

## طبقه بندی بیماری آلزایمر مبتنی بر یادگیری عمیق با استفاده از MRI مغز

مریم سورگی\*<sup>۱</sup>، سید حمید خاتمی<sup>۲</sup>

- ۱- دانشجوی کارشناسی مهندسی پزشکی، گروه الکترونیک، دانشکده برق و کامپیوتر، دانشگاه بیرجند  
۲- دانشجوی دکتری مهندسی برق-الکترونیک، گروه الکترونیک، دانشکده برق و کامپیوتر، دانشگاه بیرجند

\*maryamsoorgi@birjand.ac.ir

ارسال: مرداد ماه ۱۴۰۲ پذیرش: مهر ماه ۱۴۰۲

### چکیده

آلزایمر، یک اختلال مغزی شناخته شده است که در حال حاضر هنوز درمانی ندارد. با این حال، تشخیص زودهنگام بیماری می تواند به بیمار کمک کند تا درمان مناسب را دریافت کند و روند پیشرفت بیماری را کاهش دهد. در تصویربرداری پزشکی، روش های یادگیری عمیق به طور گسترده برای کمک به متخصصان پزشکی در تشخیص بیماری آلزایمر برای طبقه بندی و مراحل بیماری آلزایمر استفاده شده است. این مقاله، عملکرد طبقه بندی معماری یادگیری عمیق مانند MobileNetV2، DenseNet-121، ResNet-101 و مدل شبکه عصبی کانولوشنال اصلاح شده پیشنهادی (CNN) را با الهام از شبکه VGG16 با استفاده از مجموعه داده های تصویربرداری تشدید مغناطیسی مغز (MRI) از Kaggle مقایسه می کند. همچنین عملکرد مدل بر اساس دقت، صحت، نرخ فراخوانی و امتیاز FI ارزیابی می شود و نتایج به دست آمده نشان می دهد که طبقه بندی بیماری آلزایمر با استفاده از مدل پیشنهادی این مقاله، دقیق تر از مدل دیگر با دقت ۹۷.۶۲۵ درصد، نرخ فراخوانی ۹۸ درصد، صحت ۹۸ درصد و امتیاز FI ۹۸ درصد است. در این مقاله، با موفقیت ثابت کرد که کنار گذاشتن برخی بخش ها در مدل CNN، می تواند دقت مدل را بهبود بخشد و مدت زمان آموزش مدل را کاهش دهد و بینش های ارزشمندی برای تشخیص تصویر پزشکی و تحقیقات آینده ایجاد کند.

کلمات کلیدی: آلزایمر، یادگیری عمیق، یادگیری ماشین، تصویربرداری پزشکی، هوش مصنوعی.

### ۱- مقدمه


آلزایمر (AD)<sup>۱</sup> به عنوان یک بیماری عصبی تعریف می شود. بیماری که مهارت های به خاطر سپردن، تفکر و انجام ساده ترین کارها را از بین می برد. این بیماری، در حال حاضر در رتبه هفتم علت اصلی مرگ و میر در جهان قرار دارد و معمولاً به عنوان بزرگترین علت زوال عقل در میان بزرگسالان مشخص می شود [۱]. به عنوان یک بیماری پیش رونده، علائم به تدریج برای چندین سال تکامل می یابند و پیشرفت می کند.

همچنین اثرات زوال عقل برای هر فردی می تواند متفاوت باشد؛ زیرا اثرات آن به دلایل زمینه ای بستگی دارد. علائم و نشانه های مرتبط با زوال عقل به سه مرحله تقسیم می شوند؛ مرحله اول، مرحله خفیف زوال عقل است که علائم می تواند شامل سهل انگاری و گم شدن در زمان و مکانی از قبل شناخته شده باشد. سپس، در مرحله دوم (متوسط)، علائم و نشانه ها آشکارتر می شوند؛ ردیابی

<sup>1</sup> Alzheimer's disease

وقایع اخیر و نام افراد دشوار خواهد بود. علاوه بر این، ارتباط افراد در این مرحله ممکن است سخت شود و نیاز به مراقبت فردی داشته باشند. مرحله سوم، مرحله شدید است که در آن اختلال جدی حافظه رخ می دهد و علائم و نشانه های فیزیکی بارزتر می شوند. مثلاً عدم آگاهی از زمان و مکان، ناتوانی در شناخت خویشاوندان و راه رفتن آسان. همچنین، این تغییرات رفتاری می تواند بدتر شود و منجر به پرخاشگری شود [۱].

بسیاری از مردم، اعتقاد دارند که مشکلات مربوط به حافظه، بخشی از پیری است. در مقابل، یک واقعیت توضیح می دهد که زوال عقل بر افراد مسن تأثیر نمی گذارد؛ اگرچه که سن به عنوان قوی ترین عامل خطر زوال عقل شناخته می شود. مواردی که با شروع جوانی، زوال عقل دارند، در ۹ درصد از موارد آلزایمر یافت می شود [۲]. در ایالات متحده، تخمین خطرات مادام العمر برای AD در سن ۴۵ سالگی به ۱۰.۳ درصد برای مردان و ۱۹.۵ درصد برای زنان رسیده است و این خطر در سن ۶۵ سالگی افزایش می یابد [۳]. این افزایش خفیف خطر، بین افراد ۴۵ تا ۶۵ ساله در شکل (۱) نشان داده شده است.



شکل ۱- تخمین ریسک و خطر بر اساس جنسیت برای زوال عقل بر اثر آلزایمر در سنین ۴۵ و ۶۵ [۳]

به عنوان دومین عامل مرگ و میر در استرالیا، ۷۰ درصد افراد جامعه از زوال عقل رنج می برند. تخمین زده می شود تا سال ۲۰۲۲، ۴۸۷۵۰۰ استرالیایی با زوال عقل و بدون استفاده از پیشرفت های پزشکی زندگی می کنند. پیش بینی می شود که این تعداد به ۱.۱ میلیون تا سال ۲۰۵۸ افزایش یابد [۴].

