

## Developing a Genetic Algorithm to Select the Important Features from a Set of Extracted Brain Image Features to Achieve Fast and Accurate Classifier

Dr. Samir Kraman<sup>\*</sup>  
Dr. Rasha Masoud<sup>\*\*</sup>  
Sobhi Al-Shikha<sup>\*\*\*</sup>

(Received 3 / 2 / 2019. Accepted 13 / 3 / 2019)

### □ ABSTRACT □

Classification process for a large number of MRI brain images, and a large number of features extracted, will be done with less accuracy and slowly. To achieve a fast and accurate classifier, we must reduce these features. Feature selection refers to the procedure of selecting a subset of informative attributes to build models describing data. The main purpose of feature selection is to reduce the number of features used in classification while maintaining high classification accuracy. A large number of algorithms have been proposed for feature subset selection.

In this paper, we have use MRI brain image to determine the area of tumor in brain. The steps started by preprocessing operation to the image before inputting it to algorithm. The image was converted to gray scale, later on remove film artifact using special algorithm, and then remove the Skull portions from the image without effect on white and gray matter of the brain using another algorithm, After that the image enhanced using optimized median filter algorithm and remove Impurities that produced from first and second steps, then we used the Gaussian Pyramid algorithm with Laplacian pyramid algorithm for detecting edges in the image, Finally we use a developed genetic algorithm for feature selection, and apply the K Nearest Neighbor for classification.

**Keywords:** MRI Brain images, Tracking Algorithm, Modified Tracking Algorithm, Center Weighted Median Filter, Gaussian Pyramid, Laplacian Pyramid, Genetic Algorithm, K Nearest Neighbor.

---

<sup>\*</sup>Associate Professor, Faculty of Mechanical and Electrical Engineering , Damascus University, Damascus, Syria.

<sup>\*\*</sup>Associate Professor, Faculty of Mechanical and Electrical Engineering , Damascus University, Damascus, Syria.

<sup>\*\*\*</sup>Postgraduate Student, Faculty of Mechanical and Electrical Engineering , Damascus University, Damascus, Syria.

## تطوير خوارزمية جينية لتحديد الخصائص الهامة من صور الرنين المغناطيسي للدماغ للحصول على مصنف أسرع وأدق

الدكتور سمير كرمان\*

الدكتورة رشا مسعود\*\*

صبي الشيخة\*\*\*

(تاريخ الإيداع 3 / 2 / 2019. قُبِلَ للنشر في 13 / 3 / 2019)

### □ ملخص □

ان اجراء عملية التصنيف لكمية كبيرة من صور الرنين المغناطيسي للدماغ، لمجموعة كبيرة من الخصائص المستخرجة من هذه الصور سيتم بدقة محدودة وبسرعة بطيئة، وللحصول على مصنف أسرع وأدق يجب تقليل هذه الخصائص. ان تحديد الخصائص هو إجرائية تحديد مجموعة صغيرة من الخصائص لبناء نموذج توصيف البيانات. ان الهدف الرئيسي من تحديد الخصائص هو تقليل عدد الخصائص المستخدمة للتصنيف وذلك لتحسين الدقة والسرعة. هناك عدد كبير من الخوارزميات التقليدية قدمت سابقاً لتحديد المجموعات الجزئية من الخصائص، في هذه المقالة تم استخدام قاعدة بيانات صور رنين الدماغ المأخوذة من الموقع:

**The MNI BITE database** <http://www.bic.mni.mcgill.ca/~laurence/data/data.html#>

تبدأ الخطوات بإجراء معالجة أولية للصورة قبل إدخالها الى الخوارزمية بتحويلها إلى صورة ثنائية بتدرج رمادي ليتم بعد ذلك إزالة المعلومات النصية من الصورة (معلومات المريض وبارامترات صورة الدماغ) وذلك باستخدام خوارزمية خاصة، بعد ذلك يتم إزالة أجزاء الجمجمة من صورة الدماغ دون التأثير على المادة البيضاء والمادة الرمادية في الدماغ. ثم بعد ذلك يتم استخدام مرشح معدل (مطور) عن المرشح الوسيط لإزالة الشوائب من الصورة الرقمية الناتجة، يتم ضغط الصورة وتمديدتها باستخدام الهرم الغاوصي، ليتم بعدها كشف حواف الصورة الناتجة باستخدام هرم اللابلاسيان، يتم استخراج خصائص الاكساء من الصورة وهي عبارة عن مجموعة كبيرة من الخصائص، كخصائص التباين (النصوع)، وخصائص التصحيح وخصائص التجانس وخصائص العشوائية، بعدها يتم تطبيق خوارزمية جينية مطورة لتحديد الخصائص الهامة من الخصائص الكبيرة المستخرجة لإدخالها الى مصنف K اقرب جار .

**الكلمات المفتاحية:** صور الرنين المغناطيسي للدماغ، خوارزمية الأثر، خوارزمية الأثر المعدلة، خوارزمية المرشح الوسيط المركزي الموزون، هرم غاوص، هرم لابلاسيان، الخوارزمية الجينية.

