

SIGNAL PROCESSING

Detection and Classification of Brain Tumours from MRI Images Using VGG16 Deep Learning Algorithm

Fatime Bashir Mishri ¹ , Rasim Amer Ali ^{1,*} 

¹Electrical-Electronics Engineering Department, Faculty of Engineering, Wadi Alshatti University, Brack, Libya

ARTICLE HISTORY

Received 09 January 2025
Revised 22 January 2025
Accepted 24 January 2025
Online 24 January 2025

KEYWORDS

Detection of brain tumors;
Deep learning;
Convolutional neural networks
(CNN);
VGG16.

ABSTRACT

The objective of this paper is developing an accurate and effective system for detecting and classifying brain tumors in MRI images. Brain tumors are considered serious diseases that require early and accurate diagnosis, and MRI images are an essential tool in the diagnosis process. However, manually analyzing these images is time-consuming and subject to human error. Therefore, this work seeks to take advantage of deep learning techniques to develop an automated system that can facilitate the diagnosis process and improve its accuracy. The research relied on the use of the pre-trained VGG16 algorithm, which is one of the most famous algorithms used in the field of computer vision. This algorithm was trained on a large data set of MRI images consisting of 3000 images divided equally between healthy and diseased images. The data was divided into 33% training and testing, training was done for 10 iterations, and the model's performance was evaluated using a variety of criteria including Accuracy, Recall, and F1-Score, which is the most important evaluation criteria in digital images. The results showed that the model achieved a training accuracy of 99.9% and a testing accuracy of 98.8%. The confusion matrix also showed that the model succeeded in correctly classifying 500 healthy samples and 479 infected samples correctly, in terms of evaluation criteria, and the results were outstanding, as the Precision, Recall, and F1-Score reached about 99% for healthy images and 98-99% for images. Infected. These results indicate that the pre-trained VGG16 model was effective in classifying brain tumors with high accuracy, with balanced performance in classifying both normal and lesioned images.

كشف وتصنيف أورام الدماغ من لصور الرنين المغناطيسي باستخدام خوارزمية التعلم العميق VGG16

فاطمة بشير المشري¹، راسم عامر على^{1,*}

الكلمات المفتاحية	الملخص
كشف أورام الدماغ التعلم العميق الشبكات العصبية الالتفافية CNN VGG16	تهدف هذه الورقة إلى تطوير نظام دقيق وفعال لكشف وتصنيف أورام الدماغ في صور الرنين المغناطيسي. تعتبر أورام الدماغ من الأمراض الخطيرة التي تتطلب تشخيصًا مبكرًا ودقيقًا، وتعد صور الرنين المغناطيسي أداة أساسية في عملية التشخيص. ومع ذلك، فإن تحليل هذه الصور يدويًا يستغرق وقتًا طويلاً ويعرض للخطأ البشري. لذلك، هذا العمل يسعى إلى الاستفادة من تقنيات التعلم العميق لتطوير نظام آلي يمكنه تسهيل عملية التشخيص وتحسين دقته. اعتمد البحث على استخدام خوارزمية VGG16 المدربة مسبقًا، وهي واحدة من أشهر الخوارزميات المستخدمة في مجال رؤية الحاسوب، حيث تم تدريب هذه الخوارزمية على مجموعة بيانات كبيرة من صور الرنين المغناطيسي مكونة من 3000 صورة مقسمة بالتساوي بين الصور السليمة والمصابة، و تم تقسيم البيانات إلى بيانات تدريب واختبار بنسبة 33% للتدريب، وتم التدريب لمدة 10 تكرارات، حيث تم تقييم أداء النموذج باستخدام مجموعة متنوعة من المعايير بما في ذلك Accuracy و Recall و F1-Score، وهي أهم معايير التقييم في الصور الرقمية، أظهرت النتائج أن النموذج حقق دقة تدريب بلغت 99.9% ودقة اختبار بلغت 98.8%. كما أظهرت مصفوفة الارتباك أن النموذج نجح في تصنيف 500 عينة سليمة بشكل صحيح و 479 عينة مصابة بشكل صحيح، من حيث معايير التقييم، وكانت النتائج متميزة، حيث بلغ ال Precision و Recall و F1-Score نحو 99% للصور السليمة و 98-99% للصور المصابة. تشير هذه النتائج إلى أن نموذج VGG16 المدرب مسبقًا كان فعالًا في تصنيف أورام الدماغ بدقة عالية، ومع أداء متوازن في تصنيف كل من الصور السليمة والمصابة.

تحدثًا كبيرًا للباحثين والمهنيين الطبيين. إن التشخيص المبكر والدقيق لهذه الأورام هو مفتاح نجاح العلاج وتحسين فرص البقاء على قيد الحياة،

المقدمة
تعتبر أورام الدماغ من أخطر الأمراض التي تهدد حياة الإنسان، وتشكل

ResNet، أظهرت الدراسة أن تقنيات التعلم العميق تقدم أدوات واعدة للكشف عن أورام الدماغ وتصنيفها بدقة وكفاءة، حيث حقق النموذج دقة عالية في الكشف عن أورام الدماغ، بلغت دقة درجة %98.28 F1 كما تفوق نموذج VGG16 على النماذج الأخرى، حيث حقق دقة F1 قدرها %99.86، في حين حققت نماذج ResNet50 و MobileNet و Inception V3 دقة F1 بلغت %98.14 و %88.98 و %99.88 على التوالي.

يهدف هذا البحث إلى تطوير نموذج دقيق وسريع لتصنيف صور الرنين المغناطيسي إلى صور تحتوي على أورام دماغية وصور لا تحتوي أورام وذلك من خلال الاستفادة من قدرة VGG16 على استخراج الميزات المعقدة من الصور بهدف تحقيق دقة تصنيف عالية تتجاوز الدقة التي يمكن تحقيقها بالطرق التقليدية .

