

Comparison Between Convolutional Neural Networks (CNNs) and Support Vector Machine Algorithm (SVM) in Classifying Brain MRI Tumors

Dr. Sobhi Al Shikha*

(Received 26 / 1 / 2024. Accepted 26 / 2 / 2024)

□ ABSTRACT □

Brain tumors are among the diseases that endanger human health. This disease not only harms people physically, but also puts financial and emotional obstacles to family and professional life. The key to early diagnosis of brain tumors is to draw conclusions from doctors' observation of MRI images of the brain. Brain tumors are divided into high-grade tumors and low-grade tumors. However, because each doctor has different experience and approaches to treating tumors, doctors have no way to have a uniform classification standard for brain tumors. In this research, a large number of brain MRI images were obtained from the 2019 Brain Tumor Segmentation challenge dataset. We process the brain MRI image data through a computer, and then train the data through a machine learning algorithm, which can classify tumors. brain effectively. In the experiment, convolutional neural network and support vector machine were used as the model training algorithm. The accuracy of the support vector machine on the test set was 84.3%, while the performance of the convolutional neural network on the test set was 77.6%. From the two experimental results, it can be concluded that the performance of SVM is better than that of CNN in both brain tumor classifications. In addition, in this study we also tried to improve the model performance through different model parameters. This research can be applied to the system for diagnosing brain tumors as well as other tumors. We hope that this paper will provide researchers with useful experience in this field.

Keywords: brain tumor classification, brain MRI images, deep learning, convolutional neural networks, support vector machine (SVM).

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.alshikha44@tishreen.edu

مقارنة بين الشبكات العصبونية الالتفافية CNNs وخوارزمية آلة المتجهات الداعمة SVM في تصنيف أورام صور الرنين المغناطيسي للدماغ

د. صبحي الشيكحة*

(تاريخ الإيداع 26 / 1 / 2024. قُبِلَ للنشر في 26 / 2 / 2024)

□ ملخص □

تعد أورام الدماغ من الامراض التي تعرض صحة الإنسان للخطر. حيث لا يؤدي هذا المرض الأشخاص جسدياً فحسب، بل يضع أيضاً عقبات مالية وعاطفية أمام الأسرة والحياة المهنية. إن مفتاح التشخيص المبكر لأورام الدماغ هو استخلاص استنتاجات من ملاحظة الأطباء لصور التصوير بالرنين المغناطيسي للدماغ. حيث تنقسم أورام الدماغ إلى أورام عالية الدرجة وأورام منخفضة الدرجة. ومع ذلك، نظراً لأن كل طبيب لديه خبرة وطرق مختلفة في علاج الأورام، فلا توجد لدى الأطباء طريقة للحصول على معيار تصنيف موحد لأورام الدماغ.

في هذا البحث، تم الحصول على عدد كبير من صور الرنين المغناطيسي للدماغ من قاعدة بيانات The 2019 Brain Tumor Segmentation challenge dataset.

حيث نقوم بمعالجة بيانات صورة التصوير بالرنين المغناطيسي للدماغ من خلال جهاز حاسوب، ثم نقوم بتدريب البيانات من خلال خوارزمية التعلم الآلي، والتي يمكنها تصنيف أورام الدماغ بشكل فعال. في التجربة، تم استخدام الشبكة العصبونية الالتفافية وآلة متجهات الدعم كخوارزمية للتدريب النموذجي. بلغت دقة آلة متجه الدعم في مجموعة الاختبار 84.3%، بينما يبلغ أداء الشبكة العصبونية الالتفافية في مجموعة الاختبار 77.6%.

من النتائج التجريبيتين يمكن استنتاج أن أداء SVM أفضل من أداء CNN في تصنيف أورام الدماغ. بالإضافة إلى ذلك، حاولنا في هذه الدراسة أيضاً تحسين أداء النموذج من خلال بارامترات النموذج المختلفة. ويمكن تطبيق هذا البحث على نظام تشخيص أورام الدماغ بالإضافة إلى الأورام الأخرى. ونأمل أن توفر هذه الورقة للباحثين خبرة مفيدة في هذا المجال.

