

Improving Brain Tumor Classification using Convolutional Neural Networks (CNNs) For MRI Images of the Brain

Dr. Sobhi Al Shikha*

(Received 7 / 11 / 2023. Accepted 28 / 1 / 2024)

□ ABSTRACT □

Brain tumors are serious and fatal diseases, which often lead to a decrease in human life expectancy. Early and accurate detection of the nature and classification of these tumors is crucial for developing an appropriate treatment plan that can lead to prolonging the lives of patients with these tumors. Manual diagnosis of large quantities of brain MRI images is considered extremely difficult and complex, and requires the diagnosing physician to have high experience and great accuracy in classifying each type of these tumors according to its shape, dimensions, and location in the human brain. Therefore, an intelligent model based on deep learning (DL) must be developed to accurately diagnose and classify brain tumors. In this study, we will propose a new deep learning (DL) model based on convolutional neural networks (CNNs). This model uses a number of algorithms for the initial processing of MRI images and to be input to the convolutional neural network that In turn, it contains, in addition to the input layer, a number of hidden internal convolutional layers, which perform a number of mathematical operations on the input data to extract features from brain MRI images, and a number of pooling layers, which select the most important features from the total of extracted features, and full connection layers, which create paths. Additional neurons between layers. This allows the network to learn complex relationships between features and make high-level predictions. The results obtained by applying the new model achieved an accuracy rate of 99.6% on an MRI brain tumor dataset obtained from a database Kaggle Brain tumor dataset and over relatively small time frames make this model extremely useful for neurologists to help make quick and accurate diagnostic decisions.

Keywords: brain tumor classification, brain MRI images, convolutional neural networks (CNN), graph neural network (GNN16Net), deep learning (DL).

Copyright



:Tishreen University journal-Syria, The authors retain the copyright under a CC BY-NC-SA 04

* Assistant Professor, Faculty of Information Engineering, Al-Shahbaa Private University, Aleppo, Syria. sobhi.alshikha@tishreen.edu

تحسين تصنيف أورام الدماغ باستخدام نموذج جديد من الشبكات العصبونية الالتفافية (CNNs) من صور الرنين المغناطيسي

د. صبحي الشبخة*

(تاريخ الإيداع 7 / 11 / 2023. قُبِلَ للنشر في 28 / 1 / 2024)

□ ملخص □

تعد أورام الدماغ من الأمراض الخطيرة والقاتلة، والتي قد تؤدي غالباً لانخفاض في متوسط العمر المتوقع للبشر. وإن الكشف المبكر والدقيق عن طبيعة هذه الأورام وتصنيفها يعتبر ذو بالغة لوضع خطة العلاج المناسبة والتي من الممكن أن تؤدي لإطالة عمر المرضى المصابين بهذه الأورام. يعتبر التشخيص اليدوي للكيمات الكبيرة من صور الرنين المغناطيسي للدماغ أمراً بالغ الصعوبة والتعقيد، ويتطلب من الطبيب المشخص خبرة عالية ودقة كبيرة في تصنيف كل نوع من أنواع هذه الأورام تبعاً لشكله وابعاده وموقعه في الدماغ البشرية، وبالتالي لا بد من تطوير نموذج ذكي يعتمد على التعلم العميق (DL) لتشخيص أورام الدماغ وتصنيفها بدقة. في هذه الدراسة سوف نقترح نموذجاً جديداً للتعلم العميق (DL) يعتمد على الشبكات العصبونية الالتفافية (CNNs)، حيث يستخدم هذا النموذج عدداً من الخوارزميات الخاصة بالمعالجة الأولية لصور الرنين المغناطيسي و لتكون دخلاً للشبكة العصبونية الالتفافية التي بدورها تحتوي بالإضافة لطبقة الدخل على عدد من الطبقات الالتفافية الداخلية المخفية والتي تقوم بعدد من العمليات الحسابية على بيانات الدخل لاستخراج الخصائص من صور الرنين المغناطيسي للدماغ وعدد من طبقات التجميع والتي تقوم باختيار أهم الخصائص من مجموع الخصائص المستخرجة، وطبقات الاتصال الكامل" والتي تقوم بإنشاء مسارات عصبونية إضافية بين الطبقات. يسمح هذا للشبكة بتعلم العلاقات المعقدة بين الميزات وتقديم تنبؤات عالية المستوى. إن النتائج التي تم الحصول عليها بتطبيق النموذج الجديد قد حققت معدل دقة يصل إلى 99.6% في مجموعة بيانات أورام الدماغ الخاصة بالرنين المغناطيسي والتي تم الحصول عليها من قاعدة بيانات kaggle Brain tumor dataset وخلال أطر زمنية تعد صغيرة نسبياً تجعل من هذا النموذج مفيداً بشكل كبير لأطباء الدماغ والأعصاب للمساعدة في اتخاذ قرارات تشخيصية سريعة ودقيقة.

