

نظام هجين : توازي خوارزمية جينية- عصبية في كبس الصور الكسوري باستخدام حاسبات متعددة

أمية غانم عبد الجبار

سوزان خالد إبراهيم

شهلة عبد الوهاب عبد القادر

قسم أنظمة الحاسوب

المعهد التقني / الموصل

تاريخ قبول البحث: ٢٠١٣/١١/٣٠

تاريخ استلام البحث: ٢٠١٢/٩/١٩

ABSTRACT

Recently, effective technologies in Fractal Image Coding (FIC) were used to reduce the complexity of search for the matching between the Range blocks and the Domain blocks which reduces the time needed for calculation. The aim of this research is to propose a Hybrid Parallel Neural -Genetic Algorithm (HPNGA) using the technique of (Manager/Worker) in multiple computers in order to obtain the fastest and best compression through extracting the features of the gray and colored images to attenuate the problem of dimensions in them. The NN enabled to train separate images from the test images to reduce the calculation time. The NN able to adapt itself with the training data to reduce the complexity and having more data and is merged with the parallel GA to reach optimum values of weights with their biases. The optimum weights obtained will classify the correct search domains with the least deviation, which, in turn, helps decompress the images using the fractal method with the minimum time and with high resolution through multiple computers. The results showed that the proposed hybrid system is faster than the standard algorithm, the NN and GA in decompressing the FIC and they are flexible and effective to reach the optimum solution with high speed and resolution. The search method used for compression and de-compression has a vital role in improving the ratio and the quality of image compression which reached 15s. The ratio of compression reached to 90.68% and the image improvement after decompression reached to 34.71_{db} when compared to other methods of (FIC), which didn't exceed 90.41% and image quality of 32.41_{db} and the execution speed was only 21s.

Keywords: Hybrid System, Artificial Neural Network(ANN), Parallel Genetic Algorithm (PGA), Fractal Image Coding(FIC), Rang Block, Domain Block.

المخلص

استخدمت مؤخرًا تقنيات فعالة في التشفير الكسوري للصور Fractal Image Coding(FIC) لتقليل تعقيد البحث للتطابق بين كتل المدى Range Block وكتل المجال Domain Block الذي يقلل الوقت المستغرق في الحساب. الهدف من هذا البحث اقتراح نظام هجين : توازي خوارزمية جينية- عصبية في كبس الصور الكسوري Hybrid Parallel Neural -Genetic Algorithm (HPNGA) بتقنية المدير/العامل في حاسبات متعددة للحصول على أسرع وأفضل كبس من خلال إستخلاص الصفات للصور الرمادية والملونة لتقليل مشكلة الأبعاد فيها، إذ مكنت الشبكة العصبية من تدريب صور منفصلة عن صور الاختبار لتقليل وقت الحساب، كما استطاعت الشبكة العصبية أن تكيف نفسها من بيانات التدريب لتقليل التعقيد وامتلاكها بيانات أكثر، ودمجت مع الخوارزمية الجينية المتوازية للوصول إلى القيم المثالية من الأوزان بانحيازاتها، والأوزان المثالية التي تم

الحصول عليها سوف تصنف مجالات البحث الصحيحة بأدنى انحراف والذي يساعد على فك الكبس للصور بالطريقة الكسورية بأقل وقت وبدقة عالية من خلال حاسبات متعددة. بينت النتائج ان النظام الهجين المقترح أسرع من الخوارزمية القياسية، الشبكات العصبية والخوارزمية الجينية في كبس الصور الكسوري FIC ، وأنها مرنة وفعالة للوصول إلى الحل الأمثل بسرعة وكفاءة عاليتين، وان طريقة البحث المستخدمة للكبس وفك الكبس كان لها دور فعال في تحسين نسبة ونوعية الكبس للصور بسرعة عالية وصلت الى 15_s ، كما وصلت نسبة الكبس الى 90.68% وتحسين نوعية الصورة بعد فك الكبس الى ما يقارب 34.71db مقارنة بالطرائق الاخرى لكبس الصور الكسوري التي لم تتجاوز نسبة الكبس فيها الى 90.41% ونوعية صورة 32.41db وبسرعة تنفيذ لم تتجاوز الى 21_s .

الكلمات المفتاحية: النظام الهجين، الشبكات العصبية الاصطناعية، الخوارزمية الجينية المتوازنة، كبس الصور الكسوري، كتلة المدى، كتلة المجال.

1- المقدمة

كبس وفك الكبس للصور من تقنيات الصور الرقمية التي أصبحت جانبا مهما في خزنها ونقلها في مجال المعلومات. يعد كبس الصور الكسوري (FIC) من أفضل خوارزميات الكبس وفك الكبس التي طورت في العقد الاخير من قبل [1] Barnsley و Jacquin. والذي هو نتيجة دراسة نظام الوظيفة المتكرر Iterated Function System (IFS) إذ طورت الكثير من البحوث في هذا المجال بسبب ارتفاع معدل الكبس (CR) compression ratio وسهولة فك الكبس، فقد ركز الباحثون على كيفية تحديد وتحسين صنف كتل المدى Rang Blocks ، زيادة معدل الكبس، التوازن بين سرعة الكبس وفك الكبس وتحسين جودة الصورة بعد فك الكبس، ووضعت خوارزميات كثيرة في هذا المجال على أساس تصنيف البحث الذي يقلل التعقيد [1]، فقد استخدم باحثون خوارزميات التقنيات الذكائية مثل (ANN,GA) لكبس الصور الكسوري.

الخوارزميات الجينية تعتبر من تقنيات البحث الذكي التي تُستخدم لإيجاد حلول تقريبية للمسائل التي تتطلب حولا أمثلية وتستغرق وقتا طويلا لإيجادها في التقنيات التقليدية. يتم في GA توصيف المشكلة بكموسومات تمثل الحلول بوحدة من طرائق الترميز ومعالجتها بطرائق رياضية مستوحاة من العمليات البيولوجية الحية كالوراثة، الاختيار، العبور والطفرة للحصول على الجيل النهائي للكموسومات والذي يمثل الحل الأمثل للمشكلة المطروحة [15]. اما ANN هي ايضا من التقنيات الذكية والتي تستخدم لبناء النماذج الرياضية مستندة بالأساس على الشبكات العصبية الحيوية لانها تعالج كمية هائلة من البيانات بالتدريب والموزعة بالتوازي لإكسابها المعرفة لغرض التطبيق، والمعالجة في ANN تتم من خلال وحدات معالجة تسمى عقد Node والتي لها خاصية عصبية من حيث انها تقوم بتخزين المعرفة والمعلومات لتجعلها متاحة لاي تطبيق عن طريق ضبط الأوزان، والفائدة الأكبر في ANN هي قدرتها على تشكيل العلاقات اللاخطية المعقدة بدون فرضيات استنتاجية عن طبيعة العلاقة [2]. لذلك استخدمت ANN و GA لتصنيف مجال البحث عن كتل المدى وكتل المجال في كبس الصور الكسوري.

الباحث M.Mohamed [3],2006 عمل على تطوير NN لكبس الصور الكسوري، فيما عمل الباحثون M.Sheng ,Y.Chakrapani [6],2009 , X.Lifeng[5],2007 , A.Ben [4],2006 [7],2006 ، B.S.Sanjay [8],2010، على تطوير GA لكبس الصور الكسوري وكانت نسبة الكبس عالية للصور المختبرة وصلت الى 88% في حين كانت نوعية الكبس للصورة جيدة تراوحت بين $(27-31)\text{db}$ ، فيما عمل

آخرون Y.Chakrapani[10],2009, Y.Chakrapani[9],2008 على تطوير نظم هجينة من الشبكات العصبية والمنطق المضرب لكبس الصور الكسوري وقد كانت النتائج متفاوتة بين طريقة وأخرى فقد وصلت نسبة الكبس الى 90.12% في حين لم تتجاوز نوعية الكبس للصورة (31)db، وقام الباحثون Y.Chakrapani[11],2008 , Y.Chakrapani[12],2009 بتطبيق خوارزمية جينية-عصبية لتسريع كبس الصور الكسوري فمع سرعة الكبس فان نوعية الكبس للصورة لم تتجاوزdb(29) .