الكلمات المفتاحية: تصنيف أورام الدماغ، صور الرنين المغناطيسي للدماغ، التعلم العميق، الشبكات العصبونية الالتفافية CNNs، آلة المتجهات الداعمة SVM.

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.alshikha44@tishreen.edu

مقدمة:

ورم الدماغ هو مرض تتكون فيه خلايا غير طبيعية في أنسجة الدماغ أو يبدأ الورم في جزء آخر من جسم الإنسان ثم تنتقل الخلايا السرطانية إلى الدماغ [15]. يعتبر الدماغ مهم للإنسان لأنه يتحكم في العديد من وظائف الجسم. وبالتالي، عندما يتشكل ورم فيه، تظهر أعراض خطيرة قد تؤثر على جسم المريض وحياته. تشمل الأعراض الصداع والنوبات ومشاكل في الرؤية والقيء والتغيرات العقلية (D.L. ،Longo ،2012). يمكن تقسيم أورام الدماغ تقريباً إلى نوعين: أورام خبيثة وأورام حميدة [15]. يمكن تقسيم الأورام السرطانية إلى أورام أولية تبدأ في الدماغ وأورام ثانوية تنتشر خارج الدماغ (تسمى النقائل الدماغية) [15]. تبلغ نسبة الإصابة بأورام الدماغ حوالي 1.9 إلى 5.4 (100.000 شخص سنوياً)، وهو ما يمثل 1% إلى 3% من الأورام المختلفة في الجسم [17]. نظراً لأن معظم الناس يفتقرون إلى فهم أورام الدماغ، فإن العديد من المرضى لم يتلقوا التشخيص المبكر والعلاج في الوقت المناسب وقد فقدوا حياتهم. ورغم أن العلاجات المحسنة سمحت للناس بالعيش لفترة أطول، فإن تكلفة هذا المرض في الولايات المتحدة ارتفعت إلى 206 مليار دولار في عام 2006. ومن بينها، تم استخدام 78 مليار دولار فقط، أي حوالي ثلث التكلفة الإجمالية للنفقات الطبية المباشرة. وكان الباقي عبارة عن تكاليف غير مباشرة بسبب فقدان الإنتاجية الناجم عن الإصابة بالأمراض والوفيات [18]. ان تصنيف أورام الدماغ يعتبر ضرورياً في العلاج. نظراً لكون إمكانية تحديد تصنيف ورم الدماغ سيؤدي لتقديم خطة العلاج المناسبة لتحقيق أفضل تأثير علاجي. وفقاً لمنظمة الصحة العالمية. تساعد صور الرنين المغناطيسي الأطباء بشكل كبير في تشخيص أورام الدماغ. 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 إلى صنفين أساسيين واسعين: الصنف الأول يكون دخله صورة وخرجه صورة ايضاً، والصنف الثاني يكون دخله صورة وخرجه خصائص استخلصت من هذه الصورة.

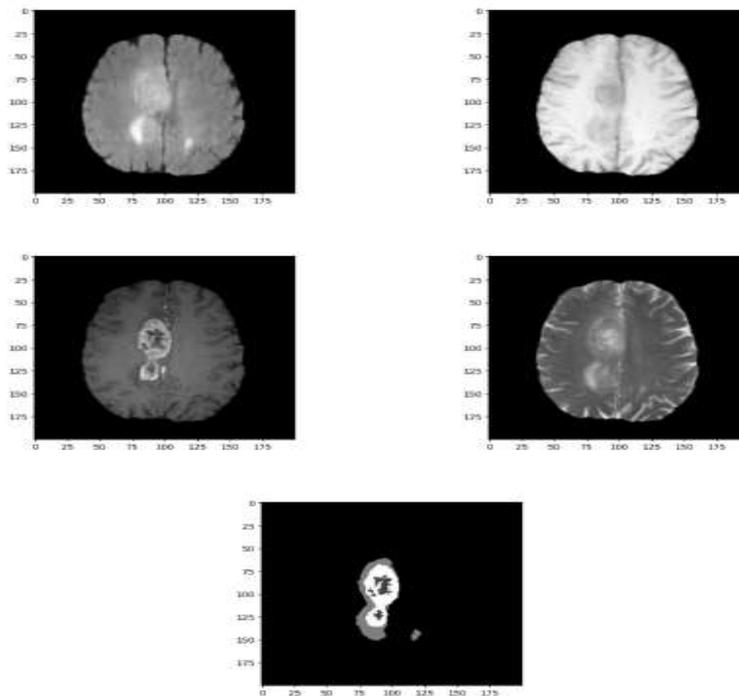
أهمية البحث وأهدافه:

في هذا البحث، قمنا بتنفيذ مقدمة نظرية لتصنيف مجموعات بيانات صور التصوير بالرنين المغناطيسي لأورام الدماغ باستخدام خوارزميات التعلم الآلي. الهدف التجريبي هو تحليل أداء SVM و CNN في معالجة مشاكل تصنيف أورام الدماغ. تم استخدام برنامج ال MATLAB كلغة تطوير. حيث تم استخدام مكتبة LIBSVM لبناء نموذج SVM وتابع MatConvNet لبناء نموذج CNN. في هذا البحث تم استخدام مجموعة بيانات The 2019 Brain Tumor Segmentation challenge dataset. حيث تم في مرحلة ما قبل التدريب، تطبيق مجموعة خطوات كمعالجة مسبقة للبيانات، تتضمن هذه الخطوات توحيد الصورة، واقتصاص الصورة، واختيار شريحة لكل صورة من صور التصوير بالرنين المغناطيسي.

في التدريب، يتم استخدام بارامترات ومجموعات بيانات مختلفة في كل نموذج SVM و CNN لتقييم تأثير بارامترات الدخل على أداء التابع. بعد التدريب، نقوم بتقييم أداء كل نموذج من خلال بعض المؤشرات، بما في ذلك الدقة والضبط والاستدعاء وقياس F والرسم البياني ROC

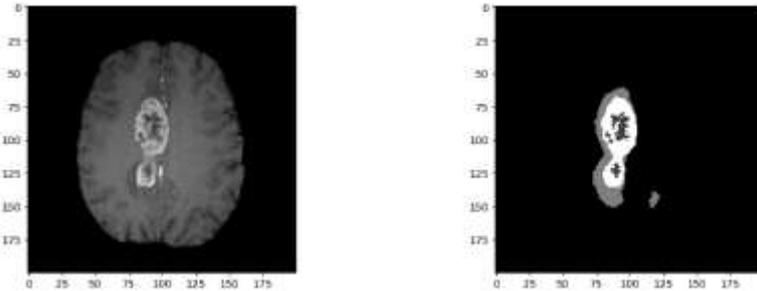
طرائق البحث ومواده:

يمكن العثور على الأنسجة غير الطبيعية في الدماغ من خلال صور الرنين المغناطيسي. لذلك، يعد الكشف عن الصور المقطعية وسيلة مثالية للتحقق مما إذا كانت هذه الأورام قد تكونت أم لا. البيانات المستخدمة في هذا المشروع (<https://ipp.cbica.upenn.edu>) مأخوذة من مجموعة بيانات The 2019 Brain Tumor Segmentation challenge dataset. من خلال جمع بيانات صور التصوير بالرنين المغناطيسي من مرضى الأورام والسماح بتقديم هذه البيانات للعلماء لإجراء الأبحاث. ويمكن للباحثين تحليل هذه الصور وتحسين تكنولوجيا علاج أورام المخ، وتحسين معدل بقاء المرضى على قيد الحياة. تتكون مجموعة البيانات هذه من أربع مجلدات. المجلد الأول (HGG) هو مجموعة بيانات صور التصوير بالرنين المغناطيسي للمرضى الذين يعانون من ورم دقيقي عالي الجودة (منظمة الصحة العالمية 3-4). المجلد الثاني (LGG) عبارة عن مجموعة بيانات من صور التصوير بالرنين المغناطيسي للمرضى الذين يعانون من الأورام الدبقية منخفضة الدرجة (WHO1-2). المجلد الثالث المسمى name_mapping هو لتحديد هوية المرضى. يتضمن المجلد الأخير المسمى Survival_data العمر الحالي للمريض وبقائه على قيد الحياة. تحتوي مجموعة البيانات بأكملها على إجمالي 355 حالة. من بينها 259 حالة في HGG و 76 حالة في LGG. تحتوي كل حالة على صور الرنين المغناطيسي لأربعة طرائق صورة وملف seg. يوضح الشكل 1 خمس صور تم أخذها من مريض واحد، تحتوي على صورة Flair و T1 و T1ce و T2 بالإضافة لصورة التقطيع. من هذه الصور الأربع للطرائق المختلفة، يمكن تحديد موقع الورم والمخطط التفصيلي للورم بوضوح من صور T1ce و T2، في طريقة Flair يمكن رؤية موقع ورم الدماغ بشكل تقريبي، ولكن الخطوط العريضة للورم غير واضحة. ولكن في الطريقة T1، من الصعب العثور على الورم

