



تُجْنِيهِتُ العُصُورِ بِالسُّجُودِ تَقْنِيَاتِ

الحساب المبرور

رسالة مقدمة من قبل

أنوار جمعفر موسى مير

إلى مجلس كلية العلوم – جامعة بابل
كجزء من متطلبات نيل درجة الماجستير في علوم الحاسبات

آب ٢٠٠٦ م

شعبان ١٤٢٧ هـ

بِسْمِ اللَّهِ الرَّحْمَنِ الرَّحِيمِ

﴿نَزَفَعُ دَرَجَاتٍ مِّنْ نَّشَأٍ وَفَوْقَ كُلِّ ذِي عِلْمٍ

عَلِيمٍ﴾

بِسْمِ اللَّهِ الرَّحْمَنِ الرَّحِيمِ

سورة يوسف (٧٦)

توصية الأساتذة المشرفين

اشهد إن إعداد هذه الرسالة الموسومة (تصنيف الصور باستخدام تقنيات الحساب المرن) قد جرى تحت إشرافي في قسم علوم الحاسبات- كلية العلوم- جامعة بابل وهي جزء من متطلبات نيل درجة الماجستير في علوم الحاسبات.

التوقيع:

اسم المشرف: أ. د. نبيل هاشم كاغد

المرتبة العلمية: أستاذ

التاريخ: / / ٢٠٠٦

التوقيع:

اسم المشرف: د. توفيق عبد الخالق الأسدي

المرتبة العلمية: أستاذ مساعد

التاريخ: / / ٢٠٠٦

توصية رئيس القسم

إشارة إلى التوصية أعلاه المقدمة من قبل الأستاذ المشرف أحيل هذه الرسالة إلى لجنة المناقشة لدراساتها وبيان الرأي فيها.

التوقيع:

الاسم: د. عباس محسن

المرتبة العلمية: أستاذ مساعد

التاريخ: / / ٢٠٠٦

قرار لجنة المناقشة

نحن أعضاء لجنة المناقشة، نشهد بأننا قد اطلعنا على الرسالة الموسومة بـ(تصنيف الصور باستخدام تقنيات الحساب المرن). وقد ناقشنا الطالبة (أنوار جعفر موسى) في محتوياتها وفيما له علاقة بها وذلك بتاريخ / / ٢٠٠٦ ووجدنا أنها جديرة بالقبول بدرجة () لنيل درجة ماجستير في علوم الحاسبات.

| | |
|-------------------|-------------------|
| التوقيع: | التوقيع: |
| رئيس اللجنة: | عضو اللجنة: |
| المرتبة العلمية: | المرتبة العلمية: |
| العنوان: | العنوان: |
| التاريخ: / / ٢٠٠٦ | التاريخ: / / ٢٠٠٦ |

| | |
|-------------------|---|
| التوقيع: | التوقيع: |
| عضو اللجنة: | عضو اللجنة (مشرف): د. نبيل هاشم الاعرجي |
| المرتبة العلمية: | المرتبة العلمية: استاذ |
| العنوان: | العنوان: رئاسة جامعة بابل/ جامعة بابل |
| التاريخ: / / ٢٠٠٦ | التاريخ: / / ٢٠٠٦ |

| |
|--|
| التوقيع: |
| عضو اللجنة(مشرف): د.توفيق عبد الخالق الأسدي |
| المرتبة العلمية: أستاذ مساعد |
| العنوان: جامعة بابل/كلية العلوم/قسم الحاسبات |
| التاريخ: / / ٢٠٠٦ |

كلية العلوم

| |
|------------------------|
| التوقيع: |
| الاسم: عودة مزعل ياسر |
| المرتبة العلمية: أستاذ |
| التاريخ: |

/ / ٢٠٠٦

الإهداء

أهدي ثمرة جهدي إلى

ليوالعلاء

العلاء

بسمه

أتمنى منهم أن يسامحوني إن كنت قد قصرت بحقهم

شكر و تقدير

الحمد لله رب العالمين والصلاة والسلام على اشرف المرسلين محمد وعلى اله الطيبين الطاهرين. أتقدم بشكري الوافر وجزيل الاعتراف بالجميل إلى كل من الأستاذ الدكتور (بيل هاشم طه الأميري) والأستاذ المساعد الدكتور (توفيق عبد الخالق الأسدي) لمتابعتهما المستمرة وإرشادهما لي لإتمام هذه الرسالة جزاهما الله عني خير الجزاء. كما أقدم شكري وامتناني إلى رئاسة جامعة بابل وعمادة كلية العلوم وقسم علوم الحاسبات رئيساً وأساتذة ومنتسبين لما أبدوه من المساعدة لي. ويسعدني أن أتقدم بالامتنان إلى الأهل (أبي و أمي وأخوتي وأخواتي) على المساعدة الدائمة والدعاء المستمر لي بالتوفيق. كما أتقدم بالشكر والعرفان إلى كل من قدم لي يد المساعدة أو النصيحة لتكون شمعة تنير لي الطريق لإتمام بحثي هذا ولا أنسى أن اشكر كل زملائي وصديقاتي في مرحلة الدراسات العليا الذين كانوا لي عوناً في هذا المشوار.

الخلاصة

يدرس البحث تصنيف الصور بالاستفادة من مبدأ الحساب المرن وباستخدام ثلاث تقنيات في معالجة الصور، المرحلة الأولى من معالجة الصورة تم بتحليل عناصر الصورة image analysis عن طريق تجزيء الصورة إلى مكوناتها الأساسية بهدف إيجاد كيانات objects ذات معنى في تلك الصورة وقد تم ذلك باستخدام خوارزميه Breeder الجينية وهي خوارزميه هجينه بين الخوارزميات الجينية Genetic Algorithm والإستراتيجيات التطورية Evolution Strategies، والتي تمتاز بسرعة الوصول إلى الحل الأمثل وفيها تم استخدام التزاوج المضرب للاستفادة من تقنية النظام المضرب Fuzzy System، والمرحلة الثانية هي مرحلة تصنيف الكيان المستخرج من الصورة المجزأة باستخدام شبكة Neo-cognitron العصبية التي لها القابلية على تمييز الأنماط التي فيها نسبة من التشويه أو حتى التزحيف في الموقع وبصوره جيده مع سرعه عاليه في التدريب نسبة إلى باقي الشبكات، ومن المعروف أن هذه الشبكه قد صممت لتمييز الأحرف ولاسيما المكتوبة بخط اليد لذلك كانت مدخلات الشبكة عبارة عن قيم ثنائيه (0، 1) لأن الصفات تؤخذ لصورة الحرف عن طريق عمل نافذة متحركة (sliding window) بحجم معين للصورة أو عن طريق تقسيم الصورة إلى أجزاء صغيره أما الجديد في استخدامنا لهذه الشبكة هو تطبيقها في مجال الصور الملونة لذلك كانت مدخلات الشبكة عبارة عن صفات تصف الهيئة العامة للشكل وصفاته الإحصائية لذلك كانت القيم رقميه ومختلفة وليست ثنائيه وكذلك تم تدريب الشبكة على أربع هيئات للصورة الواحدة في المرة الواحدة حيث كان النمط المدخل يحتوي على هذه الهيئات الأربع .

تم تطبيق النظام على ست صور حركيه Movie image بعد أن تم تقطيعها إلى مجموعة الهيئات المكونة لها وبسبب وجود الاختلافات البسيطة بين الهيئات المتتالية للصورة الحركية الواحدة فقد تم دراسة عدد الهيئات التي تم التعرف على كياناتها لكل صورة باعتبارها فروقات للصور المدرب عليها فكانت نسبة التمييز للنظام المقترح تتراوح بين (50% - 100%).

لاحظنا أن الطبيعة المتكاملة لكل من التقنيات المستخدمة في تصنيف الصورة أعطى

نتائج أفضل وأكثر دقه في كل مرحله من مراحل تصنيف الكيان.

المحتويات

| <u>رقم الصفحة</u> | <u>العنوان</u> |
|--|------------------------------------|
| ١-١ | مقدمة عامة..... المقدمة |
| ٢-١ | نبذة مختصرة عن البحوث السابقة..... |
| ٣-١ | هيكل الرسالة..... |
| ٤-١ | هدف الرسالة..... |
| الفصل الثاني مفاهيم تقنيات الحساب المرن | |
| ١-٢ | مقدمة..... |
| ٢-٢ | الحساب التطوري..... |
| ١-٢-٢ | الخوارزميات الجينية..... |
| ٢-٢-٢ | الإستراتيجيات التطورية..... |
| ٣-٢ | الشبكات العصبية..... |
| ٤-٢ | معالجة الصور الرقمية..... |
| ٥-٢ | إستحصال الصورة..... |
| ٦-٢ | المعالجة الأولية..... |
| ٧-٢ | تجزئ الصور..... |
| ١-٧-٢ | تقنيات العنقدة..... |
| ١-١-٧-٢ | تقنيه الأوساط المتعددة..... |
| ٢-١-٧-٢ | تقنية شطر المناطق التداخلي..... |

| | | |
|---------|--|---------|
| ٢٦..... | تقييم أداء تقنيات التجزيء | ٢-٧-٢ |
| ٢٨..... | الخوارزميات الجينية | ٣-٧-٢ |
| ٢٩..... | خوارزمية Breeder الجينية | ١-٣-٧-٢ |
| ٣٤..... | تمثيل ووصف البيانات | ٨-٢ |
| ٣٥..... | طريقة توقيع الكفافات | ١-٨-٢ |
| ٣٦..... | المدرج التكراري | ٢-٨-٢ |
| ٣٨..... | تمييز الأنماط باستخدام الشبكات العصبية | ٩-٢ |
| ٣٩..... | نبذة تاريخيه عن شبكة Neo-cognitron | ١-٩-٢ |
| ٤١..... | الهيكل العام للشبكة | ٢-٩-٢ |
| ٤٥..... | الوصف الرياضي للشبكة | ٣-٩-٢ |
| ٤٨..... | التنظيم الذاتي للشبكة | ٤-٩-٢ |

الفصل الثالث منظومة الحساب المرن المقترحة لتصنيف الصور

| | | |
|---------|---------------------------------------|---------|
| ٥١..... | الهيكل العام للمنظومة المقترحة | ١-٣ |
| ٥٢..... | قراءة ملف الصورة | ١-١-٣ |
| ٥٣..... | المعالجة الأولية | ٢-١-٣ |
| ٥٣..... | تجزئة الصورة باستخدام العنقدة الجينية | ٣-١-٣ |
| ٦٥..... | استخلاص الصفات | ٤-١-٣ |
| ٦٥..... | طريقة توقيع الكفافات | ١-٤-١-٣ |
| ٦٦..... | المدرج التكراري | ٢-٤-١-٣ |
| ٦٦..... | تصنيف كل جزء من الصورة | ٥-١-٣ |
| ٦٧..... | مرحلة التدريب | ١-٥-١-٣ |
| ٧٠..... | مرحلة الاختبار | ٢-٥-١-٣ |

الفصل الرابع النتائج والاستنتاجات والأعمال المستقبلية

| | | |
|---------|-----------------------|-------|
| ٧٢..... | أداء الطريقة المقترحة | ١-٤ |
| ٧٢..... | التجزيء | ٢-٤ |
| ٧٢..... | التجربة الأولى | ١-٢-٤ |
| ٧٤..... | التجربة الثانية | ٢-٢-٤ |
| ٩٩..... | التصنيف | ٣-٤ |

| | | |
|-----------|--------------------------------|-----|
| ١٠٥ | الاستنتاجات..... | ٤-٤ |
| ١٠٧..... | الأعمال المستقبلية..... | ٥-٤ |
| ١٠٨..... | المصادر باللغة الانكليزية..... | |
| ١١٣..... | المصادر باللغة العربية..... | |

قائمة المصطلحات العربية والإنكليزية

| المصطلح الإنكليزي | المصطلح العربي |
|----------------------|------------------|
| Replacement | إحلال |
| Reinforce | إعادة تقويه |
| Self organization | التنظيم الذاتي |
| Spatial spread | الانتشار الحيزي |
| Spatial distribution | التوزيع الحيزي |
| Spatial domain | المجال الحيزي |
| Preprocessing | المعالجة الأولية |
| Elitism | النخبة |
| Stimulus pattern | النمط الحالي |
| Selection | انتقاء |
| Monotonically | بشكل رتيب |
| Variance | تباين |
| Segmentation | تجزئ |
| Gray- scale | تدرج رمادي |
| Recombination | تزاوج |
| Encoding | تشفير |
| المصطلح الإنكليزي | المصطلح العربي |
| Contrast | تضاد لوني |
| Interpretation | تفسير |
| Normalizaton | تقييس |
| Evaluation | تقييم |
| Assignment | تنسيب |
| Smoothing | تنعيم |
| Breeding | توليدي |

| | |
|--------------------------|-----------------------|
| Parameter | حد |
| Receptive field | حقل استلام |
| Cell | خلية |
| Features | صفات |
| Fitness | صلاحية |
| Noise | ضوضاء |
| S- layer | طبقة S- |
| Input layer | طبقة الإدخال |
| C-layer | طبقة C- |
| S-layer | طبقة S- |
| Layer | طبقة |
| المصطلح الإنكليزي | المصطلح العربي |
| Mutation | طفرة |
| Offspring | طفل |
| Threshold | عتبه |
| S-column | عمود S |
| Pixel | عنصر الصورة |
| Individual | فرد |
| Density | كثافة |
| Analoge | متناظر |
| Population | مجتمع |
| Pool | مجمع مربّي |
| Cell-plane | مستو - خلية |
| Afferent | مصدر |
| Operator | معامل |
| Inhibitory | معيقة |
| Mapping | مقابلة |

| | |
|-------------------|----------------------------|
| Excitatory | منشطة |
| Region | منطقة |
| Synapses | نقطة اتصال الخلايا العصبية |
| المصطلح الإنكليزي | المصطلح العربي |
| Input pattern | نمط الإدخال |
| Structure | هيكل |
| Description | وصف |

الفصل الأول المقدمة

١-١ مقدمة عامة (General Introduction)

لقد أصبح الاتجاه المستقبلي في علم الحاسبات الالكترونية هو بناء حاسبات ذكية تساعد في أداء مهام بإسلوب مشابه لإسلوب الإنسان، أو بمعنى آخر هو بناء جيل جديد من الحاسبات تحاكي قدرات الإنسان .

تعد قدرة الإنسان على الإدراك والتمييز من أهم الميزات التي أعطته صفة الذكاء والتي يسعى الإنسان إلى تمثيلها في نظام الحاسبة. لذلك يجب أن نقوم بتحليل هذه القدرات كي تكون عملية تمثيلها عملية سهلة.

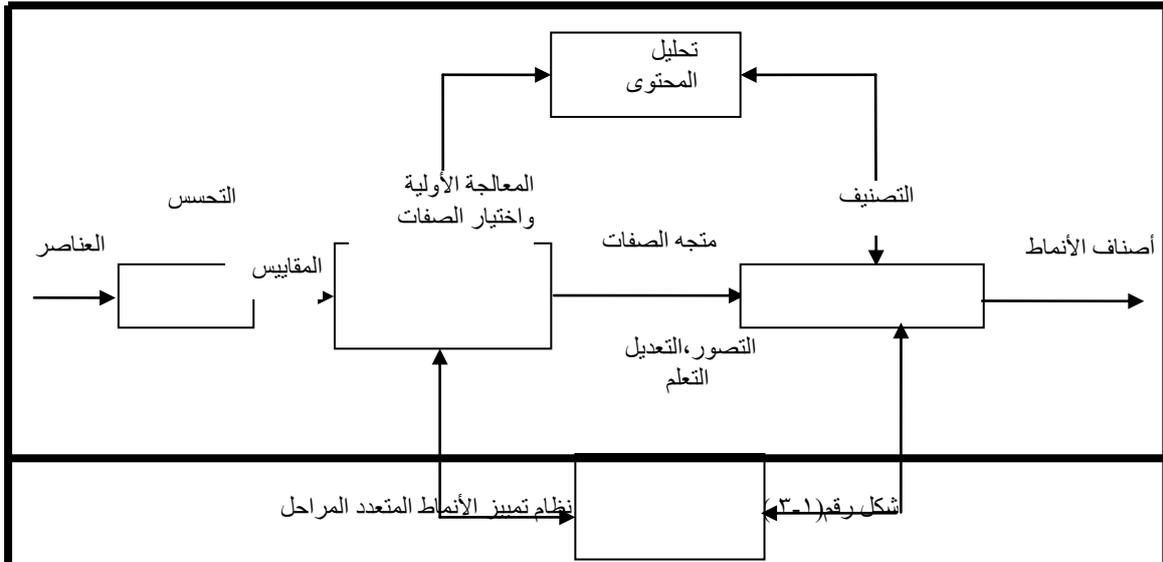
ترتبط عملية الإدراك لدى الإنسان بعملية تسجيله للحقائق التي يشاهدها في محيطه مسجلا معلومات حول تلك الحقائق في ذاكرته كوسيلة لاكتساب المعرفة وقد لا تكفي تلك الحقائق بصيغتها المجردة في بعض الأحيان فيقوم بتسجيلها بهيئة نمط pattern .

ومن الجدير بالملاحظة أن قدرة الإنسان على التمييز تمتلك مرونة عالية جعلته قادرا على تمييز أنماط الحقائق رغم التغير الكبير والناج عن فقدان أو تشوه تلك الأنماط وتسمى صفة المرونة هذه بقابلية التعديل والتي تعطي الإنسان القدرة على التعلم.

نستنتج مما سبق بأن عملية محاكاة قدرة الإدراك والتمييز لدى الإنسان في نظام الحاسبة يعني إكسابها القدرة على التعامل مع المعلومات بهيئة أنماط ويتضمن ذلك إستحصال ومعالجه لهذه المعلومات [١][٢] .

يهدف العمل الحالي إلى محاكاة العقل البشري في تصنيف الصور، إذ أن الصنف هو واحد فقط من الهيئات التي ربما تكون أو لا تكون محددة اعتمادا على طبيعة المشكلة والهيئات ربما تكون قيم منفصلة أو قيم منطقية أو جداول قواعدية أو قيم تناظرية والتعلم بهذا المعنى هو تحديد لقوانين الارتباطات بين الصفات والهيئات للأنماط [٣].

إن أنظمة تمييز الصور عمليا وبصورة عامة تحتوي على مراحل متعددة بالإضافة إلى آلة التمييز نفسها. لقد عرف النموذج المتعدد المراحل الذي يصف عملية التمييز لعقود عديدة. ولقد تم تحديد مراحل هذا النموذج بناء على مشاهدات الباحثين وتحليلهم لنظام التمييز البشري. الشكل رقم (٣-١) الآتي يمثل المراحل الأساسية لنظام تمييز الأنماط [٤]، [٥] .



التحسس هو عملية تمثيل البيانات للعنصر المراد تمييزه وتتضمن عملية تحويل العنصر من فضاء إلى ما يسمى بفضاء القياس (measurement space) والذي تمثل فيه العناصر بمتجه يسمى متجه القياس (measurement vector) لتمثل عناصر هذا المتجه خواص العنصر الموصوف به [٥] .

إن المعالجة الأولية قد تتضمن تجزئة الصورة إلى أجزاء منفصلة أو كيانات بالإضافة إلى أنها ربما تتضمن تقييس الصورة لتسمح بالتركيز على الأشياء. أما استخلاص الصفات فهي

تلخص المعلومات المهمة حول النمط الفعلي لتتمكن من التمييز أما في التصنيف فإن المصنف يقوم بالتعرف إلى من ينتمي النمط وبصوره عامه الهيئات مرتبطة مع النمط المعطى ،وأما تحليل المحتوى فهو يزيد من دقة التمييز بتجهيز معلومات متعلقة بالبيئة المحيطة بالشيء كمثل في حالة تمييز الأحرف ربما يكون قاموس بلغة and/or يكون ملحق به [3]. وقد ذكر Gonzalez بان تقسيم فضاء التقنيات في مجال تحليل الصور إلى ثلاث مستويات من التعقيد والذكاء أمرا ضروريا ، فعد أن مرحلة التحسس (الأولى في التدريب) هي مرحلة خالية من الذكاء طالما أن أي عملية في العقل لا تستطيع البدء حتى تتوفر الصورة الملائمة، في حين تحتاج المرحلتان الأخيرتان إلى عمليات ذكية لاستخلاص الصفات واتخاذ قرار التمييز على التوالي.

أن التصنيف حقل مهم في دراسة تحليل الصور الرقمية ،وقد ظهرت أجيال جديدة ومتطورة من المتحسسات التي تظهر الصورة بوضوح أكبر مما أدى إلى ظهور طرق عديدة في تصنيف الصور وقد استعملنا هنا مبدأ الحساب المرن soft computing للتصنيف وهو مصطلح شامل لمجموعة من تقنيات الحساب، إذ أن كل تقنية يمكن أن تستخدم بصورة مستقلة لكن الفائدة الحقيقية من الحساب المرن هو الطبيعة المتكاملة للتقنيات فباستخدامها سويه يمكن أن تنتج حلول لمشاكل معقدة جدا أو التي لا يمكن حلها بالطرق الرياضية التقليدية.

وهذا المصطلح أول من ابتكره البروفسور LOTFI ZADEH الذي طور المنطق المضرب fuzzy logic في منتصف الستينيات من القرن السابق. في كلماته الآتية:

"الحساب المرن يختلف عن الحساب الصلب hard computing التقليدي إذ انه لا يشبه الحساب الصلب في ان الحساب المرن له القابلية على تحمل عدم الدقة وعدم التأكيد والحقيقة الجزئية وبالنتيجة الدور الرئيسي للحساب المرن هو العقل البشري. المبادئ المرشدة للحساب المرن هو توضيح القابلية لعدم الدقة، عدم التأكيد والحقيقة الجزئية ليحقق طريق، قوي وبكلفة حل قليلة" [6]. التقنيات الأساسية في الحساب المرن هي [7] [8] :-

- الحساب التطوري Evolutionary computation
- الشبكات العصبية Neural networks
- الأنظمة المضببة Fuzzy systems
- تعلم الماكنة Machine learning
- الاستنتاج الاحتمالي Probabilistic reasoning

وفيما يأتي نبذة مختصرة عن الأعمال السابقة في مجال تصنيف الصور:

١-٢ نبذة مختصرة عن البحوث السابقة

في عام ١٩٩٩ قام كل من U.Ammer,R.de Kok,T.Schneider بنشر بحث لتصنيف صور غابات الألب بالاعتماد على المحتوى context للشكل بدلا من عنصر الصورة pixel وكانت الصور هي صور GIS ،حيث تم استخدام المعرفة الخبيرة expert knowledge وتأثير الأشكال المجاورة في وضع قوانين قرار العضوية وكذلك تم استخدام المنطق المضرب لإضافة شفافية إلى قوانين القرار وقد اعتمد التصنيف المرن أي التصنيف بالاستفادة من مبدأ الحساب المرن ،يتم تصنيف الصور اعتمادا على الـ resolution للصورة إذ أن الصورة تتراوح بين مناطق غاباتية وأخرى غير غاباتية فمثلا منطقة غابات في ألمانيا غالبا تأخذ مساحة تتراوح بين ١٣ إلى ١٥ هكتارا على الأرض بينما تقابل ٣٥ إلى ٢٠٠ عنصر صورته في المتحسس Landsat القياسي، أما الراسم scanner مثل DPA فكل منطقه مزدحمة لها قطر يتراوح بين ١٠-٢٠ عنصر صورته [٩] .

قام كل من R.Kh.Sadykhov,M.E.Vatkin في عام ١٩٩٩ بنشر بحث لتصنيف صور فوتوغرافية ذات تدرج رمادي تحتوي على مجموعة شرائح chips من الدوائر المتكاملة (integrated circuit IC) إذ تم استخدام شبكة Neo-cognitron للتصنيف بعد أن دربت على نوعين من شرائح الدوائر الالكترونية . إذ كانت خوارزمية البحث عن الوحدات units في الصورة هي باستخدام نافذة متحركة sliding window حيث لكل موقع في النافذة يتم مقارنة مقياس الصلاحية للصورة في الشباك مع صورة وحدة قطعة الدائرة المتكاملة IC المطلوبة أو التي تم تدريب الشبكة عليها ،وكانت طريقة التعلم المستخدمة هي تعلم مشرف عليه . حيث أن الطبقة S الأولى تحتوي على ٨ مستويات خلايا وكل مستوى خلية مكون من مصفوفة ذات ٤×٤ ويتم دمج كل اثنين من مستويات الخلايا المتشابهة في الصفات في مستوى خلية واحده في الطبقة C .وكانت الشبكة تتكون من مرحلتين بحيث تصبح الطبقة الأخيرة تحتوي على مستوى خلية واحدة [١٠] .

قامت الباحثة وفاء محمد سعيد في عام ٢٠٠١ بتصميم نظام تجزئة لتمييز أهداف الصور الحرارية ذات التدرج الرمادي حيث استخدمت ثلاث تقنيات لتجزئة الصورة وهي تقنية استرخاء تدرج اللون الرمادي وتقنية استرخاء الحافة وتفاعل تدرجات اللون الرمادي مع معلومات الحافة إذ أثبتت أن كل من التقنيتين الاثنتين لهما القابلية على تجزئة أكثر من هدف أما التقنية الأخيرة فهي أفضل في حالة احتواء الصورة على هدف وحيد وإنها تنتج تقطيع أفضل للهدف من الطريقتين السابقتين في حالة الصور ذات الانبعاثية القليلة ، أما الطريقة الأولى فإنها تزيد من

درجة النعومة للصورة كلما زادت عدد التكرارات وأما الطريقة الثانية فكانت لها القابلية على تعريف الهدف بصورة أسرع من باقي التقنيات [٥١].

في عام ٢٠٠١ قدم Zhiling Long بحث لنظام تجزئة لصور الغابات حيث كانت قاعدة البيانات المستعملة مأخوذة من Ouachita.Ozark National Forests. في Arkansas USA حيث صممت صفات تعتمد على اللون الأصفر yellow واللون البني brown، الصفات اعتمدت على تحويلات الجيب تمام المنفصلة discrete cosine transform وكذلك الصفات تعتمد في تصميمها على مجموعة فلاتر Cabor حيث كانت ملائمة في تحليل صور الغابات وكذلك طور خوارزمية تجزئة تعتمد على تصنيف البلوكات باستخدام مبدأ تحليل المكونات. وقدم النظام باستخدام هذه الخوارزمية نسبة خطأ ٦١.٤ % [١١].

وفي عام ٢٠٠٣ قام كل من L.Lepisto,L.Kunttu,J. Autio,A.Visa بتصنيف صور طبيعية ملونة RGB للصخور باستخدام صفات بنيوية texture و صفات طيفية spectral أما الصفات البنيوية فقد تم حسابها باستخلاص جدول للحدوث co-occurrence حيث يحتوي على معلومات عن كل عنصر صورته وعلاقته مع العناصر المجاورة وعدد تكراراته لذلك هذه الصفات تعد صفات إحصائية stochastic أما الصفات الطيفية فقد تم استخلاصها باستخدام المقياس الطيفي HSI حيث H (hue) يصف اللون و S (Saturation) هو مدى الإشباع و I (Intensity) هو الكثافة، في طريقة التصنيف هذه الصور ذات الطبيعة غير المتجانسة non-homogenous قسمت إلى مجموعته من البلوكات blocks وقيمة الصفات تم حسابها لكل بلوك بصوره منفصلة وبهذه الطريقة تكون قيم الصفات بشكل خواص المدرج التكراري histogram features. تم اختبار هذه الطريقة من التصنيف على نوعين من الصخور وأظهرت نتيجة التجارب أن الصفات المستعملة لها القابلية على تمييز الصخور بصوره جيده [١٢].

قامت الباحثة سماهر حسين علي في عام ٢٠٠٥ بتصميم نظام برمجي يستخدم التقنيات الحساب المرنة لتصنيف كيانات في الصور الجوية وصور الأقمار الاصطناعية اعتمادا على خصائصها وبأقل خطأ ممكن، حيث قامت بتصنيف خمسة أنواع من الكيانات (منطقة حضرية، منطقة غابات، أنهار، طرق، ملاعب كرة قدم) عن طريق بناء قاعدة بيانات تصف تلك الكيانات بالاعتماد على خصائصها، حيث استخدمت خوارزمية Breeder الجينية لأجراء عملية عنقدة جينية لتجزئة الصورة وتجهيزها بعدد العناقيد الموجودة في الصورة. ومن ثم تم استخلاص نوعين من الخصائص لكل عنقود وهي خصائص مرئية وتضمنت (النمط Pattern والشكل Shape والظل Shadow والتركيب Texture والتطابق Association) وخصائص

إحصائية وتمثلت بالخصائص الطيفية التي اشتملت على (الشدة اللونية Intensity واللون النقي Hue والإشباع Saturation) [١٣].

