

استخدام الخوارزميات الجينية المتوازية لكبس الصور الكسوري*

شهلة عبد الوهاب عبد القادر

مدرس مساعد، المعهد التقني / الموصل

المستخلص

مؤخراً استخدمت تقنيات فعالة في تشفير الصور الكسوري Fractal Image Coding (FIC) لتقليل تعقيد البحث للتطابق بين كتل المدى Range Block وكتل المجال Domain Block.

الهدف من هذا البحث هو استعمال الخوارزمية الجينية المتوازية Parallel Genetic Algorithm (PGA) بتقنية المدير/ العامل (Manager/ Worker) في حاسبات متوازية للحصول على كتل المجال المتطابقة التي تمنع التقارب غير الصحيح بواسطة تشفير موقع كتلة مجال البحث بشفرة رمادية وبدالة لياقة تقلل المسافة بين تطابق كتلة المدى الحالية مع كتلة مجال البحث لاختيار استراتيجية حماية وتشفير عالي الدقة لأية صورة.

النتائج بينت أن الخوارزمية الجينية المتوازية أثبتت نجاحها في تشفير الصور الكسوري FIC، وأنها مرنة وفعالة للوصول إلى الحل الأمثل بسرعة وكفاءة عاليتين من خلال استخدام الشفرة الرمادية، وأن طريقة البحث المستخدمة للخوارزمية الجينية المتوازية للكبس وفك الكبس للصور، وطريقة اختيار معاملات الخوارزمية الجينية الاختيار والعبور والطفرة كان له دور فعال في تحسين نسبة الكبس ونوعية الكبس للصورة، فقد وصلت نسبة الكبس إلى ٨٧٪ في حين تم تحسين نوعية الصورة بعد فك الكبس التي وصلت إلى ما يقارب ٣٣ مقارنة بالطريقة التقليدية لتشفير الصور الكسوري.

(*) تم استلام البحث في ٢٠١٢/١٠/١٠ وحصل على قبول النشر في ٢٠١٢/١٠/٢٣.

Using Parallel Genetic Algorithms to Compress Fractal Images

Shahlla A. Abd-Al kader

Asst. Lect., Technical Institute\ Mosul

Abstract

Efficient technologies have been recently used in fractal image coding (FIC) to reduce the complexity of searching for matching between range block and domain block.

The research aims at using the Parallel Genetic Algorithm (PGA) by the technology of the (Manager/Worker) in parallel computers to obtain matched domain blocks that prevent unsuitable convergence by coding the site of the searching domain block with a Gray code and a fitness function that minimizes the space between the matching of the current range block with the domain block under discussion in order to choose a protection strategy and coding of high accuracy for any image.

Results showed that PGA is successful in fractal image coding and is flexible and efficient in reaching the optimum solution in higher speed and efficiency through using the Gray code.

The searching method used for the parallel algorithm for compression and decompression, the method of choosing GA's coefficients, the selection, the crossover and mutation had a significant role in improving the image compression ratio and quality. Compression ratio has reached 87% while the image quality was improved after decompression that reached roughly 33% compared to traditional method in fractal image coding (FIC).

Keywords-Parallel Genetic Algorithm (PGA), Fractal Image Coding (FIC), Local Iterated Function System (LIFS), Rang Block, Domain Block.

١- المقدمة:

الكبس وإزالة الكبس للصور من تقنيات الصور الرقمية التي أصبحت جانباً مهماً في تخزينها ونقلها في مجتمع المعلومات. يعدّ تشفير الصور الكسوري (FIC) من احسن خوارزميات الكبس وفك الكبس طوره في العقد الاخير Jacquin و Barnsley. والذي هو نتيجة دراسة نظام الوظيفة المتكرر Iterated Function System (IFS) الكثير من الباحثين عملوا في هذا المجال بسبب ارتفاع معدل الكبس Compression Ratio وبساطة فك الكبس. إن الباحثين يركزون في الوقت الحاضر على كيفية تحديد وتحسين صنف كتل المدى Rang Blocks ، التوازن بين سرعة الكبس وفك الكبس، زيادة معدل الكبس، تحسين جودة الصورة بعد فك الكبس، وخوارزميات كثيرة وضعت في هذا المجال لغرض الحد من التعقيد على أساس تصنيف البحث الذي يقلل التعقيد [5]. فقد استخدم باحثون الخوارزميات الجينية Genetic Algorithm (GA) لكبس الصور الكسوري، والخوارزميات الجينية هي تقنية من تقنيات البحث الذكي التي تستخدم لايجاد حلول تقريبية للمسائل التي تتطلب حلولاً امثلية وتستغرق وقتاً طويلاً لايجادها في التقنيات التقليدية، ويتم في الخوارزميات الجينية توصيف المشكلة بكموسومات تمثل الحلول بوحدة من طرائق الترميز ومعالجتها بطرائق رياضية مستوحاة من العمليات البيولوجية الطبيعية في الكائنات الحية، إذ تستخدم تقنيات الوراثة Inheritance، الاختيار Selection، التزاوج Crossover والطفرات Mutations، للحصول في نهاية المطاف على الجيل النهائي للكموسومات والذي يمثل الحل الأمثل للمشكلة المطروحة، فقد عمل الباحثون [3][10][11][8][4] على تطوير خوارزميات جينية لكبس الصور الكسوري وكانت نسبة الكبس عالية للصورة المختبرة وصلت إلى 88% في حين كانت نوعية الكبس للصورة جيدة تراوحت بين (27-31)db، في ما عمل آخرون [6][12][15][1] على تطوير نظم هجينة من الشبكات العصبية والمنطق المضبب والخوارزميات الجينية لكبس الصور الكسوري إذ كانت النتائج متفاوتة بين طريقة واخرى فقد وصلت نسبة الكبس إلى 90.12% في حين لم تتجاوز نوعية الكبس للصورة

