

تطوير نظام تشخيص أنواع ورم الدماغ في صور الرنين المغناطيسي باستخدام الخرائط ذاتية التنظيم والشبكات العصبونية الاصطناعية أمامية الانتشار

د. م فادي متوج⁽¹⁾

د. م فائق عجيب⁽²⁾

الملخص

يؤدي نمو الخلايا غير الطبيعي إلى ورم في خلايا الدماغ. يعد الكشف المبكر عن ورم الدماغ وتشخيصه وعلاجه أمراً ضرورياً لمنع موت الإنسان. في هذا البحث تم اقتراح نظام تشخيص لكشف نوع ورم الدماغ وتصنيفه من بين ثلاثة أنواع في صورة الرنين المغناطيسي. اعتمدت الخوارزمية المقترحة أولاً على استخدام الخرائط ذاتية التنظيم SOM لتجزئة الصورة وكشف منطقة الورم ليأتي بعدها عمليات معالجة الصورة وتحسينها واستخراج خصائص الورم، وفي النهاية تم استخدام الشبكات العصبونية ذات الانتشار الأمامي من أجل تشخيص نوع الورم بالاعتماد على الخصائص المكتشفة. تم اعتماد قاعدة بيانات تحتوي على 3064 صورة رنين مغناطيسي محسنة، وتحتوي كل صورة على معلومات الورم، ونوعه، وموقعه. تم تدريب الخوارزمية على 300 صورة موزعة بشكل متساوٍ على أنواع ثلاثة لورم الدماغ، و100 صورة لحالة سليمة لا تحتوي ورم. أظهرت النتائج دقة النظام المقترح وموثوقيته، حيث تم بنجاح كشف 297 صورة وتشخيصها من أصل 300 صورة حيث بلغت الحساسية والتحديد والدقة 99%، 98%، 98% على الترتيب.

الكلمات المفتاحية: التشخيص الطبي - الذكاء الاصطناعي - الشبكات العصبونية الاصطناعية - ورم الدماغ.

(1) دكتور مدرس في قسم هندسة الميكاترونك في كلية الهندسة الميكانيكية والكهربائية - جامعة تشرين.

(2) دكتورة مدرسة في قسم الهندسة الطبية في كلية الهندسة الميكانيكية والكهربائية - جامعة دمشق.

Developing a diagnostic system for brain tumor types in MRIs using self-organizing maps and feed forward artificial neural networks

Dr. Fadi Motawej⁽¹⁾
Dr. Faten Ajeeb⁽²⁾

Abstract

Abnormal cell growth leads to a tumor in the brain cells. Early detection, diagnosis and treatment of brain tumor is necessary to prevent human death. In this research, a diagnostic system was proposed to detect and classify the type of brain tumor among three types in the magnetic resonance images. The proposed algorithm first relied on the use of self-organizing maps (SOM) to segment the image and detect the tumor area, followed by image processing and improvement processes and extract tumor properties, and finally, a Feed Forward neuronal network was used to diagnose the type of tumor based on the detected properties. A database containing 3064 improved magnetic resonance images has been adopted, each image contains tumor information, type, and location. The algorithm was trained on 300 images distributed equally in three types of brain tumor and 100 images without tumor. The results showed the accuracy and reliability of the proposed system, as 297 out of 300 images were successfully detected and diagnosed with sensitivity, specificity and accuracy reached 99%, 98% and 98% respectively.


Keywords: Medical Diagnosis - Artificial Intelligence - Artificial Neural Networks - Brain Tumor

⁽¹⁾Doctor in the Department of Mechatronic Engineering at the Faculty of Mechanical and Electrical Engineering- Tishreen University.

⁽²⁾Engineer in the Department of biomedical Engineering at the Faculty of Mechanical and Electrical Engineering- Damascus University.

