An Analytical Mathematical Study of Artificial Neural Network Algorithms in the Suitability of a Model for Medical Diagnosis

Omar Saber Qasim *omar.saber@uomosul.edu.iq*
Israa Rustum Mohammed *israaru.alkhayyat@gmail.com*
College of Computer Science and Mathematics
University of Mosul, Mosul, Iraq

Received on: 10/10/2012 **Accepted on: 30/01/2013**

ABSTRACT

In this research discuss the concept of appropriate form, by examining mathematical behavior for three models represent neural networks are (GRNN, BPNN, PNN), were applied two types of medical data are (osteoporosis and weaknesses auditory) and different in the way of classification and spaces Input and output, and show through the application of these data and suitability models with neural networks in terms of the Domain and Range the network (PNN) is the best in the diagnosis of audio data through average MSE, and network (GRNN) is better diagnose bone crisp data (which are more complex) and the network (BPNN) is the most generalization, especially when test data are large compared with the training data.

Keywords: Classification; Regression; Perceptron NN; Backpropagation NN.

دراسة رياضية تحليلية لخوارزميات الشبكات العصبية الاصطناعية في ملاءمة نموذج للتشخيص الطبي

عمر صابر قاسم **إسراء رستم محمد**
كلية علوم الحاسوب والرياضيات
جامعة الموصل، الموصل، العراق

تاريخ استلام البحث: 2012/10/10 **تاريخ قبول البحث: 2013/01/30**

الملخص

تم في هذا البحث مناقشة مفهوم ملاءمة النموذج، وذلك بدراسة السلوك الرياضي لثلاثة نماذج تمثل شبكات عصبية هي (GRNN, BPNN, PNN)، كما تم تطبيق نوعين من البيانات الطبية هما (وهن العظام والضعف السمعي) ومختلفين في طريقة التصنيف وفضاءات الإدخال (Input) والإخراج (Output), وتبين من خلال تطبيق هذه البيانات وملاءمتها مع نماذج الشبكات العصبية الاصطناعية من حيث المنطلق (Domain) والمدى (Range) إن شبكة (PNN) هي الأفضل في تشخيص أنماط البيانات السمعية من خلال معدل (MSE)، وان شبكة (GRNN) هي الأفضل في تشخيص أنماط بيانات وهن العظام (التي تكون أكثر تعقيدا) وان شبكة (BPNN) هي الأكثر عمومية (Generalization) خصوصاً عندما تكون أنماط بيانات الاختبار كبيرة مقارنة مع أنماط بيانات التدريب.

الكلمات المفتاحية: التصنيف، الانحدار، شبكة الادراك، شبكة التراجع الخلفي للخطأ.

(1) مقدمة Introduction

تعد الشبكات العصبية الاصطناعية من نماذج تقنيات الأنظمة الذكائية الواسعة التطبيق في مختلف المجالات العلمية الحديثة والتي تتطلب معرفة نوع النموذج الذي يتم من خلاله تحويل بيانات الإدخال (Input) إلى الإخراج المطلوب (Target) والتي تعجز عن حلها الطرائق الرياضية والإحصائية التقليدية، إلا أن العديد من التطبيقات التي تم دراستها باستخدام الشبكات لم تأخذ بنظر الاعتبار النموذج المناسب لها والذي يتوافق مع بيانات الإدخال وطبيعة الإخراجات المطلوبة، وبذلك يؤدي هذا الاضطراب في اختيار النموذج إلى مردود سلبي قد يتمثل في إجراء عمليات حسابية غير ضرورية أو قد يؤدي إلى زيادة معدل مربع الخطأ (MSE).

لقد تم تقديم دراسة رياضية تحليلية عن مجموعة من الشبكات العصبية الاصطناعية هي (Perceptron Back Propagation (BPNN), (PNN) و(Generalized Regression (GRNN))، والتي تكون خوارزمياتها مختلفة في آلية المعالجة وطريقة تقبلها وتصنيفها للبيانات بالاعتماد على فضاء المدى (Range) والمجال (Domain)، إذ إن (PNN) مجالها ينتمي إلى فضاء الأعداد الحقيقية (R) ومداها يكون ثنائياً (Binary) وبذلك تصلح لبيانات قياس درجة السمع، في حين أن كل من (GRNN) و(BPNN) تتقبل في إدخالها وإخراجها فضاء الأعداد الحقيقية (R) أي أنها تصلح للبيانات متعددة الأصناف (Multi Classes) مثل أنماط بيانات وهن العظام، إلا أن (GRNN) تعتمد طريقة الانحدار(Regression) في معالجة أنماط البيانات ولا تعتمد طرق تكرارية في تعديل الأوزان، بينما (BPNN) تعتمد آلية تعديل الأوزان بالاتجاه العكسي وهذه تعطيها إمكانية اكبر في أن تكون ذات صفة عمومية (Generalization).

(2) وصف البيانات Data Description

تضمن البحث نوعين مستقلين من أنواع البيانات الطبية هي (بيانات وهن العظام وبيانات لتحديد ضعف السمع) إذ تتضمن أنماط البيانات السمعية قراءات لمستويات السمع لدى الإنسان ويتم من خلالها تحديد هل أن الشخص مصاب أم لا، أي أن التصنيف فيها يكون ثنائي (0 أو 1) وبيانات الإدخال بسيطة تنتمي إلى فضاء الإعداد الصحيحة (Integer Space) وهذه البيانات عبارة عن أنماط عينات مختلفة من المرض عددها (100) تمثل أشخاصاً مصابين بمرض ضعف السمع وآخرين طبيعيين وكل نمط من أنماط البيانات تتكون من خمسة قراءات تمثل أعداداً صحيحة فقط يتم من خلالها تحديد هل الشخص طبيعي أم مصاب بضعف السمع.

