

تقطيع الصور الرقمية الملونة باعتماد شبكة SOM

عامرة استقلال الحياي

كلية علوم الحاسبات والرياضيات

جامعة الموصل

تاريخ قبول البحث: ٢٠١٠/٤/١١

تاريخ استلام البحث: ٢٠٠٩/٩/٢٨

ABSTRACT

Image segmentation is one of the important stages in computer vision which is necessary for various applications such as robot control and identification of military targets, as well as image analysis of remote sensing applications.

In this paper the segmentation is implemented using k-means algorithm and minimum distance with and without SOM. Segmentation with SOM is done via many stages. In the first stage initialization and reading of image is done as well as type identification and normalization.

In the second stage the neural network SOM is implemented on the resultant image to extract its main colors. In the final stage image segmentation is done by clustering method using k-means algorithm with minimum distance. Segmentation is implemented by the following steps:-

- ▼ Image is segmented into two parts using two clusters centers.
- ▼ Calculation of a suggested quality factor to test segmentation quality for that number of clusters.
- ▼ Increment number of a clusters by one, calculate a new quality factor and compare it with the previous segmentation quality factor. Iterate this until the quality factor degrades and consider the previous classification as the right one.
- ▼ When fixing right clusters centers, a new image is created by substitution of image pixel with cluster center value that is nearest to the pixel value and then displaying and saving the final image.

Finally comparison is done between the four cases of results. It has been shown from result that the use of SOM with k-means & Minimum distance algorithm is feasible, since it is depends on the variation of objects components of image.

الملخص

إن تقطيع الصورة (Image Segmentation) هي إحدى أهم المراحل في الرؤية الحاسوبية (Computer Vision) وضرورية في العديد من التطبيقات مثل السيطرة على الإنسان الآلي (Robots) وكذلك تحديد الأهداف العسكرية، بالإضافة إلى تحليلات الصورة في تطبيقات التحسس النائي.

في هذا البحث تم تنفيذ عملية التقطيع باستخدام خوارزمية الـ k-means و Minimum distance باعتماد شبكة الـ SOM وبدونها. إن إجراء عملية التقطيع باعتماد شبكة الـ SOM يتم من خلال المرور بعدة مراحل، المرحلة الأولى حيث يتم فيها تهيئة قراءة الصورة والتأكد من نوعها ومن ثم معايرة ألوانها (Normalization). أما المرحلة الثانية فيتم فيها تنفيذ الشبكة العصبية (SOM) على الصورة الناتجة وذلك لاستخلاص الألوان الرئيسية من الصورة. أخيراً المرحلة الثالثة والتي يتم فيها تقطيع الصورة بطريقة العنقدة (Clustering) باستخدام خوارزمية الـ k-means والأقل مسافة (Minimum distance) وتم إنجاز التقطيع بعدة خطوات :-

- تقطيع الصورة إلى قسمين باعتبار مركزين عنقوديين.
- حساب عامل جودة مقترحة لاختبار جودة التقطيع بهذا العدد من العناقيد.
- زيادة عدد العناقيد بواحد وحساب عامل الجودة مرة أخرى ثم مقارنتها مع عامل الجودة للتقطيع السابق، ونستمر بذلك طالما إن هناك تحسن بعامل الجودة، ثم نتوقف عند نقصانه ونعتبر التصنيف الذي سبق نقصان عامل الجودة هو التصنيف الصحيح.
- عند تثبيت مراكز عنقودية صحيحة يتم تكوين الصورة الجديدة وذلك بإعطاء نقاط الصورة (Pixels) قيمة المركز العنقودي الأقرب لقيمة النقطة وعرض الصورة النهائية وخصنها.
- وفي النهاية تم إجراء عملية مقارنة نتائج التقطيع من أربعة حالات الناتجة، فأظهرت النتائج مدى جدوى استخدام شبكة التنظيم الذاتي (SOM) مع خوارزميتي الـ k-means و Minimum distance. من خلال اعتمادها على تقاوت في الكائنات المكونة للصورة.

