

تجزئة الصور الرقمية بواسطة خوارزمية

تستخدم نموذج التجميع K-mean

عبد الله حمود محمد

جامعة كركوك - كلية العلوم - الفيزياء

الخلاصة

تلعب التجزئة الصورية دورا مهما في الرؤية الحاسوبية (Computer Vision). هي : تقسيم الصورة الرقمية إلى منصات هدفية ، وذلك بتحديد المناطق الرقمية التي لها صفات متشابهة عن المناطق غير المتشابهة" . تعد مشكلة التجزئة الصورية من المشاكل التي يستخدم فيها الحل الأمثل ، في هذا البحث تم استعمال طريقة الحل الأمثل التي تعتمد على خوارزمية التجميع K-mean clustering لإيجاد التجزئة الصورية المثلى . وهذه الطرائق المختلفة المقترحة قد اختبرت باستعمال صور ذات تدرج رمادي وصور ملونة وبأحجام مختلفة ، وقد قورن بين هذه الطرائق . بين أنجاز واعدية الخوارزمية التجميع و نجاحها في حل مشكلة التجزئة الصورية . فقد تضمن العمل الاعتماد على طريقة التصنيف باستعمال التجزئة وبينت نتائج الاختبار كفاءتها العالية على تصنيف مناطق الصورة . كما ان نظام تجزئة الصورة باستعمال التجميع يمتلك قابلية للتطوير والتصنيف بإمكانه تصنيف تشكليه من السيناريوهات المتضمنة أي تطبيق وكذلك تمتلك قابلية للتعلم ،

الكلمات المفتاحية:

معالجة الصور الرقمية - تجزئة الصور - نموذج التجميع K-mean - كشف الحافات.

المقدمة Introduction

تجزئة الصورة ضرورية في كثير من التطبيقات. الرؤية الحاسوبية والسيطرة الصناعية والبحوث الجيولوجية (GIS) والعمليات العسكرية والبناء والأنشاء... الخ. الهدف الأساسي من عملية التجزئة هو فصل وتجزئة الصورة إلى مناطق ذات خواص متجانسة لإبراز الأجسام المهمة في الصورة وبذلك يمكن تحليل الصورة من خلال معرفة مساحة وحجم كل جسم في الصورة لاستخلاص المعلومات الإحصائية المهمة للأهداف الموجودة في الصورة [1,2].

تجزئة الصور الرقمية بواسطة خوارزمية تستخدم نموذج التجميع K-mean

بسم الله الرحمن الرحيم

طرق تجزئة الصورة تبحث عن الاجسام التي اما لها قياس تجانس Homogenous مع نفسها أو لها قياس تباين Contrast مع الأهداف التي على حدودها . الكثير من خوارزميات التجزئة تعتمد بشكل أو بآخر على المفهومين الأساسيين وهما التجانس والتباين لسمات المناطق في الصورة مثل (المستوى الرمادي، اللون، التركيب). هنالك عدد من المسائل المرتبطة بتجزئة الصورة منها الضوضاء Noise التشوهات Deformation في الصورة والترقيم Digitization. تحدث العيوب بسبب منظومة التصوير والمحيط والضوء المستعمل في عملية التصوير ويمكن تقليل هذه العيوب باستعمال مرشحات معالجة مختلفة حسب طبيعة العيوب والتشوه في الصورة . يمكن تقسيم تقنية تجزئة الصور إلى ثلاث مجاميع:

تحليل وتجزئة الصورة Image analysis and Segmentation

تجزئة الصورة تعتبر واحدة من أهم مهام عملية التحليل للصور ، والتي يقصد بها معالجة بيانات الصورة الرقمية للحصول على معلومات تساعد في فهم الصور واستخلاص المعلومات المحتواة فيها [2]، وتعد عملية التجزئة من العمليات الصعبة ، و المعقدة في كثير من الأحيان ، وذلك لصعوبة تحديد سمات الأهداف المختلفة في الصور وذلك لتبايناتها ، وتنوعاتها الكثيرة ، واعتمادها على الحزم الطيفية المعتمدة في التصوير وعلى شدة الإضاءة . فضلاً عن اعتمادها التركيب النسيجي (texture) [4،5] . أهم مراحل عملية التجزئة هي عملية استخلاص السمات (feature extraction) لمناطق الصورة المختلفة [3] ، إذ أن عملية تجزئة الصورة هي تجزئة مناطق الصورة الرقمية إلى مناطق متباينة ذات خواص متجانسة وذلك بالاعتماد على السمات المستخلصة من الصورة [6] .

تقنيات التجزئة Techniques Segmentation

أحدى أهم وظائف معالجة الصور هي تجزئة الصور إلى مناطقها تعرف تجزئة الصورة بأنها عملية تجزئة الصورة الرقمية إلى مناطق مفصولة disjoined regions غير متداخلة وتقسم تقنيات التجزئة إلى نوعين [7,8,9] :

تقنيات تجزئة الصورة باعتماد أسلوب المنطقة (Region-based approach image segmentation techniques)

