

تجزئة صور الرنين المغناطيسي لأورام الدماغ بطريقة آلة المتوجه الداعم

اسراء كاظم رشيد / باحثة

د. هيفاء طه عبد / الجامعة المستنصرية/ كلية الإدارية والاقتصاد

P: ISSN : 1813-6729

E : ISSN : 2707-1359

<https://doi.org/10.31272/jae.i133.943>

مقبول للنشر بتاريخ: 2202/3/6

تاریخ استلام البحث : 2022/2/1

المستخلص

تم استعمال تقنية آلة المتوجه الداعم Support Vector Machine(SVM) لتجزئة مجموعة من صور الدماغ المأخوذة بالرنين المغناطيسي، حيث تستند عملية التجزئة هذه على تصنیف البيانات وفصلها خطيا او لا خطيا الى صنفين من خلال ايجاد نقاط مثالیة تمثل الحد الفاصل بين نقاط المجموعتين ومن خلال هذه النقاط يتم تمیيز النقاط الباقيه، ويكون فصل البيانات عن طريق استخدام المناطق البارزة وفصلها عن الخلفية من خلال استخدام تحويل فورييه واستخدام البيانات المحورة الجديدة من اجل الحصول على الترمیز الثنائي للصورة ومن ثم تدريب هذه البيانات حسب الترمیز، ويأتي بعد ذلك استخدام نموذج SVM من اجل تدريب البيانات واستخراج الصورة المجزئه وتحديد الاورام فيها.

الكلمات المفتاحية: أورام الدماغ ، تجزئة صور الرنين المغناطيسي ، تقنية آلات المتوجهات الداعمة(SVMs).



مجلة الادارة والاقتصاد
مجلد 47 / العدد 133 / حزيران / 2022
الصفحات : 244 - 235

* بحث مستقل من رسالة ماجستير .

١- مقدمة Introduction

ورم الدماغ هو أخطر أنواع الأورام الخبيثة التي تهدد الحياة نظراً لحساسية الأماكن التي تتكون فيها، ومعظم أورام الدماغ غير معروفة وتكون خطرة أكثر عندما يحدث الورم في أنسجة المخ أو المنطقة المحيطة، ويمكن أن يلعب الاكتشاف المبكر لأورام الدماغ دوراً مهمًا في تقليل معدل الوفيات وما يرتبط بها من آثار مميتة وكذلك تشخيص المرض وإدارته، مما يؤدي إلى ارتفاع معدل الشفاء ولكن بالنسبة للعديد من الأورام، لا تزال الجراحة والعلاج الإشعاعي معيار العلاج، هناك العديد من الدراسات حول هذا الموضوع ولاتزال مستمرة لابحاث علاج أو لمعرفة سبب هذا المرض، القاتا، [5]

يعتمد تشخيص الورم على التعريف السريري والخصائص الإشعاعية والأنسجة ومراحل الورم من خلال عينات يتم الحصول عليها بالجراحة، ويستند توصيف البنية النسيجية بشكل أساسي على تقييم أنواع الخلايا وأنماط الأنسجة وذلك باستعمال المجهر الضوئي التقليدي، والكيماء المعاصرة، واستعمال المجهر الإلكتروني كأدلة إضافية مهمة لتحديد أنواع الخلايا السرطانية، وتصنيف أورام الدماغ يعطي تقديرًا عامًا لسلوك الضرر البيولوجي المتوقع.^[3]

تجزئة الصور هي إحدى الخطوات الأساسية في تحليل الصور للعثور على أي شيء مهم في الصورة، حيث إن الهدف من التجزئة هو الحصول على مناطق ذات معنى تمثل الكيانات أو جزءاً من الكيانات في الصورة من أجل فهمها أو استخلاص هدف معين منها.^[1]

تم طريقة تجزئة الصور من خلال البحث عن كيانات ذات مقياس تجانس معين بينها، أو كيانات ذات مقياس تباين معين بين الكيانات والخلفية، ومعظم خوارزميات تقطيع الصور هي عبارة عن تغييرات أو امتدادات أو دمج لهذين المبدأين. تشمل مقاييس التجانس والتباين معايير أو خصائص، مثل: المقياس الرمادي، اللون، الملمس والشكل وغيرها. لكن المشكلة الرئيسية التي تواجهها الصورة أثناء عملية القطع هي الضوضاء (التشویش) Noise، والتي تحدث عادةً بسبب الكاميرا أو العدسة أو مسار الإشارة أو عدم كفاءة جهاز التصوير أو عدم خرجة المصور وغير ذلك من الأسباب ويمكن إزالة الضوضاء بطرق المعالجة الأولية.^[2]

2- آلة المتوجه الداعم :Support Vector Machine

Machine Learning هي إحدى خوارزميات التعلم الآلي المستخدم في مهام التصنيف والانحدار، لكن في الغالب تستخدم في مهام التصنيف فقط وتعتمد على تحويل البيانات الأصلية إلى نمط جديد بشكل يميز البيانات في فضاء أعلى من فضائها الأصلي، حيث يمكننا من خلاله فصل البيانات وتصنيفها [12].

