

دراسة مقارنة بين طرق تدريب الشبكات العصبونية

أم.د.م. علي أحمد عجيب *

د.م. منهل صالح المحمد **

م. ديانا حسين الحسن ***

تاريخ الإيداع 24 / 3 / 2021 . قُبل للنشر في 19 / 6 / 2021)

□ ملخص □

يعد الذكاء الصناعي من أهم المجالات العلمية التي جذبت اهتمام الكثير من الباحثين في هذا القرن، وذلك لتنوع مجالاته (كالتعلم الآلي (Machine learning) ونظم إدارة القرار (Decision Management) والتعلم العميق (Deep Learning))، وتطبيقاته في الآلات الذكية والعلوم الإدراكية وتطوير التعليم، حيث تعتبر الشبكات العصبونية من أهم فروع الذكاء الصناعي وذلك لأنها تحاكي العقلي البشري في أسلوب تعلمها واكتسابها للمعرفة. نفذت في هذا البحث دراسة مقارنة بين طرق تدريب الشبكات العصبونية الثلاث وأنظمة الشبكات العصبونية الضبابية باستخدام الحزمة البرمجية Matlab R2018b:

(Back propagation Neural Network(BPNN), Feed Forward Neural Network (FFNN), Kohen Neural Network and Adaptive Neuro-Fuzzy Inference Systems (ANFS)).

على قاعدة بيانات خاصة بمرضى السرطان، حيث أكدت التجارب أن نتائج التعرف على مرض السرطان كانت أفضل ما يمكن عند استخدام طريقة التدريب (FFNN)، كما أجريت مجموعة تجارب مقارنة بين النموذج المقترح باستخدام الشبكات العصبونية مع نفس النموذج باستخدام مصنف شجرة القرار (C5.0) ومصنف الجار الأقرب (K Nearest Neighbors) باستخدام الحزمة البرمجية Weka 3.8.4، حيث أكدت التجارب فعالية النظام المقترح، كما أجريت مجموعة من التجارب لاختبار فعالية النظام المقترح مع زيادة عدد الأشخاص (عينات التدريب)، وأكدت هذه التجارب أن زيادة عدد الأشخاص تزيد من دقة التعرف على المرضى.

كلمات مفتاحية: الذكاء الصناعي، الشبكات العصبونية، مرض السرطان.

* أستاذ مساعد _ كلية الهندسة المعلوماتية _ أكاديمية الأسد للهندسة العسكرية .

**مدرس _ كلية الهندسة المعلوماتية _ أكاديمية الأسد للهندسة العسكرية .

*** طالب ماجستير _ كلية الهندسة المعلوماتية _ أكاديمية الأسد للهندسة العسكرية .

A Comparative Study of Neural Network Training Methods

Ali Ahmed Ajeeb*

Manhal Saleh Al-Muhammad **

Diana Hussein Al-Hassan ***

(Received 24 / 3 /2021 Accepted 19 / 6 /2021)

Abstract

Artificial intelligence is one of the most important scientific fields that have attracted the interest of many researchers in this century, due to the diversity of its fields (such as machine learning, decision management systems and deep learning) and its applications in smart machines, cognitive sciences and educational development.

Where neural networks are considered one of the most important branches of artificial intelligence, because they simulate the human mind in the way they learn and acquire knowledge.

In this paper, a comparative study among of three neural network training methods was implemented using Matlab R2018b software package:

(Back propagation Neural Network (BPNN), Feed Forward Neural Network (FFNN) and Kohen Neural Network) on a database of cancer patients, where the experiments confirmed that the results of cancer identification were the best possible when using the FFNN training method. A group of experiments compared the proposed model using neural networks against of the same model using the decision tree classifier (C5.0) and the (K Nearest Neighbors) classifier, using the Weka 3.8.4 software package, where experiments confirmed the effectiveness of the proposed system, then a set of experiments were conducted to test the effectiveness of the proposed system with an increase in the number of people (training samples). From the accuracy of patient identification.

Key words: artificial intelligence, neural networks, cancer.

* Doctor of informatics engineering, Al-Assad Academy of Military Engineering

** Doctor of informatics engineering, Al-Assad Academy of Military Engineering

*** Postgraduate Student ,Informatics College, AL-Assad Academy, For Military Engineering

1- مقدمة: (Introduction)

تُعدُّ الشبكات العصبونية علماً قائماً بحد ذاته ويعرف بأنه فرع من فروع الذكاء الاصطناعي، حيث اهتم به العلماء لسنوات عديدة بهدف الوصول إلى طريقة أشبه ما تكون بطريقة الإنسان في التعلم مستخدماً في ذلك خوارزميات وأساليب برمجية مختلفة.

