

Brain Tumor Detection in MRI using Convolutional Neural Network

Daed Youssef Alkohdy*

(Received 31 / 3 / 2022. Accepted 30 / 10 / 2022)

□ ABSTRACT □

Today, the medical world is living with an enormous amount of DATA information, which has arisen from the womb of laboratory tests and clinical observations. As clinicians began to shift in clinical practice from accidental analysis and reliance on the accuracy of their observation to the analysis of various data and structured algorithms, relying on continuously updated sets of data, therefore doctors who learn Artificial Intelligence will have ability to improve detecting disease.

The machine learning algorithm was able to obtain a final result in the classification of medical images by convolutional neural networks. In this research, magnetic resonance images of human brain were collected to search for human tumors. we applied appropriate stages to process this image as a first step, and then used deep convolutional neural networks to extract best features from these processed images and classify them. we designed two different models by structure. Then, we trained two models and studied operands of each model loss, accuracy, f-score by Python language, and got accuracy 90% for first model and 69% for second model.

Keywords: brain tumors, magnetic resonance imaging, convolutional neural networks, inception v3 networks, deep learning.

* Academic Assistant, Department of computer & control Engineering, Faculty of Mechanical & Electrical Engineering, Tishreen University, Latakia, SYRIA Daedalkody90@gmail.com

كشف أورام الدماغ في صور الرنين المغناطيسي باستخدام الشبكات العصبية الالتفافية

دعد يوسف الكعدي*

(تاريخ الإيداع 31 / 3 / 2022. قُبِلَ للنشر في 30 / 10 / 2022)

□ ملخص □

يتعايش العالم الطبي اليوم مع كمية هائلة من المعلومات، والتي نشأت من رحم الفحوصات المخبرية والمراقبات السريرية. حيث بدأ الأطباء بالتحول في الممارسة السريرية من التحليل العرضي ودقة الملاحظة لديهم إلى تحليل بيانات مختلفة وخوارزميات منمّمة، تعتمد على مجموعات من البيانات المحدثة باستمرار، لذلك سيكون للأطباء الذين يتعلمون الذكاء الصناعي القدرة على تحسين إمكانية تشخيص المرض.

إن خوارزمية التعلم الآلي التي حققت نتيجة نهائية جوهريّة في تصنيف الصور الطبية هي الشبكة العصبية الالتفافية (CNN) convolutional neural networks. في هذا البحث تم جمع صور الرنين المغناطيسي Magnetic Resonance Imaging (MRI) الخاصة بالدماغ البشري بهدف كشف الأورام الدماغية حيث تم تطبيق عمليات مناسبة لمعالجة الصور المجمعّة كخطوة أولى، ومن ثم استخدام الشبكات العصبية الالتفافية العميقة لاستخلاص أفضل السمات من هذه الصور المعالجة، وفق نموذجين مقترحين مختلفين من حيث البنية ومن ثم تدريب النموذجين وتحليل أداء كل نموذج بدراسة المعاملات (loss, accuracy, f-score) حيث تم استخدام لغة البرمجة بايثون Python والوصول إلى دقة تعرف 90% بالنسبة للنموذج الأول و 69% بالنسبة للنموذج الثاني.

الكلمات المفتاحية: أورام الدماغ، صور الرنين المغناطيسي، الشبكات العصبية الالتفافية، شبكات inception v3، التعلم العميق.

* قائم بالأعمال - قسم هندسة الحاسبات والتحكم الآلي - كلية الهندسة الميكانيكية والكهربائية - جامعة تشرين - اللاذقية - سورية.
Daedalkody90@gmail.com

مقدمة:

ورم الدماغ هو كتلة أو نمو غير طبيعي للخلايا في الدماغ. يمكن أن تكون أورام الدماغ سرطانية (خبيثة) أو غير سرطانية (حميدة)، من أفضل الأساليب التي يتم الاعتماد عليها في تشخيص الأورام على اختلاف أنواعها، هي صور الرنين المغناطيسي (MRI). حيث تعتبر من أسس الطرق وأكثرها مرونة في المجال الطبي. وغالباً ما يتم الاعتماد على تحليل صور الرنين المغناطيسي للدماغ للوصول إلى تشخيص نهائي، حيث يوجد أربع أنواع لتحليل الصور وهي:

T1-Weighted -1

T2-Weighted -2

Post-Contrast T1-Weighted -3

Fluid-Attenuated Inversion –Recovery (FLAIR) -4

حيث تستخدم هذه الطرق لمهام التشخيص المختلفة الخاصة بالتشخيص والعلاج السريري، والتي غالباً ما تعطي نتائج إيجابية. ومع ذلك تُعتبر مهمة تشخيص الأطباء للمصابين بالأورام عن طريق صور الرنين المغناطيسي مهمة شاقة، وذلك لوجود تباين كبير في الحجم والشكل والانتظام والموقع والمظهر غير المتجانس لأورام الدماغ. لذلك هناك حاجة ماسة إلى إجراء تحليل كمي تلقائي وتقسيم دقيق لصور أورام الدماغ سريرياً، لمساعدة الأطباء على إجراء تشخيصات دقيقة.

أهمية البحث وأهدافه:

تتضمن أهداف البحث بما يلي:

- التعرف على مرض ورم الدماغ بسهولة وفعالية وتقليل أعباء عمل الأطباء في المجال الطبي.
- اقتراح نموذجين مختلفين لتقنية التعلم العميق للتعرف على ورم الدماغ.
- يمكن تحويل البحث في مراحل متقدمة إلى تطبيق قابل للتنفيذ مباشرة في المشافي دون الحاجة إلى توافر بيئة محددة لتشغيله.

طرائق البحث ومواده:**1- الشبكات العصبية الالتفافية (CNN) Convolutional Neural Networks:**

تعتبر الشبكات العصبية الالتفافية (CNN) من الوسائل والتقنيات الشائعة لمعالجة الصورة في مجال التعلم العميق، حيث تم استخدامها في حل العديد من المشاكل المختلفة في مجال معالجة الصورة وسبب نجاح هذه الشبكة يعود إلى قدرتها العالية على تعلم واستخراج صفات وميزات دقيقة وعميقة من الصور بدلاً من الاعتماد على صفات مستخرجة يدوياً، وهذا ما يجعلها في مقدّمة الأساليب المرنة والسريعة والناجحة في مجال معالجة الصورة.

