

مقارنة بين طريقة المربعات الصغرى الجزئية وخوارزمية تجزئة القيم المفردة لتقدير معلمات أنموذج الانحدار اللوجستي في حالة وجود مشكلة التعدد الخطى بـاستعمال المحاكاة

أ.د. محمود مهدي البياتى/ كلية الادارة والاقتصاد /جامعة بغداد
الباحثة/ هديل حميد شاكر/ كلية الادارة والاقتصاد /جامعة بغداد

تاریخ التقديم: 2018/7/8
تاریخ القبول: 2018/9/12

المستخلص

يعد أنموذج الانحدار اللوجستي من النماذج الاحصائية المهمة حيث يوضح العلاقة بين المتغير التابع ثانى الاستجابة والمتغيرات التوضيحية (التفسيرية).
أن العدد الكبير لمتغيرات توضيحية تستعمل عادة لتوضيح الاستجابة ادى الى ظهور مشكلة التعدد الخطى (Multicollinearity) بين المتغيرات التوضيحية التي تجعل تقدير معلمات النموذج ليست دقيقة.
تم في هذا البحث استعمال طرائق لتقدير معلمات أنموذج الانحدار اللوجستي في حالة وجود مشكلة التعدد الخطى وهذه الطرائق هي طريقة انحدار المربعات الصغرى الجزئية (PLSR) و خوارزمية تجزئة القيم المفردة (SVD)، اذ تم استخدام اسلوب المحاكاة للمقارنة بين طرائق التقدير من خلال متوسط مربعات الخطأ (MSE) لأنموذج.
وأوضح من خلال المقارنة أن خوارزمية تجزئة القيم المفردة (SVD) هي الافضل في تقدير معلمات أنموذج الانحدار اللوجستي في حالة وجود مشكلة التعدد الخطى.

المصطلحات الرئيسية للبحث/ الانحدار اللوجستي، البيانات الثانية، المربعات الصغرى الجزئية، خوارزمية تجزئة القيم المفردة، مشكلة التعدد الخطى





1- المقدمة Introduction

يعرف الانحدار بشكل عام بأنه أحد الأساليب الاحصائية المهمة التي تستخدم بشكل واسع جداً لتحديد وتوضيح التأثيرات بين المتغيرات التوضيحية (التفسيرية) والمتغير التابع (متغير الاستجابة) وتستخدم أيضاً للتنبؤ عن قيمة المتغير التابع بدلالة المتغيرات التوضيحية بعد أيجاد معادلة الانحدار الخطية^[1].

بعد أنموذج الانحدار اللوجستي الاسلوب الاحصائي المستخدم لتوفيق العلاقة بين المتغير التابع ثانٍ القيمة وعدة متغيرات توضيحية أيًا كان نوعها، ويسمى الأنموذج في هذه الحالة أنموذج الانحدار اللوجستي الثاني، ويعد من الأساليب الاحصائية المهمة التي يمكن استخدامها في كثير من مجالات الحياة، مثلًا في مجال الطب والجيولوجيا والبيولوجيا والزراعة.

تكمّن أهمية تحليل الانحدار اللوجستي عند مقارنته بالأساليب الاحصائية الأخرى في أن الانحدار اللوجستي هو أداة أكثر قوّة، لأنّه يقدم اختباراً دلالاً للمعاملات، كما أنه يعطي الباحث فكرة عن مقدار تأثير المتغير التوضيحي على متغير الاستجابة الثانية، فضلاً عن ذلك فإن الانحدار اللوجستي يرتب تأثير المتغيرات، مما يسمح للباحث بالاستنتاج أن متغيراً ما يعد أقوى من متغير آخر في فهم ظهور النتيجة المطلوبة^[3].

تعد مشكلة التعدد الخطي أو الارتباط المتعدد(Multicollinearity) بين المتغيرات التوضيحية، واحدة من أهم وأكثر المشكلات التي تقف عقبه أمام الباحثين عند استخدام الانحدار اللوجستي، وهي تنشأ عندما يتضمن نموذج الانحدار أكثر من متغير توضيحي وتكون هناك علاقة ارتباط قوية بين الاثنين أو أكثر من هذه المتغيرات، أو بين جميع المتغيرات.

لأهمية مشكلة التعدد الخطي في أنموذج الانحدار اللوجستي، تم اقتراح طرائق من قبل الكثير من العلماء والباحثين لمعالجة هذه المشكلة وللحصول على مقدرات دقيقة في الأنموذج اللوجستي.