1- المقدمة:

ويخاصة في البلدان النامية [5]. ومع ذلك، فإنه من الصعب للغاية على الأطباء التمييز واتخاذ القرارات وتقديم التشخيص في بعض الحالات. يخلق التشخيص الخاطئ وأساليب العلاج الخاطئة أعباءً مالية ثقيلة على المريض، ويؤدي إلى نتائج لا يمكن علاجها. لذا برزت الحاجة إلى استخدام تقنيات الذكاء الاصطناعي في التشخيص والتي يمكن أن تسهم في تحسين قدرة الأطباء على تشخيص أورام الدماغ، وتقليل الزمن اللازم للتشخيص الدقيق، ومن ثم لا تتأثر دقة التشخيص بسبب التعب والعدد الكبير من الصور.



الشكل (1) بعض أنواع أورام الدماغ المعروفة [4]

يهدف هذا البحث إلى تطوير نظام لمساعدة الممارسين الطبيين في التشخيص المسبق لنوع ورم الدماغ من حيث الكشف الأولي لوجود سرطان الدماغ ليتبعه عملية فصل الورم في حال وجوده، وتصنيفه باستخدام الشبكات العصبونية الاصطناعية.

في الوقت الحاضر، تستخدم العديد من تقنيات الذكاء الاصطناعي في الكشف عن أورام الدماغ، ومن بينها الشبكات العصبونية الاصطناعية. اقترح الباحثون في [6] نظاماً من مرحلتين للتمييز بين المادة الرمادية والمادة البيضاء وأجزاء أخرى من الدماغ في صور MR باستخدام الخرائط ذاتية التنظيم (SOM). كما تم استخدام شبكة SOM أيضاً لتجزئة أورام المخ وتصنيفها في [7]. في [8]، تم أيضاً اقتراح نظام ANN الذي يقوم على تجزئة الصور واستخراج المزايا والتصنيف لكشف أورام المخ. في [9]، تم استخدام عملية تجزئة عصبية ضبابية (neuro-fuzzy) للكشف عن ورم الدماغ. لقد اقتصر معظم هذه الأبحاث على كشف أورام الدماغ، ولم تنطرق إلى تحديد نوع الورم.

ورم الدماغ هو نمو غير طبيعي لخلايا الدماغ، وهو أحد الأسباب الأكثر شيوعاً للوفاة [1]. وفقاً لتقرير الوكالة الدولية لبحوث السرطان، فإن السرطان هو سبب الوفاة لأكثر من 7.6 مليون شخص في عام 2008م، وهذا يمثل 13% من إجمالي الوفيات في جميع أنحاء العالم للعام نفسه [2]، ووفقاً لتقارير منظمة الصحة العالمية (WHO)، سيصاب 22.2 مليون شخص بالسرطان بحلول عام 2030م [3].

يتم اللجوء إلى العمليات الجراحية والعلاج الكيميائي والعلاج الإشعاعي في علاج أورام المخ، حيث يعتمد اختيار نوع العلاج على اكتشاف الطبيب الدقيق لنوع الورم، وموقعه، وحجمه، وحدوده. لذلك، من الأهمية بمكان الكشف عن الورم في وقت مبكر وبدقة عالية لتحديد العلاج المناسب.

هناك أكثر من 120 نوعاً من أورام المخ والجهاز العصبي المركزي (Central Nervous System (CNS). اليوم، تستخدم معظم المؤسسات الطبية نظام تصنيف منظمة الصحة العالمية (WHO) لتحديد أورام المخ، حيث تصنف منظمة الصحة العالمية أورام المخ حسب أصل الخلية وكيف تتصرف الخلايا، من الأقل عدوانية (حميدة) إلى الأكثر عدوانية (خبيثة). يتم تعيين درجة لبعض أنواع الورم تدل على معدل نموه، تتراوح من الدرجة الأولى (الأقل خبثاً) إلى الدرجة الرابعة (الأكثر خبثاً). يساعد تصنيف الورم ودرجته في توقع سلوكه المحتمل. من الأنواع المعروفة لأورام الدماغ [4] الشكل (1):

