



Computational Intelligence in Electrical Engineering
Vol. 16, No. 4, 2026
pp. 59-68
Research Paper

Diagnosis of Parkinson's Disease from Magnetic Resonance Images Using Deep Learning Techniques

Shabnam Cheghameh ¹, Saeed Meshgini ^{*2}, Reza Afrouzian ³

¹ Department of Biomedical Engineering, Faculty of Electrical and Computer Engineering, University of Tabriz, Tabriz, Iran

² Associate Professor, Department of Biomedical Engineering, Faculty of Electrical and Computer Engineering, University of Tabriz, Tabriz, Iran

³ Assistant Professor, Department of Biomedical Engineering, Faculty of Electrical and Computer Engineering, University of Tabriz, Tabriz, Iran

Abstract:

Parkinson's disease is a progressive neurodegenerative disorder whose early and accurate diagnosis plays a pivotal role in treatment planning and slowing symptom progression. In this study, a deep learning-based approach is proposed for classifying brain MRI scans to detect Parkinson's disease. The proposed model employs the VGG16 architecture as a feature extractor. This architecture was chosen due to its simple structure, appropriate depth, and proven performance in medical image analysis, providing satisfactory accuracy and stability for medium-sized MRI data. Jacobian normalization is applied during training to enhance stability and generalization capability. This method controls the model's sensitivity to local changes and minor noise, producing smoother and more stable mappings while reducing the risk of overfitting. The MRI dataset underwent standard preprocessing techniques, including intensity distribution optimization, and was partitioned into training, validation, and testing subsets while preserving class balance. Model optimization was performed using the Adam optimizer and the binary cross-entropy loss function within a supervised training scheme. Experimental results demonstrate that the proposed architecture achieves 100% accuracy on both validation and test sets, while exhibiting rapid convergence in minimizing the loss function. These results indicate the positive impact of Jacobian normalization on improving model generalization. Overall, combining deep feature extraction with Jacobian normalization can effectively capture Parkinson's disease-related patterns in brain MRI images, offering a potential component for clinical decision-support systems.

Keywords: Brain MRI Images, Convolutional Neural Network (CNN), Deep Learning, Parkinson's Disease, Medical Image Classification.



This is an open access article under the CC BY-NC-ND/4.0/ License (<https://creativecommons.org/licenses/by-nc-nd/4.0/>).



<https://doi.org/10.22108/isee.2026.146745.1767>

مقاله پژوهشی

تشخیص بیماری پارکینسون از روی تصاویر MRI با استفاده از روش‌های یادگیری عمیق

شبیم چغامه ^۱، سعید مشگینی ^{۲*}، رضا افروزیان ^۳

۱- دانشجوی کارشناسی ارشد گروه مهندسی پزشکی، دانشکده مهندسی برق و کامپیوتر، دانشگاه تبریز، تبریز، ایران

shabnamcheghami@gmail.com

۲- استادیار گروه مهندسی پزشکی، دانشکده مهندسی برق و کامپیوتر، دانشگاه تبریز، تبریز، ایران

meshgini@tabrizu.ac.ir

۳- استادیار گروه مهندسی پزشکی، دانشکده مهندسی برق و کامپیوتر، دانشگاه تبریز، تبریز، ایران

afrouzian@tabrizu.ac.ir

چکیده: بیماری پارکینسون یک اختلال پیشرونده سیستم عصبی مرکزی است که تشخیص زودهنگام آن نقشی کلیدی در درمان و کاهش سرعت پیشرفت علائم ایفا می‌کند. در این مطالعه، رویکردی مبتنی بر یادگیری عمیق برای طبقه‌بندی تصاویر MRI مغزی ارائه شده است. مدل پیشنهادی از معماری VGG16 به عنوان استخراج گر ویژگی بهره می‌گیرد که این شبکه به دلیل ساختار ساده، عمق مناسب و عملکرد اثبات شده در تحلیل تصاویر پزشکی انتخاب شده است و برای داده‌های MRI با حجم متوسط، دقت و پایداری مطلوبی فراهم می‌کند. به منظور افزایش پایداری و بهبود تعمیم پذیری، از تکنیک نرمال سازی Jacobian در فرایند آموزش استفاده شده است که این روش با کنترل حساسیت مدل نسبت به تغییرات موضعی و نویزهای جزئی، نداشت‌های پایداری و هموارتر ایجاد می‌کند و احتمال بیش‌برازش را کاهش می‌دهد. مجموعه داده MRI پس از اعمال پیش پردازش‌های استاندارد و بهینه سازی توزیع شدت تصویر، به سه زیرمجموعه آموزش، اعتبارسنجی و آزمون با حفظ توازن کلاس‌ها تقسیم شد. مدل با استفاده از الگوریتم بهینه ساز Adam و تابع زیان binarycross-entropy، طی یک فرایند آموزش نظارت شده بهینه سازی شد. نتایج آزمایش‌ها نشان داد معماری پیشنهادی قادر به دستیابی به دقت ۱۰۰ درصد در هر دو مجموعه اعتبارسنجی و آزمون است و همگرایی سریعی را در کاهش تابع زیان نشان داده است که این موضوع بیانگر تأثیر مثبت نرمال سازی Jacobian در بهبود تعمیم پذیری مدل است. این یافته‌ها بیانگر آن است که ترکیب استخراج ویژگی عمیق با نرمال سازی Jacobian می‌تواند به طور مؤثر الگوهای مرتبط با بیماری پارکینسون را در تصاویر MRI شناسایی کند و به عنوان بخشی از سامانه‌های کمک تشخیصی بالینی به کار رود.