تم أخذ أنماط من بيانات جهاز P.T.A حيث تم التركيز على فحص توصيل السمعي الهوائي الذي يعد الفحص الأعم في قياس درجة ضعف السمع، حيث تم أخذ الفحوصات بالتعاون مع مركز الصفا التقني ومستشفى الموصل العام ومستشفى الجمهوري التعليمي. فمثلاً تمثل القيم (10, 0, 0, 0, 5) قراءات لحالة شخص سليم والقراءات (20, 20, 65, 55, 50) تمثل حالة المريض.

أما بيانات وهن العظام فتتكون من أنماط عينات مختلفة من مرض وهن العظام تنتمي إلى فضاء الإعداد الحقيقية (Real Space) والذي يكون أوسع واعقد من فضاء الإعداد الصحيحة (Integer Space). تتكون الحالات في أنماط بيانات وهن العظام خلال مراحل مختلفة من الإصابة، إذ تمثل حالة (Osteopenia) المرحلة الأولى من الإصابة، كما تمثل (Osteoporosis) المرحلة الثانية والمتأخرة من الإصابة بالمرض، في حين تكون الحالة الثالثة هي الحالة السليمة (Normal) [1]، الموضحة بالشكل (1)، كما تمثل أنماط البيانات التي تم

استخدامها في التعرف على مرض وهن العظام عبارة عن قيم عددية ووصفية تمثل قاعدة أساسية لمعلومات ضمن قاعدة بيانات (Data Base) لأشخاص تم إجراء عملية الفحص عليهم داخل العراق وتحديداً في محافظة نينوى مستشفى ابن سينا.

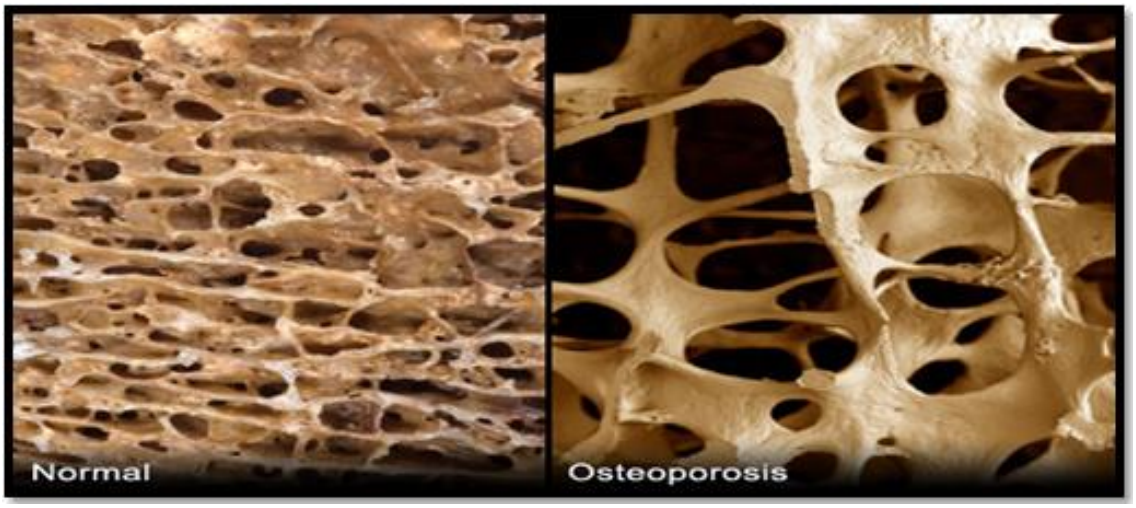

الشكل (1). مقطع يوضح المقارنة بين النسيج الطبيعي (Normal) والنسيج المصاب بمرض الوهن من نوع (Osteoporosis).

تتكون مصفوفة البيانات التطبيقية لمرض وهن العظام من (344) حالة منها (113) نمطاً تشخيصها من نوع (Osteoporosis)، في حين يوجد (131) نمطاً من نوع (Osteopenia)، أما بقية الأنماط والتي يبلغ عددها (100) نمطاً، يمثل تشخيصها الحالة الطبيعية (Normal) غير مصابة، أما عدد الأنماط القياسية المقروءة في كل نمط فيبلغ عددها (17) قيمة يمكن من خلالها التعرف على نوعية الحالة، أي أن أبعاد مصفوفة الإدخال هي ($17 * 344$) والتي تحوي على (5848) عنصراً من مستويات الأنماط المستخدمة في تحديد مرض وهن العظام. ومن اهم هذه القراءات هي (T-score)، وفي الحالة المرضية من نوع (Osteoporsis) تكون فيها (T-score) أقل من(2.5-) وفي الحالة الطبيعية(Normal) تكون أعلى من (1.0-) ومابينهما تمثل الحالة المرضية (Osteopenia) وهذا هام جدا من اجل الإنذار والتشخيص المبكر لمرض وهن العظام.

إن التشخيص المتقن والتعرف الدقيق على الأنماط يعد من أهم المسائل التي تحتاج إلى اختيار دقيق لتقنيات التشخيص، وقد تم في هذا البحث دراسة سلوك مجموعة من الشبكات العصبية الاصطناعية من ناحية ملاءمتها مع البيانات المستخدمة، كما تم تقديم آلية يتم من خلالها تحديد نوع الشبكة المستخدمة وبتوافق مع أنماط البيانات التطبيقية.