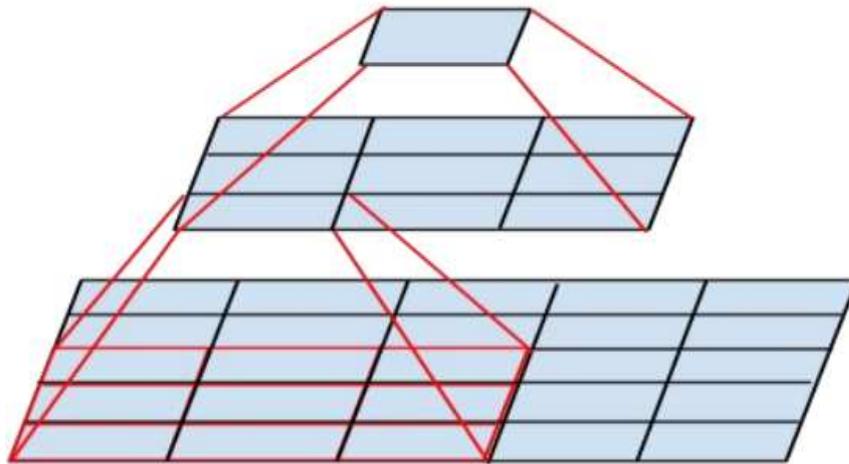
مع التطورات الملحوظة في مجال الذكاء الصناعي ومع تزايد قوة القدرات الحاسوبية، بالإضافة إلى الأعداد الكبيرة من الأبحاث العلمية في هذا المجال، كان تطوير الشبكات العصبونية الالتفافية CNNs كبيراً وملحوظاً.

كل هذه الشبكات والدراسات جعلت استخدام الشبكات العصبونية وتفعيلها في مجال معالجة الصور الطبيّة ممكناً، حيث ان الأبحاث الحديثة أثبتت أن شبكات CNN تتفوق على أساليب تحليل الصور الطبية التقليدية في المشافي، لأن عملية تقطيع صور الرنين المغناطيسي تُعتبر مهمة حساسة وتطلب دقة واهتماماً واسع النطاق وخاصة أن أساليب التقطيع لصور الرنين المغناطيسي الخاصة بالدماغ متنوعة.

1-1 شبكة inception v3 [5]:

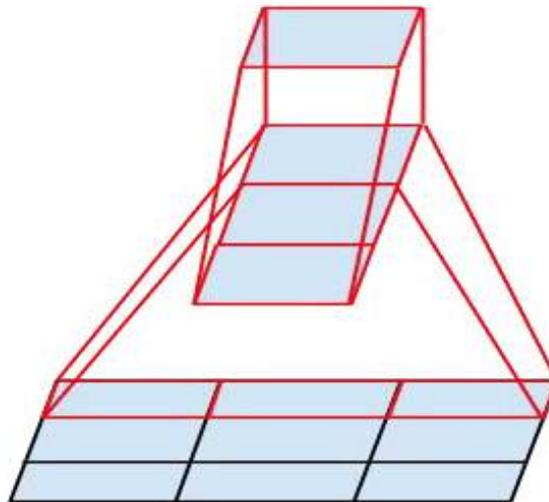
هي نموذج للتعرف على الصور شائع الاستخدام والذي أثبت أنه يحقق دقة تزيد عن 78.1% على مجموعة بيانات ImageNet. هذا النموذج هو نتويز للعديد من الأفكار التي طورها العديد من الباحثين على مر السنين، ويمتلك قدرات حسابية هائلة من الممكن استغلالها في مهام ومشاريع متنوعة، تتكون شبكة inception v3 من بنى كثرية موزعة كالتالي: Factorized Convolution-1: تقلل عدد العمليات الحسابية المطبقة على الدخل، وذلك عن طريق تقليل عدد المتحولات المستخدمة في الشبكة.

Smaller Convolution-2: كخطوة ثانية لتقليل عدد المتحولات الخاصة بأي شبكة عصبية، يمكننا استخدام بنى الالتفافية ذات نوى صغيرة الحجم. كأن نستخدم نواة 3×3 التي تنتج 9 متحولات بدلاً من نواة 5×5 التي تنتج 25 متحول. وهذا التغيير البسيط سيسرع التدريب بشكل ملحوظ. كما هو موضح بالشكل (1):



الشكل (1) تدرج الطبقات الالتفافية لتقليل المتحولات. [5]

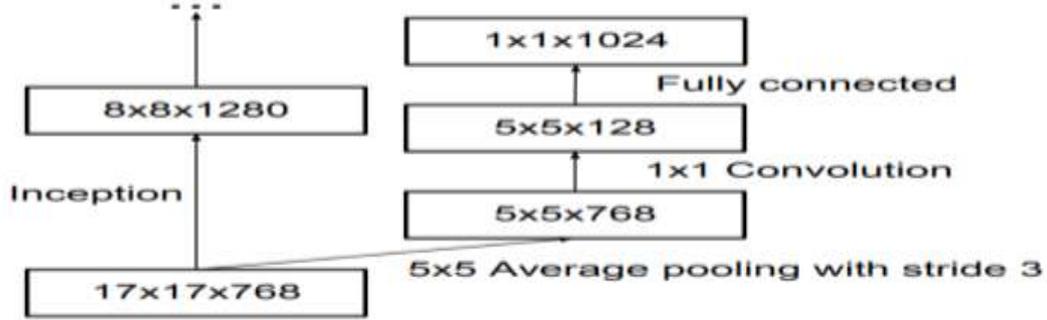
3- الالتفافات غير المتناظرة Asymmetric convolutions: يتم استبدال الطبقة الالتفافية ذات القياس 3×3 بطبقتين الالتفائيتين متتاليتين الأولى بقياس 3×1 ، والأخرى بقياس 1×3 ، كما هو موضح بالشكل (2).



الشكل (2) الالتفافات غير المتناظرة [5]

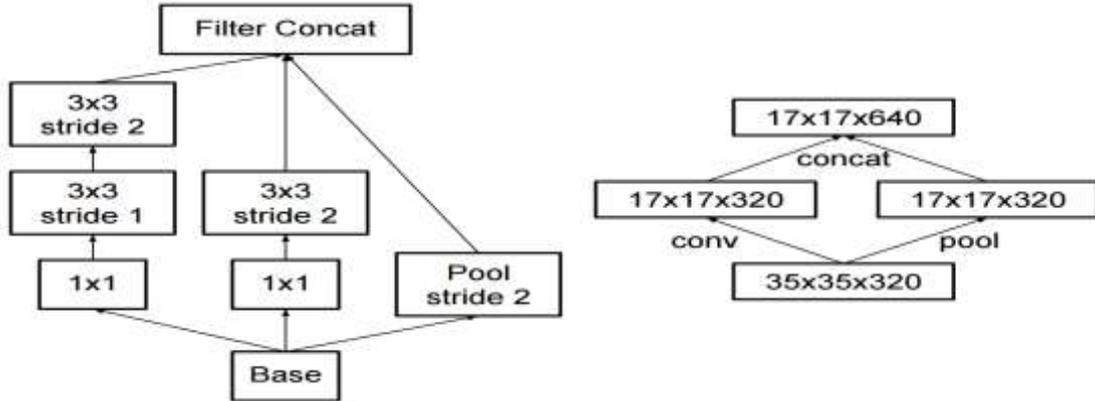
4-مصنف مساعد Auxiliary Classifier:

إحدى ميزات شبكة Inception v3 هو احتوائها على مصنف مساعد عبارة عن شبكة عصبونية الالتفافية صغيرة. تعمل أثناء التدريب regularizer كما هو مبين بالشكل (3).



