

Detection of citrus diseases using a fuzzy neural network

Huda Saad Taher^{1*}, Baydaa I. Khaleel²

^{1*}College of Medicine, University of Mosul, Mosul, Iraq

²Department of Computer Science, College of Computer Science and Mathematics, University of Mosul, Mosul, Iraq

E-mail: ^{1*}hstahez2020@gmail.com, ²baydaaibraheem@uomosul.edu.iq

(Received July 27, 2021; Accepted September 15, 2021; Available online December 01, 2021)

DOI: [10.33899/edusj.2021.130928.1179](https://doi.org/10.33899/edusj.2021.130928.1179), © 2021, College of Education for Pure Science, University of Mosul.

This is an open access article under the CC BY 4.0 license (<http://creativecommons.org/licenses/by/4.0/>)

Abstract

The objective is to use AI techniques to build a citrus image recognition system and to produce an integrated program that will assist plant protection professionals in determining whether the disease is infected and early detection for the purpose of taking the necessary preventive measures and reducing its spread to other plants. In this research, the RBF and FRBF networks were used and applied to 830 images, to detect whether citrus fruits were healthy or ill. At first, the preprocessing of these images was done, and they were reduced to 250 x 250 pixels, and the features were extracted from them using the co-occurrence matrix method (GLCM) after setting the gray level at 8 gradients and 1 pixel distance, 21 statistical features were derived, and then these features were introduced to RBF after determine the number of input layer nodes by 21 , 20 for the hidden layer and 1 node for output layer, the centers were randomly selected from the training data and the weights were also randomly selected and trained using the Pseudo Inverse method. The RBF network was hybridized with the fuzzy logic using the FCM method, the fuzziness parameter = 2.3 was selected, and a new network called FRBF was acquired. These networks were trained and tested in training data (660 images) and testing (170 images) for citrus fruits. The detection rate was then calculated, and the results showed that the (FRBF) had a higher accuracy of 98.24% compared to RBF of 94.71%.

keywords: Artificial neural networks, Feature extraction, FRBF, Fuzzy c-means, RBF, Texture feature.

كشف أمراض الحمضيات باستخدام الشبكة العصبية المضببة

هدى سعد ظاهر^{1*}، بيداء ابراهيم خليل²

قسم علوم الحاسوب، كلية علوم الحاسوب والرياضيات، جامعة الموصل، الموصل، العراق
كلية الطب، جامعة الموصل، الموصل، العراق

الملخص

يهدف البحث إلى استخدام تقنيات الذكاء الاصطناعي لبناء نظام تمييز صور نباتات الحمضيات وإنتاج برنامج متكامل يعد أداة مساعدة لذوي الاختصاص في مجال وقاية النباتات وذلك لتحديد هل هناك إصابة بالمرض وللكشف المبكر عنه لغرض اتخاذ الإجراءات

الوقائية اللازمة والحد من انتشاره لبقية النباتات. في هذا البحث، استخدمت شبكة دالة القاعدة الشعاعية (RBF) و شبكة دالة القاعدة الشعاعية المضببة (FRBF) وتطبيقها على مجموعة صور بعدد 830 صورة للكشف ما إذا كانت ثمار الحمضيات صحية أم مريضة. في البداية ، تمت المعالجة الأولية لهذه الصور وتحجيمها الى صور بحجم 250×250 بيكسل واستخلاص الميزات منها باستخدام طريقة مصفوفة التواجد المشترك (GLCM) بعد تحديد المستوى الرمادي بعدد 8 درجات وبمسافة بيكسل واحد ، وتم استخلاص 21 ميزة إحصائية منها ثم تم إدخال هذه الميزات إلى RBF بعد تحديد عدد خلايا طبقة الإدخال بـ(21) و الطبقة المخبئة بـ (20) خلية وخلية واحدة للإخراج وتم اختيار المراكز بصورة عشوائية من بيانات التدريب وتم اختيار الالوزان بصورة عشوائية أيضا وتدريبها باستخدام طريقة Pseudo Inverse . تم تهجين شبكة RBF بالمنطق المضبب والمتمثل بطريقة (FCM) وتم اختيار معامل التضبيب $(m) = 2.3$ وتم الحصول على شبكة جديدة سميت بشبكة Fuzzy RBF. حيث تم تدريب واختبار هاتين الشبكتين على بيانات التدريب (660 صورة) والاختبار (170 صورة) لثمار الحمضيات. ثم تم حساب الدقة، وأظهرت النتائج أن الطريقة الجديدة المقترحة (Fuzzy RBF) حصلت على دقة أعلى وهي 98.24% مقارنة مع RBF التي كانت نسبتها 94.71%.

