

Textures Recognition using Elman Neural Network

Fawziya Mahmood Ramo

Alaa Anwr Mohamed

Fawziya.ramoo@uomosul.edu.iq

College of computer science and mathematics

University of Mosul, Iraq

Received on : 26/2/2013

Accepted on : 24/6/2013

ABSTRACT

In this research building system to recognition texture images using artificial neural networks. The system consists of two phases: phase extraction important feature of each texture by using an algorithm Principal Components Analysis (PCA) and recognition phase which recognize these feature by using Elman network were trained network on a number of various texture models down to the steady-state network and then test the network by input samples of textures. The experiments show that the method achieves high performance and produces 92% recognition rate.

Key words : pattern recognition, Neural network, feature extraction, Texture images

تمييز الانسجة باستخدام شبكة أيلمان العصبية الاصطناعية

علاء أنور محمد

فوزية محمود رموا

كلية علوم الحاسوب والرياضيات، جامعة الموصل

تاريخ قبول البحث : 2013\6\24

تاريخ استلام البحث : 2013\2\26

المخلص

تم في هذا البحث بناء نظام لتمييز صور الانسجة باستخدام الشبكات العصبية الاصطناعية. يتكون النظام من مرحلتين مرحلة استخلاص الخصائص المهمة من كل نسيج عن طريق استخدام خوارزمية تحليل المركبات الاساسية ومرحلة تمييز هذه الخصائص عن طريق استخدام شبكة Elman العصبية الاصطناعية حيث تم تدريب الشبكة على عدد من نماذج الانسجة المتنوعة وصولا الى حالة استقرار الشبكة ومن ثم اختبار الشبكة بإدخال مجموعة من نماذج الانسجة وأثبتت النتائج أن الطريقة كفوءة واعطت دقة في التمييز تصل الى 92% .

الكلمات المفتاحية : تمييز الانماط ، شبكات العصبية الاصطناعية ، استخلاص الخصائص، صور انسجة

1. المقدمة

تطبيقات معالجة الصور تستخدم إما لتحسين الصور وتمهيدها ودعمها لعمليات معالجة لاحقة أو لتحليل الصور واستخلاص بعض المعلومات منها ليتمكن الحاسوب من إدراكها وتفسيرها. وقد ظهرت الحاجة إلى تحليل الصورة لاستخلاص معالمها وتحديد الأشكال فيها وتحويلها إلى بيانات ثم معالجتها، مما حفز الباحثين في هذا المجال إلى تقديم عدد من الخوارزميات المقترحة لتحديد الأشكال وتمييز الخصائص في الصورة والتي تعتمد على التطبيق المستخدم، ويرتبط تحليل الصور مع استخلاص مقاييس مفيدة أو بيانات أو معلومات عن الصورة عن طريق أجهزة وأنظمة آلية وشبه آلية والتي تشتمل على معالجة بيانات الصورة لتحديد المعلومات المطلوبة الضرورية لحل مشكلة الإبصار الحاسوبي[1].

إن مجال التمييز من المجالات الواسعة والمهمة والتي كانت محط اهتمام العديد من الباحثين في أدناه عدد

من الدراسات في هذا المجال:

في عام 2005 قام كل من Imran Sarwar Bajwa و S. Irfan Hyder من معهد كراتشي للاقتصاد و التكنولوجيا، ببناء نظام يستطيع تمييز صور الغيوم. يعتمد هذا النظام على تحليل المركبات الأساسية لاستخلاص الصفات المهمة من ثلاثة أصناف من الغيوم (قليلة، متوسطة، كثيفة) و استخدام تلك الصفات لتمييز الصور الداخلة إلى النظام[2]. في عام 2010 قدم (Y.H. Zhang) نظام ذكي لاكتشاف خلل نسيج و تمييز نوع الخلل بالاعتماد على كابور فلتر (Gabor Filter) و شبكة ايلمان العصبية (Elman Neural Network) [3]. في عام 2011 قام الباحثان (Mohd Fauzi Othman) و (Mohd Ariffanan Mohd Basri) باستخدام شبكة (Probabilistic Neural Network PNN) وخوارزمية تحليل المركبات الاساسية (Principal Component Analysis PCA) لتمييز أورام الدماغ أوتوماتيكيا [4]. وفي عام 2012 قام الباحث (Ghassem Farajpour) بتطبيق نظام لكشف وصول أجرة البريد حيث تم استخدام خوارزمية تحليل المركبات الاساسية وجعلها إدخال للشبكة العصبية الاصطناعية لعمل توقعات لممر أجرة البريد[5].

2. هدف البحث

يهدف البحث إلى تصميم نظام له القدرة على تمييز الأنسجة باستخدام تقنيه ذكاء اصطناعية معتمدة على الشبكات العصبية الاصطناعية بعد استخلاص خصائص النسيج باستخدام خوارزمية تحليل المركبات الاساسية التي تعد احدى طرائق استخلاص الصفات او الخصائص واعتماد البحث نواة لأنظمه مستقبلية تعتمد على استخدام الأنسجة للتصنيف أو تمييز أوتقطيع الصور في المجالات الطبية والعلمية الأخرى.

3. استخلاص الخصائص (Features Extraction)

استخلاص الخصائص تعرف كأداة رياضية للفصل بين البيانات وهي عادة تعتبر مكمل في معظم أعمال تمييز الأنماط. تشمل اشتقاق مجموعة من الخصائص أو المتجهات التي تتضمن اختلافات هامة تتعلق بتركيب البيانات حيث تخفض أبعاد وحجم مثل هذه البيانات[6]. إن استخلاص الخصائص من المراحل المهمة في نظام التمييز حيث تأخذ الصفات التي تحقق دقة عالية في التمييز وسرعة في المعالجة[7].