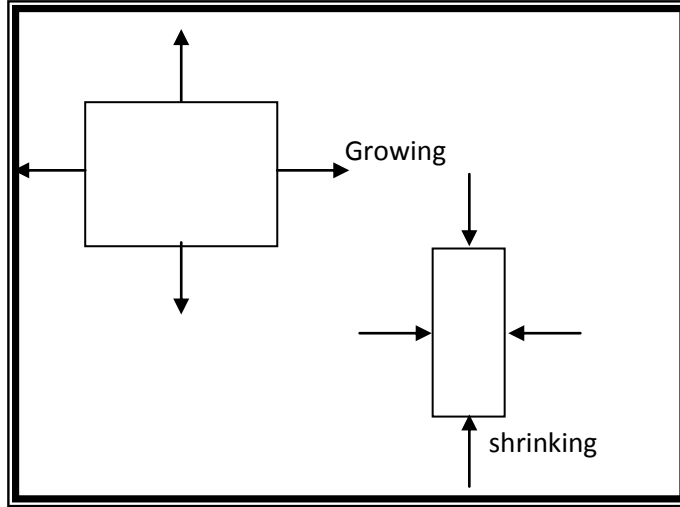
(segmentation techniques : يعتمد هذا الأسلوب على فصل مناطق الصورة بالاعتماد على سمات التشابه مثل : (المستوى الرمادي ، أو اللون ، أو النسيج)؛ لغرض فصل مناطق الصورة إلى أهداف مختلفة . الفكرة الأساسية لتقنيات التجزئة المعتمدة أسلوب المنطقة هو تمييز مناطق

تجزئة الصور الرقمية بواسطة خوارزمية تستخدم نموذج التجميع K-mean

الصورة المختلفة ، وتحليلها بالاعتماد على صفات ، أو سمات التماثل (التشابه) لكل منطقة ، لغرض فصلها ، وتمييزها ، وأبسط حالة هي حالة الصورة الثنائية التي تمثل صورة ذات خلفية ، وتحتوي على جسم (هدف) ذو شدة رمادية مختلفة عن مستويات الشدة لخلفية الصورة . لذا يمكن اعتماده أسلوب التعييب ؛ لغرض تجزئة الصورة ، وتحليلها ، وذلك باستعمال عتبة (th) محددة لفصل عناصر الهدف عن عناصر الخلفية ، فإذا كان الهدف أكثر إضاءة (أعلى مستويات شدة رمادية) من الخلفية أي أن الهدف يميل للبياض بينما الخلفية تميل للسواد . فهنا يمكن تحديد عناصر الهدف إذا كانت قيمها اكبر من العتبة وتحديد عناصر الخلفية إذا كانت اصغر أو تساوي العتبة [10] إلا إن عملية تحديد العتبة (th) بكفاءة عملية صعبة ، ومعقدة وتزداد هذه الصعوبة عندما يزداد تنوع الأهداف في الصورة ، وهنا نحتاج إلى عدة عتبات مختلفة لفصل مناطق الصورة المختلفة

نمو المنطقة وتقلصها - Region growing - Shrinking

هذه الطريقة تستعمل صف وعمود (xy) المعتمدة على فضاء الصورة. كما مبين في الشكل (1)




شكل (1) نمو المنطقة وتقلصها. [11]

طريقة التجميع (Clustering Method)

هي الطريقة التي يمكن تطبيقها على اي مجال حيزي Spatial لفضاءات السمات

(الشدة الرمادية، واللونية ،النسيجية) . كما مبين في الشكل (2):



شكل (2) التجميع البيانات تكون متجمعة في مجالات (Domains) اخرى مقارنة مع المجال الحيزي [11,12(Spatial)].

التصنيف (Classification)

إن التصنيف هو عملية تقوم بتخصيص صحيح لانماط غير معروفة إلى صنف نمط محدد . النمط (Pattern) يدل على مجموعة من النقاط في الصورة لها صفات وسمات مشتركة وتمثل جسم محدد في الصورة . بينما صنف النمط Pattern class هو مجموعة من الانماط التي تشترك في بعض الخصائص العامة[13].

يمكن تصنيف تقنيات التصنيف إلى ثلاثة طرق أساسية:

- تصنيف النمط الإحصائي Statistical Pattern classification يعتمد على تعريف مجموعة قواعد القرار المستندة على النظرية الاحصائية القياسية (Statistical Standard Theory). إن هذه المجموعة مأخوذة من بيانات الصورة الداخلة التي جمعت لتعريف متجه السمات Feature vector ، والذي يعرف بصنف النمط قواعد القرار مشتقه إما من التوزيع المتوقع للنمط الذي يتضمن مقاييس ابتدائية كثيرة.

- تصنيف النمط التركيبي Syntactic Pattern Classification : يعمل باستعمال هيكلية الأنماط structurepattern نفسها. في بعض الحالات تشير المعلومات التي لا تقع في متجهات الأنماط نفسها ولكن في علاقات داخلية تعمل ارتباطات داخلية تساعد في عملية التصنيف لان التصنيف هو ضروري لتحديد وانتزاع المعلومات الهيكلية. المعلومات الهيكلية

تجزئة الصور الرقمية بواسطة خوارزمية تستخدم نموذج التجميع K-mean

س تكون عناصر أو كتل بنائية خارجة بعناصر اكثر تعقيداً من الصور البنائية الناتجة من تركيب الوحدات البنائية (الكتل البنائية).