المقدمة:

لقد وهب الله الإنسان القدرة على الإبصار وتمييز الأشياء مما يساعده على اتخاذ القرار، في الكثير من التطبيقات تكون الحاجة إلى هذه القدرة ضرورية. لذلك حاول علماء الحاسوب إكساب هذه القدرة للحاسوب ليتمكن من التعرف على مكونات الصورة، ويتم ذلك باستخدام مفاهيم الذكاء الاصطناعي الذي يحاول أن يحاكي العقل البشري في طريقة معالجة المعلومات والتعلم.

وإحدى المراحل الضرورية للحصول على رؤية آلية هي تقطيع الصورة إلى مناطق تمثل مكونات الصورة.

يهدف هذا البحث إلى الحصول على تقطيع للصورة مجهولة المكونات للحصول على مكونات الصورة بدون تدخل الإنسان، وهذا قد يكون مفيداً في الكثير من التطبيقات، منها في مجال التحكم بالإنسان الآلي (Robots) وكذلك تحديد الأهداف العسكرية. بالإضافة إلى تحليلات الصورة في تطبيقات التحسس النائي. وان الشبكة المستخدمة في هذا البحث هي شبكة التنظيم الذاتي العصبية (SOM).

شبكة التنظيم الذاتي:

شبكات التنظيم الذاتي، والتي تدعى بشبكات (Kohonen). يوجد في هذه الشبكة عدد من الوحدات العنقودية، مرتبة في مصفوفة أحادية أو ثنائية البعد، وإشارات إدخال مكونة من عدد من الوحدات. بمعنى آخر، يؤخذ في الحسبان الهيكل الهندسي بين الوحدات. إن كل إدخال يكون مرتبط كلياً بكل الوحدات العنقودية، التي تستجيب بشكل مختلف لنمط الإدخال. وخلال مرحلة التنظيم الذاتي فإن الوحدة العنقودية التي متجه وزنها يجعل عينة الإدخال أكثر تقارباً من متجه التمثيل (أي: أقل مسافة، لاحظ المعادلة (1)) فإن هذه الوحدات ستختار كوحدة فائزة، وفي كل خطوة من طور التدريب، فإن الوحدة العنقودية ذات الأوزان الأفضل مطابقة لنمط الإدخال تُنتخب كفائزة (winner)، هذه الوحدة الفائزة ومنطقة جوارها (الوحدات التي حولها) تُحدّث بطريقة بحيث أن أوزانها الداخلية تكون أقرب إلى الإدخال المقدم، لاحظ المعادلة (2). إن عامل التحديث المتبني ليس متساوياً لجميع الخلايا. لكن يكون أقوى عند الوحدة الفائزة، ويتناقص عند الوحدات الأكثر بعداً [2][5][6].

$$\|x(t) - W_c(t)\| = \min_i \{ \|x(t) - W_i(t)\| \} \quad \dots(1)$$

حيث أن:

x : متجه الادخال.

W_c : وزن الوحدة الفائزة.

W_i : متجه الاوزان.

t : الوقت.

تُحدَّث الأوزان مع الوقت، والعامل المكتسب يجب أن يخفض وأيضا الجوار يجب أن ينقص في الحجم. ويُقصد بتقارب الخصائص خصائص الصورة الرئيسية التي تميل إلى أن تكون منظمة طبقا لتوزيع هندسي في الشبكة. إن تقارب هذه الخصائص في خريطة التنظيم الذاتي يحصل بالأخذ بنظر الاعتبار بعض التقييدات على العامل المكتسب أثناء تحديث الأوزان والتي تتم حسب المعادلة التالية [2][6]: -

$$W_i(t+1) = W_i(t) + a(t)[x_i(t) - W_i(t)] \quad \dots(2)$$


$$\forall i \in Nc(t)$$

حيث ان:

α : الدالة الخطية المكتسبة (عامل تحديث الأوزان).

Nc : منطقة الجوار.

الدالة المكتسبة المتنبية هي خطية، قيمها أعلى ما تكون في الوحدة الفائزة، وأقل ما تكون عند حدود المنطقة الدائرية، لاحظ الشكل (1) [6].