- (a) ورم سحائي meningioma.
- (b) دقيقي glioma.
- (c) الغدة النخامية pituitary

يقوم الأطباء بالكشف عن الورم عن طريق تفسير صور الرنين المغناطيسي MRI للدماغ، حيث يحتاج الطبيب عادةً من 30 إلى 45 دقيقة لتفسير صور الرنين المغناطيسي للدماغ. يمكن لعدد قليل فقط من أطباء الأشعة القيام بالتفسير الصحيح لصور الرنين المغناطيسي للدماغ،

2- الأسس النظرية للبحث:

2-1- مفهوم تجزئة الصور:

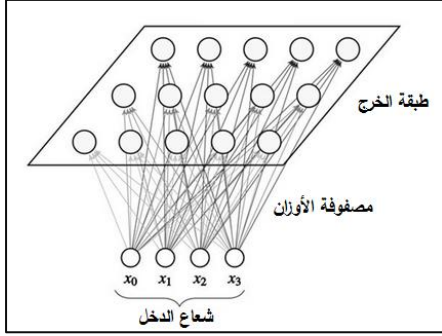
تجزئة (تقسيم) الصور هي واحدة من الخطوات الأساسية في تحليل الصور، والرؤية الحاسوبية، وتطبيقات معالجة الصورة. إن هدف تجزئة الصورة هو الحصول على مناطق ذات معنى، ونعني بذلك إيجاد المنطقة التي تمثل كياناً أو جزءاً من كيان داخل الصورة [10]. عملية العنقدة هي طريقة لتجميع البيانات المتشابهة في مجاميع أو عناقيد مختلفة، وكل مجموعة لا بد أن تكون متشابهة، والمجاميع المختلفة لا بد أن تكون غير حاوية على بيانات مشتركة. إن اختيار معيار التشابه يؤدي دوراً مهماً في دقة نتيجة التقسيم. تعدُّ العنقدة طريقة مفيدة في تحليل العديد من الأنماط، اتخاذ القرار، معالجة البيانات، تنقيب البيانات، تجزئة الصور وتصنيف الأنماط. توجد العديد من الخوارزميات المستخدمة لتجزئة الصور، ومن بينها الخرائط ذاتية التنظيم SOM والتي تم اقتراحها في هذا البحث.

2-2- الخرائط ذاتية التنظيم SOM :

الخرائط ذاتية التنظيم SOM وتسمى أيضاً شبكات كوهونين Kohonen Maps نسبة للعالم الفنلندي تيف كوهونين الذي اقترحها عام 1982م [11]، [12]. هي عبارة عن شبكات عصبونية اصطناعية يتم تدريبها بالاعتماد على التعلم غير المراقب Unsupervised Learning، بمعنى آخر إن هذا النوع من الشبكات العصبونية تدرب نفسها بنفسها أي بمعنى لا يوجد خرج محدد يعطى للشبكة كما في حالة التعلم عن طريق معلم.

تتكون الشبكة ذاتية التنظيم SOM من العقد (العصبونات) المنتظمة على خريطة ثنائية البعد 2D. كل عصبون في الشبكة يكون مرتبطاً ارتباطاً كاملاً بطبقة الدخل و يمثل بواسطة شعاع وزن بعده يساوي بعد أشعة الدخل. كما أنه لا توجد وصلات بين العقد في الشبكة. يبين الشكل (2) شبكة kohonen صغيرة مؤلفة من 3x5 عقدة متصلة بطبقة الدخل الممثلة بشعاع رباعي البعد. عندما يتم تقديم

شعاع دخل إلى SOM، يقوم كل عصبون بحساب مدى تشابه هذه الدخل مع أوزانه، والعصبون الذي تتشابه أوزانه أكثر مع الدخل يفوز في المنافسة بالنسبة لهذا الدخل ويسمى العصبون الفائز بأفضل وحدة مطابقة (Best Matching Unit) BMU.



