# اكتشاف الأورام الدماغية باستخدام التعلم العميق ( د. طارق محمد الناصوري )


- مسابقة أفضل مقالة علمية
- أفضل مقال - كلية طب الأسنان
- أفضل مقال - كلية الصيدلة
- أفضل مقال - كلية الهندسة
- أفضل مقال - كلية هندسة العمارة
- أفضل مقال - كلية الإدارة


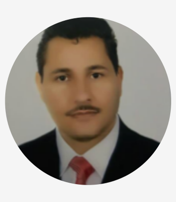

الكاتب : د. طارق محمد الناصوري

**الملخص :**

سرطان الدماغ هو تجمع غير طبيعي للخلايا يحدث في الدماغ، في الوقت الحاضرتلعب تقنيات التصوير الطبي دورًا مهمًا في تشخيص السرطان. يعد التصوير بالرنين المغناطيسي (MRI) أحد أكثر التقنيات استخدامًا لتحديد مكان الورم في الدماغ. قد تصبح الصور التي يتم الحصول عليها بتقنيات التصوير الطبي صورة ذات جودة أفضل من خلال تطبيق خوارزميات التعليم العميق. لذلك نهدف في هذه الدراسة إلى تطوير طريقة للتمييز بوضوح بين الأنسجة المصابة بالسرطان والانسجة السليمة والحصول على صور واضحة للجمجمة والدماغ والورم بما يكفي لمراقبتها من قبل الطبيب ومنحهم المزيد من التفاصيل حول الورم في تشخيصهم، تُستخدم صور التصوير بالرنين المغناطيسي لتقييم دقة البحث المقترح توجد صور في قاعدة البيانات غير طبيعية وصور طبيعية (مع وبدون ورم) للدماغ بالرنين المغناطيسي. جميع الصور بحجم 256 × 256 بكسل بتنسيق JPEG.

يهدف البحث إلى بناء شبكة تعليم عميق قادرة على تمييز المصابين بمرض سرطان الاورام الدماغية، وذلك بعد تدريبها للتعرف على هذا المرض باستخدام خوارزميات التعليم العميق، تعتمد على آخر تطويرات الشبكات العصبونية التلافيفية من خلال استخدام شبكة Mask RCNN. حيث سنقوم بمناقشة بنية وأعمال خوارزميات الرؤية الحاسوبية والتعليم العميق المختلفة للشبكة العصبونية الالتفافية CNN، وشبكة CNN التي تعتمد على المنطقة (R-CNN)، Fast R-CNNg، Faster R-CNNg وصولاً إلى التقنية التي تم استخدامها في بحثنا وهي Mask R-CNN.

**الكلمات المفتاحية**

شبكة اقتراح المنطقة    Region Proposal Network    RPN

SVM    Support Vector Machine    عامل التصنيف الخطي

الشبكة العصبونية الالتفافية    CNN  Convolutional neural network

قسمة منطقة التقاطع الفعلي والمتوقعIntersection over Union    IoU

**1- الخوارزميات المستخدمة والتطورات المستمرة عليها**

**1-1 الشبكة العصبونية الالتفافية (CNN):**

عندما نشاهد صورة، نقوم بمسحها ضوئيًا، قد نعرض صورة من اليسار إلى اليمين أو من أعلى إلى أسفل لفهم الميزات المختلفة للصورة، يجمع دماغنا بين الميزات المحلية (local features) المختلفة التي قمنا بمسحها ضوئيًا لتصنيف الصورة، وهذا بالضبط ما تقوم به هذه الشبكة. تأخذ شبكة CNN الإدخال كصورة "x"، وهي عبارة عن مجموعة ثنائية الأبعاد من البكسلات بقنوات ألوان مختلفة (RGB). أهم قيود شبكة CNN:

يستخدم لاكتشاف الاعتراض باستخدام المربعات المحيطة ولكن لكائن واحد فقط في كل مرة، لا تعمل بشكل جيد عندما توجد كائنات متعددة في المجال البصري بسبب التداخل [1].

