



A Lightweight and Accurate Deep Convolutional Neural Network Method based on MRI for the Diagnosis and Classification of Alzheimer's Disease

Elahe Abdolkarimi^{1*}, Yasaman Bakhtiari², Mohammadreza Yazdani³

¹Assistant Professor, Department of Electrical Engineering, Tafresh University, Tafresh, Iran.

²Master's Graduate from Shahab Danesh University, Qom, Iran.

³Assistant Professor, Department of Electrical Engineering, National University of Skill (NUS), Tehran, Iran.

ARTICLE INFO

Article Type:

Original Research

Received: 07.06.2024

Revised: 07.13.2024

Accepted: 08.14.2024

Keyword:

Alzheimer's Disease

Diagnosis

Convolutional Neural Network (CNN)

Brain MRI Images

Classification

Performance Evaluation

*Corresponding Author:

Elahe Abdolkarimi

Email: e_abdolkarimi@tafreshu.ac.ir

ABSTRACT

The Alzheimer's disease, a progressive brain disorder, necessitates timely detection for effective management due to the current diagnostic methods' limitations. The study presents an efficient convolutional neural network (CNN) designed for classifying brain magnetic resonance imaging (MRI) images into four categories related to Alzheimer's disease. To enhance diagnosis, this study proposes two distinct approaches at different stages: (1) using optimized data pre-processing; and (2) designing a lightweight CNN architecture with low complexity and fewer parameters that simultaneously possesses good accuracy, computational efficiency, and excellent performance. The proposed method achieved outstanding results, with a final accuracy of 99.22%, a macro average F1 score of 0.99, an MCC of 0.9870, and a Cohen kappa score (CKS) of 0.9870. In addition to accuracy, the complexity of the proposed model, including the comparison of model size, time elapsed, the number of FLOPs, and the trainable and non-trainable parameters of the proposed method were also thoroughly investigated. This model, with the advantages of high accuracy, reduced FLOPs, faster execution time, and lower memory requirements outperforms other deep learning methods used in recent studies.



EXTENDED ABSTRACT

Introduction

Alzheimer's disease (AD) is the leading form of dementia, characterized by a progressive decline in memory and cognitive functions, followed by impairments in speech, visual-spatial skills, and behavioural changes such as apathy, aggression, and depression. AD is marked by two key neuropathological features: the accumulation of beta-amyloid plaques in neuronal spaces and the formation of neurofibrillary tangles inside neurons due to tau protein hyperphosphorylation. Impaired synaptic function is central to cognitive decline in AD patients, exacerbated by beta-amyloid's toxic effects on mitochondria, leading to neuronal damage. Early diagnosis is crucial for disease management, with machine learning and deep learning techniques emerging as vital tools for diagnosis and classification. Deep learning, noted for its efficiency with large datasets, is increasingly preferred over traditional machine learning methods for brain structure segmentation and AD classification.

Methodology

Figure 1 provides an overview of the design and performance stages of the network. According to Figure 1, this study proposes two distinct approaches at different stages: (1) using optimized data pre-processing, and (2) designing a lightweight and simple CNN architecture with low complexity and fewer parameters that simultaneously possesses good accuracy and excellent performance. 6400 MRI data related to Alzheimer's disease were obtained from the Kaggle dataset, and then the data were preprocessed. Class weight is a technique used during the preprocessing phase to handle class imbalance. Imbalances in class distribution within datasets can significantly impact classification outcomes. Consequently, it becomes essential to incorporate class weighting into the network loss function. This ensures that classes with fewer instances are assigned greater weight and also offsets the influence of classes with larger sample sizes. In addition, the MRI images were resized to 224×224 pixels in size in the preprocessing phase. In the proposed convolutional neural network with a lightweight architectural structure and low complexity, the learning stages were performed by extracting features from the training data, and then the performance of the network was evaluated on the images related to the test dataset and classified into 4 classes: MID, MOD, ND, and VMD.

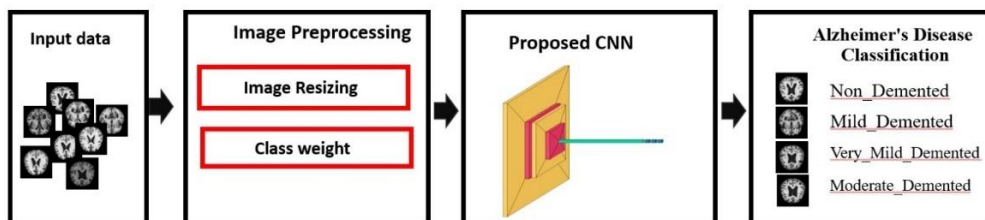


Figure 1. Overall system framework of the methodology.

Results and discussion

Figure 2 depicts the precision, recall, f1-score, and support values associated with each of the four classes within a classification model. Table 1 represents the sensitivity, specificity, and AUC of the model. The proposed method achieved outstanding results, with a final accuracy of 99.22%, a marco average F1 score of 0.99, an MCC of 0.9870, and a Cohen kappa score (CKS) of 0.9870. In addition to accuracy, the complexity of deep learning models should also be considered. In Table 2, a comparison is presented between the result of the proposed model and two relatively light architectures, MobileNetV2 and InceptionV3; the preprocessed data was applied to them. The size plays a crucial role as it dictates the computational expenses involved. In this aspect, the proposed model was remarkable in terms of model accuracy, model size, and time elapsed. Floating point operations per second (FLOPs) are calculated in Table 3 to better express the complexity of the models. Table 4 compares the trainable and non-trainable parameters of the proposed method with those of other deep-learning models. The designed CNN uses fewer parameters in its design, resulting in less memory usage and much faster training and execution times compared to larger networks. Due to its much fewer parameters compared to other deep CNN networks, the designed CNN method has a much faster execution speed while providing very acceptable accuracy, demonstrating its superiority. The proposed CNN architectures require less memory than more complex CNN architectures due to their smaller number of parameters. This can be an advantage when working with limited memory resources. In this study, the time elapsed of 4068.9661543369293 seconds for training the proposed model was significantly less than the time required to train other CNN architectures.

	precision	recall	f1-score	support
Mild_Demented	1.00	0.96	0.98	53
Moderate_Demented	1.00	1.00	1.00	3
Non_Demented	0.99	0.99	0.99	189
Very_Mild_Demented	0.98	0.99	0.99	139
accuracy			0.99	384
macro avg	0.99	0.99	0.99	384
weighted avg	0.99	0.99	0.99	384

Figure 2. Classification report of designed CNN.

Table 1. Statistical results of the model.

	Sensitivity	Specificity	AUC
Mild_Demented	0.96	1.00	0.98
Moderate_Demented	1.00	1.00	1.00
Non_Demented	0.99	0.99	0.99
Very_Mild_Demented	0.99	0.99	0.99

Table 2. Results of the proposed method compared to other the DCNN models.

	Train Accuracy	Validation Accuracy	Test Accuracy	F1-score	MCC	Time Elapsed (s)	Total Params
InceptionV3	0.7601	0.7517	0.7109	0.78	0.4719	14750.527214765549	22059168 (84.15 MB)
MobileNetV2	0.8671	0.8056	0.7865	0.79	0.6038	6387.819058418274	2422208 (9.24 MB)
Proposed Model	1.00	0.9931	0.9922	0.99	0.9870	4068.9661543369293	5406776 (20.63 MB)

Table 3. Comparison of FLOPs with other models.

Model	FLOPs
InceptionV3	3449417648
MobileNetV2	1001225392
Proposed model	120874096

Table 4 Comparison of the trainable and non-trainable parameters of the proposed model and other deep learning models.

Model	Total parameters	Trainable parameters	Non-trainable parameters
ResNet50	27,784,580	27,731,460	53,120
VGG19	21,075,524	21,075,524	0
Xception	25,058,348	25,003,820	54,528
EfficientNetB7	69,343,131	69,032,404	310,727
DenseNet201	22,256,708	22,027,652	229,056
Proposed Model	5,406,776	5,406,776	0

Conclusion

In this study, a lightweight and accurate deep Convolutional Neural Network (CNN) method was presented for the detection and classification of Alzheimer's disease based on brain MRI images. Using Kaggle data consisting of 6400 MRI images related to four different categories of Alzheimer's disease, the proposed model achieved high accuracy by utilizing optimized data processing and designing a simple and lightweight CNN architecture with low complexity and fewer parameters. The results showed that the proposed model achieved a high accuracy of 92.22% and an average F1 score of 0.99. The main advantages of this model compared to other deep CNN models are its higher execution speed and lower memory requirement due to the fewer number of parameters. Ultimately, this study demonstrated that the proposed model, with its lightweight and optimized architecture, can be used as an effective and efficient tool for the detection and classification of Alzheimer's disease using MRI images, and it outperforms other existing models in this field.



یک روش شبکه عصبی پیچشی عمیق سبک و دقیق مبتنی بر MRI برای تشخیص و طبقه‌بندی بیماری آلزایمر

الهه سادات عبدالکریمی^{۱*}، یاسمن بختیاری^۲، محمدرضا یزدانی^۳

۱- استادیار، دانشکده مهندسی برق، دانشگاه تفرش، تفرش، ایران.

۲- دانش‌آموخته کارشناسی ارشد، دانشگاه شهاب دانش، قم، ایران.

۳- استادیار، گروه مهندسی برق، دانشگاه ملی مهارت (NUS)، تهران، ایران.