الكلمات المفتاحية: تصنيف أورام الدماغ، صور الرنين المغناطيسي للدماغ، التعلم العميق، الشبكات العصبونية الالتفافية، الشبكة العصبونية VGG16Net.



حقوق النشر : مجلة جامعة تشرين- سورية، يحتفظ المؤلفون بحقوق النشر بموجب الترخيص

CC BY-NC-SA 04

* مدرس، كلية الهندسة المعلوماتية، جامعة الشهباء الخاصة، حلب، سورية. sobhi.alshikha@tishreen.edu

مقدمة:

يعد الدماغ مكوناً أساسياً ومعقداً للغاية في جسم الإنسان، وهو مسؤول عن التحكم في كل من الافعال الارادية والارادية [1]. باعتباره واحداً من أكثر الأعضاء تعقيداً وحساسية، فهو يتحكم في العديد من الوظائف الحيوية، بما في ذلك الإدراك والعاطفة والرؤية والسمع والاستجابة [2]. تعتبر أورام الدماغ، التي تنتج عن نمو الأنسجة غير الطبيعية داخل الجمجمة، من بين أكثر اضطرابات الدماغ فتكاً. يمكن تصنيف هذه الأورام إلى أنواع أولية وثانوية. أورام الدماغ الأولية، التي تمثل 70٪ من الحالات، تنتشر فقط داخل الدماغ، في حين أن الأورام الثانوية تنشأ في أعضاء أخرى مثل الثدي أو الكلى أو الرئة قبل أن تنتشر إلى الدماغ [3].

في الماضي كانت الصور الطبية تستخدم للتعليم والاستنتاجات العلمية فقط، بينما أصبح التصوير الطبي في وقتنا الحاضر أداة بحث وتشخيص سريري يومية. وباعتبار ان الدماغ هو الجزء الأهم من جسم الانسان، فقد لقي الاهتمام الأكبر في المجال الطبي،

ويعد التصوير بالرنين المغناطيسي ملائماً جداً للدراسة غير الجراحية لأمراض الدماغ ووظائفه وبنيتة من حيث تكوينها الشكلي، وهذا النوع من الصور وعمليات معالجتها مفيد جداً في تحليل الصور الطبية وتشخيصها [4].

يعتبر مجال معالجة الصور الرقمية الطبية بواسطة الخوارزميات المختلفة إما لتحسينها من أجل التشخيص من قبل الطبيب المختص أو لتعرف محتواها الطبي وفهم الحالة المرضية الموجودة فيها عن طريق الحاسوب باستخدام تقنيات معالجة الصور الرقمية الطبية كتقنية فهم الصور وتحليلها Image Analysis، أو تشخيص الحالة المرضية فيها (Computer Image Diagnosis(CID) ومن هنا يمكن تقسيم طرائق معالجة الصور الرقمية الى صنفين أساسيين واسعين: الصنف الأول يكون دخله صورة وخرجه صورة ايضاً، والصنف الثاني يكون دخله صورة وخرجه خصائص استخلصت من هذه الصورة.