الشكل(1): يوضح منطقة جوار حول الوحدة الفائزة

نصف قطر منطقة الجوار والدالة المكتسبة كلاهما تتناقصان في المقدار مع الوقت. هذا يتم بعاملتي تخفيض، والتي تضرب في نصف القطر ومعاملات الدالة المكتسبة لكي تخفض قيمها. كلا القيمتين في المدى من 0% إلى 100%. الـ 100% يعني اضمحلال كلي، والـ 0% يعني انه لا يوجد تخفيض. وعادة ما تكون قيمة صغيرة لمقدار التخفيض مطلوبة لانجاز تقارب فضاء خصائص الـ SOM [2]. يتم حساب المسافة الاقليدية للمناطق المتجاورة باعتماد المعادلة التالية [7][9]:

$$Dist = \sqrt{\sum_{j=1}^n (x_j - W_j)^2} \quad \dots(3)$$

حيث ان:

$Dist$: المسافة الاقليدية.

n : عدد عناصر المصفوفة.

التقطيع (Segmentation):

يُعد التقطيع أحد أهم المراحل في أنظمة الرؤية الحاسوبية. وهو مهم في الكثير من تطبيقات الرؤية الحاسوبية ومعالجة الصور. والهدف من تقطيع الصورة هو إيجاد مناطق تمثل الأشياء (Objects) أو الأجزاء المهمة من الأشياء (Objects) الموجودة في الصورة. وذلك بتصنيف نقاط الصورة (Pixels) طبقاً لقيمها اللونية لتتجمع في مناطق تمثل هذه الأشياء [10]. إن تقسيم الصورة إلى مناطق مطابقة للأشياء (Objects) المهمة الموجودة في الصورة يُعد ضرورياً قبل أية معالجة تقع في مستوى أعلى من مستوى النقطة (Pixel) [6][11]. قبل الخوض في الحديث عن طرق التقطيع، يجب أن نتطرق إلى بعض المشاكل التي تواجه عملية التقطيع. المشكلة الرئيسية هي الضوضاء الناتجة في الصورة، فعند تحويل الصورة من صورة تناظرية (Analogue) إلى صورة رقمية (Digital)، تحدث الضوضاء بسبب الكاميرا أو العدسات أو الإضاءة أو غير ذلك. ويمكن تقليل تأثيرها باستخدام طريقة من طرق التهيئة لما قبل المعالجة [10].

في هذا البحث تم التخلص من تأثير الإضاءة عن طريق معايرة ألوان الصورة (Normalization) للحصول على الألوان الطبيعية للصورة من دون تأثير الإضاءة، ومن ثم استخدام الشبكة العصبية للتخلص من الضوضاء في الصورة وإبراز الألوان الرئيسية للصورة.

ولقد تم في هذا البحث استخدام طريقة العنقدة، وهي طريقة لتقطيع الصورة إلى مجموعات أو مراكز تجمع (عناقيد) وتمتلك عناصر هذه المجموعات درجة من التشابه فيما بينها ودرجة من التباين مع عناصر المجموعات الأخرى [10].

سنستخدم في هذا البحث التقطيع بطريقة العنقدة لأن التقطيع بطريقة اكتشاف الحواف (Boundary Detection) يصعب عليها التعامل مع الصور المشوهة الحواف نسبياً أي تكون غير واضحة الحواف بينما التقطيع بطريقة نمو وتقلص المنطقة (Region Growing and Shrinking) يتطلب تحديد عدد مراكز التجمع (العناقيد) في الحيز المكاني قبل البدء بالتقطيع، في حين أن طريقة العنقدة تستطيع التعامل مع الصور المشوهة الحواف والتي لا يمكن فيها تمييز حدود الأشياء المتواجدة داخل الصورة، وكذلك تعتمد عنقودين (Two Clusters) في البداية، لذلك فضلنا استخدامها [3].

لقد ذكرنا سابقاً أن مفهوم طريقة العنقدة هو تقطيع الصورة إلى عدة مناطق تمثل عينات من الصورة (Samples). إن مفهوم الـ (Unsupervised Learning and Clustering) يبحث عن معلومات مستخلصة من عينات عشوائية، والطريقة العامة للعنقدة تُعرف بعض مقاييس التشابه بين عنقودين إضافة إلى المقياس العام مثل مجموع مربع الأخطاء (Sum-squared error) أو مقدار مصفوفة التشتت (Scatter Matrix) [3][9].