db(31)، وقام الباحثون [13][14] بتطبيق خوارزمية جينية لتسريع كبس الصور الكسوري فمع سرعة الكبس فإن نوعية الكبس للصورة لم تتجاوز db(29). الهدف من هذا البحث تطوير خوارزمية جينية في حاسبات متوازية لتقليل التعقيد والسرعة من أجل الحصول على كتل المجال المتطابق Domain Blocks من الجزء الكسوري في كبس الصور والذي يستخدم نظام الوظيفة المتكرر المحلي Local Iterated Function System (LIFS) وكبس الصور الكسوري. إذ تم لكل كتلة مدى تطوير استراتيجية خوارزمية جينية متوازية بترميز موقع البحث لكتلة المجال وبشفرة رمادية Gray Code ذات دالة لياقة لإيجاد أقل مسافة بين تطابق كتلة المدى الحالية مع كتلة مجال البحث.

في النهاية يكون لدينا نظام ترميز للعثور على كتلة المجال المناسب لكل كتلة مدى وتوزع على عدة حاسبات لتقليل الوقت المستغرق في حساب دالة اللياقة في الخوارزمية الجينية. ما تبقى من البحث كما يلي: القسم الثاني يتضمن تفاصيل الطريقة المستخدمة في البحث، القسم الثالث يشرح المواد ومنهجية البحث المقترحة، القسم الرابع النتائج ومناقشتها، القسم الخامس الاستنتاجات.

٢- الخوارزمية الجينية المتوازية لكبس الكسوري وفك الكبس الكسوري:

ستراتيجية الخوارزمية الجينية المتوازية في كبس الصور الكسوري تكون كالآتي:

٢-١ كبس الصور الكسوري (Fractal Image Coding (FIC:

كبس الصور الكسوري مستند بالأساس على النظرية الكسورية لتحويلات التشابه الذاتية والتقارب الذاتية Self-affine and Self similar transformations وتوضح بالآتي:

٢-١-١ تحويلات التشابه الذاتية والتقارب الذاتية:

النظرية الأساسية في كبس الصور الكسوري تستند بالأساس على تحويلات التشابه والتقارب الذاتي. تحويل التقارب الذاتي $W: R^n \rightarrow R^n$ هو التحول من النموذج $W(x) = T(x) + b$ ،

إذ إن T : هو التحويل الخطي في R_n و $b \in R^n$ هو متجهه. وان
 $W : D \rightarrow D, D \subseteq R^n$ هو التقليص Contraction في D .
 وإذا كانت c أي عدد حقيقي $(0 < c < 1)$ ،
 وان $d(w(x), w(y)) \leq cd(x, y)$ لكل $x, y \in D$ والمقياس d في R^n ،
 فإن العدد الحقيقي c يسمى تقليص Contractility في W .

أما إذا كانت $d(w(x), w(y)) = cd(x, y)$ فإن W تسمى التشابه Similarity
 في مجموعة التقليص $\{w_1, \dots, w_m\}$ التي تُعرف نظام الوظيفة المتكرر المحلي
 (LIFS)، إذا كانت المجموعة الجزئية $F \subseteq D$ لمجموعة التقلصات
 $LIFS\{w_1, \dots, w_m\}$ فإن:

$$F = \bigcup_{i=1}^m w_i(F) \dots \dots \dots (1)$$

إذ إن F ثابت في LIFS. وإذا كان F ثابت في مجموعة التشابهات، F تسمى
 مجموعة التشابهات الذاتية Self Similar Set. ولتكن S تشير إلى الصنف لكل
 المجاميع الجزئية المضغوطة غير الخالية في D ، δ هي جسم متواز Parallel Body
 $A \in S$ التي هي مجموعة النقاط ضمن المسافة δ من A أي بمعنى:

$$A_\delta = \{x \in D : \text{there exists } a \in A \text{ such that } |x - a| \leq \delta\} \dots \dots \dots (2)$$

تعرف المسافة $d(A, B)$ بين مجموعتين A, B بالمعادلة:

$$d(A, B) = \inf \{\delta : A \subset B_\delta \text{ and } B \subset A_\delta\} \dots \dots \dots (3)$$

دالة المسافة في المعادلة (٣) تعرف بـ Hausdorff Metric في S .