چکیده

اطلاعات مقاله

نوع مقاله: مقاله پژوهشی

دریافت مقاله: ۱۴۰۳/۰۴/۱۶

بازنگری مقاله: ۱۴۰۳/۰۴/۲۳

پذیرش مقاله: ۱۴۰۳/۰۵/۲۴

کلید واژگان:

بیماری آلزایمر

تشخیص

شبکه عصبی پیچشی (CNN)

تصاویر MRI مغز

طبقه‌بندی

ارزیابی عملکرد

هدف بیماری آلزایمر، یک اختلال پیشرونده مغزی است که تشخیص به‌موقع آن برای مدیریت و درمان مؤثر ضروری است. این مطالعه یک شبکه عصبی پیچشی^۱ (CNN) کارآمد، کم‌حجم و دقیق را برای طبقه‌بندی تصاویر MRI مغز به چهار دسته مرتبط با آلزایمر ارائه می‌دهد. دو رویکرد اصلی برای طراحی روش در زمینه بهبود تشخیص، استفاده شده است: (۱) پیش‌پردازش بهینه داده‌ها و (۲) طراحی یک معماری سبک، کم‌حجم و دارای پیچیدگی کم شبکه عصبی پیچشی که به‌طور هم‌زمان دارای دقت خوب، کارایی محاسباتی و عملکرد عالی می‌باشد. مدل پیشنهادی به‌دقت ۹۹/۲۲ درصد، میانگین امتیاز FI برابر با ۰/۹۹، ضریب همبستگی متیو^۲ (MCC) برابر با ۰/۹۸۷۰ و ضریب کاپا کوهن^۳ (CKC) برابر با ۰/۹۸۷۰ دست یافت. در این تحقیق، علاوه بر دقت، پیچیدگی مدل پیشنهادی، مقایسه اندازه مدل، زمان سپری شده، عملیات نقطه شناور در ثانیه^۴ (FLOPs) و پارامترهای قابل آموزش و غیرقابل آموزش روش پیشنهادی به‌طور کامل مورد بررسی قرار گرفته است. این مدل با داشتن مزایای دقت بالا، کاهش FLOPs، زمان اجرای سریع‌تر و نیاز به حافظه کمتر، در مقایسه با دیگر روش‌های یادگیری عمیق استفاده‌شده در مطالعات اخیر، عملکرد بهتری دارد.

*نویسنده مسئول: الهه سادات عبدالکریمی

پست الکترونیکی:

e_abdolkarimi@tafreshu.ac.ir

¹ Convolutional Neural Network

² Matthews correlation coefficient

³ Cohen's kappa coefficient

⁴ Floating-point operations per second



مقدمه

بیماری آلزایمر به عنوان رایج‌ترین شکل زوال عقل شناخته می‌شود که به‌طور معمول با کاهش تدریجی حافظه اپیزودیک و توانایی‌های شناختی مشخص می‌شود. این کاهش سپس با مشکلاتی در گفتار و مهارت‌های بینایی-فضایی همراه است و اغلب با مسائل رفتاری مانند بی‌تفاوتی، پرخاشگری و افسردگی همراه می‌شود. یافته‌های موجود در [۱] تأثیر جهانی قابل توجه بیماری آلزایمر را از نظر شیوع و تأثیرات بالقوه مداخلات بر کاهش تعداد موارد و نیازهای مراقبتی سطح بالا برجسته می‌کنند. آلزایمر با دو ویژگی آسیب‌شناختی عصبی مشخص می‌شود: از جمله تجمع پلاک‌ها در فضای خارج سلولی نورون‌ها که عمدتاً از پپتیدهای بتا-آمیلوئید تشکیل شده‌اند و تشکیل کلافه‌های نوروفیبریلی در داخل نورون‌ها به دلیل فسفریلاسیون بیش‌ازحد پروتئین‌های تاو. پپتیدهای بتا-آمیلوئید از تجزیه پروتئین پیش‌ساز آمیلوئید تولید می‌شوند. نقص در عملکرد سیناپسی یکی از مهم‌ترین ویژگی‌های آلزایمر است که منجر به ناتوانی‌های شناختی در این بیماران می‌شود. بتا-آمیلوئید یک سم قوی برای میتوکندری‌ها است که باعث اختلالات عملکردی در میتوکندری‌ها و در نهایت منجر به آزاد شدن رادیکال‌های آزاد و آسیب به نورون‌ها می‌شود. تشخیص زود هنگام آلزایمر تأثیر قابل توجهی بر کنترل پیشرفت بیماری دارد. امروزه یکی از فن‌های مهم مورد استفاده در تشخیص و طبقه‌بندی این بیماری، استفاده از الگوریتم‌های یادگیری ماشین و یادگیری عمیق است. در میان پژوهش‌های انجام‌شده با استفاده از روش‌های مختلف یادگیری ماشین مانند نزدیک‌ترین همسایگی^۱ (KNN)، جنگل تصادفی^۲ (RF)، ماشین بردار پشتیبانی^۳ (SVM) و درخت تصمیم^۴ (DT) برای شناسایی بیماری آلزایمر، ما بر تکنیک‌های یادگیری عمیق^۵ متمرکز شده‌ایم. به دلیل توانایی آن‌ها در تولید نتایج کارآمد با مجموعه داده‌های گسترده، الگوریتم‌های یادگیری عمیق برای بخش‌بندی ساختار مغز و طبقه‌بندی بیماری آلزایمر توجه‌ها را جلب کرده‌اند. به همین دلیل، تکنیک‌های یادگیری عمیق در حال حاضر بر روش‌های سنتی یادگیری ماشین ترجیح داده می‌شوند. شبکه عصبی پیچشی^۶ (CNN) در تحلیل تصاویر پزشکی استفاده شده و نتایج چشمگیری در تشخیص ناهنجاری‌های مختلف در تصاویر پزشکی نشان داده است. به عبارت دیگر، بخش‌بندی تصاویر MRI مغز و تشخیص آلزایمر اغلب بر مجموعه داده‌های عمومی موجود، مانند آن‌هایی که توسط سازمان‌هایی نظیر ابتکار تصویربرداری عصبی بیماری آلزایمر (ADNI)، مخزن بخش‌بندی مغزی اینترنتی (IBSR)، و مجموعه مطالعات تصویربرداری با دسترسی آزاد (OASIS) ارائه می‌شوند، تکیه دارد [۲-۴]. در ادامه فهرستی از جدیدترین مقالات منتشرشده با مجموعه داده مرتبط آمده است که با یادگیری عمیق پیشنهاد شده است. برای مثال، مقاله منتشرشده در [۵] مدل‌هایی را معرفی می‌کند که از روش‌های یادگیری ماشین بر روی مجموعه داده ADNI استفاده می‌کنند. این مطالعه نشان می‌دهد که شبکه عصبی‌های ۱۸ لایه نتایج دقیق‌تری نسبت به ۳D CNN دارند و در پیش‌بینی زود هنگام بیماری آلزایمر ۹۸ درصد دقت دارند. در [۶] یک چارچوب انتها به انتهای مبتنی بر شبکه عصبی پیچشی برای طبقه‌بندی آلزایمر پیشنهاد شده است. این چارچوب، دقت بالای طبقه‌بندی دودویی^۷ ۹۹.۶، ۹۹.۸ و ۹۷.۸ درصد برای طبقه‌بندی آلزایمر در مقابل طبقه‌بندی نرمال شناختی^۸ (CN) بر روی مجموعه داده ADNI را به دست آورد. در آزمایش‌های چندطبقه‌بندی^۹، این چارچوب دقت طبقه‌بندی ۹۷.۵ درصد را بر روی همان مجموعه داده

¹ K-nearest neighbor

² Random Forest

³ Support vector machine

⁴ Decision tree

⁵ Deep learning

⁶ Convolutional neural network

⁷ Binary classification

⁸ Cognitively normal

⁹ Multi classification

نشان داد. در [۷] تصویر MRI مجموعه داده کگل^۱ برای تشخیص آلزایمر در مراحل اولیه استفاده شده است. مجموعه‌های معماری‌های EfficientNet-B2 و VGG-16 به کار گرفته شد. نتایج آزمایشی نشان داد که روش پیشنهادی دقت ۹۷/۳۵ درصد و AUC برابر با ۹۹/۶۴ درصد را برای مجموعه داده‌های چندکلاسه و دقت ۹۷.۰۹ درصد و AUC برابر با ۹۹/۵۹ درصد را برای مجموعه داده‌های دودویی به دست آورد. کار انجام شده در [۸] یک راه حل مبتنی بر ابر محلی^۲ برای طبقه‌بندی بیماری آلزایمر با استفاده از اسکن‌های MRI توسعه داده است. این کار از انتقال یادگیری با مدل از پیش آموزش دیده GoogleNet استفاده می‌کند که دقت ۹۸ درصد را در طبقه‌بندی چندکلاسه آلزایمر به دست می‌آورد. نتیجه این کار یک برنامه وب است که پیش‌بینی آلزایمر از راه دور توسط پزشکان را امکان‌پذیر می‌سازد. یک رویکرد شبکه عصبی پیچشی عمیق سه‌بعدی در [۹] برای تمایز زوال عقل خفیف بیماری آلزایمر از اختلال شناختی خفیف و افراد با شناخت نرمال با استفاده از MRI ساختاری پیشنهاد شده است. یک مدل مرجع مبتنی بر حجم و ضخامت ناحیه‌های مغزی نیز برای مقایسه ایجاد شد. محققان تکنیک‌های مختلف تصویربرداری عصبی را برای تشخیص آلزایمر به کار گرفته‌اند. این تکنیک‌ها شامل تصویربرداری تشدید مغناطیسی ساختاری^۳ (SMRI)، تصویربرداری تشدید مغناطیسی عملکردی^۴ (fMRI)، توموگرافی انتشار پوزیترون^۵ (PET)، توموگرافی کامپیوتری انتشار تک فوتون^۶ (SPECT) و تصویربرداری با تانسور انتشار^۷ (DTI) هستند. مطالعات بسیاری از این روش‌ها برای تشخیص یا پیش‌بینی پیشرفت بیماری آلزایمر استفاده کرده‌اند. برای مثال، SMRI در مطالعات [۱۰-۱۵]، fMRI در مطالعات [۱۶؛ ۱۷]، PET در مطالعات [۱۸؛ ۱۹]، SPECT در مطالعات [۲۰-۲۲]، و DTI در مطالعات [۲۳؛ ۲۴] استفاده شده است. این مطالعات به‌طور جمعی پتانسیل عظیم روش‌های یادگیری عمیق، به‌ویژه شبکه عصبی پیچشی‌ها را برای دسته‌بندی دقیق بیماری آلزایمر از تصاویر MRI نشان می‌دهند. دستیابی به دقت، صحت، بازخوانی، امتیاز FI و مقادیر AUC چشمگیر نشان‌دهنده قابلیت این تکنیک‌ها به‌عنوان ابزارهای تشخیصی ارزشمند در زمینه‌های بالینی است. با این حال، در مطالعه حاضر، داده‌ها از سایت کگل دانلود شده‌اند که شامل زوال عقل خفیف^۸ (MID)، زوال عقل متوسط^۹ (MOD)، غیرزوال عقل^{۱۰} (ND) و زوال عقل بسیار خفیف^{۱۱} (VMD) می‌باشد. در مجموع ۶۴۰۰ تصویر MRI شامل هر کدام با یک برچسب از یکی از چهار کلاس مذکور استفاده شده‌اند. در این مطالعه، با انتخاب تکنیک‌های مناسب پیش‌پردازش داده، یک معماری شبکه عصبی پیچشی بسیار سبک و ساده که با پیچیدگی کم طراحی شده است، برای تشخیص و طبقه‌بندی چهار نوع تصویر MRI به کار گرفته می‌شود. این معماری می‌تواند نسبت به معماری‌های پیچیده‌تر شبکه عصبی پیچشی سریع‌تر آموزش ببیند و نیاز به پارامترهای کمتری دارد که منجر به نیاز کمتر به حافظه می‌شود. مدل پیشنهادی با پیچیدگی محاسباتی پایین و عملکرد بهبودیافته، دقت آزمایشی ۹۹/۲۲ درصد در تشخیص و طبقه‌بندی چهار دسته تصاویر MRI به دست آورد که عملکرد مطلوبی در مقایسه با سایر مطالعات مشابه نشان داد. نکته قابل توجه روش پیشنهادی در این مقاله این است که با انتخاب تکنیک‌های مناسب پیش‌پردازش داده و طراحی یک معماری شبکه عصبی پیچشی بسیار سبک با پیچیدگی کم، دقت بسیار بالایی به دست آمده است. در این پژوهش، نتایج با استفاده از

