المجلة العراقية للعلوم الإحصائية (21) 2012
ص ص [234-245]

مقارنة التنبؤ باستخدام شبكة الانحدار العصبية المعممة بأسلوب الشبكات العصبية وتحليل الانحدار

زكريا يحيى الجّمال[1] د. عمر صابر[2]

المستخلص

تم في هذا البحث استخدام أسلوب مهجن بين الشبكات العصبية الاصطناعية ونموذج الانحدار الخطي، إذ تم توضيح آلية عمل هذا الأسلوب المهجن ومقارنته مع نماذج الشبكات العصبية ونموذج الانحدار الخطي لمعرفة مدى كفاءة هذا الأسلوب. وباستخدام معيار متوسط مربعات الخطأ ثبتت كفاءة هذا الأسلوب المهجن وهو ما يطلق عليه أسلوب شبكة الانحدار العصبية المعممة مقارنة مع النموذجين المستخدمين من خلال تجارب المحاكاة وتطبيق الأمثلة الواقعية.

العبارات الدالة : الشبكات العصبية الاصطناعية، نموذج الانحدار الخطي، شبكة الانحدار العصبية المعممة.

Prediction Comparison Using the Generalized Regression Neural Network with Neural Networks Approach and Regression Analysis

Zakariya Y. Algamal **Dr. Omar Saber**

Abstract

In this paper, we use a hybrid technique from artificial neural network and linear regression model. We explain how this hybrid technique works and compare it with neural network and linear regression model. To show how well done, we used the Mean Square

[1] مدرس- قسم الإحصاء والمعلوماتية – كلية علوم الحاسوب والرياضيات – جامعة الموصل.

[2] مدرس – قسم الرياضيات - كلية علوم الحاسوب والرياضيات – جامعة الموصل.

تاريخ التسليم 2011/10/4 ـــــــــــــــــ تاريخ القبول 2011/12/11

Error (MSE) criteria through using simulation and real examples, we show that this hybrid technique, generalized regression neural network has minimum value of MSE.

1- المقدمة :

إن من أوسع الأساليب الإحصائية استخداما في مختلف العلوم هو أسـلوب تحليـل الانحدار فهو يحدد ويوضح العلاقة بين المتغيرات على شكل علاقة دالية يعبر عنها بهيأة معادلة ويستدل من تقدير معلماتها على أهمية العلاقة وقوتها واتجاهها ، وان لهذا الأمـر أهمية كبيرة في التخطيط واتخاذ القرارات الرصينة قيد البحث. ولما كان الانحدار يحـدد العلاقة بين المتغيرات وان النجاح والفشل للنموذج المقدر يعتمدان علـى طريقـة تقـدير معلمات هذا النموذج فقد وضعت العديد من الطرائق لتقدير هذه المعلمات أهمها طريقـة المربعات الصغرى, كما تم تقدير المعلمات بأساليب ذكائيـة ومنهـا أسـلوب الـشبكات العصبية الاصطناعية التي أولاها الباحثون في السنوات الأخيرة اهتمامـاً بالغـاً بهـدف الوصول إلى أسلوب يحاكي دماغ الإنسان في التعرف على الأشياء, وذلك عـن طريـق استخدام المعالجة المتوازية للبيانات, وهذا يتضمن بناء نماذج رياضية مستندة الى طبيعـة الأشياء الموصوفة وخصائصها.

إن الشبكات العصبية الاصـطناعية (Artificial Neural Networks) بوصـفها احد مجالات الذكاء الاصطناعي تعمل على تمثيل عقل الإنسان عن طريـق شـبكة مـن المعطيات الرقمية (التي تمثل الخلية العصبية) متصلة بروابط موزونة (التي تمثل الروابط بين الخلايا) والتي تتم معالجتها بواسطة نموذج رياضي محدد. فالمعطيات لوحدها لا تقوم بأي تأثير، أما إذا اتحدت هذه المعطيات مع الأوزان فإنها تـؤدي إلـى تحديـد المهمـة المطلوبة من الشبكة العصبية. لقد نشط هذا الأسلوب في العديد من المجالات الإحـصائية ومنها تقدير معلمات نماذج الانحدار. من هنا كان الهدف من الدراسة هو تقديم أسـلوب جديد يعتمد على الشبكات العصبية الاصطناعية وهو أسلوب شبكات الانحـدار العـصبية المعممة. إذ تمت مقارنة الأسلوب المهجن مع أسلوبي الانحدار والشبكات العـصبية فـي تقدير النماذج عن طريق المفاضلة بينها باستخدام معيار متوسط مربعات الخطأ.