الشكل (2) بنية الخريطة ذاتية التنظيم SOM [11]

يتم تعديل أوزان العصبون الفائز وأوزان العصبونات المجاورة له لجعلها أكثر قرباً من شعاع الدخل، وكلما كان العصبون أقرب للعصبون الفائز كان تغير أوزانه أكبر [12]. تستخدم SOM بكثرة في عملية تصنيف البيانات، وتحليلها، وإظهارها، وبالإضافة لذلك تقدم SOM وسيلة لتمثيل البيانات متعددة الأبعاد في فضاءات ذات أبعاد أقل بكثير (تخفيض أبعاد البيانات) مع الحفاظ على العلاقات والخواص الموجودة ضمن بيانات التدريب دون تغيير، مما يسهل عملية فهم هذه البيانات وتحليلها.

من الطرق المستخدمة لتحديد أفضل مطابقة هي حساب المسافة الإقليدية (Euclidean distance) بين شعاع وزن كل عقدة وشعاع الدخل الحالي وتعطى بالعلاقة الآتية [12]:

$$D = \sqrt{\sum_{i=0}^{i=n} (V_i - W_i)^2}$$

حيث:

V: شعاع الدخل، W: شعاع الوزن

يتم تعديل أوزان العصبون الفائز والعصبونات المجاورة له وفق العلاقة:

$$W(t+1) = W(t) + \theta(t)L(t)(V(t) - W(t))$$

حيث:

أورام الدماغ: الورم السحائي (708 شريحة)، الورم الدبقي (1426 شريحة)، ورم الغدة النخامية (930 شريحة). مع العلم أن الصور مخزنة على شكل متغيرات بصيغة .mat. يمكن استخدامها داخل بيئة Matlab وكل ملف .mat يحتوي على الصورة المقطعة، رقم المريض، نوع الورم، وحدود الورم داخل الصورة على شكل شعاع إحداثيات. تم استخدام قاعدة البيانات هذه في العديد من الأبحاث المشابهة ([15]، [16]). في بحثنا تم استخدام 200 شريحة من كل نوع، بحيث يتم استخدام 100 صورة من كل نوع لتدريب الشبكات، و 100 صورة لاختبار الشبكات والتحقق من عملها.

3- طرائق البحث والخوارزمية المقترحة:

تتضمن الخوارزمية المقترحة في هذا البحث استخدام ثلاث خطوات لتصنيف الورم الدماغية موضحة في الشكل (4)، الأولى: شبكة SOM ووظيفتها كشف منطقة الورم داخل الصور وإعطاء قيمة لونية مميزة للورم، والخطوة الثانية: هي القيام بعمليات مورفولوجية (التمدد dilation والحت Erosion) بحيث يتم إلغاء منطقة العظم بسبب صغر مساحتها بالنسبة للورم (شبكة SOM في أغلب الأحيان ستظهر عظم الجمجمة على أنه ورم بسبب التقارب اللوني بينهما) ليتم بعدها القيام بعمليات تجزئة الصورة الرئيسية (وسم الكائنات، واستخراج خصائص الكائنات، وحساب قيمهم النسبية)، والخطوة الثالثة: هي شبكة عصبونية ذات تغذية أمامية FFANN ووظيفتها استخدام الخصائص المستخرجة من الورم داخل الصورة (المساحة، الموقع، الأبعاد) وتدريبها على هذه الخصائص لتصبح قادرة على تمييز نوع الورم المكتشف من الأورام الثلاثة للدماغ المذكورة سابقاً. سنقوم فيما يأتي بشرح كل خطوة على حدة:

3-1- كشف منطقة الورم باستخدام شبكات SOM:

تستخدم شبكات SOM من أجل تصنيف الصور، تم في هذا البحث استخدام شبكة SOM من أجل كشف منطقة الورم الدماغية داخل الصور المقطعية، من خلال تدريب الشبكة على تصنيف البكسلات داخل الصورة نفسها إلى

$L(t)$: معدل التعلم، $\theta(t)$: تابع الجوار


تتناقص منطقة الجوار مع الزمن مع تقدم عملية التدريب، وكذلك يتناقص معدل التعلم مع تقدم عملية التدريب.

