

استخدام الشبكات العصبية لترميم قواعد البيانات عبر تقدير المدخلات اعتماداً على قيم المخرجات بأقل نسبة خطأ ممكنة

*دفاطمة شلاف

الملخص

قمنا في هذا البحث بتقدير القيم المفقودة أو القيم الارتباطية لمتغير مستقل (دخل الشبكة العصبية) أو أكثر من متغيرات الدراسة وبالتالي ترميم قاعدة البيانات، من خلال تدريب شبكة عصبية أمامية التغذية وباستخدام خوارزمية Levenberg-Marquardt والتي تعد تطويراً لخوارزمية الانتشار العكسي التقليدية المستخدمة في تدريب الشبكات العصبية الأمامية، حيث قمنا بحذف بعض القيم من متغير مستقل أو أكثر ومن ثم التنبؤ بها من خلال الخوارزمية المقترنة في هذا البحث وذلك اعتماداً على القيمة الدنيا والعليا للمتغير المستقل المراد التنبؤ بقيمه المفقودة حيث تم تقسيم مجال المتغير إلى نقاط قطع تصل إلى (n) نقطة أو أكثر حسب الرغبة بدقة النتائج (يمكننا تقسيم المجال إلى 1000 وأكثر من نقاط القطع) ومن ثم تعتبر هذه القيم مداخل للشبكة العصبية بعد تدريبيها مع بقية المتغيرات المستقلة التي لا تحتوي قيماً مفقودة عند هذه المشاهدة هذه النقاط ويتم الحصول على خرج مقابل لكل نقطة قطع وبعد حساب القيمة الدنيا للفرق بين القيمة الحقيقية للهدف وخرج الشبكة تم اختيار نقطة القطع التي تعطي أقل قيمة لهذا الفرق وتكون هي تقديرًا ذو دقة عالية لقيمة المفقودة. وقد وصلت دقة التنبؤ إلى 0.99.

الكلمات المفتاحية: الشبكات العصبية، خوارزمية الانتشار العكسي، خوارزمية ليفينيرغ، القيم المفقودة، المتغير المستقل.

*مدرس- قسم الإحصاء الرياضي- كلية العلوم -جامعة حمص.

Using Neural Networks to Restore Databases by Estimating Inputs Based on Output Values with the Least Possible Error

Fatima Shallaf*

Abstract

In this research, we predict missing values or uncertainty values for one or more independent variables of the study and thus restore the database, by training a feed-forward neural network and using the Levenberg-Marquardt algorithm, which is a development of the traditional backpropagation algorithm used in training forward neural networks. By deleting some values from one or more independent variables and then predicting them through the proposed algorithm in this research, depending on the lower and upper values of the independent variable whose missing values are to be predicted, where the variable field was divided into cut-off points up to (n) points or more as desired accurately. The results (we can divide the field into 1000 and more than the cut-off points) and then these values are considered as inputs to the neural network after training it with the rest of the independent variables that do not contain missing values when viewing these points. A corresponding output is obtained for each cut-off point and after calculating the minimum value of the difference between The true value of the target and the output of the network. The cut-off point that gives the lowest value for this difference is chosen, and it is a highly accurate estimate of the missing value. The prediction accuracy reached 0.99

Keywords: Neural networks, backpropagation algorithm, Levenberg algorithm, missing values, independent variable.

*Teacher, Dept. of Mathematical Statistics, Faculty of Science, Homs University.

