

الكشف عن ورم الدماغ باستخدام تقنيات التعلم العميق

م.ماري سليمان⁽¹⁾ ، د.جعفر سلمان⁽²⁾ ، د.غادة سعد⁽³⁾

طالبة دراسات عليا في كلية هندسة تكنولوجيا المعلومات والاتصالات- قسم تكنولوجيا المعلومات- جامعة طرطوس

مدرس في كلية هندسة تكنولوجيا المعلومات والاتصالات- قسم تكنولوجيا المعلومات- جامعة طرطوس

مدرسة في كلية الهندسة الميكانيكية والكهربائية – قسم الهندسة الطبية – جامعة تشرين

Mariesliman1994@gmail.com

ملخص:

يعد التعلم العميق والرؤية الحاسوبية من أهم علوم الذكاء الاصطناعي التي تطورت بشكل كبير وتزايد الاهتمام بها في الآونة الأخيرة حيث تم توظيف هذا التطور ببناء تطبيقات ذكية في مختلف المجالات التعليمية والصناعية والتجارية والأمنية والطبية وغيرها، وبما أن البيانات الطبية تعتمد على الصور بشكل كبير جداً يوجد استخدامات واسعة للرؤية الحاسوبية في المجال الطبي ومن أهمها طرق التشخيص الحديثة وتحليل الصور الطبية. يقترح هذا البحث استخدام خوارزميات التعلم العميق الفعالة للكشف عن ورم الدماغ حيث أنه كلما كان الكشف عن الورم سريعاً ودقيقاً تزداد فرص نجاح العلاج وبالتالي انخفاض معدل الوفيات بهذا المرض. تم اقتراح نموذج تعلم عميق يعتمد على الشبكات العصبونية الالتفافية CNN للكشف عن ورم الدماغ، وتدريب هذا النموذج على قاعدة بيانات صور رنين مغناطيسي MRI تتألف من 253 صورة تنقسم إلى قسمين 155 سليمة و98 مصابة (تحتوي على ورم). تم أولاً القيام بعمليات معالجة للصورة لتهيئتها لتصبح بمواصفات مقبولة لاستخدامها في نموذج التعلم العميق، ثم تمت المقارنة بين عدة نماذج حيث تم الاستفادة من النماذج المدربة مسبقاً *pre-trained models* باستخدام تقنية نقل التعلم *transfer learning* وتم تحقيق أفضل دقة تقييم باستخدام النموذج *xception* وأخيراً تم تطبيق تقنية الضبط الدقيق *fine tuning* على هذا النموذج ليصبح أكثر ملائمة للمهمة المطلوبة وأعطت النتائج دقة 94% وحساسية 91% وخصوصية 96% وبالتالي توضح النتائج فعالية الخوارزمية المقترحة كنموذج مساعد للأطباء وأخصائي الأشعة كقارئ للصور وللتحقق من صحة نتائجهم.

الكلمات المفتاحية: ورم دماغ، التعلم العميق، الشبكات العصبونية الالتفافية، معالجة صورة، نقل التعلم، صور MRI.

Abstract:

Deep learning and computer vision are among the most important sciences of artificial intelligence that have developed greatly and the interest has increased in them recently, as this development has been employed to build smart applications in various educational, industrial, commercial, security, medical and other fields, since medical data depends a lot on images, there are wide uses of computer vision in the medical field, the most important are modern diagnostic methods and analysis of medical images. This paper proposes the use of effective deep learning algorithms for brain tumor detection, where the faster and accurate the detection of the tumor, the higher the chances of successful treatment and thus the lower the death rate of this disease. A deep learning model based on CNN is proposed to detect brain tumor, and this model has trained on a database of MRI images consisting of 253 images divided into two parts 155 healthy and 98 infected (containing tumor). First, image processing operations have performed to prepare it to become acceptable specifications for use in the deep learning model, then several models have compared,

where pre-trained models were taken advantage of using transfer learning technology, and the best evaluation accuracy has achieved using the xception model. Finally, the fine-tuning technique has applied to this model to make it more suitable for the required task, and the results are 94% accuracy, 91% sensitivity, and 96% specificity. Therefore, the results demonstrate the effectiveness of the proposed algorithm as an assistant model for clinicians and radiologists as an image reader and to validate their results.

Key words: Brain tumor, Deep learning, Convolution Neural Networks(CNN), Transfer learning, MRI images, Image processing.

feature maps حيث تساعد عملية الالتفاف في تقليل عدد المعاملات مما يسمح للشبكة بأن تكون أعمق بمعاملات أقل وأيضاً تحل مشكلة التدرجات المتلاشية exploding gradients التي تحصل في تدريب الشبكات التقليدية، تتبعها عادةً طبقة التجميع pooling layer التي تقوم بتجميع الميزات وتقليل حجم مصفوفات الخصائص مع الحفاظ على الميزات المهمة لكل مصفوفة ثم تحول طبقة flatten layer كافة مصفوفات الخصائص إلى متجه vector واحد لأجل ربطه بالطبقة الأخيرة output layer وهي طبقات الاتصال الكامل Full connection layers التي تقوم بعملية التصنيف [1].

تم تقديم مفهوم CNN لأول مرة في 1989 من قبل العالم Yann LeCun وآخرون وتمكنت شبكات CNN من جذب انتباه العالم بسبب قدرتها الفريدة على التعلم مباشرة من البيانات الخام دون الحاجة إلى تصميم عملية استخلاص الخصائص يدوياً وبالإضافة إلى مستوى الأداء العالي الذي تحققه فهي تقوم بجمع مهمة استخلاص الخصائص المحسنة (optimized) والتصنيف في مرحلة واحدة على عكس شبكات ANN التي تؤدي بعض خطوات المعالجة المسبقة ثم تقوم باستخراج الخصائص يدوياً والتي ربما لا تكون الأمثل وتتطلب تعقيد حسابي عالي .

