

Detection of desert percentage in Al-Hatra Region based on image contents

Saja Y. H. Malla'alo
Sata8071@gmail.com

Ghayda A.A. Al-Talib
ghaydabdulaziz@uomosul.edu.iq
College of Computer Science and Mathematics
Mosul University

Received on: 10/09/2013

Accepted on: 12/2/2014

ABSTRACT

In this paper we benefiting from Satellite imaging to retrieve information by using its contents, which is the pixels value of the image and by using the information of groups of pixels like texture, color gradation etc....then analyzing these information to extract spatial and temporal information of this images. Content Based Information Retrieval (CBIR) technique was used to retrieve image contents depending on visual objects of it. Support Vector Machine (SVM) technique was put into use by depending on more than one function like polynomial and RBF, then applying every one of them alone with the training image with different blocks size, then using block size and function that give best result from the training phase to be applied on the test images.

The Satellite imaging was classified into two areas; desert and none desert in order to find the desert percentage of each image and comparing increasing of the desert percentages in Al-Hatra Region as a typical desertification area in nenavah governorate on different temporal periods. The language used in building the system is Matlab R2011a.

Keywords: Content based information retrieval, SVM

اكتشاف نسبة التصحر في منطقة الحضر بالاعتماد على محتويات الصورة

سجى يونس حامد

غيداء عبد العزيز الطالب

كلية علوم الحاسوب والرياضيات، جامعة الموصل

تاريخ قبول البحث: 2014/2/12

تاريخ استلام البحث: 2013/9/10

المخلص

تم في هذا البحث الاستفادة من المرئيات الفضائية لاسترجاع معلومات منها من خلال محتويات المرئية اي بالاعتماد على ما تعطيه كل وحدة تمييز بصرية pixel من قيمة وبالتالي ما تمثله مجموعة من pixels. من معلومات مثل النسجة Texture والتدرج اللوني وغيرها والقدرة على تحليلها وذلك لمعرفة معلومات مكانية وزمانية لهذه المرئيات. إذ استخدمت تقنية Content Based Information System (CBIR) لاسترجاع محتويات الصورة اعتمادا على العناصر المرئية فيها وذلك بالاعتماد على تقنية Support Vector Machine (SVM) فقد تم استخدام اكثر من دالة مع هذه التقنية وهي دوال polynomial RBF والتي تم تطبيق كل واحدة منها على حدة مع صورة التدريب Training وبجسم قالب مختلف في كل مرة ثم تم اختيار افضل حجم قالب وافضل دالة ليتم تطبيقها على صورة الاختبار Testing.

وقد تم تصنيف المرئية الفضائية الى منطقتين منطقة متصحرة واخرى غير متصحرة ومن ثم معرفة نسبة التصحر لكل مرئية ومقارنة زيادة مناطق التصحر لمنطقة الحضر كمنطقة نموذجية للتصحّر في محافظة نينوى وعلى فترات زمنية مختلفة. لقد استخدمت لغة Matlab R2011a كلغة برمجية في بناء النظام المقترح.

الكلمات المفتاحية: استرجاع المعلومات استنادا الى محتويات الصورة، تقنية SVM

1. المقدمة

بسبب التطور الهائل في علم الحاسوب سواء على صعيد تطور الاجهزة الحاسوبية أو البرمجيات فان الانظار اتجهت الى امكانية الاستفادة من الصور الملتقطة بشتى الوسائل وذلك لمعرفة معلومات مختلفة مثل مكانية معرفة وجود الامراض وانتشارها من الصور الطبية او معرفة الطقس ونوعية النباتات من المرئيات الفضائية

او التعرف على الاشخاص من صور كاميرات المراقبة وهكذا . حيث ان تطابق واسترجاع الصور يبني على خصائص سمات الصورة من خلال تحليل مجموعة من الصور لاستخلاص سماتها ووضعها في قاعدة بيانات مع الصور الاصلية لمطابقتها لاحقا مع سمات الصورة المدخلة للبحث بعد تحليلها ايضا ونتيجة البحث ستكون مجموعة من صور قاعدة البيانات ذات السمات المتطابقة مع الصورة المدخلة [11]. ومن هنا نشأت فكرة الاستفادة من محتويات الصورة إذ ان كل صورة عندما تلتقط من احد انظمة الحاسبة تخزن كمصفوفة قيم ثنائية وهذه المصفوفة تمثل رؤية الحاسبة لهذه الصورة من منظورها [12] وان كل قيمة في هذه المصفوفة تسمى وحدة تمييز بصرية pixel حيث يمكن الاستفادة من قيمة كل pixel لوحدها او مجتمعة مع مجاوراتها وذلك لمعرفة مميزات تلك المنطقة من الصورة مثل النسجة Texture والتدرج اللوني وغيرها. وبالاعتماد على هذه المحتويات للصورة اصبح بالإمكان تصنيفها وبالتالي استرجاعها من بين مجموعة من الصور حسب دلالة معينة وهو ما يعرف باسترجاع المعلومات وهو علم البحث عن الوثائق من بين مجموعة من البيانات ليطابق استعمال معين. والوثائق هنا قد تكون اي شيء كصفحة ويب او مقالة بصحيفة او صورة او فيديو. ومجموعة البيانات عادة تكون صنف من قواعد البيانات والتي تخزن كـ metadata او بيانات مشتقة من مجموعة من استعمال الوثائق [5]. وان علم استرجاع المعلومات يعتمد على تقنية (CBIR Content Base Information Retrieval) وهي تقنية لاسترجاع الصور من قاعدة بيانات صورية وعلى نحو دلالي مناسب لاستعلام المستخدم وهذه التقنية قد جذبت الكثير من الانتباه خلال العقد الاخير، وفي انظمة CBIR التقليدية فان سمات الصورة المرئية بالمرحل الواطئة (مثل اللون، النسجة والشكل) يتم استخلاصها اوتوماتيكياً لأغراض وصف الصورة وفهرستها، وكذلك لأغراض البحث عن صور معينة فان المستخدم يقدم صورة لتكون مثلاً للتشابه، ثم يقوم النظام بإرجاع مجموعة من الصور المشابهة لتلك الصورة بالاعتماد على السمات المستخلصة [17]. ان عملية CBIR تتكون من ثلاث مراحل [12]:

أ. استحصال الصورة Image acquisition

ب. استخلاص السمات Feature Extraction

ج. مضاهاة التشابه Similarity Matching

في هذا البحث، تم التعرف على نسبة التصحر في منطقة الحضر بالاعتماد على محتويات الصورة الخاصة بتلك المنطقة وتطبيق تقنية CBIR .

وبالإضافة الى هذه المقدمة، فان المقطع 2 خصص للدراسات السابقة في هذا المجال، كما طرح المقطع 3 طريقة العمل وبعض النتائج المستحصلة من تلك الصورة وقياس نسبة التصحر فيها، وقد خصص المقطع 4 للاستنتاجات.

2. الدراسات السابقة Previous Studies

- قام الباحثان [15] بتصنيف مرئيات تعود للقمر Ikonos وذلك لتتميز الطرق في منطقة الدراسة وذلك باستخدام تقنية آلة المتجه الداعم مع دالة كاوس *Gaussian* واثبتت الدراسة القدرة على التصنيف.
- كما قام [19] باستخدام تقنية آلة المتجه الداعم في تشخيص أمراض اللوكيميا، وبشكل خاص تصنيف البيانات المعتمد على مدى فعالية الجينات وفق التشخيص الجزيئي للأمراض، إذ استخدم عتبة الانحراف المعياري مع تقنية آلة المتجه الداعم من أجل إعطاء دقة اكبر في تصنيف بيانات مرض اللوكيميا.

- كما قام [9] باستخدام تقنية آلة المتجه الداعم في تصنيف المرئيات الفضائية لأكثر من قمر صناعي واحد وذلك للتفريق بين انواع شجر المنغروف.
- كما قام Volpi واخرون بكشف ومراقبة التغييرات في صور (Very high geometrical resolution) VHR حيث تمت عمليات كشف وتصنيف تغيرات الغطاء الارضي ولفترات زمنية مختلفة, حيث تم استخلاص السمات لكل صورة من خلال الخواص النسيجية للصورة وبعدها القيام بالعمليات الرياضية المتمثلة بالتاكل والتوسع erosion and dilation ومن ثم استخدام تقنية SVM غير الخطية لينتج من هذه العمليات مخطط تصنيف زمني متعدد [16].
- وقام Bekkari, واخرون بتصنيف المرئيات الفضائية باستخدام الة متجه الداعم (Support Vector SVM (Machine GLCM (Gray Level Co-occurrence Matrix) Haralick المعتمدة على مصفوفة Pixel ومعلومات مكانية بالاعتماد على مميزات Haralick المعتمدة على مصفوفة GLCM (Gray Level Co-occurrence Matrix) لاستخلاص الخواص النسيجية للصورة وبعدها تم استخدام هذه المعلومات الطيفية والمكانية لتكون مصدر البيانات لـ SVM والتي تم اعتماد دالة RBF (Radial Basis Function) فيها وقد بلغت نسبة الدقة بتصنيف الصور بهذه الطريقة حوالي 94 % [4] .
- قامت Jain واخرون باسترجاع صورة بالاعتماد على محتوياتها من خلال استخلاص متجه السمات بالاعتماد على خليط مكون من اللون والنسجة والشكل وذلك من خلال تكوين قاعدة بيانات تضم مجموعة من الصور المعنقدة حسب نوعها ومن ثم تتم عملية استرجاع الصورة المراد معرفة نوعها من خلال القيام بعملية مطابقة لمتجه السمات لهذه الصورة (بعد استخلاصه) مع متجه السمات لصور قاعدة البيانات [10] .