وإذا اعطينا مجموعة التقلصات $LIFS\{W_1, \dots, W_m\}$ ، واستحداثات مجموعة احادية مضغوطة ثابتة لـ F تختلف عن المجموعة في المعادلة (١) لمجموعة التشابهات، إذ F يعرف Attractor جذاب النظام. وإذا كانت E مجموعة جزئية مضغوطة غير خالية مثل $W_i(E) \subset E$ فإن:

$$w(E) = \bigcup_{i=1}^m w_i(E) \dots \dots \dots (4)$$

وكذلك نعرف k للتكرار في W ، أي $w^k(E)$ على وفق المعادلة الآتية:

$$w^0(E) = E, w^k(E) = w(w^{k-1}(E)) \dots \dots \dots (5)$$

فلكل $k \geq 1$ نجد المعادلة الآتية:

$$F = \bigcap_{i=1}^{\infty} w^k(E) \dots \dots \dots (6)$$

سلسلة التكرار $w^k(E)$ تنجذب Attractor لأية مجموعة من E ، هذا يعني أنه يوجد عائلة من التقلصات Contractions التقريبية من الصور المعقدة، مجموعة التقلصات هذه للصورة الاصلية يمكن استعمالها في الخزن والنقل بطريقة ذات كفاءة عالية أي إنه LIFS طريقة واضحة وكفاءة للحصول على صورة مشفرة.

٢-١-٢ نظرية Collage:

مجموعة التقلصات $\{w_1, \dots, w_m\}$ في R^n لأي $x, y \in R^n$ ولأية حالة من i ، فإن:

$$|w_i(x) - w_i(y)| \leq c|x - y| \dots \dots \dots (7)$$

إن $c \in (0,1)$ وهو ثابت. وإذا كانت $E \subset R^n$ مجموعة جزئية مضغوطة غير خالية فإن:


$$d(E, F) \leq \frac{1}{(1-c)} d(E, \bigcup_{i=1}^m w_i(E)) \dots \dots \dots (8)$$

إن F مجموعة ثابتة w_i ، d هي Hausdorff Metric، كنتيجة لهذه النظرية فإن أية مجموعة جزئية لـ R^n يمكن أن تقرب ضمن المدى المحدد (tolerance) بواسطة مجموعة التشابه الجزئية، أي بمعنى $\delta > 0$ ، واستحداثا تقليصات متشابهة $\{w_1, \dots, w_m\}$ بمجموعة ثابتة F لتحقيق $d(E, F) < \delta$ ، لهذا المشكلة في إيجاد $LIFS\{w_1, \dots, w_m\}$ التي لها جذاب F إذا أعطيت الصورة I والمعادلة الآتية تكافئ تقليل المسافة $d(I, \bigcup_{i=1}^m w_i(I))$ [10].

٢-١-٣ كبس الصورة الكسوري (FIC):

كبس الصورة الكسوري عملية معقدة جداً لكن فك الكبس عملية سهلة جداً مما يجعل معدل الكبس عالياً فيها، هذا التعقيد جاء لأنها تستند بالأساس إلى نظرية الوظيفة المتكررة، ولبس صورة أصلية بطريقة FIC يكون التعقيد فيها هو كيفية الحصول على معلمات LIFS، والتي تتم كالاتي:

- ١- الصورة الاصلية I تقسم إلى كتل المدى (I) Block Rang لموقع (M) غير المتداخلة بحجم $B*B$ يوضحها الشكل (١)، وبشكل عشوائي لموقع (N) لكتل المجال Domain Block(I) وبحجم $2B*2B$. كتل المدى ترقيم من (1:M) وتمثل بواسطة $R_i (1 \leq i \leq M)$ ، وكذلك كتل المجال ترقيم (1:N) وتمثل بواسطة $D_j (1 \leq j \leq N)$.



شكل (١)

تحويلات كتل المدى- المجال

٢- لكل كتلة مدى R_i ، أفضل تطابق للمجال D_k ($1 \leq K \leq N$) وكذلك تقليص التحويل المتقارب T_{ik} والذي يحقق بالمعادلة الآتية:

$$d(R_i, T_{ik}(D_k)) = \min. d(R_i, T_{ij}(D_j)) \dots \dots \dots (9)$$

إذ إن T_{ik} تحويل التقليص المتقارب من كتلة المجال D_j إلى كتلة المدى R_i ، مقياس التشويش $d(R_i, T_{ij}(D_j))$ هو متوسط مربع الخطأ MSE بين كتلة مدى R_i ، وكتلة المجال المتقلصة $T_{ij}(D_j)$. تحويل التقليص المتقارب T_{ij} مكون من (θ_{ij}, ϕ_j) على وفق المعادلة (10):

$$T_{ij} = \theta_{ij} \circ \phi_j \dots \dots \dots (10)$$

إذ إن ϕ_j تحويل حجم كتلة المجال إلى الحجم نفسه من كتل المدى، وهذا التحويل يوضح كالاتي:

كتلة المجال D_j تقسم إلى 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 .

