

استخدام الشبكات العصبية الاصطناعية في تحليل الانحدار الخطي المتعدد

عزة حازم زكي

مدرس مساعد - قسم الاحصاء والمعلوماتية

كلية علوم الحاسبات والرياضيات

azza_master@yahoo.com

ندوى خزعل رشاد

مدرس مساعد - قسم نظم المعلومات

كلية الادارة والاقتصاد

المستخلص

يعد تحليل الانحدار أنموذجاً توقعياً إحصائياً، ويهتم بوصف وتقييم العلاقة بين متغير معطى (يسمى المتغير التابع عادة) وواحد أو عدة متغيرات أخرى والتي تسمى عادة بالمتغيرات التوضيحية. وتحليل الانحدار من الوسائل الإحصائية ذات التطبيقات الواسعة عند المهتمين في مختلف العلوم الاجتماعية والاقتصادية والصحية. ومن الأساليب الحديثة التي أخذت اهتماماً واضحاً وخاصة في مجال علوم الحاسبات، حيث ظهر في الآونة الأخيرة أسلوب الشبكات العصبية الاصطناعية Artificial Neural Networks. ويهدف هذا البحث إلى تحليل الانحدار المتعدد باستخدام الشبكات العصبية ومقارنته مع أسلوب تحليل الانحدار المتدرج Stepwise Regression. وتم التوصل إلى أن الشبكات العصبية ذات دقة أكثر من طريقة الانحدار الخطي المتعدد في كشف المتغيرات ذات الفروقات غير المعنوية.

Using Artificial Neural Networks in Multiple Linear Regression

Nadwa Kh. Rashad

Assistant Lecturer

Department of Management Information Systems

University of Mosul

Azza H. Zaki

Assistant Lecturer

Department of Statistics and Information University of Mosul

azza_master@yahoo.com

Abstract

The regression analysis is considered as an expectative and statistical model. It concerns with the description and standardization of the relationship between a given variable which is called (dependent variable) and other variables called independent variables. Regression analysis is one of the statistical methods that have wide applications to those concerning with many different societies, economic and health sciences. One of the modern methods that clearly concerned with the computer field which has appeared these

days is Artificial Neural Networks. The aim of this research is the comparison between Neural Networks Method with multiple regressions using stepwise regression method.

المقدمة

يعرف أنموذج الانحدار الخطي المتعدد بأنه عملية تقدير العلاقة الخطية بين عدة متغيرات أحدها متغير الاستجابة والباقي متغيرات توضيحية يعتقد بأنها تؤثر في متغير الاستجابة.

العلاقة للدالة Function Relationship بين المتغير المعتمد (الاستجابة) Y والمتغيرات التوضيحية (X_1, X_2, \dots, X_m) في تحليل الانحدار الخطي المتعدد تاخذ الصيغة الآتية (شرجي، ١٩٨١):

$$Y_i = \beta_0 + \beta_1 X_{i1} + \beta_2 X_{i2} + \dots + \beta_m X_{im} + U_i \quad \dots\dots\dots(1)$$

$$Y_i = \beta_0 + \sum_{j=1}^m \beta_j X_{ij} + U_i \quad , i=1,2,\dots,n ; j=1,2,\dots,m$$

حيث إن:

Y_i : المتغير المعتمد أو التابع أو قيمة متغير الاستجابة

β_0 : نقطة تقاطع مستوى الانحدار بالمحور Y.

$\beta_1, \beta_2, \dots, \beta_m$: تمثل معاملات الأنموذج المجهولة.

U_i : الخطأ العشوائي المعدل = ٠ وتباين σ^2 .

وبتطبيق الصيغة ادناه والتي تعرف بصيغة المعادلات الطبيعية Normal Equations نحصل على مقدر المربعات الصغرى لمتجه المعلمات (شرجي، ١٩٨١).