الكلمات المفتاحية: استخلاص الميزات، الشبكات العصبية الاصطناعية، المنطق المضبب، شبكة دالة القاعدة الشعاعية، شبكة دالة القاعدة الشعاعية المضببة، ميزات النسيج.

1. المقدمة

تتأثر زراعة الحمضيات بمجموعة متنوعة من العوامل الحيوية مثل الأمراض الناتجة عن البكتيريا والفطريات والفيروسات وغير الحيوية مثل: الماء ودرجة الحرارة والعوامل البيئية الأخرى[1]. في العقد الماضي، استخدم باحثون مختلفون تقنيات معالجة الصور والتعرف على الأنماط في التطبيقات الزراعية. النهج الأساسي لكل هذه التقنيات هو نفس النهج. أولاً، يتم الحصول على الصور من البيئة باستخدام كاميرات تناظرية أو رقمية، ثم يتم تطبيق تقنيات معالجة الصور لاستخراج خصائص مفيدة ضرورية لمزيد من التحليل للصور. وبعد ذلك، تستخدم تقنيات تمييزية مثل المصنفات الإحصائية والشبكات العصبية والخوارزميات الذكية لتصنيف الصور[2]. حيث استخدم العديد من الباحثين طرق معالجة الصور لتحسين الصور المراد تصنيفها بالإضافة إلى استعمال طريقة التقطيع لاستقطاع الجزء المراد فحصه وتصنيفه وكذلك تم استخدام العديد من طرق استخلاص الميزات ومن ثم استخدام نوع أو عدة أنواع من تقنيات التصنيف للوصول إلى الدقة المطلوبة للتصنيف. في عام 2014 استخدم العالم Kiran R. Gavhale وآخرون طريقة تقطيع الصورة (Segmentation) باستخدام K-means clustering algorithm ومن ثم استخدام طريقة مصفوفة التواجد GLCM لاستخلاص سمات الصورة لتصنيف أربع أنواع لأمراض الحمضيات وباستخدام الآلة ناقله الدعم Support Vector Machine (SVM) مع نواة القاعدة الشعاعية Radial Basis Kernel وPolynomial Kernel كمصنفين [3]. وفي عام 2016 استخدم العالم Deng Xiaoling وآخرون طرق استخلاص سمات اللون Color Feature واستخلاص سمات النسيج Texture Feature مع الشبكات العصبية من نوع شبكة الانتشار العكسي (two-stage back propagation neural network) لتصنيف خمس أنواع لأمراض الحمضيات [4]. وفي عام 2018 استخدم العالم M. Sharif وآخرون طريقة التقطيع الموزونة المثلى للصورة مع طرق استخلاص الخواص من اللون والنسيج والشكل لاوراق وثمار الحمضيات ثم تم اختيار السمات باستخدام طريقة تحليل المكونات الأساسية (PCA) واستخدموا للتصنيف طريقة الآلة ناقله الدعم المتعدد (M-SVM) [5]. وكذلك في عام 2019 استخدم العالم Ayobami I. Ojelabi وآخرون طريقة تقطيع الصورة (segmentation) مع استخلاص الخواص بطريقة استخلاص سمات اللون Color Feature

Extraction) واستخلاص سمات النسيج (Texture Feature Extraction) لتصنيف أربع أنواع لأمراض الحمضيات وباستخدام SVM كمصنف [6].

يهدف هذا البحث الى رصد إصابة ثمار الحمضيات لضمان الكشف المبكر عن الحمضيات المصابة وبالتالي الى زيادة إنتاجية المحاصيل والحفاظ على الثروة الزراعية من خلال المحافظة على صحة النبات. خطة البحث في الجزء رقم (2) سنتطرق الى شرح لبعض التقنيات المستخدمة في انظمة كشف وتصنيف أمراض الحمضيات وفي الجزء رقم (3) شرح لمصفوفة التواجد وفي الجزء رقم (4) سنتناول فيه شرحا للشبكات العصبية الاصطناعية وشبكة RBF، وفي الجزء رقم (5) شرح للعنقدة المضببة في الجزء رقم (6) النظام المقترح ثم جزء التجارب والاستنتاج.

2. التقنيات المستخدمة في انظمة كشف وتصنيف أمراض الحمضيات

بشكل عام تشمل أغلب التقنيات المستخدمة في هذه الانظمة معالجة اولية للصور، استخلاص الميزات وأخيرا المصنفات.

