

تحليل صور الرنين المغناطيسي لمرض الزهايمر باستخدام تحسين التباين والشبكات العصبية

م. علي سليمان*، د. عبد الكريم السالم**

*طالب ماجستير، قسم هندسة الإلكترونيات والاتصالات، كلية الهندسة الميكانيكية والكهربائية، جامعة حمص **أستاذ في قسم هندسة الإلكترونيات والاتصالات، كلية الهندسة الميكانيكية والكهربائية، جامعة حمص

الملخص

يُعدّ مرض الزهايمر Alzheimer's Disease – AD اضطرابًا تنكسيًا عصبيًا تدريجيًا يشكّل تحديًا كبيرًا لأنظمة الرعاية الصحية على مستوى العالم. ولا تزال عملية التصنيف المبكر والدقيق لمراحل المرض باستخدام التصوير بالرنين المغناطيسي MRI مهمة صعبة، وذلك بسبب الفروق البنوية الطفيفة بين مراحل المرض، وانخفاض تباين الصور.

يقترح هذه البحث إطارًا محسنًا قائمًا على صور الرنين المغناطيسي لتصنيف مرض الزهايمر متعدد المراحل، حيث يدمج بين تحسين التباين وتقنيات التعلّم العميق واستراتيجيات التصنيف الهجين. ولتحسين جودة الصور وإبراز البنى التشريحية ذات الأهمية التشخيصية، يتم تطبيق معادلة تسوية الهيستوغرام التكيفي ذات التوزيع الغاوسي

Gaussian-based Contrast-Limited Adaptive Histogram Equalization – G-CLAHE

خلال مرحلة المعالجة المسبقة. بعد ذلك، تُستخدم الشبكة العصبية الالتفافية

Convolutional Neural Network – CNN لاستخلاص تمثيلات عميقة للميزات من الصور المحسنة. وفي مرحلة التصنيف، تم استخدام كلٍّ من نموذج CNN مستقل، وإطار تصنيف هجين يجمع بين CNN وآلة متجه الدعم CNN-SVM.

تم تقييم المنهجية المقترحة باستخدام مجموعة بيانات عامة لصور الرنين المغناطيسي، حيث يتم تصنيف الحالات إلى أربع فئات: طبيعي إدراكيًا، ضعف إدراكي بسيط مبكر، ضعف إدراكي بسيط متأخر، ومرض الزهايمر. أظهرت النتائج التجريبية أن تحسين التباين يسهم بشكل ملحوظ في زيادة

تحليل صور الرنين المغناطيسي لمرض الزهايمر باستخدام تحسين التباين والشبكات العصبية قابلة تمييز الميزات. وقد حقق نموذج CNN المستقل دقة تصنيف كلية بلغت 96%، في حين أظهر النموذج الهجين CNN-SVM تحسناً إضافياً في الأداء، محققاً دقة 97% مع قيم استرجاع أعلى ومثانة أفضل، لا سيما في تصنيف المراحل المرضية ضعيفة التمثيل. الكلمات المفتاحية: مرض الزهايمر، الشبكة العصبية الالتقافية، تحسين التباين، التعلّم العميق، التصوير بالرنين المغناطيسي، آلة متجه الدعم.

MRI Image Analysis for Alzheimer's Disease Using Contrast Enhancement and Neural Networks

Abstract:

Alzheimer's disease - AD is a progressive neurodegenerative disorder that poses a significant challenge to healthcare systems worldwide. Early and accurate classification of AD stages using magnetic resonance imaging-MRI remains difficult due to subtle structural differences between disease stages, low image contrast.

This paper presents an enhanced MRI-based framework for multi-stage Alzheimer's disease classification that integrates contrast optimization with deep learning and hybrid classification strategies. To improve image quality and highlight diagnostically relevant anatomical structures, a Gaussian-based Contrast-Limited Adaptive Histogram Equalization -G-CLAHE technique is applied during preprocessing. A convolutional neural network - CNN is then employed to extract deep feature representations from the enhanced images. For classification, both a standalone CNN model and a hybrid CNN-Support Vector Machine CNN-SVM framework are investigated.

The proposed approach is evaluated on a publicly available MRI dataset and classifies subjects into four categories: cognitively normal, early mild cognitive impairment, late mild cognitive impairment, and Alzheimer's disease. Experimental results demonstrate that contrast enhancement significantly improves feature discriminability. The standalone CNN achieves an overall classification accuracy of 96%, while the hybrid CNN-SVM model further improves performance, reaching 97% accuracy with

higher recall and robustness, particularly for underrepresented disease stages.

Keywords: Alzheimer's disease, convolutional neural networks, contrast enhancement, deep learning, magnetic resonance imaging, support vector machine

1. المقدمة:

يُعدّ مرض الزهايمر Alzheimer's Disease – AD أكثر الاضطرابات التنكسية العصبية انتشارًا، والسبب الرئيسي للخرف على مستوى العالم. ويتميز بتدهور معرفي تدريجي، وضعف في الذاكرة، وتراجع في الوظائف الإدراكية، مما يؤدي في المراحل المتقدمة إلى إعاقة شديدة وفقدان الاستقلالية [1]. ومع الازدياد المستمر في أعداد كبار السن، يتصاعد العبء العالمي لمرض الزهايمر بوتيرة متسارعة، الأمر الذي يفرض حاجة ملحة إلى حلول تشخيصية مبكرة وموثوقة. ويُعدّ التصوير بالرنين المغناطيسي Magnetic Resonance Imaging – MRI أحد أكثر تقنيات التصوير العصبي استخدامًا في تقييم مرض الزهايمر، وذلك لما يتميز به من كونه غير تدخلية وقدرته على توفير معلومات بنيوية عالية الدقة عن تشريح الدماغ. ويلعب التصوير البنيوي بالرنين المغناطيسي دورًا محوريًا في الكشف عن أنماط ضمور الدماغ، ولا سيما في مناطق مثل الحُصين Hippocampus والفصوص الصدغية الإنسية، والتي ترتبط ارتباطًا وثيقًا بتطور مرض الزهايمر. ومع ذلك، لا يزال التصنيف الدقيق لمراحل المرض باستخدام صور MRI مثل تحديًا كبيرًا، خاصة في المراحل المبكرة والمتوسطة، حيث تكون التغيرات التشريحية طفيفة وغالبًا ما تتداخل بين الفئات المرضية المختلفة.

في السنوات الأخيرة، تم توظيف تقنيات التعلّم الآلي والتعلّم العميق على نطاق واسع في تشخيص مرض الزهايمر بشكل آلي. وتعتمد الأساليب التقليدية في التعلّم الآلي بشكل كبير على الميزات المصممة يدويًا، والتي غالبًا ما تعاني من ضعف القدرة على التعميم عند تطبيقها على بيانات

MRI غير المتجانسة. في المقابل، أظهرت الشبكات العصبية الالتفافية Convolutional Neural Networks – CNNs قدرة عالية على تعلّم تمثيلات هرمية للميزات مباشرة من الصور الطبية، وحققت نتائج واعدة في مهام تصنيف مرض الزهايمر. وعلى الرغم من هذه التطورات، لا تزال نماذج CNN حساسة لجودة الصور، الضجيج، وانخفاض التباين، وعدم توازن الفئات، وهي خصائص شائعة في مجموعات بيانات MRI الواقعية.

ويُعدّ جودة تباين الصور أحد العوامل الحاسمة، إلا أنه لم يحظَ بالاهتمام الكافي نسبيًا في تصنيف مرض الزهايمر المعتمد على صور الرنين المغناطيسي [2]. إذ غالبًا ما تعاني صور الرنين المغناطيسي من انخفاض التباين وعدم تجانس الشدة، مما قد يؤدي إلى طمس التفاصيل التشريحية الدقيقة ويؤثر سلبيًا على عملية استخراج الميزات العميقة. وعلى الرغم من تركيز العديد من الدراسات على تحسين بنية الشبكات العصبية، فإن القليل منها تناول الدمج المنهجي لتقنيات تحسين التباين المصممة خصيصًا لصور الدماغ قبل تطبيق نماذج التعلّم العميق. إن تعزيز البنى التشريحية ذات الأهمية التشخيصية قبل مرحلة استخراج الميزات يمكن أن يسهم بشكل كبير في تحسين متانة التصنيف، لا سيما في الكشف المبكر عن المرض.