**Region based CNN) R-CNN 2-1:**

- إنشاء مقترحات منطقة (category-independent) مستقلة عن الفئة باستخدام البحث الانتقائي لاستخراج 2000 منطقة.
- يتم تغذية مقترحات المنطقة المشوهة (Warped region proposals) إلى شبكة عصبية تلافيفية كبيرة، تعمل CNN كمستخرج ميزة حيث تستخرج متجه ميزة ذات طول ثابت من كل منطقة، وبعد المرور عبر CNN تستخرج R-CNN متجهًا مكونًا من 4096 بعدًا لكل مقترح منطقة.
- يتم تطبيق SVM (Support Vector Machine) على الميزات المستخرجة من CNN، حيث يساعد SVM في تصنيف وجود الكائن في المنطقة، ويستخدم الـ Regressor للتنبؤ بالقيم الأربع للمربع المحيط، ويتم تطبيق عملية إزالة التشويش الجشع غير الأقصى (greedy non-maximum suppression) على جميع المناطق المسجلة في صورة ما.
- ترفض عملية إزالة التشويش الجشع غير الأقصى منطقة ما إذا كانت تمتلك قيمة (IoU) تتداخل مع منطقة تم اختيارها بنتيجة أعلى من العتبة التي تم تعلمها. مما يجعل التدريب بطيئًا ومكلفًا في R-CNN
- نقوم باستخراج 2000 منطقة لكل صورة بناءً على البحث الانتقائي.
- استخراج الميزات لكل منطقة صورة بالنسبة للصورN سيكون لدينا عدد ميزات يبلغ القيمة [2] N * 2000 CNN

**Fast R-CNN 3-1**

إطارعمل سريع لتصنيف الكائنات واكتشاف الأشياء باستخدام شبكات ConvNets العميقة، يستخدم شبكة تحويل عميقة واحدة لاستخراج الميزات، تعمل شبكة ConvNet عميقة واحدةعلى تسريع معالجة الصور بشكل كبير على عكس R-CNN التي تستخدم2000 ConvNets لكل منطقةمن الصورة، يستخدم softmax لتصنيف الكائنات بدلاً من SVM المستخدم في R-CNN، يستخدمFast R-CNNالبحث الانتقائي كطريقةاقتراح للعثورعلى مناطق الاهتمام، وهي عملية بطيئة وتستغرق وقتًا طويلاً، لذا هو غير مناسب لمجموعات البيانات الواقعية الكبيرة [3].

**: Faster R-CNN 4-1**

يستخدم شبكة اقتراح المنطقةRPNبدل البحث الانتقائي المكلف والتي هي شبكة واحدة وموحّدة لاكتشاف الكائنات. يتكون من مرحلتين: المرحلة الأولى هي الشبكة التلافيفية العميقة التي تقترح مناطق تسمى شبكة اقتراح المنطقة (RPN)، نموذج RPN يُستخدم للإشارة إلى الشبكة الموحدة. المرحلة الثانية هي كاشف Fast R-CNN الذي يستخرج الميزات باستخدام RoI Pool من كل مربع مرشح وينفذ التصنيف وانحدار الصندوق المحيط (bounding-box regression) [4].

**5-1 خوارزمية Mask R-CNN:**

يتم تجزئة كل حالة أونموذج (instance)، والهدف هنا هو تصنيف كل بكسل في مجموعة ثابتة من الفئات دون التفريق بين نماذج الكائن، يُعتبر هذا النوع امتداد لشبكة Faster RCNN، وما يلي أهم الاختلافات بينهما:

يحتوي Mask R-CNNعلى فرع إضافي للتنبؤ بأقنعة التجزئة في كل منطقة اهتمام (RoI) بطريقة (pixel-to pixel manner). لم يتم تصميم Faster R-CNN لتحقيق محاذاة من النوع بكسل تلو بكسل بين مدخلات ومخرجات الشبكة. يمتلك Faster RCNN مخرجين: لكل كائن مرشح هناك تصنيف فئة (class label) و(bounding-box offset). بينما تمتلك شبكة  Mask RCNNثلاثة مخرجات:لكل كائن مرشح هناك تصنيف فئة(class label) وإزاحة الصندوق المحيط (bounding-box offset)،وناتج ثالث هو قناع الكائن (object mask) [5] [4].

