التصنيف الأمثل لمعطيات التحسس النائي باستخدام التعليم الموجه وغير الموجه للشبكات العصبية

كنار محمد سامي مصطفى
قسم الحاسبات/ كلية التربية
جامعة الموصل

لبنى ذنون الكحلى
كلية طب نينوى
جامعة الموصل

الاستلام **2009 / 09 / 28**

القبول **2010 / 01 / 05**

Abstract

The study of multi classification of data has become one of the important issues which geographical studies focus on especially those which take their data from satellites.

Two ways of classification has been taken into consideration, each one completes the other. The two ways are used together to get the benefits of both and to obtain the full advantage. The data of remote sensing were chosen to be tested.

The system suggested is a software package which consists of neural networks of supervised learning and neural networks of unsupervised learning to classify the land of (Al-Mosul Dam) in Mosul city.

The best use of remotely sensed data is by using the methods of supervised and unsupervised classification consequently which improve the primary input data in the classification. Thus, a high degree of accuracy and efficiency in the classification are obtained.

It is worth mentioning that software package used in the integration consists of the nets: the supervised ART-II neural network and the unsupervised Kohonen neural network.

الملخص

أصبحت دراسة التصنيف المتعدد للبيانات من المسائل المهمة التي ركزت عليها الدراسات الجغرافية وخصوصاً تلك الدراسات التي تأخذ بياناتها من الاقمار الصناعية. تم في

هذا البحث الاخذ بعين الاعتبار طريقتين من طرق التصنيف احداها مكملة للأخرى وتستخدمان سوية حيث يتم جمع فوائد كلتا الطريقتين للحصول على الفائدة الكلية، وقد تم اختيار بيانات التحسس النائي لاجراء الاختبارات عليها. ان النظام الذي تم اقتراحه هو عبارة عن حزمة برمجية متكونة من الشبكات العصبية ذات التعليم الموجه والشبكات العصبية ذات التعليم غير الموجه لتصنيف منطقة (سد الموصل) في مدينة الموصل. ان الاستغلال الامثل لمعطيات التحسس النائي عن طريق استخدام اسلوبي التصنيف الموجه وغير الموجه بشكل متتالي يعمل على تحسين المعلومات الأولية التي تدخل في التصنيف وبالتالي الحصول على درجة عالية في الدقة والكفاءة في التصنيف.

ومن الجدير بالذكر ان الحزمة البرمجية التي تم استخدامها في التكامل تتكون من الشبكتين (ART-II) ذات التعليم الموجه و(Koheneen) ذات التعليم غير الموجه.

1. المقدمة

تعد المعالجة الرقمية للمرئيات الفضائية من اهم التقنيات المستخدمة في الوقت الحاضر في مجال التحسس النائي. ومما ساعد في سرعة انتشار تطبيق هذه التقنية، امكانية الحصول على معطيات الاقمار الصناعية بشكل رقمي ولأطوال موجية متعددة من جهة، ومن جهة اخرى التطور الكبير الذي تشهده الحواسيب من حيث سرعة معالجتها للمعطيات الرقمية واللامكانية الهائلة لتخزينها. وازاء هذه الديناميكية العالية نستطيع ان نقول ان المزايا الاساسية لطرائق المعالجة الرقمية تتمثل في تنوعها وامكانية تكرارها ومحافظتها على دقة المعطيات الاصلية للمرئية نفسها [15]. واحدى تلك الطرائق في المعالجة هي تصنيف المعطيات باستخدام الشبكات العصبية الاصطناعية.

الشبكات العصبية الاصطناعية هي احد الاتجاهات الحديثة في تطبيق الحواسيب الالكترونية فقد جاءت بديلا عن الاساليب التقليدية في المعالجة التي واجهت مشكلات كبيرة واساسية في التطبيقات الحديثةو وانتهجت معمارية واسلوب عمل الانظمة الطبيعية كالمحاكاة للوصول الى انتاج اجهزة وبرامج ذكية [12].

فهي تتميز بقدرتها على تميز الانماط لامتلاكها القدرة على تعلم نمط جديد بمجرد تمريره على الشبكة [14]. وبشكل عام يمكن تمييز نوعين من التعلم في الشبكات العصبية الاصطناعية يمثل النوع الاول التعليم الوجه (Supervised learning) الذي يتم التعلم فيه بادخال كل من المعطيات المدخلة (Input data) والخرج المطلب (Desired output) ويستمر التعليم الى ان يصبح الفرق بين القيمتين مقاربا للصفر. واشهر شبكات هذا النوع من التعلم والمستخدمة في تصنيف معطيات التحسس النائي هي شبكة المدرك (Perceptron) متعددة الطبقات وشبكة الرنين التكيفي ART-I وشبكة الرنين التكيفي ART-II.

اما النوع الثاني من الشبكات فيمثل الشبكات ذات التعلم غير الموجه (Unsupervised) في هذا النوع من التعلم لا تحتاج الشبكة الى وجود الخرج المطلوب ويكتفي بادخال المعطيات او تحدث عملية تنظيم ذاتي بالاعتماد على درجة التشابه والاختلاف بين الاصناف الداخلة ويكون الخرج عبارة عن مجموعة غير معلومة العدد من الاصناف، واكثر الشبكات استخداما في تصنيف معطيات التحسس النائي هي شبكة التنظيم الذاتي (Self Organizing Network).