الهدف من هذا البحث تطوير نظام هجين:توازي خوارزمية جينية- عصبية لكبس الصور الكسوري في حاسبات متعددة لاستخلاص صفات الصور بهدف تقليل التعقيد لمشكلة الابعاد من اجل الحصول على كتل المجال المتطابق من الجزء الكسوري في الكبس والذي يستخدم نظام الوظيفة المتكرر المحلي (LIFS) وكبس الصور الكسوري للصور الرمادية والملونة التي تقلل الوقت وتحسن نوعية الصورة بعد فك الكبس.

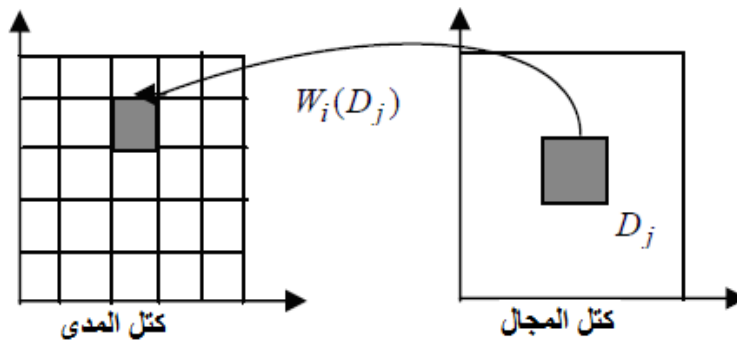
2- توازي خوارزمية جينية - عصبية لكبس الصور الكسوري

ستراتيجية النظام الهجين في كبس الصور الكسوري تكون كالآتي:-

1-2 كبس الصور الكسوري (FIC):

كبس الصورة الكسوري عملية معقدة جدا لكن فك الكبس عملية سهلة جدا مما يجعل معدل الكبس عاليا فيها، هذا التعقيد جاء لانها تستند بالاساس على نظرية الوظيفة المتكرر LISF. التعقيد في كبس صورة أصلية بطريقة FIC هو كيفية الحصول على معلمات LIFS، وكالاتي:-

1- الصورة الاصلية I تقسم الى كتل المدى (I) Rang Block (M) غير المتداخلة بحجم B*B يوضحها الشكل (1) ، وبشكل عشوائي لموقع (N) لكل كتل المجال Domain Blocks(I) وبحجم 2B*2B. كتل المدى ترقم من (1:M) وتمثل بواسطة $R_i (1 \leq i \leq M)$ ، وكذلك كتل المجال ترقم (1:N) وتمثل بواسطة $D_j (1 \leq j \leq N)$.



الشكل رقم (1): تحولات كتل المدى -المجال

2- لكل كتلة مدى R_i ، يحقق أفضل تطابق للمجال $D_k (1 \leq K \leq N)$ وكذلك تقليص التحول المتقارب T_{ik} والذي يحقق بالمعادلة التالية [5] :

$$d(R_i, T_{ik}(D_k)) = \min .d(R_i, T_{ij}(D_j)) \quad \dots(1)$$

حيث ان : T_{ik} تحويل التقليل المتقارب من كتلة المجال D_j الى كتلة المدى R_i ; مقياس التشويش $d(R_i, T_{ij}(D_j))$ هو متوسط مربع الخطا MSE بين كتلة المدى R_i ، وكتلة المجال المنقلصة $T_{ij}(D_j)$.
تحويل التقليل المتقارب T_{ij} مكون من (θ_{ij}, ϕ_j) حسب المعادلة (2):

$$T_{ij} = \theta_{ij} \circ \phi_j \quad \dots(2)$$

حيث ان ϕ_j تحويل حجم كتلة المجال الى الحجم نفسه من كتل المدى ، وهذا التحويل يوضح كالاتي : كتلة المجال D_j تقسم الى وحدات غير متداخلة بحجم $2*2$ ، وكل نقطة صورية pixel في كتلة التحويل $\phi_j(D_j)$ هي معدل من اربع قيم صورية في كل وحدة من D_j . اما θ_{ij} فهو مكون من خطوتين : **الخطوة الاولى** تحولات كتلة $\phi_j(D_j)$ بواسطة واحدة من التحولات الثمانية الاتية : الدوران حول مركز الكتلة $\phi_j(D_j)$ ، للدرجات $(0^\circ, +90^\circ, +180^\circ, +270^\circ)$ وكل دوران بعد الانعكاس المتعامد حول منتصف المحور العمودي للكتلة $\phi_j(D_j)$ ، تلك التحولات الثمانية تسمى isometrics ، اما **الخطوة الثانية** هي التحول P_{ij} للنقطة الصورية للكتلة المحصل في الخطوة الاولى ، [5] ويعرف بالمعادلة (3) :

$$P_{ij}(v) = a_{ij}v + g_{ij} \quad \dots(3)$$

حيث ان v هي النقطة الصورية pixel للكتلة الناتجة في الخطوة الاولى .
حيث a_{ij} ، g_{ij} : يحسب بواسطة تحليل Least square analysis للقيم الصورية لكتل المدى R_i والكتلة الناتجة بواسطة الخطوة الاولى . ويسمى a_{ij} : معامل القياس ، ويسمى g_{ij} : معامل التعديل . المشكلة الأساسية في هذه الطريقة هو استهلاك وقت كبير في FIC ، في هذا البحث طور نظام هجين توازي خوارزمية جينية - عصبية في كبس الصور لتسريع هذه الطريقة في إيجاد معلمات LIFS قريبة من الصورة الاصلية [5] .

2-2 استخلاص الصفات Features Extraction

كبس الصور الكسوري يستغرق وقتا طويلا لأنها تحتاج الى عدد كبير من حسابات التطابق بين كتل المدى وكتل المجال ، لذلك تستخدم خوارزميات التصنيف لتقليل حسابات التطابق في الطريقة الكسورية ، والتصنيف يتم في هذا البحث باستخدام ANN وخوارزمية الانتشار العكسي التي تدرب على بيانات الصفات المستخلصة من خلايا المجال التي حصل عليها من الصورة $I(w,w)$ ، والصورة في عملية الكبس تقسم الى كتل المدى غير المتداخلة بحجم $(b*b)$ ، ويتم البحث عن موقع كتلة المجال من (اعلى - يسار) الصورة ، ولاستخلاص صفات الصور استخدمت قياسات مختلفة توضح في المعادلات (4) ، (5) ، [12] .

1- **Standard Deviation (σ)** : الذي يعطى بالمعادلة الاتية :

$$\sigma = \sqrt{\frac{1}{n_r n_c} \sum_{i=1}^{n_r} \sum_{j=1}^{n_c} (P_{i,j} - M)^2} \quad \dots(4)$$

حيث ان M : معدل النقاط الصورية لمقطع الصورة $(n_r * n_c)$.

P_{ij} : النقطة الصورية للسطر (i) ، والعمود (j) .