ويجب الإشارة هنا إلى أنه عندما نتعامل مع البيانات فإننا نتعامل مع عينات عشوائية من تلك البيانات، هذه العينات يمكن أن تشكل حشود من النقاط (Pixels) في الفضاء المتعدد الأبعاد (Multidimensional space). وإذا عرفنا أن هذه العينات أتت من توزيع طبيعي مفرد فإن أهم عینتين هما عينة المعدل وعينة مصفوفة التباين (Mean and Covariance Matrix Sample). وان عينة المعدل تحدد مركز الثقل في حشد معين من النقاط ومركز الثقل هو عبارة عن نقطة (Pixel) مفردة وهي أفضل تمثيل للبيانات ضمن مفهوم (أقل مجموع لمربع المسافات من مركز الثقل إلى العينات الأخرى) بينما عينة مصفوفة التباين تصف مقدار التشتت على مختلف الاتجاهات. وهناك عدة خوارزميات للعنقدة منها [3]:

1 - المسافة الأقل (Minimum Distance):

وهي إحدى الطرق المستخدمة في العنقدة حيث نختار نقطتين (Two Pixels) في البداية تمثّلان مركزي تجمع (عنقودين) ثم نضم باقي النقاط اعتماداً على المسافة الأقل (من هذه النقاط إلى العنقودين) أي أن النقطة تُضم إلى العنقود الأقرب مسافةً إليها وهكذا بالنسبة إلى بقية النقاط [3]. ويمكن تمثيل خوارزمية المسافة الأقل (Minimum Distance) بالخطوات التالية:-

- 1- تُحدد المراكز العنقودية
- 2- لكل نقطة (pixel) تُكرر الخطوات (3-4).
- 3- تُحسب المسافة بين النقطة و كل مركز عنقودي .
- 4- تُضم النقطة إلى العنقود الأقل مسافة .
- 5- يُعطى لكل عنقود اللون الذي يمثل المركز العنقودي .

2 - العنقدة بعدة معدلات k-means clustering :-

هي إحدى الطرق المستخدمة في العنقدة، ويتم فيها تحديد المراكز العنقودية وتنفيذ العنقدة باستخدام طريقة المسافة الأقل، ثم يحسب المعدل لكل عنقود ناتج وتعتبر كمراكز عنقودية جديدة،

وتستمر هذه العملية إلى أن تثبت المراكز العنقودية [4][5]. وتمثل هذه الخوارزمية بالخطوات التالية [9]:

1- تهيئة المراكز العنقودية $\mu_1, \mu_2, \dots, \mu_n$.

2- تصنيف نقاط الصور باستخدام خوارزمية المسافة الأقل إلى μ_i .

3- إعادة حساب μ_i .

4- تكرار الخطوات (٢-٣) ما دامت μ_i تتغير

5- إرجاع $\mu_1, \mu_2, \dots, \mu_n$.

مصفوفة التشتت (Scatter Matrix):

ذكرنا سابقاً أن الطريقة العامة للعقدة تكون عن طريق قياس التشابه بين عنقودين إضافة إلى المقياس العام. والآن سنتكلم عن أحد دوال المقياس العام والذي هو مصفوفة التشتت. إن الغرض من استخدام هذه المقاييس هو لتحسين عمل العقدة [3]. هناك نوعين من مصفوفات التشتت:

1. النوع الأول من مصفوفات التشتت يسمى التشتت الضمني، وهو عبارة عن مجموع تباعد كل عنصر عن مركز صنفه ونرمز لها بالرمز S_w . ويتم حسابها كما في المعادلات التالية [6][8]:

$$S_w = \sum_{i=1}^c S_i \quad \dots(4)$$

$$S_i = \sum_{x \in D_i} (x - m_i)(x - m_i)^t \quad \dots(5)$$

$$m_i = \frac{1}{n_i} \sum_{x \in D_i} x \quad \dots(6)$$

حيث ان:

- S_W : التشنت الضمني داخل العنقود.
 c : عدد العناقيد.
 S_i : تشنت العنقود الذي تسلسله i .
 x : عناصر المصفوفة.
 D_i : العنقود الذي تسلسله i .
 m_i : معدل العنقود الذي تسلسله i .
 n_i : عدد العناصر في العنقود الذي تسلسله i .

