



## Convenient ways Artificial Neural

### Networks in the Appropriate Model for Medical Diagnosis

#### ملائمة طرق الشبكات العصبية لنموذج للتشخيص الطبي

م. عبير كاظم عليوي حمزة الطائي

**Abstract :** In this research discuss the concept of appropriate form, by examining sporting behavior for three models represen neural networks are (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 (BPNN) is better diagnose bone crisp data generalization, especially when test data are large compared with the training data.

#### الملخص

في هذا البحث تم مناقشة مفهوم ملائمة النموذج ، وذلك بدراسة السلوك الرياضي لنموذجين تمثل شبكات عصبية هي (BPNN،PNN) ، كما تم تطبيق نوعين من البيانات الطبية هما (ضعف السمع ولين العظام ) ومختلفين في فضاءات الإدخال (INPUT) والإخراج (OUTPUT) وفي طريقة التصنيف ، وتبين من خلال تطبيق هذه البيانات وملائمتها مع نماذج الشبكات العصبية الاصطناعية من حيث المدى (Range) والمنطق (Domain) إن شبكة (PNN) هي الأفضل في تشخيص أنماط البيانات السمعية من خلال معدل (MSE) وأن شبكة (BPNN) هي الأكثر عمومية (Generelization) خصوصاً عندما تكون أنماط بيانات الاختبار كبيرة مقارنة مع أنماط بيانات التدريب .

\* جامعة الفرات الأوسط /المعهد التقني المسيب

## المقدمة

تعد الشبكات العصبية الاصطناعية من نماذج تقنيات الانظمة الذكية الكثيرة التطبيق في مختلف المجالات العلمية الحديثة والذي يتطلب معرفة نوع النموذج الذي يتم من خلاله تحويل بيانات الإدخال (Input) إلى الإخراج المطلوب (Target) والتي تعجز عن حلها الطرائق الرياضية والإحصائية التقليدية ، إلا ان العديد من التطبيقات التي تم دراستها باستخدام الشبكات لم تأخذ بنظر الاعتبار النموذج المناسب لها والذي يتوافق مع بيانات الإدخال وطبيعة الاخراجات المطلوبة ، وذلك يؤدي إلى النموذج إلى مرود سلبي قد يمثل في إجراء عمليات حسابية غير ضرورية أو قد يؤدي إلى زيادة معدل مربع الخطأ (MSE) .

وصف البيانات

تضمن البحث على نوعين من البيانات الطبية هي (بيانات لتحديد ضعف السمع وبيانات لتحديد لين العظام ) إذ تضمن البحث أنماط البيانات السمعية قراءات لمستوى السمع لدى الانسان أي يتم معرفة الشخص مصاب أم لا ، أي ان التصنيف يكون ثنائي ( ٠ أو ١ ) ، وهذه البيانات عبارة عن أنماط عينات مختلفة من المرض وعددها ( ١٠٠ ) ، تمثل أشخاص مصابين بضعف السمع وآخرين طبيعيين وكل نمط من أنماط البيانات تتكون من خمسة قراءات تمثل أعداد صحيحة فقط يتم من خلالها تحديد هل ان الشخص مصاب أو لا .

ومن جهاز ( P.T.A ( pure tone Audiometry وهو جهاز فحص عند الانسان مبني على أساس الفحص المسمى ب(P.T.A) وهو يقوم بفحص ترددات مختلفة تم أخذ انماط من البيانات حيث ركز على فحص توصيل السمع الهوائي حيث يعد الفحص الأوسع في قياس درجة ضعف السمع ، حيث تم أخذ العينات بالتعاون مع مستشفى النعمان حيث تمثل القيم (10,0,0,0,5) تمثل قراءات لحالة شخص سليم والقراءات (20,20,65,55,50) تمثل حالة الشخص المصاب .