(1) مقدمة:

يبقى المتغير التابع هو المتغير الذي يهتم فيه الإحصائيون للتتبؤ بقيمة ومن هذا الاهتمام نشأت نماذج الانحدار سواء كانت بسيطة أو متعددة خطية أو غير خطية وجميعها معتمد على العلاقة التابعة (الارتباطية) بين المتغير التابع والمتغيرات المستقلة، أما التتبؤ بقيم المتغير المستقل بقيت حتى الآن مستقلة معتمدة فقط على قيم المتغير المستقل نفسه فبنيت نماذج انحدار ذاتي وغيرها من النماذج التي تجعل هذا المتغير مستقل يعتمد على نفسه فقط،

حتى قمنا بهذا البحث الذي يعتمد على تطوير استعمال الشبكة العصبية
للاستعمال من خلال الخوارزمية المقترحة على التنبؤ بقيم المتغيرات المستقلة المفقودة،
وذلك لأن سلامة البيانات وترميم القيم المفقودة التي تظهر في البيانات مهمة ضرورية
لسلامة النتائج والاستنتاجات في تحليل المعطيات.

(2) أهـمـيـة الـبـحـث:

اهتمت الأبحاث بنمذجة البيانات المدروسة من أجل استخدام النماذج للتنبؤ بالقيم المستقبلية أو ترميم قيم المتغير التابع وذلك باستخدام نماذج الانحدار التقليدية أو باستخدام الشبكات العصبية ولكن لم يتم استخدام أي من هذه النماذج للتنبؤ بقيم المتغير المستقل ليعطي دقة عالية في التنبؤ بقيمه، لذا اعتمد البحث على اقتراح خوارزمية جديدة تعتمد على تدريب شبكة العصبية (بناء النموذج التنبؤي)، ومن ثم تقدير القيم المفقودة وبالتالي جعل هذه الطريقة أحد الأدوات المساعدة في تقيير المعطيات المفقودة.

الهدف من البحث:

- التعرّف على أهم خوارزميات تدريب الشبكات العصيّونية لإيجاد العلاقة المعقّدة بين المدخل والمخرج والتي لا يمكن نمذجتها بأساليب الانحدار.
 - اقتراح أسلوب جديد لتقدير القيم المفقودة للمتغيرات المسنّقة (مدخل الشبكة العصيّونية).

استخدام الشبكات العصبية لترميم قواعد البيانات عبر تقدير المدخلات اعتماداً على قيم المخرجات باقل نسبة خطأ ممكنة

3- قياس دقة التقدير للقيم المفقودة بالأسلوب المقترن.

(3) الشبكات العصبية الاصطناعية [Artificial Neural Networks]

[2][3]

تُعد الشبكات العصبية الاصطناعية تمثيلاً لطريقة عمل الجهاز العصبي في الكائنات الحية. حيث تم اكتشاف قابليتها للتعلم والذكاء والقدرة على التمييز واتخاذ القرارات من قبل العلماء. تتألف هذه الشبكات من مجموعة من الوحدات المعالجة تُسمى بالعصبونات، حيث تمر الإشارات بين العصبونات من خلال خطوط الاتصال، ويتم تعين وزن معين (قيمة عددية) لكل خط اتصال. وتفاعل هذه الأوزان مع الإشارات الواردة إلى العصبون.

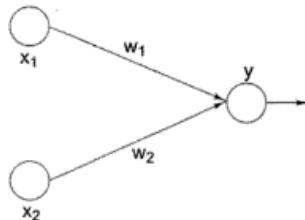
وتتضمن مكونات الشبكة العصبية الاصطناعية مجموعة من العصبونات التي تكون متصلة بعضها عبر روابط، ويتم تعين قيم وزن لكل رابط وهذه القيم تؤثر على كيفية استجابة العصبونات للإشارات الواردة. ويتم تطبيق تابع تفعيل على كل عصبون لتحديد الإشارة الناتجة عنه. تختلف توابع التفعيل والطرق المستخدمة في الشبكات العصبية الاصطناعية وفقاً لغرض التطبيق.

باستخدام هذه البنية، يمكن للشبكات العصبية الاصطناعية تعلم تمثيلات معقدة للبيانات واستخدامها لمهام مثل التصنيف والتنبؤ والتشخيص. تُعتبر هذه الشبكات مكوناً أساسياً في مجالات متعددة مثل التعلم العميق ومعالجة اللغة الطبيعية والرؤية الحاسوبية والذكاء الاصطناعي بشكل عام.

