

دراسة مقارنة بين أداء الشبكات العصبية ونظام الاستدلال العصبي الضبابي المتكيف في تشخيص سرطان الثدي بالاعتماد على السمات البنيوية

د. بلسم أحمد عيد*

(تاريخ الإيداع 21 / 12 / 2016. قُبِلَ للنشر في 1 / 6 / 2017)

□ ملخص □

في هذه البحث تم تصميم شبكة عصبية اصطناعية تعتمد على خوارزمية الانتشار الخلفي للخطأ (BPNN) لتشخيص أورام الثدي وكذلك تصميم مصنف للتشخيص باستخدام نظام الاستدلال العصبي الضبابي المتكيف (ANFIS) وقد اعتمدت كلا الدراستين على السمات البنيوية للخزعة الموجودة في قاعدة البيانات لصور الثدي لجامعة ويسكونسون في الولايات المتحدة الأمريكية "Wisconsin Brest Cancer dataset" في النهاية تم إجراء مقارنة بين الدراستين من أجل التشخيص الحميد والخبيث للكتل السرطانية لسرطان الثدي حيث حصلت الدراسة الاولى BPNN على دقة 95.95% بينما الدراسة الثانية ANFIS حصلت على دقة 91.9% وهذه النتائج تعتبر هامة جدا ومساعدة إذا ما قورنت بالأبحاث المعتمدة على السمات الشكلية المأخوذة من الصور لأجهزة متنوعة كالماموغراف والرنين المغناطيسي.

الكلمات المفتاحية: النظام العصبي الضبابي، الشبكات العصبونية، خوارزمية الانتشار الخلفي، سرطان الثدي، السمات البنيوية للثدي، المنطق الضبابي، تشخيص الأورام.

* مدرس - قسم هندسة الحاسبات والتحكم الآلي - كلية الهندسة الميكانيكية والكهربائية - جامعة تشرين - اللاذقية - سورية.

A Comparative Study between Artificial Neural Network Performance and Adaptive Neuro-fuzzy Inference Systems in Breast Cancer Diagnosis Depending On Structural Features

Dr. Balsam Ahmad Eid*

(Received 21 / 12 / 2016. Accepted 1 / 6 / 2017)

□ ABSTRACT □

This research aims to produce a diagnosis system for breast cancer by using Neural Network depending on Back Propagation algorithm (BPNN) and Adaptive Neuro Fuzzy Inference System 'ANFIS', the both of studies was done using structural features of biopsies in "Wisconsin Breast Cancer" data base.

In the end a comparison was made between the two studies of malignant- benign classification of breast masses of breast cancer which has accuracy 95,95% with BPNN and 91.9% with ANFIS system, this results can be consider very important if they compared with researches depending on image features that obtained of various devises like mammography, magnetic resonance.

Keywords: Neural Networks, back propagation Algorithm, Breast cancer, structural features of biopsies, Neuro-Fuzzy systems, Fuzzy logic, Tumors Diagnosis.

* Assistant Professor, Department Of Computers And Automatic Control Engineering, Faculty Of Mechanical And Electrical Engineering, Lattakia , Syria.

مقدمة:

يعد سرطان الثدي من أكثر الأمراض انتشاراً لدى النساء مسبباً عدداً كبيراً من الوفيات سنوياً ومعدل الوفيات يتزايد بشكل كبير نتيجة التأخر في الكشف عنه ولما كان الكشف المبكر عن سرطان الثدي هو من اهم العوامل في الوقاية منه واتخاذ قرار علاجي كاستئصال كتل ورمية من الثدي تحمي المريض من تفاقم وانتشار المرض كانت الابحاث متوجهة نحو المعرفة المسبقة والدقيقة لمواصفات وأبعاد هذه الكتل، لذلك كان لابد من العمل على تطوير طرق جديدة لاستخراج هذه الأورام وتحديد خصائصها [1].

ان علوم الذكاء الصناعي تطورت في العقد الاخير من هذا القرن بشكل ملحوظ و سريع في جميع المجالات العلمية حيث تم تطبيق تقنيات الذكاء الصناعي في المجالات الطبية بشكل كبير وخصوصا في التشخيص الآلي والتصنيف لكثير من الاورام السرطانية بالاعتماد على السمات الشكلية المستخرجة باستخدام تقنيات معالجة الصور الرقمية لعدة انواع من الصور الطبية الرقمية كصور الاشعة السينية وصور المرنان المغناطيسي والماموغراف او بالاعتماد على السمات البنوية المستخرجة من الخزع والمعتمدة من جامعات عالمية لتكون متاحة للباحثين و بذلك تشكل هذه التطبيقات على اختلاف تقنياتها أداة مساعدة للطبيب المختص كراي داعم ذلك لأن بعض الكتل قد تكون صغيرة ونسيجها سميك و يعتمد الاطباء على المشاهدة في الصور بالاضافة الى التحاليل المخبرية في تحديد وجود المرض وايضا كراي اساسي في الاماكن التي تنقص فيها الخبرات البشرية الاختصاصية [2,6].

أهمية البحث وأهدافه:

يهدف البحث إلى الوصول إلى الخوارزمية الأمثل والأدق في تشخيص أورام الثدي بالاعتماد على السمات البنوية للأورام من خلال إجراء مقارنة بين تصميم شبكة عصبية اصطناعية و تدريبها للتعرف على عينات مرضية مختلفة من الكتل السرطانية باستخدام خوارزمية الانتشار الخلفي للخ طاً وبين نظام الاستدلال العصبي الضبابي المتكيف, (Adaptive Neuro-Fuzzy Inference System) حيث تم باستخدام كلا الطريقتين تشخيص سرطان الثدي وتصنيفه الى سرطان حميد وخبث بالاعتماد على السمات البنوية المأخوذة من الخزع المرضية للكتل والمعتمدة في قاعدة البيانات في جامعة وسكونسون في الولايات المتحدة الأمريكية (Wisconsin breast cancer data base) وتكمن أهمية هذه المقارنة في كونها قد تكون مفيدة جدا في التشخيص الالي لدعم رأي الطبيب المختص في التشخيص السليم و اتخاذ القرار المناسب وقد تم في النهاية تقييم أداء الخوارزميتان من حيث عدة عوامل أهمها دقة التصنيف والأداء و سهولة التصميم.