أما بالنسبة لبيانات لين العظام تتكون من أنماط عينات مختلفة اي تنتمي إلى فضاء الأعداد الحقيقية (Real Space) حيث يكون أعقد وأوسع من فضاء الأعداد الصحيحة (Integer Space) . حيث تمر الانماط بمراحل مختلفة من الإصابة إذ تمثل حالة (Osteopenia) المرحلة الأولى من الإصابة ، وتمثل (osteoporosis) المرحلة الثانية والمتأخرة من الإصابة وأما الحالة الثالثة هي الحالة السليمة (Normal) [1] ، والموضحة بالشكل (١) ،



Osteoporosis

Normal

في العراق وتحديداً في محافظة بغداد مستشفى النعمان.

الشكل رقم (١): يوضح المقارنة بين النسيج الطبيعي (Normal) والنسيج المصاب بمرض لين العظام من نوع (Osteoporosis).

تتكون مصفوفة البيانات التطبيقية لمرض ولين العظام من (344) حالة منها (113) نمطاً تشخيصياً من نوع (Osteoporosis)، في حين يوجد (131) نمطاً من نوع (Osteopenia)، أما بقية الأنماط والتي يبلغ عددها (100) نمطاً، يمثل تشخيص الحالة الطبيعية (Normal) غير مصابة، وعدد الأنماط القياسية في كل نمط فعددها (17) قيمة، أي ان مصفوفة الإدخال فتكون أبعادها (344\*17) والتي تحتوي على (٥٨٤٨) عنصراً من مستويات الأنماط المستخدمة في مرض لين العظام.

ومن اهم هذه القراءات في الحالة المرضية من نوع (Osteoporosi)

هي (T-Score) والتي تكون أقل من (-2.5) وفي الحالة الطبيعية (Normal) تكون قيمتها أعلى من (-1.0) وما بينهما تمثل الحالة المرضية (Osteopenia) وهذا هام جداً من أجل الإنذار والتشخيص المبكر لللين العظام.

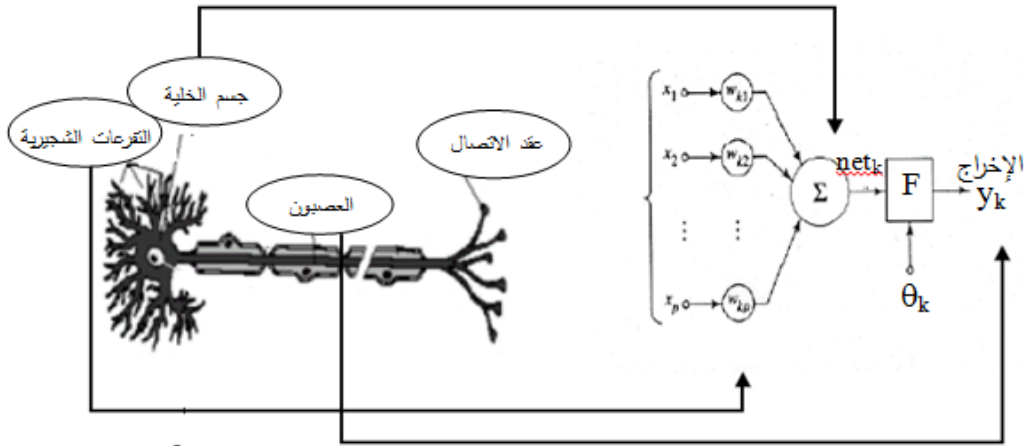
وقد تم في هذا البحث دراسة سلوك مجموعة من الشبكات العصبية الاصطناعية من ناحية ملائمتها مع البيانات المستخدمة، كما تم تقديم الية يتم من خلالها تحديد نوع الشبكة المستخدمة وبتوافق مع أنماط البيانات التطبيقية.