وقد استخدمت الشبكات العصبية في عملية التصنيف بشكل واسع ومنتشر وذلك لما تتميز به من السرعة الفائقة في التنفيذ مقارنة بالطرق التقليدية وكذلك عدم حاجتها الى فرض موديلات رياضية واحصائية كما هو الحال في الطرق التقليدية [3].

ونظراً لاهمية الشبكات العصبية فقد استخدمت في مجالات عديدة ومتنوعة حيث استخدمت لاول مرة من قبل (Key et al,1989) [8] في تطبيقات التحسس النائي متعددة الاطياف بواسطة المتحسسات SMMR، وازداد استخدامها فيما بعد من قبل العديد من الباحثين في هذا المجال حيث استخدم (Lee et al,1990) [9] في تصنيف الغابات باستخدام الصور المأخوذة بالقمر الصناعي (TM)، وكذلك استخدمت من قبل (AL-Rawi&Casanova, 1999) [4] لنفس الغرض ولكن باستخدام شبكة (ART-II)، وقد تم استخدام شبكة (Kohonen) من قبل الباحثين (Mather et al,1998) [11] لتصنيف الصخور باستخدام المتحسس (TM) في حين تم استخدام شبكة الرنين التكيفي من قبل الباحثة (AL-Omran,2000) [1] في ايجاد طريقة جديدة في حساب التماثل او التشابه بين المتجهات المميزة لكل صنف من الاصناف المحتواة لغرض عزل هذه المتجهات وتصنيفها وقد اعطت هذه الطريقة نتائج دقيقة.

2. التكامل في الشبكات العصبية

لقد شغل موضوع التكامل في الشبكات العصبية عقول الكثير من الباحثين خاصة بعد ان بدأت نقاط الضعف بالظهور عند استخدام الشبكات العصبية بشكل منفرد في حل المسائل المعقدة، ومن الباحثين الذين استخدموا التكامل في مجال تصنيف بيانات التحسس النائي: (Wilkinson et. al ,1995) [14] حيث قاما بتصنيف البيانات الفضائية باستخدام طريقة التكامل بين الشبكات العصبية والطرق الاحصائية وقد تم اجراء التكامل بين شبكة بيرسبترون ذات التعليم الموجه وطريقة Maximum Likelihood الاحصائية. اما الباحثة (AL-Shaumam,2001) [5] فقد اعتمدت في تصميم نظامها على دراسة لطرائق الشبكات العصبية ومقارنتها مع طرائق التصنيف التقليدية حيث استخدمت الشبكة العصبية (Kohonen(SOM)) غير الموجهة.

ان المحاولات السابقة التي استهدفت تحسين اداء الشبكات العصبية لتحقيق نظام تصنيف متكامل كانت اغلبها تفتقر الى الشمولية فكانت مقتصرة على تحقيق التكامل بين نوع واحد من

الشبكات العصبية واكثرها اقتصرت على التكامل الموجه ربما بسبب سهولة حـساب النتـائج وذلك لوجود نماذج اولية داخلة في صياغة القرار ,ولكن على الرغم من هذه الميزة التي تتمتع بها الشبكات العصبية الموجهة الا انه يراعى فيها الدقة العالية في اختيار مساحات التـدريب لان دقة التصنيف تعتمد بدرجة كبيرة على دقة اختيار نماذج تدريب من مناطق ذات تـداخل كبير في اغطية الارض [3].

اما في التصنيف غير الموجه فلم تجري محاولات جادة لتحقيق تكامل وذلك لصعوبة استنتاج مدلولات يمكن من خلالها صياغة طريقة معينة لحساب كفاءة الطرائق المراد تكاملها وكـذلك يجب معرفة معلومات مسبقة عن المعطيات المراد تصنيفها وفي هذه الحالة يتم اخذ معطيـات بشكل عشوائي مما يقلل من الكفاءة والدقة لعملية التصنيف[7]، لهذا السبب تم اقتراح وتصميم منهج يمكن من خلاله تحقيق تكامل بين خوارزميات التصنيف الموجه وغير الموجه للحصول على دقة وكفاءة عالية من خلال الاستفادة من النتائج التي يتم الحصول عليها من اخذ محاسن كلا النوعين (الموجه وغير الموجه).

3. الشبكات العصبية المستخدمة

تم في هذا البحث استخدام شبكتين عصبيتين الأولى ART-II والثانية شبكة Kohenen.

3-1 شبكة الرنين التكيفي الموجهة ART-II

Adaptive Resonance Theory Supervised Network

لقد طوّرت أول شبكة ART غير الموجهة من قبل (Grossbergh, 1976) [ ]، تـم بعدها تطوير عدد من صيغ الـART غير الموجهة، (ART1,ART2, ART3, SART, Fuzzy ART)، وتم في مطلع التسعينات تطوير صيغتين مـن شـبكات ART الموجهـة، وكانت أولاهما ARTMAP، التي لها القابلية على تدريب وتصنيف الأنماط المتعـددة القـيم الممثلة ثنائياً (Binary)، والصيغة الثانية هي(Fuzzy ARTMAP) التي لها القابليـة علـى تدريب وتصنيف البيانات المستمرة الممثلة تناظرياً (analog). تتركب ARTMAP من زوج من ART، في حين أن الـ Fuzzy ARTMAP تتركب من زوج من (Fuzzy ART).