وهناك العديد من الدراسات والبحوث التي تناولت موضوع أنموذج الانحدار اللوجستي والمشاكل التي يتعرض لها، وطرائق تقدير معلمات هذا الأنماذج في عام (2001م) ناقش الباحثان (Tormod and Bjorn-Helge) مشكلة التعدد الخطي في أنموذج الانحدار اللوجستي والتحليل المميز وحلها باستخدام المربعات الصغرى الجزئية (PLS) والمركبات الرئيسية (PC)، إذ تم التوصل إلى أن المربعات الصغرى الجزئية هي أفضل طريقة لحل مشكلة التعدد الخطي من المركبات الرئيسية وتوصل أيضًا إلى أن المربعات الصغرى الجزئية أفضل من المركبات الرئيسية في إيجاد بعض المركبات المهمة في عملية تصنيف البيانات باستعمال الانحدار اللوجستي والدالة المميزة وفي عام (2005م) قام (Anne and Korbinian)^[7] باستخدام طريقة المربعات الصغرى الجزئية وهي أسلوب احصائي مهم في تحليل البيانات للأبعاد العالية لبيانات الآلاف من الجينات وكذلك لتقييد الأبعاد حيث أن المرحلة الأولى، استخدم التصنيف بالطريقة الكلاسيكية (الانحدار اللوجستي) باستخدام المركبات الرئيسية للمربعات الصغرى الجزئية وفي العام نفسه (2005م) درس الباحثان (LI shen and Eng^[13]) طريقة المربعات الصغرى الجزئية(PLS) وطريقة تجزئة القيم المفردة (SVD) مع الانحدار اللوجستي الجزائري (Penalized Logistic Regression) (PLR) (and Eng^[14]) إذ تم تحديد مجموعة فرعية من (16) جينات لتصنيف سرطان الدم الحاد حيث أن خطأ الاختبار على هذه المجموعة الفرعية من الجينات هو صفر تجريبياً إذ تم التوصل إلى أن هذه الطرائق تعطي نتائج أكثر دقة وفي عام (2009م) قام الباحثان (Francesca and Fabio^[12]) باستخدام طريقة تجزئة القيم المفردة (SVD) في حالة أنموذج الانحدار اللوجستي لتحديد ميزة في علم التصنيف حيث توصل الباحثان إلى أن طريقة تجزئة القيم المفردة (SVD) تعطي نتائج أكثر دقة.



2- مشكلة البحث Problem of the Research

في حالة كون متغير الاستجابة من النوع الثاني أي ثانوي الاستجابة (0,1) مع متغير توضيحي واحد فإنه بالامكان استخدام أنموذج الانحدار اللوجستي في تحليل هذه البيانات، ولكن في ظل وجود متغيرات توضيحية عديدة 7 فأكثر فإنه لايمكن اعتماد النموذج اللوجستي بصيغته العادي وذلك بسبب ظهور مشاكل في المتغيرات التوضيحية، ومن هذه المشاكل هي مشكلة التعدد الخطأ (Multicollinearity) لذلك يتم اللجوء الى استعمال طرائق تلام واقع هذه البيانات.

3- هدف البحث Object of Research

يهدف هذا البحث الى معالجة مشكلة التعدد الخطأ التي من الممكن أن تظهر بين المتغيرات التوضيحية من خلال استخدام طريقة انحدار المربعات الصغرى الجزئية (Partial Least Square Regression: PLSR) وخوارزمية تجزئة القيم المفردة (Singular Value Decomposition: SVD) في الأنماذج اللوجستي للحصول على مقدرات اكثراً دقة من طريقة المربعات الصغرى الاعتيادية في الانحدار اللوجستي، وباستخدام أسلوب المحاكاة يتم المقارنة بين طرائق التقدير من خلال معيار متوسط مربعات الخطأ .MSE

4- الجانب النظري:

1-4 أنموذج الانحدار اللوجستي: Logistic regression model
يبني أنموذج الانحدار اللوجستي على فرض أساسى هو أن المتغير التابع (Y) ثانوي الاستجابة يأخذ أحدى القيمتين (0,1) أما النجاح (Success) بأحتمال (π_i) أو الفشل (Failure) بأحتمال ($1 - \pi_i$) لذلك يكون المتغير (y_i) يتوزع بحسب توزيع برنولي (π_i).^[10]

$$y_i \sim Ber(\pi_i) \\ i=1,2,\dots,n$$

ومن ثم فإن دالة الكثافة الاحتمالية تكون وفق الصيغة الآتية :

$$P(Y_i = y_i) = \pi_i^{y_i} (1 - \pi_i)^{1-y_i} \dots \dots (1)$$

$$y_i=0,1$$

أذ أن :

y_i متغير تابع ثانوي الاستجابة (0,1)
 π_i أحتمال حدوث الاستجابة عندما $y_i=1$
 $1 - \pi_i$ – أحتمال عدم حدوث الاستجابة عندما $y_i=0$
لذلك فإن توقع المتغير y_i يمثل أحتمال حدوث الاستجابة (π_i) وكالاتي:

$$E(y_i) = pr(y = 1) = \pi_i$$

أما تباين المتغير y_i بحسب توزيع برنولي كالاتي:

$$V(y_i) = \pi_i(1 - \pi_i)$$

ليكن X_1, X_2, \dots, X_p مجموعة من المتغيرات التوضيحية ولتكن n تمثل عدد المشاهدات لهذه المتغيرات التي تكون المصفوفة X .^[5]

$$X = (X_{ij})_{n \times p} \dots \dots (2)$$

أذ أن:

$i=1,2,\dots,n$ ، (n) تمثل حجم العينة.
 $j=1,2,\dots,p$ ، (p) تمثل عدد المتغيرات التوضيحية.
فإذا كان $[y_1, y_2, \dots, y_n] = y_i$ عينة عشوائية من المتغير ثانوي الاستجابة وأن $\{0,1\} \in y_i$ ومن ثم فإن
أنموذج الانحدار اللوجستي يكتب بالصيغة الآتية:



مقدمة بين طريقة المربعات الصغرى الجزئية وخوارزمية تجزئة القيم المفردة لتقدير معلمات أنموذج الانحدار اللوجستي في حالة وجود مشكلة التعدد الخطى باستعمال العد

$$y_i = \pi_i + \varepsilon_i \quad \dots\dots(3)$$

اذ أن π_i تمثل دالة الانحدار اللوجستي (احتمال الاستجابة)

$$\pi_i = \frac{\exp\{\beta_0 + \beta_1 X_{i1} + \dots + \beta_p X_{ip}\}}{1 + \exp\{\beta_0 + \beta_1 X_{i1} + \dots + \beta_p X_{ip}\}} \quad \dots \dots (4)$$

أو يمكن كتابته بالصيغة الآتية:

$$\pi_i = \frac{\exp\{\beta_0 + \sum_{j=1}^p \beta_j X_{ij}\}}{1 + \exp\{\beta_0 + \sum_{j=1}^p \beta_j X_{ij}\}} \quad \dots \dots (5)$$

حيث β_0, \dots, β_p هي معلمات النموذج، وأن ϵ يمثل حد الخطأ العشوائي بمتوسط صفر ومتباين $\pi_i(1 - \pi_i)$.

نلاحظ من المعادلة (5) أن شكل العلاقة بين المتغيرات التوضيحية (X_{ij}) واحتمال الاستجابة π_i لا يمكن أن يكون خطياً وإنما تأخذ شكلاً منحنياً.

لقد اقترح (Berkson) عام 1944م بأنه يمكن تحويل دالة الانحدار اللوجستي إلى دالة خطية وبحسب الصيغة الآتية^[9]:

$$\frac{\pi_i}{(1-\pi_i)} = \exp \{ \beta_0 + \sum_{j=1}^p \beta_j X_{ij} \} \quad \dots \dots (7)$$

وبأخذ اللوغاريتم الطبيعي لكلا الطرفين نحصل على:

$$Z_i = \ln\left(\frac{\pi_i}{1-\pi_i}\right) = \beta_0 + \sum_{j=1}^p \beta_j X_{ij} \quad \dots (8)$$

أذأن

(Z_i) تمثل العلاقة الخطية الناتجة من اخذ اللوغاريتم الطبيعي ل($\frac{\pi_i}{1-\pi_i}$) والذي يتبع التوزيع الطبيعي بمتوسط وتبالين⁻¹ [X_iβ] [n_iπ_i(1-π_i)] اي ان^[9]:

$$Z_i \sim N((X_i \beta), [n_i \pi_i(1 - \pi_i)]^{-1}) \quad \dots \dots (9)$$

4-2 طرائق تقدير معلمات أنموذج الانحدار اللوجستي في حالة وجود مشكلة التعدد الخطى:

4-2-1 طريقة انحدار المربعات الصغرى الجزئية: Partial Least Square Regression(PLSR)
أن طريقة المربعات الصغرى الجزئية تعتمد على خطوتين اساسيتين الاولى هي ايجاد المتغيرات الكامنة (Latent variable) بين X و Y من خلال تعظيم مصفوفة التباين والثانية هي الخطوة الثانية هي

نفرض لدينا المصفوفة $Xn \times p$ والمتجه $Xn \times 1$ المربعات الصغرى الجزئية تعتمد على النموذج الثاني بين X و Y وكالاتي [11][15]:

$$X = TP' + E \quad \dots \dots \dots (10)$$

$$Y = Uq' + f \quad \dots\dots(11)$$

۱۳

T : مصفوفة ذات x-score مصفوفة ذات ذات pqr حيث أن T هي متماثلة Symmetric

U: مصروفه در حات ذات، ته Y-score-nxr

P': مصروفه تحميلات x-loading ذات رتبة

٩: متحه تحميلات-Y بعد X-loading

E: مصروفه البياني - x-residual ذات رتبة



\underline{Y} : متوجه الباقي Y-residual ببعد $n \times 1$
 المصفوفة P^T والمتجه q^T له r من الأعمدة وهو محدد بما يأتي:
 $(r < \min(n, p))$

اذ ان:
 P : عدد المتغيرات
 n : عدد المشاهدات
 r : عدد المركبات
 والعلاقة الداخلية التي تربط بين scores تعطى كالتالي
(12)

$$U = TD + H$$

حيث D مصفوفة قطرية ذات رتبة $r \times r$
 H مصفوفة الباقي ذات رتبة $n \times r$
 الفكرة الاساسية في المربعات الصغرى الجزئية هو في كيفية ايجاد المتوجه w من مجال X والمتوجه c من المجال Y بحيث ان

$$\text{Max } \text{COV}(Xw, Yc) \\ \text{with } \|t\| = \|Xw\| = \|Yc\| = 1 \quad \dots \dots (13)$$

اذ ان COV هو تقدير التباين المشترك وان t, u هي اعمدة في المصفوفتين T, U ويتم تنفيذ التكرارات بطريقة متسلسلة وهذا يعني ان المتوجهات $scores$ يتم احتسابها الواحد بعد الاخر حتى يتم استخراج كافة المتوجهات الى r تحت القيد عدم الارتباط بين المتوجهات وتوجد طرائق عده لحل المعادلة (13) منها خوارزمية Kernel و خوارزمية SIMPLS و خوارزمية NIPALS وغيرها من الخوارزميات وفي هذا البحث تم الاعتماد على خوارزمية التكرار غير الخطى للمربعات الصغرى الجزئية Non-linear Iterative partial least squares NIPALS(PLS1)

