

التحليل المميز والانحدار اللوجستي بوجود مشكلة التعدد الخطى (دراسة تطبيقية على مرض فقر الدم)

أ.م.د. رباب عبد الرضا صالح البكري /جامعة بغداد / كلية الادارة والاقتصاد
الباحث / محمد شاكر محمود العزي / جامعة بغداد / كلية الادارة والاقتصاد

تاريخ التقديم: 2017/1/15
تاريخ القبول: 2017/1/26

المستخلص

تعد طريقة الانحدار اللوجستي الثنائي regression logisticBinary والدالة المميزة الخطية Linear discriminant function من اهم الطرائق الاحصائية المستخدمة في التصنيف والتتبؤ، عندما تكون البيانات من النوع الثنائي (0،1) فإنه لا يمكن استخدام الانحدار الاعتيادي فلذلك نتج الى الانحدار اللوجستي الثنائي والدالة المميزة الخطية في حالة وجود مجموعتين، وفي حالة وجود مشكلة التعدد الخطى Multicollinearity بين البيانات (ان البيانات يوجد فيها ارتباطات عالية بين المتغيرات) أصبح عدم الامكان في استخدام الانحدار اللوجستي والدالة المميزة الخطية، ولحل هذه المشكلة نتج الى طريقة انحدار المربعات الصغرى الجزئية Partial least square regression لحل مشكلة التعدد الخطى.

وقد جرى في هذه البحث المقارنة بين الانحدار اللوجستي الثنائي regression logistic binary والدالة المميزة الخطية linear discriminant function عن طريق خطأ التصنيف. حيث تم جمع بيانات عن مرض فقر الدم بمتغيرين هما فقر الدم الحاد بالرمز (0)، وفقر الدم المزمن بالرمز (1) وبعده متغيرات حول المرض. جمعت البيانات من عدة مستشفيات عراقية، وجمعت عينة من المرضى الراغبين في المستشفى وحالات سابقة رقدت في المستشفى بعينة قدرها (140) مريضاً مصاباً بهذا المرض. وعند اختبار البيانات وجدت ان هناك مشكلة التعدد الخطى Multicollinearity تمت معالجتها باستعمال طريقة المربعات الصغرى الجزئية Partial least square .

وتوصل البحث الى ان الدالة المميزة الخطية linear discriminant function هي افضل في تصنيف البيانات من الانحدار اللوجستي الثنائي binary logistic regression ، اذ صفت الدالة المميزة البيانات بشكل صحيح وأكثر دقة من الانحدار اللوجستي الثنائي.

المصطلحات الرئيسية للبحث / الدالة المميزة الخطية- الانحدار اللوجستي الثنائي- المربعات الصغرى الجزئية - مشكلة التعدد الخطى - نسبة التصنيف.





1- المقدمة Introduction

في اي بلد في العالم توجد هناك الكثير من الامراض والعرق واحد من البلدان الموجودة في العالم التي طالما تعاني الكثير من الامراض المتنوعة التي تصيب الانسان سواء كانت مزمنة او مكتسبة او متوازنة عن طريق الاجيال. ان فقر الدم واحد من كثير من الامراض التي تعاني منها المجتمعات في العالم ولطالما اخذ الكثير من الباحثين دراسات حول اسباب هذا المرض والوقاية منه. وفي موضوع البحث سيتم اخذ المرض من اتجاهين الاتجاه الاول (فقر دم حاد) والاتجاه الثاني (فقر دم مزمن). وعندما يكون المتغير المعتمد من النوع الثاني فأنتا نلجاً الى الانحدار اللوجستي سيتم اعتماد طريقتين للعمل على هذا المرض وهما طريقة الانحدار اللوجستي الثاني وطريقة الدالة المميزة الخطية باستعمال المربعات الصغرى الجزئية.

ان طريقة الانحدار اللوجستي من الطرائق المهمة التي تدخل في تحليل البيانات التي يكون فيها المتغير المعتمد (Y) يكون فيه البيانات ثنائية (0,1)، ويكون الهدف الاساس من هذه الطريقة هو ايجاد أفضل نموذج يصف الحالة بين المتغير المعتمد والمتغير التوضيحي (المتغيرات التوضيحية)، وان طريقة التحليل المميز هي من التحليلات الاحصائية التي تهتم بمتعدد المتغيرات حيث يتم بهذا التحليل استعمال مجموعة من التغيرات للتميز بين مجموعتين او أكثر بواسطة عدة دوال تميزية.

2- مشكلة البحث problem of research

للغرض توظيف بيانات فقر الدم ثاني الاستجابة والتي تعاني من وجود مشكلة التعدد الخطى من اجل تكوين نموذج احتمالي للمريض بفقر الدم والذي يتم على اساس تصنيف او تحديد المريض بفقر الدم (الحاد او المزمن) ثم استعمال اسلوبين من اساليب التصنيف لغرض ايجاد أفضل نموذج احتمالي باقل خطأ تصنيف ممكن.

3- هدف البحث objective of research

يتضمن هذا البحث المقارنة بين اسلوبين من اساليب التصنيف وهما الانحدار اللوجستي الثاني والدالة المميزة الخطية بوجود مشكلة التعدد الخطى ولمعرفة مدى قابلتهم لتصنيف البيانات بأقل احتمال خطأ للتصنيف وذلك باستعمال بيانات حقيقة حول مرض فقر الدم (فقر الدم الحاد، فقر الدم المزمن) بوجود مشكلة التعدد الخطى بعد معالجتها بطريقة المربعات الصغرى الجزئية ومن ثم تطبيق اسلوب الانحدار اللوجستي الثاني الاستجابة والدالة المميزة الخطية.

4- الجانب النظري

من اساليب الاحصائية المهمة في متعدد المتغيرات والتي تستعمل في تحليل وتقويم العلاقات بين مجموعة من المتغيرات يكون فيه المتغير التابع (متقطع)، ليس دائماً يكون فيها المتغير التابع مستمراً وذلك لغرض الحصول على انموذج رياضي يوضح العلاقة بين مثل هكذا بيانات تستعمل اسلوب التحليل المميز والانحدار اللوجستي. وان هناك بعض الافتراضات الخاصة للأسلوبين المذكورين آنفًا وان تكون المتغيرات التوضيحية مستقلة ولا يوجد أي ارتباط بينها ولمعالجة مثل هكذا حالات تستعمل طرائق عدة منها طريقة المركبات الرئيسية وطريقة المربعات الصغرى الجزئية وطريقة الحرف وسوف نركز على طريقة المربعات الصغرى الجزئية.

4-1 المربعات الصغرى الجزئية⁽¹⁾⁽⁵⁾⁽⁶⁾ Partial least square

تعد طريقة المربعات الصغرى الجزئية أكثر الطرائق أهمية في الانحدار فهي تستعمل لتقليل عدد المتغيرات التوضيحية المرتبطة في الانموذج الى مركبات غير مرتبطة (خطية، متعامدة)، او عندما يكون عدد المتغيرات التوضيحية أكثر من عدد المشاهدات في التجربة. وطريقة المربعات الصغرى الجزئية مشابهة لطريقة المركبات الرئيسية وأسلوب انحدار الحرف لمعالجة مشكلة التعدد الخطى ولكنها تختلف في الحسابات فخوارزمية (Partial least square) تأخذ بالحساب التباين المشترك ما بين متغير (متغيرات) الاستجابة والمتغيرات التوضيحية، اما طريقة المركبات الرئيسية (PCA) تأخذ بنظر الاعتبار التباين بين المتغيرات التوضيحية فقط. يقوم بتحويل المتغيرات التوضيحية المرتبطة الى مركبات رئيسية تختلف في الحسابات فخوارزمية الحل بطريقة PLS طريقة تكرارية عند استعمالها تنتج سلسلة من النماذج ويتوقف الحل التكراري عندما نصل الى العدد الكلي من المركبات في الانموذج او عندما تكون الباقي مساوية للصفر.



التحليل المعزز والانحدار الوجستي بوجود مشكلة التعدد الخططي [دراسة تطبيقية على مرض فقر الدم]

في حال تساوي عدد المركبات مع عدد المتغيرات التوضيحية فإن النتائج ستكون متطابقة مع طريقة المرربعات الصغرى. ولأجل تحديد عدد المركبات التي تصغر من خطأ التنبؤ نستعمل طريقة العبور الشرعي Cross-validation وبعد تحديد عدد المركبات تقدر معلم انموذج الانحدار لكل متغير. وان طريقة PLS أول من طبقها الباحث Wold عندما يكون هناك ارتباط عالي ما بين المتغيرات التوضيحية او عندما يكون عدد المتغيرات التوضيحية تفوق عدد المشاهدات. وتوجد عدة خوارزميات وأكثرها تداولاً خوارزمية NIPALS عام 1973 للباحث Wold وخوارزمية SIMPLS 1993 المنسوبة للعالم De Jong وخوارزمية KERNEL المنسوبة للعالم DAYAL وخوارزمية TRYGG structures عام 2002 المنسوبة الى TRYGG وكلها الأسلوب نفسه (الهدف) ولكن الاختلاف يكون في حساب الخوارزمية، خوارزمية NIPALS او تسمى (PLS1, PLS2) حيث ان خوارزمية PLS1 تستعمل عندما يكون متغير الاستجابة متوجه اما خوارزمية PLS2 تستعمل عندما يكون متغير الاستجابة مصفوفة، وخوارزمية PLS1 تعطي نتائج خوارزمية SIMPLS نفسها ويكون الاختلاف في كيفية تفريغ البيانات، ففي الأول يتم عن طريق X وY اما في خوارزمية SIMPLS يكون لمصفوفة التباين والتباين المشترك، وسنركز في هذا البحث على الخوارزميتين NIPALS وSIMPLS.