قام الباحث مهدي عبد سلمان في عام ٢٠٠٥ بتطوير أسلوب برمجة مرنة لإيجاد طريقة جيدة لها القدرة على استخلاص نماذج مخفية من قاعدة البيانات وبصورة سهلة. فقد تم استخدام الشبكة العصبية من نوع (Winner –Take –All) لأجراء عملية عنقدة لسجلات قاعدة البيانات بعد أن تم تحديد العدد الأولي لهذه العناقيد مع تحديد الأوزان الابتدائية المناسبة للشبكة حيث تم استخدام الخوارزميات الجينية لهذا الغرض. بعد تحديد العدد الأولي للعناقيد يمكن تدريب الشبكة العصبية وبعد إكمال عملية التدريب تصنف السجلات في عملية استدعاء للشبكة. وبدراسة كل صنف (مجموعة سجلات) إحصائياً يمكن التعبير بقوانين تصف كل صنف. خلال المنطق المضرب نعبر عن بعض الصفات بتعابير لغوية. إن لهذا الأسلوب قدرة على التعامل مع أي نوع من قواعد البيانات ومن أي مجال كما وإنها سريعة وسهلة، وكانت قواعد البيانات المستخدمة في مجالات متعددة مثل الطب وعمليات التوطين ومعلومات الرادار [١٤].

٣-١ هيكل الرسالة

تتكون الرسالة من أربعة فصول، يقدم الفصل الأول مقدمه عامه حول موضوع تمييز الأنماط وتصنيف الصور والحساب المرن ومن ثم يعرض الأعمال السابقة في مجال تصنيف الصور، أما الفصل الثاني فيسلط الضوء على المفاهيم الأساسية لتقنيات الحساب المرن والمستخدمه في النظام المقترح ومن ثم يتطرق إلى مراحل معالجة الصور الرقمية بحيث يتم البحث في المراحل التي يمر بها النظام المقترح وبصورة مفصله كي يكون ركيزة في بناء النظام المقترح، أما الفصل الثالث فيستعرض منظومة الحساب المرن المقترحة لتصنيف الصور والفصل الرابع يتضمن النتائج والاستنتاجات والأعمال المستقبلية.

٤-١ هدف الرسالة

يهدف البحث إلى بناء نظام يحاكي العقل البشري في تصنيف الصور وبالاستفادة من مبدأ الحساب المرن، حيث يتم تجزئة الصورة إلى كيانات ذات معنى عن طريق استخدام خوارزمية Breeder الجينية والهجينة واستخراج صفات هذه الكيانات ليتم تصنيف هذه الكيانات عن طريق شبكة Neo-cognitron العصبية.

الفصل الثاني

مفاهيم تقنيات الحساب المرن

١-٢ مقدمة

إن هذا الفصل يقدم عرضاً مفصلاً عن مفاهيم تقنيات الحساب المرن والمستخدمة في البحث وهذه المفاهيم تتضمن الحساب التطوري والذي يشمل الخوارزميات الجينية و الاستراتيجيات التطورية لتكون ركيزة لتوضيح خوارزمية Breeder الجينية الهجينة، أما التقنية الثانية والتي تم استخدامها هي الشبكات العصبية، ومن ثم يقدم الفصل مراحل معالجة الصور الرقمية والذي تم عن طريقه الخوض في الشرح التفصيلي لكل مرحلة مستخدمة في النظام المقترح.

٢-٢ الحساب التطوري [١٥]

يستخدم مبدأ دارون (البقاء للأصلح) لضمان الحلول المثلى للمشاكل. هناك عدد من التقنيات التطورية التي تتشابه بينها في استخدام مجتمع ذو حلول متولدة عشوائياً. وكل واحدة من هذه

التقنيات يحكم عليها حسب تكيفها للمشكلة المعينة ،أما دالة الصلاحية فهي تقييم الحل وترجع جواب عددي والتي تمثل معدل أو قيمة الحل المناسب والمجتمع الابتدائي يستخدم بعدها لإنشاء مجتمع جديد من الحلول وباستخدام واحد أو أكثر من العوامل الجينية الآتية :

- التزاوج Cross over : هذه العملية تتضمن اشتراك المعلومات (الجينية) من الحلول لأبوين لإنتاج حلول الأطفال

- الطفرة Mutation : هذه العملية تتضمن اخذ حلول وتعديل معلوماتها الجينية بصورة طفيفة

- الاستنساخ Cloning: هذه العملية تستنسخ الحلول لإنتاج نسخة جديدة .

الحلول المستخدمة في هذه العمليات مختارة من المجتمع الرئيسي وتوضع في المجتمع المولد باستخدام طريقة الاختيار ،الطريقة المتبعة لخلق هذا المجتمع تختلف بين الخوارزميات المختلفة، كذلك الطريقة لتقرير أي المرشحات تدخل الجيل الجديد. كل التقنيات تتطلب من حجم المجتمع أن يكون ثابت مابين الأجيال.عملية التقييم وإعادة التوليد للمجتمعات المرشحة تكرر إلى أن تصل إلى الحل الأمثل.أما تقنيات الحساب التطوري فهي:

١- الخوارزميات الجينية Genetic Algorithm

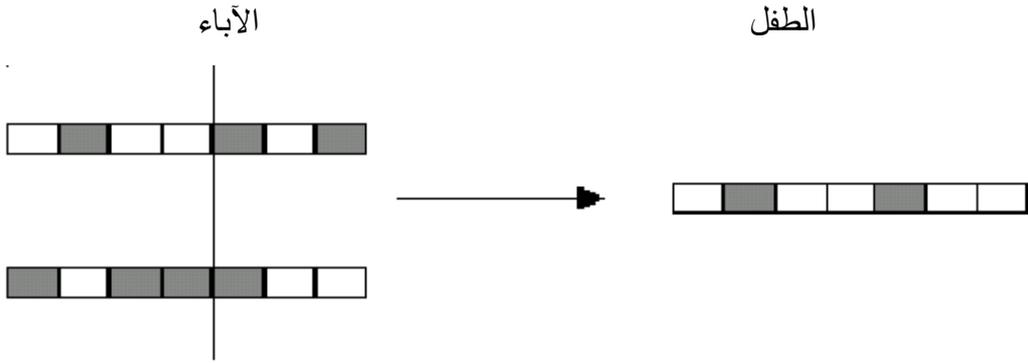
٢- البرمجة الجينية Genetic Programming

٣- الاستراتيجيات التطورية Evolution Strategies

٤- البرمجة التطورية Evolutionary Programming

٢-٢-١ الخوارزميات الجينية [١٥]

تعد الخوارزميات الجينية (Holland ١٩٦٠) الأكثر نجاحا تجاريا من بين التقنيات التطورية والحلول في هذه الخوارزميات تشفر بصيغة سلسلة رموز حيث تمثل الخواص التي تملكها الحلول الناتجة،كمثال قائمه بقيم المتغيرات في معادله أو الخواص لمكونات في تصميم ما. أجيال جديدة تخلق باستخدام كل العوامل الجينية ،لكن عامل التزاوج يعطى اسبقية أعلى من عوامل الطفرة أو الاستنساخ وطفرة عادة تستخدم كعملية تغذية عكسية لعمل تنوع في المجتمع والتزاوج يتم بواسطة دمج أجزاء سلسلة الرموز المشفرة من الأبوين لإنتاج طفل كالاتي:



الشكل رقم (٢-١): يمثل عملية التزاوج

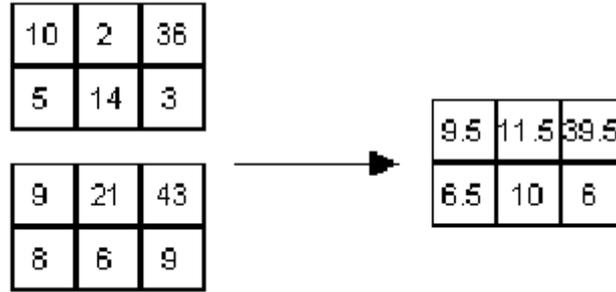
عامل الطفرة عادة يكون في نقطة واحدة فعندما تكون البيانات مشفرة بصيغة ثنائية ، الطفرة ستكون بقلب بت واحد لتغير القيم ، لكن عند استعمال الأرقام الحقيقية يمكن أن يضاف أو يطرح رقم عشوائي بدلا من ذلك.

حلول الأباء التي تشارك في خلق الجيل الجديد يتم اختيارها اعتمادا على صلاحيتها وأشهر طريقة لعمل ذلك هي بتقييم كل المجتمع باستخدام دالة صلاحية لإنتاج مجتمع جديد باستخدام تمثيل صلاحية مناسب. والطريقة الأخرى هي بأخذ مجموعه عشوائية من المرشحات من المجتمع الرئيسي ويتم منافستها لإيجاد المرشحات الأفضل في كل مجموعة. كل هذه التقنيات تنتج في مجتمع مختار يمتلك نسبة عالية من الحلول الجيدة، لكن لاتستبعد الحلول السيئة. أما مبدأ الإحلال يتضمن إحلال كل أفراد الجيل السابق بالأفراد الذين تم توليدهم جديدا، لكن أكثر الطرق المستخدمة عندما الأبناء المتولدين يتم إحلالهم محل الأفراد الأضعف في مجتمع الأباء.

٢-٢-٢ الإستراتيجيات التطورية [١٥]

تم تطويرها من قبل باحثين تقنيين في برلين والتمثيل الذي استعمل للحلول المرشحة هي قائمه من المتجهات الثابتة الأطوال ، والقيم التي تصف خصائص التصميم هي قيم حقيقية. في البداية تم اخذ تصميم من أب مفرد وتم عمل الطفرة له ومن ثم حسبت دالة الصلاحية للابن والأب كلاهما ، وبعدها تم اختيار الفرد ذو الصلاحية الأعلى لينقل إلى الجيل الآتي. هذه الطريقة تم توسيعها فيما بعد لتسمح لمجتمعات الأباء والأبناء حيث الأباء يتم اختيارهم داخليا عشوائيا ويتم استخدامهم لإنتاج مجتمع أطفال ذو حجم اكبر من حجم المجتمع الابتدائي.

اعتياديا العامل الجيني المستخدم هو الطفرة فقط، لكن يمكن ان يستخدم عامل التزاوج الوسطي لدمج الخصائص من الآباء. هذا العامل يعمل على القيم في متجه الأب، ويؤخذ معدل القيم لإنتاج الطفل وكما موضح ذلك في الشكل رقم (٢-٢). على كل حال الإستراتيجيات التطورية لا تشبه الخوارزميات الجينية حيث الطفرة هنا هي عامل أولي والتزاوج يستخدم بصورة ثانوية.



شكل رقم (٢-٢): يمثل عملية التزاوج في الإستراتيجيات التطورية

هناك نوعان من مبادئ الإحلال المستخدمة، تسمى $(\mu + \lambda)$ و (μ, λ) حيث أن μ هو حجم المجتمع و λ عدد الأطفال الناتجين. في طريقة الفاصلة الجيل التالي مختار من الأطفال، أما طريقة الجمع فهي تختار الشروط الأفضل من الآباء والأبناء ليكون الجيل التالي.

٢-٣ الشبكات العصبية

في العقل البشري هنالك عدد من الخلايا العصبية المرتبطة فيما بينها والتي لها القابلية على حساب مشاكل ذات تعقيد كبير وتعيد العمل لمحطات جديده بواسطة التعلم من الخبرات السابقة. وهذا هو الأساس للشبكات العصبية الصناعية [١٥].

عرف Zurada الشبكات العصبية بأنها، الأنظمة العصبية الاصطناعية، أو الشبكات العصبية، هي انظمه خلوية فيزيائية لها القابلية على اكتساب وخرن والانتفاع من المعرفة المجربة أو المختبرة [١٦].

لا يوجد تعريف شامل للشبكات العصبية ولكن يمكن تعريفها عن طريق الخواص العامة بأنها شبكه من عدة معالجات بسيطة تدعى بـ (وحدات)، كل وحده يمكن أن يكون لها عدد قليل من ما يسمى بالذاكرة المحلية. هذه الوحدات ترتبط فيما بينها عن طريق الروابط والتي تقوم بتقبل قيم رقميه، مشفره بطرق مختلفة وحسب الحاجة، والوحدات تعمل فقط على البيانات المحلية وعلى المدخلان التي تستلمها عبر الروابط.

وبعض الشبكات العصبية هي نموذج لشبكات عصبية بايولوجية وبعضها ليست كذلك، لكن تاريخيا سبب ظهور الشبكات العصبية هو الرغبة في بناء نظام اصطناعي قادر على حساب ما هو معقد وربما "الذكي" بصورة تشبه ما يقوم به العقل البشري .

واغلب الشبكات العصبية لها نوع من قوانين التدريب حيث الأوزان للروابط يتم تعديلها على أساس البيانات .وبعبارة أخرى الشبكات العصبية تتعلم من الأمثلة (كتعلم الطفل التمييز بين الألوان)، وكذلك تظهر بعض القابلية لعمل عمومي للبيانات المدربة والشبكات العصبية لها قابلية كبيرة على العمل بصورة متوازية، حيث أن الحساب للمكونات مستقل بصورة كبيرة لكل واحد منها [١٧] .

أما طرق التعلم في الشبكات العصبية هي التعلم المشرف عليه وغير المشرف عليه.في التعلم المشرف عليه المخرجات المطلوبة معروفة وتعطى إلى الشبكة العصبية أثناء التدريب فالشبكة العصبية لها القابلية على تعديل أوزانها لتحاول مطابقة مخرجاتها مع المخرجات المطلوبة وبعد التدريب يتم اختيار الشبكة العصبية بإعطائها القيم المدخلة فقط وليس المخرجات المطلوبة لنرى مدى مطابقتها إلى المخرجات المطلوبة.

أما في التعلم الغير مشرف عليه، الشبكة العصبية لا تجهز بالنتائج الصحيحة أثناء التدريب والشبكات العصبية الغير مشرف عليها عادة تقوم ببعض أنواع مقارنة البيانات مثل اختصار الأبعاد أو العنقدة.

والطرق المشرف عليها تضم نوعين ذاتية الترابط (auto-associative) ومختلفة الترابط(hetro-associative) في التعلم ذاتي الترابط قيم الهدف هي قيم المدخلات نفسها بينما في التعلم مختلف الترابط، الهدف بصورة عامه يختلف عن المدخلات وبعض الطرق الغير مشرف عليها مكافئه للطرق المشرف عليها ذاتية التعلم.

هناك نوعان رئيسان في تركيب الشبكات العصبية وهو التغذية الأمامية (feed forward) والتغذية العكسية (feedback) .

في شبكات التغذية الأمامية الارتباطات بين الوحدات لا تشكل دوره وعادة تنتج استجابة للمدخلات سريعة، واغلبها يمكن تدريبها باستخدام أنواع عديدة من الطرق العددية التقليدية الكفوءة بالإضافة إلى الخوارزميات المبتكرة من باحثي الشبكات العصبية.

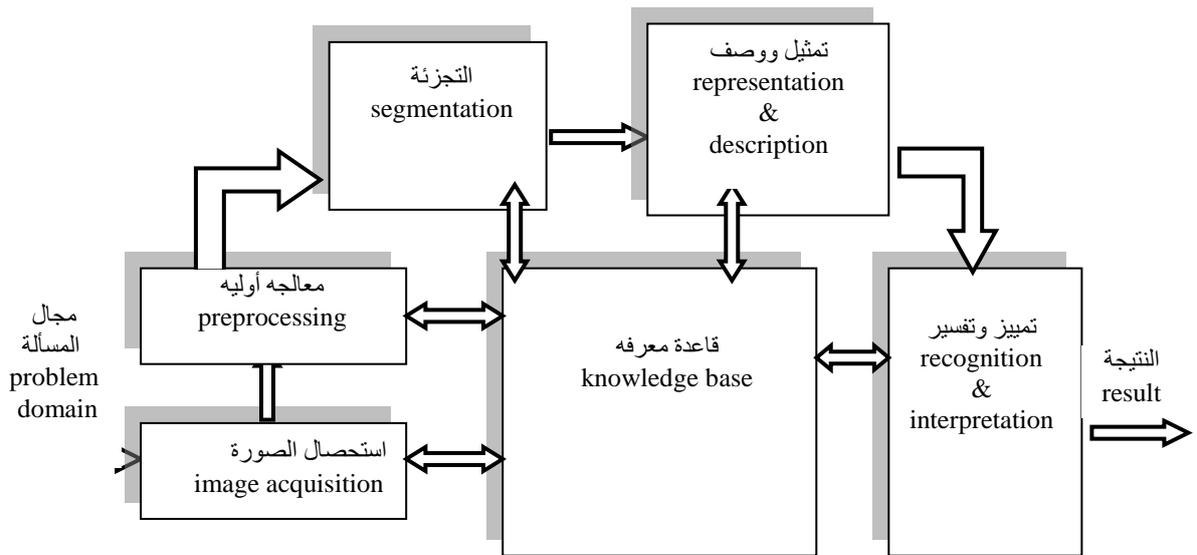
في شبكات التغذية العكسية يوجد دوره في الروابط وفي بعضها في كل مره يجب أن تكون المدخلات حاضره والشبكة العصبية يجب أن تكرر لمرات عديدة قبل أن تنتج استجابة.شبكات التغذية العكسية عادة أصعب في التدريب من شبكات التغذية الأمامية، بعض

أنواع الشبكات مثل (وحدات winner-take –all) يمكن أن تنفذ أما كشبكات تغذية إماميه أو تغذية عكسية.

الشبكات العصبية كذلك تختلف في أنواع البيانات التي تتقبلها، هناك نوعين أساسيين من البيانات (المطلقة و الكمية) المتغيرات المطلقة تأخذ الأرقام المنتهية أو المحددة من القيم الممكنة واغلب الحالات هي من هذا النوع. الشبكة المشرف عليها في التعلم مع بيانات مطلقة في الإخراج وكذلك الشبكة الغير مشرف عليها في التعلم مع بيانات إخراج مطلقة تدعى (بالتصنيف). المتغيرات الكمية هي مقاييس عدديه لبعض الرموز أو الأشياء، مثل عدد الأطفال أو أي متغير ثنائي [١٧].

٢-٤ معالجة الصور الرقمية digital image processing

حقل معالجة الصور الرقمية من الحقول المهمة والتي لاقت نجاحا واهتماما كبيرين في العديد من التطبيقات في مجالات مختلفة منها الطبية والعسكرية والصناعية بالإضافة إلى مجال الفضاء والاتصالات يختص هذا الحقل بالتعامل مع صور ثنائيه البعد من خلال الحاسوب [١٨]. وبصورة عامه هناك غرضان لتطبيقات معالجة الصور كافة، حيث يتمثل الغرض الأول بتحسين الصور (image enhancement) بطريقة ما لتسهيل تفسيرها من قبل الناس فضلا عن دعمها لخطوات المعالجة اللاحقة، أما الغرض الثاني فيختص بتحليل الصور (image analysis) لاستخلاص معلومات معينه منها بهدف فهمها وتفسيرها من قبل الحاسوب [٢٥][٥]. أن تحقيق هذين الغرضين يتم من خلال المرور بعدد من المراحل وكما موضح في الشكل (٢-٣) [٥].



شكل رقم (٢-٣): المراحل الأساسية في معالجة الصور الرقمية

٢-٥ استحصال الصورة

تتوفر العديد من الصيغ لتمثيل الصور، تعتمد عملية قراءة ملف الصورة على صيغة ملف الصورة المستخدم، وتعد الصورة من نوع BMP (bitmap format) من أشهر وأهم الأنواع ويرجع السبب في ذلك إلى سهولة التعامل مع هذه الملفات والنتيجة من كون البيانات مخزونة فيه بشكلها الطبيعي الخالي من أي طريقه لضغط البيانات والتي تستخدم في الملفات الصورية الأخرى [٢٠] بالإضافة إلى أنها تمتاز بإمكانية تخزين وعرض الرسوم أو الصور من أي نظام عرض [٥٢].

يتألف هيكل ملف BMP كما في باقي الملفات الصورية من جزأين هما رأس الملف header وجزء البيانات data حيث يحتوي الجزء الأول معلومات عن الصورة والتي تساعد في معالجة الصورة في حين يحتوي الجزء الثاني على بيانات الصورة [١].

هناك نوعان من صور BMP حيث تعتمد على طريقة تمثيل عنصر الصورة pixel في جزء البيانات، النوع الأول هو الصورة الملونة RGB حيث كل نقطه تتألف من ثلاث بايتات، البايت الأول للون الأحمر، البايت الثاني للون الأخضر، البايت الثالث للون الأزرق وحسب الترتيب [٢١]. والنوع الثاني هو الصور ذات التدرج الرمادي أو صورة لوحة الألوان palette image حيث تخزن الألوان بصورة غير مباشرة، تكون الأرقام محصورة على شكل مجموعة مرقمة من الألوان تسمى لوحة الألوان palette كل لون في اللوحة يعرف بثلاثة أرقام تمثل الشدة أو الكثافة اللونية الابتدائية ولون النقطة على الشاشة يعرف بتعيين رقم اللون باللوحة وفوائد هذه الطريقة هي تقليل نسبة الذاكرة اللازمة لخزن الصورة [٢٢].

يعتمد حجم لوحة الألوان على عدد الثنائيات لكل عنصر bit per pixel فإذا كان عدد الثنائيات يساوي ثمانية واحده (بايت) فإن حجم لوحة الألوان يكون (٠ - ٢٥٥) وكل عنصر في الصورة يمثل فهرس يشير إلى احد مداخل لوحة الألوان، ويمثل الجزء الأخير بيانات الصورة [٢٣].

٢-٦ المعالجة الأولية

يمكن اعتبار عمليات تحسين الصورة هي المعالجة الأولية للصورة لجعل الصورة أكثر ملائمة للمعالجة من الصورة الأصلية وتتضمن عمليات تحسين الصورة في المجال الحيزي (spatial domain) والمجال الترددي (frequency domain). تقنيات المجال الحيزي تشير إلى مستوى الصورة نفسها والطرق في هذا المجال تعتمد المعاملة المنفصلة لعناصر الصورة. أما تقنيات المجال الترددي فهي تعتمد على تحويل الصورة بتحويلات مختلفة مثل فورير (

(Fourier transform) و (discrete cosine transform DCT) و (transform) و (Wavelet) وغيرها .

٢-٧ تجزئة الصور

تعد التجزئة الخطوة الأولى على طريق تفسير بيانات الصورة حيث تحدد هذه المرحلة النجاح أو الفشل النهائي لهذه العملية [٥]. وهي من المراحل الحرجة لأي نظام ممكن لفهم الصورة، حيث تمتد الأخطاء الناتجة من هذه المرحلة إلى المراحل اللاحقة للمعالجة [١٩]، [٢٥] تؤدي مهمة تجزئة الصورة إلى عدد من المناطق المختلفة كل منها يمتلك الخواص نفسها (مثلا المستوى الرمادي (gray level) ، اللون (color) والنسيج (texture)) [٢٦] .

ونظرا لأهمية وخطورة هذه المرحلة في عملية المعالجة ككل، فقد اقترحت العديد من التقنيات لانجازها، حيث تصنف هذه التقنيات بصورة عامة إلى ثلاثة أصناف رئيسة [٢٧] .

١- التقنيات المعتمدة على الحافة (edge-based techniques)

٢- التقنيات المعتمدة على العنقدة (cluster-based techniques)

٣- التقنيات المعتمدة على المنطقة (region-based techniques)

وبصورة عامة يتم صياغة مسألة التجزئة رياضيا كالآتي [٥] :

إذا كانت R تمثل منطقة الصورة بكاملها، فإن عملية التجزئة تقسم هذه المنطقة إلى N من المناطق الجزئية R_1, R_2, \dots, R_N بحيث تحقق هذه المناطق الشروط الآتية:

$$\bigcup_{i=1}^N R_i = R \quad (١)$$

(٢) R_i منطقة متصلة لكل $i=1, 2, \dots, n$

(٣) $R_i \cap R_j = \Phi$ لكل i, j بحيث $i \neq j$

(٤) $P(R_i) = True$ لكل $i=1, 2, \dots, n$

(٥) $P(R_i \cup R_j) = False$ لكل $i \neq j$

يدل الشرط الأول على وجوب كمالية التجزئة، وهذا يعني ضم كل عنصر صورة إلى منطقه ما في الصورة. في حين يتطلب الشرط الثاني أن تكون كل منطقه متصلة. أما الشرط الثالث فيدل على ضرورة أن تكون المناطق منفصلة (disjoint) ويتعامل الشرط الرابع مع الخواص الواجب توفرها في كل صورة داخل المنطقة الواحدة، فمثلا إذا كان $P(R_i) = TRUE$ فهذا يعني امتلاك كل عناصر الصورة التابعة للمنطقة R_i الشدة اللونية نفسها. وأخيرا يحرص الشرط الخامس على أن تكون المناطق R_i و R_j مختلفة.

عمليا تعد مهمة تحقيق هذه الشروط عمليه صعبة الحصول، حيث تحتوي صور العالم الحقيقي على بعض التعقيد نتيجة لتداخل كياناتها بالإضافة إلى فقدانها للتضاد اللوني (contrast) العالي بين مناطقها. وبصورة عامه، قد يصاحب عملية التجزئء نوعان من الأخطاء [٢٨] :

(١) قد تنتج عملية التجزئء مناطق إضافية، بعبارة أخرى مناطق لا تمثل كيانات فعليه في الصورة.

(٢) قد تكون بعض المناطق مفقودة في الصورة.

وعليه مثلما لا توجد نظريه لمسألة العنقدة، ليس هناك نظريه للتجزئء، حيث تعتمد جميع التقنيات الموجودة على مبدأ التخمين الذكي (ad hoc) في انجازها لعملية التجزئء، وفيما يأتي أكثر الطرق شيوعا في عملية التجزئء.

١- العتبية (Thresholding)

٢- كشف الحدود (Boundary Detection)

٣- نمو المناطق (Region Growing)

٤- شطر ودمج المناطق (Region Splitting and Merging)

٥- تقنيات العنقدة (Clustering – Techniques)

٢-٧-١ تقنيات العنقدة (Clustering – Techniques)

تعد العنقدة واحده من التقنيات البسيطة والمستعملة بصورة وأسعه في مجال تجزئء الصور [٢٩]، حيث يرجع استعمالها إلى الستينات وتقوم هذه التقنية بتجميع عناصر الصورة في مناطق معينه.

وقبل الدخول في كيفية استخدام هذه التقنية في عملية التجزئء، سيتم تسليط الضوء على بعض المفاهيم الخاصة بالعنقدة.

في البداية تعرف العنقدة على أنها طريقة تصنيف غير موجهه (unsupervised classification) هدفها تقسيم مجموعة من الأنماط التي تدعى متجهات الصفات (Feature vectors) إلى عدد محدد من المجاميع الجزئية تدعى عناقيد (cluster). وعليه إذا كانت لدينا المجموعة $Q = \{X^{(i)} | i=1,2,\dots,N\}$ بحيث أن $X^{(i)} = X_1^i, X_2^i, \dots, X_K^i$ فإن العنقدة تقوم بتقسيم هذه المجموعة إلى M من المجاميع الجزئية $\pi = \{C_1, C_2, \dots, C_M\}$ والتي تمتلك الخواص الآتية [٣٠].

(أ) $C_i \neq \Phi$ لكل $i=1,2,\dots,M$

(ب) $\Phi = C_i \cap C_j$ لكل $i \neq j$

$$Q = \bigcup_{i=1}^M C_i \quad (ج)$$

بصورة عامة، تتضمن مهمة العنقدة العناصر الآتية [٢٧]:

١- **تمثيل الأنماط (Pattern Representation)**: يشير تمثيل الأنماط إلى تحديد

عدد العناقيد، عدد المتجهات المتوفرة إضافة إلى عدد الصفات في متجه الصفات .

