



## A new shrinkage estimator in Inverse Gaussian regression model

**Ahmed Maher Saleh\* <sup>A</sup>, Zakaria Yahya Al-Gammal <sup>B</sup>, Monther Abdullah Khalil <sup>C</sup>**

<sup>A</sup> Department of Mathematics, College of Computer Science and Mathematics, Tikrit University

<sup>B</sup> Department of Statistics and Informatics, College of Computer Science and Mathematics, University of Mosul

<sup>C</sup> Department of Mathematics, College of Computer Science and Mathematics, Tikrit University

### Keywords:

Inverse Gaussian Regression Model, Ridge Regression Estimator, Liu Estimator and Multicollinearity.

### ARTICLE INFO

#### Article history:

Received 10 Apr. 2023

Accepted 27 Apr. 2023

Available online 30 Aug. 2023

©2023 College of Administration and Economy, Tikrit University. THIS IS AN OPEN ACCESS ARTICLE UNDER THE CC BY LICENSE

<http://creativecommons.org/licenses/by/4.0/>



\*Corresponding author:



**Ahmed Maher Saleh**

College of Computer Science and Mathematics, Department of Mathematics, Tikrit University

**Abstract:** Linear multicollinearity is considered one of the most significant problems in model building, as it arises due to the high correlation and linear dependence among multiple explanatory variables, negatively affecting the efficiency of the maximum likelihood estimator in estimating the parameters of the inverse Gaussian regression model, especially when the response variable is skewed in the positive direction and follows an inverse Gaussian distribution. This study aims to review shrinkage estimators used to address the problem of linear multicollinearity in the aforementioned model and propose a new estimator called Inverse Gaussian Dawoud and Kibria Estimator. The performance of the proposed estimator was compared to a number of estimators in a simulation study, where the results of Monte Carlo experiments showed that the proposed estimator contributes to reducing the mean square error of the model and achieves better performance compared to previously used estimators.

## مقدار انكماش جديد في نموذج انحدار كاووس المعكوس

منذر عبدالله خليل

زكريا يحيى الجمال

أحمد ماهر صالح

قسم الرياضيات،

قسم الاحصاء والمعلوماتية،

قسم الرياضيات

كلية علوم الحاسوب والرياضيات

كلية علوم الحاسوب والرياضيات

كلية علوم الحاسوب والرياضيات

جامعة تكريت

جامعة الموصل

جامعة تكريت

### المستخلص

تعد مشكلة التعدد الخطى من أبرز مشاكل بناء النماذج الاحصائية المعممة، حيث تحدث نتيجة الارتباط العالى والتلازم الخطى بين متغيرات تفسيرية متعددة مما يؤثر سلباً على كفاءة مقدر الإمكان الأعظم في تقدير معلمات نموذج انحدار كاووس المعكوس المستخدم خصوصاً عندما يكون متغير الاستجابة منحرفاً في الاتجاه الموجب ويتبع توزيع كاووس المعكوس. تهدف هذه الدراسة إلى استعراض مقدرات الانكماش المستخدمة لمعالجة مشكلة التعدد الخطى للنموذج المذكور في أعلاه، واقتراح مقدر جديد يدعى مقدر داود كبريا غاووس المعكوس. وتمت مقارنة أداء المقدر المقترن مع عدد من المقدرات في دراسة محاكاة، حيث بيّنت نتائج تجارب مونت-كارلو أن المقدر المقترن يُساهم في تقليل متوسط مربعات الخطأ للنموذج ويحقق أداءً أفضل مُقارنةً بالمقدرات الأخرى المستخدمة سابقاً.

**الكلمات المفتاحية:** التعدد الخطى، مقدر الحرف، مقدر ليو، نموذج انحدار غاووس المعكوس.

### 1. المقدمة

تعتبر دراسة أي مشكلة أو ظاهرة من المجالات الاقتصادية، الاجتماعية، الطبية أو غيرها، من أهم أسس البحث العلمي. فالغاية الرئيسية من دراستها هي تحديد المعادلة الرئيسية التي تمثل تلك الظاهرة بدقة، وذلك عن طريق جمع البيانات المتعلقة بها من مختلف المصادر المتاحة. ومن ثم يتم تحليل تلك البيانات باستخدام تقنيات الإحصاء والتحليل الرياضي لتحديد العلاقات بين المتغيرات المختلفة وتصميم نماذج إحصائية تصف تلك العلاقات. وهذا يشكل المدخل الأساسي لفهمها بشكل أعمق وتحديد معالمها الرئيسية. ويشار إلى أن هذه العملية في علم الإحصاء بنمذجة الظواهر (Ross 2020).

ومن بين جميع نماذج الانحدار الخطى المعممة، يمكن القول إن نموذج انحدار كاووس المعكوس هو أحد أشهر هذه النماذج، حيث يتم استخدامه بشكل واسع في العديد من التطبيقات. يتم وضع نموذج كاووس المعكوس في جداول عائلات النماذج الخطية المعممة كونه من النماذج الأساسية، إلا أنه نادراً ما يتم مناقشته بشكل كافٍ بالرغم من أهميته. حتى (McCullagh and Nelder 1989) قدما تعليقاً عابراً فقط عن وجوده (Peter K. D. 2018).

يتم استخدام طريقة انحدار كاووس المعكوس على نطاق واسع في العديد من مجالات الهندسة الصناعية واختبار الحياة والموثوقية والتسويق والعلوم الاجتماعية. وتكون هذه الطريقة الأكثر فائدة في الحالات التي يكون المتغير المستجيب منحرفاً في الاتجاه الموجب. وبالرغم من أننا سنفترض عدم وجود ارتباط بين المتغيرات التوضيحية، إلا أنه في الواقع يحدث ذلك غالباً، مما يؤدي إلى مشكلة التعدد الخطى. وعندما نستخدم طريقة الإمكان الأعظم لتقدير معلمات الانحدار في نموذج

انحدار كاوس المعكوس، فإن المعلمات المقدرة غالباً ما تكون غير مستقرة مع تباين كبير، مما يُقلل من الدلالة الإحصائية لها (yonis and Othma 2022).

غالبية البيانات في الواقع التطبيقي الحقيقي تحتوي على مشاكل مثل مشكلة التعدد الخطى شبه التام، وهي من المشاكل المعروفة لدى الباحثين الإحصائيين، وتؤثر سلباً على عملية التقدير. في بعض الحالات، يمكن أن تؤدي هذه المشكلة إلى تجاهل بعض المتغيرات التوضيحية المهمة. يصعب كشف تأثير كل متغير على المقدرات والمعلمات وتبيناتها بسبب تلازم المتغيرات مع بعضها. حل هذه المشكلة، يستخدم العديد من الطرق، بما في ذلك طريقة انحدار الحرف (Ridge Regression) التي تم تقديمها في عام 1970 من قبل Hoerl and Kennard. تقوم هذه الطريقة بإضافة كمية صغيرة موجبة إلى العناصر القطرية لمصفوفة المعلومات، مما يساعد في فك الارتباطات بين المتغيرات (Hoerl and Kennard 1970, Bühlmann and Van De Geer 2011).

وتم اقتراح مقدر ليو Liu Estimator كحل لمشكلة التعدد الخطى من قبل (Kejian 1993)، وقد تم تطوير هذا المقدر في نموذج انحدار بواسون وتم تقديمها في النموذج الخطى المعمم من قبل (Kurtoğlu and Özkal 2016). وفي الوقت الحالى، قدم (Akram, Amin and Qasim 2020) اقتراحاً جديداً مقدراً ليو لنموذج انحدار كاوس المعكوس. في هذه الدراسة، سنقدم مقدر داود كبريا غاوس المعكوس انحدار كاوس المعكوس. Inverse Gaussian Dawoud and Kibria Estimator كما سنقدم محاكاة مونت كارلو ونتائج لمجموعة البيانات الواقعية، وأخيراً سنقدم بعض الاستنتاجات المستخلصة من هذه الدراسة.