أما θ_{ij} فهو مكون من خطوتين: الخطوة الاولى تحولات كتلة $\phi_j(D_j)$ بواسطة واحدة من التحويلات الثمانية الآتية: 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 التحويلات الثمانية تسمى Isometries.

أما الخطوة الثانية هي التحول P_{ij} للنقطة الصورية للكتلة المحصل في الخطوة الاولى، ويعرف بالمعادلة الآتية (11):

$$P_{ij}(v) = a_{ij}v + g_{ij} \dots \dots \dots (11)$$

إذ إن: v هي النقطة الصورية pixel للكتلة المحصل عليها في الخطوة الاولى [11].
 g_{ij} ، a_{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.


والمخطط الانسيابي في الشكل (٢) يوضح كبس الصور الكسوري FIC.

وبعد الحصول على معلمات LIFS يتم تشفيرها كالاتي:

١- معلمات تشير إلى موقع افضل تطابق لكتلة المجال.

٢- معلمة تشير إلى isometry لأفضل تطابق لكتلة المجال.

٣- معامل القياس Scaling Coefficient(a_{ij}) ومعامل التعديل offset(g_{ij}) [10][11].



شكل (٢)

كبس الصور الكسوري FIC [11]

٢-٢ 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 بخوارزمية جينية متوازية لإيجاد أقرب حل مثالي. فالخوارزمية الجينية هي تقنيات بحث تستخدم لإيجاد الحلول الحقيقية والتقريبية لمشاكل البحث، إذ يتم فيها توصيف المشكلة لتمثيل الكروموسومات Chromosomes الممثلة للحلول بواحد من طرائق الترميز، بعد ذلك تطبق مجموعة من العمليات الرياضية المستنبطة من العمليات البيولوجية كالعنبر، التوارث، الاختيار، التزاوج والطفرة للحصول في نهاية المطاف على مجموعة من الكروموسومات التي تمثل الجيل النهائي وكل كروموسوم ما هو إلا فرد من أفراد الجيل، وأفضل كروموسوم هو الحل الأمثل الذي تبحث عنه المشكلة المطروحة. إذ تبدأ عملية البحث من مجموعة حلول وليس حلاً واحداً.

الحلول عادة تمثل بصيغة ثنائية (1,0) لكل الاحتمالات الممكنة للمسألة، والجيل الأول يبدأ بتوليد جيل عشوائي لكل الكروموسومات لتمثيل مساحة الحل. الجيل

الجديد يتكون من تقييم كل فرد في الجيل القديم على وفق دالة اللياقة المستخدمة في كبس الصور الكسوري FIC وكالاتي [1]:

- تشفير المعلمات Parameter Coding: تشفير الكروموسومات LIFS المكونة من $\{x, y, z, a, g\}$ بصورة ثنائية، إذ إن $\{x, y\}$ معلمات تشير إلى موقع أفضل تطابق لكتلة المجال، $\{z\}$ معلمة تشير إلى isometry لأفضل تطابق لكتلة المجال، $\{a\}$ معامل القياس، $\{g\}$ معامل التعديل، تسمى هذه الشفرة بالشفرة الرمادية للبحث عن كتلة المجال يوضحها الشكل (٣).

X_n		X_1	Y_n		Y_1	2	1	0
كتلة المجال المتطابق السينية			كتلة المجال المتطابق الصادية			Isometry		

شكل (٣)

الشفرة الرمادية للبحث عن كتلة المجال

الصورة $I(w, w)$ في عملية الكبس تقسم إلى كتل المدى غير المتداخلة بحجم $b \times b$ لكل كتلة مدى والبحث عن موقع كتلة المجال يبدأ عادة من (أعلى - يسار) الصورة وتشفر بواسطة الشفرة الرمادية $g_i (i=1, 2, \dots, n)$ وأكبر قيمة لـ n هي أكثر دقة. ثم تحول الشفرة الرمادية $g_i(n)$ إلى شفرة ثنائية $X_i (i=1, 2, \dots, n)$ كما في المعادلة (١٢) [10]:

$$X_n = g_n$$

$$X_i = X_{i+1} \oplus g_i, (i = n-1, n-2, \dots, 1) \dots \dots \dots (12)$$

ثم نحصل على الرقم العددي X بالمعادلة (١٣):

$$X = 1 + \frac{\sum_{i=1}^n X_i * 2^{i-1}}{2^n - 1} * (w - 2b) \dots \dots \dots (13)$$