وبالتالي ستكون الشبكة العصبية الاصطناعية مؤلفة من الأقسام التالية[4]:

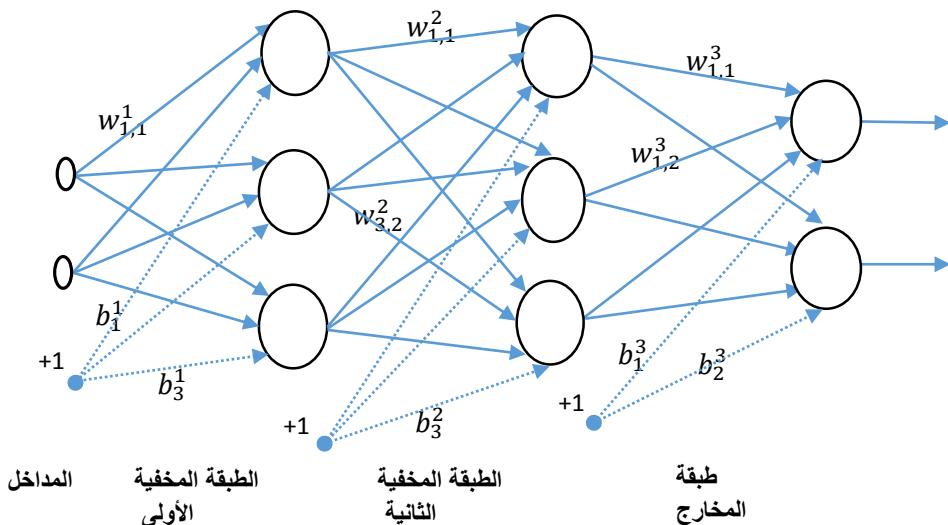
- 1- طبقة الدخل input layer: هي طبقة الخلايا التي تستقبل إشارات الدخل من الوسط الخارجي
- 2- طبقة الخرج output layer: هي طبقة الخلايا التي تعطي القرار النهائي إلى الوسط الخارجي.

- الطبقة المخفية hidden layer: هي طبقة (طبقات) الخلايا التي تقع بين طبقتي الدخل والخرج وتقوم بعملية المعالجة، علماً أنها تكون غير موجودة في الشبكة العصبية البسيطة التي تكون مؤلفة من طبقة فقط (المدخلات وطبقة الخرج) كما في الشكل التالي



الشكل (1) شبكة عصبية بسيطة وحيدة الطبقة.

أما في الشبكات العصبية متعددة الطبقات يكون هناك طبقة مخفية واحدة أو أكثر من طبقة مخفية كما في الشكل التالي:



الشكل (2) شبكة عصبية متعددة الطبقات.

ويتم تحديد عدد المدخل وعدد عصبونات طبقة الخرج من المعطيات التي يتم تحليلها لذلك إذا كان ضمن المعطيات أربعة متغيرات لاستخدامها كمدخلات،

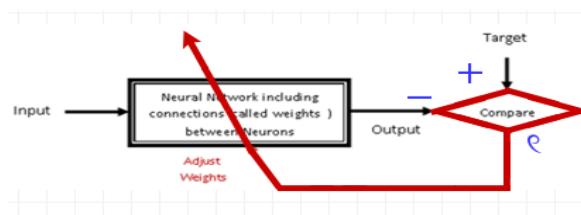
استخدام الشبكات العصبية لترميم قواعد البيانات عبر تقدير المدخلات اعتماداً على قيم المخرجات باقل نسبة خطأ ممكنة

ستبني الشبكة العصبية بأربعة مداخل، وبالمثل إذا كان هناك سبعة متغيرات يجب دراستها كخرج للشبكة العصبية تبني الشبكة العصبية بسبعة عصبونات في طبقة الخرج. أما عدد عصبونات الطبقة المخفية لم تحدد من قبل أي عالم [5] فكلها تبني بالتجريب، فلو كان عدد عصبونات الطبقة المخفية قليلاً فإن الشبكة العصبية لن تتعلم، وإن كان عدد عصبونات الطبقة المخفية كثيراً عندها بساطة تميل الشبكة للفحص، لذلك يتم تحديد عدد عصبونات الطبقة المخفية بين القلة التي يجعل الشبكة لا تتعلم وبين الكثرة التي يجعل الشبكة تحفظ معطيات الدخل. [5]

