة:**اسم الباحث : د. حسن سامي عربى
hassan.uraibi@qu.edu.iqDOI: <https://doi.org/10.55562/jrucs.v56i1.3>**المستخلص**

يعد نموذج الانحدار الخطى المتعدد أحد الاساليب الاحصائية الأكثر استعمالا في العديد من المجالات العلمية. اذ يتم تقدير معلمات النموذج باستخدام طريقة المرءات الصغرى الاعتيادية التي تعطي أفضل تقدير خطى غير متحيز عند تحقق فرضياتها، أحد من هذه الفرضيات ان توزيع حد الخطأ العشوائى يكون طبيعيا بمتوسط صفر وتباين ثابت. ان وجود القيم الشاذة يؤدي الى خرق هذا الافتراض وعليه لا يمكن تطبيق طريقة المرءات الصغرى. لقد ظهرت الطرائق الحصينة كبديل مناسب عند ظهور القيم الشاذة مثل ،طريقة M، LMS ومقبر S الا ان ظهور النقاط الرافعة Leverage Points كنوع اخر من القيم الشاذة في فضاء المتغيرات التوضيحية ادى الى عدم دقة تقديرات هذه الطرائق. لقد اقترح في الادبيات الإحصائية طرائق مميزة جدا مثل طريقة مقرر MM وطريقة GM6 لكن ظهور مشكلة النقاط الرافعة العالمية High Leverage Points يعزى سبب وجودها مصدرها ظاهري ظاهري (Masking & Swamping). هاتين الظاهرتين تشير الى عدم الدقة في تشخيص النقاط الرافعة مما يسبب اما الخسارة في المعلومات او عدم معالجة النقاط الرافعة الرديئة بالكامل. ان مقترح هذا البحث يسعى الى تحسين أداء طريقة GM6 حتى مع وجود هاتين الظاهرتين من خلال توظيف خوارزمية تشخيص عالية الدقة تدعى IDRGP(RMVN) من اجل الحصول على اوزان عالية الدقة لتقليل اثر النقاط الرافعة في طريقة GM6. لقد وضعنا التشخيص الدقيق وطريقة GM6 في إطار خوارزمي واحد أطلقنا عليه (GM6.IDRGP(RMVN) التي أظهرت أداء مميزا مقارنة بالطرق السابقة من خلال نتائج دراسة المحاكاة والبيانات الحقيقة.

1. المقدمة Introduction

أن الانحدار الخطى المتعدد الذي يقوم بالأساس في تقسير ودراسة مدى تأثير المتغيرات المستقلة على المتغير المعتمد يعتمد على مجموعة من الفرضيات الأساسية التي يجب توفرها. عند مخالفة إحدى هذه الفرضيات يكون التحليل غير دقيق كأن تكون الأخطاء العشوائية لا تتوزع طبيعيا بسبب وجود القيم الشاذة. القيمة الشاذة تعرف على أنها القيمة التي تكون منحرفة عن باقي المشاهدات كما عرفها [1] وفي غالب تكون غير منسجمة و بعيدة عن مركز تجمع البيانات، و ان سبب عدم الانسجام قد يعود الى انها قيمة غير منطقية بسبب أخطاء في التسجيل [2] او انها تولدت من توزيع مختلف عن توزيع معظم البيانات كما وصفها [3]. تصنف القيم الشاذة في نماذج الانحدار الخطى المتعدد حسب موقع وجودها فتلك التي توجد في الخطأ العشوائي والمتغير المعتمد والتي يطلق عليها مصطلح (Outliers)، أما القيم الشاذة التي تظهر في مصفوفة المتغيرات التوضيحية يطلق عليها مصطلح النقاط الرافعة التي يمكن تصنيفها الى جيد و رديء كما ان هناك النقاط الرافعة العالمية Leverage Point (LP) High Leverage Point (HLP) [4].

ان المقدرات الحصينة يجب ان تتمتع بالكفاءة ونقطة انهيار عاليتان تثبت قدرتها على مقاومة القيم الشاذة، ولذلك لا تعد مقدرات طريقة المرءات الصغرى كفؤة عند وجود القيم الشاذة في مجموعة البيانات لأن قيمة نقطة انهيارها تكون صفراء. لمعالجة مثل هذه المشكلة اقترح العديد من الباحثين عددا من الطرائق الحصينة في الادبيات الإحصائية مثل [5][عام 1981] قدموا طريقة M-estimate التي استبدلت دالة الخسارة التربيعية للأخطاء بدالة حصينة و بأسلوب شبه لا معلمى يعتمد على إعادة ترجيح الأخطاء من خلال دالة Huber وبأسلوب تكراري، عام (1984) اقترح [6] طريقة وسيط المرءات الصغرى Least Median of Squares (LMS) التي اختزلت احتساب حسانة المقدرات على نحو 50% من حجم بوافي الانحدار بعد اخضاعها للإحصاء

الترتيبى، و في عام (1987) اعلن عن طريقة المربعات الصغرى المشذبة [7] Least Trimmed of Squares (LTS) التي عملت على تقليل مجموع مربعات البواقي المشذبة بعد ان يتم ترتيبها تصاعديا او تنازليا. على الرغم من ان هذه الطرائق الحصينة تملك نقطة انهيار تصل الى 0.50 الا ان كفافتها متباعدة وقد تصل نقطة انهيارها الى الصفر عن ظهور نقطة رافعة رديئة واحدة على الأقل في مصفوفة المتغيرات التوضيحية. لذلك دعت الحاجة لاقتراح طرائق بديلة لها القدرة على مقاومة القيم الشاذة والنفاقة الرافعة، لذلك اقترح [8] طريقة (MM) التي تمنع بكفاءة عالية تصل الى 95% و نقطة انهيار تبلغ 0.50 و طريقة GM التي وضع خطواتها الاولى [9] التي تعمل على ترجيح النقاط الرافعة بعد تشخيصها. تعد طريقة مسافة Mahalanobis للكشف على النقاط الرافعة العالية واحدة من اهم الطرق الا ان [10] اظهرا ان اعتماد هذه المسافة على الوسط الحسابي و مصفوفة التباين والتباين المشترك التقليدية قد يؤدي الى حدوث ظاهرتي Masking & Swamping و لذلك اقترح استخدام مصفوفة الموقع و القياس الحصينة بدلا عنهما. اذ ان ظاهرة Masking تحدث عندما تشخص الطريقة قيمة شاذة واحدة على الأقل و لكن واقعا هذه القيمة تخفي و تغطي على قيمة او قيم شاذة أخرى. اما ظاهرة Swamping فهي خطأ في التشخيص من خلال عدم مشاهدة طبيعية واحدة على الأقل على انها شاذة مما تقدم يتضح ان أي خطأ في تشخيص النقاط الرافعة بسبب وجود الـ HLP يؤدي بالضرورة الى عدم الدقة في التقدير.