(3) الشبكات العصبية الطبيعية والشبكات العصبية الاصطناعية
Natural Neural Networks and Artificial Neural Networks

تعد الشبكات العصبية الاصطناعية تقنية رياضية برمجية مصممة لمحاكاة طريقة التفكير ومعالجة الأعصاب للمعلومات التي يودي بها عقل الإنسان مهمة معينة من خلال نظام معالجة موزع على التوازي، تتكون الشبكات العصبية الاصطناعية من وحدات معالجة بسيطة تسمى الخلية أو العقدة (Neuron or Node) العصبية الاصطناعية وكل اتصال بين هذه الخلايا محددة بقيم تسمى الأوزان (Weights)، إذ تقوم بتخزين المعلومات لتجعلها متاحة للمستخدم وذلك من خلال ضبط الأوزان (Weights) [4][5].

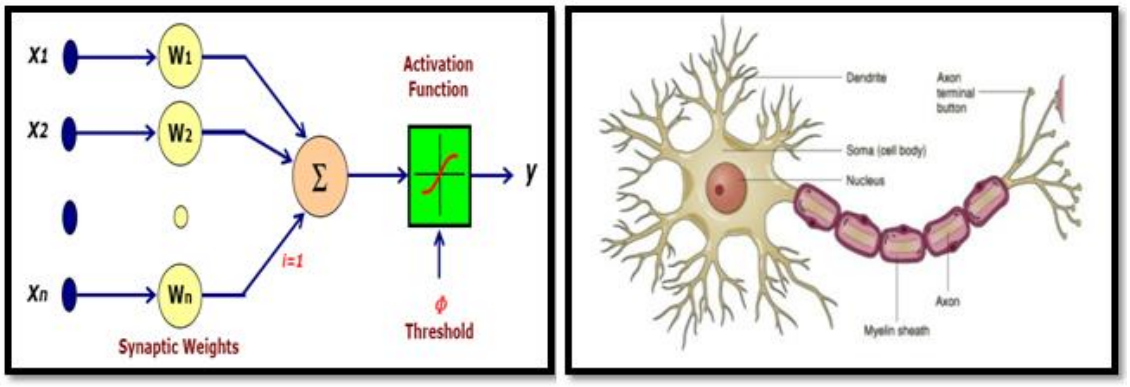

الشكل (2). يمثل مقارنة بين الخلية العصبية الطبيعية والخلية العصبية الاصطناعية.

(4) معمارية الشبكات العصبية الاصطناعية Architecture of ANNs

تتكون معمارية الشبكات العصبية الاصطناعية (ANNs) من الأجزاء الآتية :

1- **طبقة المدخلات (Input Layer):** تقوم باستلام إشارات الإدخال من خارج الشبكة وتقابل التفرعات التشجرية (Dendrites) في الخلية الطبيعية لدى الإنسان.

2- **الأوزان (Weights):** تمثل الاتصالات بين الطبقات في الشبكات العصبية الاصطناعية والتي تقابل (Synapse) بالشبكات العصبية الطبيعية.

3- **طبقة المخرجات (Output Layer):** وهي الطبقة الأخيرة التي تعطي الإخراج الحقيقي بعد سلسلة من المعالجات التي تتم خلال الطبقات السابقة.

4- **حد العتبة (Threshold):** هو الحد الذي يحدد مدى ونوع الإخراج ليتسنى مقارنته مع الإخراج المطلوب (Target Output).

5- **دالة التنشيط (Activation Function)** : هناك عدة أنواع من هذه الدوال منها:

- دالة الخطوة (Step Function) : هي الدالة التي يقع إخراجها بين [0,1].
- دالة الإشارة (Sign Function): حيث يكون فيها صورة الإخراج بين [-1,1]، وتسمى أيضاً (Hard Limit Function) وتستخدم في التصنيف (Classification) والتعرف على الأنماط (Pattern Recognition).

- الدالة الخطية (Linear Function): هي الدالة تكون فيها صورة الإخراج مشابهه للإدخال وتعطي تصنيفات متعددة وغير محدودة.
- الدالة السيجماوية (Sigmoid Function): وهي دالة غير خطية يقع مداها بين [0,1] وتكون مستمرة وقابلة للاشتقاق, والشكل (3) يوضح أشهر دوال التنشيط.

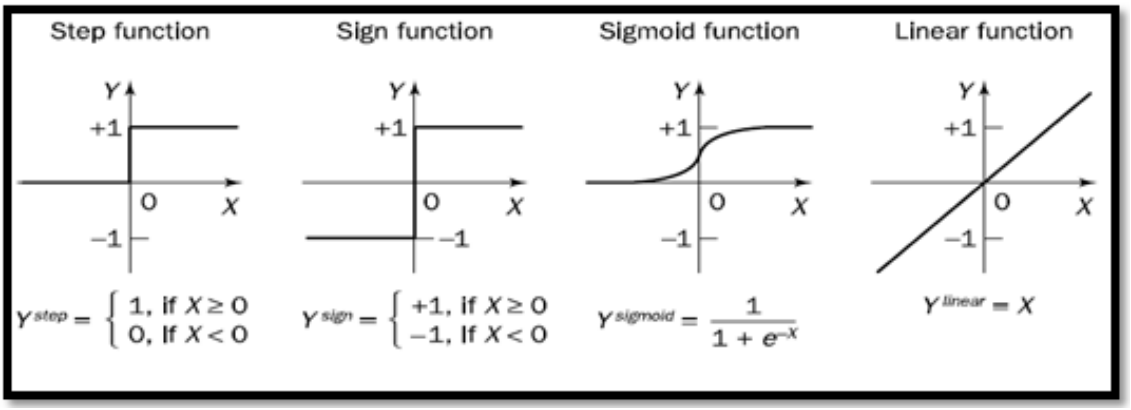

الشكل (3). دوال التنشيط المستخدمة في الشبكات العصبية الاصطناعية.