3. طريقة العمل ونتائجها

تم استخدام تقنية CBIR في استرجاع المعلومات من المرئيات الفضائية والتي تتكون من المراحل الآتية:

أ. استحصال الصورة Image acquisition

تم الاعتماد على المرئيات الفضائية للقمر P 170 R 35 LANDSAT ETM+ حيث تظهر منطقة الدراسة في هذا البيان وللعامين 2005 و 2007 وقد اختيرت القناة السابعة لظهور التربة فيها بشكل اوضح من باقي القنوات، إذ تم اختيار القناة السابعة لما لها من افضلية في تمييز الاراضي الجرداء فهي تستخدم بالدراسات الجيولوجية للتمييز بين المعادن وانواع الصخور ورسم الخرائط الحرارية للمياه وقياس الرطوبة في الغطاء النباتي [18] ومن هنا تعد هذه القناة الافضل في رصد التصحر .


تم تكوين نمط (pattren) للمناطق المتصحرة وغير المتصحرة من خلال اختيار عينات مختلفة من عدة مرئيات ليتم من خلالها تكوين صورة تدريب training بأبعاد (1200 × 1200) pixel اذ يمثل الجزء الايمن منها المناطق غير المتصحرة والجزء الايسر المناطق المتصحرة وحسب الصورة رقم (1)، اما في منطقة الدراسة وهي قضاء الحضر فقد اختيرت عينة بأبعاد (3600 × 3600) pixel من مرئيات القناة السابعة للعامين 2005 و2007 وحسب الصورة رقم(2).



الصورة رقم (1): منطقة التدريب قبل التصنيف



مرئية عام 2007



مرئية عام 2005

الصورة رقم (2): مرئيات القناة السابعة لمنطقة الحضر

ب. استخراج السمات Feature Extraction

تم استخراج السمات للصورة لينتج بعدها متجه يتكون من 12 سمة وذلك حسب الخطوات الآتية:

1. قراءة الصورة.

2. تقطيع الصورة الى مجموعة من القوالب blocks وباحجام مختلفة اذ يتكون كل قالب من حجمين (حجم

خارجي (كلي) ، حجم داخلي(جزئي)) وكما مبين في الشكل (1) والذي تم فيه تقسيم صورة التدريب (أ)

بالابعاد (1200×1200) بكسل الى شبكة متكونة من قوالب خارجية بحجم (40×40) بكسل وكل قالب

خارجي قُسم الى قوالب داخلية بابعاد (20×20) بكسل والتي تنتج عنها 900 قالب خارجي مع أربعة قوالب

داخلية لكل قالب خارجي وحسب المعادلات الآتية:

$$M_{blockN} = (blockS / M_{blockS})^2;$$

$$M_{blockR} = blockS / M_{blockS};$$

$$blockR = pattrenD / blockS;$$

$$blockN = blockR * blockR;$$

حيث ان

$$pattrenD = \text{بُعد الصورة}$$


$$blockS = \text{بُعد القالب الخارجي}$$

$$M_{blockS} = \text{بُعد القالب الداخلي}$$

MblockN = عدد القوالب الداخلية في القالب الخارجي الواحد

blockN = عدد القوالب الخارجية الكلي في الصورة الكلية

3. حساب المعدل mean , الانحراف المعياري std , وكمية المعلومات entropy لينتج عن هذه الخطوة ثلاث سمات.



الشكل (1) أ. صورة التدريب بأبعاد (1200 × 1200) بكسل

ب. صورة للقالب رقم 70 بأبعاد (40 × 40) بكسل

4. تحويل القوالب الى مصفوفة الجوار (GLCM) Gray Level Co-occurrence Matrix حسب المعادلة رقم (1) والمطبقة على الجدول رقم (1) والتي نتج عنها الجدول رقم (2) تمهيدا لاستخلاص سمات النسجة وهي (التجانس Homogeneity , الطاقة Energy , التباين Contrast) لينتج عن هذه الخطوة ثلاث سمات اخرى.

ولقد تم حساب مصفوفة الجوار (GLCM) باعتماد قيمة المسافة d=1 وبزاوية (0°=θ) وباستخدام المعادلة [8] ، [3] الاتية:

$$P_{0^\circ, d}(i, j) = \#\{(k, l), (m, n) \in (M \times N) \times (M \times N) : k - m = 0, |l - n| = d, f(k, l) = i, f(m, n) = j\} \quad (1)$$

حيث أن:

d = المسافة بين البكسلات. θ = الزاوية. j، i موقع القيمة في مصفوفة الجوار اذ تمثل i شدة البكسل الاولى و تمثل j شدة البكسل الثانية للصورة الاصلية. # عدد عناصر المجموعة

K, m = 1...M عرض الصورة

l, n = 1... N ارتفاع الصورة

5. حساب الانحراف المعياري std لسمات القوالب الداخلية لكل قالب لينتج عن هذه الخطوة ست سمات اخرى ايضاً.

6. تجميع السمات السابقة والتي تم احتسابها حسب الجدول رقم (3) [3] ، [2] ، [8] في متجه واحد يتكون من اثنتي عشرة سمة.

