

A Novel Approach to Alzheimer's Disease Diagnosis: Ensemble of Deep Learning Models for Improved Diagnostic Accuracy

Batool Nederi¹, Shahla Nemati^{2*}, Mohammad Ehsan Basiri³

1. MSc Student, Department of Computer Engineering, Shahrekord University, Shahrekord, Iran.
2. Assistant Professor, Department of Computer Engineering, Shahrekord University, Shahrekord, Iran.
**Corresponding Author, s.nemati@sku.ac.ir*
3. Associate Professor, Department of Computer Engineering, Shahrekord University, Shahrekord, Iran.

Abstract

Introduction: Alzheimer's disease is a common and complex brain disorder that gradually gets worse and is irreversible. It often develops slowly, affecting memory, thinking, and the ability to carry out everyday activities. This disease has presented significant challenges for early diagnosis and treatment. Early detection is vital for improving the quality of life for both patients and their families.

Method: In this research, an ensemble deep learning model for classifying medical images related to Alzheimer's disease is proposed, utilizing seven convolutional neural networks as a foundation. The results of the study demonstrate the high performance of the proposed model compared to other independent deep learning models and traditional ensemble methods.

Results: The proposed model effectively improves the system's accuracy in identifying and classifying different stages of Alzheimer's disease using the CatBoost algorithm in ensemble stage. The F1 score achieved by the proposed model in different classes, especially in the early stages of the disease such as EMCI and MCI, indicates significant achievements. Specifically, these scores demonstrate the model's enhanced ability to accurately diagnose Alzheimer's patients at an early stage, which can have a significant impact on preventive treatments and clinical management.

Compared to independent models, the results obtained from the proposed model indicate superior performance in overall diagnostic accuracy as well as in differentiating between different stages of the disease. For instance, while other models like EfficientNet and DenseNet performed well in specific classes, the proposed model yielded better results in every class. The use of traditional ensemble methods such as voting and maximization also produced acceptable results, but clearly fell short of the performance of the proposed model.

The results also indicate that ensemble learning models like CatBoost can enhance the overall system performance by combining features from different neural networks. This is clearly evident when compared to other ensemble learning methods like AdaBoost and XGBoost.

Another noteworthy point is the importance of data preprocessing steps. Preprocessing steps such as normalization, registration, brain tissue extraction, intensity correction, and segmentation were designed to maximize the quality of the input data, which significantly impacted the final results.

Discussion: In conclusion, this study emphasizes that utilizing advanced deep learning and ensemble learning methods can contribute to the early and accurate identification of Alzheimer's disease. These achievements promise to improve medical diagnostic processes and can pave the way for future research in the field of diagnosing and treating neurological diseases.

Keywords: Alzheimer's disease, Deep learning, Ensemble learning, Convolutional neural network.

یک رویکرد نوین در تشخیص آلزایمر: تلفیق مدل‌های یادگیری عمیق برای بهبود عملکرد تشخیص

دوره پنجم، پاییز ۱۴۰۳
شماره سوم، صص: ۱۵۹-۱۶۹

تاریخ دریافت: ۱۹/۰۴/۱۴۰۳
تاریخ پذیرش: ۲۹/۰۵/۱۴۰۳

بتول نادری^۱، شهلا نعمتی^{۲*}، محمداحسان بصیری^۳

۱- کارشناسی ارشد مهندسی کامپیوتر، دانشکده فنی و مهندسی، دانشگاه شهرکرد، شهرکرد، ایران. bnaderi104@gmail.com

۲- استادیار، گروه مهندسی کامپیوتر، دانشکده فنی و مهندسی، دانشگاه شهرکرد، شهرکرد، ایران. (نویسنده مسئول) s.nemati@sku.ac.ir

۳- دانشیار، گروه مهندسی کامپیوتر، دانشکده فنی و مهندسی، دانشگاه شهرکرد، شهرکرد، ایران. basiri@sku.ac.ir

چکیده: بیماری آلزایمر به‌عنوان یکی از شایع‌ترین و پیچیده‌ترین اختلالات عصبی پیش‌رونده و غیرقابل برگشت در سنین بالا، تاکنون چالش‌های قابل توجهی برای تشخیص و درمان به همراه داشته‌است. این بیماری معمولاً به تدریج و در طول زمان بروز می‌کند و به تدریج بر حافظه، تفکر و توانایی‌های شناختی فرد تأثیری گذارد؛ به طوری که تشخیص زودهنگام آن در بهبود کیفیت زندگی بیماران و خانواده‌های آنها به شدت حیاتی است. در این مقاله یک روش یادگیری عمیق جمعی برای دسته‌بندی تصاویر پزشکی بیماری آلزایمر پیشنهاد شده‌است. در این مدل پیشنهادی از هفت مدل شبکه عصبی کانولوشنی شامل Inception v3، AlexNet، MobileNet، EfficientNet، NASNet و ResNet، DenseNet، CatBoost با هم تلفیق شده‌اند. نتایج این مدل پیشنهادی با روش‌های یادگیری جمعی دیگر مانند XGBoost، AdaBoost، QSVM و همچنین با تکنیک‌های تجمیع نظیر رأی‌گیری و ماکزیمم‌گیری مقایسه شده‌است. نتایج مدل پیشنهادی بر روی مجموعه داده ADNI که شامل تصاویر MRI اسکن‌های مغزی افراد هستند، نشان می‌دهد که مدل پیشنهادی عملکرد بهتری در دسته‌بندی تصاویر پزشکی بیماری آلزایمر دارد. عملکرد مدل پیشنهادی، چه در هر یک از کلاس‌ها و چه در کل، از تمامی مدل‌های یادگیری عمیق مستقل نیز بهتر بوده‌است.

واژه‌های کلیدی: بیماری آلزایمر، یادگیری عمیق، یادگیری جمعی، شبکه عصبی کانولوشنی.

۱. مقدمه

زوال عقل یک اصطلاح کلی برای ازدست‌دادن حافظه و سایر توانایی‌های ذهنی ناشی از تغییرات فیزیکی در مغز است و به حدی شدید است که سبب بروز مشکل در زندگی روزمره می‌شود. زوال عقل سندرمی است که حافظه، تفکر، رفتار و توانایی انجام فعالیت‌های عادی روزمره را ضعیف می‌کند؛ اگرچه زوال عقل عمدتاً افراد مسن را تحت تأثیر قرار می‌دهد، اما بخشی از پیری نیست [۱].

بیماری آلزایمر، شایع‌ترین نوع زوال عقل است که ۶۰ تا ۸۰ درصد موارد را تشکیل می‌دهد. زوال عقل عروقی که پس از سکته مغزی رخ می‌دهد، دومین نوع شایع زوال عقل است. اما بسیاری از شرایط دیگر وجود دارند که می‌توانند علائم زوال عقل را ایجاد کنند، از جمله برخی از آن‌ها مانند مشکلات تیروئید و کمبود ویتامین که برگشت‌پذیر نیز هستند [۲].