ورم الدماغ هو تكاثر خلايا شاذة في أنسجة الدماغ، والتي يمكن أن تكون سرطانية (خبيثة) أو غير سرطانية (حميدة) ويعد من الأمراض الخطيرة فالدماغ عضو معقد وحيوي ويحتوي على حوالي 100 مليار خلية عصبية ويتحكم في جميع الوظائف الحيوية [2]، لذلك فإن أي نوع من الضرر الذي يصيب الدماغ قد يعرض صحة الإنسان للخطر وتعد الأورام من أشد هذه الأضرار، يمكن الكشف عن أورام الدماغ باستخدام فحص التصوير بالرنين المغناطيسي MRI قبل ملاحظة العلامات السريرية، ويعد أفضل فحص تصويري للتعرف على ورم الدماغ حيث يتم استخدامه لفحص التراكيب التشريحية واكتشاف الاختلافات بين الأنسجة المريضة والسليمة باستخدام الموجات الراديوية في

1- مقدمة:

واجه الباحثون بعض المشاكل في الشبكات العصبونية التقليدية حيث تكون الدقة accuracy محدودة وغير قابلة للتحسين حتى مع زيادة حجم بيانات التدريب Training datasets أو عدد الطبقات المخفية hidden layers لذلك طور الباحثون هذه الشبكات وسميت الشبكات الجديدة بعد التطوير الشبكات العصبونية العميقة Deep Neural Networks(DNN)، وكلمة العميقة تشير إلى عدد الطبقات المخفية، وأصبح من الممكن زيادة الدقة عن طريق زيادة عدد الطبقات المخفية أو زيادة حجم قاعدة بيانات التدريب.

يعتمد التعلم العميق على معالجة كميات ضخمة من البيانات والأنماط المعقدة كاللغات والصور والكلام من خلال تمريرها على الشبكات العصبونية العميقة وتدريبها على استخراج معلومات مفيدة من هذه البيانات، وتنقسم هذه الشبكات إلى نوعين الشبكات الالتفافية والشبكات التكرارية، وتعد الشبكات العصبونية الالتفافية Convolution Neural Networks(CNN) نوع خاص من الشبكات العصبونية العميقة تستمد آلية عملها من العمليات البيولوجية الموجودة في الفص البصري بالتحديد من دماغ الإنسان، وتستخدم غالباً في معالجة مهام الرؤية الحاسوبية فالعين ترى الصورة ثم يقوم الدماغ بتحليلها واستخراج الخصائص منها وكما ينظم البشر أفكارهم ومفاهيمهم بشكل هرمي بدءاً من المفاهيم البسيطة وصولاً للمفاهيم الأكثر تعقيداً تقوم الشبكات الالتفافية باستخلاص الخصائص بدءاً من الخصائص العامة وصولاً للخصائص المعقدة حيث أن خصائص الصورة features هي منطقة تغيير مفاجئ بالقيمة مثل مناطق الحافة لا يمكن ملاحظتها بالعين المجردة ولكن يمكن فهم الصورة عن طريقها، وعملية استخلاص الخصائص هي الحصول على هذه المميزات. سميت الشبكات الالتفافية بهذا الاسم لأنها تحتوي على الطبقات الالتفافية convolution layers التي تقوم باستخلاص الخصائص ووضعها ضمن مصفوفات الخصائص

Network [7] تقترح بناء شبكة CNN لتصنيف صور دماغ إلى صورة تحتوي ورم ولا تحتوي ورم وهذه الشبكة مكونة من 3 طبقات التفاضلية conv2d تحتوي على perceptron 128 ، 64 ، 32 و كل منها متبوعة بطبقة تجميع ثم طبقة مسطحة وبعدها طبقة اتصال كامل مع عدة توابع تنشيط , Relu sigmoid, tanh وبلغ عدد العناصر التي سيتم تدريبها 952,278 وحقق النموذج دقة 96% على قاعدة بيانات صور MRI المكونة من 64 صورة.

➤ في العام 2019 [8] قام الباحثون Mohamed et el Shakeel ببناء نظام لتصنيف أورام الدماغ حيث يعتمد هذا النظام على استخدام التعلم الآلي القائم على الشبكات العصبية للانتشار الخلفي (MLBPNN) machine learning based back propagation neural networks حيث يتم تحليل MLBPNN بمساعدة تقنية التصوير بالمستشعر اللاسلكي بالأشعة تحت الحمراء infrared في بيئة لشبكات الحساسات اللاسلكية وذلك لفحص للمرضى المسنين أو الذين يعيشون في مناطق نائية. تم استخراج الميزات باستخدام مصفوفة التغيرات ذات المستوى الرمادي Gray Level Covariance Matrix (GLCM) وخوارزمية تحليل المكون الرئيسي Principal Component Analysis (PCA) ثم تم استخدام MLBPNN للتصنيف وقد وصلت الدقة إلى 93.33%.

2- مشكلة البحث:

إن التشخيص المبكر والدقيق لأورام الدماغ هو الخطوة الأولى نحو العلاج الناجح، وتفيد فحوصات التصوير في تشخيص الأورام في مراحل مبكرة، لكن يؤدي الاكتشاف البصري أحياناً لهذه الأورام إلى التشخيص الخاطئ بسبب أخطاء بشرية ناجمة عن التعب البصري وخاصة في المناطق التي يتداخل فيها الورم مع أنسجة المخ الكثيفة ويكون التشخيص الخاطئ مكلف ومجهد للمريض نفسياً كما كشفت الدراسات عن وجود 20-60 % من السرطانات تم تفسيرها مسبقاً كوضع طبيعي [9].

3- أهمية البحث وأهدافه:

يقوم هذا البحث بإجراء دراسة علمية لتأثير استخدام تقنيات التعلم العميق والرؤية الحاسوبية لكشف حالات مرضية مثل حالة ورم الدماغ باستخدام صور MRI، فمع تطور وسائل التصوير ظهرت الحاجة إلى استخدام

مجال مغناطيسي معين وهو طريقة خالية من الإشعاع ولا تتطلب إعدادات أولية كما توفر صور MRI تبايناً أكبر مقارنةً بالتصوير المقطعي المحوسب CT أو صور الموجات فوق الصوتية [3]. ويعود التشخيص النهائي للطبيب وأخذ خزعة من الدماغ لكن يبقى التشخيص بمساعدة الحاسب أداة مفضلة للتشخيص غير الجراحي [4].


يعد الكشف الآلي عن ورم الدماغ مسألة مهمة ومجال بحثي نشط حيث قام العديد من الباحثين بدراسة طرق ونماذج مختلفة للكشف عن ورم الدماغ.

الدراسات المرجعية

➤ في العام 2020 قام الباحث Febrianto, et al. باجراء دراسة بعنوان Convolutional Neural Network for Brain Tumor Detection [5] حيث قام ببناء نموذج شبكة CNN للكشف عن ورم الدماغ وتطبيقه على قاعدة البيانات التي تم الحصول عليها من موقع Kaggle (وهي القاعدة المستخدمة في هذه الدراسة) حيث قام أولاً بمعالجة مسبقة للبيانات لوجود أنواع مختلفة من الكثافة والتباين والحجم في الصور ثم قام بالمقارنة بين نموذجين مختلفين للشبكات الالتفافية الأولى يتألف من طبقة التفاضلية ثم ثلاث طبقات تجميع وطبقة مسطحة وطبقة اتصال كامل وحقق دقة 85% أما النموذج الثاني يتألف من طبقة التفاضلية، طبقة تجميع ، طبقة اسقاط (مكررة مرتين) ثم طبقة مسطحة، طبقة اتصال كامل، طبقة اسقاط، طبقة اتصال كامل وتم الحصول على دقة 93% لكنه استغرق وقت أطول في التدريب.