2- **Skewness** : الذي يعطى بالمعادلة الاتية [12]:


$$Sk = \frac{1}{n_r n_c} \sum_{i=1}^{n_r} \sum_{j=1}^{n_c} \frac{(P_{i,j} - M)^3}{\sigma^3} \quad \dots(5)$$

3-2 الحاسبات المتوازية Multi Computer

هو شكل من أشكال الحوسبة التي يجري فيها تنفيذ العديد من العمليات في وقت واحد والتي تعمل من مبدأ ان المشاكل الكبيرة يمكن ان تقسم على مشاكل اصغر حجما ويتم حلها في وقت متزامن بالتوازي بحيث يكون للنظام المستخدم القدرة على توزيع المهام بين هذه الحاسبات. تم في العقدين الأخيرين تصميم وأنشاء الكثير من الحاسبات المتوازية والتي تصنف اعتمادا على المهام ، ويعد التصنيف الذي اقترحه مايكل ج. فلين Flynn عام 1966 واحد أ" من أوائل التصنيف للحاسبات المتوازية والتي تعرف بتصنيف فلين، الذي صنف فيه برامج واجهزة الحاسوب من خلال عاملين مهمين في التوازي هما كمية سريان الأيعازات وكمية سريان البيانات بين الحاسبات، وعليه فان فلين صنف الحاسبات [16] كالآتي :

- 1- الحاسبات وحيدة الایعازات ووحيدة البيانات والذي يعني برنامج متسلسل تماما Single Instruction Single Data(SISD) .
- 2- الحاسبات وحيدة الایعازات ومتعددة البيانات والذي يعني القيام بالعملية نفسها على مجموعة كبيرة من البيانات وهو شائع الاستعمال Single Instruction Multiple Data(SIMD) .
- 3- الحاسبات متعددة الایعازات وحيدة البيانات وهو تصنيف نادر الاستخدام Multiple Instruction Single Data(MISD) .
- 4- الحاسبات متعددة الایعازات ومتعددة البيانات ويعد شائعا" في البرامج المتوازية Multiple Instruction Multiple Data(MIMD) .

استخدم في هذا البحث التصنيف Single Program Multiple Data(SPMD) المطور عن التصنيف SIMD والذي يعني توازيا" على مستوى المهام بحيث يحقق سريان الایعازات ببرنامج واحد الى الحاسبات المتوازية وتنفذ بيانات مختلفة بالوقت نفسه، هذا التصنيف يتميز بوجود وحدة تحكم مركزية وذاكرة مشتركة تشرف على الحاسبات المختلفة لتنفيذ البرنامج بشكل متزامن على بيانات مختلفة، ولتحقيق هذا النوع من التوازي استخدم طريقة الربط النجمية Star Connection التي من خلالها ربطت حاسبة رئيسية كخادم، وعدة حاسبات كزبائن يوضحها الشكل (2) حيث مكن هذا الربط عملية الدخول الى الذاكرة المشتركة واستخلاص عدة معاملات في الوقت نفسه مع تبادل البيانات بين الحاسبات عن طريق الذاكرة المشتركة، كما يتمتع هذا الربط مع التصنيف المستخدم SPMD بالجودة والاداء العالي في تنفيذ البرامج والنتائج عن امكانية ربط عدد كبير من الحاسبات والتي جعلها تحتل موقعا" بارزا" في تاريخ الحاسبات المتوازية [16].



الشكل رقم (2): الشبكة النجمية

4-2 الشبكة العصبية الاصطناعية ANN

في حقل كبس الصور طورت الكثير من البحوث التي تستخدم التقنيات الذكائية مثل ANN لكبس وفك الكبس لأنها تعالج كمية هائلة من البيانات بالتدريب وإكسابها المعرفة لغرض التطبيق ، لهذا الغرض استخدمت الشبكة العصبية الاصطناعية ذات التغذية الامامية (FFNN) FeedForward Neural Network ويخوارزمية تدريب ذات انتشار عكسي لتصنيف النقط الصورية للمجال ، والشبكة مكونة من عدة طبقات : طبقة الإدخال، طبقة الإخراج وواحدة او أكثر من الطبقات الخفية، ولا تحتوي على روابط رجوع بصورة عكسية ،الإخراج يحسب مباشرة من الإدخال باتجاه تغذية أمامية من خلال روابط الشبكة بانتشار عكسي للخطأ عند التدريب، وكما موضح في الشكل (3). الإدخالات في الشبكة لها وزن w بحيث تجمع الإدخالات الموزونة مع انحيازاتها $Bias(b)$ ، ثم تطبق عليها دالة التنشيط (AF) Activation Function والتي يمكن ان يستعمل أنواع منها لتوليد الإخراج وبشكل عام دوال التنشيط اللاخطية تعتبر ملائمة ومثالية لأكثر التطبيقات، والشبكات ذات التغذية الامامية في اغلب الاحيان تكون طبقاتها الخفية بدالة السيكمويد (sigmoid AF)، وطبقة الإخراج بدالة خطية $purline$ (AF). كما تمر شبكة FFNN بمرحلتان : **مرحلة التغذية الامامية** التي تدخل فيها أنماط التدريب (البيانات) الى الشبكة وترسل خلال الطبقات المتعاقبة وصولاً إلى الإخراج ، و**مرحلة التدريب** التي تعدل من خلالها الأوزان بشكل تكراري لكل أنماط التدريب على أساس تقليل الأخطاء بين مخرجات الشبكة والمخرجات الحقيقية بانحدار تدريجي للأخطاء يقارن بعدها الإخراج Y_k مع الإخراج الحقيقي حسب المعادلة (6) لحساب الأخطاء لطبقة الإخراج [2] :

$$\delta_k = (T_k - Y_k) * Y_k(1 - Y_k) \quad \dots(6)$$

حيث ان Y_k هو إخراج الشبكة ، T_k هو الإخراج الحقيقي ، كذلك يحسب الخطأ العكسي للطبقة الخفية حسب المعادلة (7):

$$\delta_k = Y_k(1 - Y_k) \sum \delta_k * W_k \quad \dots(7)$$

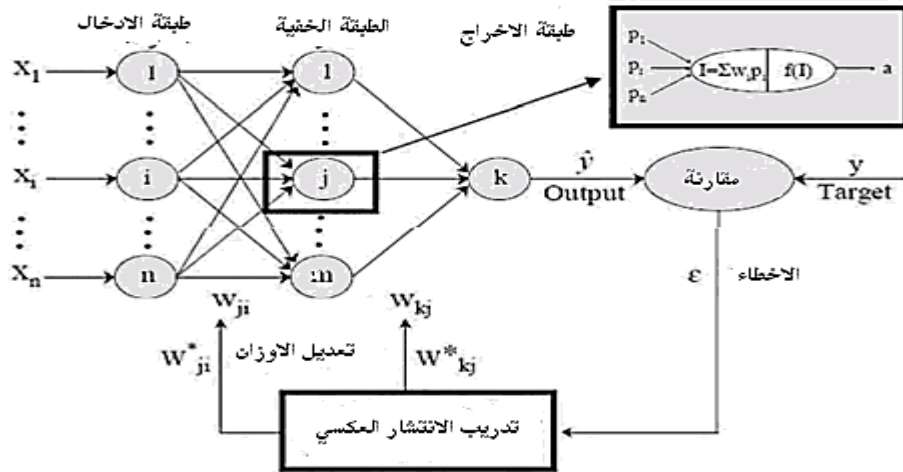
حيث ان δ_k هو معدل الخطا بين طبقة الإخراج والطبقة الخفية ، في حين تعدل أوزان الشبكة في كل مرحلة من خلال المعادلة (8):

$$W_{jk}(t+1) = W_{jk}(t) + \eta \delta_k Y_k + \alpha(W_{jk}(t) - W_{jk}(t-1)) \quad \dots(8)$$

حيث ان η هي معامل التدريب ، α معامل التعجيل والتي تستخدم لتسريع خوارزمية التدريب [2].