روش ها و ابزارهای مختلفی وجود دارد که پزشکان می توانند از آنها استفاده کنند. در تجزیه و تحلیل بیماران مبتلا به بیماری آلزایمر، به عنوان یک قانون، پزشکان از فرد، اعضای خانواده یا دوستان در مورد سلامت کلی سوال می پرسند؛ سوالاتی مانند محاسبات ریاضی، یادآوری گذشته، زبان و درخواست حل مسئله. همچنین اسکن های مغز مانند توموگرافی گسیل پوزیترون (PET)، توموگرافی کامپوتری (CT<sup>۲</sup>) یا تصویربرداری تشدید مغناطیسی (MRI<sup>۳</sup>) را برای از بین بردن سایر علائم احتمالی یا کمک به فرآیند تشخیصی بیماری آلزایمر انجام می دهند [۵]. بنابراین، تشخیص دقیق، بهترین فرصت را برای آمادگی و پیگیری بیماری و دریافت هر گونه درمان یا حمایتی که ممکن است، فراهم می کند.

در ارتباط با مغز، شبکه به عنوان بافتی که لایه ای است توسط حسگرهای عصبی که پشت چشم را می پوشاند و به مغز متصل می شود نیز به عنوان بستری برای مطالعه اختلالات سیستم عصبی مرکزی که توسط مطالعات نمونه های پس از مرگ اثبات شده است، مورد بررسی قرار گرفته است. شبکه چشم در AD دخالت دارد؛ زیرا انبساط مغزی است که از نظر آناتومی، جنین شناسی و فیزیولوژی قابل دسترسی است [۶]. یکی از فناوری های تصویربرداری غیرتهاجمی شبکه، توموگرافی انسجام نوری (OCT) است. OCT از نور مادون قرمز نزدیک برای شناسایی نور پراکنده عقب استفاده می کند [۷]. برخلاف استفاده از فناوری تصویربرداری از مغز، تصویربرداری شبکه مانند OCT در هزینه کم، در دسترس بودن غیر درجه سوم و متغیرهای کمی

<sup>1</sup> Positron Emission Tomography

<sup>2</sup> Computed Tomography

<sup>3</sup> Magnetic Resonance Imaging

متفاوت است. از نظر پزشکی، ویژگی‌های AD با از دست دادن سلول‌های گانگلیونی شبکه‌ی و آکسون‌های آنها مشخص می‌شود. با مبنای مطالعات بالینی که OCT را پیاده‌سازی می‌کند، رابطه‌ی بین AD و لایه‌های شبکه‌ی می‌تواند مشخص باشد. محققان برخی از کامپیوترها را تکامل داده‌اند. سیستم‌های تشخیصی برای تشخیص دقیق بیماری از دهه ۱۹۷۰ تا ۱۹۹۰، سیستم‌های خبره مبتنی بر قوانین با موفقیت توسعه یافتند و مدل‌های آن را در دهه ۱۹۹۰ تحت نظارت قرار دادند [۸]. مطالعات متعددی در مورد استفاده از یادگیری ماشین در تشخیص و طبقه‌بندی بیماری آلزایمر انجام شده‌است. به عنوان مثال، برخی ترکیبی از ویژگی‌های بافت را انجام دادند که از ماتریس وقوع همزمان سطح خاکستری و تجزیه و تحلیل تصویربرداری عصبی مورفومتری مبتنی بر وکسل برای استخراج ویژگی‌های تبعیض‌آمیزتر برای طبقه‌بندی‌کننده ماشین بردار پشتیبان (SVM) استخراج شد. بالاترین دقت با ادغام ویژگی‌های ماتریس هم‌وقوع سطح خاکستری (GLCM) و مورفومتری مبتنی بر وکسل (VBM) به میزان ۸۸ درصد، بیشتر از تنها استفاده به دست آمد.

با این حال، چندین محقق، زمانی که یک مدل از یادگیری عمیق آموزش داده شده بر روی تصاویر MRI مغز در تشخیص AD استفاده شد، به نتایج بهتری دست یافتند. در یادگیری عمیق، ConvNet (شبکه عصبی کانولوشنال) اغلب در تجزیه و تحلیل تصاویر بصری استفاده می‌شود، در حالی که ConvNet عمیق اغلب برای طبقه‌بندی تصاویر در مجموعه داده‌های تصویری بزرگ استفاده می‌شود [۱۰][۱۱]. در سال ۲۰۲۰، مطالعاتی در مورد طبقه‌بندی AD با استفاده از مدل CNN به میزان دقت ۹۹٪ دست یافت و بیان کرد که نتیجه را می‌توان با استفاده از ConvNet عمیق افزایش داد [۱۲]. مطالعات دیگری، مدلی از ConvNet عمیق را برای پردازش تصاویر MRI و طبقه‌بندی بیماری آلزایمر پیشنهاد کرد و به دقت ۹۹.۸۹ درصد در طبقه‌بندی دست یافت. ثابت شده‌است که ترکیب یک مدل ConvNet همه‌جانبه به مطالعه ویژگی‌های خاص داده‌های تصویربرداری عصبی کمک می‌کند [۱۳].

در طبقه‌بندی وضعیت AD، AlexNet، Faster R-CNN و ورژن چهارم از YOLO نیز با مقایسه اثربخشی و دقت معماری‌های یادگیری عمیق مورد تحقیق قرار گرفتند. با استفاده از تقویت داده، AlexNet، Faster R-CNN، YOLO به ترتیب ۹۹، ۸۴، و ۹۹ درصد دقت را بدست آوردند [۱۴].