أورام الدماغ

تعد أورام الدماغ من الأورام الخطيرة التي تؤثر على وظائف الدماغ الحيوية. تنشأ هذه الأورام من خلايا الدماغ نفسها أو تنتشر إليها من أجزاء أخرى من الجسم. وتختلف أنواع الأورام الدماغية باختلاف نوع الخلية المنشأ وسلوكها، حيث تعد الأورام الدبقية من أكثر الأنواع شيوعاً [9]، تسبب أورام الدماغ مجموعة متنوعة من الأعراض التي تعتمد على حجم الورم وموقعه في الدماغ، ومن أبرز هذه الأعراض الصداع المستمر، النوبات الصرعية، الغثيان، والتغيرات في الرؤية والكلام والحركة. وتعتبر التشخيص المبكر لأورام الدماغ أمراً حيوياً لتحسين فرص الشفاء، حيث يتيح ذلك اختيار العلاج المناسب [10]. تعتمد طرق تشخيص أورام الدماغ بشكل أساسي على الفحص السريري والتصوير الطبي. يشمل الفحص السريري تقييم الأعراض العصبية، بينما تستخدم التصوير الطبي لتحديد حجم الورم وموقعه وشكله. وتعتبر تقنية التصوير بالرنين المغناطيسي (MRI) هي التقنية الأكثر استخداماً في تشخيص أورام الدماغ، حيث توفر صوراً مفصلة للدماغ بأبعاد ثلاثية. بالإضافة إلى ذلك، يمكن استخدام تقنيات التصوير الأخرى مثل التصوير المقطعي المحوسب (CT) والتصوير المقطعي بالإصدار البوزيتروني (PET) لتقديم معلومات إضافية عن الورم [11, 12]. بعد الحصول على الصور التشخيصية، قد يلجأ الطبيب إلى إجراء الخزعة، وهي عبارة عن أخذ عينة صغيرة من الورم لتحليلها تحت المجهر وتحديد نوعه بدقة [13]. وبناءً على نتائج التشخيص، يتم اختيار العلاج المناسب، والذي قد يشمل الجراحة، العلاج الإشعاعي، العلاج الكيميائي، أو مجموعة من هذه العلاجات.

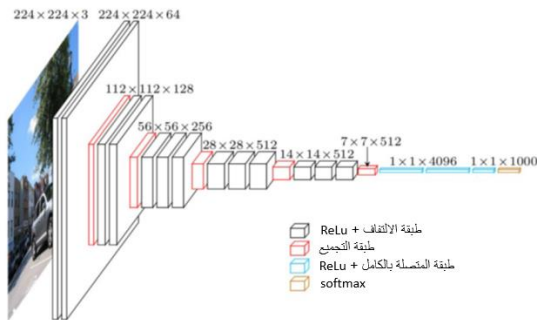
خوارزميات التعلم العميق (DLA)

تعتمد خوارزميات التعلم العميق (DLA) على نوع من الذكاء الاصطناعي والتعلم الآلي الذي يحاكي الطريقة التي يكتسبها البشر المعرفة [7]. عند النظر في التطورات في التصوير بالرنين المغناطيسي للدماغ والتدخلات الحسابية ذات الصلة، يتم إعطاء أهمية مركزية للشبكات العصبية التلافيفية (CNN) والتعلم العميق (DL)، لقد تطورت الشبكات العصبية التقليدية بالفعل أو تطورت إلى أساليب الشبكات العصبية العميقة (DNN) تعتمد الاتصالات في هذه الشبكات على البيانات ويتم إنشاء نوع المنهجية تلقائياً دون أي تدخل، وهو ما يفسر دقة هذه الأنظمة وأدائها الرائع في مختلف المجالات. في الواقع، إنها خوارزمية تعلم عميقة تتكون من عدة خوارزميات عصبية تكتشف تلقائياً ميزات وخصائص البيانات المدخلة قبل تطبيق المعرفة لتطوير التدخلات [14]. الشبكة العصبية التلافيفية (CNN)

التقنيات الحديثة للتصوير الطبي، مثل التصوير بالرنين المغناطيسي (MRI)، ومعالجة الصور الطبية قدمت أدوات قوية لتحليل الأورام الدماغية. ومع ذلك، فإن عملية تحليل صور الرنين المغناطيسي وتشخيص الأورام تعتمد بشكل كبير على خبرة الأطباء، وهي عملية تستغرق وقتاً وتعرض للخطأ البشري. بالمقارنة مع التصوير المقطعي المحوسب (CT) والتقنيات الأخرى، فإن صور التصوير بالرنين المغناطيسي أكثر أمناً ويمكن أن تنتج صوراً أعلى تبايناً للأدمغة [2, 1].

في السنوات الأخيرة، شهدنا تطورات مذهلة في مجال الذكاء الاصطناعي، خاصة في مجال التعلم العميق. وقد أثبتت الشبكات العصبية التلافيفية (CNNs) قدرتها على التعامل مع البيانات المرئية المعقدة وتحقيق نتائج ماهرة في العديد من التطبيقات، بما في ذلك الطب [3]. ومن أبرز هذه التطبيقات هو استخدام الشبكات العصبية التلافيفية (CNNs) في تحليل الصور الطبية، مثل صور الرنين المغناطيسي (MRI). أثبتت هذه الشبكات قدرتها العالية على استخراج الميزات المعقدة من الصور وتصنيفها بدقة [4]. في هذا البحث، نقترح استخدام إحدى أشهر الشبكات العصبية التلافيفية وهي VGG16، لكشف الأورام الدماغية في صور الرنين المغناطيسي، تناولت العديد من الدراسات جوانب مختلفة لتصنيف أورام الدماغ، حيث قدم داكشنامورثي وآخرون في عام 2024 [1] دراسة حول اكتشاف وتصنيف أورام الدماغ باستخدام نماذج التعلم العميق، واقترحت الدراسة نهجاً جديداً لتحسين دقة وكفاءة التشخيص. اعتمدت الدراسة على تقييم ثلاثة نماذج أساسية في مجال الرؤية الحاسوبية وهي AlexNet و VGG16 و ResNet-50. أظهر نموذج VGG16 و ResNet-50 أداءً متميزاً، مما أدى إلى دمجهما في نموذج هجين VGG16-ResNet-50 تم اختياره على مجموعة بيانات حقيقية، حيث أظهرت النتائج أداءً ممتازاً للنموذج في اكتشاف أورام الدماغ وتصنيفها بدقة بلغت %99.98 وحساسية %99.98 ونوعية %99.98 مع درجة F1 مرتفعة %99.98، وفي دراسة بريريبا جاياتري في عام 2023 [5]، تم استكشاف إمكانيات بنية VGG-16 للكشف الدقيق عن أورام الدماغ باستخدام التعلم العميق. استخدمت مجموعة بيانات تتكون من 1655 صورة رنين مغناطيسي لدماغ مصاب بالأورام و 1598 صورة سليمة. تم تدريب نموذج VGG-16 على هذه البيانات، حيث حقق دقة إجمالية قدرها %94 في الكشف عن أورام الدماغ. كما أظهر نموذج VGG-16 أداءً أفضل مقارنة بنماذج أخرى مثل GoogLeNet و ImageNet. وفي دراسة محمود وآخرون في عام 2023 [6] تم تطوير نموذج شبكة عصبية تلافيفية (CNN) تقدمه لتحليل صور الرنين المغناطيسي واكتشاف أورام الدماغ بدقة عالية. تم اقتراح بنية الشبكة العصبية التلافيفية CNN، ومقارنة النماذج المختلفة مثل ResNet-50 و VGG16 و Inception V3. تم اختبار النموذج المقترح على مجموعة بيانات من 3264 صورة رنين مغناطيسي للدماغ، حيث أظهر النموذج المقترح أداءً أفضل من النماذج الأخرى وحقق نتائج تتمثل في دقة %93.3 و AUC بنسبة %98.43، واستدعاء بنسبة %91.19. وفقد قدرها 0.25، وفي ورقة علمية قدمها المدهون وأبو ناصر في عام 2023 [4]، تم تطوير نموذج للكشف عن أورام الدماغ باستخدام تقنيات التعلم العميق وتحليل صور الرنين المغناطيسي (MRI)، حيث تم تدريب النموذج على مجموعة بيانات ضخمة تضم 10000 صورة للكشف عن الأورام، واختباره باستخدام نماذج متعددة مثل Inception و VGG16 و MobileNet