4. تحليل المركبات الأساسية (Principal Components Analysis PCA)

تحليل المركبات الرئيسية يسمى كذلك تحويل المركبات الرئيسية، تحويل متجه (Eigen). قدم هذا التحويل لأول مرة من قبل بيرسن (1901) وتمت عليه تحويلات عدة إلى أن تم تعميمه من قبل لوي (1963)[8]. تعتبر (PCA) طريقه لتمييز الأنماط في البيانات. ويظهر البيانات بطريقه حيث يميز الشيء المهم بالنسبة للتشابه والاختلاف في هذه البيانات، حيث يمكن لخوارزمية تحليل المركبات الاساسية ان تحول سلسلة البيانات المترابطة بعض الشيء الى سلسلة مرتبة من المكونات الاساسية توفر وسيلة لاستخلاص الخصائص. أن انجاز التحويل يتطلب تصميم مصفوفة التغاير للمتغيرات المعقدة، مصفوفة التغاير (Covariance Matrix) هي المصفوفة التي يكون عناصر قطرها الرئيسي هي الخلف (Variance) للمتغيرات، وعناصر القطر الثانوي (Off-Diagonal Elements) هو التغاير و يسمى أحيانا (التباين) (Covariance) بين كل متغيرين[6]. هذه المصفوفة يمكن حسابها بالصيغة التالية :

$$C_{ij} = \frac{1}{MN} \sum_{k=1}^M \sum_{l=0}^N (X_i(K, l) - \mu_i) (X_j(K, l) - \mu_j) \dots \dots \dots (1)$$

حيث أن :

$$n \dots 1,2,3, i, j$$

n : عدد الصور المستخدمة في حساب مصفوفة الخلاف و التغيرات .

K & I : تمثل موقع كل نقطه في صوره بحجم M*N .

إذا كان $i = j$ فان C : تمثل الخلاف (Variance) للصورة.

إذا كان $i \neq j$ فان C : تمثل التغيرات (Covariance) للصورة.

$X_i(K, I)$: هي قيمه عددية في الصورة i للموقع k,l.

$X_j(K, I)$: هي قيمه عددية في الصورة j للموقع k,l.

μ_j & M_j : هي معدل قيم الصورة I والصورة j .

حيث أن حساب المعدل بالمعادلة التالية:

$$\mu_i = \frac{1}{MN} \sum_{k=0}^M \sum_{l=0}^N X_i(K, I) \dots \dots \dots (2)$$

مصفوفة آيكن (Eigen-Vector & Eigen-Value matrix):

هي مصفوفة مشتقة من مصفوفة التغيرات (Covariance Matrix) باستخدام نظرية جاكوبي لإيجاد الأقطار (Jacobi Diagonalisation Method). يتمثل هذه المصفوفة بالحرف T, فان T' هي المصفوفة المدورة [8]. كما في المعادلة (3) التالية:

$$D = TCT' \dots \dots \dots (3)$$

حيث أن المصفوفة D تمثل قطر مصفوفة التغيرات (Covariance Matrix) ويمكن تمثيلها بالمصفوفة

التالية :

$$D = \begin{bmatrix} \lambda_{11} & 0 & \dots & 0 \\ 0 & \lambda_{22} & \dots & 0 \\ \dots & \dots & \dots & \dots \\ 0 & \dots & \dots & \lambda_{nn} \end{bmatrix}$$

العناصر القطرية (Diagonal Elements) للمصفوفة D تدعى قيم آيكن (Eigen-Values) لمصفوفة الخلاف/التغيرات (Variance/Covariance Matrix). حيث λ_{ii} لكل $i=1,2,\dots,n$ هي الخلاف (Variance) للـ (PCA). وباقي العناصر (Off-Diagonal) للمصفوفة D تحمل القيمة (zero 0) مما يدل على أن المركبات الخارجة غير مترابطة, أي أنها مستقلة [8]. بعد حساب قيم المصفوفة T, يمكن إجراء التحويل للصورة باستخدام الصيغة التالية:

$$Y = TX \dots \dots \dots (4)$$

حيث أن:

Y : متجه عناصره هي قيم المركبات الأساسية .

X : متجه عناصره هي قيم الصور في المستوى الرمادي (Original Gray Values).

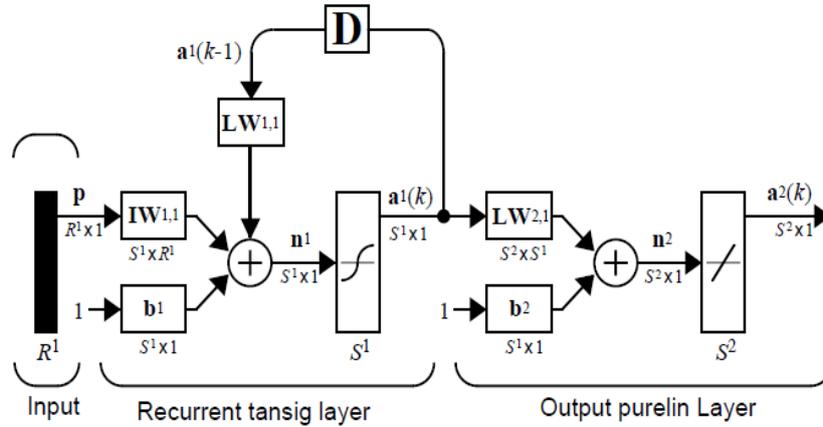
T: قيم مصفوفة (Eigen-Vector Matrix) [8].