- تصنيف النمط البيولوجي Biological Pattern Classification : عملية حيوية (إحيائية) تخزن وتعالج المعلومات تستعمل الشبكة العصبية Neural network والأنظمة الجينية Genetic systems [14]. هنالك نظريتان أساسيتان في تصنيف النمط وهي الموجهة Supervised وغير الموجهة Unsupervised اعتماداً على عدم توفر مجموعة النماذج [15,16]. التصنيف الموجهة Supervised classification أو التعليم الموجهة Supervised learning يتضمن تقنية التوزيع الحر Distribution Free Technique أو التقنية الإحصائية Statistical technique. إن طرق تقنية التوزيع الحر لا تتطلب معرفة دوال توزيع الاحتمالية [16]. بينما التقنيات الإحصائية مستندة على نماذج توزيع الاحتمالية التي قد تكون بارامترية Parametric مثل (توزيع كاوسي Gaussian Distribution) أو غير بارامترية [16,14 Non-parametric].

طريقة التصنيف الموجهة تبدأ بتعريف بعض الاصناف المحتملة لمناطق الصورة. ان خوارزمية التصنيف تخصص لكل نقطة صورة صنف تكون السمات اقرب إلى نقطة الصورة [16,17]. إن طرق التصنيف الموجهة والاكثر شيوعاً هي المسافة الدنيا Minimum Distance والاحتمالية العظمى Maximum Likelihood.

نموذج التجميع k-means

قدم من قبل العالم J-MacQueen عام 1967 ويعتبر من تقنيات التصنيف غير الموجهة إذ استعملت الطريقة معايير المسافة الأدنى. تلك الطريقة مشابهة إلى طريقة قاعدة الجوار الاقرب k-nearest neighbor rule (هنالك ايضاً بعض التشابهات بطريقة kohonen طريقة (LVQ) [Vector Quantization - 18L]. يعمل K-means بالبحث عن عدد التجمعات (كقيمة معطاة) فإذا قسم فضاء بعده P إلى عدد C من التجمعات لذا فإن عداد الأصناف $i=1$ To C) وان كل صنف له عدد n_i من العناصر لذا فإن عداد العناصر للصنف $i(j=1$ To $n_i)$ وكل عينة X_j في الصورة يمكن ان تصنف بافتراض أن U_{ij} تمثل السمة الافتراضية للعينة ويفرض ان $U_{ij}=1$ إذا كان X_j يعود للتجمع i . و $U_{ij}=0$ اذا كانت X_j لا تعود للتجمع i و إنما تعود لتجمع آخر. و بهذا يمكن تجزئة الصورة باعتماد المعادلات الآتية [18]:

$$U_{ij} = 0,1$$

$$U_{ij} \in U_{exn}$$

$$\sum_{i=1}^c U_{ij} = 1$$

$$\sum_{i=1}^c \sum_{j=1}^{n_i} U_{ij} = n_i$$

$$C_i = \frac{1}{n_i} \sum_{j=1}^{n_i} X_j$$

$$\min_i = \sum_{j=1}^{n_i} U_{ij} \|X_j - C_i\|^2, \quad i = 1 \text{ To } C$$

إذ إن C_i = يمثل مركز الصنف (التجمع) i . المعادلة الأخيرة تعطي التجمع (i) الصحيح للعنصر X_j وذلك إذا كانت قيمة المعادلة اصغر ما يمكن مقارنة مع بقية التجمعات .

الخوارزميات المتعلقة بالعمل

تم في هذه الدراسة بناء العديد من الخوارزميات لغرض تجزئة الصورة الرقمية ذات التدرج الرمادي والصور الملونة وهذه الخوارزميات هي كالآتي:

الخوارزميات المتعلقة بالعمل

تم في هذه الدراسة بناء العديد من الخوارزميات لغرض تجزئة الصورة الرقمية ذات التدرج الرمادي والصور الملونة وهذه الخوارزميات هي كالآتي:

(A) خوارزمية توليد الأصناف الابتدائية

• بداية الخوارزمية

1. إدخال قيمة عدد الأصناف (nc)

2. تحديد مصفوفة الشدة للأصناف وهي $M[2nc]$.

3. توليد الأصناف بشكل منتظم كما يأتي:

(a) نحسب عرض الفترة (dl) لكل صنف (وهي ثابتة لجميع الأصناف) من العلاقة الآتية:

$$dl = 255 \text{ div } nc \quad \dots\dots\dots(3-9)$$

تجزئة الصور الرقمية بواسطة خوارزمية تستخدم نموذج التجميع K-mean

بسم الله الرحمن الرحيم

(b) نحسب نصف عرض الفترة (hd) من العلاقة

$$hd = dl \div 2 \quad \dots\dots\dots(3-10)$$

(c) نحدد قيمة الشدة لكل صنف من الأصناف التي عددها nc وذلك كما يأتي:

i. نضع القيمة الابتدائية للشدة $Ld=hd$ وتمثل قيمة الشدة للصنف الأول .

ii. تبدأ دورة for k=1 to nc do begin

تحسب الشدة للصنف من العلاقة الآتية : $M[k]=Ld$

ونكرر هذه القيمة لكي نحصل على عدد $2nc$ من القيم ، قيمة كل صنف مكرر بعد تسلسل

. (k+nc)

$$M[k+nc]=Ld$$

iii. نحسب قيمة الشدة للصنف اللاحق من العلاقة :

$$Ld=Ld+dl$$

iv. نهاية الدورة End for (k)

❖ ملاحظة الاخراج هو output(M[])

• نهاية الخوارزمية .