4) أنواع الشبكات العصبية حسب نوع التدريب:[1][2]

حيث تعتبر عملية التدريب من العمليات الهامة جداً بالنسبة للشبكات العصبية، لأنها عبارة عن عملية تستطيع الشبكة العصبية من خلالها أن تتكيف مع مدخلات محددة من أجل الحصول على استجابات مطلوبة ويمكن تصنيف أساليب التدريب المختلفة للشبكات العصبية إلى:

1-5- التدريب المشرف عليه (المراقب) [1][2]: Supervised Training
في التعليم المشرف عليه تعطى مجموعة من بيانات التدريب (data base) المكونة من أزواج من (دخل - خرج) أي أن هذا التدريب يحتاج إلى معلم أو مشرف يتمثل بشعار الهدف ويتم التنبؤ بالخرج لدخل جديد وبعد إدخال معطيات التدريب تعالج الشبكة المدخلات وتقارن النتائج مع النتائج المرغوبة (الخرج المرغوب) وتحسب الخطأ (الفرق بين الخرج الفعلي الذي تم الحصول عليه من المدخلات وفق خوارزمية التدريب والخرج المرغوب) وتعاد (تنشر - تباث) الأخطاء من خلال الشبكة مما يؤدي لتحديث الأوزان التي تحكم بالشبكة، تحدث هذه العملية عدة مرات طالما أن الأوزان تتعدل.



الشكل(3) طريقة التدريب بمعلم

2-5 التدريب غير المشرف عليه (غير المراقب) [5]: Unsupervised Training لا تحتاج الشبكات التي تستخدم هذا الأسلوب من التدريب إلى معلم أي إلى شعاع الهدف (المخرجات المرغوبة) فهي قادرة على التعلم والتصنيف للدخلات المقدمة لها بشكل ذاتي أي تقدم المدخلات للشبكة بدون المخرجات المرغوبة، فهي نوع من أنواع شبكات التنظيم الذاتي، حيث تبني الشبكة العصبية الاصطناعية أساليب التعليم على أساس قدرتها على اكتشاف الصفات المميزة لما يعرض عليها من أشكال وأنساق وقدرتها على تطوير تمثيل داخلي لهذه الأشكال وذلك دون معرفة مسبقة وبدون عرض أمثلة لما يجب عليها أن تنتجه وذلك على عكس المبدأ المتبعة في أسلوب التعليم بوساطة معلم، ويوجد عدة أنواع للشبكات ذات خوارزميات التعلم بدون مشرف.

6- الشبكات العصبية بتغذية أمامية [4]: feed forward networks تنتشر هنا المدخلات من وحدات الدخل إلى الطبقات المخفية فطبقة الخرج عن طريق وصلات مقترنة بأوزان كما يلي:

6-1- المدخلات inputs: تستقبل الإشارات الواردة من المحيط الخارجي وتمثل بالشعاع (x_n, x_1, x_2, \dots) حيث يتم نقلها إلى جسم الخلية بنسب مختلفة.
6-2- الأوزان weights: قيم عددية قابلة للزيادة والنقصان وفق معادلات رياضية محددة ويرمز لها بـ (w_1, w_2, \dots, w_n) ، حيث يتم اعطاؤها قيم ابتدائية في الخطوة الأولى للتدريب ثم يتم تعديل هذه القيم حتى الوصول إلى أصغر قيمة ممكنة للخطأ الذي يتمثل بالفرق بين الخرج الفعلي للشبكة العصبية والخرج المرغوب.