5. الشبكة العصبية الاصطناعية (Artificial Neural Network)

الشبكات العصبية هي تقنيات حسابية مصممة لمحاكاة الطريقة التي يؤدي بها الدماغ البشري مهمة معينة، ومكونة من وحدات معالجة بسيطة، هذه الوحدات ما هي إلا عناصر حسابية تسمى عصبونات أو عقد والتي لها خاصية عصبية، من حيث أنها تقوم بتخزين المعرفة العملية والمعلومات التجريبية لتجعلها متاحة للمستخدم وذلك عن طريق ضبط الأوزان. ويتم ربط هذه العصبونات بواسطة بعض أنواع الربط والتي تحمل بيانات رقمية. تستخدم الشبكات العصبية الاصطناعية في مجالات علمية مختلفة منها التمييز الصوري، وإيجاد قيم الدالة التقريبية، والتخطيط لإيجاد حل امثل للمسائل، مجالات التشخيص الطبي والسيطرة والتحكم [9].

1.5. معمارية شبكة ايلمان (ELMAN):

تعد شبكة ايلمان العصبية من الشبكات العصبية التي طورت من قبل جيفري ايلمان عام 1990 وتعد من شبكات التدريب باشراف وتمتلك اعادة تغذية (recurrent) [10]. هذا النوع من الشبكات يتكون على الاقل من ثلاث طبقات طبقة الإدخال والطبقة المخفية وطبقت الإخراج بالإضافة الى طبقة context layer التي تعمل تغذية راجعة بدون وزن، ان هذه الشبكة تمتاز بقدرة تمييز عالية ووصولها إلى الحل الأمثل لأنها تعيد اخراج الطبقة المخفية إلى طبقة الإدخال مما يزيد سرعة التدريب وضبط أوزان الشبكة، الشبكة تمتلك (Tansig-Neurons)، في الطبقة المخفية وكذلك تمتلك (Purelin-Neurons) في طبقة الإخراج. كما في الشكل (1) الذي يوضح معمارية الشبكة. [11]



الشكل (1): معمارية شبكة ELMAN

R: عدد العناصر في عمود الإدخال. S¹: عدد العصبونات في الطبقة الأولى.

P: مصفوفة الإدخال. S²: عدد العصبونات في الطبقة الثانية.

b¹, b²: مصفوفة الـ basis.

K: عدد دورات الرجوع. LW^{1,1}: مصفوفة الوزن للطبقة المخفية.

LW^{2,1}: مصفوفة الوزن لطبقة الإخراج.

العقد في الطبقة المخفية تنفذ بواسطة الدالة (tansig) الرجعية التي تعمل على منطقة محصورة من حيز

الإدخال. وذلك باعتماد المعادلة الآتية [11]:

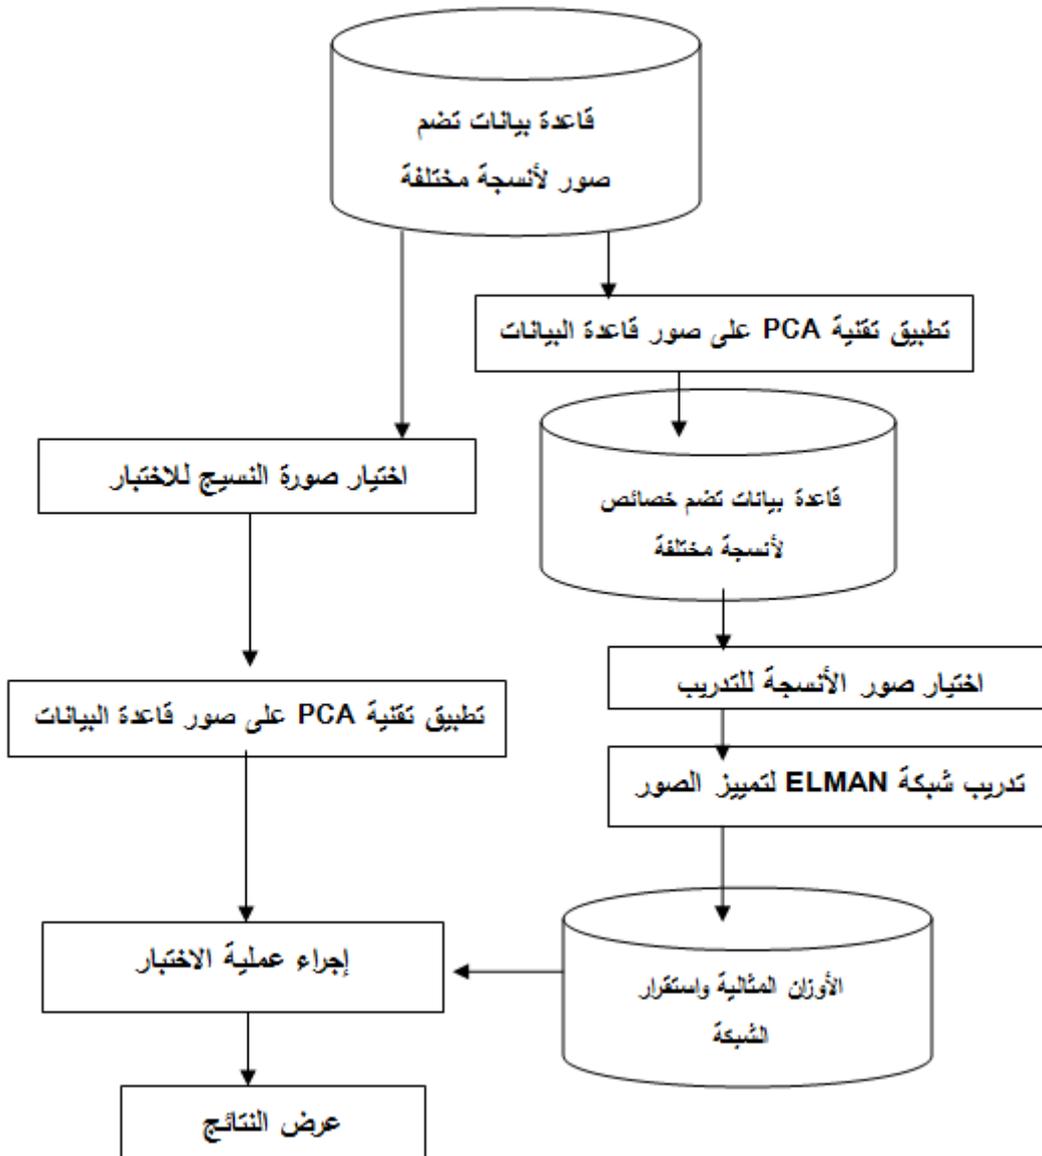
$$a1(k) = \tan \text{ sig } (IW_{1,1}p + LW_{1,1}a_1(k-1) + b_1) \dots\dots\dots(5)$$