التعميم وتحسين أداء الشبكة على البيانات الجديدة. تعد VGG-16 شبكة عصبية تلافيفية (CNN) تم تطويرها بواسطة Karen Simonyan و Andrew Zisserman في عام 2014 [21] تميزت VGG-16 بعمقها الكبير مقارنة بالشبكات السابقة، مما أدى إلى تحسينات كبيرة في أداء التصنيف على مجموعات بيانات واسعة النطاق. وهو قالب لنموذج CNN المكون من 16 طبقة. ولا يزال يعتبر أحد أفضل النماذج وأكثرها فعالية اليوم. بدلاً من وجود العديد من المعلمات، تركز بنية نموذج VGG 16 على طبقات ConvNet بحجم النواة 3×3 [22] وتكمن أهمية هذا النموذج في حقيقة أن قيمه متاحة مجاناً على الإنترنت ويمكن تنزيلها لاستخدامها في أنظمتها الخاصة و التطبيقات بالمقارنة مع النماذج الأخرى المطورة بالكامل، فهي تتميز ببساطتها. الحد الأدنى لحجم الصورة المدخلة المتوقعة لهذا النموذج هو 224×224 بكسل مع ثلاث قنوات. في الشبكات العصبية، تستخدم خوارزميات التحسين لتقييم ما إذا كان ينبغي تنشيط الخلايا العصبية أم لا من خلال تحديد المجموع المرجح للمدخلات. تنشأ الحاجة إلى وظيفة النواة من تحريض اللاخطية في الخلايا العصبية الناتجة. تعمل الخلايا العصبية في الشبكة العصبية مع الأوزان والتحييزات وعمليات التدريب المرتبطة بها. يتم ضبط أوزان اتصال الخلايا العصبية بناءً على عدم دقة الإخراج. تضيف طبقة الإدخال ووظيفة التنشيط عدم الخطية إلى المدخلات العصبية الاصطناعية، مما يمكنها من التعلم وتنفيذ المهام المعقدة. [23] ويبين الشكل 2 بنية شبكة VGG 16 القياسية




الشكل 2: بنية خوارزمية VGG-16

تم استخدام خوارزمية VGG16 بنجاح في العديد من الدراسات لكشف وتصنيف أورام الدماغ من صور الرنين المغناطيسي. تتمثل الفكرة الأساسية في تدريب الشبكة على مجموعة كبيرة من الصور التي تم تصنيفها مسبقاً إلى صور تحتوي على أورام وأخرى لا تحتوي عليها. بعد التدريب، تصبح الشبكة قادرة على التعرف على الميزات المميزة للأورام في صور جديدة [24].

منهجية البحث

المنهجية المتبعة في هذا البحث والموضحة في الشكل 3 تهدف إلى تطوير نموذج دقيق لتصنيف أورام الدماغ باستخدام خوارزمية VGG16. حيث سيتم التطرق إلى جميع المراحل بدءاً من جمع البيانات وحتى تقييم النموذج. يتم جمع مجموعات البيانات المستخدمة من موقع Kaggle، وهي منصة متخصصة بمشاركة البيانات والتعلم الآلي، وتتكون البيانات من 3000 صورة مصنفة بالتساوي إلى 1500 صورة سليمة و 1500 صورة مصابة بأورام. الشكل 4 يبين بعض من بيانات الصور السليمة والمصابة ومن يتم معالجة الصور المشمولة من خلال سلسلة من الخطوات المتسلسلة

هي نوع خاص من الشبكات العصبية يستخدم لمعالجة البيانات، بخاصة الصور، بكفاءة عالية. تتميز هذه الشبكات بتركيب يشبه الشبكة، مما يجعلها مثالية للتعامل مع البيانات ثنائية الأبعاد، مثل الصور التي يمكن تمثيلها كشبكة من وحدات البيكسل، حققت الشبكات التلافيفية نجاحاً هائلاً في العديد من التطبيقات العملية، من التعرف على الوجه وتصنيف الصور إلى معالجة الفيديو وأنظمة التوصية [15]، يأتي اسم "الشبكة العصبية التلافيفية" من استخدامها لعملية رياضية تسمى "التلافيف". تعتبر عملية التلافيف عملية خطية خاصة تستخدم لتحليل البيانات بطريقة فعالة [16]، وتتكون الشبكات التلافيفية من مجموعات من الخلايا العصبية (النيورونات) التي تنفذ عملية التلافيف بدلاً من عملية الضرب المصفوفي في بعض طبقاتها على الأقل، بفضل هذه الخصائص، تتمتع الشبكات التلافيفية بتطبيقات واسعة النطاق في مجالات متنوعة، مثل التعرف على الصور والفيديو: تستخدم الشبكات التلافيفية لتمييز الأجسام والأشخاص في الصور ومقاطع الفيديو، مما يجعلها تقنية أساسية في أنظمة التعرف على الوجه والتحليل المرئي، أنظمة التوصية: تستخدم الشبكات التلافيفية لتحديد المنتجات أو الأفلام أو الموسيقى التي قد تعجبك بناءً على سلوكك واهتماماتك، ومعالجة اللغات الطبيعية: تستخدم الشبكات التلافيفية لفهم وتحليل النصوص، مثل استخراج المعنى من الجمل وتحديد المشاعر [17]، تعد الشبكات التلافيفية أداة قوية في مجال الذكاء الاصطناعي، ولها دور هام في تطوير تطبيقات ذكية تحدث ثورة في العديد من المجالات، تتكون هذه الشبكات من طبقات متعددة، كل طبقة تؤدي وظيفة محددة. الطبقة التلافيفية هي اللبنة الأساسية، حيث تقوم باستخراج الميزات من الصور عن طريق عملية الالتفاف. تلمها طبقة التجميع التي تعمل على تقليل أبعاد الميزات والحفاظ على المعلومات الأساسية. ثم تأتي الطبقة المتصلة بالكامل التي تقوم بتصنيف الصورة بناءً على الميزات المستخرجة. وأخيراً، تلعب طبقة التسرب دوراً هاماً في منع ظاهرة الإفراط في التوافق وتحسين قدرة الشبكة على التعميم على بيانات جديدة [18,19]. وبشكل عام، تعمل هذه الطبقات معاً بشكل متسلسل لتحقيق أداء عالٍ في مهام مثل تصنيف الصور، والكشف عن الأجسام، وتجزئة الصور. [15] الشكل 1 يبين معمارية شبكة CNN.