\* أستاذ مساعد، رئيس قسم الحواسيب والاطمئة ، كلية الهندسة الكهربائية والميكانيكية، جامعة دمشق، سورية

\*\* أستاذ مساعد، قسم الهندسة الطبية، كلية الهندسة الكهربائية والميكانيكية، جامعة دمشق، سورية

\*\*\*طالب دراسات عليا (دكتوراه) ، كلية الهندسة الكهربائية والميكانيكية، جامعة دمشق، سورية

## مقدمة

منذ أواخر القرن الماضي، غير تطور تقانات التصوير الطريقة التي ينتج بها العلم حيث كانت الصور الطبية تستخدم في الماضي للتعليم وإظهار الاستنتاجات العلمية، بينما أصبح التصوير الطبي اليوم، بما في ذلك التقاط الصور ومعالجتها، أداة بحث وتشخيص سريري روتينية. ونظرا إلى كون دماغ الإنسان هو الجزء الأهم من جسمه فقد لقي الاهتمام الأكبر في مجال التصوير الطبي، ولذلك سنستخدم صوره لتوضيح المفاهيم الأساسية المعروضة في هذا البحث.

تشمل البارامترات السريرية لصورة الدماغ:- القياسات الحجمية- قياسات الشكل (المورفولوجيا: الطول، العرض، المساحة التقوس، إلخ) -مدى الضرر الذي ألحقه المرض بالعضو (درجة الورم، مثلا) والأسباب المرضية -وظيفة العضو المصور (سلامته الوظيفية) .

وبعد التصوير بالرنين المغناطيسي ملائما جدا للدراسة غير الجراحية لأمراض الدماغ ووظائفه وبنيته من حيث تكوينها الشكلي وهذا النوع من الصور وعمليات معالجتها مفيدة جدا في تحليل الصور الطبية وتشخيصها [1].

إن مجال معالجة الصور الرقمية يرمز إلى معالجة الصور الرقمية بواسطة الحاسوب إما لتحسينها من أجل التشخيص منظورا إليها من قبل المشخص وهو الطبيب، أو لتعرف محتواها الطبي وفهم الحالة المرضية الموجودة فيها عن طريق الحاسوب باستخدام تقنيات معالجة الصور الرقمية كتقنية فهم الصور أو تحليلها image analysis ، أو تشخيص الحالة المرضية فيها (CID) computer image diagnosis. يمكن تقسيم طرائق معالجة الصور الرقمية إلى صنفين أساسيين واسعين: الصنف الأول: يكون دخله صورة وخرجه صورة أيضا، أما الصنف الثاني فيمكن أن يكون دخله صورا ولكن خرجه خصائص attributes استخلصت من هذه الصور.

## أهمية البحث وأهدافه

يهدف هذا البحث الى إيجاد خوارزمية سريعة وفعالة لتصنيف صور الرنين المغناطيسي للدماغ، وذلك بإجراء مجموعة من الخوارزميات المطورة لتحسين الصورة الطبية ثم ضغطها وكشف حوافها ومن ثم استخراج الخصائص المميزة للصورة وبعد ذلك يتم تطوير خوارزمية جينية لتحديد اهم الخصائص على الصورة الناتجة لكشف المناطق التي فيها احتمال إصابة بالمرض، وتحديد كون هذا المرض حميد او خبيث.

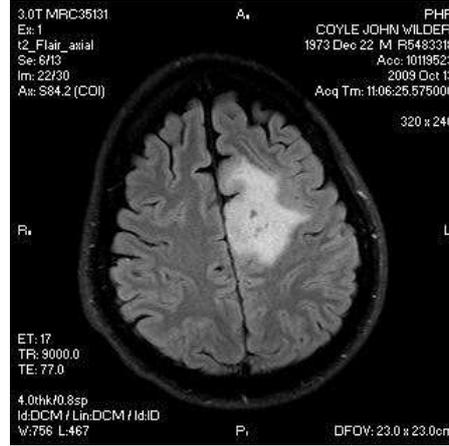
## طرائق البحث ومواده

تم الحصول على قاعدة بيانات لصور رنين مغناطيسي للدماغ مكونة من حوالي 6500 صورة طبية عليها مجموعة من المعلومات للمريض وبيانات سريرية لصورة الدماغ وذلك من موقع

The MNI BITE database <http://www.bic.mni.mcgill.ca/~laurence/data/data.html#>

حيث تم اجراء مجموعة الخوارزميات المقترحة في البحث على عينة من هذه الصور. هذه الخوارزميات تبدأ بخوارزمية الأثر التي تقوم بحذف البيانات المحيطة بصورة الدماغ، وخوارزمية الأثر المعدلة التي تزيل الجمجمة لتبقي على الدماغ بمادتيه الرمادية والبيضاء، ومن ثم يتم تحسين الصورة وإزالة الشوائب عنها باستخدام خوارزمية مطورة عن المرشح الوسيط خوارزمية (المرشح الوسيط المركزي الموزون)، ثم يتم ضغط

الصورة وتوسيعها باستخدام هرم غاوص، بعد ذلك يطبق هرم اللابلاسيان لكشف الحواف، ثم يتم استخراج خصائص النسيج باستخدام خوارزمية مصفوفة التوارد Gray Level Co-Occurrence Matrix وهي خصائص النصوص وخصائص التصحيح وخصائص التجانس وخصائص العشوائية. بعد ذلك تم تطوير خوارزمية جينية لتحديد الخصائص الهامة من مجموعة الخصائص المستخرجة لإجراء عملية التصنيف بدقة وسرعة أعلى. تم استخدام برنامج الماتلاب MATLAB 2017 لتطبيق الخوارزميات المقترحة والحصول على النتائج المطلوبة.



### طريقة العمل المقترحة:

#### 1 إزالة البيانات النصية باستخدام خوارزمية الأثر:

تحتوي صور الرنين المغناطيسي للدماغ معلومات نصية او بيانات أخرى كاسم المريض وعمره وبيانات عن الصورة المأخوذة [2]، يتم إزالة هذه المعلومات الغير مرغوبة أثناء معالجة الصورة باستخدام الخوارزمية التالية:

- قراءة الصورة وتخزينها في مصفوفة ثنائية البعد.
- تحديد قيمة العتبة العليا (لإزالة اللوحة الاسمية).
- ارجاع قيمة العناصر الى القيمة 255 (اللون الأبيض).
- إذا كانت قيمة البكسل = 255 تعاد القيمة الى الصفر وبالتالي نحصل على إزالة للتسميات الموجودة على صورة ال MRI.