- **حجم الجيل Population size:** يقصد به عدد الأفراد ضمن الجيل وهو من العوامل المهمة والتي يتوقف عليها أداء الخوارزمية. لذلك فإن زيادة حجم الجيل سوف يقلل من خطأ النتائج. لكن تنخفض دقة النتائج بشكل ملحوظ عند كون حجم الجيل صغيراً لأنه لا يشمل كامل المجال المدروس بشكل جيد، وحجم الجيل هو (100) كروموسوم عشوائي [1].
- **دالة اللياقة Fitness Function:** سلسلة الكروموسومات المكونة للجيل القديم من بيانات الصورة تتغير إلى الجيل الجديد اعتماداً على دالة اللياقة:

$$Fitness(x) = \begin{cases} \frac{1}{mse(x) + 1} & mse(x) > \varepsilon \\ \infty & mse(x) \leq \varepsilon \end{cases} \dots\dots\dots (14)$$

إن $mse(x)$: هي متوسط مربع الخطأ بين كتلة المدى وكتلة المجال المحصلة من الكروموسوم X ، وإن ε : أقل قيمة خطأ لا تتجاوزها قيمة X ، وقيمة ε هي 0.00001 [10].

- **شرط التوقف Stop Condition:** النتيجة النهائية للخوارزمية تتأثر بشرط التوقف، فمن الممكن أن يكون الشرط هو الوصول بالنتيجة إلى قيمة خطأ محددة مسبقاً نسبة إلى القيمة المرغوب فيها. وقد يضاف إليه شرط آخر هو عدم تجاوز زمن التنفيذ لقيمة محددة، وهذا يحدث إذا ما أدخل مفهوم الزمن الحقيقي لأية دراسة وذلك بأن يُشترط في النظام الحصول على النتيجة قبل وصول المهمة إلى زمنها الحرج المعرف بأنه آخر لحظة زمنية يمكن قبول انتهاء تنفيذ المهمة عندها [2] وحتى يمكن إجراء المقارنات المختلفة عند تغير بقية المتغيرات كان شرط التوقف على وفق عدد مرات التكرار (توليد الأجيال).

- **توليد الأجيال Generation:** توليد الأجيال يعني الحصول على جيل جديد من الأبناء من خلال تزاوج كروموسومات الأباء التي لها لياقة أكبر وفرصة للتزاوج والبقاء، وبهذا يتم توليد جيل جديد من الأبناء بشكل عشوائي أكثر تكيفاً للظروف

البيئية وفناء الأفراد الأقل تكيفاً، لذلك كلما زاد عدد الاجيال فإن الحلول المثلى سوف تحافظ على نفسها في الاجيال اللاحقة بأقل تقدير، وتمر عملية التوليد بثلاث مراحل (الاختيار، العبور، الطفرة).

• الاختيار وفق مبدأ العجلة المتدرجة Roulette Wheel Selection: محاكاة هذه الطريقة تتم بوجود عجلة لها مؤشر تقسم إلى 100 قطاع، أفراد الجيل يُوزعون على القطاعات على وفق متوسط احتمالية الانتخاب لكل فرد من أفراد الجيل الحالي والذي يعطى بالمعادلة (١٥):

$$P_{is} = \frac{F_i}{\sum_{i=1}^M F_i}, (i = 1, 2, \dots, M) \dots \dots \dots (15)$$

إذ إن P_{is} : احتمالية انتخاب الفرد i ,

F_i : درجة ملاءمة الفرد i ,

M : عدد الاجيال.

الاختيار 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.

جيل	$X_{1,0}$	$X_{1,0,1}$	..	$X_{1,1}$	$X_{1,1,1}$	..	$X_{1,2}$	$Y_{1,0}$	$Y_{1,0,1}$	..	$Y_{1,1}$	$Y_{1,1,1}$	..	$Y_{1,2}$	$Z_{1,1}$	$Z_{1,2}$	$Z_{1,3}$
الآباء	$X_{2,0}$	$X_{2,0,1}$	..	$X_{2,1}$	$X_{2,1,1}$	..	$X_{2,2}$	$Y_{2,0}$	$Y_{2,0,1}$	..	$Y_{2,1}$	$Y_{2,1,1}$	..	$Y_{2,2}$	$Z_{2,1}$	$Z_{2,2}$	$Z_{2,3}$
جيل	$X_{1,0}$	$X_{1,0,1}$	..	$X_{1,1}$	$X_{1,1,1}$	..	$X_{1,2}$	$Y_{1,0}$	$Y_{1,0,1}$	..	$Y_{1,1}$	$Y_{1,1,1}$	..	$Y_{1,2}$	$Z_{1,1}$	$Z_{1,2}$	$Z_{1,3}$
البناءء	$X_{2,0}$	$X_{2,0,1}$	..	$X_{2,1}$	$X_{2,1,1}$	..	$X_{2,2}$	$Y_{2,0}$	$Y_{2,0,1}$	..	$Y_{2,1}$	$Y_{2,1,1}$	..	$Y_{2,2}$	$Z_{2,1}$	$Z_{2,2}$	$Z_{2,3}$