2-4 انحدار المرربعات الصغرى الجزئية⁽¹⁾⁽²⁾⁽³⁾

ان طريقة المرربعات الصغرى الجزئية تعتمد على خطوتين اساسيتين لإيجاد المتغيرات الكامنة Latent variable بين X وY من خلال تعظيم مصفوفة التباين والتباين المشترك اما الخطوة الثانية فهي انحدار Y على المركبات. فلو فرضنا ان لدينا مصفوفة $X_{n,p}$ والمتجه $Y_{n,1}$ فطريقة المرربعات الصغرى الجزئية تعتمد على الانموذج الثاني بين X وY الآتي:

$$X = T\bar{P} + E \dots \dots \dots (1)$$

$$Y = U\bar{q} + F \dots \dots \dots (2)$$

حيث ان:

T: مصفوفة درجات X-score X - بعد

U: مصفوفة درجات Y-score Y - بعد

P: مصفوفة تحميلات X-loading X - بعد

q: متجه تحميلات Y-loading Y - بعد

E: مصفوفة الباقي X-residual X - بعد

F: متجه الباقي Y-residual Y - بعد

والمصفوفة \bar{P} والمتجه q له r من الاعمدة ويكون عدد بما يأتي:

$$r < \min(n, p) \dots \dots \dots (3)$$

حيث ان:

P: عدد المتغيرات

n: عدد المشاهدات

r: عدد المركبات

والعلاقة الداخلية تكون كالتالي:

$$U = TD + H \dots \dots \dots (4)$$

حيث ان:

D: هي مصفوفة قطرية ذات بعد $r \times r$

H: مصفوفة الباقي ذات بعد $n \times r$

ملخص طريقة المربعات الصغرى الجزئية هي إيجاد w من مجال X والمتجه c من مجال Y حيث ان:

$$\text{Max cov}(X_w, Y_c) \quad \text{with} \quad \|X_w\| = 1 \quad \|Y_c\| = 1 \dots \dots \dots (5)$$



حيث ان $Y_c cov(X_w)$, هو تقدير التباين المشترك وتنفذ الطريقة بصورة تكرارية متسللة وهذا يعني ايجاد المتجهات Scores الواحدة بعد الآخرى حتى يتم استخراج كافة المتجهات الى r تحت قيد عدم الارتباط بين المتجهات .r

اما لحل المعادلة المذكورة انفاً توجد عدة خوارزميات سنركز على خوارزمية NIPALS(PLS1) وخوارزمية SIMPLS في هذه الاطروحة.

3-4 خوارزمیہ NIPALS Algorithm (6)(5)(1)

- نختار عمود من أعمدة المصفوفة Y بحيث ان $U_1 = Y$.**

حساب اوزان X (X-weight) باستخدام الصيغة التالية:

$$W_1 = \dot{X}U_1/\dot{U}_1 U_1 \dots \dots \dots (6)$$

وان W_1 هي متوجه ببعد (p^*1) .

تكون normalized بالشكل الاتي: W_1 -3

١-نبدأ بحساب درجات $-X$ (X-score) وهي اسقاطات للبيانات او المشاهدات X على اوزان $-X$ -(weight).

$$t_1 = XW_1 \dots \dots \dots (8)$$

حيث ان t_1 هي متوجه ببعد (1)

2-حساب اوزان (y-weight) Y-

حيث ان C_1 متجه بعد (1^*1) .

يكون C_1 -3 normalized بالشكل الاتي:

$$C_1 = C_1 / \|C_1\| \dots \dots \dots (10)$$

4-حساب درجات (y-score) Y

وهي براكيت حطيه

11

$$\Delta U < \epsilon$$

فإذا كانت Δ حيث ϵ قيمة صغيرة وجذنا أول مركبة نتوقف، عدا ذلك نذهب إلى الفقرة الأولى ونستعمل

بدل U_1 ونستمر بالخطوات.

ت التوضيحية X مع درجات - $X-$

$R = \frac{\hat{y}_t}{\hat{y}_{t-1}}$ (10) .(score



7- إيجاد تحميلات - $(Y\text{-loading})$ وهي معلم خطية تربط متوجه الاستجابات الى درجات - Y - (score) وهي بأبعاد *11. ويتم حسابها من الصيغة التالي:

$$q = \dot{Y}U_1/\dot{U}_1U_1 \dots \dots \dots (15)$$

حيث ان q متوجه بعده (1^*1) .

8- بعد ذلك يتم إيجاد التداخل الخطى للمعلم بواسطة انحدار OLS بالصيغة الآتية:

حيث ان d_1 متوجه ببعد (1*1)

٩- عمل تفريغ الى بيانات X وY

ثم نستمر بالخطوات من (1-12) مرات عدة باستعمال البيانات المفرغة الى X و Y حتى نحصل على عدد المركبات المحدد، ثم نحدد معاملات الانحدار من خلال المعادلة الآتية:

حيث ان W مصفوفة بعد $r^* p$ وان P مصفوفة بعد $p^* r$ وان C مصفوفة بعد $r^* r$.

٥- العبور الشرعي Cross-Validation^{(١)(٥)(٦)}

ان تحديد عدد المركبات h في انموذج المربعات الصغرى الجزئية ضروري لأجل بناء الانموذج وتوجد عدة طرائق وهي جذر متوسط مربعات الخطأ الشرعي (Leave-one-out-cross-validation) وطريقة M-field-cross validation الى مجموعتين اختيارية وهي مستقلة عن المجموعة الثانية وهي مجموعة التدريب والخطوات المتبعة لأجل تحديد عدد المركبات كالتالي:

١- حذف مشاهدة واحدة بالاعتماد على طريقة العبور الشرعي المختار.

2- يتم حساب الانموذج بدون المشاهدة المخذولة.

3- التنبؤ بقيمة الاستجابة $X_{ij,h}$ والتي لا تتضمن المشاهدة المحفوظة باستعمال طريقة PLS h مركبة

$$\cdot \hat{Y}_{ij,h}$$

4- إيجاد جذر متوسطات مربعات الخطأ التشريعي ل h مركبة وكالاتي:

$$PRESS = \sum_{i=1}^h (y_i - \hat{y}_{-i,(h)}) \quad \dots \dots \dots (19)$$

حيث ان $\hat{y}_{i(h)}$ هي القيمة التقديرية الى Y الحاصل عليها من البيانات بدون المشاهدة المحفوظة i من انموذج المربيات الصغير الحذئي PLS للمركبة h .

وان عدد المركبات النهائية تحدد من اقل PRESS او من خلال اقل قيمة الى جذر متوسط مربعات الخطأ الشرعي:

حيث ان n العدد الكلى.



تكرار الخطوات من (1-3) حيث في كل مرة يتم حذف مشاهدة واحدة وإيجاد الانموزج والتنبؤ. وان احصاء $\text{RMSECV}(h)$ يمكن الاعتماد عليها في حالة وجود القيم الشاذة في البيانات لذا يتوجب إزالة القيم الشاذة الموجودة في البيانات قبل البدء بعملية تحديد المركبات. وان تحديد منحنى (8) من الطائق الشائعة لتحديد العدد الأقل من المركبات.

6- الانحدار الوجستي logistic regression

بعد انموزج الانحدار الوجستي من النماذج الإحصائية المهمة في تحليل البيانات اذ ان الهدف الأساسي من معظم الدراسات هو تحليل وتقويم العلاقات بين مجموعة من المتغيرات للحصول على صيغة تستطيع من خلالها ان نصف النموذج ويستعمل انموزج الانحدار الوجستي لوصف العلاقة بين بين متغير الاستجابة من النوع المتقطع والمتغيرات التوضيحية ويكون على نوعين انموزج الانحدار الوجستي ثاني الاستجابة وانموزج الانحدار الوجستي متعدد الاستجابة وسنركز على النوع الأول من الانحدار الوجستي.

1-6 انموزج الانحدار الوجستي ثانوي الاستجابة (2)

ان من خصائص الانحدار الوجستي ثاني الاستجابة ان المتغير التابع (y) متغير الاستجابة يتبع توزيع برنولي ويأخذ القيم (0) و (1) اي بمعنى ان (1) باحتمال قدره (p) احتمال نجاح، وباحتمال فشل ($1-p$) قدره (0) وبمعنى اخر احتمال حدوث الاستجابة (1) واحتمال عدم حدوث الاستجابة (0). ان نموذج الانحدار الخطى المتعدد MLR يكون كالتالي:

$$Y = XB + \epsilon \quad (22)$$

حيث ان:

Y : موجه المتغير المعتمد

X : مصفوفة المتغيرات التوضيحية

B : موجه معلمات دالة الانحدار

ϵ : موجه الأخطاء العشوائية والذي يشرط به تحقق الشرط الآتي:

1- توزع توزيع طبيعي ϵ

2- $E(\epsilon) = 0$

3- $\text{Cov}(\epsilon_i, \epsilon_j) = 0$

4- $\text{Var}(\epsilon_i) = \sigma^2$

في حالة وجود متغير توضيحي واحد فان متوسط قيم المشاهدة Y عند متوجه معين للمتغير x فهو $E(y | x)$ وبذلك يمكن كتابة النموذج على النحو التالي:

$$E(y | x) = \beta_0 + \beta_1 x \quad (23)$$

ان الطرف الامين لهذا النموذج يأخذ قيم $(-\infty, +\infty)$ ، لكن عندما يكون المتغير (y) ثانيا فان الانموزج اعلاه لا يكون ملائما لأن:

$$E(y/x) = P_r(y = 1) = p \quad (24)$$

وفي هذه الحالة يكون الطرف الامين محصور بين (0,1)، وهذا يعني ان الانموزج يكون غير قابل للتطبيق احصائيا. وللتخلص من هذه المشكلة سنقوم بادخال تحويلة رياضيا على المتغير التابع y . وبما ان $0 \leq p \leq 1$ وان $\frac{p}{1-p}$ هو مقدار موجب محصور بين $(0, +\infty)$ اي $(\frac{p}{1-p}, +\infty)$ وبأخذ



اللوغاريتم الطبيعي للاسas (e) للمقدار $\frac{p}{1-p}$ فان مجال القيمة تصبح محصور بين $(-\infty, +\infty)$ و تكون كالاتي $(-\infty \leq loge(\frac{p}{1-p}) \leq \infty)$ ، وبالنهاية يمكن كتابة انموذج الانحدار في حالة وجود متغير توضيحي واحد وكالاتي:

اما اذا كان لدينا اكثر من متغير توضيحي فتصبح صيغته كالتالي:

اذ ان:

$i = 1, 2, 3, \dots, n$ $j = 1, 2, 3, \dots, k$
 موجہ للمعلم المطلوب تقدیرها. : $\beta_1, \beta_2, \dots, \beta_k$

x_{ii} : متغيرات توضيحية.

اما بالنسبة ($\frac{p}{1-p}$) نسبة افضلية النجاح (odds of success) او نسبة الافضلية للحدث المرغوب به وصيغته الرياضية هي كالتالي:

$$\frac{P(Y=1)}{1-P(Y=1)} = e^{\beta_0 + \sum_{j=1}^k \beta_j x_{ij}} \dots \dots \dots (27)$$

وصيغة احتمالات الاستجابة لأنموذج الانحدار اللوجستي تكتب كالتالي:

$$p = \frac{1}{1 + (e^{\beta_0 + \beta_1 x_i})^{-1}} \dots \dots \dots (28)$$

وإن المقدار $(\frac{P}{1-P})$ يسمى لوغاريتmic نسبة افضلية النجاح (logs odds of success).

6- الافتراضات الخاصة بالانحدار اللوجستي

ان الانحدار الوجستي لا يتطلب افتراضات كثيرة فقط يتطلب عدم وجود ارتباط بين المتغيرات التوضيحية وان حجم المشاهدات كبيرة في كل مجموعة يفترض انها تكون اكبر من خمس مرات من عدد المعالم المستعملة في الانموذج النهائي.

٣-٦ تقدیر احتمالات الاستجابة Estimation of response probabilities (2)(4)(8)

ان صيغة احتمال الاستجابة لأنموذج الانحدار اللوجستي الثاني يمكن الحصول عليها وذلك بادخال الـ (e) على المعادلة الآتية:

وذلك صيغة احتمال الاستجابة تصبح كالتالي:

ويتمكن ايضاً ان نكتب المعادلة المذكورة أعلاه بالصيغة الآتية:



وباستعمال الطائق الجبرية للاستفادة من صيغة احتمال الاستجابة لأنموذج الانحدار اللوجستي الثنائي يكون كما يأتي:

وهذا يعني ان احتمال متغير الاستجابة (y) تأخذ القيمة (1) ويكون كالتالي:

و عند القيمة (0) فإن احتمال متغير الاستجابة (y) يكون على النحو الآتي:

وبما ان مجموع الاحتمالات يساوي (1) فأن:

7- بعض الاختبارات الاحصائية المهمة

هناك بعض الاختبارات الاحصائية المهمة منها:

1- اختبار wald

لبيان أهمية ومعنى معلمات الانحدار المقدرة بطريقة الإمكان الأعظم بالنسبة لأنموذج الوجستي وتخبر احصاء wald حسب الفرضية الآتية:

$$H_0: \beta_k = 0$$

$$H_1: \beta_k \neq 0$$

واحصاء الاختبار هي كالتالي:

$$wald = t^2 = \left(\frac{\hat{b}_i}{S.E(\hat{b}_i)} \right)^2 \quad \dots \dots \dots (36)$$

: هي تمثل معلمة المتغير المعتمد.

$S.E(\hat{b}_i)$: الخطأ القياسي للمعلمـة.

فإذا كانت قيمة p -value أقل من 0.05 نرفض فرضية العدم H_0 أي ان معاملات المتغير التوضيحي معنوية.

٢- اختبار الدرجة او المقارنة Score Test

وهو اختبار إحصائي يختبر المعلمات في إطار فرضية عدم $H_0: \beta = 0$ ، إذ يعد هذا الاختبار من أقوى الاختبارات عندما تقترب قيمة المعلمات من قيمة β_0 ، فالميزة الرئيسية لهذا الاختبار هو عدم حاجته إلى تقديم المعلومات تحت إطار الفرضية البديلة $H_1: \beta \neq 0$ ، إذ تقترب أحصاء هذا الاختبار من توزيع مربع كاي (χ^2_{ν}) وتقارن مع قيمتها الجدولية.

3- اختبارات حسن المطابقة Goodness OF FIT

جودة الملاعنة تعني كم إن الإنموذج الإحصائي هو ملائم لبيانات عينة الدراسة، فمقاييس جودة الملاعنة تقيس التقارب بين القيم المشاهدة والمتوقعة للإنموذج وفيما يأتي يأتي بعض الاختبارات المهمة لجودة الملاعنة.



6- معامل التحدّد The Coefficient Of Determination R^2

كثيراً ما يعرف **R²** بأنه نسبة التباين أو الاختلاف في المتغير التابع التي يمكن تفسيرها من

خلال المتغيرات التوضيحية في الإنموزج، ويمكن أن يعرف R^2 بطرائق أخرى، كل منها ينتج قيمة متطابقة لمعامل التحديد في إنموزج الانحدار الخطى (LRM)، ومع ذلك، عندما يتم تطبيق هذه الصيغة للنماذج الفنية فإنها تنتج قيم مختلفة، وبالتالي توفر قياسات مختلفة لملاعمة النماذج ، إن احصاء الاختبار (R^2) لا تفسر جودة الملاعمة للإنموزج كما في الانحدار الخطى ولكنها تعد موشرًا لأهمية المتغيرات التوضيحية للتنبؤ بمتغير الاستجابة ومن ثم قياس حجم التأثير.

ويمكن أن نذكر صيغة Cox & Snell R^2 كالتالي :

$$R^2_{cs} = 1 - \left[\frac{\hat{L}(B_{(0)})}{\hat{L}(B)} \right]^{2/N} \quad \dots \dots \dots (41)$$

ان هذا الصيغة إذ $\hat{L}(B_{(0)})$ هو دالة الإمكان للإنموذج الذي يحتوي فقط على معلومة الحد الثابت (دالة الإمكان للإنموذج تحت فرضية العدم) اي وإن $\hat{L}(B)$ دالة الإمكان للإنموذج الذي يتضمن معلمات الميل(دالة الإمكان للإنموذج تحت الفرضية البديلة) N : العدد الكلي للمشاهدات

أما صيغة² NagelkerkeR فيمكن توضيحها بالصيغة الآتية:

$$R^2 N = \left[\frac{R^2_{cs}}{1 - \{\hat{L}(B_{(0)})\}^{2/N}} \right] \dots \dots \dots \quad (42)$$

ان حجم العينة الكبير يعطي قوة لتحليل الاختبار لنمودج الوجستيك إذ انه كلما ازداد حجم العينة كلما ازدادت قوة الاختبار لنمودج.

- 7 - جودة توفيق النموذج

لقياس جودة توفيق النموذج سجيري اختبارا لا معلميا يكون اعتماده على اختبار نسبة الامكان الاعظم (likelihood ratio test) والذي يتبع احصاء او توزيع مربع كاي وكما في الصيغة الآتية:

$$\chi^2 = 2[\log_e H_o - \log_e H_1] \quad(43)$$

اذ ان

H_0 : قيمة دالة الامكان الاعظم تحت فرضية العدم.

H_1 : قيمة دالة الامكان الاعظم تحت الفرضية البديلة.



التحليل المعمّر والانحدار اللوجستي بوجود مشكلة التعدد الخططي [دراسة تطبيقية على مرض فقر الدم]

8- التحليل التمييزي Discriminant analysis:

يعد التحليل التميزي من الأساليب الإحصائية المهمة في متعدد المتغيرات التي تهتم بتفريق (تميز) بين مجتمعين (مجموعتين) أو أكثر من خلال إيجاد توافق خطية للمتغيرات التوضيحية تعرف بدالة التميز التي يمكن عن طريقها الفصل او تميز بين مجموعتين او أكثر ثم تأتي بعدها عملية تصنيف المفردات الجديدة الى أحد المجاميع باقل خطأ ممكن. وهناك عدة دوال تميزية منها الدالة المميزة الخطية والتي قدمت من قبل العالم فيشر عام (1936) والتي تستعمل في حالة تساوي مصفوفة التباينات المشتركة للمجاميع كافة وان كل مجموعة تعبر عن مجتمع طبيعي لمتعدد المتغيرات اما في حالة عدم تساوي مصفوفة التباينات المشتركة نلجم الى الدالة المميزة التربيعية.