٢- **انتقاء الصفات (Feature Selection)**: يدل هذا العنصر على تعريف مجموعه

جزئية من الصفات لاستعمالها في عملية العنقدة و بالنسبة للصور يمكن أن تأخذ هذه

الصفات قيمة مثل المستوى الرمادي، مقدار الميل (Gradient Magnitude)، طور الميل

(Gradient Phase) إضافة إلى اللون (color) و/ أو صفات أخرى [١٨].

٣- **المستخلص البياني (Data Abstraction)**: يقصد بالمستخلص هنا عملية إيجاد

تمثيل بسيط للمجاميع العنقودية، حيث يوجد عدد من التمثيلات أكثرها شيوعا تلك التي تقوم

بتمثيل العنقود من خلال مركزه فمثلا إذا كان لدينا العنقود C_i الذي يتكون من S_i من

المتجهات، فيمكن بعد ذلك حساب مركز ذلك العنقود كالآتي [٣٠]:

$$Z^{(i)} = \frac{\sum_{X \in C_i} X}{S_i} \quad (1.2)$$

٤- **مقياس التنسيب (Assignment measure)**: الذي يدل على كيفية ضم متجهات

الصفات بالصفات المختارة إلى احد العناقيد المتوفرة ويوجد نوعان من المقاييس هما [١]:

أ. **مقاييس التباعد distance measures**: ان الشكل الأبسط والأكثر شيوعا لهذا

النوع من المقاييس هو مسافة اقليدس (Euclidean Distance) التي تعكس مقدار الاختلاف

بين متجهين، فمثلا إذا كان $X^{(i)}, X^{(j)}$ متجهين في فراغ متكون من k من الأبعاد فان مسافة

اقليدس بينهما تحسب كالآتي:

$$d(X^{(i)}, X^{(j)}) = \sqrt{\sum_{k=1}^K (X_k^{(i)} - X_k^{(j)})^2} \quad (2.2)$$

$X_k^{(i)}$: الصفة k للمتجه i

$X_k^{(j)}$: الصفة k للمتجه j

تعطي القيمة الكبيرة لهذه المسافة مؤشرا على وجود اختلاف كبير بين المتجهين أما

القيمة الصغيرة فتدل على وجود تشابه كبير بينهما.

يمكن أن يواجه هذا المقياس مشكله عندما تكون مديات قيم متجه الصفات مختلفا ولذلك يحتاج إلى تقييس (Normalization) لمديات هذه القيم وجعلها تقع ضمن الفترة [0, 1] وحسب العلاقة الآتية:

$$d(X^{(I)}, X^{(J)}) = \sqrt{\sum_{K=1}^K \frac{(X_K^{(I)} - X_K^{(J)})^2}{r_K^2}} \quad (3.2)$$

r_k مدى قيم الصفة K في متجه الصفات.

ب. مقاييس التشابه (Similarity Measures): من الهيئات الشائعة لهذا النوع هي الضرب الداخلي للمتجه (Vector inner product). حيث يتم تنسيب متجه الصفات إلى العنقود الذي يمتلك مع مركزه قيمه أكبر نسبه لعملية الضرب المتجهي كالاتي:

$$\sum_{K=1}^K X_K^{(I)} \cdot X_K^{(J)} = (X_1^{(I)} \cdot X_1^{(J)} + X_2^{(I)} \cdot X_2^{(J)} + \dots + X_K^{(I)} \cdot X_K^{(J)}) \quad (4.2)$$

كذلك يمكن تقسيم مديات قيم متجه الصفات لهذا المقياس كالاتي:

$$\sum_{K=1}^K \frac{X_K^{(I)} \cdot X_K^{(J)}}{r_K^2} = \left(\frac{X_1^{(I)} \cdot X_1^{(J)}}{r_1^2} + \frac{X_2^{(I)} \cdot X_2^{(J)}}{r_2^2} + \dots + \frac{X_K^{(I)} \cdot X_K^{(J)}}{r_K^2} \right) \quad (5.2)$$

بعد توضيح هذه المفاهيم، يمكن صياغة مسألة التجزيء كمسألة عنقدة، حيث يتم تحويل الصورة من المجال الحيزي (spatial domain) إلى فضاء الصفات (feature space) وبذلك يصبح كل عنصر في الصورة ممثلا من خلال متجه صفات معين في ذلك الفراغ. وعليه تصبح مسألة التجزيء عبارة عن مسألة إيجاد العناقيد في هذا الفضاء، حيث يمثل كل عنقود كيانا ما في الصورة. وبعد إيجاد تلك العناقيد رجوعا إلى المجال الحيزي للصورة [31][32].

بصورة عامه، يعتمد نجاح استخدام العنقدة في تجزيء الصور بصورة كبيره على انتقاء الصفات المناسبة، حيث ان العناقيد الغير مكتشفه في فضاء ما قد يكون من السهل اكتشافها في فضاء آخر [18].

توجد العديد من التقنيات المستخدمة لحل مسألة العنقدة، وفيما يأتي أكثر الطرق شيوعا

فيها:

٢-٧-١-١ تقنية الأوساط المتعددة K_Means

وهي واحدة من التقنيات البسيطة والشائعة التي تم اقتراحها من قبل العالم McQueen

عام ١٩٦٧ حيث استخدم في هذه التقنية مربعات الخطأ (Squared Errors) معيارا لتوجيه

تقاربها [٢٧]. يرجع شيوع هذه الطريقة إلى سهولة تنفيذها وإلى تعقيداتها البسيطة من حيث الوقت.

تهدف هذه التقنية إلى تصغير (minimizing) مجموع المسافات المربعة بين المتجهات التابعة لعنقود ومركزه. ويمكن تلخيص خطوات عمل هذه التقنية كالآتي [٣٣][٣٣]:

١- اختيار M من العناقيد العشوائية $Z^{(1)}(1), Z^{(2)}(1), \dots, Z^{(M)}(1)$.

٢- تنسيب متجهات الواصفات في الخطوة t إلى M من العناقيد باستعمال العلاقة الآتية:

$$d(X, Z^{(j)}(t)) < d(X, Z^{(l)}(t)) \quad \text{IF } X \in C_j(t) \quad (6.2)$$

لكل $J \neq I, I=1, 2, \dots, M$

$C_j(t)$: عنقود مركزه $Z^{(j)}(t)$

٣- حساب مراكز عناقيد جديدة $Z^{(j)}(t+1)$ لكل $J=1, 2, \dots, M$ بحيث تصغر المسافة المربعة لكل المتجهات في العنقود $C_j(t)$ بالنسبة لمركز العنقود الجديد، وببساطه فإن متوسط المتجهات التابعة للعنقود $C_j(t)$ هو المقياس الذي يقوم بالتصغير، وعليه يمكن حساب مركز العنقود الجديد كالآتي:

$$Z^{(j)}(t+1) = \frac{1}{S_j} \sum_{X \in C_j(t)} X, \quad J=1, 2, \dots, M \quad (7.2)$$

S_j : عدد المتجهات التابعة للعنقود $C_j(t)$

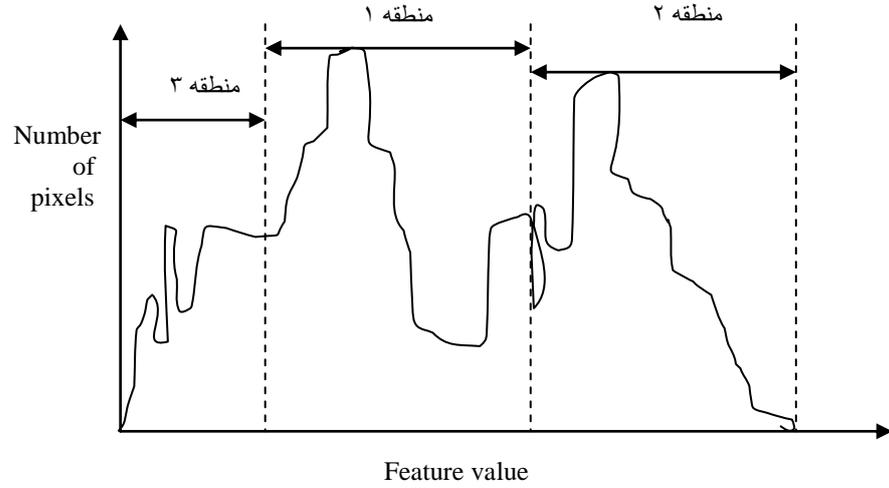
٤- إذا كان $Z^{(j)}(t+1) = Z^{(j)}(t)$

لكل $J=1, 2, \dots, M$ ، فهذا يعني تقارب الخوارزمية، حيث يتم التوقف وبخلافه يتم الذهاب إلى الخطوة (٢).

من المشاكل التي تواجه هذه التقنية هي حساسيتها لاختيار مراكز العناقيد الابتدائية حيث يعتمد نوع الحل الذي نحصل عليه على مراكز العناقيد الابتدائية المختارة ونتيجة لذلك تعاني هذه التقنية من مشكلة النهاية الصغرى المحلية (Local minima).

٢-١-٧-٢ تقنية شطر المناطق التداخلي (Recursive Region Splitting)

أصبحت هذه التقنية طريقه قياسية لانجاز مهمة العنقدة، حيث تستعمل هذه التقنية طريقة عتبه المدرج التكراري لتجزئ الصور وكما موضح في الشكل (٢-٤) الآتي:



شكل رقم (٢-٤): إيجاد قمة المدرج التكراري

وفيما يأتي تلخيصاً للخطوات التي تتبعها هذه التقنية [١]:

١- اعتبار الصورة منطقة واحدة ومن ثم حساب المدرج التكراري لكل عنصر من عناصر متجه الوصفات.

٢- تطبيق اختبار إيجاد القمة (peak) لكل مدرج تكراري وبعد ذلك اختيار القمة الأفضل واعتبار القيم الواقعة على جانبي القمة كقيم للعتبات ومن ثم تجزئ الصورة إلى منطقتين بالاعتماد على هذه القمة.

٣- تنعيم (Smoothing) الصورة الثنائية الناتجة من العتبية.

٤- يتم تكرار الخطوات ١-٣ لكل منطقة حتى لا يكون بالإمكان توليد مناطق جزئية جديدة وهذا يعني عدم احتواء المدرج التكراري على قمم بارزه.

تعاني هذه الطريقة من مشكلة تحديد اختبار إيجاد القمة المناسبة بالإضافة إلى تحديد قيم العتبات.

بصورة عامة تعاني طرق التجزئ المعتمدة على استخدام تقنيات العنقدة من مشاكل تحديد عدد عناقيد الصورة المرغوبة أضافه إلى أن الوصفات تعتمد على الصورة ولا توجد طريقه عامه لتعريف الوصفات المرغوبة للحصول على نتائج تجزئ جيده [٣١].

٢-٧-٢ تقييم أداء تقنيات التجزئ

يعد تقييم الأداء عاملاً أساسياً في توفير مسار تغذية عكسي يستطيع من خلاله النظام تعديل سياسته خلال المعالجة. فمثلاً يمكن للأنظمة ذات الأهداف المعروفة جيداً إيجاد معاملات

الأداء والتي تقيس المسافة بين نقطة الهدف والنقطة التي توصل إليها النظام، بعد ذلك يمكن استخدام تلك المعاملات لأتباع المسار الأمثل باتجاه ذلك الهدف. ولسوء الحظ لا تقع أنظمة تجزيء الصور ضمن هذا الصنف من الأنظمة، على الأقل ليس في مستوى أدنى من المعالجة حيث يمكن فقط تعريف الهدف بصورة دقيقة في مستوى أعلى [٣٤] .

يعتمد أداء تقنيات التجزيء على مدى واسع من العوامل التي تتضمن نوعية الصورة التي يتم معالجتها، وحاجات التطبيق الذي يستعمل المناطق والحواف الناتجة، إضافة إلى ذلك قد تكون السرعة عاملاً مهماً في تطبيقات الوقت الحقيقي (real-time application) لهذا السبب من المهم تقييم أداء عدة تقنيات لإيجاد التقنية المثلى لتطبيق ما [٣٥]. تتميز تجارب تقييم الأداء الجيدة بما يأتي [٣٦] .

١- مقارنة التقنية الحالية مع عدد من تقنيات التجزيء الشائعة.

٢- تقييم كل تقنية باستعمال العديد من الصور ومن مختلف التطبيقات ودرجات تعقيد مختلفة أيضاً.

٣- استعمال مقاييس تقييم عديدة لأجل المقارنة.

يعد الفحص المرئي من قبل البشر الطريقة الأبسط لتقييم الأداء . أضافه إلى ذلك يمكن مكنة عملية تقييم تقنية ما إذا كان هناك مناطق كيانات و/ أو حدود كيانات معروفة، حيث أن إحدى الطرق للحصول على مثل هذه المعلومات هي توليد صورة اصطناعية (Synthetic image) حيث تكون كيانات الصورة معروفة مسبقاً [٣٥] .

يوجد بالإضافة إلى المقياس السابق عدد من المقاييس الإحصائية التي يمكن تقسيمها إلى صنفين هما المخالفة التجريبية (Empirical discrepancy) والجودة التجريبية (Empirical goodness) [٣٦] .

أ- المخالفة التجريبية

تعتمد مقاييس هذا الصنف على استخدام صورة مرجعية مجزأة يدوياً ومن ثم مقارنة الصورة الناتجة من تطبيق تقنية التجزيء مع هذه الصور المرجعية. إن إحدى الطرق للقيام بهذا التقييم تتم بمقارنة تجزيئين للصورة، حيث أن احد هذين الجزئين منتج من قبل المستعمل ويمثل إلى كيانات الصورة المراد اختبارها. بعد ذلك يتم استعمال مقياس التباعد (distance measure) ثنائي البعد لقياس الاختلاف بين الاثنين، وبذلك يوفر تخميناً لخطأ التجزيء المنتج من قبل تقنية التجزيء نسبة إلى التجزيء المجهز من قبل المستعمل [٣٤] .

ب- الجودة التجريبية

تعتمد عملية تقييم هذا الصنف على مقياس بديهي للجودة ،مثلا انتظام الشدة اللونية ضمن المناطق المجزأة أو التضاد اللوني للشدة اللونية بين مناطق الصورة المختلفة،حيث يوجد مقياسان للأداء هما [٣٦]:

أ- انتظام المناطق (Region Uniformity)

ب- التضاد اللوني للمناطق (Region contrast)

٣-٧-٢ الخوارزميات الجينية (Genetic Algorithm)

تعاني اغلب الطرق المستخدمة التقليدية لحل مسألة الأمثلية (Optimization problem) من عدد من المشاكل والصعوبات وخاصة عند استعمالها لحل المسائل المعقدة. وفيما يأتي بعض المشاكل التي تعاني منها هذه الطرق [٣٧]:

- يعتمد التقارب إلى الحل المثالي على الحل الابتدائي المختار .
- ميول اغلب هذه الطرق إلى أمثليه محليه (Local optima) .
- عدم كفاءة الطرق التقليدية في التعامل مع المسائل ذات المتغيرات المتقطعة (discrete variables) .

لقد تم استخدام الخوارزميات الجينية لحل اغلب المسائل المعقدة وفي مجالات عديدة ،حيث تبدأ هذه الخوارزميات بمجتمع عشوائي يمثل مجموعة الحلول الممكنة،كل حل يمثل فردا ويتكون من مجموعة من الجينات تسمى كروموسوم وتخصص له صلاحية (fitness) معينه ترتبط مباشرة بدالة الهدف للمسألة المعينة،بعد ذلك يتم تعديل هذا المجتمع وتوليد مجتمع آخر جديد من خلال تطبيق مجموعه من العوامل الجينية (Genetic Operators) منها الانتقاء (Selection) والتزاوج (Crossover) والطفرة (Mutation) وغيرها بصورة متكررة وبالتتابع على أجيال هذا المجتمع لحين تحقق شرط التوقف [٣٧] .

تمتاز الخوارزميات الجينية بالإضافة إلى حلها لأغلب المشاكل والصعوبات المذكورة سابقا والتي تعاني منها الطرق التقليدية بالخصائص الآتية [٣٨]:

- تعمل على شفره المعاملات (parameters) التي تمثل متغيرات القرار للمسألة وليس على المعاملات نفسها.
- تبحث انطلاقا من مجموعة نقاط في فضاء البحث (search space) وليس من نقطه واحده كما هو الحال بالنسبة للطرق التقليدية.
- تستعمل معلومات دالة الهدف وليس مشتقاتها أو أي معرفه أخرى .

- تستعمل قواعد انتقالات احتمالية (probabilistic) وليس قواعد محددة (deterministic).

٢-٧-٣-١ خوارزمية Breeder الجينية (BGAs)

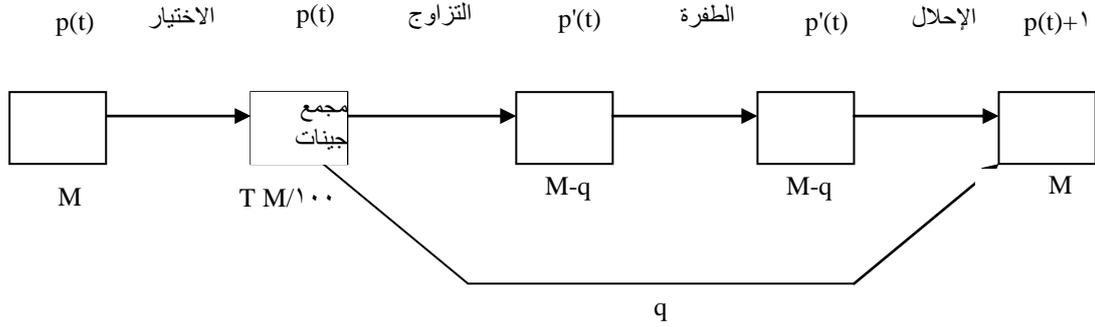
صممت خوارزمية Breeder الجينية من قبل Heinz Muhlenbei الألماني في بداية التسعينيات فهي تقع ما بين الخوارزميات الجينية GAS والإستراتيجيات التطورية ESSs حيث أنها تستعير من كل واحد منها بعض الأفكار، فهي تشبه ESSs في إنها تعالج المتغيرات الحقيقية مباشرة ومعاملات التزاوج لا تختلف كثيرا عنها في ESSs [٣٩][٤٠]. أن BGAs لا تشبه GAS في أنها تستعمل التمثيل المباشر حيث إن الجين هو متغير القرار (أي لا توجد فرصه للتشفير)، كذلك في GAS الانتقاء يكون عشوائي والملائمة تعتمد على فكرة دارون في التطور أما في BGAs فان الانتقاء يسمى انتقاء القطع truncation selection .

تعتمد BGAs كما في GAS على التزاوج والطفرة التي تعد مهمة ولكن كمعامل إرجاع خلفي يهتم بإعادة إنتاج بعض الأفراد على المستوى الجيني allele. هذه النظرة صحيحة في GAS بسبب طريقة التشفير المستخدمة في تمثيل الكرموسوم لكن في حالة GAS والتي تستخدم التمثيل الحقيقي للقيم على مستوى الجين فان الطفرة ستظهر بدور مزدوج فهي قناة جيدة (في حالة الطفرات القليلة جدا) وقوة اكتشاف رئيسه في الحالة المخففة [٤١].

• الانتقاء

تختلف BGAs عن الخوارزمية الجينية GAS، في أنها تعتمد على نموذج مشتق من ميكانيكية توليدية، حيث أن العناصر الأفضل ستضاف إلى المجتمع الجديد (النخبة) ودورة الحياة مستمرة ونموذج الانتقاء هو (موديل القطع) وفيه يتم البدء من مجتمع ذو P من الأفراد، و فقط T% من العناصر والتي لها أفضل دالة صلاحية يتم اختيارها لتعطي الأساس لأفراد الجيل الجديد. والحد T يدعى العتبة، بعد أن يتم انتقاء $T \times \frac{P}{100}$ فرد سيتم اختيار عنصرين من بينهم عشوائيا وباحتماليه متساوية لتوليد عنصر جديد وهذا سيكرر إلى P-١ مره. لذلك فان نموذج الانتقاء يكون محددًا أو مقتصرًا على مجموعة محددة [٤٢][٤٠]، حيث يتم اختيار العنصر الأفضل وإهمال الأسوأ كما في الشكل (٢-٥) [٤١].

ولو أخذنا المعاملات بنظر الاعتبار فإن هناك فرصه كبيره لعملية التزاوج والطفرة.



شكل رقم (٥-٢): هيكل عمل خوارزمية Breeder الجينية

• التزاوج

إذا أعطي الأبوين $\bar{x} = (x_1, \dots, x_N)$ و $\bar{y} = (y_1, \dots, y_N)$ فإن كل عنصر من الطفل $\bar{z} = (z_1, \dots, z_N)$ يمكن أن يتم الحصول عليه بواسطة التزاوج بعدة طرق وكالاتي [١٥]

١. التزاوج المنفصل (DR) Discrete Recombination

$$z_i = x_i \vee y_i \quad (8.2)$$

وباحتمالية اختيار عشوائية متساوية أي ٥٠% لكل واحد.

٢. التزاوج الخطي الموسع (ELR) Extended Line Recombination

$$z_i = x_i + \alpha_i (y_i - x_i) \quad 1 \leq i \leq N \quad \alpha_i = 1, 2, \dots, N \quad (9.2)$$

α يتم اختيارها بشكل عشوائي ومنتظم في الفترة $[-d, 1.0 + d]$ عندما d حد BGA

٣. التزاوج الوسيط الموسع (EIR) Extended Intermediate Recombination

$$z_i = x_i + \alpha_i (y_i - x_i) \quad 1 \leq i \leq N \quad \alpha_i = 1, 2, \dots, N \quad (10.2)$$

α_i يتم اختيارها بشكل عشوائي ومنتظم في الفترة $[-d, 1.0 + d]$ حيث يتم اختيار α_i جديدة لكل i

٤. التزاوج المضبب (FR) Fuzzy Recombination

تعتمد على فكره مستعارة من النظرية المضببة fuzzy theory . حيث يتم استبدال دالة التوزيع الاحتمالي pdf (probability distribution function) بدالة توزيع هرميه (bimodal distribution) حيث الاحتمالية لامتلاك الطفل z_i القيمة معطاة كالاتي:-

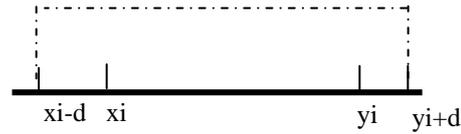
$$p(z_i) \in \{\phi(x_i), \phi(y_i)\} \quad (11.2)$$

العنوان مضبب جاء من حقيقة أن الجزأين $\phi(x_i)$ و $\phi(y_i)$ من التوزيع الاحتمالي تأخذ أرقام مضببة (مثلثية في الهيئة الاعتيادية) [٤١] وفي التوزيعات الاحتمالية المثلثية $\phi(r)$ لها القيم x_i و y_i وتحقق الشروط الآتية:

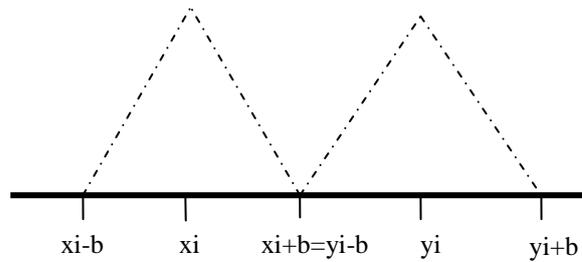
$$x_i - d \cdot |y_i - x_i| \leq r \leq x_i + d \cdot |y_i - x_i| \quad (12.2)$$

$$y_i - d \cdot |y_i - x_i| \leq r \leq y_i + d \cdot |y_i - x_i| \quad (13.2)$$

لكل $x_i \leq y_i$ و $d \geq 0.5$ ، أفضل قيم الأطفال القريبة من الآباء وهذا موضح في الشكل (٦-٢) [٤١][٤٠] .



(أ)



(ب)

شكل رقم (٦-٢): التوزيع الاحتمالي لـ z_i (أ) التزاوج الوسطي الموسع (ب) التزاوج المضبب

• الطفرة

إن BGAs تقدم نوعين أساسيين من الطفرة [٤٠]

١. الطفرة المنفصلة Discrete Mutation (DM) وتكون صيغتها كالاتي:

$$z'_i = z_i \pm search\ int\ erval.\ const. \sum_{j=0}^{k-1} \gamma_j . 2^{-j} \quad (14.2)$$

k يمثل حد يتعلق بدقة الماكينة المستعملة ويكون ثابت constant ويمكن أن يمثل عدد البتات المستخدمة لتمثيل المتغير الحقيقي في الماكينة التي نعمل عليها.

Const منتصف قيمة المدى الذي يقع فيه Z_i

$$\gamma_i \text{ تساوي } 0 \text{ قبل الطفرة وبعدها تطفّر إلى } 1 \text{ مع احتمالية } \frac{1}{k}$$

وكذلك يمكن أن تكون الصيغة كالآتي:

$$z'_i = z_i \pm search\ int\ erval.\ const. . 2^{-j} \quad 0 \leq j \leq k - 1 \quad (15.2)$$

٢. الطفرة المستمرة (CM) Continuous Mutation وتأخذ الصيغة الآتية:

$$z'_i = z_i \pm search\ int\ erval.\ const. . 2^{-\beta k} \quad (16.2)$$

β قيمة حقيقية يتم اختيارها عشوائياً في الفترة $[0.0, 1.0]$ ، k ثابت كما تم ذكره سابقاً.

٨-٢ تمثيل ووصف البيانات representation and description [٤٣]

يقدم كل عنصر في الطبيعة مجموعة من الصفات التي تضعه في صنف خاص به لتمييزه عن عناصر الأصناف الأخرى. لتبقى عملية تحديد تلك الصفات واستخلاصها الخطوة الأولى التي تجري من قبل الإنسان أو الآلة قبل البدء بعملية التمييز.