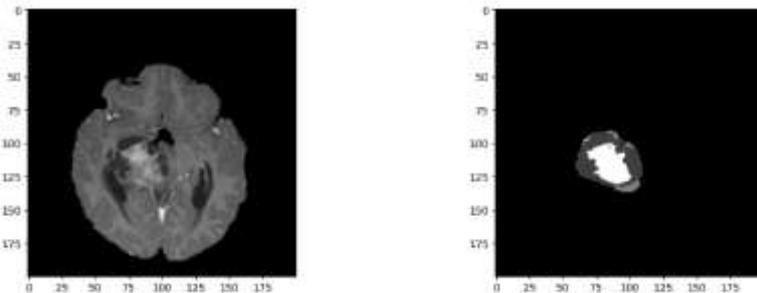


الشكل 1: خمس صور مختلفة لمريض واحد (T1, T1ce, T2, Seg)

ان تحديد مكان وشكل الورم في صور الرنين المغناطيسي للدماغ يعد عاملاً هاماً في تصنيف هذا الورم. في هذا البحث سوف نصنف نوعين من الورم الدبقي (عالي الدرجة - ومنخفض الدرجة).



الشكل 2: ورم دبقي عالي الدرجة



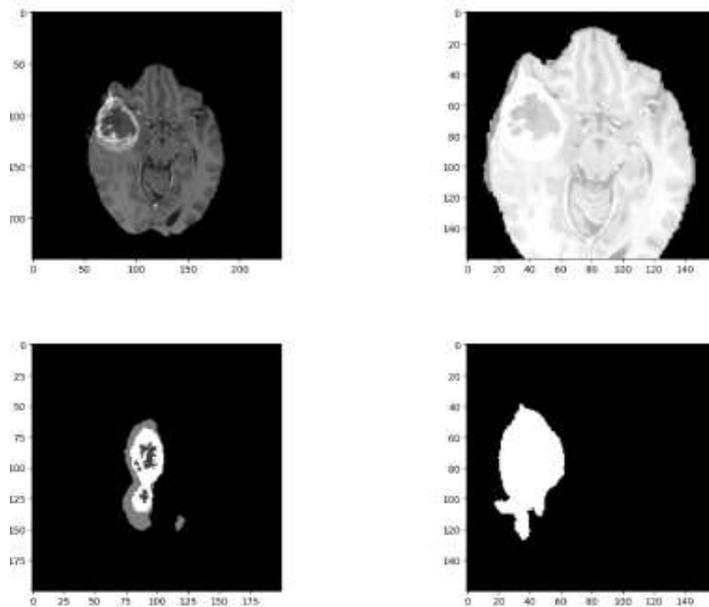
الشكل 3: ورم دبقي منخفض الدرجة

قبل بدء التدريب، يجب استخدام المعالجة المسبقة للبيانات في مجموعة البيانات الموجودة لتسهيل عمليات الكمبيوتر. ومن أجل تحسين جودة تحليل البيانات، تم اقتراح تقنية المعالجة المسبقة للبيانات. تسمى المعالجة المسبقة للبيانات أيضاً بتسوية قيم الخصائص. هناك العديد من أنواع قيم الخصائص، بما في ذلك نوع الميزة ونوع الكلفة ونوع الفاصل الزمني. بشكل عام، هناك عدة طرق للمعالجة المسبقة للبيانات.