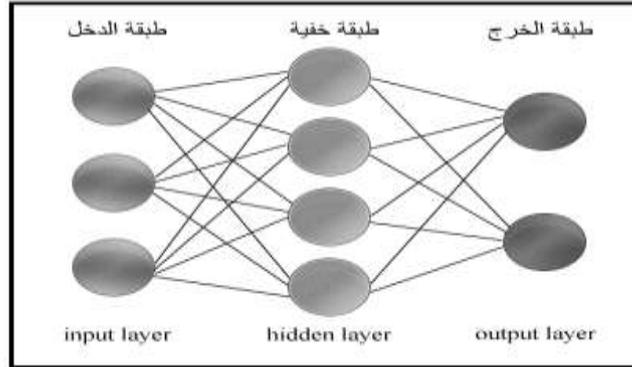
طرائق البحث ومواده:

1-خوارزمية الانتشار الخلفي (Back propagation algorithm):

هي إحدى طرق تعليم الشبكات العصبونية التي تؤمن نقل معلومات بالانتشار العكسي للاتجاه الأصلي لقدم المعلومات. تعتمد هذه الطريقة على مبدأ التعليم المراقب وتحتاج في مرحلة التدريب إلى بيانات خاصة تتعلم بها الشبكة حيث تقدم لها بيانات دخل (input) مع بيانات الخرج (output) المرغوب فيها ومن ثم تقوم الشبكة بالقيام بعملية الانتشار امامي (feed forward) لبيانات الدخل للحصول على قيمة خرج الشبكة بعدها تقوم بالمقارنة بين الخرج المحسوب والخرج المرغوب فإذا لم تتطابق النتائج تقوم الشبكة بحساب قيمة الفرق بينهما لكل عصبون من طبقة الخرج

والذي يمثل قيمة الخطأ (error) ، بعدها تأتي مرحلة الانتشار الخلفي للأخطاء (back propagation) حيث تعيد الشبكة حساب قيمة الخطأ في كل عصبون من الطبقات الخفية. في النهاية تأتي المرحلة التالية وهي مرحلة تحديث قيمة الأوزان (weight update) حيث تقوم الشبكة بإعادة حساب كل الأوزان وتعويضها بالقيم الجديدة المحسوبة [2,3].

يشترط في الانتشار الخلفي ان تكون توابع التنشيط التي تستعملها العصبونات قابلة للاشتقاق. ذلك لأنه في مرحلة تحديث الأوزان تستعمل الدالة المشتقة لدالة التنشيط في حساب القيم الجديدة.



الشكل (1) طبقات الشبكة العصبية الاصطناعية

آلية التدريب:

يمكن تقسيم مراحل التعليم التي تعتمد عليها الشبكة إلى مرحلتين [4]:
المرحلة الأولى (الانتشار) مع كل عينة من بيانات الدخل يجب أن يتم تغذية أمامية للشبكة بعينة بيانات الدخل (input) لحساب بيانات الخرج (output) ومن ثم يتم مقارنة النتائج المحصل عليها مع النتائج المرغوب فيها ويتم حساب الفرق الذي يمثل قيمة الخطأ (error) ومن ثم تغذية خلفية حيث يتم حساب قيمة الخطأ في كل عصبون ينتمي للطبقات الخفية.

المرحلة الثانية (تحديث قيم الأوزان) يتم تحديث قيمة أوزان العصبونات التي تنتمي إلى الطبقات الخفية (Hidden Layers).

وبالتالي يمكن تلخيص مراحل تدريب الشبكة العصبية الاصطناعية بالخطوات التالية: إعطاء أوزان عشوائية للترابط بين خلايا الشبكة.

- 1) تقديم إحدى المدخلات المعدة للتدريب إلى الشبكة.
- 2) تطبيق عملية التغذية الأمامية لتحديد مخرجات الشبكة.
- 3) مقارنة المخرجات الفعلية مع المخرجات المطلوبة وتحديد قيمة الخطأ.
- 4) التراجع بالخطأ عبر الشبكة وتصحيح الأوزان في الاتجاه الذي يضمن تصغير قيمة الخطأ اعتباراً من طبقة الخرج باتجاه طبقة الدخل (الانتشار الخلفي).
- 5) تصفير إجمالي الخطأ لكل المدخلات المستخدمة في التدريب.

1-1 طرق الانتشار الخلفي للخطأ:

تعتمد خوارزمية الانتشار الخلفي على حساب الخطأ بين المخارج الفعلية (outputs) للشبكة والمخارج المطلوبة (Targets)، ثم نشر الخطأ بشكل عكسي أي تعديل قيم الأوزان والانحياز عدداً من المرات حتى تتمكن من تقليل تابع الكلفة (الأداء) (mean square error (mse)) إلى أقل قيمة ممكنة، وبالتالي ربط مداخل عملية التدريب بالمخارج المناسبة، أو تصنيف هذه المداخل إلى الأصناف المحددة من قبل المستخدم. يمكن لشبكة مؤلفة من طبقة واحدة خفية تستخدم تابع (sigmoid) كتابع تفعيل لها مزودة بطبقة خطية في الخرج أن تصل إلى مرحلة التقارب وتقليل قيمة تابع الخطأ المعتمد إلى القيمة المطلوبة [5].

تستخدم خوارزمية الانتشار الخلفي تقنية انحدار الميل (gradient descent) بشكل افتراضي، والتي تتحرك فيها الأوزان في الاتجاه السالب لميل تابع الأداء. تشير عبارة "الانتشار الخلفي" إلى الطريقة التي يتم فيها حساب الميل للشبكة العصبونية غير الخطية متعددة الطبقات. هناك عدد من النسخ الأخرى من خوارزمية الانتشار الخلفي والتي تعتمد على تقنيات أخرى مثل طريقة نيوتن (Newton) والميل الموحد (conjugate gradient) [3].

1-1-1 طريقة انحدار الميل (gradient descent):

هناك العديد من طرق تطبيق خوارزمية الانتشار الخلفي للخطأ، لكن أسهل هذه الطرق هي الطرق التي تعتمد على تحديث أوزان الشبكة والانحياز في الاتجاه الذي تتناقص فيه قيمة تابع الكلفة (الأداء) أي في الاتجاه السلبي لتابع الكلفة، وهذا مبدأ تقنية انحدار الميل. يمكن أن نكتب تكراراً واحداً من هذه الطريقة كما يلي [7]:

$$X_{k+1} = X_k - \alpha_k g_k(y) \quad (1)$$

حيث يمثل X_k شعاع الأوزان والانحياز الحالي، بينما تمثل g_k الميل الحالي، و α_k معدل التعلم. يوجد طريقتان مختلفتان يمكن أن تطبق من خلالها خوارزمية تناقص (انحدار) الميل (gradient descent algorithm) وهما النمط التزايدى (Incremental)، ونمط الدفعة الواحدة (batch). في النمط التزايدى، يحسب الميل وتعديل الأوزان بعد أن يطبق كل دخل إلى الشبكة. في نمط الدفعة الواحدة، تطبق كل المداخل إلى الشبكة قبل تعديل الأوزان.

تستخدم خوارزمية انحدار الميل في نمط الدفعة الواحدة التابع (training) تعديل الأوزان والانحياز في الاتجاه السلبي (المعاكس) للميل الخاص بتابع الأداء (mse).

1-1-2 طريقة الميل الموحد المتدرج (Scaled Conjugate Gradient):

على الرغم من أن خوارزمية انحدار الميل تقوم بإنقاص تابع الخطأ، إلا أن ذلك قد لا ينتج تقارباً سريعاً للخوارزمية، فقد تستغرق الشبكة عدد كبيراً من التكرارات لتصل للقيمة الدنيا من الخطأ وقد لا تصل مطلقاً. على عكس ذلك فإن خوارزمية الميل الموحد أسرع كونها تنجز باتجاه واحد، ليس ذلك فحسب بل إن هذه الخوارزمية لا تعتمد قيمة ثابتة لمعدل التعلم α ، بل يتم تغيير قيمة هذا المعامل في كل تكرار للشبكة، وتهدف هذه العملية إلى تسريع تقارب الخوارزمية [5,7].