والعقد في طبقة الإخراج تنفذ بواسطة الدالة (purelin) الخطية التي تعمل على منطقة محصورة من حيز الإخراج. وذلك باعتماد المعادلة الآتية [11]:-

$$a2(k) = \text{purelin}(LW_{2,1}a_1(k) + b_2) \dots\dots\dots(6)$$

6. الخوارزمية المقترحة

تم تصميم نظام تمييز أنسجة الصور الرقمية المعتمد على تحليل المركبات الأساسية لاختيار أفضل الميزات من البيانات واستخدام شبكة (ELMAN) العصبية الاصطناعية لتمييز هذه الصور، النظام يعمل بثلاث مراحل مرحلة المعالجة الأولية، مرحلة استخلاص الخصائص ومرحلة التمييز كما موضح في المخطط الصندوقي الآتي :



الشكل (2) المخطط الصندوقي لتصميم العام للنظام المقترح

1.6. مرحلة المعالجة الاولية Preprocessing stage تتكون هذه المرحلة من الخطوات التالية :

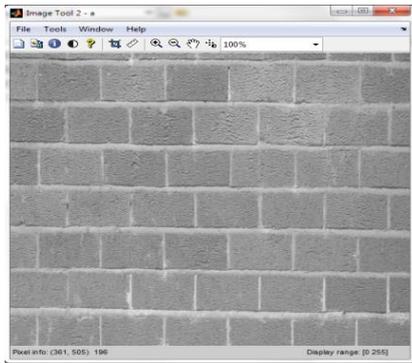
1- تكوين قاعدة بيانات تضم نماذج لصور أنسجة مختلفة تمثل 10 أصناف متنوعة مثل (نسيج الخشب المسطح، نسيج الحجر، نسيج الفاكهة،، نسيج الطابوق نسيج نجارة الخشب، نسيج أرضية منزل، نسيج ورق حائط، نسيج خشب بشكل ألواح، نسيج الرخام، نسيج إسفلت) كل صنف يضم (8 أو 10) نسيج, كما في الشكل التالي:



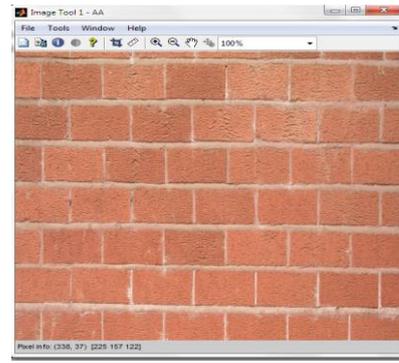
الشكل(3): يوضح نماذج أنسجة لإنشاء قاعدة البيانات

2- تغيير حجم صور الأنسجة الى (512*512) كما في الشكل (4).

3- تحويل الصورة إلى فضاء الرمادي (Gray Level) كما في الشكل (5).



الشكل(5): النسيج في الفضاء الرمادي



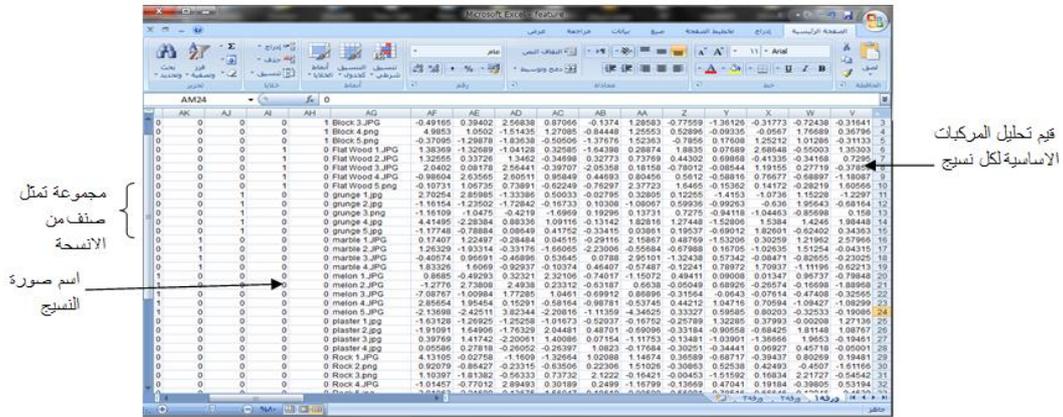
الشكل (4): نسيج بحجم (512*512)