(B) خوارزمية التجميع (Clustering)

• بداية الخوارزمية

1. توليد الأصناف الابتدائية [M] باستعمال الخوارزمية (A).

2. إدخال الصورة $Img[]$

// ملاحظة المدخلات هي Input (M[],picture [])

3. تحديد أبعاد مصفوفة لمجموع قيم شدات عناصر أصناف الصورة وعدد هذه العناصر

والمصفوفة هي ($clu1[ci,1]$ ، $cloc2[ci,2]$ ، $clu2[ci,1]$ ، $clu3[ci,1]$ ، $cloc3[ci,2]$)

$$(cloc1[ci,2])$$

4. نضع المصفوفة الثنائية للصورة في مصفوفة احادية لكل من (RGB) كما يلي:

i. نضع $i=0$

ii. نبدأ دورة لحساب ارتفاع الصورة

For y=0 To hm:yy=hm-y

.iii نبدأ دورة لحساب عرض الصورة

For x=0 To wm

img1(i)=p1(x,yy) نضع .iv

img2(i)=p2(x,yy) نضع .v

img3(i)=p3(x,yy) نضع .vi

.vii نزيد المصفوفة بمقدار واحد كل مرة i=i+1

.viii نهاية الدورة End for (X)

.ix نهاية الدورة End for (Y)

.x نبدأ عملية التحديث والتحسين لقيم الأصناف بالاعتماد على معلومات الصورة. وذلك كما يأتي:

.xi نبدأ دورة لعدد الأصناف لحساب أصغر فرق مطلق

For i= 0 to (hm+1)*(wm+1)-1

.xii نحسب أصغر فرق بين عنصر الصورة ذو التسلسل (i) مع الأصناف كما يأتي :

.xiii نضع ci1=0

.xiv نضع ci2=0

.xv نضع ci3=0

mn1 = | M[0]- img1[i] |

mn2 = | M[0]- img2[i] |

mn3 = | M[0]- img3[i] |

نبدأ دورة لعدد الأصناف لحساب أكبر فرق مطلق

For k= 1 to nc

.xvii نحسب

mm1 = | M[k]- Img1[i] |

mm2 = | M[k]- Img2[i] |

mm3 = | M[k]- Img3[i] |

نطبق الشرط الاول : If mn1 > mm1 then begin يتم تغيير رقم الصنف إلى الصنف

الأقرب ci1=k ويتم تغيير قيمة أصغر فرق mn1=mm1

End if .xviii نهاية الشرط

نطبق الشرط الثاني: If $mn2 > mm2$ then begin يتم تغيير رقم الصنف إلى الصنف

الأقرب $ci2=k$ ويتم تغيير قيمة أصغر فرق $mn2=mm2$

End if

نطبق الشرط الثالث: If $mn3 > mm3$ then begin يتم تغيير رقم الصنف إلى الصنف

الأقرب $ci3=k$ ويتم تغيير قيمة أصغر فرق $mn3=mm3$

End if

5. نحسب تراكم قيم الشدات للصنف ci ونحسب عدد الشدات التي تراكمت من العلاقات الآتية:

$$clu1[ci,1] = clu1[ci,1] + I_{mg1}[i]$$

$$cloc1[ci,2] = cloc1[ci,2] + 1$$

$$clu2[ci,1] = clu2[ci,1] + I_{mg2}[i]$$

$$cloc2[ci,2] = cloc2[ci,2] + 1$$

$$clu3[ci,1] = clu3[ci,1] + I_{mg3}[i]$$

$$cloc3[ci,2] = cloc3[ci,2] + 1$$

End for i ; .xix نهاية الدورة

End for (k) .xx نهاية الدورة

for $k= 1$ to nc do begin .xxi نحسب معدل كل صنف جديد وذلك بفتح دورة جديدة

If $cloc1[k,2] > 0$ then begin .xxii نطبق الشرط الآتي لتحسين الأصناف المهمة

$$m1[k] = clu1[k,1] \text{ div } cloc1[k,2] \dots\dots\dots(3-11)$$

End if; .xxiii نهاية الشرط

If $cloc2[k,2] > 0$ then begin .xxiv نطبق الشرط الآتي لتحسين الأصناف المهمة

$$m1[k] = clu2[k,1] \text{ div } cloc2[k,2] \dots\dots\dots(3-11)$$

End if; .xxv نهاية الشرط

If $cloc3[k,2] > 0$ then begin .xxvi نطبق الشرط الآتي لتحسين الأصناف المهمة

تجزئة الصور الرقمية بواسطة خوارزمية تستخدم نموذج التجميع K-mean

$$m1[k] = \text{clu3}[k,1] \text{ div } \text{cloc3}[k,2] \quad \dots\dots\dots(3-11)$$

End if; .xxvii نهاية الشرط

End for (k); .xxviii نهاية الدورة

Output (M[]) ❖ ملاحظة الأخراج هو

• نهاية الخوارزمية

(C) خوارزمية التجزئة

• بداية الخوارزمية

1. إدخال صورة

Input(Picture[], M[]) ❖ ملاحظة الأدخلات

2. نضع المصفوفة الثنائية للصورة في مصفوفة احادية لكل من (RGB) كما يلي:

i. نضع $i=0$

ii. نبدأ دورة لحساب ارتفاع الصورة

For y=0 To hm:yy=hm-y

iii. نبدأ دورة لحساب عرض الصورة

For x=0 To wm

iv. نضع $\text{img1}(i)=p1(x,yy)$

v. نضع $\text{img2}(i)=p2(x,yy)$

vi. نضع $\text{img3}(i)=p3(x,yy)$

vii. نزيد المصفوفة بمقدار واحد كل مرة $i=i+1$

viii. نهاية الدورة End for (X)

ix. نهاية الدورة End for (Y)

3. استدعاء خوارزمية التجميع (B) للحصول على M[].