(١-١) الشبكات العصبية الطبيعية والشبكات العصبية الاصطناعية

### Natural Neural Networks and Artificial Natual Neural

تعد الشبكات العصبية الاصطناعية تقنية رياضية برمجية مصممة لمحاكاة طريقة التفكير ومعالجة الأعصاب للمعلومات التي يؤدي بها عقل الانسان مهمة معينة من خلال معالجة موزع على التوازي، تتكون الشبكات العصبية الاصطناعية من وحدات من وحدات معالجة بسيطة تسمى خلية أو

عقدة (Node) وكل اتصال بين الخلايا المحددة بقيم تسمى الأوزان (Weights) ، حيث تقوم بتخزين المعلومات حيث تجعلها متاحة للمستخدم وذلك عن طريق ضبط هذه الأوزان (Weights). [٤][٥]

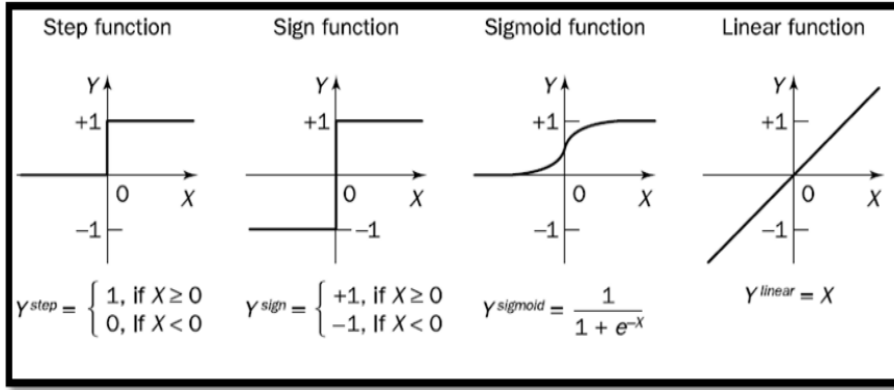


الشكل (٢): مقارنة بين خلية عصبية طبيعية وخلية عصبية اصطناعية.

(١-٢) معمارية الشبكات العصبية الاصطناعية Architecture of Anns

تتكون من الأجزاء التالية:

- ١- طبقة المدخلات (Input Layer) : تقوم باستلام إشارات الإدخال من خارج الشبكة والتي تقابل التفرعات الشجرية (Dendrites) في الخلية الطبيعية لدى الإنسان .
- ٢- طبقة المخرجات (Output Layer) : وهي الطبقة الأخيرة والتي تعطي الإخراج بعد سلسلة من المعالجات .
- ٣- الأوزان (Weights) : حيث تقابل (Synapse) بالشبكات العصبية الطبيعية وكذلك تمثل الاتصالات بين طبقات في الشبكات الاصطناعية.
- ٤- دالة التنشيط (Activation function) : هنالك عدة أنواع من هذه الدوال منها :
  - دالة الخطوة (Step function) : ويقع إخراجها بين (0,1).
  - دالة الإشارة (Sign function) : حيث يقع إخراجها بين [-1,1], وتستخدم في التصنيف (Classification) والتعرف على الأنماط (Pattern Recognition)
  - الدالة الخطية (Linear Function) وهي الدالة التي تكون فيها صور الإخراج مشابهة للإدخال وتعطي تصنيفات متعددة وغير محددة .
  - الدالة السيجماوية (Sigmoid Function) : وهي دالة غير خطية يقع مداها بين [0,1] وتكون مستمرة وقابلة للاشتقاق والشكل (٣) يوضح أشهر دوال التنشيط .



والشكل (٣) : دوال التنشيط المستخدمة في الشبكات العصبية الاصطناعية.  
 قد تحوي الشبكات العصبية الاصطناعية على طبقة مخفية (hidden layer) تضاف هذه  
 الطبقة حسب تعقيد المسألة [8].

(١-٣) أنواع الشبكات العصبية الاصطناعية

### Types of Artificial Neural Networks

هناك العديد من الشبكات العصبية الاصطناعية المستخدمة في معالجة انماط البيانات وكل نوع من  
 هذه الانواع له خصوصية في المعمارية والية معالجة البيانات من خلال عدد ونوع العقد في كل طبقة  
 بالإضافة إلى نوعية دوال التنشيط والية تعديل الأوزان ومن هذه الشبكات هي :

- (١) شبكة الإدراك العصبية (Perceptron) .
  - (٢) شبكة الانحدار العصبية المعممة (Generalized Regression) .
  - (٣) الشبكة العصبية ذات التراجع الخلفي للخطأ (Back propagation) .
- شبكة الإدراك العصبية (PNN)