2-3- الشبكات العصبونية ذات التغذية الأمامية

FFANN:

الشبكات العصبونية ذات التغذية الأمامية Feedforward ANN الشكل (3) هي شبكات عصبونية اصطناعية حيث لا يوجد تغذية عكسية أو انتشار خلفي بين الطبقات. كانت الشبكات FFANN هي النوع الأول من الشبكات العصبونية الاصطناعية التي تم اقتراحها ويطلق عليها ذات تغذية أمامية Feedforward لأن المعلومات تنتقل فقط إلى الأمام في الشبكة (دون حلقات تغذية راجعة)، أولاً من خلال طبقة الدخل، ثم من خلال العصبونات في الطبقة الخفية (إن وجدت)، وأخيراً من خلال عصبونات الخرج. يتم تدريب هذا النوع من الشبكات بالاعتماد على التعلم المراقب Supervised Learning.

أهم ما يميز الشبكات العصبونية الاصطناعية FFANN هي قدرتها على التعلم والتعميم. لهذا السبب، يتم تطبيقها على نطاق واسع في نمذجة النظم غير الخطية حيث تكون العلاقة بين المتغيرات غير معروفة أو معقدة للغاية.

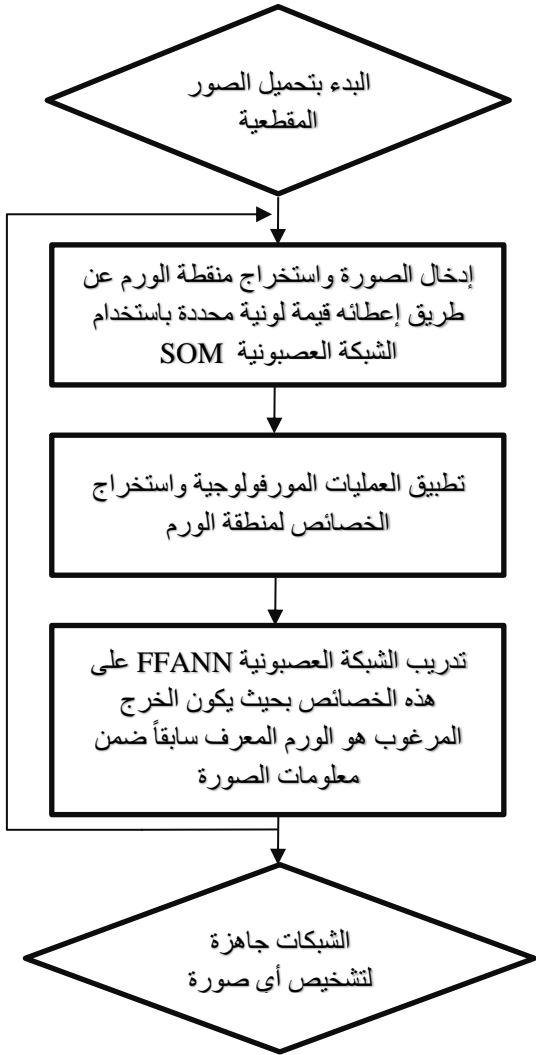


الشكل (3) بنية الشبكة العصبونية

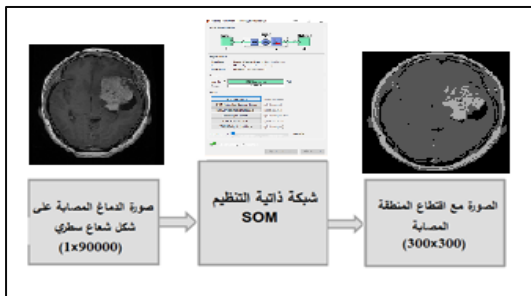
ذات التغذية الأمامية [13]

2-4- قاعدة البيانات المستخدمة في البحث:

تم استخدام قاعدة البيانات brain tumor dataset [14] والتي تحتوي على 3064 صورة مقطعية (شريحة) محسنة وذت تباين عالٍ من 233 مريضاً يعانون من ثلاثة أنواع من



الشكل (4) خوارزمية نظام التشخيص المقترح.