أهمية البحث وأهدافه:

يهدف هذا البحث الى تطوير نموذج ذكي يعتمد على التعلم العميق (DL) لتشخيص أورام الدماغ وتصنيفها بدقة بناء على الشبكات العصبونية الالتفافية (CNNs) ، والتي دخلها صور الرنين المغناطيسي للدماغ، وطبقاتها الالتفافية تعتمد على الشبكة العصبية للرسم البياني (GNN) والتي تستخدم لاستخراج الخصائص من هذه الصور، وطبقاتها التجميعية تقوم باختيار الخصائص الهامة فقط من هذه الخصائص، وطبقات الاتصال الكامل التي تقوم بإنشاء مسارات عصبونية إضافية بين الطبقات، وخرجها هو تصنيف الورم كورم الدماغ الدبقي أو ورم الدماغ السحائي أو ورم الغدة النخامية أو بدون ورم، ويعتبر هذا النموذج مهماً لمساعدة أطباء الدماغ والأعصاب في اتخاذ قرارات تشخيصية سريعة ودقيقة.

طرائق البحث ومواده:

تم الحصول على قاعدة بيانات لصور الرنين المغناطيسي للدماغ المصابة بالورم مكونة من حوالي 1311 صورة رنين مغناطيسي لعدد من أنواع ورم الدماغ تشمل 300 صورة ورم الدماغ الدبقي، و 306 صور ورم الدماغ السحائي، و 300 صورة ورم الغدة النخامية، و 405 صور بدون ورم من قاعدة بيانات صور الرنين المغناطيسي Kaggle. <https://www.kaggle.com/datasets/masoudnickparvar/brain-tumor-mri-dataset>

حيث ستقسم هذه الصور الى مجموعتين: مجموعة أولى تضم صور تدريب النموذج، ومجموعة ثانية تضم صور اختبار النموذج.




الشكل 1: نماذج صور الرنين المغناطيسي للدماغ من قاعدة البيانات Kaggle

سوف نستخدم للتصنيف خوارزمية الشبكات العصبونية الالتفافية (CNNs) والتي تعد فرع من فروع التعلم العميق (DL) وهي نوع من نماذج الشبكات العصبونية التي تسمح بالعمل مع الصور ومقاطع الفيديو، حيث تأخذ CNN بيانات البيكسل الأولية للصورة، وتدريب النموذج، ثم تستخرج الميزات تلقائيًا للحصول على تصنيف أفضل. طبقات الشبكة العصبونية الالتفافية CNNs Layers:


- طبقة الدخل
- طبقة الالتفاف مع تابع ال ReLU
- طبقة التجميع
- طبقة الاتصال الكامل
- طبقة الخرج (التصنيف)

الشكل التالي يبين تسلسل عمل طبقات الشبكة العصبونية الالتفافية:




الشكل 2: تسلسل عمل طبقات الشبكة العصبونية الالتفافية

في كل طبقة التفاف تجري تطبيق تابع الالتفاف التالي [5]:




الشكل 3: عمل طبقة الالتفاف في الشبكة العصبونية الالتفافية

وفي كل طبقة تجميع يجري تطبيق تابع التجميع وفق التالي [5]:



الشكل 4: عمل طبقة التجميع في الشبكة العصبونية الالتفافية

وفي طبقة الاتصال الكامل يتم توصيل جميع العصبونات وفق التالي [5]:



الشكل 5: عمل طبقة الاتصال الكامل في الشبكة العصبونية الالتفافية


بينما تقوم الطبقة الأخيرة (طبقة الخرج) بعملية التصنيف النهائي تم اجراء دراسة تحليلية عن عدد من الأبحاث التي استخدمت خوارزميات تصنيف متعددة حيث يبين الجدول التالي النماذج المستخدمة في الدراسات ونسب النجاح والنتائج التي تم الحصول عليها منها.

جدول 1: مقارنة للنتائج التي تم التوصل إليها من عدة نماذج تصنيف باستخدام الشبكات العصبونية ومصنف SVM

Ref.	Year	Methodology	Dataset	Result	Drawback
[6]	2020	PNN Classification CNN	KaggleTCIA	%90 Accuracy	Lack of comparative analysis
[7]	2019	Inception Pre-Trained CNN	BRATS 13,14,17,18	%99.12 Accuracy	Complex Approach
[8]	2019	CNN with a Modified Softmax Loss Function	BRATS, ISLES, FLAIR, DWI	%98.9 Accuracy	It can be developed and can be tested with large datasets. More efficient than related work because training time is shorter than others
[9]	2018	ELM-LRF	MNI Brain Website	%97 Classification Success	Long Process Time
[10]	2029	CNN	TCIA, Kaggle	%90 Accuracy	Computational time, system complexity, and memory space requirements are too much
[11]	2022	CNN	Harvard Medical School website	%98.5 Accuracy	SVM cannot handle a larger data set.
[12]	2022	SVM	BRATS 2017	%92.3 Accuracy	Complex System
[13]	2022	Evolutionary CNN	BRATS 2015 data set and brain image datasets from Harvard Medical School,	%97.4 Accuracy	The problem in thresholding point
[14]	2021	HOG + LBP + deep features	BRATS2015	%96 DSC	