إضافة إلى ذلك، وعلى الرغم من تفوق الشبكات العصبية الالتفافية في تعلّم الميزات، فإن طبقات التصنيف النهائية فيها لا توفر دائمًا حدود قرار دقيقة، خاصة عند التعامل مع بيانات محدودة أو غير متوازنة. وتُعدّ استراتيجيات التعلّم الهجين التي تجمع بين استخراج الميزات باستخدام CNN والمصنّفات التقليدية، مثل آلة متجه الدعم Support Vector Machine، بديلًا واعدًا. إذ تتميز خوارزميات SVM بقدرتها العالية على التعميم وفعاليتها في فضاءات الميزات عالية الأبعاد، مما يجعلها مناسبة بشكل خاص لمهام التصنيف التي تعاني من نقص العينات في بعض الفئات [3]، [4].

انطلاقًا من هذه التحديات، تقترح هذه الدراسة إطارًا محسنًا قائمًا على صور الرنين المغناطيسي لتصنيف مرض الزهايمر متعدد المراحل، يجمع بين تحسين التباين وتقنيات التعلّم العميق واستراتيجيات التصنيف الهجين. ويعتمد الإطار المقترح على استخدام تقنية المعادلة التكيفية

المحدودة على النقيض للهستوغرام المعتمدة على التوزيع الغاوسي Gaussian-based Contrast-Limited Adaptive Histogram Equalization – G-CLAHE

لتحسين جودة صور MRI وإبراز البنى التشريحية ذات الأهمية التشخيصية. بعد ذلك، يتم استخدام شبكة عصبية التلافيفية لاستخلاص الميزات العميقة من الصور المحسنة، يليها تصنيف باستخدام كل من نموذج CNN مستقل وإطار هجين يجمع بين CNN و SVM [5].

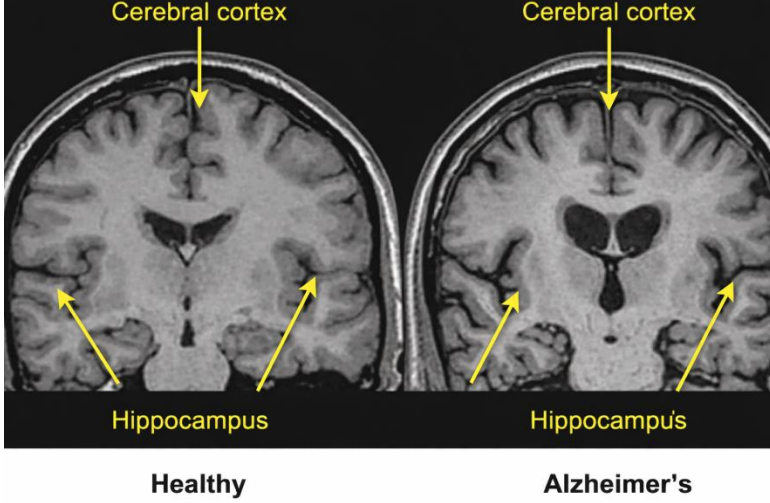
- المساهمات Contributions:

يمكن تلخيص المساهمات الرئيسية لهذا البحث على النحو الآتي:

1. اقتراح خطوات معالجة للصور لتحسين التباين قائم على التوزيع الغاوسي ومُصمَّم خصيصًا لصور الرنين المغناطيسي للدماغ، بهدف تحسين جودة الصور وقابلية تمييز الميزات في تصنيف مرض الزهايمر.
2. تطوير إطار تصنيف هجين يجمع بين CNN و SVM لدمج تعلم الميزات العميقة مع التصنيف القائم على الهامش، مما يعزز المتانة والحساسية، خاصةً في المراحل المرضية ضعيفة التمثيل.
3. إجراء تجارب موسَّعة باستخدام مجموعة بيانات عامة لصور MRI لتقييم فعالية المنهجية المقترحة بالاعتماد على عدة مقاييس أداء، بما في ذلك الدقة، والاسترجاع، ومقياس F1، وتحليل ROC-AUC.
4. تعزيز قابلية تفسير النموذج باستخدام تقنية Grad-CAM++، من خلال توفير تفسيرات بصرية تُبرز المناطق الدماغية ذات الصلة السريرية المرتبطة بمرض الزهايمر.

2.مراجعة الأدبيات والأعمال ذات الصلة

شهدت تقنيات التصوير والمعالجة تقدمًا ملحوظًا في تشخيص مرض الزهايمر Alzheimer's Disease-AD، مدفوعًا بالتطورات المتسارعة في مجال الذكاء الاصطناعي. وعلى وجه الخصوص، أظهرت الأساليب المعتمدة على التصوير والمقترنة بتقنيات التعلم الآلي والتعلم العميق إمكانات كبيرة في الكشف الآلي عن مرض الزهايمر وتحديد مراحله. ومن بين مختلف تقنيات التصوير، لا يزال التصوير بالرنين المغناطيسي MRI أحد أكثر الأدوات استخدامًا، نظرًا لطبيعته غير التداخلية، ودقته المكانية العالية، وقدرته على التقاط التغيرات البنوية في الدماغ المرتبطة بالتكس العصبي، مثل ضمور القشرة الدماغية cerebral cortex وانكماش الحصين hippocampus، كما هو موضح في الشكل 1.



الشكل (1) صورة بالرنين المغناطيسي لدماع سليم ودماع مصاب بمرض الزهايمر ويوضح الضمور البنيوي المرتبط بتطور المرض.

اعتمدت الأساليب المبكرة في تشخيص مرض الزهايمر باستخدام التعلّم الآلي بشكل أساسي على الميزات المصممة يدويًا والمستخرجة من صور الرنين المغناطيسي، مثل سماكة القشرة الدماغية، وحجم الحُصين، وواصفات النسيج. وعلى الرغم من تحقيق هذه الطرق لنجاح متوسط، إلا أن أدائها كان غالبًا محدودًا بسبب تعقيد تصميم الميزات وضعف قدرتها على التعميم عبر مجموعات البيانات المختلفة. ولمعالجة هذه القيود، تم الاعتماد بشكل متزايد على تقنيات التعلّم العميق، ولا سيما الشبكات العصبية الالتفافية Convolutional Neural Networks، التي تتيح تعلّم تمثيلات هرمية للميزات مباشرة من بيانات التصوير العصبي.

أظهرت العديد من الدراسات أن نماذج التعلّم العميق، وبخاصة الشبكات العصبية الالتفافية، فعالة للغاية في استخراج ميزات تمييزية من بيانات الرنين المغناطيسي MRI والتصوير المقطعي بالإصدار البوزيتروني PET. على سبيل المثال، اقترح Raza et al إطارًا عميقًا متعدد الوسائط يدمج بيانات PET وMRI مع المعلومات السريرية باستخدام بنية CNN-3D، محققًا دقة تصنيف بلغت 98.1%. وقد أكدت هذه الدراسة أهمية دمج البيانات متعددة الوسائط والجينية في تحسين الأداء التنبؤي [6]. وبالمثل، قدّم Nazir et al 2025 مراجعة منهجية ركزت على الاتجاهات المستقبلية في التنبؤ بمخاطر مرض الزهايمر باستخدام التعلّم العميق، حيث أشار إلى أن البنى

المتقدمة مثل ResNet-50 و DenseNet حققت دقة تشخيصية وصلت إلى 96.4% على مجموعات بيانات MRI و PET [7].

وفي سياق دمج بيانات PET و MRI، استكشف Woodward et al 2025 أساليب تشخيصية قائمة على الذكاء الاصطناعي عقب اعتماد تصوير Tauvid للكشف عن بروتين تاو. وحقق نموذج CNN ثلاثي الأبعاد الذي استخدمه دقة بلغت 97.2% في التمييز بين مرض الزهايمر والضعف الإدراكي البسيط، مما يبرز القيمة التشخيصية للمؤشرات الحيوية المرتبطة ببروتين تاو عند دمجها مع التعلم العميق [8]. وإلى جانب التصوير العصبي، حظيت المقاربات المعتمدة على المؤشرات الحيوية باهتمام متزايد، حيث استعرض Bhatia et al 2025 التقدم في اكتشاف المؤشرات الجزيئية والكيميائية العصبية باستخدام الذكاء الاصطناعي، واعتمدوا على خوارزمية آلة متجه الدعم SVM لتحليل بيانات السائل الدماغي الشوكي CSF و PET، محققين دقة بلغت 95.7% [9].