¹ Kaggle

² local cloud-based

³ Structural magnetic resonance imaging

⁴ Functional magnetic resonance imaging

⁵ Positron emission tomography

⁶ Single photon emission computed tomography

⁷ Diffusion tensor imaging

⁸ Mild dementia

⁹ Moderate dementia

¹⁰ Non-demented

¹¹ Very mild dementia

منحنی مشخصه عملکرد گیرنده (ROC)، دقت، صحت، امتیاز FI، بازخوانی، ضریب کاپا کوهن^۱ (CKC) و ضریب همبستگی متیو^۲ (MCC) ارزیابی شده‌اند. نوآوری‌های اصلی مطالعه ما به شرح زیر است:

- این مطالعه دو رویکرد متمایز در مراحل مختلف برای تشخیص بیماری آلزایمر را پیشنهاد می‌کند: (۱) استفاده از پیش‌پردازش داده‌های بهینه و (۲) طراحی یک معماری شبکه عصبی پیچشی سبک با پیچیدگی کم و پارامترهای کمتر که به‌طور هم‌زمان دارای دقت خوب، کارایی محاسباتی و عملکرد عالی باشد.
- این روش نسبت به مطالعات اخیر که از همان مجموعه داده در این زمینه استفاده کرده‌اند، نتایج برجسته‌ای به‌دست آورده است، دقت ۹۹/۲۲ درصد، میانگین امتیاز FI برابر با ۰/۹۹، ضریب همبستگی متیو (MCC) برابر با ۰/۹۸۷۰ و ضریب کاپا کوهن^۳ (CKC) برابر با ۰/۹۸۷۰.
- علاوه بر دقت، پیچیدگی مدل یادگیری عمیق ارائه‌شده، از جمله مقایسه اندازه مدل، زمان سپری‌شده، تعداد عملیات‌های اعشاری شناور^۴ (FLOPs) و پارامترهای قابل آموزش و غیرقابل آموزش روش پیشنهادی، نیز به‌طور کامل با دیگر روش‌های اخیر با همان پایگاه‌های داده بررسی شده است. بنابراین، مدل پیشنهادی مزیتی دارد که دقت بالا را با کاهش FLOPs، زمان اجرای بسیار سریع‌تر نسبت به شبکه‌های بزرگ‌تر و پارامترهای کمتر در طراحی خود به‌دست می‌آورد که منجر به کاهش استفاده از حافظه می‌شود.

مقاله به شرح زیر سازمان‌دهی شده است: بخش روش مقاله به بررسی رویکردها و تکنیک‌های به‌کار گرفته‌شده در طول مطالعه می‌پردازد. این بخش شامل توضیح مجموعه داده، پیش‌پردازش داده‌ها و توضیح دقیق شبکه پیچشی طراحی شده است. بخش نتایج و عملکردها به نتایج و اثربخشی مدل می‌پردازد. این بخش به ارائه یافته‌ها و ارزیابی عملکرد مدل بر اساس روش‌های اجراشده می‌پردازد. بخش بحث شامل تحلیل مقایسه‌ای است. این بخش به مقایسه مدل مورد مطالعه با سایر مجموعه داده‌های مشابه می‌پردازد و نقاط قوت، ضعف و تفاوت‌های قابل توجه را برجسته می‌کند. این بخش به دنبال ارائه درک عمیق‌تری از زمینه مدل در گستره پژوهشی بزرگ‌تر است.

روش‌شناسی

شکل ۱ نمای کلی از مراحل طراحی و عملکرد شبکه را ارائه می‌دهد. بر اساس شکل ۱، این مطالعه دو رویکرد متمایز در مراحل مختلف پیشنهاد می‌کند: (۱) استفاده از پیش‌پردازش داده‌های بهینه‌شده و (۲) طراحی یک معماری شبکه عصبی پیچشی سبک و ساده با پیچیدگی کم و پارامترهای کمتر که به‌طور هم‌زمان دارای دقت خوب و عملکرد عالی باشد. ۶۴۰۰ داده MRI مرتبط با بیماری آلزایمر از مجموعه داده کگل به‌دست آمد و سپس داده‌ها پیش‌پردازش شدند. وزن‌دهی به کلاس یک تکنیک است که در مرحله پیش‌پردازش برای مقابله با عدم توازن کلاس‌ها در داده‌ها به‌کار می‌رود. عدم توازن در توزیع کلاس‌ها در مجموعه داده‌ها می‌تواند به‌طور قابل توجهی بر نتایج طبقه‌بندی تأثیر بگذارد. بنابراین، ضروری است که وزن‌دهی کلاس‌ها در تابع خسارت^۵ شبکه وارد شود. این کار تضمین می‌کند که به کلاس‌هایی با نمونه‌های کمتر وزن بیشتری اختصاص داده شود و همچنین تأثیر کلاس‌های با اندازه نمونه بزرگ‌تر، جبران شود [۲۵]. علاوه بر این، تصاویر MRI در مرحله پیش‌پردازش به‌اندازه 224×224 پیکسل تغییر اندازه داده شدند. در شبکه عصبی پیچشی پیشنهادی با ساختار معماری سبک و پیچیدگی کم، مراحل یادگیری با استخراج ویژگی‌ها از داده‌های

¹ Cohen's kappa coefficient


² Matthews correlation coefficient

³ Cohen's kappa coefficient

⁴ Floating-point operations per second

⁵ Loss


آموزشی انجام می‌شود و سپس عملکرد شبکه بر روی تصاویر مرتبط با مجموعه داده آزمون ارزیابی شدند و تصاویر به چهار طبقه زوال عقل خفیف، زوال عقل متوسط، غیرزوال عقل و زوال عقل بسیار خفیف دسته‌بندی می‌شوند.



شکل ۱. چارچوب کلی مدل پیشنهادی.

مجموعه داده MRI مغز

این کار از مجموعه داده تصاویر MRI عمومی موجود در کگل استفاده می‌کند. انگیزه اصلی از اشتراک گذاری این مجموعه داده به صورت عمومی، پرورش یک مدل با دقت بسیار بالا برای پیش‌بینی مراحل آلزایمر است. مجموعه داده شامل چهار دسته از تصاویر MRI مرتبط با آلزایمر است: زوال عقل خفیف، زوال عقل متوسط، غیرزوال عقل و زوال عقل بسیار خفیف. این مجموعه داده شامل مجموعاً ۶۴۰۰ تصویر MRI است. در این دسته‌ها، گروه زوال عقل خفیف شامل ۸۹۶ تصویر، گروه زوال عقل متوسط شامل ۶۴ تصویر، گروه غیرزوال عقل شامل ۳۲۰۰ تصویر و گروه زوال عقل بسیار خفیف شامل ۲۲۴۰ تصویر است [۲۶]. داده‌ها از منابع مختلف، از جمله وب‌سایت‌ها، بیمارستان‌ها و مخازن عمومی گردآوری شده‌اند که منجر به توزیع نابرابر داده‌ها شده است. بیماری آلزایمر در درجات مختلفی از شدت خود را نشان می‌دهد. در مرحله زوال عقل بسیار خفیف، بیماران با معضلاتی در یادآوری مکان اشیای خود، به دلیل سپردن نام افراد و نگرداشتن اطلاعات مشابه مواجه می‌شوند. این مشکلات به‌ویژه از طریق آزمون‌های توانایی شناختی پیچیده هستند. با پیشرفت بیماری به مرحله زوال عقل خفیف، بیماران در یادآوری کلمات، مسیریابی به مقاصد دلخواه و حفظ تمرکز و ظرفیت کاری با مشکلاتی روبه‌رو می‌شوند. در این مرحله، بیماران ممکن است حتی از میزان از دست دادن حافظه خود، آگاه نباشند و تشخیص عمدتاً از طریق ارزیابی‌های شناختی ممکن است. در مرحله زوال عقل متوسط، بیماران شروع به فراموشی رویدادهای اخیر و جزئیات تاریخی مهم می‌کنند، در محاسبات مالی با مشکلاتی روبه‌رو می‌شوند، در مستقل بیرون رفتن دچار مشکل می‌شوند و همدلی آن‌ها کاهش می‌یابد. شکل ۲ برخی از نمونه‌های تصاویر MRI از مجموعه داده را نشان می‌دهد.



