

Distinguish of Fingerprint Based on Artificial Neural Networks

Zahraa Mazen Al-Qattan

College of Computer Sciences and Mathematics
University of Mosul, Mosul, Iraq

Received on: 14/04/2013

Accepted on: 24/06/2013

ABSTRACT

In this research use one of artificial intelligence techniques which is artificial neural networks was used to distinguish fingerprint from a range of fingerprints belong to a unified database, based on a set of properties to the texture of image and which are extracted and analyzed using co-occurrence matrix (Event), These properties are (contrast ,correlation, determined, homogeneity), and after extracting properties, a combination of neural networks (Cascade Neural Network CNN and Radial Basis Functions network RBFN and Elman Neural Network ENN) used to distinguish fingerprint, and the results of training 100% for the three networks after being trained on the network (18) sample where each person(3)samples.

Network efficiency was measured in recognition by using scale (training rate) and scale (recognition rate RR) for comparison between these networks to see the best network in the recognition.

Keywords: Fingerprint, Artificial Neural Networks.

تميز بصمة الاصبع المعتمد على الشبكات العصبية الاصطناعية

زهراء مازن القطان

قسم هندسة البرمجيات

كلية علوم الحاسوب والرياضيات

جامعة الموصل

تاريخ قبول البحث : 2013\6\24

تاريخ استلام البحث : 2013\4\14

الملخص

في هذا البحث تم استخدام احدى تقنيات الذكاء الاصطناعي وهي الشبكات العصبية الاصطناعية لتميز بصمة الاصبع من بين مجموعة من البصمات التابعة لقاعدة بيانات موحدة وذلك بالاعتماد على مجموعة من الخواص الخاصة بنسيج الصورة والتي يتم استخراجها وتحليلها باستخدام مصفوفة التواجد (الحدث)(CO-occurrence matrix), وهذه الخواص هي (التباين، الترابط، العزم، التجانس)، وبعد ان يتم استخراج الخواص سوف يتم استخدام مجموعة من الشبكات العصبية(الشبكة العصبية المتتالية وشبكة دالة القاعدة الشعاعية وشبكة ايلمان) لتميز بصمة الاصبع، وكانت نتائج التدريب 100% بالنسبة للثلاث شبكات بعد ان دربت الشبكة على (18) عينة حيث لكل شخص(3) عينات .

تم قياس كفاءة الشبكة في التمييز باستخدام مقياس نسبة التدريب (training rate) ومقياس نسبة التمييز (recognition rate RR) للمقارنة بين هذه الشبكات لمعرفة افضل شبكة في التمييز. الكلمات المفتاحية: بصمة الاصبع، شبكة عصبية اصطناعية.

1. المقدمة

ان تمييز الانماط هو احد فروع علم معالجة الصور والذكاء الاصطناعي حيث يهدف الى ايجاد او تطوير تقنيات التعرف على نمط او شكل معين [1].

وان من التطبيقات المهمة والمفيدة في تمييز الانماط هي تمييز الحروف والتعرف على الاشكال والاشخاص وكذلك يستخدم في المجالات الطبية.

لقد عرف الإنسان بصمات الأصابع والكف وباطن القدم منذ عصر ما قبل التاريخ ، وقد أكد الباحثون والعلماء ذلك من خلال الآثار التي عثروا عليها في مختلف أرجاء العالم وذكر بشكل أو بآخر من خلال الكتب السماوية المقدسة اذ يحكى ان بطرس الرسول قد وقّع كتابه ببصمة اصبع.

وتعد بصمات الاصابع والكف وباطن القدم ذات اهمية كبيرة في تحقيق شخصية الفرد اذ ثبت علميا وعمليا انه ليس هناك شخصان لهما طبعتان متطابقتان لاصبعين في الخطوط والميزات حتى لو كان الشخصان توأمين ، ولم يحدث الى حد الآن أن هناك بصمة أصبع ما انطبقت مع بصمة شخص آخر أو مع بصمة أصبع أخرى من أصابع نفس الشخص.

ونتيجة لتطور المجتمع فقد تطورت معه استعمال بصمات الأصابع مثل العلوم الأخرى ويسمى علم بصمة الاصبع (fingerprint science) ويتركز هذا العلم لغرض تحقيق الشخصية على خطوط واضحة تظهر على سطح السلامة الأولى من أصابع اليدين (خطوط حلمية بارزه) ولهذه الخطوط انحناءات معينة وكل نوع له خصائص مميزة من حيث الشكل [1].

ان الهدف من البحث هو تمييز بصمة الاصبع باستخدام الشبكات العصبية الاصطناعية وبالاعتماد على مصفوفة التواجد (co-occurrence matrix)، حيث تقوم هذه المصفوفة بتحليل نسيج الصورة واستخلاص خواصها، ومن ثم اعتماد هذه الخواص كمدخلات الى الشبكات العصبية المستخدمة في البحث لغرض عملية التمييز.

2. الاعمال السابقة

قدم الباحثون Sushmita M., Sanker k. and Malay k. طريقة لتصنيف بصمة الاصبع باستخدام شبكة المدرك متعددة الطبقات المضطربة (Fuzzy Multilayer Perceptron) MLP بالاعتماد على خواص الصورة التي تم استخلاصها من مصفوفة التواجد (co-occurrence matrix) [7].

قام الباحثان Mehran Y. and Kazem G. باستخدام مصفوفة التواجد في تصنيف بصمة الاصبع. حيث اعتمد على قيم الخواص المستخلصة من هذه الشبكة في تعليم الشبكة العصبية المستخدمة في تصنيف بصمة الاصبع حسب انواعها المختلفة [8].

اما الباحثون Fakheri , Mashoufi B., Sedgi T. فقد قدموا من خلال بحثهم الموسوم تطبيق جديد لتمييز بصمة الاصبع (ANovel Approach for Fingerprinting Recognition) تمييز لبصمة الاصبع

باستخدام شبكة الانتشار العكسي (Back-propagation algorithm) بعد ان يتم استخلاص الخواص من صورة بصمة الاصبع باستخدام مصوفة التواجد GLCM [9] .

اما الباحثة ميسون خضر النعيمي فقد قامت من خلال بحثها(تمييز بصمة الاصبع باستخلاص الخواص وبعتماد الشبكات العصبية) اولا بعملية ازالة الضوضاء من الصورة باستخدام الفلترالمتوسط ومن ثم التنحيف لصورة بصمة الاصبع وجعلها كادخال لشبكة الانتشار العكسي لاجل التمييز بعد حساب القيمة المميزة لتلك الصورة كطريقة لاستخلاص الخواص [2].