جدول (2) قيم GLCM للقالب رقم 70 بأبعاد 20 × 20 بتدرجات الرمادي 1-20

0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	14	4	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	14	168	164	14	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	4	164	1300	300	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	14	300	580	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0

جدول رقم (3): معادلات احتساب السمات والقيمة هي للقالب رقم 70

ت	السمات	المعادلة	القيمة
1.	التباين Contrast للقالب الخارجي	$Contrast = \sum_{i=1}^{N1} \sum_{j=1}^{M1} i - j ^2 P1(i, j)$	0.362
2.	الطاقة Energy للقالب الخارجي	$Energy = \sum_{i=1}^{N1} \sum_{j=1}^{M1} P1(i, j)^2$	0.248
3.	التجانس Homogeneity للقالب الخارجي	$Homogeneity = \sum_{i=1}^{N1} \sum_{j=1}^{M1} \frac{P1(i, j)}{1 + i - j ^2}$	0.835
4.	كمية المعلومات entropy للقالب الخارجي	$entropy = - \sum_{i=1}^N \sum_{j=1}^M P(i, j) \cdot \log P(i, j)$	4.829
5.	الانحراف المعياري std للقالب الخارجي	$std = \frac{1}{N \times M} \sum_{i=1}^N \sum_{j=1}^M (P(i, j) - mean)^2$	7.309
6.	المعدل mean للقالب الخارجي	$mean = \frac{1}{N \times M} \sum_{i=1}^N \sum_{j=1}^M P(i, j)$	136.556
7.	الانحراف المعياري لتباين Contrast القوالب الداخلية	$std \sum_{i=1}^S Contrast(s)$	0.0846
8.	الانحراف المعياري لطاقة Energy القوالب الداخلية	$std \sum_{i=1}^S Energy(s)$	0.0579
9.	الانحراف المعياري لتجانس Homogeneity القوالب الداخلية	$std \sum_{i=1}^S Homogeneity(s)$	0.195
10.	الانحراف المعياري لكمية المعلومات entropy القوالب الداخلية	$std \sum_{i=1}^S entropy(s)$	1.067
11.	الانحراف المعياري للانحراف المعياري std القوالب الداخلية	$std \sum_{i=1}^S std(s)$	1.520
12.	الانحراف المعياري لمعدل mean القوالب الداخلية	$std \sum_{i=1}^S mean(s)$	31.936

علما ان

P هي مصفوفة قيم القالب

P1 هي مصفوفة GLCM وبمسافة $d=2$ وبزاوية $\theta = 0$

$P = N \times M$ ابعاد المصفوفة P

$P1 = N1 \times M1$ ابعاد المصفوفة P1

$s =$ عدد القوالب الداخلية

آلة المتجه الداعم Support Vector Machine

قُدمت هذه التقنية في عام (1992) من قبل الباحث Vapnik وهي عبارة عن أنظمة تستند إلى نظرية التعلم الإحصائية (Statistical Learning Theory). وتعد من خوارزميات التعلم عن طريق مشرف أو موجه (Supervised). وتهدف إلى إيجاد أفضل مستوى فاصل (Hyperplane) يصنف البيانات بشكل صحيح قدر الإمكان [19].

ثم تفصل الفئات بطريقة خطية عن طريق الـ hyperplane الذي يُنشئ مُصنفاً يقوم بتصنيف البيانات خطياً، وفي بعض الأحيان يوجد بعض المشاكل التي لا يمكن فصلها خطياً في مجال بيانات الإدخال الأصلية لذلك تقوم الـ SVM باستخدام أحد أهم المكونات التي تقوم بالتحويل من مجال إلى آخر وتدعى Kernals حيث تقوم بتحويل الخوارزميات الخطية إلى غير خطية، وإن إمكانية استخدام Kernals مختلفة سوف تسمح بعرض أساليب التعلم المختلفة. ومما سبق يتبين ان الـ SVM تحول البيانات إلى فضاء البحث Feature Space الذي عادة ما يكون ضخماً الأبعاد، ومن الملاحظات المهمة حول الـ SVM أنها تعتمد على الخصائص الهندسية لبيانات التدريب وليس على أبعاد البيانات المدخلة [20]. وقد استخدمت SVM للقيام بعملية التصنيف للصور في مرحلتي التدريب والتعلم.

مفهوم آلة المتجه الداعم Support Vector Machine [14] : تقوم تقنية آلة المتجه الداعم بإيجاد أفضل

سطح فاصل (optimal hyperplane) يقع في أقصى حد يفصل بين النوعين والذي تكون معادلته بالشكل

$$w \cdot x + w_{N+1} = 0$$

كذلك يتم إيجاد الحد الهامش (marginal hyperplanes) وهما حدان فاصلان إضافيان موازيان للحد المثالي ويكونان متاخمين لأقرب نقاط تدريب لكلا الصنفين ومعادلتها هي كالآتي:

$$w \cdot x + w_{N+1} = 1$$

$$w \cdot x + w_{N+1} = -1$$

ومعادلة النقاط الواقعة خلف حد الهامش ستكون كما يأتي:

$$w \cdot x + 1$$


معادلة النقاط المنتمية للصنف الأول

$$w_{N+1} \geq$$

$$w \cdot x + w_{N+1} \leq -1$$

اما معادلة النقاط المنتمية للصنف الثاني فهي

حيث ان x تمثل متجه بيانات الإدخال و w متجه الأوزان و w_{N+1} هو قيمة التحيز bias . وكما مبين في الشكل رقم (2).