واژه‌های کلیدی: تصاویر MRI مغزی، شبکه عصبی پیچشی، یادگیری عمیق، بیماری پارکینسون، طبقه بندی تصاویر پزشکی.

۱- مقدمه

بیماری‌ها دارند. این تصاویر به کمک میدان مغناطیسی قوی و امواج رادیویی، اطلاعات سه بُعدی و دقیق از بافت‌های مغزی ارائه می‌دهند که برای پزشکان و پژوهشگران امکان تحلیل تغییرات مورفولوژیکی و ساختاری مغز را فراهم می‌کند [۱]. بیماری‌های عصبی مانند بیماری پارکینسون، آلزایمر و مولتیپل اسکلروزیس (MS) از جمله بیماری‌های مهمی هستند

تصاویر تشدید مغناطیسی^۱ از مهم ترین و گسترده ترین روش‌های تصویربرداری پزشکی به شمار می‌روند که به دلیل ارائه تصاویر با وضوح زیاد و قابلیت نمایش دقیق ساختارهای نرم بدن، به ویژه مغز، کاربردهایی فراوان در تشخیص و پایش

^۱ تاریخ ارسال مقاله: ۱۴۰۴/۰۶/۳۱

تاریخ پذیرش مقاله: ۱۴۰۴/۱۱/۲۶

نام نویسنده مسئول: سعید مشگینی

نشانی نویسنده مسئول: ایران، تبریز، دانشگاه تبریز، دانشکده مهندسی برق و

کامپیوتر، گروه مهندسی پزشک

پیدری است که باعث افزایش دقت و بهبود عملکرد مدل می‌شود. این شبکه علاوه بر اینکه در بسیاری از چالش‌های بینایی کامپیوتری موفق بوده، در تحلیل تصاویر پزشکی نیز کاربردهای فراوان یافته است [۵].

استفاده از مدل‌های پیش‌آموزش‌دیده مانند VGG16 که بر روی داده‌های بزرگ عمومی مانند ImageNet آموزش دیده‌اند، امکان انتقال یادگیری^۳ را فراهم می‌کند. این روش کمک می‌کند تا با داده‌های کمتر و هزینه محاسباتی کمتر، مدل‌هایی دقیق برای تصاویر تخصصی پزشکی مانند MRI توسعه یابند [۶].

با وجود توانایی زیاد شبکه‌های CNN در یادگیری ویژگی‌های پیچیده، این مدل‌ها به‌تنهایی قادر به استخراج دقیق ویژگی‌های هندسی و ساختاری تصاویر نیستند. تغییرات فضایی و موضعی بافت‌ها در تصاویر MRI می‌تواند باعث کاهش دقت طبقه‌بندی شود. به همین دلیل، استفاده از روش‌های پیش‌پردازش مبتنی بر تحلیل تغییر شکل و نرمال‌سازی تصاویر، به ویژه نرمال‌سازی جاکوبین، به منظور بهبود کیفیت داده‌ها و کمک به مدل در یادگیری ویژگی‌های مهم‌تر و پایدارتر مطرح شده است [۳].

مطالعات اخیر نشان داده‌اند ترکیب روش‌های نرمال‌سازی با شبکه‌های CNN پیش‌آموزش‌دیده می‌تواند به طرز چشمگیری عملکرد طبقه‌بندی تصاویر MRI را بهبود بخشد. برای مثال، پژوهش‌های جدید نشان داده‌اند این رویکرد ترکیبی می‌تواند به تشخیص دقیق‌تر بیماری‌های نورودژنراتیو منجر شود و در تشخیص زودهنگام بیماری‌هایی مانند پارکینسون نقش بسزایی ایفا کند [۷]، [۸].