همچنین مطالعه دیگری، اجرای شبکه‌های عصبی کانولوشنال عمیق را پیشنهاد کرد. مجموعه‌ای که از سه مدل Dense Net121، Net-161 Dense و Net-169 Dense با طبقه‌بندی‌کننده Softmax برای طبقه‌بندی مراحل آلزایمر تشکیل شده‌است. الگوریتم SGD (Stochastic Gradient Descent) برای بهینه‌سازی مدل‌های فردی و توقف اولیه برای منظم‌سازی استفاده شد. فرآیند تمرین با استفاده از وزنه‌های کلاس انجام شد و دقت ۹۳/۱۸ درصد، صحت ۹۳ درصد، نرخ فراخوانی ۹۲ درصد و امتیاز f1 بدست آمد [۱۵]. برش‌های محوری تصاویر MRI به عنوان داده‌های ورودی شبکه‌های عصبی استفاده شد که فرآیند استخراج ویژگی‌ها و طبقه‌بندی داده‌ها را انجام می‌دهد.

معماری ResNet پیشنهادی با انباشتن بلوک‌های باقی‌مانده ساخته شده‌است که هر یک از آنها از ۳ لایه  $(1 \times 1)$  و  $3 \times 3$  و  $(1 \times 1)$  تشکیل شده‌است و دقت ۹۹.۵۱ درصد برای دمانس‌های خفیف، ۱۰۰ درصد برای دمانس‌های متوسط، ۹۹.۶۱ درصد برای دمانس‌های متوسط را بدست می‌آورد. می‌توان نتیجه گرفت که معماری ResNet-101 از نظر تمام معیارهای ارزیابی، VGG19، VGG16، ResNet-18، ResNet-34 و ResNet-50 را شکست می‌دهد [۱۶].

بر اساس تحقیقاتی که بررسی شده‌است، متوجه شدیم که عمدتاً از معماری CNN بدون لایه‌های لایت و حذفی استفاده می‌کنند. اشکالات این معماری این است که فقط می‌تواند مجموعه داده‌های کوچکی را مدیریت کند که نیاز به زمان بیشتری برای آموزش و آزمایش بیش از حد نوروها دارد. لایه‌های حذفی به الگوریتم CNN اضافه می‌شوند تا بر این معایب غلبه کنند؛ به طوری که می‌تواند از داده‌های مقیاس بزرگ پشتیبانی کند و زمان آموزش را کاهش دهد [۱۷].

امروزه با کمک تکنولوژی و کامپیوتر، بسیاری از محاسبات و تشخیص‌ها از جمله تشخیص بیماری آلزایمر به صورت دیجیتال صورت می‌گیرد. تحقیقات بسیاری در زمینه مغز، تصاویر ام-آر-آی مغزی و تشخیص بیماری آلزایمر صورت گرفت است.

حجت‌اله واهب، از مورفومتری مبتنی بر وکسل برای تعیین اختلاف تراکم ماده خاکستری در نواحی مغزی بین افراد سالم و افراد مبتلا به آلزایمر استفاده کرده‌است که در بیماران آلزایمری بیشینه است. گلن فانگ و همکارانش، جهت تشخیص زود هنگام آلزایمر با استفاده از روش ماشین بردار پشتیبان، به طبقه‌بندی تصاویر مغزی پرداختند. در مجموع ۱۵۸ نفر انتخاب شدند؛ سپس با استفاده از تصویربرداری پرفیوژن اسپکت برای تشخیص بیماری آلزایمر، تفاوت بین تصاویر افراد سالم و بیماران مبتلا به بیماری آلزایمر بررسی شد و به نرخ صحت ۹۰ درصد رسید.

جورجن داکارت و همکاران از ۲۸ فرد آلزایمری و ۲۸ فرد سالم پایگاه داده 2ADNI استفاده کردند. سپس با داده‌هایی از ۲۲ فرد مبتلا به آلزایمر و ۱۳ فرد گروه لایپزیگ مقایسه شده‌است. در طبقه‌بندی ماشین بردار پشتیبان با استفاده از حجم مفید اطلاعات، از اف-دی-جی-پت و ام-آر-آی بر اساس تجزیه و تحلیل سندرم زوال عقل، نشان داد که ماشین بردار پشتیبان با نرخ صحت ۹۱ درصد روشی مناسب برای طبقه‌بندی است.

ژین لو و همکارانش، ۴۱۳ نمونه از افراد سالم و بیمار انتخاب کردند. در این کار، به طبقه‌بندی تصاویر مغزی بر اساس برخی مشخصه‌های آن مثل ضخامت، شکل و غیره پرداخته شده‌است. برای طبقه‌بندی تصاویر در این مقاله از روش تعبیه خطی به شکل محلی استفاده شد و به نرخ صحت ۹۶ درصد رسید.

سایکی لئو و همکاران، یک مدل تشخیص آلزایمر با یادگیری عمیق به روش سافتمکس و خود رمزگذار طراحی کردند. از مجموعه داده ADNI، ۳۱۱ عکس ام-آر-آی و پت از دو گروه دارای اختلال خفیف و افراد سالم، تهیه شده‌است. آن‌ها یک روش جدید برای تشخیص زود هنگام آلزایمر و اختلال خفیف شناختی بر اساس یادگیری عمیق ارائه کردند که به نرخ صحت ۸۳ درصد رسیدند.

ایمان بهشتی به کمک تابع توزیع احتمال مبتنی بر طبقه بندی ام-آر-آی به تشخیص بیماری آلزایمر رسید. برای انجام این کار از مجموعه داده ADNI با ۲۶۰ نفر که ۱۳۰ نفر افراد سالم و ۱۳۰ نفر بیمار بودند استفاده شد. روش شامل چند بخش است: روش مورفومتری مبتنی بر وکسل، خوشه‌بندی وکسل به شرح VOIS، استفاده از تابع آماری توزیع احتمال برای انتخاب ویژگی و طبقه‌بندی با ماشین بردار پشتیبان انجام و به نرخ صحت ۸۹ درصد رسیدند. ایمان بهشتی در کار بعدی با رتبه‌بندی ویژگی‌ها بر اساس طبقه‌بندی ام-آر-آی ساختاری به تشخیص بیماری آلزایمر پرداخت. سیستم به کار رفته در این تحقیق شامل ۱۳۶ نمونه، ۶۸ تصویر مغزی از افراد سالم و ۶۸ تصویر از افراد بیمار از مجموعه داده ADNI تهیه شده‌است. سیستم طبقه‌بندی پیشنهادی شامل ۵ سطح است: روش مورفومتری مبتنی بر وکسل - خوشه‌بندی وکسل - استخراج ویژگی بین دو گروه افراد سالم و بیمار به کمک آزمون T-طبقه‌بندی با ماشین بردار پشتیبان و استفاده از روش همجوشی داده‌ها برای بهبود عملکرد طبقه‌بندی بر اساس خوشه آتروفی و به نرخ صحت ۹۶ درصد رسیدند.