$$\hat{b} = (X'X)^{-1} X'Y \quad \dots\dots\dots(2)$$

حيث ان

$X'X$: مصفوفة مربعة تدعى مصفوفة المعلومات Information Matrix

$X'Y$: متجه لحاصل ضرب المتغيرات التوضيحية في متغير الاستجابة

اي ان

$$X'X = \begin{bmatrix} n & \sum X_{i1} & \sum X_{i2} & \dots & \sum X_{im} \\ \sum X_{i1} & \sum X_{i1}^2 & \sum X_{i1}X_{i2} & \dots & \sum X_{i1}X_{im} \\ \cdot & \cdot & \cdot & \dots & \cdot \\ \sum X_{im} & \sum X_{im}X_{i1} & \sum X_{im}X_{i2} & \dots & \sum X_{im}^2 \end{bmatrix}$$

$$X'Y = \begin{bmatrix} \sum Y_i \\ \sum Y_i X_{i1} \\ \sum Y_i X_{i2} \\ \cdot \\ \cdot \\ \sum Y_i X_{im} \end{bmatrix}$$

ويمكن تنظيم جدول تحليل التباين كما في الجدول الآتي للتعرف على معنوية معاملات دالة الانحدار واختبار الفرضية لآتية (الراوي، ٢٠٠٤):

$$H_0: \beta_1 = \beta_2 = \dots = \beta_m$$

$$H_1: \beta_1 \neq \beta_2 \neq \dots \neq \beta_m$$

جدول تحليل التباين للانحدار المتعدد

S.o.V.	d.f	S.S	MS	F.cal.
R(X ₁ , X ₂ , ..., X _m)	m	SSR	MSR	$\frac{MSR}{MSe}$
Error (X ₁ , X ₂ , ..., X _m)	n-m-1	SSE	MSe	
Total	n-1	SST		

حيث إن:

SST: مجموع المربعات الكلي

$$SST = S_{YY}$$

$$SST = y'y - \frac{(\sum y_i)^2}{n}$$

$$SST = \sum y_i^2 - \frac{(\sum y_i)^2}{n}$$

SSR: مجموع المربعات العائدة الى الانحدار

$$SSR = \underline{\beta'X'y} - \frac{(\sum y_i)^2}{n}$$

رشاد وزكي [٤]

$$= [b_0 \ b_1 \dots \ b_m] \cdot \begin{bmatrix} \sum_{i=1}^n y_i \\ \sum_{i=1}^n x_{i1} y_i \\ \vdots \\ \sum_{i=1}^n x_{im} y_i \end{bmatrix} - \frac{(\sum y_i)^2}{n}$$

MSR: متوسط مجموع المربعات

$$MSR = \frac{SSR}{m}$$

SSe: مجموع المربعات العائدة الى الخطأ

$$MSe = \frac{SSe}{n - m - 1}$$

فإذا كانت قيمة F المحسوبة مساوية أو أكبر من قيمة F الجدولية تحت مستوى معنوية α يدل على معنوية المتغيرات قيد الدراسة.

طريقة الانحدار المتدرج Stepwise Regression Procedure

تستخدم هذه الطريقة في تحليل الانحدار المتعدد لانتخاب المتغيرات ذات التأثير المعنوي والمهم في المتغير المستجيب، إذ إن جميع المتغيرات التوضيحية التي دخلت المعادلة تحسب فيها قيمة F الجزئية في كل خطوة وتقيم على أساسها مرة أخرى، لأنه لا بد عند اختيارنا المبكر لأحد المتغيرات التوضيحية أحياناً قد يعطي قيمة F الجزئية أقل من قيمة F الجدولية في المرحلة المتأخرة، وذلك لوجود علاقة قوية بينه وبين أحد المتغيرات التوضيحية الأخرى التي اختيرت في المعادلة، وهذه القيمة تحتاج الى قيمتين من قيم F الجدولية هما F_{in} ، وتستخدم لادخال المتغيرات التوضيحية الى المعادلة و F_{out} ، وتستخدم لحذف المتغير الذي ليس له تأثير على المتغير المستجيب.

ويمكن تلخيص أهداف تحليل الانحدار المتدرج في النواحي الآتية:

١. تنبؤ سلوك المتغير التابع في ضوء تأثيره بالمتغيرات التوضيحية.
٢. تقرير مساهمة كل متغير توضيحي في مدى التباين الحاصل في المتغير المستجيب.
٣. قياس مدى الترابط الكلي بين المتغير المستجيب والمتغيرات التوضيحية.
٤. إجراء سلسلة من الاختبارات الفرضية لأي من العلاقات المشار إليها في النقاط السابقة.