شكل (٤)

العبور للشفرة الرمادية

٣-٢ الخوارزمية الجينية المتوازية:

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 تعدّ المدير، و N من الحاسبات الطرفية بوصفها عمالاً، الموضحة بالشكل (٥). المدير يعمل على تأسيس الاتصال مع العمال من خلال إرسال إشارة الاتصال، ثم يقوم بتوليد كروموسومات الجيل الابتدائي عشوائياً وتوزيعها على العمال بالتساوي، 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 لإنهاء 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 الخوارزمية الجينية، وجزء من الكروموسومات الكلية لتنفيذ الخوارزمية بدالة اللياقة، ومن ثم إرسال ناتج الخوارزمية الجزئية إلى المدير، العمليات تكرر لكل عامل مع كل إرسال من المدير إلى أن يستلم إشارة بإنهاء الاتصال بعد الوصول إلى الحل الأمثل النهائي [7][9]، والنظام المقترح للخوارزمية الجينية المتوازية (PGA) يوضح في الشكل (٦).

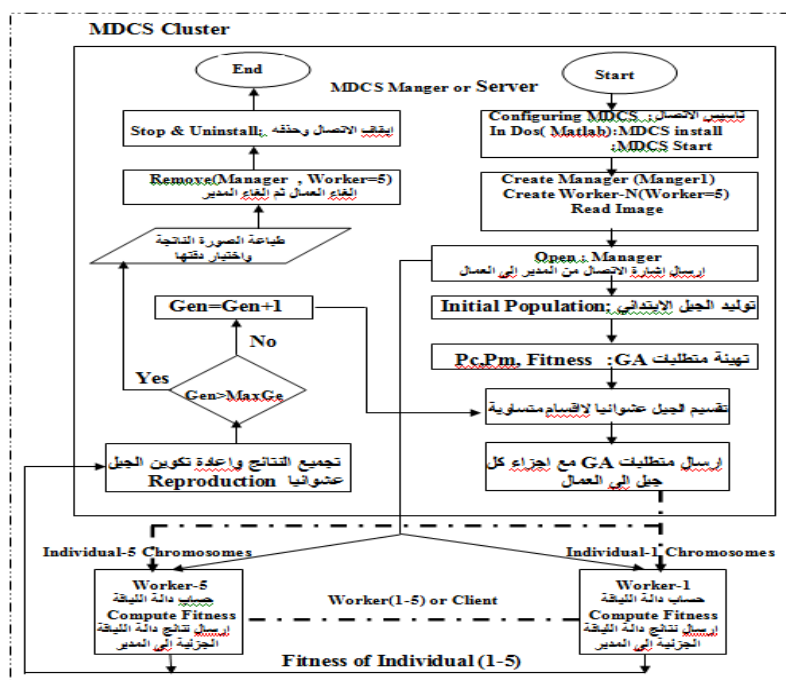


شكل (٥)

الخوارزمية الجينية المتوازية [7]

٣- مواد البحث وطرائقه:

على وفق ما تقدم في المقطع الثاني، استخدمت بيانات الصورة الاصلية الرمادية لـ (Lena) بحجم 256×256 والتي شغرت بـ 8-bit/pixel لكل نقطة صورية والجدول ذو الرقم (١) يمثل البيانات المستخدمة في تمثيل أنموذج الخوارزمية الجينية المتوازية. استخدمت تقنية (MDCS) 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، إذ ربطت ٦ حاسبات التي بينت بالتجربة أنها تحقق سرعة في التنفيذ، واحدة منها تمثل المدير يعمل على إدارة الخوارزمية كخادم Server، العمال Worker-N الذين يعملون كطرفيات وهنا عدد الحاسبات $Worker-N=5$.



شكل (٦)

مخطط النظام المقترح PGA في كبس الصورالكسوري

جدول (١)

بيانات أنموذج الخوارزمية الجينية المتوازية

120-50	عدد الاجيال
100-50	حجم افراد الجيل الكلي المولد في المدير Manager
20-10	حجم الجيل المستلم لكل عامل Worker
معادلة (14)	دالة اللياقة
1	احتمالية العبور المثالية (Pc)
0.001	احتمالية الطفرة المثالية (Pm)
4*4	حجم كتلة المدى

٤- مناقشة النتائج:

تشير النتائج التي حصل عليها أن تطبيق الخوارزمية الجينية المتوازية لها تأثير في تحسين عملية الكبس وفك الكبس الكسوري FIC. تبين ذلك من خلال استخدام صور رمادية بالحجم 256×256 لصورة Lena بشفرة 8-Bit/Pixel. الاستراتيجية المثالية من النقط الصورية (Pixel) للشفرة الرمادية لفضاء البحث مكونة من 14-bit لكتلة المجال المتطابق (باحداثيات عمودية وافقية)، 3-bit للمعلمة 5-bit somorphic لمعلمة القياس، 7-bit لمعلمة التعديل. ولكل كتلة مدى الشفرة الكسورية مكونة من 29-bit وتخزن في ملف نصي يسمى ملف الكبس. خلال عملية التكرار لفك كبس الصورة تم التغلب على قيم الصورة الرمادية اذا تجاوزت المدى (0-256) بأخذ معدل جيران النقطة الصورية الأربعة لتجنب التباعد عن القيم الاصلية.