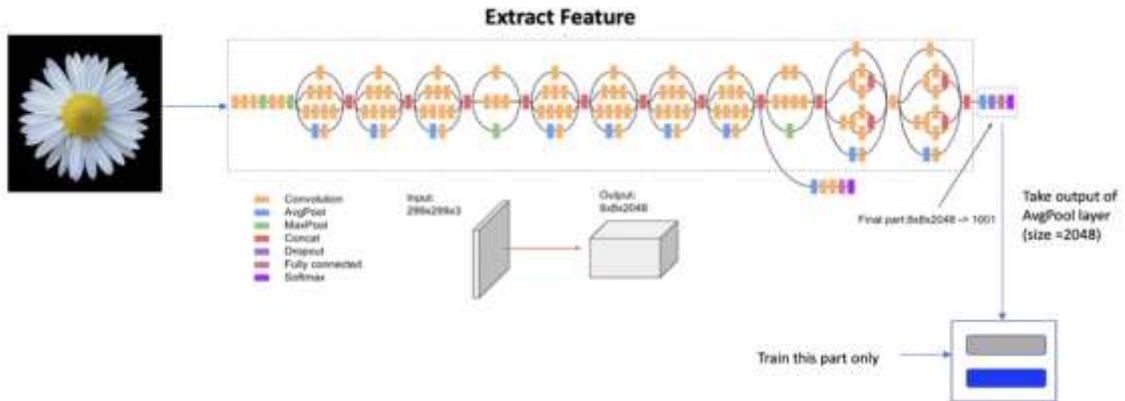
الشكل (3) المصنفات المساعدة [5]

5-Grid Size Reduction تقليل حجم الشبكة: عادة ما يتم تقليل حجم الشبكة عن طريق عمليات Pooling، إلا أنها حسابياً مكلفة جداً، لذلك تم اقتراح نموذج من أكثر. يبين الشكل (4) إحدى الطرق المكافئة لعملية Pooling.



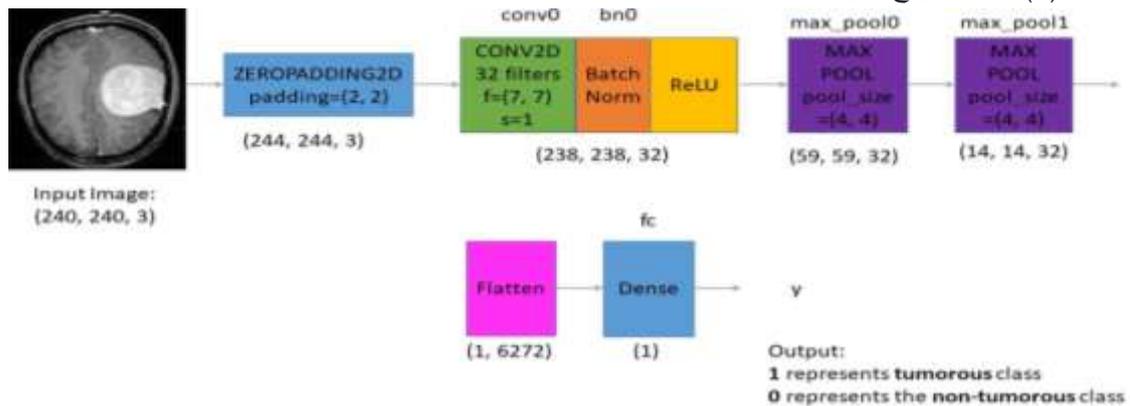
الشكل (4) نموذج بديل عن عمليات Pooling [5]

يتكون النموذج نفسه من كتل بناء متناظرة وغير متناظرة، بما في ذلك convolutions, average pooling max pooling, concatenations, dropouts, and fully connected layers كما هو موضح في الشكل (5):



الشكل (5) بنية شبكة Inception v3 [5]

- بناء على ما سبق وبعد دراسة العديد من المقالات [3][5][6][7] تم بناء نموذجين مختلفين لشبكة عصبية التلافيفية عميقة. النموذج الأول بسيط في بنيته ولا يعتمد على طريقة نقل التعلم حيث تم تدريبه من الصفر وله البنية البسيطة التالية:
- 1-Zero Padding layer: تقوم هذه الطبقة بوضع حشوة صفرية حول الصورة بقياس 2×2 من أجل ضمان مسح الصورة بشكل كامل مع حوافها.
 - 2-convolutional layer: طبقة التلافيفية تحتوي على 32 فلتر وكل منها بحجم 7×7 ، تقوم بمسح كامل الصورة بخطوة مقدارها 1.
 - 3-batch normalization layer: هذه الطبقة تقوم بعملية normalization لقيم بكسلات الصورة وهذا يسرع التدريب أكثر فأكثر من ناحية الحسابات.
 - 4-ReLU activation layer: يتم تطبيق تابع التفعيل ReLU في هذه الطبقة.
 - 5- Max Pooling layers : عبارة عن طبقتين متتاليتين ذات نواة 4×4 ، لتخفيض الحجم الكلي للصورة.
 - 6-Flatten: تقوم هذه الطبقة بتحويل المصفوفة الثنائية الخاصة بالصورة إلى شعاع من أجل إدخالها إلى طبقة Dense التي تليها.
 - 7-Dense: تمثل الطبقة الأخيرة في الشبكة المعطاة، وتقوم بعملية التصنيف الثنائي على أساس تابع Sigmoid.
- يبين الشكل (6) بنية النموذج الأول.