لن سورسنا و همکاران برای تشخیص افتراقی اختلال شناختی خفیف و بیماری آلزایمر از ام-آر-آی ساختاری، ضخامت قشر مغز، شکل هیپوکامپ، بافت هیپوکامپ و اندازه‌گیری حجم کمک گرفتند. برای تشخیص تفاوت افراد سالم، اختلال شناختی خفیف و آلزایمر به‌طور همزمان بر اساس یک اسکن ام-آر-آی ساختاری پرداخت شد. داده‌ها از پایگاه داده ADNI به دست آمد. این ترکیب با وارد کردن تمام نشانگرهای زیستی در یک طبقه‌بندی خطی، آنالیز تشخیصی خطی ویژگی‌ها را به دست آورده و تشخیص افتراقی همزمان افراد سالم، اختلال شناختی خفیف و آلزایمر انجام شد و به نرخ صحت ۶۲ درصد رسیدند.

فنگ ژانگ و همکاران، ۵۸ عکس از افراد بیمار و ۹۴ عکس از افراد سالم از مجموعه داده‌های ADNI را مورد استفاده قرار دادند. برای انجام این تحقیق تصاویر ام-آر-آی مغزی مورد بررسی قرار گرفته شده‌است. به این شکل که ابتدا ناحیه سفید و خاکستری مغزی از هم جدا شده سپس توسط روش‌های فیلترگذاری استخراج ویژگی انجام شده‌است و در نهایت به کمک شبکه عصبی ELM طبقه‌بندی انجام شده‌است و به نرخ صحت ۹۶ درصد رسیدند.

این مطالعه با هدف پیاده سازی ۴ معماری یادگیری عمیق انجام شده‌است. معماری‌هایی که در یکی از آن‌ها از مدل پیشنهادی ما و یک لایه حذفی استفاده می‌کند و عملکرد آن را در طبقه‌بندی مراحل آلزایمر مقایسه می‌کند. مدل یادگیری عمیق پیشنهادی از

ویژگی های MRI مغز بیماران آلزایمر (که به ۳ گروه تقسیم می شود) و بیماران سالم استفاده می کند. در پایان این تحقیق معماری یادگیری عمیق که بالاترین دقت را دارد، ارائه خواهد شد.

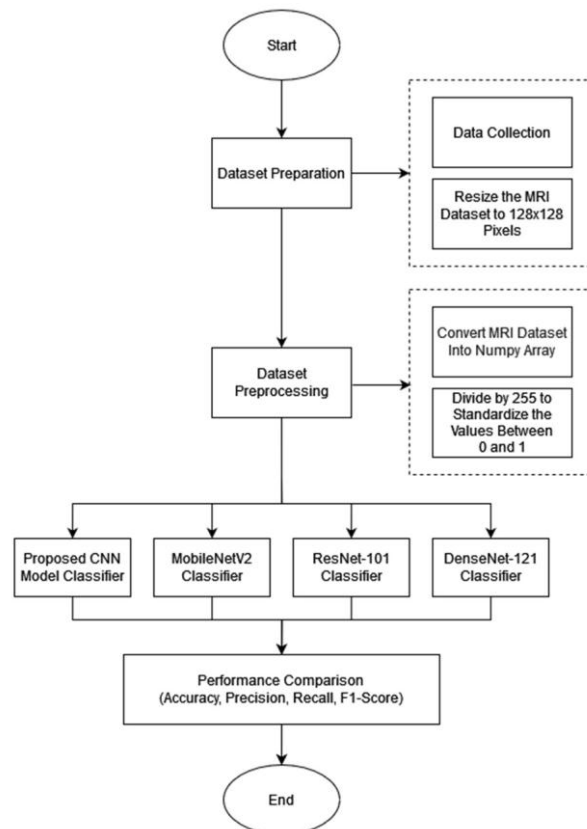
## ۲- روش

ما یک گردش کار مشکل از آماده سازی مجموعه داده، پیش پردازش مجموعه داده، طبقه بندی و مقایسه عملکرد را پیشنهاد کردیم. مراحل دقیق در شکل (۲) نشان داده شده است.

هوش مصنوعی (AI)، شبیه سازی شده است تا عمل تقلید و تفکر را مانند انسان انجام دهد و به نوعی شبیه سازی از سیستم مغز انسان است. در این مورد، این اصل برای سایر ماشین هایی که هر گونه ویژگی ذهنی انسان مانند حل مسئله یا یادگیری را نشان می دهند نیز قابل اجرا است [۱۸].

به عنوان زیرمجموعه ای از هوش مصنوعی، یادگیری ماشینی دارای زیرمجموعه ای به نام یادگیری عمیق است [۱۹]. یادگیری عمیق، تقسیم بندی معنایی، تشخیص اشیا و طبقه بندی تصویر را پوشش می دهد و معمولاً برای تجزیه و تحلیل داده هایی با ابعاد بالا اجرا می شود [۲۰].

در یادگیری عمیق، شبکه عصبی کانولوشن به عنوان الگوریتم نماینده آن به عنوان گونه ای از یک شبکه عصبی مصنوعی تعریف می شود که اصولاً برای پردازش آرایه های ساختاری داده ها مانند تصاویر، طراحی شده است [۲۱]. شبکه عصبی کانولوشن به دلیل تشخیص کارآمد، ساختار ساده، پارامترهای آموزشی کمتر و سازگاری، به یک الگوریتم پرکاربرد در پردازش تصویر و تشخیص الگو تبدیل شده است [۲۲].