وضع العالمان Pitts and McCulloch المفهوم الأول للشبكات العصبونية عام 1943، ووفق هذا المفهوم تتكون الأنظمة العصبية من عدد من العصبونات البسيطة التي تعتبر المصدر الرئيسي في زيادة القدرات الحسابية، حيث تم تطويرها من قبل العالمان (Kohonen and Anderson)[1].

نشر (MA Mazurowski, PA Habas, JM Zurada and JY Lo) في عام 2008 بحثاً بعنوان "دراسة تأثير عدم التوازن الطبقي في بيانات التدريب عند تطوير مصنفات الشبكة العصبونية للتشخيص الطبي بمساعدة الكمبيوتر"، ووفق هذا البحث تم التحقق من أنه يوجد بارامترات مختلفة متعلقة بالبيانات الطبية تؤثر بشكل كبير على معدل تدريب الشبكة العصبونية، وهي حجم عينة التدريب وعدد عناصر شعاع الميزات والارتباطات بين هذه الميزات، واكتشفت طريقتين لتدريب الشبكة العصبونية (Backpropagation (BP) and particle Swarm Optimization (PSO))، وأجريت دراسة تجريبية لتقييم عمل هاتين الطريقتين، وذلك باستخدام بيانات سريرية حقيقية لتشخيص سرطان الثدي، حيث أظهرت النتائج أن أداء المصنف يتناقص مع عدم التوازن الطبقي لبيانات التدريب، كما اتضح أن BP هي الأفضل بشكل عام من PSO في حالة استخدام بيانات التدريب غير المتوازنة (خاصة مع عينة البيانات الصغيرة وعدد كبير من الميزات)[2].

قام الباحث (مناهل عبد الكريم يوسف) في عام 2010 بنشر "دراسة مقارنة بين طرق تدريب الشبكات العصبونية على قاعدة بيانات لتميز الأرقام الإنكليزية المطبوعة"، حيث نفذت الدراسة على أربع شبكات عصبونية وهي:

(Kohen, Hopfield, Backpropagation and Adaline Neural Networks)

ووفق نتائج المقارنة لوحظ أن قدرة التمييز لا تعتمد على تعقيد بنية الشبكة أو على عدد الطبقات، وإنما يعتمد على زيادة عدد أنماط التدريب وتنوعها [3].

قام (F Amato, A López, EM Peña-Méndez, P Vaňhara, A Hampl and J Havel) في عام 2013 بنشر بحث بعنوان "الشبكات العصبونية الاصطناعية في التشخيص الطبي"، حيث تمت مناقشة مشكلة تبسيط عملية التشخيص في الروتين اليومي وتجنب خطأ التشخيص واستخدام أساليب خاصة للتشخيص بمساعدة الكمبيوتر والشبكات العصبونية، حيث أن خوارزميات التعلم التكيفي يمكن أن تتعامل مع أنواع مختلفة من البيانات الطبية ودمجها وتصنيف النتائج، حيث تم الوصول إلى أن الشبكات العصبونية قادرة على معالجة كم كبير من البيانات، وتقليل وقت التشخيص، وانها مناسبة لتشخيص مختلف الأمراض [4].

قام الباحثان (Jasmina D Novakovic and Alempije Veljovic) في عام 2017 بنشر بحث لتصميم شبكة عصبونية اصطناعية تعتمد على خوارزمية (BPNN) لتشخيص أورام الثدي، وكذلك تصميم مصنف للتشخيص باستخدام (ANFIS) Adaptive Neuro Fuzzy Inference System، وقد اعتمدت كلتا الدراستين على السمات البنوية للخزعة الموجودة في قاعدة البيانات لصور الثدي في جامعة ويسكونسون في الولايات المتحدة الأمريكية "Wisconson Brest Cancer dataset"، حيث أجريت مقارنة بين الدراستين من أجل التشخيص الحميد

والخبث للكتل السرطانية لسرطان الثدي، و حصلت الدراسة الأولى التي تعتمد على خوارزمية (BPNN) على دقة 95.95 % بينما حصلت الدراسة الثانية التي تعتمد على خوارزمية Adaptive Neuro Fuzzy Inference System (ANFIS)

على دقة 91.9 % وهذه النتائج تعتبر هامة جداً ومساعدة إذا ما قورنت بالأبحاث المعتمدة على السمات الشكلية المأخوذة من الصور لأجهزة متنوعة كالماموغراف والرنين المغناطيسي[5].