بیماری آلزایمر، یک بیماری مزمن و غیرقابل برگشت است که به سلول‌های مغز حمله می‌کند و منجر به اختلال در عملکرد ذهنی می‌شود. آلزایمر یا زوال عقل مراحل متفاوتی دارد. یکی از این مراحل، مرحله پیش‌بالینی^۱ (NC) است که در آن بیمار تغییر خاصی در روزمرگی خود احساس نمی‌کند، اما این مرحله ابتدایی آلزایمر است که در آن مغز به تدریج کوچکتر می‌شود و می‌توان آن را کنترل کرد. پس از مرحله پیش‌بالینی، مرحله بعدی زوال عقل خفیف یا اختلال شناختی خفیف^۲ (MCI) است. در این مرحله، تغییرات جزئی در مغز به وجود می‌آید، هرچند که تأثیر قابل توجهی بر فعالیت‌های روزمره بیمار ندارد. مرحله بعدی مربوط به آلزایمر خفیف^۳ (EMCI) است، که در آن مغز بیشتر کوچک می‌شود و علائم آلزایمر خفیف شروع به بروز می‌کنند و مقداری بر فعالیت‌های روزمره تأثیر می‌گذارند. سپس مرحله‌ای وجود دارد که شامل زوال عقل ناشی از آلزایمر متوسط^۴ (LMCI) است. در این مرحله، علائم شروع به تأثیرگذاری بیشتر می‌کنند و بخش قابل توجهی از فعالیت‌های روزانه فرد را تحت شعاع قرار می‌دهند. مرحله نهایی شامل زوال عقل مرتبط با آلزایمر شدید^۵ (SMC) است. در این مرحله بحرانی، بیماران با چالش‌های متعددی مواجه می‌شوند. این چالش‌ها شامل ازدست‌دادن عمیق حافظه، سردرگمی مداوم، ناتوانی در فهم اطلاعات جدید، تغییرات در شخصیت، مشکلات در گفتار منسجم و دشواری در ابراز مناسب عواطف هستند. اینها مراحل مختلف آلزایمر هستند و طیف آلزایمر نشان‌دهنده زمان لازم برای بروز علائم آن است؛ انتقال از اختلال شناختی خفیف به آلزایمر ممکن است حدود ۲۰ سال طول بکشد. در این مدت، ساختار مغز تغییراتی پیدامی‌کند، که به دلیل تجمع پروتئین آمیلوئید در سلول‌های مغزی و بزرگ شدن بطن‌های مغزی رخ می‌دهد [۳].


تشخیص زود هنگام نه تنها می‌تواند به پزشکان کمک کند تا تصمیمات دقیقی درباره درمان بگیرند بلکه می‌تواند در پیشگیری از عوارض نیز مؤثر باشد. شکل ۱ تفاوت بین مغز طبیعی و مغز آلزایمری

را نشان می‌دهد [۴]. توجه شود که مغز بیمار آلزایمری نه تنها به‌طور قابل توجهی کوچک‌تر از مغز فرد عادی است، بلکه به‌طرز شدیدی تحت تأثیر اختلال عصبی و عوارض عملکردی قرار می‌گیرد. بنابراین ایجاد سیستمی هوشمند که بتواند به تشخیص زود هنگام بیماری آلزایمر کمک کند، هم در بالا بردن کیفیت زندگی افراد و هم در کاهش هزینه‌های درمان این بیماری مؤثر است. بنابراین هدف این پژوهش این است که سیستمی هوشمند برای تشخیص این بیماری پیشنهاد دهد.

عملاً تا به امروز هیچ درمان مؤثری برای بیماری آلزایمر وجود ندارد. با این حال، راه‌هایی وجود دارد که می‌تواند به‌طور موقت روند علائم آلزایمر را کند کرده و کیفیت زندگی بیمار را بهبود بخشد. در این راستا، پژوهش‌های زیادی برای یافتن روش‌های مؤثر تشخیص و درمان بیماری آلزایمر با تمرکز بر پیشگیری از پیشرفت بیماری در طول زمان انجام شده است [۲].

به‌واسطه رشد روزافزون فن‌آوری و کاهش محدودیت ساخت افزارهای رایانشی، روش یادگیری عمیق نیز روزبه‌روز پتانسیل گسترده خود را جهت استفاده در زمینه‌های کاربردی گوناگون نشان می‌دهد. از جمله کاربردهای این روش در حوزه پزشکی، دسته‌بندی تصاویر گوناگون اعم از تصاویر MRI، ماموگرافی، scan CT جهت تشخیص انواع بیماری‌ها، با دقت و سرعتی هرچه بیشتر است [۵].

در این پژوهش، به بررسی دسته‌بندی تصاویر مربوط به بیماری آلزایمر به‌عنوان نمونه‌ای از یادگیری ماشین نظارتی پرداخته می‌شود. این فرایند شامل ارزیابی مدل با مقایسه نتایج آن با برجسب‌های واقعی است. چالش‌های اصلی در یادگیری ماشین سنتی شامل شناسایی و استخراج ویژگی‌های اثرگذار بر نتایج است؛ در حالی که روش‌های نوآورانه سعی دارند این کار را خودکار انجام دهند [۶]. یادگیری عمیق، سعی دارد ویژگی‌های سطح بالا را از داده‌های خام استخراج کند و از آن‌ها برای انجام وظایف مختلف مانند خوشه‌بندی و رده‌بندی استفاده کند. در زمینه تصاویر، خودکارسازی مرحله مهندسی ویژگی‌ها به معنای تشخیص جزئیات مهم در تصویر ورودی است، ولی چالش هزینه‌بر بودن اجرای این فرایند توسط شبکه‌های عصبی کاملاً متصل وجود دارد. به دلیل اینکه هر پیکسل باید به‌عنوان ورودی عمل کند و شبکه‌های کاملاً متصل پارامترهای بسیار بالایی دارند، کارایی آن محدود می‌شود. یکی از بهترین روش‌ها برای استخراج ویژگی در داده‌های تصویری، شبکه‌های عصبی کانولوشن^۶ (CNN) است [۷].



شکل ۱: تفاوت بین مغز سالم و مغز آلزایمر شدید [۴].

این شبکه‌ها با استفاده از لایه‌های مختلف ویژگی‌ها را استخراج و ابعاد داده‌ها را کاهش می‌دهند تا نقشه‌ای کوچکتر از ویژگی‌های

اصلی ایجاد کنند که به عنوان ورودی برای شبکه عصبی دیگر استفاده می شود.

چالش دیگر در پردازش تصاویر، دقت و اطمینان شبکه های عصبی عمیق است. یکی از رویکردها در یادگیری ماشین، یادگیری جمعی است که سعی در ترکیب چندین مدل یادگیرنده دارد تا نتیجه نهایی بهتری به دست آید [۷]. یادگیری جمعی عمیق، ترکیبی از مزایای یادگیری جمعی و یادگیری عمیق را ارائه می دهد و موجب افزایش تعمیم پذیری و بهبود نتایج می شود [۷].

در این پژوهش، یک روش نوین برای طبقه بندی تصاویر پزشکی مرتبط با بیماری آلزایمر ارائه می شود که بر پایه یادگیری عمیق جمعی طراحی شده است. با توجه به ویژگی های شگرف مدل های شبکه های عصبی کانولوشن در استخراج ویژگی ها، در اینجا یک مدل ترکیبی شامل هفت نوع شبکه کانولوشنی معرفی می گردد. علاوه بر این، برای بهره برداری همزمان از مزایای یادگیری جمعی و یادگیری عمیق، از رویکرد یادگیری جمعی عمیق استفاده شده است.

در مدل پیشنهادی، یادگیری عمیق در قالب یک ترکیب مبتنی بر هفت مدل کانولوشنی پیاده سازی می شود، و برای ترکیب این مدل ها از الگوریتم CatBoost بهره برداری می شود.