2. الكشف الكلى للنقاط الرافعة

لجا الكثير من الباحثين الى تحصين مسافة Mahalanobis عن طريق ابدال مدخلاتها التي تعتمد على الوسط الحسابي والتباين بمعلمي الموقع والقياس الحصينة للتخلص من ظاهرتي Masking & Swamping. لكن هذه الإجراءات لم تساعدهم من التخلص الكلى من هاتين الظاهرتين لأنهم استخدمو ما يسمى بطرق التشخيص الفردي. لذلك قدم [11] طريقة Potential measure (GP) Generalized Potential measure عام (2002) للتشخيص الكلى و هي تعتمد طريقة (GP) اقتراها [12] عام (1992). حفز اقتراح [11] باحثين آخرين لتحسين أداء هذه الطريقة، لذلك قدمت Midi وآخرون عام (2009) [13] خوارزمية DRGP (MVE) كطريقة لتشخيص العدد الكلى للـ HLP من خلال الدمج بين النهجين السابعين. فالتشخيص الأولي يكون باستخدام MD الحصينة بالإضافة على (MVE) Minimum Volume Ellipsoid و من ثم وضع الصفوف المشكوك باحتواها على النقاط الرافعة العالية في مصفوفة تدعى مصفوفة الحذف D ، اما الصفوف الغير مشكوك تتوضع في مصفوفة أخرى و تطبق منهج GP ، و من ثم إعادة فحص صفوف مصفوفة الحذف فيما اذا كانت تحتوي على نقاط رافعة باستخدام منهج Potential measure .

إذ لاحظ [14] عام (2015) ان تأثير للـ Masking and Swamping Diagnostic مازال موجودا على طريقة DRGP(MVE) Robust Generalized Potential based on MVE عندما تكون نسبة HLP تتراوح بين 5% و 10%. وقد أعزى السبب إلى إن تشخيص HLP في الخطوة الثانية من خوارزمية DRGP(MVE) التي وضعتها في مصفوفة الحذف التي أطلق عليها D لم يتم التتحقق منها بشكل صحيح. لذلك اقترح (IDRGP(MVE)) Improvise DRGP based on MVE (IDRGP(MVE)) من خلال إضافة خطوة جديدة إلى خوارزمية التشخيص باستخدام hat matrix التي وضع المصفوفة المشكوك بها في مصفوفة الحذف D₂ ومن ثم اجرى مقاطعة للتشخيصين (D, D₂) للتحقق من التشخيص الأول D ، فيتم الاحتفاظ على ما تم التوافق عليه بين المصفوفتين من حيث التشخيص و ما لم يتم التوافق عليه يعاد إلى مصفوفة المشاهدات النظيفة.

لقد اثبتت [15] ان استخدام مصفوفة الموقع و القياس MVE مع مسافة مهالوبىز غير كافي للتخلص من هذه المشكلة وان خطأ التشخيص في هذه المرحلة لا يصح في مرحلة مصفوفة القبعة Hat matrix لوجود علاقة ما بين مسافة مهالوبىز و هذه المصفوفة، هذا بالإضافة إلى إمكانية فقدان مصفوفة القبعة إلى دقة التشخيص لكون عتبة التشخيص للمصفوفة غير ثابتة وتناولتها الأدبيات على ثلاث عتبات الامر الذي يجعل عدم التخلص التام من مشكلة Masking & Swamping امر منطقيا، لذلك اقترحنا طريقة IDRGP(RMVN) من خلال وضع خوارزمية (RMVN) Re-weighted Multivariate Normal (RMVN) ذات التركيز العالى جدا في إطار خوارزمي واحد مع طريقة التشخيص الكلى :

3. الطريقة المقترحة GM6.IDRGP(RMVN)

تم اقتراح هذه الطريقة بناء على خوارزمية IDRGP(RMVN) المقترحة من قبل [15] إذ تتبع نفس الخطوات فقط يتم ابدال مصفوفة الموقع و القياس بـ RMVN مكان MVE لكي تحافظ على كفاءة الطريقة وتحصينها من تأثير نقاط الرفع العالية وايضا معالجة ظاهرتي Masking & Swamping وتخفيف تأثيرها بنسب عالية. إذ كانت الخوارزميات السابقة تعاني من هذه المشكلة على الرغم من تخفيض Masking & Swamping إلا إنها لم تخلص من تأثيرها بشكل كافٍ. لذلك قمنا في الطريقة المقترحة تكوين تركيبة من خلال توظيف خوارزمية [15]، لتكون دالة وزن حصينة لطريقة التقدير GM6 و يتم توضيح ذلك من خلال الخطوات الآتية:

1. توظيف الخوارزمية المقترحة من قبل (Uaribi&Haraje,2022) التي عملت على ابدال مصفوفة الموقع و القياس RMVN بـ MVE لحساب مسافة مهالوبىز الحصينة RMD(RMVN) عن طريق الآتى:

$$RMD(RMVN) = \sqrt{(X_i - T_{RMVN}(X))^T C^{-1} RMVN(X) (X_i - T_{RMVN}(X))}$$

2. تكون الأوزان الأولية الجديدة لطريقة GM6 بعد توظيف خوارزمية IDRGP(RMVN) محسوبة بالشكل الآتى:

$$\pi_i = \min \left\{ 1, \frac{\chi^2_{(k,0.95)}}{RMD(RMVN)} \right\}$$

3. احسب المقدر الأولي $\hat{\beta}$ باستخدام طريقة المربعات الصغرى المشنبة (LTS).
 4. احسب الواقي (r_i) ومقدر القياس $\tilde{\sigma}$ عن طريق الصيغة الآتية:

$$\tilde{\sigma} = (1.4826) [(1 + \frac{5}{n-k-1}) med|r_i|]$$

5. حساب دالة وزن لإيجاد مقدر GM كالاتي

$$W_i = \pi_i \psi \left(\frac{r_i}{\pi_i \tilde{\sigma}} \right) X_i$$

6. احسب قيم جديدة لـ $\hat{\beta}$ باستخدام طريقة المربعات الصغرى المشنبة (LTS) مع الاوزان.
 $\hat{\beta}_{GM} = (X'WX)^{-1}X'Wy$

7. كرر الخطوات من (4-6) إلى أن يتم الوصول لمقدر الطريقة المقترحة GM6.IDRGP(RMVN) إلى التقارب.

4. المحاكاة Simulation

ليكن نموذج الانحدار الخطى المتعدد الآتى :

$$y = X\beta + e$$

حيث أن X هي مصفوفة المتغيرات التوضيحية ذات بعد $(p+1) \times n$ المولدة من توزيع طبيعي متعدد المتغيرات بمتوسط قيمته صفرأ و تباين $\alpha^{ij} = \rho$ اي أن $X \sim N(0, \rho^{ij} I_p)$

حيث أن $p=3$ و $n=50$ و $\beta = \{25, 50, 0.5\}$ و $\alpha = 0.5$ هي متوجه الوحدة لمعلمات هذا النموذج مع الحد الثابت $\beta_0 = 1$ ، أما α فهو متوجه الأخطاء العشوائية للنموذج يتوزع طبيعياً بمتوسط قيمته صفر تباين ثابت. قام الباحث باختبار كفاءة طرق التقدير خلال الحالات الآتية:

✓ **الحالة الأولى:** توليد حد الخطأ العشوائي e من توزيع مختلط وفقاً للصيغة الآتية

$$e = [(1 - \alpha) \times n] \sim N(0, 2) + [\alpha \times n] \sim \chi^2_{(25, 0.95)}$$

حيث $\{0.05\} = \alpha$ وضرب أعظم قيمة في X_1 وأعظم قيمة في y بالرقم (50) لضمان وجود الـ HLP ومن ثم ضرب $[n \times \alpha]$ من قيم X_2 و X_3 بالرقم (10) لضمان وجود الـ LP's.