3. الشكل العام لبصمة الاصبع

يلاحظ الشكل العام لبصمة الإصبع إن سطحه مكسو بخطوط دقيقة متوازية ترتفع عن سطح جلد البشرة وتسمى الخطوط البارزة أو الحافات (Ridges) ويفصل بين خط وآخر خط منخفض دقيق تسمى الخطوط المنخفضة أو الشقوق (Furrows) أو الوديان (Valleys) ولا تسير في مجراها باستقامة واحدة إنما تكوّن أشكالاً متنوعة عديدة غريبة في ترتيبها فمنها تكون على شكل دوائر متعددة حول نقطة الوسط بينما غيرها تكون على هيئة خطوط منحدرّة إلى اليمين أو اليسار ، وهكذا تتكون منها خطوط مقوسة تبدأ من جهة وتنتهي من الجهة الثانية [1]. وتقسم بصمة الاصبع الى عدة انواع هي:

1- **المقوسات (Arches)** والتي تضم : المقوسات البسيطة (Plain arch) ، المقوسات المرتفعة (الخيمة) (Tented arch) ، المقوسات الاستثنائية.

2- **المنحدرات (Loops)** والتي تضم : المنحدرات الكعبرية (Radial Loops) و المنحدرات الزندية (Lunar) .Loops

3- **المستديرات (Whorl)** والشكل الاتي يوضح بعض الاشكال المختلفة لبصمة الاصبع [1].



الشكل (1) الاشكال المختلفة لبصمة الاصبع

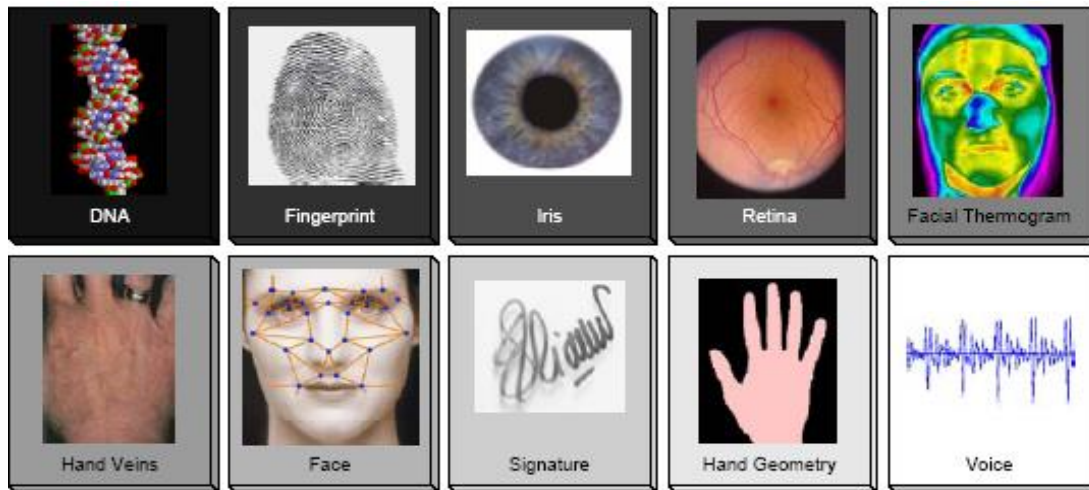
4. الخصائص الشخصية لبصمات الأصابع والمعايير الحيوية

هناك عدة مميزات لنمط بصمة الاصبع تجعلها اكثر استخداما من غيرها من المعايير الحيوية الاخرى مثل الوجه والاذن والصوت وغيرها لاغراض الامن والتحقق وهي :

- عدم التغير (Unexchangeability)
- الوحدانية (Uniqueness)

وهناك أنواع مختلفة من المعايير الحيوية نذكر أهمها:

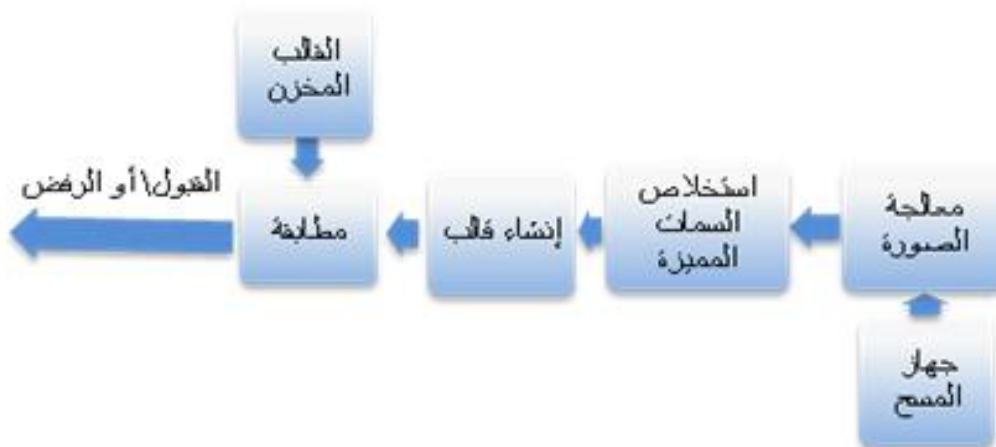
الوجه Face ، الأذن Ear ، بصمة باطن اليد (Palmprint) ، الحامض النووي (Dexyribo (DNA) Nucleic Acid ، قزحية العين Iris ، بصمة الأصبع (Fingerprint) وغيرها ، وان بصمة الأصبع تعتبر من أكفا أنواع المعايير الحيوية والشكل (2) يوضح بعض أنواع المعايير الحيوية المستخدمة لإثبات الهوية [1].



الشكل (2) أنواع مختلفة من المعايير الحيوية

5. نظام التعرف على بصمة الإصبع

بداية ليكون النظام قادرًا على التعرف على شخص ما على أساس بصمته يحتاج - بالطبع - إلى مطابقة هذه البصمة مع مواصفات البصمة الحقيقية للشخص. تسمى عملية إدخال بصمة المستخدم إلى النظام لأول مرة بالتسجيل، وفي هذه الحالة فإن سمات البصمة تخزن على شكل قالب في قاعدة البيانات [10].



الشكل (3) مكونات نظام التعرف على بصمة الإصبع

يقوم النظام بالتقاط صورة البصمة عن طريق الماسح. و ماسح بصمة الإصبع هو جهاز إلكتروني يستخدم لالتقاط صورة مباشرة لشكل البصمة. بعد ذلك يقوم بمعالجة صورة البصمة، ثم استخراج وقياس التفاصيل و السمات الفريدة من نوعها باستخدام خوارزميات لإنشاء قالب. يتم تخزين هذه القوالب في قاعدة بيانات داخل النظام، ويمكن تخزينها أيضا على بطاقة ذكية.

يقوم المستخدم في كل مرة يحتاج فيها إلى تعريف شخصيته، بوضع إصبعه على الماسح، ينشئ النظام قالب. بعد ذلك يقوم النظام بمطابقة هذا القالب المدخل بإحدى طريقتين بحسب نوعية النظام كما موضح بالشكل (3).