➤ في العام 2020 قام الباحث Siddique, et al. [6] ببناء شبكة CNN لتصنيف صور ورم دماغ إلى صنفين سليم ومصاب على قاعدة البيانات السابقة نفسها حيث قام أولاً بعمليات معالجة للصورة كالتعتيب والعمليات المورفولوجية ثم استخدام نموذج VGG16 لبناء شبكة CNN مع تعديل النموذج باستبدال طبقة MAX Pooling بطبقة Average Pooling وإضافة طبقتين اسقاط Dropout بمعدل 0.3 ثم انشاء طبقة تصنيف مع تابع تنشيط Softmax وكانت الدقة 96%.

➤ في العام 2020 قام الباحث Choudhury باجراء دراسة بعنوان Brain Tumor Detection and Classification using Convolutional Neural Network and Deep Neural




شكل (1) خطوات مرحلة معالجة الصورة

1-1-5 الحصول على الصور:

تم الحصول على قاعدة البيانات من موقع Kaggle وهو تابع لشركة Google LLC، وهو مجتمع عبر الإنترنت لعلماء البيانات والتعلم الآلي. <https://www.kaggle.com/brain-mri-images-for-brain-tumor-detection>، تحتوي قاعدة البيانات على صور رنين مغناطيسي MRI تتألف من 253 صورة تنقسم إلى قسمين 155 سليمة و98 مصابة.

2-1-5 المعالجة المبدئية:

يتم في هذه المرحلة تطبيع البيانات normalization أي توحيد حجم الصور والقيم اللونية لها، الخطوة الأولى هي الحصول على صورة الدماغ أي تحديد الجزء المهم من الصورة وحذف الأطراف غير المهمة وللقيام بهذه العملية يجب أولاً إيجاد الإطارات في الصورة بهدف القيام بعملية اقتطاع الصور عن طريق تحديد الإطارات وهي عبارة عن منحنيات تضم كل النقاط المتصلة مع بعضها والتي تملك نفس اللون أو الشدة وتتم عملية الاقتطاع بإيجاد الأطار ثم تحديد النقاط المتطرفة وقص الصورة عند هذه النقاط كما يوضح الشكل (2) خطوات عملية الاقتطاع.



شكل (2) مثال عن اقتطاع الدماغ من الصورة

ثم يتم بعدها توحيد حجم الصور إلى (224,224) لتناسب النموذج المستخدم وتقسيم بكسلات الصور على 255 وبما أن الصور 8units أي مكعبة ب 8 بنات سيتم تحويل القيم من 0 إلى 255 إلى المجال بين 0 و 1 حيث يجب أن تكون جميع الصور الداخلة إلى الشبكة نفس النوع والحجم والتدرج اللوني.

3-1-5 تحسين الصورة والتخلص من الضجيج Image enhancement and Noise removal:

أجهزة وبرامج حاسوبية تمد الطبيب بالمزيد من المعلومات وتحقق بذلك تكاملاً مع بقية عمليات الرعاية الصحية وتطويراً لأدائها.

يهدف هذا البحث إلى تحسين جودة الصورة الرقمية للدماغ ثم تطوير نموذج للكشف عن ورم الدماغ بأقل وقت وتكلفة ممكنة حيث تفيد في تصنيف عدد كبير من الحالات بزمن أقل بالمقارنة مع التشخيص البشري وتكون مساعد للأطباء وأخصائي الأشعة في الكشف عن الأورام.

تساعد الخوارزمية المقترحة على تحليل الصور الطبية واستخلاص البيانات المفيدة منها لدعم اتخاذ القرار الطبي في التشخيص وهو الكشف عن وجود ورم ويقوم أيضاً بإضافة الحالات الجديدة إلى قاعدة البيانات أي أرشفة الحالات وبالتالي يدعم القدرات التعليمية والمرجعية للدارسين والباحثين.

4- طرق البحث ومواده:

تم تنفيذ هذا البحث باستخدام لغة البرمجة python ضمن بيئة العمل anaconda على جهاز حاسوب شخصي يمتلك وحدة معالجة مركزية intel corei7-6500u بسرعة 2.6GHz وذاكرة نظام 8GB.

يتضمن البحث عدة مراحل بدءاً من الحصول على الصورة وصولاً إلى مرحلة التشخيص من خلال بناء نموذج التعلم العميق الذي يعتمد على شبكات CNN مع الاستعانة بمكتبات Tensorflow و Keras من أجل بناء النموذج.

5- مراحل البحث:

1-5 مرحلة معالجة الصورة:

معالجة الصورة هي مجموعة من العمليات تتم على الصورة بهدف تحسينها طبقاً لمعايير محددة بحيث تكون الإشارة الخارجة منها هي صورة مفهومة من قبل الانسان بعد اجراء التحسينات المطلوبة وتكون هذه الصورة هي دخل لعملية الرؤية الحاسوبية التي يتم فيها استخلاص المميزات والخصائص من الصورة أما خرج عملية الرؤية الحاسوبية هو إشارات مفهومة من قبل النموذج الحاسوبي وليست صورة أي خصائص ومميزات وقياسات.

يتم تحقيق تحسين ناجح عندما يتم دمج مجموعة من التقنيات من أجل تحقيق النتيجة النهائية وليس عن طريق عملية واحدة [10]، وتم ضمن خطوات مرحلة معالجة الصورة المبينة بالشكل (1) تطبيق العديد من التحسينات والمرشحات لتحسين جودة الصورة لتهيئتها لنموذج التعلم العميق حيث تم اختيار المرشحات التي تناسب طبيعة الصور وتحقق أفضل نتيجة.


وهذا يساعد في تهيئة الصورة لعمليات المعالجة التالية فكلما كانت الصورة أوضح كانت نتيجة عملية التعتيب أفضل.

4-1-5 تجزئة الصورة

:image segmentation

(1) تعتيب الصورة Thresholding:

التعتيب هو اظهار مستوى لوني محدد في الصورة ونقوم به لتحويل الصورة الرمادية إلى ثنائية من أجل إمكانية تطبيق العمليات الشكلية عليها [11]، ويظهر الشكل (4) الصورة قبل وبعد عملية التعتيب.