وتـم حـديثاً، تطـوير شـبكة الـرنين الموجهـة مـن نـوع (ART-I) من قبـل (AL-Rawi et. al., 1999) [4]، وهـذه الـشبكة تـشبه شـبكة الـ Fuzzy ARTMAP، فهي تملك القدرة على تعليم وتصنيف الأنماط متعددة القيم على شكل (binary, analog)، وهي تملك معمارية سهلة ومعاملات قليلة وتتطلب ذاكرة أصغر مما تتطلبه الـ Fuzzy ARTMAP وهذا يقود إلى خوارزميات سريعة للتعليم والتصنيف وبالدقة نفسها التي يمكن الحصول عليها من الـFuzzy ARTMAP، ان الإنجاز العظـيم للـ Supervised ART I يكمن في أن معماريتها تبنى من Fuzzy ART مفردة بدلاً مـن زوج مـن Fuzzy ART الذي تبنى منه الـFuzzy ARTMAP وهذا يقود إلى إلغاء الـ(Map Field).

ان مثل هذه الهيئة من الشبكات ساعدت على بناء تكوين جديد للـ ART-I الموجهة الذي يسمى شبكة الرنين الموجهة نوع (ART II)، وهو أسرع في التعليم ويتطلب ذاكرة أقل. أن دقة التصنيف والمعاملات لا تختلف عما موجود في الـART-I.

تبنى شبكة الرنين الموجهة (ART II)، كما تبنى شبكة الرنين الموجهـة (ART I) من صيغة مفردة من الـFuzzy ART، ان ذاكرة النقاط التي مـن نـوع ART Iالموجهـة احادية الأبعاد (N) تقسم على عدد من الذاكرات أحادية الأبعاد في الشبكة ART-II تسمى كل منها Stack وعددها L وتحوي كل منها عدداً من العقد هو N ويرمز لهـا عـادة Nk اذ k يشير إلى رقم الصنف وN يشير إلى عدد العقد، اذ أن $N_k; k = 1..L$

في ART II الموجهة، وكما مبين في الشكل (3-2)، تـدعى كـل ذاكـرة أحاديـة الأبعاد N_k بـ "Stack" ويمثل عدد الـ stacks (k) رمز الـصنف (Class Code) لكـل العقد المحجوزة (Committed Nodes). وليس من الضروري أن يكون حجم الـذاكرة N_k (عدد العقد الخاصة للحجز) في كل stack متساوياً. انما يعتمد حجم الـذاكرة علـى طبيعـة البيانات وحجمها في كل صنف، وإذا لم تكن هناك معرفة سابقة عن حجم البيانات المتـوفرة فيوصى بتساوي حجم الذاكرة.

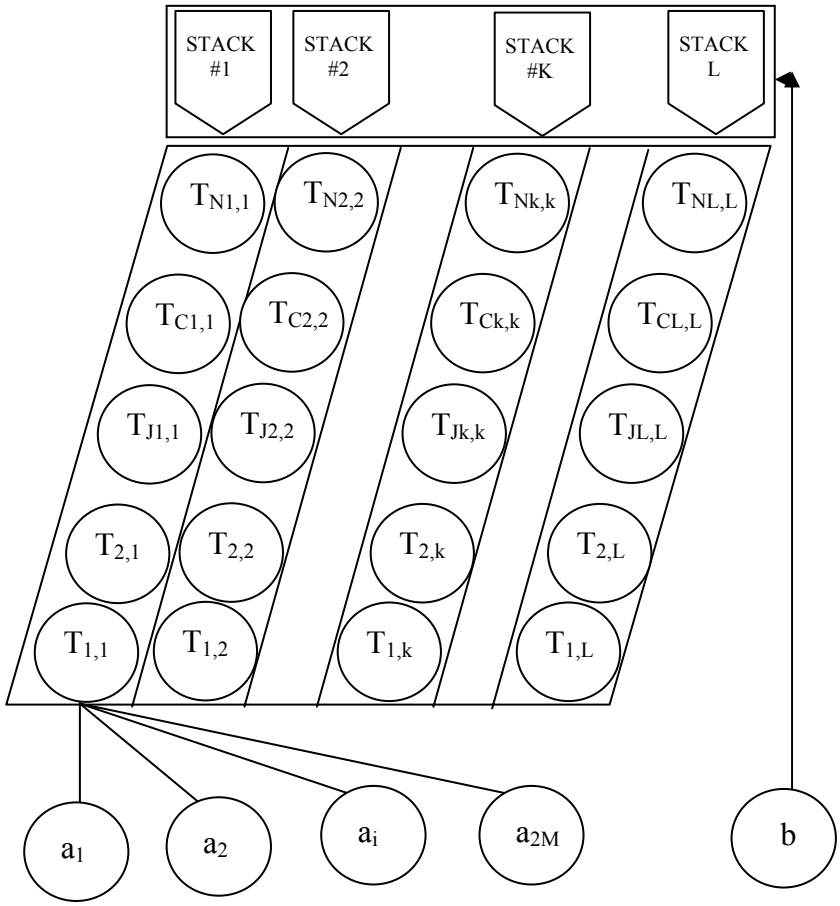

الشكل(1): معمارية شبكة الرنين الموجه ART-II، يجب ان تربط الاوزان العقد المحجوزة كلها، وتظهر في هذا الشكل الاوزان الرابطة للعقدة الأولى.