وبفرض أن لدينا متغير استجابة Y وعدد من المتغيرات التوضيحية $(X_{i,s})$ ، فيمكن احتساب طريقة الانحدار المتدرج Stepwise Regression حسب المراحل الآتية :
أ. إيجاد جدول تحليل التباين لانحدار Y على $(X_{i,s})$ لكل متغير على حدة (Y على X_1 ، Y على X_2 ، ...، Y على X_p) وكما في الجدول الآتي:

S.o.V.	d.f	S.S	MS	F.cal.
R(X ₁)	p	B'X'Y - n \bar{Y}^2	(SSR*X ₁)/d.f	$\frac{MSR}{MSe}$
Error(X _i)	n-p-1	Y'Y - B'X'Y	SSe/d.f.	
Total	n-1	Y'Y - n \bar{Y}^2		

حيث إن:

B: عبارة عن متجه المعلمات ذات سعة (p*1).

X: عبارة عن مصفوفة ذات سعة (p*n) من المتغيرات التوضيحية.

Y: عبارة عن متجه مشاهدات ذات سعة (p*1).

نقوم باختيار جدول تحليل التباين ذي القيمة الأكبر.

ب. إيجاد جدول تحليل التباين لانحدار أعلى (X_{i,s}) مع إضافة المتغير المنتخب في الخطوة (أ) وبحسب جدول تحليل التباين الآتي:

S.o.V.	d.f	S.S	MS	F.cal.
R(X _i ,X _k)	p	B'X'Y - n \bar{Y}^2		
R(X _k)	1	B'X'Y - n \bar{Y}^2		
R(X _i /X _k)	1	B'X'Y - n \bar{Y}^2	$\frac{SSR (X_i / X_k)}{d.f}$	$\frac{MSR (X_i / X_k)}{MSe}$
Error(X _i ,X _k)	n-p	Y'Y - B'X'Y	$\frac{SSe}{d.f}$	
Total	n-1	Y'Y - n \bar{Y}^2		

حيث إن:

R(X_i,X_k): هو المتغير ذو الرتبة k، وتمت اضافته الى معادلة الانحدار و i=(1,2,3,...,p-1) اي عدد المتغيرات المتبقية.

بعد اختيار أكبر قيمة لجدول تحليل التباين لانحدار Y على X_L بتثبيت X_k، حيث إن

X_L هو المتغير ذو الرتبة L وتم اضافته الى الأنموذج.

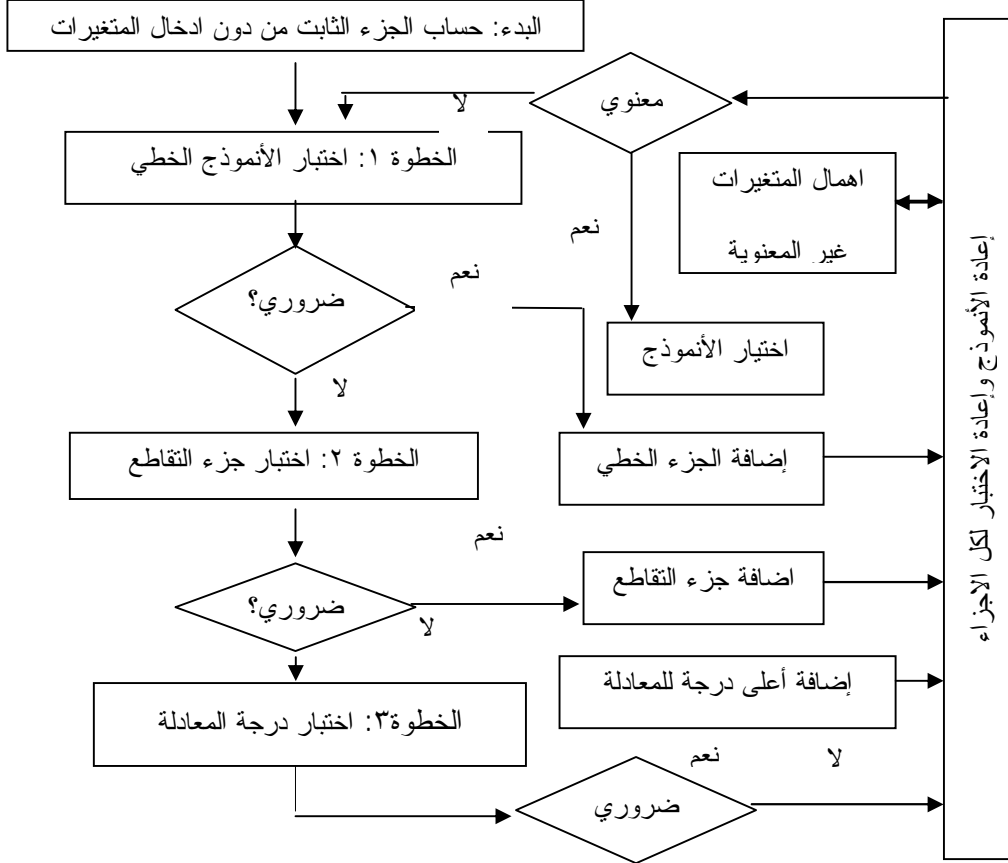
ج. هذه الخطوة هي انحدار Y على (X_{i,s}) بتثبيت X_L و X_k، وهكذا نستمر الى أن نحصل