شکل ۲. نمونه‌هایی از تصاویر MRI از مجموعه داده‌ها.

روش انجام آزمایش

پیش‌پردازش تصویر

این مطالعه دو تکنیک متمایز را برای پیش‌پردازش مجموعه داده آرایمر اعمال می‌کند: تکنیک اول شامل استفاده از وزن‌دهی کلاس‌ها برای بهبود عملکرد مدل در مشکلات طبقه‌بندی نابرابر^۱ است [۲۷] که به آن یادگیری حساس به هزینه^۲ گفته می‌شود. یادگیری حساس به هزینه به‌ویژه برای مقابله با مجموعه داده‌های نامتوازن^۳ در یادگیری عمیق، مفید است. با اختصاص وزن‌های بیشتر به کلاس اقلیت و وزن‌های کمتر به کلاس اکثریت، الگوریتم در طول آموزش اهمیت بیشتری به کلاس اقلیت می‌دهد. این به‌طور مؤثر تأثیر هر دو کلاس را در محاسبه خسارت متعادل می‌کند. تکنیک دوم شامل تغییر اندازه تصاویر MRI به 224×224 پیکسل است. برای غلبه بر مسئله توزیع نابرابر داده‌ها و جلوگیری از موانع بیش‌برازش، ما از وزن‌دهی کلاس‌ها^۴ برای تنظیم تابع خسارت در طول آموزش استفاده کردیم [۲۸]. برای وظایف طبقه‌بندی با استفاده از تصاویر MRI، جایی که بیش از دو کلاس دارید (برای مثال مراحل مختلف بیماری آرایمر)، از تکنیک وزن‌دهی به کلاس‌ها استفاده می‌شود. این تابع خسارت برای مشکلات طبقه‌بندی چند کلاسه مناسب است. تابع خسارت اصلاح‌شده کراس-انتروپی پراکنده دسته‌ای با وزن‌دهی به کلاس‌ها از رابطه زیر محاسبه می‌شود:

$$\text{Modified Sparse Categorical Cross – Entropy Loss with Class Weights} = \sum(x_i \times L(y_i, p_i)) \quad (1)$$

¹ Imbalanced

² Cost-sensitive learning

³ Imbalanced datasets

⁴ Class weights

که در آن w_i وزن اختصاص داده شده به کلاس i ، و $L(y_i, p_i)$ تابع خسارت اصلی است که تفاوت بین برچسب واقعی y_i و احتمال پیش‌بینی شده p_i را محاسبه می‌کند. برای دسته‌بندی، معمولاً از تابع خسارت کراس‌انترویی استفاده می‌شود. تابع کراس‌انترویی به صورت زیر تعریف می‌شود:

$$L(y_i, p_i) = - \sum_{c=1}^C y_{i,c} \log(p_{i,c}) \quad (2)$$

که در آن C تعداد کل کلاس‌ها است. $y_{i,c}$ برچسب واقعی برای کلاس c در نمونه i است. ۱ برای کلاس صحیح و ۰ برای بقیه کلاس‌ها می‌باشد. $p_{i,c}$ احتمال پیش‌بینی شده برای کلاس c در نمونه i است. در وزن‌دهی کلاس‌ها z وزن مربوط به کلاس نمونه i است. این وزن به‌طور معمول بر اساس تعداد نمونه‌های هر کلاس تعیین می‌شود. برای مثال، کلاس‌هایی که تعداد نمونه‌های کمتری دارند، وزن بیشتری دریافت می‌کنند تا در طول آموزش اهمیت بیشتری داشته باشند. وزن کلاس z می‌تواند به‌صورت معکوس نسبت به تعداد نمونه‌های آن کلاس تعریف شود.

$$x_j = \frac{N}{N_j} \quad (3)$$

که در آن N تعداد کل نمونه‌ها در مجموعه داده است. N_j تعداد نمونه‌های کلاس j است و در نهایت این جمع کل \sum در فرمول (۱) مجموع تمام خسارت‌ها برای تمام نمونه‌های موجود در مجموعه داده است. به این ترتیب، هر نمونه با وزن مربوط به کلاس خود در محاسبه خسارت نهایی دخالت داده می‌شود.

شبکه عصبی پیچشی طراحی شده

معماری مدل شبکه عصبی پیچشی شامل چندین لایه است، از جمله لایه‌های پیچشی^۱، لایه‌های تجمیع^۲ و لایه‌های کاملاً متصل^۳ [۲۹]. مدل پیشنهادی برای استخراج ویژگی و طبقه‌بندی در تشخیص تصویر طراحی شده است. لایه ابتدایی (conv2d) با ۶ فیلتر ۵×۵ عمل پیچش دوبعدی را انجام می‌دهد و نقشه‌های ویژگی با ابعاد ۲۲۰×۲۲۰ و عمق ۶ تولید می‌کند. سپس، تابع فعال‌سازی ReLU ویژگی‌های غیرخطی را تقویت می‌کند. لایه تجمیع حداکثر (max_pooling2d) ابعاد نقشه‌های ویژگی را به ۱۱۰×۱۱۰ کاهش می‌دهد. لایه پیچشی دوم (conv2d_1) با ۱۶ فیلتر، نقشه‌های ویژگی با ابعاد ۱۰۶×۱۰۶ و عمق ۱۶ ایجاد می‌کند. لایه تجمیع حداکثر دوم (max_pooling2d_1) این نقشه‌ها را به ۵۳×۵۳ کاهش می‌دهد. لایه flatten خروجی را به بردار یک‌بعدی تبدیل می‌کند. سپس، لایه کاملاً متصل (dense) با ۱۲۰ نورون، ویژگی‌ها را به فضای ۱۲۰ بعدی نگاشت می‌کند. لایه بعدی (dense_1) با ۸۴ نورون، تبدیل خطی دیگری اعمال می‌کند. در نهایت، لایه خروجی (dense_2) با ۴ نورون، کلاس‌های پیش‌بینی شده تصویر ورودی را تولید می‌کند. هر نورون به یک کلاس مربوط است و کلاس پیش‌بینی شده با بالاترین مقدار فعال‌سازی تعیین می‌شود. کراس-انترویی دسته‌ای، یک تابع خسارت به‌طور گسترده پذیرفته شده در سناریوهای طبقه‌بندی چندکلاسه است که تفاوت بین احتمالات کلاس‌های پیش‌بینی شده و واقعی را کمی می‌کند. بهینه‌ساز آدام که یک الگوریتم بهینه‌سازی نرخ یادگیری تطبیقی متداول در یادگیری عمیق است، در این زمینه به کار گرفته شده است. سپس مدل با

¹ Convolutional layer

² Pooling layer

³ Fully connected layer

استفاده از مجموعه داده آموزشی آموزش داده می‌شود و با مجموعه داده آزمایشی ارزیابی می‌شود تا کارایی آن در طبقه‌بندی دقیق تصاویر پزشکی مشخص شود. بر اساس شکل ۴، معماری مدل پیشنهادی شامل مجموعاً ۵,۴۰۶,۷۷۶ پارامتر قابل آموزش است که در طول فرایند آموزش بهینه‌سازی می‌شوند تا ویژگی‌های متمایزکننده برای طبقه‌بندی دقیق را یاد بگیرند. شبکه عصبی پیچشی پیشنهادی، تصاویر MRI با ابعاد 224×224 را در ۲۰ دوره^۱ با نرخ یادگیری^۲ 0.001 و بهینه‌ساز Adam آموزش داده است. مدل پس از ۱۲ دوره به دلیل استفاده از روش توقف زود هنگام^۳، متوقف شد. توقف زود هنگام با ارزیابی منظم عملکرد مدل بر روی مجموعه اعتبارسنجی پیاده‌سازی می‌شود و زمانی که عملکرد کاهش یابد، آموزش متوقف می‌شود تا از بیش‌برازش جلوگیری شود. مزایای توقف زود هنگام شامل جلوگیری از بیش‌برازش، بهره‌وری محاسباتی، اجتناب از تنظیم اضافی هایپر پارامترها، بهبود عمومی‌سازی، افزایش سادگی و مقاومت در برابر داده‌های نویزی است. هدف از آموزش، بهینه‌سازی پارامترهای مدل برای حداقل‌سازی تابع خطا است که تفاوت بین پیش‌بینی‌های مدل و برچسب‌های واقعی را اندازه‌گیری می‌کند. تابع ذخیره نقاط برای ذخیره وزن‌های مدل پس از هر دوره استفاده می‌شود و تابع توقف زود هنگام بر عملکرد مدل نظارت می‌کند و در صورت بهبود نیافتن، آموزش را متوقف می‌کند. ماتریس سردرگمی^۴ به‌عنوان ابزار محاسباتی در مسائل دسته‌بندی استفاده می‌شود و دقت، صحت، ویژگی^۵، حساسیت^۶ و معیار F از مقادیر آن محاسبه می‌شوند. این ماتریس تعداد نمونه‌های به‌درستی و به‌اشتباه طبقه‌بندی‌شده را نشان می‌دهد.