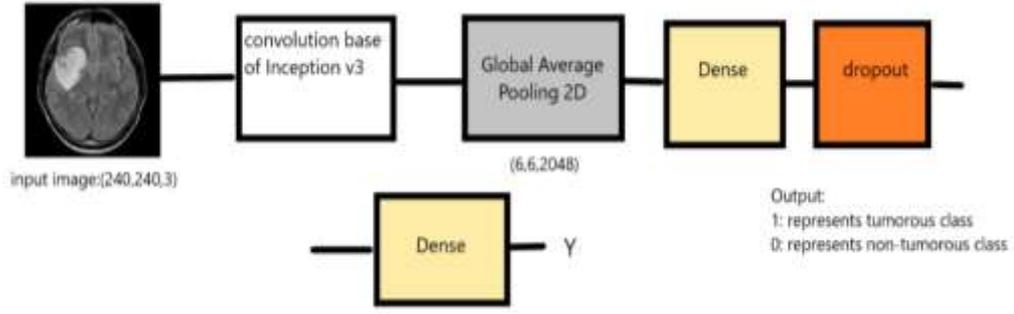


الشكل (6) بنية النموذج الأول

أما النموذج الثاني فهو يعتمد على طريقة استخراج الميزات حيث سيتم استخدام شبكة معروفة كمستخرج للميزات من الدخل ومن ثم سحب هذه الميزات لتطبيق على مصنف من اختيارنا في بحثنا سنعتمد على القاعدة الالتفافية convolution base من شبكة Inception v3، المدربة على استخراج كم هائل من الصفات الدقيقة مضافاً عليها بالترتيب من اليسار الى اليمين:

Global Average Pooling2D Layer, fully connected layer (Dense), Dropout, fully connected layer (Dense)

يبين الشكل (7) بنية النموذج الثاني.



الشكل (7) بنية النموذج الثاني

وتم تطبيق النموذجين السابقين باعتماد حواسيب بإمكانيات معالجة عالية لا تقل عن core-i5, 8 RAM.

3-2 تطبيع الحزمة batch normalization [8]:

يعد تدريب الشبكات العصبية العميقة مع عشرات الطبقات أمراً صعباً حيث يمكن أن تكون حساسة للأوزان العشوائية الأولية وتكوين خوارزمية التعلم، أحد الأسباب المحتملة لهذه الصعوبة هو أن توزيع المدخلات على طبقات عميقة في الشبكة قد يتغير بعد كل دفعة صغيرة عند تحديث الأوزان. يمكن أن يسبب هذا في قيام خوارزمية التعلم بمطاردة هدف متحرك إلى الأبد. يشار إلى هذا التغيير في توزيع المدخلات على الطبقات في الشبكة إلى الاسم internal covariate shift. تطبيع الحزمة هو أسلوب لتدريب الشبكات العصبية العميقة جداً التي تقوم بتوحيد المدخلات إلى طبقة لكل دفعة صغيرة. هذا له تأثير في تثبيت عملية التعلم وتقليل عدد فترات التدريب المطلوبة بشكل كبير لتدريب الشبكات العميقة.

3-3 مقاييس الأداء Performance Measurement [9]:

• **الدقة Accuracy:** هي عدد التنبؤات الصحيحة التي قام بها النموذج على عدد التنبؤات الكلي التي تم إجراؤها وتعد الدقة مقياساً جيداً عندما يكون عدد البيانات في الأصناف المدروسة متوازناً تقريباً ويتم حسابها بالعلاقة التالية:

$$Acc = \frac{Tp + Tn}{Tp + Tn + Fp + Fn}$$

• **الحساسية (sensitivity/recall):** تعرف بأنها نسبة عدد التوقعات الإيجابية الصحيحة ، وهي توضح قدرة النموذج على تجنب وضع الـ (1) سلبية على أنها إيجابية ويشير هذا المقياس إلى قدرة تحديد المرضى بشكل صحيح ويتم حسابها بالعلاقة:

$$Sen = \frac{Tp}{Tp + Fn} \quad (2)$$

• **النوعية (The specificity (precision):** يتم تعريفها على أنها نسبة السلبيات الفعلية التي تم توقعها على أنها سلبية (سلبية حقيقية). يشير هذا المقياس إلى قدرة الاختبار على تحديد الأشخاص غير المصابين بالمرض بشكل صحيح ويتم حسابها بالعلاقة التالية:

$$spec = \frac{Tn}{Tn + Fp}$$

• **Score (3):** مع بين الخصوصية والحساسية معاً في مقياس أكثر إيجازاً ، هو مقياس لدقة النموذج في مجموعة البيانات. يتم استخدامه لتقييم أنظمة التصنيف الثنائية، والتي تصنف الأمثلة إلى موجبة أو سلبية ويتم تعريفها أيضاً على أنها المتوسط التوافقي لحساسية النموذج وخصوصيته.

$$F_score = 2 * \frac{(sensitivity * specificity)}{sensitivity + specificity} \quad (4)$$

وهو ما سنعتمد عليه في بحثنا من أجل الحصول على أكبر عدد من التشخيصات الصحيحة.

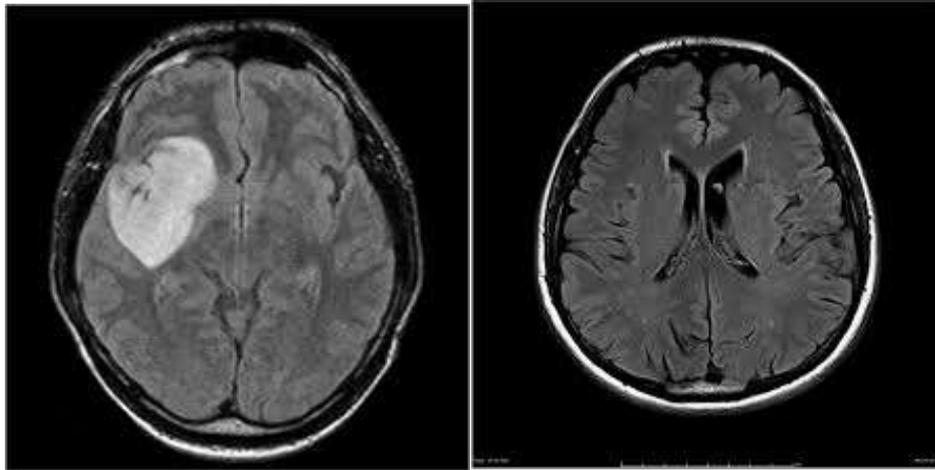
النتائج والمناقشة:

تم العمل وفق المراحل الآتية:

- تجميع البيانات dataset.
- مرحلة المعالجة الأولية preprocessing.
- مرحلة التدريب training.
- مرحلة الاختبار والتقييم. testing and evaluation.