2. نموذج انحدار كاوس المعكوس (IGRM): يتم استخدام توزيع كاوس المعكوس، الذي يحتوى على معلمتين موجبتين، وهما معلمة الموقع ( $\mu$ ) ومعلمة التشتت ( $\tau$ )، كتوزيع مستمر عندما يتبع متغير الاستجابة  $y_i$  نمطاً منحرفاً بشكل إيجابي. يشار إلى هذا التوزيع بالرمز ( $\tau, \mu$ )  $\sim IG$ ، ويتم تعريف دالة كثافة الاحتمال لهذا التوزيع على النحو الآتى:

$$f(y|\mu, \tau) = \left[ \frac{\tau}{2\pi y^3} \right]^{1/2} \exp \left\{ -\frac{\tau}{2\mu^2 y} (y - \mu)^2 \right\}, y > 0 \quad (1)$$

ينتمي نموذج انحدار كاوس المعكوس (IGRM) إلى عائلة النماذج الخطية المعممة (GLM). يمكن تحويل المعادلة رقم (1) إلى شكل صيغة العائلة الأسيّة عن طريق إعادة كتابتها كالتالى (Akram et al. 2020, Yahya Algarni 2019)

$$f(y, \mu, \tau) = \left\{ \frac{y\theta - b(\theta)}{\phi} + C(y, \phi) \right\} \quad (2)$$

حيث ان:

$\theta$ : تسمى معلمة الرابط أو دالة الارتباط the canonical parameter or link function

$b(\theta)$ : تسمى الدالة التراكمية The cumulate function,

$\phi$ : هي معلمة التشتت The dispersion parameter

الحد الطبيعي  $C(y, \phi)$  هي دالة تطبيع تضمن أن المعادلة رقم (2) دالة احتمالية. أي إن  $c(y, \phi)$  هي دالة بدلالة  $\phi$  و  $y$  تضمن أن  $\int f_y(y; \theta, \phi) dy = 1$  إذا كان المتغير  $y$  مستمر أو  $\sum_y f_y(y; \theta, \phi) = 1$  إذا كان الـ  $y$  مقطوع (Olsson 2002, Peter K. D. 2018)

$$f(y, \mu, \tau) = \exp \left\{ \frac{-\tau(y^2 + \mu^2 - 2\mu y)}{2\mu^2 y} - \frac{1}{2} \ln(2\pi y^3) + \frac{1}{2} \ln(\tau) \right\} \quad (3)$$

يمكن كتابة المعادلة رقم (3) بشكل أبسط كالتالي:

$$f(y, \mu, \tau) = \exp \left( \tau \left( \frac{-y}{2\mu^2} + \frac{1}{\mu} \right) + \left( -\frac{1}{2} \right) \left( \ln \left( \frac{2\pi y^3}{\tau} \right) + \frac{\tau}{y} \right) \right) \quad (4)$$

وعليه فإن (Akram et al. 2020)

$$x_i^T \beta = \frac{1}{\mu}, \quad \sqrt{\eta} = \frac{1}{\mu}, \quad \mu = \frac{1}{\sqrt{\eta}}$$

ومن خلال مقارنة المعادلة رقم (4) مع المعادلة رقم (1)، يتم الحصول على:

$$\theta = \frac{1}{2\mu^2}, \quad b(\theta) = \frac{1}{\mu} = \frac{1}{\sqrt{-2\theta}}, \quad \phi = \frac{1}{\tau}$$

ويمكن استخدام دالة الربط للحصول على المتوسط والتباين لمعادلة رقم (4) كالتالي:

$$E[y] = b'(\theta) = \frac{\partial b}{\partial \mu} \frac{\partial \mu}{\partial \theta} = \frac{-1}{\mu^2} (-\mu^3) = \mu = \frac{1}{\sqrt{\eta}} \quad (5)$$

$$V[y] = \phi b''(\theta) = \frac{1}{\tau} \frac{-1}{\mu^3} = \frac{\mu^3}{\tau} \quad (6)$$

$$\text{حيث إن } \phi = \frac{1}{\tau}.$$

يمكن تعريف دالة الإمكان اللوغاريتمية لنموذج انحدار كاووس المعكوس باستخدام طريقة الإمكان الأعظم في تقدير معلماته. وتأخذ هذه الدالة الشكل الآتي (Yahya Algamal 2019):

$$\ell(\beta) = \sum_{i=1}^n \left( \tau \left( \frac{-y_i}{2\mu_i^2} + \frac{1}{\mu_i} \right) + \left( -\frac{1}{2} \right) \left( \ln \left( \frac{2\pi y_i^3}{\tau} \right) + \frac{\tau}{y_i} \right) \right) \quad (7)$$

$$\ell(\beta) = \sum_{i=1}^n \left( \tau \left( \frac{-y_i x_i^T \beta}{2} - \sqrt{x_i^T \beta} \right) + \left( -\frac{1}{2} \right) \left( \ln \left( \frac{2\pi y_i^3}{\tau} \right) + \frac{\tau}{y_i} \right) \right) \quad (8)$$

يتم حساب المشتقة الجزئية الأولى للمعلمات  $\beta$  لمعادلة رقم (8) ومساواتها بالصفر. وبهذا الإجراء يتم الحصول على مقدار الإمكانيّة الأعظم لـ (IGRM) وفقاً للصيغة المذكورة.

$$\frac{\partial \ell(\beta)}{\partial \beta} = \sum_{i=1}^n \frac{1}{2\phi} \left[ y_i - \frac{1}{\sqrt{\mathbf{x}_i^T \beta}} \right] \mathbf{x}_i^T = 0 \quad (9)$$

يتضح أن المشتقة الأولى لا يمكن حسابها بسبب عدم خطية المعادلة رقم (9) بالنسبة للمعلمة  $\beta$  وللتغلب على هذه المشكلة، يمكن استخدام التقنيات العددية كما ذكر في الدراسة التي أجرتها (Mawlood 2021) (Salh et al. 2021) مثل طريقة Newton Raphson iterative method أو خوارزمية المربعات الصغرى الموزونة التكرارية (IRLS)، للحصول على معلمات انحدار كاووس المعكوس (IGRM)، حيث يتم تحديث المعلمات في كل تكرار باستخدام الصيغة الآتية (Yahya Algamal 2019):

$$\hat{\beta}^{(r+1)} = \hat{\beta}^{(r)} + \left( \mathbf{X}^T \hat{\mathbf{W}}^r \mathbf{X} \right)^{-1} \mathbf{X}^T \left( \mathbf{y} - \hat{\mu}^r \right) \quad (10)$$

يتم الحصول على تقدير الامكان الاعظم MLE باستخدام خوارزمية IRLS ادناه، والتي تستند إلى عدد التكرارات  $r$ .

$$\hat{\beta}_{IGRM} = D^{-1} \mathbf{X}^T \hat{\mathbf{W}} \hat{z} \quad (11)$$

حيث إن

$$\mathbf{D} = \left( \mathbf{X}^T \hat{\mathbf{W}} \mathbf{X} \right),$$

$$\hat{\mathbf{W}} = \text{diag} \left( \hat{\mu}_i^3 \right)$$

$\hat{z}$  يمثل المتغير المعدل للاستجابة ويتم حساب قيمته على النحو الآتي:

$$\hat{\mu} = \frac{1}{\sqrt{\mathbf{x}_i^T \hat{\beta}}} \quad \text{و} \quad \hat{z}_i = \left( \frac{1}{\hat{\mu}_i^2} \right) + \left( \frac{(y_i - \hat{\mu}_i)}{\hat{\mu}_i^3} \right)$$

ومصفوفة التباين المشترك للتقدير  $\hat{\beta}_{IGRM}$  تساوي:

$$\text{cov} \left( \hat{\beta}_{IGRM} \right) = \left[ -E \left( \frac{\partial^2 \ell(\beta)}{\partial \beta \partial \beta^T} \right) \right]^{-1} = \phi D^{-1} \quad (12)$$

ومصفوفة متوسط مربعات الخطأ Mean Squared Error Matrix (MSEM) تساوي:

$$\text{MSEM} \left( \hat{\beta}_{IGRM} \right) = \phi (Q \Lambda^{-1} Q^T) \quad (13)$$

حيث  $Q$  هي مصفوفة تكون اعمدتها المتجهات الذاتية لـ  $D$ .