3-2: اسباب اختيار هذه الشبكة:

تم اختيار هذه الشبكة لانها تجمع بين صفتي الاستقرارية والمرونة قياسـا بالـشبكات العصبية الاخرى مثل MLP و PNN وMPNN، ونقصد بالاستقرارية ثبات العينـات فـي وحدة عنقودية واحدة وعدم اهتزازها بين الوحدات العنقودية المختلفة في مراحل التـدريب أي اننا نحصل على استقرارية بعدد دورات اقل نسبيا من عـدد الـدورات التكراريـة للـشبكات العصبية الاخرى,ومن خصائص هذه الشبكة كذلك انهـا متزايـدة (Incremental) أي لهـا القدرة على منع طرائق التعليم الجديد من (اكتساح) ذاكرة التعليم الاولى وعندما تكون استجابة الشبكة للتعلم نسبة الى عينة جديدة متساوية في أي مرحلة من مراحل التعليم فحينذاك تتصف الشبكة بالمرونة فضلا عن معمارية الشبكة البسيطة وغير القابلة للتغييـر مـن حيـث عـدد الطبقات [4].

3-3: الشبكة الثانية شبكة كوهنن:

هي شبكة عصبية اكتشفت من قبل العالم (Teuvo Kohenen) وتسمى ايضا بشبكة التنظيم الذاتي (Self Organazation Map SOM) وهي نوع من انواع الشبكات العـصبية غيـر الموجهة (unsupervised nets)ففي هذا النوع من الشبكات لايوجد اخراج محدد يقدم الـى الشبكة كما في الشبكات العصبية الموجهة، وشبكة كوهنن تمتلك طبقتين (two layers) واحدة للادخال تسمى (input layer) التي تتالف من عدد من العقد (nods) ويكون غير ثابت فـي كل الشبكات ولكن حسب الادخال الى الشبكة، اما الطبقة الاخـرى فهـي طبقـة الاخـراج (output layer) التي يكون فيها عدد العقد (nodes) غير محدد ولا يعتمد على عدد العقـد الموجودة في طبقة الادخال وعددها يعتمد على مصمم الشبكة وحسب التطبيق وفـي اغلـب الاحيان يطلق عليها اسم العالم الذي صمم الشبكة وهي (kohonen layer) وهـذه الطبقـة ممكن ان تكون لوحدها او ترتبط مع طبقات اخرى لشبكة عصبية اخرى.[13]

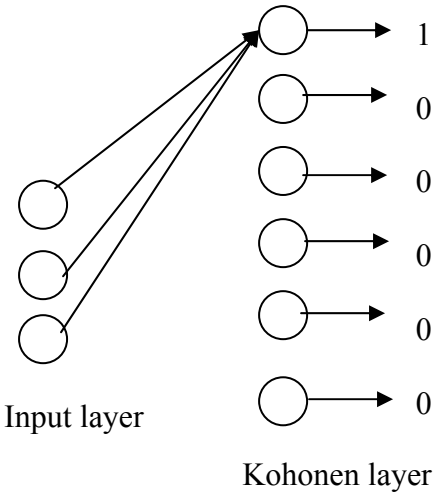

الشكل(2): مخطط يوضح التركيب لشبكة kohonen

3-4: اسباب اختيار هذه الشبكة:

تم اختيار هذه الشبكة لقدرتها على تمييز مراكز الاصناف كما انها تستخدم خاصية التعليم الذاتي لذا تكون سريعة جدا مقارنة بطرائق التعليم الاخرى,وهي من الشبكات الواسعة الاستخدام في تصنيف معطيات التحسس النائي وذلك لان عملية التعليم الذاتي فعالة جدا لمعالجة المشاكل التي تكون فيها انماط الاصناف معقدة وعشوائية كما هو الحال في الاصناف المتكونة في معطيات التحسس النائي[6].

4. خوارزمية النظام الهجيني (ARTKN)

ان النظام المقرح في هذا البحث يعتمد على مبدأ التصنيف المتكامل الذي يتضمن التصنيف باستخدام شبكتين عصبيتين الشبكة الاولى باستخدام طريقة التعليم الموجه مع بقاء قسم من الوحدات الصورية عجزت الشبكة عن اتخاذ قرار التصنيف عليها فتصنف على انها مجهولة، لهذا تعمل الشبكة الثانية على اعادة تصنيف الصورة التي نتجت من الشبكة الاولى باستخدام طريقة التعليم غير الموجة دون الحاجة الى فرض او اختيار اصناف بشكل عشوائي كما هو الحال في التصنيف غير الموجه وتصنف الوحدات المجهولة واعادتها الى الاصناف الاصلية، وفيما يلي خوارزمية تصنيف النظام الهجيني.ARTKN

1) قراءة المعطيات من الصورة الاصلية,هذه المعطيات تمثل الانماط الطيفية لخلايا الصورة متعددة الاصناف.

2) حساب قيمة (T) "التي تمثل القيمة المختارة لكل عقدة محجوزة في جميع الخزانات. (stacks) كما في المعادلة (1)" ويتم حساب قيمة T لكل عقدة وللأصناف جميعا وإيجاد اعلى قيمة من بينهم.

$$T_{j_k k} = \frac{\sum_{i=1}^{2M} (A \wedge W_{ij_k k})}{\alpha + \sum_{i=1}^{2M} W i j_k k} \quad ; \quad j_k = 1.....C(k); k = 1...L \qquad .....(1)$$

إذ أن C(k) يمثل عدد العقد المحجوزة في الـstack ذي الرقم (k).

$\wedge$ تمثل اختيار القيمة الأقل (minimum).

$W_{ij_k k}$ يمثل الأوزان المرتبطة بكل عقدة (J_k) في كل stack (k) مع جميع العقد المدخلة (I) إذ (I=1....2M)، M يمثل بعد متجه البيانات الداخلة (A). α هو العامل المختار (Choice Parameter) ويسمى أيضاً بعامل التحيز حيث زيادة α توجه البحث نحو العقد ذات الأوزان العالية وعادة تأخذ قيمة في حدود (0.02-0.01).