۲. پیشینه پژوهش

تلفیق روش های یادگیری عمیق برای تشخیص بیماری آلزایمر تاکنون کم تر مورد استفاده بوده است با این حال انتظار می رود که استفاده از تلفیق بتوان از بروزترین مدل های پیشنهاد شده در آخرین پژوهش ها به صورت همزمان استفاده کرده و به نتایج بهتری دست پیدا کرد.

نویسندگان در [۳] به بررسی کارایی مدل های مختلف یادگیری عمیق و ماشین در تشخیص بیماری آلزایمر پرداخته و نشان داده اند که استفاده از مدل های شبکه عصبی کانولوشنی می تواند به بهبود دقت تشخیص مراحل مختلف بیماری آلزایمر کمک کند. آن ها در این تحقیقات به شناسایی دقیق مراحل مختلف شامل کنترل عادی (NC)، نگرانی های قابل توجه حافظه (SMC)، اختلال شناختی خفیف اولیه (EMCI)، اختلال شناختی خفیف پیشرفته (LMCI) و آلزایمر (AD) پرداخته و دقت های مدل ها را اعلام کرده اند.

در [۸] یک روش ترکیبی تصویر چندوجهی برای ادغام دو تکنیک تصویربرداری PET و MRI برای تشخیص بیماری آلزایمر پیشنهاد شده است. همچنین، از ویژگی های استخراج شده از نشانگرهای زیستی تلفیقی و غیرتلفیقی با استفاده از یک استراتژی انتخاب ویژگی مبتنی بر جنگل تصادفی استفاده شده و سپس این ویژگی ها به یک دسته بندی کننده منتقل شده است.

در مطالعه [۹]، یک مدل تجمیعی شامل جنگل تصادفی، پرسپترون چندلایه و SVM برای بهبود دسته بندی بیماری آلزایمر طراحی شده است که موفق به دستیابی به دقت ۹۶٪ در دسته بندی

پنج مرحله بیماری می شود. این مدل برای استفاده از تصاویر MRI بیماران مبتلا به آلزایمر طراحی شده و نشان دهنده عملکرد بهتری نسبت به مدل های قبلی است.

نویسندگان در [۱۰] تحلیل جامعی از شناسایی بیماری آلزایمر با استفاده از تکنیک های یادگیری ماشین ارائه داده اند. با پیش پردازش داده ها و استفاده از تحلیل مؤلفه های اصلی (PCA)، پنج مدل تجمیعی شامل جنگل تصادفی، آدابوست، گرادیان بوسستینگ، درختان اضافی و باگینگ ارزیابی شده اند. عملکرد مدل ها با معیارهایی مانند دقت و امتیاز FI تحلیل شده است.

در [۱۱] یک معماری CNN جدید با استفاده از تصاویر MRI برای تشخیص بیماری آلزایمر با پارامترهای نسبتاً کمی پیشنهاد شده است و راه حل پیشنهادی برای آموزش مجموعه داده های کوچک تر ایده آل است. این مدل پیشنهادی با موفقیت مراحل اولیه بیماری آلزایمر را تشخیص و نقشه های فعال سازی کلاس را به عنوان یک نقشه حرارتی روی مغز نشان می دهد.

در کار [۱۲] از روش های مختلف یادگیری انتقال مبتنی بر شبکه عصبی کانولوشنی، برای دسته بندی باینری و چندطبقه ای بیماری آلزایمر با استفاده از تصاویر MRI مغز استفاده شده است.

نویسندگان در [۱۳] یک دسته بندی عملی بیماری آلزایمر از طریق تصویربرداری مغز مبتنی بر یادگیری عمیق بر روی ۸۵۷۲۱ نمونه انجام داده اند.

در کار [۱۴] استفاده از یک مدل یادگیری عمیق ترکیبی بر اساس طبقه بندی های یادگیری ماشین کوانتومی^۶ برای تشخیص بیماری آلزایمر می پردازد. داده ها از دو مجموعه داده ADNI1 و ADNI2 ترکیب شده اند و ویژگی های مهم با استفاده از مدل های VGG16 و ResNet50 استخراج شده است. در نهایت، ویژگی های استخراج شده به QSVM برای طبقه بندی چهار مرحله آلزایمر (غیردمانس، دمانس خفیف، دمانس متوسط و دمانس شدید) داده شده است. در جدول ۱ خلاصه پژوهش های مشابه سال های اخیر آورده شده است.

۳. مجموعه داده

در این پژوهش، برای تشخیص هوشمند بیماری آلزایمر از مجموعه داده های ADNI استفاده شده است [۱۵]. این تصاویر MRI شامل اسکن های مغزی افرادی هستند که در مراحل مختلف بیماری آلزایمر قرار دارند. تمامی این افراد در گروه سنی میانسال و بالای ۶۰ سال قرار داشته و به واسطه نمرات آزمون (MMSE) به دسته های مختلف تقسیم شده اند. این دسته ها شامل گروه های NC، SMC، EMCI، LMCI، MCI و آلزایمر (AD) می باشند. در مجموع، مجموعه داده مورد استفاده در این پژوهش شامل ۵۰۸ تصویر MRI است که از این تعداد، ۲۰۰ تصویر مربوط به افراد سالم و باقی مانده مربوط به بیماران مبتلا به مراحل مختلف بیماری آلزایمر می باشد [۳].

۱.۳. پیش‌پردازش داده

برای تحلیل تصاویر MRI بیماران مبتلا به آلزایمر، مراحل پیش‌پردازش زیر با استفاده از نرم‌افزار MIPAV [۱۶] انجام شده است:

۱. بازآرایی: در این مرحله، ساختارهای آناتومیک مغز مورد بررسی قرار می‌گیرند و بافت رابط قدامی (AC) و بافت رابط خلفی (PC) شناسایی می‌شوند. این فرآیند برای تعیین خط مرجع دقیق بسیار حیاتی است و اجازه می‌دهد تا تصاویر را در فضایی استاندارد منظم کنیم [۳].
۲. ثبت: تصاویر MRI حاصل از اسکن‌های مختلف بیماران به گونه‌ای هم‌راستا شدند که خصوصیات فضایی مغز حفظ شود. در این مرحله، از روش ثبت B-spline استفاده شده است که با توزیع یکنواخت و پیوسته‌ای از نقاط کنترل، فرآیند ثبت را دقیق‌تر و بهتر انجام می‌دهد [۳].
۳. استخراج بافت مغز: برای تفکیک بافت مغز از پس‌زمینه در تصاویر MRI، الگوریتم تقسیم‌بندی و استخراج مغز^{۱۱} (BSE) به کار گرفته شده است. این الگوریتم شامل مراحل مختلفی چون فیلتر کردن، شناسایی لبه‌ها و اعمال فرایندهای مورفولوژیکی است که به تمایز بهتر مغز از پس‌زمینه کمک می‌کند [۳].

۴. تصحیح سایه^{۱۱}: به منظور بهبود کیفیت تصاویر و حذف ناهنجاری‌های ناشی از سایه و نویز، از الگوریتم تصحیح N3 استفاده شده است. این مرحله به افزایش وضوح و کیفیت تصاویر کمک کرده و داده‌ها را برای تحلیل‌های بعدی آماده می‌سازد [۳].