**الشكل (1): بنية عمل Mask R-CNN**

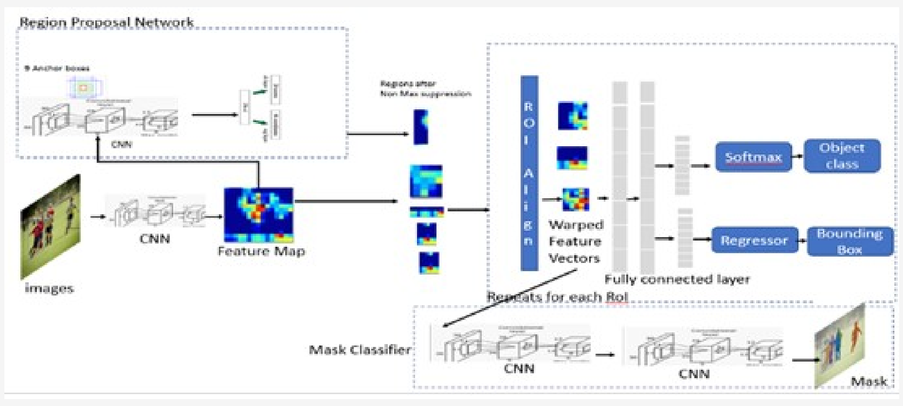


**يتم تنفيذ الخطوات وفقاً للمراحل التالية:**

- يتم تشغيل الصورة من خلال شبكة CNN لإنشاء خرائط الميزات.
- تستخدم شبكة اقتراح المنطقة (RPN) شبكة CNN لتوليد عدة مناطق اهتمام (RoI) باستخدام مصنف ثنائي خفيف الوزن، يقوم بذلك باستخدام 9 مربعات تثبيت فوق الصورة. يقوم المصنف بإرجاع نتيجة وجود أوعدم وجود كائن، حيث يتم تطبيق عملية (Non Max suppression)
- تقوم شبكة RoI Align بإخراج مربعات إحاطة متعددة بدلاً من مربع واحد محدد ومن ثم إعادة تشكيلها إلى بُعد ثابت. يتم بعد ذلك إدخال الميزات – بعد تحويلها – في طبقات متصلة بالكامل (FCN) لإجراء التصنيف باستخدام تابع التفعيل softmax ويتم تحسين تنبؤ الصندوق المحيط باستخدام نموذج الانحدار (regression model). يتم أيضًا تغذية الميزات – بعد تحويلها – في مصنف القناع، والذي يتكون من شبكتي CNN لإخراج قناع ثنائي لكل منطقة اهتمام، حيث يسمح مصنف القناع للشبكة بإنشاء أقنعة لكل فئة.
- بينما تحافظ المفاهيم التي طبقت سابقا في شبكة Faster RCNN مثل Anchor Boxesg Non-IoU على آلية عملها ذاتها في شبكة Mask RCNN.يمثل الشكل التالي مقارنة بين الخوارزميات السابقة لعائلة [4] CNN.