تعتمد خوارزمية الميل الموحد (SCG) على الدمج بين تقنيتي الميل الموحد وليفيبرغ ماركورس (Levenberg–Marquardt) بحيث تقلل كمية الحسابات المطلوبة في كل تكرار فهي ليست بحاجة إلى كل تلك الحسابات الخطية في النسخ المشابهة لها والتي تعتمد على تقنية الميل الموحد. يحسب الميل وفقاً لتقنية (SCG) وفق العلاقة التالية [7]:

$$g = J^T e(y) \quad (2)$$

حيث J هي مصفوفة المشتقات الأولى لأخطاء الشبكة مع الأخذ بالحسبان الأوزان والانحيازات. أما e فتمثل شعاع أخطاء الشبكة.

يتم تحديث أوزان الشبكة في كل تكرار وفق العلاقة الآتية [13]:

$$X_{k+1} = X_k - [J^T J + \mu I]^{-1} J^T e \quad (3)$$

حيث يمثل X_k شعاع الأوزان والانحياز الحالي، بينما يعبر المقدار $J^T e$ عن قيمة الميل الحالي، و μ معدل التعلم.

تلعب القيمة μ دوراً أساسياً في تقارب الخوارزمية، فكلما كانت قيمتها صغيرة كلما تناقصت قيمة الخطأ وبالتالي تقاربت الخوارزمية بشكل أسرع. بعد كل تكرار يتم فيه تعديل الأوزان بشكل صحيح بحيث تتخفف قيمة الخطأ، يتم إنفاص قيمة معدل التعلم، تستمر هذه العملية حتى الوصول إلى أصغر قيمة ممكنة لمعدل التعلم أو الوصول إلى قيمة الخطأ الدنيا المطلوبة.

هناك 6 بارامترات تدريب لتابع التدريب (`trainscg`) المستخدم في برنامج الماتلاب لتعديل الأوزان و هي [7,5]:

1. عدد التكرارات (`epochs`): عدد المرات اللازمة لتدريب الشبكة وتعديل الأوزان للحصول على الأوزان النهائية المناسبة للمسألة المدروسة.

2. (`Show`): يستخدم هذا المعامل لإظهار حالة التدريب (كيفية تناقص قيمة الخطأ) في كل تكرار. إذا تم وضع قيمة هذا المعامل مساوية للقيمة (`NAN`)، فإن حالة التدريب لن يتم إظهارها.

3. الهدف (`goal`): قيمة الخطأ الأدنى المطلوب الوصول إليها حتى يتم قبول قيم الأوزان كقيم نهائية.

4. الزمن (`Time`): الزمن الذي استغرقته عملية التدريب بالثواني.

5. القيمة الأصغرية للميل (`min_grad`): القيمة الدنيا للميل المسموح بالوصول إليها خلال عملية

التدريب [7].

6. معدل التعلم: هو معامل يمثل سرعة تقارب الخوارزمية أي الوصول للأوزان المناسبة. يضرب معدل التعلم

عدة مرات بسالب الميل ليحدد تغيرات الأوزان والانحياز. كلما كان معدل التعلم أكبر، كلما كان حجم الخطوة الواحدة أكبر. بالتالي، عندما يكون معدل التعلم كبير جداً، تصبح الخوارزمية غير مستقرة، بينما إذا كان معدل التعلم صغير جداً، تأخذ الخوارزمية وقتاً طويلاً حتى تتقارب (حتى الوصول إلى القيمة الأصغرية لتابع الأداء).

تتوقف عملية التدريب في إحدى الحالات الآتية [8]:

إذا تم الوصول إلى العدد الأعظمي من التكرارات المحدد من قبل المستخدم (`epochs`).

إذا انحدر تابع الأداء إلى قيمة أصغر من الهدف المطلوب الوصول إليه (`goal`).

إذا انحدر منحنى الميل إلى قيمة أقل من قيمة أصغرية محددة.

إذا أصبح زمن التدريب أكبر من الزمن المحدد للخوارزمية.

2- نظام الاستدلال العصبي الضبابي المتكيف (ANFIS):

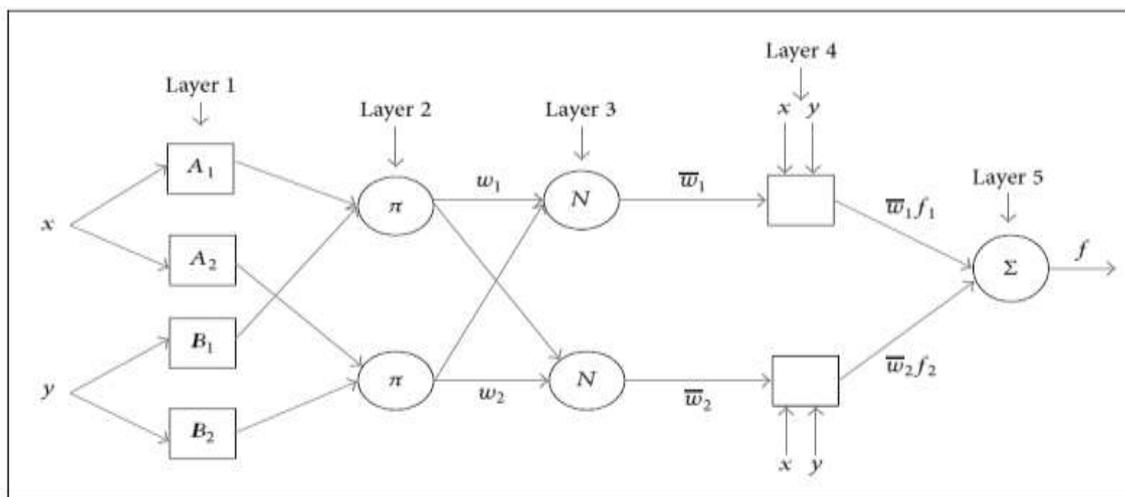
الأنظمة العصبية الضبابية هي أحد أنواع الأنظمة الذكية والتي تتكون من أنظمة الشبكات العصبية الاصطناعية والأنظمة الضبابية القائمة على المنطق الضبابي. وقد ظهرت هذه الأنواع من الأنظمة الذكية في عدة

قطاعات من مجالات الصناعة الحديثة، مثل علم صناعة الروبوت "الإنسان الآلي" وأنظمة التحكم بالصناعة ومعظم هذه الأنظمة مبنية على آلية التحكم الضبابية والتي تصف نظام معقد من العلاقات الرياضية بمجموعة من العبارات اللغوية [6].

تأتي عبارة أنظمة ضبابية من حقيقة ان معظم المشاكل في الحياة العملية هي مشاكل غير واضحة المعطيات وتوضح طبيعة الإنسان أنه قادر على القيام بوظائف متعددة بالتقريب، والفكرة هنا القدرة على تلخيص كمية هائلة من المعطيات والبقاء قادراً على حل المشاكل بفعالية [12].