2- الشبكات العصبية الاصطناعية ونموذج الانحدار الخطي :

تعد الشبكات العصبية الاصطناعية إحدا مجالات الذكاء الاصطناعي إذ تمثل تقنيات حسابية مصممة لمحاكاة الطريقة الذي يؤدي فيها الدماغ البشري مهمة معينة عن طريـق شبكة من المعطيات الرقمية متصلة بروابط موزونة والتي تتم معالجتها بوساطة نمـوذج رياضي محدد، فالمعطيات لوحدها لا تقوم بأي تأثير، أما إذا اتحدت هذه المعطيـات مـع الأوزان فإنها تؤدي في تحديد المهمة المطلوبة من الشبكة العصبية. والشكل (1) يوضـح الشكل الرياضي للشبكة العصبية الاصطناعية (Samarasingha, 2007):

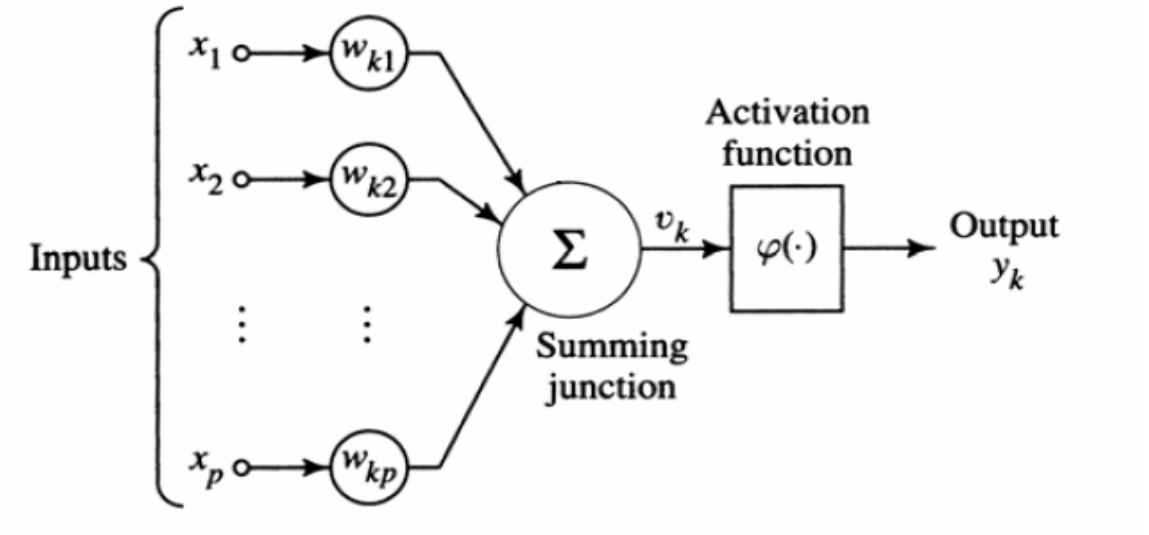

الشكل (1) : يمثل الشكل الرياضي للشبكة العصبية الاصطناعية.

تتكون الخلية العصبية الاصطناعية من جزأين أساسيين، الجزء الأول (Net) الذي يمثـل مقداراً جامعا لقيم المتغيرات الداخلة مضروبة بأوزانها، ويعبر عنها رياضـياً بالمعادلـة الآتية (Bishop, 2006):

$$Net = \sum_{i=1}^{n} w_i \, x_i \qquad \ldots\ldots(1)$$

أما الجزء الثاني فيمثل دالة مستمرة لا خطية تسمى دالة التنشيط (التفعيل) تتـولى نـشر القيمة الداخلة إليها وفق المقياس المحدد لها في القيمة الخارجة ويعبـر عنهـا رياضـياً بالمعادلة الآتية:

$$y = f(Net) \quad \ldots\ldots(2)$$

تحتوي الشبكات العصبية الاصطناعية في تركيبها وبنيتها الهندسية على عدد من الطبقات المترابطة فيما بينها وتتمثل هذه الطبقات من خلال طبقة الإدخال، الطبقة المخفية وطبقـة الإخراج. تتكون معالجة المعلومات في الشبكات العصبية الاصطناعية من دالة التنـشيط وطريقة التدريب وتحدد دالة التنشيط ردة الفعل لعنصر المعالجة بالنـسبة لقـيم المتغيـر الداخل، أما طريقة التدريب المستخدمة في الشبكة فتحدد طريقة تعديل الوزن الخاص بكل عنـصر للحـصول علـى النتيجـة المطلوبـة. وتعـد شـبكة الانتـشار العكـسي (Backpropagation) من الشبكات الواسعة الاستخدام وذلك لسهولتها وقابليتهـا علـى خزن المعلومات في الارتباطات التي تمثل أوزان الشبكة والتي من خلالها يتم ربط خليـة بأخرى، إذ تتكون هذه الشبكة من طبقة الإدخال والإخراج وطبقة مخفيـة واحـدة علـى الأقل، كما أن خوارزمية تدريب هذه الشبكة هدفها هو تقليل الخطأ تدريجيا مـن خـلال استخدامه في تغيير الأوزان وكما تعمل الخوارزمية على تحديث الأوزان علـى دفعـات خلال مراحل التكرار (Samarasingha, 2007).

يستند نموذج الانحدار الخطي المقدر الى افتراض وجـود علاقـة خطيـة بـين متغيـر الاستجابة y وعدد من المتغيرات التوضيحية $x_1, x_2, \ldots, x_k$ ويعبـر عنـه بالمعادلـة الرياضية الآتية (Bishop, 2006):

$$y = x' \beta + \varepsilon \quad \ldots\ldots(3)$$

إذ أن y متجه ذو بعد $(n \times 1)$ و x مصفوفة المتغيرات التفسيرية ذات بعـد $(n \times k)$ وان β هو متجه المعلمات ذو بعد $(k \times 1)$ و ε يمثل متجـه الأخطـاء العـشوائية ذو

بعد $(n \times 1)$. وغالبا ما تستخدم طريقة المربعات الصغرى للحـصول علـى مقـدرات نموذج الانحدار الخطي بالشكل الأتي:

$$\hat{\beta} = (x'x)^{-1}x'y \quad \ldots\ldots\ldots(4)$$

وبصورة عامة يمكن تمثيل مكونات الشبكة العصبية بدلالة المفهوم العام للانحدار بالشكل الأتي:

$$t = y(x,\beta) + \varepsilon \quad \ldots\ldots\ldots(5)$$

$$y(x,\beta) = \sum_{i=1}^{k} w_i x_i + b \quad \ldots\ldots\ldots(6)$$

إذ تمثل t متغير الاستجابة أو متغير الإخراج حسب مفهوم الشبكة العـصبية و $\mathbf{x}$ تمثـل المتغيرات التفسيرية أو مجموعة متغيرات الإدخال, و ε تمثل متغير ذا توزيـع طبيعـي بوسط مقداره صفر وتباين معلوم, أما b فتمثل التحيز (Bishop, 2006).

3- شبكة الانحدار العصبية المعممة
Generalized Regression Neural Networks

تعد شبكة الانحدار العصبية المعممة (GRNN) نوعاً من أنواع شـبكات التغذيـة الأمامية (Feedforward) والتي تم اقترحها من قبل العالم Specht عام 1991 لانجاز الانحدار العام سواء أكان خطياً أم غير خطي, إذ تستخدم لحل أنواع متعددة من المـسائل كالتنبؤ (Prediction) والسيطرة (Control) ومسائل التخطيط العامـة, وقـد اسـتندت خوارزمية هذه الشبكة الى نظرية الانحدار اللاخطي مـن جهـة والـشبكات العـصبية الاصطناعية من جهة أخرى, ويمكن اعتبارها تهجينـاً للـشبكة العـصبية الاصـطناعية باستخدام الانحدار الخطي, وتتضمن شبكة الانحدار العـصبية المعممـة والتـي تكتـب اختصارا (GRNN) في تركيبها دالـة (Radial Basis Function) وهـي مـن