1.2 المعالجة الأولية

وهي الخطوة التحضيرية الهامة لتحسين التباين في الصور المدخلة (الصورة التي التقطت من أجهزة الاستشعار والكاميرات)، وهذه الصور لديها الكثير من الضوضاء بما في ذلك الخلفية السيئة، والتي تؤثر على دقة النتائج. تعمل تقنيات المعالجة الابتدائية على هذه الصور وتغيرها إلى صور محسنة مناسبة (مثلا سنحجم الصور المختارة ونقص بحيث يمكن إختبارها بكفاءة) [7]. تحتوي مرحلة المعالجة الابتدائية على العديد من العمليات مثل تحسين الصورة، وتحويل مساحة الألوان، وتحجيم الصورة. [2]

2.2 طرق إستخلاص الميزات

يتم تحليل البيانات الخام للصور من اجل الحصول على رؤية واضحة لما يحدث مع الصورة بحيث يمكن إستخدامها لاستخراج المعلومات المطلوبة. في معالجة الصور والتعرف على النمط، استخراج الميزات هو خطوة هامة، وهو شكل خاص من تقليل الأبعاد. عندما تكون بيانات المدخلات كبيرة جدا بحيث لا يمكن معالجتها، فسوف نحتاج الى عملية لتقليل حجم البيانات. تسمى عملية تحويل بيانات المدخلات إلى مجموعة من الميزات بإستخلاص الميزات، وغالبا ما تحتوي الميزات على معلومات تتعلق باللون أو الشكل أو النسيج أو السياق [8]. تم إستخدام العديد من الطرق لإستخلاص الميزات من الصور من قبل الباحثين حسب مجال التطبيق وحسب البيانات المستخدمة ومنها [9]:

- طرق استخراج الميزات المكانية Spatial features extraction
- طرق استخراج ميزات التحويل Transform features extraction
- طرق استخراج ميزات الحافة و الحدود Edge and boundary features extraction
- طرق استخراج ميزات الألوان Color features extraction
- طرق استخراج ميزات الشكل Shape features extraction
- طرق استخراج ميزات النسيج Texture features extraction

3. مصفوفة التواجد GLCM

إقترح العالم هاراليك خطوتين لإستخراج خاصية النسيج، الخطوة الأولى هي حساب مصفوفة التواجد للعناصر المترابطة، والخطوة الثانية هي حساب خاصية النسيج على أساس هذه المصفوفة [10]. هذه التقنية مفيدة في مجال واسع من تطبيقات تحليل الصور من الطب الحيوي ونظم الاسترجاع المعتمدة على الصور إلى تقنيات الإستشعار عن بعد [8]. مصفوفة التواجد للعناصر المترابطة هي أداة إحصائية راسخة لإستخلاص ميزات الترتيب الثاني للنسيج. وهي مصفوفة يكون فيها عدد الصفوف والأعمدة مساويا لعدد المستويات الرمادية المتميزة

أو قيم البيكسل في صورة ذلك السطح. وهي مصفوفة تصف تواتر مستوى رمادي واحد يظهر في علاقة خطية مكانية محددة مع مستوى رمادي آخر داخل مجال التحقيق [9]. إن مصفوفة التواجد للعناصر المترابطة واحدة من أفضل أساليب تحليل النسيج المعروفة. كل مدخل (i, j) في GLCM يتطابق مع عدد مرات حدوث زوج من المستويات الرمادية (i, j) التي تفصل بينها مسافة (d) في الصورة الأصلية [9].

4. الشبكات العصبية الاصطناعية:

استخدمت الشبكات العصبية الاصطناعية (ANN) بنطاق واسع في العديد من البحوث باعتبارها عضواً بالغ الأهمية في الذكاء الحسابي والذكاء الاصطناعي. وهي تشكل أدوات قوية لتحليل البيانات ووضع النماذج، حيث أنها تلتقط العلاقات الخطية وغير الخطية وتمثلها بدقة، وهي أداة قيمة لتقريب الوظائف، وتجميع البيانات، ومعالجة الاشارة، والتعرف على الأنماط وتصنيف الصور [11].