النتائج قيست على أساس وقت التنفيذ وعدد مرات التكرار وحجم الجيل، فمع بقاء حجم الجيل بمقدار 100، وانخفاض عدد مرات التكرار من 120-50 ازداد معه فضاء البحث وتم الحصول على ارتفاع متدرج في نوعية الصورة ونسبة ضغط الصورة.

يوضحها الجدول ذو الرقم (٢) إذ تراوحت قيمة PSNR بين (27.43-32.89)، رافقها ارتفاع متدرج لنسبة الكبس التي وصلت إلى 87.47. كذلك تم الحصول على أفضل نوعية للصورة ونسبة كبس عالية عند زيادة حجم الجيل الذي عمل على زيادة مساحة البحث، موضحة بالجدول (٣). فمع زيادة حجم الجيل وبقاء عدد مرات التكرار ثابت، قلت نسبة الخطأ خاصة بعد زيادة حجم الجيل عن حد معين، وهذا واضح عندما كان حجم الجيل مساوياً لـ 50 إذ وصلت نوعية الكبس PSNR إلى 27.86 ثم ارتفعت ووصلت 32.89 عندما ازداد حجم الجيل إلى 100، انعكس ذلك أيضاً على نسبة الكبس الذي ازداد مع زيادة حجم الجيل ووصلت إلى 87.47 عند الجيل 100. من الجدول (٢) و(٣) تبين أنه مع زيادة حجم الجيل وانخفاض عدد مرات التكرار تدريجياً أن أفضل حالة عند حجم الجيل مساوي لـ 100 وعدد مرات التكرار مساوية 50، والتي يوضحها الشكل (٧) لصورة Lena.

جدول (٢)

نتائج صورة Lena المحصل من عدد مختلف من التكرارات

نسبة الكبس	نوعية الكبس	الوقت	مرات التكرار	حجم الجيل
Compression ratio%	PSNR	Time(S)	Iteration	Population size
79.45	27.43	20	120	100
80.66	27.76	22	100	100
81.86	28.56	23	90	100
83.89	28.89	25	80	100
84.75	30.65	27	70	100
87.47	32.89	29	50	100

جدول (٣)

نتائج صورة Lena المحصل من زيادة حجم الجيل

نسبة الكبس	نوعية الكبس	الوقت	مرات التكرار	حجم الجيل
Compression ratio%	PSNR	Time(S)	Iteration	Population size
80.76	27.86	19	50	50
81.87	28.89	22	50	60
82.56	29.17	23	50	75
83.77	30.54	26	50	80
85.65	31.87	27	50	90
87.47	32.89	29	50	100



شكل (7b)

الصورة بعد الكبس



شكل (7a)

الصورة الاصلية

وعلى الرغم من سرعة الخوارزمية الجينية المتوازية لوحظ أن هناك زيادة في الوقت بين حالة وأخرى. الزيادة في الوقت تم تقليله بواسطة الخوارزمية الجينية المتوازية أيضاً، من خلال وجود نسبة خطأ ضئيلة مع بقاء حجم الجيل 100 نفسه وبتكرار 50. نسبة الخطأ هذه اثبتت أنها تقلل وقت الكبس من دون أي خسارة في نسبة ونوعية الكبس للصورة وكما موضح بالجدول (٤). ولغرض قياس كفاءة هذه الطريقة تم مقارنتها مع الطريقة القياسية الكسورية الموضحة بالجدول (٥) إذ تبين أن نوعية

الكبس للخوارزمية الجينية المتوازية تتراوح بين (32.88-32.15)، وأن نسبة الكبس وصلت إلى 87٪، مع سرعة في الوصول للحل وصلت إلى (19s). أما في الطريقة القياسية الكسورية كان هناك انخفاض في وقت التنفيذ رافقه انخفاض في نوعية الكبس الذي تراوح بين (32.32-22.76) مع زيادة قليلة في نسبة الكبس التي وصلت إلى (83.85) وكما موضح في الشكل (٨) لصورة لنا بوجود نسبة خطأ (0.1) لكل طريقة فالصورة (8b) وضحت الصورة بعد الكبس في الخوارزمية الجينية المتوازية التي حصل عليها بوقت أقل من الصورة (8c) المحصل عليها باستخدام الخوارزمية الكسورية القياسية.