قبل

بعد

شكل (4) الصورة بعد تطبيق التعتيب

(2) التحويلات من الناحية الشكلية

:morphological transformations

تتكون صور الدماغ من مادة رمادية وبيضاء وتكون المنطقة التي تحتوي على الورم أكثر كثافة (أي باللون الأبيض) لذلك من خلال التحويلات الشكلية (المورفولوجية) يمكن استخراج منطقة الورم.

حيث أن العمليات الشكلية هي بعض العمليات البسيطة التي تجري على شكل الصورة وتعد أداة لاستخراج مكونات الصورة المفيدة [10]، تنفذ على الصور الثنائية يُحتاج لتنفيذ هذه العملية إلى دخليين الدخول الأول هو الصورة الأصلية والدخول الثاني هو العنصر التركيبي structuring element أي المصفوفة المسؤولة عن تحديد القناع kernel الذي يحدد طبيعة العملية.

يتم عادة اختيار العنصر التركيبي بشكل مشابه للكائن المراد معالجته في الصورة المدخلة لذلك تم اختيار العنصر البيضاوي ellipse. حيث ساعد العنصر البيضاوي بعدم تحديد الهيكل العظمي في المنتصف على أنه ورم.


تعاني الصور الطبية بشكل عام من الضجيج والتشويش [10] حيث أن الضجيج هو معلومات غير مرغوب فيها تؤدي إلى تشويه الصورة وإضعاف وضوحها، ويمكن أن يحدث بسبب تشتت الموجات باتجاهات مختلفة وذلك لوجود جسيمات أو دقائق أو شوائب ذات أقطار صغيرة نسبياً موجودة في محيط وأجهزة نظام التصوير نفسه أو قد تكون ناتجة عن ضجيج حراري في منظومة نقل الإشارة أو تسجيلها.

يوجد أنواع مختلفة من المرشحات المتاحة لمعالجة الصور لإزالة الضجيج وهي المرشحات الخطية والمرشحات غير الخطية وكل منها له خصائص مختلفة.

A. **المرشحات الخطية:** هي المرشحات المتوسطة مثل مرشح المتوسط الحسابي، مرشح المتوسط الهندسي، مرشح المتوسط التوافقي وكل مرشح يناسب نوع ضجيج مختلف مثلاً مرشح المتوسط التوافقي يناسب الضجيج النبضي أما المرشحات الحسابية والهندسية فهي مناسبة للضوضاء العشوائية مثل مرشح Gaussian، يتميز هذا المرشح أنه يقوم بتنعيم الصورة وفي نفس الوقت الحفاظ على أجزاء الصورة الأصلية وأبرزها الحواف.

B. **المرشحات غير الخطية:** تعد مرشحات min و max مرشحات إحصائية غير خطية، يزيل مرشح max ضجيج الفلفل إلى حد كبير ولكنه يزيل أيضاً بعض وحدات البيكسل المظلمة من حدود الكائن المظلمة وبما أن صورة MRI تتكون من كائن مظلم فإن هذا المرشح غير مناسب لذلك يتم استخدام مرشح متوسط median يسعى إلى إيجاد الوسيط لقيم مجموعة البكسلات التي تقع تحت هذا المرشح ويستبدل النتيجة بالعنصر المركزي [11].

وبين الشكل (3) أن النتيجة هي صورة أقل ضجيج (الضجيج الذي يظهر كنقط أو حبيبات رمل على الصورة الأولى والتي لا تحتوي على أي معلومات مفيدة).



قبل

بعد

شكل (3) الفرق بين الصورة الأصلية والصورة بعد تطبيق المرشحات

الحواف من الصورة حيث الحواف هي خيط رفيع يمر بين المناطق الغير مشتركة في الصورة أو المجالات اللونية الغير متجانسة والتي تظهر بشكل مفاجئ وبالتالي من أجل ترميم الصورة يجب استرجاع الحواف.

1) عملية كشف الحواف:

يتم الحصول على حواف الصورة الأصلية من خلال خوارزمية كشف الحواف canny وهي خوارزمية مشهورة لكشف الحواف حيث تعمل هذه الخوارزمية على إيجاد تدرج الحافة واتجاه كل بكسل بالاعتماد على المعادلات التالية


$$\text{EdgeGradient}(G)=\sqrt{G_x^2 + G_y^2} \quad (1)$$

$$\text{Angle}(\alpha)=\tan^{-1}\left(\frac{G_y}{G_x}\right) \quad (2)$$

G_x : تدرج الصورة في الاتجاه الأفقي

G_y : تدرج الصورة في الاتجاه العمودي

ثم إجراء مسح للصورة لحذف البكسلات التي لا تشكل الحافة، ويمتاز هذا الكاشف في أنه يقوم بتأدية عدة خطوات خلال عملية الكشف ينتج منها كشف دقيق للحواف. يظهر الشكل(7) الصورة الأصلية وبعد كشف الحواف.



قبل (الصورة الأصلية) بعد (كشف الحواف)


شكل (7) كشف حواف الصور

2) دمج الصورتين:

يتم بعد كشف الحواف إعادة بناء الصورة من خلال دمج الصورة التي تم الحصول عليها بعد تطبيق العمليات الشكلية مع حواف الصورة الأصلية، ويظهر الشكل(8) عملية الدمج والصورة الناتجة.

يوجد عمليتان أساسيتان وهما عملية التآكل Erosion وعملية التمدد Dilation.

A. التآكل Erosion: هو عملية تقلص الكائنات في الصورة، تؤدي هذه العملية إلى تنعيم حدود السطح الأمامي (الذي يكون باللون الأبيض) كما في الشكل(5).



قبل

بعد

شكل (5) الصورة بعد عملية التآكل

B. التمدد Dilation: هو عملية تكبير الكائنات في الصورة وهي عكس عملية التآكل وبالتالي يزداد حجم المنطقة البيضاء كما في الشكل(6).



قبل

بعد

شكل (6) الصورة بعد عملية التمدد

يمكن ملاحظة أنه عند يتم تطبيق عملية التآكل قلت مساحة الجسم الأبيض في الصورة ولهذا السبب تتبع عملية التآكل بعملية التمدد حتى تزيد مساحة الجسم الذي تآكل ولاسترجاع الأجزاء المتأكلة من الجسم وتم تطبيق هذه العمليات مرتين لتحقيق المزيد من الدقة.