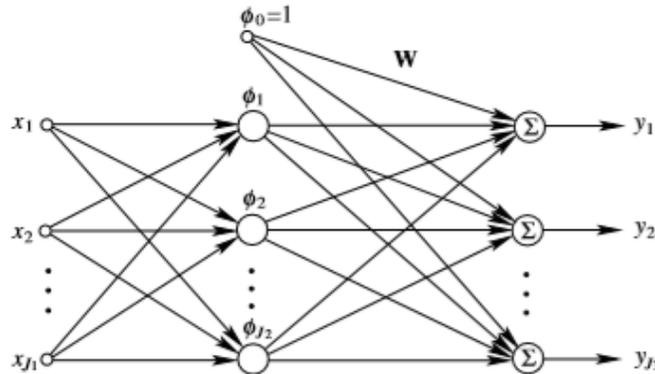
1.4. شبكة دالة القاعدة الشعاعية (RBFN) Radial Basis Functions Network

اكتسبت شبكة دالة القاعدة الشعاعية RBFN جاذبية واسعة النطاق بين الباحثين وأظهرت أداءً جيداً في مجموعة متنوعة من مجالات التطبيقات. قدمت لأول مرة من قبل الباحث "باول" وفي وقت لاحق قام برومهيدي ولوي بتطويرها وأصبحت أكثر مرونة [13][12]. تعتبر شبكة دالة القاعدة الشعاعية RBFN بديلاً قوياً لشبكة multi-layer perceptron لأنها تتميز ببساطة الهيكلية ووجود خوارزمية تعلم خطية سريعة فيها قادرة على تمثيل رسم غير خطي معقد واداء تقريب عالي [14].

2.4. معمارية شبكة دالة القاعدة الشعاعية RBFN Radial Basis Functions Network

تعتبر من شبكات التغذية الأمامية *feed forward* وتتكون من ثلاث طبقات [15]:

- طبقة الإدخال: التي تحتوي على عدد وحدات بعدد نقاط البيانات، لا يتم في هذه الطبقة اي عملية حسابية وإنما يجري فقط تمرير البيانات الى الطبقة المخفية، وتكون الوحدات في هذه الطبقة مرتبطة بالكامل مع وحدات الطبقة المخفية.
- الطبقة الثانية هي الطبقة المخفية: تتكون من عدد وحدات اقل من عدد الوحدات في طبقة الإدخال ويعتمد عددها على طبيعة التطبيق الذي يستخدم شبكة RBF ، وهي تستقبل بيانات الإدخال التي تكون غير قابلة للانفصال خطياً وتحولها الى فضاء جديد متعدد الأبعاد وقابل للانفصال خطياً. والشكل رقم (1) يمثل معمارية شبكة دالة القاعدة الشعاعية ، دالة اللياقة لهذه الطبقة تسمى Basis Functions وكل وحدة فيها لها مركز وعرض انتشار.



الشكل 1: معمارية شبكة دالة القاعدة الشعاعية [14]

- الطبقة الاخيرة هي طبقة الاخراج التي تعمل كمصنف (classifier).

3.4. التعلم للمراكز في الطبقة المخفية

لاختيار المراكز يمكن استخدام احدى الطرق التالية التي تعتبر Unsupervised Method [15]:

- اختيار مراكز عشوائية وهي طريقة سهلة وسريعة حيث يتم اختيار المراكز بطريقة عشوائية من البيانات المدخلة.
- العنقدة Clustering يتم استخدام تقنيات العنقدة العادية لاجاد مراكز الوحدات مثل طريقة C-means clustering وطريقة fuzzy c-means clustering وطريقة Self-Organized Map وغيرها من طرق العنقدة.
- طريقة التربيع الصغرى المتعامدة Orthogonal Least Squares وهو أحد النهج الدقيقة في اختيار مجموعة فرعية من نقاط البيانات كمراكز للخلايا.

4.4. التعلم للأوزان بين الطبقة المخفية وطبقة الاخراج

هناك عدة طرق لتدريب الاوزان منها [16]:

1. طريقة المعكوس الزائف Pseudo Inverse
2. طريقة مربع المعدل الاصغر Least-Mean-Square (LMS)
3. طريقة الانحدار الاكثر حدة Steepest Descent (SD)
4. طريقة الانتشار السريع Quick Propagation (QP)

5. العنقدة المضببة Fuzzy c- mean clustering

العنقدة هي عملية تجميع متجهات الميزات إلى صفوف في نمط التنظيم الذاتي وتؤدي العنقدة الضبابية دورا هاما في حل المشاكل في مجالات التعرف على الأنماط وتحديد النماذج الضبابية. خوارزمية FCM (التي طورها دون وحسنها بيزديك) هي طريقة للعنقدة تسمح لنقطة واحدة من البيانات بالانتماء إلى مجموعتين أو أكثر، وكثيراً ما تستخدم هذه الطريقة في التعرف على النمط [17]. وخوارزمية FCM مبنية على تقليل الدالة القياسية التالية:

$$j(U, v_1, v_2, \dots, v_c) = \sum_{i=1}^c \sum_{j=1}^n \mu_{ij}^m d_{ij}^2 \quad \dots \dots (1)$$

حيث

μ_{ij} بين 0 و 1

m معامل التضبيب قيمته اكبر من 1 وغالبا ما يتم تعيين قيمته بـ 2.