وهي ايضاً عبارة عن أسلوب يجمع بين النظرية الإحصائية والتعليم الموجه، طورت من قبل الباحث Vapnik عام 1998، وتعتمد فكرتها على البحث على أفضل طريقة لتقسيم البيانات الى مجموعتين بوضع مستوى فائق (hyper plane) بينهما بعض النظر عن طبيعة البيانات سواء كانت قابلة للفصل الخطي او لا وهذا تكمن قوتها.^[13]

1-2 المستوى الفائق Hyper plane : هو عبارة عن خط مستقيم يقوم بتقسيم مجموعة البيانات الى

صنفين بأفضل طريقة وكلما ابتعدت النقاط عن المستوى الفائق كلما تم تصنيف النقاط بشكل صحيح وأفضل طريقة لفصل البيانات الى صنفين هو اختيار مستوى فائق ذو اكبر هامش بينه وبين أي نقطة في بيانات التدريب والهامش هو المسافة بين المستوى الفائق واقرب نقطة من أي مجموعة من البيانات.^[10]

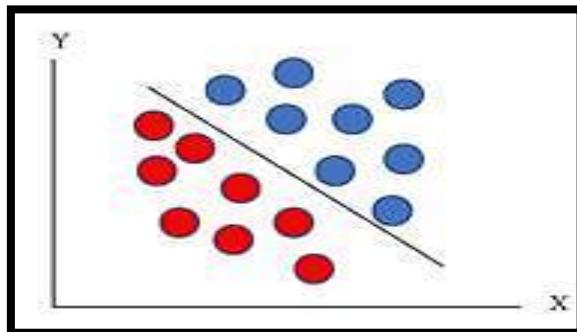
2-2 المتجهات الداعمة Support Vector: هي نقاط البيانات الأقرب لل المستوى الفاصل وهي النقاط التي

ان تم ازالتها من مجموعة البيانات ستتغير من موقع المستوى الفائق الذي يقسم البيانات لذلك يمكن اعتبار هذه النقاط انها العناصر المهمة مجموعة البيانات.^[11]

3- أنواع متوجهات الدعم Support vector types

3-آلية المتجه الداعم الخطى Linear SVM

عبارة عن مصنف Classifier وتم استخدامه لفصل البيانات التي تتميز بانها قابلة للفصل خطياً بواسطة مستوى فائق يعبر عن مستقيم مهمته فصل مجموعة البيانات الى مجموعتين، ويدعى هذا المصنف بـ Linear SVM Classifier أي مصنف آلة المتوجه الداعم الخطي وبدأ عمله ينبع على إيجاد القيمة المثلية لمعادلة الخط المستقيم التي تفصل هذه البيانات بأفضل شكل أي بأكبر مسافة للهامش ما بين أي نقطة من نقاط متوجهات الدعم والمستوى الفائق كما في الشكل التالي:[9]



شكل (1): فصل البيانات (قابلة للفصل خطياً) بواسطة مستقيم

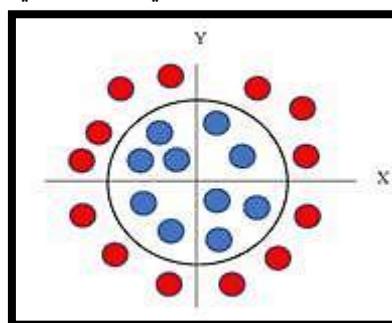
آلة المتجه الداعم غير الخطى Non Linear SVM 2-3

عبارة عن مصنف يتم استخدامه لفصل البيانات التي تتميز بأنها غير قابلة للفصل خطياً بواسطة خط مستقيم ويدعى هذا المصنف بـ **Non Linear SVM Classifier** أي مصنف آلة المتجه الداعم غير الخطى وبدأ عمله ينص على تحويل مجموعة البيانات من فضائها الثنائي البعد إلى فضاء أعلى حيث يمكننا فصل البيانات وتمييزها، وبالتالي تبدأ الخوارزمية بشكل آلي بتجريب إضافة بعد ثالث للبيانات ولتكن Z كاحتمال أول وبعدها يتم اختبار مجموعة البيانات الممثلة في فضاء ثلاثي الأبعاد (x,y,z) هل أصبحت قابلة للفصل أم لا. فإذا تحقق الشرط عندها تبحث الخوارزمية عن المستوى الفائق المناسب أكثر لعملية الفصل ربما مستوى ثالثي الأبعاد أو مجسم معين، أما إذا لم يتحقق الشرط فيتم إضافة بعد رابع ولتكن M كاحتمال ثاني وبعدها تم اختبار مجموعة البيانات الممثلة في فضاء رباعي الأبعاد (x,y,z,m) هل أصبحت قابلة للفصل أم لا وهكذا... تستمر الخوارزمية بإضافة أبعاد حتى تصل لمرحلة تصبح فيها البيانات قابلة للفصل وهذه الطريقة تسمى طريقة النواة **Kernel method**.