۵. بخش‌بندی: در نهایت، تصاویر مغز به قسمت‌هایی شامل ماده خاکستری، ماده سفید و مایع مغزی-نخاعی تقسیم شده‌اند. در این مرحله، از الگوریتم خوشه‌بندی Fuzzy C-Means استفاده شده است که امکان انجام بخش‌بندی نرم و دقیقی را فراهم می‌آورد [۳].

این مراحل پیش‌پردازش برای اطمینان از کیفیت و دقت داده‌های ورودی به مدل‌های یادگیری عمیق ضروری بوده و به ما کمک می‌کند تا دقت و کارایی سیستم تشخیص بیماری آلزایمر را افزایش دهیم. پس از تکمیل مراحل پیش‌پردازش، از بین مجموعه‌ای وسیع از فایل‌های با فرمت NIfTI-1، که هر یک شامل ۲۵۵ برش تصویری بودند، تصاویری انتخاب شدند. معیار اصلی برای انتخاب، وضوح و نمایان بودن ساختارهای مغزی و عناصر مرتبط در تصاویر بود. با دقت، مجموعه‌ای شامل ۶۰ تصویر با این ویژگی‌ها برگزیده شد تا تحلیل‌ها بر روی داده‌های اصلی و مفید متمرکز شود. این تصاویر منتخب سپس به فرمت JPG تبدیل شدند. در نهایت، از میان ۴۵۲۱ تصویر انتخاب شده، ۳۶۱۵ تصویر به عنوان داده‌های آموزشی، ۵۴۳ تصویر برای ارزیابی و ۳۶۳ تصویر برای آزمایش در نظر گرفته شده است.

جدول ۱: خلاصه پیشینه پژوهش

ردیف	سال	روش	توضیحات	مجموعه داده	مرجع
۱	۲۰۲۴	یادگیری عمیق با استفاده از مدل‌های CNN	تشخیص مراحل مختلف بیماری آلزایمر با استفاده از مدل‌های پیش‌آموزش دیده	ADNI	[۳]
۲	۲۰۲۳	روش ترکیبی برای ادغام تصاویر PET و MRI	استخراج ویژگی‌ها از نشانگرهای زیستی تلفیق شده و غیرتلفیق شده با استفاده از استراتژی مبتنی بر جنگل تصادفی	ADNI	[۸]
۳	۲۰۲۳	مدل‌های یادگیری ماشین (جنگل تصادفی، پرسپترون چندلایه، SVM)	طبقه‌بندی بیماران به ۵ مرحله بیماری آلزایمر با دقت ۹۶٪	اسکن‌های MRI از بیماران مبتلا به آلزایمر	[۹]
۴	۲۰۲۳	پیش‌پردازش داده‌ها و تحلیل مؤلفه‌های اصلی (PCA) ارزیابی مدل‌های تجمیعی	مدل تجمیعی: جنگل تصادفی، آدا بوست، گرادیان بوستینگ، درختان اضافی و دسته‌بندی	داده‌های استخراج شده از بیماران با ویژگی‌های متنوع	[۱۰]
۵	۲۰۲۲	شبکه تشخیص بیماری آلزایمر (ADD-Net)	طراحی یک مدل CNN برای تشخیص مراحل بیماری آلزایمر با کاهش پارامترها و هزینه‌های محاسباتی. تشکیل نقشه‌های حرارتی برای نمایش فعال‌سازی‌ها بر روی تصاویر MRI.	مجموعه داده تصاویر MRI کگل ^{۱۲}	[۱۱]
۶	۲۰۲۲	یادگیری انتقال با استفاده از مدل‌های CNN (Xception, ResNet101) و InceptionV3	ارزیابی قدرت یادگیری انتقال و تقسیم‌بندی تصاویر MRI به اجزای WM, GM, CSF. آموزش و تست بر روی طبقه‌بندی دوگانه و چهارکلاسه	OASIS, ADNI, AIBL	[۱۲]
۷	۲۰۲۲	یادگیری عمیق و یادگیری انتقالی	ساخت طبقه‌بند MRI بر اساس یادگیری عمیق برای شناسایی بیماری آلزایمر با استفاده از یک مجموعه داده بزرگ و متنوع از MRI.	MIRIAD, OASIS, AIBL	[۱۳]
۸	۲۰۲۴	یادگیری عمیق و دسته‌بند QSVM	استفاده از یک مدل یادگیری عمیق ترکیبی بر اساس طبقه‌بندهای یادگیری ماشین کوانتومی برای تشخیص بیماری آلزایمر	ADNI1, ADNI2	[۱۴]

۴. معماری مدل پیشنهادی

در این پژوهش، برای طبقه‌بندی تصاویر پزشکی مرتبط با بیماری آلزایمر، یک معماری یادگیری عمیق ترکیبی طراحی شده است که از هفت مدل شبکه عصبی کانولوشنی به‌عنوان مدل‌های پایه برای دسته‌بندی تصاویر آلزایمر استفاده می‌کند. این مدل‌ها شامل InceptionV3 [۱۷]، AlexNet [۱۸]، MobileNetV2 [۱۹]، EfficientNet [۲۰]، DenseNet [۲۱]، ResNet [۲۲] و NASNetLarge [۲۳] هستند. سپس این مدل‌ها در فاز تلفیق با استفاده از روش‌های مختلف ترکیب شده و خروجی آن یکی از کلاس‌های مختلف بیماری آلزایمر خواهد بود. معماری مدل پیشنهادی در شکل ۲ نشان داده شده است. هدف از این تلفیق، بهره‌برداری از ویژگی‌های منحصربه‌فرد هر مدل برای بهبود دقت و کارایی سیستم طبقه‌بندی است. در ادامه، هر یک از این مدل‌ها معرفی و ویژگی‌های کلیدی آن‌ها توضیح داده می‌شود و سپس روش‌های مختلف برای تلفیق بیان خواهد شد.



شکل ۲: معماری مدل پیشنهادی

۱.۴. مدل‌های پایه استفاده شده در معماری پیشنهادی

۱.۱.۴. مدل الکسنت

مدل الکسنت یک شبکه عصبی عمیق است که در سال ۲۰۱۲ طراحی و معرفی شد. این شبکه به‌عنوان یکی از نقاط عطف در یادگیری عمیق و بینایی کامپیوتری شناخته می‌شود و نقش مهمی در پیشرفت‌های بعدی در این حوزه ایفا کرده است. الکسنت برنده مسابقه ImageNet در سال ۲۰۱۲ شد و توانست خطای بسیار کمتری نسبت به دیگر روش‌ها در شناسایی تصاویر ارائه دهد [۱۸].

معماری این شبکه عمدتاً از مراحل متوالی تشکیل شده است که شامل لایه‌های کانولوشن، لایه‌های پولینگ^{۱۳}، لایه‌های ReLU و لایه‌های کاملاً متصل^{۱۴} می‌باشد. علت موفقیت الکسنت را می‌توان به برخی از استراتژی‌ها مانند لایه غیرخطی و استفاده از دراپ‌اوت^{۱۵} نسبت داد.

۲.۱.۴. مدل InceptionV3

سال ۲۰۱۴ در مطالعه‌ای با عنوان «رفتار عمیق‌تر با کانولوشن‌ها» [۲۴]، میکرو-معماری Inception معرفی شد. هدف اصلی ماژول Inception این است که به‌عنوان یک «استخراج‌کننده ویژگی چندسطحی» عمل کند. این امر با گنجانیدن کانولوشن‌های ۱×۱، ۳×۳ و ۵×۵ درون یک عنصر شبکه انجام می‌شود. نتایج این کانولوشن‌ها در راستای ابعاد کانال ترکیب شده و سپس به لایه بعدی شبکه منتقل می‌شوند. مدل InceptionV3 در سال ۲۰۱۶ معرفی شد که از یازده ماژول تشکیل شده است که هر کدام شامل لایه‌های ادغام و لایه‌های می‌باشند [۱۷].