$$d_{ij} \text{ تمثل المسافة الإقليدية } = \|x_j - v_i\|$$

v_i مركز العنقود i

x_j نقطة الادخال

تتضمن الخوارزمية التقليدية لـ FCM الخطوات التالية [18]:

1. وضع قيم ابتدائية لمراكز العناقيد ، و قيم ابتدائية عشوائية لمصفوفة العضوية. اختيار قيمة M الذي يمثل معامل التضبيب.

$$U^{(0)} = \begin{bmatrix} \mu_{11}^{(0)} & \mu_{12}^{(0)} & \dots & \mu_{1n}^{(0)} \\ \mu_{21}^{(0)} & \mu_{22}^{(0)} & \dots & \mu_{2n}^{(0)} \\ \dots & \dots & \dots & \dots \\ \mu_{c1}^{(0)} & \mu_{c2}^{(0)} & \dots & \mu_{cn}^{(0)} \end{bmatrix} = \begin{bmatrix} \mu_1^{(0)}(x_1) & \mu_1^{(0)}(x_2) & \dots & \mu_1^{(0)}(x_n) \\ \mu_2^{(0)}(x_1) & \mu_2^{(0)}(x_2) & \dots & \mu_2^{(0)}(x_n) \\ \dots & \dots & \dots & \dots \\ \mu_c^{(0)}(x_1) & \mu_c^{(0)}(x_2) & \dots & \mu_c^{(0)}(x_n) \end{bmatrix} \quad \dots \dots (2)$$

يجب ان تحقق μ_{ij} الشروط الثلاثة

1. $0 \leq \mu_{ij} \leq 1 \quad \forall i, j$
2. $0 < \sum_{j=1}^n \mu_{ij} < n \quad \forall i$
3. $\sum_{i=1}^c \mu_{ij} = 1 \quad \forall j$

2. حساب مراكز العناقيد V بالاعتماد على قيم دالة العضوية U وحسب المعادلة التالية:

$$v_j = \frac{\sum_{i=1}^n (\mu_{ij})^m x_i}{\sum_{i=1}^n (\mu_{ij})^m} \quad \forall j = 1, \dots, c \quad \dots\dots (3)$$

3. تحديث قيم دالة العضوية للحضور على $U^{(t+1)}$ بالاعتماد على قيمة V وحسب المعادلة التالية:

$$\mu_{ij} = \left[\sum_{k=1}^c \left(\frac{d_{ij}}{d_{ik}} \right)^{\frac{2}{m-1}} \right]^{-1} \quad \dots\dots (4)$$

حيث

$$d_{ij} = \| x_i - v_j \|, \quad \forall i = 1, \dots, n, \quad \forall j = 1, \dots, c$$

4. تكرار الخطوات (2) و (3) إلى أن يتم تحقيق الحد الأدنى من القيمة J أو تكون الكتيبات من التكرار السابق مطابقة لتلك المتولدة في التكرار الحالي.

5. وأخيرا لا بد من إزالة التجزئة لتعيين كل نقطة بيانات في مجموعة محددة (أي بتحديد نقطة بيانات لمجموعة تصل درجة العضوية فيها إلى الحد الأقصى).

6. النظام المقترح

في هذا البحث تم تهجين شبكة دالة القاعدة الشعاعية القياسية بخوارزمية العنقدة المضببة وهي الـ (fuzzy c-means) والحصول على طريقة مهجنة ومقترحة جديدة سميت بشبكة دالة القاعدة الشعاعية المضببة Fuzzy Radial Basis Functions Network وهي عبارة عن شبكة RBFN مضاف لها العنقدة المضببة (Fuzzy c mean) لإختيار مراكز الخلايا في الطبقة المخفية للشبكة.

يتضمن نظام كشف وتصنيف أمراض الحمضيات المقترح كما هو موضح في الشكل رقم (2) المعالجة الاولية والتي شملت توحيد لون الخلفية وتحجيم الصور الى 250 X250 بكسل وتغيير مساحة الالوان من RGB الى GREY LEVEL ثم عملية إستخلاص الميزات بإستخدام مصفوفة التواجد (GLCM) وإستخلاص 21 ميزة من الصورة الواحدة وبعدها عملية الكشف بإستخدام الشبكة العصبية التقليدية والمضببة.