- تنظيف البيانات هو تنظيف البيانات عن طريق ملء القيم المفقودة، وتنعيم بيانات التشويش، وتحديد القيم المتطرفة أو حذفها، وحل حالات عدم الاتساق.
- تحقيق الأهداف التالية: توحيد التنسيق وإزالة البيانات غير الطبيعية وتصحيح الأخطاء وإزالة البيانات المكررة.
- تكامل البيانات هو جمع البيانات من مصادر بيانات متعددة وتخزينها بشكل موحد. ان عملية إنشاء مستودع البيانات هي في الواقع تكامل البيانات.
- تحويل البيانات هو تحويل البيانات إلى نموذج مناسب لاستخراج البيانات من خلال التجميع السلس وتعميم البيانات وتوحيدها.
- تقليل البيانات، نظراً لأن كمية البيانات غالباً ما تكون كبيرة جداً أثناء التنقيب في البيانات، فإن استخراج كمية صغيرة من البيانات وتحليلها يستغرق وقتاً طويلاً. يمكن استخدام تقنية تقليل البيانات للحصول على تمثيل

التخفيض لمجموعة البيانات، وهو أصغر بكثير، ولكنه لا يزال قريباً من الحفاظ على سلامة البيانات الأصلية، وتكون النتيجة هي نفسها أو قريبة من نفس النتيجة قبل التخفيض.

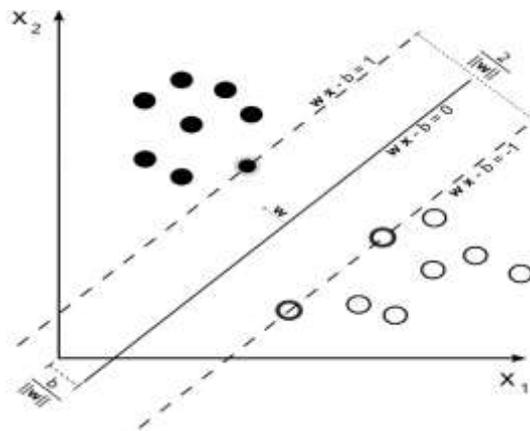
- في عملية المعالجة المسبقة، يجب اقتصاص كل شريحة، حيث يتم قطع البكسلات السوداء لتقليل تأثير هذه البيانات على النتيجة. تتمثل عملية اقتصاص الصورة في قص صورة الرنين المغناطيسي الأصلية (240*240) إلى صورة جديدة بقياس (160*160)، مما يقلل بشكل فعال من المساحة السوداء في صورة الرنين المغناطيسي.



الشكل 4: صور الرنين قبل المعالجة وبعد المعالجة الاولية

التصنيف باستخدام SVM:

من أفضل مصنفات الصور الطبية من حيث الدقة وزمن التشغيل. تقوم هذه الخوارزمية بحساب سطح أو مجموعة أسطح في بعد آخر يختلف طوله عن طول متجه الخصائص. تحدد دقة الخوارزمية بقدرتها على الفصل بين نوعين بحيث تكون أقرب عينة من كلي



الشكل 5: SVM يفصل بين عينات من فئتين

النوعيتين أبعد ما يكون عن بعضهما البعض وهو ما يسمى بالحافة، وبصفة عامة كلما زادت الحافة أو هامش الفصل، كلما قل الخطأ. بالرغم مما تبدو عليه المشكلة من سهولة، إلا أنه في أغلب الأحيان لا يمكن الفصل بين النوعين خطياً، وحينها نلجأ لتحويل محاور متجهات الخصائص لبعد أعلى بحيث يتم الفصل بينهم بسطح. ويراعى في هذا المنظور العبء الحسابي فيتم حساب الضرب القياسي للمتجهات بواسطة دالة المصفوفة، حيث يكون السطح الفاصل معرف بمجموعة من النقاط نتاج ضربهم القياسي مع متجه في الإحداثيات الجديدة (ذات البعد الأعلى) تكون ثابتة [12].