مبدأ عمل هذه الأنظمة قائم على افتراض أن مجموعة من المدخلات والمخرجات معطاة ونود إنشاء نظام ضبابي لتقريب هذه البيانات، يتكون النظام من مجموعة من الاقتترانات التي تبين نسبة الانتماء إلى توابع العضوية membership functions ومجموعة من القواعد ذات المتغيرات القابلة للتعديل لتضبط هذه الاقتترانات. الهدف من خاصية التكيف هو إنشاء نظام ضبابي محسن وهو عبارة عن القدرة على تحويل المعرفة إلى مجموعة من القيود والقدرة على إنشاء شبكة قادرة على التعديل الذاتي لعناصرها. وبالرغم من هذه الخصائص فإن هذه الأنظمة بها بعض العيوب حيث انها ذات خرج وحيد وهذا يقلل عدد المشاكل التي يمكنها التعامل معها [9,10].

يوضح في الشكل (2) النظام العصبي الضبابي بنظام الاستدلال العصبي الضبابي المتكيف (ANFIS). ويتكون من خمس طبقات ذات انتشار أمامي ويمكن لنظام ANFIS أن يعبر عن المعرفة الخاصة بها على صيغة قواعد من الشكل IF-Then. تتكون بنية (ANFIS) من ثلاثة أجزاء رئيسية



الشكل (2) معمارية نظام ANFIS [9]

1- جزء الدخل: يتم في هذا القسم نمذجة متغيرات الدخل باستخدام توابع العضوية، يوجد العديد من توابع العضوية الضبابية التي يمكن استخدامها كتابع العضوية المثلثي أو الشبه منحرف أو الغوسي أو غيرها، حيث تسمى هذه التوابع بتوابع العضوية المرشحة، ويتم تحديد نوع تابع العضوية من قبل المستخدم حيث يختاره من بين توابع العضوية المرشحة.

2-جزء القواعد: في هذا الجزء يتم تشكيل القواعد من مجموعة توابع العضوية، وباعتبار لا يوجد اي سبب مسبق لاستبعاد أي مجموعة من القواعد المدمجة مع بعضها من مجموعة توابع العضوية وبالتالي سيتم تشكيل جميع مجموعات القواعد الممكنة من الشكل IF-Then [13].

3-جزء الخرج: في هذا الجزء سيتم تشكيل المخارج باستخدام مجموعات مخارج القواعد، يوجد عدد من الاحتمالات وبالتالي عملياً يوجد خيارين شائعين: الأول هو أن الخرج سيكون عبارة عن تجميع خطي للمداخل. أما الثاني فهو استخدام تابع خرج (TSK) Takaga-Sugeno-Kang والذي يعد آلية تتيح تأثير مباشر للدخل على الخرج.

تعاني معمارية الـ ANFIS الشائعة من بعض العيوب التي تحد من أدائها مع الأنظمة العملية وخصوصاً الأنظمة اللاخطية العالية التعقيد وهي: القصور في قابلية التوسع مع الأعداد الكبيرة من متغيرات الدخل، وكذلك لا يوجد طرق مخصصة ليتم فيها اختيار تابع العضوية وعدد توابع العضوية المطلوب لكل متغير دخ ل يعتمد ذلك على المستخدم. وبالتالي ليس هناك حل لمشكلة عدد القواعد التي سيتم تشكيلها فلن يتم تشكيل القواعد حسب الحاجة، في الواقع فإن معمارية الـ ANFIS لا تقوم بأي عملية افتراض مسبق لبنية القواعد وبالتالي فإنه من المطلوب أن يتم تشكيل جميع المجموعات الممكنة من متغيرات الدخل،

3- تشخيص سرطان الثدي بالاعتماد على السمات البنيوية للأورام:

يعد تشخيص سرطان الثدي عن طريق التحليل المجهرى لعينة أو خزعة مأخوذة من المنطقة المصابة من الثدي من أكثر الطرق المضمونة من أجل التشخيص الصحيح . مع ذلك، هناك أنواع نادرة من سرطان الثدي تتطلب طرق تشخيص مخبرية متخصصة . بعد تحليل العينات المأخوذة يقوم الطبيب بالاعتماد على عدة سمات لهذه العينات من أجل الوصول إلى التشخيص النهائي ، وقد قامت جامعة ويسكونون في الولايات المتحدة الأميركية ببناء قاعدة بيانات لتشخيص أورام الثدي حيث تتكون قاعدة البيانات هذه من 699 عينة بالاعتماد على 9 سمات بنيوية وهي:

- 1- سماكة الأجمة (Clump thickness)
- 2- انتظام حجم الخلية (Uniformity of cell size)
- 3- انتظام شكل الخلية (Uniformity of cell shape)
- 4-نسبة الالتصاق الهامشي (Marginal Adhesion)
- 5-حجم ظهارة الخلية الإفرادي (Single epithelial cell size)
- 6-نسبة تعري نواة الخلية (Bare nuclei)
- 7-درجة ترقق كروماتين الخلية (Bland chromatin)
- 8-درجة طبيعية نواة الخلية (Normal Nucleoli)
- 9-درجة الانقسام الفتيلي للخلية (Mitoses)

النتائج والمناقشة:

من أجل القيام بعملية التصنيف باستخدام خوارزمية الانتشار الخلفي وكذلك باستخدام نظام الاستدلال العصبي الضبابي المتكيف تم اختيار 6 سمات من السمات التسعة لاستخدامها في عملية التصنيف حيث تم اهمال آخر ثلاثة

سمات من قاعدة البيانات وذلك بسبب قلة تأثيرها على الخرج في مرحلة التدريب للتشابه الكبير بين قيم كل سمة من السمات في جميع العينات أما السمات التي تم اختيارها في التصنيف فهي:

- 1- سماكة الأجمة (Clump thickness)
- 2- انتظام حجم الخلية (Uniformity of cell size)
- 3- انتظام شكل الخلية (Uniformity of cell shape)
- 4- نسبة الالتصاق الهامشي (Marginal Adhesion)
- 5- حجم ظهارة الخلية الإفرادي (Single epithelial cell size)
- 6- نسبة تعري نواة الخلية (Bare nuclei)

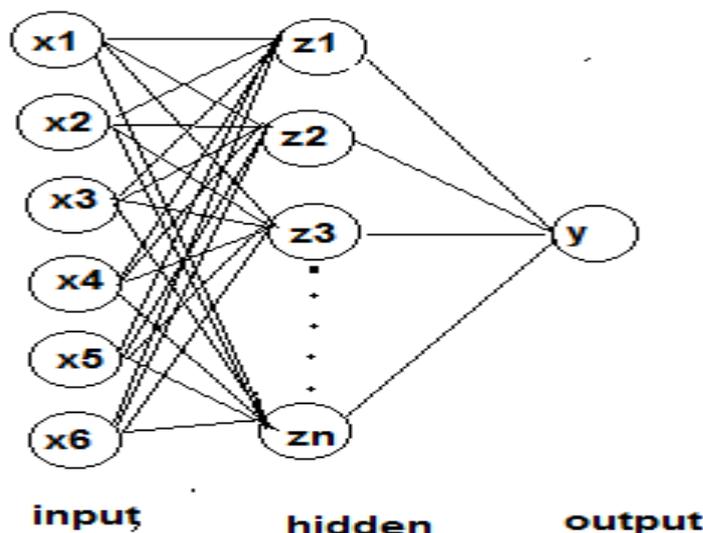
وبالتالي أصبح لدينا قاعدة بيانات تتكون من 699 عينة لكل عينة 6 سمات ، أما الخرج الذي سنحصل عليه باستخدام كلا المصنفين فهو خرج وحيد أي تصنيف الكتلة الورمية إلى سليمة أو خبيثة.