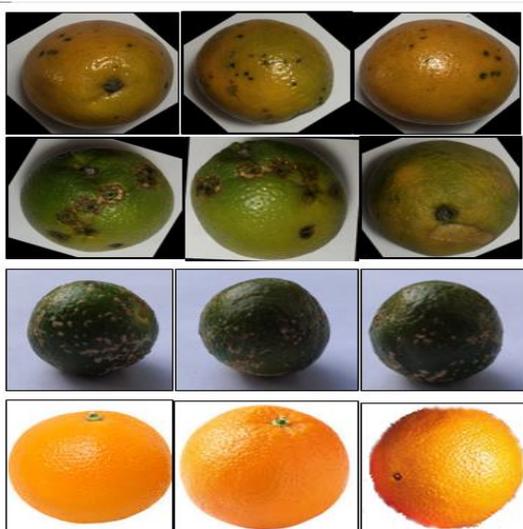


الشكل 2: المراحل الرئيسية للنظام المقترح

وقاعدة البيانات لصور ثمار الحمضيات تألفت من (830) صورة وشملت هذه البيانات صور لثمار الحمضيات السليمة والمريضة. حيث تتكون من ثلاثة أنواع لأمراض الحمضيات وثمار صحية تم تقسيمها الى 660 صورة لتدريب الشبكات العصبية الاصطناعية و 170 صورة لإختبار الشبكات. والجدول رقم (1) يوضح نماذج الصور لثمار الحمضيات السليمة والمريضة. والشكل رقم (3) يبين عينات من صور ثمار الحمضيات المجموعة المستخدمة.

الجدول 1: نماذج لمجموعة الصور لثمار الحمضيات

نماذج الاختبار	نماذج التدريب	نوع الصور
150	600	ثمار مريضة
20	60	ثمرة سليمة
170	660	المجموع الكلي



الشكل 3: عينات من مجموعة الصور المستخدمة (ثمار صحية وثمار مريضة)

تم بناء شبكة RBFN والمتكونة من طبقة ادخال بعدد خلايا 21 خلية بعدد الصفات التي تم استخلاصها من كل صورة وطبقة مخفية عدد خلاياها يساوي 20 خلية ايضا وطبقة اخراج بعدد خلية واحدة، تم إختيار مراكز الخلايا في الطبقة المخفية بإستخدام طريقة إختيار المراكز العشوائية وتم تدريب الأوزان لطبقة الإخراج بطريقة Pseudo Inverse وحسب المعادلة التالية:

$$W = (\phi * \phi^T)^{-1} * t * \phi^T \quad \dots\dots (5)$$

حيث

W مصفوفة الأوزان

t مصفوفة الإخراج الهدف

phi مصفوفة إخراج الطبقة المخفية وتحسب من معادلة كاوسين Gaussain

$$\phi(x) = \exp\left(-\frac{\|x - c_j\|^2}{2\sigma^2}\right) \quad \dots\dots(6)$$

حيث c يمثل الوزن المرتبط بالطبقة المخفية j

σ تمثل المعلمة الخاصة بالتحكم بالانتشار حول المنحني.

ويتم حساب الإخراج النهائي للشبكة من المعادلة

$$Y = W * \phi \quad \dots\dots (7)$$

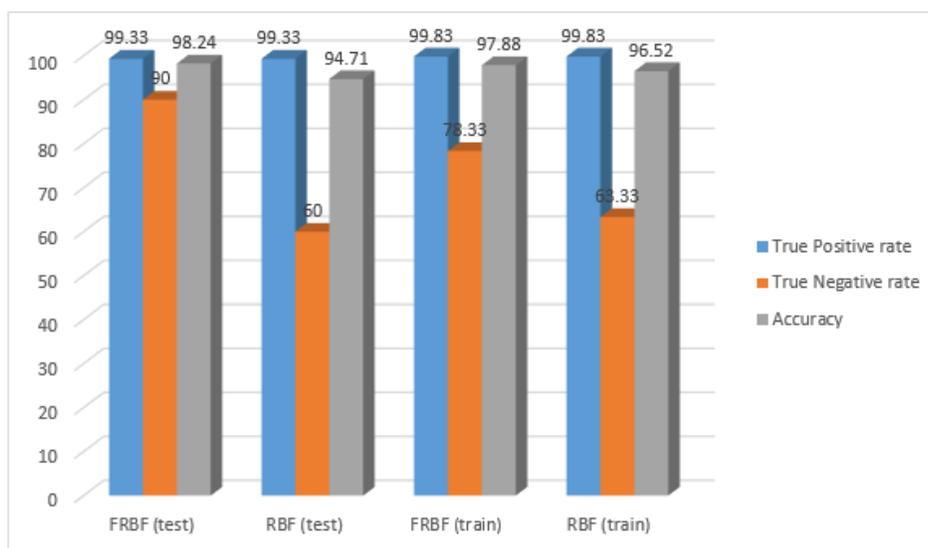
اما في الطريقة المقترحة الجديدة وهي شبكة FRBFN فبنيت أيضا من طبقة ادخال بعدد خلايا 21 خلية وطبقة مخفية عدد خلاياها يساوي 20 خلية وطبقة اخراج بعدد خلية واحدة، حيث تم إختيار مراكز الخلايا في الطبقة المخفية بإستخدام طريقة العنقدة المضببة Fuzzy C mean وبعد تحديد معامل التضبيب m=2.3 وتم تدريب الأوزان لطبقة الإخراج حسب المعادلة رقم (5) وحساب إخراج الطبقة المخفية حسب المعادلة رقم (6) وحساب الإخراج النهائي للشبكة من المعادلة رقم (7).