على أنموذج يحتوي على المتغيرات ذات التأثير المهم في الأنموذج، اي يمكن

استخدام هذه المتغيرات في الحصول على تمييز افضل بين مجتمعين (الراوي،

١٩٨٧).

والشكل الآتي يبين خوارزمية الانحدار المتدرج (Wikipedia,2008)




الشكل ١
خوارزمية الانحدار المتدرج

الشبكات العصبية الاصطناعية Artificial Neural Networks

هي تقنيات حاسوبية مصممة لمحاكاة الطريقة التي يؤدي بها الدماغ البشري مهمة معينة، وذلك عن طريق معالجة ضخمة موزعة على التوازي. فالشبكات العصبية الاصطناعية تتشابه مع الدماغ البشري في أنها تكتسب المعرفة بالتدريب، وتخزن هذه المعرفة باستخدام قوى وصل داخل العصبونات تسمى الأوزان التشابكية. وهناك أيضا تشابه عصبي حيوي، مما يعطي الفرصة لعلماء البيولوجيا في الاعتماد على ANN لفهم تطور الظواهر الحيوية.

مكونات الشبكة العصبية الاصطناعية

تتكون الشبكات العصبية من مجموعة من وحدات المعالجة، ويسمى أحدها عصبون، والشكل ٢ يبين أنموذجاً لاختياً وبسيطاً للعصبون الاصطناعي :



الشكل ٢
خلية عصبية اصطناعية

كما إن للإنسان وحدات إدخال توصله بالعالم الخارجي وهي حواسه الخمس، فذلك الشبكات العصبية تحتاج لوحدة إدخال. ووحدات معالجة يتم فيها عمليات حسابية تضبط بها الأوزان، ونحصل من خلالها على ردة الفعل المناسبة لكل مدخل من المدخلات للشبكة. فوحدات الإدخال تكون طبقة تسمى طبقة المدخلات، ووحدات المعالجة تكون طبقة المعالجة وهي التي تخرج نواتج الشبكة. وبين كل طبقة من هذه الطبقات هناك طبقة من الوصلات البينية التي تربط كل طبقة بالطبقة التي تليها والتي يتم فيها ضبط الأوزان الخاصة بكل وصلة بينية، وتحتوي الشبكة على طبقة واحدة فقط من وحدات الإدخال، ولكنها قد تحتوي على أكثر من طبقة من طبقات المعالجة.

البنية المعمارية للشبكات العصبية

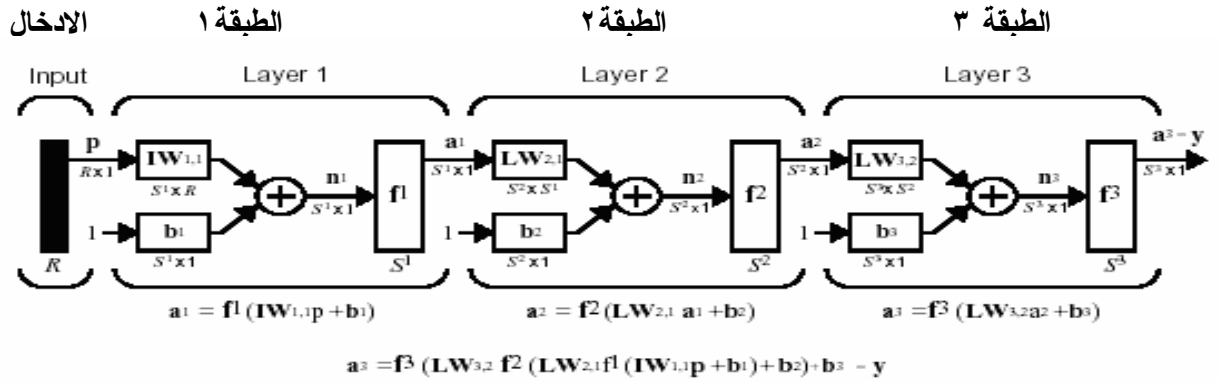
معمارية الشبكة العصبية الاصطناعية، هي الطريقة التي ترتبط بها العصبونات مع بعضها البعض لتشكيل الشبكة، وترتبط كل مركبة من مركبات متجه الإدخال بكل عصبون من خلال مصفوفة الوزن W .