$$accuracy = \frac{TP + TN}{TP + FN + TN + FP} \quad (۴)$$

$$specificity = \frac{TN}{TN + FP} \quad (۵)$$

$$precision = \frac{TP}{TP + FP} \quad (۶)$$

$$recall = \frac{TP}{TP + FN} \quad (۷)$$

$$F1 = \frac{2 \times precision \times recall}{precision + recall} \quad (۸)$$

^۱ Epoch

^۲ Learning rate

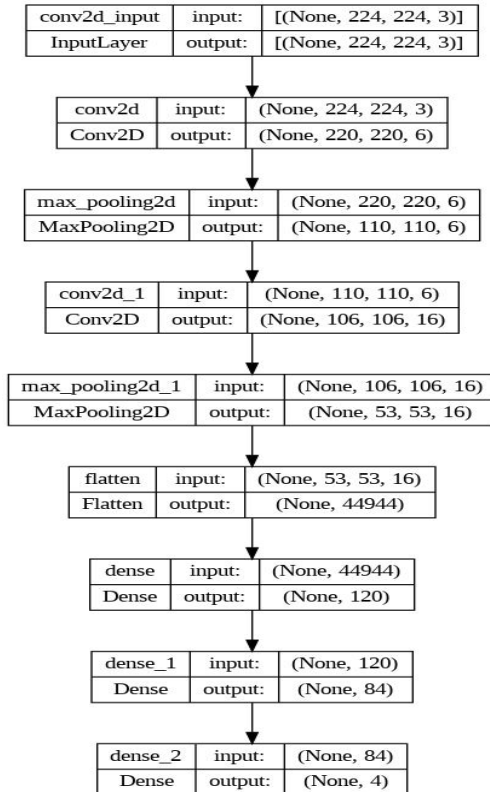
^۳ Early stopping

^۴ Confusion matrix

^۵ Specificity

^۶ Sensitivity

که این مقادیر به‌عنوان موارد مثبت واقعی (TP)، موارد منفی واقعی (TN)، موارد مثبت کاذب (FP) و موارد منفی کاذب (FN) شناخته می‌شوند [۳۰].



شکل ۳. نمودار ساختاری مدل پیشنهادی

Layer (type)	Output Shape	Param #
conv2d (Conv2D)	(None, 220, 220, 6)	456
max_pooling2d (MaxPooling2D)	(None, 110, 110, 6)	0
conv2d_1 (Conv2D)	(None, 106, 106, 16)	2416
max_pooling2d_1 (MaxPooling2D)	(None, 53, 53, 16)	0
flatten (Flatten)	(None, 44944)	0
dense (Dense)	(None, 120)	5393400
dense_1 (Dense)	(None, 84)	10164
dense_2 (Dense)	(None, 4)	340

Total params: 5406776 (20.63 MB)
 Trainable params: 5406776 (20.63 MB)
 Non-trainable params: 0 (0.00 Byte)

شکل ۴. خلاصه‌ای از معماری طراحی‌شده شبکه عصبی پیچشی پیشنهادی.

نتایج و بحث

داده‌های آموزشی برای آموزش مدل استفاده می‌شوند. داده‌های اعتبارسنجی برای تنظیم دقیق مدل در طول فرایند آموزش استفاده می‌شوند که به جلوگیری از بیش‌برازش کمک می‌کند و داده‌های آزمون برای ارزیابی عملکرد مدل بر روی داده‌های جدید و دیده‌نشده حفظ می‌شوند. جداسازی و مدیریت صحیح این مجموعه داده‌ها برای توسعه مدل‌های یادگیری عمیق قابل‌اعتماد و مؤثر، بسیار حیاتی است. دو معیار رایج برای ارزیابی عملکرد شبکه عصبی شامل از خطا و دقت است. نمودارهای خطا و دقت در شکل ۵ آورده شده است. شکل ۶ مقادیر دقت، بازخوانی^۱، امتیاز FI و پشتیبانی مرتبط با هر یک از چهار کلاس را در یک مدل طبقه‌بندی نشان می‌دهد. دقت نسبت پیش‌بینی‌های مثبت واقعی به همه پیش‌بینی‌های مثبت است، درحالی‌که بازخوانی نسبت پیش‌بینی‌های مثبت واقعی به تعداد کل نمونه‌های واقعی مثبت را نشان می‌دهد. امتیاز FI یک معیار متوازن است که میانگین هارمونیک دقت و بازخوانی را نشان می‌دهد. علاوه بر این، پشتیبانی تعداد نمونه‌ها در هر کلاس را نشان می‌دهد. علاوه بر این، در مرحله اجرا برای آزمون مدل پیشنهادی، یک ماتریس سردرگمی تولید شد، همان‌طور که در شکل ۷ نشان داده شده است. این ماتریس شامل معیارهای مهمی است که از طبقه‌بندی صحیح و نادرست تصاویر MRI به‌دست آمده است. مطابق شکل ۸، منحنی ROC نمایش گرافیکی عملکرد طبقه‌بندی مدل‌های یادگیری عمیق راه هم برای سناریوهای دودویی و هم چندکلاسه، ارائه می‌دهد. منحنی ROC یک نمودار با نرخ مثبت واقعی^۲ (TPR) بر روی محور y و نرخ مثبت کاذب^۳ (FPR) بر روی محور x است [۳۰]. منحنی ROC یک مدل کارآمد به گوشه بالای سمت چپ نزدیک خواهد شد که توازن بین نرخ مثبت واقعی (حساسیت یا بازخوانی) و نرخ مثبت کاذب را در سطوح مختلف آستانه مورد استفاده برای طبقه‌بندی موارد مثبت و منفی نشان می‌دهد [۳۱]. در شکل ۸، منحنی همه کلاس‌ها به‌طور قابل‌توجهی به گوشه بالای سمت چپ نزدیک است که نشان‌دهنده عملکرد عالی مدل پیشنهادی است. برای توضیح بیشتر، همان‌طور که در شکل ۸ نشان داده شده است، منحنی‌های زوال عقل خفیف، زوال عقل متوسط، غیرزوال عقل و زوال عقل بسیار خفیف به‌ترتیب به مقادیر AUC برابر با ۰/۹۸، ۱/۰۰، ۰/۹۹ و ۰/۹۹ دست یافتند. این نتایج نشان می‌دهد که مدل پیشنهادی بسیار خوب عمل می‌کند. محدوده MCC از ۱- تا ۱+ است. مقدار ۱+ نشان‌دهنده پیش‌بینی بی‌نقص، ۰ نشان‌دهنده پیش‌بینی مشابه شانس و ۱- نشان‌دهنده تفاوت کامل بین پیش‌بینی و مشاهده واقعی است. به‌عبارت‌دیگر، حداکثر مقدار MCC (۱+) به معنی طبقه‌بندی کامل است [۳۲]. MCC با فرمول زیر تعریف می‌شود:

$$MCC = \frac{TP \times TN - FP \times FN}{\sqrt{(TP + FP)(TP + FN)(TN + FP)(TN + FN)}} \quad (9)$$

مدل پیشنهادی عملکرد عالی را با MCC متوسط ۰/۹۸۷۰ نشان داد. در مورد ضریب کاپا کوهن (CKS)، این معیار به‌عنوان یک معیار قابل‌اعتماد برای ارزیابی همخوانی بین ارزیاب‌های مختلف و همخوانی یک ارزیاب در طول زمان استفاده می‌شود. فرمول محاسبه ضریب کاپا کوهن به شرح زیر است [۳۳]:


$$MCKS = \frac{p_o - p_e}{1 - p_e} \quad (10)$$

¹ Recall

² True positive rate

³ False Positive Rate


که در آن p_0 توافق مشاهده شده است، که نسبت مواردی است که هر دو ارزیاب با هم توافق دارند. p_e توافق مورد انتظار است که نشان‌دهنده توافقی است که به‌طور تصادفی اتفاق می‌افتد. مدل پیشنهادی به ضریب کاپا کوهن متوسط ۰/۹۸۷۰ دست یافت که نشان‌دهنده سطح تقریباً کامل توافق است.




شکل ۵. تحلیل عملکرد آموزش روش پیشنهادی بر روی مجموعه داده آرایمر کگل در طول چندین دوره: نمودارهای خطا و دقت.

	precision	recall	f1-score	support
Mild_Demented	1.00	0.96	0.98	53
Moderate_Demented	1.00	1.00	1.00	3
Non_Demented	0.99	0.99	0.99	189
Very_Mild_Demented	0.98	0.99	0.99	139
accuracy			0.99	384
macro avg	0.99	0.99	0.99	384
weighted avg	0.99	0.99	0.99	384

شکل ۶. گزارش طبقه‌بندی الگوریتم پیشنهادی.



شکل ۷. ماتریس سردرگمی الگوریتم پیشنهادی.



شکل ۸. تحلیل منحنی‌های ROC برای تشخیص بیماری آلزایمر.