7. التجارب والنتائج

تم إستخدام مجموعتين من شبكة RBFN حيث شملت المجموعة الأولى شبكة RBF التقليدية للكشف عن الثمرة السليمة من بين ثمار الحمضيات المريضة والسليمة، وحصلت على نتائج دقة كشف بلغت 94.71% لمرحلة الإختبار وبنسبة 96.52% لمرحلة التدريب عند إختيار قيمة معامل الإنتشار = 3.5 وعند تحديد عدد الخلايا للطبقة المخبئة = 20 خلية. اما المجموعة الثانية فتمثلت بتنفيذ الطريقة المقترحة الجديدة وهي شبكة دالة القاعدة الشعاعية المضببة (Fuzzy-RBFN) وحصلت على نتائج دقة كشف بلغت 98.24% لمرحلة الإختبار وبنسبة 97.88% لمرحلة التدريب عند إختيار قيمة معامل الإنتشار = 3 وعند تحديد عدد خلايا الطبقة المخبئة = 20 خلية ومعامل التضبيب m=2.3. ويبين الجدول رقم (2) والشكل رقم (4) نتائج كشف الشبكتين المستخدمين في البحث.

الجدول 2: نتائج كشف الثمار السليمة والمريضة لشبكتي RBFN والطريقة المقترحة Fuzzy-RBF

Fuzzy-RBF		RBF		المقاييس
النسبة في مرحلة الاختبار	النسبة في مرحلة التدريب	النسبة في مرحلة الاختبار	النسبة في مرحلة التدريب	
%90	%78.33	%60	%63.33	نسبة الكشف السلبي True Negative Rate
%99.33	%99.83	%99.33	%99.83	نسبة الكشف الايجابي True Positive Rate
%98.24	%97.88	% 94.71	%96.52	الدقة



الشكل 4: مخطط نتائج كشف الثمار السليمة والمريضة لشبكتي RBFN والطريقة المقترحة Fuzzy-RBF

أما مقارنة النتائج مع نتائج دراسات سابقة فهي موضحة في الجدول رقم (3).

الجدول 3: مقارنة لنتائج البحث مع دراسات سابقة

اسم الباحث	الطريقة المستخدمة	نوع مجموعة الصور	دقة التصنيف
Kiran R. Gavhale وآخرون [3]	Support Vector Machine (SVM)	اوراق حمضيات	%96
Deng Xiaoling وآخرون [4]	Radial Basis Kernel- Polynomial Kernel- two-stage back propagation neural network	اوراق حمضيات	%95 %92
M. Sharif وآخرون [5]	M-SVM	اوراق وثمار حمضيات	%97
Ayobami I. Ojelabi وآخرون [6]	SVM	اوراق حمضيات	%95
النظام المقترح	RBF FRBF	ثمار الحمضيات	%94.71 %98.24

8. الاستنتاج

تم في هذا البحث استخدام GLCM لإستخلاص ميزات النسيج للصور وذلك لتسهيل التعامل مع الصور وكشفها بصورة دقيقة. واستخدمنا الشبكات العصبية الاصطناعية والمتمثلة بشبكة دالة القاعدة الشعاعية التقليدية وكذلك استخدام الطريقة المقترحة الجديدة والتي تم الحصول عليها من دمج خوارزمية شبكة دالة القاعدة الشعاعية بالمنطق المضرب والتي سميت بدالة القاعدة الشعاعية المضربة. تم استخدام هذه التقنيات للتعرف والكشف عما اذا كانت ثمار الحمضيات مريضة ام سليمة. واعطت شبكة دالة القاعدة الشعاعية المضربة نتائج دقيقة ونسبة كشف الثمار السليمة وغير السليمة عالية مقارنة بنسبة الكشف لشبكة دالة القاعدة الشعاعية التقليدية والاعمال السابقة.

9. شكر وتقدير

هذا البحث منجز لجامعة الموصل.