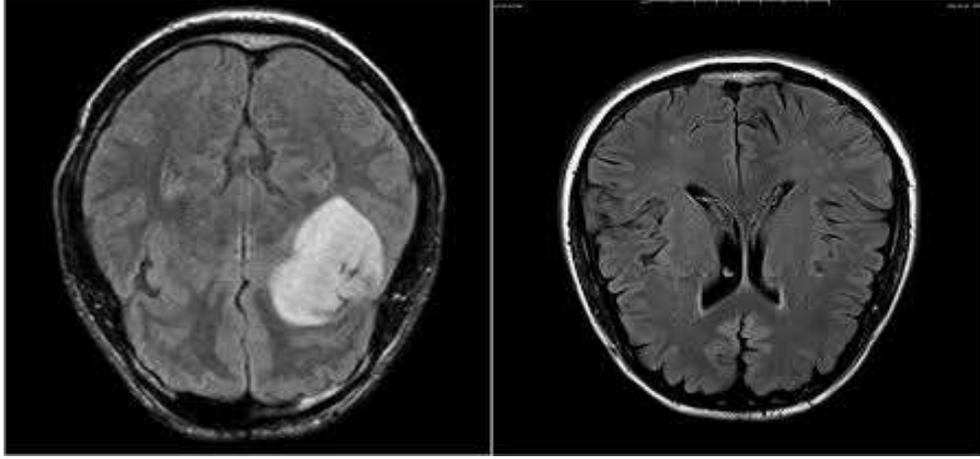
1- تجميع البيانات dataset:

سنعتمد في هذا البحث على dataset مكونة من 253 صورة شعاعية للدماغ، تضم 155 عينة مشخصة كحالات ورم و98 عينة سليمة. حيث تم اعتماد هذه البيانات من الموقع الشهير Kaggle. يوضح الشكل (8) نموذج عن هذه البيانات، حيث أن الصورة اليسارية عبارة عن عينة مصابة، بينما الصورة اليمينية عينة سليمة.



الشكل (8) نموذج عن البيانات المستخدمة.

نظراً لصغر حجم البيانات وعدم كفايتها للبحث كعينات تسمح باستخراج المعلومات المهمة واللازمة لتعميم التشخيص، فقد قمنا بعملية توليد Data Augmentation من البيانات الأصلية من أجل زيادة عدد العينات اللازمة للبحث، ليصبح عددها 1755 عينة، تضم 930 عينة مصابة و825 عينة سليمة، حيث تم زيادة عينات معدلة عن العينات الأصلية عن طريق تطبيق استدارة يمينية ويسارية وعملية تكبير وعمليات تعديل إضاءة وعمليات قلب أفقية وشاقولية للصور. يبين الشكل (9) العينات المعروضة في الشكل (8) بعد تطبيق عملية augmentation عليها.



الشكل (9) نموذج عن البيانات الناتجة عن عملية augmentation.

وتم الحصول على 310 عينة من مشفى تشرين الجامعي تضم 155 عينة مصابة و155 عينة سليمة سيتم اعتمادها لاحقاً في عملية الاختبار ليصبح عدد العينات الكلي 2065 عينة، تضم 1085 عينة مصابة و980 عينة سليمة.

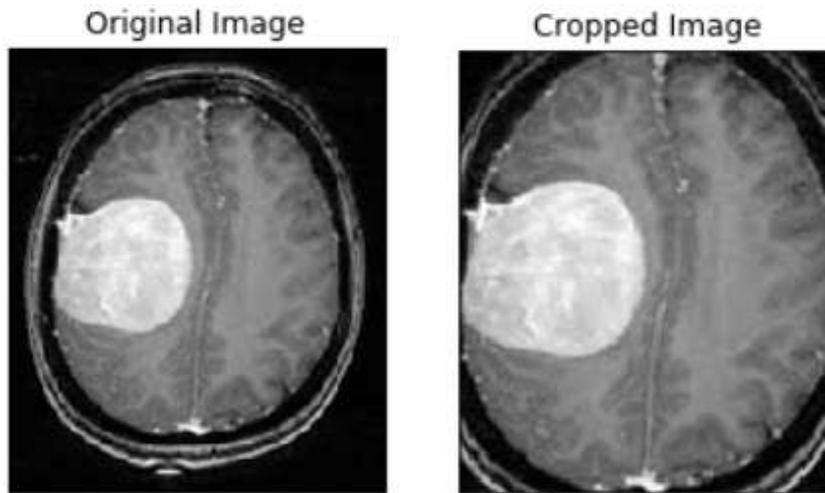
2- مرحلة المعالجة الأولية preprocessing:

تعد هذه المرحلة من أهم المراحل التي تسبق عملية التدريب، وتساهم بشكل كبير في اختيار العوامل التي سنعتمد عليها كمعايير للتصنيف. في هذا البحث سنعتمد على مكتبة opencv الخاصة بمجال الرؤية الحاسوبية [1] ، من أجل معالجة الصور الشعاعية قبل إدخالها إلى المرحلة التالية تضمنت عملية المعالجة مجموعة من المراحل وهي:

- مرحلة تعديل الألوان: تشتمل هذه المرحلة على خطوة وحيدة وهي تحويل الصورة من RGB إلى Gray.
 - مرحلة إزالة الضجيج: نقوم في هذه الخطوة بإزالة الضجيج الغوسي Gaussian Noise من الصورة من أجل ضمان الحصول على صورة خالية من الشوائب للاعتماد عليها أثناء التدريب والاختبار.
 - مرحلة تقييس الصورة بالاعتماد على العتبة: هنا سنعتمد على العتبة ذات القيمة 255، وذلك للحصول على صورة ثنائية بالأبيض والأسود، وهذا يساعدنا في تبسيط التعامل مع البيانات واختصار الصفات التي لسنا بحاجة لها ومنها الألوان وطبقاتها، بالإضافة إلى قدرتنا على تطبيق عمليات لاحقة كالمعاملات المورفولوجية morphological operations التي لا يمكن تطبيقها إلا على الصور الثنائية.
 - مرحلة التحويلات المورفولوجية: تتضمن هذه المرحلة خطوتين أساسيتين وهما Erosion and Dilation وهاتان الخطوتان ضروريتان من أجل التخلص من الضجيج بشكل نهائي من الصورة، على الرغم من أننا قمنا بإزالة معظمه في المرحلة الثانية "إزالة الضجيج"، إلا أن الصورة لا زالت تحوي ضجيج صغير يمكنه التأثير سلباً على التصنيف أثناء التدريب، وخاصة في الصور الشعاعية التي تحتوي على أورام ذات حجم صغير جداً.
- يقوم erosion بتحديد حواف الأغراض في الصورة بشكل أدق، أي يحذف الضجيج الصغير. وسنستخدم نواة ذات قياس 5X5، سنقوم بمسح الصورة بشكل كامل وتعويض قيمة 1 في حال كانت جميع قيم البكسلات التي تغطيها النواة 1، وقيمة 0 في حال وجود قيمة واحدة صفرية تغطيها النواة. ومن الطبيعي أن يتقلص حجم الأغراض في الصور بعد هذه العملية، كوننا اقتطعنا جزء منها أثناء تحديد حوافها، لذلك نحن بحاجة لعملية dilation المرافقة للعملية السابقة في تقوم بإعادة الأغراض في الصورة إلى حجمها الطبيعي طالما أننا أزلنا الضجيج بشكل كامل من الصورة. حيث سنعتمد على نفس نواة

العملية السابقة 5X5. في هذا العملية يكفي وجود بكسل واحد ذو قيمة 1 من البكسلات التي تغطيها النواة أثناء مسح الصورة حتى تكون النتيجة 1، وهذا ما يفسر زيادة حجم الأغراض بعد تطبيق هذه العملية.