3) حساب قيمة التطابق للعقدة الفائزة كما في المعادلة(2).

$$MV = \sum_{i=1}^{2M} (A_i \wedge W_{iJK}) / M \qquad .....(2)$$

إذ ان MV يمثل (Match Value)

4) مقارنة قيمة التطابق للعقدة الفائزة مع معامل الخطورة (p-vigilance param.) "الـذي يأخذ عادة قيم بين (0-1).

5) فاذا كانت هذه القيمة (قيمة التطابق) اكبر او تساوي معامل الخطورة يـتم اعطـاء رقـم التصنيف الذي ينتمي اليه العقدة الفائزة الى النقطة المتوضعة على الصورة، اما اذا كـان العكس فيعطى قيمة 0مع اعطاء لون اسود لذلك الصنف، ومن هنا يمكن معرفة ان اللون الاسود الموجود في الصورة المصنفة الملونة يعزى الى فشل الشبكة في تصنيف النقـاط التي تمثله وبالتالي عدم معرفة الى أي صنف تنتمي تلك النقاط لهذا يـتم الاشـارة اليهـا بصنف جديد يدعى النقاط غير المعرفة.

6) قراءة المعطيات من الصورة التي يتم تصنيفها من الخطوة السابقة.

7) تحديد قيمة α التي هي عبارة عن قيمة صغيرة جدا تتراوح بين (0-1) وتحديـد قيمـة (neighborhood size) "التي تمثل عدد العقد التي تقع الى يمين ويسار العقدة الرابحـة" (winner node)، وتحديد رقم الدورة (tt=1).

8) حساب دالة التنشيط للانماط الداخلة عند كل عقدة اخراج باستخدام المعادلة ادناه, حيث ان هذه المعادلة تمثل المسافة الاقليدية بين الانماط الداخلة والاوزان المرابطة على كل عقدة.

$$d_j = \sum_{i=1}^{m} w_{ij} * x_i \qquad \ldots\ldots(3)$$

حيث ان x_i تمثل النمط المدخل الى الشبكة عبر طبقة الادخال.

d_j تمثل قيمة الاخراج (Output) عند العقدة j في طبقة الاخراج.

w_{ij} تمثل متجه الاوزان من العقدة ذات التسلسل (i) في طبقة المدخلات الى العقـدة الموجودة في طبقة الإخراج ذات التسلسل (j)

9) اختيار اعلى قيمة من بين قيم d_i $(j=1,2,3,\ldots,m)$ لتحديد العقدة الفائزة.

10) تحديث الاوزان (weight update) لكل من العقدة الفائزة والعقد المحددة كاقرب جار للعقدة الفائزة (neighborhood size) باستخدام المعادلة:

$$w_{ij}(t+1) = w_{ij}(t) + \alpha(t) * [(x_i) - w_{ij}(t)] \qquad \ldots\ldots\ldots(4)$$

حيث ان t: تمثل رقم الدورة.

11) مقارنة متجهات الاوزان المرابطة على عقدة الاخراج فاذا تساوت جميعها في الـدورة tt مع نظيراتها في الدورة tt-1 فهذا يعني ان الاوزان وصلت الى حالـة الاسـتقرار والانتقال الى الخطوة 13، اما اذا لم تتساوى فيتم تقديم قيمة α وزيـادة رقـم الـدورة tt=tt+1 ثم يتم اعادة الخطوات من الخطوة 8.

12) يتم اختبار الشبكة وذلك بادخال الانماط المراد تصنيفها ثم تصنيف النمط x_i الى عقـدة الاخراج ذات القيمة القصوة $(\max,d_j)$.

5) النتائج:

تم تحويل خوارزمية نظام التصنيف الهجين ARTKN الى حزمة برمجية لغرض الاستفادة منها في تطبيقات التحسس النائي المختلفة، وتم تصميم هذه الحزمة وبرمجتها باستخدام لغة C++ المرئية ولكي يستوعب النظام صور متعددة الاطياف فقد تم توفير سعة كافية للذاكرة ومعالج سريع وصمم النظام لاستيعاب ست صور وهذا اعلى عدد من الحزم الطيفية المتوفرة حالياً للمتحسس TM المرابط على القمر الصناعي لاندسات 5. وقد اعتمدت منطقة سد الموصل للدراسة وتطبيق النظام الهجين على تلك المنطقة المبينة بالشكل التالي.