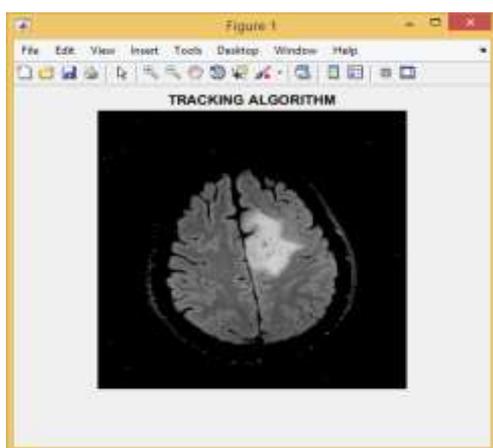
- إذا كانت القيمة أقل من 255 تبقى قيمة البكسل على حالها.

الشكل 1: الصورة البدائية التي تم الحصول عليها من قاعدة البيانات

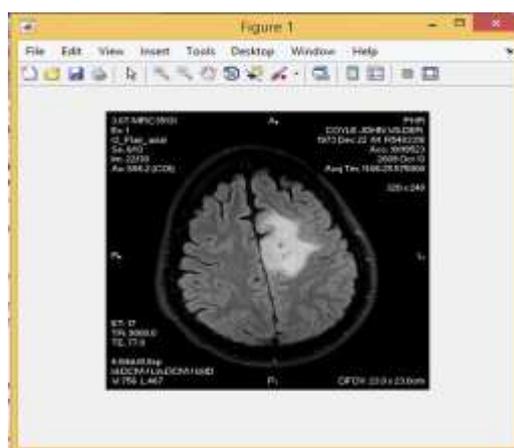
نتيجة تطبيق هذه الخوارزمية نحصل على صورة بدون معلومات نصية محيطة بالدماغ، ولكنها تحتوي على ضجيج الملح والفلفل.

الشكل 2 يوضح الصورة الناتجة عن تحويل الصورة الأساسية الى تدرج الرمادي، الشكل 3 يوضح الصورة

الناتجة بعد تطبيق خوارزمية الأثر (نلاحظ ضجيج الملح والفلفل الناتج بعد عملية المعالجة).



الشكل 3: الصورة بعد إزالة المعلومات باستخدام خوارزمية الأثر



الشكل 2: الصورة البدائية بعد تحويلها لتدرج الرمادي

## 2 إزالة أجزاء الجمجمة باستخدام خوارزمية الأثر المعدلة:

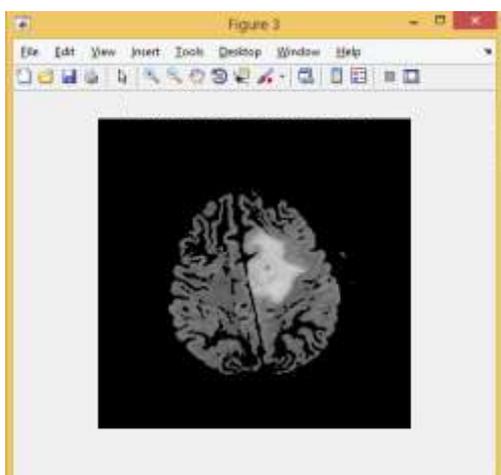
تستخدم هذه الخوارزمية لإزالة الأجزاء اليمنى واليسرى من الجمجمة المحيطة بالدماغ والتي تعتبر غير مرغوبة

أثناء معالجة الصورة. خطوات الخوارزمية:

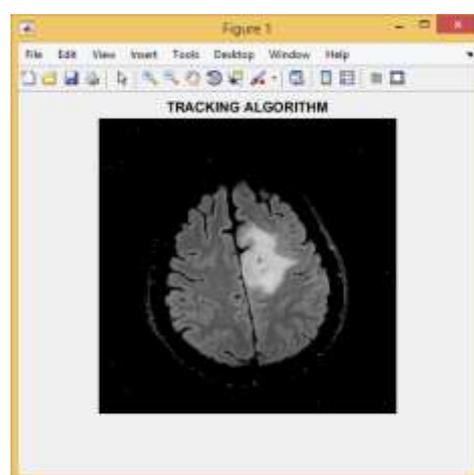
- قراءة الصورة وتخزينها في مصفوفة ثنائية البعد.
- البداية من السطر الأول والعمود الأول في المصفوفة.
- حدد قيمة العتبة العظمى من الجانب الأيسر للمصفوفة.
- ارجاع قيمة العناصر ذات العتبة الى القيمة 200.
- إذا كانت قيمة الكثافة ضمن المجال [200-255] أرجع قيمة العنصر الى الصفر، وبالتالي الجانب الأيسر من الجمجمة تمت إزالته.
- كرر العمليات من 2-5 لإزالة الجانب الأيمن من الجمجمة.

الشكل 5 يوضح الصورة الناتجة بعد تطبيق خوارزمية الأثر المعدلة (نلاحظ ضجيج الملح والفلفل الناتج بعد

عملية المعالجة).