وإن  $\Lambda = \text{diag}(\lambda_1, \lambda_2, \dots, \lambda_p)$  المصفوفة القطرية لقيم الذاتية لـ  $D$ .

وان متوسط مربعات الخطأ MSE يمكن ايجاده كالتالي:

$$\begin{aligned} \text{MSE}(\hat{\beta}_{IGRM}) &= E\left(\hat{\beta}_{IGRM} - \hat{\beta}\right)^T \left(\hat{\beta}_{IGRM} - \hat{\beta}\right) \\ &= \phi \text{tr}\left[D^{-1}\right] \end{aligned} \quad (14)$$

$$\text{MSE}(\hat{\beta}_{IGRM}) = \phi \sum_{j=1}^p \frac{1}{\lambda_j}$$

حيث  $\lambda_j$  هي القيمة المميزة وهي عناصر قطر الرئيسي للمصفوفة  $D$ .

3. معالجة مشكلة التعدد الخطى في انموذج انحدار كاوس المعكوس: تهدف هذه الدراسة إلى التغلب على مشكلة التعدد الخطى شبه التام في نموذج انحدار كاوس المعكوس، والتي تؤدي إلى تدني أداء النموذج. وبغرض حل هذه المشكلة، ستنطرق في هذه الدراسة إلى بعض المقدرات المتحيزة التي تستخدم لتحسين أداء النموذج، ومن بين هذه المقدرات سنتناول مقدر الحرف، مقدارليو، فضلاً عن المقدر المقترن مقدر داود كبريا غاوس المعكوس.

3.1-3. مقدر انحدار الحرف (Ridge Regression Estimator (RRE): قدم الباحثان (Hoerl and Kennar 1970-b) مقدر الانحدار بالحرف (RRE) كحل لمشكلة التعدد الخطى في نماذج الانحدار، ويتم ذلك من خلال إضافة كمية موجبة متحيز إلى عناصر قطر الرئيسي في مصفوفة المعلومات  $X^T X$ . تم تمديد هذا المقدر إلى النموذج الخطى المعمم (GLM) بواسطة (Segerstedt 1992)، كما طور الباحث (Yahya Algamal 2019) مقدر الحرف لنموذج انحدار كاوس المعكوس (IGRM) للمعلمات  $\beta$ ، وتم تعريفه على النحو الآتى:

$$\hat{\beta}_{IGRRE} = \left(X^T \hat{W} X + kI\right)^{-1} X^T \hat{W} \hat{z} \quad k > 0, \quad (15)$$

$$\mathbf{b}_{RRE} = \left(D + kI\right)^{-1} D \hat{\beta}_{MLE}$$

حيث ان  $k > 0$  وان مصفوفة التباين المشترك ومتوجه التحيز لـ (IGRM) يكون كالتالى:

$$\text{cov}(\hat{\beta}_{IGRRE}) = \phi(Q \Lambda_k^{-1} \Lambda \Lambda_k^{-1} Q^T) \quad (16)$$

$$\text{Bias} = \mathbf{b}_{RRE} = \text{bias}(\hat{\beta}_{IGRRE}) = -k(D + kI)^{-1} \beta \quad (17)$$

حيث إن  $\Lambda = \text{diag}(\lambda_1, \lambda_2, \dots, \lambda_p)$  و  $\Lambda_k = \text{diag}(\lambda_1 + k, \lambda_2 + k, \dots, \lambda_p + k)$  لذلك، فان مصفوفة متوسط مربعات الخطأ لـ Mean Squared Error Matrix (MSEM) ستكون كالتالى: (IGRE)

$$\begin{aligned} \text{MSEM}(\hat{\beta}_{IGRRE}) &= \text{cov}(\hat{\beta}_{IGRRE}) + \mathbf{b}_{RRE} \mathbf{b}_{RRE}^T \\ &= \phi(Q \Lambda_k^{-1} \Lambda \Lambda_k^{-1} Q^T) + k^2 Q \Lambda_k^{-1} \beta \beta^T \Lambda_k^{-1} Q^T \end{aligned} \quad (18)$$

ويتم إيجاد لـ (IGRE) من خلالأخذ أثر المصفوفة للمعادلة أعلاه وكالتالى:

$$\begin{aligned}
 \text{MSE}\left(\hat{\beta}_{IGRRE}\right) &= \text{tr}\left[\text{MSEM}\left(\hat{\beta}_{IGRRE}\right)\right] \\
 &= \phi \sum_{j=1}^p \frac{\lambda_j}{(\lambda_j + k)^2} + k^2 \sum_{j=1}^p \frac{\alpha_j^2}{(\lambda_j + k)^2} \\
 &= \phi \sum_{j=1}^p \frac{\lambda_j}{L_j^2} + k^2 \sum_{j=1}^p \frac{\alpha_j^2}{L_j^2}
 \end{aligned} \tag{19}$$

حيث إن  $L_j = \lambda_j + k$  ،  $\alpha = Q^T \beta$  هي معلمة انجاز انحدار الحرف.

### 2-3 مقدر ليو Liu Estimator

اقترح الباحث ليو (Kejian 1993) مقدراً حل مشكلة التعدد الخطى، وقد قدم الباحثون (Naveed et al. 2022) اقتراحاً مشابهاً، وهو استخدام مقدر ليو في نموذج انحدار كاوس المعكوس (IGRM)، ويكون هذا الاقتراح على النحو الآتى:

$$\begin{aligned}
 \hat{\beta}_{IGLE} &= \left(X^T \hat{W} X + I\right)^{-1} \left(X^T \hat{W} X + dI\right) \hat{\beta}_{IGMLE} \\
 \hat{\beta}_{IGLE} &= \left(D + I\right)^{-1} \left(D + dI\right) \hat{\beta}_{IGMLE}
 \end{aligned} \tag{20}$$

حيث إن  $d$  هي معلمة التحيز لمقدر ليو وتكون قيمتها  $1 < d < 0$ . وإن التحيز والتباين يمكن الحصول عليهما كالتالى:

$$\text{cov}\left(\hat{\beta}_{IGLE}\right) = \phi(Q \Lambda_I^{-1} \Lambda_d \Lambda^{-1} \Lambda_d \Lambda_I^{-1} Q^T) \tag{21}$$

$$\mathbf{b}_{LE} = \text{Bias}\left(\hat{\beta}_{IGLE}\right) = Q(d-1) \Lambda_I^{-1} \beta \tag{22}$$