2.6. مرحلة استخلاص الخصائص: تنفيذ خوارزمية تحليل المركبات الاساسية التي تتكون من الخطوات التالية:-

- * حساب المتوسط لقيم صور النسيج.
- * حساب مصفوفة التباين/الخلاف (Variance/Covariance Matrix).
- * إيجاد مصفوفة أيكن (Eigenvalues And Eigenvectors Matrix).

* إيجاد المعاملات (Coefficients) للبيانات التي تم اختيارها.

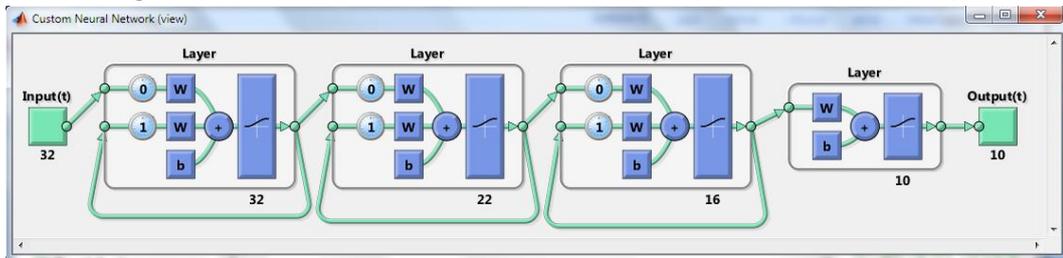
يتم خزن معاملات تحليل المركبات الاساسية لكل الانسجة في مصفوفة وخزنها في ورقة أكسل (Excel) كما يوضح الشكل التالي :-



الشكل(6): جزء من قاعدة البيانات

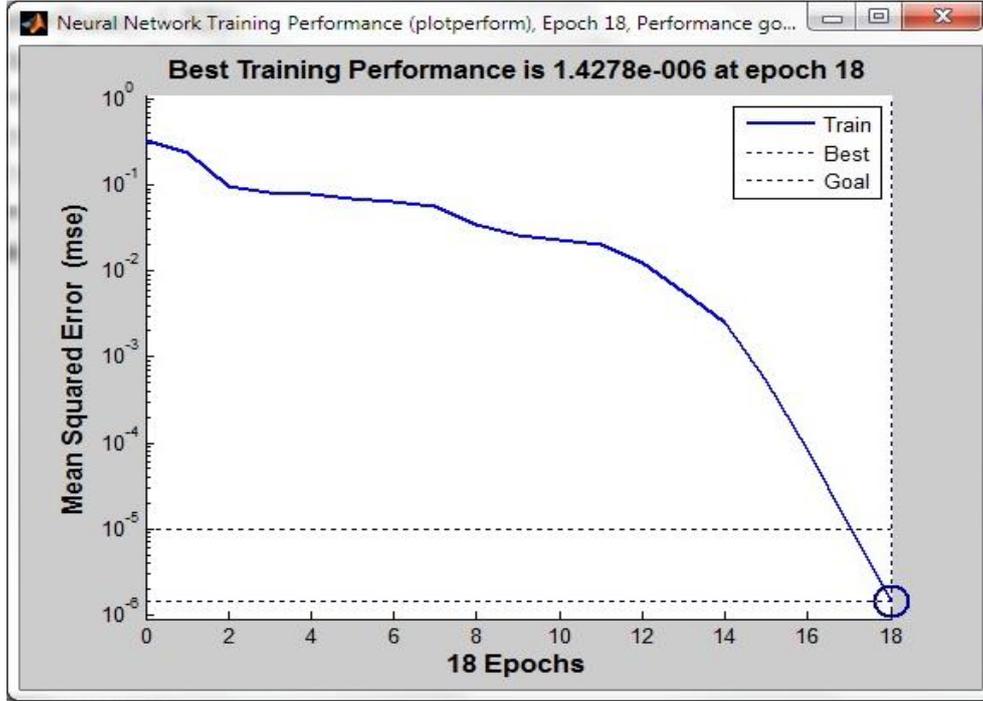
3.6. مرحلة تمييز الانسجة: تتكون هذه المرحلة من طورين

طور التدريب حيث إن مرحلة تدريب الشبكة العصبية هي من أساس النظام، حيث تم بناء شبكة (ELMAN) من أربع طبقات الطبقة الأولى تتكون من 32 عقدة (بعدد الإدخالات) والطبقة الثانية من 22 عقدة والطبقة الثالثة من 16 عقدة والطبقة الرابعة من 10 عقد (بعدد الإخراجات)، الشكل (7) يوضح بنية الشبكة العصبية الاصطناعية من عدد الإدخالات، وعدد الطبقات، وعدد إخراجات الشبكة العصبية الاصطناعية حيث تم التدريب الشبكة على عدد من النماذج بلغت (47) نموذج وبعدد من الطبقات المختلفة وعدد من العقد المختلفة لجميع الطبقات وتم تدريب الشبكة الى ان يتم الوصول الى حالة الاستقرار والوصول الى افضل النتائج للشبكة.