الشكل 1: الشبكة العصبية التلافيفية CNN

تشمل الأمثلة الشهيرة على معماريات CNNs شبكات مثل LeNet-5 و AlexNet و VGG-16 و Inception و ResNet [20,18]. تتميز هذه الشبكات بمرونة عالية، حيث يمكن تعديلها وتكييفها لتناسب مجموعة واسعة من المهام والبيانات، تعتمد البنى الحديثة للشبكات العصبية التلافيفية على وحدات قابلة للتكرار، مما يسهل عملية التصميم والتدريب. هذه الوحدات تعمل كمستخرجات ميزات قوية، ويمكن تكرارها عدة مرات لبناء شبكات عميقة قادرة على تعلم ميزات أكثر تعقيداً. كما تساهم هذه البنى في تقليل عدد المعلمات في الشبكة، مما يقلل من خطر الإفراط في

33% من البيانات، تستخدم لتقييم أداء الخوارزمية على بيانات غير مرئية سابقاً.

بناء نموذج خوارزمية الشبكة العصبية VGG16

تم استخدام شبكة عصبية التلافيفية CNN القائمة على خوارزمية VGG16 لتصنيف صور الرنين المغناطيسي. تتكون الشبكة من طبقات متعددة، كل منها تؤدي وظيفة محددة. يستعرض الجدول 1 طبقات خوارزمية VGG16 ومخرجاتها.

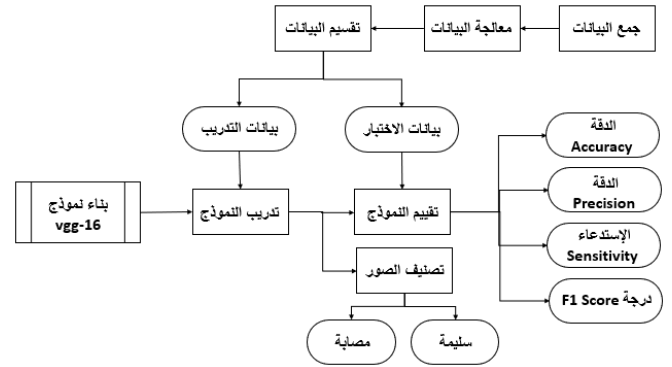
الجدول 1 طبقات خوارزمية VGG-16

مخرجاتها	الطبقة
(224, 224, 3)	طبقة الإدخال Input layer
(224, 224, 64)	Blook1_conv1 (conv2D)
(224, 224, 64)	Blook1_conv2 (conv2D)
(112, 112, 64)	Blook1_pool (Maxpooling2D)
(112, 112, 128)	Blook2_conv1 (conv2D)
(112, 112, 128)	Blook2_conv2 (conv2D)
(56, 56, 128)	Blook2_pool (Maxpooling2D)
(56, 56, 256)	Blook3_conv1 (conv2D)
(56, 56, 256)	Blook3_conv2 (conv2D)
(56, 56, 256)	Blook3_conv3 (conv2D)
(28, 28, 256)	Blook3_pool (Maxpooling2D)
(28, 28, 512)	Blook4_conv1 (conv2D)
(28, 28, 512)	Blook4_conv2 (conv2D)
(28, 28, 512)	Blook4_conv3 (conv2D)
(14, 14, 512)	Blook4_pool (Maxpooling2D)
(14, 14, 512)	Blook5_conv1 (conv2D)
(14, 14, 512)	Blook5_conv2 (conv2D)
(14, 14, 512)	Blook5_conv3 (conv2D)
(7, 7, 512)	Blook5_pool (Maxpooling2D)
512	Global_average_pooling2d (GlobalAveragePooling2D)
1024	Dense (Dense)
1024	Dense_1 (Dense)
512	Dense_2 (Dense)
2	Dense_3 (Dense)


حيث تم استخدام مصفوفة الارتباك لتقييم النموذج المقترح وهي مصفوفة Confusion التي تلعب دوراً هاماً في تقييم أداء نموذج الشبكة العصبية التلافيفية (CNN) المقترح، حيث تقدم هذه المصفوفة تحليلاً تفصيلياً لكيفية تمييز النموذج بين الصور المحتوية على أورام الدماغ (الحالات الإيجابية) والصور الخالية من الأورام (الحالات السلبية). تشتق مصفوفة الارتباك من خلال ربط نتائج تصنيف النموذج بالنتائج الفعلية للمرضى. وتتضمن أربعة إيجابيات حقيقية (TP): تصنيف صور أورام الدماغ بشكل صحيح على أنها تحتوي على أورام، و الإيجابيات الخاطئة (FP): تصنيف صور خالية من أورام الدماغ بشكل خاطئ على أنها تحتوي على أورام، والسلبيات الحقيقية (TN): تصنيف صور خالية من أورام الدماغ بشكل صحيح على أنها سلبية، والسلبيات الخاطئة (FN): تصنيف صور أورام الدماغ بشكل خاطئ على أنها سلبية. من خلال تحليل عناصر مصفوفة الارتباك، يمكن حساب مقاييس أداء من خلال دقة Accuracy، حيث الدقة Accuracy تعطي نسبة العدد الإجمالي للتنبؤات التي كانت صحيحة أي نسبة الصور المصنفة بشكل صحيح، سواء كانت تحتوي على أورام أم لا.

الدقة Precision أو القيمة التنبؤية الإيجابية هي جزء من القيم الإيجابية


والموضحة في الشكل 5 لضمان جودتها وملاءمتها لمرحلة التحليل باستخدام خوارزميات التعلم العميق.