۳.۱.۴. مدل ResNet

یک معماری شبکه عصبی عمیق است که توسط محققان مایکروسافت در سال ۲۰۱۵ معرفی شد [۲۲]. هدف اصلی این معماری حل مشکل کاهش دقت در شبکه‌های عصبی عمیق است که با افزایش تعداد لایه‌ها به وجود می‌آید. این مشکل به دلیل دشواری در آموزش شبکه‌های بسیار عمیق و ناپایداری در گرادیان‌ها ایجاد می‌شود. اصلی‌ترین ویژگی ResNet استفاده از بلاک‌های ماندگار است. این بلاک‌ها به شبکه اجازه می‌دهند تا اطلاعات را از لایه‌های قبلی به لایه‌های بعدی منتقل کند و به این ترتیب، مشکل ناپایداری در یادگیری کاهش می‌یابد.

این انتقال اطلاعات به صورت اضافه کردن skip connection انجام می‌شود، به طوری که ورودی بلاک به خروجی آن اضافه می‌شود. این روش باعث می‌شود که شبکه بتواند یادگیری‌های عمیق‌تری داشته باشد و در عین حال از ناپایداری‌های موجود جلوگیری کند [۲۲].

۴.۱.۴. مدل DenseNet

مدل DenseNet یک معماری شبکه عصبی عمیق است که برای مسائل بینایی کامپیوتری طراحی شده است. این معماری برای اولین بار در سال ۲۰۱۷ معرفی شد و به خاطر ساختار منحصربه‌فرد خود در اتصال لایه‌ها، شهرت بسیار یافت [۱۲]. هر لایه با همه لایه‌های قبل از خود ارتباط مستقیم دارد. این به این معنی است که هر لایه ورودی نه تنها از لایه قبلی خود، بلکه از تمام لایه‌های قبل از آن نیز ویژگی‌ها را دریافت می‌کند. این امر منجر به کاهش مشکلاتی مانند فراموشی اطلاعات و بهبود جریان گرادیان می‌شود.

۵.۱.۴. مدل MobilenetV2

یک مدل شبکه عصبی عمیق است که به طور خاص برای استفاده در دستگاه‌های موبایل و کم‌قدرت طراحی شده است. این مدل در سال ۲۰۱۸ توسط گوگل معرفی شد. MobileNetV2 از معماری شبکه‌های عصبی کانولوشنی استفاده می‌کند و بر روی بهینه‌سازی مصرف منابع و سرعت پردازش تمرکز دارد [۱۹].

مدل از ساختاری به نام برش معکوس استفاده می‌کند که شامل لایه‌های کانولوشنی عمیق و توده‌ای است. این ساختار به مدل کمک می‌کند تا ویژگی‌های بیشتری را با تعداد پارامترهای کمتر استخراج کند [۱۹].

۶.۱.۴. مدل NASNetLarge

این مدل در سال ۲۰۱۸ توسط Google Brain معرفی شد [۲۳]. این مدل با استفاده از تکنیکی به نام «جستجوی معماری عصبی» توسعه یافته است. به عبارت ساده‌تر، به جای اینکه یک انسان ساختار شبکه عصبی را طراحی کند، یک الگوریتم هوشمند این کار را انجام داده است. این سیستم می‌تواند تعداد پارامترها را کاهش دهد در حالی که دقت را حفظ می‌کند. همچنین، معماری NasNet شامل طراحی سلول‌های نرمال و کاهش دهنده است و این فرایند همچنین برای افزایش دقت از یادگیری تقویتی استفاده می‌کند [۲۳].

۷.۱.۴. مدل EfficientNetB0

EfficientNetB0 یکی از مدل‌های پیشرفته شبکه‌های عصبی عمیق است که توسط گوگل در سال ۲۰۱۹ معرفی شد [۲۰]. این مدل بخشی از خانواده EfficientNet است که به طور کلی بر روی بهینه‌سازی عملکرد، دقت و کارایی مصرف منابع تمرکز دارد. EfficientNetB0 به عنوان پایه‌گذار این خانواده طراحی شده و به عنوان یک مدل مقیاس پذیر برای یادگیری عمیق در وظایف بینایی ماشین شناخته می‌شود. تمام لایه‌ها با یک نرمال‌سازی دسته‌ای و فعال‌سازی غیرخطی همراه هستند، به جز لایه نهایی کاملاً متصل که فاقد غیرخطی است و به یک لایه سافت‌مکس برای طبقه‌بندی متصل می‌شود.

۲.۴. ترکیب مدل‌ها در معماری پیشنهادی

پس از پیاده‌سازی هر یک از مدل‌های کانولوشنی، مرحله بعدی تلفیق نتایج به دست آمده از این مدل‌ها است. برای این منظور، انواع روش‌های یادگیری جمعی شامل CatBoost، XGBoos، AdaBoost و روش رأی‌گیری اکثریت و ماکزیمم‌گیری و همچنین روش پیشنهادی در [۱۴] بررسی شده است.

۱.۲.۴. الگوریتم CatBoost

الگوریتم CatBoost یک الگوریتم یادگیری جمعی است که به صورت خاص برای مدیریت داده‌های دسته‌ای طراحی شده و از تکنیک‌های گرادینتی برای بهبود دقت پیش‌بینی استفاده می‌کند. این الگوریتم توسط یاندکس توسعه داده شده و از ویژگی‌های خاصی برخوردار است که آن را از سایر الگوریتم‌های گرادینت بوستینگ متمایز می‌سازد [۲۵]. ویژگی‌های خاص الگوریتم CatBoost شامل پشتیبانی از ویژگی‌های دسته‌ای، ترتیب تصادفی، نمایش داده‌های دسته‌ای به روش‌های خاص است. CatBoost با استفاده از ساختار درختی، به

آنالیز و پیش‌بینی داده‌ها می‌پردازد. بهترین درخت برای پیش‌بینی خروجی انتخاب می‌شود و سپس درخت‌های جدید برای تصحیح خطاهای درخت‌های قبلی اضافه می‌گردند. این فرایند به صورت رابطه (۱) نمایش داده می‌شود:

$$F(x) = F_{\{m-1\}}(x) + \eta \cdot h_m(x) \quad (1)$$

که در آن $F(x)$ مدل نهایی پیش‌بینی، $F_{\{m-1\}}(x)$ پیش‌بینی مرحله قبل، η نرخ یادگیری و $h_m(x)$ مدل درختی جدید است.

۲.۲.۴. الگوریتم XGBoost

الگوریتم XGBoost بر اساس تقویت گرادینت عمل می‌کند که در آن مدل‌های ضعیف (معمولاً درختان تصمیم) به تدریج به یکدیگر اضافه می‌شوند تا یک مدل قوی‌تر بسازند. در این الگوریتم از K درخت تجمعی برای تقریب‌سازی خروجی \hat{y}_i به صورت رابطه (۲) استفاده می‌کند [۲۶]:

$$\hat{y}_i = \sum_{k=1}^K w_k f_k(X_i) \quad (2)$$

که در آن، f_k یک درخت طبقه‌بندی و رگرسیون مستقل در هر یک از مراحل k است؛ w_k وزن درخت k ام است که نشان می‌دهد که هر درخت چقدر در پیش‌بینی نهایی تأثیرگذار است. \hat{y}_i خروجی پیش‌بینی شده برای نمونه i است.