✓ **الحالة الثانية:** تختلف هذه الحالة عن الحالة الثانية بجعل توزيع الخطأ العشوائي توزيعاً طبيعياً مختلطًا بتضخيم الوسط الحسابي وجعل موقع القيم الشاذة على نفس صفوف النقاط الرافعه العليا المذكورة في الحالة الثانية كالاتي:

$$e = [\alpha \times n] \sim N(5, 2) + [(1 - \alpha) \times n] \sim N(0, 2)$$

✓ **الحالة الثالثة:** لا تختلف هذه الحالة عن الحالة الثالثة سوى ان الباحث رجع متوسط التوزيع الطبيعي الملوث الى الصفر و ضخم التباين الى الـ (25)، هذا بالإضافة جعل موقع القيم الشاذة بمواقع لا تناظر النقاط الرافعه العليا كالاتي:

$$e = [(1 - \alpha) \times n] \sim N(0, 25) + [\alpha \times n] \sim N(0, 2)$$

اخضع الباحث الحالات السابقة الى 5000 دورة محاكاة لكل نسبة تلوث α التي ولدت n من المشاهدات لكل نموذج. تم في كل دورة محاكاة تقدير معلمات نموذج الانحدار $\hat{\beta}$ بوجود الحد الثابت $\beta_0 = 0, 1, 2, 3$. لقد اعتمدت الباحثة على متوسط مربعات خطأ تقدير المعلمات لأجمالي دورة المحاكاة كمعيار للمفاضلة بين طرق التقدير،

$$Mse(\hat{\beta}_j) = \frac{\sum_{j=1}^{5000} (\hat{\beta}_j^* - \beta_j)^2}{5000}$$

فالطريقة التي تحقق اقل قيمة لـ $Mse(\hat{\beta}_j)$ لكل معلمة مقدرة او لأغلب المعالم المقدرة بما فيها الحد الثابت. من ناحية أخرى قام الباحث برسم $Mse(\hat{\beta}_j)$ لحالات المحاكاة الأربعه كمخرجات لكل طريقة ذلك بهدف معرفة فيما اذا أداء الطرق ثابتًا مع تغيير حالات المحاكاة ام لا ، مع ملاحظة ان الطريقة الأفضل هي التي ستظهر ان خط رسم $Mse(\hat{\beta}_j)$ لكل معلمة مقدرة يكون تحت خطوط التقدير لبقية الطرق.

لفرض قياس كفاءة الطريقة المقترحة تمت مقارنتها مع مقدري M لـ Huber و Bisquer و طريقي LMS و LTS بالإضافة الى مقدري S و MM
 (1) عندما $n=25$ ونسبة التلوث في البيانات $\alpha=0.05$

جدول (1) لطرق التقدير لـ $Mse(\hat{\beta})$ 5000 دورة لكل حالة محاكاة عندما $n = 25$, $\alpha = 0.05$

Method	α	$Mse(\hat{\beta}_0)$	$Mse(\hat{\beta}_1)$	$Mse(\hat{\beta}_2)$	$Mse(\hat{\beta}_3)$
M_{hub}	Case 1	3.738	24.067	1.3066	0.957
M_{bisq}		2.705	24.093	1.316	0.957
LMS		2.008	1.341	1.141	1.053
LTS		1.910	1.262	1.115	1.004
S estimator		1.531	0.902	0.766	0.691
MM-Estimator		1.290	0.632	0.538	0.456
REWLSE		1.266	0.600	0.488	0.423
GM6.IDRGP(RMVE)		1.122	0.412	0.357	0.337
M_{hub}	Case 2	1.872	3.688	0.895	0.770
M_{bisq}		1.850	3.692	0.912	0.800
LMS		1.973	1.548	1.424	1.068
LTS		1.871	1.459	1.329	1.126
S estimator		1.628	0.960	0.939	0.742
MM-Estimator		1.360	0.663	0.559	0.490
REWLSE		1.325	0.601	0.534	0.449
GM6.IDRGP(RMVE)		0.823	0.354	0.321	0.316
M_{hub}	Case 3	3.444	21.777	8.277	5.194
M_{bisq}		3.176	21.831	7.493	5.521
LMS		1.919	1.290	1.283	1.164
LTS		1.819	1.311	1.166	1.105
S estimator		1.561	0.858	0.822	0.850
MM-Estimator		1.266	0.724	0.559	0.497
REWLSE		1.292	0.651	0.513	0.481
GM6.IDRGP(RMVE)		0.753	0.406	0.377	0.342

من النتائج المعروضة في الجدول (1) للحالات الأربع للمحاكاة عندما عدد المشاهدات (25) و بوجود 5% من القيم الشاذة.

لقد لجأت الباحثة الى اسلوب مناقشة النتائج للحالات الأربع للمحاكاة لبقية المعلم المقدرة كالتالي:

- أولاً $Mse(\hat{\beta}_0)$: نلاحظ في جميع ان $Mse(\hat{\beta}_0)$ المقترن هو اقل بكثير من بقية الطرق و انه تغير الحالات من الأولى الى الثالثة اظهر أداء قويا و متسقا، اذ انخفضت قيمته من (0.792) في الحالة الأولى الى (0.585) في الحالة الثانية و أخير الى (0.546) في الحالة الثالثة. اما بقية الطرق لم تكن مستقرة فقط سجلت ارتفاعا ملحوظا في الحالة الثانية و من ثم سجلت انخفاضا جديدا في الحالة الثالثة للدلالة على عدم الاستقرار. ان اقرب الطرق لها هي طريقي ، MM ، REWLSE .

- أولاً $Mse(\hat{\beta}_1)$: ان في كافة حالات المحاكاة X_1 تضمنت بياناتة نقطة رفع عالية واحدة HLP تقع في موقع عشوائي ربما يكون مختلفا عن موقع القيم الشاذة و النقاط الرافعة. هذا لا يعني ان الأسلوب العشوائي المتبوع قد لا يجعل موقع HLP على نفس الصف المفهرس لمواقع القيم الشاذة و النقاط الرافعة. عموما لمناقش النتائج حسب الحالات كالتالي:

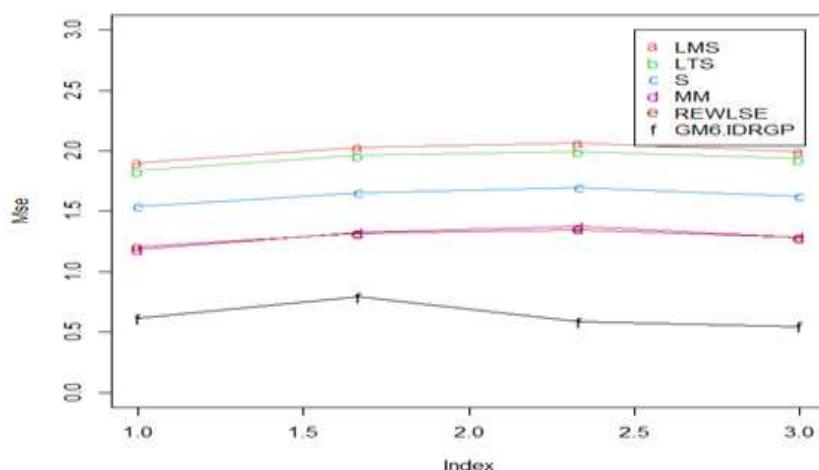
- Case 1: نلاحظ للمقترح GM6.IDRGP(RMVE) الذي اظهر مقاومة عالية ليعطي باقل قيمة لمتوسط مربعات الخطأ (0.43)، على العكس من طريقي M_{hub} و M_{bisq} اللتان تتبعان اسلوب الترجيح لبواقي الانحدار قد تأثرتا تماما بالنقطة الرافعية العالية HLP من جانب و موقع القيم الشاذة في صف الصف المفهرس للنقاط الرافعية من جانب اخر، لتنتج لنا متوسط مربعات خطأ لمعلماتها يصل الى (20.905, 20.883). بالمقابل ان طريقي LMS,LTS كان اقل تأثيرا من سابقتها بسبب ان هاتين الطريقيتين تستخدمان اسلوب الحذف او التشذيب، فطريقة LMS تعامل مع 50% من البيانات كإحصاء ترتيبى، في حين LTS تعمل على تشذيب نسبة محددة من البيانات مكافئة لنسبة القيم الشاذة في بواقي الانحدار وبإحصاء ترتيبى أيضا. بناء على ذلك فان هاتين الطريقيتين شملت هذه HLP النقاط الرافعية LP's بالحذف لكنها لم تتمكن من تأثير الحذف الذي بدوره خفض درجات الحرية الامر الذي رفع التباين. بالتأكيد طرق التقدير REWLSE ، MM ، S كانت اقل تأثيرا من الطرق السابقة في حساب $Mse(\hat{\beta}_1)$ وان REWLSE و MM و LMS و LTS تتحسن للنقاط الرافعية ولكن بدرجة اقل من طرق الحذف و الترجيح السابقة.