الشكل 5: الصورة بعد إزالة أجزاء الجمجمة باستخدام خوارزمية الأثر المعدلة



الشكل 4: الصورة بعد إزالة المعلومات باستخدام خوارزمية الأثر

### 3- تحسين الصورة باستخدام المرشح الوسيط الموزون:

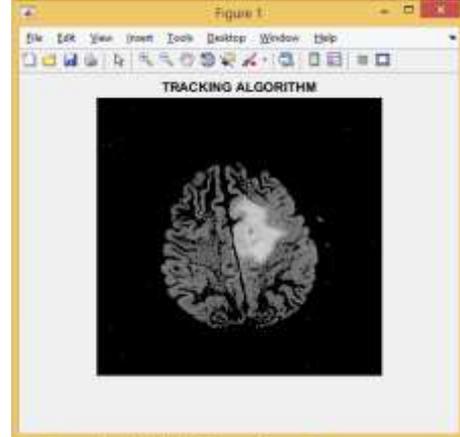
الهدف الرئيس من تحسين الصورة هو معالجتها بحيث تكون نتيجة المعالجة أفضل من الصورة الأصلية لتطبيق معين، حيث تقع طرائق تحسين الصورة في تصنيفين أساسيين [3]:

- طرائق المجال الحيزي (وتعتمد هذه الطرائق على معالجة عناصر الصورة مباشرة).
- طرائق المجال الترددي (وتعتمد على تعديل تحويل فورييه للصورة).

يستخدم المرشح الوسيط لإزالة الضجيج عن الصور الطبية وإزالة المكونات ذات التردد العالي الناتجة عن التصوير بتقنية MRI والتي تعتبر مزعجة للحواف، وضجيج الملح والفلفل. وهناك معياران يتم الاعتماد عليهما بشكل كامل في هذا المرشح:

حجم النافذة والمعطى بالعلاقة  $(2N+1) * (2N+1)$  وهو يساوي عدد عناصر النافذة M وزن العنصر الوسيط المعطى بالعلاقة  $2K+1$  حيث  $K \geq 0$  ويتم إعطاء باقي عناصر النافذة القيمة 1. وقد تم تطوير هذا المرشح للحصول على نتائج أفضل باستخدام الأوزان، حيث تعتمد هذه الطريقة على إعطاء أوزان للبكسلات بحسب مجال الكثافة، فيما يلي خطوات الخوارزمية:

- نستخدم أربعة أوزان مثل: 0 ، 0.1 ، 0.2 ، 0.3 .
  - إذا كانت قيمة الكثافة للبكسل مساوية للصفر يضرب البكسل بالوزن 0.
  - وإلا إذا كانت كثافة البكسل ضمن المجال [1-100] نضرب قيمة البكسل بالوزن 0.1.
  - وإلا إذا كانت كثافة البكسل ضمن المجال [101-200] نضرب قيمة البكسل بالوزن 0.2.
  - وإلا نضرب قيمة البكسل بالوزن 0.3.
- تطبيق المرشح الوسيط (نختار نافذة ولتكن  $3 \times 3$  ونرتب عناصرها تصاعديا ونختار العنصر الأوسط وننسب اليه باقي عناصر النافذة).



الشكل 5: الصورة بعد إزالة أجزاء الجمجمة باستخدام خوارزمية الأثر المعدلة الشكل 6: الصورة الناتجة عن خوارزمية المرشح الوسيط المركزي الموزون

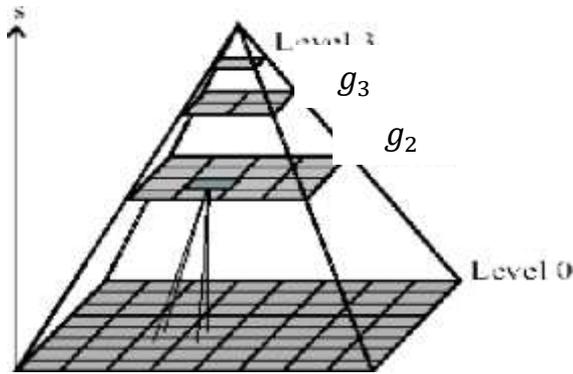
### 4- ضغط وتوسيع الصورة باستخدام هرم غاوص:

هو سلسلة من مرشحات التمرير المنخفض Low Pass Filter ذو عدة مستويات يقوم في كل مستوى بتخفيض ابعاد الصورة حسب ال Kernel

$$[g_k] = [g_0 * g_1 * \dots * g_{H-1}]$$

حيث H هو ارتفاع الهرم

تتولد هذه الطبقات  $g_k$  من الصورة الأصلية  $g_0$  باستخدام تابع التقليل:



حيث يوضح الشكل 6 طبقات هرم غاوص المتناقصة باستخدام تابع التقليل

$$g_{k+1} = \text{REDUCE}(g_k)$$

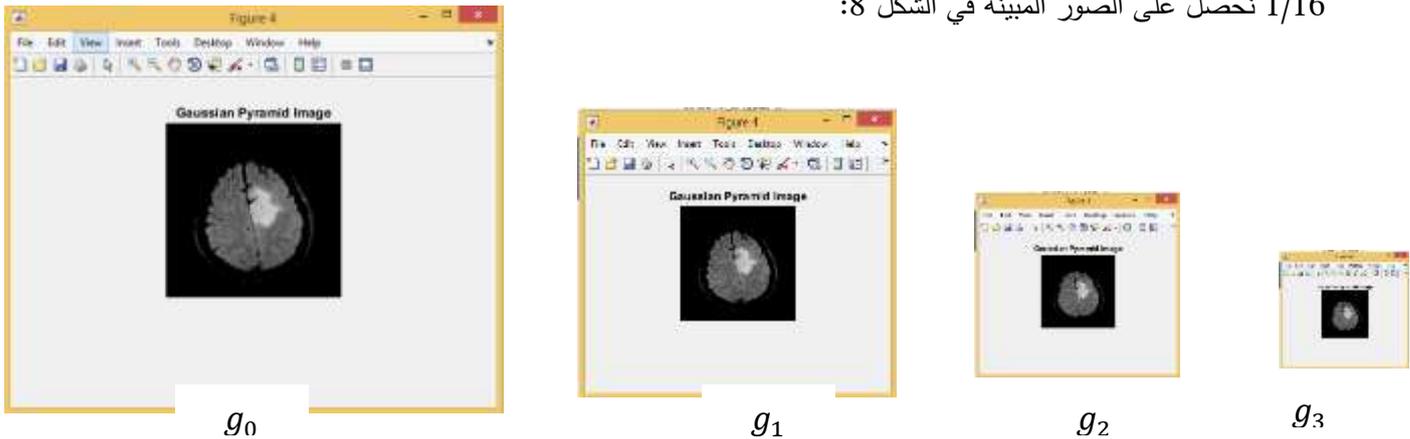
$$g_0 \quad g_1$$

$$g_{k+1}(i, j) = \sum_{p=-2}^2 \sum_{q=-2}^2 w(p, q) g_k(2i + p, 2j + q)$$

الشكل 7: هرم غاوص

بتطبيق خوارزمية هرم غاوص على الصورة الناتجة عن المرشح الوسيط الموزون لاربع طبقات من أجل كيرنال

1/16 نحصل على الصور المبينة في الشكل 8:



الشكل 8: الصور الناتجة عن تطبيق هرم غاوص لأربع طبقات

يتم تكبير الصور المصغرة باستخدام تابع التوسيع الغاوصي Expanded Gaussian Pyramid

وهو عبارة عن سلسلة من الصور الموسعة المولدة من الصورة  $g_k$  بواسطة تابع التوسيع.

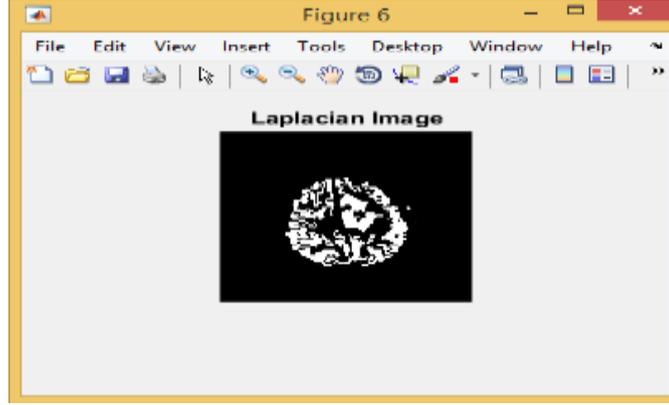
$$g_k^* = \text{EXPAND}(g_{k+1})$$

$$g_k^*(i, j) = 4 \sum_{p=-2}^2 \sum_{q=-2}^2 w(p, q) g_{k+1}((i-p)/2, (j-q)/2)$$

5- كشف الحواف باستخدام تابع اللابلاسيان:

وهو عبارة عن مرشح تمرير عالي، حيث يتم طرح كل صورة في كل مستوى من مستويات هرم غاوص (بعد توسيعها باستخدام تابع التوسيع الغاوصي) من الصورة الأصلية الناتجة عن المرشح الوسيط الموزون، فنحصل في كل عملية طرح على صورة مزال منها المادة البيضاء والمادة الرمادية للدماغ ومحدد فيها الحواف فقط.

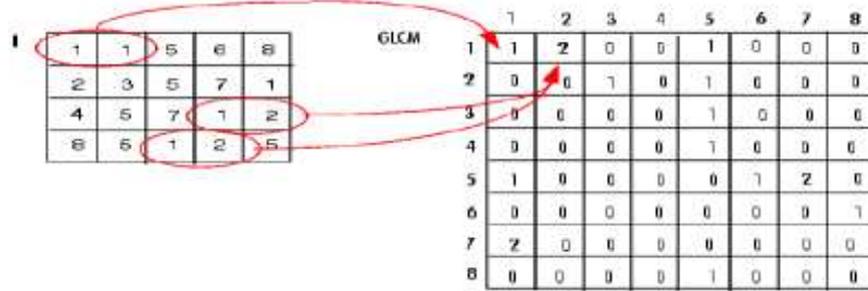
$$L_k = g_k - g_k^*, 0 \leq k < H - 1$$



الشكل 9: الصورة الناتجة عن تطبيق تابع اللابلاسيان

6- استخراج خصائص النسيج باستخدام مصفوفة التوارد (Gray Level Co-Occurrence Matrix):

وهي تصف العلاقات المكانية بين مستويات الرمادي في الصورة.