۳.۲.۴. الگوریتم AdaBoost

الگوریتم AdaBoost برای ایجاد یک طبقه‌بند قوی از مجموعه‌ای از طبقه‌بندهای ضعیف پیشنهاد شد. الگوریتم AdaBoost مجموعه‌ای از چند مدل ضعیف را ایجاد کرده و در در ابتدا، به هر نمونه آموزشی یک وزن اولیه یکسان اختصاص می‌دهد. سپس یک مدل ضعیف (مانند یک درخت تصمیم ساده) روی مجموعه داده آموزشی با توزیع وزن‌های فعلی آموزش داده می‌شود. در ادامه خطای مدل ضعیف محاسبه شده که این خطا نشان می‌دهد که مدل چقدر در طبقه‌بندی نمونه‌ها اشتباه کرده است. وزن‌های نمونه‌های آموزشی که به طور نادرست طبقه‌بندی شده‌اند، افزایش یافته و در عوض وزن‌های نمونه‌هایی که به طور صحیح طبقه‌بندی شده‌اند، کاهش می‌یابد [۲۷].

۴.۲.۴. الگوریتم QSVM

الگوریتم QSVM یک تکنیک جدید در یادگیری ماشین است که از اصول محاسبات کوانتومی برای بهبود فرآیند دسته‌بندی استفاده می‌کند. این الگوریتم بر پایه روش‌های کلاسیک SVM بنا شده و با بهره‌گیری از توانایی‌های محاسبات کوانتومی، می‌تواند داده‌های پیچیده‌تر و غیرخطی را به شیوه‌ای کارآمدتر پردازش کند. QSVM با استفاده از ویژگی‌هایی مانند سوپروپوزیشن و تداخل کوانتومی، فضای ویژگی‌ها را به طور مؤثرتری تحلیل کرده و مرزهای تصمیم‌گیری دقیق‌تری ایجاد می‌کند. این امر منجر به افزایش دقت در دسته‌بندی

که در آن fn و fp به ترتیب مثبت درست، منفی درست، مثبت کاذب و منفی کاذب است.

۶. نتایج ارزیابی

برای ارزیابی عملکرد مدل پیشنهادی، از مجموعه‌ای از ۳۶۳ تصویر که در طی فرایند یادگیری به مدل‌ها نشان داده نشده بودند، استفاده شد. این تصاویر شامل نمونه‌هایی از مراحل مختلف بیماری آلزایمر بودند. پیکربندی سخت‌افزاری و نرم‌افزاری استفاده شده برای پیاده‌سازی در جدول ۲ آورده شده است. همچنین زمان لازم برای آموزش و استنتاج مدل تجمیعی پیشنهادی در جدول ۳ نشان داده شده است.

جدول ۲: پیکربندی سخت‌افزاری و نرم‌افزاری استفاده شده برای پیاده‌سازی مدل پیشنهادی

مشخصات سخت‌افزاری			نرم‌افزار مورد نیاز
CPU	RAM	GPU	Jupyter notebook
Intel(R)Xeon(R)	۱۲ گیگ	۱۲ گیگ	

جدول ۳: زمان لازم برای آموزش و استنتاج مدل تجمیعی پیشنهادی

نام مدل	زمان لازم برای آموزش و استنتاج
EfficientNetB0	۱۲ ساعت
MobileNetV2	۷ ساعت
DenseNet121	۱۱ ساعت
AlexNet	۱۰ ساعت
InceptionV3	۱۰ ساعت
ResNet50	۸ ساعت
NasNetLarge	۷ ساعت
Majority Voting	۲۰ دقیقه
Maximization Method	۲۰ دقیقه
XGBoost	۱۵ دقیقه
AdaBoost	۱۵ دقیقه
QSVM	۱۵ دقیقه
CatBoost	۱۵ دقیقه
مدل پیشنهادی	۱۵ دقیقه

داده‌ها شده و زمان محاسباتی را نسبت به الگوریتم‌های کلاسیک کاهش می‌دهد. در نتیجه، QSVM پتانسیل بالایی برای کاربردهای مختلف یادگیری ماشین، به‌ویژه در زمینه‌هایی مانند تشخیص الگوها و تحلیل تصویر دارد [۱۴].

۵. روش مقایسه

برای بررسی و ارزیابی عملکرد مدل پیشنهادی حالت‌های زیر در نظر گرفته شده است:

۱- هفت مدل CNN مستقل بر روی مجموعه داده‌های پژوهش آموزش داده می‌شوند تا اساساً عملکرد روش پیشنهادی در برابر عملکرد مدل‌های مستقل سنجیده شود.

۲- یک مدل تلفیقی شامل هفت مدل CNN تشکیل شده و پیش‌بینی هر یک از این مدل‌ها به‌عنوان ورودی برای یک مدل XGBoost در نظر گرفته می‌شود.

۳- یک مدل تلفیقی شامل هفت مدل CNN تشکیل شده و پیش‌بینی هر یک از این مدل‌ها به‌عنوان ورودی یک مدل AdaBoost در نظر گرفته می‌شود.

۴- یک مدل تلفیقی شامل هفت مدل CNN تشکیل شده و پیش‌بینی هر یک از این مدل‌ها به‌عنوان ورودی یک مدل CatBoost در نظر گرفته می‌شود.

۵- یک مدل تلفیقی شامل هفت مدل CNN تشکیل شده و ویژگی‌های هر ۷ مدل با هم ترکیب شده و به‌عنوان ورودی یک مدل CatBoost در نظر گرفته می‌شود.

۶- یک مدل تلفیقی شامل هفت مدل CNN تشکیل شده و ویژگی‌های هر ۷ مدل با هم ترکیب شده و به‌عنوان ورودی یک دسته‌بند QSVM در نظر گرفته می‌شود.

۷- علاوه بر مقایسه با روش‌های یادگیری جمعی بالا عملکرد مدل پیشنهادی با روش‌های تجمیع ساده‌ای مانند ماکزیمم‌گیری و رأی‌گیری اکثریت نیز مقایسه می‌شود.

در این پژوهش از تابع اتلاف categorical_crossentropy، بهینه‌ساز آدام و تابع فعال‌ساز سافت‌ماکس به‌عنوان پارامترهای مدل‌های CNN استفاده شده است. برای ارزیابی عملکرد مدل پیشنهادی در این پژوهش، از معیارهای صحت^{۱۶}، دقت^{۱۷}، یادآوری^{۱۸} و امتیاز F1 برای ارزیابی مدل پیشنهادی استفاده شده است که به‌صورت روابط (۳) - (۶) آمده است [۳].

$$accuracy = \frac{tp + tn}{(tp + fp + tn + fn)} \quad (3)$$


$$precision = \frac{tp}{(tp + fp)} \quad (4)$$

$$recall = \frac{tp}{(tp + fn)} \quad (5)$$

$$F1 = \frac{2 \times precision \times recall}{(precision + recall)} \quad (6)$$

جدول ۴: نتایج نهایی بر اساس امتیاز F1.