- Case 2: نلاحظ ان قيمة $Mse(\hat{\beta}_1)$ في الحالة الثانية قد تغير بالنسبة لطرق الترجيح M_{hub} و M_{bisq} و أظهرت حساسية اقل لـ HLP و النقاط الرافعية و السبب يعود في ذلك الى ان القيم الشاذة و النقاط الرافعية وقعتا على نفس الصيغ المفهرسة و

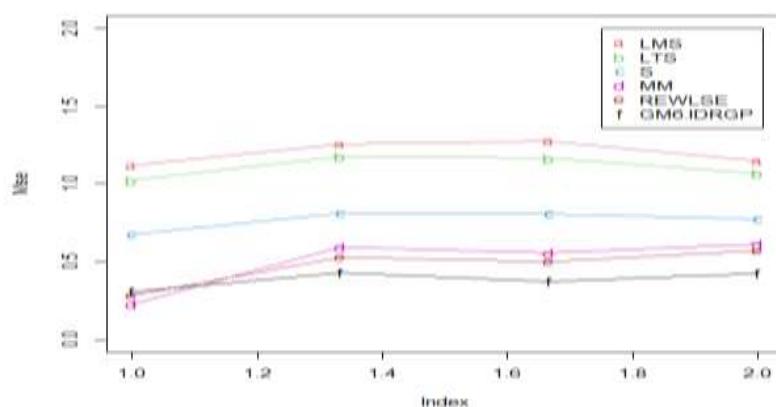
لذلك الترجيح شمل الباقي المفهرسة على نفس تلك الصيغ. بكلام آخر ان كل البيانات سوف تضرر بدالة ترجيح واحدة وعليه القيم الشاذة و النقاط الراجعة المفهرسة على نفس الصيغ ستضرر بنفس القيمة المرجحة و التي بالتأكيد هدفها تقليل تأثير القيم الشاذة و لذلك ظهرت قيمة متوسط مربعات الخطأ لهاتين الطريقتين (3.255 ، 3.256). اما طريقة LMS لم تتأثرا كثيرا بهذه التغيير لذلك اظهرت نتيجة متقاربة مع الحالة الأولى للمحاكاة. اما طريقة LTS اظهرت اداء افضل من اداءها في الحالة الأولى لأن عملية التنشيب لم رفعت من درجات الحرارة في الحالة الأولى لكون النقاط و الراجعة و القيم الشاذة وقعت على نفس المفهرس و هي في الاداء شأنها شأن تقديرات الطرق S، MM، REWLSE مع الحفاظ على ذات الافضلية السابقة. الملاحظ ان المقترن GM6.IDRGP(RMVE) قدم اداء افضل حتى من الحالة الأولى للمحاكاة حيث ان متوسط مربعات الخطأ انخفض من (0.43) الى (0.373) لتتفوق على الطرق الأخرى في الحالة الثانية أيضا.

Case3 : ان ارتفاع قيمة متوسط مربعات الخطأ لطرق الترجيح M_{hub} و M_{bisq} الى (17.096 ، 17.188) ليس نتيجة لتضخيم تباين للتوزيع الطبيعي الملوث للتوزيع الطبيعي لباقي الانحدار و انما جاء بسبب اختلاف مواقع النقاط الراجعة عن القيم الشاذة و لذلك ظهر تأثير هذه الحالة على هاتين الطريقتين اسوة بتاثيرهما بالحالة الأولى للمحاكاة، مع محافظة الطرق الأخرى على نفس الاداء الغير مستقر ما عدا المقترن GM6.IDRGP(RMVE) الذي اظهر قدرة عالية على التعامل مع الحالات الثلاث للمحاكاة بل باداء افضل في الحالة الثالثة من اداءها في الحالة الأولى و الثانية على الرغم من تفوقه على الطرق الأخرى في جميع الحالات.

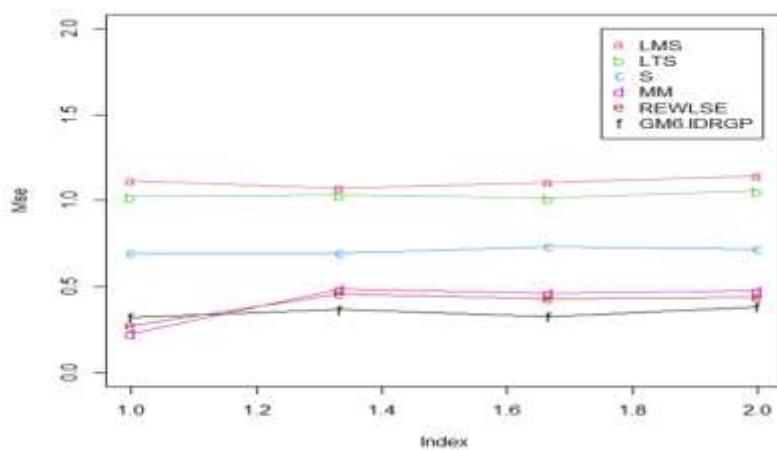
لقد سعينا الى رسم متوسط مربعات الأخطاء لطرق التقدير أولا من خلال بيانات نظيفة و خالية تماما من أي نوع من أنواع القيم الشاذة كحالة قياسية تضاف للحالات الثلاث لدراسة المحاكاة. من الشكل (1-3) الذي يظهر بما لا يقبل الشك ان $Mse(\hat{\beta}_0)$ لمقترح GM6.IDRGP(RMVN) يتتفوق على الطرق الأخرى في الحالة القياسية و الحالات الثلاث الأخرى للمحاكاة مع تقارب شبه تام في اداء كل من REWLSE، MM. الشكل (2) يعرض رسميا لنتائج $Mse(\hat{\beta}_1)$ لطرائق الستة في الحالة القياسية و حالات المحاكاة الثلاث. من الواضح في الحالة القياسية لهذا النموذج هناك تفوق في اداء طريقتي MM و REWLSE على الطرق S و GM6.IDRGP(RMVE) في النماذج الأخرى للمحاكاة مع بقاء تفوق الطريقتين السابقتين على الطرق الأخرى.