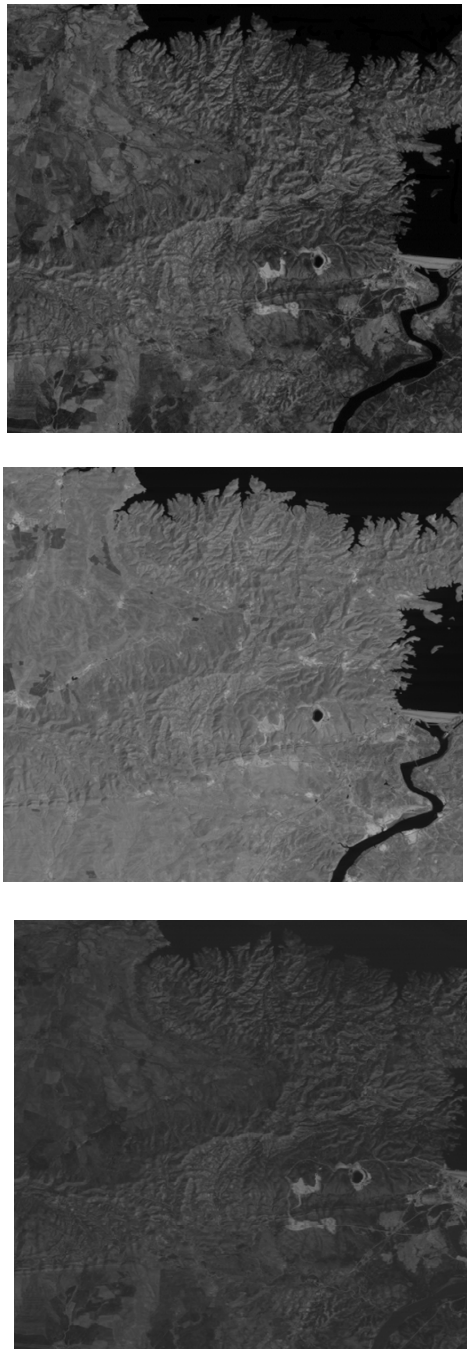

شكل (3): يمثل الحزم الطيفية للأطوال الموجية (3 ،4 ،2) على التوالي لمنطقة سد الموصل

نتائج تطبيق النظام على منطقة سد الموصل:

تتميز هذه المنطقة بوجود اصناف مختلفة من الغطاء الارضي مثـل الميـاه والمنـاطق الزراعية والتربة ومناطق سكنية وقد اقتصر التطبيق على ثلاث حزم موجية فقط وهي:

الحزمة الأولى (0.52-0.59) مايكرون.

الحزمة الثانية (0.63-0.69) مايكرون.

الحزمة الثالثة (0.76-0.9) مايكرون.

اذ تم تحديد 7 اصناف تمثل حقول يابسة وحقول رطبة والزراعة الاروائية والزراعة الديميـة ومياه، مناطق حضرية، صبة السد، مقالع، مكاشف صخرية.

الصورة (5-أ) مخرجات شبكة (ART-II) وقد تم اختيار7 اصناف للغطاء الارضي نلاحـظ من خلال هذه الصورة انه توجد نقاط ذات لون اسود والتي لم تستطع شـبكة ART II مـن تصنيفها وفشلت في معرفة الى اي صنف قد تنتمي.

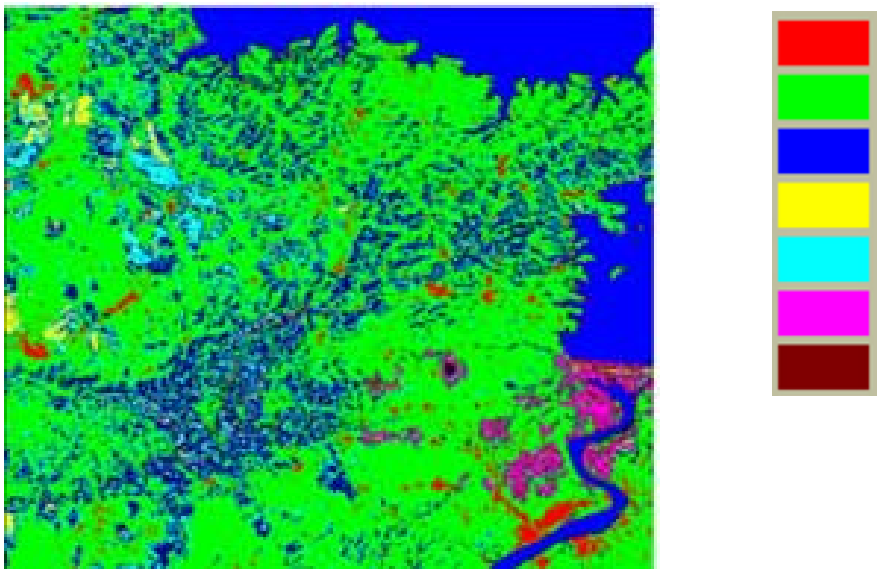

الصورة (5-أ): يمثل مخرجات المصنف ART-II

الصورة (5-ب) تمثل مخرجات مصنف شبكة (Kohenen) والتي من خلالهـا نلاحـظ ان عملية التصنيف قد تمت بشكل عشوائي بالاعتماد على مبدأ (Trail & Error) الـذي يعتمـد عليه التصنيف غير الموجه لعدم المعرفة المسبقة عن المعطيات المراد تصنيفها مما يؤثر على دقة نتائج التصنيف. وقد تم الحصول على سبعة اصناف فقط.