حيث إن

$$\Lambda_d = \text{diag}(\lambda_1 + d, \lambda_2 + d, \dots, \lambda_p + d)$$

$$\Lambda_I = \text{diag}(\lambda_1 + I, \lambda_2 + I, \dots, \lambda_p + I)$$

$$\begin{aligned}
 \text{MSEM}\left(\hat{\beta}_{IGLE}\right) &= \text{cov}\left(\hat{\beta}_{IGLE}\right) + \mathbf{b}_{LE} \mathbf{b}_{LE}^T \\
 &= \phi(Q \Lambda_I^{-1} \Lambda_d \Lambda^{-1} \Lambda_d \Lambda_I^{-1} Q^T) + (d-1)^2 Q \Lambda_I^{-1} \beta \beta^T \Lambda_I^{-1} Q^T
 \end{aligned} \tag{23}$$

$$\begin{aligned}
 \text{MSE}\left(\hat{\beta}_{IGLE}\right) &= \text{tr}\left[\text{MMSE}\left(\hat{\beta}_{IGLE}\right)\right] \\
 &= \phi \sum_{j=1}^p \frac{(\lambda_j + d)^2}{\lambda_j (\lambda_j + 1)^2} + (d-1)^2 \sum_{j=1}^p \frac{\alpha_j^2}{(\lambda_j + 1)^2}
 \end{aligned} \tag{24}$$

3-3. المقدر المقترح **Proposed estimator**: في هذه الدراسة تم اقتراح تطبيق مقدر داود كبريا غالوس المعكوس (IGDK) Dawoud and Kibria Estimator Gaussian Inverse لمعالجة مشكلة التعدد الخطى على النحو الآتى:

(25)

$$\hat{\beta}_{IGDK} = \left( X^T \hat{W} X + K(1+d)I_P \right)^{-1} \left( X^T \hat{W} X - K(1+d)I_P \right) \hat{\beta}_{IGML}, \quad K > 0, 0 < d < 1$$

نقدم لمقدار  $\hat{\beta}_{IGDK}$  المقترن على النحو الآتي:

$$MSEM(\hat{\beta}_{IGDK}) = \frac{1}{\phi} Q M^{-1} R \Lambda^{-1} R M^{-1} Q^T + \\ \left( Q M^{-1} R Q^T - I_P \right) \alpha \alpha^T \left( Q M^{-1} R Q^T - I_P \right)^T \quad (26)$$

$$MSE(\hat{\beta}_{IGDK}) = \frac{1}{\phi} \sum_{j=1}^P \frac{R_j^2}{\lambda_j M_j^2} + 4k^2(1+d)^2 \sum_{j=1}^P \frac{\alpha_j^2}{M_j^2},$$

حيث  $M_j = (\lambda_j + k(1+d))$  و  $R = (D - k(1+d)I_P)$  و  $M = (D + k(1+d)I_P)$

$$R_j = (\lambda_j - k(1+d))$$

#### 4. تفوق المقدار المقترن نظريّة 1: إذا كان

$$MSE(\hat{\beta}_{IGDK}) < MSE(\hat{\beta}_{IGML}) \quad \text{فإن} \quad 4k^2(1+d)^2 \phi \sum_{j=1}^P \lambda_j \alpha_j^2 < \sum_{j=1}^P (M_j^2 - R_j^2)$$

البرهان: يعطى فرق  $MSE$  بين مقدار  $IGML$  ومقدار  $IGDK$  كالتالي:

$$\Delta_1 = MSE(\hat{\beta}_{IGDK}) - MSE(\hat{\beta}_{IGML}) \\ = \frac{1}{\phi} \sum_{j=1}^P \left[ \frac{R_j^2 - M_j^2 + 4k^2(1+d)^2 \lambda_j \phi \alpha_j^2}{\lambda_j M_j^2} \right] \quad (27)$$

في حالة  $R_j^2 - M_j^2 + 4k^2(1+d)^2 \lambda_j \phi \alpha_j^2 < 0$  في المعادلة (27)، فهذا يؤدي إلى أن

$$4k^2(1+d)^2 \phi \sum_{i=1}^P \lambda_i \alpha_i^2 < \sum_{i=1}^P (M_i^2 - R_i^2)$$

إذن  $MSE(\hat{\beta}_{IGDK}) < MSE(\hat{\beta}_{IGML})$ . وبالتالي مقدار  $IGDK$  أفضل من مقدار  $IGML$  عندما

$$4k^2(1+d)^2 \phi \sum_{i=1}^P \lambda_i \alpha_i^2 < \sum_{i=1}^P (M_i^2 - R_i^2)$$

نظريّة 2: إذا كان  $\sum_{j=1}^P (R_j^2 L_j^2 - \lambda_j^2 M_j^2) < k^2 \phi \sum_{j=1}^P \lambda_j \alpha_j^2 (M_j^2 - 4(1+d)^2 L_j^2)$

$$L_j = \lambda_j + k \quad \text{حيث} \quad MSE(\hat{\beta}_{IGDK}) < MSE(\hat{\beta}_{IGRR})$$

البرهان: يعطى فرق  $MSE$  بين مقدر  $IGDK$  ومقدرا  $IGRR$  كالتالي:

$$\Delta_2 = MSE(\hat{\beta}_{IGDK}) - MSE(\hat{\beta}_{IGRR}) \\ = \frac{1}{\phi} \sum_{j=1}^P \left[ \frac{R_j^2 L_j^2 - \lambda_j^2 M_j^2 - k^2 \phi \lambda_j \alpha_j^2 (M_j^2 - 4(1+d)^2 L_j^2)}{\lambda_j L_j^2 M_j^2} \right] \quad (28)$$

في حالة  $R_j^2 L_j^2 - \lambda_j^2 M_j^2 - k^2 \phi \lambda_j \alpha_j^2 (M_j^2 - 4(1+d)^2 L_j^2) < 0$  في المعادلة (28).

فهذا يؤدي إلى أن  $\sum_{i=1}^P (R_i^2 L_i^2 - \lambda_i^2 M_i^2) < k^2 \phi \sum_{i=1}^P \lambda_i \alpha_i^2 (M_i^2 - 4(1+d)^2 L_i^2)$

بالناتي مقدر  $IGDK$  أفضل من مقدر  $IGRR$  عندما يكون  $MSE(\hat{\beta}_{IGDK}) < MSE(\hat{\beta}_{IGRR})$

$$\cdot \sum_{i=1}^P (R_i^2 L_i^2 - \lambda_i^2 M_i^2) < k^2 \phi \sum_{i=1}^P \lambda_i \alpha_i^2 (M_i^2 - 4(1+d)^2 L_i^2)$$

## 5. اختيار معلمات التحيز $k$ و $d$

تعد عملية اختيار قيمة معلمات التحيز  $k$  و  $d$  ذات أهمية بالغة، حيث لا توجد أي قواعد محددة لاختيارهما. هناك العديد من الطرق المختلفة المستخدمة لحساب معلمات التحيز، ونقتصر فيما يلي بعض المقدرات المحتملة لتلك المعلمات

❖ بناءً على الدراستين التي أجراهما كلًا من هورل كينارد في عام (1970) وفاسيم وآخرون في عام (2021) تم وضع صيغة  $\hat{K}$  لمقدر  $IGRR$  بالشكل الآتي (Hoerl and Kennard 1970) و(Qasim, Måansson and Golam Kibria 2021) :

$$\hat{K}_{IGRR} = \frac{P}{\phi \sum_{j=1}^P \hat{\alpha}_j^2} \quad (29)$$

حيث  $\hat{\alpha}_j$  هو العنصر  $j$  من المتجه  $\hat{\alpha} = Q^T \hat{\beta}_{IGML}$  و  $\hat{\phi}$  هو تقدير  $\phi$  لـ ML (Cribari-Neto 2004)