1-1-2-4 خوارزمية NIPALS(PLS1)
 فيما يأتي الخطوات الاساسية لخوارزمية NIPALS(PLS1) لحساب اول مركبة^[4]
 1- في الخطوة الاولى يتم تهيئة U_1 عن طريق \underline{Y} بحيث

$$U_1 = \underline{Y} \dots \dots (14)$$

اذ ان U_1 متوجه ببعد $n \times 1$
 2- حساب X-weight

$$W_1 = X' U_1 / (U_1' U_1) \dots \dots (15)$$

اذ ان W_1 متوجه ببعد $1 \times n$

$$W_1 = W_1 / \|W_1\|$$

اذ ان W_1 يكون normalize بالشكل

3- اسقاط البيانات X على W_1 لحساب x-scores و كالاتي

$$t_1 = XW_1 \dots \dots (16)$$

اذ ان t_1 متوجه ببعد 1×1
 4- حساب y-weight

$$C_1 = \hat{Y} t_1 / (t_1' t_1) \dots \dots (17)$$

اذ ان C_1 متوجه ببعد 1×1

اذ ان C_1 تكون normalize بالشكل $C_1 = C_1 / \|C_1\|$ لحساب Y-weight

5- اسقاطات بيانات Y على C_1 لحساب y-scores

$$U_1^* = Y C_1 \dots \dots (18)$$

حيث U_1^* متوجه ببعد $n \times 1$



مقدمة بين طريقة المربعات الصغرى الجزئية وخوارزمية تجزئة القيم المفردة لتقدير معلمات أنموذج الانحدار اللوجستي في حالة وجود مشكلة التعدد الخطبي باستعمال المحاكاة

٦- نحدد _١^{*} بحيث تحقق ما يأتي

$$\Delta U = (U\Delta)'(U\Delta) \dots (19)$$

$$\mathbf{U}\Delta = U^*_1 - U_1$$

إذا كانت ΔU وجدنا اول مرکبة ونتوقف حيث U^* قيمه صغیره عدا ذك نذهب الى الخطوة الاولى
ونستعمل U_1 بدل U ونستمر بالخطوات.

7- ایجاد X-loading

$$P_1 = X't_1/(t'_1 t_1)$$

اذا ان P_1 متوجه ببعد 1 Y-loading - ايجاد 8

$$\mathbf{q} = \underline{\mathbf{Y}'\mathbf{U}_1}/(\mathbf{U}'_1\mathbf{U}_1) \quad \dots\dots(21)$$

حيث ان q متوجه ببعد 1×1

٩- ايجاد التداخل الخطى للمعلم بواسطة انحدار OLS

$$d_1 = U'_1 t_1 / (t'_1 t_1)$$

اذا ان d_1 متوجه ببعد 1

10- عمل تفريغ deflate الى بيانات X وبيانات Y

$$X_1 = X - t_1 P'_{-1}$$

.....(23)

$$Y_1 = Y - d_1 t_1 C'_1$$

.....(24)

ونستمر بالخطوات من (1-10) عدة مرات وباستعمال البيانات المفرغة إلى X وY حتى نحصل على كل المركبات المحددة ونستطيع ان نجد معاملات الانحدار بواسطة العلاقة الآتية

-11- ايجاد معاملات الانحدار

$$\beta = w(p'w)^{-1} c'$$

اذا ان W هي مصفوفة برتبة $p \times r$

pxr مصفوفة برتبة P

C مصفوفة برتبة rxr

٤-٢-٢ خوارزمية تجزئة القيم المفردة: Singular Value Decomposition (SVD)

تقوم هذه الخوارزمية بأختصار عدد الأبعاد إلى أقل ما يمكن بحيث تكون الأبعاد المتبقية لها أكبر تباين (معنوي آخر ضغط البيانات عن طريق إزالة المتكرر)، عادة تستخدم كعملية سابقة لعمليات تحليل وتنقيب البيانات ، يمكن النظر إلى تجزئة القيمة المفردة (SVD) من ثلاثة نقاط متوافقة مع بعضها البعض، فمن جهته يمكننا أن نرى ذلك كوسيلة لتحويل المتغيرات المترابطة إلى مجموعة من تلك غير المترابطة التي تعرض أفضل العلاقات المختلفة بين عناصر البيانات الأصلية، في نفس الوقت SVD هو طريقة لتحديد وترتيب الأبعاد لبيانات التي تظهر أكبر التباين، إذ أنه بمجرد تحديد أكبر تباين فإنه من الممكن العثور على أفضل تقرير من نقاط البيانات الأصلية باستخدام أبعاد أقل، ومن ثم يمكن عدّها SVD كوسيلة لخفض البيانات، تستخدم خوارزمية تجزئة القيم المفردة (SVD) للتخلص من مشكلة التعدد الخطى التام بين المتغيرات [٨] التوضيحية