1- التصنيف للشبكة العصبية بالاعتماد على خوارزمية الانتشار الخلفي للخطأ (Back propagation)

:algorithm

تتضمن مرحلة التصنيف تغذية الشبكة العصبية بأشعة السمات لكل عينة من العينات إلى الشبكة العصبية ومن ثم تدريب الشبكة حتى تصبح قادرة على التصنيف وبعد عملية التدريب يتم تغذية الشبكة المدربة بأشعة سمات لعينات لم يتم تدريب الشبكة عليها لتعطي التشخيص كمنطقة ورمية خبيثة أو سليمة.

مواصفات الشبكة المصممة:



الشكل (3) يبين بنية الشبكة العصبية المقترحة

الشبكة مؤلفة من ستة مداخل و طبقة خفية مؤلفة من عدد من العصبونات تم تغييره لتقييم أداء الشبكة وفق الجدول (2) و خرج وحيد يأخذ قيمة 0 عند نوع الورم الحميد و 1 عند نوع الورم الخبيث. ان دخل الشبكة العصبونية هو أشعة السمات التي تتكون من 400 شعاع كل شعاع يتكون من 6 سمات توصف بنية المنطقة الورمية .

تم تقسيم قاعدة البيانات إلى مجموعة بيانات تدريب و بيانات تحقق و بيانات اختبار والجدول التالي يتضمن عدد العينات في كل مجموعة وكل من الخطأ الوسطي MS الذي يوضح متوسط الخطأ بين الخرج لعينات التدريب والهدف وكذلك نسبة الخطأ التي تبين نسبة العينات التي حدث فيها خطأ في التصنيف.

الجدول(1) مجموعات البيانات لشبكة الانتشار الخلفي

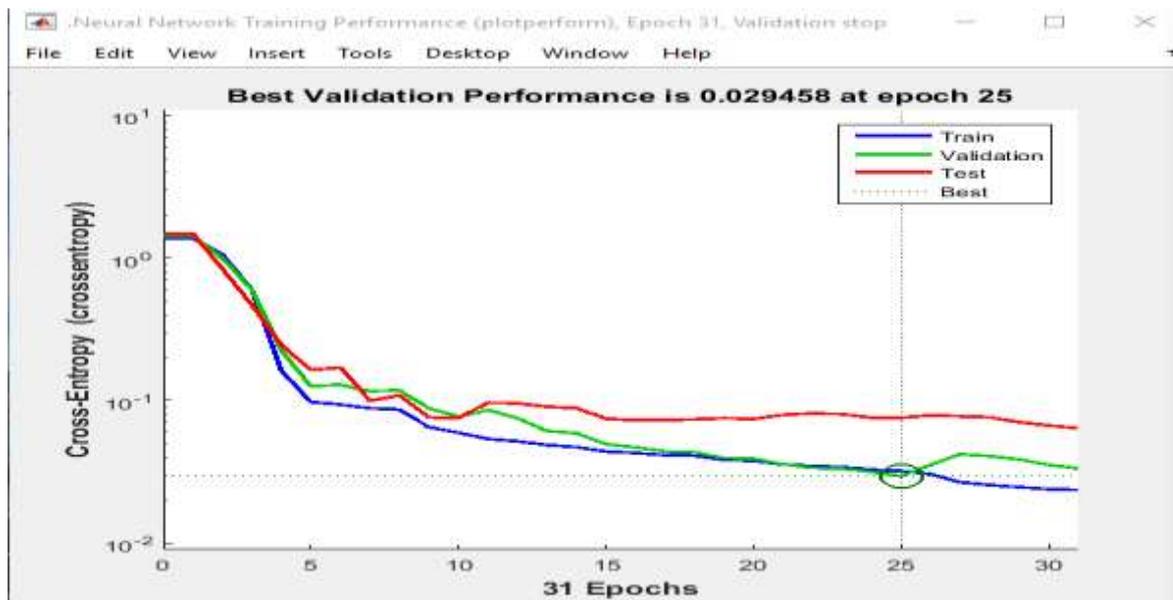
مجموعة البيانات	عدد العينات	الخطأ الوسطي MS	نسبة الخطأ E%
التدريب	400	1.05719e-2	2.61904e-0
التحقق	100	2.83389e-0	2.22222e-0
الاختبار	100	2.83422e-0	4.44444e-0

تم اختبار دقة الشبكة لخوارزمية الانتشار الخلفي للخطأ على أعداد مختلفة من التكرارات وعصبونات الطبقة الخفية والعيّنات حتى تم الوصول إلى العدد الأمثل من حيث الدقة في التصنيف والجدول التالي يوضح دقة التصنيف الناتجة حيث نلاحظ عند زيادة عدد العصبونات للطبقة الخفية بشكل كبير لم نتوصل إلى دقة أكبر بل توقفت الشبكة عن التدريب.

الجدول(2) قيم مراحل التدريب لشبكة الانتشار الخلفي

عدد العينات	زمن التدريب (بالدقائق)	عدد العصبونات للطبقة الخفية	عدد التكرارات	الدقة %
100	0:29	10	100	90
200	01:02	100	340	93.7
400	03:30	100	500	95.95
400	-	1000	100	Out of memory

ويبين الشكل التالي أن أفضل أداء لبيانات الاختبار عند اختبار تدريب الشبكة قد ظهر عند التكرار رقم 25 حيث حقق نسبة خطأ أصغر بقيمة 0.029458