الشكل 3: مخطط كشف وتصنيف أورام الدماغ



الشكل 4: بيانات صور MRI للدماغ




الشكل 5: معالجة البيانات

يتم قراءة الصور باستخدام مكتبة OpenCV، وهي أداة شائعة في مجال معالجة الصور، يتلو ذلك تطبيق مرشح Gaussian Blur لإزالة الضوضاء العشوائية التي قد تؤثر على دقة النتائج. ويتم توحيد صيغة الصور إلى نظام الألوان RGB لضمان اتساق البيانات وللتأكد من أن قنوات الألوان (الأحمر والأخضر والأزرق) مرتبة بشكل صحيح، ثم يتم توحيد حجم جميع الصور إلى (224 × 224 بكسل) لتناسب متطلبات الشبكات العصبية المستخدمة. وأخيراً، يتم تحويل الصور إلى تمثيل رقمي على شكل مصفوفة من الأرقام، حيث تمثل كل قيمة شدة اللون في كل بكسل، مما يبرئ البيانات لدخول مرحلة التدريب في النموذج العميق، وهذا يهدف إلى التحضير المسبق للبيانات إلى ضمان جودة البيانات المدخلة إلى النموذج، وتحسين أداء الخوارزمية، وتقليل تأثير الضوضاء العشوائية على النتائج النهائية، وكذلك تم تطبيع بيانات التدريب والاختبار باستخدام (Normalization)، حيث تم تحويل قيم وحدات بكسل لكل قناة لون إلى نطاق يتراوح بين 0 و 1. تساعد عملية (Normalization)، على تحسين أداء خوارزمية التعلم العميق من خلال جعل قيم البيانات متنسقة على جميع القنوات، حيث يتم تقسيم

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

البيانات إلى مجموعتين: مجموعة بيانات التدريب بنسبة 67% من البيانات، تستخدم لتدريب خوارزمية التعلم العميق. ومجموعة بيانات الاختبار بنسبة

الرين المغناطيسي، حيث تم تقسيم المجموعة البيانات إلى مجموعتي تدريب واختبار بنسبة 33%. وتم تدريب النموذج لمدة 10 دورات وهي قيمة تجريبية جاءت من خلال التجارب السابقة [24]، سيتم عرض النتائج في شكل رسوم بيانية ومصفوفة ارتباك، بالإضافة إلى حساب معايير التقييم الدقة (precision)، التذكر (recall)، ودرجة F1 المتعلقة بكل فئة، الشكل 6 يوضح العلاقة بين أداء النموذج وعدد فترات التدريب على مدار 10 دورات، الشكل 6-أ يبين منحنى الدقة لتدريب واختبار النموذج بينما يبين الشكل 6-ب فقدان التدريب والاختبار للنموذج والموضحة قيمها عند الدورة الأخيرة، في الجدول 2. تظل دقة التدريب مرتفعة جداً وتحافظ على ثباتها حتى تصل إلى الدورة الأخيرة. الثبات في دقة التدريب طوال الدورات يشير إلى عدم وجود مشاكل ملحوظة في تعلم النموذج، مثل الانحياز المفرط (Overfitting). دقة الاختبار تبدأ من مستوى عالٍ وتستقر عند قيمة مقاربة لدقة التدريب في الدورة الأخيرة. على الرغم من أن دقة الاختبار أقل قليلاً من دقة التدريب، إلا أنها تبقى مرتفعة، مما يشير إلى أن النموذج قادر على تعميم المعرفة المستفادة من بيانات التدريب إلى بيانات جديدة لم يرها من قبل. يظهر فقد التدريب انخفاضاً ملحوظاً، حيث يبدأ عند قيمة مرتفعة ثم ينخفض بسرعة إلى قيمة منخفضة في الدورة الأخيرة. فقد الاختبار أيضاً يظهر انخفاضاً تدريجياً، لكنه يبدأ من قيمة مرتفعة وينخفض، على الرغم من أن فقد الاختبار أعلى من فقد التدريب، إلا أن القيمة لا تزال مقبولة وتعكس تحسناً جيداً في أداء النموذج على بيانات الاختبار.



الشكل 6: منحنيات الدقة والفقد لتدريب واختبار النموذج

الجدول 2: قيم الدقة والفقد

دقة التدريب %	فقد التدريب %	دقة الاختبار %	فقد الاختبار %
99.9	0.0030	98.8	0.085

دقة التدريب تمثل نسبة الصور التي تم تصنيفها بشكل صحيح أثناء مرحلة التدريب مقارنةً بإجمالي عدد الصور في مجموعة التدريب. قيمة دقة التدريب التي بلغت 99.9% تشير إلى أن النموذج قد تعلم بشكل جيد من مجموعة التدريب، مما يعكس قوة الخوارزمية في التمييز بين الصور السليمة والمصابة أثناء مرحلة التدريب. فقد التدريب يمثل قيمة الخسارة التي تمثل الفرق بين

من إجمالي الحالات الإيجابية المتوقعة. بمعنى آخر، الدقة هي نسبة القيم الإيجابية التي تم تحديدها بشكل صحيح (قدرة النموذج على تمييز صور أورام الدماغ عن الصور الخالية من الأورام).

$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}} \quad (2)$$

الحساسية أو الاستدعاء أو معدل (TPR) TP هو جزء من القيم الإيجابية من إجمالي الحالات الإيجابية الفعلية أي قدرة النموذج على تحديد جميع صور أورام الدماغ.

$$\text{Recall} = \text{Sensitivity} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (3)$$

درجة F1 أو قياس F هي الوسط التوافقي للدقة والحساسية التي تعطي أهمية لكلا العاملين (مقياس توازن بين الدقة والاستدعاء).

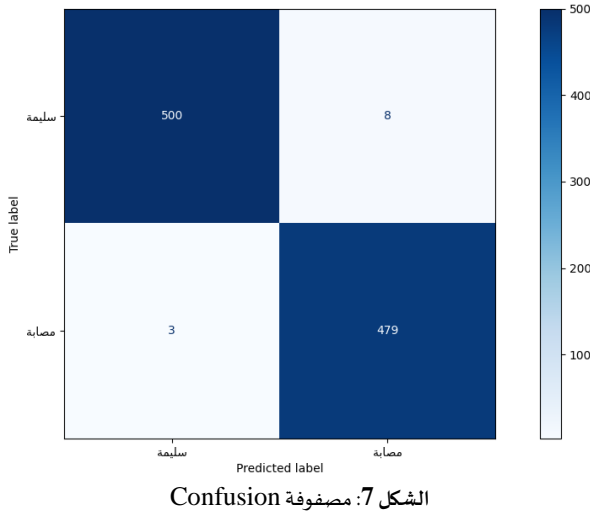
$$\text{F1 score} = 2 \times \left[\frac{\text{Precision} * \text{Sensitivity}}{\text{Precision} + \text{Sensitivity}} \right] \quad (1)$$