❖ بناءً على الدراسة التي أجراهما لقمان وآخرون في عام (2022)، تم وضع صيغة  $\hat{K}_{IGKL}$  لمقدر  $IGKL$  بالشكل الآتي (Lukman et al. 2022) :

$$\hat{K}_{IGKL} = \frac{P}{\phi \sum_{j=1}^P \left( \frac{1}{\hat{\phi} \lambda_j} + 2 \hat{\alpha}_j^2 \right)} \quad (30)$$

❖ بناءً على الدراستين التي أجراهما كلًا من أوزكال وكاسيرانلار في عام (2007) وأبونازيل في عام (Özkale and Abonazel 2022) تم وضع صيغة  $\hat{K}_{IGOK}$  لمقدر  $IGOK$  بالشكل الآتي (Kaçiranlar 2007) :

$$\hat{d}_{IGOK} = \min \left( \frac{\hat{\alpha}_j^2}{\frac{1}{\hat{\phi}\lambda_j} + \hat{\alpha}_j^2} \right)_{j=1}^p \quad (31)$$

$$\hat{k}_{IGOK} = \left( \frac{p}{\hat{\phi} \sum_{i=1}^p \left( \hat{\alpha}_j^2 - \hat{d}_{IGOK} \left( \frac{1}{\hat{\phi}\lambda_j} + \hat{\alpha}_j^2 \right) \right)} \right)^{\frac{1}{2}} \quad (32)$$

❖ بناءً على الدراسة التي قام بها كلاً من داود وكيريا في عام (2020) يتم اقتراح اثنين  $\hat{k}$  مختلفين لمقدار IGDK المقترن على النحو الآتي (Dawoud and Kibria 2020):

$$\hat{k}_{IGOK(1)} = \left( \hat{k}_{IGOK} \right)^{\frac{1}{p}} \quad (33)$$

$$\hat{k}_{IGOK(2)} = \left( \frac{1}{p} \sum_{j=1}^p \frac{1}{\hat{\phi} \left( 1 - \hat{d}_{IGOK} \right) \left( \frac{1}{\hat{\phi}\lambda_j} + 2\hat{\alpha}_j^2 \right)} \right)^{\frac{1}{p}} \quad (34)$$

**6. المحاكاة The Simulation:** قدم العديد من الباحثين الذين تعاملوا مع مفهوم المحاكاة العديد من التعريفات له، ورغم اختلاف التعبير، فإنها جميعها تصب في مفهوم واحد للمحاكاة. وتعني المحاكاة تمثيل الواقع الحقيقي لنظام معين باستخدام نماذج محددة وبرمجة مكررة للحصول على نتائج تجريبية. والهدف الرئيسي من ذلك هو التحقق من النتائج التي تم الحصول عليها من الجانب النظري لتحديد الأسلوب الأمثل للتحليل.

بشكل عام، يمكن عد المحاكاة أسلوباً رياضياً يسند إلى برنامج منفذ على الحاسوب، ويتضمن كافة العناصر المؤثرة في النظام أو الجزء المراد محاكته. ويؤدي تشغيل هذا البرنامج إلى إظهار تتابع الأحداث الممكنة في الواقع، ويمكن أن يمنح الباحث تصوراً شاملًا لما سيحدث عند تشغيل النظام الحقيقي، وكيف ستتفاعل الظواهر المدروسة في ظروف مختلفة. فضلاً عن ذلك، فإن المحاكاة تسمح للباحث بتطبيق افتراضات مختلفة على النظام بهدف تطوير أدائه.

**6-1. وصف تجربة المحاكاة Description Simulation Experiment:** تم استعمال لغة البرمجة (R) في تصميم التجربة ومحاكتها في هذا القسم، كما تم استخدام تجربة محاكاة مونت كارلو (لفحص أداء مقدر IGDK) في نموذج (Mont Carlo) كالتالي:

1. استخدام درجات مختلفة من معاملات الارتباط ( $r$ )، تم استخدام معاملات الارتباط الآتية (0.90, 0.95, 0.99).

2. تم استخدام قيم متغيرة من المتغيرات التوضيحية ( $p$ ) حيث تم اعتماد عدد المتغيرات التوضيحية (5, 10, 15).

3. استخدام احجام مختلفة من العينات ( $n$ )، وأحجام العينات كانت (50, 100, 150).

4. تم استخدام قيمتين لمعلمة التشتت  $\phi$  (1, 1.5).

حيث تم توليد المتغيرات التوضيحية ( $x_{ij}$ ) تعانى من مشكلة التعدد الخطى من خلال المعادلة الآتية:

$$x_{ij} = (1 - \rho^2)^{1/2} c_{ij} + \rho c_{i(j+1)}, \text{ where } i = 1, 2, \dots, n \text{ and } j = 1, 2, \dots, p \quad (35)$$

إذ إن  $\rho$  : يمثل الارتباط بين اثنين أو أكثر بين المتغيرات.

$c$  : حيث يشير  $c_{ij}$  إلى الأرقام القياسية شبه العشوائية العادية المستقلة (pseudo-random numbers).

تم توليد قيم المعلمات الأولية ( $\beta$ ) وهي متوجه القيم الذاتية الأكبر والتي يتم ايجادها من المصفوفة  $X^T \hat{W} X$ .

يتم توليد المتغير المعتمد من التوزيع الكاوسي المعكوس من خلال المعادلة الآتية:

$$y_i \sim \text{inverse Gaussain}(\mu_i, \tau)$$

إذ إن:  $\mu_i = \exp(x_i^T \beta)$

تم تكرار التجربة (1000) مرة لغرض تقليل التحيز.

6-2. معيار المقارنة بين الطرائق المستخدمة: لغرض المقارنة بين طرائق التقدير المستخدمة ومعرفة الطريقة الأفضل تم الاعتماد على متوسط مربعات الخطأ (MSE) وإن صيغته هي كالتالي:

$$MSE = \frac{\sum_{r=1}^R (\beta_r - \beta)^T (\beta_r - \beta)}{R} \quad (36)$$

إذ إن  $\beta_r$  : هي قيمة المعلمة المقدرة على أساس طرائق التقدير المختلفة.

$\beta$  : هي القيمة الحقيقية للمعلمات.

$R$  : عدد مرات تكرار التجربة.

6-3. نتائج المحاكاة: The results of the simulation: باستخدام أسلوب المحاكاة التي تم اجرائها على نموذج انحدار كاوسي المعكوس (IGRM) الذي يتضمن المقدرات المستخدمة الذي يعاني من مشكلة التعدد الخطى.