- مرحلة تحديد الحواف: في هذه المرحلة يتم ببساطة رسم منحني لمجموعة النقاط المتتالية والمستمرة والتي تمتلك نفس الكثافة اللونية، أي باختصار سنحصل على حدود كل الأغراض الموجودة في الصورة وهذا سيساعدنا باختصار مجال البحث وتقليصه ضمن القسم الأهم في الصورة الشعاعية وهو الدماغ وبالتالي تحديد أكبر إطار في الصور أي أكبر غرض فيها.
- مرحلة اقتطاع أكبر غرض في الصورة: سنعتمد على ما يُسمى extreme points، والتي ستساعدنا على معرفة امتداد الغرض الذي قمنا بتحديد حوافه لنتمكن من اقتطاعه من الصورة، وذلك من خلال تحديد أقصى نقطة يسارية وأقصى نقطة يمينية وأقصى نقطة علوية وأقصى نقطة سفلية للغرض الأكبر في الصورة وهو الدماغ، وسيكون الناتج النهائي لكل العمليات السابقة كما هو موضح بالشكل (10).



الشكل (10) مرحلة المعالجة الأولية

- مرحلة تحجيم وتقييس الصور resizing and normalization: بعد الانتهاء من مرحلة المعالجة الأولية للصور الدماغية ننتقل إلى مرحلة توحيد قياسها إلى القياس 240X240. تليها عملية ضبط قيم الصورة ضمن المجال [0,1]. وهذه العمليات ضرورية جداً قبل الانتقال إلى مرحلة التدريب من أجل توحيد الصفات العامة للصور والتعامل مع صور تمتلك نفس المجال اللوني ونفس القياس.

3- مرحلة التدريب Training:

سيتم تطبيق النموذجين المقترحين سابقاً على مجموعة البيانات بعد تقسيمها إلى 70% عينة للتدريب، 15% عينة للتحقق، و15% عينة للاختبار أي 1445 عينة تدريب من أصل 2065 عينة، و310 عينة للتحقق، و310 عينة للاختبار وسيتم اعتماد قياس موحد لكل العينات وهو 240*240. سيتم اعتماد Adam Optimizer من أجل عملية التدريب العميق، بالإضافة إلى استخدام تابع entropy cross من أجل حساب قيمة الخطأ عند كل دورة تدريبية واستخدامها في عملية الانتشار الخلفي من أجل تحسين التدريب [1].

3-1 تدريب النموذج الأول:

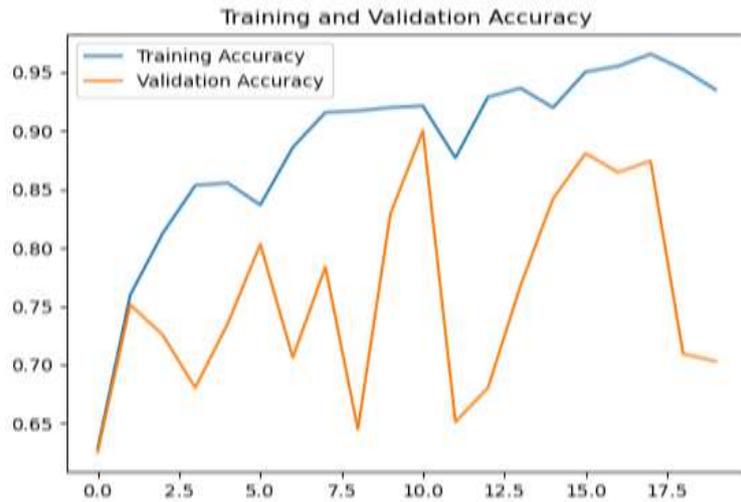
تم التدريب والتحقق على 20 دفعة متتالية في نفس الوقت كطريقة أولى للتدريب، وكانت النتائج كالآتي:

من أجل 20 دفعة تدريب متواصلة ومنتالية، كانت الخسارة الخاصة بالتدريب 0.14. بينما كانت خسارة التحقق 1.12 كما هو موضح في الشكل (11) حيث نلاحظ أن الخسارة في التدريب تتناقص بشكل جيد بينما الخسارة في التحقق تتغير بشدة وبشكل كبير.



الشكل (11) خسارة التدريب والتحقق Training and Validation Loss من أجل 20 دفعة تدريب متواصلة

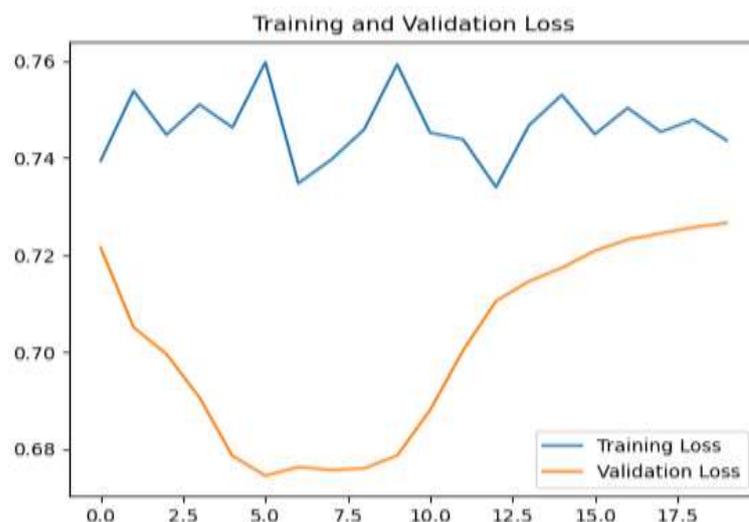
من أجل 20 دفعة تدريب متواصلة ومنتالية، كانت دقة التدريب 94%، بينما كانت دقة التحقق 69% حيث تم حساب كل منها وفق العلاقة (1)، كما هو موضح في الشكل (12).