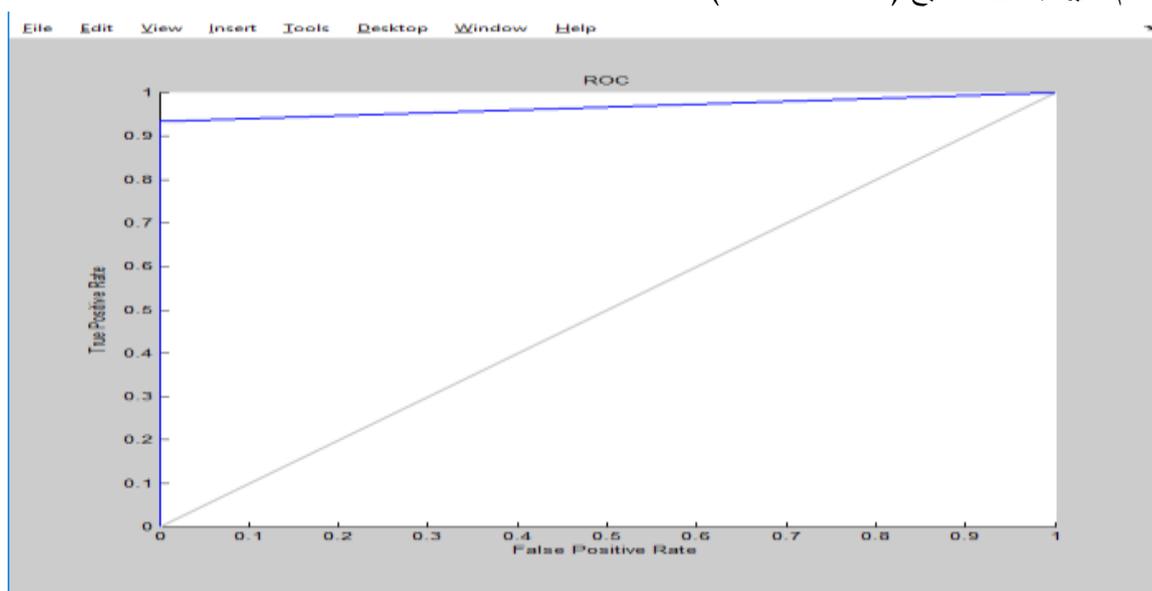


الشكل (4) أداء مجموعات البيانات بالنسبة لعمليات التكرار

1-1 اختبار أداء الشبكة العصبية الاصطناعية:

لاختبار أداء الشبكة تم إدخال مجموعة بيانات التطبيق وهي 99 عينة عشوائية متبقية من قاعدة البيانات عينات من قاعدة البيانات لم تتدرب عليها الشبكة وهي مصفوفة أبعادها 99×6 ، يوضح الشكل منحنى الأداء (ROC) للشبكة العصبية المقترحة.

يتم تحليل الأداء للمصنف من خلال منحنى الأداء (ROC Receiver operating characteristic) وهو منحنى يربط بين عدد العينات التي نسبها النظام إليه رغم أنها لا تنتمي إليه (False Positives) وعدد العينات التي تعرف النظام عليها بشكل صحيح (True Positive)



الشكل (5) منحنى ROC للشبكة العصبونية المقترحة

يمكن الملاحظة من الشكل أن المساحة تحت المنحنى أعظمية، وهذا يعني أن أداء النظام ممتاز.

الجدول التالي يوضح نتائج مجموعة بيانات التطبيق حيث:

الجدول (3) قيم إحصائيات تقييم الأداء لشبكة الانتشار الخلفي

True Positives (TP)	True Negatives (TN)	False Positives (FP)	False Negatives (FN)
69	26	4	0

True Positives (TP): عدد العينات التي صنفها النظام على أنها تنتمي إليه وهي بالفعل تنتمي إليه.

True Negatives (TN): عدد العينات التي صنفها النظام على أنها لا تنتمي إليه وهي بالفعل لا تنتمي إليه.

إليه.

False Positives (FP): عدد العينات التي صنفها النظام على أنها تنتمي إليه وهي لا تنتمي إليه حقيقة.

False Negatives (FN): عدد العينات التي صنفها النظام على أنها لا تنتمي إليه وهي تنتمي إليه حقيقة.

حقيقة.

تم التقييم أيضاً باستخدام المعايير الإحصائية للمصنفات كمايلي [11]:

الدقة (Accuracy) :

$$ACC(\%) = \frac{TP + TN}{TP + TN + FP + FN} * 100 = \frac{69 + 26}{69 + 26 + 4 + 0} * 100 = \frac{95}{99} * 100 = 95.95\%$$

الحساسية (Sensitivity) :

$$Se(\%) = \frac{TP}{TP + FN} * 100 = \frac{69}{69 + 0} * 100 = 100\%$$

التنبؤ الإيجابي (Positive predictively) :

$$Ppre(\%) = \frac{TP}{TP + FP} * 100 = \frac{69}{69 + 4} * 100 = 94.52\%$$

2 التصنيف بواسطة نظام ANFIS :

من أجل تدريب نظام الاستدلال العصبي الضبابي المتكيف تم تقسيم قاعدة البيانات الجديدة إلى ثلاث

مجموعات بيانات كمايلي (كما في المصنف السابق لانجاز عملية المقارنة):

مجموعة بيانات التدريب: 400 عينة

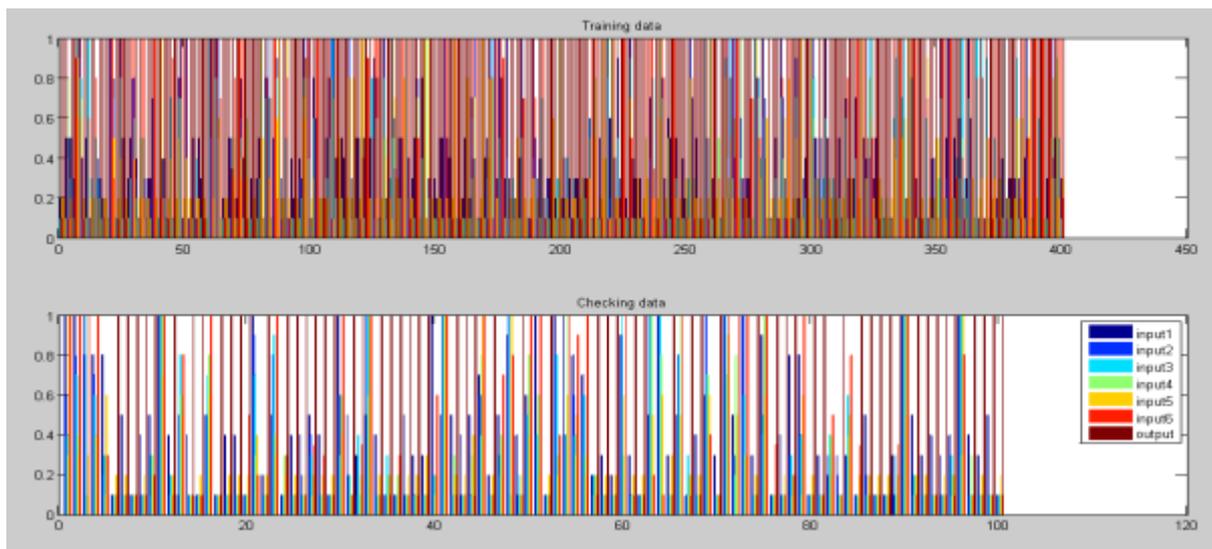
مجموعة بيانات الفحص: 100 عينة

مجموعة بيانات الاختبار: 100 عينة

أما 99 عينة الباقية فتركت من أجل إجراء تقييم أداء المصنف العصبي الضبابي والمقارنة بينه وبين أداء

خوارزمية الانتشار الخلفي بحيث تكون عينات لم يتم تدريب أي من المصنفات عليها.