نام مدل	امتیاز F1 AD	امتیاز F1 EMCI	امتیاز F1 LMCI	امتیاز F1 MCI	امتیاز F1 NC	امتیاز F1 SMC	امتیاز F1 کل
EfficientNetB0	۶۷	۸۲	۸۸	۷۵	۸۲	۸۸	۸۰٫۳۳
MobileNetV2	۳۸	۴۴	۵۶	۲۵	۶۲	۷۰	۴۹٫۱۶
DenseNet121	۷۷	۷۹	۸۸	۶۳	۸۵	۹۳	۸۰٫۸۳
AlexNet	۵۶	۵۶	۶۲	۴۲	۶۷	۹۲	۶۲٫۵
InceptionV3	۷۸	۷۳	۶۴	۵۷	۸۳	۹۲	۷۴٫۵
ResNet50	۵۳	۵۵	۶۵	۸۲	۶۸	۸۶	۶۸٫۱۶
NasNetLarge	۳۴	۲۸	۴۵	۱۸	۵۶	۷۰	۴۱٫۸۳
Majority Voting	۸۳	۸۲	۹۰	۸۲	۸۷	۹۵	۸۶٫۵
Maximization Method	۸۰	۸۲	۹۰	۸۲	۸۷	۹۵	۸۶
XGBoost	۸۰	۸۴	۸۶	۱۰۰	۸۸	۹۸	۸۹٫۳۳
AdaBoost	۱۵	۲۷	۳۶	۷۸	۸۹	۹۸	۵۷٫۱۶
QSVM	۸۲	۸۶	۹۶	۹۵	۹۳	۹۸	۹۱٫۶۶
CatBoos	۸۲	۸۷	۹۰	۱۰۰	۹۰	۹۷	۹۱
مدل پیشنهادی	۹۳	۹۳	۹۷	۹۵	۹۴	۹۸	۹۵



شکل ۳: مقایسه مدل پیشنهادی با سایر مدل‌ها بر اساس معیار صحت

بهتری در تمامی کلاس‌ها از خود نشان داده است. به علاوه، نتایج به دست آمده از روش‌های تجمیع سنتی نظیر رأی‌گیری و ماکزیمم‌گیری نیز نشان‌دهنده برتری چشم‌گیر مدل پیشنهادی است. در نهایت، نتایج مربوط به مدل AdaBoost که به ترتیب در کلاس‌های مختلف امتیاز F1 نسبتاً پایینی ارائه داد (حداکثر ۵۷٫۱۶) نشان‌دهنده ضعف این مدل در مقایسه با مدل‌های دیگر و به ویژه مدل پیشنهادی می‌باشد.

این یافته‌ها، اثربخشی و توانایی بالای مدل پیشنهادی در شناسایی و طبقه‌بندی مراحل مختلف بیماری آلزایمر را تأیید می‌کند و بر اهمیت به کارگیری روش‌های یادگیری عمیق جمعی در تشخیص‌های پزشکی تأکید می‌نماید. به ویژه، این نتایج می‌توانند به بهبود فرآیندهای تشخیصی زود هنگام و مدیریت بالینی بیماری آلزایمر کمک کنند.

به منظور تحلیل دقیق سیستم، امتیاز F1 برای هر مدل و در هر کلاس محاسبه شد و نتایج به دست آمده به تفکیک هر مدل نشان داده شده است. جدول ۴ امتیاز F1 برای هر یک از مدل‌ها در کلاس‌های مختلف (AD, EMCI, LMCI, MCI, NC, SMC) و همچنین امتیاز F1 کل را نشان می‌دهد. مقایسه مدل پیشنهادی با سایر مدل‌ها بر اساس معیار صحت نیز در شکل ۳ نشان داده شده است.

نتایج حاصل نشان می‌دهد که عملکرد مدل پیشنهادی نسبت به سایر مدل‌ها به ویژه در تشخیص مراحل ابتدایی بیماران (مانند EMCI و LMCI) بهبود معناداری داشته است. به طور خاص، امتیاز F1 مدل پیشنهادی در کلاس AD معادل ۹۳، در EMCI معادل ۹۳ و در LMCI معادل ۹۷ بوده است که بالاترین امتیازهای کسب شده توسط سایر مدل‌ها را به نمایش می‌گذارد.

در مقایسه با مدل‌های مستقل، همچون EfficientNet، DenseNet و دیگر مدل‌های CNN، مدل پیشنهادی به وضوح عملکرد

۷. نتیجه‌گیری و بحث

بیماری آلزایمر امروزه یکی از چالش‌برانگیزترین اختلالات عصبی است و نیاز به تشخیص زودهنگام آن برای بهبود کیفیت زندگی بیماران و خانواده‌های آنان به شدت احساس می‌شود. در این پژوهش، یک مدل یادگیری عمیق جمعی برای طبقه‌بندی تصاویر پزشکی مربوط به بیماری آلزایمر ارائه داده شده است که از هفت مدل شبکه عصبی کانولوشنی به عنوان پایه استفاده می‌کند. نتایج تحقیق نشانگر عملکرد بالای مدل پیشنهادی در مقایسه با سایر مدل‌های یادگیری عمیق مستقل و روش‌های تجمیع سنتی است.

مدل پیشنهادی با استفاده از الگوریتم CatBoost به طور مؤثری دقت سیستم را در شناسایی و طبقه‌بندی مراحل مختلف بیماری آلزایمر بهبود می‌بخشد. امتیاز F1 به دست آمده از مدل پیشنهادی در کلاس‌های مختلف، به ویژه در مراحل ابتدایی بیماری نظیر EMCI و MCI نشان‌دهنده دستاوردهای قابل توجهی است. به طور خاص، این امتیازات نشان‌دهنده توانایی ارتقا یافته مدل در تشخیص زودهنگام و دقیق بیماران مبتلا به بیماری آلزایمر است که می‌تواند در درمان‌های پیشگیرانه و مدیریت بالینی تاثیرگذار باشد.

در مقایسه با مدل‌های مستقل، نتایجی که از مدل پیشنهادی به دست آمد، نشان‌دهنده برتری در دقت تشخیص کلی و همچنین در تفکیک مراحل مختلف بیماری است. به عنوان مثال، در حالی که مدل‌های دیگری مانند EfficientNet و DenseNet در کلاس‌های خاص عملکرد خوبی داشتند، مدل پیشنهادی در هر کلاس نتایج بهتری ارائه داد. استفاده از روش‌های تجمیع سنتی مانند رأی‌گیری و ماکزیمم‌گیری نیز نتایج قابل قبولی به دست داد، اما به وضوح کمتر از کارایی مدل پیشنهادی است.

نتایج همچنین حاکی از این است که مدل‌های یادگیری جمعی مثل CatBoost می‌توانند با ترکیب ویژگی‌های مختلف شبکه‌های عصبی، عملکرد کلی سیستم را افزایش دهند. این موضوع به وضوح در مقایسه با AdaBoost و XGBoost به عنوان روش‌های دیگر یادگیری جمعی نمایان است.

از دیگر نکات قابل توجه می‌توان به اهمیت مراحل پیش‌پردازش داده‌ها اشاره کرد. مراحل پیش‌پردازش مانند بازآرایی، ثبت، استخراج بافت مغز، تصحیح سایه و بخش‌بندی به نحوی طراحی شده بودند که کیفیت داده‌های ورودی را به حداکثر برسانند و این خود بر نتایج نهایی تأثیر قابل توجهی گذاشت.