قام الباحثان (Jasmina D Novakovic and Alempije Veljovic) في عام 2017 بحل مشاكل التصنيف الطبي باستخدام الشبكة العصبونية Radial Basic Function (RBF) وطرق التصفية (تخفيض عدد الميزات واختيار الأفضل)، قيم هذا البحث دقة تصنيف الشبكة العصبونية (RBF) وطرق التصفية لاختيار الميزات في مجموعات البيانات الطبية، وإمكانية تحسين أداء النظام قواعد التعلم الاستقرائي مع الشبكة العصبونية RBF مشاكل التصنيف الطبي، باستخدام طرق التصفية لتحديد الميزات. فكان الهدف من هذا البحث تقديم ومقارنة نهج الخوارزمية المختلفة لنظام البناء الذي يتعلم من التجربة ويتخذ القرارات والتنبؤات ويقلل من العدد أو النسبة المئوية للأخطاء المتوقعة [6].

قامت الباحثة (هديل صادق أحمد) في عام 2018 بنشر بحث بعنوان "تصنيف مجموعات البيانات الطبية باستخدام خوارزمية الشبكات العصبونية"، حيث أخذت مجموعات بيانات طبية لنتائج التحليل السريرية لعدد من الحالات وتطبيق الخوارزميتين (MLP(Multilayer Perception) and RBF) لتدريب شبكة العصبونية، بالاعتماد على تقسيم البيانات الى مجموعتين(مجموعة التدريب ومجموعة الاختبار) أظهرت النتائج اختلاف متوسط مربعات الخطأ كمقياس لجودة التصنيف مع اختلاف طريقة التدريب والاختبار [7].

2- أهمية البحث:

تتلخص أهمية البحث في النقاط التالية:

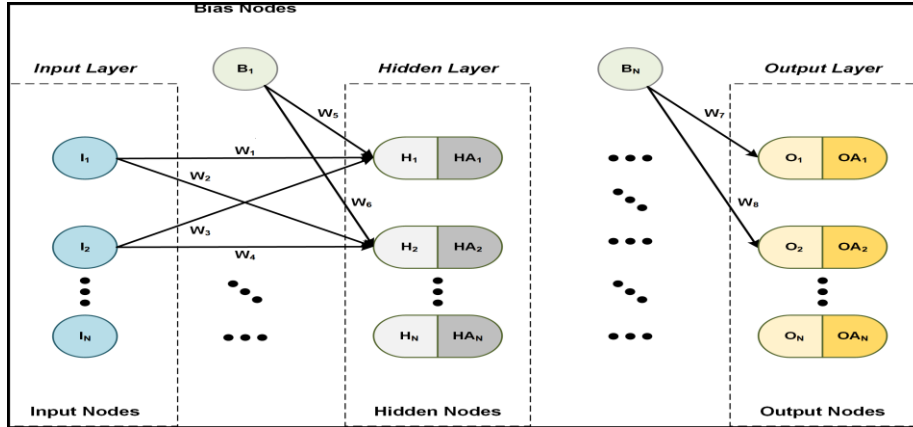
- (1) التعرف على الشبكات العصبونية ومقارنة طرق تدريبها.
- (2) دعم القرار في التعرف على مرضى السرطان.
- (3) اختبار الطريقة المقترحة على قاعدة بيانات عالمية خاصة بمرضى السرطان ، وأعطت نتائج مشجعة.

3- أنواع الشبكات العصبونية الاصطناعية التي تمت الدراسة المقارنة عليها:

تتكون الشبكات العصبونية الاصطناعية من عدة أنواع، سيتم التركيز في هذا البحث على ثلاث أنواع من الشبكات العصبونية بالإضافة الى الأنظمة العصبونية الضبابية القابلة للتكيف (Adaptive Neuro-Fuzzy Inference System)

3-1- الشبكة العصبونية ذات التغذية الأمامية (FFNN):

تعتبر من الشبكات التي تتدرب بمعلم (Supervised)، وأغلب مجالات استخدامها في الرؤية الحاسوبية وفي السيارات ذاتية القيادة وفي مجال التعرف على الصوت، يمكن توضيح البنية الهندسية لهذه الشبكة بالشكل (1) [3].



الشكل (1): البنية الهندسية للشبكة العصبونية ذات التغذية الأمامية

تتكون هذه الشبكة من ثلاث طبقات هي: طبقة الدخل input layer وطبقة مخفية hidden layer وطبقة الخرج output layer، تتكون كل طبقة من مجموعة من العقد nodes ترتبط كل عقدة بالعقد التي تليها، تقوم طبقة الدخل بتلقي الإشارة في اتجاه واحد، كما تتكون الطبقة المخفية من عدة طبقات، أما طبقة الخرج فهي المسؤولة على اتخاذ القرار.