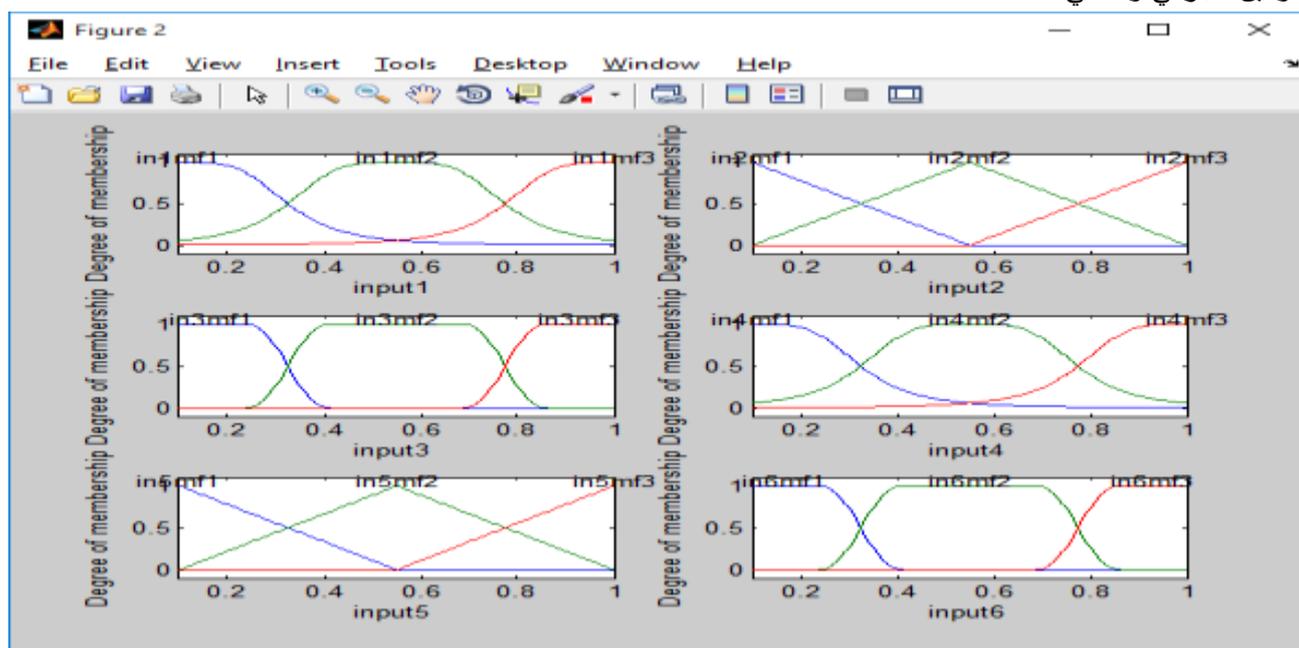
مجموعة بيانات التطبيق: 99 عينة



الشكل (6) قيم مجموعة بيانات التدريب والاختبار

تتكون الشبكة من ستة مداخل وخرج وحيد وقد تم استخدام ثلاثة توابع عضوية لكل دخل وهذه التوابع من

النوعين الجريسي والمثلثي.



الشكل (6) يبين اشكال توابع العضوية المقترحة لكل من الماخذ الستة

إن اختيار 400 عينة من أجل تدريب الشبكة لم يتم بشكل عشوائي إنما تم من خلال محاولة تدريب الشبكة على عدد أقل من العينات وبعدد تكرارات أقل وتقدير دقة الشبكة من خلال ادخال عينات اختبارية وتم في النهاية الوصول إلى أن 400 عينة هو العدد الأمثل من ناحية الدقة وبعدد تكرارات 100 وقد استغرق تدريبها 1 ساعة تقريباً والجدول 3 يوضح محاولات تدريب الشبكة بعدد عينات أقل مع عدد التكرارات وزمن التدريب بالدقائق والدقة التي تم الوصول إليها

الجدول (4) قيم مراحل التدريب للشبكة العصبية الضبابية

عدد العينات	زمن تدريب الشبكة (بالدقائق)	عدد التكرارات	الدقة %
100	16:10	100	81
200	30:11	340	83.666
300	44:50	500	85.1
400	57:12	1000	91.9

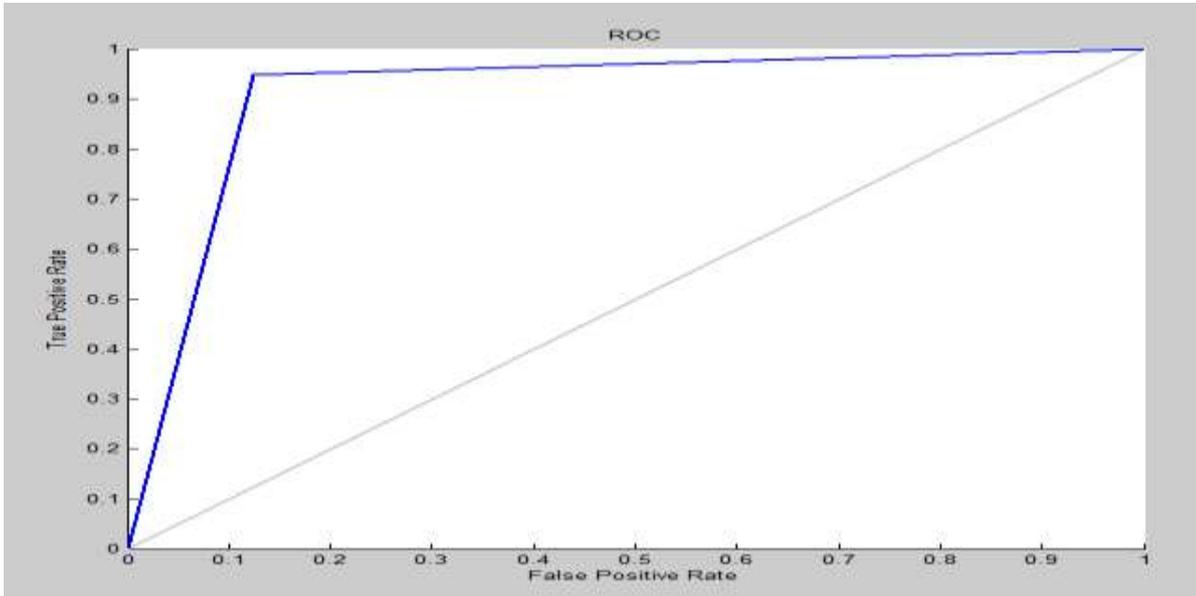
بعد تدريب نظام الاستدلال العصبي الضبابي ب 400 عينة تم الوصول إلى قيم أخطاء مقبولة في عملية التدريب والجدول (5) يوضح قيم كل من خطأ التدريب الذي تم الوصول إليه وخطأ الاختبار والخطأ الكلي لمرحلة التدريب.