5-2 الخوارزميات الجينية لكبس الصور الكسوري FIC GA

السمة الرئيسية لـ FIC هو إيجاد كتلة المجال المناسبة والتحول إلى نوعية من كتلة المدى ، والمشكلة فيها هو إيجاد مساحة البحث لذلك استبدلت ميكانيكية البحث التقليدية لـ FIC بـ GA لإيجاد اقرب حل مثالي. فالخوارزمية الجينية هي تقنية من تقنيات البحث التي تستخدم لإيجاد الحلول الحقيقية والتقريبية لمشاكل البحث، إذ يتم فيها توصيف المشكلة بـ كروموسومات الممثلة للحلول بواحد من طرائق الترميز، بعد ذلك تطبق مجموعة من العمليات الرياضية المستنبطة من العمليات البيولوجية كالتوارث، الاختيار، العبور، والطفرة للحصول على مجموعة من الكروموسومات التي تمثل أفراد الجيل النهائي، وأفضل كروموسوم هو الحل الأمثل الذي تبحث عنه المشكلة المطروحة. اذا، تبدأ عملية البحث من مجموعة طول وليس حلاً واحداً والتي تمثل عادة بصيغة ثنائية (1,0) لكل الاحتمالات الممكنة للمسألة، والجيل الاول يبدأ بتوليد جيل عشوائي لكل الكروموسومات التي تمثل مساحة الحل. الجيل الجديد يتكون من تقييم كل فرد في الجيل القديم حسب دالة اللياقة، استخدمت هذه الطريقة في كبس الصور الكسوري وكالاتي [15] :



الشكل رقم (3): نموذج مثالي لشبكة الانتشار العكسي

- تشفير المعلومات Parameter coding: هي تشفير الكروموسومات LIFS بصورة ثنائية والتي تعتمد على قيم الاوزان ومعامل الانحياز ANN للبحث عن كتلة المجال يوضحها الشكل (4) .

11010	11010	11010	11010	11010
V_{11}	V_{23}	W_{11}	W_{31}	B
← Input Weight →			← Output Weight →			Bias

الشكل (4): الكروموسوم للشبكة العصبية الاصطناعية

- **حجم الجيل Population size** : يقصد به عدد الأفراد ضمن الجيل وهو من العوامل المهمة التي يتوقف عليها أداء الخوارزمية. لذلك فإن زيادة حجم الجيل يقلل من خطأ النتائج، لكن تنخفض دقة النتائج بشكل ملحوظ عند كون حجم الجيل صغيراً لأنه لن يشمل كامل المجال المدروس بشكل جيد، وتتم عملية بناء الجيل الابتدائي initial population بطريقة عشوائية.
- **دالة اللياقة Fitness Function** : سلسلة الكروموسومات المكونة للجيل القديم من بيانات الصورة تتغير الى الجيل الجديد اعتماداً على دالة اللياقة بالمعادلة (9) :

$$Fi(x) = \begin{cases} \frac{1}{mse(x) + 1} & \dots mse(x) > \epsilon \\ \infty & \dots mse(x) \leq \epsilon \end{cases} \quad \dots(9)$$

حيث $MSE(X)$: هو متوسط مربع الخطأ بين كتلة المدى وكتلة المجال المحصلة من الكروموسوم X ، وان ϵ : اقل قيمة للخطا لا تتجاوزها قيمة X ، وقيمة ϵ هي 0.00001 [5] .

- **توليد الاجيال Generation** : توليد الأجيال يعني الحصول على جيل جديد من الأبناء من خلال تولد كروموسومات الاباء التي لها لياقة اكبر وفرصة للتزاوج والبقاء، وبهذا يتم توليد جيل جديد من الأبناء بشكل عشوائي اكثر تكيفا للظروف البيئية وفناء الافراد الاقل تكيفا ، لذلك كلما زاد عدد الاجيال فان الحلول المثلى سوف تحافظ على نفسها في الاجيال اللاحقة باقل تقدير، وتتم عملية التوليد بثلاث مراحل، (الاختيار، العبور، الطفرة).

• الاختيار على وفق مبدأ العجلة المتدرجة **Roulette Wheel Selection**: محاكاة هذه الطريقة تتم بوجود عجلة لها مؤشر تقسم إلى 100 قطاع ،أفراد الجيل يُوزعون على القطاعات وفقاً لمتوسط احتمالية الانتخاب لكل فرد من أفراد الجيل الحالي والذي يعطى بالمعادلة (10) :

$$Pis = \frac{Fi}{\sum_{i=1}^m Fi}, (i=1,2,\dots,M) \quad \dots(10)$$

حيث أن Pis هي احتمالية انتخاب الفرد i ، Fi : درجة لياقة الفرد i ، و M : عدد الأجيال. الانتخاب يتم بإدارة العجلة عشوائياً ويؤخذ بعدها الفرد الذي أشار إليه المؤشر. درجة لياقة الفرد تزداد بزيادة عدد قطاعاته ومن ثم يزداد احتمال انتخابه في الجيل اللاحق بتأثير إيجابي.

• العبور **Crossover**: يعد من العمليات المهمة في GA فالمعتقد السائد أن التزاوج بين أفراد يتمتعون بمواصفات جيدة ينتج عنه أفراد بمواصفات جيدة بأقل تقدير. ثم يتم انتخاب الأفراد بمقياس لياقة جيد، تنفذ بعد ذلك عملية مزج عشوائي للتخلص قدر الإمكان من إجراء العبور بين الفرد ونفسه والنتيجة عن احتمال تكرار الفرد أكثر من مرة بشكل متتالي نتيجة عملية الاختيار التي تسبق العبور، تتم عملية العبور بين الفرد والذي يليه باستخدام إحدى طرائق العبور كالعبور المنسق أو عبور نقطة البسيط Simple n-point المستخدم في هذه الدراسة ، إذ تم في جيل الإبناء تقسيم الكروموسومات الى (مجموعتين) والعبور يتم فيها عشوائياً لكل مجموعة وفق احتمالية العبور Probability of Crossover (Pc) والشكل (5) يوضح المجاميع المضللة لعملية العبور (نقطة البسيط-2) لكل فرد ضمن الجيل [15].

جيل الإباء	$V_{1,1}$	$V_{1,2}$	$V_{1,3}$	$W_{1,1}$	$W_{1,2}$	$B_{3,1}$	$B_{3,2}$
	$V_{2,1}$	$V_{2,2}$	$V_{2,3}$	$W_{1,3}$	$B_{1,4}$	$B_{3,3}$	$B_{3,2}$
جيل الإبناء	$V_{1,1}$	$V_{2,2}$	$V_{2,3}$	$W_{1,1}$	$B_{1,4}$	$B_{3,3}$	$B_{3,2}$
	$V_{2,1}$	$V_{1,2}$	$V_{1,3}$	$W_{1,3}$	$W_{1,2}$	$B_{3,1}$	$B_{3,2}$

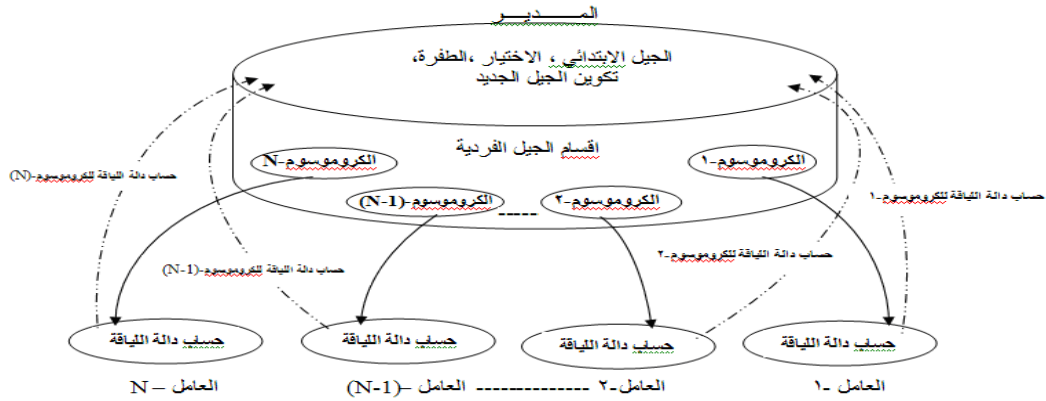
الشكل رقم (5): عبور نقطة البسيط

• الطفرة **Mutation**: هي المرحلة الأخيرة من سلسلة العمليات التكرارية التي تسهم بشكل جيد للوصول إلى الحل الأمثل بسرعة فعند حدوث تغيير مفاجئ وعشوائي في الجيل ولو كان باحتمال طفيف يكون له الأثر الإيجابي في الاقتراب من الحل الأمثل. الطفرة في الترميز الثنائي تكون بعكس الكروموسومات من 0 إلى 1 أو العكس، واحتمال حدوث هذا التغيير يعرف باحتمال الطفرة Probability of Mutation (Pm) وعادة يختار بقيمة متدنية نسبياً [15]