در این پژوهش، با استفاده از داده‌های معتبر پایگاه PPMI^۴ که شامل تصاویر MRI افراد با رده سنی ۲۰ تا ۵۰ سال است، روشی ترکیبی مبتنی بر شبکه VGG16 پیش‌آموزش‌دیده و نرمال‌سازی جاکوبین پیشنهاد شده است. هدف اصلی این پژوهش ارائه مدلی دقیق، کارآمد و قابل اعتماد برای طبقه‌بندی تصاویر MRI مغزی است که بتواند در کاربردهای بالینی و تشخیص زودهنگام بیماری‌های نورودژنراتیو نقشی مؤثر ایفا کند. این روش، با بهبود استخراج ویژگی‌های معنایی و ساختاری، قادر است محدودیت‌های روش‌های سنتی و حتی مدل‌های CNN خالص را پوشش

که در مراحل اولیه با تغییرات ظریف در بافت مغزی همراه هستند و تشخیص به‌موقع آنها نقش بسیار حیاتی در روند درمان و بهبود کیفیت زندگی بیماران دارد. استفاده از MRI در این زمینه به دلیل عدم تهاجمی بودن و قدرت تفکیک زیاد به یکی از ابزارهای اصلی در تشخیص پزشکی تبدیل شده است [۲].


با وجود اهمیت بسیار زیاد تصاویر MRI، تحلیل دقیق و خودکار آنها به دلیل پیچیدگی‌های ذاتی این تصاویر، وجود نویز، تنوع بین‌فردی و تفاوت‌های دستگاه‌های تصویربرداری چالش‌برانگیز است. استخراج ویژگی‌های مؤثر و معنادار از تصاویر MRI نیازمند روش‌هایی است که بتوانند پیچیدگی‌های فضایی و ساختاری بافت‌های مغزی را به صورت دقیق و جامع مدل کنند [۳].

روش‌های سنتی تحلیل تصاویر پزشکی عمدتاً مبتنی بر استخراج دستی ویژگی‌ها و قواعد تجربی بوده‌اند که نه فقط زمان‌بر هستند، بلکه محدودیت‌های زیادی در دقت و قابلیت تعمیم‌پذیری دارند. به همین دلیل، توسعه روش‌های یادگیری ماشینی و به ویژه یادگیری عمیق به منظور خودکارسازی و افزایش دقت تحلیل تصاویر پزشکی بسیار مورد توجه قرار گرفته است.

یادگیری عمیق، شاخه‌ای از یادگیری ماشین، با استفاده از شبکه‌های عصبی مصنوعی چندلایه امکان استخراج ویژگی‌های سطح بالا و پیچیده را فراهم می‌کند. شبکه‌های عصبی پیچشی (CNN)^۲ که به طور خاص برای داده‌های تصویری طراحی شده‌اند، در سال‌های اخیر موفقیت‌هایی چشمگیر در طبقه‌بندی تصاویر پزشکی از جمله MRI به دست آورده‌اند [۱].

ویژگی برجسته CNN‌ها توانایی خودکار یادگیری ویژگی‌های مهم از داده‌ها بدون نیاز به طراحی دستی ویژگی است. این قابلیت باعث شده است تا در کاربردهایی متنوع مانند تشخیص تومورهای مغزی، بیماری‌های نورودژنراتیو و تحلیل بافت‌های مغزی به طور گسترده استفاده شوند [۴].

شبکه VGG16 که توسط گروه Visual Geometry در دانشگاه آکسفورد توسعه یافته، یکی از شبکه‌های عمیق و پرکاربرد CNN است که با ساختار ساده اما عمیق خود (۱۶ لایه)، قابلیت استخراج ویژگی‌های سطح بالا را دارد. مزیت مهم VGG16 استفاده از فیلترهای کوچک ۳×۳ به صورت



شکل (۱): تصاویر MRI افراد در دو کلاس HC و PD

۲-۲- شبکه عصبی پیچشی VGG16

شبکه عصبی پیچشی VGG16 یکی از مدل‌های پرکاربرد در حوزه بینایی ماشین است که نخستین بار توسط Simonyan و Zisserman در سال ۲۰۱۴ در دانشگاه آکسفورد توسعه داده شد. این مدل به عنوان یکی از برترین شبکه‌های شرکت‌کننده در رقابت ILSVRC 2014 معرفی شد و با عملکرد جالب توجه خود در مجموعه داده ImageNet جایگاهی ویژه در مسائل طبقه‌بندی تصویر پیدا کرد. مدل VGG16 متشکل از ۱۶ لایه شامل ۱۳ لایه کانولوشنی و ۳ لایه کاملاً متصل است. در این معماری، از کرنل‌های همگن با اندازه 3×3 و استراید ۱ استفاده شده است که با padding مناسب، ابعاد ویژگی‌ها را حفظ می‌کند. پس از هر بلوک کانولوشنی، یک لایه تجمیع^۷ با کرنل 2×2 و استراید ۲ برای کاهش ابعاد و استخراج ویژگی‌های مکانی استفاده می‌شود.