4. تحديد مصفوفة الصورة المجزئة [seg] بنفس حجم الصورة [img] لل (RGB)

5. نبدأ عملية التجزئة وذلك كما يأتي :

x. نبدأ دورة لعدد الأصناف لحساب أصغر فرق مطلق

تجزئة الصور الرقمية بواسطة خوارزمية تستخدم نموذج التجميع K-mean

بسم الله الرحمن الرحيم

For i= 0 to (hm+1)*(wm+1)-1

.xi نحسب أصغر فرق بين عنصر الصورة ذو التسلسل (i) مع الأصناف كما يأتي :

$$mn1 = | M[0] - img1[i] |$$

$$mn2 = | M[0] - img2[i] |$$

$$mn3 = | M[0] - img3[i] |$$

نضع $ci1=0$

.xii نضع $ci2=0$

.xiii نضع $ci3=0$

.xiv نبدأ دورة لعدد الأصناف لحساب أكبر فرق مطلق

For k= 1 to nc

.xvi نحسب

$$mm1 = | M[k] - Img1[i] |$$

$$mm2 = | M[k] - Img2[i] |$$

$$mm3 = | M[k] - Img3[i] |$$

نطبق الشرط الاول : If $mn1 > mm1$ then begin يتم تغيير رقم الصنف إلى الصنف

الأقرب $ci1=k$ ويتم تغيير قيمة أصغر فرق $mn1=mm1$

.xvii نهاية الشرط End if

نطبق الشرط الثاني : If $mn2 > mm2$ then begin يتم تغيير رقم الصنف إلى الصنف

الأقرب $ci2=k$ ويتم تغيير قيمة أصغر فرق $mn2=mm2$

End if

نطبق الشرط الثالث : If $mn3 > mm3$ then begin يتم تغيير رقم الصنف إلى الصنف

الأقرب $ci3=k$ ويتم تغيير قيمة أصغر فرق $mn3=mm3$

End if

End for (k)

.xviii نهاية الدورة

$$seg1[i] = M[ci1]$$

.xix نضع

$$seg2[i] = M[ci2]$$

.xx نضع

$$seg3[i] = M[ci3]$$

.xxi نضع

output Seg[]

❖ الإخراج هو الصورة المجزئة

- نهاية الخوارزمية .

تجزئة الصور الرقمية بواسطة خوارزمية تستخدم نموذج التجميع K-mean

بسم الله الرحمن الرحيم

النتائج

ان من أهم النتائج التي تم التوصل إليها في هذه الدراسة . تم تطبيق تقنيات معالجة وتحليل مختلفة تنوعت بين طرق تقليدية لغرض تجزئة الصورة العادية والملونة . إذ إن هذه التقنيات تم تطويرها وبناء برامجها باستخدام لغة فيجوال بيسك (VB6) الصور المعتمدة في الدراسة:

لقد اعتمد نوعين من الصور:

1. الصور ذات التدرج الرمادي (8bits) وهي

a. صورة الفاكهة (Fruit Image) وهذه تعد من الصور الشائعة الاستعمال في العديد من الدراسات والبحوث وهي بحجم (256×256) عنصر وذات تدرج رمادي (0-255). و هذه الصورة موضحة بالشكل (3a) والمخطط التكراري لها موضح بالشكل (4a).

b. صورنا لينا (Lena image) هي أيضا من الصور المعروفة و الشائعة الاستعمال عالميا . وهي بحجم (256×256) عنصر ومستويات الشدة الرمادية لها تتراوح ما بين (0-255). و هذه الصورة موضحة بالشكل (3b) والمخطط التكراري لها موضح بالشكل (4b).

c. صورنا باربارا (Barbara image) هي أيضا من الصور المعروفة و الشائعة الاستعمال عالميا . وهي بحجم (256×256) عنصر ومستويات الشدة الرمادية لها تتراوح ما بين (0-255). و هذه الصورة موضحة بالشكل (3c) والمخطط التكراري لها موضح بالشكل (4c).



(a)




(b)



(c)

الشكل (3): (a) صورة الفاكهة Original Fruit Image، (b): صورة لينا (c) صورنا باربارا



(a)

(b)

(c)


الشكل (4): (a): المخطط التكراري لصورة الفاكهة (b): المخطط التكراري لصورة لينا (c): المخطط التكراري لصورة باربارا

2. الصور الملونة (24 bits) وهي :

a. صورة الورد: هي صورة حقيقية خالية من الضوضاء بحجم (256×256) عنصر وذات شدة رمادية لكل حزمة تتراوح ما بين (0-255) . و هذه الصورة موضحة بالشكل (5a) والمخطط التكراري لها موضح بالشكل (6a) .


b. صورة باربارا (barbara image) هي صورة حقيقية خالية من الضوضاء بحجم (256×256) عنصر وذات شدة رمادية لكل حزمة تتراوح ما بين (0-255) . و هذه الصورة موضحة بالشكل (5b) والمخطط التكراري لها موضح بالشكل (6b) .

c. صورة الفاكهة (Fruit image) هي صورة حقيقية خالية من الضوضاء بحجم (256×256) وذات شدة رمادية لكل حزمة تتراوح ما بين (0-255) . و هذه الصورة موضحة بالشكل (5c) والمخطط التكراري لها موضح بالشكل (6c) .