6-2 توازي خوارزمية جينية -عصبية

الخوارزمية الجينية تتطلب وقتاً طويلاً لتنفيذها لكن في تقنيات الحاسوب الحديث تم التغلب على طول الوقت بتنفيذ هذا النوع من الخوارزميات في حاسبات متوازية الهدف منه الحصول على الحل الأمثل بسرعة عالية. الخوارزمية الجينية المتوازية طبقت على أساس المدير/ العامل Manager/Worker بعدة حاسبات، حاسبة رئيسية تعد المدير، و N من الحاسبات الطرفية بوصفها عمالاً، الموضحة بالشكل (6). المدير يعمل على تأسيس الاتصال مع العمال من خلال إرسال إشارة الاتصال، ثم يقوم بتوليد كروموسومات الجيل الابتدائي عشوائياً من اوزان الشبكة العصبية وانحيازاتها وتوزيعها على العمال بالتساوي، تدريب شبكة FFNN لحساب اوزانها وانحيازاتها ، تهيئة متطلبات الخوارزمية الجينية وتوزيعها على العمال Worker-N. أيضاً يقوم المدير باستلام النتائج من كل عامل لإعادة تمثيلها عشوائياً ليتسنى تكرار تلك العمليات، إرسال إشارة لانتهاء الاتصال مع كل العمال بعد الحصول

على الحل الأمثل النهائي. أما العمال N ، يقوم كل عامل من البداية باستلام الإشارة من المدير لتأسيس الاتصال والانتظار لحين البدء بإرسال متطلبات GA ، وجزء من الكروموسومات الكلية لتنفيذ الخوارزمية بدالة اللياقة ، ومن ثم إرسال ناتج GA الجزئية الى المدير ، العمليات تكرر لكل عامل مع كل إرسال من المدير إلى أن يستلم إشارة بإنهاء الاتصال بعد الوصول إلى الحل الأمثل النهائي [13][14]. والنظام المقترح (HPNGA) لكبس الصور الكسوري في حاسبات متعددة يوضح بالشكل (7).



الشكل (6) الخوارزمية الجينية المتوازية [13]

3- مواد البحث وطرقه :

استخدمت بيانات الصور الرمادية (Lena, Barbara) بـ 8Bit/Pixel والذي يمثل شدة اللون الرمادي بتدرجات (0-255) ،والصور الملونة (Girl, Butterfly) التي يتم فيها تخصيص ثلاث خانات لكل نقطة صورية لتحديد شدة اللون RGB (الاحمر ، الاخضر ، الازرق) وكل خانة تحتوي 8Bit/Pixel لشدة اللون المحدد من الالوان الثلاثة أي سوف يكون لكل صورة 24Bit/Pixel . واستخدمت صيغة (JPEG) لكونها صيغة فعالة لضغط الصور الرقمية وهي الصيغة الأكثر شيوعا لحفظ وإرسال ملفات الصور عبر شبكة الانترنت لان حجمها صغير ودقتها عالية . واختيرت الصور بحجم 256*256 والتي شفرت ب 8-bit/pixel لكل نقطة صورية والجدول رقم (1) يمثل البيانات المستخدمة في تمثيل النظام الهجين . استخدمت تقنية MATLAB Distributed Computing Server (MDCS) المعروفة بخوادم الحاسبات الموزعة والموجودة في بيئة الماتلاب MatlabR2010b وتأسيسها على مجموعة حاسبات. واستخدم منها تقنية المدير/العامل Manager/Worker ،حيث ربطت (11) حاسبة ، واحدة منها تمثل المدير يعمل على إدارة النظام بوصفه خادماً Server ،العمال Worker-N الذين يعملون بوصفهم طرفيات وهنا عدد الحاسبات Worker-N=10،حيث تم تأسيس الاتصال كالآتي :

1-Install the MDCE Service on all computers

2-In Dos for the folder:

Matlabroot\distcomp\bin\Mdce install

Matlabroot\distcomp\bin\Mdce start

Matlabroot\distcomp\bin\admincenter.bat

3-In admincenter: Create Job Manager : Jm1,Worker (1 – 10)

واستخدمت المعادلات (11)، (12) لقياس كفاءة الخوارزمية المقترحة من خلال الابعاز الآتي:

[PSNR,MSE,Error, Compression raio] = measerr(image Name)

$$MSE = \frac{\sum_{i=0}^{M_{Rows}} \sum_{j=0}^{N_{Cols}} |X(i, j) - X_c(i, j)|^2}{M_{Rows} * N_{Cols}} \quad \dots(11)$$