احد النماذج للشبكة العصبونية الالتفافية تم اقتراحه في العام 2014 والذي اطلق عليه اسم VGG16Net حصل على المرتبة الثانية في معيار الدقة ILSCRC حيث تتكون أكبر بنية VGG16 التي تم إنشاؤها من 16 طبقة، 3 منها متصلة بالكامل وتحتوي وسطياً على 144 مليون بارامتر. تحتوي الطبقات على خمس طبقات تجميعية بحجم 2×2 في كل طبقة التفافية. هناك أيضاً طبقة خطية softmax عند الخرج. يتم تطبيق وظيفة تابع ReLU على جميع الطبقات المتصلة بالكامل، وفي الوقت نفسه، يتم استخدام طبقة الخرج في الطبقات المتصلة بالكامل. بالمقارنة مع الطرق الشائعة، يعتبر هذا النموذج من CNN ذو عمليات حسابية ضخمة بسبب عدد البارامترات الكبير.

النموذج الجديد الذي تم اقتراحه هو نموذج DenseNet والذي يعتبر نمط جديد من انماط الشبكة العصبونية الالتفافية حيث تكون فيه الطبقة الالتفافية الحالية مرتبطة بجميع الطبقات الالتفافية السابقة، يمتلك هذا النموذج مقارنة بالنموذج العادي من CNNs مزايا إضافية كالتخفيف من مشكلة عدم الوضوح المتدرج، وتحسين خاصية النشر، وتعزيز إعادة استخدام الخاصية، وتقليل عدد البارامترات. يتم تعريف نموذج DenseNet العميق على أنه سلسلة من DenseNets (تسمى الكتل الكثيفة) المتصلة تسلسلياً عن طريق عمليات الالتفاف والتجميع الإضافية بين الكتل الكثيفة المتتالية. يمكننا إنشاء شبكة عصبية عميقة ومرنة بما يكفي لتمثيل التحويلات المعقدة بمثل هذا الهيكل، يظهر الشكل 6 مثال على DenseNet العميق



الشكل 6: مثال على عمل نموذج DenseNet في الشبكة العصبونية الالتفافية

تم إجراء بعض التغييرات في نموذج CNN المعدل مع مراعاة أوجه القصور في النماذج الأخرى. نتيجة لفحص البنية المعمارية لشبكة VGG16، لوحظ أن الطبقات الالتفافية لشبكة VGG16 أثرت بشكل إيجابي على معدل النجاح في المناطق التي لا يتم فيها استخدام البيانات الغير مصابة من صور الرنين المغناطيسي للدماغ. لهذا السبب، تم استخدام الطبقات الالتفافية في النموذج الذي تم إنشاؤه. بعد ذلك، تم فحص بنية DenseNet. ويفضل الطبقات الكثيفة لهذا الهيكل المعماري، تم إجراء بحث أكثر تفصيلاً في صور التصوير بالرنين المغناطيسي. لهذا السبب، تم بناء الشبكات الالتفافية بمبدأ عمل أكثر كثافة في النموذج الذي تم إنشاؤه. وأخيراً، تم الكشف عن انخفاض في معدل النجاح بسبب انخفاض عدد الطبقات في تحليل البنية المعمارية البسيطة لشبكة CNN. ولهذا السبب تم زيادة عدد الطبقات. وبهذه الطريقة، تم إجراء عمليات البحث عن الصورة بشكل أكثر تفصيلاً. التعديلات التي تم إجراؤها على النموذج الذي تم إنشاؤه وزيادة عدد الطبقات أثرت على معدلات التصنيف وزيادة نسبة النجاح. يوضح الشكل 7 مكونات شبكات CNN المعدلة.