مطالعات متعددی در ادبیات بر استفاده از تکنیک‌های یادگیری عمیق برای شناسایی آلزایمر از طریق پردازش تصویر تمرکز کرده‌اند. جدول ۱ مقایسه‌ای جامع از روش پیشنهادی با سایر روش‌های یادگیری عمیق که از پایگاه‌های داده مشابه استفاده کرده‌اند، ارائه می‌دهد. مدل طراحی شده ما نسبت به سایر مدل‌ها عملکرد بهتری دارد. در [۷] مدل از بیش‌نمونه‌برداری^۱ تطبیقی و ترکیب VGG۱۶ و EfficientNet-B۲ برای شناسایی بیماری آلزایمر استفاده می‌کند. این مدل به دقت ۹۷.۳۵ درصد و AUC برابر با ۹۹.۶۴ درصد برای طبقه‌بندی چندکلاسه و دقت ۹۷.۰۹ درصد و AUC برابر با ۹۹.۵۹ درصد برای طبقه‌بندی دودویی دست یافته است. در [۳۳]، یک مدل هوش مصنوعی ترکیبی با استفاده از یادگیری انتقالی و یادگیری ماشین مبتنی بر جایگشت معرفی شده است. مدل شامل DenseNet-۱۲۱ و DenseNet-۲۰۱ برای استخراج ویژگی و SVM، Naïve Bayes و XGBoost برای طبقه‌بندی است. مدل به دقت ۹۱.۷۵ درصد، ویژگی ۹۶.۵ درصد و امتیاز F1 برابر با ۹۰.۲۵ دست یافته است. در [۳۴]، یک مدل یادگیری عمیق سبک برای شناسایی آلزایمر از تصاویر MRI معرفی شده است. مدل شامل تنها هفت لایه است و دقت کلی ۹۵.۹۳ درصد برای طبقه‌بندی چندکلاسه را ارائه می‌دهد. در [۳۵]، شبکه DEMentia NETwork برای شناسایی مراحل زوال عقل از مجموعه داده MRI مغز طراحی شده است و به دقت ۹۵.۲۳ درصد، AUC برابر با ۹۷ درصد و امتیاز کاپای ۰.۹۳ دست یافته است. در [۳۶] دو شبکه عصبی عمیق، AlexNet و ResNet۵۰، برای طبقه‌بندی و تشخیص بیماری آلزایمر استفاده شده‌اند. AlexNet به دقت ۹۴.۵۳ درصد، ویژگی ۹۸.۲۱ درصد، نمره F1 برابر با ۹۴.۱۲ درصد و حساسیت ۱۰۰ درصد دست یافته است. در [۳۷]، یک مدل یادگیری عمیق مبتنی بر شبکه عصبی پیچشی برای طبقه‌بندی چهار کلاس آلزایمر استفاده شده است. کلاس زوال عقل متوسط بالاترین دقت ۸۹.۹ درصد، نرخ خطای طبقه‌بندی ۰.۰۱ و ویژگی ۹۹.۲ درصد را نشان داده است. در [۳۸] از یادگیری انتقال عمیق و تصاویر MRI برای شناسایی مراحل بیماری آلزایمر استفاده شده است. DenseNet۲۰۱ با دقت اعتبارسنجی ۹۶.۵۹ درصد از دیگر مدل‌ها پیشی گرفته است. در [۳۹] مدل‌های مختلف شبکه عصبی پیچشی برای طبقه‌بندی مراحل مختلف بیماری آلزایمر استفاده شده‌اند. Alz-MobileConvNet به‌عنوان مؤثرترین روش برای طبقه‌بندی چندکلاسه شناخته شده و به دقت ۹۴ درصد دست یافته است. در [۴۰] الگوریتم یادگیری عمیق با استفاده از یک طبقه‌بندی‌کننده شبکه عصبی با استخراج ویژگی به کمک VGG۱۶ برای

¹ Oversampling

تشخیص زودهنگام بیماری آلزایمر به کار گرفته شده است. نتایج شامل دقت ۹۰/۴ درصد، صحت ۹۰/۵ درصد، یادآوری ۹۰/۴ درصد، ۹۶/۹ درصد برای AUC و امتیاز F1 برابر با ۹۰/۴ درصد هستند. در [۴۱] شبکه شناسایی بیماری آلزایمر (ADD-Net) معرفی شده که به دقت ۹۶.۷ درصد، صحت ۹۷ درصد و حساسیت ۹۷ درصد دست یافته است. این مدل با استفاده از تکنیک نمونه برداری بیش سازگاری مصنوعی برای مدیریت عدم توازن کلاسها استفاده شده است. در [۴۲]، عملکرد طبقه بندی شش شبکه از پیش آموزش دیده^۱ مقایسه می شود. شبکه های VGG-۱۶، VGG-۱۹، Inception-V3، Xception، ResNet-۵۰ و DenseNet۱۶۹ به ترتیب دارای دقت کلی ۹۲/۸۶، ۹۲/۸۳، ۹۱/۰۴، ۹۰/۵۷، ۸۵/۹۹ و ۸۶/۶۴ درصد در تشخیص آلزایمر هستند. با این حال، روش پیشنهادی دقت و عملکرد بالاتری را نسبت به همه تحقیقات مورد مقایسه در جدول ۱ دارد.

بررسی پیچیدگی مدل

علاوه بر دقت، پیچیدگی مدل های یادگیری عمیق نیز باید در نظر گرفته شود. در جدول ۲، مقایسه ای بین نتایج مدل پیشنهادی ما و دو معماری نسبتاً سبک، MobileNetV2 و InceptionV3 با سایز داده ورودی ۲۲۴ × ۲۲۴ ارائه شده است. ما داده های پیش پردازش شده خود را به آن ها اعمال کردیم. اندازه مدل، نقش مهمی دارد زیرا هزینه های محاسباتی مرتبط را دیکته می کند. در این جنبه، مدل پیشنهادی از نظر دقت مدل، اندازه مدل و زمان سپری شده، قابل توجه است.

جدول ۱. نتایج مطالعات اخیر بر روی همان پایگاه های داده در مقایسه با مدل پیشنهادی برای طبقه بندی چند کلاسه با مجموعه داده کگل.

روش	AUC	معیار F1	فراخوانی	صحت	دقت (درصد)	سال	مقاله
VGG-۱۶+EfficientNet-B۲	۰/۹۹۶۴	۹۷/۳۷	۹۷/۳۵	۹۷/۳۲	۹۷/۳۵	۲۰۲۳	[۷]
DenseNet۱۲۱ with SVM, Gaussian NB, XGBoost classifiers	-	-	-	-	(SVM) ۸۹/۸۹	۲۰۲۲	[۳۳]
	-	-	-	-	(GNB) ۸۹/۱۸		
	-	-	-	-	(XG) ۸۸/۲۵		
Densenet۲۰۱ with SVM, Gaussian NB, XGBoost class	-	-	-	-	(SVM) ۹۱/۰۳	۲۰۲۲	[۳۳]
	-	-	-	-	(GNB) ۹۱/۷۵		
	-	-	-	-	(XG) ۹۱/۱۳		
Lightweight Deep Model	-	۹۵/۹۰	۹۵/۸۸	۹۵/۹۳	۹۵/۹۳	۲۰۲۳	[۳۴]
DEMNET	۰/۹۷	۹۵/۲۷	۹۵	۹۶	۹۵/۲۳	۲۰۲۱	[۳۵]
AlexNet	۰/۹۹۱۳	۰/۹۴/۱۲	-	-	۸۸/۸۹	۲۰۲۲	[۳۶]
Restnet۵۰	-	۷۵/۱۴	-	-	۵۸/۰۷	۲۰۲۲	[۳۶]
Non_Demented DCNN	-	-	-	-	۰/۶۹۳	۲۰۲۲	[۳۷]

^۱ Pre-trained

مقاله	سال	دقت (درصد)	صحت	فراخوانی	معیار F1	AUC	روش
		۰/۶۶۸	۰/۵۲۸				Very_Mild_Demented
		۰/۸۱۲	۰/۳۹۹				Mild_Demented
		۰/۹۸۹	۰/۴۴۴				Moderate_Demented
[۳۸]	۲۰۲۳	۹۶/۵۹	-	-	-	-	DenseNet۲۰۱
		۰/۹۲	۰/۹۲	۰/۹۳	۰/۹۲		Alz-DenseConvNet
		۰/۹۳	۰/۹۲	۰/۹۲	۰/۹۳	-	Alz-VGGConvNet
[۳۹]	۲۰۲۳	۰/۶۹	۰/۷	۰/۶۹	۰/۷	-	Alz-ResConvNet
		۰/۹۴	۰/۹۳	۰/۹۳	۰/۹۴	-	Alz-MobileConvNet
		۰/۸۸	۰/۸۷	۰/۸۷	۰/۸۸	-	Alz-XceptionConvNet
[۴۰]	۲۰۲۲	۹۰/۴	۰/۹۰۵	۰/۹۰۴	۰/۹۰۴	۰/۹۶۹	NN+ VGG16 feature extraction
[۴۱]	۲۰۲۲	۹۷/۰۵	۹۷	۹۷	۹۷/۰۵	۰/۹۹۸۹	ADD-Net+ SMOTE
		۹۲/۸۶	-	-	-	-	VGG-۱۹
		۹۲/۸۳	-	-	-	-	VGG-۱۶
[۴۲]	۲۰۲۴	۹۱/۰۴	-	-	-	-	Inception-V۳
		۹۰/۵۷	-	-	-	-	Xception
		۸۵/۹۹	-	-	-	-	ResNet-۵۰
		۸۸/۶۴	-	-	-	-	DensNet-۱۶۹
		۹۶/۲۲	۱/۰۰	۰/۹۶	۰/۹۸	۰/۹۸	Mild_Demented
		۱۰۰	۱/۰۰	۱/۰۰	۱/۰۰	۱/۰۰	Moderate_Demented
		۹۹/۲۸	۰/۹۹	۰/۹۹	۰/۹۹	۰/۹۹	Non_Demented
		۹۹/۴۷	۰/۹۸	۰/۹۹	۰/۹۹	۰/۹۹	Very_Mild_Demented

روش پیشنهادی

جدول ۲. مقایسه نتایج مدل پیشنهادی با سایر مدل‌های کم‌حجم.