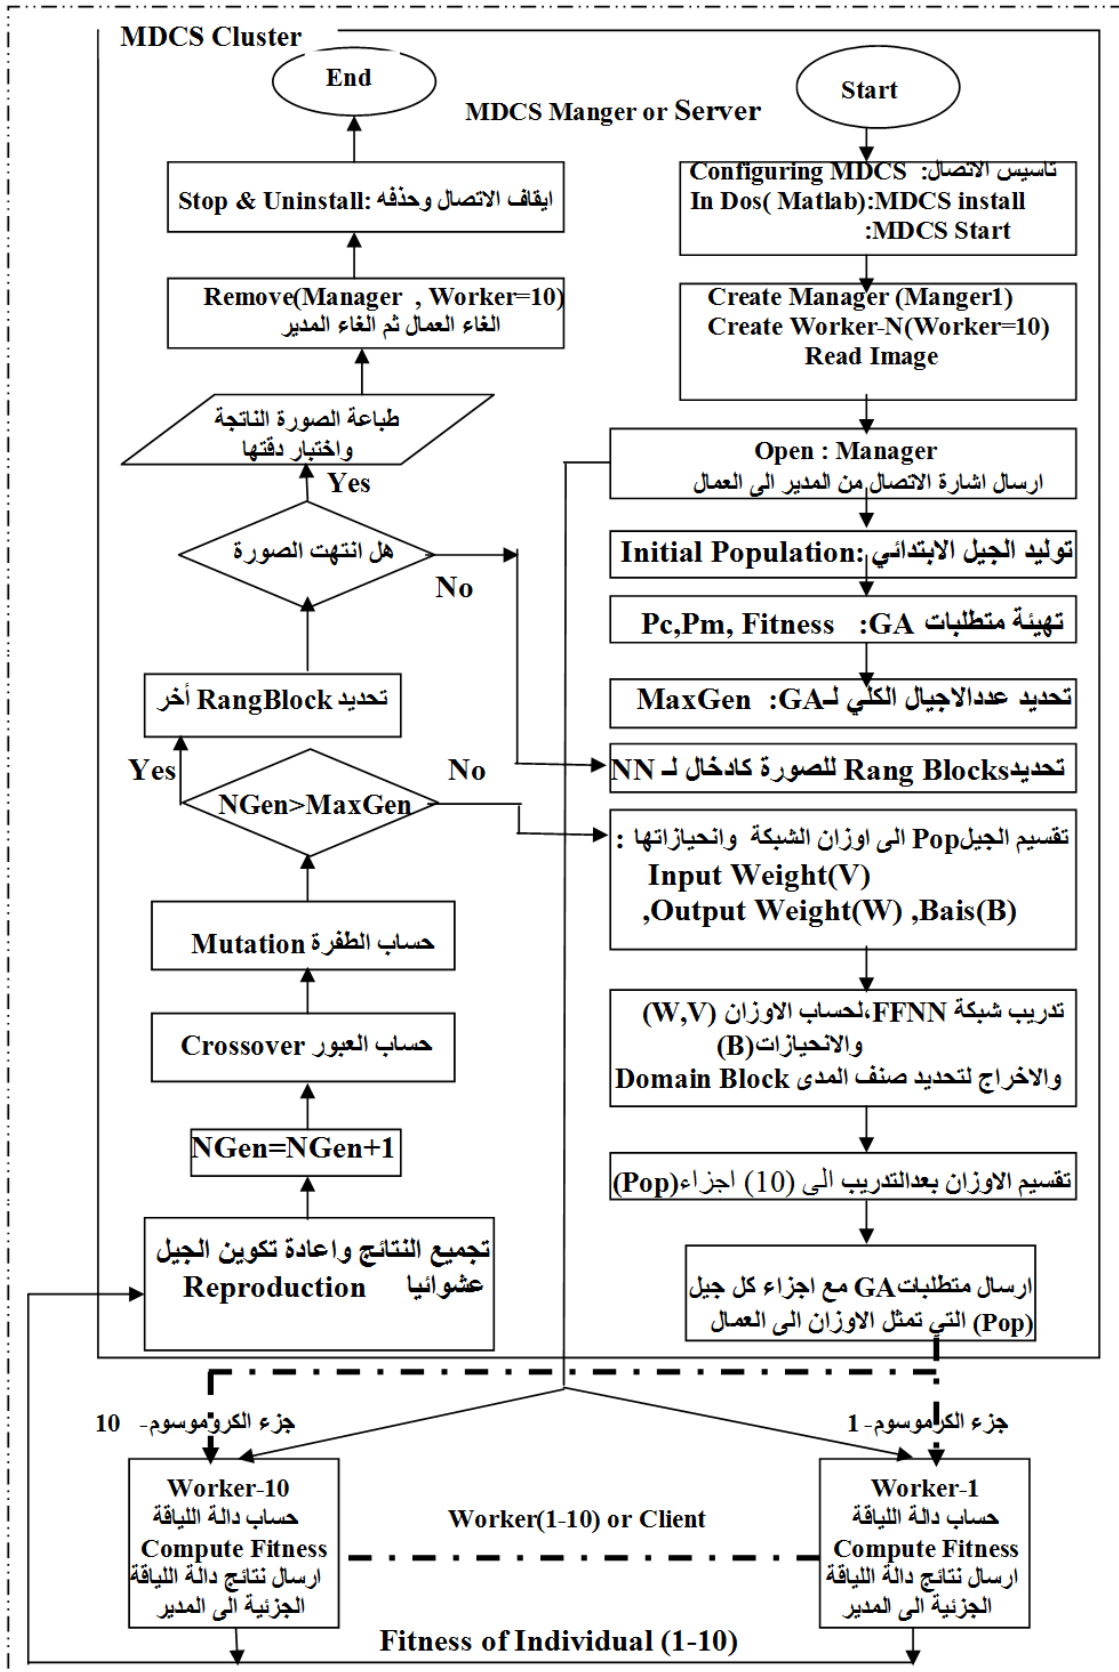
$$PSNR = 10 \log_{10} \left(\frac{255^2}{MSE} \right) \quad \dots(12)$$

الجدول رقم (1) بيانات النظام الهجين (HPGANN)

معادلة (9)	دالة اللياقة	200,100	حجم افراد الجيل الكلي المولد في المدير
50	عدد الاجيال	40,20	حجم الجيل المستلم لكل عامل
4*4	حجم كتلة المدى	1	احتمالية العبور المثالية (Pc)
3	عد العقد الخفية	0.001	احتمالية الطفرة المثالية (Pm)
sigmoid AF	دالة التنشيط للطبقة الخفية	feedforwardNet	الشبكة العصبية الاصطناعية
purline AF	دالة التنشيط للخارج	2-3-1	تصميم الشبكة العصبية

4- مناقشة النتائج :

تشير النتائج التي تم الحصول عليها بتطبيق النظام الهجين ان له تأثيراً في تحسين عملية الكبس وفك الكبس الكسوري FIC وبسرعة أفضل من الطرائق (ANN,GA,FIC) لكبس الصور الكسوري. تبين ذلك من خلال استخدام صور رمادية بالحجم (256*256) للصور (Barbara , Lena)، والصور الملونة (girl, Butterfly) بنفس الحجم، وبشفرة 8-Bit/Pixel، وخلال عملية التكرار لفك الكبس تم اخذ معدل النقاط الصورية الأربعة المتجاورة للصورة والتي تتجاوز المدى (0-255) لتجنب التباعد عن القيم الأصلية. النتائج قيست على أساس سرعة التنفيذ للنظام في حاسبات متعددة فعند اختيار حجم الجيل 200، التكرار 50 وبتنفيذات مختلفة يوضحها الجدول (2) للصور الرمادية كانت سرعة التنفيذ تتفاوت بزيادة عدد الحاسبات لصورة Lena، فقد وصلت سرعة التنفيذ بين حاسبتين أي المدير وعامل واحد الى 67s، و PSNR وصلت الى 31.23db، في حين وصلت CR الى 87.22%، كما لوحظ ان هناك تسريعاً في التنفيذ من (2-10) عمال إذ قلت السرعة الى 0.08s بتنفيذها في 10 عمال، رافقه تحسين في PSNR التي وصلت الى 34.95db، في حين وصلت CR الى 91.56%. كذلك لوحظ أن هناك تسريعاً في تنفيذ النظام عند تقليل حجم الجيل من 200 إلى 100 حيث تراوح وقت التنفيذ بين (0.02-65s) لكل حالات التنفيذ الموضحة بالجدول (2) لصورة Lena، رافقه أيضاً ارتفاع متدرج في نوعية ونسبة الكبس الذي جاء نتيجة استخلاص الصفات للصورة لتقليل مشكلة الأبعاد وتصنيف مجالات البحث الصحيحة في الطريقة الكسورية بأدنى انحراف والذي يساعد على فك الكبس للصورة بأقل وقت وبدقة عالية من خلال استخدام GA و ANN، حيث وصلت PSNR الى 34.99db في حين وصلت CR الى 91.43% بأسرع تنفيذ للنظام ويعدد عمال مساوٍ لـ 10.



الشكل (7) مخطط النظام المقترح HPNGA في كيس الصور الكسوري

ولغرض اختبار دقة النتائج التي طبقت على صورة Lena تم تطبيق النظام على الصورة الرمادية لـ (Barbara) والصور الملونة (Girl, Butterfly) وبالمحددات نفسها ، فقد لوحظ ان هناك تسريعاً في كبس وفك الكبس باستخدام HPNGA يوضحها الجدول (2) والجدول (3) ، فعند اختيار حجم الجيل 200 وبتكرار 50 مرة لصورة Barbara كانت سرعة التنفيذ تتفاوت بزيادة عدد الحاسبات ، إذ وصلت سرعة التنفيذ الى 0.07_s بعدد العمال 10 رافقه ايضاً تحسين في PSNR للصورة التي وصلت الى 34.11_{db} في حين وصلت CR الى 91.33% . كذلك لوحظ ان هناك تسريعاً في تنفيذ النظام عند تقليل حجم الجيل الى 100 إذ وصلت سرعة التنفيذ الى 0.02_s بـ PSNR للصورة وصلت الى 34.99_{db} و CR مساوٍ الى 91.41% عند تنفيذها في 10 حاسبات .