تجزئة الصور الرقمية بواسطة خوارزمية تستخدم نموذج التجميع K-mean

الشكل (5): (a) صورة مقطع الورد Original Rose Image، (b) صورة باربارا barbara، (c) صورة الفاكهة Fruit Image، (d) صورة الفاكهة Fruit Image.



الشكل (6): (a) المخطط التكراري لصورة مقطع الورد Original Rose Image، (b) المخطط التكراري لصورة باربارا barbara، (c) المخطط التكراري لصورة الفاكهة Fruit Image.

نتائج طريقة التجميع على الصور ذات التدرج الرمادي

لقد تم في هذه الدراسة الاعتماد على تجزئة مناطق الصورة ذات التدرج الرمادي (3-a,3-b,3-c) إلى مجاميع لتجمع المناطق الصغيرة إلى تجمعات رمادية بحيث ظهرت عناصر الصورة (Pixels) المتماثلة التي تعود إلى نفس الشدة الرمادية. وتم الحصول على نتائج هذه العملية بتجزئة الصورة إلى مجاميع مختلفة حسب الصورة المستخدمة وحساب خصائص الصورة μ_i . حيث لوحظت دقة التجزئة لصورة لينا باستخدام هذه التقنية، كما كانت عملية التجزئة لصورة الفاكهة أقل كفاءة وذلك لتقارب مستويات الشدة الرمادية للمناطق المختلفة في هذه الصورة وكما مبين بالأشكال (7-a) و (7-b) و (7-c). فقد تم الحصول على أفضل تجمع يضم عدد العناصر الجديدة ومعدلاتها الجديدة الموجودة في كل منطقة مجزأة وكانت النتائج مبينة في الجداول المبينة ادناه.

1. الصور ذات التدرج الرمادي (8bits) وهي

a. صورة الفاكهة (Fruit Image): إذ استقطعت أربعة مناطق متجانسة (R_1, R_2, R_3, R_4) ثم حساب المعدل لكل منطقة لحساب واعتماد هذه القيم لغرض التجزئة و بعد تجزئة الصورة تم حساب نسبة كل صنف في الصورة و النتائج مبينة في الجدول (1)


تجزئة الصور الرقمية بواسطة خوارزمية تستخدم نموذج التجميع K-mean

بسم الله الرحمن الرحيم

والشكل (7a) يوضح صورة الفاكهة المصنفة.

b. صورته لينا (Lena image): إذ استقطعت أربعة مناطقمتجانسة (R_1, R_2, R_3, R_4) ثم حساب المعدل لكل منطقة لحساب واعتماد هذه القيم لغرض التجزئة و بعد تجزئة الصورة تم حساب نسبة كل صنف في الصورة و النتائج مبينة في الجدول (2). والشكل (7b) يوضح صورة لينا المصنفة.

b. صورته باربارا (Barbara image): إذ استقطعت أربعة مناطقمتجانسة (R_1, R_2, R_3, R_4) ثم حساب المعدل لكل منطقة لحساب واعتماد هذه القيم لغرض التجزئة و بعد تجزئة الصورة تم حساب نسبة كل صنف في الصورة و النتائج مبينة في الجدول (3). والشكل (7c) يوضح صورة باربارا المصنفة.



الشكل (7): (a) صورة الفاكهة المصنفة باستخدام التجميع ، (b) صورة لينا المصنفة

باستخدام K-mean clustering .

جدول (1) : يبين خصائص الصورة (μ_i, R_i) للمناطق المتجانسة والمستقطعة من صورة الفاكهة Original Fruit Image.

(Ri) المنطقة المستقطعة	μ_i المعدل للمنطقة المستقطعة	نسبة صنف المنطقة في الصورة بعد التجزئة
R_1	19.94	72.19
R_2	72.98	12.15
R_3	144.92	10.74
R_4	185.25	4.91

تجزئة الصور الرقمية بواسطة خوارزمية تستخدم نموذج التجميع K-mean

جدول (2): يبين خصائص الصورة (R_i, μ_i) للمناطق المتجانسة والمستقطعة من صورة لينا

.Original Lena Image

(Ri) المنطقة المستقطعة	μ_i المعدل للمنطقة المستقطعة	نسبة صنف المنطقة في الصورة بعد التجزئة
R ₁	24.83	72.69
R ₂	77.162	12.62
R ₃	130.73	10.31
R ₄	189.80	4.36

جدول (3): يبين خصائص الصورة (R_i, μ_i) للمناطق المتجانسة والمستقطعة من صورة

باربارا .Original Barbara Image

(Ri) المنطقة المستقطعة	μ_i المعدل للمنطقة المستقطعة	نسبة صنف المنطقة في الصورة بعد التجزئة
R ₁	35.10	71.24
R ₂	83.76	11.59
R ₃	142.26	10.71
R ₄	192.47	6.43

w2. الصور الملونة (24 bits) وهي:

لقد تم في هذه الدراسة الاعتماد على تجزئة مناطق الصورة الملونة (5-a)، (5-b)، (5-c) ، إلى مجاميع لتجمع المناطق الصغيرة (إلى تجمعات لونية احمر، اخضر، ازرق) إذ ظهرت عناصر الصورة (Pixels) المتماثلة التي تعود إلى نفس اللون. وتم الحصول على نتائج لهذه العملية بتجزئة الصورة إلى مجاميع مختلفة حسب الصورة المستخدمة وحساب خصائص الصورة. إذ لوحظت دقة التجزئة للصور (الوردة وباربارا والفاكهة) و إن صورة باربارا كانت عملية التجزئة فيها أقل كفاءة وذلك لتقارب مستوياتها اللونية للمناطق المختلفة في هذه الصورة. كما تم الحصول على أفضل تجمع يضم عدد العناصر الجديدة ومعدلاتها الجديدة الموجودة في كل منطقة مجزئة ولكل الصور التي تم تجزئتها وكانت النتائج مبينة في الجداول (4-5) ، (4-6) ، (4-7).

a. صورة الوردة (Rose image): إذ استقطعت أربع مناطق متجانسة (R_1, R_2, R_3, R_4)

تجزئة الصور الرقمية بواسطة خوارزمية تستخدم نموذج التجميع K-mean

بسم الله الرحمن الرحيم

ثم حساب المعدل لكل منطقة لحساب وأعتقاد هذه القيم لغرض التجزئة و بعد تجزئة الصورة تم حساب نسبة كل صنف في الصورة و النتائج مبينة في الجدول (4) . والشكل (8a) يوضح صورة

الوردة المصنفة باستخدام K-mean clustering

b صورته باربارا (Barbara image): إذ استقطعت أربع مناطق متجانسة (R_1, R_2, R_3, R_4)

لغرض التجزئة و بعد تجزئة الصورة تم حساب نسبة كل صنف في الصورة و النتائج مبينة في

الجدول (5) . والشكل (8b) يوضح صورة لينا المصنفة باستخدام K-mean clustering

c. صورة الفاكهة (Fruit image): إذ استقطعت أربع مناطق متجانسة (R_1, R_2, R_3, R_4)

يم لغرض التجزئة و بعد تجزئة الصورة تم حساب نسبة كل صنف في الصورة و النتائج مبينة في

الجدول (6) . والشكل (8c) يوضح صورة الفاكهة المصنفة باستخدام K-mean clustering .



الشكل (8): (a) صورة الوردة المصنفة باستخدام K-mean clustering ، (b) : صورة باربارا

المصنفة باستخدام K-mean clustering ، (c) صورة الفاكهة المصنفة باستخدام K-mean clustering

تجزئة الصور الرقمية بواسطة خوارزمية تستخدم نموذج التجميع K-mean

جدول (4): يبين خصائص الصورة (R_i, M_B, M_G, M_R) للمناطق المتجانسة والمستقطعة من صورة مقطع الورد.

(Ri) المنطقة المستقطعة	M_R معدل الحزمة الحمراء	M_G معدل الحزمة الخضراء	M_B معدل الحزمة الزرقاء	نسبة صنف المنطقة في الصورة بعد التجزئة
R_1	16.83	24.58	30.11	54.70
R_2	95	96.71	110.12	23.66
R_3	163.74	161.10	168.72	8.38
R_4	197.71	213.94	204.32	13.24

جدول (5): يبين خصائص الصورة (R_i, M_B, M_G, M_R) للمناطق المتجانسة والمستقطعة من صورة باربارا.

(Ri) المنطقة المستقطعة	M_R معدل الحزمة الحمراء	M_G معدل الحزمة الخضراء	M_B معدل الحزمة الزرقاء	نسبة صنف المنطقة في الصورة بعد التجزئة
R_1	30	35.44	34.11	21.17
R_2	91.66	92.55	94.91	40.87
R_3	147.82	146.54	148.93	22.06
R_4	194.45	196.42	198.11	15.88

جدول (6): يبين خصائص الصورة (R_i, M_B, M_G, M_R) للمناطق المتجانسة والمستقطعة من صورة الفاكهة Fruit Image .


(Ri) المنطقة المستقطعة	M_R معدل الحزمة الحمراء	M_G معدل الحزمة الخضراء	M_B معدل الحزمة الزرقاء	نسبة صنف المنطقة في الصورة بعد التجزئة
R_1	35.54	31.91	46.51	33.27
R_2	90.60	106.69	115.14	29.37

تجزئة الصور الرقمية بواسطة خوارزمية تستخدم نموذج التجميع K-mean

بسم الله الرحمن الرحيم

R ₃	156.64	158.94	156.48	10.48
R ₄	204.48	197.87	194.89	26.86

كما وقد لوحظ انه عند تطبيق (sharpen filter) للصورة بعد التجزئة ان الصورة تكون اوضح والمناطق المستقطعة تكون واضحة اكثر والشكل (9) يبين ذلك:



شكل (9)

a - زيادة حدة تفاصيل sharpening لصورة الورد المصنفة باستعمال K-mean clustering
b - زيادة حدة تفاصيل sharpening لصورة الفاكهه المصنفة باستعمال K-mean clustering
تعد تجزئة الصور من أهم مهام عملية تحليل الصورة Image analysis التي تعالج بيانات الصورة الرقمية للحصول على معلومات تساعد في حل مشاكل صور الحاسوب، لأنها تجزئ مناطق الصورة إلى مناطق هدفية لتحديد المناطق التي لها صفات متشابهة عن المناطق غير المتشابهة. ان تطبيقات التجزئة تتنوع بين الصور الجغرافية والطوبوغرافية والتطبيقات العسكرية والطبية... الخ. تم في هذا البحث برمجة أهم طرق لتجزئة الصورة وهي (التصنيف الموجه باستخدام المسافة الدنيا واستعملنا صور ملونة (Color images) وصور ذات تدرج رمادي (Gray images) وتم استنتاج ما يأتي:

1 نظام تجزئة الصورة باستعمال التجميع يمتلك قابلية للتطوير والتصنيف بإمكانه تصنيف تشكيله من السيناريوهات المتضمنة أي تطبيق وكذلك تمتلك قابلية للتعلم..
2. قد أستنتجنا إن في الصور ذات التدرج الرمادي إن صورة الفاكهه أقل كفاءة من صورة لينا و ذلك لتقارب مستويات الشدة الرمادية للمناطق المختلفة في الصورة . أما بالنسبة للصور الملونة كانت صورة باربارا أقل كفاءة من صورتي لينا وصورة الورد لتقارب مستوياتها اللونية للمناطق المختلفة في الصورة .

تجزئة الصور الرقمية بواسطة خوارزمية تستخدم نموذج التجميع K-mean

بِسْمِ اللَّهِ الرَّحْمَنِ الرَّحِيمِ

3. في الصور ذات التدرج الرمادي تكون الخوارزمية أبسط و التنفيذ أسرع مما هو عليه في الصور الملونة لأنها صورة أحادية اللون أي تتمثل بدالة واحدة (بعد واحد) .

References

- [1] K.I.K. Jain, "Fundamentals of Digital Image Processing", Prentice Hall, India, 2000.
- [2] S.E. Umbaugh, "Computer vision and Image processing", Prentice Hall ,PTR , Upper Saddle River, USA, 1998.
- [3] E.M.Gurari and H. Wechsler, "On the difficulties Involved in the Segmentation of pictures", IEEE Tranpatt.Anal. Mach. Int, Vol. PAMI-4, No.3, PP. 304-306, May, 1982.
- [4] J.J. Games and L. Vetho, "Image processing for computer graphics", Springer- verlay, New York, 1997.
- [5] D. Philips, "Image processing in C", India under arrangement with: R and D publications, USA, 1999.
- [6] Z. Hussain, "Digital Image Processing Practical Applications of parallel processing techniques", ELL is Harwood, England, 1991.
- [7] P.R. Roelfsema, and W. Singer, "Feature article detecting connectedness", Cerebral Cortex Jul, Vol.8, No.5, PP. 385-396, 1998.
- [8] B. Ogar, V. Haese-coat, and K-Kplama, "The Cooperation of mathematical morphology and region growing for remote sensing segmentation", Decode European satellite and remote sensing symposium, 1995.
- [9] W. David, "Digital imaging in C and the worldwide web", Word are publishing, USA, 1998.
- [10] K.R. Castleman, "Digital image processing", Prentice Hall, Inc., Englewood cliffs, New Jersey. 1979.
- [11] M.SchmidtandT.Stidsen, "Hybrid System: Genetic Algorithms, Neural Networks and Fuzzy logic", DATMIIR, 1997.
- [12] N. Efford, "Digital Image Processing a practical introduction", School of computer studies University of Leads, 2000.
- [13] S. Kuochai., "Multiclassifier Neural Networks for Hand Written Character recognition", Ph.D. Thesis, University of Ohio, 1995.
- [14] G.J. Awcock and R. Thomas, "Applied image processing" Macmillan New Electronics Series, 1995.
- [15] F.B. Melgani, "Design of a software package for multispectral remote sensing image classification using Fuzzy logic and Neural networks". M.Sc. Thesis, Submitted to the college of Engineering University of Baghdad, 1999.
- [16] L.H.A. Al-Amry, "Synthetic- aperture radar (SAR) Images segmentation", M.Sc. Thesis, Submitted to the College of Science, University of Al-Mustansiriya, 2000.
- [17] E.A. Ashton , M.J. Berge , K.J. Parker , J. Weisberge , C.W. Chen , and L. Ketone, "Segmentation and feature extraction techniques, with applications to the MRI head studies", Williams and Wilkins, PP. 670-677, 1999.
- [18] P. Andrey, "Selection Relaxation Genetic Algorithms applied to Image Segmentation", Image and vision computing, PP. 175- 187. 1999.

Image segmentation by using minimum distance adaptive algorithm

Abdullah .H. Muhammad

University of Kirkuk , collage of science ,physics department

Abstract

Image segmentation plays an important role in computer vision. It is a process that partitions a digital image into several meaningful regions, by identifying regions of an image that have common properties while separating regions that are dissimilar . The image segmentation problem is posed as an optimization procedure .In this thesis, an optimization approach based on K-mean clustering algorithm is introduced for finding optimal image segmentation, as well as to study of the statistical properties for the all classes that have been segmented ,and the range of their influence of the segmentation operation in this design and the best choice for the characterized function to get the best solution in the most short time , as well as study of the efficiency of the algorithm and how to accelerated its work to get the best solution

Keyword:

Image processing, segmentation, edge detection, k-mean-clustering