تستخدم خوارزمية تجزئة القيم المفردة (SVD) لأيجاد المركبات الرئيسية اذ انها تعطى المتوجه المميز والقيم المميزة التي تحتاج في تحليل المركبات الرئيسية ، اذ انه في تحليل المركبات الرئيسية (PCA) نحصل على اول مركبة رئيسية (PC) بأستعمال SVD من خلال تجزئة المصفوفة X ذات الرتبة $p \times n$ الى ثلاثة مصفوفات وکالاتي [8][14] :



$$X = T_0 S P^I \quad \dots\dots(26)$$

نفرض أن

$$t = \min\{n, p\}$$

اذ أن:

T_0 : مصفوفة متعمدة ذات رتبة $t \times n$ وهي مصفوفة المركبات ويتم ايجادها من المتوجه المميز $L' XX'$
 S : مصفوفة قطرية ذات رتبة $t \times t$ وهي تساوي الجذور المربعة الى القيم المميزة $L' X' X$ أو $X' X$ اذا ان

$$S = \text{diag}\{\theta_1 > \theta_2 > \dots > \theta_p > 0\}$$

P : مصفوفة متعمدة ذات رتبة $t \times p$ وهي مصفوفة تحويل ويتم ايجادها من المتوجه المميز $X' X$ الى

اذ أن المركبات الرئيسية في التحليل هي T يمكن أن تكون(27)

$$T = T_0 S$$

$$X = T_0 S P + \varepsilon \quad \dots\dots(28)$$

أما معاملات الانحدار هي

$$\begin{aligned} \beta &= P(T'T)^{-1} T'y \\ &= P S^{-1} T'_0 \end{aligned} \quad \dots\dots(29)$$

5- الجانب التجاري:

1-5 مراحل تطبيق تجربة المحاكاة

Stages of the application of simulation experiment

لقد تضمنت تجارب المحاكاة كتابة عدد من البرامج بلغة (MATLAB 2017)، إذ أن الأنموذج الذي تم الاعتماد عليه يكون وفق الصيغة الآتية:

$$y_i = \pi_i + \varepsilon_i \quad \dots\dots(30)$$

اذ يتم وصف مراحل تجربة المحاكاة من خلال الخطوات الآتية:

1- تعين القيم الافتراضية للمعلمات وهذه المرحلة من اهم المراحل التي يعتمد عليها، حيث تم تحديد القيم الافتراضية للمعلمات كقيم اولية من دراسات سابقه، اذ اختيرت قيم المعلمات والنماذج المفترض كما مبين في ادناه:

β_0	β_1	β_2	β_3	β_4	β_5	β_6	β_7
0.33	0.41	-0.95	-0.17	-0.29	1.38	-0.61	-0.94

2- توليد المتغيرات التوضيحية من خلال استعمال اسلوب مونت-كارلو(Mont-Carlo) في المحاكاة حيث يتم توليد سبعة متغيرات توضيحية وفق التوزيع الطبيعي القياسي وحدوث مشكلة التعدد الخطبي بحسب الصيغة الآتية [6]

$$X_{ij} = (1 - P^2)^{\frac{1}{2}} u_{ij} + P u_{i(p+1)} \quad , \quad i=1,2,\dots,n, \quad j=1,2,\dots,p \quad \dots\dots(31)$$

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

$u_{i(p+1)}$: يمثل قيم العمود الأخير من أعمدة المتغيرات المولدة.

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

i : يمثل عدد المشاهدات.

P : يمثل قيمة الارتباط بين المتغيرات التوضيحية .



**مقارنة بين طريقة المربعات الصغرى الجزئية وخوارزمية تجزئة القيم المفردة لتقدير
معلمات أنموذج الانحدار اللوجستي في حالة وجود مشكلة التعدد الخطأ باستعمال المحاكاة**

- 3- توليد قيم متغير الخطأ العشوائي في أنموذج الانحدار اللوجستي تبعاً لتوزيع برنولي.
- 4- حساب المتغير التابع (y) ثاني الاستجابة الذي يتوزع توزيع برنولي، وفق طريقة توليد التحويل المعكوس(invers transformation) بالاعتماد على دالة الانحدار اللوجستي (π) وحد الخطأ العشوائي
- 5- من أهم العوامل الأخرى التي يتم اختيارها والموزّرة هي كالتالي:
- اختيار أربعة أحجام للعينات المقترضة وهي (200,100,50,25)
 - اختيار القيم الافتراضية لمعاملات الارتباط وهي (0.99,0.90,0.80)
- 6- تقدير معلمات أنموذج الانحدار اللوجستي وفق طرائق التقدير التي تم عرضها في الجانب النظري وهي كالتالي:
- 1- طريقة انحدار المربعات الصغرى الجزئية (PLSR).
 - 2- خوارزمية تجزئة القيم المفردة (SVD).
- 7- أما في هذه المرحلة، تتم المقارنة بين طرائق التقدير المدروسة بالاعتماد على المقياس الاحصائي متوسط مربعات الخطأ (MSE) للأنموذج.
- $$MSE = \frac{1}{n} \sum_{i=1}^n (\hat{\pi}_i - \pi_i)^2 \dots\dots (32)$$
- واخيراً سوف يتم تكرار تجربة المحاكاة (1000) مرّة.