2. النوع الثاني من مصفوفات التشنت يسمى التشنت الخارجي، وهو عبارة عن مجموع تباعد مراكز الأصناف عن المركز الكلي لجميع الأصناف ونرمز لها بالرمز S_B . ويتم حسابها من المعادلتين التاليتين [6][8]:

$$m = \frac{1}{n} \sum_D x \quad \dots(7)$$

$$S_B = \sum_{i=1}^c n_i (m_i - m)(m_i - m)^t \quad \dots(8)$$

حيث ان:

S_B : التشنت ما بين العناقيد.

m : معدل عناصر المصفوفة.

نلاحظ أن مصفوفة التشنت النهائية لا تعتمد على كيفية تقسيم مجموعة العينات إلى عناقيد، وإنما تعتمد على المجموعة النهائية للعينات. لكي نكون أكثر دقة في الكلام عن مقدار مصفوفة التشنت الضمني أو مصفوفة التشنت الخارجي نحتاج إلى مقياس مدرج لحجم مصفوفة التشنت. هذا المقياس هو Trace of a matrix. وإذا أجرينا هذا المقياس يمكن أن نعرف أن أفضل تقسيم (تصنيف) هو عندما نحصل على أقل تشنت ضمني وأكبر تشنت خارجي. ويمكن حساب Trace لمصفوفات التشنت من المعادلات التالية [3][8]:

$$tr[S_W] = \sum_{i=1}^c \sum_{x \in D_i} \|x - m_i\|^2 \quad \dots(9)$$

$$tr[S_B] = \sum_{i=1}^c n_i \|m_i - m\|^2 \quad \dots(10)$$

حيث ان:

.Trace of a matrix : $tr[]$

عامل جودة التقطيع هو ناتج ضرب Trace لمصفوفة التشتت ضمن نفس العنقود في Trace لمصفوفة التشتت ما بين العناقيد، كما في المعادلة التالية[6].

$$b = tr[S_W] \quad tr[S_B] \quad \dots(11)$$

حيث ان:

b : عامل الجودة.

الطريقة المقترحة لعملية التقطيع:

1- التهيئة :

في البداية تتم قراءة الصور ويتم التأكد من أن الصورة ذات ألوان حقيقية (true color) لان هذا البحث يتعامل مع صورة حقيقية الألوان، ثم تتم معالجة ألوان الصورة الداخلة كتهيئة أولية قبل دخولها إلى الشبكة العصبية الاصطناعية. وذلك بمعايرة (Normalization) هذه الألوان باستخدام المعادلات التالية لتقليل تأثير الإضاءة على ألوان الصورة[1].

$$r = \frac{R}{R + G + B} \quad \dots(12)$$

$$g = \frac{G}{R + G + B} \quad \dots(13)$$

$$b = \frac{B}{R + G + B} \quad \dots(14)$$

2- تنفيذ خريطة التنظيم الذاتي:

بعد إتمام معايرة ألوان الصورة (Normalization) ندخل عينات من ألوان هذه الصورة إلى الشبكة العصبية والتي هي خريطة التنظيم الذاتي (Self Organization Map) — Kohonen. ويتم تنفيذ خوارزمية خريطة التنظيم الذاتي كما يلي:

الخطوة الأولى :

قبل البدء بتنفيذ الشبكة العصبية يجب تهيئة معاملات هذه الشبكة، وكما يلي:
إن أوزان الشبكة تكون بأبعاد (32*32)، كل منها مرتبط بثلاثة أوزان (تقابل مركبات ألوان الصورة الثلاثة RGB). تتم تهيئة الأوزان بقيم عشوائية صغيرة ضمن المدى (0-1). بعد ذلك يتم تعيين نصف قطر منطقة الجوار التي يتم تحديث الأوزان ضمنها، وقد أعطينا القيمة (16) لنصف قطر منطقة الجوار، وقد تم ذلك تجريبياً حيث أُختبرت قيم أخرى مع تثبيت باقي المعاملات وحصلنا على أفضل النتائج عند هذه القيمة.