قبل استخدام مصنف SVM للتدريب، يجب تحويل مجموعة البيانات الموجودة، لأن SVM لا يمكنه التعامل مع المصفوفات ثلاثية الأبعاد. مواصفات صورة الرنين المغناطيسي لكل مريض هي (160، 160، 130)، لذلك تحتاج هذه الصورة ثلاثية الأبعاد لتحويلها إلى مصفوفة ثنائية الأبعاد. يمكن القيام بذلك عن طريق دالة "إعادة التشكيل" و"المتوسط" في numpy. معلمات "إعادة الشكل" هي (-1، 130)، مما يعني أن المصفوفة الأصلية يتم تحويلها إلى مصفوفة تحتوي على 130 عموداً فقط وعدد غير معروف من الصفوف. لكي لا تفقد معلومات الصورة لكل شريحة في الصورة الأصلية، يتم ضغط بيانات الشريحة الأصلية ثنائية الأبعاد إلى بيانات أحادية البعد باستخدام الدالة "المتوسط". وبهذه الطريقة، يتم إعادة بناء مصفوفة جديدة ثنائية الأبعاد تحتوي على معظم معلومات البيانات الأصلية.

يبين الجدول 1 مجموعة من ثلاثة بارامترات لمصنف SVM لهذا البحث، واستخدام هذه البارامترات للتدريب:

جدول 1: ثلاثة أنواع من البارامترات المستخدمة في مصنف ال SVM

Classifier No.	C	Kernel	Gamma
1	5	Linear	Auto
2	5	RBF	None
3	5	Poly	Auto

يبين الجدول 2 نتائج تصنيف صور التصوير بالرنين المغناطيسي لأورام الدماغ بواسطة مصنف SVM تحت بارامترات مختلفة. DataSet تمثل نوع مجموعة البيانات المستخدمة.

Classifier No يمثل البارامترات التي يستخدمها المصنف والمقابلة للبارامترات المستخدمة في الجدول 1. وتمثل الأعمدة الأربعة الأخيرة المؤشرات التي يستخدمها النموذج لتقييم أداء النموذج المحسوب على مجموعة الاختبار. يمكن أن نرى من الجدول أنه عند معالجة نفس مجموعة البيانات، يكون أداء استخدام poly كنواة أفضل من الاثنين الآخرين. قد يكون السبب في ذلك هو أن poly يمكنه تعيين مساحة الإدخال منخفضة الأبعاد إلى مساحة الميزة عالية الأبعاد للعثور على مستوى تصنيف أفضل. على الرغم من أن RBF يمكنه أيضاً تعيين مساحة إدخال منخفضة الأبعاد إلى مساحة ميزات عالية الأبعاد، إلا أن poly يمكنه تعيين بُعد أعلى. في مشكلة تصنيف ورم الدماغ، نظراً لأن الصورة تحتوي على المزيد من قيم الميزات، فقد تحتاج إلى أن تكون في مساحة ذات أبعاد أعلى حتى يتم تصنيفها بشكل أفضل. في المقارنة بين مجموعة البيانات القياسية ومجموعة البيانات غير القياسية، وجدنا أن أداء التصنيف لمجموعة البيانات القياسية في صورة التصوير بالرنين المغناطيسي بعد التجزئة يعتبر جيداً. ومع ذلك، في وضع Tice، فإن مجموعة البيانات غير القياسية تتمتع بأداء تصنيف جيد. قد يكون هذا لأنه، في مجموعة بيانات seg،

نظرًا لأن ورم الدماغ قد تم تجزئته، فمن الواضح أن الخطوط العريضة وخصائص ورم الدماغ يتم تخزينها في بيانات صورة التصوير بالرنين المغناطيسي. ولذلك، فإن مجموعة بيانات seg القياسية أكثر ملاءمة للتدريب من مجموعة بيانات seg الأصلية. ومع ذلك، في صورة T1ce MRI حيث لا يتم تقسيم ورم الدماغ، يكون ورم الدماغ مدمجًا في الدماغ. بعد التوحيد، قد تضعف ملامح وخصائص أورام المخ، وبالتالي فإن تأثير تدريب مجموعة بيانات T1ce غير القياسية أفضل.