6. مصفوفة التواجد

عبارة عن تطبيق احصائي يستخدم لوصف نسيج الصورة المراد تمييزها من خلال استخراج خواص الصورة عن طريق معادلات احصائية، حيث يتم تحويل صورة بصمة الإصبع الى مصفوفة ثنائية الأبعاد ويتم التعامل معها [11],[12].

ان فكرة تكوين هذه المصفوفة تعتمد على قيم الأزواج المتجاورة افقيا من النقاط في الصورة المراد تمييزها واحتمالية تكرار هذه الأزواج ضمن المصفوفة حيث تتم عملية جمع لعدد مرات التكرار ووضع المجموع في الموقع الذي يمثل الزوج المكرر. وبما ان الصورة التي سوف نتعامل معها هي من نوع graylevel اي انها تحوي على 256 قيمة لونية فأنها تتكون من (level 8) فعلية سوف نرمز لهذه المصفوفة بالرمز (gray level GLCM (co-occurrence matrix حيث تتكون مصفوفة 8*8 وهذه المصفوفة تمثل مصفوفة GLCM [11],[12]. والشكل الاتي يوضح كيفية تكوين المصفوفة لو كان لدينا صورة ابعادها 5*4

	1	2	3	4	5	6	7	8
1	1	2	0	0	1	0	0	0
2	0	0	1	0	1	0	0	0
3	0	0	0	0	1	0	0	0
4	0	0	0	0	1	0	0	0
5	1	0	0	0	0	1	2	0
6	0	0	0	0	0	0	0	1
7	2	0	0	0	0	0	0	0
8	0	0	0	0	1	0	0	0

الشكل (4) كيفية تكوين المصفوفة

1.6 استخراج الصفات الخاصة بالمصفوفة GLCM

تحوي المصفوفة على مجموعة من الصفات الاحصائية التي تصف قيم الكثافة في نسيج الصورة ومنها يتم استخراج الصفات الخاصة بنسيج الصورة [7] [13]. والصفات التي تم استخدامها في هذا البحث لاستخراج خصائص بصمة الإصبع هي:

أ- التباين (contrast) وهو مقياس لشدة التباين بين كل نقطة ضوئية واخرى مجاورة لها بالنسبة لصورة البصمة كلها , و يحسب عن طريق المعادلة التالية :

$$F=\sum \sum (i-j)^2 p(i,j) \dots\dots\dots(1)$$

ب- الترابط (correlation) وهو مقياس لمدى ترابط كل نقطة ضوئية مع اخرى مجاورة لها بالنسبة للصورة باكملها , المعادلة التالية:

$$F=\sum \sum (i,Mj)*(j-Mi)*p(i,j)/6x6y\dots\dots\dots(2)$$

ج- العزم (energy) وهو عبارة عن مجموع لمربع العناصر الموجودة في مصفوفة ال GLCM ويحسب وكما يلي :

$$F=\sum \sum p(i-j)^2\dots\dots\dots(3)$$


د- التجانس (Homogeneity) يعطي مؤشر لكمية التجانس داخل النسيج ويحسب عن طريق المعادلة التالية :

$$F=\sum \sum (p(i-j)/i+|i+j)|\dots\dots\dots(4)$$

7. الشبكات العصبية الاصطناعية

يمكن القول إن تاريخ دراسة الشبكات العصبية الاصطناعية يعود الى عام 1943، اذ بني أول نموذج لخلية عصبية من قبل العالمان *McCulloch & Pitts*، وكانت عبارة عن خلية بسيطة ثنائية الحالة وقد أمكن من خلالها تمثيل الدوال المنطقية. وفي عام 1949 قدم العالم *Hebb* أول قاعدة لتعليم الشبكة العصبية أطلق عليها *Hebbian learning Rule* أتمدت كقاعدة أساسية لتطوير خوارزميات التعليم [3].

فالشبكات العصبية هي نوع من أنواع الذكاء الاصطناعي تقوم بتقليد طريقة عمل الدماغ البشري وتخزن المعلومات، أساس عملها هو إنشاء اتصالات بين معالجات رياضية تسمى خلايا عصبية *neurons*. وقوة معرفة الشبكة تعتمد على قوة الاتصالات بين الخلايا المختلفة وهذه الاتصالات تسمى أوزاناً *weights*. ومجموعة من هذه الخلايا العصبية تشكل طبقة وتسمى *layer* حيث تعمل خلايا هذه الطبقة على التوازي وفي نفس الوقت، وإن الشبكة العصبية تتكون من ثلاث طبقات هي طبقة الإدخال *input layer* والطبقة المخفية *hidden layer* وطبقة الإخراج *output layer*. ويتعلم النظام من خلال عملية تحديد عدد الخلايا العصبية في كل طبقة وكذلك ضبط أوزان الاتصالات بناء على بيانات التدريب. في مرحلة التدريب إذا احتاجت الشبكة العصبية لعلم مسبق لبيانات الإدخال والإخراج فإن مرحلة التعليم تسمى التعليم بمُعَلَّم *Supervised Training* أما إذا لم تحتج الشبكة لبيانات الإخراج وكان اعتمادها على بيانات الإدخال فقط فإن مرحلة التعليم تسمى التعليم بدون مُعَلَّم *Unsupervised Training* [3] [4]. والشكل رقم (5) يمثل الخلية العصبية الطبيعية.



الشكل (5) الخلية العصبية الطبيعية


تم استخدام الشبكات العصبية الاصطناعية في عملية التمييز لما تقدمه من كفاءة عالية في العمليات الحسابية واسلوب عملها المتوازي حيث تتميز الخلايا العصبية بالسرعة العالية في معالجة البيانات كما تتميز بقدرتها على التعلم والتعامل مع انماط مختلفة من البيانات التي يكون جزء منها خاطئاً مما جعلها مناسبة لكثير من التطبيقات مثل تمييز الصور والكلام، تمييز الصوت الخ [6].

8. وصف الشبكات العصبية المستخدمة في البحث

تم في هذا البحث استخدام ثلاث شبكات عصبية وهي الشبكة العصبية المتتالية (CNN) وشبكة دالة القاعدة الشعاعية (RBFN) وشبكة ايلمان وتطبيقها مع مصفوفة ال (GLCM) لتمييز بصمة الاصبع لشخص من بين مجموعة من الاشخاص التابعين لنفس قاعدة البيانات.