در نهایت، این مطالعه تأکیدی می‌کند که بهره‌گیری از روش‌های پیشرفته یادگیری عمیق و یادگیری جمعی می‌تواند به شناسایی زودهنگام و دقیق بیماری آلزایمر کمک کند. این دستاوردها بهبود فرآیندهای تشخیصی پزشکی را نوید می‌دهد و می‌تواند راهگشای تحقیقات آتی در حوزه تشخیص و درمان بیماری‌های عصبی باشد. پژوهش‌های آینده می‌توانند بر روی بهینه‌سازی بیشتر مدل‌ها، ادغام دیگر تکنیک‌ها، و همچنین بررسی تأثیر تغییرات در داده‌های ورودی

متمرکز باشند تا بدین وسیله دقت و کارایی سیستم‌های تشخیصی بهبود یابد.

منابع

- [1] Rawat, R. M., Akram, M., & Pradeep, S. S. (2020, June). Dementia detection using machine learning by stacking models. In 2020 5th International Conference on Communication and Electronics Systems (ICCES) (pp. 849-854). IEEE.
- [2] Dashtipour, K., Taylor, W., Ansari, S., Zahid, A., Gogate, M., Ahmad, J., ... & Abbasi, Q. (2021, December). Detecting Alzheimer's disease using machine learning methods. In *EAI International Conference on Body Area Networks* (pp. 89-100).
- [3] Singh, A., & Kumar, R. (2024). Brain MRI Image Analysis for Alzheimer's Disease (AD) Prediction Using Deep Learning Approaches. *SN Computer Science*, 5(1), 160.
- [4] Taylor, K. (2020). *Dementia: A very short introduction*. Oxford University Press.
- [5] LeCun, Y. (2019, February). 1.1 deep learning hardware: Past, present, and future. In *2019 IEEE International Solid-State Circuits Conference-(ISSCC)* (pp. 12-19). IEEE.
- [6] Garg, A., & Mago, V. (2021). Role of machine learning in medical research: A survey. *Computer science review*, 40, 100370.
- [7] Dong, X., Yu, Z., Cao, W., Shi, Y., & Ma, Q. (2020). A survey on ensemble learning. *Frontiers of Computer Science*, 14, 241-258.
- [8] Shukla, A., Tiwari, R., & Tiwari, S. (2023). Alzheimer's disease detection from fused PET and MRI modalities using an ensemble classifier. *Machine Learning and Knowledge Extraction*, 5(2), 512-538.
- [9] Nykoniuka, M., Melnykovab, N., Paterehac, Y., Salad, D., & Cichońe, D. (2023). Classification of Patients with the Development of Alzheimer's Disease using an Ensemble of Machine Learning Models. *Proceedings* <http://ceur-ws.org> ISSN, 1613, 0073.
- [10] Chandralekha, E., Gokila, E., & Vasudevan, I. (2023, November). Exploratory Investigation and Alzheimer's Disease Classification Utilizing Ensemble Models in Machine Learning. In *2023 International Conference on Ambient Intelligence, Knowledge Informatics and Industrial Electronics (AIKIIIE)* (pp. 1-7). IEEE.
- [11] Fareed, M. M. S., Zikria, S., Ahmed, G., Mahmood, S., Aslam, M., Jillani, S. F., ... & Asad, M. (2022). ADD-Net: an effective deep learning model for early detection of Alzheimer disease in MRI scans. *IEEE Access*, 10, 96930-96951.
- [12] Ghaffari, H., Tavakoli, H., & Pirzad Jahromi, G. (2022). Deep transfer learning-based fully automated detection and classification of Alzheimer's disease on brain MRI. *The British journal of radiology*, 95(1136), 20211253.
- [13] Lu, B., Li, H. X., Chang, Z. K., Li, L., Chen, N. X., Zhu, Z. C., ... & Yan, C. G. (2022). A practical Alzheimer's disease classifier via brain imaging-based deep learning on 85,721 samples. *Journal of Big Data*, 9(1), 101.
- [14] Jenber Belay, A., Walle, Y. M., & Haile, M. B. (2024). Deep Ensemble learning and quantum machine learning approach for Alzheimer's disease detection. *Scientific Reports*, 14(1), 14196.
- [15] ADNI Dataset. <https://ida.loni.usc.edu/login.jsp?project=ADNI&page=HOME>. Accessed 10 Mar 2022.

- [22] Q. Ji, J. Huang, W. He, and Y. Sun, "Optimized deep convolutional neural networks for identification of macular diseases from optical coherence tomography images," *Algorithms*, vol. 12, no. 3, p. 51, 2019.
- [23] Saber, H. A., Younes, A., Osman, M., & Elkabani, I. (2024). Quran reciter identification using NASNetLarge. *Neural Computing and Applications*, 36(12), 6559-6573.
- [24] C. Szegedy et al., "Going deeper with convolutions," in Proceedings of the IEEE conference on computer vision and pattern recognition, 2015, pp. 1-9 .
- [25] Dorogush, A. V., Ershov, V., & Gulin, A. (2018). CatBoost: gradient boosting with categorical features support. arXiv preprint arXiv:1810.11363.
- [26] Chen, T., & Guestrin, C. (2016, August). Xgboost: A scalable tree boosting system. In *Proceedings of the 22nd acm sigkdd international conference on knowledge discovery and data mining* (pp. 785-794).
- [27] Li, X., Wang, L., & Sung, E. (2005, July). A study of AdaBoost with SVM based weak learners. In *Proceedings. 2005 IEEE International Joint Conference on Neural Networks, 2005.* (Vol. 1, pp. 196-201). IEEE.
- [16] MIPAV. <https://mipav.cit.nih.gov/>
- [17] Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D. & Rabinovich, A. (2015). Going deeper with convolutions. In Proceedings of the IEEE conference on computer vision and pattern recognition (pp. 1-9).
- [18] X. Han, Y. Zhong, L. Cao, and L. Zhang, "Pre-trained alexnet architecture with pyramid pooling and supervision for high spatial resolution remote sensing image scene classification," *Remote Sensing*, vol. 9, no. 8, p. 848, 2017 .
- [19] Sandler, M., Howard, A., Zhu, M., Zhmoginov, A., & Chen, L. C. (2018). Mobilenetv2: Inverted residuals and linear bottlenecks. In Proceedings of the IEEE conference on computer vision and pattern recognition (pp. 4510-4520).
- [20] M. Tan and Q. Le, "Efficientnet: Rethinking model scaling for convolutional neural networks," in *International conference on machine learning*, 2019: PMLR, pp. 6105-6114 .
- [21] Huang, G., Liu, Z., Van Der Maaten, L., & Weinberger, K. Q. (2017). Densely connected convolutional networks. In Proceedings of the IEEE conference on computer vision and pattern recognition (pp. 4700-4708).

پی‌نوشت

- 10 Brain Segmentation and Extraction (BSE)
- 11 Shading Correction
- 12 Kaggle
- 13 Pooling
- 14 Fully Connected (FC)
- 15 Dropout
- 16 Accuracy
- 17 Precision
- 18 Recall

- 1 Normal Control (NC)
- 2 Mild Cognitive Impairment (MCI)
- 3 Early Mild Cognitive Impairment (EMCI)
- 4 Late Mild Cognitive Impairment (LMCI)
- 5 Significant Memory Concern (SMC)
- 6 Convolutional Neural Network (CNN)
- 7 Quantum Support Vector Machine (QSVM)
- 8 Restoration
- 9 Registration