جدول (٤)

نتائج صورة Lena بعد إضافة نسبة خطأ في PGA

نسبة الكبس	نوعية الكبس	الوقت	مرات التكرار	نسبة خطأ	حجم الجيل
Compression ratio%	PSNR	Time(S)	Iteration	Error	Population size
87.89	32.88	29	50	0.01	100
87.76	32.74	28	50	0.03	100
87.32	32.66	27	50	0.06	100
87.19	32.51	25	50	0.08	100
87.11	32.37	22	50	0.09	100
87.08	32.15	19	50	0.1	100

جدول (٥)

نتائج صورة Lena بعد اضافة نسبة خطأ في FIC القياسية

نسبة الكبس	نوعية الكبس	الوقت	مرات التكرار	نسبة خطأ	حجم الجيل
Compression ratio%	PSNR	Time(S)	Iteration	Error	Population size
80.98	32.32	65	–	0.01	–
81.89	32.21	54	–	0.03	–
82.88	30.11	42	–	0.06	–
83.11	28.76	36	–	0.08	–
83.55	25.76	33	–	0.2	–
83.85	22.76	24	–	0.1	–



(8c)
FIC القياسية

(8b)
PGA

شكل (8a)
الصورة الاصلية

الاستنتاجات والتوصيات:

الخوارزمية الجينية المتوازنة أثبتت نجاحها لتحسين كبس الصور الكسوري من خلال استخدام الشفرة الرمادية للصبغيات التي منعت التقارب غير الجيد للصبغي من خلال تحسين أداء الخوارزمية للوصول إلى الصبغي المثالي.

النتائج بينت ان الشفرة الرمادية مرنة وفعالة للوصول إلى الحل الأمثل بسرعة وكفاءة عاليتين بتقنية المدير/ العامل، وأن طريقة البحث المستخدمة في كبس الصور للخوارزمية الجينية المتوازنة للكبس وفك الكبس، وطريقة اختيار معاملات الخوارزمية الجينية الاختيار والعبور والطفرة كان له دور فعال في تحسين نسبة الكبس التي وصلت إلى 87٪ وتحسين نوعية الصورة بعد فك الكبس التي وصلت إلى ما يقارب 33.

أوصي باستخدام التقنية المتوازنة في ايجاد الحلول لأية مشكلة إذا كان عامل السرعة مهم لحلها، كما أوصي باستخدام هذه التقنية على الصور الملونة.

قائمة المصادر

- [1] الحجار، م. عبید، م. (٢٠٠٣)، الخوارزميات الجينية، إشراف هادي العرفي، مشروع دبلوم، جامعة دمشق، كلية الهندسة الميكانيكية والكهربائية.
- [2] مزهر، و.، داود، ع.، بحبوح، أ. (٢٠٠٣)، "محاكاة عمل قواعد المعطيات الموزعة في بيئة زمن حقيقي مع تشارك الحمولة"، مجلة جامعة دمشق للعلوم الهندسية، المجلد ١٩، العدد ٢.
- [3] A. Ben Jmaa, M. Ben Jemaa & Y. Ben Jemaa (2006), "Optimization of fractal image compression with genetic algorithms", A. BEN JMAA is with National School of Engineering of Sfax, BPW, 3038 Sfax ahmed.benjmaa@gmail.com.
- [4] B. S. Sanjay, M. V. Kulkarni (2010), "Fractal Image Compression Using Genetic Algorithm", Advances in computer Engineering ACE, India.
- [5] Mingshui Li, Shanhu Ou & Heng Zhang (2004), "The new progress in research approach of fractal image compression, Journal of Engineering Graphics. 4(3), 143-152.
- [6] M. Mohamed (2006), "Optimization of Fractal Image Compression Based On Kohonen Neural Networks", EEDIS Laboratory, Engineering Faculty, University of SBA.
- [7] P. Borovska (2006), "Solving the Travelling Salesman Problem in Parallel by Genetic Algorithm on Multicomputer Cluster", Computer Systems Dept., Technical University of Sofia.
- [8] M. Sheng, J. H. Jeng (2006), "Schema genetic algorithm for Fractal Image Compression", Dept. of Electronic Engineering, N. S. Yet-Sen University, Taiwan.
- [9] S. Tongcham, Prabhas (2000), "Parallel Genetic Algorithm for Finite-State Machine Synthesis from Input/Output Sequences", Department of Computer Engineering, Chulalongkorn University Bangkok 10330, Thailand.

- [10] X, Lifeng, Z, Liangbin (2007), "A Study of Fractal Image Compression Based on an Improved Genetic Algorithm", Zhejiang Wanli University.
- [11] Y.Chakrapani, K. Soundara (2009), "Genetic Algorithm Applied to Fractal Image Compression", Dept. of Electronic and communications, J.N.T.U College of Engineering, India.
- [12] Y.Chakrapani, K. Soundara (2008), "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.
- [13] Y.Chakrapani, K. Soundara (2008), "Hybrid Genetic–Simulated Annealing Approach for Fractal Image Compression", Dept. of Electronic and communications, J.N.T.U College of Engineering, India.
- [14] Y.Chakrapani, K. Soundara (2009), "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.
- [15] Y.Chakrapani, K. Soundara (2009), "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.