كل عصبون يحوي وحدة مجموع تقوم بجمع الإدخال الموزون مع الإزاحة لتشكيل الإخراج العددي للعصبون، وفي النتيجة إن مركبات إخراج طبقة العصبونات تشكل متجه الإخراج مركبات متجه الإدخال تدخل إلى الشبكة من خلال مصفوفة الأوزان الآتية:

$$W = \begin{bmatrix} w_{1,1} & w_{1,2} & \dots & w_{1,R} \\ w_{2,1} & w_{2,2} & \dots & w_{2,R} \\ \dots & \dots & \dots & \dots \\ w_{S,1} & w_{S,2} & \dots & w_{S,R} \end{bmatrix}$$

الشبكة ذات الطبقات المتعددة الأمامية

الشبكة العصبية يمكن أن تتألف من عدة طبقات، وفي هذه الحالة يكون لكل طبقة مصفوفة وزن W ، ومنتجه إزاحة ومنتجه إخراج، ومن أجل التمييز يضاف رقم الطبقة كدليل علوي لكل من المتحولات المستعملة من خلال الشبكة المبينة مركبة الإدخال، عصبون في الطبقة الأولى، عصبون في الطبقة الثانية، وهكذا بالأسلوب نفسه. ومن الملاحظ أيضا أن إخراج كل طبقة متوسطة هو ادخال للطبقة التي تليها وبذلك تعد كل طبقة في هذه الشبكة كأنها شبكة ذات طبقة وحيدة، والطبقة التي تعطي الإخراج تسمى طبقة الإخراج، أما الإدخال فلا يعد طبقة، وبقيّة الطبقات تسمى الطبقات المخفية (Orna, 2001). والشكل الآتي يبين معمارية الشبكات ذات التغذية الأمامية:



الشكل ٣

خوارزمية الشبكات ذات التغذية الأمامية

خوارزمية الشبكات ذات التغذية الأمامية في تحليل الانحدار (Bacure, 1998)

١. ابدأ بالمعادلة الآتية

$$p = \delta \left(\sum_{i=1}^L \lambda_i \delta(x * w_i) \right) \quad (3)$$

حيث إن:

L : عدد الطبقات المخفية

δ : دالة Sigmoid ويعبر عنها بالمعادلة $\delta(x) = 1/1 + \exp(-x)$

x: متجه الادخال (المتغيرات التوضيحية)

w: الاوزان (β_i)

λ : دالة التحفيز bias (β_0)

٢. بأخذ اللوغارتم تصبح المعادلة

$$\log(p/(1-p)) = \sum_{i=1}^L \lambda_i \delta(x * w_i) \quad (4)$$

٣. اشتقاق المعادلة بالنسبة الى x

$$\frac{\partial}{\partial x_j} \log(p(x)/(1-p(x))) = \sum_{i=1}^L \lambda_i \delta(x * w_i) w_{ij} \quad (5)$$

٤. أما الاوزان فتحسب على وفق المعادلة

$$\bar{w}_j(x) = \sum_{i=1}^L \lambda_i \delta'(x * w_i) w_{ij} \quad (6)$$

الجانب التطبيقي

استخدمت بيانات عن مرضى سرطان الدم بعدد (٥٣) جمعت من المستشفى العام في مدينة الموصل وكانت المتغيرات المدروسة هي:

Y نسبة الخلايا السرطانية

X₁ الجنس (ذكر، انثى)