6-3-تابع التجميع summation function: يقوم بجمع المدخلات الموزونة وفق العلاقة weighted function

$$y_{in} = \sum_{i=1}^{i=n} w_i x_i = w_1 x_1 + w_2 x_2 + \dots + w_n x_n \mp b \quad (1)$$

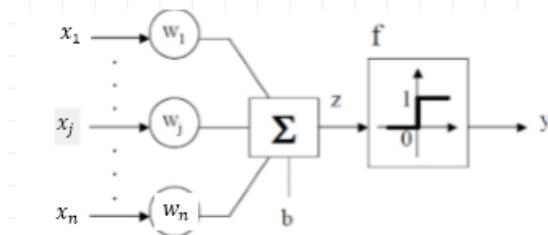
استخدام الشبكات العصبية لترميم قواعد البيانات عبر تقدير المدخلات اعتماداً على قيم المخرجات باقل نسبة خطأ ممكنة

6-4- تابع التفعيل (التنشيط) activation function: يقوم بتحويل حاصل جمع المدخلات الموزونة إلى إشارة رياضية محددة حسب طبيعة المشكلة لينتج الخرج النهائي للخلية العصبية كما يلي:

$$y_{in} = \sum_{i=1}^n w_i x_i + b \quad (2)$$

فيكون خرج الشبكة العصبية بتطبيق تابع التفعيل على y_{in} كما في العلاقة التالية:

$$\hat{y}_0 = output = f(y_{in}) = f\left(\sum_{i=1}^n w_i x_i\right) \quad (3)$$



الشكل (4) الشكل التفصيلي للشبكة العصبية perceptron Network.

7 - خوارزميات تدريب الشبكات العصبية:

لدينا عدة خوارزميات تدريب للشبكات العصبية ذكر منها: [4][5]

1- شبكة التكيف الخطي ADALINE NN : خوارزمية التدريب :

2- شبكة التكيف الخطي متعددة الطبقات MADALINE NN : هي عبارة عن

تركيب لشبكة التكيف الخطي الـ Adaline . ولهذه الشبكة خوارزميتي تدريب

MRI,MRII

3- خوارزمية الانتشار العكسي Back Propagation Algorithm

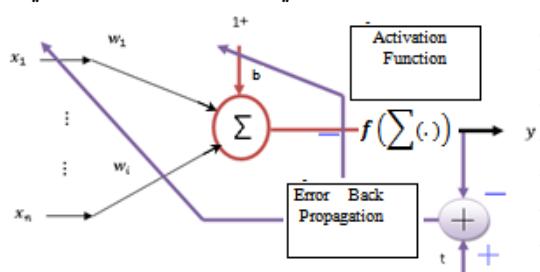
8 - خوارزمية الانتشار العكسي Back Propagation Algorithm [5][6]

تم اقتراح هذه الخوارزمية من قبل Paul Werbos في السبعينات، ولكن لم تستعمل إلا لعام 1986م من قبل Rumelhart و McClelland وهي من أهم خوارزميات تدريب شبكة عصبية تعتمد على الانتشار العكسي للخطأ من طبقة

الخرج باتجاه الطبقات السابقة (المخفية إلى الدخل)، تُستخدم لتعليم الشبكات العصبية ذات التعلم بإشراف، والجدير بالذكر أن تابع التفعيل المستخدم في هذه الخوارزمية هو تابع Sigmoid، كما تعتبر خوارزمية الانتشار العكسي من الخوارزميات السريعة لكنها تأخذ وقت في إيجاد مجموعة الحلول المثلث للأوزان، ولا يمكن استخدامها إلا بوجود طبقة أو أكثر من الطبقات المخفية.

تطوير فكرة الانتشار الخلفي لتدريب الشبكات العصبية متعددة الطبقات لعبت الدور الأساس في إبراز الشبكات العصبية الصناعية كأداة لحل الكثير من المشاكل على نطاق واسع.

