



تصنيف الصور الطبية لمرض الزهايمر باستعمال تقنيات التعلم العميق

الباحث شهد هيثم علي

الباحث احمد طالب عبد الامير

الكلية التقنية الادارية - بغداد

الملخص

تلعب الصور الطبية دوراً مهماً في التشخيص السريري وعلاج الطبيب والتدريس والبحث وما إلى ذلك. يعد مرض الزهايمر هو النوع الأكثر شيوعاً من الخرف، يبدأ عادةً في منتصف العمر أو الشيخوخة، عن طريق تراكم البروتين في الخلايا العصبية وحولها ويؤدي إلى تدهور مطرد في الذاكرة. يتم تصنيف المرضى في المرحلة الأولى من مرض الزهايمر (AD) Alzheimer's disease على أنهم يعانون من ضعف إدراكي معتدل (MCI) Mild Cognitive Impairment، يعتبر الضعف الإدراكي المعتدل MCI يعتبر المرحلة البادئة لمرض الزهايمر. يعد تحديد موضوعات الـ MCI المعرضون لخطر كبير للتحويل إلى AD امراً ضرورياً للعلاجات الفعالة فهناك مرضى MCI يتحولون إلى AD وهناك من يظل مستقر Mild cognitive impairment non-converted (MCI-nc) فليس كل MCI يتحولون إلى AD. تم استخدام خوارزمية التعلم العميق (CNN) لتصنيف صور مرضى (MCI) على أنهم مرضى سيتطورون إلى زهايمر Mild converted cognitive impairment (MCI-c)، أو مرضى (MCI) مستقرين (MCI-nc)، حيث يعد هذا النوع أحد أهم أنواع التصنيف، وذلك لأن MCI يعتبر نافذة تدخلية لوقف التقدم المرضي للمرض لأخذ التدابير الوقائية قدر الامكان حتى قبل حدوث تلف الدماغ الذي لا يمكن اصلاحه. ان هدف هذا البحث هي انشاء نموذج كفاء مطور يساعد الاطباء في تعزيز دقة وسرعة اكتشاف مرض الزهايمر (AD) لأنه امر مهم لبدء العلاج الفعال من اجل ابطاء او منع تطور المرض وبالتالي يمكن للمرضى الحفاظ على استقلاليتهم لفترة أطول. ان طريقة المعالجة المسبقة لصور مرضى MCI التي تطرق اليها الباحث واعداد وتهئية خوارزمية Convolutional Neural Network (CNN) في عملية التعلم العميق أدت الى انشاء نموذج دقته تصل الى 96.67%.

الكلمات المفتاحية

البيانات الطبية، الشبكة العصبية الالتفافية، التعلم العميق، الضعف الإدراكي المستقر MCI-NC، الضعف الإدراكي الغير مستقر MCI-C، مرض الزهايمر AD.

١. المقدمة

الزهايمر (AD) هو النوع الأكثر شيوعاً من الخرف، ويشكل ما يقدر بنحو 60 - 80 % من جميع حالات الخرف. يبدأ عادةً في منتصف العمر أو الشيخوخة، وربما يبدأ عن طريق تراكم البروتين في الخلايا العصبية وحولها، ويؤدي إلى تدهور مطرد في الذاكرة (مرتبط بخلل التشابك العصبي، وانكماش الدماغ، وموت الخلايا). تحدث التغييرات الأولى في الدماغ قبل أن يبدأ الاختلال المعرفي، وقد تصبح بعض المؤشرات الحيوية غير طبيعية في هذه المرحلة المبكرة. تشير الأبحاث إلى أن التغييرات الدماغية المتعلقة بمرض الزهايمر قد تبدأ قبل 20 عاماً على الأقل من ظهور الأعراض يتم تصنيف المرضى في المرحلة الأولى من مرض الزهايمر على أنهم يعانون من ضعف إدراكي معتدل (MCI) [١] الضعف الإدراكي المعتدل (MCI) هو مرحلة انتقالية من الطبيعي إلى الزهايمر، حيث يكون لدى الشخص تغييرات طفيفة في القدرة المعرفية واضحة للشخص المصاب وللقارب ولكنه لا يزال قادراً على أداء الأنشطة اليومية. حوالي 20 - 50 % من الأشخاص الذين تبلغ