X₂ العمر

X₃ الحالة الزوجية (اعزب، متزوج)

X₄ محل السكن (مدينة، قضاء، قرية، ناحية)

X₅ الهيموكلوبين

X₆ مكداس الدم

X₇ فحص دم له علاقة بالهيموكلوبين

X₈ عدد الصفائح الدموية

X₉ عدد كريات الدم البيضاء

X₁₀ نوع الخلايا السرطانية الحادة

١. تحليل الانحدار المتدرج Stepwise Regression

تم استخدام أسلوب الانحدار الخطي المتدرج، اذ يحدد هذا الأسلوب مقدار العلاقة بين المتغير التابع (نسبة الخلايا السرطانية) وعدد من المتغيرات التوضيحية.

وطريقة الانحدار التدريجي تعطي نسبة تفسير كل متغير مرتبة بحسب أهمية المتغير في التحليل (أي إن التحليل يبدأ بتحديد أهم متغير وينتهي بالمتغير الأقل أهمية في

رشاد وزكي [١٠]

تفسير الاختلاف الذي يحدث في المتغير التابع). وتم الحصول على النتائج الموضحة في الجدول ١.

الجدول ١

جدول تحليل التباين باستخدام طريقة الانحدار التدريجي

Stepwise Regression: y versus x1; x2; x3; x4; x5; x6; x7; x8; x9; x10

Alpha-to-Enter: 0.05 Alpha-to-Remove: 0.05

Response is y on 10 predictors, with N = 53

Step	1	2	3
Constant	27.42	46.17	53.57
x9	0.324	0.231	0.275
T-Value	4.20	2.85	3.56
P-Value	0.000	0.006	0.001
x7	-0.35	-0.40	
T-Value	-2.63	-3.19	
P-Value	0.011	0.003	
x10		-20.7	
T-Value		-2.90	
P-Value		0.006	

أظهرت نتائج تحليل الانحدار المتدرج أن عدد كريات الدم البيضاء و فحص الدم الذي له علاقة بالهيموكلوبين و نوع الخلايا السرطانية الحادة لدى المرضى هي أهم عناصر يجب أخذها بالاعتبار إذا ما اريد قياس نسبة الخلايا السرطانية للمرضى. ويوضح الجدول ٢ معادلة الانحدار لطريقة الانحدار المتعدد .

الجدول ٢

معادلة الانحدار المتعدد

The regression equation is

$$y = 53.6 - 0.400 x7 + 0.275 x9 - 20.7 x10$$

Predictor	Coef	SE Coef	T	P	VIF
Constant	53.571	8.106	6.61	0.000	
x7	-0.4003	0.1256	-3.19	0.003	1.3
x9	0.27528	0.07728	3.56	0.001	1.3
x10	-20.656	7.133	-2.90	0.006	1.1

٢. الشبكات العصبية الاصطناعية Artificial Neural Networks


استخدم برنامج حاسوبي لغرض التحليل باستخدام الشبكات العصبية الاصطناعية واختيرت المتغيرات التي تبين أن لها تأثيراً معنوياً في متغير الاستجابة. إن أولى الخطوات في التحليل هي تحديد المدخلات للشبكة العصبية، وكانت المتغيرات (عدد كريات الدم البيضاء، فحص الدم الذي له علاقة بالهيموكلوبين ونوع الخلايا السرطانية) هي مدخلات الشبكة. تم تحديد العقد في الطبقة المخفية والذي يتحدد من خلال التدريب والعديد من التجارب الحاسوبية والجدول ٣ يوضح مقدار الخطأ المطلق للشبكة.

الجدول ٣
عدد العقد في الطبقة المخفية

معمارية الشبكة	الخطأ المطلق	الخطأ للشبكة
3-1-1	17.199	0.059
3-2-1	15.384	0.044
3-3-1	17.242	0.051
3-4-1	17.529	0.052

في هذا الاختبار تم تثبيت عدد مرات التدريب بـ ١٠٠٠٠ مرة، وقيمة متوسط مربعات الخطأ ٠,٠١، ومعدل التعلم للشبكة ٠,٧، ويتضح من الجدول أن أقل قيمة للخطأ عند استخدام عصبونين للطبقة المخفية.