الشكل (5) مخطط صندوقي يبين عمل

شبكة SOM في كشف الورم.

3-2- معالجة وتقطيع الصور:

كما هو موضح في الشكل (5)، فقد كان خرج شبكة SOM عبارة عن صورة ذات ثلاث قيم لونية موزعة ضمن البكسلات، والقيمة العظمى للسوية اللونية (القريبة للون

ثلاث قيم (الخلفية السوداء، النسيج الدماغي الطبيعي، و نسيج الورم الذي يتم تمييزه على أنه المنطقة الأكثر بياضاً في الصورة). بما أن الشبكات العصبونية بشكل عام تعتمد في بنية الدخل لكل عينة على صف واحد (شعاع) من القيم، قمنا في البداية بتغيير عدد بكسلات الصورة إلى 300 بكسل لكل من الطول والعرض (توحيد حجم جميع الصور) ليتم بعدها تحويل الصورة من شكل المصفوفة ثنائية البعد إلى شعاع ذي 90000 عنصر (300x300) ليتم بعدها تدريب الشبكة عليه، وتصنيف الصورة، والخرج عبارة عن الشعاع نفسه ولكن بعناصر تحتوي ثلاث قيم فقط (قيم الخلفية السوداء، النسيج الدماغي، والورم) ليعاد بعدها تحويل بنية الشعاع إلى مصفوفة ثنائية البعد وعرضها على شكل صورة توضح موقع الورم كما في الشكل (5).

4- النتائج والمناقشة

تم اختبار طريقة التصنيف المقترحة في هذا البحث على 300 صورة (100 صورة لكل نوع ورم دماغي)، وقد نجحت الخوارزمية بكشف 298 حالة ورم دماغي من خلال شبكة SOM، وتم بنجاح تصنيف 297 نوع ورم بشكل صحيح باستخدام شبكة FFANN. وأيضاً تم اختبار الخوارزمية على 100 صورة لا تحتوي ورم وقد نجحت الخوارزمية بكشف عدم وجود ورم ضمن 98 صورة منها.

لأجل تقييم أداء النظام المقترح قمنا بحساب بعض المقاييس (المعايير) الشائعة اعتماداً على مصفوفة الإرباك (Confusion Matrix). وتُظهر مصفوفة الإرباك النسب المئوية للتصنيفات (التشخيصات) الصحيحة وغير الصحيحة، وينبع اسم هذه المصفوفة من حقيقة أنها تجعل من السهل رؤية ما إذا كان النظام المصمم مرتكباً بين التصنيفين (أي يخطئ بين أحد التصنيفين على أنه الآخر). يظهر الشكل (7) مصفوفة الإرباك. تمثل الأرقام على طول المحور الرئيس للمصفوفة القرارات الصائبة المتخذة أما الأرقام على طول المحور الثانوي فتمثل القرارات الخاطئة بين الأصناف المختلفة.

تم تحديد دقة النظام المقترح وكفائه من خلال المعايير المتعارف عليها في أنظمة التشخيص والتصنيف الطبي [17]، والتي تعرف بدقة التشخيص (AC) accuracy، الحساسية (SE) sensitivity، والتحديد (SP) specificity


		Actual Values	
		Positive	Negative
Predicted Values	Positive	TP الإيجابي الحقيقي	FP الإيجابي الكاذب
	Negative	FN السلبي الكاذب	TN السلبي الحقيقي

الشكل (7) مصفوفة الإرباك.