شکل ۲- گردش کار تحقیق


با مجموعه داده های کوچک، شبکه های عصبی عمیق برای داده های آموزشی مناسب و سازگار است [۲۳]. مجموعه داده مورد استفاده در مطالعه ما دارای ۶۴۰۰ تصویر مغزی MRI بود که از پلتفرم باز Kaggle جمع آوری شده است [۲۴]. این پلتفرم باز، شامل چهار کلاس است: دمانس خالی، دمانس خیلی خفیف، دمانس خفیف و دمانس متوسط. یک تحقیق [۲۵] نشان داده است که

با تقسیم مجموعه داده‌ها به ۷۰-۸۰ درصد برای آموزش و ۳۰ تا ۲۰ درصد باقیمانده برای آزمایش بهترین نتیجه را می‌توان به دست آورد. بنابراین ما در مجموع از ۴۸۰۰ تصویر برای آموزش استفاده کردیم و ۱۶۰۰ تصویر برای آزمایش استفاده خواهد شد. علاوه بر این، اندازه تمام تصاویر به  $128 \times 128$  پیکسل تغییر خواهد کرد. حال به بررسی معماری مدل و پیش پردازش داده‌ها می‌پردازیم. ما از کتابخانه Numpy پایتون استفاده می‌کنیم که می‌تواند محاسبات عددی را پردازش کند. این کتابخانه، توانایی تشکیل اشیاء آرایه  $N$  بعدی را دارد. همچنین مجموعه داده تصویر خود را با تابع `np.array` به یک آرایه NumPy تبدیل می‌کنیم. ما مجموعه داده را بر ۲۵۵ تقسیم می‌کنیم تا مقادیر بین ۰ و ۱ را استاندارد کنیم. با استفاده از NumPy، مزایایی مانند سهولت انجام عملیات محاسباتی داده‌ها و همچنین استفاده کارآمدتر از ذخیره سازی را به دست می‌آوریم [۲۷].

مدل پیشنهادی از شبکه VGG16 الهام گرفته شده است. اما با برخی تغییرات اضافی در لایه همراه است. پس از مرحله پیش پردازش، مجموعه داده ورودی از لایه کانولوشن، لایه حذفی و حداکثر ادغام دو بعدی عبور می‌کند. در لایه کانولوشن، مجموعه‌ای از فیلترها (یا هسته‌ها) وجود دارد که پارامترهای آن‌ها باید در حین پیشرفت مورد مطالعه قرار گیرد [۲۸]. بنابراین، اندازه فیلتر این مدل کوچکتر از تصویر مجموعه داده شده است.

لایه های کانولوشن اول و دوم از ۶۴ فیلتر با اندازه هسته  $3 \times 3$  و فعال سازی ReLU (واحد خطی اصلاح شده) تشکیل شده است. به دنبال لایه بعدی، لایه‌های حذفی را در این مدل اعمال می‌کنیم تا از همگرا شدن همه نورون‌ها به سمت یک مقصد جلوگیری کنیم [۲۹]. برای کاهش پیش‌پردازش و افزایش خطای تعمیم در همه انواع شبکه‌های عصبی عمیق، از انصراف‌ها استفاده می‌کنیم که روش‌های منظم سازی از لحاظ محاسباتی ارزان و فوق‌العاده کارآمد را ارائه می‌دهند. هدف ما حذف موقت یک واحد از شبکه‌ها، همراه با اتصالات ورودی و خروجی آن با حذف آن است. ما می‌خواستیم ثابت کنیم که با استفاده از حذف، عملکرد تعمیم در تمام مجموعه‌های داده در مقایسه با شبکه‌های عصبی که از انصراف استفاده نکرده‌اند، بهبود می‌یابد [۳۰].


تصاویر مجموعه داده در اولین لایه حذفی از ۲۰٪ منظم شدن عبور می‌کنند. علاوه بر این، ما از تابع ادغام پس از لایه حذف برای کاهش تعداد پارامترهای مجموعه داده ورودی به صورت مکانی توسط یک عملیات نمونه برداری پایین استفاده می‌کنیم. روشی که ما استفاده می‌کنیم، حداکثر ادغام دو بعدی است. از طریق لایه کانولوشن سوم و چهارم ۳۲ فیلتر با اندازه هسته  $3 \times 3$  با تابع فعال سازی ReLU ادامه دهید. تصاویر مجموعه داده ها ۳۰٪ منظم سازی را در لایه حذف شده طی می‌کنند و از حداکثر لایه ادغام دو بعدی باز می‌گردند. علاوه بر این، مانند لایه‌های کانولوشن سوم و چهارم است. تفاوت این است که لایه‌های کانولوشن پنجم و آخر از اندازه هسته  $2 \times 2$  استفاده می‌کنند و به دنبال آن یک لایه حذفی با تنظیم ۵۰ درصد قرار می‌گیرد. لایه‌های نهایی شامل سه لایه متراکم است که در لایه‌های اول و دوم از ۵۱۲ ویژگی استفاده می‌شود. استفاده از تابع تلفات متقابل آنتروپی مقوله‌ای در کاهش تلفات مدل پیشنهادی مفید خواهد بود. در این مدل، ما همچنین از Softmax استفاده می‌کنیم؛ زیرا دارای یک تابع فعال سازی مناسب برای استفاده با تابع از Loss متقابل آنتروپی طبقه‌ای است. شکل (۳)، چارچوب پیشنهادی برای طبقه بندی بیماری آلزایمر را نشان می‌دهد.