النتائج بينت ان هناك تسريعاً في تنفيذ النظام الهجين للصور الملونة (Girl, Butterfly) عند تنفيذها في (10) حاسبات يوضحها الجدول (3) رغم الحجم المضاعف لها والذي كان بسعة 24-Bit/Pixel عن حجم الصور الرمادية الذي كان بسعة 8-Bit/Pixel فمع اختلاف حجم الجيل من 200 الى 100 وبتكرار 50 مرة كانت سرعة التنفيذ تتفاوت بزيادة عدد الحاسبات للصورة Butterfly اذ وصلت الى 0.04_s بعدد عمال 10 وحجم جيل مساوٍ لـ 100 ، رافقه ايضاً تحسين في PSNR للصورة وصلت الى 35.33_{db} في حين وصلت CR الى 91.78% . كذلك لوحظ ان سرعة التنفيذ تتفاوت بزيادة عدد الحاسبات للصورة Girl مع اختلاف حجم الجيل من 200 الى 100 وبتكرار 50 مرة اذ وصلت الى 0.01_s بعدد العمال 10 وحجم جيل مساوٍ لـ 100 ، رافقه ايضاً تحسين في PSNR للصورة التي وصلت الى 35.1_{db} في حين وصلت CR الى 91.88% .


من الجداول (2) ، (3) يلاحظ انه مع بقاء التكرار ثابتاً حصل تسريع في تنفيذ النظام ووصل الى أفضل حالة بعدد عمال مساوٍ (10) ، لكن مع انخفاض حجم الجيل من 200 الى 100 حصل تسريع أخرفي التنفيذ لكل حالات الاختبار حيث وصل الى أفضل حالة بعدد عمال مساوٍ لـ 10 أيضاً، هذا التسريع جاء من تقليل التعقيد في الحسابات لمشكلة الأبعاد في الطريقة الكسورية باستخدام ANN التي دمجت مع GA للوصول إلى القيم المثالية من الأوزان بانحيازاتها التي تصنف مجالات البحث الصحيحة بأدنى انحراف والذي يساعد على فك الكبس للصور بأقل وقت ودقة عالية من خلال حاسبات متعددة، وكما موضح في الشكل (8) الذي يمثل تسريعاً للنظام مع اختلاف حجم الجيل للصور المختبرة واختلاف الحجم بين الصور الرمادية والملونة ، وكان هذا التسريع واضحاً على الصور بحصولها على نسبة ونوعية كبس عالية يوضحها الشكل (9) لصورة Lena التي طبقت بسرعة 0.02_s ، والشكل (10) لصورة Barbara التي طبقت بسرعة 0.02_s ، والشكل (11) لصورة Butterfly التي طبقت بسرعة 0.04_s والشكل (12) لصورة Girl التي طبقت بسرعة 0.01_s .

ولغرض قياس كفاءة النظام الهجين تمت مقارنة نتائجه مع نتائج تنفيذ (GA، ANN، FIC) من خلال تنفيذها في (10) حاسبات لنفس مواصفات النظام الهجين والموضحة بالجدول (4) إذ تبين ان تلك الطرائق أبطأ في التنفيذ من النظام الهجين، فقد تراوح وقت التنفيذ بالطريقة القياسية FIC بين $(24-28)_s$ لجميع صور الاختبار في حين تراوحت PSNR بين $(30.1-30.38)_{db}$ ، و CR تراوحت بين $(88.1-88.45)\%$. وحصل تسريع في التنفيذ باستخدام شبكة feedforwardNet، فقد تراوح وقت التنفيذ بين $(15-17)_s$ في حين تراوحت PSNR بين $(30.12-30.87)_{db}$ و CR بين $(89.22-90.66)\%$. كما لوحظ تسريع آخر لكبس الصور الكسورية عند تنفيذها باستخدام GA فقد تراوح وقت التنفيذ بين $(10-12)_s$ ، في حين تراوحت PSNR بين $(32.66-32.88)_{db}$ و CR بين $(90.55-90.60)\%$.

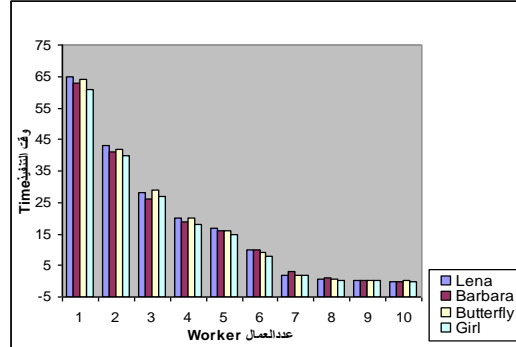
وحصل تسريع عالي لكبس الصور عند تطبيق النظام الهجين على صور الاختبار فقد تراوح وقت التنفيذ بين $(0.04-0.01)_s$ ، في حين تراوحت PSNR بين $(35.33-34.99)_{db}$ ، و CR بين $(91.88-91.41)\%$ ، والشكل (13) يوضح مقارنة النظام الهجين HPNGA مع الطرائق (GA,NN,FIC). كما يوضح الشكل (14) لصورة Lena افضلية النظام الهجين في الحصول على كبس عالي الدقة للصور المختبرة ، فالصورة (b) وضحت الصورة بعد الكبس في النظام الهجين بوقت اقل من الصورة (c) الناتجة باستخدام الخوارزمية الكسورية القياسية (FIC) والصورة (d) الناتجة من (NN) والصورة (e) الناتجة من (GA).

الجدول رقم (2) : سرعة التنفيذ في (10) حاسبات للصور الرمادية

صورة (Barbara)/بحجم (256*256)			صورة (Lena)/ بحجم (256*256)			الإدخالات		
نسبة الكبس CR%	نوعية الكبس PSNR	الوقت Time	نسبة الكبس CR%	نوعية الكبس PSNR	الوقت Time	التكرار Iteration	حجم الجيل Population size	عدد العمال workers
87.21	31.27	66	87.22	31.23	67	50	200	1
87.61	31.82	45	87.55	31.76	49	50	200	2
88.46	32.28	30	88.42	32.21	31	50	200	3
89.93	32.91	21	88.91	32.82	22	50	200	4
90.23	33.42	18	90.22	33.28	19	50	200	5
90.36	33.56	12	90.44	33.35	12	50	200	6
90.65	33.78	4	90.86	33.55	3	50	200	7
90.88	33.89	2	91.22	34.57	2	50	200	8
91.12	33.94	0.6	91.34	34.90	0.5	50	200	9
91.33	34.11	0.07	91.56	34.95	0.08	50	200	10
88.51	31.41	63	88.53	31.35	65	50	100	1
88.92	31.95	41	88.92	31.89	43	50	100	2
89.56	32.91	26	89.54	32.87	28	50	100	3
90.23	33.95	19	90.2	33.93	20	50	100	4
90.55	34.42	16	90.53	34.33	17	50	100	5
90.66	34.65	10	90.72	34.42	10	50	100	6
90.87	34.71	3	90.92	34.61	2	50	100	7
91.1	34.82	0.9	91.11	34.77	0.6	50	100	8
91.23	34.91	0.08	91.24	34.85	0.2	50	100	9
91.41	34.99	0.02	91.43	34.99	0.02	50	100	10



(B) تسريع الصور المختبرة بحجم الجيل (100)



(A) تسريع الصور المختبرة بحجم الجيل (200)