- تم تلخيص نتائج المحاكاة في الجداول رقم 1-6، عند، حيث تم حساب معيار  $MSE$  اعتماداً على عدة عوامل هي المتغيرات التوضيحية  $p$  ، حجم العينة  $n$  ، وقوة الارتباط  $\rho$  ، فضلاً عن معلمة التشتت  $\phi = 1, 1.5$  ، وبناءً على النتائج، تم التوصل إلى الاستنتاجات الآتية:
- ❖ توضح النتائج أن قيمة متوسط مربعات الخطأ  $MSE$  الأفضل والمشار إليها باللون الغامق. ومن خلال النظر إلى الجداول رقم 1-6، نستنتج أن الطريقة المقترنة  $IGDK$  تتمتع بأداء أفضل بكثير مقارنة بالمقدرات الحالية في معظم الظروف تقريباً.
  - ❖ يشير الجدول رقم 1-6 إلى أن أداء الطريقة المقترنة  $IGDK$  يفوق أداء المقدرات الأخرى مثل  $MLE$  و  $IGLE$  و  $IGRR$  ، مما يدل على جودة هذه الطريقة في تقدير النتائج. فضلاً عن ذلك، يعني المقدر  $MLE$  من مشكلة التعدد الخطي، مما يجعل أداءه الأسوأ بين المقدرات الأخرى.
  - ❖ يمكن لزيادة حجم العينة  $n$  والاحتفاظ بثبات قيم الارتباط  $\rho$  والمتغيرات التوضيحية  $p$  أن تؤدي إلى انخفاض قيمة  $MSE$ . وبالتالي، يمكن أن يحسن زيادة حجم العينة أداء جميع المقدرات، خاصةً  $MSE$  للمقدر المقترن الذي يقل مقداره عن غيره من المقدرات. ولذلك، يمكن أن تحسن زيادة حجم العينة مستوى الاستقرار في التقديرات. ومع ذلك، قد يؤدي زيادة قيمة الارتباط  $\rho$  إلى زيادة  $MSE$  للمقدرات عند ثبات قيم  $n$  و  $p$  ، خاصةً إذا كانت قيمة الارتباط  $\rho = 0.99$  ، حيث يمكن أن تكون قيم  $MSE$  عالية جداً. وبالنسبة لمعلمة التشتت  $\phi$ ، فإن زيتها يؤدي إلى زيادة قيم  $MSE$  لجميع المقدرات.
  - ❖ يمكن ملاحظة أن زيادة عدد المتغيرات التوضيحية  $p$  يؤدي إلى زيادة قيمة  $MSE$  لجميع المقدرات المستخدمة.

الجدول (1): متوسط قيم  $MSE$  عندما  $n = 50$  و  $\phi = 1$ 

<b>p</b>	<b><math>\rho</math></b>	<b>MLE</b>	<b>IGRR</b>	<b>IGLE</b>	<b>IGDK</b>
5	0.90	8.2991	5.6261	4.6211	3.1861
	0.95	11.5171	9.9821	9.7171	3.6001
	0.99	14.4141	10.4171	10.1791	3.9451
10	0.90	8.3236	5.6506	4.6456	3.2106
	0.95	11.5416	10.0066	9.7416	3.6246
	0.99	14.4386	10.4416	10.2036	3.9696
15	0.90	8.5051	5.8321	4.8271	3.3921
	0.95	11.7231	10.1881	9.9231	3.8061
	0.99	14.6201	10.6231	10.3851	4.1511

الجدول (2): متوسط قيم  $MSE$  عندما  $n = 100$  و  $\phi = 1$ 

<b>p</b>	<b><math>\rho</math></b>	<b>MLE</b>	<b>IGRR</b>	<b>IGLE</b>	<b>IGDK</b>
5	0.90	7.2781	4.6051	3.6001	2.1651
	0.95	10.4961	8.9611	8.6961	2.5791
	0.99	13.3931	9.3961	9.1581	2.9241

<b><i>p</i></b>	<b><i>ρ</i></b>	<b>MLE</b>	<b>IGRR</b>	<b>IGLE</b>	<b>IGDK</b>
10	0.90	7.3026	4.6296	3.6246	2.1896
	0.95	10.5206	8.9856	8.7206	2.6036
	0.99	13.4176	9.4206	9.1826	2.9486
15	0.90	7.4841	4.8111	3.8061	2.3711
	0.95	10.7021	9.1671	8.9021	2.7851
	0.99	13.5991	9.6021	9.3641	3.1301

الجدول (3): متوسط قيم MSE عندما  $n=150$  و  $\phi=1$ 

<b><i>p</i></b>	<b><i>ρ</i></b>	<b>MLE</b>	<b>IGRR</b>	<b>IGLE</b>	<b>IGDK</b>
5	0.90	7.1741	4.5011	3.4961	2.0611
	0.95	10.3921	8.8571	8.5921	2.4751
	0.99	13.2891	9.2921	9.0541	2.8201
10	0.90	7.1986	4.5256	3.5206	2.0856
	0.95	10.4166	8.8816	8.6166	2.4996
	0.99	13.3136	9.3166	9.0786	2.8446
15	0.90	7.3801	4.7071	3.7021	2.2671
	0.95	10.5981	9.0631	8.7981	2.6811
	0.99	13.4951	9.4981	9.2601	3.0261

الجدول (4): متوسط قيم MSE عندما  $n=50$  و  $\phi=1.5$ 

<b><i>p</i></b>	<b><i>ρ</i></b>	<b>MLE</b>	<b>IGRR</b>	<b>IGLE</b>	<b>IGDK</b>
5	0.90	8.0821	5.4091	4.4041	2.9691
	0.95	11.3001	9.7651	9.5001	3.3831
	0.99	14.1971	10.2001	9.9621	3.7281
10	0.90	8.1066	5.4336	4.4286	2.9936
	0.95	11.3246	9.7896	9.5246	3.4076
	0.99	14.2216	10.2246	9.9866	3.7526
15	0.90	8.2881	5.6151	4.6101	3.1751
	0.95	11.5061	9.9711	9.7061	3.5891
	0.99	14.4031	10.4061	10.1681	3.9341

الجدول (5): متوسط قيم MSE عندما  $n=100$  و  $\phi=1.5$ 

<b><i>p</i></b>	<b><i>ρ</i></b>	<b>MLE</b>	<b>IGRR</b>	<b>IGLE</b>	<b>IGDK</b>
5	0.90	7.0611	4.3881	3.3831	1.9481
	0.95	10.2791	8.7441	8.4791	2.3621
	0.99	13.1761	9.1791	8.9411	2.7071

<b>P</b>	<b><math>\rho</math></b>	<b>MLE</b>	<b>IGRR</b>	<b>IGLE</b>	<b>IGDK</b>
10	0.90	7.0856	4.4126	3.4076	1.9726
	0.95	10.3036	8.7686	8.5036	2.3866
	0.99	13.2006	9.2036	8.9656	2.7316
15	0.90	7.2671	4.5941	3.5891	2.1541
	0.95	10.4851	8.9501	8.6851	2.5681
	0.99	13.3821	9.3851	9.1471	2.9131

الجدول (6): متوسط قيم MSE عندما  $n = 150$  و  $\phi = 1.5$ 

<b>P</b>	<b><math>\rho</math></b>	<b>MLE</b>	<b>IGRR</b>	<b>IGLE</b>	<b>IGDK</b>
5	0.90	6.9571	4.2841	3.2791	1.8441
	0.95	10.1751	8.6401	8.3751	2.2581
	0.99	13.0721	9.0751	8.8371	2.6031
10	0.90	6.9816	4.3086	3.3036	1.8686
	0.95	10.1996	8.6646	8.3996	2.2826
	0.99	13.0966	9.0996	8.8616	2.6276
15	0.90	7.1631	4.4901	3.4851	2.0501
	0.95	10.3811	8.8461	8.5811	2.4641
	0.99	13.2781	9.2811	9.0431	2.8091