قد تحوي الشبكات العصبية الاصطناعية على طبقة مخفية (Hidden Layer) تضاف هذه الطبقة حسب تعقيد المسألة ونوعها [8].

(5) أنواع الشبكات العصبية الاصطناعية Types of Artificial Neural Networks

هناك العديد من الشبكات العصبية الاصطناعية المستخدمة في معالجة أنماط البيانات وكل نوع من هذه الأنواع له خصوصية في المعمارية وآلية معالجة المعلومات من خلال عدد ونوع العقد في كل طبقة بالإضافة إلى نوعية دوال التنشيط وآلية تعديل الأوزان ومن هذه الشبكات :

1) شبكة الإدراك العصبية (Perceptron).
2) الشبكة العصبية ذات التراجع الخلفي للخطأ (Back Propagation).
3) شبكة الانحدار العصبية المعممة (Generalized Regression).

(5-1) شبكة الإدراك العصبية (PNN)

تعد شبكة الإدراك من أوائل الشبكات التي تم دراستها في منتصف 1950 وهي شبكة وحيدة الطبقة وذات تغذية أمامية وهي من الشبكات التي تتعلم بإشراف. كما إن خوارزمية التعليم لها أكتشفها العالم (Frank Rosenblatt) سنة 1958. وفي سنة 1969 برهن (Minsky and Papert) أن الشبكة تستطيع تعليم الدوال القابلة للفصل الخطي فقط مثل الدوال المنطقية (OR, AND) التي تحوي على نوعين من الإخراج فقط [9].

(5-1-1) استخدام شبكة الإدراك في التصنيف الخطي [8]:

تعريف: يقال للمجموعتين $M_1 \subset R^n$ و $M_2 \subset R^n$ أنها قابلة للفصل الخطي إذا كانت أعداد حقيقية (Real Number) $a_1, a_2, a_3, \dots\dots\dots, a_n$ وعدد حقيقي يمثل حد العتبة (Threshold) θ بحيث:

$$\begin{cases} \sum_{i=1}^{n} a_i x_i > \theta & \forall x \in M_1 \\ \sum_{i=1}^{n} a_i x_i \leq \theta & \forall x \in M_2 \end{cases} \quad \dots(1)$$

تعريف: لتكن W متجه من الأوزان $W = (W_1, W_2, W_3, \dots\dots\dots, W_n) \in \mathrm{R}^n$ و$\mathrm{X} \in \mathrm{R}^n$ متجه الإدخال فأن تمثيل (Perceptron).

$$f: R^n \to \{0,1\}$$

التي تطابق القاعدة الآتية:

$$P(x) = \begin{cases} 1 & if \ \sum_{i=1}^{n} x_i w_i > 0 \\ 0 & otherwise \end{cases} \quad \dots(2)$$

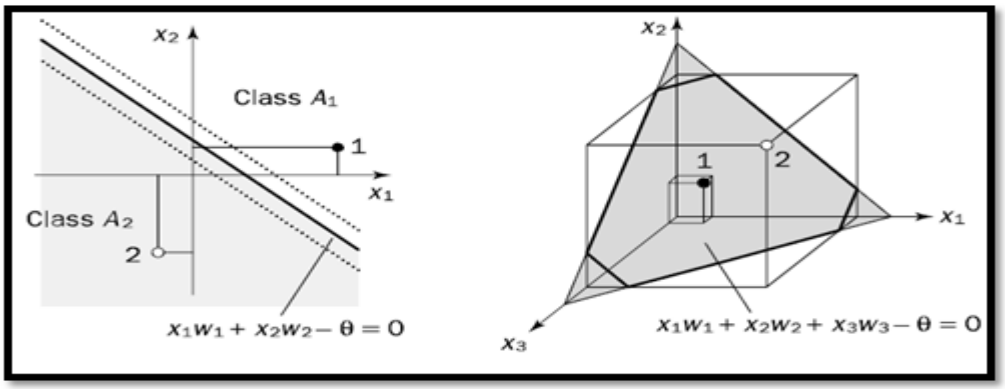

الشكل (4). يوضح آلية فصل البيانات في البعدين الثنائي والثلاثي.

(2-1-5) خوارزمية تعليم شبكة الإدراك (PNN)

الخطوة الأولى: تهيئة الأوزان الابتدائية$\mathrm{W} = (\mathrm{w}_1, \mathrm{w}_2, \mathrm{w}_3 \dots\dots\dots \mathrm{w}_n)$ وθ تمثل قيمة حد العتبة (Threshold) .

الخطوة الثانية: اختيار زوج التدريب (X_N, Y_N)

حيث تمثل X_N متجة الادخال $X_N = (\mathrm{x}_1, \mathrm{x}_2, \mathrm{x}_3, \dots\dots\dots \mathrm{x}_n)$

وتمثل Y_N الاخراج المطلوب (Target Output) : $Y_N = (\mathrm{y}_1, \mathrm{y}_2, \mathrm{y}_3, \dots\dots\dots \mathrm{y}_n)^T$

الخطوة الثالثة : إيجاد قيمة الإخراج الحقيقي (Actual Output) :

$$net = [\sum_{i=1}^{n} X_i W_i - \theta_i] \quad Y = f(net)$$

الخطوة الرابعة : مقارنة الإخراج الحقيقي (Actual Output) مع الإخراج المطلوب (Target Output) أي إذا كان Err=Target-Actual =0 نرجع إلى الخطوة الثانية, وإلا نطبق الخطوة الخامسة.

الخطوة الخامسة : تحديث الأوزان $W_i^{new} = W_i^{old} + \Delta W_i$

حيث $\Delta W_i = \alpha X_i \, Err$ وα تمثل مقدار التعلم.