الشكل 10: طريقة عمل مصفوفة التوارد GLCM

هذه الخصائص التي يتم استخراجها هي: خصائص التباين (النسوع)، وخصائص التصحيح وخصائص

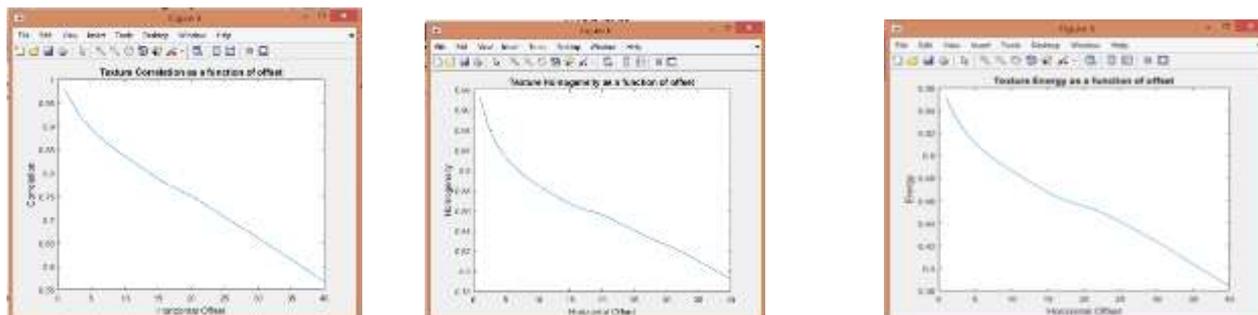
التجانس وخصائص العشوائية، والتي تعطى وفق الصيغ الرياضية التالية

$$\text{Contrast} = \sum_{n=0}^{Ng-1} n^2 \left\{ \sum_{l=1}^{Ng} \sum_{j=1}^{Ng} p(l, j) \right\}, |l, j|$$

$$\text{Entropy} = \sum_l \sum_j P_d^2(l, j) \log P_d(l, j)$$

$$\text{Correlation} = \sum_l \sum_j (l - \mu_x)(j - \mu_y) p_d(l, j) / \sigma_x \sigma_y$$

$$\text{Homogeneity} = \frac{\sum_l \sum_j P_d(l, j)}{1 + (l - j)^2}$$



الشكل 11: خصائص النصوص والتجانس والطاقة

### 7- الخوارزمية الجينية المقترحة:

الفرضية الأساسية التي نعتمد عند تحديد الخصائص الهامة من مجموعة الخصائص المستخرجة هي ان هناك كمية كبيرة من الخصائص الغير مرتبطة ببعضها البعض او تحتوي على بيانات مكررة لا داعي لوجودها ضمن البيانات المستخرجة من خصائص الصورة والتي تؤدي في كثير من الأحيان لتقليل دقة المصنف [13]. يتم تقييم الخصائص بواسطة تابع الملائمة (fitness function) وبالتالي تحديد الخصائص الأفضل من مجموعة الخصائص المستخرجة. ان تحديد الخصائص هو التابع المشغل المخطط من الفضاء البعدي  $m$  في الدخلى الى الفضاء البعدي  $n$

$$f_g: R^{r*m} \rightarrow R^{r*n}$$

حيث  $n \geq m$ ،  $R^{r*m}$ : المصفوفة التي تضم مجموعة الخصائص الأصلية والتي تضم  $r$  عينة.

$R^{r*n}$ : مجموعة الخصائص المقصصة (المخفضة) والتي تضم  $r$  عينة في مجموعة التحديد.

ان الخوارزمية الجينية هي محول تحسين عام رياضي البحث مبني على التوافق المباشر للتحديد الطبيعي والجيني في الأنظمة الحيوية [14]. وقد تم تحسينها لتكون البديل الأفضل للتقنيات الكلاسيكية السابقة. فهي تعمل بمجموعة مختارة او منتخبة من الحلول تدعى المجتمع (Population) وتحصل على أفضل الحلول بعد سلسلة من العمليات الحسابية. تقوم الخوارزمية الجينية بتقييم كل ملائمة (Fitness) على سبيل المثال جودة الحل، تابع الملائمة، والفرد الذي يملك اعلى احتمال يبقى ضمن المرحلة التالية باستخدام تقنيات التحديد. ان التتابع الأساسية في الخوارزمية الجينية هي تابع التصالب (Crossover) وتابع التبادل (Mutation) والتي تقوم بالتحويل العشوائي للأفراد ضمن المجتمع وبالنهاية تحديد قيم الملائمة لهم. تستمر هذه التتابع بالتوليد والعمل حتى الحصول على نتيجة مقبولة (عتبة).

تستطيع الخوارزمية الجينية التعامل مع فضاء كبير من الخصائص وبفعالية عالية. وهي تعتبر خوارزمية وراثية

تستخدم نظرية داروين في النشوء.

عناصر الخوارزمية:

- المجتمع (Population) هو مجموعة عشوائية مولدة من الافراد.
- الفرد (Chromosome) العناصر المنفردة التي تكون المجتمع (bit string)
- الجين (gene) يمثل خاصية محددة ضمن الفرد وهو (bit)
- تابع الملائمة (fitness function) هو تابع يقوم بتقييم الافراد وهو يعطي كل فرد قيمة ملائمة رقمية ضمن المجتمع الكامل.

### خطوات عمل الخوارزمية:

بداية التوليد (Generation Begin): يتم توليد مجتمع عشوائي من الافراد حجمه  $n$  وعدد خصائصه  $m$  بمصفوفة ( $n \times m$ ) مكونة من العناصر  $(a_{11}, a_{12}, \dots, a_{mn})$

المعالجة (Tournament): هذه المرحلة تقوم بتحديد المكونات المنفصلة الأفضل ملائمة لإعادة الإنتاج، فردين (two Chromosome) يسميان الافراد الاباء والذين يملكون القيمة الأكبر من الملائمة سيأخذون جزء في التصلب.

التصلب (Cross Over): هي عملية تبديل البيئات من خلال الاباء المحددين لتوليد الأبناء (offspring.) عدد البيئات  $b$  التي يتم تحديدها من الاب  $P_n$  يتم حسابها وفق المعادلة:  
 $b = K * P_n$  حيث  $0 < k < 1$  احتمال التصلب.