القيم الأولية لدالة التحديث الخطية (α) عند الوحدة الفائزة هي (0.3)، وعند محيط دائرة منطقة الجوار (0.05)، وهذه القيم أيضاً جاءت نتيجة التجربة للحصول على أفضل النتائج. أما عاملاً التخفيض لنصف قطر منطقة الجوار (0.001%) وللدالة المكتسبة الخطية تم إعطائهما (0.001%)، وهذه القيم أيضاً جاءت نتيجة التجربة للحصول على أفضل أداء، وموازنة بين دقة النتائج وسرعة التنفيذ، مع إعطاء الأولوية لدقة النتائج [6].

- الخطوة الثانية: طالما أن قيمة نصف القطر أكبر من أو تساوي (7) نفذ الخطوات من (3-7).
- الخطوة الثالثة: حساب المسافة بين الأوزان وعينات الإدخال من خلال اعتماد معادلة رقم (3).
- الخطوة الرابعة: إيجاد الوحدة الفائزة وتحديد موقعها من خلال اعتماد معادلة رقم (1).
- الخطوة الخامسة: تحديث الأوزان ضمن منطقة الجوار من خلال اعتماد معادلة رقم (2).
- الخطوة السادسة: تخفيض قيمة الدالة الخطية المكتسبة بمقدار عامل التخفيض (0.001).
- الخطوة السابعة: تقليل نصف قطر منطقة الجوار بمقدار عامل التخفيض المحدد في الخطوة رقم (1).

3- العنقدة :

- بعد الانتهاء من تدريب الشبكة العصبية تكون الأوزان النهائية هي إخراجات من الشبكة العصبية والتي تدخل في عملية العنقدة (Clustering) التي تبدأ بمركزين عنقوديين .
- (1) إن تحديد المراكز العنقودية قبل البدء بالعنقدة يكون باعتماد الخطوات التالية:
 1. نأخذ أصغر قيمة لونية ونعتبرها قيمة المركز الأول .
 2. نأخذ أكبر قيمة لونية ونعتبرها قيمة المركز الأخير .
 3. بقية المراكز تأخذ القيم المحصورة بين الأصغر والأكبر بتكرار منتظم .
 - (2) أما العنقدة فتكون بالاعتماد على المراكز العنقودية المحددة في الخطوة السابقة وذلك باعتماد احد الأسلوبين التاليين:

الأسلوب الأول/ المسافة الأقل وفيه يتم:

1. استلام المراكز العنقودية المحددة مسبقاً .
2. لكل نقطة من نقاط الصورة (Pixel)(مصفوفة الأوزان) تكرر الخطوات من 3-4.
3. إيجاد الفرق بين قيمة النقطة (Pixel) الحالية والمراكز العنقودية .
4. تُصنّف النقطة (pixel) إلى المركز العنقودي الأقل فرقا (الأقل مسافة).
5. نعيد حساب المعدل للعناقيد (لتحديد لون العناقيد).

الأسلوب الثاني/k-means تم في هذا الأسلوب اعتماد خوارزمية k-means والذي يعتبر أسلوب محدث عن أسلوب المسافة الأقل ويمكن تلخيصها بالخطوات التالية:

1. استلام المراكز العنقودية المحددة مسبقاً .
2. طالما أن المراكز العنقودية الحالية لا تساوي المراكز السابقة تكرر الخطوات من 3-6.
3. لكل نقطة من نقاط الصورة (Pixel)(مصفوفة الأوزان) تكرر الخطوات من 4-5.
4. إيجاد الفرق بين قيمة النقطة (Pixel) الحالية والمراكز العنقودية .
5. تُصنّف النقطة (pixel) إلى المركز العنقودي الأقل فرقا (الأقرب مسافة).
6. نعيد حساب المعدل للعناقيد (أي تكوين مراكز جديدة للعناقيد).