الخطوة السادسة : تكرار الخطوات من الخطوة الثانية إلى الخطوة الخامسة إلى أن يتم الحصول على التقارب المطلوب (اقل معدل مربع الخطأ MSE) [8][9].

(2-5) الشبكة العصبية ذات التراجع الخلفي للخطأ (BPNN)

تعد هذه الشبكة من أكثر الشبكات العصبية الاصطناعية استخداماً والتي قد تبدو معقدة لكنها أسهل بكثير على مستوى الفهم والبرمجة ولها القدرة على التعامل مع المسائل غير الخطية وهي من الشبكات التي تتعلم بإشراف (Supervised Learning) ولها العديد من التطبيقات في معالجة الصور ومعالجة الإشارة والتعرف على الكلام. طورت في منتصف 1970 من قبل (Rumelhart, Hinton and Williams)، حيث أن هدف الشبكة هو تقليل

الخطأ من خلال تعديل الأوزان (Weights) وذلك بمقارنة إخراج الشبكة الحقيقي (Actual Output) مع الإخراج المطلوب (Target Output) [11].

(1-2-5) معمارية الشبكة: تتكون معمارية شبكة BPNN من مرحلتين أساسيتين:

المرحلة الأولى: المسار الأمامي (Forward Pass):

في هذه المرحلة يتم حساب قيم إشارة الإخراج لكل خلية في طبقات الشبكة بدءاً من طبقة الإدخال (Input Layer) باتجاه طبقة الإخراج (Output Layer)، أي أن إشارة الإخراج لأي خلية لا توثر إلا في الطبقة التي تليها وتنتهي هذه المرحلة مع حساب إشارة الخطأ بين الإخراج الحقيقي(Actual Output) للشبكة والإخراج المطلوب (Target Output).

المرحلة الثانية: المسار الخلفي (Backward Pass):

في هذه المرحلة يتم تعديل الأوزان (Weights) باتجاه يسمح لإشارة الخطأ أن تكون ضمن المستوى المسموح به، إذ يتم إعادة نشر إشارة الإخراج للشبكة لتصبح إشارة إدخال باتجاه عكسي أي من طبقة الإخراج (Output Layer) إلى طبقة الإدخال (Input Layer) حيث يتم تعديل الأوزان (Weights) [3].

(2-2-5) خوارزمية تعليم شبكة الانتشار الخلفي للخطأ (BPNN):

الخطوة الأولى: تهيئة الأوزان الابتدائية $W_N = (w_1, w_2, w_3 \dots\dots\dots w_n)$ وθ تمثل قيمة حد العتبة (Threshold) .

الخطوة الثانية : اختيار زوج التدريب (X_N, Y_J) حيث تمثل X_N متجه الإدخال

$$X_N = (x_1, x_2, x_3, \dots\dots\dots x_n)$$

وتمثل Y_J الاخراج المطلوب (Target Output) $Y_J = (y_1, y_2, y_3, \dots\dots\dots y_j)^T$

الخطوة الثالثة : في الاتجاه الأمامي حساب قيمة الإخراج الحقيقي (Actual Output) كالأتي :

1) حساب قيمة الإخراج الحقيقي من طبقة الإدخال (Input Layer) إلى الطبقة المخفية (Hidden Layer)

$$Y_H = f(net_{IH}) \quad , net_{IH} = [\sum_{i=1}^{n} X_{Ii}\, W_i - \theta_i]$$

n: تمثل عدد العناصر في طبقة الادخال (Input Layer) للشبكة.

2) حساب قيمة الإخراج الحقيقي من طبقة المخفية (Hidden Layer) إلى طبقة الإخراج (Output Layer) :

$$Y_O = f(net_{HO}) \, , net_{HO} = [\sum_{j=1}^{p} Y_{Hj}\, W_j - \theta_j]$$

P : تمثل عدد العناصر في الطبقة المخفية للشبكة.

الخطوة الرابعة: حساب الخطأ ويتم من خلال الخطوات الآتية:

$$e_j = Y_d - Y_j \neq 0$$

1) نقوم بتعديل الأوزان بين طبقة الإخراج (Output Layer) والطبقة المخفية (Hidden Layer):

$$W_j^{new} = W_j^{old} + \Delta W_j$$

$$\Delta W_j = \alpha\, Y_j\, \delta_j \quad and \quad \delta_j = Y_j(1 - Y_j)\, e_j$$

2) نقوم بتعديل الأوزان بين الطبقة المخفية (Hidden Layer) وطبقة الإدخال (Input Layer):

$$W_i^{new} = W_i^{old} + \Delta W_i$$

$$\Delta W_i = \alpha X_i \delta_i \quad and \quad \delta_i = Y_i(1 - Y_i)\sum_{j=1}^{p} \delta_j W_j$$

الخطوة الخامسة: تكرار الخطوات من الخطوة الثانية إلى الخطوة الخامسة إلى يتم الحصول على التقارب المطلوب والذي يمثل (اقل معدل مربع الخطأ MSE) [10][11].

(3-5) شبكة الانحدار العصبية المعممة Generalized Regression Neural Network

تعد شبكة الانحدار العصبية المعممة من الشبكات العصبية الاصطناعية ذات التغذية الأمامية، اقترحت من قبل العالم الأمريكي (Donald F. Specht) عام 1991. وهي شبيهة بشبكة دالة الأساس الشعاعي (Radial Basis) [2]. وإن تعليم الشبكة لا يحتاج إلى عمليات تكرارية لذا تمتاز بالسرعة والدقة في معالجة المعلومات.