تم تدريب شبكة عصبية ذات تغذية أمامية لحين الوصول الى أفضل شبكة عصبية أعطت أقل متوسط مربع للخطأ، والمؤلفة من طبقة إدخال ذات ٣ متغيرات (X_9 و X_{10} و X_7) وطبقة مخفية واحدة مكونة من عصبونين (H_1 و H_2) وطبقة إخراج (y)، وكانت دالة التنشيط المستخدمة هي دالة Sigmoid. والشكل الآتي يوضح الشبكة المستخدمة في التحليل:



الشكل ٤
الشبكة العصبية المستخدمة في تحليل الانحدار

ويوضح الجدول ٤ معادلة الانحدار وتحليل التباين لطريقة الشبكات العصبية الاصطناعية ذات التغذية الأمامية.

الجدول ٤
معادلة الانحدار بطريقة الشبكات العصبية الاصطناعية

The regression equation is

$$\text{output} = 60.9 - 0.426 x7 + 0.0909 x9 - 9.16 x10$$

Predictor	Coef	SE Coef	T	P	VIF
Constant	60.918	5.694	10.70	0.000	
x7	-0.42610	0.08826	-4.83	0.000	1.3
x9	0.09088	0.05428	1.67	0.001	1.3
x10	-9.161	5.010	-1.83	0.074	1.1

ويلاحظ من قيم VIF في الجدولين ٢ و ٤ بان ليس هناك مشكلة تعدد العلاقات الخطية لكلتا الطريقتين.

ويوضح الجدول ٥ نتائج تحليل التباين لكل من طريقتي الانحدار المتعدد والشبكات العصبية الاصطناعية ذات التغذية الأمامية.

الجدول ٥
تحليل التباين

أ. طريقة الانحدار المتعدد

Analysis of Variance

Source	DF	SS	MS	F	P
Regression	3	20737.2	6912.4	12.98	0.000
Residual Error	49	26087.6	532.4		
Total	52	46824.8			

ب. طريقة الشبكات العصبية الاصطناعية

Analysis of Variance

Source	DF	SS	MS	F	P
Regression	3	10144.4	3381.5	12.87	0.000
Residual Error	49	12872.1	262.7		
Total	52	23016.5			

ومن مقارنة قيم MSE لكلا الطريقتين يتبين بأن طريقة الشبكات العصبية الاصطناعية ذات التغذية الأمامية هي الأفضل في تحليل الانحدار المتعدد. وهذا ينسجم مع الحقائق الطبية التي تذكر أن الأمراض السرطانية تنشأ في نخاع العظم وتسبب احتلال حيز من مساحة النخاع العظمي يجعل الخلايا الطبيعية لا تجد مساحة كافية للتكاثر لإنتاج مكونات الدم من كريات الدم الحمراء أو الصفائح الدموية. ولذلك تتميز كلها بأنها تسبب فقر دم أو ضعف الخلايا المتعادلة، وبالتالي ضعف في المناعة أو ضعف إنتاج الصفائح الدموية، في كل الأنواع المختلفة للسرطان تمتد يد السرطان الخبيثة إلى القسم الخاص بإنتاج الخلايا البيضاء فتتكاثر بسرعة وبأعداد كبيرة، فتخرج خلايا بيضاء كثيرة جداً لكنها غير طبيعية فتكون خلايا سرطانية، ولأنها تتجمع وتتراكم بنخاع العظم فإنها تضعف إنتاج الخلايا الأخرى ولأن هذه الخلايا البيضاء غير الطبيعية تزاحم الخلايا الأخرى السليمة وتطغى عليها وتحد من إنتاجها فإننا نتوقع حدوث حالة من الأنيميا بسبب انخفاض الخلايا الحمراء مع ظهور بقع تحت الجلد بسبب انخفاض الصفائح الدموية، وهذا ما يفسر التناسب الطردي للمتغير X_9 .

أما بالنسبة للمتغير X_{10} (نوع الخلايا السرطانية الحادة) فإن أنواع سرطانات الدم تنقسم إلى أربعة أنواع رئيسية هي:

سرطان الدم النخاعي الحاد

سرطان الدم الليمفاوي الحاد

سرطان الدم النخاعي المزمن

سرطان الدم الليمفاوي المزمن

السرطان الحاد يعني ذلك أنه يظهر فجأة، ويمكن أن تتدهور الحالة الصحية للمصاب بسرعة إذا لم يعالج في وقت مبكر. إذ إن في اللوكيميا الحادة تكون الخلايا الشاذة قاصرة عن النضج، و تبقى غير بالغة و تستمر في التكاثر و الإحتشاد بالنخاع و تندفع في تطورها بسرعة متزايدة، بحسب الآلية الطبيعية لدورة حياة الخلايا الطبيعية. وهذا ما يفسر العلاقة العكسية للمتغير X_{10} مع نسبة الخلايا السرطانية.