يتم تدريب هذا النوع من الشبكات وفق المراحل الآتية [7] [3]:

1. Network Construct Network Layers();
2. Network weights Initialize Weights(Network, Problem Size);
3. for i = 1 to iterations max do
4. Pattern i Select Input Pattern (Input Patterns);
5. Output i Forward Propagate (Pattern i, Network);


3-2- شبكة الانتشار العكسي (BPNN):

هي نوع من الشبكات متعددة الطبقات التي تتدرب بمعلم (Supervised)، يتضمن تدريبها ثلاثة مراحل وهي:

- ✓ مرحلة التغذية الأمامية لأنماط الإدخال.
- ✓ مرحلة الحساب والانتشار العكسي للخطأ المتعلق بالخرج.
- ✓ مرحلة تعديل الأوزان.

بعد هذه المراحل الثلاثة تبدأ مرحلة اختبار الشبكة في طور الانتشار الأمامي. يوضح الشكل (2) البنية

الهندسية لشبكة الانتشار العكسي [8],[3].



الشكل (2): البنية الهيكلية لشبكة الانتشار العكسي.


خطوات التدريب تتم وفق المراحل الآتية [7]:

1. Network Construct Network Layers();
2. Network weights Initialize Weights(Network, Problem Size);
3. for i = 1 to iterations max do
4. Pattern i Select Input Pattern (Input Patterns);
5. Output i Forward Propagate (Pattern i, Network);
6. Back ward Propagate Error(Pattern i, Output i, Network);
7. Update Weights (Pattern i, Output i, Network, learn rate);
8. end

3-3- شبكة Kohen:

تدعى شبكات التنظيم الذاتي (SOM) Self-Organizing Map، وهي من نوع الشبكات التي تعمل بدون معلم Unsupervised، لا يوجد لها خرج محدد يقدم للشبكة كما في الشبكات السابقة، ومن خلال خصائص التنظيم الذاتي لها نجد أنها قادرة على إنتاج علاقة بين عدد من الإدخالات المقدمة لها وهذه الخاصية موجودة في الدماغ البشري [9].

تمتلك شبكة kohen طبقة واحدة للإدخال Input Layer وطبقة واحدة للخروج Output Layer كما هو موضح في الشكل (3) وهذه الطبقة ممكن أن تكون لوحدها في الشبكة أو قد ترتبط مع طبقة أخرى لشبكة عصبونية أخرى [3].



الشكل (3): البنية الهيكلية لشبكة Kohen.

خطوات التدريب تتم وفق المراحل الآتية [3] :

start : The n -dimensional weight vectors (w_1, w_1, \dots, w_i) of the m computing units are selected at random. a learning constant η , and a neighborhood function ϕ are selected.

step 1 : Select an input vector (a_1, a_2, \dots, a_n) using the desired probability distribution over the input space.

step 2 : The unit k with the maximum excitation is selected (that is, for which the distance between w_i and a_n is minimal, $i = 1, \dots, n$).


step 3 : The weight vectors are updated using the neighborhood function and the update rule $w_i \leftarrow w_i + \eta \phi(i, k) (a_i - w_i)$, for $i = 1, \dots, n$.

step 4 : Stop if the maximum number of iterations has been reached; otherwise modify η and ϕ as scheduled and continue with step 1.

3-4- أنظمة الشبكات العصبونية الضبابية (القابلة للتكيف) ANFIS

ظهرت الأنظمة الذكية في عدة مجالات للصناعة الحديثة، مثل علم صناعة الروبوت "الإنسان الآلي" وأنظمة التحكم بالصناعة ومعظم هذه الأنظمة مبنية على الية التحكم الضبابية والتي تصف نظام معقد من العلاقات الرياضية بمجموعة من العبارات اللغوية. تأتي عبارة أنظمة ضبابية من حقيقة ان معظم المشاكل في الحياة العملية هي مشاكل غير واضحة المعطيات وتوضح طبيعة الإنسان انه قادر على القيام بوظائف متعددة بالتقريب والفكرة هنا القدرة على تلخيص كمية هائلة من المعطيات والبقاء قادرا على حل المشاكل بفعالية [5].