5-1-5 استعادة الصورة

:Image Restoration

يمكن من خلال العمليات الشكلية الحصول على موقع الورم وحجمه ولكن بنفس الوقت تؤدي هذه العمليات إلى إزالة

2-5 مرحلة بناء النموذج Model building

I. استدعاء المكتبات

import libraries and modules

يبدأ أي برنامج بتهيئة بيئة العمل واستدعاء المكتبات اللازمة لعمل البرنامج حيث تم الاعتماد على مكتبة Tensorflow و Keras من أجل التعامل مع شبكات CNN بالإضافة إلى مكتبات Numpy للتعامل مع المصفوفات و Matplotlib للرسم البيانية و OpenCV من أجل توابع معالجة الصورة.

II. تحميل البيانات:

يتم تقسيم البيانات إلى ثلاث مجموعات وهي:

- ✓ مجموعة التدريب training set: هي المجموعة التي يتم تدريب النموذج عليها.
- ✓ مجموعة التحقق validation set: هي المجموعة التي يتم استخدامها أثناء تدريب النموذج لضبط المعاملات.
- ✓ مجموعة الاختبار test set: مجموعة صغيرة لا يتم الاقتراب منها أبداً أثناء عملية التدريب وتستخدم فقط لتقييم أداء النموذج النهائي.

تم تقسيم البيانات إلى 70% للتدريب و 20% للتحقق و 10% للاختبار أي سيكون هناك 183 صورة للتدريب و 50 للتحقق و 20 للاختبار.


III. معالجة البيانات process data

تتم في هذه المرحلة خطوات معالجة الصورة المذكورة سابقاً في مرحلة معالجة الصورة وبما أنه في قاعدة البيانات الموجودة لدينا كل صورة لديها عرض وارتفاع مختلف وبما أننا سنقوم بتوحيد حجم الصور الداخلة إلى النموذج قمنا أولاً بحساب ratio وهو نسبة عرض الصور إلى ارتفاعها $ratio = width/height$ ويظهر أن قيم أغلب الصور حول 1 أي الطول متناسب مع العرض ولن نحصل على صور غريبة عند إعادة تحجيم الصور resizing.


IV. تحديد بنية النموذج:

بنية النموذج الذي يقوم بمهمة تصنيف الصور image classification تنقسم إلى قسمين:

- 1- استخلاص الخصائص: تقوم بها الطبقات الالتفافية وما بينها من طبقات ثانوية مثل pooling layers.




=



الصورة بعد الدمج

شكل (8) نتيجة دمج الصورتين

وبعد تطبيق هذه العملية تصبح الشبكة العصبونية الالتفافية قادرة على كشف الورم بدقة أفضل، ويظهر الشكل (9) الصورة النهائية.



الصورة الأصلية

الصورة النهائية

شكل (9) مقارنة بين الصورة الأصلية والصورة النهائية بعد استعادة الحواف

2- التصنيف: الطبقات الأخيرة وهي طبقات الاتصال الكامل وخاصة طبقة الخرج output layer.

خرجها ويسمى وصلة الاختصار shortcut connection.

4- النموذج InceptionV3: يتألف من 48 طبقة، ومساحتها أقل من النماذج السابقة حيث بلغت 96 ميغابايت فقط يتميز بقلّة العناصر الواجب تدريبها يعتبر خطوة مهمة باتجاه زيادة الكفاءة والسرعة للنماذج المدربة حيث يتألف من وحدات بناء أساسية تسمى inception module وهي كتلة من طبقات التفاضلية متوازية ذات أحجام مرشحات مختلفة وطبقة تجميع وفق القيمة الأكبر ثم يتم جمع نتائج جميع الطبقات مما يؤدي لتقليل كمية العمليات الحسابية المطلوبة.

5- النموذج Xception: هو امتداد لبنية inception السابقة وله نفس العدد من المعاملات يتألف من 36 طبقة التفاضلية في 14 وحدة تأسيس وهي بنية شبكة التفاضلية تعتمد كلياً على طبقات التفاضلية قابلة للفصل في العمق.

تم إضافة بعض التقنيات التي تخفف من ظاهرة فرط التخصيص overfitting مثل إضافة طبقة dropout layer لتطبيق تقنية الإسقاط بمعدل 0.25 أي أنه في لحظة معينة سيكون هناك بعض الخلايا العصبونية التي لن تكون متصلة بأي خلية عصبونية أخرى في الشبكة وهذا يؤدي إلى تحسين أداء الشبكة لأنه يعزز من استقلال الخلايا وكذلك تم استخدام تقنية ضبط الأوزان التي تقوم بدفع الأوزان غير المهمة التي لا تسهم كثيراً في الشبكة إلى قيم صغيرة وأخيراً إضافة طبقة التصنيف الأخيرة وتابع التنشيط sigmoid الذي يعمل وفق المعادلة

$$F(x) = \frac{1}{1+\exp(-x)} \quad (3)$$

وبالتالي تم تحويل مجال الدخل من $(-\infty, +\infty)$ إلى مجال $(0, 1)$ ، ليسخدم في حالة التصنيف الثنائي.

V. تدريب النموذج:

بعد تصميم النموذج ومعالجة البيانات تأتي مرحلة تدريب النموذج على هذه البيانات، ويتم استخدام الخوارزمية الأكثر شيوعاً وهي الانتشار نحو الخلف Back propagation وهي عملية تكرارية تبدأ من الطبقة الأخيرة وتحسب الخطأ على الخرج عبر إيجاد الفرق الحاصل بين قيمته وقيمة الخرج المطلوب ثم نحاول تخفيض قيمة هذا الخطأ باستخدام خوارزمية التحسين Adam التي تجعل النموذج يتقارب بشكل أسرع من خلال حسابات خاصة بها وهي خوارزمية فعالة وتستهلك ذاكرة قليلة وتستخدم على نطاق واسع في تطبيقات التعلم العميق [13] وتم تحديد دالة

تم استخدام بعض النماذج المدربة مسبقاً وهي مجموعة من النماذج تم تدريبها بشكل مسبق على نطاق واسع جداً من مسائل تصنيف الصور ضمن قاعدة بيانات imagenet (وهي قاعدة بحثية ضخمة تضم أكثر من 14 مليون صورة تنتمي لأكثر من 20000 صنف) لذلك تميل هذه النماذج لتعلم مزايا تمييزية فاصلة للغاية لأنه تم تدريبها على عدد كبير من الصور وتطبيق تقنية نقل التعلم أي استخدام هذه النماذج من أجل حل مهام أو مسائل أخرى غير المهام التي تدربت عليها سابقاً بشكل نقطة بداية مفيدة جداً على اعتبار أنّ المزايا التي تم تعلمها أثناء التدريب على المهمة القديمة ستكون مفيدة للمهمة الجديدة، وذلك عن طريق استخدام الطبقات الالتفافية لهذه النماذج لاستخراج الخصائص ثم تدريب مصنف يعتمد على الخصائص المستخرجة، وكذلك تفيد في تقليل زمن التدريب [12].