التبادل (Mutation): يتم فيها استبدال البيئات (جينات الفرد)

تابع تقييم الملائمة (Fitness Evaluation): الافراد اللذين يملكون مستوى ملائمة اعلى من العتبة سيقفون في الجيل التالي من التوليد والافراد البقية (اللذين يملكون مستوى ملائمة أقل من العتبة) سيتم الغائهم.

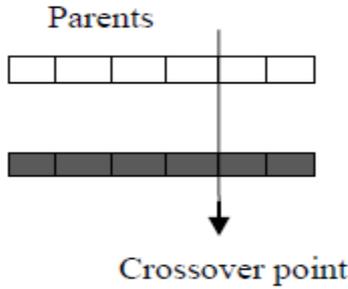
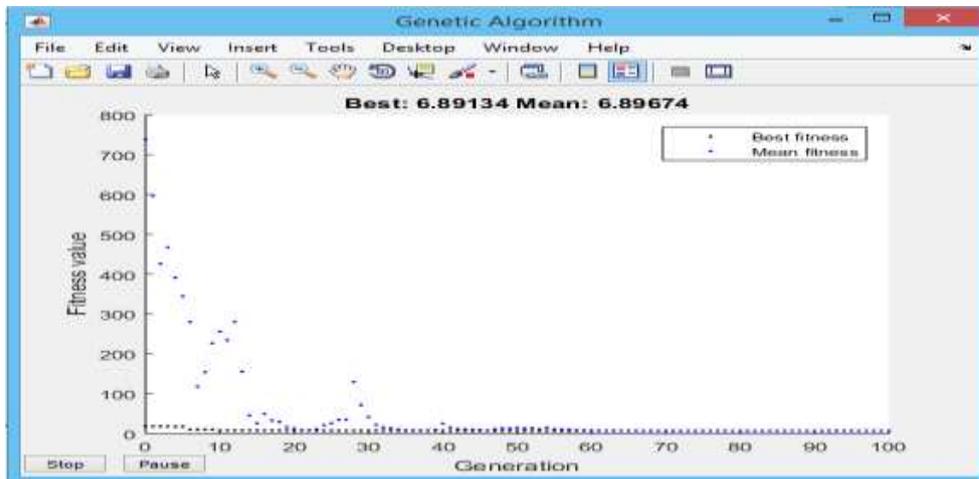


Fig.2: Illustration of crossover



Fig.3: Illustration of Mutation.



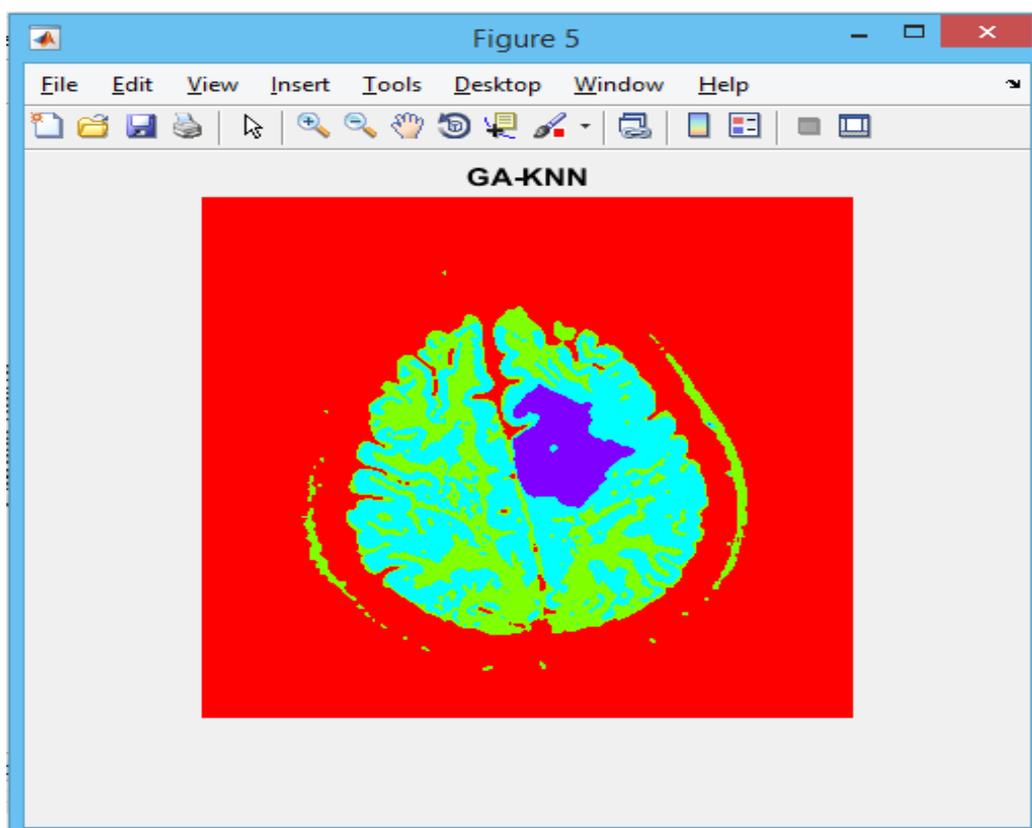
الشكل 12: تطبيق الخوارزمية الجينية على الصورة باستخدام Matlab

**التصنيف:**

في هذا العمل تم استخدام مصنف KNN (K-Nearest Neighbors) وهو المصنف الأكثر وضوحاً والأبسط في تقنيات التعلم الآلي (Machine Learning). ويستند تصنيف KNN على تصويت أغلبية ك أقرب تصنيف. ويتحقق التصنيف بتحديد أقرب الجيران واستخدام هذه الجيران لتحديد صنف من الاستعلام. في هذا العمل، تم استخدام  $K=9$ ، وهذا يعني أن الخوارزمية سوف تتخذ بأغلبية الأصوات من الجيران الـ 9 الأقرب. تم اختبار هذا المصنف على الصورة الناتجة من الخوارزمية الجينية وتم حساب كل من الدقة والتحديد والحساسية وفق الجدول 1.