2- تحليل نتائج المحاكاة

جدول رقم (1) يبيّن تقديرات المعلمات وقيم متوسط مربعات الخطأ لأنموذج الانحدار اللوجستي في حالة $n = 25$ وبارتباطات مختلفة

coefficients		ethods	
		PLS-LR	SVD-LR
$\rho = 0.80$	$\hat{\beta}_0$	0.6223	0.6037
	$\hat{\beta}_1$	-1.5584	-0.1316
	$\hat{\beta}_2$	-2.9660	-0.3779
	$\hat{\beta}_3$	1.6159	0.4421
	$\hat{\beta}_4$	-0.0956	-0.4892
	$\hat{\beta}_5$	1.4277	0.4850
	$\hat{\beta}_6$	0.5762	-0.0021
	$\hat{\beta}_7$	-1.7556	-0.3079
<i>MSE</i>		0.0430	0.2272
$\rho = 0.90$	$\hat{\beta}_0$	0.9379	0.6027
	$\hat{\beta}_1$	-1.2520	-0.1542
	$\hat{\beta}_2$	-4.0195	-0.4661
	$\hat{\beta}_3$	3.8164	0.6021
	$\hat{\beta}_4$	-2.1037	-0.6292
	$\hat{\beta}_5$	4.4086	0.6707
	$\hat{\beta}_6$	1.4833	0.0011
	$\hat{\beta}_7$	-1.6693	-0.3835



**مقارنة بين طريقة المربعات الصغرى الجزئية وخوارزمية تجزئة القيم المفردة لتقدير
معلمات أنموذج الانحدار اللوجستي في حالة وجود مشكلة التعدد الخطأ باستعمال المعاكمة**

MSE		0.5315	0.2270
$\rho = 0.99$	$\hat{\beta}_0$	1.9452	0.5764
	$\hat{\beta}_1$	1.2372	-0.7521
	$\hat{\beta}_2$	1.6299	0.3048
	$\hat{\beta}_3$	0.2982	1.0379
	$\hat{\beta}_4$	-2.5430	-2.0744
	$\hat{\beta}_5$	1.1551	1.4358
	$\hat{\beta}_6$	-1.3145	-0.1619
	$\hat{\beta}_7$	-0.7477	-0.2738
MSE		2.6251	0.1292

جدول رقم (2) يبين تقديرات المعلمات و قيم متوسط مربعات الخطأ لأنموذج الانحدار اللوجستي في حالة $n = 50$ وبارتباطات مختلفة.

coefficients	Methods	
	PLS-LR	SVD-LR
$\rho = 0.80$	$\hat{\beta}_0$	0.8437
	$\hat{\beta}_1$	0.1583
	$\hat{\beta}_2$	-0.6667
	$\hat{\beta}_3$	-2.0207
	$\hat{\beta}_4$	-0.7534
	$\hat{\beta}_5$	3.8577
	$\hat{\beta}_6$	0.6635
	$\hat{\beta}_7$	-1.4759
MSE	0.3158	0.3256
$\rho = 0.90$	$\hat{\beta}_0$	1.1388
	$\hat{\beta}_1$	2.9498
	$\hat{\beta}_2$	0.5989
	$\hat{\beta}_3$	-0.6850
	$\hat{\beta}_4$	-1.4520
	$\hat{\beta}_5$	1.1056
	$\hat{\beta}_6$	0.4241
	$\hat{\beta}_7$	-0.8912



**مقارنة بين طريقة المربعات الصغرى الجزئية وخوارزمية تجزئة القيم المفردة لتقدير
معلومات أنموزج الانحدار اللوجستي في حالة وجود مشكلة التعدد الخطأ باستعمال المعاكمة**

MSE		0.9166	0.3797
$\rho = 0.99$	$\hat{\beta}_0$	1.6533	0.6643
	$\hat{\beta}_1$	2.3920	0.7841
	$\hat{\beta}_2$	0.3864	0.4513
	$\hat{\beta}_3$	1.1341	-0.6195
	$\hat{\beta}_4$	-1.0094	-0.8437
	$\hat{\beta}_5$	-1.4502	0.1186
	$\hat{\beta}_6$	-0.2631	-0.0264
	$\hat{\beta}_7$	-0.0776	-0.1912
MSE		3.1336	0.3723

جدول رقم (3) يبين تقديرات المعلومات وقيم متوسط مربعات الخطأ لأنموذج الانحدار اللوجستي في حالة $n = 100$ وبارتباطات مختلفة.

coefficients		Methods	
		PLS-LR	SVD-LR
$\rho = 0.80$	$\hat{\beta}_0$	1.1774	0.5379
	$\hat{\beta}_1$	0.6195	0.1808
	$\hat{\beta}_2$	1.1958	-0.1083
	$\hat{\beta}_3$	0.5448	0.0466
	$\hat{\beta}_4$	-1.5659	-0.2114
	$\hat{\beta}_5$	2.9040	0.2641
	$\hat{\beta}_6$	-1.0970	-0.2212
	$\hat{\beta}_7$	-1.6154	-0.2053
MSE		2.2721	0.6820
$\rho = 0.90$	$\hat{\beta}_0$	1.5461	0.5557
	$\hat{\beta}_1$	-0.0853	0.0781
	$\hat{\beta}_2$	1.8931	-0.0843
	$\hat{\beta}_3$	-0.2563	0.0397
	$\hat{\beta}_4$	-0.7778	-0.2314
	$\hat{\beta}_5$	1.8156	0.2201
	$\hat{\beta}_6$	-0.0810	-0.1365
	$\hat{\beta}_7$	-1.1259	-0.1795
MSE		5.7854	0.6695
$\rho = 0.99$	$\hat{\beta}_0$	1.5222	0.6193
	$\hat{\beta}_1$	-0.6439	-0.1130
	$\hat{\beta}_2$	2.6572	0.1032
	$\hat{\beta}_3$	0.3443	0.1135