تم اختيار خمسة من أكثر النماذج شهرة في مجال التعلم العميق حيث تعتمد جميع هذه النماذج على الشبكات الالتفافية وتختلف من حيث البنية وعدد الطبقات والمعاملات المطلوبة حيث سيتم دراسة خصائصها وتعديلها لتناسب المشكلة المدوسة وهي:

1- النموذج VGG16: يحتوي على 16 طبقة (ذات أوزان) 13 طبقة التفاضلية و3 طبقات اتصال كامل وما بينهما من طبقات تجميع وتبلغ مساحة تخزينها 533 ميغابايت تستخدم جميع الطبقات الالتفافية في هذا النموذج مرشحات (3×3) وحجم الخطوة 1 والمرشح الخاص بال (Pooling) هو 2 وبخطوة مقدارها 2 وطبقات الاتصال الكامل كل منها تحتوي 4096 عصبون وتابع تنشيط softmax.

2- النموذج VGG19: نفس بنية النموذج السابق لكن لديه عدد أكبر من الطبقات وهي 19 طبقة.

3- النموذج ResNet50: ويتألف من 50 طبقة وعلى الرغم من زيادة عدد الطبقات فيه مقارنة بالنموذج VGG16 إلا إن مساحته تبلغ 102 ميغابايت وذلك نظراً لاختلاف بنيته التركيبية، من خلال هذا النموذج تم إثبات إمكانية تدريب الشبكات الأكثر عمقاً حيث تم تجاوز عتبة التشعب في الدقة عند زيادة عدد الطبقات وذلك من خلال تقنية تسمى الكتلة المتبقية residual block وهي كتلة من طبقتين التفاضلتين لهما نفس عدد المرشحات حيث يضاف خرج الطبقة الثانية مع دخل الطبقة الأولى وبعدها يجمع دخل هذه الوحدة مع

الخسارة binary_crossentropy التي تقوم بحساب الخطأ وقياس الدقة accuracy لاختبار الأداء.

$$\text{Specificity} = \frac{\text{Number of true negative assessment}}{\text{Number of all negative assessment}} = \frac{TN}{TN+FP} \quad (6)$$

VI. تقييم النموذج وحساب الدقة:

يقوم النموذج بتصنيف الصور إلى صنفين Yes مصاب و No سليم وبعد بناء النموذج وتدريبه يتم اختباره على بيانات التحقق ثم يتم حساب مصفوفة الارتباك confusion matrix لكل نموذج حيث تحتوي هذه المصفوفة على عدد الحالات الإيجابية والسلبية الصحيحة والكاذبة ويرمز لها بالرموز True Positive (TP) و False Negative (FN) و False Positive (FP) و True Negative (TN)، يظهر الجدول (1) مصفوفة الارتباك.

جدول (1) مصفوفة confusion matrix

	Predicted (No)	Predicted (yes)
Actual (No)	TP	FN
Actual (yes)	FP	TN

وبناء على هذه الأرقام يتم حساب مجموعة من القيم التي تقيم أداء النموذج وهي

- **الدقة accuracy:** هي عدد الحالات التي تم تصنيفها بشكل صحيح على جميع الحالات [14] وتعطى بالمعادلة:

$$\text{Accuracy} = \frac{\text{Number of correct assessments}}{\text{Number of all assessments}} = \frac{TN+TP}{TN+TP+FN+FP} \quad (4)$$

- **الحساسية sensitivity:** تسمى أيضاً بالاسترجاع recall وهي مجموع الحالات الإيجابية المصنفة بشكل صحيح على جميع الحالات الإيجابية [14].

$$\text{Sensitivity} = \frac{\text{Number of true positive assessment}}{\text{Number of all positive assessment}} = \frac{TP}{TP+FN} \quad (5)$$

- **الخصوصية specificity:** هي مجموع الحالات السلبية المصنفة بشكل صحيح على جميع الحالات السلبية [14].

6- النتائج ومناقشتها:

يظهر الجدول (2) مقارنة بين قيم الدقة والخصوصية والحساسية للنماذج المستخدمة ويتم ملاحظة أن قيم الخصوصية جيدة بشكل عام أكثر من قيم الحساسية وذلك لأن أغلب الحالات التي تم تشخيصها بشكل خاطئ هي من فئة False Negative أي حالات سلبية كاذبة مثلاً الشخص غير مريض والنموذج تنبأ بأنه مريض وذلك بسبب وجود العديد من الهياكل في صورة الدماغ مثل السائل النخاعي والمادة الرمادية والمادة البيضاء وأنسجة الجمجمة بصرف النظر عن الورم.

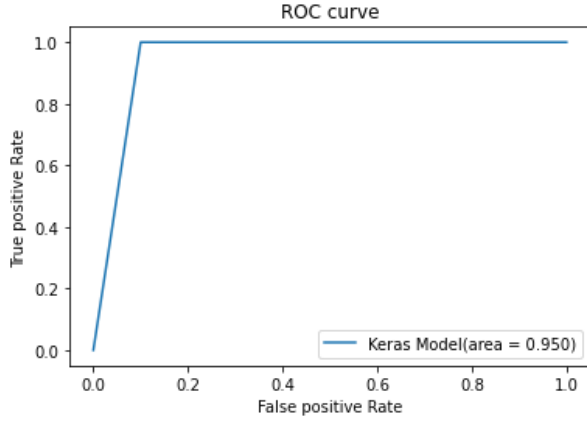
جدول (2) مقارنة بين قيم الدقة والخصوصية والحساسية للنماذج المستخدمة

	VGG16	VGG19	ResNet50	InceptionV3	Xception
Accuracy	82	84	85	88	90
Specificity	96	80	90	90	95
Sensitivity	58	89	80	84	85