اختيار هذه المعايير لأن التوازن بين الدقة والاستدعاء هو أمر بالغ الأهمية في التطبيقات الطبية، حيث أن التقليل من الأخطاء في تصنيف الأورام (الإيجابية) يمكن أن يكون أكثر أهمية من تصنيف صحيح لجميع العينات. مع ذلك، فإن هذه المعايير توفر أيضاً طريقة لقياس أداء النموذج بشكل عام (من خلال الدقة) و موازنته بين الأداء في الفئات المختلفة (من خلال درجة F1). لذلك، يعد استخدام مزيج من الدقة، الاستدعاء، ودرجة F1 مناسباً لتقييم النموذج في سياقات مثل الكشف عن الأورام في الصور الطبية، ويتم تحليل أداء نموذج التعلم العميق وتقييم قدرة النموذج في تصنيف الصور والتمييز بين صور الدماغ السليمة والصور التي تحتوي على أورام، في هذا البحث تم استخدام البايثون كإداة تحليل وهي لغة برمجة عالية المستوى تدعم البرمجة الموجهة للكائنات، وتتميز بسهولة تعلمها وقراءتها. تدعم الوحدات النمطية وإعادة استخدام التعليمات البرمجية، مما يتيح تطوير سريع وصيانة أقل تكلفة. كما أنها مجانية ومتاحة على جميع الأنظمة الرئيسية. كذلك تم استخدام تنسرفلو وهي مكتبة مفتوحة المصدر للمحاكاة العددية، تستخدم في التعلم الآلي والذكاء الاصطناعي. توفر بيئة مرنة لتشغيل العمليات الحسابية على وحدات المعالجة المختلفة. تم تطويرها في الأصل من قبل Google Brain وتدعم لغات برمجة متعددة مثل Python و C، واستخدام كيراس كواجهة برمجة تطبيقات عالية المستوى تستخدم في بناء الشبكات العصبية، ويمكن تشغيلها على TensorFlow أو CNTK. تركز على السرعة وسهولة الاستخدام، وتتيح إنشاء نماذج جديدة بسهولة من خلال دمج مكونات متعددة. توفر بيئة مرنة لدعم الابتكار في التعلم العميق، و كاجل وهي منصة للتعلم الآلي تجمع علماء البيانات وتوفر موارد بيانات ضخمة. تتيح للمستخدمين المشاركة في المسابقات وحل التحديات باستخدام أدوات مثل Pandas. كما توفر بيئة تعاونية لتبادل المعرفة والتعلم من خبراء المجال، المعالجة تمت باستخدام حاسوب يستخدم قرص تشغيل SSD ومعالج Intel(R) Core(TM) i7-10700 CPU 2.90 GHz ، بذاكرة 8.0.

النتائج والمناقشة

تم اختبار النموذج التجريبية التي تم الحصول عليها من تطبيق نموذج VGG16 المدرب مسبقاً على مهمة كشف وتصنيف أورام الدماغ في صور

السليمة والمصابة، يوضح الجدول 4 قيم معايير التقييم للنموذج حيث (الدقة) Precision لصور سليمة: تشير إلى أن 99% من الصور التي تم تصنيفها على أنها سليمة هي بالفعل سليمة. هذا يعكس قوة النموذج في تحديد الصور السليمة بدون تقديم العديد من النتائج الإيجابية الخاطئة.



الشكل 7: مصفوفة Confusion

Recall (التذكر) لصور سليمة: يدل على أن النموذج قام بالكشف عن 98% من الصور السليمة بشكل صحيح. بمعنى آخر، النموذج قادر على استرجاع معظم الصور السليمة من مجموعة البيانات.

الجدول 4: معايير التقييم

معايير التقييم	الدقة Precision	التذكر Recall	درجة F1- Score
صور سليمة	99%	98%	99%
صور مصابة	98%	99%	99%

Score لصور سليمة: هو مقياس لتوازن الدقة والتذكر، وبقية 99%، يدل على أن النموذج يقدم أداءً ممتازاً في تصنيف الصور السليمة، Precision و Recall و F1-Score بالنسبة للصور المصابة (98%، 99%، 99% على التوالي) تشير إلى أن النموذج يقدم أيضاً أداءً ممتازاً في تصنيف الصور المصابة بالأورام، يظهر الشكل 8، نتائج تصنيف مجموعة من الصور العشوائية التي تم اختيارها من مجموعة بيانات الاختبار. كل صورة تحتوي على عنوانين: الأول يشير إلى نتيجة التصنيف، حيث يشير اللون الأخضر إلى تصنيف صحيح واللون الأحمر إلى تصنيف خاطئ، أما الثاني فيظهر التصنيف الفعلي للصور بين قوسين. بشكل عام، أظهرت خوارزمية التعلم العميق أداءً جيداً في تصنيف صور أورام الدماغ، حيث تم تصنيف غالبية الصور بشكل صحيح، بالرغم من وجود بعض الحالات التي تم تصنيفها بشكل خاطئ.

ومن خلال ذلك يمكن القول ان النتائج أظهرت أن نموذج VGG16 المدرب مسبقاً حقق أداءً ممتازاً في مهمة كشف وتصنيف أورام الدماغ في صور الرنين المغناطيسي. تظهر نتائج دقة التدريب والاختبار العالية (99.9% و 98.8% على التوالي) أن النموذج يحقق أداءً ممتازاً في تصنيف صور الرنين المغناطيسي للأورام. النموذج قادر على التعميم بشكل جيد على بيانات الاختبار التي لم يرها أثناء التدريب، مما يعكس فعالية الخوارزمية في التعامل مع بيانات جديدة، الفقد المنخفض (0.0030) في التدريب و 0.085 في الاختبار) يشير إلى أن النموذج قد تم تدريبه بشكل جيد مع الحفاظ على

التوقعات الحقيقية والتوقعات التي تم إنتاجها بواسطة النموذج. فقد التدريب الذي بلغ 0.0030 يعني أن النموذج قد حصل على نتائج دقيقة جداً أثناء التدريب مع انخفاض في القيمة الإجمالية للفقد، وهو ما يشير إلى أداء قوي للنموذج أثناء تعلمه. دقة الاختبار هي النسبة التي يتم فيها تصنيف الصور بشكل صحيح أثناء مرحلة الاختبار مقارنةً بالإجمالي. تبلغ دقة الاختبار 98.8%، مما يعكس قدرة النموذج على تصنيف الصور بدقة عالية خارج مجموعة البيانات التدريبية، وهو أداء ممتاز مقارنة بدراسات أخرى في هذا المجال. يوضح الجدول 3 مقارنة بين نتائج هذه الدراسة وبعض الدراسات السابقة.