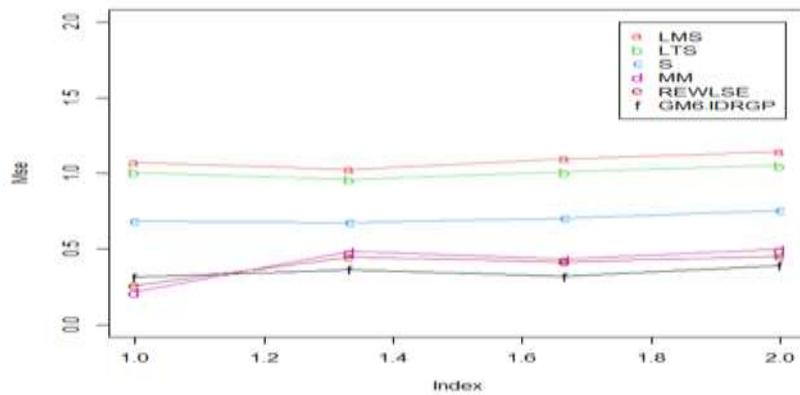
شكل (1): $Mse(\hat{\beta}_0)$ لطرق التقدير الحصينة لكل حالات المحاكاة عندما $\alpha = 0.05, n = 25$



شكل (2): $Mse(\hat{\beta}_1)$ لطرق التقدير الحصينة لكل حالات المحاكاة عندما $\alpha = 0.05, n = 25$

شكل (3): $Mse(\hat{\beta}_2)$ لطرق التقدير الحصينة لكل حالات المحاكاة عندما $n = 25$

هذا التفوق لمقرر هنا استمر في تقدير $Mse(\hat{\beta}_2)$ كما هو واضح في الشكل (3) و الشكل (4) مع أداء ثابت لكل الطرق تقريرياً في الحالة القياسية او في حالات المحاكاة.

شكل (4): $Mse(\hat{\beta}_3)$ لطرق التقدير الحصينة لكل حالات المحاكاة عندما $n = 25$

(2) عندما يكون حجم العينة $n=50$ و نسبة التلوث في البيانات $\alpha=0.05$

جدول (2): $Mse(\hat{\beta})$ لطرق التقدير لـ 5000 دورة محاكاة عندما $n = 50$ ، $\alpha=0.05$

Method	α	$Mse(\hat{\beta}_0)$	$Mse(\hat{\beta}_1)$	$Mse(\hat{\beta}_2)$	$Mse(\hat{\beta}_3)$
M_{hub}	Case 1	2.275	11.146	0.662	0.581
M_{bisq}		1.619	11.155	0.656	0.575
LMS		1.493	0.581	0.529	0.533
LTS		1.459	0.561	0.534	0.539
S estimator		1.311	0.376	0.384	0.379
MM-Estimator		1.122	0.221	0.306	0.302
REWLS		1.115	0.194	0.251	0.248
GM6.IDRGP(RMVN)		0.675	0.171	0.151	0.154
M_{hub}	Case 2	1.486	2.116	0.562	0.527
M_{bisq}		1.393	2.127	0.539	0.506
LMS		1.506	0.578	0.512	0.523
LTS		1.487	0.568	0.504	0.521
S estimator		1.340	0.381	0.364	0.355
MM-Estimator		1.153	0.214	0.235	0.221
REWLS		1.138	0.184	0.218	0.197
GM6.IDRGP(RMVN)		0.527	0.159	0.149	0.136

M_{hub}	Case 3	1.773	11.937	2.199	1.754
M_{bisq}		1.607	11.697	1.663	1.363
LMS		1.511	0.555	0.533	0.518
LTS		1.481	0.557	0.538	0.521
S estimator		1.321	0.386	0.372	0.358
MM-Estimator		1.116	0.315	0.241	0.247
REWLSE		1.122	0.265	0.215	0.217
GM6.IDRGP(RMVN)		0.503	0.168	0.159	0.152

من النتائج المعروضة في الجدول (2) للحالات الأربع للمحاكاة عندما عدد المشاهدات (50) و بوجود 0.05 من القيم الشاذة.
لقد لجأت الى اسلوب مناقشة النتائج للحالات الأربع للمحاكاة لبقية المعلم المقدرة كالتالي:

- **Aولاً ($\widehat{Mse}(\beta_0)$):** عند مقارنة متوسط مربعات الاخطاء للمعلم المقدرة لجميع الطرق الحصينة مع الطريقة المقترحة اعطت الطريقة المقترحة GM6.IDRGP(RMVN) اقل قيمة مقارنة مع الطرق الاخرى في ظل وجود القيم الشاذة الانها حافظت على كفاءتها وقدرتها على المقاومة وعدم الانهيار، بينما اعطت الحالة الثالثة افضل تقدير قوي متسق بلغت قيمته (0.503) واوضحت استقرارها العالي مقارنة مع الحالات الاخرى اما الحالة الثانية التي اعطت نتيجة مقاربة الثالثة(0.527) الا ان الحالة الاولى سجلت قيمة مقاربة لطرق التقدير الاخرى. اعطت الطريقتان (REWLS,MM) نتائج مقاربة اليها.

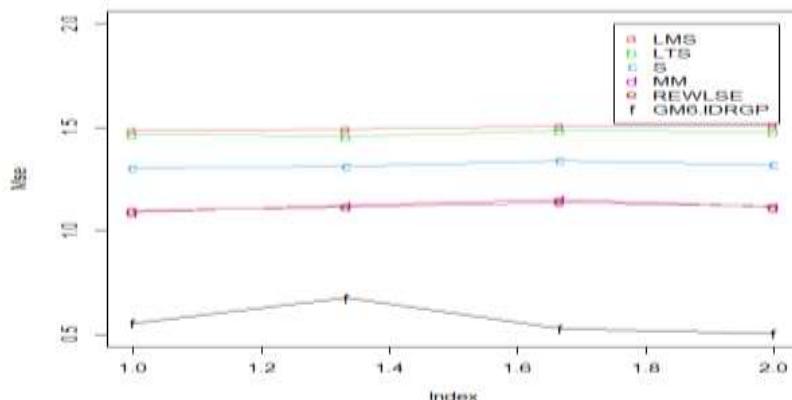
- **أولاً ($\widehat{Mse}(\beta_1)$:** يتم مقارنة متوسط مربعات الاخطاء للمعلمات المقدرة بالطرق التقدير الحصينة في ظل وجود نقاط الرفع والقيم الشاذة ونقط الرفع العالية HLP ، بالاعتماد على($\widehat{Mse}(\beta_1)$) حيث نلاحظ قيمتها عالية وهذا يدل على وجود نقاط الرفع والقيم الشاذة على موقع مختلف وهذا الامر لا يعني بان نقاط الرفع العالية HLP تكون في اتجاه بعيد عن موقع نقاط الرفع والشاذة في حالة كون الصف يحتوي على هذه القيم، لذلك يتم مناقشة النتائج حسب الحالات بالشكل الآتي:-

❖ Case1: بناء على نتائج المحاكاة في الجدول اعلاه لوحظ ان طريقتنا المقترحة GM6.IDRGP(RMVN) قد تفوقت على الطرق الاخرى بإعطاء اقل متوسط مربعات الاخطاء للمعلمات المقدرة وثبتت قدرتها العالية على مقاومة القيم الشاذة ونقط الرفع ونقط الرفع العالية HLP، حيث سجلت الحالة الاولى قيمة تصل الى (0.171) وكانت قيمة كل من الطريقتين (MM,S) قريبة في المقاومة لهكذا نوع من القيم حيث اعطت طريقة S قيمة تصل الى (0.376) بينما اعطت MM (0.221) بينما ابديت طريقتين Mhub و Mbisq فشلها في مقاومة نقاط الرفع العالية HLP ونقط الرفع على الرغم من مقاومتها لقيم الشاذة في الصف الذي يحتوي على هذه القيم.