تعد شبكة الإدراك من أوائل الشبكات التي تم دراستها في منتصف ١٩٥٠ ذات تغذية أمامية  
 ووحيدة الخلية وهي من الشبكات التي تتعلم بأشراف . كما ان خوارزمية التعليم لها اكتشافها  
 العالم ( Frank Rosenblatt ) سنة ١٩٥٨ . وفي سنة ١٩٦٩ برهن ( Minsky and  
 Papert ) أن الشبكة تستطيع تعليم الدوال القابلة للفصل الخطي فقط مثل الدوال المنطقية  
 (OR,AND) التي تحوي على نوعين من الاخراج فقط [9] .

(١-٤) خوارزمية تعليم شبكة الإدراك (PNN) .

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

الخطوة الثانية: اختيار زوج التدريب  $(X_N, Y_N)$

حيث تمثل  $X_N$  متجة الادخال  $X_N = (x_1, x_2, x_3, \dots \dots x_n)$

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

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

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

الخطوة الرابعة : مقارنة الإخراج الحقيقي (Actual Output) مع الإخراج المطلوب (Target)

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  $\Delta W_i = \alpha * X_i * Err$  و  $\alpha$  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].

(١-٥) الشبكة العصبية ذات التراجع الخلفي للخطأ (BPNN)

تعد هذه الشبكة من أكثر الشبكات العصبية 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 بأشراف (Supervised Learning) ولها العديد من التطبيقات في معالجة الصور ومعالجة الإشارة والتعرف على الكلام . طورت في منتصف ١٩٧٠ من قبل (Rumelhart, Hinton and Williams) ، حيث أن هدف الشبكة هو تقليل الخطأ من خلال تعديل الأوزان (Weights).

وذلك بمقارنة اخراج الشبكة الحقيقية (Actual Output) مع الإخراج المطلوب (Target Output) [11] .

(١-٦) معمارية الشبكة : تتكون معمارية الشبكة (BPNN) من مرحلتين اساسيتين :

المرحلة الاولى : المسار الامامي (Forward Pass) :

في هذه المرحلة يتم حساب قيم إشارة الأخراج لكل خلية في طبقات الشبكة بدءاً من طبقة الادخال (Input Layer) باتجاه طبقة الإخراج (Output Layer) ، أي ان إشارة الإخراج لأي خلية لا تؤثر إلا في الطبقة التي تليها وتنتهي هذه المرحلة مع حساب إشارة

الخطأ بين الاخراج الحقيقي (Actual out put)

للشبكة والاجراج المطلوب (Target Output)

المرحلة الثانية : المسار الخلفي (Backward Pass):

في هذه المرحلة يتم تعديل الازان (Weights) باتجاه يسمح لإشارة الخطأ ان يكون ضمن المسموح به ،اذ يتم اعادة نشر اشارة الاخراج للشبكة لتصبح إشارة ادخال باتجاه عكسي حيث يتم تعديل الازان (Weights) [3].

(1-7) خوارزمية تعليم شبكة الانتشار الخلفي للخطأ (BPNN)

الخطوة الاولى : تهيئة الازان الابتدائية

$W_N = (w_1, w_2, w_3 \dots \dots w_n)$  تمثل قيمة حد العتبة  
(Threshold).

الخطوة الثانية : اختيار زوج الترتيب  $(X_N, Y_j)$  حيث تمثل  $X_N$  متجة الادخال .

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

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

الخطوة الثالثة : في اتجاه الامامي حساب قيمة الاخراج الحقيقي (Actual Output) كالاتي :

١. حساب قيمة الاخراج الحقيقي من طبقة الادخال (Input Layer) إلى الطبقة المخفية (Hidden Layer)

$$net_{IH} = \sum_{i=1}^N [X_{Ii} W_i - \theta_i]$$

$N$ : تمثل عدد العناصر في طبقة الادخال (Input Layer) للشبكة. كما ان  $Y_H = f(net_{IH})$