الشكل (7): بنية الشبكة العصبية

كان عدد دورات التدريب 1,000، وكان متوسط تربيع الخطأ (MSE = 0.00001). ولكل تدريب وقت مختلف مع نفس الشبكة العصبية ونفس البيانات، استغرقت الشبكة العصبية أثناء التدريب دقيقة وأربعة وخمسين ثانية فقط باستخدام حاسبة تعمل تحت بيئة نظام التشغيل Windows وتحوي على معالج ذات سرعة 2.6 Cord (2 Due) وذاكرة عشوائية حجمها (2Gbyte). الشكل(8) يمثل منحنى التدريب للشبكة العصبية الاصطناعية المستخدمة.



الشكل (8): منحنى تدريب الشبكة

طور الاختبار حيث يبدأ بتجميع بيانات الاختبار المتكونة (47) نموذج وتهيتها وإدخالها إلى الشبكة العصبية المدربة مسبقا (الشكل (9) يمثل نماذج الاختبار) بعد الحصول على النتائج يتم تقييم أداء الشبكة عن طريق حساب نسبة التمييز حسب المعادلة التالية [11]:-

$$\text{Recognition Rate}(RR) = TP/P$$

... (6)

TP: تمثل عدد الصور المصنفة بشكل صحيح.

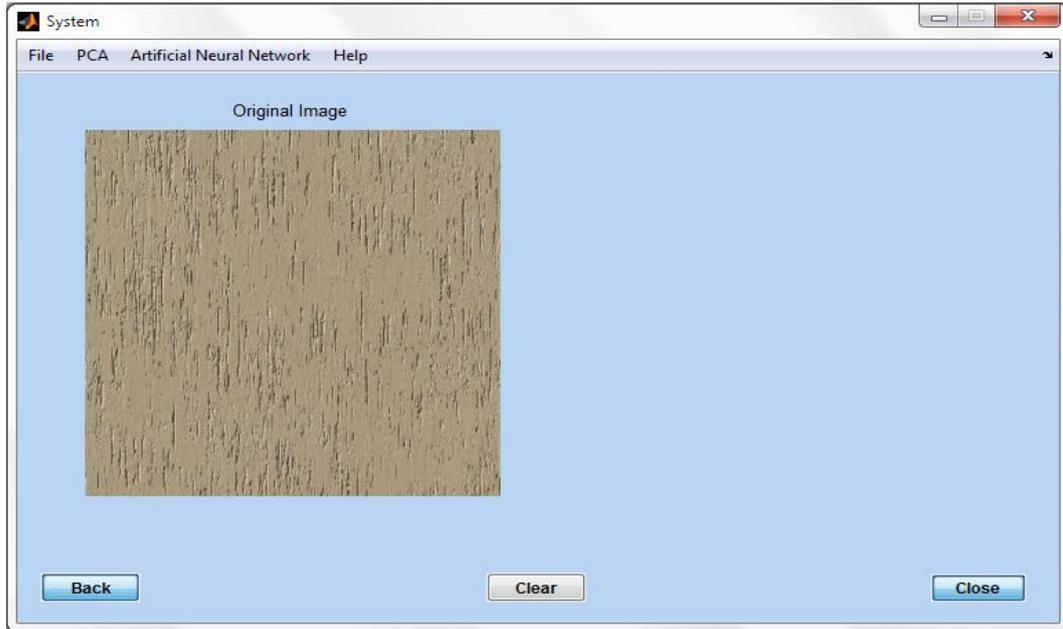
P: تمثل عدد الصور الكلي.