كما أكدت عدة مراجعات شاملة فعالية نماذج CNN في تشخيص مرض الزهايمر. فقد أشار Awang et al 2025 إلى أن الشبكات العصبية الالتفافية العميقة حققت دقة تراوحت بين 96.8% و 98.3% عند تطبيقها على بيانات MRI و fMRI ضمن إطار ADNI [10]. وفي السياق نفسه، اقترح Alsubaie et al 2024 بنية شبكة عصبية التلافية جديدة تُعرف باسم ConvADD لتشخيص مرض الزهايمر باستخدام صور الدماغ، حيث حقق النموذج دقة بلغت نحو 98% مع عدد معاملات منخفض نسبياً، مما يعكس كفاءة البنية المقترحة في استخراج الميزات التشخيصية من صور MRI [22]. وبالمثل، شدد Moraveji et al 2025 على مزايا النماذج الهجينة التي تجمع بين استخراج الميزات باستخدام CNN والمصنّفات التقليدية مثل SVM، لا سيما عند التعامل مع بيانات متعددة الوسائط تشمل PET, MRI, EEG، حيث تم تحقيق دقة بلغت 97.5% إلى جانب تحسين قابلية التفسير باستخدام تقنيات الذكاء الاصطناعي القابل للتفسير XAI [11].

كما تم استكشاف التنبؤ الشخصي بتطور مرض الزهايمر، حيث طور Koksalmis وآخرون 2025 نموذجاً تنبؤياً متعدد الطبقات يدمج بيانات MRI و PET والمؤشرات الحيوية السائلة والمعلومات الجينية، محققاً دقة بلغت 98.4% [12]. وفي المقابل، تناول Ehteshamzad

2024 نماذج تشخيصية قائمة على EEG ومقترنة بعلامات جينية، وحقق دقة بلغت 94.6% [13]. ولا تزال أساليب التعلّم الآلي التقليدية تلعب دورًا مهمًا في تشخيص مرض الزهايمر، إذ أظهر Abdalrada 2025 أن خوارزميات التجميع مثل XGBoost و Random Forest حققت دقة بلغت 95.3% عند تطبيقها على بيانات MRI و CSF والاختبارات النفسية العصبية [14]. وعلى الرغم من هذه النتائج الواعدة، فإن المقاربات العميقة متعددة الوسائط غالبًا ما تتطلب آليات معقدة لجمع البيانات، وموارد حسابية مرتفعة، ومراحل معالجة مسبقة مكثفة، مما يحدّ من قابليتها للتطبيق السريري. كما أن الوصول إلى بيانات متعددة الوسائط لا يكون متاحًا دائمًا في الممارسة السريرية اليومية، لا سيما في البيئات محدودة الموارد، الأمر الذي يعزز الحاجة إلى تطوير أطر تشخيصية تعتمد على بيانات MRI فقط.

ويُعد انخفاض التباين، ووجود الضجيج، وعدم تجانس شدة الإشارة من التحديات المهمة الأخرى في تصنيف مرض الزهايمر باستخدام صور الرنين المغناطيسي، حيث يمكن لهذه العوامل أن تحجب التفاصيل التشريحية الدقيقة وتؤثر سلبًا على استخراج الميزات العميقة. وعلى الرغم من تركيز العديد من الدراسات على تصميم بنى الشبكات العصبية، لم يحظَ تحسين الصور بشكل منهجي ومُكَيَّف خصيصًا لصور الدماغ بالاهتمام الكافي. وقد تم استكشاف أساليب تسوية الهستوغرام العالمية، إلا أنها قد تؤدي إلى تضخيم الضوضاء وتحسين مفرط لمناطق غير ذات صلة. في المقابل، تُعد تقنيات تحسين التباين التكيفية، مثل CLAHE، أكثر ملاءمة للتصوير الطبي، نظرًا لاعتمادها على المعالجة المحلية وفرض حدود على التباين للحد من تضخيم الضوضاء.

وبالتوازي مع ذلك، ازداد الاهتمام بأطر التصنيف الهجينة التي تجمع بين استخراج الميزات العميقة باستخدام CNN والمصنّفات التقليدية. إذ تعمل CNN كمستخرج قوي للميزات، بينما تتولى خوارزميات مثل SVM أو Random Forest أو Gradient Boosting عملية اتخاذ القرار النهائي. وتُظهر خوارزمية SVM على وجه الخصوص قدرة عالية على التعميم ومثانة في التعامل مع مجموعات البيانات المحدودة أو غير المتوازنة. وقد أظهرت عدة دراسات أن النماذج الهجينة CNN-SVM تتفوق على نماذج CNN المستقلة، خاصة في مهام التصوير الطبي التي تعاني من قلة العينات أو عدم توازن الفئات.

ومؤخرًا، تم دمج تقنيات الذكاء الاصطناعي القابل للتفسير، مثل Grad-CAM++، ضمن طرق تشخيص مرض الزهايمر، بهدف إظهار المناطق الدماغية المميزة التي تؤثر في قرارات النموذج، مما يعزز قابلية التفسير والثقة السريرية.

وبوجه عام، تشير الأدبيات العلمية إلى أنه على الرغم من النجاح الكبير الذي حققته نماذج التعلم العميق في تشخيص مرض الزهايمر، لا تزال هناك تحديات تتعلق بجودة البيانات، ومثانة النماذج، والتكلفة الحسابية. كما أن التأثير المشترك لتحسين التباين والتصنيف الهجين باستخدام CNN-SVM لم يُدرس بشكل موسّع في أطر تعتمد على MRI فقط لتحديد مراحل المرض. وانطلاقاً من هذه الملاحظات، تقترح هذه الدراسة منهجية قائمة على تحسين التباين باستخدام توزيع غاوسي ومتكاملة مع إطار CNN-SVM هجين لتصنيف مرض الزهايمر متعدد المراحل، بما يحقق توازناً بين دقة التشخيص، والكفاءة الحسابية، وقابلية التطبيق السريري.

3. مواد وطرائق البحث:

يصف هذا القسم الإطار المقترح لتصنيف مرض الزهايمر متعدد المراحل باستخدام التصوير بالرنين المغناطيسي MRI وتكامل المنهجية المقترحة بين تحسين التباين، واستخلاص الميزات العميقة باستخدام الشبكات العصبية الالتفافية CNNs، واستراتيجية تصنيف هجينة تعتمد على آلة متجه الدعم SVM.

- وصف مجموعة البيانات Dataset Description

تم الحصول على مجموعة البيانات المستخدمة في هذه الدراسة من مستودع مفتوح الوصول مستضاف على منصة Kaggle وتحمل المجموعة عنوان Alzheimer's MRI Dataset، وهي متاحة للاستخدام العام دون قيود لأغراض البحث والتعليم. وتتضمن مجموعة البيانات ما يقارب 6,400 صورة رنين مغناطيسي للدماغ من نوع T1-weighted، تمثل مراحل مختلفة من تطور مرض الزهايمر. وقد صُنِّفت الصور إلى أربع فئات سريرية ذات صلة: غير مصاب بالخرف Non-Demented، خرف خفيف جداً Very Mild Demented، خرف خفيف Mild Demented، وخرف متوسط Moderate Demented ونتيح هذه الفئات إجراء تصنيف متعدد الأصناف ودراسة تطور المرض حيث يبين الجدول 1 مراحل التدهور المعرفي المتتالية.

الجدول (1) توزيع صور الرنين المغناطيسي عبر مراحل مرض الزهايمر.

الصنف	Number of Images
Non-Demented	640
Very Mild Demented	448
Mild Demented	179
Moderate Demented	13


جميع الصور مقدمة على شكل مقاطع ثنائية الأبعاد بصيغ قياسية JPG/PNG، وتمت إعادة تحجيمها إلى دقة موحدة قدرها 128×128 بكسل لضمان الكفاءة الحسابية والتوافق مع نماذج التعلم العميق المقترحة كما يوضح الشكل 2 امثلة عن بيانات المرض في حالاته. كما جرى تسوية قيم البكسلات قبل التدريب لتحسين الاستقرار العددي.




NonDemented



ModerateDemented



MildDeemenred



veryMildDemented

الشكل (2): مجموعة الصور لحالة المرض الاربعة

تُظهر مجموعة البيانات عدم توازن في الفئات، ولا سيما في فئة الخرف المتوسط، وهو ما يعكس التوزيع السريري الواقعي الشائع في دراسات مرض الزهايمر. ولتجنب تسرب البيانات، تم تقسيم البيانات عشوائياً إلى مجموعتي تدريب واختبار بنسبة 80:20، مع ضمان عدم وجود تداخل بين العينات.