الشكل رقم (2)

اما في حالة كون البيانات غير قابلة للفصل خطيا عندئذ يتم الاستعانة بدوال النوى وحسب المعادلة الاتية [16]:

$$c = \text{sign} \left(\sum_{i=1}^N \alpha_i \omega_i k(x_i, x') + b \right).$$

حيث ان: x = بيانات الادخال. α = متجه الاوزان. $\omega \in \{1, -1\}$. N = عدد القيم في فضاء الادخال.

k = دالة النوى. b = عامل التحيز

فاذا كانت ($c > 0$) ستنتهي x للصف الاول اما اذا كانت ($c < 0$) ستنتهي x للصف الثاني. وفي هذا البحث تم

استعمال دالتي النوى RBF radial basis functions و polynomial .

أولاً: مرحلة التدريب

تم ادخال مصفوفة مكونة من اثنتي عشر سمة الى تقنية SVM وبيانات بعدة احجام داخلية وخارجية

وكانت دالة النوى (Kernels) المستخدمة متمثلة بدالتي RBF radial basis functions و polynomial

والمتمثلة بالمعادلتين [7]:

$$K(x,y) = \exp(-\|x-y\|^2 / 2\delta^2) \dots \dots \dots \text{RBF}$$

$$K(x,y) = (x \cdot y + 1)^d \dots \dots \dots \text{polynomial}$$

حيث ان

$x, y \in$ فضاء الادخال

δ = معلمة خاصة بانتشار الدالة حول المركز.

d = رتبة المعادلة وقد تم استخدام الرتبة الثالثة.

ان RBF تمتلك عدة مزايا حيث انها بعكس Linear تقوم بطريقة لاخطية بتحويل النماذج الى فضاء بأبعاد

اكبر ليستطيع التعامل مع الحالات التي يكون فيها من الصعب الفصل بين الاصناف التي لا تفصل خطيا وكذلك

ان RBF تمتلك مقاسات اقل من polynomial وبالتالي تكون اقل تعقيدا (Li, et al , 2010). وكذلك عدا [1]

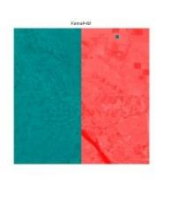
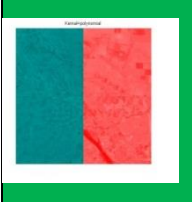



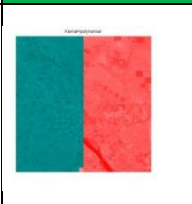
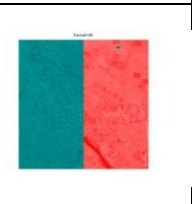


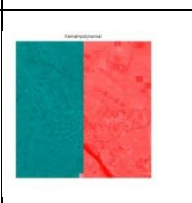

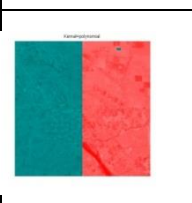
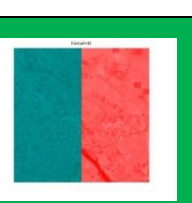
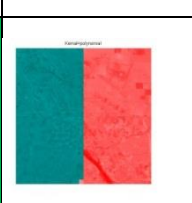
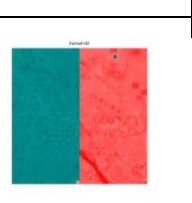
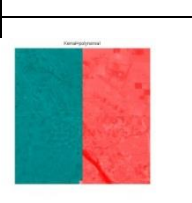


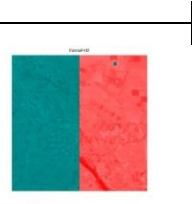
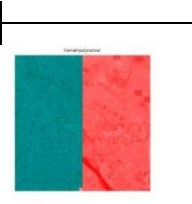


ان دالة RBF هي الافضل لسببين الاول هو انها تستطيع التعامل مع الحالات التي تكون فيها العلاقة بين

الاصناف وسماتها غير خطية فتحويل العينات بطريقة لاخطية الى فضاء بأبعاد اعلى وثانيا ان عدد المقاسات يؤثر

على صعوبة اختيار الموديل وهذا يعني ان RBF ترتبط بمشكلات عديدة اقل.

فكانت النتائج حسب الجدول رقم (4).

الجدول (4): نتائج تطبيق تقنية SVM على مصفوفة سمات صورة الانماط

RBF	polynomial	نوع الدالة		RBF	polynomial	نوع الدالة
		حجم قالب (داخلي-خارجي)				
		30 - 30				5 - 20
		5-40				10 - 20
		10-40				20 - 20
		20-40				5 - 30
		40-40				10 - 30
						15 - 30

وقد تبين بعد التنفيذ وكما مبين في الجدول ان افضل نتائج كانت عند استخدام معادلة polynomial مع حجم قالب (30-30) وعند استخدام معادلة RBF مع حجم قالب (20-40) و (40-40) وذلك لتحقيقها نسبة 100% في عملية التصنيف لصورة الانماط.