شکل ۳- معماری مدل CNN پیشنهادی برای طبقه بندی بیماری آلزایمر

استفاده از کانولوشن قابل جداسازی در عمق باعث می‌شود MobileNet تعداد کمی پارامتر داشته باشد و به یک شبکه عصبی عمیق سبک تبدیل شود [۳۱]. در مقایسه با MobileNetV1، MobileNetV2 دو ویژگی جدید را ارائه می‌دهد. به عنوان مثال، استفاده از لایه‌های خطی و اتصالات میانبر بین گلوگاه‌ها. لایه‌های داخلی در MobileNetV2 می‌توانند مدل را از یک

مفهوم سطح پایین (پیکسل‌های توضیحی) به توصیفگرهای سطح بالاتر تغییر دهند (مقوله‌های تصویر توضیح دهید. MobileNetV2 تنها ۳۰ درصد از پارامترها را می‌گیرد و با اتصالات باقی‌مانده سنتی به مدل اجازه می‌دهد تا کار کند. آموزش سریعتر و با دقت بهتر [۳۲]، در شکل (۴) نشان داده شده‌است. MobileNetV2 ثابت کرد که دقت بالاتری نسبت به MobileNetV1 دارد.



شکل ۴- دقت در مقابل تأخیر بین MobileNetV1 و MobileNetV2 [۳۳]

ResNet-101 دارای عمق ۱۰۱ لایه با ۳۳ بلوک باقی‌مانده، از جمله لایه‌های ورودی و خروجی است [۳۴]. این شبکه دارای اندازه ورودی تصویر ۲۲۴×۲۲۴ است [۳۵]. این شبکه‌های باقیمانده برای بهینه‌سازی، پیچیدگی کمتری دارند و دقت آن‌ها ممکن است با افزایش قابل ملاحظه عمق بهبود یابد [۳۶].

DenseNet که به عنوان یک شبکه عصبی کانولوشن تعریف می‌شود، شامل لایه‌های به هم پیوسته‌ای است که به تمام لایه‌های عمیق‌تر شبکه دیگر متصل می‌شود. این مدل با طرحی که لایه اول را به لایه دوم، لایه سوم و غیره و به دنبال آن لایه دوم به لایه سوم، لایه چهارم و ... پیوند می‌دهد، می‌تواند جریان اطلاعات بین شبکه را به حداکثر برساند. لایه‌ها به منظور حفظ ماهیت فید فوروارد، هر لایه قبلی ورودی ارائه می‌کند و نقشه ویژگی خود را به تمام لایه‌های بعدی ارسال می‌کند [۳۷]. چندین مزیت معماری DenseNet شامل کاهش مشکل گرادیان، ناپدید شدن، بهبود انتشار ویژگی‌ها، تسهیل قابلیت استفاده مجدد از ویژگی‌ها و کاهش قابل توجه پارامترهای شبکه است [۳۸].

### ۳- نتایج

در این تحقیق، آزمایش با استفاده از پلتفرم Google محاسبه خواهد شد. ما از کتابخانه‌های یادگیری عمیق پایتون مانند TensorFlow Keras و Numpy استفاده کردیم. با استفاده از کتابخانه Keras که مدل‌های یادگیری عمیق را با وزن‌های از پیش آموزش داده شده ارائه می‌کند، برای انجام استخراج ویژگی، تنظیم دقیق و طبقه‌بندی استفاده می‌کنیم. همچنین از tf.keras.applications برای فراخوانی معماری MobileNetV2، ResNet-101 و DenseNet-121 و مقایسه عملکرد آنها با عملکرد مدل پیشنهادی خود استفاده خواهیم کرد. هر مدل با ۲۰ دوره، نرخ یادگیری ۰.۰۱ و بهینه‌ساز Adam آزمایش می‌شود. نتایجی که باید در هر مدل گرفته شود عبارتند از دقت، امتیاز f1، نرخ فراخوانی و صحت. نتایج عملکرد در مدل‌های DenseNet-121، ResNet-101 و MobileNetV2 در جدول (۱) ارائه شده است. بر اساس نتایج دقت، مدل پیشنهادی شبکه عصبی کانولوشن، بالاترین نتایج دقت را با ۹۷.۶۲۵٪ در مقایسه با بقیه شبکه‌ها دریافت کرد.

جدول ۱- اجرای مدل CNN

مدل شبکه عصبی کانولوشن	کلاس	دقت	فراخوانی	F1 امتیاز	صحت
DenseNet-121	Non Demented	0.99	0.81	0.89	0.8862
	Very Mild	0.76	0.99	0.86	
	Mild Demened	0.96	0.92	0.94	
	Moderate	1.00	0.62	0.77	
	Avg/Total	0.91	0.89	0.89	
ResNet-101	Non Demented	0.96	0.87	0.91	0.8606
	Very Mild	0.92	0.80	0.86	

	Mild Demented	0.64	0.97	0.77	
	Moderate	0.36	1.00	0.53	
	Avg/Total	0.89	0.86	0.87	
MobileNetV2	Non Demented	0.89	0.95	0.92	0.885
	Very Mild	0.93	0.83	0.88	
	Mild Demented	0.92	0.79	0.85	
	Moderate	0.29	0.89	0.44	
	Avg/Total	0.90	0.89	0.89	
Proposed CNN Model	Non Demented	0.98	0.99	0.98	0.9762
	Very Mild	0.98	0.96	0.97	
	Mild Demented	0.98	0.98	0.98	
	Moderate	1.00	1.00	1.00	
	Avg/Total	0.98	0.98	0.98	

برای نتایج صحت، یادآوری و امتیاز  $f1$ ، مدل ما ۹۸ درصد برای هر قسمت از مدل‌های دیگر بهتر عمل کرد. برای دقت مدل‌های دیگر، DenseNet-121 پس از مدل پیشنهادی ما ۹۱٪ عملکرد بهتری داشت و پس از آن MobileNetV2 با ۹۰٪ و ResNet-101 با ۸۹٪ قرار گرفتند. برای نرخ فراخوانی، DenseNet-121 و MobileNetV2 هر دو ۸۹٪ و ResNet-101 با ۸۶٪ نتیجه گرفتند. MobileNetV2 و DenseNet-121 مجدداً امتیاز ۸۹٪ را برای  $f1$ -score کسب کردند در حالی که ResNet-101 امتیاز ۸۷٪ را به دست آورد.