**الشكل (2): مقارنة في آليات عمل خوارزميات تطوير شبكة CNN**

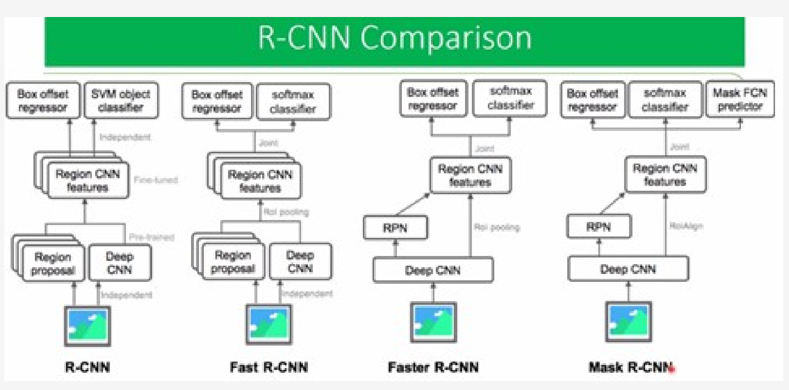


البنية العامة لشبكة Mask RCNN هي كالآتي: **[5]**

**الشكل (3): البنية العامة لشبكة Mask RCN**

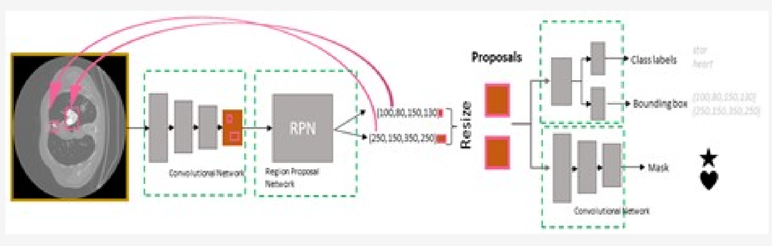


**2-النتائج**

تم اختبار هذه الخوارزمية المقترحة على قسم بيانات الاختبار، وذلك لتحديد مناطق الورم المتوقعة.

**الشكل (4): تطبيق الخوارزمية على عينات من بيانات الاختبار**

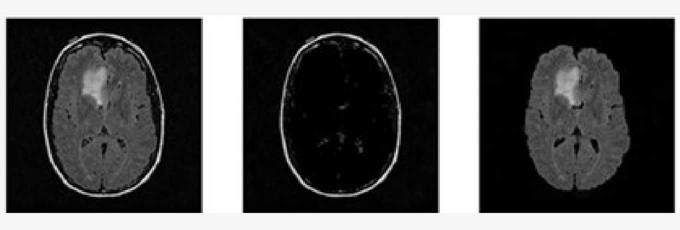

يُعتبر عامل [3] IoU الذي يُحسب من قسمة منطقة التقاطع بين الصندوق الدقيق الفعلي والصندوق المتوقع، إلى قسمة منطقة الاجتماع بينهما، عاملاً مهماً في حساب فعالية شبكة MaskR-CNN.استخدمنا مكتبة Numpy لحساب قيمته في شبكتنا. من أصل 700 صورة للورم، تم تقييم 650 صورة بشكل صحيح بواسطة النظام باقي الصور تم تحديدها على أنها خالية من الورم بشكل غير صحيح. ويعود سبب هذا الخلل إلى عدم وجود تمييز واضح بين منطقة الورم وبقية أجزاء الدماغ من حيث شدة البكسلات .[6]