إن عملية استخلاص الصفات هي عملية معقدة للغاية لذلك يجب إجراء عملية تحليل لتلك الصفات وتقسيمها حسب أهميتها للتطبيق الحالي للحصول على المجموعة التي تحقق الكفاءة المطلوبة. لقد تم تقسيم الصفات إلى ثلاثة أنواع هي [٢٤]:

١- الصفات الفيزيائية physical features

٢- الصفات التركيبية structural features

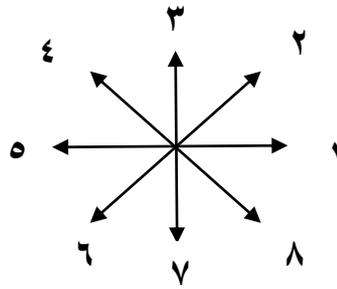
٣- الصفات الرياضية mathematical features

تلعب الصفات الفيزيائية والتركيبية دوراً مهماً في عملية التمييز لدى الإنسان وذلك بسبب سهولة التعرف على مثل هذه الصفات وسهولة تعلم النظام الحسي البشري لهذا النوع من الصفات، إلا إن دورها يبدأ بالاضمحلال عند محاولة استخدام هذه الصفات في عمليات

التمييز الآلية بسبب صعوبة تمثيلها. من الناحية الأخرى فإن الآلة تستخدم الصفات الرياضية بكفاءة، الأمر الذي يصعب على الإنسان تحقيقه بدون مساعدة آلية. ترتبط الصفات الفيزيائية والتركيبية في أنظمة التمييز الآلية بصورة خاصة مع حقل المعالجة الصورية، وتتحدد بصورة مباشرة بالمشكلة المراد حلها مما يتطلب استحداث وتطوير خوارزميات خاصة بتلك المشكلة لمعالجة الصفات. لذلك لا توجد خطوط عامه تستند عليها عملية اختيار مجموعه معينه من هذه الصفات دون غيرها. في حين تعد عمومية الخصائص الرياضية في مداها إحدى الميزات التي ترجحها على النوعين الآخرين (الفيزيائية والتركيبية). تهدف جميع البحوث التي وضعت في حقل تحليل الصور إلى استخلاص المعلومات المهمة لحل المشاكل المتعلقة بالتطبيقات المتعددة. ويتم هذا باستخدام خوارزميات ذكية تقوم بتقليص بيانات الصورة إلى تلك المهمة فقط. وبذلك يتم نقل الصورة من مستوى التمثيل الأول البسيط وهي عناصر الصورة (pixels) إلى مستوى تمثيل أعلى الصفات (features). وهناك طرق عديدة لاستخلاص الصفات منها:

١-٨-٢ طريقة توقيع الكفافات contour signature feature

يعرف توقيع الكفافات بأنه تمثيل دالي ذو بعد واحد لحدود الصورة ذات البعدين ليعطي وصفا للشكل العام لحدود الصورة ويتم استخلاص التوقيع بعدة طرق [٥], [٤٤] منها حساب المسافة بين نقاط الحدود ونقطة المركز لتلك الحدود كدالة لزاوية الحركة عند تتبع النقاط. تقسم الصورة إلى ثمان مناطق وتتبع الحدود بعكس عقرب الساعة لتكوين متجه الصفات وكما موضح في الشكل ((٧-٢) الآتي:



شكل رقم (٧-٢): اتجاه سير خوارزمية توقيع الكفافات

ويتم حساب المسافة عن طريق المعادلة الآتية:

$$dis[i] = \sqrt{(centroidx - row)^2 + (centroidy - col)^2} \quad (17.2)$$

٢-٨-٢ المدرج التكراري Histogram [١]

المدرج التكراري للصورة يمثل التوزيع الاحتمالي للمستوى الرمادي. حيث تزودنا بمعلومات حول خصائص توزيع المستوى الرمادي للصورة وتعرف الاحتمالية كالآتي:

$$p(g) = \frac{N(g)}{M} \quad (18.2)$$

حيث

$P(g)$ التوزيع الاحتمالي للمستوى الرمادي

M عدد العناصر pixels في الصورة

$N(g)$ عدد عناصر المستوى الرمادي

أما الصفات التي تؤخذ من المدرج التكراري الأحصائية فهي:-

١- المتوسط الحسابي Mean

هو معدل قيمه يدل على مدى إضاءة الصورة فالصورة ذات القيمة العالية للمتوسط الحسابي يدل على صورة عالية الإضاءة

$$\bar{g} = \sum_{g=0}^{l-1} g \cdot p(g) \quad (19.2)$$

g المستوى الرمادي

L العدد الكلي للمستوى الرمادي

$p(g)$ الاحتمالية للمستوى الرمادي

٢- الانحراف المعياري standard deviation

ويمثل الجذر التربيعي للتباين ليصف التضاد اللوني والذي يصف توزيع البيانات، لذلك الصورة ذات التضاد اللوني العالي ذات تباين عالي وبالعكس وكالآتي

$$\sigma_g = \sqrt{\sum_{g=0}^{l-1} (g - \bar{g})^2 p(g)} \quad (20.2)$$

٣- الالتواء skewness

هو مقياس للالتواء حول المتوسط الحسابي في توزيعات المستوى الرمادي

$$Skew = \frac{1}{\sigma_g^3} \sum_{g=0}^{l-1} (g - \bar{g})^3 p(g) \quad (21.2)$$

٤- الطاقة energy

٥- يدل على كيفية توزيع المستوى الرمادي

$$energy = \sum_{g=0}^{l-1} [p(g)]^2 \quad (22.2)$$

أعلى قيمه لهذا المقياس هو واحد للصور ذات القيمة اللونية الواحدة وتتناقص كلما قيم العناصر تتوزع أكثر في المستوى الرمادي، لأن قيمة $p(g)$ دائما اقل من واحد.

٥- الإنتروپيا entropy

يمثل عدد البتات المطلوبة لتشفير بيانات الصورة

$$Entropy = - \sum_{g=0}^{l-1} p(g) \log_2 [p(g)] \quad (23.2)$$

كلما قيم العناصر في الصورة تتوزع أكثر في المستوى الرمادي فأن مقياس الإنتروپيا يزداد.

٢-٩ تمييز الأنماط باستخدام الشبكات العصبية [٤٥]

لقد انصب اهتمام الباحثين في مجال تمييز الأنماط في الستينيات والسبعينيات على تحسن كل من عملية التقارب لخوارزمية المصنف ومعدلات الخطأ المسموح بها. إلا أن جميع البحوث في تلك الفترة قد أهملت جوانب عملية مهمة وهي إمكانية تطبيق هذه المصنفات على المشاكل الحقيقية (Real -World Problems) مثل مشكلة الكلام (Speech)، الإبصار (Vision) والإنسان الآلي (Robot)، حيث تكون الاستجابة المباشرة لبيانات معقدة مطلوبة.

فجاء الاهتمام ببناء الشبكات العصبية الاصطناعية لإضافة قابلية التعلم إلى تطبيقات الذكاء الاصطناعي [٤٦]، [٤٧] فقد بدأ جيل من المصنفات يعرف بمصنفات الشبكات العصبية اللامعلمية (Non-Parametric Neural Net Classifiers)، والتي خطت خطوه واسعة في حقل تمييز الأنماط، حيث قامت بتقليل معدلات الخطأ مقارنة مع المصنفات التقليدية، بالإضافة إلى سهولة استخدامها في تطبيقات المشاكل الحقيقية وقدرتها على التعميم وتحقيق الموازنة بين متطلبات الذاكرة والقوة الإحتسابية ووقت التدريب.

وتعد شبكة Neo-cognitron من الشبكات التي تستغرق وقتا قليلا نسبيا في التدريب

ولها قوة احتسابيه عاليه.

٢-٩-١ نبذة تاريخيه عن شبكة Neo-cognitron [٤٨]

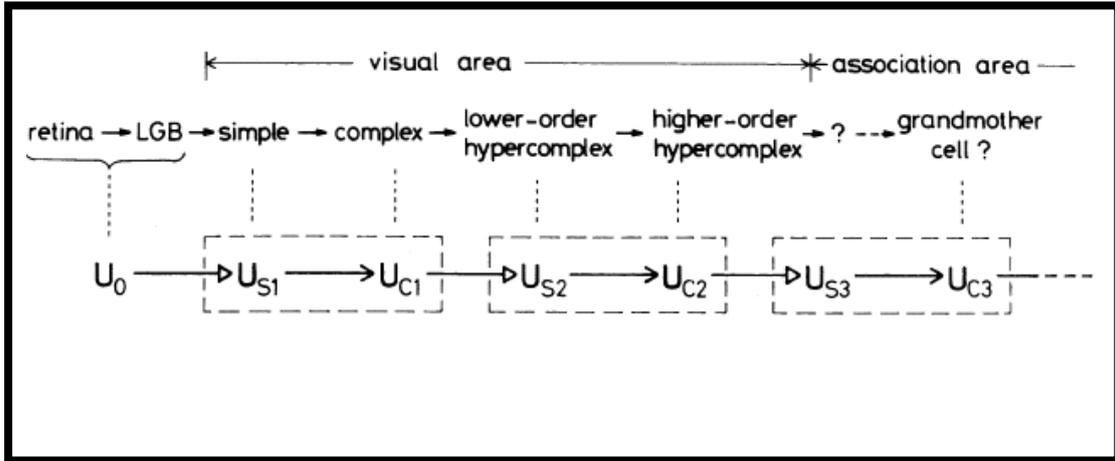
ميكانكية تمييز الأنماط في العقل البشري غير معروفه، فهي كما تبدو تعتمد على الخبرة البشرية، لذلك تم إتباع طرق مختلفة لحل هذه المشكلة، فإذا أخذنا الشبكات العصبية كطريقة لتمييز الأنماط كما في العقل البشري فستعطينا نتيجة جيدة لفهم ميكانكية عمل الأعصاب في العقل البشري. لقد ظهرت طرق عديدة للشبكات العصبية تهتم بهذا المجال منها (Rosenblatt ١٩٦٢, Kabrisky ١٩٦٦, Giebel ١٩٧١, Fukushima ١٩٧٥) الاستجابة لأكثر هذه الطرق كانت تتأثر بالترحيف في الموقع وكذلك التشويه في الشكل للنمط المدخل. كذلك قابليتها لتمييز الأنماط ليست عالية جدا. أما الشبكة قيد البحث (شبكة Neo-cognitron) فهي شبكة عصبية ذات تنظيم ذاتي حيث تتعلم بدون معلم، وتكتسب القابلية لتمييز الأنماط اعتمادا على التشابه في الشكل العام (الجغرافي) للأشكال بدون أن تتأثر بالموقع ولا التشويه في الأشكال وهذه الشبكة أعطيت اسما (niek أي ثلمه) لأنها كانت امتدادا لنموذج شبكة cognitron متعددة الطبقات ذات التنظيم الذاتي أيضا الموضوعه من قبل الباحث Fukushima ١٩٧٥ فالطريقة القديمة cognitron أيضا لها القابلية على تمييز الأنماط لكن استجابتها تعتمد على مواقع الأنماط بحيث النمط نفسه إذا جاء في مواقع مختلفة سيتعرف عليه كأنماط مختلفة بينما الطريقة الجديدة لا تتأثر بمواقع الأنماط المدخلة حيث أنها متعددة الطبقات أيضا ، وهي أيضا لها القابلية على التعلم بدون مشرف أو معلم ، حيث أنها تحتاج فقط إلى إحضار مجموعة أنماط الإدخال تكراريا إلى طبقة الإدخال وبعد إكمال التنظيم الذاتي فإن الشبكة تكتسب هيكلها كما في النموذج الهرمي لنظام الرؤيا العصبي الموضوع من قبل [wiesel, hubel ١٩٦٢, ١٩٦٥]

وفقا للنموذج الهرمي المذكور. الشبكة العصبية لها هيكل هرمي LGB

(lateral geniculate body) خلايا بسيطة خلايا معقدة خلايا أكثر تعقيد ذات أوامر اقل خلايا أكثر تعقيد ذات أوامر أعلى ، كذلك تقترض أن الشبكة العصبية بين الخلايا الأكثر تعقيد ذات أوامر الأقل والخلايا الأكثر تعقيد ذات أوامر الأعلى تمتلك هيكل يشبه الشبكة بين الخلايا البسيطة والخلايا المعقدة والخلايا في المراحل الأعلى بصورة عامة تميل للاستجابة اختياريا للصفات الأكثر تعقيدا في النمط المدخل وأكثر حساسية للتغير في موقع النمط المدخل.

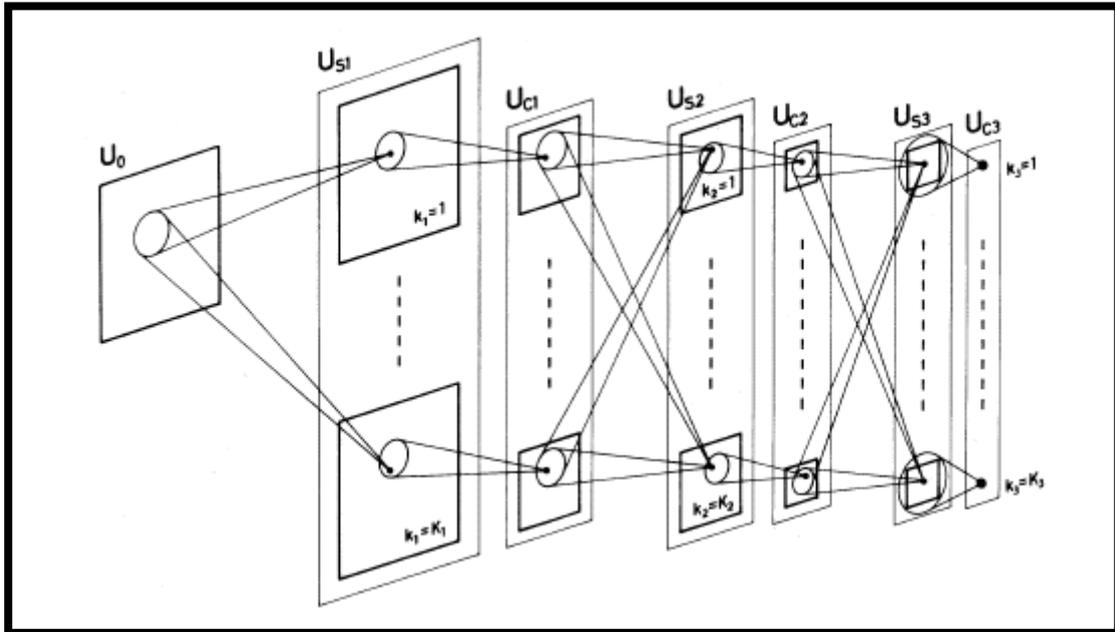
Hubel and wised لم تجربنا أي نوع من الخلايا موجودة في المراحل الأعلى من خلايا الأكثر تعقيدا.

وشبكة Neo-cognitron تعد امتدادا للهيكل الهرمي. فبعد الانتهاء من التنظيم الذاتي، استجابة الخلايا في الطبقات الأعمق تعتمد على النمط فقط ولا تتأثر بموقع وجود النمط. العلاقة بين النموذج الهرمي وهيكل شبكة Neo-cognitron موضحة في الشكل رقم (٢-٨) الآتي:



٢-٩- الهيكل العام للشبكة [٥٠]

الهيكل العام للشبكة موضح في الشكل رقم (٢-٩).

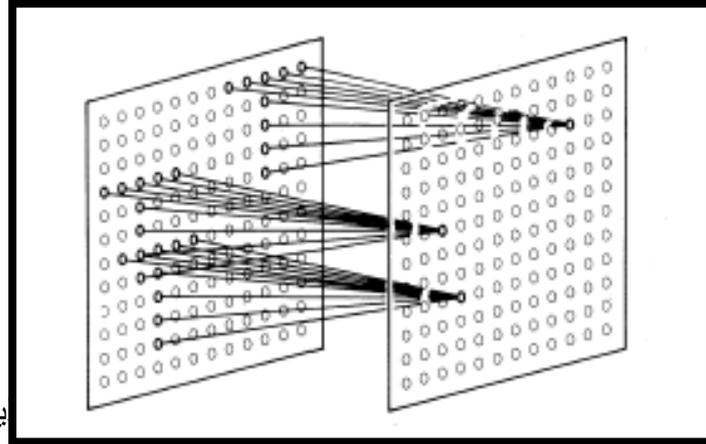


شكل رقم (١-٢): الهيكل العام لسبكة Neo-cognitron العصبية

كل مستطيل يمثل مصفوفة ذات بعدين من الخلايا. المرحلة الأوطأ(الأولى) من الشبكة هي طبقة الإدخال التي تتكون من مصفوفة ذات بعدين من الخلايا المستلمة و كل مرحلة فيها طبقة

تتكون من خلايا تدعى خلايا S متبوعة بطبقة أخرى من الخلايا تدعى خلايا C وفي كل الشبكة طبقات خلايا S وطبقات خلايا C تترتب بشكل متتالي، خلايا S هي خلايا استخلاص الصفات ، أما خلايا C فقد وضعت لتسمح بأخطاء موقعيه في الصفات وطبقة خلايا C في المرحلة الأعلى هي طبقة تمييز حيث تمثل النتيجة النهائية لتمييز الأنماط في الشبكة.

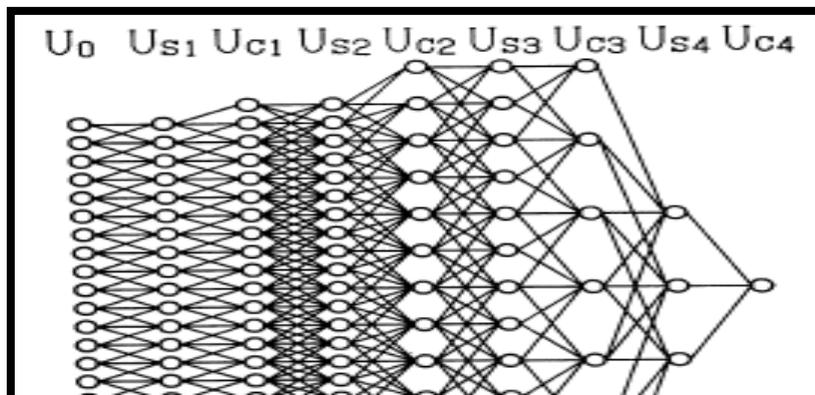
تستخدم للإشارة إلى طبقات خلايا S وطبقات خلايا C في المرحلة i على التوالي U_{S_i}, U_{C_i} طبقة الإدخال يشار إليها بـ U_0 كل طبقة من خلايا S وخلايا C تقسم إلى مجاميع جزئية تسمى مستو خلية وفقا للصفة التي لها تستجيب ، ففي الشكل كل مربع مرسوم بخط غامق يمثل مستو خلية والمستطيل الكبير الذي يحوي مجموعة مستويات الخلايا يمثل طبقة S أو طبقة C، داخلها كل طبقة من خلايا S تحتوي على خلايا معينة تسمى خلايا v لكنها غير ظاهرة في الشكل. ارتباطات الخلايا في مستو الخلية تكون متجانسة . كل الخلايا في مستو الخلية تستلم ارتباطات إدخال بالانتشار الحيزي نفسه كما في الشكل رقم (٢-١٠) [٤٨].



يا في مستو الخلية

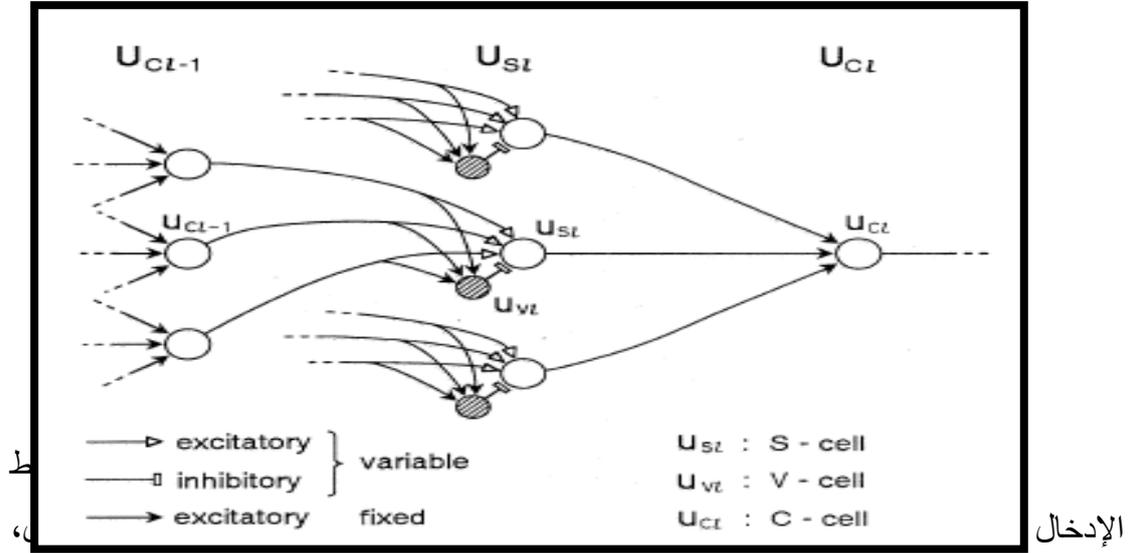
نلاحظ أن

الواحدة . وبما أن كل الخلايا في الشبكة مرتبطة داخليا بشكل أزواج كما مبين في الشكل (٢-٩) ، فإن الطبقة الأعمق تكون الأكبر من حيث الحقول المستلمة لكل خلية في الطبقة وكثافة الخلايا في كل مستو خلية يكون محددًا جدا بحيث يقل مع ازدياد حجم الحقول المستلمة، و في الطبقة الأعمق الحقول المستلمة لكل خلية C تكون كبيرة جدا بحيث تغطي كل طبقة الإدخال وكل مستو خلية C يكون محددًا جدا إلى أن تصبح تمتلك خلية C واحدة وكما في الشكل رقم (٢-١١) الآتي الذي يوضح كيفية ارتباط الخلايا في كل مستو خلية مع الخلايا في مستو خلية أخرى ، حيث تم عد مستو الخلية مصفوفة ذات بعد واحد وتم اخذ مستو خلية واحدة في كل طبقة [٤٩].



شكل رقم (١١-٢): منظر ذو بعد واحد للارتباطات الداخلية بين خلايا في مستويات خلايا مختلفة

كثافة الخلايا في كل طبقة مصممة تتناقص مع المراحل، لأن الخلايا في المراحل الأعلى تمتلك حقول استلام أعلى والخلايا المجاورة تستلم الإشارات نفسها والارتباطات التي تتقارب لاستخلاص الصفات في خلايا S متغيرة ويعاد تقويتها بالتدريب (التعليم) وبعد الانتهاء من التدريب فإن خلايا S وبمساعدة خلايا V تتمكن من استخلاص الصفات من النمط المدخل. وكما موضح في الشكل رقم (١٢-٢) الذي يوضح الارتباطات الداخلية للخلايا بين الطبقات [٥٠].



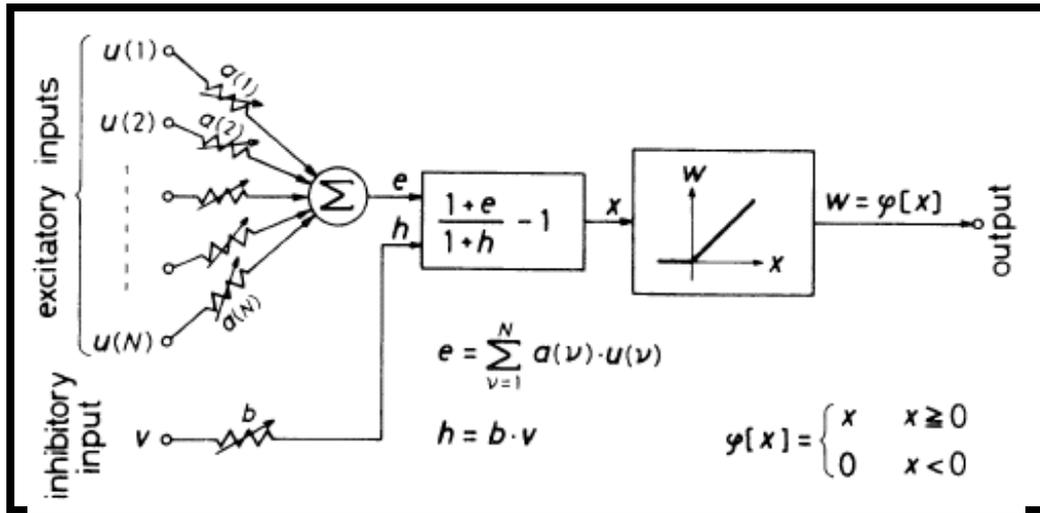
بصورة عامة الصفات المحلية مثل المستقيم بالاتجاه الشائع يتم استخلاصه في المراحل الأوطأ. وفي المراحل الأعلى تستخلص الصفات الأكثر عمومية مثلاً جزءاً من نمط التدريب .

خلايا C تمتلك دالة لتحمل الأخطاء الموقعية للصفات المستخلصة بواسطة خلايا S. الارتباطات من خلايا S إلى خلايا C ثابتة وغير متغيرة حيث أن كل خلية C تستلم إشارات من مجموعة من خلايا S التي تستخلص الصفة نفسها ولكن من مواقع مختلفة قليلاً. الخلية C تنشط إذا كانت على الأقل واحدة من خلايا S نشطة، حتى وإن كانت الصفة الأنوية مزحفة في الموقع و خلية S أخرى منشطة بدلاً من الأولى فالخلية نفسها C ستحتفظ بالاستجابة. ومع استمرار المراحل المتتالية من خلايا S وخلايا C فإن عمليات استخلاص الصفات بواسطة خلايا S وتحمل التغيير أو الترحيف في المواقع بواسطة خلايا C ستكرر وبذلك تحمل الأخطاء الموقعية تقل مع كل مرحلة من مراحل الشبكة وخلال هذه العملية الصفات المحلية المستخلصة في المراحل الأوطأ ستتكمّل تدريجياً بحيث تصبح أكثر عمومية، واخبراً كل خلية C في طبقة

التمييز أي الطبقة الأعلى ستكمل كل معلومات النمط المدخل وتستجيب فقط لأحد الأنماط المدخلة، وبعبارة أخرى فإن خلية C واحدة سوف تنشط لتقابل الصنف للنمط المدخل والخلايا الأخرى تستجيب لأنماط الأصناف الأخرى.

٣-٧-٢ الوصف الرياضي للشبكة

إن جميع الخلايا العصبية المستخدمة في هذه الشبكة هي من النوع المتناظر وهذا يعني أن الإدخال والإخراج بين الخلايا تأخذ قيم غير سالبة نسبة إلى كثافة النبضة المحفزة في الأعصاب البايولوجية الفعلية. وكما موضح في الشكل (٩-٢) حيث أن المرحلة الأولى في الشبكة هي طبقة الإدخال U_0 وهي مصفوفة ذات بعدين والخلايا المنشطة للطبقة S والطبقة C في المرحلة L يشار لها بـ US_l ، UC_l على التوالي أما $US_l(k_l, n)$ تستخدم للإشارة إلى إخراج الخلية S في الطبقة US_l عندما n تمثل موقع الخلية و k تمثل الرقم التسلسلي لمستوى الخلية وكما موضح في الشكل (١٣-٢) فإن خلايا S لها مدخلات معيقة مع ميكانيكية تحويل [٤٩].



$$US_l(k_l, n) = r_l \times \varphi \left[\frac{1 + \sum_{k_{l-1}=1}^{K_{l-1}} \sum_{v \in S_l} a_l(k_{l-1}, v, k_l) \times U_{C_{l-1}}(k_{l-1}, n+v)}{1 + \frac{2 \times r_l}{1+r_l} \times b_l(k_l) \times v_{C_{l-1}}(n)} - 1 \right] \quad (25-2)$$

عندما

$$\varphi[x] = \begin{cases} x & x \geq 0 \\ 0 & x < 0 \end{cases} \quad (26.2)$$

في حالة $l=1$ في المعادلة (٢٥.٢) فإن $UC_{l-1}(k_{l-1}, n)$ ستكون $U_0(n)$ وكذلك $K_{l-1} = 1$.

هنا $a_l(k_{l-1}, v, k_l)$ و $b_l(k_l)$ يمثل كفاءة نقاط التقاء الأعصاب synapses القابلة للتغيير
المنشطة والمعيقة على التوالي, وكما تم ذكره سابقا فان كل خلية من خلايا S في مستو خلايا S
نفسها لها مجموعة من نقاط التقاء الأعصاب المدخلة لهذا السبب $a_l(k_{l-1}, v, k_l)$ و $b_l(k_l)$ لا
تحتوي على أي عناصر تمثل الموقع n للحقول المستلمة للخلية $US_l(k_l, n)$. في الحالة الابتدائية
فإن b تأخذ قيمة صفر أما a فهي قيمة صغيرة وموجبة .
 r_l تسيطر على كثافة التعويق والقيمة الأكبر من r_l هي الأكثر اختيارا حيث تصبح استجابة
الخلايا لصفاتها الخاصة لذلك قيمة r_l يجب أن تحدد لتوفق بين قابلية الاختلاف في الأنماط
المتشابهة وقابلية تحمل التشويه في شكل الأنماط.
الخلايا المعيقة $VC_{l-1}(n)$ تحسب كالاتي:

$$V_{C_{l-1}}(n) = \sqrt{\sum_{k_{l-1}=1}^{K_{l-1}} \sum_{v \in S_l} c_{l-1}(v) u_{C_{l-1}}^2(k_{l-1}, n+v)} \quad (27.2)$$

وكما موضح في المعادلة (25.2) و (27.2) فإن المساحة التي تستلم منها الخلية الواحدة
مدخلاتها هي المدى المستخدم لعملية الجمع وهو S_l من V وهو محدد ليكون كل من
خلايا $US_l(k_l, n)$ و $VC_{l-1}(n)$ ، وكذلك كفاءة نقاط التقاء الأعصاب المنشطة وغير القابلة للتغيير
 $C_{l-1}(v)$ محددة لتجعل قيمة المعادلة

$$\sum_{k_{l-1}=1}^{K_{l-1}} \sum_{v \in S_l} C_{l-1}(v) = 1 \quad (28.2)$$

وبالمقابل فإن خلايا C لها مدخلات معيقة مشابهة لخلايا S، إن الإخراج لخلايا C في k_l من
مستو الخلية في المرحلة L تحسب بالمعادلة الآتية:

$$U_{C_l}(k_l, n) = \psi \left[\frac{1 + \sum_{v \in D_l} d_l(v) \times U_{S_1}(k_l, n+v)}{1 + v_{S_1}(n)} - 1 \right] \quad (29.2)$$

عندما

$$\psi[x] = \begin{cases} x/(\alpha_l+x) & x \geq 0 \\ 0 & x < 0 \end{cases} \quad (30.2)$$

الخلايا المعيقة $V_{S_l}(n)$ التي ترسل إشارات معيقة لخلايا C يمكن حسابها كالاتي

$$V_{S_l}(n) = \frac{1}{K_l} \sum_{k_l=1}^{K_l} \sum_{v \in D_l} d_l(v) \times U_{S_l}(k_l, n+v) \quad (31.2)$$

في المعادلة (٢٩.٢) و (٣١.٢) كفاءة نقاط التقاء الأعصاب المنشطة والغير متغيرة $d_l(v)$ هي مجموعة تكون بشكل دالة تتناقص بشكل رتيب نسبة إلى $|v|$ ، أما α في المعادلة (٣٠.٢) هو قيمه ثابتة موجبه.