و عند البدء بتجريب احتمال إضافة بعد ثالث يكون المستوى الفائق الأفضل لفصلها هو دائرة وبالتالي تكون معادلة بعد الثالث كالتالي:

$$z = x^2 + y^2 \quad \dots 1$$

فإذا كانت $z=1$ (تمثل معادلة دائرة نصف قطرها واحد) وبالتالي إذا قمنا بتحويل البيانات من بعد ثالثي إلى بعد ثالثي أي التخلص من بعد الثالث z من خلال إعطائه القيمة (1) سنحصل على دائرة جمجمة نقاطها من صنف واحد والنقاط المتبقية الواقعة خارجها من صنف واحد. كما في الشكل التالي:[8]



شكل (2): فصل البيانات (غير القابلة للفصل خطياً) بواسطة دائرة

تجزئة صورة تحتوي على كائن او منطقة مميزة بطريقة Support Vector Machine 4

يمكن تجزئة صورة معينة بطريقة SVM عن طريق الخطوات التالية:[7]

الخطوة الأولى

كشف واستخراج المنطقة المميزة او الكائنات البارزة ويرمز لها بـ (R_0) وفصلها عن الخلفية ويرمز لها بـ (R_b)

عن طريق تحويل فورييه حيث يعتبر أداة مهمة لمعالجة الصور وتحليلها و الوصول إلى خصائصها. ويتم تحديد الكائن البارز في الصورة وفصله عن الخلفية $[SM(x_1, x_2)]$ عن طريق:

$$f(x_1, x_2) = F(l(x_1, x_2)) \quad \dots 2$$

$$p(x_1, x_2) = P(f(x_1, x_2)) \quad \dots 3$$

$$SM(x_1, x_2) = g^* \|F^{-1}[e^{ip(x_1, x_2)}]\|^2 \quad \dots 4$$

حيث ان:

$f(x_1, x_2)$: صورة اصلية

F^{-1}, F : تحويل فورييه و معكوسه

$p(x_1, x_2)$: صورة فورييه المحولة

g^* : التفاف جاوسي Gaussian Convolution

و يتم الحصول على موقع الكائن البارز عن طريق عملية الترميز الثنائي:

$$OM(x_1, x_2) = \begin{cases} 0 & \text{if } SM(x_1, x_2) < t \\ 1 & \text{if } SM(x_1, x_2) \geq t \end{cases} \quad \dots 5$$

حيث ان t : هي عتبة لفصل الكائن عن الخلفية.

الخطوة الثانية

إنشاء مجموعات بيانات التدريب TSp ، TSn للمناطق R_b وذلك من خلال اختيار مستوى فائق والذى يمثل هنا العتبة t حيث يتم تحديد بيانات التدريب وفقاً لعملية الترميز الثنائي.

الخطوة الثالثة

تحديد عينات التدريب من مجموعات البيانات التدريبية TSn ، TSp واستخراج نوافذ الميزات لتدريب نموذج SVM .

بشكل عام العدد الإجمالي لمجموعة بيانات التدريب SVM كبير جداً لذلك فإن خوارزمية **Support Vector Machine** تستغرق وقتاً كبيراً وبعد ذلك من سلبياتها ، يتم اعتماد معيار التجانس لاختيار جزء من وحدات البيكسل كعينات تدريب لـ SVM فمثلاً لبيكسل (i,j) في مجموعة التدريب TSp أو TSn يقاس تجانسها بـ

$$M_p = D_p^{n \times n} = \sum q \in N_p^{n \times n} d(p, q) \quad \dots 6$$

حيث ان: $d(p, q)$ هي المسافة الأقلية بين p, q .

$N_p^{n \times n}$ هي مجموعة البيكسل المجاورة لبيكسل p .