الشكل (12) دقة التدريب والتحقق Training and Validation Accuracy من أجل 20 دفعة تدريب متواصلة

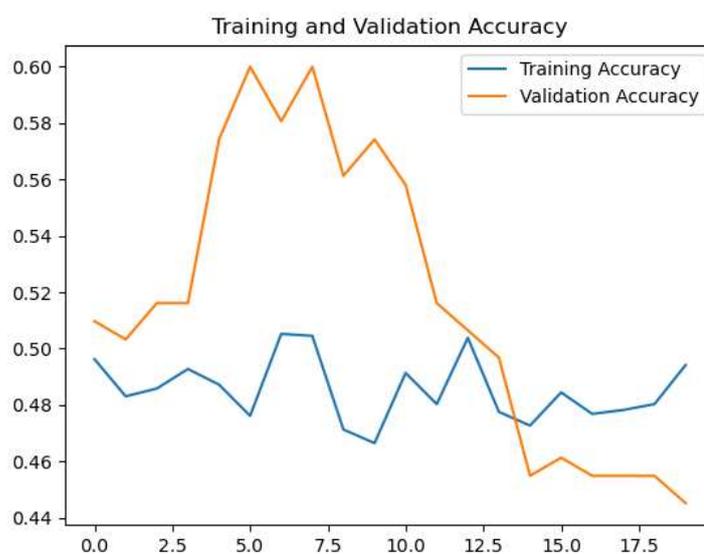
4-3-2 تدريب النموذج الثاني:

تم التدريب والتحقق على 20 دفعة تدريب متواصلة وكانت النتائج كما يوضح الشكل (13):
من أجل 20 دفعة تدريب متواصلة ومنتالية، كانت الخسارة الخاصة بالتدريب 0.74. بينما كانت خسارة التحقق 0.72. نلاحظ أن خسارة التدريب تتأرجح ضمن مستوى محدد كما هو موضح في الشكل (13).



الشكل (13) خسارة التدريب والتحقق

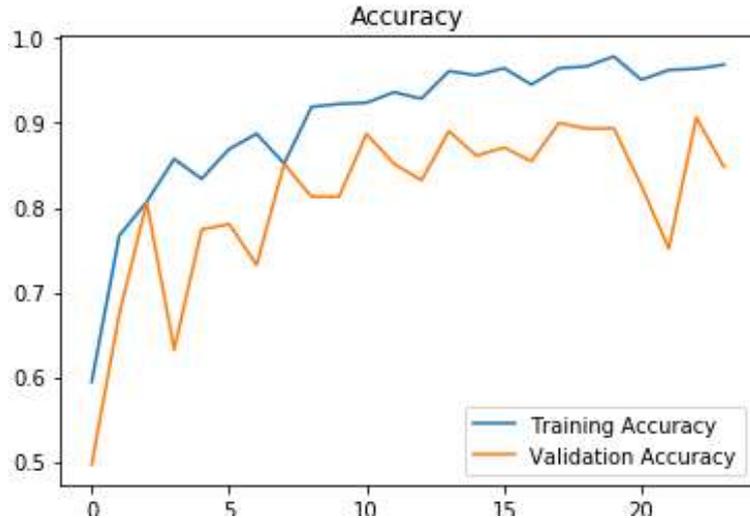
من أجل 20 دفعة تدريب متواصلة ومتتالية، كانت دقة التدريب 50%، بينما كانت دقة التحقق 45%، كما هو موضح في الشكل (14).



الشكل (14) دقة التدريب والتحقق

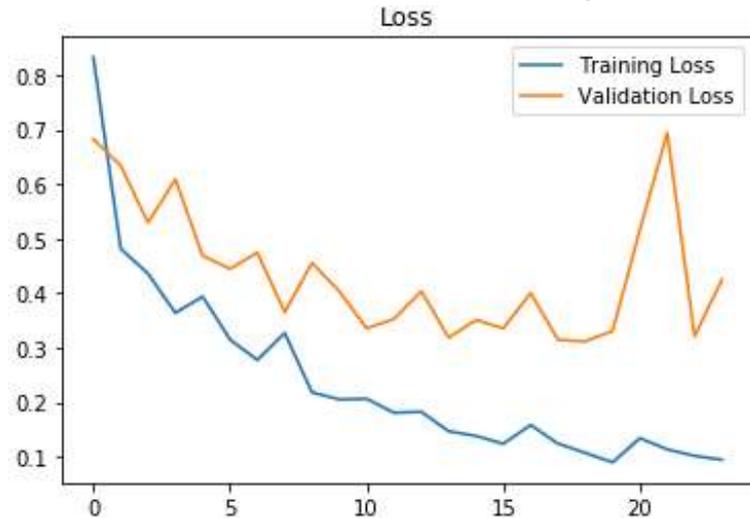
3-3- إعادة تدريب النموذج الأول باستخدام تطبيع الحزم:

تم التدريب والتحقق على 24 دفعة حيث جربنا تقسيم هذه الدفعات إلى دفعات جزئية كالتالي (10، 3، 3، 3، 5) والتدريب والتحقق على كل واحدة منها بشكل مستقل عن الدفعات الأخرى كطريقة ثانية للتدريب، فكانت النتائج: من أجل 24 دفعة مقسمة إلى 5 مجموعات جزئية (10، 3، 3، 3، 5) كانت دقة التدريب 97%، بينما كانت دقة التحقق 87% كما هو موضح بالشكل (15).



الشكل (15) دقة التدريب والتحقق Training and Validation Accuracy من أجل 24 دفعة تدريب منفصلة

من أجل 24 دفعة مقسمة إلى 5 مجموعات جزئية (10، 3، 3، 3، 5) كانت خسارة التدريب 0.1، بينما كانت خسارة التحقق 0.43، حيث نلاحظ أن منحنى خسارة التدريب والفقد يتناقصان بشكل متقارب وهذه إشارة أن التدريب جيد وسيعطي دقة اختبار جيدة كما هو موضح بالشكل (16).