وعلى الرغم من أن مجموعة البيانات ليست مجموعة سريرية أولية مثل ADNI أو OASIS ، فقد استُخدمت على نطاق واسع في دراسات تصنيف مرض الزهايمر المعتمدة على التعلّم العميق، وتوفّر تنوعاً كافياً في الصور وحجماً مناسباً للمقارنة المرجعية لنماذج CNN كما تعرّز إتاحتها العامة من قابلية إعادة الإنتاج والشفافية.

- المعالجة المسبقة للصور وتحسين التباين

Image Preprocessing and Contrast Enhancement

تلعب المعالجة المسبقة دوراً حاسماً في تحليل صور MRI لمرض الزهايمر نظراً لوجود انخفاض في التباين، وضوضاء، وعدم تجانس في شدة الإشارة. ولتعزيز البنى التشريحية ذات الأهمية التشخيصية وتحسين عملية استخراج الميزات، تم تطبيق خطوات معالجة لتحسين التباين قبل تدريب النماذج.

- تسوية الهستوغرام Histogram Equalization

تُعد تسوية الهستوغرام HE تقنية عالمية لتحسين التباين، حيث تعيد توزيع قيم شدة البكسلات لتغطي مجال التدرج الرمادي بشكل أكثر تجانساً. ومن خلال تحسين التباين العام، تعزز HE وضوح البنى التشريحية في الصور ذات المجال الديناميكي المحدود. إلا أن هذه التقنية قد تؤدي إلى تضخيم الضجيج وتحسين مفرط لمناطق غير ذات صلة. في هذه الدراسة، حيث تبين المعادلة (1) القانون العام لتوزيع الهستوغرام كما تم شرحها من قبل [15].

$$S_k = T(r_k) = (L - 1) \sum_{j=0}^k p(r_j) \quad (1)$$

حيث r_k : مستوى اللون الرمادي الأساسي و $T(r_k)$: دالة التحويل التي تقوم بتحويل مستوى الرمادي الأصلي إلى مستوى جديد. و S_k : مستوى اللون الرمادي بعد التحويل، $p(r_j)$: التوزيع الاحتمالي للمستوى الحر r_j و L : عدد مستويات التدرج الرمادي في الصورة.

Gaussian-Based Contrast Limited Adaptive Histogram Equalization -GCLAHE

للتغلب على القيود المرتبطة بتقنية تسوية الهستوغرام التقليدية HE، تم اعتماد تقنية CLAHE المعتمدة على التوزيع الغاوسي، والمعروفة بـ GCLAHE في البداية، جرى تطبيق مرشح غاوسي على الصور بهدف تقليل الضجيج عالي التردد مع الحفاظ على البنية التشريحية الأساسية للصورة. بعد ذلك، تم تطبيق خوارزمية CLAHE على مناطق محلية صغيرة تُعرف بالبلاطات Tiles، مما يسمح بتحسين تكيفي للتباين اعتمادًا على توزيع شدة البكسلات في صور الرنين المغناطيسي للدماغ المرتبطة بمرض الزهايمر.

لتحديد مقدار القطع في الهستوغرام ومنع التضخيم المفرط للتباين، يتم حساب الحد الأقصى المسموح لتكرار القيم الرمادية وفق المعادلة (2) كما وضحت في [16]:

$$MAX_{CL} = \frac{clip_{limit} \times total_pixels_in_tile}{L} \quad (2)$$

حيث يشير MAX_{CL} إلى الحد الأعلى المسموح لتكرار مستوى رمادي معين داخل الهستوغرام المحلي، بينما L : عدد مستويات التدرج الرمادي للصورة و $clip_{limit}$: معامل التحكم الذي يحدد مقدار الحد من التباين داخل كل بلاطة.


بعد تحديد هذا الحد، يتم تعديل التوزيع التكراري للهستوغرام بحيث لا تتجاوز أي قيمة التكرار الحد الأعلى المحدد. ويتم ذلك باستخدام عملية القص الموضحة في المعادلة (3) كما وضحت في [16]:

$$min(H, MAX_{CL}) = H^I \quad (3)$$

حيث تمثل H القيمة الأصلية للهستوغرام لمستوى رمادي معين، بينما تشير H^I إلى القيمة الجديدة بعد تطبيق عملية القص. وتعني هذه العملية أن أي قيمة تتجاوز الحد MAX_{CL} يتم تقليصها إلى هذا الحد، مما يمنع تضخيم التباين بشكل مفرط وتكمن أهمية هذا الإجراء:

1. يمنع تضخيم الضجيج في المناطق التي تحتوي على عدد كبير من البكسلات بنفس الشدة.
2. يحافظ على تفاصيل الصورة بشكل أفضل مقارنةً بـ HE.
3. يعطي تحكمًا جزئيًا في التباين بدلاً من التأثير على الصورة بأكملها.

يوضح الشكل (3) تسلسل مراحل معالجة البيانات، حيث يتم تطبيق خطوات التحسين تدريجيًا على الصور الطبية بهدف تحسين تباين الحواف والخصائص البنيوية لعدة فئات من مرض الزهايمر. وتساعد آلية تحديد التباين هذه في الحد من التضخيم المفرط للضجيج، مع إعادة توزيع القيم المقصودة بشكل متجانس للحفاظ على الاتساق الضوئي للصورة. إضافةً إلى ذلك، يتم استخدام الاستيفاء ثنائي الخلية Bilinear Interpolation بين البلاطات المجاورة لضمان انتقالات سلسلة بين المناطق المختلفة وتجنب ظهور آثار الحواف وقد أثبتت هذه المعالجة فعاليتها في إبراز التفاصيل التشريحية المهمة في صور الدماغ، مثل المادة الرمادية ومنطقة الحُصين، والتي تُعد مؤشرات مهمة في تحديد مراحل مرض الزهايمر [16].



الشكل (3) تطبيق HE و G-CLAHE على صورة رنين مغناطيسي للدماغ.

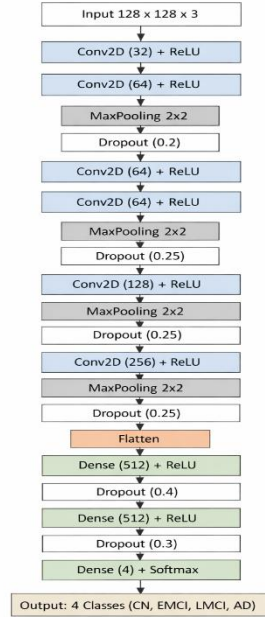
- التحليل النوعي لتقنيات تحسين الصور Qualitative Analysis وبالمقارنة البصرية والنوعية لتقنيات تحسين الصور المطبقة على عينات تمثيلية من صور MRI. تُظهر الصور الأصلية انخفاضًا في التباين وضعفًا في وضوح التفاصيل التشريحية. تعمل

تحليل صور الرنين المغناطيسي لمرض الزهايمر باستخدام تحسين التباين والشبكات العصبية

تسوية الهيستوغرام على تحسين التباين العام، إلا أنها قد تضخم الضجيج وتسبب تحسباً مفرطاً في بعض المناطق وبالمقابل، توفّر CLAHE تحسباً محلياً أكثر فاعلية للتباين مع الحفاظ على التفاصيل الدقيقة والتحكم في تضخيم الضجيج. ويساعد التموه الغاوسي في تقليل الضجيج الترددات العالية، إلا أنه قد يؤدي إلى فقدان حدة الحواف عند استخدامه بشكل منفصل. وبصورة عامة، يحقق النهج المقترح G-CLAHE توازناً فعالاً بين تحسين التباين وتقليل الضوضاء، مما يدعم استخراج ميزات أكثر موثوقة في مراحل التعلّم العميق اللاحقة.