تقوم هذه الأنظمة بافتراض أنه لدينا مجموعة من الدخل والخرج ونود إنشاء نظام ضبابي لتقريب هذه البيانات يتكون النظام من مجموعة من الاقتترانات التي تبين نسبة المشاركة (membership function) ومجموعة من القواعد ذات المتغيرات القابلة للتعديل لضبط هذه الاقتترانات. الهدف من خاصية التكيف هو إنشاء نظام ضبابي محسن أي القدرة على إنشاء شبكة قادرة على التعديل الذاتي لعناصرها. بالرغم من هذه الخصائص فان هذه الأنظمة لها بعض العيوب حيث انها ذات ناتج واحد وهذا ما يقلل عدد المشاكل التي يمكن التعامل معها، يتكون النظام من عدة طبقات كما هو موضح في الشكل (4) ولكل طبقة وظيفة محددة [5].



الشكل (4): البنية الهيكلية لأنظمة الضبابية القابلة للتكيف .

تتكون هذه الأنظمة من الطبقات التالية [5]:

الطبقة الأولى: هي الطبقة التي تتعامل مباشرة مع الدخل حيث تقوم هذه الطبقة بحساب نسبة المشاركة لمجموعة الدخل باستخدام توابع العضوية، يوجد العديد من التوابع العضوية الضبابية التي يمكن استخدامها كتابع العضوية المثلثي أو الشبه منحرف أو الغوسي أو غيرها، تسمى هذه التوابع أيضاً بتوابع العضوية المرشحة، ويتم تحديد نوع التابع من قبل المستخدم.

الطبقة الثانية: تقوم بحساب قوة القواعد الموضوعية حسب القاعدة.

الطبقة الثالثة: تقوم بحساب نسبة قوة قاعدة معينة إلى القواعد الأخرى.

الطبقة الرابعة: نقوم في هذه الطبقة بإضافة بعض المتغيرات الى تسلسل البيانات.

الطبقة الخامسة: هي الطبقة التي تنتج الجواب النهائي حسب المعادلة.

تقسم عملية التعلم إلى قسمين رئيسيين الأول هو التمرير الأمامي وفي هذه المرحلة يتم تعديل المتغيرات التي تحدد تسلسل البيانات في الطبقة الرابعة عن طريق حساب مربع الخطأ، أما القسم الآخر فهو التمرير الخلفي وبحسب التسمية المطلقة عليه فان التسلسل يكون عكسياً من الناتج إلى الدخل وفي هذه المرحلة يتم تعديل المتغيرات في القواعد بحساب نسبة المشاركة الموجود في الطبقة الأولى من الشبكة.

(ملاحظة: تعاني معمارية ال ANFIS الشائعة من بعض العيوب التي تحد من أدائها مع الأنظمة

العملية وخصوصاً الأنظمة اللاخطية عالية 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 دخل يعتمد على المستخدم، في الواقع فان معمارية ال ANFIS لا تقوم بأي عملية افتراض مسبق لبنية القواعد وبالتالي فإنه من المطلوب أن يتم تشكيل جميع المجموعات الممكنة من متغيرات الدخل).

4- المناقشة و نتائج التجارب: (Discussion and Experimental Results)

لتقييم النموذج المقترح، تم تنفيذ بعض التجارب باستخدام الحزمة البرمجية Matlab R2018b على حاسب مكتبي بالمواصفات التالية:

المعالج: Intel® Core™ i3-7100 CPU @ 3.90 GHz

الذاكرة المثبتة (RAM): 4GB

نظام التشغيل: 64Bit

تعطى دقة التصنيف وفق المعادلة التالية:

$$\text{Accurecy} = \frac{\text{Correct Samples}}{\text{All Samples}} \times 100 \dots \dots \dots (1)$$

حيث Correct Samples عدد العينات الصحيحة، All Samples عدد العينات الكلية.

يعطى الخطأ المرتكب وفق المعادلة التالية:

$$\text{Error} = \sum (y_t - y_c)^2 \dots \dots \dots (2)$$

حيث y_c هي قيمة الخرج المحسوبة، y_t الناتج الصحيح أو الهدف (Target).

نفذت مجموعة من الاختبارات على قاعدة البيانات الخاصة بمرضى السرطان، بغية المقارنة بين طرق تدريب الشبكات العصبونية الثلاث الآتفة الذكر.

إن قاعدة البيانات الخاصة بمرضى السرطان المستخدمة في هذا البحث تحتوي اشعة الميزات المستنبطة من مرحلة استخلاص السمات ويمكن تضمينها في Matlab R2018b من خلال التعليمة التالية [10].

[x,t] = ovarian_dataset;

حيث يمثل كل عمود في x مريض واحد من 216 مريض مختلف يمثل كل صف في x مستوى كثافة الأيونات يوجد 100 كتلة محددة لكل مريض، يحتوي المتغير t على صفين من 216 قيمة كل عمود منها إما [0-1] تشير إلى مريض بالسرطان أو [1-0] للمريض العادي.