10. المصادر

- [1] C. N. Roistacher, *Graft-transmissible Diseases of Citrus: Handbook for Detection and Diagnosis*. Food and Agriculture Organization of the United Nations, 1991.
- [2] Z. Iqbala, M. A. Khana, M. Sharifa, J. H. Shah, M. H. ur Rehmana, and K. Javed, "An automated detection and classification of citrus plant diseases using image processing techniques: A review," *Comput. Electron. Agric.*, vol. 153, pp. 12–32, 2018.
- [3] K. R. Gavhale, U. Gawande, and K. O. Hajari, "Unhealthy Region of Citrus Leaf Detection Using Image Processing Techniques," in *International Conference for Convergence of Technology*, 2014, pp. 1–6.
- [4] X. L. Deng, Y. Bin Lan, X. Q. Xing, H. L. Mei, J. K. Liu, and T. S. Hong, "Detection of citrus huanglongbing based on image feature extraction and two-stage BPNN modeling," *International Journal of Agricultural and Biological Engineering*, vol. 9, no. 6. pp. 20–26, 2016, doi: 10.3965/j.ijabe.20160906.1895.
- [5] M. Sharif, M. A. Khan, Z. Iqbal, M. F. Azam, M. I. U. Lali, and M. Y. Javed, "Detection and classification of citrus diseases in agriculture based on optimized weighted segmentation and feature selection," *Comput. Electron. Agric.*, vol. 150, pp. 220–234, 2018.
- [6] A. I., O. I., and O. A., "Classification and Detection of Citrus Disease using Feature Extraction and Support Vector Machine (SVM)," *International Journal of Computer Applications*, vol. 177, no. 17. pp. 17–25, 2019, doi: 10.5120/ijca2019919582.
- [7] S. L. Gonzalez, Rafael C., Woods, Richard E., Eddins, *Digital Image Processing*, Second. Pearson Education, 2001.
- [8] J. Chaki and N. Dey, "Texture Feature Extraction Techniques for Image Recognition," *SpringerBriefs in Applied Sciences and Technology*. pp. 1–6, 2020.
- [9] "Texture Feature Extraction." <https://vdocuments.mx/chapter-4-texture-feature-extraction-chapter-4-texture-feature-extraction-this.html> (accessed Jun. 15, 2021).
- [10] R. M. HARALICK, K. SHANMUGAM, and D. ITS'HAK, "Textural Features for Image Classification," *IEEE Trans. Syst. Man. Cybern.*, vol. 3, no. 6, pp. 610–621, 1973, doi: 10.1190/segam2015-5927230.1.
- [11] R. E. Neapolitan and X. Jiang, *Artificial Intelligence With an Introduction to Machine Learning*. 2018.
- [12] A. Sekhon and P. Agarwal, "International Journal of Computer Science and Mobile Computing Face Recognition Using K-Means and RBFN," *International Journal of Computer Science and Mobile Computing*, vol. 6, no. 2. pp. 137–141, 2017, [Online]. Available: www.ijcsmc.com.

- [13] J. Abdulridha, Y. Ampatzidis, P. Roberts, and S. C. Kakarla, “Detecting powdery mildew disease in squash at different stages using UAV-based hyperspectral imaging and artificial intelligence,” *Biosyst. Eng.*, vol. 197, pp. 135–148, 2020.
- [14] K.-L. Du and M. N. S. Swamy, *Neural Networks in a Softcomputing Framework*. Springer-Verlag London Limited, 2006.
- [15] C. S. K. Dash, A. K. Behera, D. Satchidananda, and S.-B. Cho, “Radial basis function neural networks: a topical state-of-the-art survey,” *Open Comput. Sci.*, vol. 6, pp. 33–63, 2016.
- [16] G. A. Montazer, D. Giveki, M. Karami, and H. Rastegar, “Radial Basis Function Neural Networks: A Review,” *Comput. Rev. J.*, pp. 52–74, 2018.
- [17] J. C. BEZDEK, R. EHRLICH, and W. FULL, “FCM: THE FUZZY c-MEANS CLUSTERING ALGORITHM,” *Remote sensing. Proc. IGARSS '88 Symp. Edinburgh, 1988. Vol. 3*, vol. 10, no. 2–3, pp. 191–203, 1984, doi: 10.1109/igarss.1988.569600.
- [18] O. Kesemen, Ö. Tezel, and E. Özkul, “Fuzzy c-means clustering algorithm for directional data (FCM4DD),” *Expert Syst. Appl.*, vol. 58, pp. 76–82, 2016, doi: 10.1016/j.eswa.2016.03.034.