دلیل عملکرد بهتر مدل پیشنهادی نسبت به سایر مدل‌های یادگیری عمیق با مجموعه داده‌های کوچک را می‌توان به تعمیم طبقه‌بندی بالای CNN با استفاده از لایه‌های حذفی نسبت داد. در طول فرآیند دوره، انصراف برخی از وزن‌ها را به طور تصادفی کوتاه می‌کند، بنابراین شبکه یاد می‌گیرد که از اتصالاتی که هنوز در دسترس هستند استفاده کند. از آنجایی که شبکه عصبی به نمونه‌هایی که قبلاً دیده نشده‌اند تعمیم می‌یابد، به مدل ما کمک می‌کند تا تجزیه و تحلیل یک مسئله را از دیدگاه‌های مختلف یاد بگیرد. بنابراین، عملکرد در طول استنباط و اعتبار سنجی افزایش می‌یابد؛ حتی اگر عملکرد در طول تمرین کاهش یابد.

#### ۴- نتیجه‌گیری

استفاده از تصاویر MRI برای طبقه‌بندی AD اغلب برای پیشگیری و درمان اولیه بیماران استفاده شده‌است. در این مقاله، مدل پیشنهادی خود را ارائه کردیم که بر روی مجموعه داده Kaggle امتحان شده‌است. سپس، سایر مدل‌های یادگیری عمیق را نیز برای مقایسه عملکرد آن‌ها آزمایش کردیم. در نتیجه، ثابت شده‌است که مدل ما عملکرد بهتری را در مدیریت مجموعه داده‌های تصویر MRI ارائه می‌کند. استفاده از لایه حذفی در مدل CNN پیشنهادی ما، بالاترین دقت را در مقایسه با سه مدل دیگر ارائه می‌دهد. این ثابت می‌کند که افزودن یک لایه حذفی می‌تواند دقت را بهبود بخشد. برای تحقیقات بیشتر، امیدواریم روی مجموعه داده‌های دیگری مانند ابتکار تصویربرداری عصبی بیماری آلزایمر (ADNI)، سری مطالعات تصویربرداری با دسترسی آزاد (OASIS)، مؤسسه ملی استاندارد و فناوری اصلاح‌شده (MNIST) و موسسه تحقیقات پیشرفته کانادا (CIFAR) کار کنیم. مدل پیشنهادی تنها بر روی مجموعه داده‌های MRI مغز بیماران آلزایمر آزمایش شد. می‌توان مطالعات بیشتری را برای طبقه‌بندی سایر بیماری‌ها در حوزه پزشکی انجام داد.

#### ۵- مراجع

1. "FASTSTATS - leading causes of death," Centers for Disease Control and Prevention, 13-Jan-2022. [Online]. Available:
2. <https://www.cdc.gov/nchs/fastats/leading-causes-of-death.htm>. [Accessed: 04-Apr-2022].
3. "Dementia," World Health Organization. [Online]. Available: <https://www.who.int/news-room/fact-sheets/detail/dementia>. [Accessed: 04-Apr-2022].
4. "2022 Alzheimer's disease facts and figures," Alzheimer's and Dementia, vol. 18, no. 4, 2022.
5. "Dementia statistics," Dementia Australia. [Online]. Available: <https://www.dementia.org.au/statistics>. [Accessed: 15-Apr-2022].



6. "Alzheimer's disease fact sheet," National Institute on Aging. [Online]. Available: <https://www.nia.nih.gov/health/alzheimersdisease-fact-sheet>. [Accessed: 04-Apr-2022].
7. C. Y. Cheung, V. Mok, P. J. Foster, E. Trucco, C. Chen, and T. Y. Wong, "Retinal imaging in Alzheimer's disease," *Journal of Neurology, Neurosurgery and Psychiatry*, vol. 92, no. 9. 2021.
8. R. K. Meleppat, K. E. Ronning, S. J. Karlen, M. E. Burns, E. N. Pugh, and R. J. Zawadzki, "In vivo multimodal retinal imaging of disease-related pigmentary changes in retinal pigment epithelium," *Sci Rep*, vol. 11, no. 1, 2021.
9. G. Litjens, B. E. Bejnordi, A. A. A. Setio, F. Ciompi, M. Ghafoorian, J. A. van der Laak, B. van Ginneken, and C. I. Sanchez, "A survey on deep learning in medical image analysis," *Medical Image Analysis*, vol. 42, Feb. 2017.
10. Y. Farouk, S. Rady, and H. Faheem, "Statistical features and Voxelbased morphometry for Alzheimer's disease classification," 2018 9th International Conference on Information and Communication Systems (ICICS), 2018.
11. "Convolutional Neural Network," DBpedia. [Online]. Available: [https://dbpedia.org/page/Convolutional\\_neural\\_network](https://dbpedia.org/page/Convolutional_neural_network). [Accessed: 15-Apr-2022].
12. [https://dbpedia.org/page/Convolutional\\_neural\\_network](https://dbpedia.org/page/Convolutional_neural_network). [Accessed: 15-Apr-2022].
13. B. Yang, H. Guo, and E. Cao, "Design of cyber-physical-social systems with forensic-awareness based on deep learning," *Advances in Computers*, vol. 120, pp. 39–79, Jan. 2021
14. A. W. Salehi, P. Baglat, B. B. Sharma, G. Gupta, and A. Upadhyay, "A CNN model: Earlier diagnosis and classification of alzheimer disease using MRI," 2020 International Conference on Smart Electronics and Communication (ICOSEC), 2020.
15. A. Nawaz, S. M. Anwar, R. Liaqat, J. Iqbal, U. Bagci, and M. Majid, "Deep convolutional neural network based classification of alzheimer's disease using MRI Data," 2020 IEEE 23rd International Multitopic Conference (INMIC), 2020.
16. R. Mirchandani, C. Yoon, S. Prakash, A. Khaire, A. Naran, A. Nair, and S. Ganti, "Comparing the Architecture and Performance of AlexNet, Faster R-CNN, and YOLOv4 in the Multiclass Classification of Alzheimer Brain MRI Scans," 2021.
17. J. Islam and Y. Zhang, "An Ensemble of Deep Convolutional Neural Networks for Alzheimer's Disease Detection and Classification,"
19. NIPS 2017 Workshop on Machine Learning for Health, Dec. 2017.
20. R. C. Suganthe, M. Geetha, G. R. Sreekanth, K. Gowtham, S. Deepakkumar, and R. Elango, "Multiclass Classification of Alzheimer's Disease Using Hybrid Deep Convolutional Neural Network," *NVEO - Natural Volatiles & Essential Oils*, vol. 8, no. 5, pp. 145–153, 2021.
23. G. S. Nandini, A. P. S. Kumar, and C. K., "Dropout technique for image classification based on extreme learning machine," *Global Transitions Proceedings*, vol. 2, no. 1, 2021.
24. M. Kaushik, "Artificial Intelligence (AI)," in *Intelligent system algorithms and applications in science and Technology*, S. Pathak, P. K. Bhatt, S. K. Singh, A. Tripathi, and P. K. Pandey, Eds. Palm Bay, FL, USA: Apple Academic Press, 2022, p. 119.
25. S. Lee, "Deep Structured Learning: Architectures and Applications," *International Journal of Advanced Culture Technology*, vol. 6, no. 4, pp. 262–265, 2018.
26. R. Yang and Y. Yu, "Artificial convolutional neural network in object detection and semantic segmentation for medical imaging analysis," *Frontiers in Oncology*, vol. 11, 2021.
27. J. Pereira-Carrillo, D. Suntaxi-Dominguez, O. Guarnizo-Cabezas,
28. G. Villalba-Meneses, A. Tirado-Espín, and D. Almeida-Galárraga,
29. "Comparison between two novel approaches in Automatic Breast Cancer Detection and diagnosis and its contribution in military defense," *Smart Innovation, Systems and Technologies*, pp. 189–201, 2021.
30. T. Liu, S. Fang, Y. Zhao, P. Wang, and J. Zhang, "Implementation of Training Convolutional Neural Networks," 2015.
31. "Dropout Explained. Here we will first understand why... | by Chirag Sharma | Jovian — Data Science and Machine Learning." [Online]. Available: <https://blog.jovian.ai/dropout-68913941f569>. [Accessed: 15-Oct-2022].
32. S. Dubey, "Alzheimer's dataset (4 class of images)," Kaggle, 26-