(1-3-5) معمارية الشبكة: تحوي هذه الشبكة في تركيبها على مرحلتين من مراحل المعالجة للمعلومات[6][7]:

المرحلة الأولى: في هذه المرحلة يتم إيجاد المسافة بين القيم المدخلة (Input Value) والتي غالبا ما تكون بشكل متجه وقيم الأوزان (Weight Value) (غالبا ما تكون بشكل متجه أيضا)، ثم يضرب الناتج بقيمة التحيز (Bias) وهو مقدار صغير. وتكون دالة التنشيط من نوع (Gaussian) وهي من الدوال غير خطية التي تعرّف بالشكل الآتي: $f(x) = e^{-x^2}$

المرحلة الثانية: تسمى الطبقة الخطية الخاصة (Special Linear) ويتم فيها إيجاد الضرب النقطي بين متجه الأوزان ومتجه الإدخال (الذي يمثل إخراج المرحلة الأولى)، ثم يقسم الناتج على مجموع قيم الإدخال ولا يتم فيها حساب قيمة التحيز(Bias)، أو حد العتبة ودالة التحويل لهذه الطبقة هي دالة خطية والتي تعرّف بالشكل الآتي:

$$f(x) = x$$

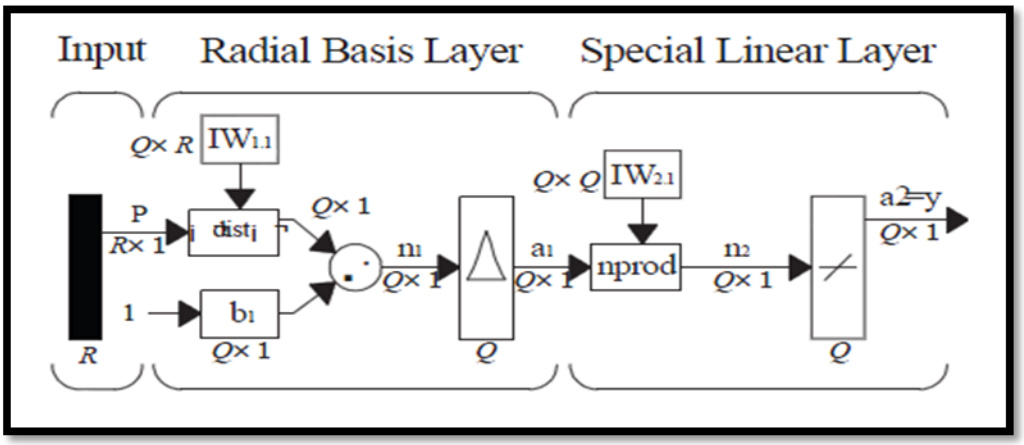

الشكل (5): يمثل معمارية شبكة الانحدار العصبية المعممة.

إذ أن: R تمثل عدد عناصر الإدخال، Q تمثل عدد الخلايا، w الأوزان، وان b التحيز.

(6) ملاءمة النموذج Appropriate The Model

هو مصطلح يتم من خلاله تحديد الآلية الصحيحة والدقيقة لاختيار النموذج المستخدم في حل المسائل المختلفة تبعاً لنوع المسألة، حيث تم في هذا البحث اختيار نوعين من أنواع البيانات التطبيقية المختلفة هي:

1- بيانات لتحديد مرض ضعف السمع : وتتميز بكون منطلقها (Domain) ينتمي إلى فضاء الأعداد الصحيحة (Integer) والمدى (Range) لها يكون ثنائي التصنيف ينحصر بقيمتين هما {0 , 1}.

2- بيانات لتحديد مرض وهن العظام : وتتميز بكون منطلقها (Domain) ينتمي إلى فضاء الأعداد الحقيقية (Real) ومداها (Range) يكون متعدد التصنيف.

كما تم دراسة سلوك كل من شبكة (PNN)، شبكة (BPNN) وشبكة (GRNN) كون هذه الشبكات تختلف فيما بينها في معمارية تكوينها وحالات تصنيفها للبيانات، وتم تطبيق كل من هذه الشبكات على البيانات أعلاه، للتمكن من الخروج بنظرة رياضية تفسيرية لحالات ونتائج التطبيق المختلفة والتي من خلالها يتم وضع بعض الأسس التي يمكن الاعتماد عليها في طريقة اختيار النموذج المناسب من الشبكات المختلفة ووفقاً إلى نوع البيانات وحالات انتماءها إلى فضاءات الأعداد المختلفة. كما تتميز كل شبكة من الشبكات قيد الدراسة بميزات رياضية في تكوينها والية تقبلها للبيانات في الإدخال ومدى قيم إخراجها (Output)، وإذا اعتبرنا أن كل شبكة هي عبارة عن دالة تحويل (Transfer Function) فيمكن تمثيلها بالشكل المبسط الآتي:

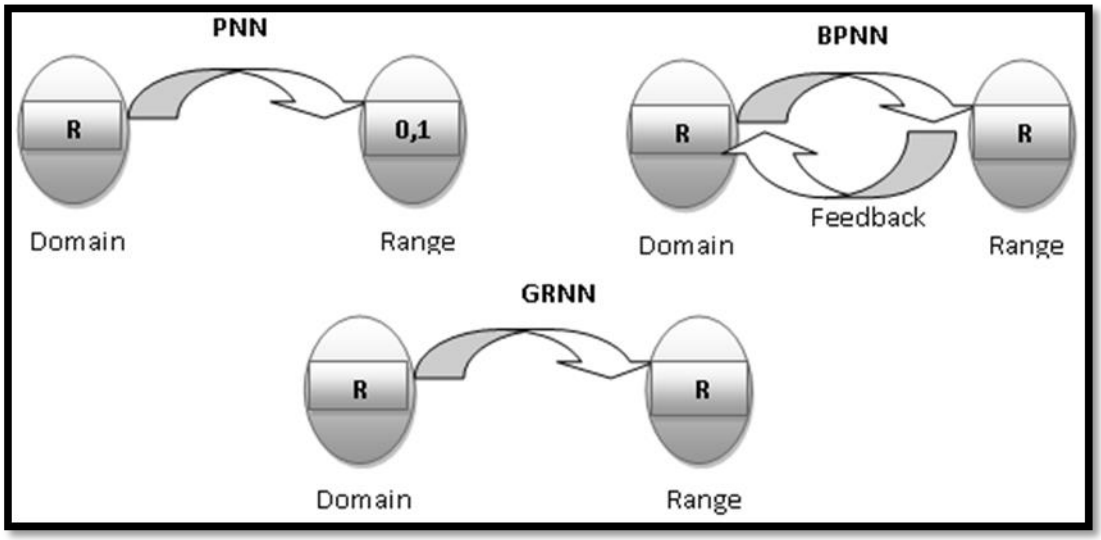

الشكل (6). مخطط يوضح آلية الترابط ومعالجة البيانات في نموذج كل شبكة.

(7) نتائج تطبيق الشبكات العصبية على البيانات السمعية:

تم تطبيق الشبكات العصبية على البيانات السمعية والتي يمكن اعتبارها بيانات بسيطة كون منطلقها ينتمي إلى فضاء الأعداد الصحيحة ومداها يمثل تصنيف البيانات بشكل ثنائي (مريض أو سليم أي إلى 0 أو 1)، وقد تم تقسيم البيانات إلى مجموعتين هما بيانات التدريب (Training) وبيانات الاختبار (Testing)، وتم حساب معدل مربع الخطأ (MSE) لبيانات الاختبار فقط على اعتبار أن بيانات التدريب يتم بناء النموذج من خلالها، ثم تم دراسة حساب (MSE) لبيانات الاختبار من خلال اخذ نسب من مجموع البيانات تبدأ من (10%– 90%) ثم اخذ معدل (MSE) لكل شبكة لمعرفة سلوكها، والجدول (1) يبين نتائج التطبيق.

الجدول (1). يبين نتائج تطبيق البيانات السمعية على الشبكات العصبية الاصطناعية.

Training	*Testing*	*MSE-PNN*	*MSE-BPNN*	*MSE-GRNN*
10 %	*90 %*	0.0444	0.0521	0.9111
20 %	*80 %*	0.0500	0.0625	0.8750
30 %	*70 %*	0.0571	0.0657	0.8143
40 %	*60 %*	0.0833	0.0321	0.7515
50 %	*50 %*	0.0600	0.3376	0.7218
60 %	*40 %*	0.0250	0.0256	0.7761
70 %	*30 %*	0.0667	0.0675	0.7348
80 %	*20 %*	0	0.0036	0.7022
90 %	*10 %*	0	0.0043	0.6045
		AV=0.0430	*AV*=0.0723	*AV*= 0.7657

نلاحظ من نتائج الجدول (1) أن شبكة (PNN) هي الأفضل من خلال معدل (MSE) لجميع النسب المئوية لبيانات الاختبار والمتمثلة بالمعدل (AV)، ونستنتج من ذلك أن البيانات البسيطة تحتاج إلى نموذج شبكة بسيط مثل (PNN)، في حين أن شبكة (BPNN) والتي تتكون من دالة (logsig) في الطبقة المخفية (والتي عدد العقد فيها 5) ودالة (purelin) في طبقة الإخراج وشبكة (GRNN) واللتان تحويان على طبقة مخفية تزيد من تعقيد العمليات الحسابية، كما أنها لا تعطي نتائج أفضل من شبكة (PNN) كونها تتناسب مع البيانات المعقدة والتي لها تصنيفات متعددة مثل بيانات وهن العظام.

(8) نتائج تطبيق الشبكات العصبية على بيانات وهن العظام:

تم تطبيق الشبكات العصبية على بيانات وهن العظام والتي يمكن اعتبارها بيانات معقدة كون منطلقها ينتمي إلى فضاء الأعداد الحقيقية ومداها يمثل تصنيف البيانات بشكل متعدد (Multi classes) وهي (Osteopenia, Osteoporosis, Normal)، وقد تم تقسيم البيانات أيضاً إلى مجموعتين هما بيانات التدريب (Training) وبيانات الاختبار (Testing)، وتم حساب معدل مربع الخطأ (MSE) لبيانات الاختبار فقط على اعتبار أن بيانات التدريب يتم بناء النموذج من خلالها، ثم تم دراسة حساب (MSE) لبيانات الاختبار من خلال اخذ نسب تبدأ من (10%− 90%) من مجموع البيانات ثم اخذ معدل (MSE) لكل شبكة لمعرفة سلوكها، والجدول (2) يبين نتائج التطبيق.

الجدول (2): يبين نتائج تطبيق بيانات مرض وهن العظام على الشبكات العصبية الاصطناعية.

Training	*Testing*	*MSE-PNN*	*MSE-BPNN*	*MSE-GRNN*
10 %	*90 %*	---------	1.7152	1.7346
20 %	*80 %*	--------	1.9309	1.9418
30 %	*70 %*	--------	2.2083	2.2083
40 %	*60 %*	--------	0.6359	0.9908
50 %	*50 %*	--------	0.7616	0.5984
60 %	*40 %*	--------	0.9489	0.4726
70 %	*30 %*	--------	0.5897	0.3435

80 %	*20 %*	--------	0.2833	0.2692
90 %	*10 %*	--------	0.2226	0.2860
			AV=1.0330	*AV*= 0.9828

نلاحظ من نتائج الجدول (2) أن شبكة (PNN) لا يمكن تطبيقها كون أن مداها (Range) يكون ثنائي (Binary) ولا يمكن من خلاله تصنيف الحالات المتعددة لبيانات وهن العظام، كما أثبتت شبكة (BPNN) أنها مناسبة مع التطبيقات التي تكون فيها بيانات الاختبار كبيرة، أي إنها أكثر عمومية (Generalization) من شبكة (GRNN)، على الرغم من كون شبكة (GRNN) هي الأفضل من خلال معدل (MSE) والمتمثلة بالمعدل الكلي (AV) في بيانات وهن العظام.