**الشكل (5): تشكيل الأقنعة لمناطق انتشار الورم المتوقعة**

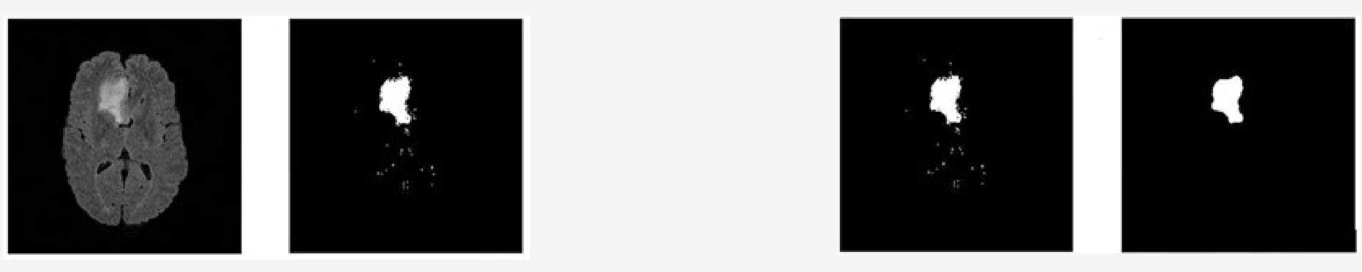

**الخاتمة**

تم في هذا البحث تدريب الشبكة على عدد كبير من البيانات والصور الطبية، يقدّم نتائج أفضل كلما أصبحت البيانات المُعالجة أكبر (Big Data) بينما لا تستطيع خوارزميات تعليم الآلة التقليدية التعامل معها.اعتمدنا على شبكات Mask-RCNN الحديثة في التعليم العميق، والتي تُعتبر تطوير للشبكات العصبونية التلافيفية CNN، ذلك أنها تؤمن أداء أفضل مع مهام التجزئة أو التقطيع مقارنةً مع الشبكات المنافسة.يعتبر هذا البحث وسيلة مساعدة ودعم للأطباء لتشخيص سرطان الدماغ باستخدام صورالتصويربالرنين المغناطيسي,التي تم الحصول عليها من أرشيف تصوير السرطان (TCIA) (The Cancer Imaging Archive, 2017). فتوجد صور في قاعدة البيانات تحتوي على صورة غير طبيعية وصور عادية (مع وبدون ورم) للدماغ بالرنين المغناطيسي. جميع الصور بحجم 256 × 256 بكسل، وبتنسيق JPEG.يتمتع البحث المقترح بمعدل التعرف على الصورالتي تحتوي على ورم بنسبة 85.28% ومعدل التعرف على الصور التي لا تحتوي على ورم بنسبة 100%. يبلغ معدل النجاح الإجمالي لنظامنا حوالي 90% ممايدل على أداء أفضل بالمقارنة.

**اقتراح الاعمال المستقبلية**

هناك خوارزميات حديثة يمكن تجريبها وخاصة اننا أتحنا الفرصة للطبيب بالاعتماد الكلي على نتائج العمل, يفضل تنفيذ معالجة صورة بشكل دقيق قبل تقديمها للخوارزميات.

**المراجع**

1-Acharya, U. Rajendra, Shu Lih Oh, Yuki Hagiwara, Jen Hong Tan, Muhammad Adam, Arkadiusz Gertych, and Ru San Tan"A deep convolutional neural network model to classify heartbeats." Computers in biology and medicine 89 (2017): 389-396.

2 -Sun, Xudong, Pengcheng Wu, and Steven CH Hoi. "Face detection using deep learning: An improved faster RCNN approach." Neurocomputing 299 (2018): 42-50

3-Wu, Minghu, Hanhui Yue, Juan Wang, Yongxi Huang, Min Liu, Yuhan Jiang, Cong Ke, and Cheng Zeng. "Object detection based on RGC mask R-CNN." IET Image Processing 4, no. 8 (2020): 1502-1508.

4 -He,Kaiming,Georgia Gkioxari,Piotr Dollár,and Ross Girshick."Mask r-cnn In Proceedings of the IEEE international conference on computer vision.2961-2969 2017

5 -Cheng, Tianheng, Xinggang Wang, Lichao Huang, and Wenyu Liu. "Boundary-preserving mask r-cnn." In European conference on computer vision, pp. 660-676. Springer, Cham, 2020.

6 -Bharati, Puja, and Ankita Pramanik. "Deep learning techniques—R-CNN to mask R-CNN: A survey." In Computational Intelligence in Pattern Recognition, pp. 657-668. Springer, Singapore, 2020.

7-The Cancer Imaging Archive,2017. Rembrandt. https://wiki.cancerimagingarchivefrom.net/display/Public/REMBRANDT;jsessionid=D8DC3A



تنفيذ إدارة المواقع الالكترونية في الجامعة الوطنية الخاصة 2023