أعمارهم 65 عامًا أو أكثر يعانون من الاضعف الإدراكي المعتدل، و 40 - 30 ٪ من الأفراد المصابين بالضعف الإدراكي المعتدل يصابون بمرض الزهايمر في غضون 5 سنوات. يتراوح وقت التحويل من 6 إلى 36 شهرًا ولكنه عادةً 18 شهرًا. يمكن تصنيف مرضى (MCI) بعد ذلك على أنهم أشخاص سيتحولون إلى زهايمر (MCI-C) أو أشخاص مستقرين (MCI-NC). مما يعني أن المريض قد تحول أو لم يتحول إلى الزهايمر (AD) في غضون 18 شهرًا [١]. عادةً ما يُنظر إلى الضعف الإدراكي المعتدل (MCI) على أنه مقدمة لمرض الزهايمر (AD). تشير الدراسات السابقة إلى أن المحور الزمني المرضي لمرض الزهايمر (AD) قد يحدث من عدة سنوات إلى عقود قبل التشخيص السريري. يحدث في البداية دون أي أعراض ثم يتقدم إلى مرحلة (MCI) لذلك، فإن الاحتياط المبكر واكتشاف مرض الزهايمر (AD)، بالإضافة إلى تتبعه والتنبؤ به، لهما أهمية خاصة. يمكن أن يساعد في منع حدوث مرض الزهايمر (AD) أو إبطاء سرعة التدهور العصبي [٢].

٢. الدراسات السابقة

عام 2019 قام كل من Yechong Huan وزملائه باقتراح استخدام خوارزمية التعلم العميق شبكة عصبية تلافيفية (CNN) لدمج جميع المعلومات متعددة الوسائط المضمنة في كل من صور T1-MRI و FDG-PET لمنطقة الحصين، لتشخيص مرض الزهايمر. تختلف هذه الطريقة عن خوارزميات التعلم الآلي التقليدية، وهي لا تتطلب ميزات مستخرجة يدويًا، وبدلاً من ذلك، استخدموا شبكات CNN لمعالجة الصور ثلاثية الأبعاد لتعلم ميزات تشخيص أو تشخيص مرض الزهايمر. المعالجة المسبقة للبيانات تمت عن طريق zxhtools، ثم قاموا بتدريب المصنف باستخدام صور T1-MR و FDG-PET المقترنة في مجموعات بيانات ADNI، بما في ذلك ٧٣١ شخصًا معرفيًا غير معرف المسمى (CN)، و ٦٤٧ شخصًا مصابًا بمرض الزهايمر، و ٤٤١ شخصًا مع استقرار معرفي معتدل. تم الحصول على دقة أعلى بنسبة ٩٠،١٠ ٪ لمهمة CN مقابل AD، و ٨٧،٤٦ ٪ لمهمة CN مقابل MCI-c، و ٧٦،٩٠ ٪ لمهمة MCI-nc مقابل مهمة MCI-c [٣].

في عام ٢٠١٩ قام كل من SilviaBasaia وزملائه قاموا ببناء والتحقق من صحة خوارزمية التعلم العميق التي تتنبأ بالتشخيص الفردي لمرض الزهايمر (AD) والضعف الإدراكي المعتدل الذي سيتحول إلى (MCI-c) AD استنادًا إلى فحص التصوير بالرنين المغناطيسي الهيكلي المقطعي للدماغ. تم تطبيق الشبكات العصبية التلافيفية (CNNs) على صور مرحلة T1 ثلاثية الأبعاد من ADNI والموضوعات المعينين في معهدنا (٤٠٧ عناصر تحكم صحية [HC]، ٤١٨ AD، ٢٨٠ c-MCI، ٥٣٣ s-MCI). تم اختبار أداء CNN في التمييز بين AD و c-MCI و s-MCI، ان المعالجة المسبقة للبيانات تمت على برنامج SPM12، تم تحقيق مستويات عالية من الدقة في جميع التصنيفات، مع تحقيق أعلى المعدلات في اختبارات تصنيف AD مقابل HC باستخدام كل من مجموعة بيانات ADNI فقط (٩٩ ٪) ومجموعة بيانات ADNI + non-ADNI المدمجة (٩٨ ٪). ميزت c-MCI و CNNs من مرضى s-MCI بدقة تصل إلى ٧٥ ٪ ولا يوجد فرق بين صور ADNI وغير صور ADNI. توفر شبكات CNN أداة قوية للتشخيص الفردي للتفاني للمريض على طول سلسلة AD المتصلة. كان أداء هذه الطريقة جيدة جدًا دون أي هندسة سابقة للميزات وبغض النظر عن تنوع بروتوكولات التصوير والمساحات الضوئية، مما يدل على أنه يمكن استغلالها من قبل المشغلين غير المدربين ومن المحتمل أن تكون قابلة للتعميم على بيانات المريض غير المرئية. قد تسرع شبكات CNN من اعتماد التصوير بالرنين المغناطيسي الهيكلي في الممارسة الروتينية للمساعدة في تقييم وإدارة المرضى [4].