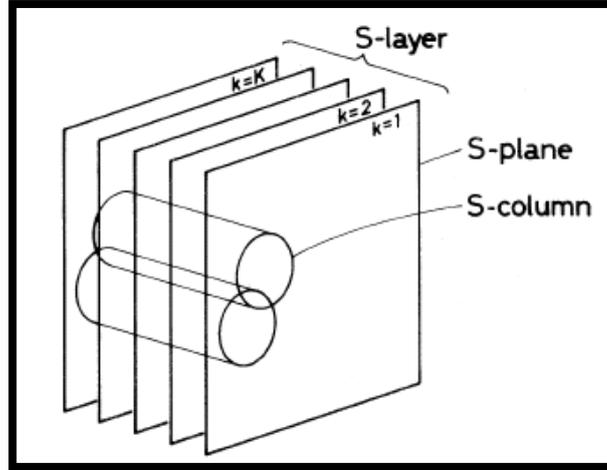
٤-٩-٢ التنظيم الذاتي للشبكة [٤٨]

لتكن $US_l(k_l, n)$ خلية تم اختيارها كخلية ممثلة فأن نقاط التقاء الأعصاب القابلة للتغيير $a_l(k_{l-1}, v, k_l)$ و $b_l(k_l)$ الواردة إلى خلايا S ذات k من مستو الخلية S سيتم إعادة تقويتها بالمقدار الآتي:

$$\Delta a_l(k_{l-1}, v, \hat{k}_l) = q_l \cdot c_{l-1}(v) \cdot u_{a-l}(k_{l-1}, \hat{n} + v) \quad (32.2)$$

$$\Delta b_l(\hat{k}_l) = (q_l/2) \cdot v_{a-l}(\hat{n}) \quad (33.2)$$

عندما تكون q_l قيمة ثابتة وموجبة تسيطر على سرعة إعادة التقوية حيث أن القيمة الابتدائية لـ b هي صفر والقيمة البدائية لـ a هي قيم موجبة صغيرة، وفيما يأتي الشرح الكامل لعملية اختيار خلية ممثلة. إذا رتبنا مخططات خلايا S في الطبقة S كما في الشكل (١٤-٢).



فان مجموعة من خلايا S ستمثل عمود في طبقة S وسنطلق عليه اسم عمود S. فنلاحظ أن العمود S يحتوي على خلايا S من كل مستويات خلايا S بحيث أن العمود S يحتوي أنواع مختلفة من خلايا استخلاص الصفات، يعني أن هناك عدد من أعمدة S في الطبقة S. لكن الحقول المستلمة لهذه الخلايا تقع غالبا في الموقع نفسه وهناك عدد من أعمدة S في طبقة S الواحدة، وبما أن هناك تداخل في أعمدة S مع بعضها لذلك فهناك إمكانية أن تقع خلية S نفسها في واحدة أو أكثر من عمود S.

من كل عمود S وفي كل وقت يتم فيه إحضار النمط الحالي سيتم اختبار الخلية S ذات اكبر إخراج لترشح كخلية ممثلة وبما أنه توجد احتمالية أن ترشح عددا من الخلايا الممثلة في مستو خلايا S نفسها فإذا ظهرت اثنتان أو أكثر من الخلايا الممثلة في مستو الخلايا نفسها فسوف يتم اختيار واحدة فقط ذات اكبر إخراج من بينهم لتعتبر خلية ممثلة في مستو خلايا S المختار. وفي حالة ترشيح واحدة فقط من الخلايا الممثلة في مستو الخلية S فسيتم اختيار هذه الخلية كخلية ممثلة بدون أي شروط. أما إذا لم ترشح أي خلية في مستو خلية S فهذا يعني لا توجد خلية ممثلة لمستو خلية S هذه. وبما أن الخلية الممثلة تم تحديدها بهذه الطريقة، فان كل مستو خلية S أصبح حساس اختياريًا لأحد الصفات من النمط الحالي. وليست هناك احتمالية وجود شكل من الفيض في الارتباطات بحيث اثنتان أو أكثر من مستويات خلايا S تستعمل لتحديد واحدة من الصفات نفسها، يلاحظ أن الخلايا الممثلة يتم اختيارها من عدد صغير فقط من مستويات خلايا S في المرة الواحدة والبقية من مستويات خلايا S سترسل ممثلاتها للأنماط الأخرى.

الفصل الثالث

منظومة الحساب المرن

المقترحة لتصنيف الصور

١-٣ الهيكل العام للمنظومة المقترحة

يهدف العمل الحالي إلى تصميم منظومة لقراءة وتمييز الصور ذات المناظر العامة، كمحاولة لمحاكاة قدرة الإنسان على قراءة مثل هذه الأنماط ، ومن أجل إضافة إمكانية لقراءة هذا النوع من الأنماط ، ليخدم حقل خيال الحاسبة.

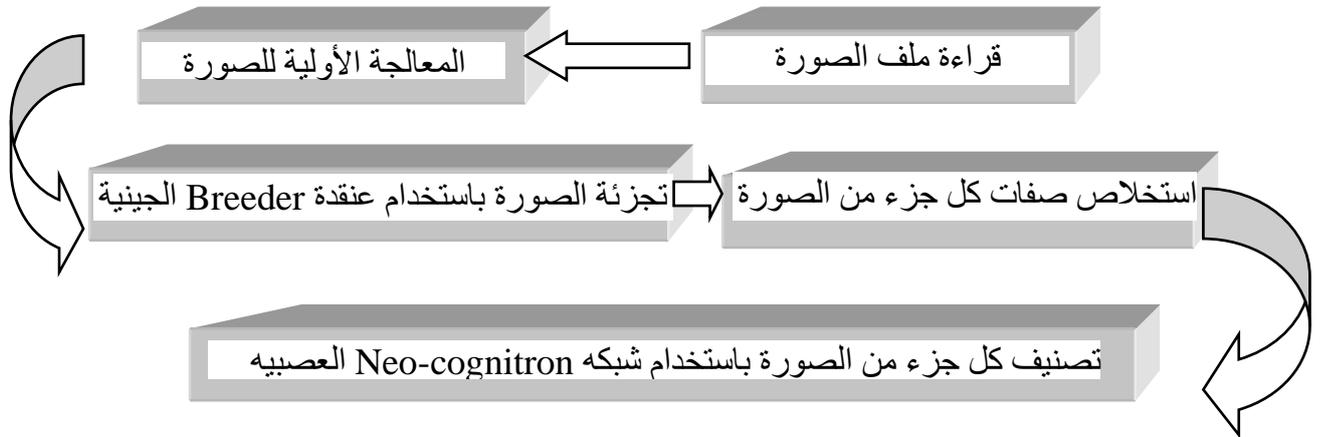
ومن أجل وضع الصيغة العامة للمنظومة المقترحة ، لا بد من تحليل نظام تمييز الأنماط بصورة عامه والمشكلة الحالية بصورة خاصة لمعرفة متطلبات النظام.

هناك عدد من المتطلبات التي يجب توفرها في أنظمة تمييز الأنماط بصورة عامه وهي قدرتها على التمييز في ظروف مثل [٣],[٢] .

١- احتمال تغيير المواقع والتقييس، والتدوير.

٢- احتمال قدر من الضوضاء.

وعلى ضوء هذا التحليل فقد تم استخدام فكرة الحساب المرن (soft computing) للاستفادة من التقنيات المتعددة لتحقيق هذا الغرض فقد تمت تجزئة الصورة إلى عدة أجزاء كمرحلة أوليه من تمييز النمط للحصول على كيانات متكاملة من الصورة وقد تم اختيار الشبكة العصبية لتحقيق عملية التمييز الحقيقية (للشكل الذي تم تجزئته سابقا) لقدرتها على التعلم والتعديل، وقد تم استخدام شبكة Neo-cognitron (المعروفة باستخدامها في مجال تمييز الأحرف المكتوبة بخط اليد بنجاح عالي) بسبب قدرتها العالية على تمييز الأنماط التي تحتوي على نسبة عالية من التشويه. يوضح الشكل (٣-١) الهيكل العام للمنظومة المقترحة، وتوضح البنود اللاحقة مجموعة الخطوات التي تمثل المنظومة المقترحة بالتفصيل، مرتبه حسب تسلسل مراحل العمل.



شكل رقم (٣-١) الهيكل العام للنظام المقترح

٣-١-١-١ قراءة ملف الصورة

الصور المستخدمة هي صور حركية movie image لمناظر وحركات طبيعية عامة بعد أن تم تقطيعها إلى مجموعة الهياكل المكونة لها frames. والسبب في اختيار الصور الحركية هو لدراسة إمكانية الشبكة في التصنيف أي لحساب نسبة التمييز للشبكة بسبب وجود الاختلافات بين الهياكل المتتالية للصور الحركية حيث كل هيئة تم تحويلها إلى صورة ملونه (RGB) من نوع bmp ويرجع السبب في اختيارنا لهذا النوع من الصور هو سهولة التعامل مع هذه الملفات والنتيجة من كون البيانات مخزونة فيه بشكلها الطبيعي الخالي من أي طريقة لضغط البيانات والتي تستخدم في الملفات الصورية الأخرى بالإضافة إلى أنها تتمتع بإمكانية تخزين وعرض

الرسوم أو الصور من أي نظام عرض ،حيث تتطلب عملية قراءة البيانات من الملفات الصورية عملية قراءة للمعلومات المخزونة في رأس الملف واستغلالها لقراءة بيانات الصورة المتمثلة بجزء البيانات ليتم بعدها مقابلة كل عنصر صورة إلى متجه صفات في فضاء الصفات حيث يتم العمل بعد ذلك في هذا الفضاء بدلا من الصورة ذاتها،وكما تم ذكره سابقا.

٣-١-٢ المعالجة الأولية

تعد هذه المرحلة من المراحل المهمة في معالجة الصورة لغرض تحسينها image-enhancement ومن ثم دعمها لخطوات المعالجة اللاحقة وتسهيل تفسيرها،حيث تم إمرار الصورة أي بياناتها على احد مرشحات الإمرار الواطي low pass filter للقضاء على الضوضاء في الصورة،وقد تم استخدام مرشح median filter والذي يعد مرشح ترتيب،حيث ترتب كل مجموعة نقاط متجاورة ذات بعد 3×3 بشكل تصاعدي أو تنازلي ومن ثم يتم اختيار القيمة الوسطية لتعتبر القيمة الجديدة للنقطة pixel في الصورة [٥]،يستخدم هذا المرشح لإزالة الضوضاء في الصور أو النقاط المتطرفة التي تظهر بشكل نقاط مضيئة أو سوداء(فجوات)موزعه بصورة عشوائية في الصورة،لذلك يعد هذا المرشح من مرشحات تنعيم الصورة،والسبب في اختياره هو للتخلص من التجمعات اللونية الصغيرة حيث أن بقائها قد يؤدي إلى الحصول على عناقيد صغيرة وغير مرغوب بها.

٣-١-٣ تجزئة الصورة باستخدام عنقدة Breeder الجينية

هذه المرحلة من معالجة الصور تختص بتحليل الصور image analysis لاستخلاص معلومات معينه وقد تم استعمال العديد من التقنيات لتجزئة الصور (وكما تم توضيحه في الفصل السابق) من بين هذه التقنيات تعد تلك المعتمدة على العنقدة من التقنيات البسيطة والشائعة إلا أن ما تعانيه من مشاكل جعل العمل الحالي يتوجه لحلها ، إن إحدى المشاكل الأساسية التي ترافق بعض تقنياتها مثل K-means هي مشكله النهاية الصغرى المحلية ، حيث يعود السبب في وقوعها بهذه المشكله إلى أنها تبدأ بحل واحد مما يزيد من احتمالية حصول هذه المشكله [٢٧].

في الجانب الآخر،تعد الخوارزميات الجينية واحده من الطرق المستخدمة في حل مشكله النهاية الصغرى المحلية،حيث تبدأ بأكثر من حل مما يزيد من احتماليه تجنبها الوقوع بهذه المشكله،وعليه تم استخدام الخوارزميات الجينية لحل مسألة العنقدة وتطبيقها في تجزيء الصور وقد تم استخدام خوارزمية Breeder الجينية في البداية تم تحويل الصورة من المجال الحيزي إلى فضاء الصفات وذلك من خلال تمثيل كل عنصر صورة بواسطة متجه صفات ومن ثم إيجاد

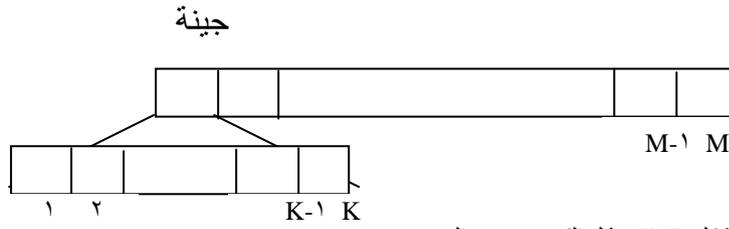
العناقيد المناسبة في هذا الفضاء، بعد ذلك يتم الرجوع إلى المجال الحيزي مرة أخرى لإظهار أجزاء الصورة بعد إنجاز عملية تجزئة الصورة عامة وتمتاز هذه الطريقة بعدد من الخصائص - استخدام خوارزمية جينية مهجنة (للاستفادة من مزايا التقنيتين المهجنة منهما)

- تعمل في بيئة غير موجهة

- يتم تطبيقها على الصور ذات التدرج الرمادي إضافة إلى الصور الملونة

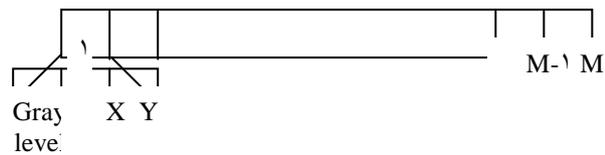
❖ تمثيل الحل

إن إحدى المشاكل الأساسية التي تواجهنا لحل مسألة ما باستخدام الخوارزميات الجينية هي إيجاد تمثيل مناسب للحل ففي هذه الطريقة يتألف الكروموسوم من M من الجينات حيث تمثل كل جينه من هذه الجينات مركز عنقود متخذاً هيئة متجه ذي K من الصفات كما في الشكل (٢-٣).

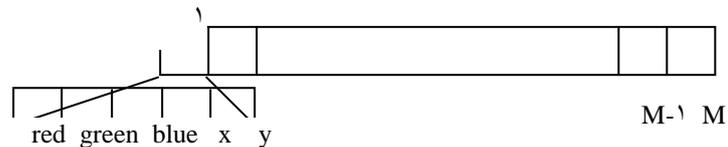


شكل (٢-٣) تمثيل الكروموسوم المعتمد على المراكز (centroid based)

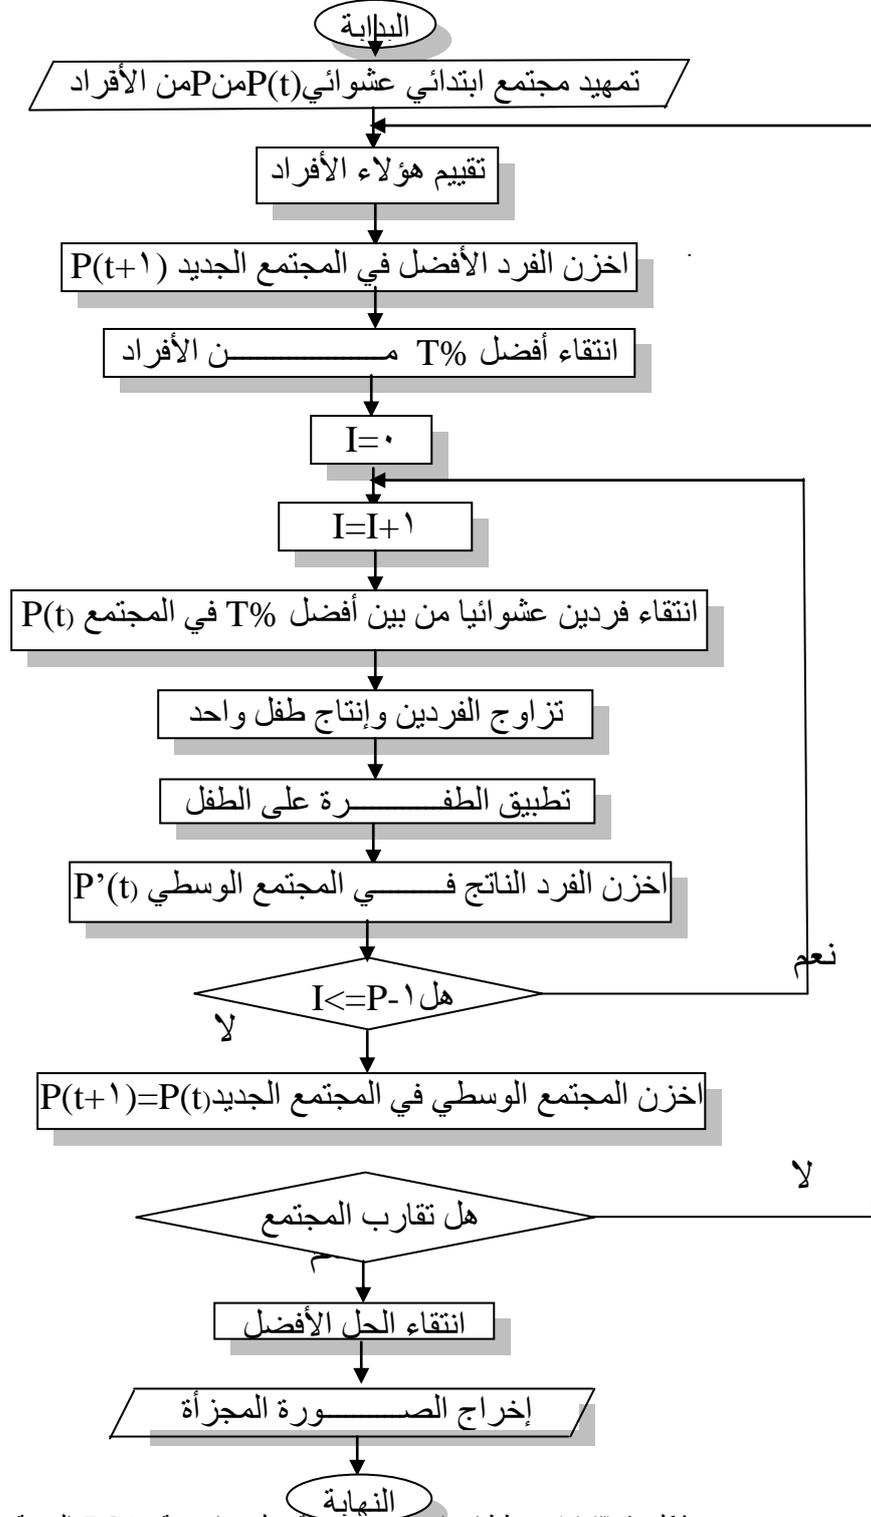
عند استخدام الصور ذات التدرج الرمادي فإن المتجه الممثل للجينة سيتكون من ثلاثة عناصر هي المستوى الرمادي والإحداثيات X, Y لمركز العنقود أما عند استخدام الصور الملونة فإن المتجه يتكون من خمسة عناصر هي الإحداثيات X, Y مع المركبات الأساسية للون (أحمر وأخضر وأزرق) وكما مبين في الشكل (٣-٣).



أ- عند استخدام الصور ذات التدرج الرمادي



❖ هيكل عمل خوارزمية breeder الجينية (BGA)



شكل رقم (٣-٤) مخطط انسيابي يوضح طريقة عمل خوارزمية BGA الجينية

وفيما يأتي توضيحا مفصلا لخطوات العمل المذكورة :-

❖ قراءة المعاملات المطلوبة

يتم في البدء قراءة المعاملات الضرورية لعمل الخوارزمية المقترحة والمتمثلة باحتمالية الطفرة Pm وحجم المجتمع وعدد الدورات القصوى max gen وبعدها يتم قراءة اسم الملف الحاوي على الصورة المراد تجزئتها، حيث تخزن الصورة عادة بملفات ذوات أسماء مختلفة.

❖ تحويل الصورة إلى فضاء الواصفات

في هذه الخطوة يتم مقابلة كل عنصر صورة إلى متجه صفات في فضاء الصفات حيث يتم العمل بعد ذلك في هذا الفضاء بدلا من الصورة ذاتها.

❖ توليد مجتمع ابتدائي من الأفراد

يتم توليد مجتمع ابتدائي من الأفراد (الحلول) من خلال انتقاء أفراد من فضاء الصفات والتي تحمل اكبر عدد تكراري للألوان في الصورة المختارة والذي عن طريق هذا العدد تم تحديد عدد العناقيد المرغوبة وكما تم ذكره سابقا ووضعها في جينات الكروموسومات لتمثل مراكز العناقيد الابتدائية بشرط عدم تكرار انتقاء المتجه نفسه للكروموسوم الواحد.

❖ تقييم أفراد المجتمع

بعد أن تم توليد المجتمع الابتدائي، يتم تقييم أفراد من خلال تطبيق داله صلاحية معينه، حيث يتم أولا تنسيب كل متجه صفات إلى احد العناقيد الموجودة والتي مركزها يكون اقرب إلى ذلك المتجه طبقا لمسافة اقليدس فعند استخدام الصور يتم استعمال الصيغة الآتية:-

$$d(x, z^{(i)}) = \sum_{k=1}^K w_k \left| \frac{(x_k - z_k^{(i)})}{r_k} \right|, i = 1, 2, \dots, m \quad (1.3)$$

x متجه الصفات المراد تنسيبه

Z⁽ⁱ⁾ مركز العنقود i

K عدد الصفات في متجه الصفات

W_k وزن الصفة k (0 < w_k ≤ 1)

r_k مدى قيم الصفة k

تتناسب قيم وزن الصفات مع أهميتها , حيث يعطى وزن كبير للمستوى الرمادي لعنصر الصورة ووزن قليل للصفات الخاصة بالإحداثيات y, x والآن بعد أن تم تنسيب تلك المتجهات، يتم حساب مقدار اختلاف المتجهات التابعة لكل عنقود كالاتي:-

$$\text{Distortion} = \frac{1}{w \times H \times k} \sum_{i=1 \times c_i}^M d(x, z^{(i)}) \quad (2.3)$$

عرض الصورة W

ارتفاع الصورة H

العنقود C_i

عدد العناقيد M

K عدد الصفات في متجه الصفات

وبما أن هدفنا هو تقليص الاختلاف بين متجهات العنقود الواحد وباعتبار distortion يمثل دالة الهدف، لذلك يتم استخدام العلاقة الآتية كدالة صلاحية لطريقتنا

$$\text{Fitness} = \frac{1}{1 + f(x_1, x_2, \dots, x_D)} \quad (3.3)$$

دالة الهدف $f()$

D عدد متغيرات القرار في دالة الهدف

وبذلك تحصل الحلول ذات القيم الأصغر لدوال الهدف على قيمة اكبر للصلاحية

❖ خزن الفرد الأفضل في المجتمع الجديد

حيث يتم اختيار الفرد ذو الصلاحية الأعلى في المجتمع الحالي ويخزن مباشرة في المجتمع الجديد.

❖ انتقاء فردين للتزاوج

تم انتقاء ٥٠% من الأفراد ذات أفضل صلاحية لتعد الأساس لأفراد المجتمع الجديد حيث يتم انتقاء فردين عشوائيا من بين هؤلاء الأفراد (أفضل ٥٠% فرد) وبنسبة احتماليه متساوية لأجراء التزاوج، حيث العنصر الأفضل سيتم اختياره والأسوأ لا يتم اختياره والنخبة أي العنصر الأفضل دائما يعيش من جيل إلى جيل مما يسرع في عملية الوصول إلى الحل الأمثل، لذلك تم اختيار هذه الخوارزمية.

❖ تزاوج الفردين

استخدمت طريقة التزاوج المضرب والموصوفة سابقا وقد تم استخدام المعادلة الآتية لإنتاج طفل جديد وهي معادلة Trinomial

$$f(Z) = \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}ZZ'} \quad (4.3)$$

Z متجه الواصفات لأحد الآباء

حيث أن

$$ZZ' = \sum_{i=1}^k Z_i^2 \quad (٥.٣)$$

K عدد الواصفات في متجه الواصفات

يتم التزاوج عن طريق مسح كل كروموسوم جينة جينة وحساب ناتج المعادلة السابقة لكل جينة متقابلة من كل كروموسوم الجينة ومقارنة ناتج المعادلة للجينتين المتقابلتين ومن ثم يؤخذ محتوى الأكبر قيمة لتمثل محتوى الجينة المقابلة للطفل الناتج. وكما موضح في الخوارزمية الآتية:-

Fuzzy Recombination Algorithm

input parent¹(x,y,r,g,b),parent²(x,y,r,g,b)

output child(x,y,r,g,b)

For $i \leftarrow 1$ to L do

$$\text{Parent}^1[i] = \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}ZZ'}$$

$$\text{Parent}^2[i] = \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}ZZ'}$$

If $\text{Parent}^1[i] \geq \text{Parent}^2[i]$ then

$$\text{Child}[i] = \text{Parent}^1[i]$$

else

$$\text{Child}[i] = \text{Parent}^2[i]$$

End if

End for

❖ تطبيق الطفرة

تم إجراء الطفرة من نوع DM والتي تم شرحها سابقا على الطفل الناتج من الخطوة السابقة من خلال مسح الكروموسوم جينة جينة وأجراء الطفرة عليها باحتماليه معينه (Pm) . حيث يتم تبديل كل جينة بمتجه واصفات يتم حسابه من المعادلة الآتية حيث تضاف أو تطرح نتيجة هذه المعادلة المحسوبة لكل قيمه من متجه الواصفات إلى محتوى متجه الواصفات للجينة المقابلة.

$$z'_i = z_i \pm \text{Search interval} * \text{const} * 2^j \quad 0 \leq j \leq k-1 \quad (٦.٣)$$

حيث

| | |
|---|-----------------|
| الطفل الناتج (جينة في الكروموسوم) بعد إجراء الطفرة | z'_i |
| عدد الواصفات في متجه الواصفات | i |
| الفرد (جينة في الكروموسوم) المراد إجراء الطفرة عليه | z_i |
| مجال البحث لكل قيمه في متجه الواصفات | Search interval |
| يمثل النصف لكل قيمه في متجه الواصفات | Const |
| عدد البتات المستخدمة لتمثيل الرقم الحقيقي (real) وهي ٦٤ | k |

وفيما يأتي خوارزمية عمل الطفرة

Discrit Mutation Algorithm

input child (x,y,r,g,b)

For i ← ١ to L do

If (rnd (٠...١) ≤ Pm) then

Childm[i]=child[i]-Search interval *(١/٢*search interval)* 2⁻⁶⁴

If (childm[i] out of Search interval) then

Childm[i]=child[i]+Search interval*(١/٢*search interval)* 2⁻⁶⁴

End if

End if

End for

حيث ان childm[i] يمثل متجه الطفل بعد إجراء الطفرة عليه.

❖ إدخال الطفل المختار إلى المجتمع

تنجز هذه الخطوة بواسطة إدخال الطفل الناتج من الطفرة في مجتمع وسطي وليكن $P'(t)$ وبعد تكرار خطوات (الاختيار والتزاوج والطفرة) ل $P-1$ مره وفي كل مره يدخل الطفل الناتج إلى هذا المجتمع الوسطي يتم إدخال هذا المجتمع الوسطي الناتج الى المجتمع الجديد والذي يحتوي سابقا على الفرد ذو الصلاحية الأفضل.

❖ معيار التوقف

معيار التوقف المستخدم هنا هو الوصول إلى الحد الأقصى من عدد الدورات الجينية أو عند حصول تقارب في صلاحيات الأفراد أي لا يوجد فرق كبير في صلاحيات أفراد المجتمع.