1-4 التجربة الأولى:

تم في هذا الاختبار تدريب الشبكة العصبونية للكشف عن السرطان من بيانات قياس الطيف الكتلي في ملفات التعريف البروتينية للأشخاص، باستخدام ثلاث طرق للتدريب.

يوضح الجدول (1) نتائج تدريب الشبكة العصبونية ذات التغذية الأمامية (FFNN) مع تغيير عدد عصبونات الطبقة الخفية، حيث يوجد عصبونين في طبقة الخرج.

الجدول (1): نتائج تدريب شبكة الانتشار الأمامية مع تغيير عدد العصبونات

Time	(Performance)	patternnet(N)
0:00:01	93.1%	N=3
0:00:01	95.8%	N=7
0:00:01	93.1%	N=21
0:00:01	88.9%	N=100

يبين الجدول (1) أن زيادة عدد عصبونات الطبقة الخفية الى حد معين يؤدي الى تحسين الأداء في الشبكة، بعد هذا الحد نلاحظ تراجع في الاداء، بينما زمن التدريب متساوي في كل الحالات.

2-4 التجربة الثانية:

يوضح الجدول (2) نتائج تدريب الشبكة العصبونية شبكة الانتشار العكسي (BPNN) مع تغيير توابع التدريب، وذلك باعتماد ثلاث عصبونات في الطبقة الخفية وعصبونين في طبقة الخرج.

يبين الجدول (2) أن دقة الشبكة العصبونية ذات الانتشار العكسي تكون أفضل ما يكون استخدام

الجدول (2): نتائج تدريب شبكة الانتشار العكسي باستخدام توابع تدريب مختلفة

تابع


Time	Performance)	feedforwardnet(3,'-');
0:00:02	88,9%	'Trainlm' Levenberg-Marquardt backpropagation
0:00:01	94,4%	'Trainscg' Scaled Conjugate Gradient
0:00:29	91,7%	'Trainbr' Bayesian regulation
0:00:01	93,1%	'Trainrp' Resilient Propagation

التدريب "Scaled Conjugate Gradient".

3-4 التجربة الثالثة:

يبين الشكل (5) شبكة التنظيم الذاتي (SOM) التي تم إنشائها والمكونة من طبقة خفية تحتوي

عصبونين وطبقة خرج تحوي عصبونين ايضاً.



الشكل(5): شبكة التنظيم الذاتي التي تم إنشائها.

يبين الشكل (6) مصفوفة النسب المئوية للتصنيفات الصحيحة وغير الصحيحة (Confusion

Matrix).

Confusion Matrix

Output Class	1	93 43.1%	4 1.9%	95.9% 4.1%
	2	28 13.0%	91 42.1%	76.5% 23.5%
		76.9% 23.1%	95.8% 4.2%	85.2% 14.8%
		1	2	
		Target Class		


الشكل (6): مصفوفة النسب المئوية للتصنيفات لشبكة الترتيب الذاتي.

يبين الشكل السابق أن دقة أداء شبكة الترتيب الذاتي (SOM) هو 85.2%.

بناءً على النتائج التي تم الحصول عليها في المثال السابق على الأنواع الثلاثة للشبكات العصبونية، نجد أن الشبكة التي أعطت أفضل أداء هي شبكة من نوع FFNN وباستخدام 7 عصبونات للطبقة الخفية، في حين أعطت شبكة SOM أسوأ نتائج مقارنةً بالأنواع الأخرى. كما بينت التجارب أن أداء الشبكات العصبونية يزداد بازدياد عدد عصبونات الطبقة الخفية، ويتغير بتغير توابع التدريب.