1.8. الشبكات العصبية المتتالية

شبكة ال CNN مشابهة لشبكات التغذية الأمامية ولكن تحتوي على ترابط بالأوزان من طبقة الإدخال الى كل طبقة تالية لها ومن كل طبقة الى الطبقات التالية لها. على سبيل المثال شبكة ذات ثلاث طبقات تملك ارتباطات من الطبقة 1 الى الطبقة 2، ومن الطبقة 2 الى الطبقة 3، ومن الطبقة 1 الى الطبقة 3. وهذه الشبكة ايضاً تملك ارتباطات من الإدخال الى الطبقات الثلاثة كلها وهذه الارتباطات الإضافية قد تحسن من سرعة تعليم الشبكة للإخراج المرغوب [14],[15]. إن شبكة الذكاء الاصطناعي CNN مشابهة للشبكات العصبية ذات التغذية الأمامية FFNN في أنها تستخدم خوارزمية الانتشار خلفاً لتعديل الأوزان ولكن العلامة الفارقة الأساسية لهذه الشبكة هي أنّ كل طبقة من العقد تكون مترابطة مع كل الطبقات السابقة من العقد، وتستخدم هذه الشبكة دالة التحويل Tan-sigmoid أو log - sigmoid للوصول الى الحالة الامثل [3],[12]. والشكل (6) يبين الهيئة العامة لشبكة CNN.



الشكل (6) الهيئة العامة لشبكة CNN

الشبكات العصبية المتتالية تحوي على ثلاث طبقات : طبقة الادخال , والطبقة المخفية وطبقة الاخراج . والتي هي $u_i, i=1,2, \dots, p, e_i, i=1,2, \dots, n, y_i, i=1,2, \dots, m$ على التتابع.

1.1.8 خوارزمية شبكة الـ CNN

إن معالجة التدريب لشبكة CNN هي معالجة تكرارية iterative process وكل تكرار iteration يتكون من عدد من الخطوات. وإن تدريب الشبكات العصبية المتتالية يمكن أن يتم عن طريق الانتشار خلفاً [16]. وفيما يلي الخطوات الأساسية:

1- في البدء تهيأ الأوزان الابتدائية، وذلك باختيار قيم ابتدائية صغيرة وعلى نحو عشوائي لأوزان الخلايا كلها في الشبكة العصبية .

2- اختيار زوج التدريب من مجموعة التدريب [Input , Target], ونحسب قيمة الإخراج لكل وحدة z في كل طبقة L . كما مبين في المعادلة (5) والمعادلة (6).
فالمعادلة التي تصف اخراج الطبقة المخفية هي:

$$e_i = \phi \left(\sum_{j=1}^p W_{ij}^{eu} u_j + \sum_{k=1}^{i-1} W_{ik}^{ee} e_k + b_i^e \right) \dots \dots \dots (5)$$

حيث :

$\emptyset(\cdot)$ هي دالة التفعيل.

W_{ij}^{eu}, W_{ik}^{ee} هما الاوزان القابلة للتعديل.

u_j, e_k هما الاخراج من طبقة الادخال والطبقة المخفية (الوسطى) على التتابع.

b_i^e هو ال bias .

والدالة التي تصف طبقة الاخراج تكون دالة خطية بحتة وهي: [15]

$$y_i = \left(\sum_{j=1}^p W_{ij}^{yu} u_j + \sum_{k=1}^n W_{ik}^{ye} e_k + b_i^y \right) \dots\dots\dots(6)$$

حيث :

y_i هو الاخراج من عقدة الاخراج.

W_{ij}^{yu}, W_{ik}^{ye} هما الاوزان القابلة للتعديل.

u_j, e_k هما الاخراج من عقد الادخال والعقد المخفية (الوسطى) على التتابع.

b_i^y هو ال bias .

3- نحسب الخطأ بين الإخراج الحقيقي للشبكة والإخراج المطلوب من زوج التدريب، ثم نستخدم القيم المحسوبة من قبل الطبقة الأخيرة، وباعتبار مجموعة عينات التدريب Z مع N من النماذج كالتالي:

$$\dots\dots\dots(7) E(Z; w) = \sum_{i=1}^N ((y_i(j) - T_i(j))^2)$$

حيث :

N هي عدد النماذج.

w هو الوزن القابل للتعديل.

$y_i, i=1, 2, \dots, N$ هو اخراج الشبكة.

$T_i, i=1, 2, \dots, N$ هو الهدف .

4- تحديث الأوزان باستخدام المعادلة الآتية مع الأخذ بنظر الاعتبار منحنى التعديل , فان الخوارزمية التكرارية ستأخذ الشكل التالي :

$$\left\{ \begin{array}{l} w^{(i+1)} = w^{(i)} - \mu^{(i)} H^{(i)} E' (w^{(i)}) \\ w^{(0)} = w_0 \end{array} \right\} \dots\dots\dots(8)$$

حيث:

μ هو حجم الخطوة ويمكن تحديده من خلال البحث على طول الخط المشار إليه.

H هو مصفوفة موجبة .

القيمة البدائية ل w ممكن أن تكون مسبقة التخمين وعملياً فان w_0 يتم توليده عشوائياً.


وفيما يتعلق بالمعادلة (8) فان تحديث منحنى التعديل يبنى ضمناً على اشتقاق دالة الكلفة مع الأخذ بنظر الاعتبار منحنى التعديل [16].

5- نرجع إلى الخطوة الثانية ونكررها لكل النماذج p والى أن يصل الخطأ إلى قيمة مقبولة. من (5) و(6) اذا تم سرد العقد الوسطية بانتظام فان ترابطاتها تشكل التالي *cascad* . وأيضاً إذا تم استخدام المصفوفة لتمثيل الترابطات بين العقد الوسطى فان المصفوفة سوف تكون مصفوفة ثلاثية منخفضة أو مصفوفة ثلاثية علوية وتكون العناصر القطرية كلها صفر(0). وبصورة عامة الشبكات العصبية المتتالية *cascading neural network* هي شبكات تغذية أمامية ولكن في هذه الشبكات مفهوم الطبقات يكون مفقود فكما هو ملاحظ في

الشكل (6) فكل عقد الإدخال والعقد الوسيطة تكون مترابطة مع الإخراجات وكل العقد الوسيطة تكون مترابطة مع بعضها [16].

2.8. شبكة دالة القاعدة الشعاعية RBFN

تعتبر RBFN من شبكات التغذية الأمامية feed forward وتحتوي على طبقة مخفية واحدة ودالة اللياقة لهذه الطبقة تسمى basis functions والشكل (7) يمثل الهيكلية العامة لشبكة دالة القاعدة الشعاعية [4].



الشكل (7): الهيكلية العامة لدالة القاعدة الشعاعية

تقوم هذه الشبكة بتحويل المدخلات بطريقة غير خطية ثم إيجاد المنحني المناسب لإعطاء النتائج الصحيحة. تمزج هذه الشبكة نوعي التعليم للشبكات العصبية (التعليم بمعلم وبدون معلم) *hybrid of unsupervised and supervised learning* بحيث يكون التعليم بين طبقة الإدخال والطبقة المخفية هو تعليم بدون مُعلم *unsupervised* ويتم عنقده البيانات إلى مجاميع حسب قانون المسافة الإقليدية بين بيانات الإدخال وأوزان الطبقة المخفية التي يتم في البداية إختيارها بشكل عشوائي وبدون الحاجة إلى معرفة المخرجات وتسمى دالة اللياقة الخاصة بهذه الطبقة *Gaussian radial basis functions*, أما التعليم بين الطبقة المخفية وطبقة الإخراج فيكون تعليمياً بمُعلم *supervised* ويعتمد على نسبة الخطأ بالاعتماد على المخرجات. المزايا الرئيسية لشبكة دالة القاعدة الشعاعية هي بساطة الدالة المستخدمة ومنحني الدالة يكون سلساً جداً وشعاعي التناظر وغالباً ما يتم إختيار دالة *Gaussian* لتكون هي دالة القاعدة الشعاعية حيث إنها تستطيع أن تحدث تقارباً في أي وظيفة ثابتة من دون الاعتماد على نموذج النظام [5].