روش	تعداد کل پارامترها	مدت‌زمان اجرا (ثانیه)	MCC	F1-score	دقت آزمون	دقت اعتبارسنجی	دقت آموزش
InceptionV۳	۲۲۰۵۹۱۶۸ (۸۴/۱۵ MB)	۱۴۷۵۰۵۲۷۲۱۴۷۶۵۵۴۹	۰/۴۷۱۹	۰/۷۸	۰/۷۱۰۹	۰/۷۵۱۷	۰/۷۶۰۱
MobileNet V۲	۲۴۲۲۰۸ (۹/۲۴ MB)	۶۳۸۷۸۱۹۰۵۸۴۱۸۲۲۴	۰/۶۰۳۸	۰/۷۹	۰/۷۸۶۵	۰/۸۰۵۶	۰/۸۶۷۱
مدل پیشنهاد شده	۵۴۰۶۷۷۶ (۲۰/۶۳ MB)	۴۰۶۸۹۶۶۱۵۴۳۳۶۹۲۹۳	۰/۹۸۷۰	۰/۹۹	۰/۹۹۲۲	۰/۹۹۳۱	۱/۰۰

علاوه بر این، تعداد عملیات نقطه شناور در ثانیه (FLOPs) در جدول ۳ محاسبه شده است تا پیچیدگی مدل‌ها بهتر بیان شود. با تخمین تعداد FLOPs مورد نیاز برای اجرای یک الگوریتم، محققان می‌توانند گلوگاه‌های احتمالی را شناسایی کنند و الگوریتم را برای کاهش پیچیدگی محاسباتی و بهبود عملکرد مدل بهینه‌سازی کنند. مقدار FLOPs

یک مدل با استفاده از منابع سخت‌افزاری GPU مطابقت دارد. مقدار بالای FLOPs نشان‌دهنده نیازهای محاسباتی بالا است که ممکن است برای مدل نقص محسوب شود. مدل‌هایی با FLOPs بالا ممکن است با دستگاه‌های سخت‌افزاری ضعیف‌تر مانند دستگاه‌های موبایل سازگار نباشند. بنابراین، طراحی مدل‌هایی که با FLOPs کمتر به دقت بالا دست یابند، دارای مزیت است.

جدول ۳. مقایسه تعداد FLOPs مدل پیشنهادی با مدل‌های دیگر.

مدل	FLOPs
InceptionV۳	۳۴۴۹۱۷۶۴۸
MobileNetV۲	۱۰۰۱۲۲۵۳۹۲
مدل پیشنهادی	۱۲۰۸۷۰۹۶

جدول ۴. مقایسه تعداد پارامترهای قابل آموزش و غیرقابل آموزش در مدل پیشنهادی با مدل‌های دیگر.

مدل	تعداد پارامترهای غیرقابل آموزش	تعداد پارامترهای قابل آموزش	تعداد کل پارامترها
ResNet۵۰	۵۳۱۲۰	۲۷۷۳۱۴۶۰	۲۷۷۸۴۵۸۰
VGG۱۹	۰	۲۱۰۷۵۵۲۴	۲۱۰۷۵۵۲۴
Xception	۵۴۵۲۸	۲۵۰۰۳۸۲۰	۲۵۰۵۸۳۴۸
EfficientNetBV	۳۱۰۷۲۷	۶۹۰۳۲۴۰۴	۶۹۳۴۳۱۳۱
DenseNet۲۰۱	۲۲۹۰۵۶	۲۲۰۲۷۶۵۲	۲۲۲۵۶۷۰۸
مدل پیشنهادشده	۰	۵۴۰۶۷۷۶	۵۴۰۶۷۷۶

جدول ۴ پارامترهای قابل آموزش و غیرقابل آموزش روش پیشنهادی را با سایر مدل‌های یادگیری عمیق مقایسه می‌کند. طراحی شبکه عصبی پیچشی پیشنهادی از پارامترهای کمتری استفاده می‌کند که منجر به کاهش استفاده از حافظه و زمان آموزش و اجرای بسیار سریع‌تر نسبت به شبکه‌های بزرگ‌تر می‌شود. این روش به دلیل تعداد کمتر پارامترها، سرعت اجرای بسیار بالاتری دارد و درعین حال دقت قابل‌قبولی ارائه می‌دهد که این یک مزیت مهم است. این ویژگی به‌ویژه در کار با مجموعه داده‌های بزرگ‌تر مانند مجموعه داده آلزایمر کگل و در مواقع محدودیت زمانی، مفید است. معماری‌های پیشنهادی شبکه عصبی پیچشی به حافظه کمتری نیاز دارند که این امر هنگام کار با منابع حافظه محدود یک مزیت محسوب می‌شود. زمان آموزش مدل پیشنهادی ۴۰۶۸.۹۷ ثانیه است که به‌طور قابل‌توجهی کمتر از زمان موردنیاز برای آموزش سایر معماری‌های شبکه عصبی پیچشی است.

نتیجه‌گیری

در این مطالعه، یک روش شبکه عصبی پیچشی عمیق سبک و دقیق برای تشخیص و طبقه‌بندی بیماری آلزایمر بر اساس تصاویر MRI مغز ارائه شده است. با استفاده از داده‌های کگل شامل ۶۴۰۰ تصویر MRI مربوط به چهار دسته مختلف بیماری آلزایمر، مدل پیشنهادی از بهره‌گیری از پردازش پهنه داده‌ها و طراحی یک معماری CNN ساده و سبک با پیچیدگی کم و تعداد پارامترهای کمتر، توانست به دقت بالایی دست یابد. نتایج نشان داد که مدل پیشنهادی با دقت ۹۲/۲۲ درصد و میانگین F1 برابر ۰/۹۹ عملکرد بسیار مطلوبی دارد. مزیت اصلی این مدل در مقایسه با سایر مدل‌های شبکه عصبی پیچشی، سرعت اجرای بالاتر و نیاز به حافظه کمتر است که به دلیل تعداد پارامترهای کمتر آن می‌باشد.

این مسئله اهمیت زیادی در فرایند توسعه و بهینه‌سازی مدل دارد. درنهایت، این مطالعه نشان داد که مدل پیشنهادی با معماری سبک و بهینه خود، می‌تواند به‌عنوان یک ابزار مؤثر و کارآمد برای تشخیص و طبقه‌بندی بیماری آلزایمر با استفاده از تصاویر MRI مورد استفاده قرار گیرد و عملکرد بهتری در مقایسه با سایر مدل‌های موجود در این حوزه دارد.

References

- [1] Brookmeyer, R., Johnson, E., Ziegler-Graham, K., & Arrighi, H. M. (2007). Forecasting the global burden of Alzheimer's disease. *Alzheimer's & Dementia*, 3(3), 186-191. <https://doi.org/10.1016/j.jalz.2007.04.381>
- [2] Aparna, M., & Rao, B. S. (2023). Xception-Fractalnet: Hybrid Deep Learning Based Multi-Class Classification of Alzheimer's Disease. *Computers, Materials & Continua*, 74(3), 6909-6932. <https://doi.org/10.32604/cmc.2023.034796>
- [3] Dolz, J., Desrosiers, C., & Ben Ayed, I. (2018). 3D fully convolutional networks for subcortical segmentation in MRI: A large-scale study. *NeuroImage*, 170, 456-470. <https://doi.org/10.1016/j.neuroimage.2017.04.039>
- [4] Salami, F., Bozorgi-Amiri, A., Hassan, G. M., Tavakkoli-Moghaddam, R., & Datta, A. (2022). Designing a clinical decision support system for Alzheimer's diagnosis on OASIS-3 data set. *Biomedical Signal Processing and Control*, 74(3), 103527. <https://doi.org/10.1016/j.bspc.2022.103527>
- [5] Patil, V., Madgi, M., & Kiran, A. (2022). Early prediction of Alzheimer's disease using convolutional neural network: a review. *The Egyptian Journal of Neurology, Psychiatry and Neurosurgery*, 58(1), 130. <https://doi.org/10.1186/s41983-022-00571-w>
- [6] AbdulAzeem, Y., Bahgat, W. M., & Badawy, M. (2021). A CNN based framework for classification of Alzheimer's disease. *Neural Computing and Applications*, 33(16), 10415-10428. <https://doi.org/10.1007/s00521-021-05799-w>
- [7] Mujahid, M., Rehman, A., Alam, T., Alamri, F. S., Fati, S. M., & Saba, T. (2023). An Efficient Ensemble Approach for Alzheimer's Disease Detection Using an Adaptive Synthetic Technique and Deep Learning. *Diagnostics*, 13(15), 2489. <https://doi.org/10.3390/diagnostics13152489>
- [8] Pruthviraja, D., Nagaraju, S. C., Mudligiriyappa, N., Raisinghani, M. S., Khan, S. B., Alkhalidi, N. A., & Malibari, A. A. (2023). Detection of Alzheimer's Disease Based on Cloud-Based Deep Learning Paradigm. *Diagnostics*, 13(16), 2687. <https://doi.org/10.3390/diagnostics13162687>
- [9] Liu, S., Masurkar, A. V., Rusinek, H., Chen, J., Zhang, B., Zhu, W., Fernandez-Granda, C., & Razavian, N. (2022). Generalizable deep learning model for early Alzheimer's disease detection from structural MRIs. *Scientific Reports*, 12(1), 17106. <https://doi.org/10.1038/s41598-022-20674-x>
- [10] Balaji, P., Chaurasia, M. A., Bilfaqih, S. M., Muniasamy, A., & Alsid, L. E. G. (2023). Hybridized Deep Learning Approach for Detecting Alzheimer's Disease. *Biomedicines*, 11(1), 149. <https://doi.org/10.3390/biomedicines11010149>
- [11] Cuingnet, R., Gerardin, E., Tessieras, J., Auzias, G., Lehericy, S., Habert, M-O., Chupin, M., Benali, H., & Colliot, O. (2011). Automatic classification of patients with Alzheimer's disease from structural MRI: A comparison of ten methods using the ADNI database. *NeuroImage*, 56(2), 766-781. <https://doi.org/10.1016/j.neuroimage.2010.06.013>
- [12] Davatzikos, C., Bhatt, P., Shaw, L. M., Batmanghelich, K. N., & Trojanowski, J. Q. (2011). Prediction of MCI to AD conversion, via MRI, CSF biomarkers, and pattern classification.