وتم حسابهم باستخدام العلاقات:

$$Sensitivity = \frac{TP}{TP + FN} \times 100 = 99\%$$

الأبيض) تدل على الورم، ولكن تم تعيين عظم الجمجمة كورم أيضاً بسبب تشابه الألوان في الصورة الأصل، لذلك كان لا بد من استخدام بعض عمليات معالجة الصورة من أجل التخلص من العظم داخل الصورة والإبقاء على الورم، من خلال النظر إلى خرج شبكة SOM يتبين لدينا أن سماكة العظم قليلة جداً مقارنة مع الورم، لذلك قمنا في البداية بعملية تعذيب لإلغاء جميع المكونات في الصورة، والإبقاء على السوية اللونية للورم وما يشابهه، ثم طبقنا العمليتين المورفولوجيتين الحت والتمدد بحيث يتم إلغاء المركبات صغيرة الحجم ويتم بعدها إعادة نمو الورم، ومن ثم نبقى فقط على الورم داخل الصورة كما يبين الشكل (6). في النهاية تم استخدام مبدأ الوسم labeling ذي الرابطة الثمانية، واستخراج خصائص الكائنات الموسومة، وحساب قيم مساحتها، وأبعادها، وموقعها بشكل نسبي (من أجل سهولة تدريب الشبكة FFANN).



الشكل (6) الخطوة الثانية من حيث معالجة

الصورة والتقطيع واستخراج الخصائص

3-3- تصنيف نوع الورم بالاعتماد على FFANN:

بعد كشف منطقة الورم واستخراج خصائصه، كان من المفيد بناء شبكة عصبونية ذات تغذية أمامية تقوم بتشخيص الورم الدماغي من خلال خصائصه. تم تصميم شبكة FFANN ذات طبقة خفية بحجم 20 عصبون وعدد مداخل 7 وهو عدد الخصائص المستخرجة من الصورة (المساحة، إحداثيات مركز الورم، أبعاد وإحداثيات بداية المستطيل المحيط بالورم)، وخرج وحيد يدل على نوع الورم (تم استخدام الترميز المستخدم نفسه في قاعدة البيانات حيث 1 لورم سحائي، 2 لورم دقيقي، 3 لورم الغدة النخامية). تم تدريب الشبكة على 300 صورة ورم موزعة بالتساوي على كل نوع من الأنواع السابقة.

$$Specificity = \frac{TN}{TN + FP} \times 100 = 98\%$$

$$Accuracy = \frac{TN}{TN + FP} \times 100 = 98\%$$

حيث:

(TP) عدد الصور المصنفة بشكل صحيح التي تحتوي

$$0.99 = 297/300 = \text{على ورم}$$

(FP) عدد الصور العادية المصنفة بشكل خاطئ على

$$0.02 = 2/100 = \text{أنها تحتوي ورمًا من نوع محدد}$$

(TN) عدد الصور المصنفة بشكل صحيح دون ورم =

$$0.98 = 98/100$$

(FN) عدد الصور التي تحتوي على ورم مصنفة بشكل

$$0.01 = 3/300 = \text{خاطئ على أنها صور عادية}$$

5-الخلاصة:

يركز هذا البحث على تطوير نظام تشخيص لكشف أورام الدماغ وتصنيفها في صور الرنين المغناطيسي بالاعتماد على الشبكات العصبونية الاصطناعية، حيث تم في البداية استخدام شبكة من نوع SOM لكشف منطقة الورم، بعد ذلك تم استخلاص بعض السمات والخصائص لتدريب شبكة عصبونية أخرى ذات تغذية أمامية لتحديد نوع الورم من بين ثلاثة أنواع مختلفة. أظهرت النتائج دقة وموثوقية النظام المقترح كأداة مساعدة للكادر الطبي الممارس.