1-8 الدالة المميزة الخطية لمجموعتين

(9)(7)(3) groups

تسمى هذه الدالة بـ **دالة فيشر (Fisher Function)** توزع فيها المشاهدات توزيعاً طبيعياً. لنفترض أن لدينا مجتمعين ونريد المقارنة بينهما ولنفترض أن هذين المجتمعين لهما نفس مصفوفة التباين والتباين المشترك $(\Sigma_1 = \Sigma_2)$ ولهم نفس موجة متوسطات (μ_1, μ_2) بالتتابع، وتم اختيار عينتين عشوائيتين

لكل من المجتمعين. $(\underline{x}_{21}, \underline{x}_{22}, \underline{x}_{23}, \dots, \underline{x}_{2n_2})$ و $(\underline{x}_{11}, \underline{x}_{12}, \underline{x}_{13}, \dots, \underline{x}_{1n_2})$

و تكون صيغة الدالة المميزة الخطية لفيشر تكتب بالشكل الآتي:

حیث ان:

وأن مقياس Mahalanobis يعتمد على القياسات ذات المسافة القليلة بين قيم المتغيرات للمشاهدات الجديدة وقيم المتوسطات للمتغيرات لكل مجموعة يمكن كتابتها بالشكل الآتي:

$$D_i^2 = (\bar{x}_1 - \bar{x}_i)' S_p^{-1} (\bar{x} - \bar{x}_i) \dots \dots \dots (46)$$

إذ أن :

\bar{x}_i : موجة متوسطات المتغيرات لكل قيمة من المجموعة (i)

S_p^{-1} : هو معكوس مصفوفة التباین والتباين المشترک المقدرة داخل العینتین.

٤-٨ الافتراضات الخاصة بالتحليل المميز

ان من الافتراضات الخاصة بالتحليل المميز بأن المجاميع المدروسة ذات توزيع طبيعي متعدد متغيرات في حالة الدالة المميزة الخطية يتشرط فيها ان تكون مصفوفة التباين متساوية للمجاميع كافة وفي حالة عدم التساوي نستعمل الدالة المميزة التربيعية، كذلك يتطلب ان تكون حجم العينة كبيرة حيث ان المجاميع المختلفة تتضمن على الاقل 20 مشاهدة لكل متغير توضيحي وأيضا يتشرط عدم وجود ارتباط بين المتغيرات التوضيحية وعدم وجود قيم شاذة بينها.

٩- تصنیف البيانات classification of data

لفرض ان:

لدينا عينة بحجم (n).

ان عدد المشاهدات من النوع (0) هي n_1
وان عدد المشاهدات من النوع (1) هي n_2



التطليل المعميز والاندثار اللوجستي بوجود مشكلة التعدد الخططي [دراسة تطبيقية على مرض فقر الدم]

وان لدينا بيانات من نوع ثانوي (binary) وكانت لدينا تصنيف البيانات كما مبين في الجدول رقم (1) الآتي:

جدول رقم (1) يبين تصنيف البيانات

البيانات الثانية	(0)	(1)
(0)	A_{11}	A_{12}
(1)	A_{21}	A_{22}

1-نسبة التصنيف الصحيحة تحسب بالشكل الآتي:

وبالتالي يمكن حساب معيار خطأ التصنيف الصحيح بالشكل الآتي:

$$(48) \quad \text{معيار خطأ التصنيف} = 100\% - \frac{\text{نسبة التصنيف الصحيح}}{\text{نسبة التصنيف}}$$

١-نسبة التصنيف الكلية على مستوى (٠) و (١) وتحسب بالشكل الآتي:

- 10 -

ان انتشار الامراض في العراق خاصة والعالم بصورة عامة على تنوعها وتعدد اساليبها تعتبر ظاهرة جديدة بالبحث والدراسة وضرورة الوقوف على مسبباتها وتحديد طرق معالجتها من الواجبات الاساسية التي تقع على عاتق الدارسين والباحثين كل حسب اختصاصه على حد سواء. بعد البحث والتقصي الامراض الاكثر شيوعا وخطورة على فئات المجتمع الانسانى وتبيين ان امراض فقر الدم هي الاكثر شيوعا. ومن ضمن امراض كثيرة شائعة والاكثر تأثيرا على انتشار اجيال جديدة تردد مجتمعنا ببطاقات متعددة على صعيد العقل والجسد. وفي موضوع الرسالة تم تناول فقر الدم على مستويين وهما فقر الدم الحاد بالرمز (٠)، وفقر الدم المزمن بالرمز (١).

1-10 فقر الدم

هو حالة مرضية تحدث بسبب انخفاض في نسبة تركيز الهيموغلوبين عن المستوى الطبيعي وبسبب الهبوط في مستوى الهيموغلوبين تعاني الأجهزة من عدم الحصول على ما يكفي من الأوكسجين وبالتالي يشكو المريض من اعراض الارهاق والصداع وعدم التركيز والخمول وغيرها.

هناك ثلاثة أنواع رئيسية لفقر الدم: فقر الدم الناجم عن فقدان الدم، وفقر الدم الناجم عن خلل في إنتاج

كريات الدم الحمراء، وفقر الدم الوراثي. ويمكن اعتبار فقر الدم هو الحاله المرضيه الاكثر شيوعا في امراض الدم.

اما انواع فقر الدم فتعدد تصنیفاتها لكن الابرز والأشمل من هذه الانواع هي:

- فقر الدم الحاد
 - فقر الدم المزمن



التحليل المعنى والاندثار الوجستي بوجود مشكلة التعدد الخطي [دراسة تطبيقية على مرض فقر الدم]

والذي تم على هذا الاساس تم اعتماد انواع فقر الدم في هذا البحث.
اما علامات ظهور هذا المرض فهي على النحو الاتي:

1- الاعياء العام والارهاق

2- شحوب الجلد

3- تسارع او عدم انتظام في ضربات القلب.

4- انقطاع او ضيق النفس.

5- الم في الصدر.

6- دوار.

7- صعوبة في التركيز او التفكير.

8- احساس بالبرودة في الأطراف.

9- صداع.

10- تكسر الأظافر.

قد يكون فقر الدم غير ظاهر ولكن بشكل عام تزداد الأعراض مع تقدم المرض.

2- متغيرات الدراسة:

1- انواع فقر الدم المتمثل بالمتغير (Y)، هناك نوعان من فقر الدم وهما:

أ- فقر الدم الحاد: وهو نوع من انواع المرض الذي يحدث غالبا بسبب نزف دم يسمى في بعض المصادر بنزف الدم الداخلي (يحدث داخل جسم الانسان) ناتج بسبب اصابة خارجية للجسم او بسبب النزف الحاد للدورة الشهرية عند النساء وغيرها، ونزف دم خارجي (خارج جسم الانسان) الذي يحدث غالبا بسبب الاصابة بجرح على الجسم يسبب هذا النزيف.

ب- فقر الدم المزمن: وهو النوع الثاني من مرض فقر الدم المصاحب لالتهاب هو شكل من أشكال فقر الدم التي تحدث مع الأمراض المزمنة مثل: **العدوى المزمنة** وتنشيط المناعة المزمن **والسرطان**. كما تفترح الاكتشافات الجديدة أن هذا النوع من الأنيميا هو نتيجة إنتاج الجسم مادة **الهيبيسيدين** (hepcidin) وهو المتحكم الرئيسي بعمليات أيض الحديد في جسم الإنسان. ومن انواع فقر الدم المزمن فقر دم البحر الأبيض المتوسط او تكسر كريات الدم الحمراء.

2- الجنس المتمثل بالمتغير (X1).

3- العمر المتمثل بالمتغير (X2): ان للعمر تأثير كبير على مرض فقر الدم ففي فقر الدم الحاد غالبا يصاب الكبار في السن والشباب سواء كان ذكر او انثى بسبب تعرضهم لمسببات النزيف اكثر من صغار السن، اما مرض فقر الدم الوراثي فغالبا يصيب جميع الفئات العمرية.

4- نسبة الهيموغلوبين (hp) المتمثل بالمتغير (X3): الهيموغلوبين هو بروتين موجود داخل كريات الدم الحمراء، وهو الذي يكسب خلايا الدم اللون الأحمر، وتتلاصص وظيفته في نقل الأوكسجين من الرئة إلى مختلف أعضاء الجسم حتى تقوم بوظائفها على أكمل وجه، ويقوم بنقل ثاني أكسيد الكربون من أنحاء الجسم إلى الرئة لطرده خارج الجسم، ويلعب الهيموغلوبين دوراً مهماً في الحفاظ على شكل خلايا الدم الحمراء، ففي شكله الطبيعي يحافظ على ثبات الكريات بحيث يكون شكلها دائرياً مقرن الوجهين، وعندما يكون غير طبيعياً فيدمـر الشكل الرئيس للكريات مما يعطـل وظيفتها وجريانها في الأوعية الدموية.

اما نسب فقر الدم الطبيعية فتكون كالتالي:

يختلف المعدل الطبيعي للهيموغلوبين من شخص لآخر حسب عمره وجنسه كما يلى:

النسبة الطبيعية للرجال: من 13.5-17.5 جرام/ديسيلتر.

النسبة الطبيعية للإناث: من 12-16 جرام/ديسيلتر.

اما خارج هذه المعدلات فيعتبر اصابة بفقر الدم .