ثانيا: مرحلة التعلم :

استخدمت نتائج مرحلة التدريب ليتم تطبيقها على مرحلة الاختبار وباستخدام الطرائق التي حققت افضل

النتائج وهي:

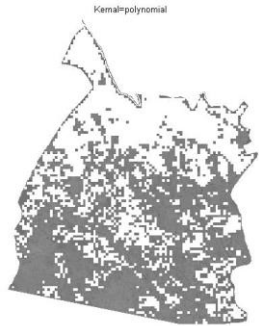





الطريقة 1= استخدام معادلة polynomial مع حجم قالب 30 - 30

الطريقة 2= استخدام معادلة RBF مع حجم قالب 40 - 20

الطريقة 3= استخدام معادلة RBF مع حجم قالب 40 - 40

فكانت نتائج التصنيف ونسب التصحر حسب ما يظهر في الجدول رقم (5).

الجدول (5): الصور المصنفة مع نسب التصحر

تصنيف المنطقة لعام 2007	تصنيف المنطقة لعام 2005	
<p>Kernal-polynomial</p>  <p>متصحرة = 0.56 , غير متصحرة = 0.44</p>	<p>Kernal-polynomial</p>  <p>متصحرة = 0.34 , غير متصحرة = 0.66</p>	الطريقة 1
<p>Kernal-rbf</p>  <p>متصحرة = 0.76 , غير متصحرة = 0.24</p>	<p>Kernal-rbf</p>  <p>متصحرة = 0.72 , غير متصحرة = 0.28</p>	الطريقة 2
<p>Kernal-rbf</p>  <p>متصحرة = 0.76 , غير متصحرة = 0.24</p>	<p>Kernal-rbf</p>  <p>متصحرة = 0.72 , غير متصحرة = 0.28</p>	الطريقة 3

ج. مضاهاة التشابه Similarity Matching

تم استخدام الصورة الناتجة من مرحلة التعلم لحساب نسبة التصحر (والمبينة باللون الغامق في الصور المصنفة) ومقارنتها مع بقية الصور إذ تم الاعتماد على الصورة الناتجة من الطريقة 3 وهي استخدام معادلة RBF مع حجم قالب 40 - 40 لتكون مرجعاً للمطابقة [1] ، فتم مقارنة الصورة الناتجة من عملية التصنيف بالطريقة 3 وهي استخدام معادلة RBF مع حجم قالب (40 - 40) مع الصورة الناتجة من عملية التصنيف بالطريقة 1 وهي استخدام معادلة polynomial مع حجم قالب (30 - 30) ولعام 2005، علماً ان المقارنة كانت بكسل بكسل (pixel per pixel).

وقد اظهرت النتائج وجود تطابق بين الصورتين بنسبة 74.90% وهكذا مع بقية الصور فتج لدينا الجدول رقم (6) والذي يمثل نسبة التطابق ما بين الصورة الناتجة من الطريقة أ مع الصورة الناتجة من الطريقة ب من خلال المعادلة الآتية:

$$\text{percent} = \text{simi5p3} / \text{all} * 100;$$

حيث ان

all = مجموع بكسلات الصورة وهي 3600 بكسل.

simi5p3 = مجموع البكسلات المتطابقة بين طريقة استخدام معادلة polynomial مع حجم قالب (30 - 30) وطريقة استخدام معادلة RBF مع حجم قالب (40 - 40).

percent = نسبة التطابق ما بين الصورتين.

والشكل (3) يوضح المخطط الانسيابي لعملية التصنيف.