- بنية الشبكة العصبية الالتفافية CNN Architecture

تم تصميم شبكة عصبية التلافية لاستخلاص ميزات عميقة تمييزية من صور MRI المحسنة. وتُعد CNN مناسبة بشكل خاص لتحليل الصور الطبية نظراً لقدرتها على تعلّم تمثيلات هرمية للميزات مباشرة من بيانات البكسل. وكما هو موضح في الشكل (4) ، تتكوّن البنية المقترحة من عدة طبقات التلاف مع دالة تنشيط ReLU، تليها طبقات Max-Pooling لتقليل الأبعاد المكانية والتعقيد الحسابي. وتُستخدم طبقات كاملة الاتصال لتجميع الميزات المستخرجة وتوليد تمثيلات مضغوطة لمهمة التصنيف النهائية. تم تدريب الشبكة باستخدام خوارزمية Adam بمعدل تعلّم 0.001، ودالة خسارة Sparse Categorical Cross-Entropy، ولمدة 50 دورة تدريبية وبحجم دفعة 32 صورة. كما استُخدم تقسيم للتحقق Validation Split لمراقبة قدرة التعميم أثناء التدريب [17].



الشكل (4): بنية الشبكة العصبية الالتفافية المقترحة.

- مصنف آلة متجه الدعم Support Vector Machine

تُعد آلة متجه الدعم SVM من خوارزميات التعلّم الخاضع للإشراف، حيث تبني حدود قرار من خلال تعظيم الهامش بين الفئات. وتُظهر فعالية عالية في فضاءات الميزات ذات الأبعاد المرتفعة، إلى جانب قدرة قوية على التعميم عند التعامل مع بيانات محدودة أو غير متوازنة [18].
تم هذه الدراسة استخدام SVM كمصنّف خارجي لتصنيف متجهات الميزات العميقة المستخرجة من CNN وتم اعتماد نواة دالة الأساس الشعاعي RBF لتمثيل العلاقات غير الخطية بين الميزات، مع اختيار المعاملات الفائقة تجريبياً لتحقيق أفضل أداء تصنيفي.

- الإطار الهجين CNN-SVM

لتحسين متانة التصنيف وحساسيته، تم اقتراح إطار هجين CNN-SVM، حيث تُستخدم CNN حصرياً لاستخلاص الميزات العميقة، بينما تتولى SVM مهمة التصنيف النهائي [19]. يستفاد من هذا النهج من قدرة CNN على تعلّم الميزات، ومن القوة التصنيفية العالية لـ SVM. ويُعد

الفصل بين مرحلتي استخراج الميزات والتصنيف مفيداً بشكل خاص في معالجة عدم توازن الفئات وتحسين الأداء في المراحل المرضية ضعيفة التمثيل.

- تدريب النموذج وتقسيم البيانات Model Training and Data Splitting

تم تقسيم البيانات إلى مجموعتي تدريب واختبار بنسبة 80:20 استُخدمت مجموعة التدريب لتحسين معاملات النموذج، بينما حُصصت مجموعة الاختبار لتقييم الأداء بشكل غير متحيز. ولم يُسمح بأي تداخل بين العينات لتجنب تسرب البيانات. كما تم تطبيق استراتيجيات التحقق المتقاطع أثناء التطوير لتعزيز المتانة والاستقرار.

- مقاييس التقييم Evaluation Metrics

تم تقييم أداء النماذج باستخدام مقاييس تصنيف متعددة الأصناف شائعة، شملت الدقة Accuracy، الدقة الإيجابية Precision، الاسترجاع Recall / Sensitivity، ومعيار F1- scour كما استُخدمت مصفوفات الالتباس لتحليل الأداء على مستوى كل فئة وأنماط الخطأ والتي تعتمد على أربع قيم أساسية هي True Positive-TP، و True Negative-TN، و False Positive-FP، و False Negative-FN يشير TP إلى عدد الحالات التي تنبأ النموذج بأنها إيجابية وكانت كذلك فعلياً، بينما يمثل TN عدد الحالات التي تنبأ النموذج بأنها سلبية وكانت صحيحة بالفعل. أما FP فيعبر عن الحالات التي تنبأ النموذج بأنها إيجابية رغم أنها سلبية في الواقع، في حين يشير FN إلى الحالات التي أخفق فيها النموذج في اكتشاف الحالة الإيجابية وتنبأ بأنها سلبية. إضافةً إلى ذلك، تم حساب منحنيات ROC والمساحة تحت المنحنى AUC لتقييم القدرة التمييزية للنماذج عبر عتبات تصنيف مختلفة. ونظرًا للأهمية السريرية للتشخيص المبكر، أُعطي اهتمام خاص لمقاييس الاسترجاع و F1 لتقليل الأخطاء السلبية الكاذبة كما وردت في [4, 6].

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (4)$$

$$precision = \frac{TP}{TP + FP} \quad (5)$$

$$recall = \frac{TP}{TP + FN} \quad (6)$$

$$F1 - score = 2 * \frac{precision * recall}{precision + recall} \quad (7)$$

- النتائج والمناقشة Results and Discussion

يستعرض هذا القسم النتائج التجريبية التي تم الحصول عليها باستخدام الإطار المقترح، ويقدم مناقشة تفصيلية لأداء التصنيف. تم تقييم نموذجين مختلفين، هما: نموذج الشبكة العصبية الالتفافية المستقل CNN، والإطار الهجين آلة متجه الدعم CNN-SVM وتركز عملية التقييم على تصنيف مرض الزهايمر متعدد المراحل اعتماداً على صور الرنين المغناطيسي MRI، وذلك باستخدام عدة مقاييس أداء تشمل الدقة، والدقة الإيجابية، والاسترجاع، ومعيار F1-scoure، ومصفوفات الالتباس، وتحليل ROC-AUC.

- أداء نموذج الشبكة العصبية الالتفافية Standalone CNN


أظهر نموذج CNN المستقل قدرة عالية على تعلم تمثيلات تمييزية من صور الرنين المغناطيسي المحسنة بالتباين. وبعد تطبيق تقنيتي تسوية الهستوغرام HE والمعادلة التكميلية المحدودة على النقيض المعتمدة على التوزيع الغاوسي G-CLAHE، حقق النموذج دقة تصنيف كلية بلغت 96%، مما يدل على قدرة موثوقة في التمييز بين مراحل مرض الزهايمر المختلفة. وتلخص مقاييس الأداء الخاصة بكل فئة في الجدول (II) وتظهر النتائج قيماً مرتفعة ومتسقة لمقاييس الدقة والاسترجاع و F1-scour للفئات ذات التمثيل الكافي في البيانات. وعلى وجه الخصوص، حققت فئة غير مصاب بالخرف Non-Demented والخرف الخفيف جداً Very Mild Demented قيم F1 بلغت 0.94-0.97 على التوالي، مما يعكس حساسية النموذج للتغيرات المرضية المبكرة. كما أظهرت فئة الخرف الخفيف أداءً قوياً، مؤكدةً فعالية استخراج الميزات العميقة عند دمجها مع تحسين التباين. في المقابل، أظهرت فئة الخرف المتوسط Moderate Demented قيمة استرجاع أقل نسبياً بلغت 0.85، على الرغم من تحقيق دقة إيجابية كاملة. ويعكس هذا السلوك تأثير عدم توازن الفئات، حيث يحدّ العدد القليل من العينات من قدرة النموذج على اكتشاف جميع الحالات الحقيقية.

ومع ذلك، فإن غياب التنبؤات الإيجابية الخاطئة لهذه الفئة يشير إلى أن نموذج CNN تعلم ميزات عالية التخصص، وإن كان ذلك على حساب الحساسية.

الجدول: (II) أداء تصنيف نموذج CNN المقترح عبر مراحل مرض الزهايمر المختلفة.


CLASS	Precision	Recall	F1-score	Support
MildDemented	0.99	0.94	0.96	179
ModerateDemented	1.00	0.85	0.92	13
NonDemented	0.97	0.96	0.97	640
VeryMildDemented	0.93	0.96	0.94	448
ACC			0.96	1280
Macro Avg	0.97	0.93	0.95	1280
Weighted Avg	0.96	0.96	0.96	1280

تُظهر منحنيات الخسارة والتحقق (الشكل 5) تقارباً مستقرًا وفارقًا طفيفاً بين أداء التدريب والتحقق، مما يدل على عدم معاناة النموذج من فرط التكيف وقدرته الجيدة على التعميم على بيانات غير مرئية. ويؤكد ذلك فعالية استراتيجية المعالجة المسبقة والتدريب المعتمدة.



الشكل (5) منحنيات الخسارة والتدريب والدقة لنموذج الشبكة العصبية الالتفافية CNN .