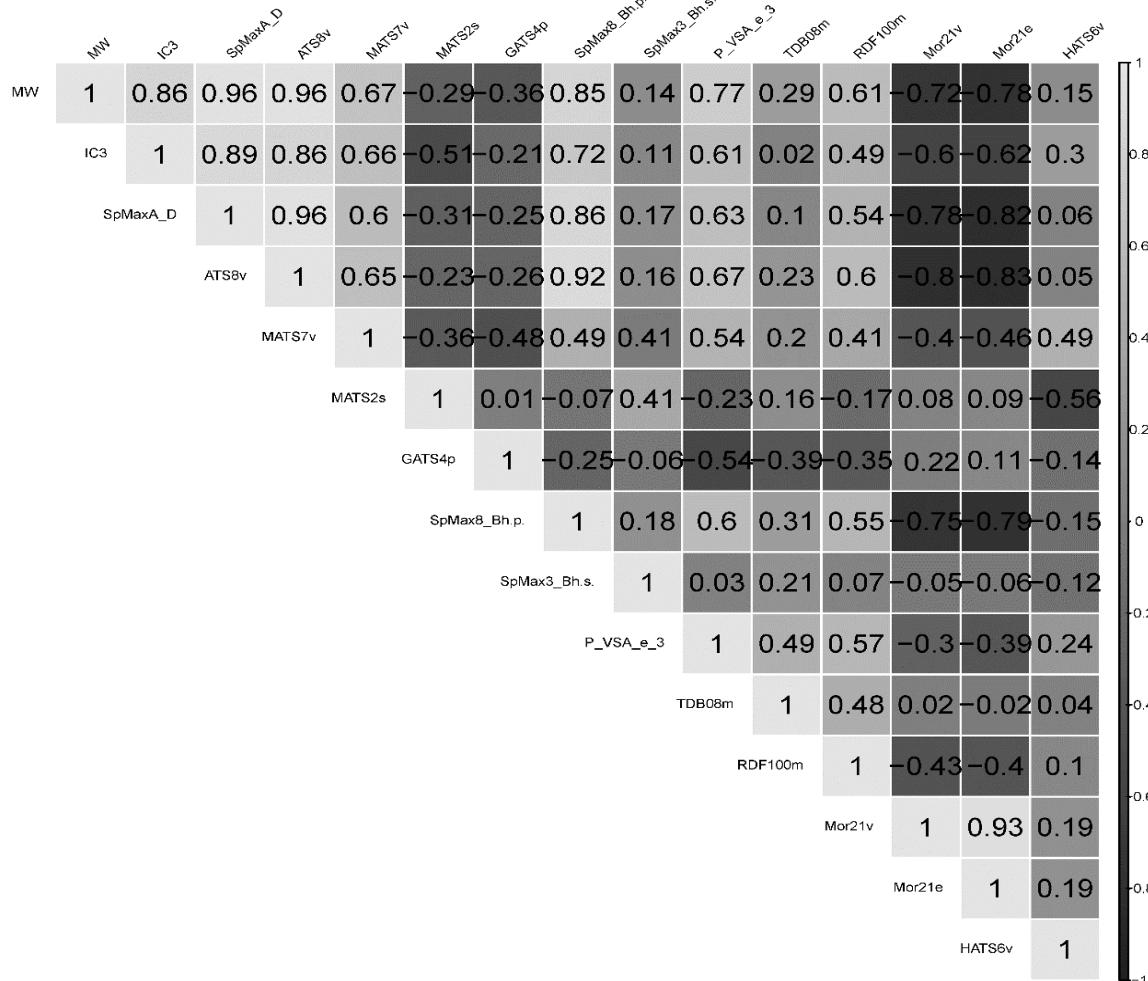
7. **الجانب التطبيقي:** في هذا الجانب، يتم إجراء مقارنة بين أداء المقدر المقترن IGDK ومقدرات أخرى عن طريق استخدام البيانات الفعلية. ويتم تقييم أداء المقدرات باستخدام معيار MSE للتحقق من أداء الطريقة المقترنة IGDK باستخدام البيانات الفعلية، تم استخدام بيانات كيميائية محددة (65,15)، تمثل  $n$  عدد مشتقات  $4,5\text{-b}$  imidazole[pyridine] وهي مركبات مضادة للسرطان، في حين يمثل الرمز  $p$  المتغير التوضيحي والتي ترمز الخصائص الجزيئية (Yahya Algamal, 2019; 10).

تناول هذه الفقرة دور متغير  $(IC_{50})$  كمتغير الاستجابة في تقييم الأنشطة البيولوجية للمركبات المضادة للسرطان، وسلط الضوء على أهمية دراسة العلاقة الكمية بين التراكيب الكيميائية والفاعلية البيولوجية باستخدام نمذجة QSAR وبوصفه نموذجاً لأنشطة البيولوجية على أساس الخصائص الهيكلية لمجموعة من المركبات الكيميائية (Algamal 2017).

تم استخدام اختبار مربع كاي للمطابقة لتحديد مدى ملاءمة التوزيع الكاوسي المعكوس لمتغير الاستجابة  $(IC_{50})$  ، حيث أظهرت النتائج أن قيمة اختبار مربع كاي تساوي 5.2762 وقيمة  $p$ -value تساوي 0.2601. وبناءً على هذه النتائج، يمكن غدّ أن توزيع كاووس المعكوس مناسب لمتغير الاستجابة المعتمد (Yahya Algamal 2019).

فيما يخص الدراسة، فقد تم تضمين 15 واصفاً جزيئياً يمثلون المتغيرات التوضيحية (مستقلة)، ويمكن ملاحظة أن هناك ارتباطات أكبر من 0.90 بين كلاً من MW و SpMaxA\_D

مع  $Mor21v$  ( $r = 0.92$ ) (  $ATS8v$  مع  $SpMax3_Bh(s)$  ( $r = 0.96$ ) (  $ATS8v$  مع  $Mor21e$  ( $r = 0.93$ )).



الشكل (1): مصفوفة الارتباط بين 15 متغير من المتغيرات التوضيحية لكشف وجود الارتباط بين المتغيرات التوضيحية بعد ملائمة نموذج انحدار گاوس المعكوس، تم الحصول على القيم المميزة للمصفوفة  $\widehat{W}^T \widehat{X}^T \widehat{X} \widehat{W}$  وهي:

$3.445 \times 10^6, 2.163 \times 10^5, 2.388 \times 10^4, 1.290 \times 10^3, 9.120 \times 10^2, 1.884 \times 10^9, 4.431 \times 10^2, 1.839 \times 10^2, 1.056 \times 10^2, 5525, 3231, 2631, 1654, 1008$  and  $1.115$

وإن العدد الشرطي المحدد هو  $CN = \sqrt{\lambda_{\max} / \lambda_{\min}} = 40383.035$  وهذا يشير إلى وجود ارتباط قوي بين المتغيرات التوضيحية.

تم إجراء تقييم لنموذج انحدار گاوس المعكوس باستخدام معلمات مقدرة وقيم متوسط مربعات الخطأ  $MSE$  للمقدرات  $IGDK$ ،  $IGLE$  و  $IGRR$ . توضح النتائج المخصصة في الجدول رقم 8 أن المقدر المقترن  $IGDK$  يتتفوق في الأداء على المقدرات الأخرى، حيث حقق أدنى قيمة  $MSE$  بناءً على نتائج المحاكاة ونتائج التطبيق الحقيقي، يمكن الاستنتاج بأن المقدر المقترن  $IGDK$  يوفر نتائج أفضل مقارنة بالمقدرات الأخرى المدروسة عند وجود علاقة خطية متعددة