الشكل (9): مجموعة أنسجة الاختبار

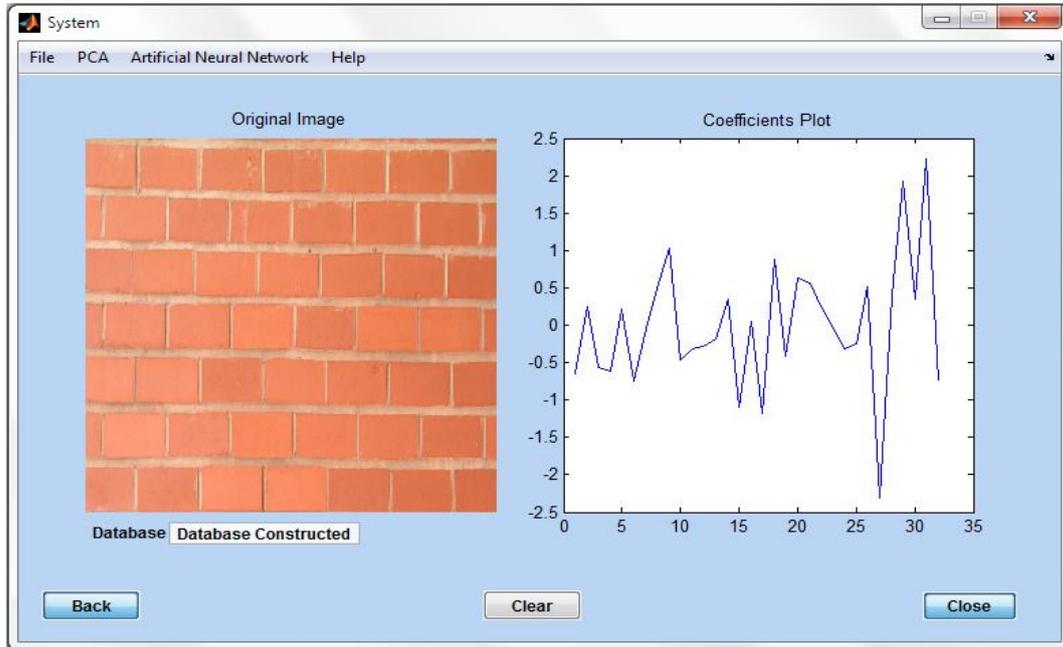
7. تنفيذ النظام ومناقشة النتائج

تم بناء عدة واجهات لتنفيذ النظام حيث يتم اختيار النسيج كما في الشكل (10) :-



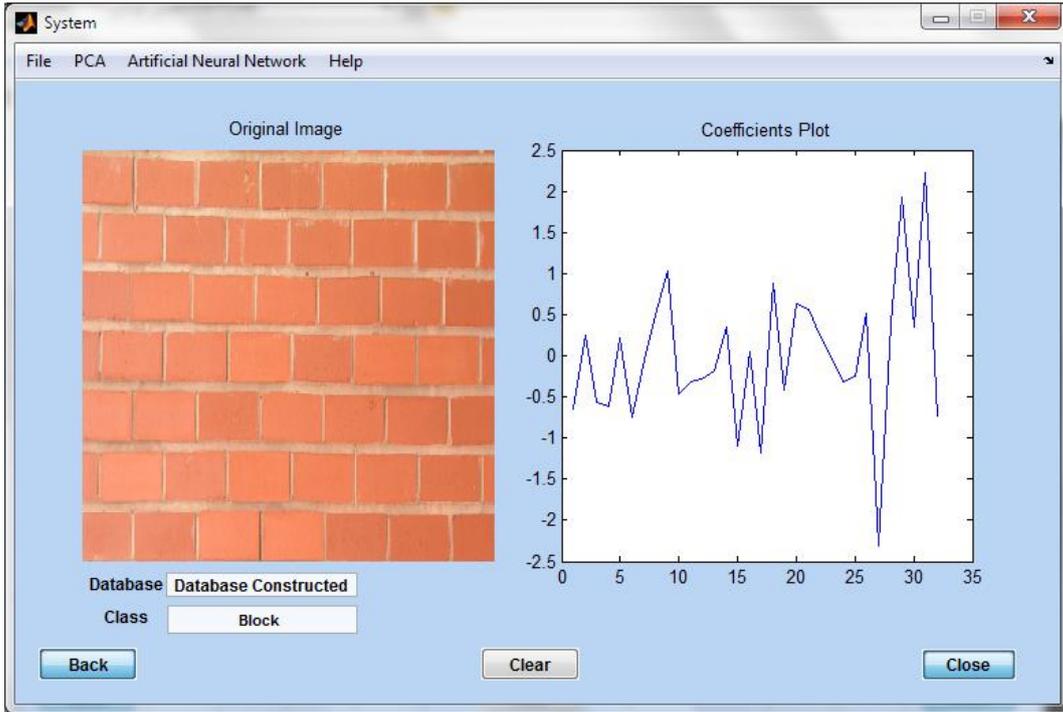
الشكل (10):الواجهة بعد استقبال الصورة

في الشكل (11) نتيجة تنفيذ مرحلة استخلاص الخصائص ورسم مخطط بياني يوضح معاملات تحليل المكونات الأساسية (PCA_Coefficients) للصورة التي تم اختيارها.



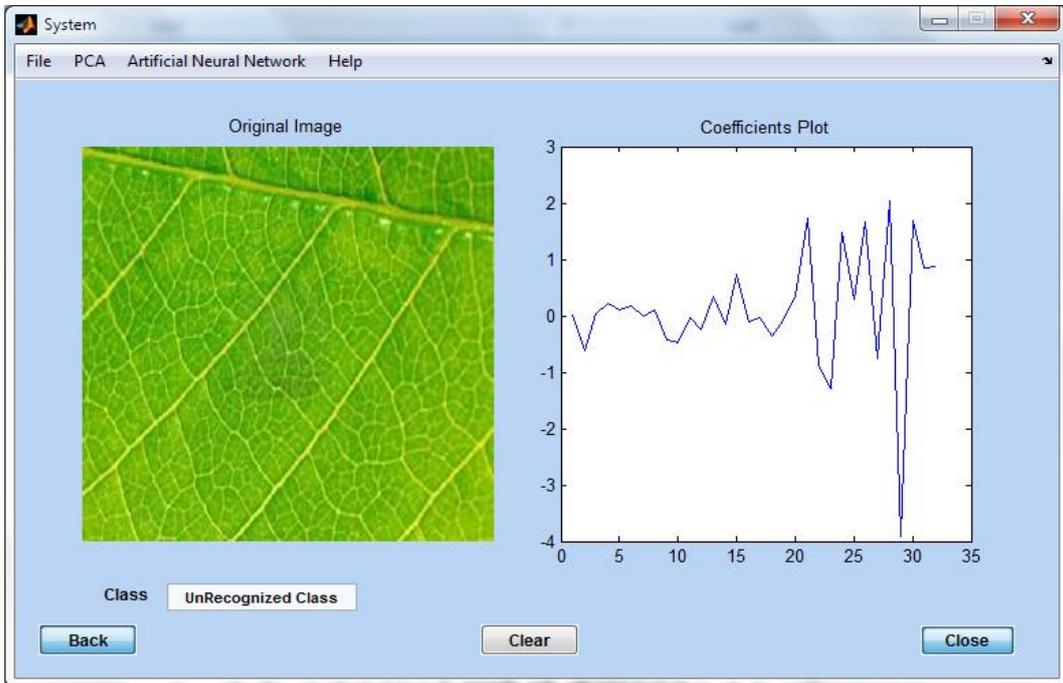
الشكل (11): معاملات تحليل المكونات الأساسية

الشكل (12) يظهر نتيجة اختبار النظام بعد تنفيذ هذا الاختيار يظهر لنا جملة توضيحية تبين الصنف للصورة التي تم اختيارها، فإذا كان نسيج الصورة التي تم اختيارها لها صنف في قاعدة البيانات، فسيظهر اسم الصنف الذي ينتمي إليه نسيج هذه الصورة.