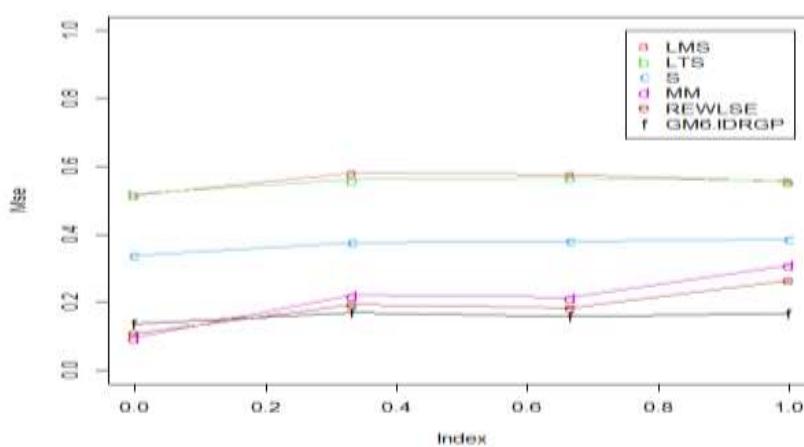
❖ Case 2: نلاحظ ان قيمة متوسط مربعات الاخطاء ($\widehat{Mse}(\beta_1)$) في الحالة الثانية سجلت عند الطريقة المقترحة GM6.IDRGP(RMVN) افضل النتائج حيث اعطت (0.159)، وهذه القيمة ابديت مقاومتها لوجود القيم الشاذة ونقط الرفع ونقط الرفع العالية HLP. في الصف الذي يحتوي عليها كما سجلت كل من (MM,S) نتائج مقاربة من الطريقة المقترحة، حيث اعطت الطريقة الاولى قيمة مقدارها (0.381) وتعد جيدة في مقاومة تأثير القيم في صف مصفوفة المتغيرات المستقلة، بينما اعطت طريقة MM قيمة (0.214) وهي تعد طريقة مقاومة لتأثير القيم الشاذة ونقط الرفع ولكنها لم تستطع مقاومة تأثير نقاط الرفع العالية HLP ، ولكن طريقة تعد قريبة للطريقة المقترحة ،حيث تعد افضل الطرق الحصينة لمقاومة هذه القيم الرديئة بينما بلغت كل من الطريقتين (LTS,LMS) قيم متقابلة في مقاومة القيم الشاذة ولكنها لم تظهر مقاومة لنقط الرفع العالية HLP ونقط الرفع حيث اعطت متوسط مربعات الاخطاء بلغت طريقة LMS (0.578)، حيث تعتمد هذه الطريقة على استخدام الوسيط كملعبة للموقع بدلا من الوسط الحسابي، لكي تقلل من تأثير القيم الشاذة وفي نفس الوقت تحصن المعلم وعلى نفس النهج سجلت طريقة LTS التي تعمل على تضليل نسب من البيانات لتقليل من تأثير القيم الشاذة وكذلك تعمل على ترتيب البيانات كما في طريقة LMS. اي اعطت قيمة (0.568) من متوسط مربعات الخطأ وتماشيا على ما تم ذكره سجلت الطريقتان (Mbisq,Mhub) نتائج مقاربة حيث اعطت Mbisq قيمة (0.116) واعطت الطريقية الاخرى على نفس النهج قيمة (0.127).ويلاحظ من خلال هذه القيم ان الطريقتان تقاوم تأثير القيم الشاذة في البيانات الا انها فشلان في المقاومة امام وجود نقاط الرفع ونقط الرفع العالية HLP في الصف الذي يحتوي على القيم الشاذة لذلك اعطت كلتا الطريقتين متواضعات اخطاء عالي جدا مقارنة بالطرق التقدير الحصينة الاخرى التي سجلت قيم مقاومة لا يأس بها، ولكن طريقتنا المقترحة ثبتت تفوقها في تقدير معلمات النموذج في ظل وجود تأثير القيم الشاذة ونقط الرفع وكذلك نقاط الرفع العالية HLP واعطت مقدر كفؤ من خلال تقليل متوسط مربعات الاخطاء.

❖ Case3: في الحالة الاخيرة من المحاكاة نلاحظ بقى الطريقة المقترحة GM6.IDRGP(RMVN) على مقاومتها وكفاءتها في اعطي افضل التقديرات وكذلك اقل متوسط مربعات اخطاء ، اذا كانت قيمتها (0.168) وهي قيمة عالية المقاومة لتأثير القيم الشاذة ونقط الرفع ونقط الرفع العالية HLP، على الرغم من اختلاف مواقعها من النموذج مقارنة بالطرق الحصينة الاخرى وكذلك سجلت كل من (S-estimator,MM -Estimator,REWLS) قيم متقابله على التوالي في مقاومة هذه القيم حيث كانت القيم الآتية (0.386,0.315,0.265) لكل طريقة ،في حين سجلت الطريقتان (Mbisq,Mhub) قيم (11.697,11.937) على التوالي وهي قيم عالية مقارنه بطريق الاخرى والطريقة المقترحة وهذا يعني اثبات ان الطريقتان ابدت فشلهم في اعطي متوسط مربعات اخطاء منخفض و عدم قدرتها على تقدير معلم النموذج في ظل وجود القيم

الشادة ونقط الرفع ونقط الرفع العالية. لقد تطرقنا الى رسم متوسط مربعات الأخطاء لطرق التقدير أولاً من خلال بيانات نظيفة و حالية تماماً من أي نوع من أنواع القيم الشادة كحالة قياسية من خلال الشكل (4) الذي يظهر بان الطريقة المقترحة GM6.IDRGP(RMVN) قد تفوقت على الطرق التقدير الحصينة الاخرى وهذا في حالة القياسية وكذلك الحالات الاخرى للمحاكاة، مع ملاحظة وجود تقارب بعض نتائج المحاكاة للطرق الحصينة.

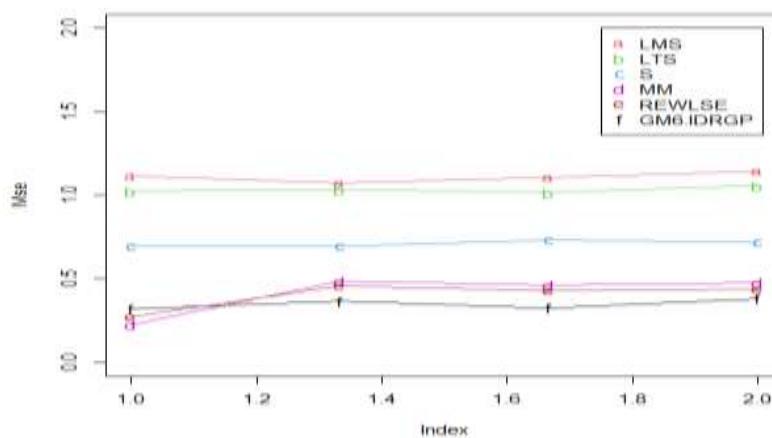


شكل (5): $Mse(\hat{\beta}_0)$ لطرق التقدير الحصينة لكل حالات المحاكاة عندما $n=50, \alpha=0.05$



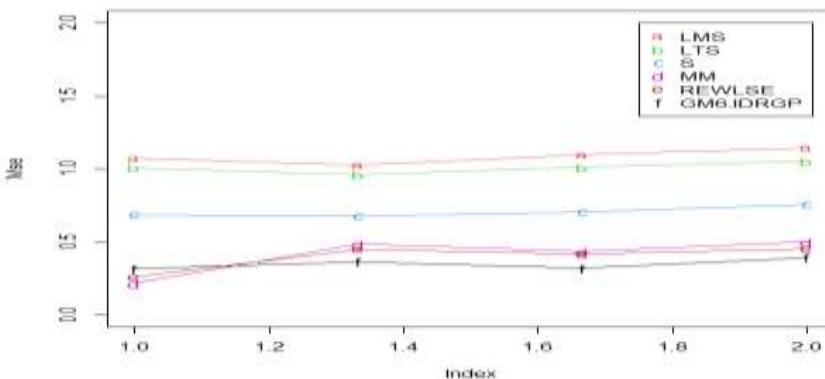
شكل (6): $Mse(\hat{\beta}_1)$ لطرق التقدير الحصينة لكل حالات المحاكاة عندما $\alpha=0.05, n=50$

الشكل (5) يوضح نتائج متوسط مربعات الأخطاء لطرق التقدير الحصينة الخمسة مع الطريقة المقترحة حيث ابتد طريقتنا المقترحة تفوقها واستقرارها في حالة المحاكاة، كما اعطت الطريقتان REWLSE,MM نتائج متقاربة وتفوقها على الطرق الاخرى.