ويوضح الجدول ٧ قيم التكهّن للطريقتين. أما الشكل ٥ فيبين رسم قيم التكهّن التي تم الحصول عليها للطريقتين.

الجدول ٧
قيم التكهّن

التكهّن بطريقة الشبكات العصبية	التكهّن بطريقة الانحدار المتعدد
52.38	49.175
56.214	68.5875
60.048	91.3
7.044	32.41
32.57	16.275
42.368	73.6
40.664	51.1
20.43	16.48
47.054	32.4325

رشاد وزكي [١٤]

التكهن بطريقة الشبكات العصبية	التكهن بطريقة الاحدار المتعدد
26.82	32.985
35.34	33.34
26.18	13.6575
52.38	53.85
21.494	4.995
20.642	24.875
48.12	58.1
35.34	30.315
33.422	17.075
57.066	73.1825
16.808	1.2
20.43	17.25
53.658	49.3575
38.534	23.525
20.43	15.875
28.95	24.975
31.506	26.77
34.488	29.625
25.116	20.77
51.528	51.675
28.95	24.9475
42.156	42.875
26.82	23.8
39.6	34.425
46.842	55.14
43.86	40.35
32.358	28.175
45.138	39.7625
50.676	45.375
40.664	29.1825
47.906	34.8
34.7	63.925
26.82	25.725
53.658	60.55
26.82	22.2875
35.552	18.8
48.972	42.8675
55.362	73.15
56.64	54.825
49.61	35.9875
50.888	82.975
39.6	34.975
20.56	26.0975



الشكل ٥

قيم التكهن لطريقتي الانحدار المتعدد والشبكات العصبية الاصطناعية

الاستنتاجات

1. يستنتج من سياق البحث الآتي إن الشبكات العصبية كانت الأفضل من طريقة الانحدار المتدرج، إذ إنها أعطت أقل قيمة لمتوسط مربعات الخطأ.
2. لاحظنا اختلاف نتائج الشبكات العصبية الاصطناعية عن طريقة الانحدار التدريجي وتبين من خلال ذلك أفضلية الشبكات العصبية، حيث أظهرت نتائجها دقة أكثر في كشف المتغيرات ذات الفروقات غير المعنوية. وتناسبت النتائج مع الحقائق الطبية .

المراجع

أولاً- المراجع باللغة العربية

١. الراوي، خاشع محمود، ١٩٨٧، "المدخل الى تحليل الانحدار"، مديرية دار الكتب للطباعة والنشر، جامعة الموصل.
٢. الراوي، عمر فوزي، ٢٠٠٤، استخدام الدالة التمييزية في السيطرة النوعية، رسالة ماجستير غير منشورة، كلية علوم الحاسبات والرياضيات، جامعة الموصل.
٣. شرجي، عبدالرزاق محمد، ١٩٨١، "الانحدار الخطي المتعدد"، مطابع وزارة التعليم العالي والبحث العلمي، جامعة الموصل.
٤. الشكرجي، ذنون يونس، ٢٠٠٥، استخدام مصفوفتي المتغيرات والافراد في التحليل العالمي، رسالة ماجستير غير منشورة، كلية علوم الحاسبات والرياضيات، جامعة الموصل.
٥. الموسوعة الصحية الحديثة www.se77ab.com.

ثانياً- المراجع باللغة الاجنبية

1. Bruce D. Baker, 1998, 'A Comparison of Linear Regression and Neural Network Methods for Forecasting Educational Spending', Department of Teaching and Leadership, 202 Bailey Hall, University of Kansas.
2. Orna Intrator and Nathan Intrator, 2001, "INTERPRETING NEURAL-NETWORK RESULTS: A SIMULATION STUDY", Brown University, Computer Science Department, February.
3. Wikipedia, The Free Encyclopedia, Stepwise regression, (2008), <http://en.wikipedia.org/wiki/Statistics>.