وتهدف عملية تدريب هذه الشبكات الوصول إلى حالة من التوازن بين قابلية الشبكة على الاستجابة لعينات الدخل التي تستخدم في عملية التدريب وقدرتها على إعطاء استجابة جيدة لدخل مشابه لكن غير مطابق لذلك الدخل المستخدم في التدريب. يتضمن تدريب الشبكة بطريقة الانتشار الخلفي ثلاثة مراحل: مرحلة الانتشار الامامي والانتشار الخلفي ثم مرحلة تعديل الأوزان. وبعد مرحلة التدريب تبدأ مرحلة اختبار الشبكة والتي تتضمن مرحلة واحدة فقط هي طور الانتشار الامامي.



الشكل (5): تدريب الشبكات الامامية متعددة الطبقات

9- تطوير خوارزمية الانتشار العكسي: [4][6][7]

إن خوارزمية الانتشار العكسي العديد من التطويرات والتطور الالهم هو خوارزمية Levenberg-Marquadt، والتي تقلل من مجموع مربعات الخطأ $t_k - y_k$ (الفرق بين الخرج المطلوب و الخرج الفعلي)[7] وهي تحقق نسبة تقارب أفضل وتنطلب ذاكرة أقل وأسرع من غيرها من خوارزميات تدريب الشبكات العصبية الأخرى مثل خوارزمية

الانتشار العكسي (Error Back propagation Algorithm) للخطأ حيث أن هذه الخوارزمية تكون غالباً بطيئة في المشاكل العملية حيث أن خوارزمية Levenberg-Marquardt يمكن أن تكون أسرع منها من 10 حتى 100 مرة وهي تعتبر تطوير لخوارزمية الانتشار العكسي للخطأ [4][6]

10- خوارزمية Levenberg- Marquardt [7]

وهي من طرائق ايجاد الحلول المثلث لأوزان الشبكة العصبية من خلال ايجاد مجموع المربعات الصغرى المعرفة بالشكل:

$$E(W_j) = \frac{1}{2} \sum_i^N \sum_{k=1}^K (t_{ik} - y_{ik})^2 \quad (6)$$

علمًا أن K : عدد عصبونات طبقة الخرج، N : عدد أنماط التدريب (iteration).

j : تعبير عن كل مسح لكامل البيانات (epoch) وبالتالي يتميز للخطأ بالشكل التالي:

$$e_i(W_j) = \sum_{k=1}^K (t_{ik} - y_{ik}) \quad (7)$$

وبالتالي يكتبتابع الكلفة بالشكل التالي:

$$E(W_j) = \frac{1}{2} \sum_i^N e_i^2 \quad (8)$$

وبحسب طريقة نيوتن تكون الحلول المتتالية معرفة وفق العلاقة التالية:

$$W_{j+1} = W_j - H_j^{-1} g_j \quad (9)$$

حيث أن: $H_j = \nabla^2 E(W)|_{W=W_j}$ وعندما نفترض أن $E(W_j)$ هوتابع مجموع المربعات:

$$E(W_j) = \frac{1}{2} \sum_i^N e_i^2 = e' e \quad (10)$$

عندما يكون العنصر ذو الترتيب j للمشتقة معرف كما يلي:

$$[\nabla E(w)]_j = \frac{\partial E(W_j)}{\partial w_j} = 2 \sum_{i=1}^N e_i \frac{\partial e_i(X)}{\partial w_j} \quad (11)$$

وبالتالي يكون شكل مصفوفة المشتق كما يلي:

$$\nabla E(w) = 2J^T(W)e(W) \quad (12)$$

حيث أن:

$$J(W) = \begin{bmatrix} \frac{\partial e_1(W)}{\partial W_1} & \frac{\partial e_1(W)}{\partial W_2} & \dots & \frac{\partial e_1(W)}{\partial W_n} \\ \frac{\partial e_2(W)}{\partial W_1} & \frac{\partial e_2(W)}{\partial W_2} & \dots & \frac{\partial e_2(W)}{\partial W_n} \\ \vdots & \vdots & & \vdots \\ \frac{\partial e_N(W)}{\partial W_1} & \frac{\partial e_N(W)}{\partial W_2} & \dots & \frac{\partial e_N(W)}{\partial W_n} \end{bmatrix} \quad (13)$$

n : عدد الأوزان ضمن الشبكة العصبية.