التحليل المعين والانحدار الوجستي بوجود مشكلة التعدد الخطي [دراسة تطبيقية على مرض فقر الدم]

- 5- نسبة ferritin في الدم المتمثل بالمتغير (X4): ومخزن الحديد الأكبر في الجسم، عملياً، يشكل الفيريتين تركيبة من الحديد والبروتينين يتيح تخزين الحديد في الانسجة. مستوى الفيريتين في المصل يمثل، عملياً، حجم مخزون الحديد في الجسم، وبواسطة هذا الفحص يمكن تشخيص سبب وجود **فقر الدم** (الأنيميا)، إن انخفاض مستوى الفيريتين في الدم يشير إلى فقدان الحديد ومن ثم حالة فقر الدم.
- 6- نسبة retic count المتمثلة بالمتغير (X5): تنقسم الخلايا في الدم إلى ثلاثة مجموعات: خلايا الدم الحمراء المسئولة عن نقل الأوكسجين من الرئتين إلى مختلف أنسجة الجسم، خلايا الدم البيضاء التي تعتبر جزءاً من جهاز المناعة وتحارب الجراثيم التي تدخل للجسم من الخارج، وطبعاً الصفائح الدموية التي تلعب دوراً مهماً في عملية تخثر الدم هو فحص روتيني يقيس كمية وسمات الأنواع الثلاثة من خلايا الدم.
- 7- نسبة MCV المتمثل بالمتغير (X6): معدل حجم كريات الدم الحمراء والتي يتراوح حجم كلٍّ منها لجميع الفئات العمرية للذكر والأنثى، ما بين (80.5 إلى 99.7) فيكولتر، ويزداد معدل حجم كريات الدم الحمراء في حال كان هناك خلل ما في النسيج النخاعي، والذي يتزامن معه نقص حاصل في فيتامين (B12)، وحمض الفوليك، أما النقص الحاصل في معدل حجم كريات الدم الحمراء فينتج عن النقص الحاصل في الحديد والبيريدوكسين، والذي يتزامن مع عدد من الأمراض مثل الثلاسيميا، وفقر نشاط الغدة الدرقية، وغيرها من الأمراض المزمنة.
- 8- نقص الحديد في الدم Iron deficiency Anemia المتمثل بالمتغير (X7): يعتبر نقص الحديد في الجسم هو أكثر أسباب فقر الدم (ضعف الدم) انتشاراً في العالم، ويصيب تقريراً 30% من سكان العالم (حوالى 500 مليون نسمة حالياً)، ويرجع ذلك إلى قدرة الجسم المحدودة لامتصاص الحديد من الغذاء وفقد الحديد عن طريق فقد الدم بالنزف.
- 9- نسبة transferrin في الدم والمتمثل بالمتغير (X8): هو بروتين يقوم بنقل الحديد للخلايا، وبشكل أساسي إلى النخاع العظمي، حيث يتم إنتاج خلايا الدم الحمراء. فيرتبط ببروتين آخر يدعى الفيريتين (Ferritin). ويقيس الترانسفيرين مستوى الحديد في الدم المرتبط بالترانسفيرين، فضلاً عن فحص كمية الترانسفيرين الإجمالية وكمية الفيريتين. تشير هذه الفحوص إلى كمية الحديد في جسم الإنسان، وإذا ما كان الشخص يعني من نقص أو فائض في عنصر الحديد. في حالات الاصابة بنقص الحديد، ينخفض مستوى الحديد والفيريتين، بينما يرتفع، بالمقابل، مستوى الترانسفيرين.
- 10- سبب الفقر هو نزف الدم المتمثل بالمتغير (X9): تعد الاصابات المباشرة بالجسم التي تؤدي إلى نزيف حاد نوع من أنواع فقر الدم وكذلك التزيف الداخلي الحاد الحاصل لدى بعض المرضى بسبب صدمة خارجية على الرأس وغيرها من الأمراض وكذلك النزف الحاد للدورة الشهرية لدى المرأة . كل هذه الأسباب تسبب فقر الدم الحاد.
- 11- فقر دم الامراض المزمنة المتمثلة بالمتغير (X10): يطلق عليه أيضاً فقر الدم المصاحب للالتهاب هو شكل من أشكال فقر الدم التي تحدث مع الأمراض المزمنة مثل: **العدوى المزمنة** وتنشيط المناعة المزمنة أو **السرطان**. كما تقترح الاكتشافات الجديدة أن هذا النوع من الأنيميا هو نتيجة إنتاج الجسم مادة **الهيبيسيدين** (hepcidin) وهو المتحكم الرئيسي بعمليات أيض الحديد في جسم الإنسان.
- 12- فقر الدم هو نقصان في كريات الدم الحمر المتمثل بالمتغير (X11): انخفاض نسبة خلايا الدم الحمراء (كريات الدم الحمراء) في الدم. فإن هناك العديد من العوامل التي يمكن أن تسهم في خفض نسبة RBC أكثر من المعتاد والتي تتأثر بالعمر والالتهابات الفيروسية وبعض الامراض المزمنة.

وقد جمعت البيانات من المستشفيات الآتية:

- 1-مستشفى بعقوبة العام / محافظة ديالى
- 2-مستشفى كلار العام / محافظة السليمانية
- 3-مستشفى الطوارئ المركزي / محافظة أربيل



التحليل المعنى والانحدار الوجستي بوجود مشكلة التعذد الخططي [دراسة تطبيقية على مرض فقر الدم]

3- التحليل الاحصائي للبيانات:

بعد اجراء التحليل الاولى للبيانات في برنامج SPSS وجد الاتي:

1- عدد المصابين بفقر الدم الحاد هم (67) مريضاً وبنسبة 47.9%，اما المصابين بفقر الدم المزمن هم (73) مريضاً وبنسبة 52.1% ما بين راقدين في المستشفى وقت جمع البيانات وما بين الملفات لمرضى رقدوا سابقاً في المستشفى (طلبات المرضى). وكما مبين في الجدول رقم (2) ادناه:

جدول (2) يبين عدد المرضى المصابين بأنواع فقر الدم

نسبة المصابين	عدد المصابين بأنواع بالمرض	انواع فقر الدم
47.9	67	فقر دم حاد
52.1	73	فقر دم مزمن
100.0	140	Total

اما عدد الذكور والإناث في العينة فكانوا كما في الجدول رقم (3) كالتالي:

جدول رقم (3) يبين عدد الذكور والإناث في العينة

نسبة الذكور والإناث	عدد الذكور والإناث	
59.3	83	ذكر
40.7	57	إناث
100.0	140	Total

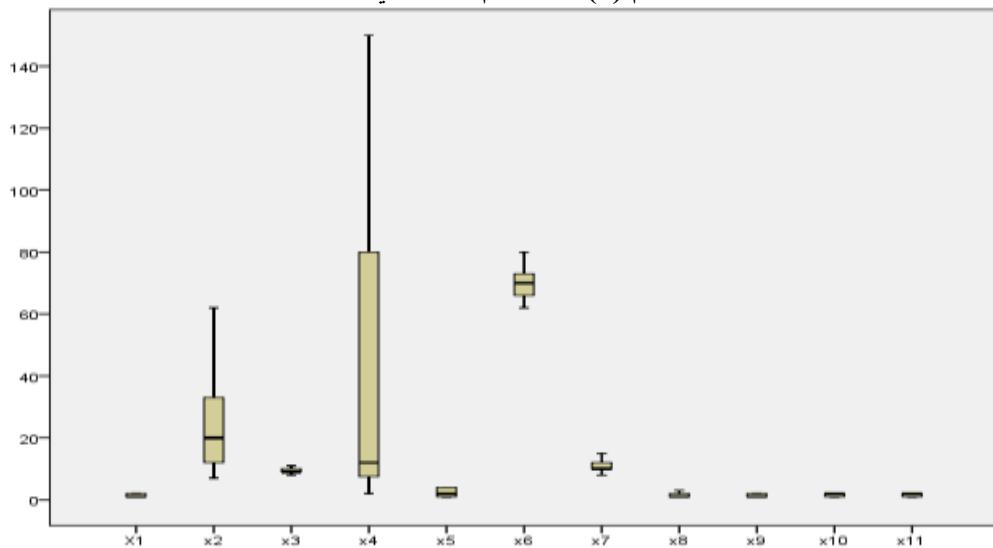
تبين ان عدد الذكور في العينة المختارة كانوا (83) ذكر وبنسبة 59.3% وكانوا عدد الإناث ضمن العينة (57) وبنسبة 40.7%.

4- طريقة المربعات الصغرى الجزئية (partial least square method)

نبدأ بأجراء التحليل الاحصائي لطريقة المربعات الصغرى الجزئية وتكون كالتالي:

1- قبل البدء بتطبيق طريقة انحدار المربعات الصغرى الجزئية (partial least square regression) نتأكد من عدم وجود قيمة شاذة وذلك من اختبار Box plot حيث ان طريقة المربعات الصغرى الجزئية لا يمكن ان تطبق في حالة وجود قيمة شاذة وذلك كما في الشكل رقم (1) الاتي:

شكل رقم (1) يبين القيم الشاذة في البيانات





**التحليل المعنى والانحدار الوجستي بوجود مشكلة التعدد
الخطي [دراسة تطبيقية على مرض فقر الدم]**

نلاحظ من الشكل رقم (1) أعلاه ان المتغيرات التوضيحية لا تحتوي على أي قيمة شاذة خارج حدود (box plot).