شكل (7): $Mse(\hat{\beta}_2)$ لطرق التقدير الحصينة لكل حالات المحاكاة عندما $\alpha = 0.05, n=50$

من خلال الشكل (7) والشكل (8) نلاحظ استمرار تفوق الطريقة المقترحة بأعطاء اداء ثابت لكل حالات المحاكاة، من خلال تسجيلها اقل متوسط مربعات اخطاء وكما ان الطريقة REWLSE,MM من خلال الشكلين ادت عمل مقارب وتفوقتا على الطرق الاخرى من خلال اعطى متوسط مربعات اخطاء كاد يكون قريب من الطريقة المقترحة، اما الطرق الحصينة الاخرى كانت بعيدة جداً في اداءها عن طریقتنا وهذا يلاحظ اعطى متوسط مربعات اخطاء عالي في نتائج وحالات المحاكاة.



شكل (8): $Mse(\beta_3)$ لطرق التقدير الحصينة لكل حالات المحاكاة عندما $\alpha=0.05$, $n = 50$ ، $y = \beta_0 + \beta_1x_1 + \beta_2x_2 + \beta_3x_3 + \epsilon$

5. بيانات القيمة السوقية:

تم الحصول على هذه البيانات من الموقع الرسمي لسوق العراق للأوراق المالية، إذ تم جمع البيانات السنوية لقيمة السوقية لتسعة من المصادر المحلية الأكثر تداولاً والمسجلة في سوق العراق للأوراق المالية في المدة (2011 – 2015) . إذ تعد هذه البيانات هي شهرية وكما تضمنت أربعة متغيرات وهي (نسبة التداول، معدل سعر السهم السنوي، الموجودات والقيمة السوقية) وكان حجم العينة ($n=45$), (Uraibi & Haraje, 2022). إذ اعتبرنا ثلاثة من هذه المتغيرات توضيحية أو تفسر حجم القيمة السوقية وفقاً لأنموذج الانحدار الخطي المتعدد يمكن وصفه كالتالي :

$$y = \beta_0 + \beta_1x_1 + \beta_2x_2 + \beta_3x_3 + \epsilon$$

حيث إن y : تمثل القيمة السوقية، x_1 تمثل نسبة التداول، x_2 : تمثل معدل سعر السهم السنوي، x_3 : تمثل الموجودات، ϵ : حد الخطأ العشوائي.

نلاحظ من خلال الجدول(2) أعلاه مقارنة معلمات نموذج الانحدار الخطي المتعدد والتي تم تقدير معالمها بواسطه طريقة M_{hub} قد سجلت β_3 أقل قيمة من قيم معلم الأخرى، وعند مقارنة الخطأ المعياري للمعلم نلاحظ أنَّ قيمة β_2 أعطت أقل قيمة عند مقارنتها مع الأخطاء المعيارية للمعلم الأخرى. إذ عند انتقال طريقة M_{bisq} ومقارنة معالمها نلاحظ أنَّ β_3 قد أعطت أقل قيمة، والخطأ المعياري للمعلم الأنماذج اتجه نحو قيمة β_3 إذ سجلت أقل قيمة من بين الأخطاء المعيارية الأخرى. في نفس الصدد أعطت طريقة LMS التي تعتمد على ترتيب المشاهدات تصاعدياً وتركز على مقياس الوسيط في تقدير معلم الأنماذج كون الوسط الحسابي حساس لقيمة الشاذة، وعند مقارنة قيم معلم لهذه الطريقة الحصينة سجلت β_3 أقل قيمة من المعلم الأخرى وأقل خطأ معياري من بين الأخطاء المعيارية الأخرى للمعلم. ويتم مقارنة جميع قيم معلم الأنماذج والأخطاء المعيارية لمعلم الأنماذج، بنفس الطريقة إذ إنَّ قيمة المعلمة والأخطاء المعيارية لطرائق التقدير الحصينة لها تعطى أقل قيمة هي أفضل طريقة حصينة في تقدير معلم مقارنة بقيم معلم الأخرى. وفي هذا السياق نلاحظ من خلال مقارنة طرائق التقدير الحصينة على أساس قيمة للأخطاء المعياري مقارنه مع الطرائق الحصينة الأخرى.

مقياس الخطأ المعياري لبواقي الأنماذج ،إذ سجلت الطريقة الحصينة المقترحة GM6.IDRGP(RMVN) أقل وهذا يعني توقف طریقتنا المقترحة على الطرائق الأخرى الحصينة أي أنها استطاعت أن تقاوم تأثير القيم الشاذة ونقاط الرفع العالية في البيانات وأعطت أفضل النتائج، في حين أنَّ طريقة REWLSE أعطت أعلى خطأ معياري للبواقي في الأنماذج من بين الطرائق الأخرى وهذا يعني فشل هذه الطريقة من مقاومة تأثير القيم الشاذة ونقاط الرفع العالية في البيانات إذ إنَّ هذه الطريقة لا يعول عليها في تقدير معلم الأنماذج. أمَّا الطرائق الأخرى فكانت نسبة الأخطاء المعيارية فيها متقاربة ولكن لا تعد أنها جيدة من ناحية التقدير كونها تتأثر بوجود نقاط الرفع العالية والقيم الشاذة، على رغم من أنَّ طريقة MM تعد من أكثر الطرائق الحصينة شيوعاً واستخداماً في الأبحاث العلمية إلا أنها لم تبدِ أي مقاومة بتأثير نقاط الرفع العالية في البيانات. نلاحظ من خلال مقارنة قيم معامل التحديد لطرائق التقدير الحصينة مع الطريقة الحصينة المقترحة بوجود نقاط الرفع العالية والقيم الشاذة ، وبلا شك أنَّ طريقة التقدير الحصينة المقترحة أعطت أفضل قيمة لمعامل التحديد إذ إنَّ قيمة معامل التحديد التي تقرب من الواحد هي أفضل قيمة من التي تقترب من الصفر وذلك يعني إنَّ الأنماذج قادر على أن يفسر البيانات بشكل دقيق وقوى. وبالتالي يمكن استخدام الطريقة التي تعطي أكبر معامل تحديد في تحصين معلمات نموذج انحدار الخطي المتعدد بوجود نقاط الرفع العالية والقيم الشاذة.