حيث تدعى $J(W)$ بمصفوفة جاكobi.

ويتم كتابة مصفوفة هيسيان بطريقة تقريبية وفق العلاقة التالية:

$$\nabla^2 E(W) \cong 2J^T(W)J(W) \quad (14)$$

وبالتالي حسب طريقة Gauss_Newton يمكن كتابة ما يلي:

$$W_{j+1} = W_j - [2J^T(W_j)J(W_j)]^{-1} 2J^T(W_j)e(W_j) \quad (15)$$

$$= W_j - [J^T(W_j)J(W_j)]^{-1} J^T(W_j)e(W_j) \quad (16)$$

ونلاحظ أن طريقة نيوتن القياسيّة ليست بحاجة إلى حساب المشتق الثاني. وأحد مشاكل Gauss_Newton أن مصفوفة Hessian قد لا تملك مقلوب

لذلك نستخدم مصفوفة تقريبية لـ Hessian معرفة بالشكل التالي:

$$G = H + \mu I \quad (16)$$

μ : برامتر ثابت يضاف في حال كانت H تملك محدداً يساوي الصفر وهو رقم صغير جداً

لا يؤثر على قيمة العناصر الموجودة في المصفوفة H

وبالتالي تعطى الأوزان لهذه الخوارزمية كما يلي:

$$W_{j+1} = W_j - [J^T(W_j)J(W_j) + \mu I]^{-1} J^T(W_j)e(W_j) \quad (17)$$

$$\Delta W_k = -[J^T(W_j)J(W_j) + \mu I]^{-1} J^T(W_j)e(W_j) \quad (18)$$

حيث I هي المصفوفة الواحدية لها نفس درجة المصفوفة J, H هي مصفوفة Jacobian لأخطاء الخرج m المتعلقة بالأوزان n للشبكة العصبية.

11- الخوارزمية المقترحة من أجل تقدير القيم المفقودة والشاذة:

إذا كان لدينا X_{ij} متحوّلات مستقلة K متحوال مستقى يتألف كلاً منها من n قيمة

$$\begin{aligned} i &= 1, 2, \dots, n \\ j &= 1, 2, \dots, k \end{aligned}$$

وكان y_i متتحول تابع:

فإن الخوارزمية المقترحة توصف بالخطوات التالية:

1- حذف جميع الأسطر من البيانات التي توجد فيها قيمة مفقودة في أحد المتغيرات المستقلة.

2- بناء شبكة عصبية متوافقة مع البيانات المتبقية بعد عملية الحذف بجعل المدخل هي X_{ij} والخرج هو y_i .

3- تدرب الشبكة العصبية والحصول على شبكة مدربة واستخلاص قيم الأوزان.

4- ترميم قاعدة المعطيات قيمة ثلو أخرى فإذا فرضنا أن المتغير رقم r ونريد التنبؤ بالقيمة رقم i تكون المعالجة كما يلي:

$$n_1 = \min(X_{ir})$$

$$n_2 = \max(X_{ir})$$

تقسيم المجال $[n_2 - n_1]$ إلى عدد من القيم m بخطوة ثابتة مقدارها α وكلما كانت m كبيرة كانت العملية أدق وأفضل وأكثر شفافية.