2- نقوم بالتأكد من وجود ارتباط ذاتي بين المتغيرات من خلال اختبار VIF وكما مبين في الجدول رقم (4) الآتي:

جدول (4) يبين مشكلة التعدد الخطى

Model	Unstandardized Coefficients		Standardized Coefficients Beta	T	Sig.	Collinearity Statistics	
	B	Std. Error				Tolerance	VIF
1 (Constant)	1.155	1.452		.795	.428		
X1	-.115-	.120	-.113-	-.963-	.337	.284	3.520
x2	.005	.004	.181	1.406	.162	.237	4.218
x3	-.019-	.061	-.025-	-.310-	.757	.605	1.654
x4	-.002-	.001	-.215-	-2.551-	.012	.555	1.802
x5	-.279-	.055	-.718-	-5.042-	.000	.194	5.151
x6	.028	.014	.299	1.984	.049	.174	5.757
x7	-.013-	.038	-.043-	-.333-	.740	.236	4.238
x8	-.411-	.146	-.514-	-2.809-	.006	.117	8.517
x9	.212	.216	.212	.981	.329	.084	11.859
x10	-.092-	.191	-.082-	-.483-	.630	.138	7.254
x11	-.060-	.135	-.054-	-.443-	.659	.269	3.714

من الجدول رقم (42) أعلاه نلاحظ بان قيمة ال $VIF > 5$ للمتغيرات (x5-X6-X8-X9-X10) وهذا يدل على وجود مشكلة التعدد الخطى. فلذلك سوف نلجأ الى حل هذه المشكلة استخدام طريقة المربعات الصغرى الجزئية (partial least square method).

3- ولمعالجة مشكلة التعدد الخطى نطبق طريقة المربعات الصغرى الجزئية وكما في الجدول رقم (5) الآتي:
جدول رقم (5) يبين اختبار لمعنى المربعات الصغرى الجزئية

Source	DF	SS	MS	F	P
Regression	7	17.255	2.465	18.40	0.00
Residual Error	132	17.6805	0.1339		
Total	139	34.9357			

نلاحظ من الجدول رقم (أعلاه) جدول تحليل التباين لمتغير الاستجابة والذى يتضمن الانموذج الذى يحتوى على 7 مركبات حيث ان قيمة p-value المحسوبة لمتغير الاستجابة بلغت قيمتها (0.00) وهي اقل من قيمة $\alpha=0.05$ وهذا يدل على ان المركبات السبعة فى الانموذج معنوية.

4- تم اختبار الانموذج بطريقة cross-validation لسبع مركبات ويمتلك معامل تحديد $R^2=0.49$ ومعامل تنبؤي 0.40 وان X-variance تشير الى مقدار التباين وقد ل 7 مركبات 0.94 من تباين المركبات المستقلة وكما مبين في الشكل رقم (6) الآتي:



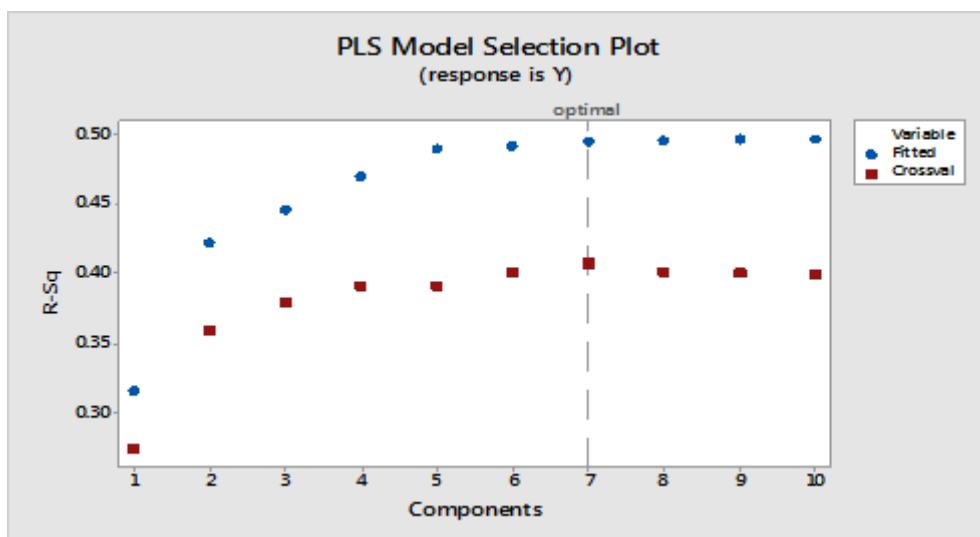
**التحليل المعنى والانحدار الوجستي بوجود مشكلة التعدد
الخطي [دراسة تطبيقية على مرض فقر الدم]**

جدول رقم (6) يبين معاملات التحديد ومعاملات التحديد التنبؤية

Components	X Variance	Error	R ²	R ² (pred)	PRESS
1	0.334	23.908	0.315	0.274	25.3604
2	0.481	20.193	0.421	0.359	22.3847
3	0.641	19.375	0.445	0.378	21.7079
4	0.730	18.518	0.469	0.391	21.2640
5	0.763	17.851	0.489	0.391	21.2659
6	0.861	17.752	0.491	0.401	20.9165
7	0.943	17.680	0.493	0.407	20.7064
8		17.621	0.495	0.400	20.9360
9		17.608	0.495	0.399	20.9757
10		17.608	0.495	0.398	21.0105

5- ان افضل انموذج لطريقة المربيعات الصغرى الجزئية حسب طريقة العبور الشرعي هل ل 7 مركبات حيث ان المحور العمودي يشير الى قيم معامل التحديد التنبؤي اما المحور الافقى فيشير الى المركبات حيث ان قيمة المركبات تتزايد حتى المركبة السابقة وبعدها تتناقص. وكما مبين في الشكل رقم (2) ادناه:

شكل رقم (2) يبين عدد المركبات المختارة من المتغيرات المستقلة

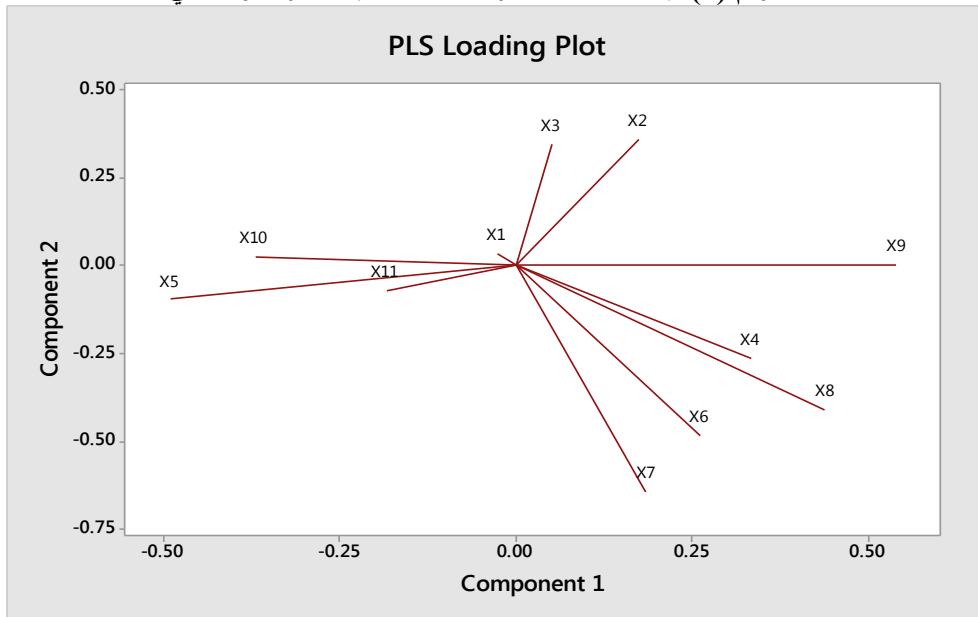


6- ان الشكل البياني لمركبات التحميل (Pls Loading) حيث ان X1 المتمثّل (بالجنس) و X11 المتمثّل (سبب فقر الدم هو نقصان في كريات الدم الحمر) يمتلك خط قصير جدا وهذا يدل على امتلاكه منخفضة وهي ليست ذات علاقة مع متغير الاستجابة (فقر الدم) وان المتغيرات X2 المتمثّل (بالعمر) و X3 المتمثّل (بنسبة الهيموكلوبين hp) و X4 المتمثّل (بنسبة الفرتين) و x5 المتمثّل (نسبة retic count) و x6 المتمثّل (نسبة MCV) و X7 المتمثّل (نقص الحديد في الدم) و X8 المتمثّل (نسبة ترانسفرين) و x9 المتمثّل (سبب فقر الدم هو نزفالمدم) و X10 المتمثّل (فقر الدم هو بسبب الامراض المزمنة) تمتلك خطوط طويلة أي ان لها تحميلات عالية أي ترتبط بعلاقة معنوية مع متغير الاستجابة.وكما مبين في الشكل رقم (3) الآتي:



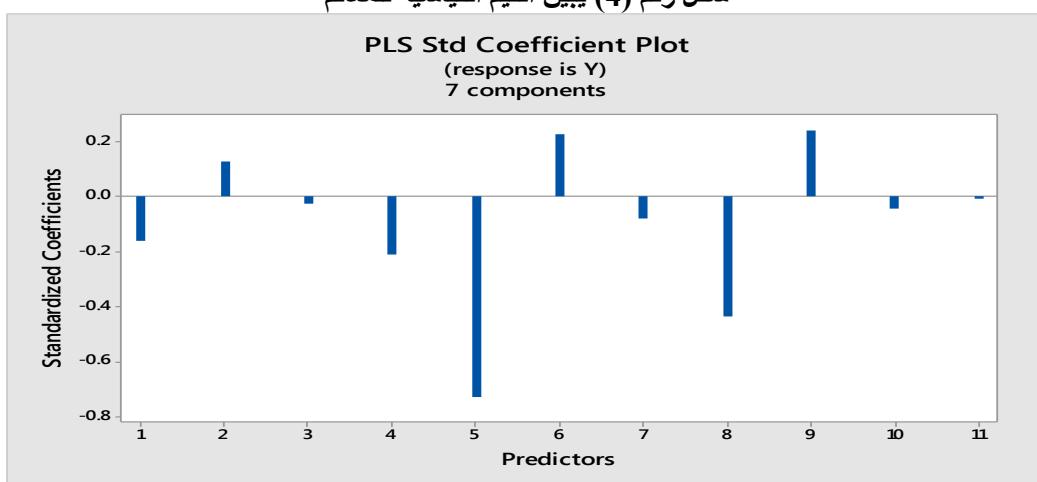
التحليل المعنى والانحدار الوجستي بوجود مشكلة التعدد الخططي [دراسة تطبيقية على مرض فقر الدم]