كما تؤكد مصفوفة الالتباس (الشكل 6) الأداء العالي للتصنيف عبر معظم الفئات. وتتركز حالات الخطأ أساساً بين المراحل المرضية المتجاورة، مثل الخرف الخفيف جداً والخرف الخفيف، وهو أمر متوقع نظراً للطبيعة التدريجية والمستمرة للتدهور العصبي.



الشكل (6): مصفوفة الالتباس لنموذج الشبكة العصبية الالتفافية CNN المقترح لتصنيف مراحل مرض الزهايمر.

ويُظهر تحليل ROC-AUC الشكل 7 قدرة تمييزية عالية، حيث تجاوزت قيم 0.99 لجميع الفئات، مع متوسط كلي بلغ 0.994، مما يشير إلى توازن قوي بين الحساسية والخصوصية عبر مختلف عتبات التصنيف.

تحليل صور الرنين المغناطيسي لمرض الزهايمر باستخدام تحسين التباين والشبكات العصبية



الشكل (7): منحنيات خصائص التشغيل للمستقبل (ROC) وقيم المساحة تحت المنحنى (AUC) لتصنيف مرض الزهايمر متعدد الفئات باستخدام نموذج الشبكة العصبية الالتفافية (CNN).

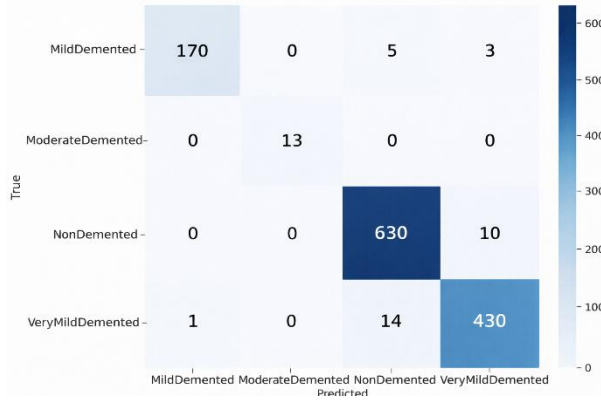
- أداء الإطار الهجين CNN-SVM

حقق الإطار الهجين CNN-SVM أداءً متفوقاً مقارنةً بنموذج CNN المستقل من أجل جميع مقاييس التقييم. فمن خلال استخدام CNN كمستخرج للميزات العميقة، وتكليف SVM بعملية التصنيف النهائية، بلغ النموذج الهجين دقة كلية قدرها 97% ومتوسط F1_score كلي بلغ 0.98. ويبين الجدول (III) نتائج النموذج الثاني.

الجدول (III): أداء تصنيف النموذج الهجين CNN-SVM .


CLASS	PRECISIO	RECAL	F1-SCOR	SUPPOR
MildDemented	0.99	0.96	0.97	179
ModerateDemented	1.00	1.00	1.00	13
NonDemented	0.97	0.98	0.98	640
VeryMildDemented	0.97	0.97	0.97	448
ACC			0.97	1280
Macro Avg	0.98	0.98	0.98	1280
Weighted Avg	0.97	0.97	0.97	1280

ومن اللافت أن النهج الهجين حسّن بشكل كبير أداء فئة الخرف المتوسط ضعيفة التمثيل، وبرز هذا التحسن فعالية المصنّفات القائمة على تعظيم الهامش، مثل SVM، في التعامل مع عدم توازن الفئات عند العمل على تمثيلات ميزات عميقة عالية الأبعاد. وتُظهر مصفوفة الالتباس (الشكل 8) انخفاضًا واضحًا في معدلات الخطأ مقارنة بنموذج CNN المستقل، خاصة في المراحل المتقدمة من المرض. كما تُظهر معدلات عالية للتنبؤات الصحيحة لجميع الفئات، مع بقاء حالات الخطأ محصورة في المراحل المتجاورة، وهو ما يعكس التداخل السريري الطبيعي بين المراحل المرضية.



الشكل (8): مصفوفة الالتباس للإطار الهجين CNN-SVM في تصنيف مرض الزهايمر.

ويؤكد تحليل ROC-AUC (الشكل 9) متانة الإطار الهجين، حيث تراوحت قيم AUC بين 0.991 و 1.000، بمتوسط كلي بلغ 0.9954، مما يدل على سلوك تصنيفي أكثر اتساقاً مقارنة بالنموذج المستقل.



الشكل (9): تحليل منحنيات خصائص التشغيل للمستقبل (ROC) والمساحة تحت المنحنى (AUC) لتصنيف متعدد الفئات.

- التحليل المقارن بين نماذج CNN و CNN-SVM

يكشف التحليل المقارن بين النموذجين عن عدة ملاحظات رئيسية. فبينما يقدم نموذج CNN المستقل أداءً موثوقاً للفئات ذات التمثيل الكافي، تتخفف حساسيته عند التعامل مع الفئات محدودة البيانات. في المقابل، ينجح الإطار الهجين CNN-SVM في معالجة هذا القيد بفضل خاصية تعظيم الهامش في SVM، مما يؤدي إلى تحسين الاسترجاع والامتانة العامة. ومن منظور سريري، يُعد الاسترجاع مقياساً بالغ الأهمية، إذ قد تؤدي الأخطاء السلبية الخاطئة إلى تأخير التشخيص والتدخل العلاجي. وقد أظهر النموذج الهجين تحسناً متسقاً في الاسترجاع عبر جميع الفئات، لا سيما في المراحل المتقدمة من المرض، مما يجعله أكثر ملاءمة لأنظمة دعم القرار السريري.


- تأثير تحسين التباين

تعزز تقنيات تحسين التباين أداء التصنيف. فقد أسهمت G-CLAHE في تحسين وضوح البنى التشريحية الدقيقة. وساعد تحسين التباين في تسهيل تعلم الميزات العميقة، مما انعكس إيجابياً على أداء كلا النموذجين. وبالمقارنة مع تسوية الهيستوغرام، قدّمت تقنية G-CLAHE المقترحة تحسناً أكثر توازناً من خلال تعزيز التباين المحلي مع الحد من تضخيم الضجيج، وهو أمر بالغ الأهمية في تحليل صور MRI حيث يتطلب التشخيص الدقيق الحفاظ على التفاصيل البنيوية الدقيقة.

- قابلية تفسير النموذج باستخدام Grad-CAM++

لتعزيز الشفافية والثقة السريرية، تم استخدام Grad-CAM++ لتصوير المناطق الدماغية التي تسهم في تنبؤات النموذج. وقد أظهرت خرائط التنشيط تركيزًا واضحًا على مناطق تشريحية ذات صلة سريرية، مثل الحُصين والفصوص الصدغية الإنسية (الشكل 10)، وهي مؤشرات حيوية معروفة لمرض الزهايمر.

Predicted: MildDemented | True: MildDemented



الشكل (10) تصوير Grad-CAM للمناطق التمييزية في حالة الخرف الخفيف.

ويشير هذا التوافق بين انتباه النموذج والأنماط العصبية المرضية المعروفة إلى أن الإطار المقترح يتعلم ميزات ذات معنى سريري حقيقي، وليس مجرد ارتباطات عشوائية. كما يعزز دمج تقنيات الذكاء الاصطناعي القابل للتفسير من قابلية اعتماد النموذج في البيئات السريرية [20,21].

- المناقشة في سياق الأعمال ذات الصلة

يوضح الجدول (IV) مقارنة بين عدد من الدراسات الحديثة التي تناولت تشخيص مرض الزهايمر باستخدام تقنيات الذكاء الاصطناعي والتعلم العميق، إضافةً إلى النماذج المقترحة في هذه الدراسة. وتهدف هذه المقارنة إلى إبراز موقع النموذج المقترح ضمن السياق البحثي الحالي، من حيث نوع البيانات المستخدمة، وبنية النموذج، ومستوى الأداء المحقق. كما تبيّن النتائج أن العديد من الدراسات الحديثة تعتمد على دمج مصادر بيانات متعددة مثل صور MRI و PET والبيانات السريرية أو الجينية، الأمر الذي يسهم غالبًا في تحسين دقة التنبؤ لكنه يزيد من تعقيد النموذج ومتطلبات المعالجة.