جدول 2: النتائج التي تم الحصول عليها من مصنف SVM

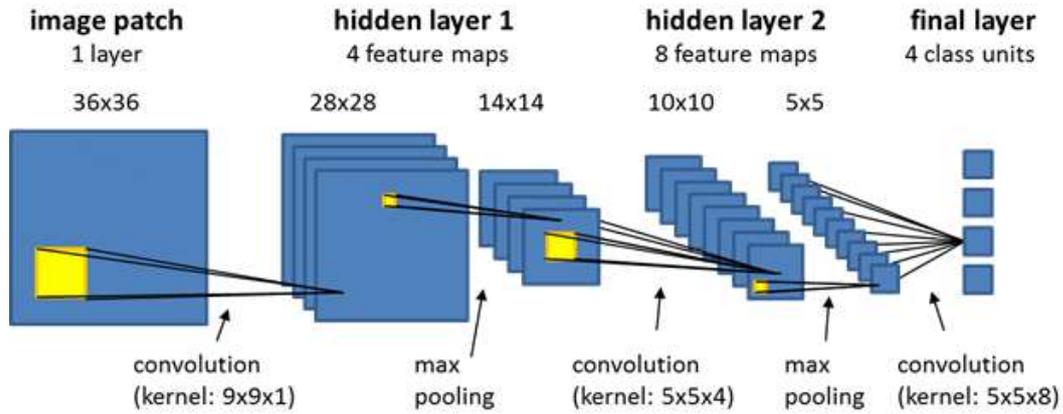
Dataset	Classifier No.	accuracy	precision	recall	f1_score
seg	1	0.773	0.880	0.849	0.864
seg	2	0.791	0.815	0.953	0.883
seg	3	0.806	0.823	0.947	0.892
seg_no	1	0.604	0.871	0.628	0.729
seg_no	2	0.763	0.848	0.895	0.870
seg_no	3	0.782	0.922	0.826	0.871
T1ce	1	0.828	0.899	0.870	0.895
T1ce	2	0.835	0.838	0.971	0.908
T1ce	3	0.843	0.894	0.918	0.905
T1ce_no	1	0.798	0.871	0.855	0.874
T1ce_no	2	0.833	0.889	0.914	0.896
T1ce_no	3	0.850	0.875	0.954	0.913

بعد تحليل نتائج تدريب SVM، نحتاج إلى البدء في تحليل نتائج تدريب CNN. تعد خوارزمية الشبكات العصبونية الالتقافية (CNNs) 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 الالتقافية CNNs Layers:

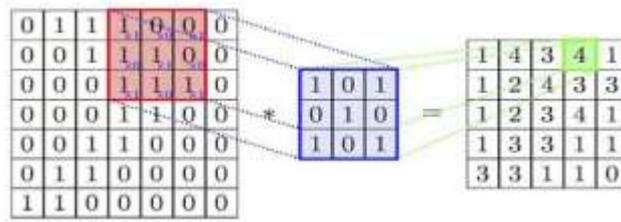
- طبقة الدخل
- طبقة الالتفاف مع تابع ال ReLU
- طبقة التجميع
- طبقة الاتصال الكامل
- طبقة الخرج (التصنيف)

الشكل التالي يبين تسلسل عمل طبقات الشبكة العصبونية الالتفافية:



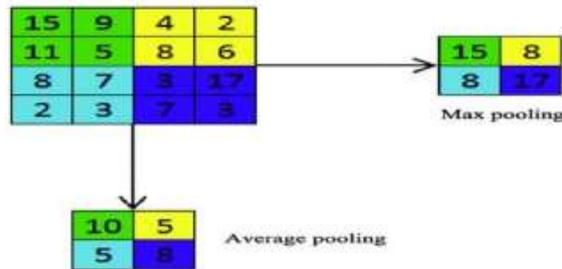
الشكل 6: تسلسل عمل طبقات الشبكة العصبونية الالتفافية