شكل رقم (3) يبين علاقة المتغيرات المستقلة بالمتغير التوضيحي



7- الشكل رقم (4) يوضح القيم القياسية للمعامل (Standardized coefficients) وللمتغيرات التوضيحية حيث نجد ان x_5 و x_8 المتمثل (نسبة ترانسفرين) و x_9 المتمثل (سبب فقر الدم هو نزف الدم) و x_6 المتمثل (نسبة MCV) و x_4 المتمثل (بنسبة الفرتين) X_2 المتمثل (بالعمر) X_1 المتمثل (بالجنس) تمتلك اكبر معاملات قياسية حيث ان x_9 المتمثل (سبب فقر الدم هو نزف الدم) و x_6 المتمثل (نسبة MCV) و X_3 المتمثل (بنسبة الهيموغلوبين hp) و X_7 المتمثل (نقص الحديد في الدم) و X_2 المتمثل (بالعمر) ترتبط بصورة ايجابية مع متغير الاستجابة نزف الدم المتمثل (Y) والمتغيرات X_1 الجنس و X_5 و X_8 ترتبط بصورة سلبية مع متغير الاستجابة.

شكل رقم (4) يبين القيم القياسية للمعامل





**التحليل المميز والانحدار الوجستي بوجود مشكلة التعدد
الخطي [دراسة تطبيقية على مرض فقر الدم]**

8- ان النموذج الرياضي لطريقة المربعات الصغرى الجزئية هو كالتالي:

$$y = 1.54 - 0.16x_1 + 0.003x_2 - 0.01x_3 - 0.001x_4 - 0.28x_5 + 0.02x_6 \\ - 0.02x_7 - 0.34x_8 + 0.24x_9 - 0.04x_{10} - 0.006x_{11}$$

10-5 الدالة المميزة الخطية باستعمال المربعات الصغرى الجزئية

تم استعمال طريقة المربعات الصغرى الجزئية للتخلص من مشكلة التعدد الخطى. وتم استعمال طريقة العبور الشرعي لتحديد عدد المركبات وقد بلغ عدد المركبات الداخلة في انموذج المربعات الصغرى الجزئية (7) مركبات وسيتم تطبيق الاختبارات الإحصائية الخاصة بالدالة المميزة على هذه المركبات وتكون الاختبارات كالتالي:

1- من الجدول رقم (7) ادناء ومن خلال اختبار Wilk's نجد ان المركبة الأولى والثانية لها اثر معنوي ومهم في تكوين الدالة المميزة الخطية ولها تأثير كبير في التفرقة بين المجموعتين.

جدول رقم (7) يبين معنوية المركبات

	Wilks' Lambda	F	df1	df2	Sig.
C1	.684	63.647	1	138	.000
C2	.894	16.422	1	138	.000
C3	.977	3.310	1	138	.071
C4	.975	3.470	1	138	.065
C5	.981	2.687	1	138	.103
C6	.997	.390	1	138	.534
C7	.998	.286	1	138	.594

2- من الجدول رقم (8) ادناء تم اختبار معنوية الدالة المميزة الخطية حيث توجد قوة للتميز من خلال التباين بين المجموعتين والتي قد فسرت 100% من التباين.

جدول رقم (8) يبين معنوية الدالة المميزة الخطية

Function	Eigenvalue	% of Variance	Cumulative %	Canonical Correlation
1	.976	100.0	100.0	.703

3-من خلال الجدول رقم (9) ادناء تم اختبار وجود علاقة خطية بين المتغيرات حيث ان قيمة Wilk's 0.506lambda ونجد معنوية chi-square sig. 0.00 هي اقل من قيمة $\alpha=0.05$ وهذا يعني وجود العلاقة الخطية بين المجموعتين في المركبات.

جدول رقم (9) يبين اختبار Wilks' Lambda

Test of Function(s)	Wilks' Lambda	Chi-square	Df	Sig.
1	.506	91.601	7	.000

4-من خلال الجدول رقم (10) نجد ان معاملات الدالة المميزة الخطية للمركبات وهي كالتالي:

$$y = 0.626pc_1 + 0.550pc_2 + 0.307pc_3 + 0.363pc_4 + 0.504pc_5 + 0.164pc_6 \\ + 0.105pc_7$$



**التحليل المميز والانحدار الوجستي بوجود مشكلة التعدد
الخطي [دراسة تطبيقية على مرض فقر الدم]**

**جدول رقم (10)
يبين معاملات الدالة المميزة الخطية**

	Function
	1
C1	.626
C2	.550
C3	.307
C4	.363
C5	.504
C6	.146
C7	.105
(Constant)	.000

5- ومن خلال الجدول رقم (11) نجد ان:

$$\hat{M} = 1/2 (-1.024 + 0.940)$$

اذا كانت المفردة الجديدة اكبر من \hat{M} تصنف على انها تعود الى المجموعة الأولى (فقر الدم الحاد) و اذا كانت المفردة الجديدة اقل من \hat{M} تصنف على انها تعود الى المجموعة الثاني (فقر الدم المزمن).

**جدول رقم (11)
يبين مجاميع الدالة المميزة الخطية**

Y	Function
	1
فقر دم حاد	-1.024-
فقر دم مزمن	.940

من خلال الجدول رقم (12) ادناه نجد ان 67 صنفت بشكل صحيح من 67 اي ان 100% صنفت بشكل صحيح من فقر الدم الحاد وان 50 مشاهدة من مجموع 73 صنفت على انها مرض مزمن اي بنسبة 68.5% وان نسبة التصنيف الصحيحة بلغت 83.6% وهذا يعني ان احتمال خطأ التصنيف .16.4%.

جدول رقم (12) يبين نسب التصنيف للدالة المميزة

Y	Predicted Group Membership		Total
	فقر دم حاد	فقر دم مزمن	
Count	فقر دم حاد	67	67
	فقر دم مزمن	23	50
%	فقر دم حاد	100.0	100.0
	فقر دم مزمن	31.5	68.5



**التحليل المعنى والانحدار الوجستي بوجود مشكلة التعدد
الخطي [دراسة تطبيقية على مرض فقر الدم]**

10- الانحدار الوجستي باستعمال المربعات الصغرى الجزئية

ان اول خطوة في التحليل الاحصائي للانحدار الوجستي هو ان نقوم بضم민 الحد الثابت فقط في الانموذج في الخطوة الصفرية ثم بعدها يتم إضافة المتغيرات التوضيحية وذلك لتحديد كفاءة الانموذج.
1- وإجراء اختبار لمعنى النموذج بوجود علاقة بين المتغير المعتمد والمركبات كانت النتائج قيم chi-square بان قيمة sig من $a=0.05$ اي ان النموذج ملائم عند ادخال المركبات والحد الثابت وكما مبين في الجدول رقم (13) الآتي:

جدول رقم (13) يبين معنوية النموذج

		Chi-square	Df	Sig.
Step 1	Step	88.215	7	.000
	Block	88.215	7	.000
	Model	88.215	7	.000

2- ومن خلال الجدول رقم (14) ادناه نلاحظ ان قيمة سالب ضعف لوغارتم دالة الإمكان الأعظم في الدورة الثانية كانت 193.824 وتوقفنا لأن التغيير في معاملات الحد الثابت أصبح اقل من 0.001.

جدول رقم (14)
يبين سالب ضعف لوغارتم دالة الإمكان الأعظم

Iteration	-2 Log likelihood	Coefficients	
		Constant	
Step 0	1	193.824	.086
	2	193.824	.086

3- ان النسبة المئوية للتصنيف الصحيح لمشاهدات المتغير المعتمد في الخطوة الصفرية حيث بلغت 52.1%. وان جميع المشاهدات ضمن المجموعة الأولى صفت بشكل خاطئ أي بمعنى ان نسبة التصنيف الصحيح 0% وان معيار خطأ التصنيف 100%. وان جميع المشاهدات صفت بشكل صحيح ضمن المجموعة الثانية حيث بلغت نسبة التصنيف الصحيح 100% وان معيار خطأ التصنيف 0%. وكما مبين في الجدول رقم (15) ادناه:

جدول رقم (15) يبين نسبة التصنيف للخطوة الصفرية					
Observed	Y	Predicted		Percentage Correct	
		Y			
		فقر دم حاد	فقر دم مزمن		
Step 0	فقر دم حاد	0	67	.0	
	فقر دم مزمن	0	73	100.0	
	Overall Percentage			52.1	

4- ان قيمة سالب ضعف لوغارتم دالة الإمكان الأعظم بلغت 105.609 وهي اقل من متوجه الانموذج الذي يتضمن الحد الثابت وهذا يدل على جودة النموذج. واتضح أيضا ان قيمة R^2 تشكل 0.624 من التباين في متغير الاستجابة تم تفسيره من قبل المركبات. وكما مبين في الجدول رقم (16) ادناه:



**التحليل المعنى والانحدار اللوجستي بوجود مشكلة التعدد
الخطي [دراسة تطبيقية على مرض فقر الدم]**

**جدول رقم (16)
يبين سائب ضعف لوغارتم دالة الإمكان الأعظم**

Step	-2 Log likelihood	Cox & Snell R Square	Nagelkerke R Square
1	105.609 ^a	.467	.624

5- ان النسب المئوية للتصنيف الصحيح لمشاهدات المتغير المعتمد في الخطوة رقم (1) حيث بلغت 80%. وان 54 من المشاهدات ضمن المجموعة الاولى صنفت بشكل صحيح و13 صنفت بشكل خاطئ. وان 58 من البيانات ضمن المجموعة الثانية صنفت بشكل صحيح و15 صنفت بشكل خاطئ. وكما مبين في الجدول رقم (17) ادناء:

جدول رقم (17) يبين نسبة التصنيف للخطوة رقم (1)

Observed	Predicted		Percentage Correct	
	Y			
	فقر دم حاد	فقر دم مزمن		
Step 1	Y	54	80.6	
	فقر دم مزمن	15	79.5	
Overall Percentage			80.0	

6- ان احصاءة مربع كاي لهذا النموذج قد بلغت 8.922 وان قيمة مستوى المعنوية اكبر من $\alpha=0.05$ اي ان النموذج ملائم عند ادخال المتغيرات التوضيحية اذ تقارب القيم المشاهدة من القيم المشابهة لها اي ان النموذج يمثل البيانات بشكل جيد. وكما مبين في الجدول رقم (18) الاتي:

جدول رقم (18) يبين احصاءة مربع كاي

Step	Chi-square	Df	Sig.
1	8.922	8	.349

7- ان النموذج الرياضي للانحدار اللوجستي الثاني كان بالشكل الاتي:

ان النموذج الرياضي للانحدار اللوجستي الثاني كان كالتالي:

$$\log_e \left(\frac{p}{1-p} \right) = 0.833 + 1.195pc_1 + 1.094pc_2 + 0.954pc_3 + 0.674pc_4 + 1.018pc_5 - 0.045pc_6 + 0.542pc_7$$

ونلاحظ ان المعلومات المقدرة باستعمال دالة الإمكان الأعظم واحصاءة Wald لهذه المعلومات نلاحظ ان اهم المركبات المعنوية هي المركبة الأولى والثانية. وكما مبين في الجدول رقم (19) ادناء:



التحليل المميز والانحدار اللوجستي بوجود مشكلة التعدد الخططي [دراسة تطبيقية على مرض فقر الدم]

جدول رقم (19) يبين المعلومات المقدرة للنموذج

	B	S.E.	Wald	Df	Sig.	Exp(B)	95% C.I.for EXP(B)		
							Lower	Upper	
Step 1 ^a	C1	1.195	.249	23.015	1	.000	3.302	2.027	5.380
	C2	1.094	.296	13.641	1	.000	2.987	1.671	5.338
	C3	.954	.576	2.741	1	.098	2.595	.839	8.023
	C4	.674	.345	3.825	1	.050	1.963	.999	3.859
	C5	1.018	.655	2.420	1	.120	2.769	.767	9.987
	C6	-0.045-	.364	.016	1	.901	.956	.468	1.949
	C7	.542	.369	2.159	1	.142	1.719	.835	3.541
	Constant	.833	.404	4.246	1	.039	2.300		

7- مقارنة بين الدالة المميزة الخطية والانحدار اللوجستي

سنقوم بأجراء مقارنة بين الدالة المميزة الخطية والانحدار اللوجستي الثاني من حيث احتمال خطأ التصنيف. فوجد ان احتمال خطأ التصنيف للدالة المميزة الخطية كان (17.1%) أقل من خطأ التصنيف للانحدار اللوجستي الثاني الذي بلغ (20%) وهذا يعني ان الدالة المميزة الخطية أفضل في تصنيف مشاهدات عينة فقر الدم من الانحدار اللوجستي الثاني.

11- الاستنتاجات

نستنتج من هذا البحث الآتي:

- 1- نلاحظ ان معامل تضخم التباين للبيانات قد قل بعد استخدام انحدار المربعات الصغرى الجزئية ولجميع المتغيرات حيث أصبحت جميعها أقل من (5) وهذا يعني انه تم التخلص من مشكلة التعدد الخططي.
- 2- عند المقارنة بين الطريقتين باستخدام معيار خطأ التصنيف تم التوصل الى ان الدالة المميزة الخطية هي أفضل في تصنيف البيانات من الانحدار اللوجستي الثاني حيث بلغ معيار خطأ التصنيف للدالة المميزة الخطية (17.1%) وهو أقل من معيار خطأ التصنيف للانحدار اللوجستي الثاني الذي بلغ (20%).
- 3- عند التوصل الى ان الدالة المميزة الخطية أفضل في التصنيف من الانحدار اللوجستي الثاني هذا يعني ان نموذج الدالة المميزة أفضل في التنبؤ من الانحدار اللوجستي الثاني لأنها أعطت أقل خطأ تصنيف.

12- التوصيات:

بناءً على ما تم التوصل اليه من الاستنتاجات نوصي بالآتي:

- 1- نوصي الى استخدام طريقة انحدار المربعات الصغرى الجزئية في التخلص من مشكلة التعدد الخططي لأنها عالجت الارتباط الخططي بين المتغيرات التوضيحية.
- 2- اجراء دراسات إحصائية في حالة وجود قيمة شاذة ومشكلة تعدد خططي واجراء دراسات مقارنة بين الانحدار اللوجستي والتحليل المميز بعد ان تتم المعالجة من وجود الشوائب بأحد الطرائق الحصينة والارتباطات بين المتغيرات (بطريقة المربعات الصغرى الجزئية)
- 3- نوصي بتوسيع انحدار المربعات الصغرى الجزئية وذلك في حالة عدد المتغيرات التوضيحية اكبر من عدد المشاهدات ومن ثم استعمالها في المقارنة بين الانحدار اللوجستي والدالة المميزة الخطية سواء كانت خطية او تربيعية.



المصادر

- 1-البكري، رباب عبد الرضا (2015)، مقارنة بعض الطرائق الخطية لمعالجة مشكلة التعدد الخطى في النماذج مع تطبيق عملي، رسالة دكتوراه - كلية الادارة والاقتصاد - جامعة بغداد.
- 2-التميمي، رعد فاضل حسن، (2013)، "الانحدار والسلسل الزمنية أساليب إحصائية تطبيقية متقدمة باستخدام برنامج Minitab، كتاب، كلية الادارة والاقتصاد، الجامعة المستنصرية.
- 3-الحمداني، بسمة رشيد، (2014)، "تميز الملاك الطبي بحسب معرفتهم للتصنيف الدولي (ICD-10)) باستعمال الدالة المميزة"، رسالة ماجستير في جامعة بغداد، كلية الادارة والاقتصاد.
- 4-عباس، علي خضير، 2012، "استخدام نموذج الانحدار اللوجستي في التنبؤ بالدول ذات المتغيرات الاقتصادية التابعة النوعية"، مجلة كركوك للعلوم الادارية والاقتصادية، مجلد 2، العدد 2.
- 5-Abdi, hervi, 2010," Partial least squares regression and projection on latent structure regression (PLS Regression)", John Wiley & Sons.
- 6-Abdelmounaim Kerkri, Zoubir Zarrouk, Jelloul ALLAL, "A comparison of NIPALS algorithm with two other missing data treatment methods in a principal component analysis" University Mohamed.
- 7-Boaz Nadler, Ronald R.Coifman, 2005, " Partial least squares, Beer's law and the net analyte signal: statistical modeling and analysis", Department of Mathematics, Yale University.
- 8-Erik Brorson, Asterios Geroukis, 2014, "A comparison between discriminant analysis and logistic regression using principal components", Department of Statistics, Uppsala University, Uppsala University.
- 9-Leo H. Chiang, Evan L. Russell, Richard D. Braatz,2000, " Fault diagnosis in chemical processes using Fisher discriminant analysis, discriminant partial least squares, and principal component analysis", Department of Chemical Engineering, universty of Illinois.
- 10- Tormod Ness and Bjorn-Helge Mevik, "Understanding the collinearity problem in regression and discriminant analysis", Journal of Chemo metrics, P (413-426), 2001.



discriminate analysis and logistic regression existence of multicollinearity problem(Empirical Study on Anemia)

Abstract

The method binary logistic regression and linear discriminant function of the most important statistical methods used in the classification and prediction when the data of the kind of binary (0,1) you can not use the normal regression therefore resort to binary logistic regression and linear discriminant function in the case of two group in the case of a Multicollinearity problem between the data (the data containing high correlation) It became not possible to use binary logistic regression and linear discriminant function, to solve this problem, we resort to Partial least square regression.

In this, search the comparison between binary logistic regression and linear discriminant function using error Category. In the practical side in the collection of data on the data on anemia collection Two variables are severe anemia (0) and chronic anemia (1) and several variables about the disease. The Data were collected from several Iraqi hospitals, where samples collected from patients at the hospital are asleep, and previous cases lay in the hospital a sample of (140) the patient is infected with the disease. When the test data and found that Multicollinearity problem, It has been processed using a method partial least square. The research found that linear discriminant function It is the best in the classification of data from binary logistic regression classified as linear discriminant function the data correctly and more accurate than binary logistic regression.

Keyword: linear discriminant function- binary logistic regression- partial least square– multicollinearity problem – ratio of classification.