الشبكات المثيرة للاهتمام, إذ تتميز بإمكانيـة التـدريب الـسريع والبـساطة والعموميـة (Specht,1991), وتتكون من طبقتين أساسيتين :

1- **الطبقة الأولى :** تسمى بطبقـة (Radial Basis) والتـي تكتـب اختـصارا (RBF), إذ يتم من خلالها حساب المسافة بين متجه الأوزان ومتجه الإدخال ومـن ثم يضرب الناتج بقيمة صغيرة تسمى بقيمة التحيز (Bias), كما أن دالة التحويل في هذه الطبقة من نوع (Gaussian) والتي يتم تمثيلها كالآتي :

$$f(x) = \exp(-x^2)$$

.....(7)

2- **الطبقة الثانية :** تسمى هذه الطبقة بالخطية, ويتم من خلالها حـساب الـضرب النقطي بين متجه الأوزان ومتجه الإدخال (الذي يمثل إخراج الطبقة السابقة) ومن ثم يقسم الناتج على مجموع قيم الإدخال, ولايتم فيها حساب قيمة التحيز (Bias), ويمثل متجه الأوزان فيها الإخراج المطلوب, كما أن دالة التحويل في هذه الطبقة هي خطية ويتم تمثيلها كالآتي :

$$f(x) = x \qquad \text{For all } x$$

.....(8)

4- تدريب شبكة الانحدار العصبية المعممة :

إن عدد الخلايا العصبية (العقد) في الطبقة المخفية يكون بقدر عدد وحدات متجـه الإدخال المستخدمة في عملية تدريب الشبكة كما أن إدخالات الطبقة المخفية تمثل معيـار المسافة (Norm) بين متجه الأوزان ومتجه بيانات الإدخال والتي يتم إدخالها علـى دوال تنشيط من النوع (RBF). أما الطبقة الخارجية فلها عدد من الخلايا العصبية بقدر عـدد وحدات أو عناصر متجه الإخراج, كما أن الخلايا العصبية في الطبقـة الثانيـة (طبقـة الإخراج) تستخدم دالة تنشيط خطية (Rutkowski,2004).

لاتتطلب شبكة (GRNN), تدريباً تكرارياً وذلك كون عملية تعديل الأوزان تجري بسرعة كبيرة إذ انه كلما نقصت المسافة بين متجه الإدخال ومتجه الأوزان في الطبقة الأولى من شبكة الانحدار العصبية المعممة فان قيمة ناتج الإخراج تزداد وهكذا, ولهـذا نلاحـظ أن قيمة الإخراج تكون أعلى مايكون عندما قيمة الإخراج ($\mathbf{out = 1}$) وذلك عندما يتساوى كل من متجه الإدخال ومتجه الأوزان, والشكل (2) يوضح معمارية هذه الشبكة :