نثبت باقي قيم المتغيرات الأخرى على وضعها في سطر المقابل للقيمة التي يتم التنبؤ بها في المتغير r ونحصل على مصفوفة جديدة نتيجة التقسيم كما يلي:

$$\begin{bmatrix} X_{i1} & \dots & n_1 & X_{ik} \\ X_{i1} & \dots & n_1 + \alpha & X_{ik} \\ X_{i1} & \dots & n_1 + 2\alpha & X_{ik} \\ \vdots & \vdots & \vdots & \vdots \\ X_{i1} & \dots & n_2 & X_{ik} \end{bmatrix}$$

نعرض المصفوفة في الشبكة العصبية المدرية:

$$\text{حسب: } Z_i = \hat{y}_i - y_i, i = 1, 2, \dots, m$$

التقدير الأمثل لـ X_{ir} هي لقيمة التي تقابل $\min(Z_i)$

التطبيق العملي:

تناولت الدراسة بيانات الطقس في خمس محطات في مدينة حلب (محطة الشيخ سعيد جنوب حلب_ محطة طريق المسلمين شمال حلب_ محطة مركز المدينة وسط حلب _ محطة حلب الجديدة غرب حلب _ محطة المطار المدني شرق حلب) ابتداءً من شهر كانون الأول من عام 2009 حتى شهر أيار من عام 2011 حيث اعتمدنا الحرارة الداخلية متغيراً تابعاً واعتمدنا أربع متغيرات مستقلة تؤثر على الحرارة الداخلية، وهي درجة الحرارة وسرعة الرياح والرطوبة الجوية

يمكن تعريف متغيرات الدراسة بالجدول التالي:

الجدول (1.3) متغيرات الدراسة

	الرمز	المتغير
الحرارة الداخلية	y	التابع
درجة الحرارة	X_1	المستقل
سرعة الرياح	X_2	المستقل
اتجاه الرياح	X_3	المستقل
الرطوبة الجوية	X_4	المستقل

استخدام الشبكات العصبية لترميم قواعد البيانات عبر تقدير المدخلات اعتماداً على قيم المخرجات باقل نسبة خطأ ممكنة

بحذف بعض القيم الموجودة في المتغير المستقل الاول وتطبيق الخوارزمية المقترنة تم الحصول على النتائج التالية:

X1(116)	X1(100)	X1(69)	رقم القيمة
17.167	11.377	23.962	القيمة الحقيقية
17.20229	11.25668	24.10501	القيمة المقدرة
0.997177	0.989424	0.994067	دقة التقدير

النتائج:

تم ترميم قاعدة البيانات من خلال تقدير القيم المفقودة وذلك بتدريب الشبكة العصبية وتطبيق الخوارزمية المقترنة.

حصلنا على دقة عالية في تقدير القيم المفقودة تصل إلى احتمال الحدث الأكيد.

النوصيات:

- 1- الاعتماد على الشبكات العصبية في معالجة القيم المفقودة والمشاكل الإحصائية الأخرى.
- 2- اعتماد طريقة الشبكات العصبية في بناء النماذج الرياضية واستخدامها لأغراض التنبؤ.

المراجع:

- [1]- Michael Negnevitsky, 2005- **Artificial Intelligence A Guide to Intelligent Systems- 2^{ed} Edition.** Addison-Wesley p435 .
- [2] Zurada M. Jacek (1995) , "Introduction to Artificial Neural Systems" , PWS.
- [3]-Ben Coppin,2004-**Artificial Intelligence Illuminated-** Jones And Bartlett Publishers
- [4] Sivanandam S N, Sumathi S, Deepa S N.,2006-**introduction to Neural Networks Using Matlab 6.0**-Tata Mcgraw_Hill Publishing Company Limited New Delhi.p549.
- [5] معالجة المعطيات المفقودة والشاذة من خلال تطوير 2019 شلال فاطمة، خوارزمية شبكة ذكاء صنعي متقدمة _ جامعة حلب، سوريا، رسالة دكتوراه. Department of Information Technology Computer Systems
- [6] B. Schiele and A. Waibel. " **Gaze tracking based on face-color**". Presented in International Workshop on Face and Gesture Recognition, Zurich, July 2001
- [7]- Martin T. Hagan. Hagan, Howard B. Demuth, Mark Hudson Beale, Orlando De Jesús.,1996-**Neural Network Design 2^{ed} Edition.** Martin T. Hagan.