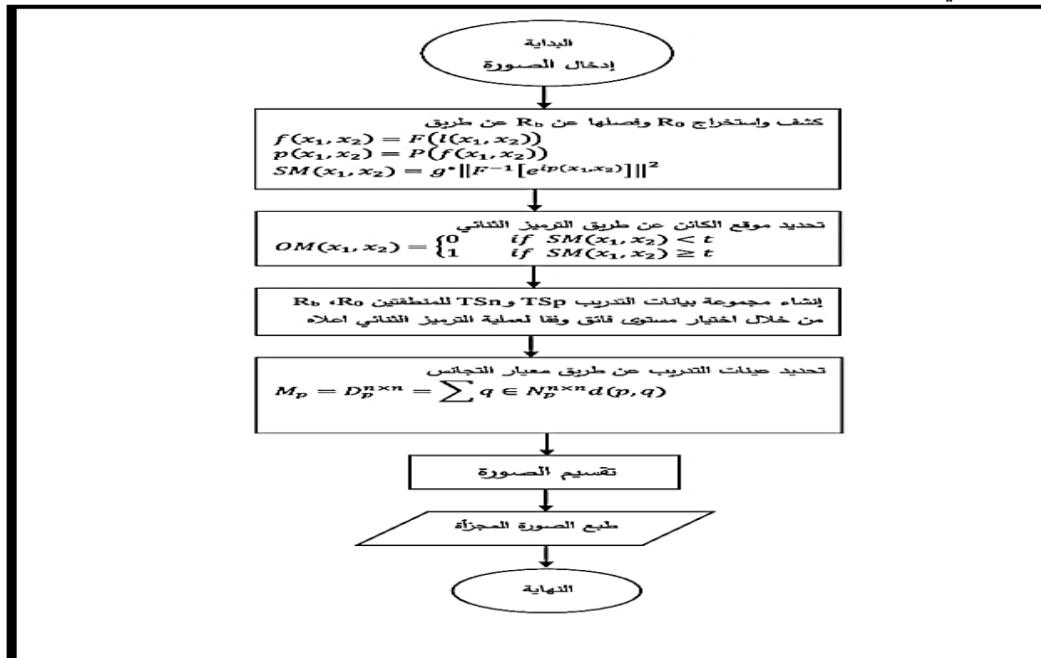
وتكون عينات تدريب SVM هي التي تحقق $M_p \leq \pi_n$

حيث ان :

π_n هي عتبة التجانس.

الخطوة الرابعة

تقسيم الصورة بواسطة نموذج التدريب SVM وإخراج الصورة المجزأة. ويمكن تمثيل هذه الخطوات بالخطط التالي:



الشكل (3): المخطط الانسيابي لطريقة آلة العتجم الداعم

5-معايير تقييم أداء الطريقة المقترنة:

سيتم استخدام المعايير التالية لتقييم أداء الخوارزمية المقترنة: [4][6]

1-5 معيار الجذر التربيعي لخطأ الصورة (RMSE) Root mean Square Error

نقوم بإيجاد الجذر التربيعي لمعدل مربعات الأخطاء بين الصورة قبل تطبيق تقنية SVM عليها والصورة بعد التطبيق ونحصل عليه بالمعادلة الآتية:

$$RMSE = \sqrt{\frac{\sum_{i=0}^{m-1} \sum_{j=0}^{n-1} (X(i,j) - Y(i,j))^2}{m * n}} \quad \dots 7$$

حيث ان:

حجم الصورة (عناصر الصورة في الصفوف والاعمدة)

$m * n$

المصورة الأصلية

$X(i,j)$

المصورة الناتجة

$Y(i,j)$

حيث كلما كانت قيمة RMSE أصغر فهذا يعني أن الصورة ذات جودة جيدة ، أما إذا كان العكس اي ان قيمة RMSE أكبر فهذا يعني أن الصورة ذات جودة رديئة.

2-5 معيار نسبة الفروة للإشارة إلى الضوضاء (PSNR)

(PSNR): وهو معيار يحدد مقدار جودة الصورة من خلال المقارنة بين الصورة الأصلية والصورة الناتجة ويستخدم هذا المعيار بشكل كبير وواسع ونحصل عليه بالمعادلة الآتية:

$$PSNR(X, Y) = 20 \log_{10} \frac{Max\ pixels}{RMSE} \quad \dots 8$$

حيث ان :

المصورة الأصلية

X

الصورة الناتجة

Y

على قيمة إضاءة لعناصر الصورة وعادة تكون 255

$Max\ pixels$

الجذر التربيعي لمعدل مربعات الخطأ بين الصورتين المدخلة والناتجة.

$RMSE$

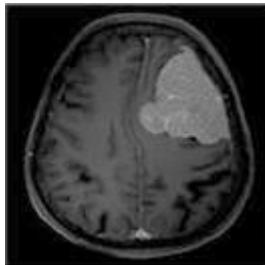
حيث كلما قيمة PSNR أكبر فهذا يعني أن الصورة ذات جودة جيدة، أما إذا كان العكس اي ان قيمة PSNR أصغر فهذا يعني أن الصورة ذات جودة رديئة.