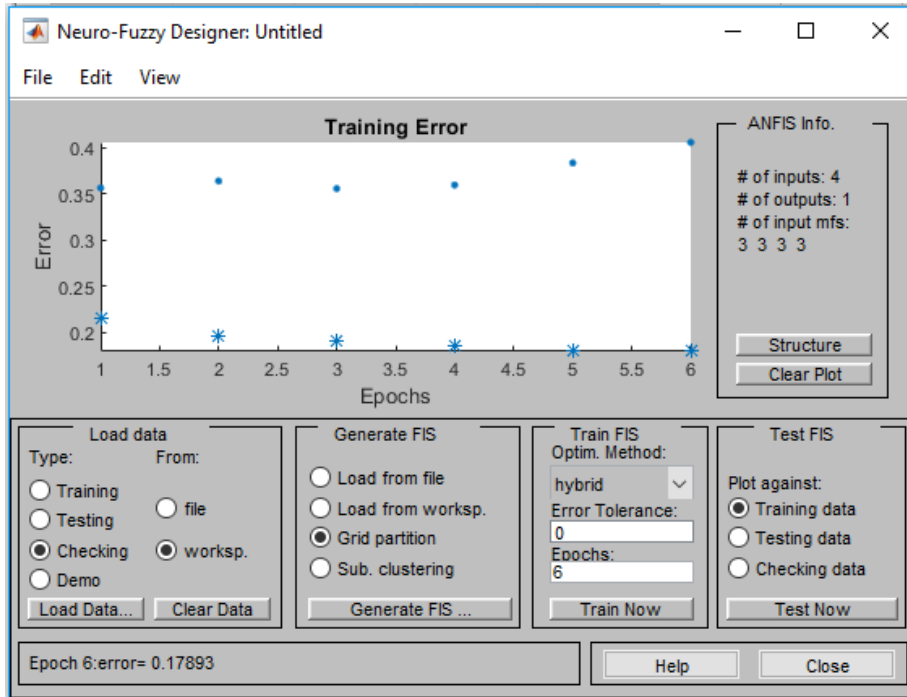
4-4 التجربة الرابعة:

تم في هذا الاختبار تدريب شبكة الأنظمة العصبية الضبابية القابلة للتكيف (ANFIS) للكشف عن السرطان من بيانات قياس الطيف الكتلي في ملفات التعريف البروتينية للأشخاص، وباستخدام 50% من قاعدة البيانات في مرحلة التدريب و50% في مرحلة الاختبار. يوضح الشكل (7) البنية الهيكلية للشبكة العصبية الضبابية المطلوب تدريبها للكشف عن مرضى السرطان



الشكل (7): البنية الهيكلية للشبكة العصبية الضبابية

يمكن تعديل اعدادات التدريب وتوابع العضوية للشبكة المقترحة عن طريق واجهة تدريب الشبكة الموضحة في الشكل (8).



الشكل (8): واجهة تدريب الشبكة العصبونية الضبابية.

يوضح الشكل السابق أن دقة أداء شبكة (ANFIS) بعد التدريب هو 82.107% ونسبة الخطأ هو 0.17893 وهي دقة جيدة .

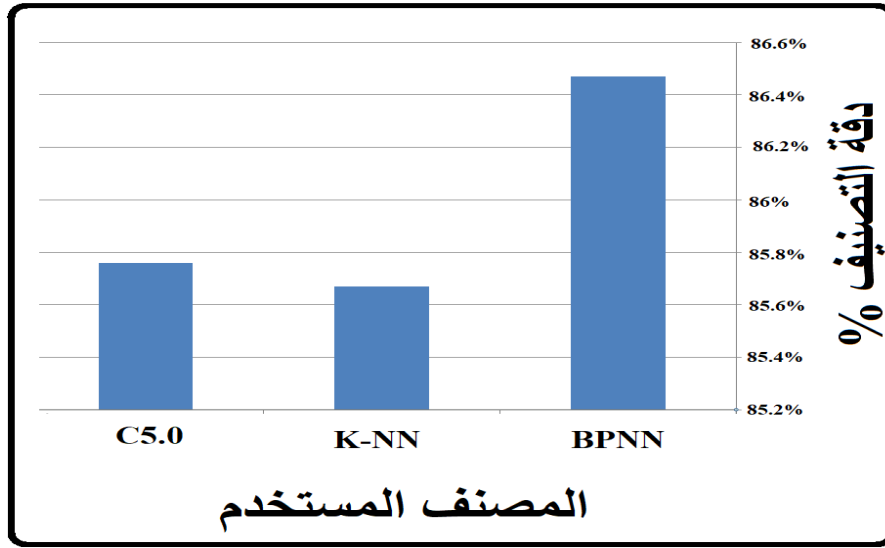
5- دراسة مقارنة: (Comparative Study)

أجريت باستخدام الحزمة البرمجية Weka 3.8.4 مجموعة من التجارب على قاعدة البيانات السابقة الخاصة بمرضى السرطان بغية تقييم النموذج المقترح وذلك بتغيير نوع المصنف حيث تم مقارنة استخدام ثلاث أنواع من المصنفات وهي:

Back propagation Neural Network, K-nearest neighbors and Decision Tree

C5.0

استخدم 60% من قاعدة البيانات في مرحلة التدريب (بناء الموديل) و40% في مرحلة الاختبار والتقييم. يبين الشكل (9) نتائج مقارنة دقة النموذج في الحالات الثلاث السابقة:



الشكل(9): دقة النموذج المقترح في حال استخدام ثلاث مصنفات مختلفة.