في عام 2018 قام كل من Weiming Lin وزملائه بتصميم نهج التعلم العميق القائم على الشبكات العصبية التلافيفية (CNN)، للتنبؤ بدقة بتحويل MCI إلى AD باستخدام بيانات التصوير بالرنين المغناطيسي (MRI) أولاً، يتم تحضير صور التصوير بالرنين المغناطيسي مع تصحيح العمر ومعالجة أخرى. ثانيًا، يتم استخراج بقع محلية، يتم تجميعها في أبعاد ٢،٥، من هذه الصور. عد ذلك، يتم استخدام التصحيحات من AD وعناصر التحكم العادية (NC) لتدريب CNN على تحديد ميزات التعلم العميق لموضوعات MCI. بعد ذلك، يتم استخراج ميزات صورة الدماغ الهيكلية باستخدام FreeSurfer لمساعدة CNN. أخيرًا، يتم تغذية كلا النوعين من الميزات في مصنف آلي متطرف للتنبؤ بتحويل AD. تم التحقق من صحة النهج المقترح على مجموعات بيانات التصوير بالرنين المغناطيسي الموحدة من مشروع مبادرة التصوير العصبي لمرض الزهايمر (ADNI) (يحق هذا الأسلوب دقة تصل إلى ٧٩،٩ ٪ ومساحة تحت منحنى خاصية تشغيل المستقبل (AUC) تبلغ ٨٦،١ ٪ في عمليات التحقق المتصالبة التي تُترك لمرة واحدة. مقارنةً بأحدث الأساليب الأخرى، يتفوق الأسلوب المقترح على الآخرين بدقة أعلى و AUC، مع الحفاظ على توازن جيد بين الحساسية والخصوصية. تظهر النتائج إمكانات كبيرة للنهج المقترح المستند إلى CNN للتنبؤ بتحويل MCI إلى AD باستخدام بيانات التصوير بالرنين المغناطيسي فقط. يمكن أن يؤدي تصحيح العمر وميزات صورة الدماغ الهيكلية المساعدة إلى تعزيز أداء التنبؤ لشبكة CNN [٥].



في عام ٢٠١٩ قام كل من Rachna Jain وزملائه باستخدام نموذج رياضي PFSECTL يعتمد على التعلم في النقل حيث يتم استخدام بنية CNN، حيث يتم استخدام VGG-16 المدربة على مجموعة بيانات ImageNet كمستخرج ميزة لمهمة التصنيف. للمعالجة المسبقة تم استخدام FreeSurfer، تم إجراء التجارب على البيانات التي تم جمعها من قاعدة بيانات مبادرة التصوير العصبي لمرض الزهايمر (ADNI). دقة التصنيف ثلاثي الاتجاهات باستخدام الطريقة الموصوفة هي ٩٥,٧٣٪ لمجموعة التحقق من الصحة [٦].

في عام 2020 قام كل من Manu Raju وزملائه اقترح تصنيفاً متعدد الفئات لـ AD، والضعف الإدراكي المعتدل (MCI)، وموضوعات التحكم العادي (NC) باستخدام شبكة عصبية تلافيفية ثلاثية الأبعاد مع مصنف دعم Vector Machine. تم إجراء دراسة مقطعية على بيانات التصوير بالرنين المغناطيسي الهيكلية لـ ٤٦٥ شخصاً، بما في ذلك ١٣٢ مريضاً بمرض AD و ١٨١ MCI و ١٥٢ NC. يتم استخراج أنماط الضمور المكاني شديدة التعقيد للدماغ المرتبطة بمرض الزهايمر و MCI من صور التصوير بالرنين المغناطيسي باستخدام طبقات متتالية من الشبكة العصبية التلافيفية ثلاثية الأبعاد. يتم التخلص من عملية التجزئة المحمومة والاستخراج الإضافي للميزات المصنوعة يدوياً. يتم أخذ الصورة الكاملة في الاعتبار للمعالجة (FreeSurfer)، وبالتالي دمج كل منطقة في الدماغ من أجل التصنيف. يتم تغذية الميزات المستخرجة باستخدام أربع طبقات متتالية من الشبكة العصبية التلافيفية ثلاثية الأبعاد في مصنف Support Vector Machine الطريقة المقترحة حققت دقة ٩٧,٧٧٪ متفوقة على أحدث التقنيات، وهذه الخوارزمية هي مؤشر واعد لتشخيص مرض الزهايمر [٧].