وتظهر المقارنة أن النموذج المقترح في هذه الدراسة يحقق توازنًا مناسبًا بين الدقة والمانعة والكفاءة الحسابية. فعلى الرغم من أن بعض الدراسات تعتمد على نماذج متعددة الوسائط أو شبكات ثلاثية

تحليل صور الرنين المغناطيسي لمرض الزهايمر باستخدام تحسين التباين والشبكات العصبية

الأبعاد معقدة، فإن النموذج المقترح يعتمد على بيانات MRI فقط مع تطبيق تقنيات تحسين الصور، مما يسمح بالحصول على أداء تنافسي مع الحفاظ على بساطة البنية وقابلية التطبيق العملي. ويُعد هذا الجانب مهماً في التطبيقات الطبية الواقعية، حيث إن تقليل تعقيد النظام ومتطلبات البيانات يسهم في تسهيل دمج النموذج ضمن أنظمة الدعم السريري واتخاذ القرار الطبي. كما تُظهر النتائج أن النموذج الهجين المقترح CNN + SVM يحقق تحسناً ملحوظاً مقارنة بالنموذج الأساسي المعتمد على CNN فقط، خاصة في التعامل مع الفئات الأقل تمثيلاً في البيانات. ويشير ذلك إلى أن الجمع بين تقنيات التعلم العميق وأساليب التعلم الآلي التقليدية يمكن أن يوفر أداءً أكثر استقراراً في مهام التصنيف الطبي.

الجدول (IV): مقارنة بين الدراسات الحديثة وأساليب الكشف عن مرض الزهايمر والنماذج المقترحة.

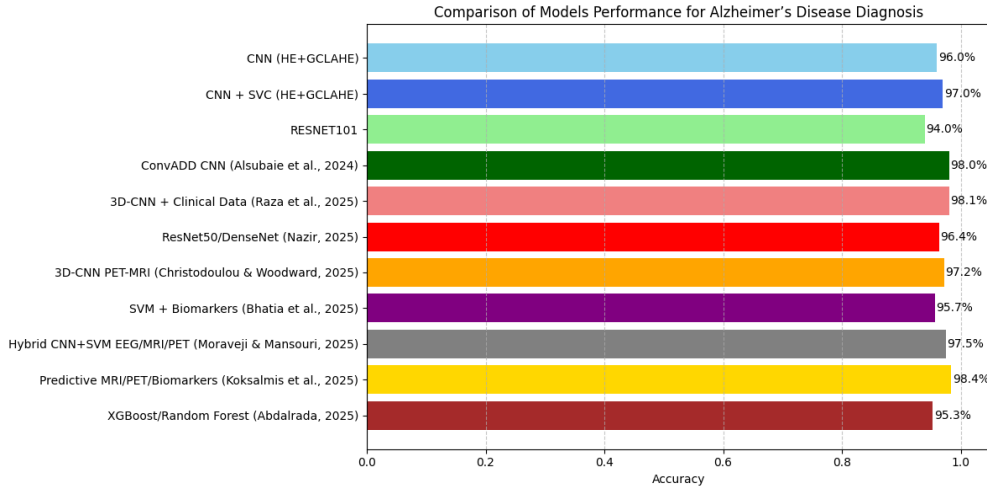
Study / Model	Data Type	Model/Tech nique	Acc(%)	Remarks
Raza et al., 2025	PET + MRI + Clinical	Multimodal 3D-CNN	98.1	Integration of genetic data improved predictive performance
Nazir, 2025	MRI + PET	ResNet-50 and DenseNet	96.4	Effective discrimination between early and advanced disease stages
Christodoulou & Woodward, 2025	PET-MRI + Tauvid	3D-CNN	97.2	Differentiation between Alzheimer's disease and mild cognitive impairment
Bhatia et al., 2025	CSF + PET	SVM with mass	95.7	Focus on molecular and

		spectrometry analysis		neurochemical biomarkers
Awang et al., 2025	MRI + fMRI	Deep CNN	96.8–98.3	Conducted within the ADNI framework
Moraveji & Mansouri, 2025	EEG + MRI + PET	Hybrid CNN–SVM	97.5	Incorporation of explainable AI (XAI) techniques
Koksalmis et al., 2025	MRI + PET + Fluid + Genomic	Multilayer predictive model	98.4	Support for personalized disease progression prediction
Ehteshamzad, 2024	EEG + Genetic data	Not specified	94.6	Non-invasive diagnostic tools
Abdalrada, 2025	MRI + CSF + Neuropsychological tests	XGBoost and Random Forest	95.3	A combination of deep learning and traditional methods
Alsubaie et al., 2024	MRI	ConvADD CNN	98.01	Alsubaie et al., 2024
Proposed Model I	MRI	CNN	96.0	Baseline model with G-CLAHE and HE preprocessing
Proposed Model II	MRI	CNN + SVM	97.0	Hybrid model with improved performance for underrepresented classes

تحليل صور الرنين المغناطيسي لمرض الزهايمر باستخدام تحسين التباين والشبكات العصبية

كما يوضح الشكل (11) مقارنة بصرية لدقة التصنيف بين النماذج المقترحة وعدد من الأساليب الحديثة، حيث يتبين أن نموذج CNN-SVM المقترح يظل منافسًا بقوة رغم اعتماده على وسيلة تصوير واحدة فقط.

وتؤكد هذه النتائج أن الإطار المقترح يوفر حلاً عملياً وقابلاً للتوسع لتشخيص مرض الزهايمر، من خلال تقليل الاعتماد على البيانات متعددة الوسائط مع الحفاظ على أداء تشخيصي قوي ومتوازن.



الشكل(11) : مقارنة دقة التصنيف بين النماذج المقترحة وعدد من الأساليب الحديثة في تشخيص مرض الزهايمر.

- القيود Limitations

على الرغم من النتائج الواعدة التي حققتها هذه الدراسة، إلا أنه يجب الإقرار بعدة قيود. أولاً، تعاني مجموعة البيانات من عدم توازن بين الفئات، لا سيما في المراحل المتقدمة من المرض، مما قد يؤثر على قدرة النموذج على التعميم، على الرغم من التخفيف الجزئي لهذا الأثر من خلال اعتماد التصنيف الهجين. ثانياً، يعتمد التحليل على مقاطع ثنائية الأبعاد من صور الرنين المغناطيسي بدلاً من البيانات الحجمية الكاملة، الأمر الذي قد يحد من الاستفادة من المعلومات البنيوية ثلاثية الأبعاد للدماغ. وأخيراً، لا تتضمن مجموعة البيانات معلومات طولية أو بيانات سريرية، مما يقيد إمكانية نمذجة تطور المرض عبر الزمن.

4. الاستنتاجات Conclusions

قدّمت هذه الدراسة إطاراً فعالاً ومنتيناً لتصنيف مرض الزهايمر متعدد المراحل باستخدام التصوير بالرنين المغناطيسي MRI وتقنيات التعلّم العميق. ومن خلال دمج تحسين التباين مع استخلاص الميزات العميقة واستراتيجيات التصنيف الهجين، عالجت المنهجية المقترحة عدداً من التحديات الرئيسية في تشخيص مرض الزهايمر اعتماداً على صور MRI، بما في ذلك انخفاض تباين الصور، والفروق الدقيقة بين الفئات المرضية، وعدم توازن البيانات.

أظهرت النتائج التجريبية أن دمج تقنيات تحسين الصور، ولا سيما G-CLAHE، أسهم بشكل ملحوظ في تحسين وضوح البنى الدماغية ذات الأهمية التشخيصية، وعزّز قابلية تمييز الميزات العميقة. وقد حقق نموذج الشبكة العصبية الالتقافية المستقل CNN دقة تصنيف كلية بلغت 96%، مما يؤكد فعالية المعالجة المسبقة المحسّنة بالتباين عند دمجها مع استخلاص الميزات المعتمد على التعلّم العميق.

علاوة على ذلك، تفوّق الإطار الهجين المقترح CNN+SVM بشكل متسق على نموذج CNN المستقل، محققاً دقة كلية بلغت 97%، ومتوسط F1 كلي قدره 0.98، ومتوسط ROC-AUC بلغ 0.9954. وقد أظهر النهج الهجين متانة وحساسية أعلى، لا سيما في المراحل المرضية ضعيفة التمثيل، وتؤكد هذه النتائج أن الإطار المقترح يحقق توازناً ملائماً بين أداء التصنيف، والمتانة، والكفاءة الحسابية.