(3) كما يتم حساب عامل الجودة باعتماد الخطوات التالية:

1. نحسب Trace لمصفوفة التشتت ضمن العناقيد نفسها Sw من المعادلة (9)
 2. نحسب Trace لمصفوفة التشتت ما بين العناقيد SB من المعادلة (1)
 3. يتم إيجاد المقياس العام (التشتت الكلي) من المعادلة (11).
- (4) بعدها يتم تكرار الخطوات من (1-3) طالما أن قيمة عامل الجودة الحالية أكبر من القيمة السابقة له.

(5) إذا كانت قيمة عامل الجودة الحالية أصغر من قيمة عامل الجودة السابقة فنوقف التكرار ونأخذ المراكز العنقودية السابقة والتي تعتبر هي المراكز العنقودية المطلوبة وتكون الصورة المقطعة الجديدة على أساس المراكز التالية:

1. لكل نقطة من نقاط الصورة الأصلية تكرر الخطوات من (2-3)
2. إيجاد الفرق بين قيمة النقطة والمراكز العنقودية .
3. إعطاء النقطة قيمة المركز العنقودي الأقل فرقا (الأقرب مسافة) .

إن المخطط الصندوقي لخوارزمية الطريقة المقترحة تم توضيحها في الشكل (2).



الشكل(2): يوضح المخطط الصندوقي للخوارزمية المقترحة


النتائج العملية :

بعد إتمام البرنامج تم اختباره فأظهر كفاءة جيدة في عملية التقطيع مع سرعة جيدة في التنفيذ، والشكل (3) يبين مثال تطبيقي، حيث تم تنفيذ البرنامج على صورة جوية لأحد الأبنية في الجامعة، يمكن ملاحظة أنه تم التعرف على البنايات والظلال، وفصلها عن باقي المناطق. بعد

الحصول على الصورة (3-ب) تم إجراء مقارنة مع التقطيع اليدوي كما في الشكل(3-ج) على الصورة لأجل إيجاد المحتويات اللازمة للاستكمال الصورة.



أ- صورة جوية



ج - صورة مقطعة تم تحسينها يدوياً



ب- صورة مقطعة باستخدام الخوارزمية المقترحة

الشكل(3): يوضح مثال تطبيقي على عملية التقطيع

مقارنة بين خوارزميتي المسافة الأقل و العنقدة بعدة معدلات :


لبيان مدى جدوى الطريقة المتبعة في هذا البحث من حيث خوارزمية العنقدة المستخدمة مع شبكة التنظيم الذاتي (SOM)، تمت أالمقارنه بين النتائج في حالة استخدام خوارزمية المسافة الأقل مرة باستخدام الـSOM ومرة بدونها. وكذلك في حالة استخدام خوارزمية العنقدة بعدة معدلات مرة باستخدام الـSOM و مرة بدونها. فأظهرت النتائج مدى جدوى استخدام الـSOM في الحالتين. والقياس الذي تم اعتماده لإثبات الأفضلية هو موضح في الشكل(4)، حيث يتم ملاحظة الشكل(4-أ) الصورة الأصلية تتكون من خمسة ألوان(5 Object) وبعد تطبيق خوارزمية المسافة الأقل بدون الـSOM وخوارزمية العنقدة بعدة معدلات بدون الـSOM كما في الشكل(4-ب، 4-د) يمكن ملاحظة انه تم تصنيفها إلى لونين فقط(2 Object)، حيث جميع الألوان اعتبرها Object واحد ما عدا اللون الأبيض والمقارب للأبيض اعتبرها Object آخر، أما عند تطبيق خوارزمية المسافة الأقل باستخدام الـSOM يمكن ملاحظة انه صنفها إلى ثلاثة ألوان(3 Object)، أي انه تم فصل اللون الأصفر عن اللون الأسود لأنه هناك فرق كبير بينهما واعتبر اللون الأصفر Object مستقل، كما انه يمكن ملاحظة ان هذا التصنيف أفضل من التصنيفين السابقين كما في الشكل(4-ج). أما عند تطبيق خوارزمية العنقدة بعدة معدلات باستخدام الـSOM يمكن ملاحظة انه صنفها أيضا إلى ثلاثة ألوان(3 Object) ولكنه فصل اللون الأحمر عن اللون الأسود وضم اللون الأحمر إلى الأصفر وأصبحت Object واحد لأنه اللون الأحمر والأصفر متقاربان(يقعان ضمن نفس المجموعة)، كما في الشكل(4-هـ)، عليه يكون هذا التصنيف أفضل من التصنيفات السابقة.