6- الجانب التجاري والنتائج (Experimental aspect and results)

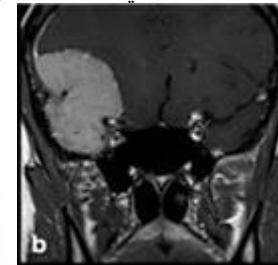
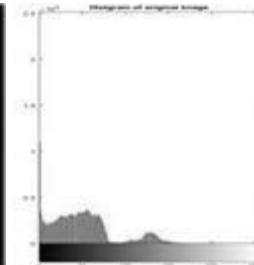
1-6 عينة البحث:

ت تكون عينة البحث من ستة صور مأخوذة بالرنين المغناطيسي للدماغ ، تحتوي هذه الصور على اورام مفردة ومتعددة في مناطق مختلفة من الدماغ وتم الحصول عليها من عيادة طبية متخصصة في اورام المخ وتحت إشراف أطباء متخصصين . تم استخدام برنامج MATLAB للحصول على جميع نتائج التجارب.

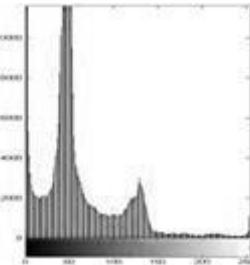
والشكل (4) يمثل الصور الأصلية مع مدرجاتها التكرارية وهذه الصور توضح شدة الإضاءة فيها ، حيث أن شدة الإضاءة من أهم المعايير التي يعتمد عليها في تجزئة الصورة ، خاصة إذا كانت هذه الصور تمثل صور التصوير بالرنين المغناطيسي للدماغ ، وهي تعتبر من أكثر الصور تعقيداً وصعوبة في التجزئة لأنها تعتمد على شدة الإضاءة ودرجة التشويه وتأثير الحجم الجزيئي ، حيث يعتمد تأثير الحجم الجزيئي على القيمة الرمادية للبيكسل و درجة وضوحها عن باقي أجزاء الدماغ السليمة ، وهذا يعقد عملية التجزئة.

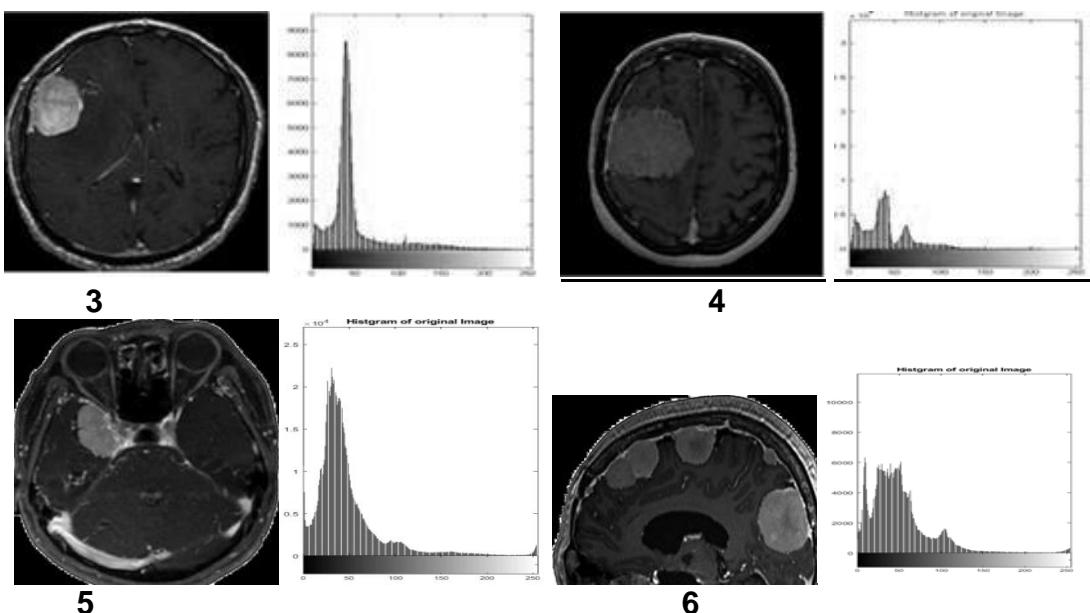


1



2





الشكل (4) الصور الأصلية مع مدرجاتها التكرارية

من خلال الشكل اعلاه الذي يوضح المدرجات التكرارية لكل صورة مدروسة نلاحظ ان الصورتين رقم (1,4) شدة الاضاءة بها مقاربة جداً فيما يليها بالصور الاخرى الذي كانت الشدة الضوئية واضحة بحيث كل قيمة بالمخلط التكراري توضح الشدة الضوئية للورم كونه افتح من باقي تفاصيل الصورة وحتى في حالة دراسة صور متعددة الاورام نلاحظ تعقيد المدرج التكراري نوعاً ما فيما يليها الصور لوجود اكثر من ورم شدته الضوئية اقل من باقي الصور ، ويمكن ملاحظة تنوع الشدة الضوئية لكل صورة مع باقي المقاييس الإحصائية للصور من خلال الجدول(1).