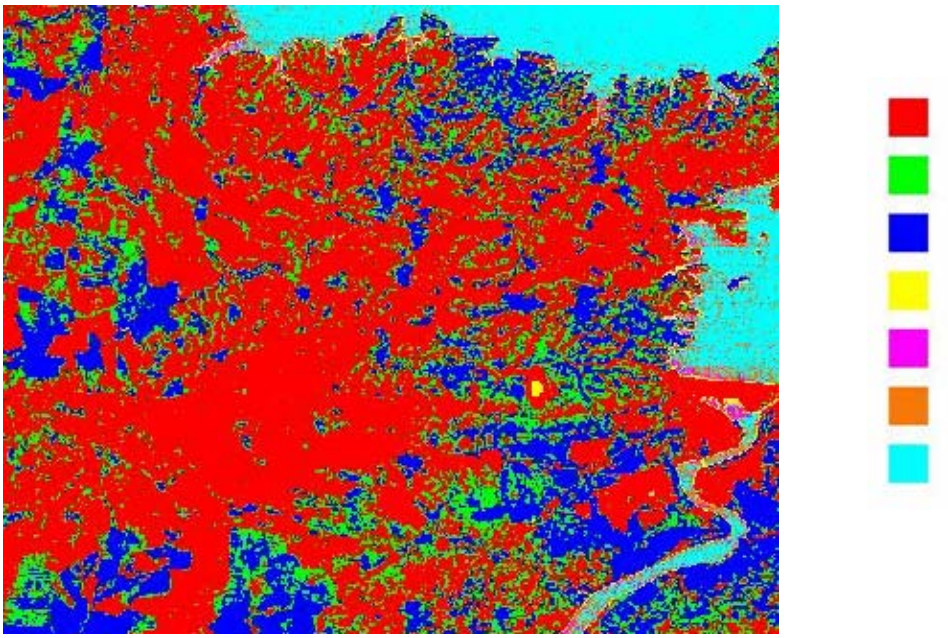

الصورة (5-ب): يمثل مخرجات المصنف Kohonen

الصورة (5-ج) تمثل مخرجات المصنف للنظام الهجين ARTKN نلاحظ في هذه الـصورة ان النقاط السوداء التي عجزت الشبكة ART II عن تصنيفها قد صنفت وان عدد الاصناف قد ازدادت الى عشرة اصناف بالاضافة الى زيادة دقة تلك الأصناف الناتجة.

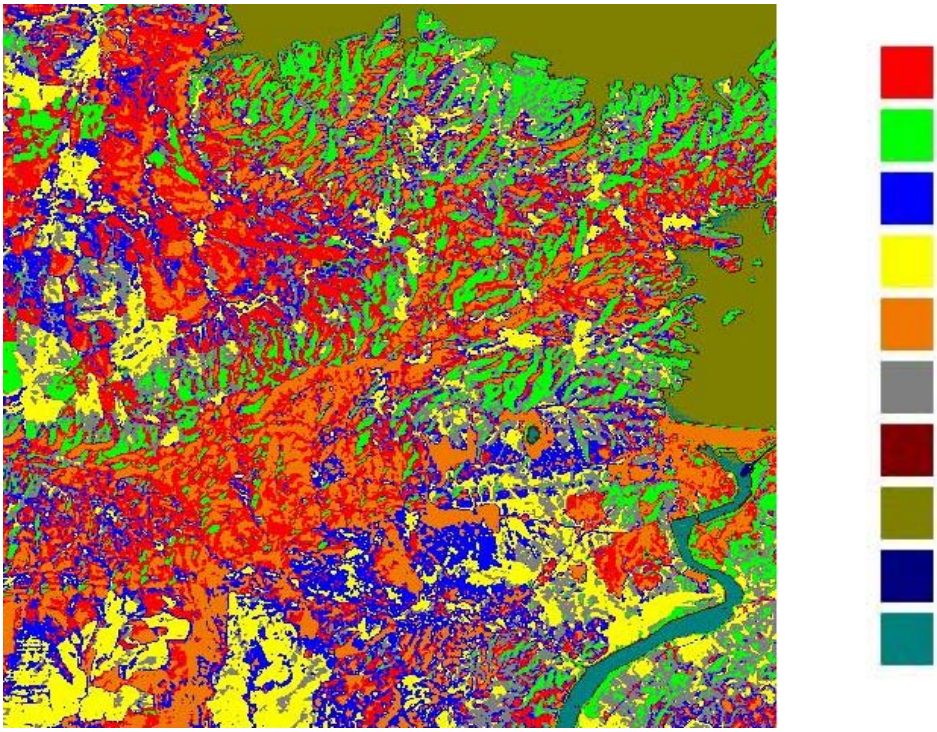

الصورة (5-ج): يمثل مخرجات المصنف ARTKN

الجدول (1) يبين دقة التصنيف للمنطقة ومن الملاحظ في هذه النتائج ان دقة الاصناف الناتجة في التصنيف الهجين ARTKN قد ازدادت مقارنة بالتفاوت الكبير في دقة الاصناف للشبكة ART II.

جدول (1): الدقة الناتجة من التصنيف لمنطقة سد الموصل

	هوية الصنف	دقة شبكة ART-II %	دقة شبكة Kohnen %	شبكة ARTKN%
1	مياه	80	85	95
2	زراعة ديمية	55	70	80
3	حقول يابسة	59	80	90
4	زراعة أروائية	60	72	87
5	صبة السد	85	60	90
6	مقالع	77	60	95
7	مكاشف صخرية	60	70	88
8	حقول رطبة			80
9	نبات طبيعي			60
10	مناطق حضرية			79

6. الاستنتاجات

في ضوء الدراسة التي أجريت على نظام التكامل تم الوصـول إلـى بعـض الاسـتنتاجات والمقترحات التي من شأنها تطوير أداء النظام وتحسينه في سبيل توسيع استخدامه في مجالات عدة وبكفاءة عالية، أما الاستنتاجات فقد شملت:

1) من خلال هذا البحث تم إثبات ان خوارزميات التصنيف سواء كانت موجهـة ام غيـر موجهة كل منها لها طريقتها واسلوبها الخاص وكفاءتها فـي التـصنيف وان النظـام الهجيني الذي تم تصميمه قد نجح في استغلال نتائج كلا النوعين كما الغيت النتائج غير الدقيقة التي ظهرت مما أدى إلى زيادة في دقة التصنيف للمناطق المأخوذة.
2) ان النظام الهجيني المقترح مرن من حيث التنفيذ اذ يمكن استخدام خوارزميتين او اكثر لغرض التكامل اضافة الى ذلك يمكن استخدام خوارزميات من نفس النوع ,فمن الممكن تطبيق النظام الهجيني على خـوارزميتين مـن خوارزميـات التـصنيف الموجـه او خوارزميات التصنيف غير الموجه وذلك للاستفادة المثلى من محاسن تلك الخوارزميات والغاء نقاط الضعف التي تفرضها هذه الخوارزميات اثناء عمليات التصنيف.
3) من الممكن معالجة القصور الذي قد يحدث في تصنيف بعض المناطق باستخدام شـبكة معينة وذلك عن طريق اعادة تصنيف تلك المنطقة باستخدام شبكة اخرى واختيار النتائج المثلى عند تكاملهما معاً.

4) ان استغلال النظام ألهجيني لتكامل خوارزميات أخرى مـن خوارزميـات التـصنيف الموجه وغير الموجه دون اقتصاره على خـوارزميتي ART-II و Kohenen قـد يؤدي الى اضافة ميزات اخرى بحسب نوع الشبكات المستخدمة والحقل الذي يفضل به عمل تلك الشبكات.

5) ان استخدام التكامل في الشبكات العصبية الموجهة وغير الموجهة اصبح مـن الممكـن استخدام شبكات ذات تعليم غير موجه بوجود معلومات اولية عن المنطقة كمعرفة عدد الاصناف التي تحويها تلك المنطقة ونوع الأصناف (مياه، منـاطق حـضرية، حقـول خضراء،.....).

7. المقترحات:

1) يمكن استخدام بيانات فضائية لمناطق اخرى ثم عمل مقارنة في التـصنيف بـين تلـك المناطق والمناطق المستخدمة في هذا البحث واستخلاص نتائج جديدة ومفيدة.

2) يمكن تطوير النظام المقترح عن طريق ادخال الطرق التقليدية والاحصائية اليه واجراء المقارنات عليها فلا يمكن اهمال الدور الكبير الذي تلعبه تلك الطرق في تصنيف بيانات التحسس النائي.

3) يمكن استخدام شبكات اخرى مع الشبكات المأخوذة في البحث واضافتها الى البرنـامج بحيث يسأل عن الشبكة الاولى والثانية اللتان نريد اجراء التكامل بينهما وتنفذ العمليـة بنقر زر باسم (التكامل او Integration).

المصادر

1) Al-Omran D. A., 2000: A Project Report Submitted To The College Of Science, University Of Baghdad.

2) Al-kuhla L. TH., 2004: M. Sc. Thesis, Remote Sensing Center, University of Mosul, Iraq, "Integration between conventional & Neural network Approachs for unsupervised classification of Remotely Sensed Data".

3) Al-Nuaimy K. M. S., 2002: M. Sc. Thesis, Remote Sensing Center, University of Mosul, Iraq, "Construction of a proposed system of Multiple Classification of Remotely Sensed Data".

4) Al-Rawi, K. R., Gonzalo C., Arquero, A., 1999a: Supervised Art-Ii: A New Neural Network Architecture With Quicker Learning Algorithm, For Classifying Multi Valued Input Patterns. To Be Presented In The European Symposium On Artificial Neural Network ESANN, Bruges, Belgium.

5) Al-Shumam T. A. K., 2001: An Integrated Software For Remotely Sensed Data Classification, M. Sc. Thesis, University of Mosul.

6) Goncalves M. L., M. L. A. Netto, 2008: "An unsupervised method of classifying remotely sensed images using Kohonen self-organizing maps and agglomerative hierarchical clustering methods", International Journal of Remote, Volume 29, Issue 11.

7) Kanellopoulos, I. Wilkinson, G. G. Megier, J., 2002: " Integration of neural network and statistical image classificationfor land cover mapping" Joint Res. Centre, Comm. of the Eur. Communities, Spray.

8) Key J., Maslanic A. And Schweiger A. J. 1989: Classification of Merged AVHRR and SMMR Artic Data with Neural Network, Photogrammetic Eng. And Remote Sensing, No. 55, pp(1331-1338).

9) Lee J., Wegner R. C., Sengupta S. K. And Welch R. M., 1990: A Neural Network Approach to Cloud Classification, IEEE Transaction on Geo science and Remote Sensing, No. 281, pp (846-855).

10) Lillsand T. M. and Kiefer R. W., 1994: Remote Sensing and Image Interpretation., 3rd Edition. John Wiley and Sons.

11) Mather P. M., Tso B. And Koch M., 1998: An Evaluation of Landsat TM Spectral data and SAR- Derived Textural Information for Litho logical Discrimination in the Red Sea Hills, Sudan, INT. J. Remote Sensing, Vol. 19, No. 4, pp(587-607).

12) Sarle w, s., 1999:" Artificial Neural Networks and their Biological Motivation, internet EXPLORER".

13) Kohonen T., Honkela T., 2007: "Kohonen Network" Scholarpedia, 2(1):1568.

14) Wilkinson G. G., Fierens F. and Kanellopoulos I., 1995b: "Integration of Neural and Statistical Approaches in Spatial Data Classification", Geographical System, Wilkinson, G. G., Vol. 2, PP. (1-20).

15) الداغستاني، حكمت صبحي، 2004، مبادئ التحسس النائي وتفسير المرئيات، دار ابـن الاثير للطباعة والنشر- الموصل، ص441.