الشكل (12): تنفيذ التمييز

بينما إذا تم اختيار نسيج صورة غير موجود في قاعدة البيانات, فسيظهر جملة تؤكد عدم مقدرة النظام على تمييز هذا النسيج كما موضح في الشكل التالي:



الشكل (13): نسيج لا يمكن تمييزه

8. مناقشة النتائج:

بعد تنفيذ مرحلة الاختبار على النظام تم الحصول على نتائج دونت في الجدول (1) حيث تم اختبار 94 نموذج من صور الأنسجة ضمت هذه النماذج مجموعة مختلفة ومتنوعة من الأنسجة ذات الدقة العالية الخالية من الضوضاء. تم تقييم أداء الشبكة باستخدام المعادلة رقم (5) لايجاد نسبة التمييز وظهرت النتائج النهائية ان نسبة التمييز ممتازة حيث بلغت 92% وان الاختلاف في نسب التمييز بين انواع الاصناف يعتمد على مخرجات خوارزمية تحليل المركبات الاساسية والتي تتاثر باتجاه النسجة في الصورة.

الجدول (1) نتائج تنفيذ النظام

اسم الصنف	التمييز الصحيح	التمييز الخاطئ	نسبة التمييز (RR)
نسيج الخشب المسطح	8	2	80%
نسيج الحجر	9	1	90%
نسيج الطابوق	8	2	80%
نسيج الفاكهة	10	0	100%
نسيج نجارة الخشب	9	1	90%
نسيج أرضية منزل	8	0	100%
نسيج ورق حائط	8	0	100%
نسيج إسفلت	10	0	100%
نسيج خشب بشكل ألواح	9	1	90%
نسيج الرخام	8	0	100%
المجموع	87	7	92%

9. الاستنتاجات

- 1- ان استخدام صور الأنسجة ذات الدقة العالية الخالية من الضوضاء ساعد على الحصول على الدقة في التمييز
- 2- ان استخدام خوارزمية تحليل المركبات الاساسية ادى الى تقليل حجم البيانات الداخلة للشبكة العصبية الاصطناعية وبالتالي ادى الى الزيادة في سرعة تدريب الشبكة
- 3- اثبتت الشبكة العصبية ELMAN كفاءتها العالية في عملية التمييز
- 4- ان استخدام خوارزمية تحليل المركبات الاساسية اضاف كفاءة ودقة في تمييز الأنسجة بالرغم من التشابه النسبي الموجود بين الأنسجة

المصادر

- [1] S. Aggarwl, A. Jangra, (2011), "Image Quality Assessment Based on Feature Extraction Using Wavelet and Riesz Transforms" International Journal of Computer Science and Security (IJCSS), Volume (1).
- [2] Imran S. Bajwa, S. Irfan Hyder, (2005), " PCA Based Classification of Single-layered Cloud Types", Vol 1 (N.2).
- [3] Y.H. Zhang, C.W.M. Yuen, W.K. Wong, (2010),"A New Intelligent Fabric Defect Detection And Classification system Based on Gabor Filter and Modified Elman Neural Network", IEEE, pp. 652-656.
- [4] Othman, M. F., Basri, M. A. M., (2011),"Probabilistic Neural Network for Brain Tumor Classification", Second International Conference on Intelligent Systems, Modelling and Simulation, pp. 136-138.
- [5] Ghassem F., 21 February, (2012)," A New Intelligent Fabric Defect Detection And Classification system Based on Gabor Filter and Modified Elman Neural Network", African Journal of Business Management, Vol. 6 (33), pp. 9496-9503.
- [6] Turkan A. Khalel,(2001),"An Integrated Software for Remotly Sensed Data Classification", Thesis, University of Mosul-Iraq.
- [7] Jamal S., Sora R. Sharef, Osama Y. Mohamad ,(2011)," An Intelligent Computer System Recognizing Printed Russian Letters Using Artificial Neural Network", IASJ ,Vol(8), Pgs.125-144.
- [8] Maha A. Alhaso, Muna Jafar , (2010)," Choosing best band by using PCA algorithm on remote sensing ", IASJ, vol. 7, issue: 3,p.p 135-144
- [9] Jamal S., Osama Y. Mohamad, Tariq H., (2010),"Recognizing Hebrew Letters Using Artificial Neural Network", Bhoth Mostakbaliya Journal, Pgs. 143-175.
- [10] Li. Penghua Chai,(2013),"Quantized Neural Modeling:Hybrid Quantized Architecture in Elman Networks",Vol.37,ISSUE2,Neural Computing & application.
- [11] Howard Demuth, Mark Beale, R2007b, "Neural Network Toolbox".
- [12] Fawcett Tom. (2004),"Roc graphs: Notes and practical considerations for researchers". Technical Report, HP Laboratories, Kluwer Academic Publishers.