الجدول (1): بعض المقاييس الإحصائية للصور الأصلية

الانحراف المعياري	التبابن	الوسط الحسابي	أعلى قيمة	أقل قيمة	الصورة
15.9483	254.3482	31.9477	203	0	الأولى
11.7035	136.9719	56.8363	255	0	الثانية
11.2262	126.0275	38.6866	246	0	الثالثة
12.6276	159.4562	24.3435	214	0	الرابعة
9.8734	97.4840	38.5957	252	0	الخامسة
12.5189	156.7228	41.4872	255	0	السادسة

2-6 تطبيق تقنية آلة المتوجه الداعم Support Vector Machine

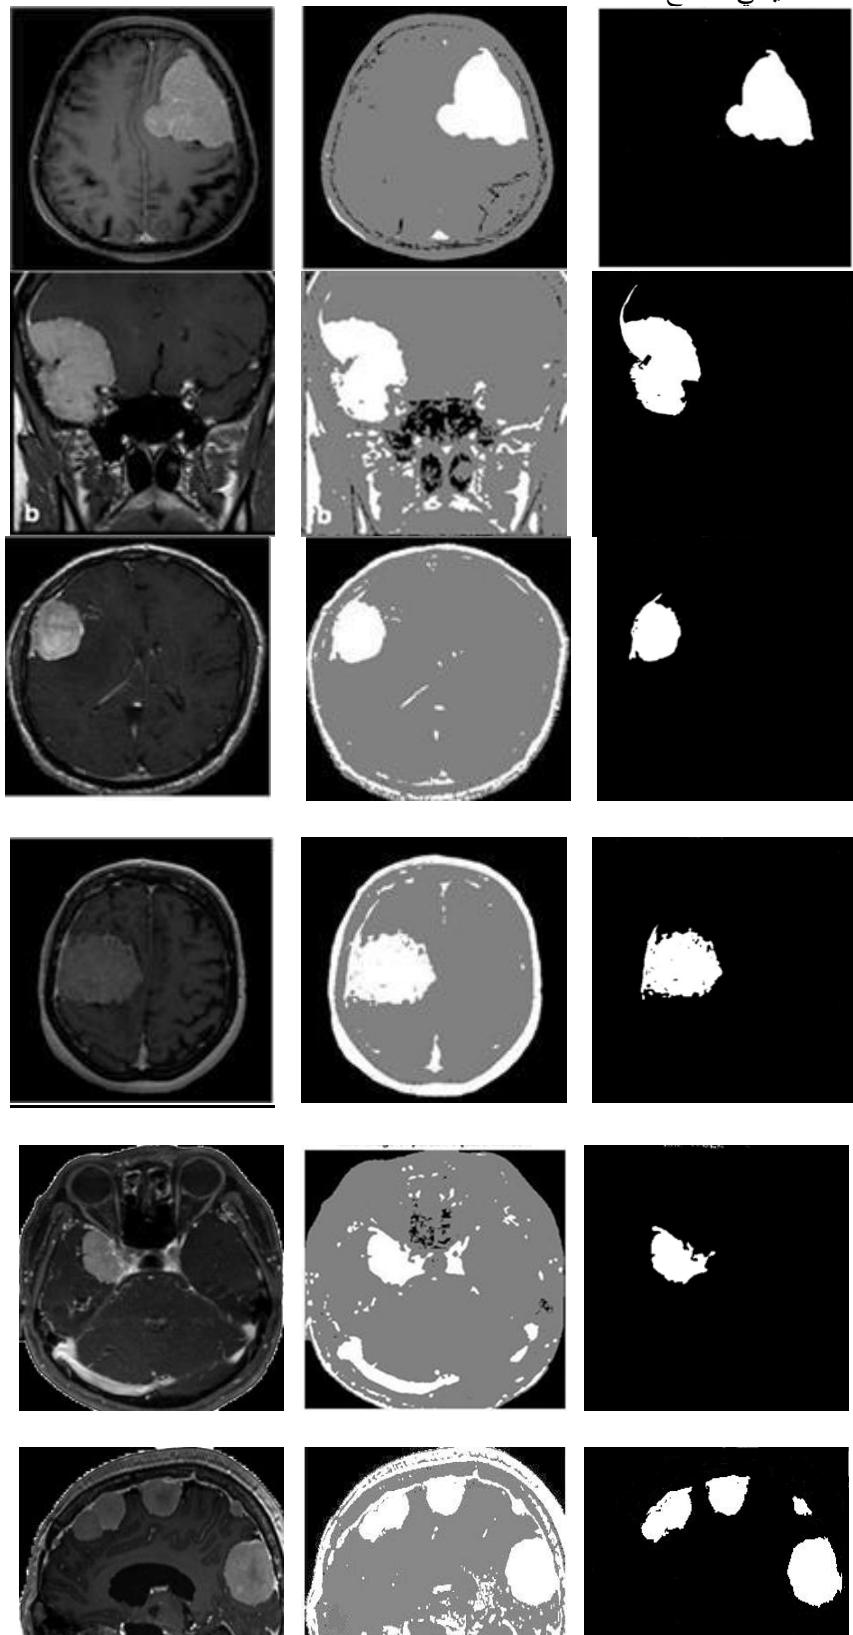
تم تطبيق تقنية آلة المتوجه الداعم Support Vector Machine على الصور الأربع المأخوذة بواسطة الرنين المغناطيسي للدماغ وقد تم حساب المقاييس الإحصائية لهذه الصور بناءً على هذه التقنية وكانت النتائج كما يأتي:

الجدول (2): بعض المقاييس الإحصائية للصور وفق آلة المتوجه الداعم (SVM)

PSNR	RMSE	الانحراف المعياري	الوسط الحسابي	الصورة
26.2601	1.0760	0.1857	0.0802	الأولى
24.9854	1.1469	0.1139	0.0835	الثانية
26.3016	1.0738	0.0964	0.0551	الثالثة
26.2513	1.0765	0.1651	0.1477	الرابعة
24.2651	1.1889	0.1046	0.0837	الخامسة
32.1875	0.8001	0.1101	0.1411	السادسة

الجدول (2) يبين الوسط الحسابي والانحراف المعياري لكل صورة بالإضافة إلى معياري المقارنة RMSE, PSNR، PSNR والتي تنص على انه كلما كانت RMSE صغيرة و PSNR كبيرة تدل على جودة الصورة المجزئه وعليه تعتبر الصورتين الاولى والرابعة افضل الصور المجزئه فقد كانت قيمة RMSE للصورة الاولى (1.0760) وقيمة PSNR كانت (26.2601) في حين قيمة RMSE للصورة الرابعة (1.0765) ومقدار PSNR كان (26.2513) وهذا ما اكده نتائج الصور في الشكل (5) وهذا يرجع اكيد

إلى أن هاتين الصورتين تحتوي على خلفية متجانسة نوعاً ما مقارنة بباقي الصور، ومع هذا يمكن الاستنتاج بالاعتماد على الجدول (2) والشكل (5) أن طريقة الـ المتوجه الداعم SVM كانت طريقة جيدة في تجزئة جميع صور الرنين المغناطيسي للدماغ.



الشكل (5) العمود الاول من اليسار يمثل الصور الاصلية العمود الثاني يمثل الصور الناتجة من التجزئة بطريقة SVM العمود الثالث يبين الورم فقط بخلفية سوداء

نلاحظ هنا القدرة العالية لتقنية آلة المتوجه الداعم (SVM) في الكشف عن المناطق المختلفة في الصورة، سواء كانت الصور تحتوي مناطق معتمة أو فاتحة، فقد استطاعت التقنية تمييز الورم وفصله عن الخلفية دون التأثير على حجمه او شكله او كونه متعدد او مفرد، تم الاستفادة ايضاً من الصور المجزئة رغم وضوحها في تمييز الورم فقد استطعنا جعل كل خلفية الصورة باللون الاسود والورم فقط باللون الابيض ليتسنى لمتذبذبي القرار تحديد حجم وشكل ومكان الورم بشكل افضل.

7- الاستنتاجات (Conclusions):

موقع وحجم أورام المخ لها تأثير كبير على صحة الإنسان، وبناءً عليه تمت دراسة أورام المخ باستخدام صور الرئتين المغناطيسي. وتم استخدام تقنية آلة المتوجه الداعم (SVM) في عملية التجزئة ، وأظهرت النتائج التجريبية ما يلي:

- a. أن هذه التقنية لها قدرة عالية في الكشف عن المناطق التي تكون غير طبيعية فقد استطاعت التقنية تمييز الورم وفصله عن الخلفية دون التأثير على حجمه او شكله حتى في حالة وجود اكثر من ورم كما في الصورة الاخيرة حيث ان الورم هنا بدأ بالتكاثر مع ذلك استطاعت التقنية تمييزه بوضوح كما مبين في الشكل (5) وخاصة في العمود الثالث الموضح بها الصور الثانية للورم فقط، وهذا يرجع على ما اعتقد الى اختيار حد عتبة مثالي بالإضافة الى باقي التفاصيل فالطريقة استطاعت فصل الورم عن الخلفية بدقة.
- b. في الصور التي تميزت بشدة ضوئية مترابطة بالإضافة الى خلفية لا تحتوي على تفاصيل كثيرة بيّنت هذه الطريقة قدرة عالية في تجزئة الصور وهذا واضح في الصور المجزئة بالإضافة الى قيم معياري المقارنة RMSE,PSNR حيث العلاقة عكسية بين هذين المؤشرين كما موضح في الجدول (2).
- c. تعتبر الصورتين الاولى والرابعة افضل الصور المجزئة فقد كانت قيمة RMSE للصورة الاولى (1.0760) وقيمة PSNR كانت (26.2601) في حين قيمة RMSE للصورة الرابعة (1.0765) ومقدار PSNR كان (26.2513).

8- المصادر (References):

- [1] العمري ، هدى عبد الله ، (2004) ، "كروموسومات جينية لتجزئة الصور" ، رسالة ماجستير، جامعة الموصل ، كلية علوم الحاسوبات والرياضيات قسم علوم الحاسوبات.
- [2] المولى ، محمد ناظم داود ، (2007) ، "تضييع صور اورام الدماغ ممتلة بالخوارزمية الجينية" ، رسالة ماجستير، جامعة الموصل ، كلية الحاسوبات والرياضيات، قسم علوم الحاسوبات.
- [3] محمد ، اسامه ياسين، (2010)، "تمييز الصور الطبية للدماغ باستخدام تقنيات البايو معلوماتية"، رسالة ماجستير، جامعة الموصل ، كلية علوم الحاسوبات والرياضيات قسم علوم الحاسوبات.
- [4] مفضي . فواز، حمزات . حسام ، (2015) ، "ضغط الصور المجمسة بتقدير الفرق بين الصورتين واستخدام التحويل الانحنائية الرقمي ثانوي البعد" ، مجلة جامعة تشرين للبحوث والدراسات العلمية _ سلسلة العلوم الهندسية المجلد (37) (العدد 1) .
- [5] Abid . H and Abdulmunim . M , (2016), "Segmentation Brain Tumor and Diagnosing Using Watershed Algorithm", American Journal of Engineering Research (AJER), Vol5, Issue-11, PP. [31-35].
- [6] Asamoah . D , Ofori . E , Opoku . S and Danso . J , (2018) , "Measuring the Performance of Image Contrast Enhancement Technique", International Journal of Computer Applications (0975 – 8887) Volume 181 – No. 22, October 2018.
- [7] Bai . X and Wang . W , (2014) "Saliency-SVM: An automatic approach for image segmentation", Contents lists available at Science Direct journal homepage: [www.elsevier.com/ locate /neucom](http://www.elsevier.com/locate/neucom) Neurocomputing.
- [8] Berisha . S , (2009) , "Image Classification Using Gabor Filters and Machine Learning" , Thesis Submitted to the Graduate Faculty of wake Forest University in Partial Fulfillment of the Requirements for the Degree of Master of Science in the Department of Computer Science pp.(34 –36).

- [9] Murugan . S , Sumithra . M and Murugappan . M , (2017), "Efficient Clustering of Unlabeled Brain DICOM Images based on similarity" , J. Phys Journal of Physics Conference Series IOP Publishing .
- [10] Shilton . A , (2006) , " Design and Training of Support Vector Machines" , Submitted in total fulfilment of the requirements for the degree of doctor of Philosophy, Department Of Electrical and Electronic Engineering , The University of Melbourne Australia .
- [11] Theodoridis . S and Koutroumbas . K , (2009)," Pattern Recognition" (Fourth Edition), Elsevier Inc.
- [12] Theodoridis . S and Koutroumbas . K, (2003)," Pattern Recognition", (second edition) , Elsevier Academic Pres .
- [13] Vapnik . V, (1999) "The Nature Of Statistical Learning Theory" , 2nd.ed.,Springer.

Segmentation of Magnetic Resonance Images of Brain Tumors using Support Vector Machine Method (Support Vector Machine)

**Israa Kazim Rasheed / Researcher
Dr. Haifa Taha Abd**

Abstract

The Support Vector Machine (SVM) technology was used to segment a set of brain MRI images. This segmentation process is based on classifying the data and separating it linearly and non-linearly into two categories by finding perfect points that represent the boundary between the points of the two groups and through these points The remaining points are distinguished, and the data is separated by using prominent regions and separated from the background by using Fourier transform and using the new modified data in order to obtain the binary coding of the image and then training this data according to the encoding, and then using the SVM model in order to train the data Extracting the fragmentary image and identifying the tumors in it.

Keywords: Brain Tumors, Image Segmentation, Support Vector Machine Technique, Features extraction.