٣. التعلم العميق Deep Learning

التعلم العميق (المعروف أيضاً باسم التعلم المنظم العميق أو التعلم الهرمي أو التعلم الآلي العميق) هو دراسة الشبكات العصبية الاصطناعية وخوارزميات التعلم الآلي ذات الصلة التي تحتوي على أكثر من طبقة مخفية واحدة. فالشبكة العميقة هي جزء من مجال التعلم الآلي الأوسع لتمثيلات التعلم. تعلم مستويات متعددة من التمثيلات التي تتوافق مع مستويات مختلفة من التجريد. المستويات تشكل تسلسل هرمي للمفاهيم. في حالة بسيطة، قد تكون هناك مجموعتان من الخلايا العصبية مجموعة تستقبل إشارة دخل والأخرى ترسل إشارة خرج. عندما تتلقى طبقة الإدخال مدخلات، فإنها تمرر نسخة معدلة من المدخلات إلى الطبقة اللاحقة.

تم تطبيق العديد من بنى التعلم العميق مثل الشبكات العصبية العميقة والشبكات العصبية التلافيفية وشبكات المعتقدات العميقة والشبكات العصبية المتكررة على مجالات مثل رؤية الكمبيوتر، التعرف التلقائي على الكلام، معالجة اللغة الطبيعية، والتعرف على الصوت والمعلوماتية الحيوية حيث ثبت أنها تقدم نتائج متطورة في مهام مختلفة [8].

٣,١ مكونات بناء الشبكة العصبية الالتفافية CNN

في هذا الجزء، يتم إدخال الصور مباشرة في خوارزمية الشبكة العصبية الالتفافية (CNN) وهذا الشيء ساعد في الحصول على نتائج جيدة ولكن إذا لم تكن الصورة جيدة فقد يفقد التغيير التعرف على الخوارزمية والتعلم. تقسيم الصور على الفصول وكل فصل يحتوي على صور لها ويتم حفظ الصور لكل فصل على حدة وبشكل إجمالي ولكل مجموعة فرق في عدد الصور لماذا قدم عدد متساوي من الصور للمجاميع. تم اعتبار شبكات CNNs متعددة الطبقات NNs تتعرف بشكل مباشر على الأنماط المرئية من وحدات البكسل للصورة التي تم التعرف عليها من حيث القوة إلى التشويه. الطبقات هي [٨].

٣,١,١ طبقة الالتواء Convolution Layer

تم تحديد معلمات هذه الطبقة من خلال أحجام الخرائط وأحجام النواة وعدد الخرائط، كل طبقة بها خرائط M بحجم متساو (M,M,C) التي تمثل (القنوات، العرض، الارتفاع). كما تم توصيل كل واحدة من الخرائط الموجودة في الطبقة Ln بجميع الخرائط الموجودة في الطبقة Ln + 1. الخلايا العصبية المرتبطة بخريطة تشارك قيم وزنها، ولكن لديها حقول إدخال مختلفة. كانت السمة الرئيسية لعملية الالتفاف هي مشاركة الوزن: تمت مشاركة النواة عبر جميع مواضع الصورة [٩].

٣,١,٢ طبقة الحشو Padding Layer

بشكل عام، باستخدام حبات صغيرة، من أجل بعض الالتواءات، قد يؤدي ذلك إلى فقد بعض وحدات البكسل، ومع ذلك قد يؤدي ذلك إلى تطبيق طبقات التفاف لاحقة مختلفة. أحد الحلول الأساسية لهذه المشكلة هو إضافة المزيد من وحدات البكسل من الحشو حول حدود الصورة المدخلة، وبالتالي زيادة الحجم الفعال للصور [٩].

٣,١,٣ الحد الأقصى للتجمع Max-Pooling

مقارنة بالطبقات التلافيفية، يشتمل مشغل التجميع على نافذة ذات شكل ثابت تنزلق على جميع مناطق الإدخال بناءً على خطوتها، وتقدير ناتجاً واحداً فيما يتعلق بكل موقع من المواقع التي تم اجتيازها من خلال نافذة الشكل الثابت (يشار إليها غالباً



كنافاذة تجميع). ومع ذلك ، على عكس حساب الارتباط المتبادل فيما يتعلق بالنواة والمدخلات في طبقة الالتواء ، لا تتضمن طبقة التجميع أي معلمات (بدون مرشح). ومع ذلك ، تم اعتبار عوامل التجميع على أنها حتمية ، وتحسب عمومًا إما متوسط الحد الأقصى لقيمة العناصر في نافذة التجميع ، وقد تمت الإشارة إلى هذه العمليات على أنها متوسط التجميع أو التجميع الأقصى[٩].