وتمثل *Gaussian* بين طبقة الإدخال والطبقة المخفية بالمعادلة التالية:

$$\varphi(x) = \exp\left(-\frac{\|x - c_j\|^2}{2\sigma^2}\right) \dots\dots\dots(9)$$

حيث c يمثل الوزن المرتبط بالطبقة المخفية j .

σ تمثل المعلمة الخاصة بالتحكم بالانتشار حول المنحني.

أما عملية المعالجة بين الطبقة المخفية وطبقة الإخراج فتكون خطية ويتم حساب ناتج طبقة الإخراج كالتالي :

$$y_m = \sum_{j=1}^m w_j \varphi_j \dots\dots\dots(10)$$

حيث w_j هو وزن الاتصال بين الطبقة المخفية j وطبقة الإخراج. m هو عدد الخلايا العصبية في الطبقة المخفية.

ويمكن أيضاً استخدام دالة *Sigmoid* بدل التحويل الخطي ويكون التحويل هنا غير خطي *non-linear*

ثم يتم تعديل أوزان طبقة الإخراج بالمعادلة التالية والتي تسمى *linear least estimation* :

$$new_w = old_w + (E * learning_rate * \varphi) \dots\dots\dots(11)$$

حيث إن *learning_rate* هي نسبة التعلم وتكون بين [1.0 - 0.0] و E هي نسبة الخطأ

وتُسمى دالة الأداء *performance function* :

$$E(k) = \frac{1}{2} (y(k) - y_m(k))^2 \dots\dots\dots(12)$$

حيث \mathcal{Y} يمثل الإخراج الحقيقي للشبكة و \mathcal{Y}_m هو ناتج طبقة الإخراج. وكلما اقتربت نسبة الخطأ من الصفر ازدادت فرصة الوصول للحل الأمثل.

إن *RBFN* تجهز بجل ممتاز للعديد من مشاكل تمييز الأنماط والتصنيف والتنبؤ. وكذلك *RBFN* ممكن

تطبيقها بنجاح لتقريب الدوال الغير خطية وتصنيف البيانات وعلى نطاق واسع [5].

1.2.8. خوارزمية شبكة دالة القاعدة الشعاعية *RBFN*

عملية التدريب للـ *RBFN* هي عملية تكرارية أو دورية. وكل دورة تتألف من الخطوات

التالية [5]:

1- تكوين أوزان الشبكة W بقيم عشوائية صغيرة.

2- اختيار زوج التدريب التالي من مجموعة التدريب [input, target], وحساب قيم الإخراج باتجاه أمامي لكل وحدة j من الطبقة المخفية وذلك:

$$\varphi_j(x) = \exp \left[- \frac{\|x - \mu_j\|^2}{2\sigma_j^2} \right] \dots\dots\dots(14)$$

3- حساب قيم الاخراج وباتجاه أمامي لكل وحدة k من طبقة الإخراج وذلك:

$$\psi_k(x) = \sum_{j=1}^L W_{jk} \varphi_j(x) + W_0 \dots\dots\dots(15)$$

4- حساب نسبة الخطأ بين الاخراج الحقيقي للشبكة $\psi_k(x)$ والإخراج المطلوب $t_k(x)$ من متجه الهدف من

زوج التدريب، وبعدها، استخدام قيم $\psi_k(x)$ المحسوبة من قبل وحدات الطبقة النهائية والقيم المماثلة $t_k(x)$

لحساب مقادير أو كميات الدلتا $\delta_k^o(x)$.

$$\delta_k^o(x) = (t_k(x) - \psi_k(x)) \dots\dots\dots(16)$$

لكل k تستخدم النموذج x .

5- تعديل الأوزان W باستخدام:

$$W_{jk}^{new} = W_{jk}^{old} + \Delta W_{jk} \dots\dots\dots(17)$$


$$\Delta W_{jk} = \eta \delta_k^o(x) \varphi_j(x) \dots\dots\dots(18)$$

6- العودة للخطوة 3 وإعادة الخطوات لكل نموذج x في مجموعة التدريب لحد الوصول إلى نسبة الخطأ الكلية والقيمة المقبولة.

3.8. الشبكة العصبية إيلمان

تتألف شبكة إيلمان Elman في الأقل من ثلاث طبقات من الخلايا: طبقة الإدخال، والطبقة الوسطى وتسمى الطبقة المخفية، وطبقة الإخراج. و ترتبط كل طبقة في الشبكة بالطبقة التي تليها مع ارتباط خلايا الطبقة الوسطى أيضاً مع طبقة الإدخال وهذا يعني أن أي خلية في طبقة الإدخال ترسل إخراجها إلى الخلايا كلها في الطبقة الوسطى، و ترسل خلايا الطبقة الوسطى إخراجها إلى كل خلية في طبقة الإخراج والى طبقة الإدخال. ويعتمد عدد الخلايا في الطبقة الوسطى على درجة تعقيد المسألة وحجم معلومات الإدخال [17].

ويوضح الشكل (8) التركيب العام للشبكة العصبية Elman المتكونة من ثلاث طبقات وهي طبقة الإدخال والطبقة الوسطى وطبقة الإخراج على الترتيب.



الشكل (8) التركيب العام للشبكة العصبية إيلمان ENN

1.3.8. خوارزمية تعليم شبكة إيلمان

إن معالجة التدريب لشبكة ENN هي معالجة تكرارية وكل تكرار يتكون من عدد من الخطوات . ويضرب كل إدخال إلى الخلايا في الوزن المقابل له، ثم تجمع الإدخالات الموزونة ويطلق على هذا الجمع مصطلح NET. وبعد حساب الإخراج NET يمرر على دالة F المتمثلة بإحدى دوال الفعالية لتحويلها إلى إشارة الـ Out [17].