الشكل (8) تسريع النظام الهجين (HPNGA) في كبس الصور الكسورية

الجدول رقم (3): سرعة التنفيذ في (10) حاسبات للصور الملونة

صورة (Girl) / بحجم (256*256)			صورة (Butterfly) / بحجم (256*256)			الادخالات		
نسبة الكبس CR%	نوعية الكبس PSNR	الوقت Time	نسبة الكبس CR%	نوعية الكبس PSNR	الوقت Time	التكرار Iteration	حجم الجيل Population size	عددالعمال workers
88.67	31.28	64	87.41	31.25	66	50	200	1
88.87	31.81	43	87.56	31.77	47	50	200	2
89.52	32.31	31	88.45	32.28	30	50	200	3
89.91	32.92	20	88.92	32.91	23	50	200	4
90.33	33.52	17	90.93	33.35	19	50	200	5
90.56	33.69	9	91.12	33.62	11	50	200	6
90.88	33.88	2	91.23	33.85	4	50	200	7
91.12	33.95	1	91.44	33.98	1	50	200	8
91.34	34.16	0.2	91.65	34.22	0.5	50	200	9
91.78	34.58	0.03	91.84	34.54	0.06	50	200	10
88.61	31.42	61	88.54	31.41	64	50	100	1
89.22	32.21	40	88.93	31.87	42	50	100	2
89.72	33.11	27	89.53	32.81	29	50	100	3
90.32	33.97	18	90.23	33.91	20	50	100	4
90.62	34.71	15	90.61	34.41	16	50	100	5
90.91	34.75	8	90.89	34.61	9	50	100	6
91.37	34.88	2	91.25	34.83	2	50	100	7
91.44	34.91	0.3	91.39	34.93	0.7	50	100	8
91.69	34.99	0.08	91.56	35.13	0.1	50	100	9
91.88	35.1	0.01	91.78	35.33	0.04	50	100	10



(b) الصورة بعد الكبس

(a) الصورة الاصلية

الشكل (9) صورة Lena الناتجة من النظام الهجين بسرعة 0.02



(b) الصورة بعد الكبس

(a) الصورة الاصلية

الشكل (10) صورة Barbara الناتجة من النظام الهجين بسرعة 0.02



(b) الصورة بعد الكبس

(a) الصورة الاصلية

الشكل (11) صورة Butterfly الناتجة من النظام الهجين بسرعة 0.04s




(b) الصورة بعد الكبس

(a) الصورة الاصلية

الشكل (12) صورة Girl الناتجة من النظام الهجين بسرعة 0.01s

الجدول رقم (4) : مقارنة HPNGA مع الطرائق (GA, NN, FIC)

الوقت Time(S)				
	FIC	NN	GA	HPNGA
Lena	28	15	10	0.02
Barbara	25	17	11	0.02
Butterfly	24	16	11	0.04
Girl	27	15	12	0.01
نوعية الكبس (PSNR) _{ab}				
	FIC	NN	GA	HPNGA
Lena	30.1	30.12	32.66	34.99
Barbara	30.2	30.17	32.78	34.99
Butterfly	30.24	31.67	32.65	35.33
Girl	30.38	31.87	32.88	35.1
نسبة الكبس (Compression ratio%)				
	FIC	NN	GA	HPNGA
Lena	88.1	89.22	90.55	91.43
Barbara	88.21	89.27	90.61	91.41
Butterfly	88.34	89.61	90.76	91.78
Girl	88.45	90.66	90.65	91.88



الشكل (13) مقارنة سرعة HPNGA مع سرعة الطرائق (GA,NN,FIC)

5- الاستنتاجات والتوصيات

النظام الهجين HPNGA أثبت نجاحه في تحسين كبس الصور الكسوري من خلال استخلاص صفات الصور لتقليل مشكلة الابعاد للصور الرمادية والملونة ومكنت ANN من تدريب الصور والحصول على الاوزان المثالية باستخدام GA التي تصنف مجال البحث بادنى انحراف الذي يساعد على كبس الصور الكسوري بدقة عالية وباقل وقت من خلال حاسبات متعددة . النتائج بينت ان HPNGA هو طريقة فعالة للوصول إلى الحل الأمثل بسرعة وكفاءة عاليتين بتقنية المدير/العامل فقد تراوحت سرعة تنفيذ HPNGA بين (0.01-0.04) كاسرع تنفيذ لكبس الصور الكسوري في (11) حاسبة، وان طريقة استخلاص الصفات المستخدمة للكبس وفك الكبس، واختيار معاملات GA (الاختيار، العبور والطفرة) ودمجها بANN كان له دور فعال في تحسين CR التي وصلت الى 91.88% وتحسين PSNR بعد فك الكبس التي وصلت الى 35.33 db. اوصي باستخدام HPNGA في ايجاد الحلول لاي مشكلة اذا كان عامل السرعة مهماً لحلها خاصة تلك المشاكل التي تحل باستخدام GA.



الشكل (a) الصورة الأصلية (b) FIC باستخدام HPNGA (c) FIC القياسية



(d) FIC باستخدام NN (e) FIC باستخدام GA

الشكل (14) مقارنة نتائج الخوارزمية المقترحة HPNGA مع الطرائق (GA,NN,FIC)

المصادر

- [1] Mingshui Li, Shanhu Ou and Heng Zhang: The new progress in research approach of fractal image compression. Journal of Engineering Graphics. 4(3), 143-152, 2004.
- [2] S. N. Sivanandam, S. Sumathi, S. N. Deepa, "Introduction To Neural Networks Using Matlab 6.0", Tata McGraw-Hill, 2006.
- [3] M. Mohamed, "Optimization Of Fractal Image Compression Based On Kohonen Neural Networks", EEDIS Laboratory, Engineering Faculty, University of SBA, 2006.
- [4] A. Ben, M. Ben and Y. Ben, "Optimization of fractal image compression with genetic algorithms", A. Ben Jmaa is with National School of Engineering of Sfax, BP, W, 3038 Sfax, 2006.
- [5] X. Lifeng, Z. Liangbin, "A Study of Fractal Image Compression Based on an Improved Genetic Algorithm", Zhejiang Wanli University, 2007.
- [6] Y. Chakrapani, K. Soundara, "Genetic Algorithm Applied To Fractal Image Compression", Dept. of Electronic and communications, J.N.T.U College of Engineering, India, 2009.
- [7] M.Sheng, J.H. Jeng, "Schema genetic algorithm for Fractal Image Compression", Dept. of Electronic Engineering, N.S. Yet-Sen University, Taiwan, 2006.
- [8] B.S. Sanjay, M.V. Kulkarni, "Fractal Image Compression Using Genetic Algorithm", Advances in computer Engineering ACE, India, June 2010.
- [9] Y. Chakrapani, K. Soundara, "A Comparative Approach To Fractal Image Compression Using Genetic Algorithm and Simulated Annealing Technique", Dept. of Electronic and communications, J.N.T.U College of Engineering, India, 2008.
- [10] Y. Chakrapani, K. Soundara, "Adaptive Neuro-Fuzzy Inference System based Fractal Image Compression", Dept. of Electronic and communications, J.N.T.U College of Engineering, India, Vol 2, No.1, November, 2009.
- [11] Y. Chakrapani, K. Soundara, "Hybrid Genetic –Simulated Annealing Approach for Fractal Image Compression", Dept. of Electronic and communications, J.N.T.U College of Engineering, India, 2008.
- [12] Y. Chakrapani, K. Soundara, "Implementation of Fractal Image Compression Hybrid Genetic –Neural Approach", Dept. of Electronic and communications, J.N.T.U College of Engineering, India, Vol.7, No. 3, September 2009.
- [13] P. Borovska, "Solving the Travelling Salesman Problem in Parallel By Genetic Algorithm on Multicomputer Cluster", Computer Systems Dept., Technical University of Sofia, 2006.
- [14] S.Tongchim, Prabhas, "Parallel Genetic Algorithm for Finite-State Machine Synthesis From Input/Output Sequences", Department of Computer Engineering, Chulalongkorn University Bangkok 10330, Thailand, 2000.

[15] الحجار، م. عبید، م، "الخوارزمیات الجینیة"، إشراف العرفی، ہادی، مشروع دبلوم، جامعة دمشق، كلية الهندسة الميكانيكية والكهربائية، 2003.

[16] الجار الله، م. الحریری، ن، "الحاسبات المتوازية والخوارزمیات المتوازية"، جامعة الملك سعود، كلية العلوم، قسم الحاسب الالى، 2002.