الشكل 7: مكونات شبكات CNN المعدلة

تم تدريب مجموعة من البيانات بطريقة كلاسيكية وفصلها كاختبار. ثم تم استخدام بيانات التدريب أثناء التعلم العميق. وبعد ذلك تم فحص بيانات الاختبار ومعدلات نجاح النموذج. ونتيجة لهذا البحث، تم الحصول على أكثر من 700 صورة مصنفة وفق أربع أصناف حسب الشكل 1 وهي: صور ورم الدماغ الدبقي، صور ورم الدماغ السحائي، و صور ورم الغدة النخامية، و صور بدون ورم. مشاركتها كمصدر مفتوح على Kaggle وكانت مخصصة للاستخدام في دراسات معالجة صور أورام المخ. تتكون هذه الصور من 4 فئات

بعد ذلك تم تقسيم هذه البيانات لاستخدامها في مرحلتي التدريب والاختبار. وكان الغرض من ذلك عدم استخدام البيانات المستخدمة في مرحلة التدريب في مرحلة الاختبار. تم إجراء هذا التمييز لأن إعادة تصنيف البيانات التي شاهدها النموذج من قبل أثناء التعلم الآلي من شأنها أن تؤثر على معدل الدقة. بعد ذلك، تم فحص الدراسات التي تستخدم نفس مجموعة البيانات على Kaggle. وكان سبب هذه الدراسات هو التعرف على أوجه القصور في الدراسات الأخرى وإزالة هذه النواقص في دراستنا

تهدف هذه المراجعة إلى قياس مدى نجاح بنية CNN، والتي تُستخدم عموماً في معالجة الصور في المجال الطبي، ومن ثم تحديد كيفية تقديم المساهمات إلى بنية CNN المعدلة.

الاستنتاجات والتوصيات:

يتم تقييم فعالية نموذج تصنيف وكشف أورام الدماغ المقترح عن طريق حساب مقاييس التقييم الأربعة الرئيسية القائمة على النتائج المستخدمة لاختبار المصنف:

- الإيجابيات الحقيقية (TP)
- الإيجابيات الكاذبة (FP)
- والسلبيات الحقيقية (TN)
- السلبيات الكاذبة (الجبهة الوطنية).

يتم تقييم أداء النموذج المقترح باستخدام البارامترات التالية، كما هو موضح في الجدول 2.

جدول 2: مصفوفة الارتباب

Class	Statement	Formula
True Positive	Images that belong to a patient who is sick and correctly known by the model	TP
True Negative	Images that belong to a patient who is healthy and correctly known by the model	TN
False Positive	Images that belong to a patient who is healthy but diagnosed as sick by the model	FP
False Negative	Images that belong to a patient who is sick but diagnosed as healthy by the model	FN

1- الدقة Accuracy: تحدد الدقة القدرة على التمييز الدقيق بين أنواع أورام المخ. لتقدير دقة الاختبار، نحسب نسبة الإيجابية الحقيقية والسلبية الحقيقية لجميع الحالات التي تم تقييمها محسوبة بالعلاقات التالية:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN}$$

2- الاستدعاء Recall: مقياس يوضح عدد العمليات التي نحتاج إلى تقديرها على أنها إيجابية ويتم استنتاجه وفق العلاقة التالية:

$$Recall = \frac{TP}{TP + FN}$$

3- الضبط Precision: كم عدد القيم التي قدرناها بأنها إيجابية هي في الواقع إيجابية ويتم استنتاجها وفق العلاقة التالية:

$$Precision = \frac{TP}{TP + FP}$$

يبين الجدول 3 نتائج الدقة (Accuracy) التي تم التوصل إليها عند تطبيق النموذج التقليدي من CNN عدداً من المرات (Number of Epochs) على عينات التدريب:

جدول 3: نتائج الدقة التي تم الحصول عليها عند تطبيق النموذج التقليدي من CNN على عينات التدريب