33. Dec-2019. [Online]. Available: <https://www.kaggle.com/datasets/tourist55/alzheimers-dataset-4class-of-images>. [Accessed: 15-Apr-2022].
34. A. Gholamy, V. Kreinovich, and O. Kosheleva, "Why 70/30 or 80/20 Relation Between Training and Testing Sets: A Pedagogical Explanation," Departmental Technical Reports (CS), Feb. 2018.
35. "NumPy." [Online]. Available: <https://numpy.org/>. [Accessed: 05Jul-2022].
36. "NumPy Array : Salah Satu Library Python." [Online]. Available: <https://dqlab.id/numpy-array-salah-satu-library-python>. [Accessed: 05-Jul-2022].
37. S. Mostafa and F. X. Wu, "Diagnosis of autism spectrum disorder with convolutional autoencoder and structural MRI images," in *Neural Engineering Techniques for Autism Spectrum Disorder: Volume 1: Imaging and Signal Analysis*, 2021.
38. R. Bonnin, *Machine Learning for Developers.*, vol. 4, no. 3. Packt, 2017.
39. "A Gentle Introduction to Dropout for Regularizing Deep Neural
40. Networks." [Online]. Available: <https://machinelearningmastery.com/dropout-for-regularizing-deep-neural-networks/>. [Accessed: 07-Jul-2022].
41. "An Overview on MobileNet: An Efficient Mobile Vision CNN | by
42. Srudeep PA | Medium." [Online]. Available:
43. <https://medium.com/@godeep48/an-overview-on-mobilenet-anefficient-mobile-vision-cnn-f301141db94d>. [Accessed: 28-Jun2022]
44. "Why Google's MobileNetV2 Is A Revolutionary Next Gen OnDevice Computer Vision Network." [Online]. Available: <https://analyticsindiamag.com/why-googles-mobilenetv2-is-arevolutionary-next-gen-on-device-computer-vision-network/>.
45. [Accessed: 28-Jun-2022]
46. K. Bousbai and M. Merah, "A Comparative Study of Hand Gestures
47. Recognition Based on MobileNetV2 and ConvNet Models," in *Proceedings - 2019 6th International Conference on Image and Signal Processing and their Applications, ISPA 2019*, 2019.
48. Y. Zheng, J. Huang, T. Chen, Y. Ou, and W. Zhou, "Transfer of learning in the convolutional neural networks on classifying geometric shapes based on local or global invariants," *Frontiers in Computational Neuroscience*, vol. 15, 2021.
49. "ResNet-101 convolutional neural network - MATLAB resnet101."
50. [Online]. Available: <https://www.mathworks.com/help/deeplearning/ref/resnet101.html>. [Accessed: 15-Apr-2022].
51. A. Fariza, Mu'arifin, and A. Z. Arifin, "Age Estimation System Using Deep Residual Network Classification Method," 2019 International Electronics Symposium (IES), 2019.
52. A. Sarkar, "Creating densenet 121 with TensorFlow," Medium, 11-
53. Jul-2020. [Online]. Available:
54. <https://towardsdatascience.com/creating-densenet-121-withtensorflow-edbc08a956d8>. [Accessed: 15-Apr-2022].
55. G. Huang, Z. Liu, L. van der Maaten, and K. Weinberger, "Densely Connected Convolutional Networks," Jul. 2017.
56. Google colab. [Online]. Available: <https://colab.research.google.com/>. [Accessed: 25-Apr-2022].
57. "TensorFlow." [Online]. Available: <https://www.tensorflow.org/>. [Accessed: 07-Jul-2022].
58. Havangi, R. and S.H. Khatami, Simultaneous identification and tracking of objects using deep learning. *Journal of Machine Vision and Image Processing*, 2023. **10**(3): p. 79-92