**مقارنة بين طريقة المربعات الصغرى الجزئية وخوارزمية تجزئة القيم المفردة لتقدير
معلمات أنموذج الانحدار اللوجستي في حالة وجود مشكلة التعدد الخطأ باستعمال المحاكاة**

$\hat{\beta}_4$	-0.3744	-0.3512
$\hat{\beta}_5$	0.3990	0.1550
$\hat{\beta}_6$	-0.3114	-0.1460
$\hat{\beta}_7$	-0.3966	0.0097
<i>MSE</i>	5.3224	0.8018

جدول رقم (4) يبين تقديرات المعلمات وقيمة متوسط مربعات الخطأ لأنموذج الانحدار اللوجستي في
حالة $n = 200$ وبارتباطات مختلفة

coefficients		Methods	
		PLS-LR	SVD-LR
$\rho = 0.80$	$\hat{\beta}_0$	1.1008	0.5934
	$\hat{\beta}_1$	1.1164	0.0686
	$\hat{\beta}_2$	-2.0406	-0.2736
	$\hat{\beta}_3$	-0.4392	0.0273
	$\hat{\beta}_4$	-0.8210	0.0195
	$\hat{\beta}_5$	3.0267	0.3835
	$\hat{\beta}_6$	0.0160	-0.2345
	$\hat{\beta}_7$	0.2301	-0.1521
<i>MSE</i>		2.8633	1.1444
$\rho = 0.90$	$\hat{\beta}_0$	1.3609	0.5957
	$\hat{\beta}_1$	1.0980	0.0443
	$\hat{\beta}_2$	-1.5818	-0.4175
	$\hat{\beta}_3$	-0.4076	0.0305
	$\hat{\beta}_4$	-0.9296	0.0432
	$\hat{\beta}_5$	1.8816	0.4421
	$\hat{\beta}_6$	0.8017	-0.2134
	$\hat{\beta}_7$	0.7385	-0.1546
<i>MSE</i>		6.5187	1.0897
$\rho = 0.99$	$\hat{\beta}_0$	1.6389	0.5875
	$\hat{\beta}_1$	1.4889	-0.1597
	$\hat{\beta}_2$	-0.9998	-0.8841
	$\hat{\beta}_3$	-0.5393	0.2081
	$\hat{\beta}_4$	-1.3706	-0.2092
	$\hat{\beta}_5$	1.2753	0.7104
	$\hat{\beta}_6$	0.7280	-0.1635
	$\hat{\beta}_7$	0.5995	0.2207
<i>MSE</i>		11.9241	0.9535



مقارنة بين طريقة المربعات الصغرى الجزئية وخوارزمية تجزئة القيم المفردة لتقدير معلومات أنموذج الانحدار اللوجستي في حالة وجود مشكلة التعدد الخطى باستعمال المحاكاة

من خلال النتائج المبينة في الجدول(1) و (2) و (3) و(4) نلاحظ الآتي:

- 1- عند حجوم العينات (25) و (50) وعندما يكون معامل الارتباط ($P=0.80$) نلاحظ أن طريقة المربعات الصغرى الجزئية (PLS) تمتلك أقل (MSE) بينما عندما يكون معامل الارتباط ($0.99, 0.90$, $P=0.90$) نلاحظ أن خوارزمية تجزئة القيم المفردة (SVD) تمتلك أقل (MSE).
- 2- عند حجوم العينات (100) و (200) ولجميع قيم معاملات الارتباط ($0.99, 0.90, 0.80$, $P=0.80$) نلاحظ بأن خوارزمية تجزئة القيم المفردة (SVD) أفضل من طريقة المربعات الصغرى الجزئية (PLS) في معالجة مشكلة التعدد الخطى لأنموذج الانحدار اللوجستي وذلك لأنها تمتلك أقل (MSE).

6- الاستنتاجات والتوصيات

1-6 الاستنتاجات

- 1- أثبتت خوارزمية تجزئة القيم المفردة (SVD) كفاءتها في تقدير معلومات أنموذج الانحدار اللوجستي في حالة وجود مشكلة التعدد الخطى بالنسبة لقيم معاملات الارتباط ($0.99, 0.90, 0.80$, $P=0.80$) ولحجوم العينات الكبيرة وذلك لأنها حققت أقل (MSE) لأنموذج وكذلك أثبتت خوارزمية (SVD) بأنها الأفضل في حالة حجوم العينات المتوسطة والصغيرة ولقيم معاملات الارتباط ($0.99, 0.90$, $P=0.80$) وذلك لأنها حققت أقل (MSE) لأنموذج .
- 2- أثبتت طريقة المربعات الصغرى الجزئية (PLS) بأنها الأفضل في حالة حجوم العينات المتوسطة والصغيرة ولقيمة معامل الارتباط (0.80) لأنها حققت أقل (MSE) لأنموذج.