وقد استخدمت في هذا البحث الدالة السيجماوية *Sigmoid Function* إذ توصف بأن مشتقتها بسيطة .

$$out = f(NE T_j) = \frac{1}{1 + e^{-NE T_j}}$$

$$f'(NE T_j) = out(1 - out) \dots\dots\dots(19)$$

وتسمى الدالة السجموية أحياناً بالدالة المنطقية *logistic Function* أو دالة الإخماد *Squashing Function* وذلك لأنها تكبس مدى الإخراج Net_j والإخراج الحقيقي out بين الصفر والواحد . والخطوات التالية توضح خوارزمية الـ ENN [16] :

1- في البدء تهيأ الأوزان الابتدائية، وذلك باختيار قيم ابتدائية صغيرة وعلى نحو عشوائي لأوزان الخلايا كلها في الشبكة العصبية .

2- اختيار زوج التدريب من مجموعة التدريب [*Input ، Target*] الذي يمثل الإدخال والإخراج المطلوبين وتحسب قيم الإخراج لكل خلية في كل طبقة L في الشبكة.

$$net_{pj}^{L+1} = \sum_{i=1}^{n^L} W_{ij}^L out_i^L \dots\dots\dots(20)$$

$$out_{pj}^{L+1} = f(net_{pj}^{L+1}) = \frac{1}{1 + e^{-net_{pj}^{L+1}}} \dots\dots\dots(21)$$

إذ أن:

net_{pj}^{L+1} عبارة عن مجموع ضرب الإدخالات كلها للخلية j في الأوزان المقابلة لها .

وإن out_{pj}^{L+1} هو إخراج الوحدة j بعد تطبيق الدالة السجموية عليها في الطبقة $L+1$.

كما أن $out_{pj}^o = x_j$ يمثل إدخال النموذج و p رقم النموذج و j رقم الخلية .

3- يحسب الخطأ بين الإخراج الحقيقي للشبكة والإخراج المتوقع من زوج التدريب. ثم نستخدم out_{pj}^o الإخراج الحقيقي مع الإخراج t_{pj} المتوقع لحساب (δ) من المعادلة (22) .

$$\delta_{pj}^o = (t_{pj} - out_{pj}^o) f'(net_{pj}^o) \dots\dots\dots(22)$$

4- نحسب قيمة (δ) للطبقات الوسطى كلها باستخدام الخطأ خلفاً وحسب المعادلة (23) .

$$\delta_{pi}^{L+1} = f'(net_{pi}^{L+1}) \left[\sum_{j=1}^{m^{L+2}} \delta_{pj}^{L+2} w_{ij}^{L+1} \right] \dots\dots\dots(23)$$

إذ إن m هي عدد الخلايا في الطبقة $L+2$.

5- تغيير الأوزان باتباع المعادلات (24), (25) .

$$w_{ij}^{new} = w_{ij}^{old} + \Delta w_{ij}^L \dots (24)$$

إذ إن w_{ij}^L يحسب من المعادلة (20) .

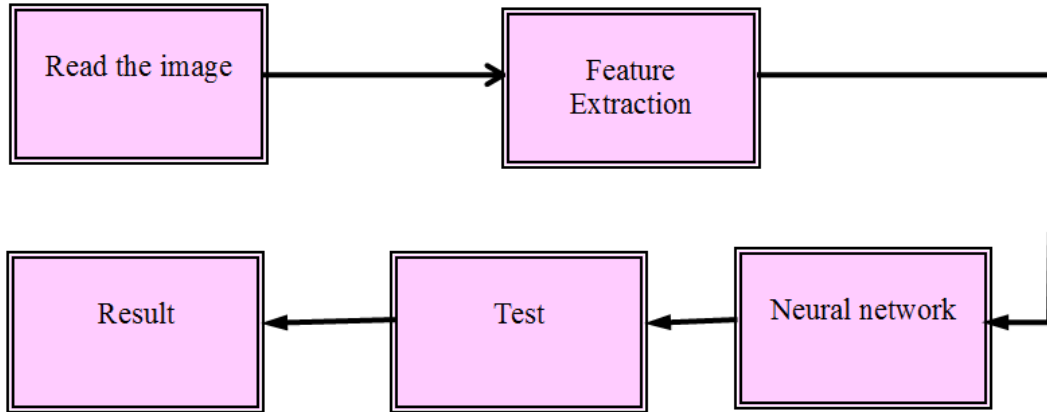
$$\Delta w_{ij}^L = \eta \delta_{pj}^{L+1} out_{pj}^L \dots (25)$$

6- تغيير الأوزان للطبقات المخفية, عكس طبقة الإخراج فان قيمة الخطأ لا يمكن حسابها مباشرة, حيث لا تحتوي الطبقات الوسطى على الإخراج المطلوب وتغَيَّر شبكة ENN الأوزان للطبقات الوسطى عن طريق انتشار الخطأ خلفاً من طبقة الإخراج نحو طبقة الإدخال وتغير الأوزان لكل طبقة .

9. مراحل العمل المستخدمة في البحث

في هذا البحث تم تمييز بصمة الاصبع بالاعتماد على مجموعة بيانات مزودة لطبقة الإدخال الخاصة بالشبكة المستخدمة والتي قد تم استخلاصها من صورة البصمة بالاعتماد على مصفوفة ال glcm, ومن ثم كيفية تدريب هذه البيانات وأخيراً كيف يتم اختبار الشبكة المستخدمة في التمييز وكما هو موضح بالشكل (8) الذي يوضح خطوات سير العمل. وعلى هذا الأساس فان عملنا هذا يبدأ بتحضير بيانات الإدخال ومعالجتها، ثم اختيار الخوارزمية المستخدمة في التدريب والاختبار ، وبعد هذا تخزين قيم الأوزان النهائية.

يقسم العمل على ثلاث مراحل: الأولى عملية تهيئة خواص الصورة ، والثانية تعريف بنية الشبكة العصبية المستخدمة بالاعتماد على الخواص المستخلصة من مصفوفة ال glcm والثالثة هي عرض نتيجة التمييز وتحديد هوية الشخص من قاعدة البيانات أو رفضه.



الشكل (8) مخطط سير العمل

1.9. تهيئة البيانات المدخلة

في البداية يتم ادخال صورة بصمة الاصبع بأسلوب معين مثلاً بواسطة الماسح الضوئي اوصورة مخزونة على شكل فايل من نوع (bmp) ، حيث البيانات المدخلة على النظام تمثل مجموعة الصفات المستخلصة لصورة بصمة الاصبع ، التي تم الحصول عليها من خلال دراسة وتحليل الصورة باستخدام مصفوفة (GLCM) حيث يتم استخلاص الصفات الخاصة بالصورة وهي التباين والترابط والعزم والتجانس وذلك لاستخدامها في تدريب الشبكة .

2.9. تهيئة الشبكة العصبية المستخدمة

إن هيكلية الشبكة يجب أن تتلاءم مع هيئة المشكلة المراد حلها ، حيث من خلال العمل تبين ان الشبكة تحتاج الى (4) عقد تمثل متجه الإدخال (Input Vector) التي تمثل الصفات الناتجة من تحليل الصورة باستخدام مصفوفة التواجد (GLCM) و(6) عقد تمثل قيمة الاخراج للشبكة (output vector) التي تكون كافية لكي تشمل قاعدة البيانات المصممة و التي تمثل عدد الاشخاص المراد تمييزهم , وكذلك تم استخدام (4) عقد في الطبقة المخفية (hidden layer) .