٣,١,٤ تسوية التسرب Dropout regularization

يشير مصطلح "التسرب" إلى ترك الخلايا العصبية (المخفية والمرئية) في الشبكة العصبية بشكل عشوائي. لمعالجة مشكلة فرط التجهيز في الشبكات العصبية بشكل أساسي. يحدد التسرب في الشبكة العصبية ناتج جزء معين من الخلايا العصبية في طبقة مخفية ، والتي تصورها نسبة التسرب إلى ٠ ، ونسبة الانسحاب ليست سوى احتمال أن يتم استبعاد خلية عصبية في طبقة معينة. ومن ثم ، إذا تم ضبطه على ١ لطبقة مخفية ، فإن جميع الخلايا العصبية في تلك الطبقة المخفية المعينة ستخرج ٠. الخلايا العصبية التي تم إسقاطها لا تساهم في المرور الأمامي وخطوات الانتشار العكسي[6].

3.1.5 الاتصال الكامل Fully Connection


كانت خرائط معالم المخرجات المتعلقة بطبقة التجميع أو طبقة الالتواء النهائية بشكل عام، مثل تحويلها إلى مصفوفة D من 1 من الأرقام (أو المتجه) ، فضلاً عن كونها متصلة بطبقات واحدة متصلة بالكامل على الأقل ، يشار إليها أيضاً باسم الطبقات الكثيفة ، حيث تم توصيل كل مدخل من المدخلات بكل مخرج من خلال الوزن القابل للتعلم. بمجرد استخراج الميزات عبر طبقات الالتفاف وتم إنشاء عينات لأسفل من خلال طبقات التجميع ، تم تعيينها عبر مجموعة فرعية من الطبقات المتصلة بالكامل إلى مخرجات الشبكة النهائية ، بما في ذلك احتمالات كل فئة من الفئات في مهمة التصنيف. علاوة على ذلك ، تشتمل الطبقة النهائية المتصلة بالكامل على قدر مماثل من عُقد الإخراج لعدد الفئات[٩].

3.1.6 الطبقات غير الخطية Non-linear layers

وظيفة التنشيط هي الجزء الرئيسي من الخوارزمية من أجل العثور على أفضل حل وهي مناسبة لي لإكمال سلسلة المعادلات. هناك أنواع مختلفة من وظائف التنشيط ولكل نوع عمل معين. في هذا العمل ، تم استخدام وظيفة تنشيط هي (SOFTMAX و RELU)[٩].

3.2 مجموعة البيانات

تم الحصول على البيانات المستخدمة من مبادرة التصوير العصبي لمرض الزهايمر (ADNI) تم إطلاق ADNI في عام ٢٠٠٣ كشراكة بين القطاعين العام والخاص، بقيادة الباحث الرئيسي Michael W. Weiner ، MD. كان الهدف الأساسي لـ ADNI هو اختبار ما إذا كان يمكن الجمع بين التصوير بالرنين المغناطيسي التسلسلي (MRI) والتصوير المقطعي بالإصدار البوزيتروني (PET) والعلامات البيولوجية الأخرى والتقييم السريري والنفسي العصبي لقياس تطور الضعف الإدراكي الخفيف (MCI) والمراحل المبكرة. مرض الزهايمر. صور ال (MRI) (3D MRI) ذات الثلاث شرائح (سهمة ، محوري ، اكلكي). حيث تم تقسيم الصور MRI إلى مجموعة من ال MCI -C classes الذين سيتحولون إلى AD خلال 6 أشهر، والذين سيتحولون إلى AD خلال ١٢ شهر، والذين سيتحولون إلى AD خلال ١٨ شهر، والذين سيتحولون إلى AD لكن لا يوجد وقت للتحويل ، والذين سيتحولون إلى AD خلال ٣٦ شهر ، وهناك من سيتحول إلى AD لكن لا يوجد وقت محدد. اما MCI-NC classes يكون من class واحد هو الذين لم يتحولوا إلى AD المستقرين يحوي كل class على (100) عينة.



شكل (١): يمثل صورة MRI لاحد مرضى MCI

3.2.1 المعالجة المسبقة للبيانات

تعد المعالجة المسبقة خطوة أولى مهمة الهدف من المعالجة المسبقة هو تحسين جودة الصورة حتى نتمكن من تحليلها بشكل أفضل من خلال المعالجة المسبقة للصورة نتمكن من قمع التشوهات غير المرغوبة. وتتمثل المعالجة المسبقة هنا بخطوات إزالة الجمجمة لاستخراج الدماغ وإزالة الضوضاء وتحسين الصور للشرائح الثلاث، ثم في بادئ الأمر عزل الشرائح الثلاث عن بعضها البعض بعد اتمام المعالجة والتحسينات تم إعادة الدمج، ان معالجة الشريحة السهمية تختلف في خطواتها بعض الشيء من المحور والاكليكي وهي كما يلي:

- الخطوة الاولى التي تم القيام بها في المعالجة المسبقة هي تحسين تباين الصور الرنين المغناطيسي MRI اول خطوة يتم القيام بها تحسين التباين ثم يتم تطبيق خطوات (Morphology) [١٠]، حيث تستخدم عملية ال closing لإزالة التفاصيل المظلمة في الصورة ، والحفاظ نسبياً على الأجزاء الساطعة غير متأثرة. ثم يتم اجراء عملية التآكل Erosion قد استخدمنا التآكل لإزالة وحدات البكسل الموجودة على حدود التصوير بالرنين المغناطيسي للدماغ MRI ويستخدم أيضاً للقضاء على المناطق غير الدماغية مثل السحايا والجمجمة وتم ذلك عن طريق التواء convolution العنصر الهيكلي على منطقة الاهتمام. يؤدي التآكل إلى تقليص المناطق المضنية تضخيم المناطق المظلمة. لتحديد مناطق الاهتمام اي object، يتم فصل ال object عن الخلفية السوداء عن طريق استخدام خوارزمية حد العتبة otsu thresholding [١١]، يتم بعد ذلك العثور على اكبر منطقة باستخدام طريقة connecting component label [١٢]، حيث يتم عن طريقها تسمية كل object ثم يتم احصاء كل منطقة للمناطق الثلاثة ، اكبر احصاء للمناطق الثلاثة تكون هي الدماغ اي اختيار اكبر منطقة ستكون هي القناع و اهمال بقية المناطق يتم مرة اخرى تطبيق عملية المورفولوجية الغلق closing لكن على القناع الذي تم تصميمه ليزيل الثقوب الموجودة في المنطقة التي تم اختيارها . وبذلك تعتبر عملية استخراج الدماغ من الجمجمة والاجزاء الاخرى الغير دماغية قد اكتملت.

- إزالة الضوضاء Noise Removing تكمن طرق إزالة الضوضاء التي تطرق لها الباحث باستخدام ثلاث انواع من الفلاتر حيث الضوضاء تسبب مشكلة التصنيف لتصبح أكثر صعوبة. تعد إزالة الضوضاء مرحلة مهمة للغاية حيث يتم تحسين البيانات بعد التنفيذ يمكننا رؤيتها بشكل أكثر وضوحاً باستعمال الفلاتر الاتية:

❖ **Mean Filter** : هنا يحسب الفلتر وسط الحسابي قيمة الصورة التالفة في منطقة محددة مسبقاً. ثم يتم استبدال قيمة كثافة البكسل المركزي بتلك القيمة الوسط. فلتر الوسط الحسابي هو فلتر مكاني بسيط، إنها فلاتر النافذة المنزلقة التي تحل محل القيمة المركزية في النافذة [١٣].

(١)

$$f(x,y) = \frac{1}{mn} \sum_{(m,n) \in w} I(m,n)$$

- ❖ **Median Filter** : يتم استخدام فلتر الوسيط لتقليل مقدار تباين الكثافة بين بكسل واحد والبكسل الآخر. في هذا الفلتر ، تستبدل قيمة البكسل بقيمة الوسيط. ثم يتم حساب الوسيط بفرز جميع قيم البكسل أولاً بترتيب تصاعدي ثم استبدال البكسل الذي يتم حسابه بقيمة البكسل الأوسط [١٣].



❖ **فلتر الغاوسي Gaussian Filter:** يسمى فلتر الغاوسي ب Gaussian Blur يعتمد فلتر Gaussian على معادلة Gaussian، ويمكن استخدامه لإنشاء نواة. النواة kernel عبارة عن مصفوفة (صغيرة) وهي عبارة عن مصفوفة معقدة تستخدم في تقنيات تصفية الصور المختلفة للنقش والتنعيم والشحذ والتمويه وما إلى ذلك. يمكن تطبيق Gaussian Blur لعمليات التنعيم أو التصفية [١٤].