6. الاستنتاجات Conclusions

من النتائج المعروضة في الجداول السابقة نستنتج بأن طريقة لعملية التشخيص الدقيق دور مهم في تحديد حصانة طريقة التقدير و ان عملية دمج طريقة التشخيص الكلي المقترحة GM6.IDRGP(RMVN) مع طريقة التقدير كان لها الأفضلية على

كافة الطرق الأخرى وتحديداً عند وجود النقاط الرافة العالية و حدوث ظاهرتي (Masking & Swamping). من خلال الجانب التجريبى للمحاكاة وباستخدام معيار متوسط مربعات الاخطاء للمقارنة بين اداء الطرائق الحصينة والطريقة المقترحة وكما تم توضيح رسم المعلم المقدرة لكل طريقة بوجود نسبة تلوث في البيانات وبحجم عينة محدد، فقد لاحظنا تقدم اداء الطريقة IDRGP(RMVN) بتسجيل أقل متوسط مربعات اخطاء وكافة حالات محاكاة بينما اعطت الطرائق الأخرى الحصينة نتائج متقاربة في المقاومة لتأثير القيم الشاذة ونقاط الرفع العالية HLP. من جانب اخر أظهر الجانب التطبيقي للبيانات الحقيقة (بيانات القيمة السوقية) نتائج جيدة للطريقة المقترحة GM6.IDRGP(RMVN) من خلال استخدام مجموعه من المعايير للمقارنة في ما بين طریقتا و الطرائق الأخرى كمعامل التحديد والخطأ المعياري لبواقي النموذج، وبحجم عينة 45 وبوجود النقاط الرافة في البيانات حيث كان اداء الطريقة المقترحة متوفقاً في معرفة مدى تأثير المتغيرات على القيمة السوقية.

الجدول (2) (يبين قيم $\hat{\beta}$ ، $Se(\hat{\beta})$ ، الخطأ المعياري لبواقي لأنموذج Se. Model ومعامل التحديد R^2)

Method	$\hat{\beta}$	$Se(\hat{\beta})$	Se. Model	R^2
M_{hub}	-0.221	0.039	0.193	0.18
	0.215	0.046		
	0.261	0.051		
	0.434	0.05		
M_{bisq}	-0.261	0.035	0.198	0.126
	0.151	0.041		
	0.275	0.046		
	0.415	0.045		
LMS	-0.265	0.047	0.139	0.175
	0.215	0.055		
	0.212	0.061		
	0.422	0.061		
LTS	-0.162	0.05	0.134	0.168
	0.223	0.058		
	0.175	0.066		
	0.655	0.065		
S	-0.294	0.065	0.190	0.153
	0.197	0.075		
	0.209	0.084		
	0.41	0.083		
MM	-0.296	0.035	0.193	0.516
	0.133	0.04		
	0.278	0.043		
	0.374	0.045		
$REWLSE$	-0.293	0.036	0.199	0.518
	0.134	0.041		
	0.276	0.044		
	0.376	0.046		
$GM6.IDRGP(RMVN)$	-0.113	0.021	0.104	0.884
	0.261	0.034		
	0.196	0.038		
	0.668	0.049		

References

- [1] Bross, I.D.J. (1961), "Outliers in Patterned Experiments: strategic Re-Appraisal". Technometrics. 3,19-102.
- [2] Barnett, Vic, & Lewis, Toby. (1994). Outliers in statistical data (Vol. 3): Wiley New York.
- [3] Freeman, R. B. (1980). Unionism and the Dispersion of Wages. ILR Review, 34(1).
- [4] Keller, G. & Brian Warrack, (2000),"Statistic For Management and Economics, "5th edition, Duxbury, Thomson Learning, U.S.A.

- [5] Huber, P . J., & Ronchetti, E. M. (1981). Robust statistics, ser. Wiley Series in Probability & Mathematical Statistics. New York, NY, USA, Wiley-IEEE, 52.
- [6] Rousseeuw, P. J. (1984). Least median of squares regression. *Journal of the American statistical association*, 79(388), 871-880..
- [7] Rousseeuw, P. J. and Zomeren B. Van, (1990). Unmasking multivariate outliers and leverage points, *J. AM. STAT. ASSOC.*, 85, 633-639
- [8] Yohai, V. J. (1987). High breakdown-point and high efficiency robust estimates for regression. *The Annals of statistics*, 642-656.
- [9] Coakley, C.W. and Hettmansperger, T.P. (1993). A bounded influence, high breakdown, efficient regression estimator. *JASA*, 88(423), 872-880.
- [10] Rousseeuw P.J. and Van Driessen, K. (1999). A fast algorithm for the minimum covariance determinant estimator. *Technometrics*. 41:212–223
- [11] Imon, A.H.M.R. (2002). Identifying multiple high leverage points in linear regression. *Journal of Statistical Studies. Special Volume in Honour of Professor Mir Masoom Ali*. 3: 207–218.
- [12] Hadi, A. S. (1992). A new measure of overall potential influence in linear regression. *Computational and Statistical Data Analysis*. 14:1-27.
- [13] Midi, H., Ramli, N and Imon, A.H.M.R. (2009). The performance of Diagnostic-Robust Generalized Potentials for the identification of multiple high leverage points in linear regression. *Journal of Applied Statistics*. 36(5): 507-520.
- [14] Mohammad A. Mohammad (2015), Rbust Estimation Methods and Robust Multicollinearity Diagnostics For Multiple Regression Model in The Presence of High Leverage Collinearity -Influential Observation, Thesis submitted to the School of Graduate Studies, UPM
- [15] Uraibi, H. S., & Haraj, S. A. A. (2022). Group Diagnostic Measures of Different Types of Outliers in Multiple Linear Regression Model. *Malaysian Journal of Science*, 41(sp1), 23-33.

AL- Rafidain
University College

PISSN: (1681-6870); EISSN: (2790-2293)

Journal of AL-Rafidain University College for Sciences

Available online at: <https://www.jrucs.iq>**JRUCS**Journal of AL-Rafidain
University College
For Sciences

Weighting GM6 Method to Estimate High Robustness Coefficients for a Multiple Regression Model

Hassan S. Uraibi

hassan.uraibi@eq.edu.iq

Noor A. Odeh

noor.alwan22@qu.edu.iqStatistics Department, College of Administration and Economics , University of Al-Qadisiyah
Al-Qadisiyah , Iraq

Article Information

Article History:

Received: February, 23, 2024

Accepted: April, 12, 2024

Available Online: December,
31, 2024
Keywords:
GM6, MM, IDRGP, RMVN,
HLP

Abstract

The multiple linear regression model is one of the most widely used statistical methods in many scientific fields. The model parameters are estimated using the ordinary least squares method, which gives the best unbiased linear estimate when its assumptions are met. One of these assumptions is that the distribution of the random error term is normal with a mean of zero and a constant variance. The presence of outliers leads to a violation of this assumption, and therefore the least squares method cannot be applied. Robust methods have emerged as a suitable alternative when outliers appear, such as the M method, LMS, LTS, and the S estimator. However, the appearance of leverage points as another type of outlier in the space of explanatory variables has led to inaccuracy in the estimates of these methods. Very distinctive methods have been proposed in the statistical literature, such as the MM estimator method and the GM6 method, but the emergence of the problem of high leverage points, the reason for whose existence is attributed to the emergence of the phenomena of (Masking and Swamping). These two phenomena indicate inaccuracy in diagnosing leverage points, which causes either a loss of information or failure to completely treat bad leverage points. The proposal of this research seeks to improve the performance of the GM6 method, even in the presence of these two phenomena, by employing a high-precision diagnostic algorithm called IDRGP (RMVN) in order to obtain high-precision weights to reduce the impact of leverage points in the GM6 method. We have put the accurate diagnosis and GM6 method into a single algorithmic framework that we called GM6.IDRGP(RMVN), which showed outstanding performance compared to previous methods through the results of simulation studies and real data.

Correspondence:

Hassan S. Uraibi

hassan.uraibi@qu.edu.iqDOI: <https://doi.org/10.55562/jrucs.v56i1.3>