الجدول 3: مقارنة النتائج بالدراسات السابقة

عدد الصور المستخدمة	الناتج (%)	النموذج المستخدم	البحث/الدراسة
3000	98.8	VGG16 المدرب مسبقاً	الدراسة الحالية (2025)
غير معروف	دقة: 99.98% حساسية: 99.98% نوعية: 99.98%	VGG16 ResNet-50 الهجين	داكشنامورثي وآخرون (2024)
3253 صورة	دقة: 94%	VGG16	بربريا جاياثري (2023)
3264 صورة	دقة: 93.3% AUC: 98.43%	CNN	محمود وآخرون (2023)
10000 صورة	دقة F1: 98.28%	VGG16, Inception, ResNet50, MobileNet	المدهون وأبو ناصر (2023)

فقد الاختبار بلغ 0.085، وهو أعلى من فقد التدريب، مما يدل على أن النموذج ربما يعاني من بعض التحديات في التعميم على بيانات جديدة خارج مجموعة التدريب. ومع ذلك، يبقى الفقد منخفضاً بشكل عام، مما يعني أن النموذج ما يزال يحافظ على دقة، يوضح الشكل 7 مصفوفة الارتباك التي تم الحصول عليها من تدريب النموذج، تقدم تحليلاً تفصيلياً لكيفية تصنيف النموذج للصور: 500 صورة سليمة تم تصنيفها بشكل صحيح (True Negatives - TN): هذا يعني أن النموذج كان قادراً على تحديد الصور السليمة بدقة عالية، 3 صور سليمة تم تصنيفها بشكل خاطئ على أنها مصابة: (False Positives - FP) هذه الحالات تشير إلى أن النموذج ارتكب خطأ في تصنيف بعض الصور السليمة على أنها تحتوي على أورام. على الرغم من أن هذا الخطأ قليل، إلا أنه يمكن أن يكون ذا تأثير كبير في بعض التطبيقات الطبية، 479 صورة مصابة تم تصنيفها بشكل صحيح (True Positives - TP): هذا يشير إلى أن النموذج نجح في تحديد معظم الصور التي تحتوي على أورام بشكل صحيح، مما يعكس أداءً جيداً في تصنيف الأورام، 8 صور مصابة تم تصنيفها بشكل خاطئ على أنها سليمة (False Negatives - FN): هذه الحالات تعني أن النموذج أخفق في التعرف على الأورام في بعض الصور، وهي مشكلة حرجة في التطبيقات الطبية لأن هذه الأخطاء تعني أن الأورام قد لا يتم اكتشافها وبالتالي قد لا يتلقى المرضى العلاج في الوقت المناسب، إلا أن النسبة الصحيحة لا تزال مرتفعة.

حيث كان الخطأ في تصنيف الصور السليمة 0.6% فقط وفي تصنيف الصور المصابة 1.7%. على الرغم من دقة التصنيف العالية، إلا أن هذه الأخطاء قد تكون نتيجة لوجود حالات غامضة أو حالات شديدة التشابه بين الصور

لاختيار الأنسب للأداء الأمثل، تعديل هيكلية النموذج لتناسب الطبيعة المعقدة للصور الطبية، استخدام تقنيات زيادة البيانات لتعزيز تنوع البيانات التدريبية وتحسين التعميم، تعديل معلمات التدريب مثل معدل التعلم وأعداد الدورات التدريبية للحصول على أفضل نتائج، تطبيق تقنيات النقل الدقيق (Transfer Learning) للاستفادة من النماذج المدربة مسبقاً في مجالات مشابهة، بالإضافة إلى ذلك، يقترح دمج النموذج في أنظمة التشخيص الطبي الساندة، وتطوير واجهة مستخدم سهلة وفعالة لضمان تسهيل تطبيق النموذج في البيئة الطبية العملية.

Author Contributions: "All authors have made a substantial, direct, and intellectual contribution to the work and approved it for publication."

Funding: "This research received no external funding."


Data Availability Statement: "No data were used to support this study."

Conflicts of Interest: "The authors declare that they have no conflict of interest."

References

- [1] V. K. Dhakshnamurthy, M. Govindan, K. Sreerangan, M. D. Nagarajan, A. Thomas, "Brain Tumor Detection and Classification Using Transfer Learning Models", Eng. Proc. 2024, 62, 1. <https://doi.org/10.3390/engproc2024062001>
- [2] P. Gayathri, A. Dhavileswarapu, S. Ibrahim, R. Paul, "Exploring the Potential of VGG-16 Architecture for Accurate Brain Tumor Detection Using Deep Learning", Journal of Computers, Mechanical and Management. (2023, June 06). DOI: 10.57159/gadl.jcmm.2.2.23056
- [3] S. Patil, D. Kirange, "Ensemble of Deep Learning Models for Brain Tumor Detection," Procedia Computer Science, vol. 218, pp. 2468-2479, 2023
- [4] S. Solanki, U. P. Singh, S. S. Chouhan, & S. J. Jain, "Brain Tumor Detection and Classification Using Intelligence Techniques: An Overview", IEEE Access, 99(99), 1-11, 2023. Doi: 10.1109/ACCESS.2023.3242666.
- [5] M.I. Mahmud, M. Mamun, A. Abdelgawad, "A Deep Analysis of Brain Tumor Detection from MRI Images Using Deep Learning Networks", Algorithms 16, 176, 2023. <https://doi.org/10.3390/a16040176>
- [6] H. R. Almadhoun, & S. S. Abu Naser, "Detection of brain tumor using deep learning," International Journal of Academic Engineering Research (IJAER), 6(3), 29-47, 2022. www.ijeais.org/ijaer
- [7] M. Vakalopoulou, S. Christodoulidis, N. Burgos, O. Colliot, & V. Lepetit, "Deep learning: basics and convolutional neural networks (CNN)", Olivier Colliot. Machine Learning for Brain Disorders, Springer, 2023, 10.1007/978-1-0716-3195-9_3. hal-03957224v2.
- [8] D. Lamrani, B. Cherradi, O. El Gannour, M. A. Bouqentari, & L. Bahatti, "Brain Tumor Detection using MRI Images and Convolutional Neural Network," International Journal of Advanced Computer Science and Applications (IJACSA), 13(7), 452, 2022.
- [9] Cancer Council Australia. "Understanding brain tumours: A guide for people with brain or spinal cord tumours, their families and friends," (1st ed.). 2022.
- [10] American Brain Tumor Association, "About brain tumors: A primer for patients and caregivers," (2015). <https://www.abta.org/>
- [11] K. Kabitha, M. Rajan, K. Hegde, S. Koshy, A. Shenoy, "A comprehensive review on brain tumor," International Journal of Pharmaceutical, Chemical and Biological Sciences, 3(4), 1165-117, 2013.
- [12] O. Turk, D. Ozhan, E. Acar, T. C. Akinci, & M. Yilmaz, "Automatic detection of brain tumors with the aid of ensemble deep learning architectures and class activation map indicators