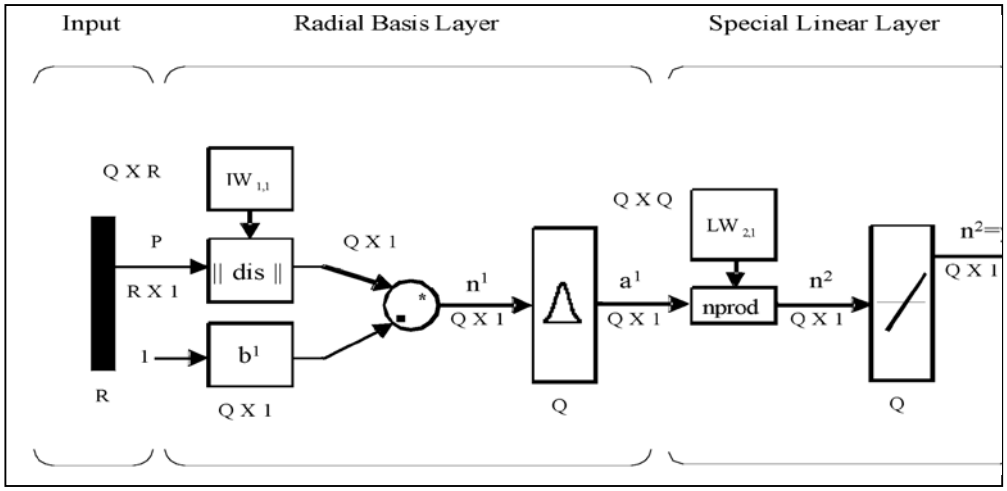

الشكل (2): يمثل معمارية شبكة الانحدار العصبية المعممة.

إذ إن:

R : تمثل عدد عناصر متجه الإدخال، **Q** تمثل عدد الخلايا في الطبقة، **w** يمثل متجه الأوزان، وان **b** يمثل التحيز.

nprod : يمثل الضرب النقطي.

5- المحاكاة :

إن الهدف من الدراسة باستخدام المحاكاة في هذا البحث هو التأكد من دقة التنبـؤ باستخدام شبكة الانحدار العصبية المعممة ومقارنة نتائجها بنتائج شبكة الانتشار العكـسي (BP) ونتائج نموذج الانحدار الخطي, إذ تم استخدام تجـربتين مختلفتـين وتـم تكـرار التجربة في كل حالة **10000**مرة ولأحجـام عينـات مختلفـة. **(10,25,50,100 and**

1000) وقد تم استخدام متوسط مربعات الخطأ معيارا للمقارنة وفق الـصيغة الرياضـية الآتية:

$$MSE = \frac{\sum_{r=1}^{10000} MSE_{(r)}}{10000}$$

.....(9)

إذ أن :

$$MSE_{(r)} = \frac{\sum_{i=1}^{n} (\hat{y}_i - y_i)^2}{n}$$

.....(10)

ففي التجربة الأولى تم توليد نموذج خطي بسيط فيه المتغير التفـسيري يتبـع التوزيـع المنتظم بالفترة **(0,1)** والمتغير ϵ يتبع التوزيع الطبيعـي القياسـي ومتجـه المعلمـات $\beta = (0,1)$. في حين اشتملت التجربة الثانية على توليد نموذج خطي متعـدد بمتغيـرين تفسيريين كلاهما يتبعان التوزيع المنتظم وبنفس فترة التجربة الأولى وكذلك المتغيـر ϵ ، أما متجه المعلمات فكان $\beta = (0,1,1)$. والجدولان (1) و (2) يوضحان نتائج تجربتـي المحاكاة.

الجدول (1): قيم معيار متوسط مربعات الخطأ لتجربة المحاكاة الأولى ولأحجام عينات مختلفة.

تجربة المحاكاة الأولى	n=10	n=25	n=50	n=100	n=1000
تحليل الانحدار (RG)	0.8932	0.9573	0.9823	0.9892	0.9987
الشبكات العصبية الاصطناعية (NN)	1.9217	1.4094	1.1673	1.0191	1.0000
شبكة الانحدار العصبية المعممة (GRNN)	0.0822	0.1994	0.3500	0.5440	0.9398

الجدول (2): قيم معيار متوسط مربعات الخطأ لتجربة المحاكاة الثانية ولأحجام عينات مختلفة.

تجربة المحاكاة الثانية	n=10	n=25	n=50	n=100	n=1000
تحليل الانحدار (RG)	0.8033	0.9200	0.9617	0.9817	0.9979
الشبكات العصبية الاصطناعية (NN)	1.5571	1.1243	1.0084	0.9939	0.9992
شبكة الانحدار العصبية المعممة (GRNN)	0.6248	0.8406	0.9217	0.9617	0.9958

6- حالات تطبيقية :

تمت دراسة حالتين تطبيقيتين لدراسات واقعية تم الاعتماد عليها في كثير من مصادر تحليل الانحدار لغرض دعم الجانب الخاص بالمحاكاة وبيان مدى الكفاءة بين الأساليب الثلاثة التي تضمنها البحث.