٢. حساب قيمة الإخراج الحقيقي من الطبقة المخفية (Hidden Layer) إلى طبقة الإخراج (Output Layer)

$$net_{HO} = \sum_{j=1}^P [Y_{Hj} W_j - \theta_j]$$

$P$ : تمثل عدد العناصر في الطبقة المخفية كما أن )

$$Y_O = f(net_{HO})$$



الخطوة الرابعة : حساب الخطأ وبشكل التالي :

$$e_j = Y_d - Y_j \neq 0 \quad (1) \text{ حساب الخطأ بين طبقة الإخراج والطبقة المخفية}$$

$$\Delta W_j = \alpha Y_j \delta_j \text{ ثم نقوم بتعديل الأوزان}$$

$$e_i = Y_j - Y_i \neq 0 \quad (2) \text{ حساب الخطأ بين طبقة المخفية وطبقة الإدخال}$$

ثم  
الأوزان  
يتم  
تعديل

$$\Delta W_i = \alpha X_i \delta_j \text{ حيث تمثل } \alpha \text{ مقدار التعلم حيث أن}$$

$$\delta_i = Y_j (1 - Y_j) \sum_{i=1}^N \delta_i W_i \text{ , ثم نقوم بتحديث الأوزان}$$

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

الخطوة الخامسة : تكرار الخطوات من الخطوة الثانية إلى الخطوة الخامسة إلى أن يتم حصول التقارب المطلوب والذي يمثل ( أقل مربع خطأ MSE ) [10][11] .

٥- ملائمة النموذج :

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


١- بيانات لتحديد مرض وهن العظام : وتتميز بكون منطلقه (Domai) ينتمي إلى فضاء الأعداد الحقيقية (Real) ومداه (Range) يكون متعدد التصنيف .

٢- 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}.

كما تم دراسة سلوك كل من شبكة (PNN) ، وشبكة (BPNN) كون هذه الشبكات تختلف في معمارية تكوينها وحالات تصنيفها للبيانات ، وقد تم تطبيق كل من هذه الشبكات على البيانات أعلاه ، لكي نتأكد من الخروج بنظره رياضية تفسر حالات ونتائج التطبيق المختلف ومن خلالها



سوف يتم وضع بعض الاسس الذي يمكن الاعتماد عليها في طريقة اختيار النموذج المناسب من الشبكات وفقا لنوع البيانات وحالات أنتمائها الى قضاءات الاعداد المختلفة . وكل شبكة من هذه الشبكات تتميز بميزه رياضية في تكوينها والية تقبلها للبيانات. وأذا اعتبرنا كل شبكة هي دالة تحويل (Transfer Function) فيمكن ان نمثلها بشكل الاتي :



الشكل (٤) : مخطط يوضح الية الترابط والمعالجة للبيانات في نموذج كل شبكة

#### (1-8) نتائج تطبيق الشبكات العصبية على البيانات السمعية:

تم تطبيق الشبكات العصبية على البيانات السمعية والتي يمكن اعتبارها بيانات بسيطة كون منطلقها ينتمي الى فضاء الاعداد الصحيحة ومداهها يمثل تصنيف البيانات بشكل ثنائي (مريض أو سليم أي إلى ٠ أو ١)، وقد تم تقسيم البيانات إلى مجموعتين وهما بيانات الاختبار (Testing) وبيانات التدريب (Training)، وكذلك تم حساب مربع الخطأ (MSE) لبيانات الاختبار فقط باعتبار ان بيانات التدريب يتم بناء النموذج من خلالها، ثم تم دراسة حساب (MSE) لبيانات الاختبار من خلال اخذ النسب من مجموع البيانات وتبدأ (١٠% - ٩٠%) ثم اخذ معدل (MSE) لكل شبكة لمعرفة سلوكها، والجدول (٥) يوضح نتائج التطبيق.

الجدول (٥) يبين نتائج تطبيق البيانات السمعية على الشبكات العصبية الاصطناعية.