أ- الصورة الأصلية



ج- خوارزمية المسافة الأقل
باستخدام الـ SOM



ب- خوارزمية المسافة الأقل
بدون استخدام الـ SOM



هـ - خوارزمية العنقدة بعدة
معدلات باستخدام الـ SOM



د - خوارزمية العنقدة بعدة معدلات
بدون استخدام الـ SOM

الشكل (4): يوضح مثال تطبيقي

في هذا البحث تم كتابة كافة الدوال اللازمة لانجاز شبكة SOM مع البرمجيات الخاصة بعملية التقطيع باستخدام خوارزمية الـ K-means و Minimum distance. ولم يتم الاعتماد على دوال جاهزة.

الاستنتاجات :

- تدريب شبكة التنظيم الذاتي على الصورة يعطي الألوان الرئيسية الموجودة في الصورة مما يعطي نتائج أفضل في مرحلة العنقدة .
- الأوزان في شبكة الـ (SOM) عشوائية مما يؤدي إلى الابتعاد عن الحل المطلوب في بعض الأحيان .
- استخدام خوارزمية الـ k-means في التصنيف يعطي نتائج أفضل (أقرب إلى الحل الصحيح) من خوارزمية الـ Minimum Distance وذلك بعد تكرار تصحيح المراكز العنقودية .
- عدد العينات المأخوذة من الصورة والتي تدخل على الشبكة العصبية ثابتة مما يجعل الوقت المستغرق في تنفيذ الشبكة العصبية ثابت مهما كبر حجم الصورة .
- الصورة الناتجة مقسمة حسب محتوياتها إلى مناطق .
- التحديد الأولي للمراكز العنقودية بترتيب منتظم قد يعطي نتائج لا تمثل فعلياً كل الأشياء الموجودة في الصورة .

المصادر

- [1] الطحان, نجم عبد الله عبد القادر سليمان,(2004), "كشف الوجه وتحديد به بالصور الملونة", رسالة ماجستير, جامعة الموصل, كلية علوم الحاسبات والرياضيات, قسم علوم الحاسبات.
- [2] عيسى, علام زكي, (2002), "الشبكات العصبية-البنيّة الهندسية-الخوارزميات-التطبيقات", شعاع للنشر و العلوم، سورية.
- [3] Duda, Richard O. & Hart, Peter E. & Stork, David G., (2001), "Pattern Classification", Second Edition, Canada.
- [4] E.S. Gopi, (2007), "Algorithm Collections for Digital Signal Processing Applications Using Matlab", National Institute of Technology, Tiruchi, India.
- [5] F. van der Heijden, (2004)," Classification, Parameter Estimation and State Estimation", The Atrium, Southern Gate, Chichester, England.
- [6] Luciano da Fontoura Costa & Moreira, Jander , (1996), "Neural-based color image segmentation and classification using self-organizing maps", Anais do Ix Sibgrapi.
- [7] Marques de Sa, Joaquim P.,(2007),"Applied Statistics Using SPSS, Statistica, Matlab and R", Universidade do Porto, Fac. Engenharia.
- [8] Martinez, Wendy L. & Martinez, Angle R., (2005),"Exploratory Data Analysis with Matlab, ",London, New York. Washington, D.C.
- [9] Martinez, Wendy L.& Martinez, Angel R., (2002)," Computational Statistics Handbook with Matlab", Boca Raton London New York Washington, D.C..
- [10] Scott E., Umbaugh, (1998), "Computer vision and image processing", A practical approach using CVPITools" .
- [11] Semmlow, John L., (2004), "Biosignal and Biomedical Image Processing" , Robert Wood Johnson Medical School, New Brunswick, Rutgers University, Piscataway, New Jersey, U.S.A..