(2)

$$G(x,y) = \frac{1}{2\pi\sigma^2} e^{-\frac{x^2+y^2}{2\sigma^2}}$$

3.3 التصنيف باستخدام CNN

بعد اتمام خطوات المعالجة المسبقة لكل شريحة من الشرائح الثلاثة تم اعادة دمج الشرائح الثلاثة مرة اخرى لتكون شريحة واحدة للثلاث انواع (السهمي والمحوري والاكليكي). فقد تم تقليص حجم الشريحة بشكل مناسب لإدخالها للنموذج فكانت الشرائح بحجم 64 x 64. تمثل الخطوات المهمة التي قام بها الباحث لأعداد وتهيئة النموذج وذلك بتقسيم البيانات الى (80%) Training و (20%) Testing والتي تعتبر الخطوة الاولى المهمة. في الشبكة العصبية التلافيفية، تشتمل الطبقات المخفية على طبقات تؤدي عمليات تلافيف. يشتمل هذا عادةً على طبقة تؤدي منتجاً نقطياً لنواة الالتواء مع مصفوفة إدخال الطبقة. طبقات تلافيفية في CNN، يكون الإدخال: (عدد المدخلات) x (ارتفاع الإدخال) x (عرض الإدخال) x (قنوات الإدخال). بعد المرور عبر طبقة تلافيفية، تصبح الصورة مجردة لخريطة المعالم، وتسمى أيضاً خريطة التنشيط، بالشكل: (عدد المدخلات) x (ارتفاع خريطة المعالم) x (عرض خريطة المعالم) x (قنوات خريطة المعالم). تقوم الطبقات التلافيفية بلف المدخلات وتمرير نتيجتها إلى الطبقة التالية. يتحكم Stride في كيفية تخصيص أعمدة العمق حول العرض والارتفاع. إذا كانت الخطوة ١، فإننا ننقل المرشحات بكسلاً واحداً في كل مرة، تلي طبقات الالتفاف طبقات التجميع قد تتضمن الشبكات التلافيفية طبقات تجميع جنباً إلى جنب مع الطبقات التلافيفية التقليدية. تعمل طبقات التجميع على تقليل أبعاد البيانات من خلال دمج مخرجات مجموعات الخلايا العصبية في طبقة واحدة في خلية عصبية واحدة في الطبقة التالية.


يجمع التجميع المحلي بين مجموعات صغيرة، وتستخدم بحجم ٢ × ٢. يعمل التجميع العالمي على جميع الخلايا العصبية في خريطة المعالم يستخدم Max pooling القيمة القصوى لكل مجموعة عصبية محلية في خريطة المعالم. طبقة متصلة بالكامل بعد عدة طبقات تلافيفية وتجميع قصوى، يتم التصنيف النهائي عبر طبقات متصلة بالكامل. الخلايا العصبية في طبقة متصلة بالكامل لها اتصالات بجميع التنشيطات في الطبقة السابقة تربط الطبقات المتصلة بالكامل كل خلية عصبية في طبقة واحدة بكل خلية عصبية في طبقة أخرى. تمر المصفوفة المسطحة عبر طبقة متصلة بالكامل. ووظيفة التنشيط الخاصة به هي عادة ReLU ولتصنيف الصور تمنح مصنفات Softmax الاحتمالات لكل تسمية فئة.

٤. نتائج تجريبية

تم بناء نموذج التصنيف باستخدام Keras واجهة برمجة تطبيقات للشبكات العصبية عالية المستوى، مكتوبة بلغة Python النتائج التي تم التوصل اليها الباحث نتيجة تهيئة واعداد نموذج التعلم العميق CNN والمتمثلة بدقة التصنيف Accuracy الدقة هي مقياس يصف بشكل عام كيفية أداء النموذج في جميع الفئات. يكون مفيداً عندما تكون جميع الفئات ذات أهمية متساوية. يتم حسابها على أنها النسبة بين عدد التنبؤات الصحيحة إلى العدد الإجمالي للتنبؤات

$$Accuracy = \frac{True\ positive + True\ negative}{True\ positive + True\ negative + False\ positive + False\ negative} \quad (3)$$

| Epoch | Accuracy | the minute | Loss |
|-------|----------|------------|--------|
| 50 | 96.67% | 53 m | 0.0278 |



شكل (2): جدول النتائج

٥. الاستنتاجات

استخدام صور MRI لمرضى MCI للتنبؤ بتحويل مرضى MCI الى AD امر مهم جدا لأخذ التدابير الوقائية والعلاج بأسرع وقت ممكن قبل التحويل للتكس العصبي. البداية الاولى المعالجة المسبقة المتمثلة بتجريد الجمجمة استخراج الدماغ من الجمجمة باستخدام طريقة Morphology. ازالة الضوضاء باستخدام فلاتر لهذا النوع من الصور الطبية (mean, median, Gaussian) وذلك لإزالة الضوضاء الأكثر شيوعا. اعداد وتهيئة نموذج خوارزمية التعلم العميق D-CNN لصور MRI ذات ثلاث شرائح يعتبر بما يناسب من هذا النوع من الصور الطبية مما انتج نموذج كفوء في التصنيف، حقق دقة ٩٦,٦٧٪.