Number of Epochs	Loss Function	Accuracy Rate	Validation Loss Function	Validation Accuracy Rate
1	1.2098	0.6435	1.8210	0.6485
2	0.5977	0.7582	0.5531	0.7680
3	0.4806	0.7959	0.6529	0.7680
4	0.4826	0.8154	0.4741	0.8629
5	0.3804	0.8502	0.5892	0.7856
6	0.3072	0.8685	0.4932	0.8084
7	0.2291	0.8969	0.3390	0.9086
8	0.2102	0.9099	0.3310	0.9174
9	0.1953	0.9166	0.3505	0.9033
10	0.1732	0.9232	0.3290	0.9192

ويبين الشكل 8 التالي مصفوفة الارتباب التي تم الحصول عليها من تطبيق CNN على عينات التدريب:

ورم دبقي	85	0	14	0
بنون ورم	0	94	3	1
ورم سحائي	13	6	80	7
ورم الغدة النخامية	2	0	3	92
	ورم دبقي	بدون ورم	ورم سحائي	ورم الغدة النخامية

الشكل 8: مصفوفة الارتباب التي تم الحصول عليها من تطبيق CNN على عينات التدريب

ويبين الجدول 4 نتائج الاستدعاء Recall والضبط Precision لكل صنف من الأصناف الأربعة عند تطبيق CNN

جدول 4: نتائج الاستدعاء Recall والضبط Precision لكل صنف من الأصناف الأربعة عند تطبيق CNN

Brain Tumor Classes	Precision	Recall
0	0.89	0.90
1	0.97	0.98
2	0.88	0.85
3	0.95	0.97

يبين الجدول 5 نتائج الدقة (Accuracy) التي تم التوصل إليها عند تطبيق النموذج الجديد DenseNet عدداً من المرات (Number of Epochs) على عينات التدريب:

جدول 5: نتائج الدقة التي تم الحصول عليها عند تطبيق النموذج الجديد DenseNet على عينات التدريب

Number of Epochs	Loss Function	Accuracy Rate	Validation Loss Function	Validation Accuracy Rate
1	0.7699	0.7271	1.1123	0.6538
2	0.4267	0.8429	0.6523	0.7522
3	0.3269	0.8773	0.7634	0.7135
4	0.2142	0.9228	0.3145	0.8981
5	0.1867	0.9310	4.2310	0.6520
6	0.1422	0.9496	0.5562	0.8418
7	0.0750	0.9742	0.2394	0.9262
8	0.0599	0.9797	0.5438	0.8453
9	0.0493	0.9850	0.1974	0.9455
10	0.0472	0.9855	0.1936	0.9438
11	0.0404	0.9877	0.2002	0.9438
12	0.0383	0.9877	0.1982	0.9525
13	0.0317	0.9922	0.2054	0.9438
14	0.0342	0.9887	0.2039	0.9455
15	0.0342	0.9914	0.2040	0.9473
16	0.0336	0.9910	0.2056	0.9438
17	0.0312	0.9910	0.2050	0.9438

ويبين الشكل 9 التالي مصفوفة الارتباب التي تم الحصول عليها من تطبيق النموذج DenseNet على عينات التدريب

ورم دقيقي	95	0	4	0
بدون ورم	0	95	2	1
ورم سحائي	4	5	94	6
ورم الغدة النخامية	1	0	0	93
	ورم دقيقي	بدون ورم	ورم سحائي	ورم الغدة النخامية

الشكل 9: مصفوفة الارتباب التي تم الحصول عليها من تطبيق DenseNet على عينات التدريب

ويبين الجدول 6 نتائج الاستدعاء Recall والضبط Precision لكل صنف من الأصناف الأربعة عند تطبيق النموذج الجديد DenseNet

جدول 6: نتائج الاستدعاء Recall والضبط Precision لكل صنف من الأصناف الأربعة عند تطبيق DenseNet

Brain Tumor Classes	Precision	Recall
0	0.96	0.97
1	0.97	0.98
2	0.96	0.91
3	0.95	0.99

استناداً لنتائج الدقة والضبط والاستدعاء ومصفوفة الارتباب نجد أن النموذج الجديد من الشبكات العصبونية الالتقافية DenseNet هو الأفضل في تصنيف الانماط الأربعة من صور الرنين المغناطيسي المأخوذة من قاعدة البيانات Kaggle. ان العمل المقدم يمكن التوسع فيه من التصنيف (Normal-Glioma-Meningioma- Pituitary) الى مصنف لأمراض متخصصة أكثر، كمرض الزهايمر، ومرض التهاب الدماغ الخبيث وغيرها من امراض الدماغ الأخرى.