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



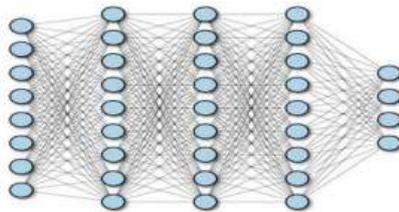
الشكل 7: عمل طبقة الالتفاف في الشبكة العصبونية الالتفافية

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



الشكل 8: عمل طبقة التجميع في الشبكة العصبونية الالتفافية

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



الشكل 9: عمل طبقة الاتصال الكامل في الشبكة العصبونية الالتفافية

بينما تقوم الطبقة الأخيرة (طبقة الخرج) بعملية التصنيف النهائي في تدريب مصنف CNN، يجب استخدام مجموعة بيانات seg ومجموعة بيانات T1ce على التوالي. عند تدريب مجموعة بيانات seg، يتم تعيين Dropout على 0.5، ولكن هذا يؤدي الى يصبح تقارب المصنف بطيئاً جداً. لذلك، بعد عدة تدريبات وتصحيحات، وجد أنه من الأفضل ضبط Dropout على 0.2. وفي الوقت نفسه، تم تعيين epochs على القيمة 50 لبدء تدريب النموذج. عند استخدام T1ce للتدريب، وجدنا أن النموذج يتقارب بشكل أسرع من تدريب مجموعة بيانات seg، لذلك يمكن ضبط قيمة Dropout على 0.5. وفي الوقت نفسه، تم تعيين epochs على القيمة 20 لبدء التدريب النموذجي على مجموعة بيانات T1ce.

يبين الجدول 3 مؤشرات التقييم لمصنف CNN لكل من seg و T1ce

جدول 3: نتائج مصنف CNN

Dataset	Accuracy	Precision	Recall	F1-score
Seg	0.731	0.787	0.905	0.842
T1ce	0.776	0.797	0.962	0.873

الاستنتاجات والتوصيات:

عند استخدام نموذج SVM كمصنف، يمكن أن تصل دقة المصنف الذي يستخدم poly كوظيفة kernel في مجموعة بيانات seg إلى 80.6%، ويمكن أن تصل مجموعة بيانات T1ce إلى 84.3%. عند استخدام نموذج CNN كمصنف، تبلغ دقة المصنف في مجموعة بيانات seg 73.1%، بينما تبلغ دقة المصنف في مجموعة بيانات T1ce 77.6%. وبالتالي، فقد حصلنا على نتائج تصنيف مرضية من خلال تعديل البارامترات على المصنفين. من خلال مقارنة المؤشرات المختلفة لـ CNN و SVM، يمكننا أيضاً أن نجد أن أداء SVM أفضل من أداء CNN عند معالجة تصنيف صور التصوير بالرنين المغناطيسي لورم الدماغ. وهذا هو الاستنتاج المفيد في هذه المهمة.

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]
- [15]. National Cancer Institute. 2020. Adult Central Nervous System Tumors Treatment (PDQ®)–Patient Version. [online] Available at: <<https://www.cancer.gov/types/brain/patient/adult-brain-treatment-pdq#section/all>> [Accessed 18 August 2020].
- [17]. Kohler, B.A., Ward, E., McCarthy, B.J., Schymura, M.J., Ries, L.A., Ehemann, C., Jemal, A., Anderson, R.N., Ajani, U.A. and Edwards, B.K., 2011. Annual report to the nation on the status of cancer, 1975–2007, featuring tumors of the brain and other nervous system. *Journal of the national cancer institute*, 103(9), pp.714-736.
- [18]. Bradley, S., Sherwood, P.R., Donovan, H.S., Hamilton, R., Rosenzweig, M., Hricik, A., Newberry, A. and Bender, C., 2007. I could lose everything: understanding the cost of a brain tumor. *Journal of Neuro-oncology*, 85(3), pp.329-338.