Training	Testing	MSE-BPNN	MSE-PNN
10%	90%	5.3892e-6	0
20%	80%	4.9636e-4	0
30%	70%	0.636	0.0667
40%	60%	0.0474	0.025

50%	50%	0.057	0.06
60%	40%	0.0636	0.0833
70%	30%	0.0684	0.0571
80%	20%	0.0591	0.05
90%	10%	0.0521	0.0444
		AV=0.1093	AV=0.0429

سوف نلاحظ من الجدول (٥) أن شبكة (PNN) هي الأفضل من خلال معدل (MSE) لجميع النسب المئوية لبيانات الاختبار والمتمثلة بمعدل (AV)، ونستنتج من ذلك ان البيانات البسيطة تحتاج الى نموذج شبكة بسيط مثل (PNN) ، في حين ان الشبكة (BPNN) والتي تتكون من الدالة (logsig) في الطبقة المخفية ( والتي عدد العقد فيها ٥) ودالة (purelin) في طبقة الاخراج

#### (٨-١) نتائج تطبيق الشبكات العصبية على بيانات لين العظام:

تم تطبيق الشبكات العصبية على بيانات لين العظام والتي يمكن اعتبارها بيانات معقدة كون منطلقها ينتمي الى فضاء الاعداد الحقيقية ومداهها يمثل تصنيف للبيانات وبشكل متعدد ( Multi classes) وهي (Normal، Osteopenia، Osteoporosis) ولقد تم تقسيم البيانات الى قسمين هما بيانات الاختبار (Testing) وبيانات التدريب (Training) ولقد تم حساب مربع الخطأ (MSE) لقسم بيانات الاختبار فقط بأعتبار ان بيانات التدريب يتم بناء النموذج من خلالها، وبعدها تم دراسة حساب مربع الخطأ (MSE) لبيانات الاختبار من خلال اخذ النسب التي تبدأ من (١٠%-٩٠%) من مجموع البيانات ثم ناخذ معدل (MSE) لكل شبكة لمعرفة سلوكها، والجدول (٢) يبين نتائج التطبيق .

الجدول (٦) يبين نتائج تطبيق بيانات لين العظام على الشبكات العصبونية الاصطناعية.

Training	Testing	MSE-PNN	MSE-BPNN
10%	90%	-----	1.7152
20%	80%	-----	1.9309
30%	70%	-----	2.2083
40%	60%	-----	0.6359
50%	50%	-----	0.7616
60%	40%	-----	0.9489
70%	30%	-----	0.4170
80%	20%	-----	0.392
90%	10%	-----	0.3577
			AV=1.0408

نلاحظ من الجدول (٦) ان شبكة (PNN) لا يمكن تطبيقها كون مداها (Range) حيث يكون ثنائي (Binary) ولا يمكن من خلاله تصنيف الحالات المتعددة لبيانات لين العظام، وكما تم اثبات ان الشبكة (BPNN) أنها مناسبة مع التطبيقات التي يكون فيها بيانات الاختبار كبيرة، اي انها اكثر عمومية (Generalization) .

الاستنتاجات والتوصيات :

١- أن شبكة (PNN) تكون هي الافضل في معدل (MSE) من شبكة (BPNN) في تطبيقها على البيانات السمعية وذلك لان كل من المدى والمنطلق للبيانات متوافق مع المدى والمنطلق لشبكة (PNN) لذلك فأنها لا تحتاج الى فضاءات اوسع لتزيد من مقدار الخطأ اثناء اجراء عمليات المعالجة .

٢- التحكم في ملائمة النموذج للتطبيقات الطبية المختلفة يمكن إعطاء نظرة مسبقة عن نوع الخوارزمية للشبكة التي يتم استخدامها وذلك من خلال دراسة السلوك الرياضي لهذه الخوارزمية وطبيعة توافقها مع المدى (Range) والمنطلق (Domain) للبيانات المستخدمة

٣- لقد اثبتت ان الشبكة (PNN) في الجدول (٢) أنها أكثر عمومية (Generalization) أي انها تكون مناسبة أكثر 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 الى قاعدة البيانات) .

### 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] 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.

[4] 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).

ISSN 1813-0526,pp(17-27).

- [5] 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.
- [6] 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.
- [7] Michael Negnevitsky,2005," Artificial Intelligence A Guide to Intelligent Systems",Second Edition,ISBN 0321204662.
- [8] 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).
- [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.