الجدول (5) أخطاء التدريب للشبكة العصبية الضبابية

0.001998	خطأ التدريب (Training error)
0.0196	خطأ الاختبار (Checking error)
0.0661	الخطأ الإجمالي للشبكة (Global error)

1-2 تقييم أداء نظام الاستدلال العصبي الضبابي المتكيف (ANFIS):

ويوضح المنحني التالي ROC اداء المصنف السابق لمجموعة بيانات التطبيق :



الشكل (7) نحني ROC لنظام الاستدلال العصبي الضبابي

حيث نلاحظ أن المساحة تحت المنحني كبيرة وهو ما يدل على أداء جيد جداً للمصنف وعند القيام بتحليل بيانات مجموعة بيانات التطبيق نجد أن القيم الإحصائية كما في الجدول التالي:

الجدول (6) قيم إحصائيات تقييم الأداء للشبكة العصبية الضبابية

True Positives (TP)	True Negatives (TN)	False Positives (FP)	False Negatives (FN)
68	23	5	3

ومن القيم السابقة يمكن حساب ما يلي:

الدقة (Accuracy) :

$$ACC(\%) = \frac{TP + TN}{TP + TN + FP + FN} * 100 = \frac{68 + 23}{68 + 23 + 5 + 3} * 100 = \frac{91}{99} * 100 = 91.9\%$$

الحساسية (Sensitivity) :

$$Se(\%) = \frac{TP}{TP + FN} * 100 = \frac{68}{68 + 3} * 100 = 95.77\%$$

التنبؤ الإيجابي (Positive predictively) :

$$Ppre(\%) = \frac{TP}{TP + FP} * 100 = \frac{68}{68 + 5} * 100 = 93.15\%$$

الاستنتاجات والتوصيات:

بمقارنة منحيي الاداء . ROC لكل من المصنف الذي يعتمد على شبكة الانتشار الخلفي والمصنف العصبي

الضبابي نلاحظ أن أداء شبكة الانتشار الخلفي أفضل حيث أن المساحة تحت المنحني أكبر وبالتالي فإن خطأ التصنيف أقل وعدد الحالات التي تم فيها تصنيف خاطئ أقل.

إن استخدام الشبكات العصبية ذات الانتشار الخلفي في التصنيف بالاعتماد على السمات البنوية للأورام أظهر قدرة أكبر في الحصول على التشخيص الصحيح من استخدام الشبكات العصبية الضبابية ويعود ذلك لكون طبيعة قيم السمات البنوية تعطي قيم أقل دقة في مرحلتي التضييب (Fuzzification) أي التحويل لقيم ضبابية وفك التضييب في الخرج (Defuzzifaction) التي يحتاجها المصنف العصبي الضبابي.

وعند المقارنة بين جدولي التدريب للعينات نلاحظ سرعة أكبر في عملية التدريب لدى شبكات الانتشار الخلفي للخطأ وذلك يعود إلى البنية الأسهل والأقل تعقيداً مقارنة بالنظام العصبي الضبابي.

كذلك عند مقارنة قيم الأداء بين المصنفين نلاحظ أن شبكات الانتشار الخلفي قد حققت دقة وصلت حتى

95.95% وهي دقة ممتازة بالنسبة لأنواع الأخرى من المصنفات بينما أقصى دقة توصل إليها المصنف العصبي

الضبابي هي 91.9% ومع ذلك يعتبر أداء جيد جداً بالنسبة للمصنفات المستخدمة في هذا المجال.

وعند مقارنة حساسية التصنيف نجد أنها أمثل في المصنف المعتمد على خوارزمية الانتشار الخلفي بينما حقق

قيمة 95.77% في المصنف المعتمد على نظام الاستدلال العصبي الضبابي.

أما عند مقارنة التنبؤ الإيجابية فنجد أنها متقاربة بين كلا المصنفين مع تفوق بسيط لمصنف شبكة الانتشار

الخلفي.

يمكن العمل على تحسين أداء المصنف العصبي الضبابي في هذا المجال من خلال تحسين خوارزميته وذلك بالعثور على طريقة لاختيار توابع العضوية بدلاً من التجريب.

المراجع:

- [1]- Ebrahim Edriss Ebrahim Ali, Wu Zhi Feng. *Breast Cancer Classification using Support Vector Machine and Neural Network*. International Journal of Science and Research (IJSR). Vol.5 No. 3, 2016, 1-6.
- [2]- K. A. Mohamed Junaid. *Classification Using Two Layer Neural Network Back Propagation Algorithm*. Circuits and Systems, Vol.1, No.7, 2016, 1207-1212.
- [3]- Htet Thazin, Tike Thein, Khin Mo. *AN APPROACH FOR BREAST CANCER DIAGNOSIS CLASSIFICATION USING NEURAL NETWORK*. Advanced Computing: An International Journal (ACIJ), Vol.6, No.1, 2015, 1-11.
- [4]- Nwaneri SC, Nwoye EO, Irurhe NK, Babatunde. *Application of Artificial Neural Networks in Breast Cancer Classification: A Comparative Study*. University of Lagos Journal of Basic Medical Sciences Vol.2, NO.1, 2014, 32-38.
- [5]- Seema Singh, Sushmitha H, Harini J and Surabhi B.R. *An Efficient Neural Network Based System for Diagnosis of Breast Cancer*. International Journal of Computer Science and Information Technologies, Vol. 5, No.3, 2014, 4354-4360.
- [6]-Pelin G.,Ahmet S.,Ainura T.,Classification of Breast Masses Using ANFIS-Based Fuzzy Algorithms:Acomparative Study.IU-JEEE,Vol.13,No.1,2013,1605-1611.
- [7]- Yasmeen M. George, Bassant Mohamed Elbagoury, Hala H. Zayed, Mohamed I. Roushd. *Breast Fine Needle Tumor Classification using Neural Networks*. IJCSI International Journal of Computer Science Issues, Vol. 9, Issue 5, No 2, 2012, 247-256.
- [8]- Sparano JA, Solin LJ. *Defining the clinical utility of gene expression assays in breast cancer*. The intersection of science and art in clinical decision-making. Vol.28, No.10, 2010, 1625–1631.
- [9]- Tamer S. Kamel, M. A. Moustafa H. *Adaptive Neuro Fuzzy Inference System (ANFIS) For Fault Classification in the Transmission Lines*. The Online Journal on Electronics and Electrical Engineering. Vol.2,No.1,2011,164-169.
- [10]-Essam A,*Cancer Diagnosis Using Modified Fuzzy Network*,Universal journal of Computer Science and Engineering Technology. Vol.1,No.2,2010,73-78.
- [11]-Marina Sokolova, Guy Lapalme. *A systematic analysis of performance measures for classification tasks*. Information Processing and Management,Vol.45,No.1, 2009, 427–437.
- [12]- Dustin N.,Ke Nie,Jeon H., Chen C.,Chih H.,Hon J., Yu O., Nalcioglu M.,Ying Su., *Selection of diagnostic features on breast MRI to differentiate between malignant and benign lesions using computer-aided diagnosis: differences in lesions presenting as massand non-mass-like enhancement*. Eur Radiol,Vol.20,No.1, 2010,771–781.
- [13]- Monireh S. Hosseini, M. Zekri. *Review of Medical Image Classification using the Adaptive Neuro-Fuzzy Inference System*. Journal of Medical Signals & Sensors.2011,49-60.