6-1 الحالة التطبيقية الأولى :

شملت هذه الحالة دراسة البيانات الخاصة بتصليح الحاسوب (Computer Repair) لدراسة العلاقة بين طول خدمة المكالمة وعدد الأجزاء الالكترونية في الحاسوب التي يجب أن يعاد تصليحها أو استبدالها (Chatterjee and Hadi, 2006) إذ بلغت عدد المشاهدات 14 إذ اعتبر طول المكالمة (بالدقائق) متغير استجابة في حين اعتبر عدد الأجزاء متغيراً توضيحياً. والجدول (3) يوضح النتائج التي تم الحصول عليها عند استخدام الأساليب الثلاثة الانفة المذكورة انفاً.

الجدول (3): قيم معيار متوسط مربعات الخطأ للحالة التطبيقية الأولى.

الحالة التطبيقية الأولى	***MSE***
تحليل الانحدار (RG)	29.071
شبكة الانتشار العكسي (BP)	931.3405
شبكة الانحدار العصبية المعممة (GRNN)	10.0534

6-2 الحالة التطبيقية الثانية :

تم في هذه الحالة استخدام البيانات الخاصة بدراسة تأثير طول السلك والارتفاع بوصفها متغيرين تفسيريين في قوة شد السلك بوصفه متغيراً معتمداً وبحجم 25 (Montgomery and Runger, 2003). الجدول (4) يوضح نتائج الحالة الثانية.

الجدول (4): قيم معيار متوسط مربعات الخطأ للحالة التطبيقية الثانية.

الحالة التطبيقية الثانية	***MSE***
تحليل الانحدار (RG)	5.5664
الشبكات العصبية الاصطناعية (NN)	5.0652
شبكة الانحدار العصبية المعممة (GRNN)	0.0029

7- الاستنتاجات :

1- من خلال نتائج تجارب المحاكاة الموضحة في الجدولين (1) و (2) ولأحجام مختلفة من العينات, وكذلك نتائج الحالتين التطبيقيتين الموضحتين في الجدولين (3) و (4) فإن أسلوب

شبكة الانحدار العصبية المعممة (GRNN) بالاعتماد على معيار متوسط مربعات الخطأ كان أكفأ مقارنة مع أسلوبي الشبكات العصبية الاصطناعية (NN) وتحليل الانحدار.

2- من وجهة نظر الباحثين فإن سبب كفاءة أسلوب شبكة الانحدار العصبية المعممة مقارنـة بأسلوب الشبكات العصبية الاصطناعية هو تميزها بالبساطة وإمكانية التـدريب الـسريع كونها لاتتطلب تدريباً تكرارياً للأوزان وذلك من خلال استخدام ميزة الانحدار الخطي في طبقة الإخراج.

3- إن أسلوب الشبكات العصبية الاصطناعية باستخدام شبكة (BP), قد لايكون دائما أكفأ من أسلوب تحليل الانحدار, وهذا ما أوضحته نتائج تجارب المحاكاة فضلا عن نتائج الحالتين التطبيقيتين , إذ ظهر أسلوب الشبكات العصبية الاصطناعية أكفأ في الحالة التطبيقية الثانية , بينما كان أسلوب الانحدار أكفأ في الحالة التطبيقية الأولى.

8- المصادر :

1- Bishop,C.,M., (2006), **"Pattern Recognition and Machine Learning''** , Springer Science + Business Media ,LLC, Singapore.

2- Chatterjee, S. and Hadi, A., S., (2006), **"Regression Analysis by Examples"**, 4th ed., John Wiley & Sons, Inc., New Jersey.

3- Montgomery, D., C. and Runger, G., C., (2003), **"Applied Statistics and Probability for Engineers"**, 3rd ed., John Wiley & Sons, Inc., New York.

4- Rutkowski, L. ,(2004), **"Generalized Regression Neural Networks in Time-Varying Environment''**, IEEE, Transactions on Neural Networks, Vol.15 , NO.3, pp. 576-596.

5- Samarasingha, S., (2007) , **"Neural Networks for Applied Sciences and Engineering",** Tayler & Francis Group, LLC. , NY.

6- Specht,D. ,F. , (1991), **"A General Regression Neural Network "** , IEEE, Transactions on Neural Networks, Vol.2 , pp: 586-576.