وبشكل عام يظهر الجدول (2) أن الشبكات المكونة من وحدات التأسيس حققت دقة أفضل حيث تتكون هذه الوحدات من طبقات التفاضلية تقوم باستخراج الميزات أي أن هذا النموذج يشبه النماذج السابقة من حيث المضمون لكنه قادر على استخراج ميزات أكثر بعدد أقل من المعاملات والسبب في ذلك هو أن الطبقات الالتفاضلية تعمل في مساحة ثلاثية الأبعاد ذات بعدين مكانيين هما العرض والارتفاع والبعد الثالث هو القناة، وبالتالي تقوم نواة التفاضل واحدة بالتخطيط المتزامن للارتباطات عبر القنوات والارتباطات المكانية بينما تقوم وحدة التأسيس بجعل هذه العملية أسهل وأكثر كفاءة من خلال دمجها في سلسلة من العمليات التي تنظر بشكل مستقل في الارتباطات عبر القنوات والارتباطات المكانية، أي الفرضية الأساسية الكامنة وراء inception هي أن الارتباطات عبر القنوات والارتباطات المكانية مفصلة بشكل كافي، ثم تطورت هذه الفرضية إلى بنية شبكة التفاضلية تعتمد كلياً على طبقات التفاضل في العمق حيث يتم تعيين الارتباطات عبر القنوات والارتباطات المكانية بشكل منفصل تماماً ونظراً لأن هذه الفرضية هي نسخة أقوى من الفرضية السابقة يطلق عليها xception

يعرف المعدل الإيجابي الكاذب FPR باحتمال الإنذار الخاطئ[14]

$$FPR = \frac{FP}{TN+FP} = 1 - \text{Specificity} \quad (8)$$



شكل (10) مخطط ROC

تسمى المنطقة الواقعة تحت منحنى ROC بـ (AUC) مقياساً جيداً للأداء [14] حيث تقيس مدى جودة تنبؤات النموذج عبر جميع عتبات التصنيف الممكنة حيث أنه كلما كان منحنى ROC أقرب إلى الزاوية اليسرى العليا كان أداء المصنف أفضل وهي قيمة بين 0 و 1 وقد حصلنا على AUC=0.95.

بالنسبة لبيانات الاختبار وعددها 30 صورة تم الحصول على دقة 90% وهذا يعني أن الشبكة قد عممت بشكل جيد فعندما يتم تدريب شبكة عصبونية فإن أداء هذه الشبكة يتوقف على قابليتها على التعميم (generalization) [1] وهو مدى قدرة الشبكة على التعلم من البيانات المقدمة لها وتطبيق ما تعلمته على بيانات أخرى مختلفة أي قدرتها على معالجة بيانات جديدة لم تتدرَّب عليها من قبل .

8- نتائج البحث:

يعد التصنيف التلقائي لورم الدماغ مهمة صعبة للغاية بسبب التباين المكاني والبنوي الكبير للمنطقة المحيطة بورم الدماغ لكن أظهرت النتائج أن النموذج المقترح الذي يعتمد على معالجة الصورة ثم شبكات CNN باستخدام الضبط الدقيق لنموذج xception تقوم بالكشف عن ورم الدماغ بدقة وأداء عالي وهو أمر بالغ الأهمية لتقديم المساعدة للأطباء بسبب الاختلاف في مستويات الخبرة فيما بينهم في اتخاذ قرار طبي بنسبة خطأ قليلة.

والتي تعني Extreme Inception، وسيتم تطبيق تقنية الضبط الدقيق على هذا النموذج.

7- الضبط الدقيق Fine tuning:

يتم في هذه الطريقة تدريب بعض طبقات النموذج الأصلي بالإضافة إلى طبقات التصنيف المدروسة أي تدريب مُصنَّف يقوم بتعديل أوزان النماذج المدربة مسبقاً وهذا يجعل النموذج أكثر ملائمة للمهمة المطلوبة [12] حيث تم تجميد جميع طبقات النموذج ما عدا الطبقات الثلاث الأخيرة وبعد إجراء هذا الضبط الدقيق يتم حساب قيم الدقة والخصوصية والحساسية من مصفوفة confusion matrix في الجدول (3) والنتائج هي الدقة Acc=94% والخصوصية Sp= 96% والحساسية Se= 91%

جدول (3) مصفوفة confusion matrix للنموذج الأخير

	Predicted (No)	Predicted (yes)
Actual (No)	22	2
Actual (yes)	1	25

تحسنت الدقة عندما تم تدريب جزئي لبعض طبقات النموذج الأصلي حيث الطبقات الالتفافية الأولى من النموذج تستخلص الخصائص المحلية الأكثر عمومية مثل الحواف والألوان والشكل أما الطبقات الأكثر عمقاً في النموذج تستخلص الخصائص الأكثر خصوصية [12] أي أن درجة العمومية للخصائص في كل طبقة تعتمد على عمق الطبقة وموقعها بالنسبة إلى طبقات النموذج لذلك يتم استخدام الطبقات الأولى من النموذج لاستخلاص الخصائص الأكثر عمومية أما الطبقات الأعلى المدربة على الخصائص أو المزايا الأكثر خصوصية تحتاج إلى إعادة تدريب وضبط لملائمة المهمة المطلوبة.

تم رسم مخطط خاصة تشغيل المستقبل (ROC) receiver operating characteristic وهو مخطط بياني يوضح القدرة التشخيصية لنظام تصنيف ثنائي عن طريق رسم المعدل الإيجابي الحقيقي True Positive Rate (TPR) (المحور الشاقولي) مقابل المعدل الإيجابي الخاطئ False Positive Rate (FPR) (المحور الأفقي)، يظهر الشكل (10) هذا المخطط.

يعرف المعدل الإيجابي الحقيقي TPR أيضاً بالحساسية أو احتمال الاكتشاف [14]

$$TPR = \frac{TP}{TP+FN} = \text{Sensitivity} \quad (7)$$

9- مقارنة مع بعض الدراسات المرجعية:

يظهر الجدول (4) مقارنة مع دراستين حديثتين في العام 2020 وتستخدم نفس قاعدة البيانات المستخدمة في هذا البحث.

جدول (4) مقارنة مع بعض الدراسات المرجعية

الدراسة	منهجية الدراسة المرجعية	منهجية الدراسة الحالية
Convolutional Neural Network for Brain Tumor Detection[5]	بناء نموذجين بنيتين مختلفتين لشبكة CNN وحقق النموذج الثاني دقة 93%	الاستفادة من تقنية نقل التعلم والنماذج المدربة مسبقاً
Convolutional Neural Networks Model-based Brain Tumor Detection in Brain MRI Images[6]	استخدام نموذج VGG16 مع التعديل على طبقاته الأساسية باستبدال طبقة Pooling بـ Average Pooling وحقق دقة 96%	قامت هذه الدراسة باستخدام نماذج أخرى مختلفة والمقارنة بينها مع تدريب جزئي للنموذج والتعديل على طبقة التصنيف الأخيرة فقط

InceptionV3 وإنما بسبب استخدام أكثر كفاءة لهذه المعاملات.