كما أسهم دمج تقنيات الذكاء الاصطناعي القابل للتفسير باستخدام Grad-CAM++ في تعزيز شفافية النموذج وأهميته السريرية. إذ أبرزت خرائط التنشيط مناطق تشريحية ذات معنى سريري واضح، مثل الحُصين والفصوص الصدغية الإنسية، المعروفة بتأثرها المبكر في مرض الزهايمر. ويعزز هذا التوافق بين تركيز النموذج والأنماط العصبية المرضية المعروفة قابلية تفسير النظام وإمكانية اعتماده سريريّاً.

وبوجه عام، تشير النتائج إلى أن الإطار المقترح المعتمد على صور MRI يوفّر حلاً موثوقاً وعملياً لتصنيف مراحل مرض الزهايمر باستخدام وسيلة تصوير واحدة فقط. وبالمقارنة مع المقاربات متعددة الوسائط الأكثر تعقيداً، يحقق هذا النهج أداءً تنافسياً مع متطلبات حسابية أقلّ وعمليات جمع بيانات أبسط.

5. الأعمال المستقبلية Future Work

يمكن استكشاف عدة اتجاهات لتطوير الإطار المقترح مستقبلاً. أولاً، يمكن دراسة دمج وسائل تصوير إضافية، مثل التصوير المقطعي بالإصدار البوزيتروني PET أو التصوير بالرنين المغناطيسي الوظيفي fMRI، إلى جانب المؤشرات الحيوية السريرية أو الجينية، بهدف تحسين دقة التشخيص وتقديم توصيف أكثر شمولية للمرض. ثانياً، قد يتيح توسيع المنهجية لتشمل شبكات CNN ثلاثية الأبعاد وتحليل صور MRI الحجمية الاستفادة من معلومات مكانية أغنى، مما قد يؤدي إلى تحسين إضافي في الأداء.

إضافة إلى ذلك، يمكن في الدراسات المستقبلية استكشاف تقنيات متقدمة لزيادة البيانات وإعادة توازن الفئات للتقليل من تأثير عدم التوازن، لا سيما في المراحل المتقدمة من المرض. كما أن دمج بيانات MRI الطولية قد يتيح نمذجة تطور المرض بمرور الزمن، ودعم التنبؤ المبكر بالتدهور المعرفي.

6. المراجع

- [1] Alzheimer's Association. (2025). 2025 Alzheimer's disease facts and figures. *Alzheimer's & Dementia*, 21(5), 1–XX. <https://alz-journals.onlinelibrary.wiley.com/doi/10.1002/alz.70235>
- [2] Rohani, M. M., Sharifi, S., & Durson, S. (2025). Deep learning in medical imaging for disease diagnosis. *World Journal of Advanced Research and Reviews*, 25(2), 2522–2526. <https://journalwjarr.com/node/772>
- [3] Zhou, J., Park, S., Dong, S., Tang, X., & Wei, X. (2025). Artificial intelligence-driven transformative applications in disease diagnosis technology. *Medical Review*, Advance online publication. <https://doi.org/10.1515/mr-2024-0097>
- [4] Sarraf, S., & Tofghi, G. (2019). DeepAD: Alzheimer's disease classification via deep convolutional neural networks using MRI and fMRI. *Cognitive Systems, Research*, 57, 147–159. <https://doi.org/10.1016/j.cogsys.2019.04.007>
- [5] Sarraf, S., & Tofghi, G. (2016). Classification of Alzheimer's Disease using fMRI Data and Deep Learning Convolutional Neural Networks. *arXiv preprint arXiv:1603.08631*. <https://arxiv.org/abs/1603.08631arXiv+5BioRxiv+5arXiv+5>
- [6] Raza, M. L., Hassan, S. T., Jamil, S., & Hyder, N. (2025). Advancements in deep learning for early diagnosis of Alzheimer's disease using multimodal neuroimaging: challenges and future

- directions. Frontiers in Neuroinformatics. <https://www.frontiersin.org/journals/neuroinformatics/articles/10.3389/fninf.2025.1557177/full>
- [7] Nazir, S. (2025). The future of Alzheimer's disease risk prediction: a systematic review. *Neurological Sciences*. <https://link.springer.com/article/10.1007/s10072-025-08167-x>
- [8] Christodoulou, R. C., & Woodward, A. (2025). Artificial Intelligence in Alzheimer's Disease Diagnosis and Prognosis Using PET-MRI: A Narrative Review of High-Impact Literature Post-Tauvid Approval. *Frontiers in Aging Neuroscience (PMC)*. <https://pmc.ncbi.nlm.nih.gov/articles/PMC12387124/>
- [9] Bhatia, V., Chandel, A., Minhas, Y., & Kushawaha, S. K. (2025). Advances in biomarker discovery and diagnostics for Alzheimer's disease. *Neurological Sciences*. <https://link.springer.com/article/10.1007/s10072-025-08023-y>
- [10] Awang, M. K., Ali, G., & Faheem, M. (2025). Recent Advancements in Neuroimaging-Based Alzheimer's Disease Prediction Using Deep Learning Approaches in e-Health: A Systematic Review. *Health Science Reports*. <https://onlinelibrary.wiley.com/doi/abs/10.1002/hsr2.70802>
- [11] Moraveji, M., & Mansouri, N. (2025). Recent Advances in Computational and Machine-Learning Approaches for Alzheimer's Disease Classification: A Comprehensive Review. *Archives of Computational Methods in Engineering*. <https://link.springer.com/article/10.1007/s11831-025-10476-5>
- [12] Koksalmis, G. H., Soykan, B., & Brattain, L. J. (2025). Artificial Intelligence for Personalized Prediction of Alzheimer's Disease Progression: A Survey of Methods, Data Challenges, and Future Directions. *arXiv preprint*. <https://arxiv.org/abs/2504.21189>
- [13] Ehteshamzad, S. (2024). Assessing the Potential of EEG in Early Detection of Alzheimer's Disease: A Systematic Comprehensive Review (2000–2023). *Alzheimer's Disease Research Journal*. <https://journals.sagepub.com/doi/abs/10.3233/ADR-230159>
- [14] Abdalrada, A. S. (2025). Comprehensive Review of Machine Learning Approaches for Alzheimer's Disease Diagnosis and

- Prognosis. International Journal of Emerging Artificial Intelligence Applications. <https://ijeaa.cultechpub.com/index.php/ijeaa/article/view/25>
- [15] Chowdhury, J. H., et al. (2024). Simple Histogram Equalization Technique Improves Performance of VGG Models on Facial Emotion Recognition. *Algorithms*, 17(6), 238. <https://doi.org/10.3390/a17060238>
- [16] Namazi Nia, S., & Shih, F. Y. (2024). Medical X-Ray Image Enhancement Using Global Contrast-Limited Adaptive Histogram Equalization. *arXiv:2411.01373*. <https://arxiv.org/abs/2411.01373>
- [17] Zhou, Y., Zhang, M., Wang, T., & Li, H. (2024). A review of convolutional neural networks in computer vision. *Artificial Intelligence Review*. <https://doi.org/10.1007/s10462-024-10721-6>
- [18] Guido, R., Ferrisi, S., Lofaro, D., & Conforti, D. (2024). An Overview on the Advancements of Support Vector Machine Models in Healthcare Applications: A Review. *Information*, 15(4), 235. <https://doi.org/10.3390/info15040235>
- [19] Anwar, S., Rehman, A., et al. (2024). Hybrid CNN-SVM Model for Enhanced Early Detection of Chronic Kidney Disease. *Alexandria Engineering Journal*. <https://www.sciencedirect.com/science/article/abs/pii/S174680942401142X>
- [20] Chattopadhyay, A., Sarkar, A., Howlader, P., & Balasubramanian, V. N. (2018). Grad-CAM++: Generalized Gradient-Based Visual Explanations for Deep Convolutional Networks. *Proceedings of the IEEE Winter Conference on Applications of Computer Vision (WACV)*.
- [21] Ahmed, S., Lee, J., & Park, S. (2024). Explainable Deep Learning for Alzheimer's Disease Classification Using Grad-CAM++ on MRI Images. *Journal of Medical Imaging and Health Informatics*, 14(3), 213-223. <https://doi.org/10.1166/jmihi.2024.23312>.
- [22] Alsubaie, M. G., Luo, S., & Shaukat, K. (2024). ConvADD: Exploring a Novel CNN Architecture for Alzheimer's Disease Detection. *International Journal of Advanced Computer Science and Applications*, 15(4), 300–313. <https://doi.org/10.14569/IJACSA.2024.0150431>