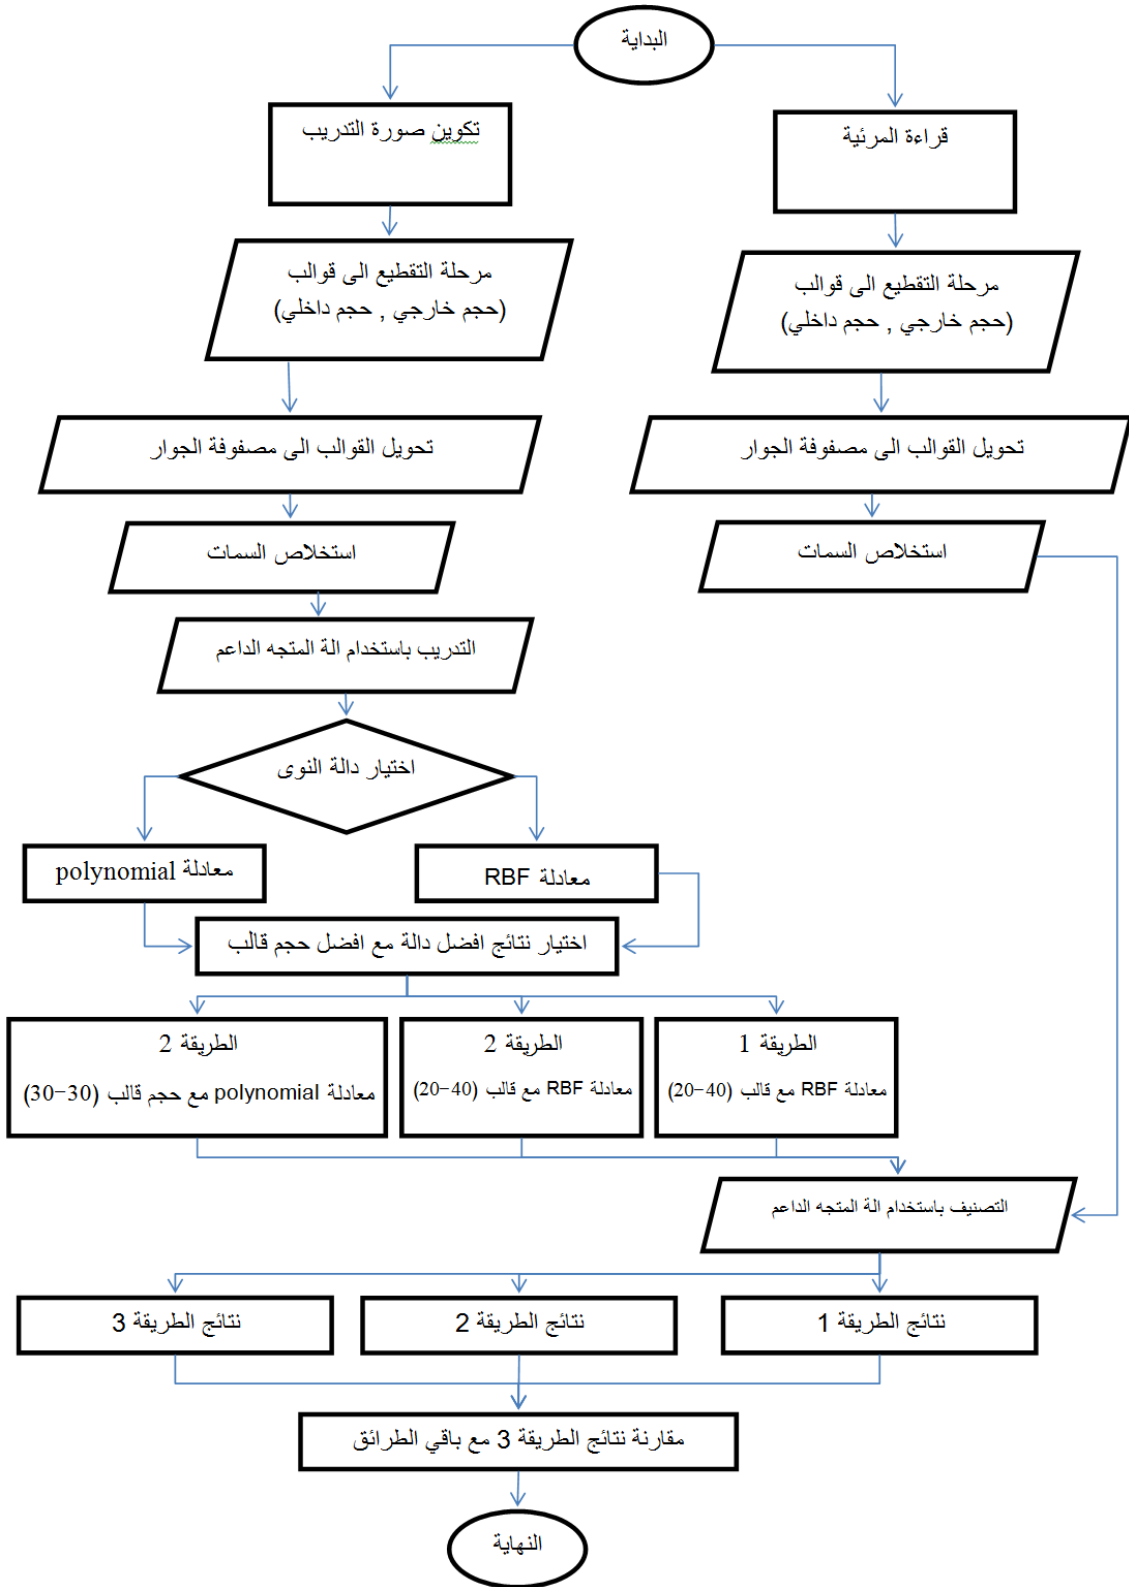
الجدول (6): نسبة التطابق بين صور مرحلة التعلم

تصنيف المنطقة لعام 2007	تصنيف المنطقة لعام 2005	مقارنة صورة الطريقة أ مع صورة الطريقة ب
84.26%	74.90%	مقارنة صورة الطريقة 3 مع صورة الطريقة 1
97.54%	96.80%	مقارنة صورة الطريقة 3 مع صورة الطريقة 2
100%	100%	مقارنة صورة الطريقة 3 مع صورة الطريقة 3

4. الاستنتاجات

بشكل عام يمكن ان نستنتج الآتي :-

1. اثبتت تقنية آلة المتجه الداعم SVM كفاءتها في القدرة على تصنيف المرئيات الفضائية الى مناطق متصحرة وغير متصحرة وينسب عالية.
2. ان استخدام دالة النوى radial basis functions RBF قد حققت نتائج بنسب تتراوح بين 0.72 - 0.76 للمناطق المتصحرة بينما كانت نسبة دالة النوى polynomial هي 0.34 - 0.56 لنفس المناطق وهذا يبين تفوق الدالة الاولى على الثانية.
3. عند تقسيم المرئية الفضائية الى قوالب فان تقسيم القالب الواحد الى قوالب ثانوية اخرى يزيد من كفاءة تقنية SVM.
4. يمكن ان يكون تقسيم القالب الواحد الى قوالب ثانوية ذا كفاءة مع بعض الدوال كما حدث مع دالة النوى radial basis functions RBF .