يعد تصميم بنى مختلفة من الشبكات الالتفافية موضوع اهتمام كبير نظراً لأن اختيار البنية الصحيحة يعد من الصعوبات التي تواجه هذا النوع من الشبكات لذلك يُقترح دراسة مفصلة أكثر لهذه النماذج والتعديل على بنية طبقاتها الأساسية لكن تدريب شبكات مؤلفة من عشرات الطبقات من الصفر يحتاج إلى أجهزة حاسوبية بمراد كبيرة ووقت طويل يصل إلى أسابيع أو أشهر بالإضافة إلى قواعد بيانات كبيرة جداً حيث أن إيجاد المعاملات غير المعروفة لشبكات CNN بدقة يتطلب الكثير من البيانات ولا يوجد قواعد ومعايير ثابتة لإيجاد المعاملات وإنما تعتمد على طبيعة المشكلة ونوع البيانات وتعقيدها وغيرها.

11- الآفاق المستقبلية:

1. إمكانية تشخيص الحالة في مراحل مختلفة مثلاً المرحلة الأولى والثانية للورم ويتطلب ذلك وجود قواعد بيانات لكل مرحلة.
2. اختبار الخوارزمية على قواعد بيانات كبيرة وتطويرها لتناسب أجزاء أخرى من الجسم.
3. تطوير نظام طبي للكشف عن ورم الدماغ مع إمكانية إضافة مدخلات أخرى للشبكة غير الصورة مثل فحوصات عصبية معينة مما يساعد أكثر في الكشف عن الورم وتحديد مكان نشأته.

10- الاستنتاجات:

أظهرت النتائج أن شبكات CNN تعطي دقة عالية وهي خوارزمية منخفضة التعقيد لأنها لا تتطلب خطوات استخراج الميزات بشكل منفصل كما في الطرق الأخرى مثل خوارزميات التعلم الآلي أو الشبكات العصبونية التقليدية التي يتم فيها استخراج الميزات بشكل يدوي من خلال خوارزميات خاصة بل تقوم بها CNN بشكل تلقائي وبناءً على قيمة هذه الميزات يتم انشاء مخرجات التصنيف كما أن استخدام النماذج المدربة مسبقاً كنقطة بداية في عملية التدريب بدلاً من تدريب نماذج جديدة من الصفر يفيد في تقليل زمن التدريب والحصول على دقة أعلى، ويجب اختيار نموذج يتناسب مع طبيعة المشكلة المدروسة، فيعد مقارنة النماذج المستخدمة يمكن ملاحظة أن نموذج xception حقق أفضل نتيجة، وإن تفوق هذا النموذج على النماذج الأخرى ليس بسبب زيادة عدد الطبقات أو الحجم فهو يملك نفس عدد المعاملات لنموذج

12-المراجع:

- [1] Gad, Ahmed Fawzy(2018), *Practical Computer Vision Applications Using Deep Learning with CNNs*, No 10013, New York- the United States of America, Springer Science.
- [2] ARI, Ali; HANBA, Davut(2018), *Deep learning based brain tumor classification and detection system*, Turkish Journal of Electrical Engineering & Computer Sciences, Volume 26, pp 2275 – 2286.
- [3] Seetha, J.; Selvakumar Rajam, S.(2018). *Brain Tumor Classification Using Convolutional Neural Networks*, Biomedical & Pharmacology Journal, Volume 11(Number 3), pp 1457-1461.
- [4] Devkota, B.; Alsadoon, Abeer; Prasad, P.W.C.; Singh, A. K.; Elchouemi, A.(2018). *Image Segmentation for Early Stage Brain Tumor Detection using Mathematical Morphological Reconstruction*, ELSEVIER, Procedia Computer Science, Volume 125 (No 2018),pp 115–123.
- [5]Febrianto, D C; Soesanti, I; Nugroho, H A(2020), *Convolutional Neural Network for Brain Tumor Detection*, IOP Conf. Series: Materials Science and Engineering, Indonesia , Volume 771, <https://iopscience.iop.org/article/10.1088/1757-899X/771/1/012031>.
- [6]Siddique, Abu Bakr; Sakib, Shadman; Mahmudur Rahman Khan; Mohammad(2020), *Deep Convolutional Neural Networks Model-based Brain Tumor Detection in Brain MRI Images*, Institute of Electrical and Electronics Engineers(IEEE), International Conference on I-SMAC , India, <https://ieeexplore.ieee.org/document/9243461>.
- [7]Choudhury, Chirodip Lodh; Mahanty, Chandrakanta; Kumar, Raghvendra(2020), *Brain Tumor Detection and Classification Using Convolutional Neural Network and Deep Neural Network*, IEEE, 2020 International Conference on Computer Science, Engineering and Applications (ICCSEA), <https://ieeexplore.ieee.org/document/9132874>.
- [8] Shakeel, Mohamed; Tobely, Tarek; AL-feel, Haytham; Manogaran, Gunasekaran; Baskar, S.(2019), *Neural Network Based Brain Tumor Detection Using Wireless Infrared Imaging Sensor*, IEEE, Volume 7(N 2019),pp 5577-5588.
- [9] Lotter, William; Diab, Abdul Rahman; Haslam, Bryan; Kim, Jiye G; Grisot, Giorgia(2019),*Robust breast cancer tomosynthesis using annotation-efficient deep learning approach*, arXiv, volume 2(IV),pp 1-16.
- [10] Sharma, Pratibha; Diwakar, Manoj; Choudhary, Sangam(2012), *Application of Edge Detection for Brain Tumor Detection*, International Journal of Computer Applications, Volume 58(No.16),pp 21-25.
- [11] Kraman, Samir; Al-Shikha, Sobhi(2018), *A comparison of Image Enhancement Techniques for Recognizing and Classifying Automatically the Medical Images and implement on MRI brain Image*, Tishreen University Journal for Research and Scientific Studies - Engineering Sciences Series, Volume 4(Number 3),pp 333-348.
- [12] Chollet, François(2018), *Deep Learning with Python*, No 11964 ,New york- the United States of America,Manning Publications.
- [13] Kingma, Diederik P; Lei Ba, Jimmy(2017), *ADAM: A method for stochastic optimization*, arxiv,v 9(cs.lg),pp 1-15.
- [14] Stralen, Karlijn J. van; Stel, Vianda S; Reitsma, Johannes; Dekker, Friedo; Zoccali, Carmine; Jager, Kitty (2009), *Diagnostic methods I: sensitivity, specificity, and other measures of accuracy*, Kidney International,V 75,pp 1257–1263.