Reference

- [1] M. A. Ebrahimighahnavieh, S. Luo, and R. Chiong, "Deep learning to detect Alzheimer's disease from neuroimaging: A systematic literature review," *Computer methods and programs in biomedicine*, vol. 187, p. 105242, 2020.
- [2] Y. Zhang, S. Liu, and X. Yu, "Longitudinal structural MRI analysis and classification in Alzheimer's disease and mild cognitive impairment," in *International Journal of Imaging Systems and Technology* vol. 30, ed, 2020, pp. 421-433.
- [3] Y. Huang, J. Xu, Y. Zhou, T. Tong, X. Zhuang, and A. s. D. N. Initiative, "Diagnosis of Alzheimer's disease via multi-modality 3D convolutional neural network," *Frontiers in Neuroscience*, vol. 13, p. 509, 2019.
- [4] S. Basaia, F. Agosta, L. Wagner, E. Canu, G. Magnani, R. Santangelo, M. Filippi, and A. s. D. N. Initiative, "Automated classification of Alzheimer's disease and mild cognitive impairment using a single MRI and deep neural networks," *NeuroImage: Clinical*, vol. 21, p. 101645, 2019.
- [5] W. Lin, T. Tong, Q. Gao, D. Guo, X. Du, Y. Yang, G. Guo, M. Xiao, M. Du, and X. Qu, "Convolutional neural networks-based MRI image analysis for the Alzheimer's disease prediction from mild cognitive impairment," *Frontiers in Neuroscience*, vol. 12, p. 777, 2018.
- [6] R. Jain, N. Jain, A. Aggarwal, and D. J. Hemanth, "Convolutional neural network based Alzheimer's disease classification from magnetic resonance brain images," *Cognitive Systems Research*, vol. 57, pp. 147-159, 2019.



- [7] M. Raju, V. P. Gopi, V. Anitha, and K. A. Wahid, "Multi-class diagnosis of Alzheimer's disease using cascaded three dimensional-convolutional neural network," *Physical and Engineering Sciences in Medicine*, vol. 43, pp. 1219-1228, 2020.
- [8] P. Ongsulee, "Artificial intelligence, machine learning and deep learning," in *2017 15th International Conference on ICT and Knowledge Engineering (ICT&KE)*, 2017, pp. 1-6.
- [9] D. Sarvamangala and R. V. Kulkarni, "Convolutional neural networks in medical image understanding: a survey," *Evolutionary intelligence*, pp. 1-22, 2021.
- [1٠] R. E. W. I. Rafael C. Gonzalez University of Tennessee *Digital Image Processing*. google, 2018.
- [1١] J. Yousefi, "Image binarization using otsu thresholding algorithm," *Ontario, Canada: University of Guelph*, 2011.
- [1٢] K. Schwenk and F. Huber, "Connected Component Labeling algorithm for very complex and high-resolution images on an FPGA platform," in *High-Performance Computing in Remote Sensing V*, 2015, p. 964603.
- [1٣] F. Mohd Padzil, "Linear and nonlinear filter for image processing using MATLAB's image processing toolbox," Murdoch University, 2016.
- [1٤] B. Desai, U. Kushwaha, S. Jha, and M. S. C. S. s. NMIMS, "Image filtering-Techniques Algorithms and Applications," *Applied GIS*, vol. 7, p. 101, 2020.

Abstract

Medical images play an important role in clinical diagnosis, physician treatment, teaching, research, and others. Alzheimer's disease is the most common type of dementia, usually beginning in middle or old age, by accumulating protein in and around nerve cells and causing a steady decline in memory. Patients in the first stage of Alzheimer's disease (AD) are categorized as having Mild Cognitive Impairment (MCI). MCI is considered to be a prodromal stage of Alzheimer's disease. Identification of MCI subjects at high risk of developing AD is important. It is necessary for effective treatments, as there are MCI patients who convert to AD and there are those who remain stable (Mild Cognitive Impairment Non-Converted MCI-nc). Not all MCI converts to AD. A deep learning algorithm (CNN) was used to classify images of MCI patients as Mild cognitive impairment converted (MCI-c) or stable MCI patients (MCI-nc), because MCI is considered an intrusive window to stop the pathological progression of the disease to take preventive measures as much as possible even before irreversible brain damage occurs. The goal of this research is to create an efficient and improved model that helps clinicians enhance the accuracy and speed of detection of Alzheimer's disease (AD) because it is important to initiate effective treatment in order to slow or prevent disease progression and thus patients can maintain their independence for a longer period. The method of preprocessing images of MCI patients, which was discussed by the researcher, and the preparation and configuration of the Convolutional Neural Network (CNN) in deep learning algorithm, lead to model that achieved an accuracy of 96.67%.