الشكل (3) : المخطط الانسيابي لعملية التصنيف

المصادر

- [1] Al-Qubaa, A. R. (2012). " An Electromagnetic Imaging System for Metallic Object Detection and Classification", PhD of Science Thesis, School of Electrical, Electronic & Computer Engineering, Faculty of Science, Agriculture and Engineering Newcastle University.
- [2] Alsaif Kh. I. and Mohi Al-Deen Sh. M. (2010): "Skin classification based on co-occurrence matrix",
وقائع المؤتمر العلمي الثالث في تقانة المعلومات, مجلة الرافدين لعلوم الحاسوب والرياضيات .
- [3] Al-Taey Sh. I. K. (2006): " Efficient Content-Based Multimedia Retrieval With Neural Network ", PhD of Computer Science Thesis (Unpublished), College of Computers & Mathematics Sciences, University of Mosul.
- [4] Bekkari A., Idbraim S., Elhassouny A., Mammass D., El yassa M. and Ducrot D. (2012): "SVM classification of high resolution urban satellites Images using Haralick features", International Journal of Scientific & Engineering Research, V. 3, I. 6.
- [5] Broberg G. (2011). " Scalable Methods for Content-Based Image Retrieval", Master of Science Thesis Stockholm, Sweden, at the School of Computer Science and Engineering.
- [6] Datta, Ritendra; Joshi, Dhiraj; LI, Jia; and Wang and James Z. (2008). " Image Retrieval: Ideas, Influences, and Trends of the New Age", ACM Computing Surveys, Vol. 40, No. 2.
- [7] Fizazi H. and Benhabib W. (2012): " Approche tribale des SVMs pour la classification des images satellitaires ", Nature & Technologie, n° 06/Janvier 2012. Pages 09 à 15.
- [8] Gonzalez R. and Woods R., (2002), "Digital Image Processing", Prentice-Hall, Inc., USA.
- [9] Heumann B. W., (2011): " An Object-Based Classification of Mangroves Using a Hybrid Decision Tree—Support Vector Machine Approach", Remote Sens. 2011, 3, 2440-2460; doi:10.3390/rs3112440, ISSN 2072-4292.
- [10] Jain N., Sharma S. and Sairam R.M., 2013, " Content Base Image Retrieval using Combination of Color, Shape and Texture Features", International Journal of Advanced Computer Research V.3, N.1.
- [11] Kankanhalli M. S., Mehtre B. M. and Wu J. K. (1996): " Cluster -Based Color Matching for Image Retrieval ", Pattern Recognition. Vol. 29, No. 4, pp. 701 708, Elsevier Science Ltd.
- [12] Kekre H.B., Mishra D. and Kariwala A. (2011). " A SURVEY OF CBIR TECHNIQUES AND SEMANTICS", International Journal of Engineering Science and Technology (IJEST), Vol.3 No.5.
- [13] Narayana M. and Kulkarni S. (2012). "Comparison between Euclidean Distance Metric and SVM for CBIR using Level Set Features", International Journal of Engineering Science and Technology (IJEST), Vol. 4 No.01.

- [14] Richards J. A. and Jia X. (2006) : "Remote Sensing Digital Image Analysis", Fourth edition, Springer
- [15] Song M. and Civco D., (2004): " Road Extraction Using SVM and Image Segmentation ", Photogrammetric Engineering & Remote Sensing, Vol. 70, No. 12, pp. 1365–1371.
- [16] Volpi M., Tuia D, Bovolo F. and Kanevski M., Lorenzo Bruzzone L., (2011) , "Supervised change detection in VHR images using contextual information and support vector machines ", International Journal of Applied Earth Observation and Geoinformation, Elsevier.
- [17] Wang X., Zhang B. and Yang H., (2013). " Active SVM-based relevance feedback using multiple classifiers ensemble and features reweighting ", Engineering Applications of Artificial Intelligence 26, Elsevier Ltd.
- [18] الداغستاني , حكمت صبحي (2004) : "مبادئ التحسس النائي وتفسير المرئيات". دار ابن الأثير للطباعة والنشر . جامعة الموصل .
- [19] قاسم، عمر صابر، (2010)، "تطبيق التقنيات الذكائية في المعلوماتية الحياتية". أطروحة دكتوراه، قسم الرياضيات، كلية علوم الحاسبات والرياضيات، جامعة الموصل، العراق.
- [20] الرشيدلي ، كرم محمد مهدي صالح ، (2011) ، " تصميم وتنفيذ نظام كشف التطفل باستخدام التقنيات الذكائية "، رسالة ماجستير ، قسم هندسة البرمجيات، كلية علوم الحاسوب والرياضيات، جامعة الموصل، العراق.