❖ انتقاء الحل الأفضل

يمثل الحل الأفضل الفرد ذو القيمة الأعلى لدالة الصلاحية الموضحة في المعادلة (٨.٣):-

$$(٨.٣) \quad \text{Fitness} = \frac{1}{1 + f(x_1, x_2, \dots, x_D)}$$

❖ إخراج أجزاء الصورة

بعد انتقاء الحل الأفضل ، يتم إيجاد العناقيد المناسبة ومن ثم الرجوع إلى المجال الحيزي للصورة من خلال تنسيب كل عنصر في الصورة إلى أحد مراكز العناقيد التي تمثل الحل الأفضل الذي يتم الوصول إليه ومن ثم تخزين الألوان الخاصة بكل عنصر في الصورة في مصفوفة خاصة لكل مركز عنقود. ولأغراض الطباعة ولحساب معدل الخطأ النسبي (Relative mean error) تم تلوين كل عنصر صورة باللون نفسه في مركز العنقود الذي نسب إليه والصورة الناتجة وضعت في ملف جديد ، أما معدل الخطأ النسبي لكل عنصر صورته فيتم حسابه كما في المعادلة (٩.٣) الآتية:

$$MRE = \frac{\sum_{x=1}^W \sum_{y=1}^H |f(x, y) - g(x, y)|}{W \times Y} \quad 9.3$$

في العلاقة أعلاه يمثل كل من $f(x, y)$ و $g(x, y)$ الشدة اللونية في عنصر الصورة (x, y) لكل من الصورة الأصلية والمجزأة على الترتيب. أما H و W فيمثلان أبعاد الصورة.

بعد أن تم فصل كل جزء من الصورة بخزنه في مصفوفة خاصة به تحتوي على ألوان هذا الجزء، يتم الآن حساب المعدل اللوني لكل عنصر صورة (في حالة الصور الملونة فقط) وكالاتي:-

$$p = \frac{r + b + g}{3} \quad (10.3)$$

ومن ثم تستخلص صفات كل جزء وبما ان الشبكة العصبية المستخدمة في طريقتنا المقترحة (شبكة (Neo-cognitron) لها القابلية على تمييز الأنماط اعتمادا على التشابه في الشكل العام وكما تم ذكره سابقا لذلك تم استخلاص الصفات بالطرق الآتية والتي تحدد الهيئة العامة للشكل وصفاته العامة باستخدام:-

٣-١-٤-١ طريقة توقيع الكفافات

والتي تم وصفها سابقا حيث تحسب المسافة بين نقاط الحدود ونقطة المركز كدالة لزاوية الحركة عند تتبع النقاط ، ويوضح هذا الوصف لطريقة عمل الخوارزمية حقيقة مهمة وهي أن هذه الخوارزمية تعمل بكفاءة عالية مع الصور ذات الضوضاء القليلة وتعمل هذه الخوارزمية مع الصور ذات الحدود المتصلة لتجنب القيم الصفرية للدالة وكذلك تعمل مع الصور الخالية من الفجوات لتجنب تعدد قيم الدالة لذلك قد نحتاج إلى إمرار كل جزء من الصورة المستخرج من المرحلة السابقة بمرشح يقوم بتقليل الضوضاء إن وجدت وكذلك تم استخراج الحدود الخارجية للصورة.

Signature Generation Algorithm

Input: A[n][m] matrix of image segment

Output:[c] element signature vector of image segment signature

Begin

Extract all gray scale pixels

Calculate centroid point coordinate

i=١

Set coordinate updating variable (step)

Use step to update the coordinate value

For each point in the contour do

If (there is no holl in the contour) then

Compute the distance between centroid point and contour point

$$\text{Signature}[i] = \sqrt{(\text{centroid}_x - \text{row})^2 + (\text{centroid}_y - \text{col})^2}$$

$i = i + 1$

else

$$\text{Signature}[i] = 0$$

$i = i + 1$

end if

end for

End

٣-١-٤-٢ المدرج التكراري Histogram

وتعد من طرق استخلاص الصفات الرياضية وقد تم استخدام المقاييس الآتية

لاستخلاص صفات المدرج التكراري والمذكورة سابقا:-

١- المتوسط الحسابي (Mean) .

٢- الانحراف المعياري (Standard deviation) .

٣- الطاقة (Energy) .

٤- الالتواء (skew ness)

٥- الأنتروبيا (Entropy) .

٣-١-٥ تصنيف كل جزء من الصورة

بعد استخلاص صفات كل جزء من الصورة يتم تصنيف كل جزء من الصورة باستخدام

الشبكة العصبية Neo-cognitron والتي تتكون مثل باقي الشبكات العصبية من مرحلتين

وهما:-

١- مرحلة التدريب Training phase

٢- مرحلة الاختبار Test phase

٣-١-٥-١ مرحلة التدريب

وفيها يتم تدريب الشبكة بإدخال الصفات المستخرجة من المرحلة السابقة لعدة أشكال

نموذجيه او مختاره إلى الشبكة كطبقة إدخال وفيما يأتي خطوات عمل شبكة Neo-cognitron

العصبية:-

Training steps for Neo-cognitron network

- Present input pattern for training(segment of image)to the input layer U_0 .
- Read number of stages, number of cell planes, number of cells for cell plane and the length(v) for neighboring cells for each layer.
- initialize a small positive value for excitatory synapses c, d of the length v for each cell plane in layer US_i, UC_i .
- set b to zero (the efficiencies of the modifiable inhibitory synapses) for each cell plane in layer US_i .
- initialize a small random values for (a)(the excitatory synapses) of the length v for each cell plane in layer US_i .

Repeat

- use Eq. [20.2] and Eq.[26.2] and Eq.[27.2] to find the output of S cells of layer US_i .
- choose the representative S cells
- reinforce the variable interconnections by using Eq.[32.2] and Eq.[33.2].

Until the response of average (a) becomes small(approach to ϵ).

- use Eq.[29.2] and Eq.[30.2] and Eq.[31.2] to find the output of C cells of layer UC_i which is directly driven by the output from layer US_i .
- if the UC_i layer is the output layer then stop and the cell that having the largest value of output is represent the number of class,

Else

go to the step of repeat

لاستخراج الخلية الممثلة يتم استخراج الخلية التي لها قيمة إخراج أكبر من بين الخلايا المتقابلة المواقع في كل مستو خليه بشرط ألا يتم استخراج أكثر من خليه ممثله واحده من كل مستو خليه فإذا حدث ووجد أكثر من خليه ممثله في مستو الخلية نفسه فسيتم إختيار الخلية التي لها قيمة إخراج اكبر من الخلية المختارة الأخرى لتعتبر كخليه ممثله وكما موضح في الخوارزمية الآتية:-

Calculation the representative cell Algorithm

input $US_l(k, n)$ // l number of stages
output rep-cell [n], rep-cell plane [n] //rep-cell No. of representative cell
//rep-cell plane No. of representative cell plane

For each cell (n) in the cell plane

Max[n] = $US_L(1, N)$

For each cell plane (k)

if Max[n] < $US_l(k, n)$ then

Max[n] = $US_l(K, n)$ //maximum output value

cp[n] = k //cp No. of cell plane

end if

next

next

For each cell plane (k)

For each cell (n) in the cell plane

For each cell (m) in the cell plane

if cp[n] = cp[m] then

if Max[n] > Max[m] then

cp[m] = •

rep-cell [n] = n

rep-cell plane [n] = k

else

```
cp[n]=0
rep-cell [n]=m
rep-cell plane[n]=k
end if
end if
next
next
next
```

٣-١-٥-٢ مرحلة الاختبار

وفيها يتم اختبار كيان الصورة المستخرج من مرحلة التجزيء السابقة للصورة حيث يتم إدخال صفات كيان الصورة إلى الشبكة ويتم التعرف أو تمييز كيان الصورة المدخل إذا كان قد تم تدريب الشبكة سابقاً على شكل مشابه تماماً أو تقريبي لكيان الصورة المدخل، عن طريق مقارنة الكيان المراد التعرف عليه مع نتائج طبقة الإخراج لكل نمط تم التدريب عليه حيث هناك مدى يقع فيه القرار لكل صنف يتم اختياره في طبقة الإخراج بحيث كل صنف من الصفات المدخلة للنمط المراد اختباره يتم مقارنتها مع المدى المخصص لكل صنف فإذا كانت ضمن منطقة القرار فسيتم اختيار هذا الصنف، أما إذا كان القرار يقع في أكثر من منطقه فإن الاختيار سيكون للصنف الذي يحمل قيمة إخراج أكبر، ويتم استخراج المدى المسموح لمنطقة القرار لكل صنف عن طريق إيجاد الفرق بين قيمة الإخراج للخلية الفائزة وأقل قيمه للصفة المقابلة (في رقم الخلية) للكيانات التي تم التدريب عليها وهذا لتحديد المدى الأوطأ lower range أما لتحديد المدى الأعلى upper range فيتم بإيجاد الفرق بين قيمة الإخراج للخلية الفائزة وأعلى قيمه للصفة المقابلة (في رقم الخلية) للكيانات التي تم التدريب عليها، وكما ذكرنا سابقاً فإن للشبكة القدرة على التعرف على الأشكال حتى وإن كان فيها نسبة من التشويه أو التزحيف في موقع الشكل وفيما يأتي خوارزمية الاختبار باستخدام شبكة Neo-cognitron العصبية:

The Neo-cognitron network testing Algorithm

```

input      U0[K] //test input object   k 1,2,...No. of cell plane
output     class //type of class
For each objects (All)
  For each cell plane (k)
    value= $UC_L[ALL, K] - U0[K]$  // L deepest stage
    if value > lower rangek and value <= upper rangek then
      classes[All]=value
    end if
  next
next
max=•
For each objects (All)
  if Max < classes[All]
    Max=classes[All]
  end if
next
class=Max

```

الفصل الرابع
النتائج والاستنتاجات
الأعمال المستقبلية

١-٤ أداء المنظومة المقترحة

يقدم هذا الفصل تجارب لاختبار أداء النظام في مجال العنقدة باستخدام خوارزمية Breeder الجينية بحيث عن طريقها يتم استخراج الكيانات لمجموعه من الصور، وكذلك يقدم الفصل المعاملات الأساسية المستخدمة في تصنيف الصور التي أجريت عليها عملية التجزيء.

٢-٤ التجزيء

لاختبار أداء طريقة التجزيء المعتمدة على خوارزمية Breeder الجينية والموضحة في الفصل السابق، والتي تمثل المرحلة الأولى من النظام فقد تم تطبيق الطريقة على مجموعة من الصور المختلفة الأنواع والتعقيدات مع التغيير في المعاملات الأساسية، كأمثله تجريبية لبيان سلوكية تلك الطريقة. وفيما يأتي مجموعة التجارب التي تم القيام بها.

١-٢-٤ التجربة الأولى

للتأكد من نتائج الطريقة المقترحة فقد تم اختيار صورة طبيعية أكثر تعقيدا لاحتوائها على تفاصيل أكثر، وللتأكد من صحة عملية العنقدة فقد تم حساب معدل الخطأ النسبي MRE للصورة بغض النظر عن عدد العناقيد التي تحقق استخراج كامل للكيان المطلوب، كما هو هدف النظام المقترح، فقد تم استخدام عدد العناقيد التي تحقق اقل معدل خطأ نسبي للصورة.

• الصورة رقم (١)

وهي من الصور التي تحتوي على تدرجات لونية كثيرة، وفيما يأتي المعاملات الأساسية المستعملة:

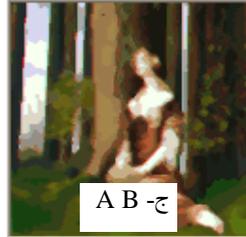
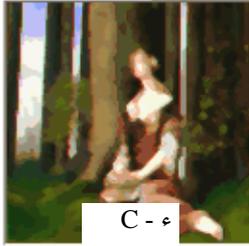
جدول (١-٤): المعاملات الأساسية المستخدمة لتجزيء الصورة (١)

| م. الت. الش. ١٣٣ | عدد العناقيد | حجم المجتمع | عدد الدورات | وزن صفة اللون | وزن صفة الموقع | معدل الخطأ النسبي | صلاحية الفرد الأفضل |
|------------------|--------------|-------------|-------------|---------------|----------------|-------------------|---------------------|
| A | ٢٥ | ٣٠ | ١٦ | ٠.٩٩ | ٠.٠١ | $E-03$ -٣.٦٨٢٤٥٤٤ | ٠.٩٨١٣٤٣٦٨٩٠١ |
| B | ٣٥ | ٣٠ | ١٦ | ٠.٩٩ | ٠.٠١ | $E-03$ -٤.٧٤٠٣٩٧١ | ٠.٩٨٣١٣٦٣٣٦١٤ |
| C | ٤٥ | ٣٠ | ١٦ | ٠.٩٩ | ٠.٠١ | $E-04$ -٩.٥٦٢٧٤٤ | ٠.٩٨٤٦١١٩٥٤٥٢ |

من الجدول السابق نلاحظ أن زيادة عدد العناقيد (أجزاء الصورة) يؤدي إلى نقصان معدل الخطأ النسبي بسبب إمكانيةه في احتواء اغلب التجمعات اللونية الصغيرة، فبذلك تصبح التوليفة C

هي الأفضل بسبب امتلاكها لأقل معدل خطأ نسبي مع أعلى صلاحية للفرد الأفضل. والشكل الآتي يبين الصورة الأصلية مع نتائج تجزيء الصورة باستخدام التوليفات المذكورة في الجدول

أ- الصورة الأصلية



شكل (٤-١): مخرجات برنامج (Vcdcut pro v٤.٤١)

من النتائج المرئية يظهر أن الصورة ذات التوليفة C هي اقرب وأكثر شبها بالصورة الأصلية، حيث أن زيادة عدد العناقيد يزيد من إمكانية احتواء التجمعات اللونية الصغيرة مما يجعل الصورة الناتجة من التجزيء أكثر شبها بالصورة الأصلية.

٤-٢-٢ التجربة الثانية

تم تطبيق طريقة التجزيء الجينية على صور طبيعية حركية Movie images بعد أن تم تقطيع كل صورة حركية إلى مجموعة الهياث (frames) المكونة لها عن طريق برنامج (Vcdcut pro v٤.٤١) والسبب في اختيار الصور الحركية هو وجود الاختلافات بين الهياث المتتالية للصورة لتساعد في حساب نسبة التمييز للشبكة العصبية المستعملة. وهنا حرصنا على استخراج الكيان (object) بكامله من الصورة كما هو هدف النظام لذلك لم نعتمد معدل الخطأ النسبي في اختيار الصورة الأفضل ، بل تم اعتماد الفرد ذو الصلاحية الأعلى، وكذلك تم اعتماد ٢٠ دوره لكل الصور الآتية ، وسيتم فقط عرض صورة الكيان الناتج من عملية التجزئة أي الكيان المطلوب استخراجه والذي سيتم استخدامه لاحقا في عملية التصنيف، حيث لا نحتاج إلى عرض الصورة كاملة بعد التجزئة كما في التجربة السابقة، وفيما يأتي هذه الصور:

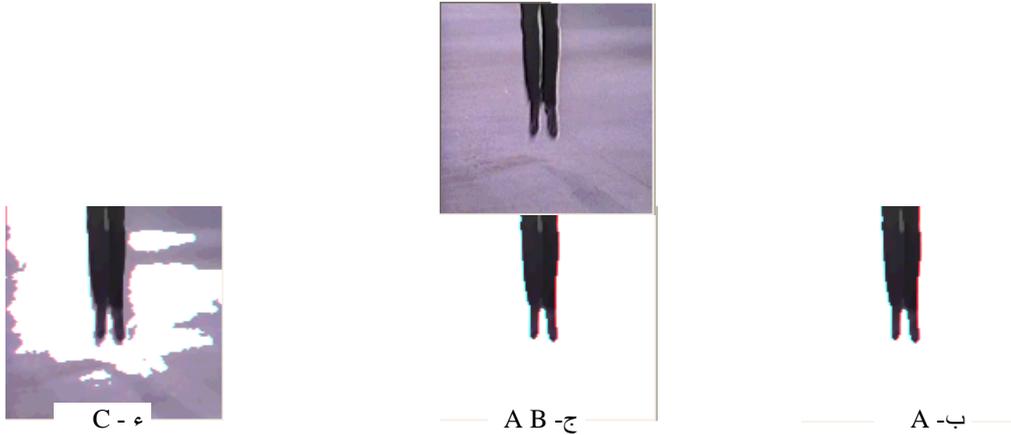
● صورة رقم (٢)

تمثل حركة أقدام على المسرح وقد تم تجزئة الهيئة الأولى من الصورة بالمعاملات الأساسية الآتية:

جدول (٢-٤) يمثل المعاملات الأساسية لتجزئة الهيئة الأولى للصورة (٢)

| صلاحيه الفرد الأفضل | وزن صفة الموقع | وزن صفة اللون | عدد الدورات | حجم المجتمع | عدد العناقيد | نوع التوليف |
|---------------------|----------------------|---------------------|----------------|----------------|-----------------|----------------|
| ٠.٩٧٢٧٧٣٣٢٤٤٩ ٣ | ٠.٠٥ | ٠.٩ | ٢٠ | ٣٠ | ٥ | A |
| ٠.٩٧٢٧٧٣٣٢٤٤٩ ٣ | ٠.٠٥ | ٠.٩ | ٢٠ | ٢٠ | ٥ | B |
| ٠.٩٦٤٥٩٠١٩٢٩٤ ٩ | ٠.٠٥ | ٠.٩ | ٢٠ | ١٠ | ٥ | C |

من الجدول نلاحظ أن زيادة حجم المجتمع يزيد من قيمة صلاحية الفرد الأفضل فلذلك التوليفتان A, B أفضل التوليفات بسبب امتلاكها للقيمة الأكبر للصلاحية، وبما أن الهدف من تجزئة هذه الصورة هو الحصول على كيان متكامل وهو الأقدام فلذلك تم استعمال المعاملات التي تحقق ذلك وكما موضح في نتائج التجزيء بالتوليفات المذكورة في الجدول (٤-٤).



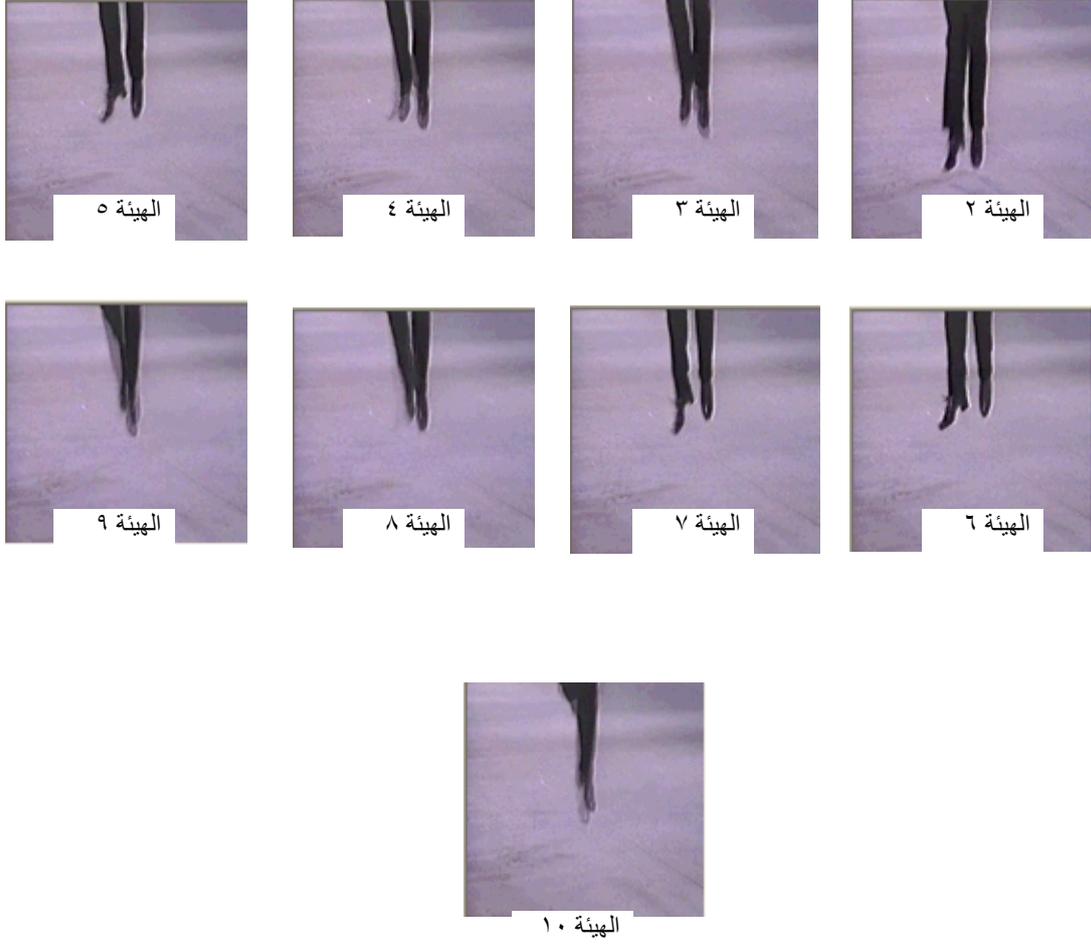
شكل (٢-٤): مخرجات النظام المقترح للهيئة الأولى للصورة رقم (٢)

نلاحظ من الصور أعلاه أن التوليفة C قد أثرت على شكل الكيان الناتج حيث لم يتمكن من استخلاصه بمفرده فكانت هناك إضافات من الخلفية قد ألحقت بالكيان (الأقدام)، بالإضافة إلى امتلاكها أقل قيمة صلاحية، لذلك فقد تم استخدام الكيان الناتج من التوليفة A في تدريب الشبكة لاحقاً. وفيما يأتي جدول بكل المعاملات الأساسية لتجزئة تسع هيئات متتالية للصورة الحركية رقم (٢):

جدول (٣-٤) المعاملات الأساسية لكل هيئات الصورة رقم (٢)

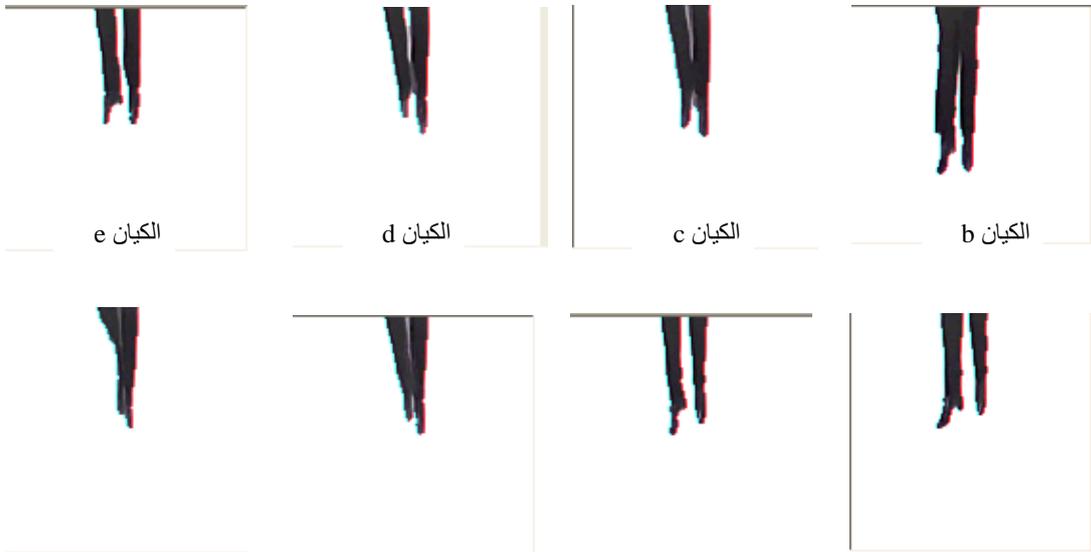
| صلاحيية الفرد الأفضل | وزن صفة الموقع | وزن صفة اللون | حجم المجتمع | عدد العناقيد | رقم الهيئة |
|----------------------|----------------------|---------------------|----------------|-----------------|---------------|
| ٠.٩٧٢٨٤٩٥٣٣٣٨ ٤ | ٠.٠٥ | ٠.٩ | ٣٠ | ٥ | ٢ |
| ٠.٩٧٣١١٩٩٢٥٧٦ ٧ | ٠.٠٥ | ٠.٩ | ٣٠ | ٥ | ٣ |
| ٠.٩٧٤٨٠.٠٧٨٥٧٥ ٢ | ٠.٠٥ | ٠.٩ | ٣٠ | ٥ | ٤ |
| ٠.٩٧٣١٣٥٥٩٩٢١ ١ | ٠.٠٥ | ٠.٩ | ٣٠ | ٥ | ٥ |
| ٠.٩٧٣٠٩٤١٠٧٠٠ ٣ | ٠.٠٥ | ٠.٩ | ٣٠ | ٥ | ٦ |
| ٠.٩٨٢٠٤٨٢٧٣٩٤ ٧ | ٠.٠٥ | ٠.٩ | ٣٠ | ٥ | ٧ |
| ٠.٩٨٢٩٢١٦٥٤٦٩ ٦ | ٠.٠٥ | ٠.٩ | ٣٠ | ٥ | ٨ |
| ٠.٩٨٢٦٠٥٨٢٩٤٧ ٢ | ٠.٠٥ | ٠.٩ | ٣٠ | ٥ | ٩ |
| ٠.٩٨٢١٠٣٤٣٨٥٣ ٩ | ٠.٠٥ | ٠.٩ | ٣٠ | ٥ | ١٠ |

فيما يأتي استعراض لهيئات الصورة رقم (٢) مع صور الكيان الناتج والمطلوب فقط من عملية التجزئة



شكل (٤-٣): الهيئات للصورة رقم (٢)

وفيما يأتي استعراض للكائنات الناتجة من التجزئة لهيئات الصورة رقم (٢) وحسب التسلسل وقد تم إعطائها تسلسلات حسب الحروف الهجائية وكالاتي:



الكيان i

الكيان h

الكيان g

الكيان f



شكل(٤-٤): الكيانات الناتجة لكل هياكل الصورة رقم (٢)

• صورة رقم (٣)

وهي صورة لحركة طائر مروحيه وقد تم تجزئة الهيئة الأولى من الصورة بالمعاملات الأساسية الآتية:

جدول (٤-٤) يمثل المعاملات الأساسية لتجزئة الهيئة الأولى للصورة رقم (٣)

| الكيان | عدد العناقيد | حجم المجتمع | عدد الدورات | وزن صفة اللون | وزن صفة الموقع | صلاحية الفرد الأفضل |
|--------|-------------------|-------------|-------------|---------------|----------------|---|
| A | ٥ | ٣٠ | ٢٠ | ٠.٣ | ٠.٥ | ٠.٩٨١٥٩٩٦٦٨١٣ ١ |
| B | ٥ | ٣٠ | ٢٠ | ٠.٩ | ٠.٥ | ٠.٩٥٧٢٨٨٧٩٢٣٧ ٨ |
| C | ٥ من الجدول (٤-٤) | ٣ | ٢ | ٧ | ٣ | ٠.٩٤١٥٥٣٠٣٢٨١ عند تثبيت حجم المجتمع ٢ |

على صلاحية الفرد الأفضل فك

أ- الصورة الأصلية



شكل (٥-٤): مخرجات النظام المقترح للهيئة الأولى للصورة رقم (٣)

نلاحظ التشابه الكبير بين النتائج المرئية عند تغيير الأوزان للهيئة الأولى للصورة رقم (٣) وفيما يأتي جدول بالمعاملات الأساسية التي تم استعمالها لتجزئة تسع هيئات متتالية للصورة رقم (٣).