2-6 التوصيات

- 1- استعمال خوارزمية تجزئة القيم المفردة (SVD) في تقدير معلومات أنموذج الانحدار اللوجستي في حالة وجود مشكلة التعدد الخطى وباختلاف احجام العينات لما تبديه من كفاءة ومرنة في التطبيق.
- 2- استعمال طريقة المربعات الصغرى الجزئية (PLS) في تقدير معلومات أنموذج الانحدار اللوجستي في حالة وجود مشكلة التعدد الخطى في حالة حجوم العينات المتوسطة والصغيرة.
- 3- استخدام خوارزميات أخرى لطريقة المربعات الصغرى الجزئية (PLS) غير خوارزمية (NIPALS(PLS1)) المستعملة في البحث مثل خوارزمية (SIMPLS) وخوارزمية (Kernel) في تقدير معلومات أنموذج الانحدار اللوجستي في حالة وجود مشكلة التعدد الخطى.

7- المصادر

- 1- البياتي ، محمود مهدي حسن . (2012) ، " تطبيق عملي لتحليل البيانات الاحصائية " ، الجزيرة للطبع والنشر/جامعة بغداد.
- 2- صالح ، رباب عبد الرضا . (2016) ، " مقارنة بين طرائق المربعات الصغرى الجزئية والمركبات الرئيسية باستعمال المحاكاة " ، مجلة العلوم الاقتصادية والإدارية ، المجلد 22 ، العدد 87 .
- 3- عباس ، علي خضير . (2012) ، " استخدام نموذج الانحدار اللوجستي في التنبؤ بالدوال ذات المتغيرات الاقتصادية التابعة النوعية " ، مجلة جامعة كركوك للعلوم الادارية والاقتصادية ، المجلد 2 ، العدد 2 .
- 4- Abdi , Hervi , (2010). " Partial Least Squares Regression and Projection on Latent Structure Regression (PLS Regression) " , John Wiley & Sons, 1-10
- 5- Aguilera , A.M., and Escabias , M and M.J. Valderrama , (2006). " Using principal components for estimating Logistic regression with high dimensional Multicollinearity data " , Computational statistics Data Analysis 50 , 1905-1924.
- 6- Al-Hassan , Yazid m., (2008). " A Monte Carlo Evaluation of Some Ridge Estimators " , J.J. Appl. Sci: Natural Sciences Series 10(2): 101-110.
- 7- Anne Laure Boulesteix , Korbinian Strimmer , (2005). "Partial Least Squares: a Versatile Tool for the analysis of high-dimensional genomic data " , Briefings in Bioinformatics , oxford University , P.32-44.
- 8- Baker , K., (2005) . " Singular Value Decomposition Tutorial " .



- 9- Berkson , J.,(1944). "Application of the Logistic Function to Bioassay",JASA Vol.39,pp.357-365.
- 10- Cook , D., Dixon , P., Duckworth , W.M., Kaiser , M.S.,Koehler, K., Meeker , W.Q and Stephenson , W.R., (2001). " Binary Response and Logistic Regression Analysis ", University NSF/ILI Project Beyond Traditional statistical Methods , grant.
- 11- Chong , I., Jun T,C., (2005). "Performance of some variable selection methods when multicollinearity Present ", Chemometrics and Intelligent Laboratory systems 78 , 103-112.
- 12- Francesca , Fallucchi and Fabio , Massimo Zanzotto , (2009) , " Singular Value Decomposition for Feature Selection in Taxonomy Learning " , Via del Politecnico 00133 Rome , Italy.
- 13- LI Shen , Eng , Chong , Tan , (2005). " PLS and SVD Based Penalized Logistic Regression for cancer Classification Using Microarray Data " , School of Computer Engineering , Nanyang Technological University , Singapore , pp 219- 228.
- 14- Mevik , B., Wehrens , R., (2007). " The PLS Package: Principal component and partial Least squares Regression in R ".
- 15- Roon , P., Zakizadeh , J., Chartier , S., (2014). " Partial Least Squares tutorial analyzing neuroimaging data ".
- 16- Tormod Naes and Bjorn-Helge Mevik , (2001). " Understanding The Collinearity Problem in Regression and Discriminant Analysis " , Journal of Chemo Metrics , p.413-426.



Comparison of the method of partial least squares and the algorithm of singular values decomposition to estimate the parameters of the logistic regression model in the case of the problem of linear multiplicity by using the simulation

Abstract

The logistic regression model is an important statistical model showing the relationship between the binary variable and the explanatory variables. The large number of explanations that are usually used to illustrate the response led to the emergence of the problem of linear multiplicity between the explanatory variables that make estimating the parameters of the model not accurate.

The methods used to estimate the parameters of the logistic regression model in the case of the linear multiplication problem.

These methods are the method of regression of the partial least squares and the algorithm of singular value decompositon.

The simulation method was used to compare estimation methods through the mean error squares of the model.

It has been shown through the comparison that the algorithm of singular value decompositon is best in estimating the parameters of the logistic regression model in the case of the problem of linear multiplicity.

Keywords Logistic regression, binary data, partial least square, algorithm singular value decomposition, multicollinearity.