الجدول (7): وصف المتغيرات التوضيحية

Variable name's	Description
MW	"molecular weight"
IC3	"Information Content index (neighborhood symmetry of 3-order)"
Sp MaxAD	"normalized leading eigenvalue from topological distance matrix"
ATS8v	"Broto-Moreau autocorrelation of lag 8 (log function) weighted by van der Waals volume"
MATS 7v	"Moran autocorrelation of lag 7 weighted by van der Waals volume"
MATS 2s	"Moran autocorrelation of lag 2 weighted by I-state"
GATS 4p	"Geary autocorrelation of lag 4 weighted by polarizability"
SpMax8 Bh(p)	"largest eigenvalue n. 8 of Burden matrix weighted by polarizability"
SpMax3 Bh(s)	"largest eigenvalue n. 3 of Burden matrix weighted by I-state"
P VSA e_3	"P_VSA-like on Sanderson electronegativity, bin 3"
TDB 08m	"3D Topological distance based descriptors lag 8 weighted by mass"
RDF 100m	"Radial Distribution Function 100 / weighted by mass"
Mor 21v	"signal 21 / weighted by van der Waals volume"
Mor 21e	"signal 21 / weighted by Sanderson electronegativity"
HATS 6v	"leverage-weighted autocorrelation of lag 6 weighted by van der Waals volume"

الجدول (8): المعاملات المقدرة وقيم MSE للمقدرات المستخدمة

	IGRR	IGLE	IGDK
$\hat{\beta}_{MW}$	0.741	0.852	0.568
$\hat{\beta}_{IC3}$	0.977	1.104	0.923
$\hat{\beta}_{SpMaxA_D}$	-1.363	-1.304	-1.307
$\hat{\beta}_{ATS8v}$	-1.64	-1.581	-1.069

	<b>IGRR</b>	<b>IGLE</b>	<b>IGDK</b>
$\hat{\beta}_{\text{MATS7v}}$	-1.48	-1.434	-1.181
$\hat{\beta}_{\text{MATS2s}}$	-1.476	-1.420	-1.064
$\hat{\beta}_{\text{GATS4p}}$	-1.498	-1.439	-1.181
$\hat{\beta}_{\text{SpMax8_Bh(p)}}$	2.245	2.304	2.307
$\hat{\beta}_{\text{SpMax3_Bh(s)}}$	1.808	1.867	2.182
$\hat{\beta}_{\text{P_VSA_e_3}}$	1.739	1.798	2.103
$\hat{\beta}_{\text{TDB08m}}$	-2.365	-2.305	-2.151
$\hat{\beta}_{\text{RDF100m}}$	1.309	1.368	1.297
$\hat{\beta}_{\text{Mor21v}}$	-2.695	-2.636	-2.164
$\hat{\beta}_{\text{Mor21e}}$	-2.613	-2.554	-2.188
$\hat{\beta}_{\text{HATS6v}}$	1.95	2.017	2.153
<b>MSE</b>	<b>2.041</b>	<b>1.341</b>	<b>1.105</b>

8. الاستنتاجات: تشير النتائج التي تم الحصول عليها من خلال المحاكاة والبيانات الحقيقية إلى أن استخدام المقدر المقترن IGDK يؤدي إلى نتائج جيدة عند استخدام معيار MSE، مما يجعله موثوقاً للمستخدمين في التنبؤ بالنتائج وتقدير النماذج الإحصائية. فضلاً عن ذلك، يبدو أن حجم العينة  $n$  له تأثير كبير على قيمة MSE، حيث تنخفض قيمة عند زيادة حجم العينة، مما يعني زيادة الدقة. وعلى الجانب الآخر، زيادة عدد المتغيرات التوضيحية  $p$  تؤثر سلباً على قيمة MSE، حيث تزيد قيمة عند زيادة قيمة  $p$ . ويلاحظ أيضاً زيادة في قيمة MSE عند زيادة درجة الارتباط لمعامل الارتباط  $\rho$  كما تزداد قيمة بازدياد قيمة معلمة التشتت  $\phi$ . ويجد بالذكر أن استخدام معيار MSE مع المقدر المقترن IGDK يؤدي إلى نتائج أفضل في التنبؤ بالنتائج وتقدير النماذج الإحصائية.

#### المصادر

1. Abonazel, M. R., Z. Y. Algamal, F. A. Awwad & I. M. Taha, (2022), A new two-parameter estimator for beta regression model: method, simulation, and application. *Frontiers in Applied Mathematics and Statistics*, 7, 87.
2. Akram, M. N., M. Amin & M. Qasim, (2020), A new Liu-type estimator for the inverse Gaussian regression model. *Journal of Statistical Computation Simulation*, 90, 1153-1172.

3. Algamal, Z. Y., & Lee, M. H., (2017), A novel molecular descriptor selection method in QSAR classification model based on weighted penalized logistic regression. *Journal of Chemometrics*, 31.
4. Bühlmann, P. & S. Van De Geer, (2011), *Statistics for high-dimensional data: methods, theory and applications*. Springer Science & Business Media.
5. Dawoud, I. & B. G. Kibria, (2020), A new biased estimator to combat the multicollinearity of the Gaussian linear regression model. *Stats J*, 3, 526-541.
6. Ferrari, S. & F. Cribari-Neto, (2004), Beta regression for modelling rates and proportions. *Journal of applied statistics*, 31, 799-815.
7. Hoerl, A. E. & R. W. Kennar, (1970-b), Ridge regression: applications to nonorthogonal problems. *Technometrics*, 12, 69-82.
8. Hoerl, A. E. & R. W. Kennard, (1970), Ridge regression: Biased estimation for nonorthogonal problems. *Technometrics*, 12, 55-67.
9. Kejian, L., (1993), A new class of blased estimate in linear regression. *Communications in Statistics-Theory Methods*, 22, 393-402.
10. Kurtoğlu, F. & M. R. J. S. P. Özkale, (2016), Liu estimation in generalized linear models: application on gamma distributed response variable. 57, 911-928.
11. Lukman, A. F., K. Ayinde, B. G. Kibria & E. T. Adewuyi, (2022), Modified ridge-type estimator for the gamma regression model. *Communications in Statistics-Simulation and Computation*, 51, 5009-5023.
12. Mawlood, K. I., (2021), Estimating Hazard Function and Survival Analysis of Tuberculosis Patients in Erbil city. *Tikrit Journal of Administration Economics Sciences*, 17.
13. McCullagh, P. & J. Nelder, (1989), *Generalized Linear Models*. London: Chapman and Hall.
14. Naveed, K., M. Amin, S. Afzal & M. Qasim, (2022), New shrinkage parameters for the inverse Gaussian Liu regression. *Communications in Statistics-Theory Methods*, 51, 3216-3236.
15. Olsson, U., (2002), *Generalized linear models. An applied approach*. Studentlitteratur, Lund, 18.
16. Özkale, M. R. & S. Kaçiranlar, (2007), The restricted and unrestricted two-parameter estimators. *Communications in Statistics-Theory and Methods*, 36, 2707-2725.
17. Peter K. D., G. K. S. 2018. *Generalized Linear Models With Examples in R*. New York: Springer.
18. Qasim, M., K. Måansson & B. Golam Kibria, (2021), On some beta ridge regression estimators: Method, simulation and application. *Journal of Statistical Computation Simulation*, 91, 1699-1712.
19. Ross, S. M., (2020), *Introduction to probability and statistics for engineers and scientists*. Academic press.
20. Salh, A. P. D. S. M., H. T. Abdalla, Z. M. J. T. J. o. A. Omer & E. Sciences, (2021), Using Multinomial Logistic Regression model to study factors that affect chest pain. 17.

21. Segerstedt, B., (1992), On ordinary ridge regression in generalized linear models. *Communications in Statistics-Theory Methods*, 21, 2227-2246.
22. Yahya Algamal, Z., (2019), Performance of ridge estimator in inverse Gaussian regression model. *Communications in Statistics-Theory Methods*, 48, 3836-3849.
23. yonis, F. a. & R. A. Othma, (2022), Shrinkage estimators in inverse Gaussian regression model: Subject review. *Iraqi Journal of Statistical Sciences*, 19, 72-82.