جدول (٥-٤) المعاملات الأساسية لكل هيئات الصورة رقم (٣)

| رقم الهيئة | عدد العناقيد | حجم المجتمع | وزن واصفة اللون | وزن واصفة الموقع | صلاحية الفرد الأفضل |
|------------|--------------|-------------|-----------------|------------------|---------------------|
| ٢ | ٥ | ٣٠ | ٠.٣ | ٠.٠٥ | ٠.٩٨١٧٣٦٦٩٥٤٤ ٩ |
| ٣ | ٥ | ٣٠ | ٠.٣ | ٠.٠٥ | ٠.٩٨١٨٨٠٥٦٠١٤ ٨ |
| ٤ | ٥ | ٣٠ | ٠.٣ | ٠.٠٥ | ٠.٩٨١٨٨١٦٧٧٢٥ ٣ |
| ٥ | ٥ | ٣٠ | ٠.٣ | ٠.٠٥ | ٠.٩٨١٨٥٠٧٣٤٨٣ ١ |
| ٦ | ٥ | ٣٠ | ٠.٣ | ٠.٠٥ | ٠.٩٨١٧٣٧٨٦٢٧٨ ١ |
| ٧ | ٥ | ٣٠ | ٠.٣ | ٠.٠٥ | ٠.٩٨١٤٨٩٢٣٧٨٠ ٢ |
| ٨ | ٥ | ٣٠ | ٠.٣ | ٠.٠٥ | ٠.٩٨١٥٨٠٩٣٦٦٨ |

| | | | | | |
|---------------|------|-----|----|---|----|
| ٥ | | | | | |
| ٠.٩٨١٧٣٧٨٦٢٧٨ | ٠.٠٥ | ٠.٣ | ٣٠ | ٥ | ٩ |
| ١ | | | | | |
| ٠.٩٨١٨٩١٠٠٩٥٥ | ٠.٠٥ | ٠.٣ | ٣٠ | ٥ | ١٠ |
| ١ | | | | | |

فيما يأتي استعراض لهيئات الصورة رقم (٣) مع صور الكيان الناتج والمطلوب فقط من عملية التجزئة



الهيئة ٥



الهيئة ٤



الهيئة ٣



الهيئة ٢



الهيئة ٩



الهيئة ٨



الهيئة ٧



الهيئة ٦



الهيئة ١٠

شكل(٤-٦): هيئات الصورة رقم (٣)



شكل(٤-٧): الكيانات: هيئات الصورة رقم (٣)

• صورة رقم (٤)

تمثل حركة رجل يركض وقد استعملنا المعاملات الأساسية في الجدول (٤-٦) لتجزئة الهيئة الأولى من الصورة

جدول (٤-٦) يمثل المعاملات الأساسية لتجزئة الهيئة الأولى للصورة (٤)

| صلاحية الفرد الأفضل | وزن صفة الموقع | وزن صفة اللون | عدد الدورات | حجم المجتمع | عدد العناقيد | تسلسل البيانات |
|---------------------|----------------------|---------------------|----------------|----------------|-----------------|-------------------|
| ٠.٩٨٣٣٢٩٦٩٩٦٨ ٤ | ٠.٠٥ | ٠.٣ | ٢٠ | ٣٠ | ٥ | A |
| ٠.٩٦٠٥٤٥٣٦٤٨١ ٥ | ٠.٠٥ | ٠.٩ | ٢٠ | ٣٠ | ٥ | B |
| ٠.٩٤٤٦٦٥٢٤١٧٥ ٠ | ٠.٣ | ٠.٧ | ٢٠ | ٣٠ | ٥ | C |

من

الجدول (٦-٤) لاحظنا تأثير تغيير الأوزان على صلاحية الفرد الأفضل عند بقاء معاملات التجزئة الأساسية الأخرى ثابتة حيث أن التوليفة A تحمل أعلى صلاحية للفرد بالإضافة إلى ذلك نلاحظ تأثير ذلك على الكيان الناتج من التجزئة كما يظهر في الشكل (٨-٤) الآتي:



شكل (٨-٤): مخرجات النظام المعرّج للهيئة الأولى للصورة رقم (٤)

النتائج المرئية أظهرت أن تجزئة الصورة بمعاملات التوليفة C على شكل الكيان المستخرج من التجزئة حيث ألحقت أجزاء من خلفية الشكل إلى الكيان، وهذا لا يحقق الهدف من التجزئة. وفيما يأتي جدول بالمعاملات الأساسية لتجزئة تسع هياكل متتالية للصورة رقم (٤)

جدول (٧-٤) المعاملات الأساسية لكل هياكل الصورة رقم (٤)

| صلاحية الفرد الأفضل | وزن صفة الموقع | وزن صفة اللون | حجم المجتمع | عدد العناقيد | تسلسل البيانات |
|---------------------|----------------------|---------------------|----------------|-----------------|-------------------|
| ٠.٩٨٣٦٨٧٣٢١٥٩ | ٠.٠٥ | ٠.٣ | ٣٠ | ٥ | ٢ |

| | | | | | |
|---------------|------|-----|----|---|----|
| ٠ | | | | | |
| ٠.٩٨٣٣٢٩٦٩٩٦٨ | ٠.٠٥ | ٠.٣ | ٣٠ | ٥ | ٣ |
| ٤ | | | | | |
| ٠.٩٨٢٨٦٨٢٤٠٧٦ | ٠.٠٥ | ٠.٣ | ٣٠ | ٥ | ٤ |
| ٣ | | | | | |
| ٠.٩٨٣٤٨١٨٠٣٠٧ | ٠.٥ | ٠.٥ | ٣٠ | ٥ | ٥ |
| ٦ | | | | | |
| ٠.٩٨٣١٢٠٤١٣١٠ | ٠.٥ | ٠.٥ | ٣٠ | ٥ | ٦ |
| ٥ | | | | | |
| ٠.٩٤٨١٠٣٢٤٧١٥ | ٠.٥ | ٠.٥ | ٣٠ | ٥ | ٧ |
| ٣ | | | | | |
| ٠.٩٤٨٠١٣٠٥٠٨٠ | ٠.٥ | ٠.٥ | ٣٠ | ٥ | ٨ |
| ٢ | | | | | |
| ٠.٩٨٢٦٢٧٨٩٦٦٠ | ٠.٥ | ٠.٥ | ٣٠ | ٥ | ٩ |
| ٧ | | | | | |
| ٠.٩٤٧٩١١٣٠٣٣١ | ٠.٥ | ٠.٥ | ٣٠ | ٥ | ١٠ |
| ٧ | | | | | |

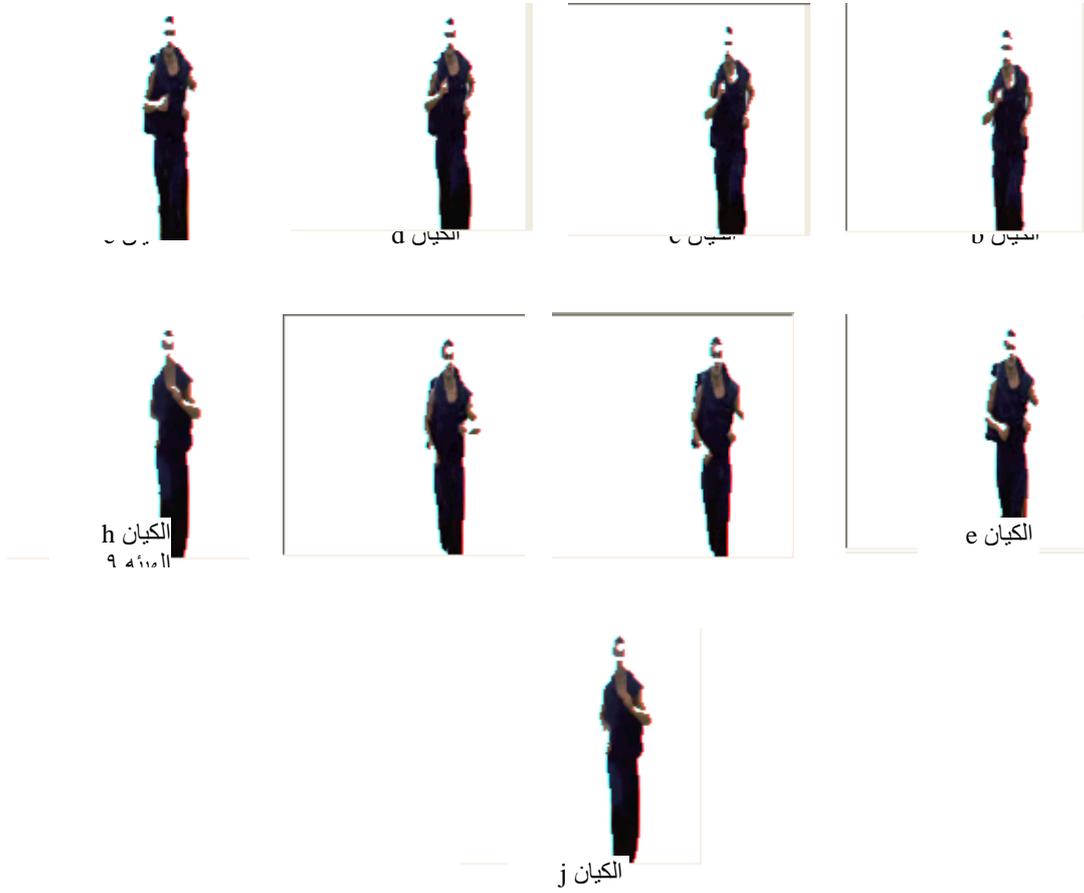
استعراض
الصورة
مع صور
الناتج
فقط من
التجزئة

فيما يأتي
لهيئات
رقم (٤)
الكيان
والمطلوب
عملية



الهيئة ١٠

شكل (٤-٩) هيايات الصورة رقم (٤)



شكل (٤-١٠): الكيانات الناتجة لكل هيايات الصورة رقم (٤)

• صورة رقم (٥)

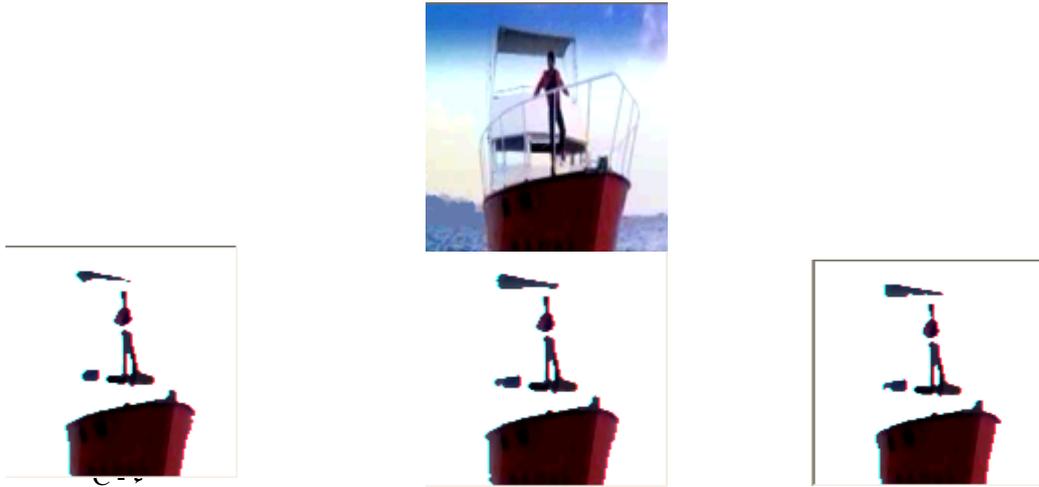
وهي صورة سفينة يقف عليه رجل وقد تم تجزئة الهيئة الأولى من الصورة بالمعاملات الأساسية الآتية:

جدول (٨-٤) المعاملات الأساسية لتجزئة الهيئة الأولى للصورة رقم (٥)

| صلاحيية الفرد الأفضل | وزن صفة الموقع | وزن صفة اللون | عدد الدورات | حجم المجتمع | عدد العناقيد | تصنيف |
|----------------------|----------------------|---------------------|----------------|----------------|-----------------|-------|
| ٠.٩٥٧٢٤٥٨٤٤٠.٨ ٧ | ٠.١ | ٠.٩ | ٢٠ | ٣٠ | ٥ | A |
| ٠.٩٥٢٩٨٥٥٦٣٢٥ ٦ | ٠.١ | ٠.٩ | ٢٠ | ٣٠ | ٤ | B |
| ٠.٩٤٣٨٤٨١٠.٥٤٩ ٤ | ٠.١ | ٠.٩ | ٢٠ | ٣٠ | ٣ | C |

من

الجدول (٨-٤) حاولنا إظهار تأثير تغيير عدد العناقيد عند بقاء المعاملات الأساسية الأخرى لتقسيم الصورة ثابتة وفيما يأتي الكيان الناتج من التجزئة باستعمال التوليفات المذكورة في الجدول (١٠-٤)



شكل (١١-٤): مخرجات النظام المقترح للهيئة الأولى للصورة رقم (٥)

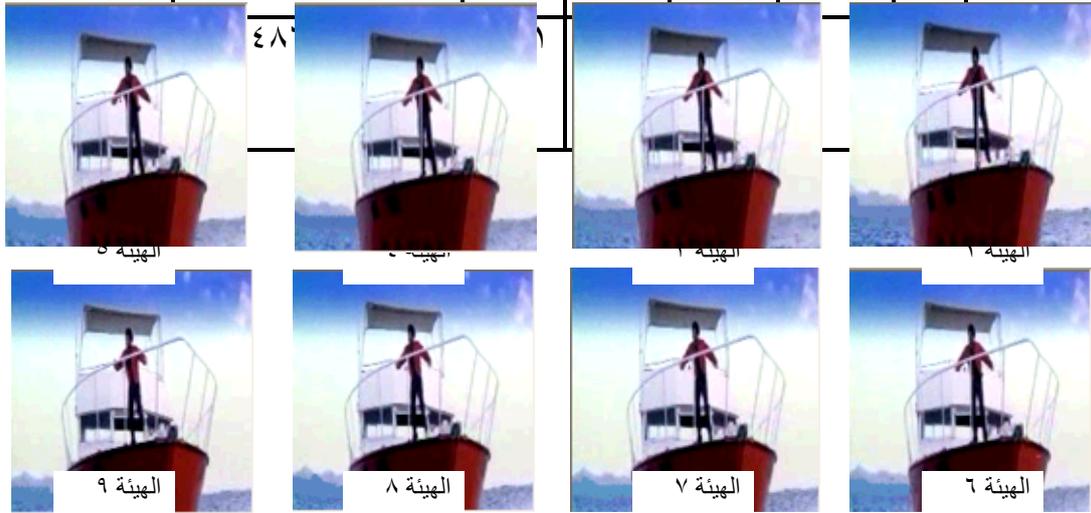
نلاحظ التشابه الكبير بين النتائج المرئية للكيانات الناتجة من التجزئة بالتوليفات المذكورة في الجدول (٨-٤) لذلك كان الاختيار حسب قيمة الصلاحيية الأكبر للفرد لذلك كانت التوليفة A هي الأفضل. وسنعرض المعاملات الأساسية المستعملة لتجزئة تسع هيئات متتالية للصورة رقم (٥).

جدول (٩-٤) المعاملات الأساسية لتجزئة هيئات الصورة رقم (٥)

| رقم الهيئة | عدد العناقيد | حجم المجتمع | وزن صفة اللون | وزن صفة الموقع | صلاحية الفرد الأفضل |
|------------|--------------|-------------|---------------|----------------|---------------------|
| ٢ | ٥ | ٣٠ | ٠.٩ | ٠.١ | ٠.٩٥٦٦٧٤٣٢٢٢١ ٣ |
| ٣ | ٥ | ٣٠ | ٠.٩ | ٠.١ | ٠.٩٥٢٣١٤٦٧٧٦٥ ٥ |
| ٤ | ٥ | ٣٠ | ٠.٩ | ٠.١ | ٠.٩٥٧٤٥٣٢١٩٩٥ ٥ |
| ٥ | ٥ | ٣٠ | ٠.٩ | ٠.١ | ٠.٩٥٤٦٧٨٢٣١٢١ ١ |
| ٦ | ٤ | ٣٠ | ٠.٩ | ٠.١ | ٠.٩٥٥٤٦١٢٨٦٢٥ ٩ |
| ٧ | ٣ | ٣٠ | ٠.٩ | ٠.١ | ٠.٩٤٨٤٠٠٦٢٠٤٤ ٧ |
| ٨ | ٣ | ٣٠ | ٠.٩ | ٠.١ | ٠.٩٤٧٥٤٦٣٦٥٥٥ ٧ |
| ٩ | ٣ | ٣٠ | ٠.٩ | ٠.١ | ٠.٩٤٨١٣٥٥٧٩٧٢ ٧ |

استعراض الصورة مع صور الناتج فقط من التجزئة.

فيما يأتي لهيئات رقم (٥) الكيان والمطلوب عملية



الهيئة ١٠

شكل (٤-١٢): هياكل الصورة رقم (٥)



شكل (٤-١٣): الكيانات الناتجة لكل هياكل الصورة رقم (٥)

• صورة رقم (٦)

وهي تمثل حركة قطه وقد تم استعمال المعاملات الأساسية الآتية لتجزئة الهيئة الأولى من الصورة.

جدول (٤-١٠): المعاملات الأساسية لتجزئة الهيئة الأولى للصورة رقم (٦)

| صلاحيه الفرد الأفضل | وزن صفة الموقع | وزن صفة اللون | عدد الدورات | حجم المجتمع | عدد العناقيد | نوع النتيجة |
|---------------------|----------------------|---------------------|----------------|----------------|-----------------|----------------|
| ٠.٩٦٦٩٢٢٢٩٨١٨ ١ | ٠.٣ | ٠.٧ | ٢٠ | ٣٠ | ١٠ | A |
| ٠.٩٦٤٩٤٥٤١٥٩٣ ١ | ٠.٣ | ٠.٧ | ٢٠ | ٣٠ | ٧ | B |
| ٠.٩٦٦٤٩٣٩٣١٩٥ ٤ | ٠.٣ | ٠.٧ | ٢٠ | ٣٠ | ١١ | C |

من

الجدول (٤-١٠) حاولنا معرفة تأثير تغيير عدد العناقيد مع ثبوت المعاملات الأساسية الأخرى على نتائج التجزئة. ولقد حصلنا على أكبر قيمة صلاحية عندما كانت عدد العناقيد ١٠ وفيما يأتي الكيان الناتج من التجزئة باستعمال المعاملات في الجدول (٤-١٠)



شكل (٤-١٤): مخرجات النظام المقترح للهيئة الأولى للصورة رقم (٦)

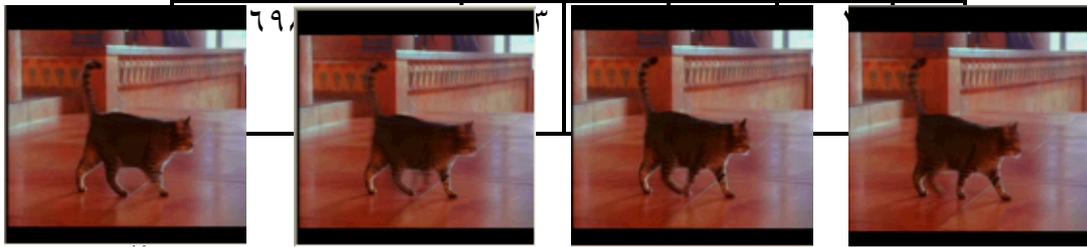
يتبين من الشكل (٤-١٤) أن التوليفة A كانت الأفضل في استخراج الكيان (القطه) كاملا وبدون أي إضافات وفيما يأتي جدول بكل المعاملات الأساسية المستخدمة لتجزئة تسع هيئات متتالية للصورة الحركية رقم (٦)

جدول (٤-١٢): المعاملات الأساسية لتجزئة تسع هيئات متتالية للصورة رقم (٦)

| رقم الهيئة | عدد العناقيد | حجم المجتمع | وزن صفة اللون | وزن صفة الموقع | صلاحية الفرد الأفضل |
|------------|--------------|-------------|---------------|----------------|---------------------|
| ٢ | ١٢ | ٣٠ | ٠.٧ | ٠.٣ | ٩.٦٦٤٣٧٦٥٣٣٣٢ ١ |
| ٣ | ١٠ | ٣٠ | ٠.٧ | ٠.٣ | ٠.٩٥٩٨٧٦٥٦٥٦٧ ٦ |
| ٤ | ١٠ | ٣٠ | ٠.٧ | ٠.٣ | ٠.٩٥٩٨٧٧٩٧٤٤٢ ٢ |
| ٥ | ١٠ | ٣٠ | ٠.٧ | ٠.٣ | ٠.٩٥٩٩٩٨٧٢٣١١ ٥ |
| ٦ | ١٠ | ٣٠ | ٠.٧ | ٠.٣ | ٠.٩٥٨٧٦٦٣٢٤٤٣ ٥ |
| ٧ | ١٢ | ٣٠ | ٠.٧ | ٠.٣ | ٠.٩٦٤٥٦٥٤٤٣٢١ ١ |
| ٨ | ١٢ | ٣٠ | ٠.٧ | ٠.٣ | ٠.٩٦٤٥٥٤٣٥٥٤٢ ١ |
| ٩ | ١١ | ٣٠ | ٠.٧ | ٠.٣ | ٠.٩٦٣٤٥٤٨٩٠٧٦ ٥ |

استعراض
الصورة
مع صور
الناتج
فقط من
التجزئة

فيما يأتي
لهيئات
رقم (٦)
الكيان
والمطلوب
عملياً





الهيئة ١٠

شكل (٤-١٥): هينات الصورة رقم (٦)



شكل (٤-١٦): الكيانات الناتجة لكل هينات الصورة رقم (٦)

• صورة رقم (٧)

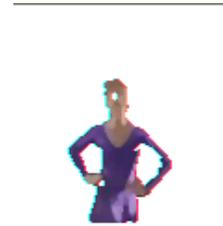
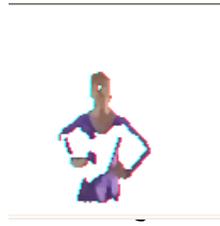
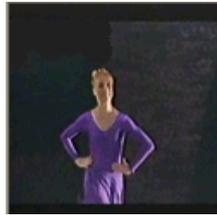
تمثل حركة امرأة وفيما يأتي المعاملات الأساسية لتجزئة الهيئة الأولى من الصورة

جدول (٤-١٢) المعاملات الأساسية لتجزئة الصورة رقم (٧)

| صلاحيه الفرد الأفضل | وزن صفة الموقع | وزن صفة اللون | عدد الدورات | حجم المجتمع | عدد العناقيد | نوع النتيجة |
|---------------------|----------------------|---------------------|----------------|----------------|-----------------|----------------|
| ٠.٩٧٤٢٧٣٨٩٧٥٣ ٦ | ٠.١ | ٠.٩ | ٢٠ | ٣٠ | ٣ | A |
| ٠.٩٧٥٤٧٠٩٢٦٣٢ ١ | ٠.١ | ٠.٩ | ٢٠ | ٤٥ | ٣ | B |
| ٠.٩٧٤٢٧٤١٦٤٥٨ ١ | ٠.١ | ٠.٩ | ٢٠ | ٦٠ | ٣ | C |

من

الجدول يظهر تأثير تغيير حجم المجتمع على صلاحية الفرد الأفضل فكانت اكبر صلاحية للفرد عندما حجم المجتمع هو ٤٥ لكن النتائج المرئية أظهرت غير ذلك وكما يأتي:



شكل (٤-١٧): مخرجات النظام المقترح للهيئة الأولى للصورة رقم (٧)

من الشكل (٤-١٧) يظهر أن الصورة A هي الأفضل أي عندما يكون حجم المجتمع يساوي ٣٠ رغم أن قيمة الصلاحية للفرد الناتج اقل وبالآتي تم اختيارها لصورة A أو الكيان ذو

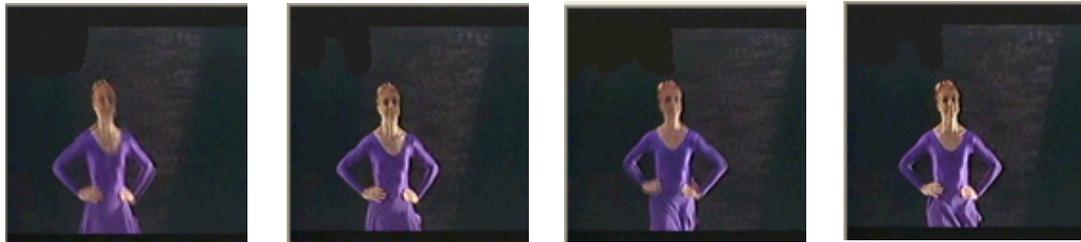
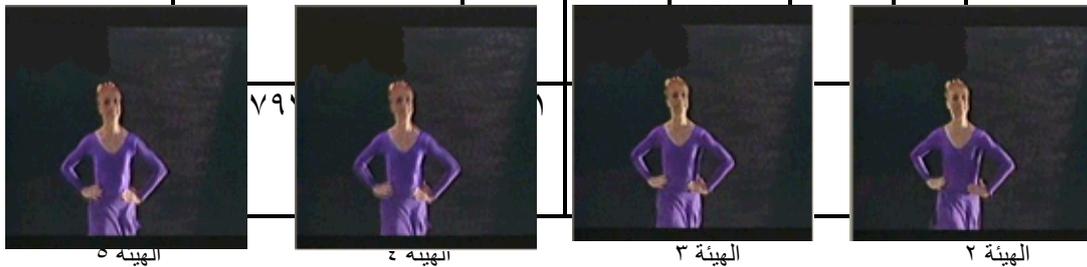
التوليفة A ليتم تدريب الشبكة عليه في المرحلة القادمة. وفيما يأتي جدول بكل المعاملات الأساسية المستخدمة لتجزئة تسع هيئات متتالية للصورة الحركية رقم (٧).

جدول (٤-١٣): المعاملات الأساسية لتجزئة الهيئات المتتالية للصورة رقم (٧)

| رقم الهيئة | عدد العناقيد | حجم المجتمع | وزن صفة اللون | وزن صفة الموقع | صلاحية الفرد الأفضل |
|------------|--------------|-------------|---------------|----------------|---------------------|
| ٢ | ٣ | ٣٠ | ٠.٩ | ٠.١ | ٠.٩٧٥٨٦٢١٥٨٧٢ ٥ |
| ٣ | ٣ | ٣٠ | ٠.٩ | ٠.١ | ٠.٩٧٥٥٨٤٥٠.٣٩٥ ٤ |
| ٤ | ٣ | ٣٠ | ٠.٩ | ٠.١ | ٠.٩٧٩٩٣١٠.٣٧٥ ٩ |
| ٥ | ٣ | ٣٠ | ٠.٩ | ٠.١ | ٠.٩٧٤٧٧١٣٦٦٣٣ ٦ |
| ٦ | ٤ | ٣٠ | ٠.٧ | ٠.٣ | ٠.٩٦٦٩٢٥١٢٠.١٨ ٩ |
| ٧ | ٤ | ٣٠ | ٠.٧ | ٠.٣ | ٠.٩٧٤٩٣١٠.٣٧٥ ٩ |
| ٨ | ٥ | ٣٠ | ٠.٧ | ٠.٣ | ٠.٩٧٠٨٦٦٥٤٣٢٧ ٨ |
| ٩ | ٥ | ٣٠ | ٠.٩ | ٠.١ | ٠.٩٧٩٢٨٩٦٥٠.٩٨ |

استعراض
الصورة
مع صور
الناتج
فقط من
التجزئة.

فيما يأتي
لهيئات
رقم (٧)
الكيان
والمطلوب
عملية



أما المرحلة الآتية فهي استخراج الصفات للكيانات التي تم الحصول عليها من عملية التجزئة السابقة، وكما ذكرنا سابقاً فإن الصفات هي ٨ صفات لتوقيع الكفافات و ٥ صفات لصفات المدرج التكراري فيصبح المجموع ١٣ صفة وبما أن الصورة هي صورة ملونة أي أن عنصر الصورة الواحد يتكون من ثلاثة قيم للألوان وهي (الأحمر والأخضر والأزرق) لذا فقد تم حساب المعدل الحسابي لهذه الألوان في عنصر الصورة الواحدة.

٣-٤ التصنيف

لقد تم تدريب شبكة Neo-cognitron العصبية على الكيانات المستخرجة من الهيئات الأربعة الأولى لكل صورة من الصور الحركية ذات الأرقام (٢ و ٣ و ٤ و ٥ و ٦ و ٧) والتي تم تجزئتها بواسطة خوارزمية breeder الجينية.