الحد الأدنى من الأخطاء. بالرغم من ذلك، هناك فارق طفيف بين فقد التدريب وفقد الاختبار، وهو أمر طبيعي ويمكن تفسيره بتحديات التعميم على بيانات جديدة، نتائج مصفوفة الارتباك تظهر أن النموذج يحقق أداءً جيداً في تصنيف كلا الفئتين (السليمة والمصابة)، حيث أن معظم الصور تم تصنيفها بشكل صحيح. ومع ذلك، هناك بعض الأخطاء في التصنيف، مثل تصنيف بعض الصور السليمة على أنها مصابة والعكس، ولكن هذه الأخطاء قليلة، معايير التقييم مثل الدقة والتذكر و F1-Score تؤكد فعالية النموذج، حيث يظهر الأداء العالي في كلا الفئتين، السليمة والمصابة.



الشكل 8: نتيجة تصنيف النموذج للأورام

الاستنتاجات

تعتبر نتائج النموذج ممتازة بشكل عام، حيث يقدم أداءً قوياً في تصنيف الصور السليمة والمصابة. الدقة العالية التي تم تحقيقها تشير إلى أن النموذج يمكن استخدامه في تطبيقات عملية لتشخيص الأورام في صور الرنين المغناطيسي، وفي مقارنة مع الدراسات السابقة، تبرز نتائج هذا العمل بمستوى عالٍ من الأداء. على سبيل المثال، حقق النموذج المقترح دقة اختبار بلغت 98.8%، وهو ما يتفوق على العديد من النماذج السابقة مثل نموذج VGG16 في دراسة بريريا جاياثري (2023) [2] التي حققت دقة قدرها 94%، وكذلك نموذج VGG16-ResNet-50، وفي دراسة داكشنامورثي (2024) [1] الذي أظهر دقة 99.98%، والتي تعتبر عالية، ولكن بفارق طفيف عن دقة الاختبار التي تم تحقيقها، بالرغم من الأداء الجيد، هناك مجال للتحسين خاصة في تقليل الأخطاء في تصنيف بعض الصور السليمة على أنها مصابة والعكس. على سبيل المثال في هذا العمل، كانت نسبة الأخطاء في تصنيف الصور السليمة 0.6%، وفي تصنيف الصور المصابة 1.7%، مما يعكس وجود بعض التحديات في التعميم على بيانات جديدة، وهو ما تم ملاحظته أيضاً في الدراسات السابقة، هذا يمكن أن يتحقق عبر تحسينات مثل زيادة حجم مجموعة البيانات أو استخدام تقنيات أخرى للتعامل مع الأخطاء في التصنيف، وتجدر الإشارة إلى أن الدراسات السابقة، مثل دراسة محمود وآخرون (2023) التي استخدمت مجموعة بيانات تضم 3264 صورة، أظهرت أيضاً تحديات في تصنيف الصور بدقة مطلقة. على الرغم من ذلك، فإن التحسينات التي تم تطبيقها في هذا النموذج من حيث زيادة دقة التدريب (99.9%) وفقد التدريب (0.0030) تعكس فعالية الخوارزمية، لتحسين أداء النموذج المقترح في كشف وتصنيف أورام الدماغ، يوصى باتباع، توسيع قاعدة البيانات وتنوعها لتشمل مجموعة أكبر من الحالات والأنماط، تحسين جودة الصور المستخدمة في التدريب من خلال استخدام تقنيات متقدمة لتحسين الصورة، تجربة نماذج شبكات عصبية متنوعة

- [18] K. S. Chandra, A. S. Priya, S. D. Maheshwari, & B. R. Naidu, "Detection of Brain Tumour by integration of VGG-16 and CNN Model," *International Journal of Creative Research Thoughts (IJCRT)*, 8(7), 2020.
- [19] A. E. Abulwafa, "A survey of deep learning algorithms and its applications," *Nile Journal of Communication & Computer Science*, 3(1), 2022.
- [20] I. Aziz, *Deep learning: An overview of convolutional neural network*. Master's thesis, Tampere University, Tampere, Finland, 2020.
- [21] L. Alzubaidi, J. Zhang, A. J. Humaidi, A. Al-Dujaili, Y. Duan, O. Al-Shamma, & L. Farhan, "Review of deep learning: concepts, CNN architectures, challenges, applications, future directions," *Journal of Big Data*, 8(1), 53, 2021. <https://doi.org/10.1186/s40537-021-00444-8>
- [22] A. Jentzen, B. Kuckuck, & P. von Wurstemberger, "Mathematical Introduction to Deep Learning: Methods, Implementations, and Theory", *arXiv preprint arXiv:2310.20360*, (2023, Oct 31).
- [23] A. Singh, R. Deshmukh, R. Jha, N. Shahare, S. Verma, & A. Nilawar, "Brain tumor classification using CNN and VGG16 model," *International Journal of Advanced Research in and Innovation in Education (IJARIE)*, 6(2), 2020.
- by employing magnetic resonance images", 2022. <https://doi.org/10.1016/j.zemedi.2022.11.010> *Brain Tumors: An Introduction Basic Level*. 2009. Mayfield Clinic.
- [13] M. Siar, & M. Teshnehlab, "Brain Tumor Detection Using Deep Neural Network and Machine Learning Algorithm," In *Proceedings of the 9th International Conference on Computer and Knowledge Engineering (ICCKE)*. Ferdowsi University of Mashhad, (2019, October).
- [14] A. M. Sehil, "Image Classification using Deep Learning," Master's thesis, University of Ghardaia, Ghardaia, ALGERIA, 2019.
- [15] P. G. Brindha, M. Kavinraj, P. Manivasakam, & P. Prasanth, "Brain tumor detection from MRI images using deep learning techniques," In *IOP Conference Series: Materials Science and Engineering*, 1055(1), 012115. IOP Publishing. 2021. Doi: 10.1088/1757-899X/1055/1/012115
- [16] A. Chattopadhyay, & M. Maitra, "MRI-based brain tumor image detection using CNN-based deep learning method", *Neuroscience Informatics*, 2, 100060., 2022. <https://doi.org/10.1016/j.neuri.2022.100060>
- [17] A. Mosavi, S. Ardabili, & A. R. Várkonyi-Kóczy, *List of Deep Learning Models*. In A. R. Várkonyi-Kóczy, *INTER-ACADEMIA*, 202–214, 2020. Springer Nature Switzerland AG. https://doi.org/10.1007/978-3-030-36841-8_20