تم في هذا البحث استخدام الشبكات العصبية الثلاث (CNN, RBFN, ELMN)

3.9. عملية التمييز

بعد أن تم تدريب الشبكات وأصبحت جاهزة للعمل كأداة في نظام تمييز بصمة الاصبع يكون عملها مشابه لمرحلة التدريب ولكنه يدعى هنا بمرحلة الاسترجاع ، وكذلك هيكلية الشبكة المستخدمة في مرحلة التدريب لا يُجرى عليها أي تغيير ولكن الفرق أن البيانات المستخدمة في مرحلة التدريب لا تستعمل في هذه المرحلة بدلاً من ذلك تستعمل الأوزان المخزونه بعد استقرار الشبكة والحصول على الأوزان المثالية. التي سوف تمثل أوزان ابتدائية وثابتة في الشبكة ، في هذه الحالة تستطيع الشبكة تحليل الإدخال لكي تميز صورة البصمة من خلال صفات المستخلصة من الصورة باستخدام المصفوفة هل الشخص من ضمن قاعدة البيانات ام لا، وعملها تم تطبيق الشبكات الثلاث على (6) اشخاص لكل شخص (3) عينات (بصمات) وبذلك يصبح عدد العينات المدربة هو (18) عينة، وكل عينة تمثل ب(4) قيم هي خواص صورة البصمة التي تم استخلاصها

10. حساب مقاييس التقييم

سوف يتم في هذا البحث استخدام نوعين من مقاييس التقييم لاختبار كفاءة كل شبكة المقياس الاول هو training rate يتم فيه قياس نسبة صحة تدريب كل شبكة باستخدام القانون التالي(18):

$$\text{نسبة صحة التصنيف} = \frac{\text{عدد البصمات المميّزة صحيح}}{\text{العدد الكلي للبصمات}} \times 100\% \dots\dots\dots (26)$$

العدد الكلي للبصمات

اما المقياس الثاني فهو recognition rate الذي يستخدم لقياس نسبة تمييز الشبكة حيث تعرف الاخطاء بFalse Accept Rate (FAR) التي تمثل نسبة تمييز الشبكة للحالات الخاطئة على انها صحيحة ، والا False Reject Rate (FRR) التي تمثل نسبة تمييز الشبكة للحالات الخاطئة على انها خاطئة والتي تحسب من خلال القانون التالي(19):

$$FAR = \frac{\text{Number of incidents of false accepted}}{\text{Total number of samples}} \times 100\% \dots\dots\dots (27)$$

$$FRR = \frac{\text{Number of incidents of false rejected}}{\text{Total number of samples}} \times 100\% \dots\dots\dots (28)$$

حيث ال RR يحسب بالشكل التالي :



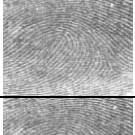
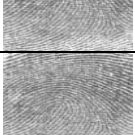
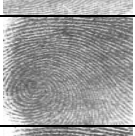


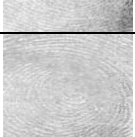
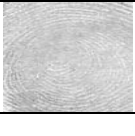
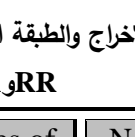
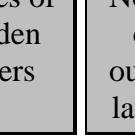
$$RR \% = 100 - (FAR + FRR) \dots\dots\dots (29)$$

11. نتائج عملية تمييز بصمة الاصبع

في هذا العمل تم استخدام الصور ذات التدرجات الرمادية ،حيث تم تمييز بصمة الاصبع باستخدام ثلاث شبكات عصبية وبالاعتماد على (GLCM) حيث كانت قاعدة البيانات مؤلفة من مجموعة من الاشخاص المراد تمييز هويتهم ،وكل شخص كان لديه ثلاث عينات من بصمات الاصابع ،تم استخلاص الخواص الخاصة لكل عينة بالاعتماد على مصفوفة (GLCM) وهذه الخواص هي [energy،correlation، contrast،homogeneity]، بعدها تم تدريب الشبكات كل واحدة حسب خوارزمتها بالاعتماد على الخواص المستخلصة من الصورة وتمييز هذه البصمة بانها ثابتة لذلك الشخص ،ومتى ما تم تمييز البصمة فان البرنامج سوف يعطي بيانات متكاملة عن الشخص المراد تمييز هويته والجدول (1) التالي يوضح قاعدة البيانات التي تحتوي على العينات الخاصة بكل شخص مع حساب الخواص الثابتة لكل عينة بالاضافة الى معلومات خاصة بذلك الشخص ،اما الجدول (2) فانه يوضح كل شبكة مع عدد خلايا الادخال والايخراج مع عدد خلايا الطبقة المخفية بالاضافة الى قيم مقاييس التقييم لكل شبكة،اما عدديعينات التدبير فكانت مكونة من(18) صورة بصمة اصبع وعدديعينات الاختبار (3)بصمات تابعة لاشخاص مختلفين.

جدول(1) المعلومات الخاصة بقاعدة البيانات

التجانس	العزم	الارتباط	التباين	عينة البصمة	العمر	الجنس	الاسم الكامل
0.9256	0.2165	0.915	0.1488		30	ذكر	احمد محمد عمر
0.9145	0.2047	0.904	0.1711				
0.9347	0.2307	0.9258	0.1306				
0.8998	0.1973	0.8827	0.2004		38	ذكر	اوس علي احمد
0.8833	0.1894	0.8526	0.2337				
0.9047	0.2378	0.8630	0.1905				
0.9129	0.3013	0.8036	0.1741		25	انثى	نور غانم علي

0.8928	0.2133	0.8459	0.2145				
0.8089	0.2505	0.8148	0.2043				
0.9058	0.2834	0.7916	0.1883		33	ذكر	احمد حازم صابر
0.898	0.2672	0.8072	0.2041				
0.8991	0.2741	7975	0.202				
0.7161	0.0991	0.6454	0.8129		45	ذكر	يونس بلال عمار
0.6946	0.0703	0.6993	0.9535				
0.721	0.1018	0.5746	0.7886				
0.8914	0.3444	0.7565	0.2238		27	انثى	سوسن عماد سعيد
0.8769	0.3538	0.5011	0.2501				
0.872	0.3488	0.4814	0.2593				

جدول (2) عدد الخلايا في طبقة الادخال والاخراج والطبقة المخفية وعدد التكرارات لكل شبكة مع حساب مقياس

TR وRR

Training Rate	Recognition rate	iteration number	Nodes of hidden layers	Nodes of output layers	Nodes of input layers	Neural Network Name
%100	%100	18	4	6	4	RBFN
%100	% 99.877	2382	4	6	4	ELMAN
%100	% 99.542	4158	4	6	4	CNN