References:

- [1]. Quader S., Kataoka K., Cabral H. Nanomedicine for brain cancer *Advanced Drug Delivery Reviews* (2022), Article 114115
- [2]. Asif S., Yi W., Ain Q.U., Hou J., Yi T., Si J. Improving effectiveness of different deep transfer learning-based models for detecting brain tumors from MR images *IEEE Access*, 10 (2022), pp. 34716-34730
- [3]. Kibriya H., Amin R., Alshehri A.H., Masood M., Alshamrani S.S., Alshehri A. A novel and effective brain tumor classification model using deep feature fusion and famous machine learning classifiers *Computational Intelligence and Neuroscience*, 2022 (2022)
- [4]. AMMAR, MAAN, *Medical Images Processing and Display*. Second Edition, Faculty of Medical Engineering, Al Andalus Private University for Medical Sciences, Syria, 2016, 651
- [5]. Hossain & Md. Shahriar Alam Sajib Pabna Classification of Image using Convolutional Neural Network (CNN) By Md. Anwar University of Science & Technology *Global Journal of Computer Science and Technology: D Neural & Artificial Intelligence* Volume 19 Issue 2 Version 1.0 Year 2019 Type: Double Blind Peer Reviewed International Research Journal Publisher: Global Journals Online ISSN: 0975-4172 & Print ISSN: 0975-4350
- [6]. Kurup, R.V.; Vishvanathan, S.; Kp, S. Effect of Data Pre-processing on Brain Tumor Classification Using CapsuleNet. In *Proceedings of the International Conference on Intelligent Computing and Communication Technologies*, Hyderabad, India, 9–11 January 2019; pp. 110–119.
- [7]. Siar, M.; Teshnehlab, M. Brain Tumor Detection Using Deep Neural Network and Machine Learning Algorithm. In *Proceedings of the 9th International Conference on Computer and Knowledge Engineering (ICCKE)*, Mashhad, Iran, 24–25 October 2019.
- [8]. Maharjan, S.; Alsadoon, A.; Prasad, P.W.C.; Al-Dalain, T.; Alsadoon, O.H. A novel enhanced softmax loss function for brain tumour detection using deep learning. *J Neurosci Methods* 2020, 330, 108520. [CrossRef] [PubMed]
- [9]. Arı, A.; Hanbay, D. Deep learning-based brain tumor classification and detection system. *Turk. J. Electr. Eng. Comput. Sci.* 2018, 26, 5.
- [10]. Boustani, A.E.; Aatila, M.; Bachari, E.E.; Oirrak, A.E. MRI Brain Images Classification Using Convolutional Neural Networks. In *Proceedings of the Advanced Intelligent Systems for Sustainable Development (AI2SD'2019)*, Marrakech, Morocco, 8–11 July 2019; pp. 308–320.
- [11]. Arif, M.; Ajesh, F.; Shamsudheen, S.; Geman, O.; Izdrui, D.; Vicoveanu, D. Brain Tumor Detection and Classification by MRI Using Biologically Inspired Orthogonal Wavelet Transform and Deep Learning Techniques. *J. Healthc. Eng.* 2022, 2022, 2693621. [CrossRef]
- [12]. Budati, A.K.; Katta, R.B. An automated brain tumor detection and classification from MRI images using machine learning techniques with IoT. *Environ. Dev. Sustain.* 2022, 24, 10570–10584. [CrossRef]
- [13]. Dehkordi, A.A.; Hashemi, M.; Neshat, M.; Mirjalili, S.; Sadiq, A.S. Brain Tumor Detection and Classification Using a New Evolutionary Convolutional Neural Network. *arXiv* 2022, arXiv:2204.12297. [CrossRef]
- [14]. Biratu, E.S.; Schwenker, F.; Debelee, T.G.; Kebede, S.R.; Negera, W.G.; Molla, H.T. Enhanced Region Growing for Brain Tumor MR Image Segmentation. *J. Imaging* 2021, 7, 22. [CrossRef]