- Neurobiology of Aging*, 32(12), 2322.e19-2322.e27. <https://doi.org/10.1016/j.neurobiolaging.2010.05.023>
- [13] Suk, H-I., Lee, S-W., & Shen, D. (2014). Hierarchical feature representation and multimodal fusion with deep learning for AD/MCI diagnosis. *NeuroImage*, 101, 569-582. <https://doi.org/10.1016/j.neuroimage.2014.06.077>
- [14] Wee, C-Y., Yap, P-T., Li, W., Denny, K., Browndyke, J. N., Potter, G. G., Welsh-Bohmer, K. A., Wang, L., & Shen, D. (2011). Enriched white matter connectivity networks for accurate identification of MCI patients. *NeuroImage*, 54(3), 1812-1822. <https://doi.org/10.1016/j.neuroimage.2010.10.026>
- [15] Zhang, D., & Shen, D. (2012). Predicting future clinical changes of MCI patients using longitudinal and multimodal biomarkers. *PloS one*, 7(3), e33182. <https://doi.org/10.1371/journal.pone.0033182>
- [16] Greicius, M. D., Srivastava, G., Reiss, A. L., & Menon, V. (2004). Default-mode network activity distinguishes Alzheimer's disease from healthy aging: Evidence from functional MRI. *Proceedings of the National Academy of Sciences*, 101(13), 4637-4642. <https://doi.org/10.1073/pnas.0308627101>
- [17] Zhou, L., Wang, Y., Li, Y., Yap, P-T., & Shen, D. (2011). Hierarchical anatomical brain networks for MCI prediction: revisiting volumetric measures. *PloS one*, 6(7), e21935. <https://doi.org/10.1371/journal.pone.0021935>
- [18] Gray, K. R., Wolz, R., Heckemann, R. A., Aljabar, P., Hammers, A., & Rueckert, D. (2012). Multi-region analysis of longitudinal FDG-PET for the classification of Alzheimer's disease. *NeuroImage*, 60(1), 221-229. <https://doi.org/10.1016/j.neuroimage.2011.12.071>
- [19] Suk, H-I., Wee, C-Y., & Shen, D. (2013). Discriminative Group Sparse Representation for Mild Cognitive Impairment Classification. In G. Wu, D. Zhang, D. Shen, P. Yan, K. Suzuki, & F. Wang (Eds.), *Machine Learning in Medical Imaging* (pp. 131-138). Springer International Publishing. https://doi.org/10.1007/978-3-319-02267-3_17
- [20] Chen, Y. J., Deutsch, G., Satya, R., Liu, H-G., & Mountz, J. M. (2013). A semi-quantitative method for correlating brain disease groups with normal controls using SPECT: Alzheimer's disease versus vascular dementia. *Computerized Medical Imaging and Graphics*, 37(1), 40-47. <https://doi.org/10.1016/j.compmedimag.2012.11.001>
- [21] Góriz, J. M., Segovia, F., Ramírez, J., Lassel, A., & Salas-Gonzalez, D. (2011). GMM based SPECT image classification for the diagnosis of Alzheimer's disease. *Applied Soft Computing*, 11(2), 2313-2325. <https://doi.org/10.1016/j.asoc.2010.08.012>
- [22] Hanyu, H., Sato, T., Hirao, K., Kanetaka, H., Iwamoto, T., & Koizumi, K. (2010). The progression of cognitive deterioration and regional cerebral blood flow patterns in Alzheimer's disease: A longitudinal SPECT study. *Journal of the Neurological Sciences*, 290(1-2), 96-101. <https://doi.org/10.1016/j.jns.2009.10.022>
- [23] Graña, M., Termenon, M., Savio, A., Gonzalez-Pinto, A., Echeveste, J., Pérez, J. M., & Besga, A. (2011). Computer Aided Diagnosis system for Alzheimer Disease using brain Diffusion Tensor Imaging features selected by Pearson's correlation. *Neuroscience Letters*, 502(3), 225-229. <https://doi.org/10.1016/j.neulet.2011.07.049>
- [24] Lee, W., Park, B., & Han, K. (2013). Classification of diffusion tensor images for the early detection of Alzheimer's disease. *Computers in Biology and Medicine*, 43(10), 1313-1320. <https://doi.org/10.1016/j.combiomed.2013.07.004>
- [25] Oktavian, M. W., Yudistira, N., & Ridok, A. (2022). Classification of Alzheimer's disease using the Convolutional Neural Network (CNN) with transfer learning and weighted

- loss. *International Association of Engineers Journal of Computer Science*, 50(3), 947-953. <https://doi.org/10.48550/arXiv.2207.01584>
- [26] Liu, Y., Tang, K., Cai, W., Chen, A., Zhou, G., Li, L., & Liu, R. (2022). MPC-STANet: Alzheimer's Disease Recognition Method Based on Multiple Phantom Convolution and Spatial Transformation Attention Mechanism. *Frontiers in Aging Neuroscience*, 14. <https://doi.org/10.3389/fnagi.2022.918462>
- [27] Shu, T., Zhang, B., & Tang, Y. Y. (2020). Sparse Supervised Representation-Based Classifier for Uncontrolled and Imbalanced Classification. *Institute of Electrical and Electronics Engineers Transactions on Neural Networks and Learning Systems*, 31(8), 2847-2856. <https://doi.org/10.1109/TNNLS.2018.2884444>
- [28] Li, Z., Kamnitsas, K., & Glocker, B. (2021). Analyzing Overfitting Under Class Imbalance in Neural Networks for Image Segmentation. *Institute of Electrical and Electronics Engineers Transactions on Medical Imaging*, 40(3), 1065-1077. <https://doi.org/10.1109/TMI.2020.3046692>
- [29] Li, Z., Liu, F., Yang, W., Peng, S., & Zhou, J. (2022). A Survey of Convolutional Neural Networks: Analysis, Applications, and Prospects. *Institute of Electrical and Electronics Engineers Transactions on Neural Networks and Learning Systems*, 33(12), 6999-7019. <https://doi.org/10.1109/TNNLS.2021.3084827>
- [30] Tharwat, A. (2021). Classification assessment methods. *Applied Computing and Informatics*, 17(1), 168-192. <https://doi.org/10.1016/j.aci.2018.08.003>
- [31] Mandrekar, J. N. (2010). Receiver Operating Characteristic Curve in Diagnostic Test Assessment. *Journal of Thoracic Oncology*, 5(9), 1315-1316. <https://doi.org/10.1097/JTO.0b013e3181ec173d>
- [32] Chicco, D., Warrens, M. J., & Jurman, G. (2021). The Matthews Correlation Coefficient (MCC) is More Informative Than Cohen's Kappa and Brier Score in Binary Classification Assessment. *Institute of Electrical and Electronics Engineers Access*, 9, 78368-78381. <https://doi.org/10.1109/ACCESS.2021.3084050>
- [33] Sharma, S., Gupta, S., Gupta, D., Altameem, A., Saudagar, A. K. J., Poonia, R. C., & Nayak, S. R. (2022). HTLML: Hybrid AI Based Model for Detection of Alzheimer's Disease. *Diagnostics*, 12(8), 1833. <https://doi.org/10.3390/diagnostics12081833>
- [34] El-Latif, A. A. A., Chelloug, S. A., Alabdulhafith, M., & Hammad, M. (2023). Accurate Detection of Alzheimer's Disease Using Lightweight Deep Learning Model on MRI Data. *Diagnostics*, 13(7), 1216. <https://doi.org/10.3390/diagnostics13071216>
- [35] Murugan, S., Venkatesan, C., Sumithra, M. G., Gao, X. Z., Elakkiya, B., Akila, M., & Manoharan, S. (2021). DEMNET: A Deep Learning Model for Early Diagnosis of Alzheimer Diseases and Dementia From MR Images. *Institute of Electrical and Electronics Engineers Access*, 9, 90319-90329. <https://doi.org/10.1109/ACCESS.2021.3090474>
- [36] Al-Adhaileh, M. H. (2022). Diagnosis and classification of Alzheimer's disease by using a convolution neural network algorithm. *Soft Computing*, 26(16), 7751-7762. <https://doi.org/10.1007/s00500-022-06762-0>
- [37] Kaur, S., Gupta, S., Singh, S., & Gupta, I. (2022). Detection of Alzheimer's Disease Using Deep Convolutional Neural Network. *International Journal of Image and Graphics*, 22(03), 2140012. <https://doi.org/10.1142/s021946782140012x>
- [38] Sisodia, P. S., Ameta, G. K., Kumar, Y., & Chaplot, N. (2023). A Review of Deep Transfer Learning Approaches for Class-Wise Prediction of Alzheimer's Disease Using MRI

- Images. *Archives of Computational Methods in Engineering*, 30(4), 2409-2429. <https://doi.org/10.1007/s11831-022-09870-0>
- [39] Shukla, A., Tiwari, R., & Tiwari, S. (2023). Alz-ConvNets for Classification of Alzheimer Disease Using Transfer Learning Approach. *Springer Nature Computer Science*, 4(4), 404. <https://doi.org/10.1007/s42979-023-01853-7>
- [40] Sharma, S., Guleria, K., Tiwari, S., & Kumar, S. (2022). A deep learning based convolutional neural network model with VGG16 feature extractor for the detection of Alzheimer Disease using MRI scans. *Measurement: Sensors*, 24, 100506. <https://doi.org/10.1016/j.measen.2022.100506>
- [41] Fareed, M. M. S., Zikria, S., Ahmed, G., Mui Zzud, D., Mahmood, S., Aslam, M., Jillani, S. F., Moustafa, A., & Asad, M. (2022). ADD-Net: An Effective Deep Learning Model for Early Detection of Alzheimer Disease in MRI Scans. *Institute of Electrical and Electronics Engineers Access*, 10, 96930-96951. <https://doi.org/10.1109/ACCESS.2022.3204395>
- [42] Assmi, A., Elhabyb, K., Benba, A., & Jilbab, A. (2024). Alzheimer's disease classification: a comprehensive study. *Multimedia Tools and Applications*, 83(27), 70193-70216. <https://doi.org/10.1007/s11042-024-18306-9>