12. الاستنتاجات

من خلال دراسة عملية التمييز لصور بصمة الاصبع باستخدام الشبكات العصبية الاصطناعية وبالاعتماد على مصفوفة التواجد ان استخدام هذه الشبكات العصبية تعتبر من الاساليب المتميزة في حل مشكلة تمييز بصمات الاصابع حيث اعطت نتائج ممتازة عند التمييز على عدة عينات لبصمات الاصابع مع العلم ان الشبكة العصبية المتتالية قد تم التطرق اليها لأول مرة في عملية تمييز بصمة الاصبع ولم يسبق لاحد ان استخدمها في هذا المجال وقد اعطت نتائج ممتازة كما في بقية الشبكات المستخدمة ،حيث كانت شبكة القاعدة الشعاعية هي افضل الشبكات المستخدمة من خلال ملاحظة قيم مقاييس التقييم المستخدمة في هذا البحث،ففي مرحلة التدريب كانت نسبة التمييز ونسبة التدريب 100% وذلك لان شبكة RBFN تحتوي على الطبقة الوسطى التي تكون عبارة عن طبقة عنقدة للبيانات لاحتوائها على دالة الكاوزين (Gaussian baiss function) لذا تميزت هذه الشبكة بدقتها في عملية التمييز و التدريب. ،ثم تليها شبكة ايلمان التي كانت نسبة التمييز لها 99.877 ونسبة التدريب 100% واخيرا الشبكة العصبية المتتالية التي كانت نسبة التمييز لها 99.542 ونسبة التدريب 100% عندما كانت عدد العقد في طبقة الادخال (4) عقد , عدد العقد في الطبقة المخفية (4) عقد, عدد العقد في طبقة الاخراج (6) عقد بالنسبة للثلاث شبكات.

عند استخدام التقنيات الذكائية المتمثلة بالشبكات العصبية الثلاث التي تم استخدامها ضمن البحث اعطت نتائج ممتازة وبذلك كانت الطرق الذكائية افضل بكثير من الطرق التقليدية في تمييز بصمة الاصبع حيث الاخيرة لاتستطيع اعطاء نسبة تمييز اعلى من جيدة، حيث صفة التقنيات الذكائية انها تعطي تصنيفات ممتازة .

المصادر

- [1] سعيد ،نغم ثروت ، (2006) ، "تمييز بصمة الاصبع باستخدام البعد الكسري" ، رسالة ماجستير ، قسم علوم الحاسبات ، كلية علوم الحاسبات والرياضيات،جامعة الموصل ، العراق.
- [2] النعيمي، ميسون خضر،(2011)،"تمييز بصمة الاصبع باستخلاص الخواص وابعتماد الشبكات العصبية"،المجلة العراقية للعلوم الاحصائية (20) ، المؤتمر العلمي الرابع لكلية علوم الحاسوب والرياضيات ص [690-975]،جامعة الموصل،العراق
- [3] قبيح، اسراء زهير مجيد ،(2012) ،"تخمين مشاريع البرمجيات باستخدام اساليب الذكاء الاصطناعي"، رسالة ماجستير، قسم هندسة البرمجيات ، كلية علوم الحاسوب والرياضيات،جامعة الموصل ، العراق.
- [4] رشيدلي ،كرم محمد مهدي صالح ، (2012)،"تصميم وتنفيذ نظام كشف التطفل باستخدام التقنيات الذكائية" ، رسالة ماجستير، قسم هندسة البرمجيات ، كلية علوم الحاسوب والرياضيات،جامعة الموصل ، العراق.
- [5] خليل ،شهباء ابراهيم ،(2006)، " الاسترجاع الكفوء للوسائط المتعددة المعتمد على المحتوى بالشبكات العصبية" ، رسالة دكتوراه ، كلية علوم الحاسوب والرياضيات/ قسم علوم الحاسبات- جامعة الموصل.
- [6] الزبيدي ،لهيب محمد ابراهيم ،الدليمي ،حنان حامد علي،(2008) ،"استخدام الشبكة العصبية الاصطناعية نيوكونكترون في تمييز الرقام العربية المكتوبة يدويا"،المؤتمر العلمي الاول لتقانة المعلومات ،كلية علوم الحاسوب والرياضيات ،جامعة الموصل ،العراق
- [7] Sushmita Mitrak,Sankar K.Pal and Malay K.kundu,"Fingerprint classification using a fuzy Multilayer perceptron unit,Machine Intelligence unit, Indian statistical Institute, Calcutta,India.
- [8] Mehran yazdi,and kazem gheysari, (2008),"A New Approach for the fingerprint classification Based on gray level Co-occurrence Matrix",International Journal of computer and Information Engineering .
- [9] Fakheri,M.M.;Mashoufi,B.Sedghi,T., , (2010),"A Novel Approach for Fingerprinting Recognition",internatonal review on computer &software.
- [10] Adnan Amin , (2004),"fingerprint classification:a revw springer-verlag London,Neil Yager.
- [11] Kyuheon Kim, Seyoon Jeong, Byung Tae Chun, Jae Yeon Lee, Younglae Bae, (1999), "Efficient video images retrieval by using local cooccurrence matrix texture features and normalized correlation" ,Proceedings of the IEEE Region 10 Conference TENCON 99. Vol. 2, pp 934-937.
- [12] MATLAB help, R2011b,(2011) "neural network toolbox".
- [13] Shashi Kumar D R, K B Raja, R K Chhotaray, Sabyasachi Pattanaik,

-
- (2011), "DWT Based Fingerprint Recognition using Non Minutiae Features", IJCSI International Journal of Computer Science Issues, Vol. 8, Issue 2.
- [14] Sumit Goyal, Gyandera Kumar Goyal, (2011), "Cascade and Feedforward Backpropagation Artificial Neural Network Models For Prediction of Sensory Quality of Instant Coffee Flavoured Sterilized Drink", Canadian Journal on Artificial Intelligence, Machine Learning and Pattern Recognition.
- [15] Mark Hudson Beale, Martin T. Hagan, Howard B. Demuth, (2012), "Neural Network Toolbox™ User's Guide R2012b".
- [16] Kang Li, Stephen Thompson, (2000), "A Cascaded Neural Network and Its Application to Modelling Power Plant Pollutant Emission", IEEE, Proceedings of the 3d World Congress on Intelligent Control and Automation.
- [17] H.Ritter, T.Kohonen " Self-Organizing Semantic Maps", Biological Cybernetics, Springer, 241-254.
- [18] Al-irhim, Yousra F., (2007), "Corpus Based Arabic Speech Recognition", A Ph.D. thesis, college of computer and mathematical sciences, computer science department, Mosul university.
- [19] Al-Gurairi, Maha.A.H,(2006)," Biometric Identification Based on Improved Iris Recognition Techniques", A Ph.D. thesis, college of computer and mathematical sciences, computer science department, Mosul university.