المصطلحات:

المصطلحات باللغة العربية	المصطلحات باللغة الإنكليزية
أفضل وحدة مطابقة	BMU: Best Matching Unit
الخريطة ذاتية التنظيم	SOM: Self Organizing Map
الشبكة العصبونية الاصطناعية	ANN: Artificial Neural Network
مصفوفة الإرباك	Confusion Matrix

REFERENCES

- [14] https://figshare.com/articles/dataset/brain_tumor_dataset/1512427
- [15] Cheng J, et al. (2015). "Enhanced performance of brain tumor classification via tumor region augmentation and partition." *PloS one* 10.10: e0140381.
- [16] Cheng Jun, et al. (2016). "Retrieval of brain tumors by adaptive spatial pooling and fisher vector representation." *PloS one* 11.6: e0157112.
- [17] J.-Y. He X, Wu Y.-G, Jiang Q. Peng, and R. Jain, (2018). "Hookworm detection in wireless capsule endoscopy images with deep learning". *IEEE Transactions on Image Processing*, vol. 27, no. 5, pp. 2379–2392.
- [1] Singh S. K, Clarke I. D, Terasaki M, Bonn V. E, Hawkins C, Squire J, & Dirks P. B. (2003). "Identification of a Cancer Stem Cell in Human Brain Tumors". *Cancer Research*, (63), 5821–5828.
- [2] Ferlay J, Shin H.-R, Bray F, Forman D, Mathers C, & Parkin D. M. (2010). "Estimates of worldwide burden of cancer in 2008". *GLOBOCAN 2008 International journal of cancer. Journal international du cancer*, 127(12), 2893–917.
- [3] Omolara, K. A. (2011). "Feasible Cancer Control Strategies for Nigeria". *American Journal of TROPICAL MEDICINE & Public Health*, 1(1), 1–10.
- [4] Jun C, Wei Y, Shuangliang C, Zhaoqiang Y. (2015). "Enhanced Performance of Brain Tumor Classification via Tumor Region Augmentation and Partition". *PLoS One*.
- [5] Berrington de González A, & Darby S. (2004). "Risk of cancer from diagnostic X-rays: estimates for the UK and 14 other countries". *Lancet*, 363(9406), 345–51.
- [6] Reddick W.E, Glass J.O, Cook E.N, Elkin T, Deaton R. (1997). "Automated segmentation and classification of multispectral magnetic resonance images of brain using artificial neural networks". *IEEE Trans. Med. Imaging*. 16(6), 911–918
- [7] Vijayakumar C, Damayanti G, Pant R, Sreedhar C.M. (2007). "Segmentation and grading of brain tumors on apparent diffusion coefficient images using self-organizing maps". *Computerized Medical Imaging and Graphics* 31, 473–484.
- [8] Sachdeva J, Kumar V, Gupta I, Khandelwal N, Ahuja C. K. (2013). "Segmentation, Feature Extraction, and Multiclass Brain Tumor Classification". *J. Digit Imaging*.
- [9] Anamika A, Jadon R. S. (2011). "Characterization of tumor region using SOM and Neuro Fuzzy techniques in Digital Mammography". *International Journal of Computer Science & Information Technology (IJCSIT)*, Vol 3, No 1.
- [10] Umbaugh SE. (2006). "Computer Vision and Image Processing". Prentice Hall, USA.
- [11] Kohonen T. (1982). "Self-organized formation of topologically correct feature maps", *Biol. Cybern.* 43, pp. 59-69.
- [12] Kohonen T. (1997). "Self-Organizing Maps", 2nd ed., Springer.
- [13] Filippo Amato, Alberto López, Eladia María Peña-Méndez, Petr Vaňhara, Aleš Hampl & Josef Havel. (2013). "Artificial neural networks in medical diagnosis". *Appl Biomed.* 11: 47–58,

Received	2020/07/16	إيداع البحث
Accepted for Publ.	2020/09/16	قبول البحث للنشر