ولذا كان نمط الإدخال يتكون من (٤ × ١٣) خليه حيث ١٣ هو عدد الصفات لكل كيان و ٤ هو عدد الكيانات التي تم التدريب عليها، أما الشبكة العصبية فهي مكونة من مرحلتين أي أربع طبقات بالإضافة إلى طبقة الإدخال وكل طبقة تتكون من ١٣ مستو خليه وعدد الخلايا في كل مستو خليه للطبقة الأولى US_1 هو ٤ لتتقلص إلى ٢ خليه في كل مستو خليه في الطبقة UC_1 أما الطبقة US_2 فتتكون من خليتين في كل مستو خليه أما الطبقة الأخيرة وهي طبقة الإخراج فكل مستو خليه سيحتوي على خليه واحده فقط. وكانت المعاملات المستخدمة في تدريب الشبكة كما في الجدول (٤-١٤):

جدول (٤-١٤): المعاملات الأساسية المستخدمة لتدريب الشبكة

| | |
|--|------|
| عدد الحقول المستلمة في المرحلة الأولى : | ٣ |
| عدد الحقول المستلمة في المرحلة الثانية : | ٢ |
| قيمة r_1 : | ٠.١ |
| قيمة r_2 : | ٠.٠١ |
| قيمة q_1 : | ٩ |
| قيمة q_2 : | ٣ |
| قيمة α : | ٩ |

أما قيم طبقة الإدخال

جدول (٤-١٥): قيم المخرجات لطبقة الإخراج

| الكيان | قيمة إخراج الخلية | رقم الصنف (رقم خلية القرار) |
|--------------|-------------------|-----------------------------|
| أقدام | ٢١٨.٧٤٣٤١٢٨٤٥٥٠.٣ | ٦ |
| طائره مروحيه | ٦٦٩٦٢.٢٥٣٥٧٥٧١٢٤ | ٥ |

| | | |
|----------|------------------|----|
| رجل يركض | ١٩٥.٧٢٣٥٦٨٧٢٢٥٤ | ١١ |
| سفينة | ١٨٦.١٠٢٤٥٩٤٢٨٤٨١ | ١٢ |
| قطه | ٣٥٩٥٩.٧٤٠٠٠٤٨٢٤٩ | ٨ |
| امراة | ٧٥١٨١.٤٧٤٦٨١٨٦١٢ | ٧ |

وفيما يأتي جدول (٤-١٦) الذي يمثل كل المعاملات الأساسية لتدريب الشبكة والتي تمت تجربتها لمعرفة تأثيرها على قيمة الخلايا في طبقة القرار .

جدول (٤-١٦): المعاملات الأساسية المستخدمة في تدريب شبكة Neo-cognitron العصبية

| التوليفة | r ¹ | r ² | q ¹ | q ² | α |
|----------|----------------|----------------|----------------|----------------|----------|
| A | ٠.١ | ٠.٠١ | ٩ | ٣ | ٩ |
| B | ١ | ٠.٠١ | ٩ | ٣ | ٩ |
| C | ١.٥ | ٠.٠١ | ٩ | ٣ | ٩ |
| D | ١.٥ | ١ | ٩ | ٣ | ٩ |
| E | ١.٥ | ١.٥ | ٩ | ٣ | ٩ |
| F | ١.٥ | ٠.١ | ٩ | ٣ | ٩ |
| G | ٠.١ | ٠.٠١ | ٢ | ٣ | ٩ |
| H | ٠.١ | ٠.٠١ | ٠.١ | ٣ | ٩ |
| I | ٠.١ | ٠.٠١ | ٢ | ٠.١ | ٩ |
| J | ٠.١ | ٠.٠١ | ٩ | ٣ | ٠.١ |

جدول (٤-١٧)
الإخراج للخلايا

وفيما يأتي
الذي يمثل قيم

في طبقة القرار للتوليفات المذكورة في الجدول (٤-١٦) مع أرقام خلايا القرار أو الصنف.

جدول (٤-١٧): قيم خلايا الإخراج لتوليفات مختلفة

| التوليفة | الصنف ٦ | الصنف ٥ | الصنف ١١ | الصنف ١٢ | الصنف ٨ | الصنف ٧ |
|----------|-------------|--------------|--------------|-------------|--------------|--------------|
| A | ٢١٨٧٤٣٤١٢٨ | ٦٦٩٦٢.٢٥٣٥٧ | ١٩٥.٧٢٣٥٦٨٧ | ١٨٦.١٠٢٤٥٩٤ | ٣٥٩٥٩.٧٤٠٠٠ | ٧٥١٨١.٤٧٤٦٨ |
| B | ٢١٨.٧٤٣٤١٢٨ | ٦٦٩.٠٢.٢٥٣٥٧ | ١٩٥.٧٢٣٥٦٨٧ | ١٨٦.١٠٢٤٦٤٩ | ٣٥٩٥٩.٧٤٠٠٠ | ٧٥١٨١.٤٧٦٨١ |
| C | ١٦٢٨١.٠٥٨١٤ | ٥٢٣٢١٣.١٦٢٠ | ١٥٣٢٦.٤٠٥٥٧ | ١٤٧١٨.٤٢٠٠٤ | ٤٢٣٣٢٨.٨٣٠٦ | ٥٢٨٤.٠٢.٠٦٨٤ |
| D | ٢١٦٢٨.٤٥١٣٩ | ٥٣٥٥١١.٠٩٥١ | ٢٠.٧١٩.٥٠٢٩٤ | ١٩٩٦٨.٥٩٥٦٢ | ٤٣٩٢٦.٠.٩٨٨٦ | ٥٣٩٣٤٩.٥٠٩٩ |

| | | | | | | |
|---------------|---------------|--------------|--------------|----------------|--------------|---|
| ٣٤١٣٣٧.٨٩٥٩ | ٢١٣٨٧٨.٠٥٧٧ | ١٨١٧.٣٣٩٣٢١ | ١٩٠.٩.١٥٣٦٤٦ | ٣٢٢٩٦.٩١٣٥ | ٢١٢١.١٨٦٩٨٥ | E |
| ١٨٤٣٥.٢٦٧٥٧ | ٨٢٧٩.٩٥٢١٨.٠ | ١٦٠.٤٦٧٥.٠٠٢ | ١٩٥.٧٢٣٥٣١٦ | ١٦١٨٧.٧٥٤١٧ | ٢١٨.٧٤٣١٤٨١ | F |
| ١٨٤٣٥.٢٦٧٥٧.٠ | ٨٢٧٩.٩٥٢١٥.٠ | ١٦٠.٤٦٧٥.٠٠٢ | ١٩٥.٧٢٣٥٣١٦ | ١٦١٨٧.٧٥٤١٧ | ٢١٨.٧٤٣١٤٨١ | G |
| ٧٢١.٦٣٨٩٢٦٨٢ | ١٧٥.٥١٧.٠٤٢٥ | ١٠٦.٥٢٤.٠٩٥٤ | ١٩٥.٧٢٢٦٢٥٧ | ٦١٣.٨.٩٩٨٦٦ | ٢١٨.٧٣٦٦٨٣٢ | H |
| ١٨٤٥٧.٦٨٦٧٥٧ | ٨٣٠.١.١١.٠٣٤٠ | ١٧٧.٤٣٧١٥٨.٠ | ٢١٥.٩٣٥٤٨٩٨ | ١٦٢٠.٩.٩١٣٥١.٠ | ٢٣٨.٩٤٥١٣٩٩ | I |
| ٩٢٣٨٣٣.٨٤٣٧٩ | ٨٤٩٦٥٥.٦٧١٤ | ٧٧٢٢.٧٨٢٨٦ | ٢٧٣٤٩.٥٢٤٧١ | ٩١٤٩١٣.٦٧٣٣١ | ٣٠.٧٢٠.٧٦٩٦٦ | J |

من الجدولين السابقين نلاحظ تأثير المعاملات الأساسية للتدريب على قيم نتائج خلايا الصنف ومن المفضل اختيار المعاملات التي تجعل الفروقات كبيره بين قيم خلايا الصنف مما يجعل منطقة القرار اكبر وأفضل ولاحظنا من الجدول أن الزيادة في قيمة r_2 تجعل قيمة إخراج الخلايا اكبر وكلما كانت قيم r_2 اصغر من r_1 فإن قيمة إخراج الخلايا ستكبر، وصغر قيمة q_1 يصغر قيم إخراج الخلايا وكلما كانت قيمة q_2 اقل من قيمة q_1 فستكبر قيمة إخراج الخلايا. النقصان في قيمة α يجعل قيمة إخراج الخلايا اكبر.

الجدول (٤-١٨) يظهر تأثير عدد الحقول المستلمة في المرحلة الأولى و عدد الحقول المستلمة في المرحلة الثانية وتأثيرها على نتائج طبقة القرار عندما المعاملات الأساسية المستخدمة في تدريب الشبكة هي المعاملات نفسها للتوليفة A في الجدول (٤-١٦).

جدول (١٨-٤): تأثير التغيير في عدد الحقول المستلمة في المرحلتين

| | | | | | | | |
|------------|----------|----------|----------|---------|---------|---|--|
| | | | | | | ٢ | عدد الحقول المستلمة في المرحلة الأولى |
| | | | | | | ٢ | عدد الحقول المستلمة في المرحلة الثانية |
| ١٠٦.٥٨٦.٠٧ | ١٨٤.٦٩٦٢ | ٢٥٦٦.١٩٣ | ١٦٣٣.٥٣٣ | ٣٥٨.٨٩٢ | ٦٨٦٩١.١ | | قيم خلايا الإخراج |
| ٣ | ١ | ١ | ٢ | | | | |
| ١ | ١١ | ٦ | ٥ | ١٠ | ٧ | | رقم الخلية |

(أ)

| | | | | | | | |
|-----------|----------|----------|----------|---------|----------|---|--|
| | | | | | | ٤ | عدد الحقول المستلمة في المرحلة الأولى |
| | | | | | | ٢ | عدد الحقول المستلمة في المرحلة الثانية |
| ١٧٨.٩٧٣٤٤ | ٣٩٣٩٦.٠١ | ٢٣٠.٥٢٨٣ | ٢٠٠.٣٩٤٥ | ١٤١.٦٨٩ | ٥١٩١٥٦.١ | | قيم خلايا الإخراج |
| ١ | ٥ | ١٣ | ٥ | ٨ | ٩ | | رقم الخلية |

(ب)

| | | | | | | | |
|-----------|----------|----------|----------|---------|----------|---|--|
| | | | | | | ٣ | عدد الحقول المستلمة في المرحلة الأولى |
| | | | | | | ١ | عدد الحقول المستلمة في المرحلة الثانية |
| ٣٧٧.٩٩٤٦٠ | ٢١٣.٥٢٥٥ | ١١٢.٥٠١٧ | ٩٥.٥٦٩٢١ | ١٨٣.٤٤٨ | ١٧٥٠.١.٢ | | قيم خلايا الإخراج |
| ٩ | ٤ | ٥ | | | | | |
| ٤ | ٤ | ٤ | ٢ | ٢ | ٧ | | رقم الخلية |

(ج)

من الجدول (١٨-٤) نلاحظ أن التغيير في عدد الحقول المستلمة في أي من المرحلتين يؤثر على نتائج التصنيف بصورة كبيرة وقد لا يصنف بصورة صحيحة كما في الحالة (ب) و(ج) حيث نلاحظ انه لا يمكن التكهن بالنتائج التي ستظهر عند التغيير في عدد الحقول المستلمة لأي من المرحلتين .

عندما قمنا بتدريب شبكة Neo-cognitron العصبية باستخدام التوليفة A من المعاملات الأساسية والمذكورة في الجدول (٤-١٦) تم التعرف على جميع الكيانات المستخلصة من الهيئات الأربع الأولى للصور الحركية الموصوفة سابقا والتي تم تدريب الشبكة عليها. وفيما يأتي جدول بكل الكيانات (التي تم التعرف عليها والتي لم يتم التعرف عليها) لست هيئات متتالية لكل الصور الحركية التي تم تدريب الشبكة عليها حيث كل واحد من هذه الهيئات تحتوي على نسبه من التشويه أو الاختلاف عن الهيئة السابقة لها .

جدول(٤-١٩): الكيانات التي تم تعرف شبكة Neo-cognitron العصبية

| رقم الصورة | الكيان e | الكيان f | الكيان g | الكيان h | الكيان i | الكيان j | نسبة التمييز |
|------------|----------|-----------|-----------|----------|-----------|-----------|--------------|
| ٢ | مطابق | مطابق | مطابق | مطابق | مطابق | مطابق | ١٠٠% |
| ٣ | مطابق | غير مطابق | غير مطابق | مطابق | مطابق | مطابق | ٦٦.٦% |
| ٤ | مطابق | مطابق | مطابق | مطابق | غير مطابق | غير مطابق | ٦٦.٦% |
| ٥ | مطابق | مطابق | مطابق | مطابق | مطابق | مطابق | ١٠٠% |
| ٦ | مطابق | مطابق | مطابق | مطابق | مطابق | مطابق | ١٠٠% |
| ٧ | مطابق | غير مطابق | مطابق | مطابق | غير مطابق | غير مطابق | ٥٠% |

حيث رقم الصورة يمثل رقم الصورة الحركية ، أما الكيانات e,f,g,h,i,j فتمثل اسم الكيان المستخلص من الهيئات المتتالية للصورة الحركية.

٤-٤ الاستنتاجات

لقد أظهرت خوارزمية Breeder الجينية لتجزئة الصورة بساطتها وسهولة تنفيذها بمتطلبات حسابيه وخزنيه قليله نسبة إلى الطرق السابقة للتجزئة إذ لا تحتاج إلى حسابات معقدة وإنما تعتمد الأسلوب المباشر في انجازها لعملية التجزئة، وكذلك اثبت استعمال خوارزمية Breeder الجينية سرعة الوصول إلى الحل المطلوب بسبب استخدامها لطريقة الانتقاء المعتمدة على انتقاء أفضل %T فرد لذلك كانت أسرع في الوصول إلى الحل الأفضل من الخوارزمية الجينية البسيطة، كذلك لاحظنا أن تأثير الطفرة كان كبيرا مما زاد في نوعية المجتمع، على الرغم من عدم وجود قابليه للتنوع في عملية التزاوج ، ودلت النتائج أيضا على اعتماد المعاملات

الخاصة بطريقة التجزيء المقترحة على العوامل الجينية المستخدمة وكذلك على الصور المراد تجزئتها

- إن عملية التجزئة تساعد في تحديد المواصفات المناسبة للكيانات المطلوب تصنيفها .
- حاولنا استخدام طريقه لإيجاد عدد العناقيد أليا عن طريق حساب قيمة التكرارات اللونية للصورة وأخذ أكبر القيم ، ولكن تبقى مشكلة تحديد العتبة المناسبة والتي تحقق عدد العناقيد المناسبة للحصول على الكيان المطلوب فبذلك كانت الطريقة غير ناجحة في تحديد عدد العناقيد.

أما في طريقة التصنيف فقد أثبتت شبكة Neo-cognitron العصبية إمكانيتها في تصنيف الصور بصورة جيدة حتى عند استخدام صفات للصورة رقميه كمدخلات للشبكة بدلا من القيم الثنائية التي تم تصميم الشبكة عليها لتمييز الأحرف المكتوبة بخط اليد ولاحظنا السرعة العالية للشبكة في التدريب ، وكذلك الاختبار نسبة إلى السرعة المعهودة في الشبكات العصبية الأخرى .

- لاحظنا صعوبة تحديد المعاملات الأساسية المستخدمة في تدريب الشبكة حيث تعتمد على التجربة لإيجاد الأفضل ، والتي تحقق فروقات كبيره بين قيم الإخراج أي منطقة القرار حيث كانت تعتمد اعتمادا كبيرا على مجموعة الأنماط المراد التعرف عليها ، وبالرغم من الصعوبة الموجودة في معرفة كيفية اختيار هذه المقاييس المثالية بدقه لكننا نستطيع أن نشير إلى ما يأتي:

حجم الـ (V) في معادلة استخراج US_1 , UC_1 والتي تحدد الانتشار الحيزي لارتباطات الإدخال المنشطة لخلايا S لها تأثير على عملية التصنيف حيث تؤثر على رقم الخلية الفائزة.

- العدد المطلوب من مستويات الخلايا في المرحلة الأولى وبالتحديد في الطبقة الأولى من الشبكة يكون معتمدا على عدد الصفات المحددة للنمط المراد تدريبه.
- عدد التشوهات المراد تدريب الشبكة عليها لكل نمط مدخل يكون غير محدد وكلما كبر كان أفضل لتحقيق الهدف من الشبكات العصبية وهو العمومية.
- عند زيادة عدد الصفات المستخرجة من الكيان ستزداد أبعاد النمط المدخل وبالتالي سيؤثر على نسبة التمييز ووقت التعلم ووقت التمييز.

٤-٥ الأعمال المستقبلية

- ١- توجد صعوبة في عملية ضبط المعاملات الأساسية المستعملة في طريقة التجزئة الجينية التي تتضمن وزن واصفة اللون ووزن واصفة الموقع وحجم المجتمع.....، الخ لذلك يمكن دراسة إمكانية تهجين الخوارزمية الحية مع تقنيات أخرى لإيجاد القيم المناسبة للحصول على أفضل استخراج للكيان من الصورة.
- ٢- لجعل الطريقة المقترحة قادرة على تحديد عدد العناقيد ألياً يجب توفير مقياس قادر على تمييز العدد الصحيح من العناقيد. وعند توفر هذا المقياس يمكن بعد ذلك استخدام كروموسومات مختلفة الأطوال وانتقاء أفضلها.
- ٣- يمكن تحديد المعاملات الأساسية المرغوبة في تدريب شبكة Neo-cognitron العصبية عن طريق استعمال الخوارزميات الجينية لانتقاء أفضل تدريب للشبكة.
- ٤- يمكن استخلاص صفات أخرى من الكيان وإضافتها إلى الصفات السابقة لتعطي قوة أكثر لعملية التصنيف.
- ٥- هناك أنواع أخرى من التدريب لشبكة Neo-cognitron العصبية بالإضافة إلى التدريب الغير مشرف عليه يمكن تطوير عمل الشبكة ليصبح بإمكانها التدريب باستخدام الأنواع الأخرى من التدريبات وهي التدريب المشرف عليه بالإضافة إلى النوع الذي يعتمد على تدريب الشبكة باستعمال النوعين المشرف عليه وغير المشرف عليه.

المصادر باللغة الإنكليزية

- [١] S.E.Umbaugh,' Computer Vision And Image Processing', Prentice Hall,NJ.,USA,١٩٩٨.
- [٢] y.h.Pao,' Adaptive Pattern Recognition ' ,Addison.Wesley,Reading MA.,١٩٨٩.

- [٣] A.S.Pandya ,and R.B.Macy,' Pattern Recognition with Neural Network in C++',CRC Press.Inc.,Florida,١٩٩٦.
- [٤] R.O.Duda,' Ellements of Pattern Recognition in Adaptive Learning And Pattern Recognition Systems ',Academic Press,N.J.,١٩٧٠.
- [٥] R.C. Gonzalez,and R.E. Wood,' Digital Image Processing ',Addition -Wesely,Reading MA.,١٩٩٢.
- [٦] L.A.Zadeh.' Fuzzy logic , neural networks and soft computing', communications of the ACM٣٧(٣) (١٩٩٤)٧٧-٨٤.
- [٧] Yuehnicen,'Hybrid Soft Computing Approach to Identification and Control of Non linear systems',PH.D.Thesis,Kumamoto University ,February,٢٠٠١.
- [٨] 'Adefinition of Soft Computing –Adapted from L.A.Zadeh' ,www.soft computing.de/jin-html.
- [٩] R.de Kok,T.Schneider,U.Ammer,' Object-Based Classification and applications in the Alpine Forest Environment ',International Archives of Photogrammetry and Remote Sensing,Vol,٣٢,part ٧-٤-٣,June,١٩٩٩.
- [١٠] R.Kh.Sadykov,M.E.Vatkin,'An Application of Neo-cognitron Neural Network for integral chip Images Processing , Sadykov@gw.bsuir-unibel.by ,Vatkin @tut.by
- [١١] Z. Long ,'The Design and Implementation of An Image Segmentation System for Forest Image analysis ',MSC Thesis, Mississippi State University ,August ٢٠٠١.
- [١٢] L. Lepisto,L.ivari Kunttu,J. Autio,A.Visa,' Rock Image Classification Using Non-Homogenous Textures an Spectral Imaging ',Czech Republic, copyright UNION, Agency-Science Press,٢٠٠٣.
- [١٣] S. H. Ali,' Designing a software for classifying objects

for Air Photos and Satellite images using Soft computing' , MSC .
Thesis .Babylon University ,٢٠٠٥.

- [١٤] M. A.Salman,'Extracting Rules from Data Base Using Soft computing ' , MSC. Thesis,٢٠٠٥.
- [١٥] A. Bower,'Soft Computing ' ,Tessella support services PLC, Issue V١.R١.MO,July ٢٠٠٣.
- [١٦] J.M.Zurada,' Introduction to Artificial Neural Systems ' ,JAICO Publishing House ,Bombay,India,١٩٩٧.
- [١٧] J. Ramik,'Soft Computing: Overview And Recent Development in Fuzzy optimization',Listopad ٢٠٠١.
- [١٨] A.K.Jain , 'Fundamentals Of Digital Image Processing ' ,Printice Hall of India ,New Delhi,١٩٨٩.
- [١٩] W.Niblack,'An Introduction to Digital Image Processing ' ,Prentice-Hall ,New Jersey,١٩٨٦.
- [٢٠] M.Luise,'Bit-Mapped Graphics Programming in C++', Addition. Wesley,Reading MA.,١٩٩٣.
- [٢١] M.J.Dallwity٢,'An Introduction to Computer Image',٢ August ٢٠٠٤.
- [٢٢] D.Lancaster , 'Exploring The BMP File Format ' ,copyright ٢٠٠٣.
<http://www.tinaji.com>
- [٢٣] E.H.Obeed , 'Parallel Structure For Image Compression Using Neural Network ' ,MSC Thesis,Babylon University ,٢٠٠٣.
- [٢٤] T.J. Tou,R.C.Gonzalez,' Pattern Recognition Principles ' ,Addition. Wesely , Reading MA.,١٩٧٤.
- [٢٥] D.Phillips,'Image Processing in C',BPB publications, New Delhi, ١٩٩٥.
- [٢٦] B.Bhann,B.A.Parvin,' Segmentation of Natural Image ' ,Pattern Recognition ,٢٠,٥,٤٨٧,(١٩٨٧).
- [٢٧] A,K.Jain,M.N.Murty,P.J.Flynn,' Data clustering : A review ,ACM

- computing Surveys', 3, 31, 264, (1999).
- [28] Z.Hussain, 'Digital Image Processing :Practical Application of Parallel Processing Techniques', Eliss Horwood, Wiltshire, 1991.
- [29] R.H.Turi, S.Ray, 'An Application Of Clustering In Colour Image Segmentation ', Proceedings of the 7th International Conference on control , Automation ,Robotics and Vision(ICARCV '2000), Singapore, 2000.
- [30] P.Franti, J.Kivijarvi, T.Kankoranta, O.Nevalainen, 'Genetic Algorithms For Large Scale Clustering problems ', The computer Jornal, 9, 40, 547, (1997).
- [31] K.S.Fu ,J.K.Mui , 'Asurvey On Image Segmentation , Pattern Recognition' , 13, 1, 3, (1981).
- [32] R.M.Haralick, L.G.Shapiro, 'Survey Image Segmentation Techniques ,Computer Vision, Graphics And Image Processin, 2a, 1, 100, (1980).
- [33] S.Ray, R.H.Turi, ' Determination Of Number Clusters in K-means Clustering and Application in Colour Image Segmentation Proceedings of the 4th International Conference on Advances in Pattern Recognition and Digital Techniques (ICAPRDT'99) ,Calcutta, 137, (1999).
- [34] M.D.Levine , A.M.Nazif , 'Dynamic Measurement of Computer Generated Image Segmentation' , IEEE Transactions on Pattern Analysis and Machine Intelligence, PAMI-7, 2, 100, (1980).
- [35] S. J.Sangwine , R.E.N.Home, ' The colour Image processing handbook', chapman&Hall, London, 1998.

- [36] B.Mccone,'On the Evaluation of Image Segmentation Algorithms, proceeding of Digital Image computing:Techniques and Applications', 400,(1997).
- [37] K.Deb,' Genetic Algorithm in Search and Optimization : The Technique and Applications ,Proceedings of International Workshop on Soft Computing and Intelligent Systems,Calcutta,08,1998.
- [38] D.E.Goldberg.' Genetic Algorithms in Search Optimization and Machine Learning ',Addison-Wesly,Massachusetts,1989.
- [39] H.Mühlenbein and D.S. Voosen ,'The Science of Breeding and its Application to the Breeder Genetic Algorithm, Evolutionary computation',1:330-360,1994a.
- [40] D.Quagliarella,J.Periaax,C.Poloni,G.Winter,' Genetic Algorithm in Engineering and Computer Science',Wiley &Son,John(1997).
- [41] Lluís A.Belanche,' A case Study in Neural Network Training with the Breeder Genetic Algorithm' ,Jordi Girena Salgado 1-3,Barcelona ,Spain ,08034,belanche @lsi.upc.es.
- [42] H. Mühlenbein and D.S. Voosen ,'Predictive Models for the Breeder Genetic Algorithm Continuous Parameter Optimization', Evolutionary computation,1:20-49,1993.
- [43] H.N.Seed,' Isolated English Handwritten character recognition using neural network ', MSC . Thesis , Babylon University,2001.
- [44] L.Gupta,M.D.Srinath, ' pattern recognition',20,3,61,(1987).
- [45] L.Faussett,' Fundamental of Neural Networks ', Printice-Hall.Inc. Englewood Cliffs,N.J.,1994.

- [٤٦] L.Gupta,and A.MVpdhye,' Pattern Recognition ',٢٤,١٠.٣٥.١٩٩١.
- [٤٧] L.Gupta,J.Wang,A.Charless,and P.Kistasky,' Pattern Recognition',
٢٥,١١,١٥,١٩٩٢.
- [٤٨] K.Fukushima.' Neo-cognitron: A self-organizing neural network
model for a mechanism of pattern recognition unaffected by shift in
position',Biol.Cybern.٣٦(١٩٨٠).
- [٤٩] K.Fukushima ,S.Miyake,T.Ito.' Neo-cognitron :Anural network
model for mechanism of visual pattern recognition ',IEEE-Trans.
Syst., Man,Cybern.SMC-١٣,NO.٥ (١٩٨٣).
- [٥٠] K.Fukushima,N.Wake,' Handwritten Alphanumeric character
recognition by Neo-cognitron ',IEEE Trans.on neural network
٢(٣)(١٩٩١).

المصادر باللغة العربية

- [٥١] وفاء محمد سعيد ،"تصميم نظام تجزئه لتمييز أهداف الصور الحرارية" ،رسالة ماجستير،
جامعة بابل، ٢٠٠١ .
- [٥٢] د.الشيشتاوي،أحمد أمين،"برمجة ومعالجة الصور"،مكتبة الدار العربية للكتاب ،ط ،
١٩٩٧ .

Abstract

This thesis deals with the classification of images using the principle of soft computing and with using three techniques of image processing. The first step of image processing started with image analysis by segmentation of image into their principle components, aiming at finding objects having special meaning in that image. This process was accomplished using a "Genetic Breeder "; a hybrid algorithm between "Genetic Algorithms" and "Evolution Strategies", characterized by the rapid achievement of the optimum solution, in which "fuzzy recombination" was used, to benefit from the fuzzy system technique. The second step was the step of classification of the objects obtained from the classified image using the "Neo-cognitron neural network", which has the ability to recognize distorted shapes and even position diffraction with a high quality and rapid training comparing with the other neural networks. It is well known that this network was originally designed to recognize letters, even those hand-written, thus the data input of this network were binary values(0,1),because letter's features were taken to the letter's image by creating a sliding window of a given picture size ,or by dividing image into small pieces.

The new in using this neural network is using it in colored images, thus data input were features of the general outlook of the object and its statistical description ,for that reason the data are numbers and not binary. The network is trained on four frames models of a given single image at a single time using input pattern containing these four frames.

The work is implemented using six movie images after partitioning them into their principal constituting frames, and due to the presence of the mild differences between the consecutive frames of the single movie image, thus we studied the number of frames of the recognized objects

for each image regarding them as differences of the images trained for, the recognition percentage of this work was (99.11%).

We noticed that the complementary features of each of the used techniques in image classification gave better results of higher resolution in each step of object classifier.



Image Classification Using Soft Computing Techniques

A Thesis
Submitted by

Anwar Jaafer Moosa Mira

to the council of college of science
University of Babylon

In partial fulfillment of the requirements for the degree of
Master of Science in Computer Science

August-٢٠٠٦
١٤٢٧

sha'ban-