الشكل (16) خسارة التدريب والتحقق Training and Validation Loss من أجل 24 دفعة تدريب منفصلة

4- مرحلة الاختبار والتقييم: evaluation and testing

بعد تدريب النموذج تم اختبار النموذج الأول المدرب بطريقة تطبيع الحزمة من أجل 310 عينة خاصة بالاختبار، لتكون الدقة النهائية 90%، والخسارة 0.2. حيث تم تقسيم مجموعة الاختبار إلى مجموعات جزئية مكونة من 32 عينة واختبار كل مجموعة على حدا وإيجاد قيمة الدقة والفقد لكل مجموعة جزئية ومن ثم إيجاد قيمة الدقة الكلية والفقد الكلي لجميع المجموعات الجزئية. كما يبين الشكل (17).

```

testing
160/310 [=====>.....] - ETA: 1s - loss: 0.2730 - accuracy: 0.8875
192/310 [=====>.....] - ETA: 1s - loss: 0.2692 - accuracy: 0.8958
224/310 [=====>.....] - ETA: 0s - loss: 0.2569 - accuracy: 0.9018
256/310 [=====>.....] - ETA: 0s - loss: 0.2417 - accuracy: 0.9062
288/310 [=====>...] - ETA: 0s - loss: 0.2276 - accuracy: 0.9132
310/310 [=====] - 3s 10ms/sample - loss: 0.2382 - accuracy: 0.9065
Test Loss is: 0.23824178653378641
Test Accuracy is: 0.90645164
F1 score for testing data is : 0.9042904290429042
    
```

الشكل (17) نتائج الاختبار النهائية على النموذج الأول

ومن ثم تم اختبار نموذج الشبكة الثاني المدرب من أجل 310 عينة خاصة بالاختبار، لتكون الدقة النهائية 69%، والخسارة 0.8. كما يبين الشكل (18).

```

testing
160/310 [=====>.....] - ETA: 1s - loss: 0.8770 - accuracy: 0.6966
192/310 [=====>.....] - ETA: 1s - loss: 0.9028 - accuracy: 0.6562
224/310 [=====>.....] - ETA: 0s - loss: 0.8411 - accuracy: 0.6830
256/310 [=====>.....] - ETA: 0s - loss: 0.8200 - accuracy: 0.6992
288/310 [=====>...] - ETA: 0s - loss: 0.8305 - accuracy: 0.7049
310/310 [=====] - 3s 10ms/sample - loss: 0.8702 - accuracy: 0.6968
Test Loss is: 0.8701591953154533
Test Accuracy is: 0.6967742
F1 score for testing data is : 0.5877192982456141
    
```

الشكل (18) نتائج الاختبار النهائية على النموذج الثاني

بعد نهاية عملية التدريب والاختبار نشكل الجدول (1) الذي يوضح النتائج النهائية لكل نموذج مقترح وفق طريقة التدريب المستخدمة:

الجدول (1) النتائج النهائية لكلا النموذجين

| | First Model (Split) | First Model (Sequence) | Second Model |
|-----------------------|---------------------|------------------------|--------------|
| Loss (Training) | 0.1 | 0.14 | 0.74 |
| Loss (Validation) | 0.43 | 1.12 | 0.72 |
| Loss (Testing) | 0.2 | — | 0.8 |
| Accuracy(training) | 97% | 94% | 50% |
| Accuracy (Validation) | 87% | 69% | 45% |
| Accuracy (Testing) | 90% | — | 69% |

الاستنتاجات والتوصيات:

وفقاً للنتائج التي تم الوصول إلى نستنتج ما يلي:

- مرحلة Preprocessing تختصر وقت وزمن تدريب كبيرين، لذلك تعتبر مرحلة ضرورية وهامة، حيث لا بد من إيجاد أكثر شكل ملائم للبيانات المدخلة بدون خسارة المعلومات الهامة منها.
- الصور الشعاعية موجودة بصيغ مختلفة، وفي بحثنا استخدمنا صيغة بسيطة منها، وهذا ما دفعنا إلى استخدام نموذج ثاني من الشبكات لكي يكون قادر على التعامل مع كافة الصيغ مستقبلاً، وهذا ما يجعله متاحاً للاستخدام الفعلي والصحيح في المشافي.
- على الرغم من تواضع أداء النموذج الثاني أمام أداء النموذج الأول، إلا أنه قابل للتطوير في مراحل قادمة، كما يمكن استخدامه في مهام التشخيص على اختلافها وليس فقط في تشخيص ورم الدماغ.
- بعد تطبيق بنيتين مختلفتين تماماً على الصور المعطاة وعند تطبيق التدريب على 20 دفعة متتالية. لاحظنا أن البنية الأولى أعطت نتائج أفضل في التدريب من النموذج الثاني.
- عدد دفعات التدريب من العوامل التي تؤثر في التدريب حيث لاحظنا أن النموذج الأول أعطى نتائج أفضل بكثير عندما قسمنا دفعات التدريب الكلية إلى خمس مجموعات جزئية.
- يوصى بالتعديل في بنية النموذج الثاني لتحسين أدائه، واستخدام صور بصيغ مختلفة وتطبيقها على النماذج المقترحة وتحليل أدائها.

References:

- [1]- CHOLLET, F. *Deep Learning with Python*, Manning, United States of America, 2018, 373.
- [2]- WANG, L., WANG, S., CHEN, R., QUM, X., CHEN, Y., HUANG, S., LIU, C. *Nested Dilation Networks for Brain Tumor Segmentation Based on Magnetic Resonance Imaging*, April 2019, Volume 13, 1-14.
- [3]- REINHOLD, J. *Deep Learning with Magnetic Resonance and Computed Tomography Images*, 2019, 1-9.
- [4]- RONNEBERGER, O., FISCHER, P., BROX, T. *U-Net: Convolutional Networks for Biomedical Image Segmentation*, Computer Science Department and BIOS Centre for Biological Signalling Studies, University of Freiburg, Germany, 2015, 234–241.
- [5]- SZEGEDY, C., VANHOUCHE, V., IOFFE, S., SHLENS, J., WOJNA, Z. *Rethinking the Inception Architecture for Computer Vision*, IEEE Conference on Computer Vision and Pattern Recognition, 2016, 2818-2826.
- [6]- ALHASSAN, A. M., Wan Zainon, W. M. *Brain tumor classification in magnetic resonance image using hard swish-based RELU activation function-convolutional neural network*, Springer, January 2021, 1-13.
- [7]- NIVESARA, T., PL, T., KALAICHELVI, T., ABIRAMI, M. *MRI Image Classification of Brain Tumor Using Convolution Neural Network and Web Framework*, International Research Journal of Engineering and Technology (IRJET), Volume: 08, Issue: 04, Apr 2021, 1-7.
- [8]- SALIMANS, T., KINGMA, D. *Weight Normalization: A Simple Reparameterization to Accelerate Training of Deep Neural Networks*, NIPS 2016, Barcelona, Spain.1-10.
- [9]- MARIAM ,S. *Classification of Pattern Recognition Techniques Used Deep Learning and Machine Learning*. International Journal of Computer Science Trends and Technology. V.7, pp.165-173(2019).