بينت نتائج الاختبار أن دقة التمييز للنموذج المقترح في حال استخدام الشبكات العصبونية (86.47%) أفضل منها في حال استخدام مصنفي الجار الأقرب (K-NN) (85.67%) وشجرة القرار (C5.0) (85.76%)، إلا أن زمن بناء الموديل الذي يستخدم الشبكات العصبونية (5.5Sec) أكبر من زمن بناء كلا الموديلين الجار الأقرب (0.01Sec) وشجرة القرار (0.01Sec)، كما يبين الجدول (3).


مجموعة التجارب النظام بالاعتماد بالشبكات

المصنف (Classifier)	الزمن (Time)
Back propagation Neural Network	5.5Sec
K-nearest neighbors	0.01Sec
Decision Tree C5.0	0.01Sec

كما نفذت من على المقترح على العصبونية

(Back propagation Neural Network) مستخدمين عصبونين في الطبقة الخفية وعصبون في طبقة الخرج، وباستخدام 60% من قاعدة البيانات في مرحلة التدريب و 40% في مرحلة الاختبار بغية دراسة استقراره النظام

المقترح مع تغيير عدد الأشخاص. يبين الشكل (10) نتائج هذه التجارب.



الشكل(10): تغيرات دقة تمييز النموذج المقترح باستخدام BPNN مع تغير عدد الأشخاص.

يوضح مخطط نتائج التجربة السابق أن دقة تمييز مرضى السرطان مستقرة ضمن مجال محدد لعدد الأشخاص وتتزايد بشكل ملحوظ مع زيادة عدد الأشخاص أكثر من 150 شخص، وهذا يدل على أن السمات المستخدمة في قاعدة البيانات فريدة في تمييز المرضى، كما أن الشبكة العصبونية BPNN تزداد دقة تعلمها مع ازدياد عينات الدخل (عدد الأشخاص).

6- الخلاصة: (Conclusion)

تم في هذا البحث دراسة مشكلة التعرف على مرضى السرطان باستخدام الشبكات العصبونية، حيث تم تنفيذ دراسة مقارنة بين طرق تدريب الشبكات العصبونية الثلاث (BPNN, FFNN and Kohen Neural Network) على قاعدة بيانات خاصة بمرضى السرطان.

أكدت النتائج التجريبية أن نتائج التعرف على مرضى السرطان كانت أفضل ما يمكن عند استخدام طريقة التدريب (FFNN)، كما أجريت مجموعة تجارب مقارنة بين النموذج المقترح باستخدام الشبكات العصبونية مع نفس النموذج باستخدام مصنف شجرة القرار (C5.0) ومصنف الجار الأقرب (K Nearest Neighbors) حيث أكدت التجارب فعالية النظام المقترح، كما أجريت مجموعة من التجارب لاختبار فعالية النظام المقترح مع زيادة عدد الأشخاص، وأكدت هذه التجارب أنه مع زيادة عدد الأشخاص (عينات التدريب) تزداد دقة التعرف على المرضى.

-7 المراجع: (References)

- [1] ELAINE R. and KEVIN K., June (2010), *AI Course lecture*, pp. 37-38, www.myreaders.info, e-mail rcchak@gmail.com.
- [2] MAZUROWSKI M., HABAS A. and ZURADA M., (2008), *Training neural network classifiers for medical decision making*, the official journal of the International Neural Network Society.
- [3] Abdel Karim Youssef M., (2010), *A comparative study between artificial neural networks (distinguishing printed English numbers)* University of Mosul, College of Dentistry.
- [4] AMATO F., LOPEZ A., MENDEZ M., VANHARA P. and HAVEL J., (2013), *Artificial neural networks in medical diagnosis*.
- [5] Dr. Ahmed Eid B., (2017), *A comparative study between the performance of neural networks and the adaptive fuzzy neural inference system in diagnosing breast cancer based on structural features*, Tishreen University Journal for Research and Scientific Studies.
- [6] JASMINA D., NOVKOVIC N. and ALEMPIJE V., (2017), *Solving medical classification problems with RBF neural network and filter methods*.
- [7] Sadiq Ahmed H., (2018), *Classification of medical data groups using neural networks algorithm*, Administrative Technical College, Baghdad, Central Technical University.
- [8] WASSERMAN D., (1989) *Neural computing theory and practice*, Van Nostrand Reinhold, New York.
- [9] Issa, Zaki A., (2000), *Neural Networks*, Shuaa Publishing and Media.
- [10] Ahmed Y., Shboul, (2004), *Applications of Matlab in Neural Networks*, Dar Al-Hamid for Publishing and Distribution, Amman, Jordan.