جدول 1: أداء مصنف KNN

KNN Classification			
Image	Accuracy	Specificity	Sensitivity
Normal and Abnormal	93.34	90	95



الشكل 13: تطبيق مصنف الـ KNN على الصورة باستخدام Matlab

**الاستنتاجات والتوصيات**

ان معالجة الصور أصبحت مهمة هامة جداً في وقتنا الحالي، فاليوم تطبيقات معالجة الصورة يمكن ان تكون منطلقاً لعدد من المجالات الطبية منها والالكترونية وغيرها. واذا سلطنا الضوء على التطبيقات الطبية فان تصنيف

الصور يعتبر ذو استخدام واسع لأغراض التشخيص. ان الجمع بين استخراج الخصائص من الصور وتحديد الخصائص الهامة سوف يؤدي الى تعزيز الدقة للمصنف، وبالتالي فان إجرائية تحديد الخصائص الهامة من الخصائص المستخرجة تؤدي الى تعزيز نتائج المصنف. وبشكل واضح فانه بدون إجرائية تحديد الخصائص فان اداء المصنف سيكون أضعف منه في حالة وجود مصنف مع خصائص اقل. ان العمل المقدم يمكن التوسع فيه من التصنيف (Normal-Abnormal) الى مصنف لأمراض متخصصة، كمرض الزهايمر، ومرض التهاب الدماغ الخبيث وغيره من الامراض الدماغ الأخرى.

## المراجع

- [1]. AMMAR, MAAN, *Medical Images Processing and Display*. Second Edition, Faculty of Medical Engineering, Al Andalus Private University for Medical Sciences, Syria, 2016, 651.
- [2]. JAYA , J.THANUSHKODI, K. KARNAN, M. November, *Tracking Algorithm for De-Noiseing of MR Brain Images*. IJCSNS International Journal of Computer Science and Network Security, VOL.9 No.11. 2009
- [3]. DIMILILER, KAMIL, LHAN, AHMET, *August 2016 Effect of image enhancement on MRI brain images with neural networks*. 12th International Conference on Application of Fuzzy Systems and Soft Computing, ICAFS 2016, 29-30 August 2016, Vienna, Austria
- [4] MISS. SUKANYA V. AHER1, MRS. S. S. VASEKAR2, " A Review: Histogram Equalization Algorithms for Image Enhancement using FPGA", International Journal of Advanced Research in Computer and Communication Engineering Vol. 5, Issue April 2016- .
- [5] RAVINDRA PAL SINGH , MANISH DIXIT, - "Histogram Equalization: A Strong Technique for Image Enhancement" International Journal of Signal Processing, Image Processing and Pattern Recognition Vol.8, No.8, 2015.345-352.
- [6] ALI AHMADVAND1AND MOHAMMAD REZA DALIRI, - " A Review on Texture Analysis Methods in Biomedical Image Processing", OMICS J Radiol, 5:2. 2016
- [7] Doshi, NP. - *Multi-dimensional local binary pattern texture descriptors and their application for medical image analysis (Doctoral dissertation, Loughborough University)*. 2014
- [8] CHU Y, WANG Y, ZHU J, WANG L, JIN Z - *A Webber local binary pattern descriptor for pancreas endoscopic ultrasound image classification*. InElectronics, Computer and Applications, 2014 IEEE Workshop on .2014.836-839.
- [9] ZHENGHAO SHI,1,2,3 LIFENG HE,4 KENJI SUZUKI,2 TSUYOSHI NAKAMURA,1 , HIDENORI ITOH , "Survey on Neural Networks Used for Medical Image Processing", nt J Comput Sci. Author manuscript; available in PMC 2016 Jan Published in final edited form as: Int J Comput Sci; 3(1): 2009 Feb-86–100.
- [10] KAREM D. MARCOMINI,1 ANTONIO A. O. CARNEIRO,2 , HOMERO SCHIABEL1, " Application of Artificial Neural Network Models in Segmentation and Classification of Nodules in Breast Ultrasound Digital Images", International Journal of Biomedical Imaging Volume 2016 , Article ID 7987212, 2016-13.
- [11] DEPEURSINGE A, FONCUBIERTA-RODRIGUEZ A, VAN DE VILLE D, MÜLLER H, *Three-dimensional solid texture analysis in biomedical imaging: Review and pportunities*. Medical image analysis 18: 2014, 176-196

[12] ALBA GARCIA SECO DE HERRERA, HENNING MULLER, STEFANO BROMURI. *Overview of the ImageCLEF 2015 medical classification task. In Working Notes of CLEF 2015 (Cross Language Evaluation Forum), CEUR Workshop Proceedings. CEUR-WS.org. September 2015.*

[13] KHARRAT, A. GASMI, K. MESSAOUD, M. B. BENAMRANE, N. ABID, M. *Automated Classification of Magnetic Resonance Brain Images Using Wavelet Genetic Algorithm and Support Vector Machine, Proc. 9<sup>th</sup> IEEE Int. Conf. on Cognitive Informatics (ICCI'10), doi:10.1109/COGINF.2010.5599712, 2010, 369 - 374.*

[14] SIVANANDAM, S.N., DEEPA, S.N.: *Introduction to Genetic Algorithms. Springer, Heidelberg ,2008.*