(9) الاستنتاجات والتوصيات:

1- إن الاحتكام إلى آلية ملاءمة النموذج للتطبيقات الطبية المختلفة تعطي نظرة مسبقة عن نوع خوارزمية الشبكة التي يتم استخدامها وذلك من خلال دراسة السلوك الرياضي لهذه الخوارزمية وطبيعة توافقها مع المنطلق (Domain) والمدى (Range) للبيانات.

2- إن شبكة (PNN) هي الأفضل في معدل (MSE) من كل من شبكة (BPNN) وشبكة (GRNN) في التطبيق على البيانات السمعية، كون المنطلق والمدى لهذه البيانات متوافق بشكل مناسب مع المنطلق والمدى لشبكة (PNN) وبذلك لا تحتاج إلى فضاءات أوسع تزيد من مقدار الخطأ أثناء إجراء عمليات المعالجة.

3- أثبتت شبكة (GRNN) أنها الأفضل في معدل (MSE) من شبكة (BPNN) في التطبيق على بيانات وهن العظام، كونها تستخدم طريقة الانحدار (Regression) في الطبقة الأخيرة وبذلك تكون متناسبة مع البيانات المعقدة.

4- أثبتت شبكة (BPNN) في الجدول (2) أنها أكثر عمومية (Generalization) من شبكة (GRNN) أي أنها مناسبة مع التطبيقات التي تكون فيها بيانات الاختبار كبيرة مقارنة مع بيانات التدريب، وهذه الحالة تشمل معظم التطبيقات الطبية (لأنها تمثل قاعدة بيانات لحالات المرض وتتوسع بإضافة مريض جديد).

5- نوصي بدراسة مفهوم (ملاءمة النموذج) لبقية أنواع الشبكات العصبية، ويمكن تعميم الدراسة إلى جميع أنواع نماذج التقنيات الذكائية لأنها تعتمد على الأسس الرياضية لهذه التقنيات.

6- نوصي بدراسة تطبيقات تنتمي إلى فضاء الأعداد المعقدة (Complex Space) والذي يعد الفضاء الأوسع الذي يشمل بقية الفضاءات العددية، ومحاولة ملاءمة نموذج مناسب للبيانات التي تنتمي إلى هذا الفضاء.

المصادر

[1] Abdellah El Maghraoui, 2011, " Dual Energy X-ray Absorptiometry", Published by InTech Janeza Trdine 9, 51000 Rijeka, Croatia.

[2] Bachir Gourine, Habib Mahi, Amar Khoudiri and Youcef Laksari, 2012, "**The GRNN and the RBF Neural Networks for 2D Displacement Field Modelling. Case study: GPS Auscultation Network of LNG reservoir (GL4/Z industrial complex – Arzew, Algeria)**", TS01F - Dam and Reservoir Engineering Surveying, 5684, pp(2/17, 17/17).

[3] Dr. Shefa Abdulrahman Dawwd, (2009), "**Real Time Implementation of Fir Filter Based on Time Delay Neural Network**", Computer Engineering Department, College of Engineering, University of Mosul, Email: shefadawwd@yahoo.com, vol.18, No.4 August 2010, ISSN 1813-0526, pp.(17-27).

[4] Edward Keedwell and Ajit Narayanan**,** 2005**, "Intelligent Bioinformatics The application of artificial intelligence techniques to bioinformatics problems",** School of Engineering, Computer Science and Mathematics University of Exeter, UK.

[5] Khalid Abulhameed Al-Hindi, 2011,"Teaching Multilayer feedforward Neural Network for Engineers using Graphical user Interface and Matlab", Vol.3, No.1, pp(33_46), UMM Al_Qura Univ. J. Eng & Arch.

[6] Lakshmi Kanaka Venkateswarlu Revada, Vasantha Kumari Rambatla, and Koti Verra Nagayya Ande,2011, "**A Novel Approach to Speech Recognition by Using Generalized Regression Neural Networks**", IJCSI International Journal of Computer Science Issues, Vol. 8, Issue 2, March 2011, ISSN (Online): 1694-0814.

[7] Ligang Zheng, Linghua Jiang, Kai Zheng, Minggao Yu, 2011, **"Estimation of Explosion Limits of Gas Mixture using a Single Spread GRNN"**, IEEE, pp.(1113-1115).

[8] Michael Negnevitsky, 2005, **"Artificial Intelligence A Guide to Intelligent Systems",** Second Edition**,** ISBN 0321204662.

[9] Rajendra Akerkar, 2010, **"Introduction to Artificial Intelligence",** PHI**.**

[10] Samy S. Abu Naser, 2012**, "Predicting Learners Performance using Artificial Neural Networks in Linear Programming Intelligent Tutoring System",** International Journal of Artificial Intelligence & Applications (IJAIA), Vol.3, No.2**.**

[11] Sumathi S.,Surekha p.,2010, **"Computational Intelligence Paradigms Theory and Applications Using MATLAB"**, by Taylor and Francis Group, LLC CRC Press is an imprint of Taylor & Francis Group, an Informa business**.**