دلیل استفاده از مدل VGG16 این است که به دلیل ساختار ساده و نسبتاً کم‌عمق خود، قابلیت آموزش پایدار روی مجموعه داده محدود MRI را دارد و امکان انتقال یادگیری از ImageNet را فراهم می‌کند. شبکه‌های پیچیده‌تر مانند ResNet یا EfficientNet به داده بیشتری نیاز دارند و روی داده محدود ممکن است به بیش‌برازش منجر شوند؛ بنابراین، برای این مطالعه مناسب نبوده‌اند.

خروجی هر لایه کانولوشنی Y با استفاده از عملیات کانولوشن ورودی X و فیلترهای W به همراه بایاس b طبق رابطه (۱) محاسبه می‌شود:

دهد و راه‌حلی نوین برای چالش‌های موجود در تحلیل تصاویر MRI فراهم آورد.

اگرچه مطالعات قبلی در داخل کشور نیز کاربرد یادگیری عمیق در تحلیل تصاویر MRI را بررسی کرده‌اند، توجه کافی به ترکیب روش‌های هندسی و شبکه‌های عمیق نشده است. بنابراین، این پژوهش می‌تواند گامی مؤثر در توسعه سیستم‌های هوشمند تشخیصی در حوزه پزشکی ایران باشد.

۲- مواد و روش‌ها

در این فصل، ابتدا پایگاه داده استفاده‌شده تشریح می‌شود و سپس به تفصیل روش‌های استفاده‌شده شامل معماری VGG16 و نرمال‌سازی جاکوبین بررسی خواهند شد. در پایان نیز، روش پیشنهادی ما ارائه می‌شود که ترکیبی از این دو مؤلفه است.

۲-۱- پایگاه داده PPMI

در این پژوهش، از داده‌های پایگاه معتبر PPMI استفاده شده است. این پایگاه داده یکی از جامع‌ترین منابع عمومی در زمینه بیماری پارکینسون است و شامل داده‌های چندمرکزی تصویربرداری MRI به همراه اطلاعات بالینی، ژنتیکی و بیولوژیکی شرکت‌کنندگان است.

در این مطالعه، فقط تصاویر MRI ساختاری T1-weighted مربوط به افراد سالم و بیماران مبتلا به پارکینسون استفاده شدند. معیار انتخاب داده‌ها در این پژوهش افراد بین ۲۰ تا ۵۰ سال بوده است.

در مجموع، ۶۶۵ تصویر MRI با وضوح 256×256 و در فرمت DICOM در این مطالعه استفاده شده‌اند. این داده‌ها در دو کلاس به فرم زیر برچسب‌گذاری شده‌اند:

- ✓ بیماران مبتلا به پارکینسون^۵
- ✓ افراد سالم^۶

در شکل (۱)، نمونه‌های از داده‌های ورودی نشان داده شده‌اند که نمونه‌های سمت راست مربوط به افراد پارکینسون و نمونه‌های سمت چپ مربوط به افراد سالم هستند.

فرض کنید مدل یادگیری عمیق تابعی $f: R \rightarrow R^n$ است که ورودی‌های $x \in R^n$ را به خروجی دودسته‌ای $y \in [0,1]$ نگاشت می‌کند. مشتق جاکوبین مدل نسبت به ورودی‌ها ماتریسی شامل مشتقات جزئی هر خروجی نسبت به هر ورودی است (رابطه ۴):

$$J_{f(x)} = \frac{f(x)\partial}{x\partial} = \left[\frac{f(x)\partial}{n\partial} \dots \frac{f(x)\partial}{2\partial} \frac{f(x)\partial}{1\partial} \right] \quad (4)$$

برای کاهش حساسیت مدل به تغییرات ناچیز ورودی، از معیار نرم فروبنیوس⁹ ماتریس جاکوبین استفاده می‌شود که طبق رابطه (۵) تعریف می‌شود:

$$F\|J_{f(x)}\| = \sqrt{\sum_{i=1}^n \left(\frac{f(x)\partial}{x_i\partial}\right)^2} \quad (5)$$

این نرم نشان‌دهنده بزرگی تغییرات خروجی مدل نسبت به تغییرات ورودی است. در حین آموزش، مقدار این نرم محاسبه می‌شود و به عنوان یک عبارت جریمه با ضریب λ به تابع هزینه¹⁰ افزوده می‌شود. تابع هزینه نهایی مدل به صورت رابطه (۶) تعریف می‌شود:

$$L = L_{BCE} + \lambda \cdot E_{X \sim D} [\|J_{f(x)}\|_F] \quad (6)$$

که در آن:

✓ متغیر L_{BCE} زیان باینری کراس انتروپی برای طبقه‌بندی دوکلاسه است.

✓ متغیر λ ضریب وزندهی به رگولاریزاسیون جاکوبین است.

✓ متغیر $E_{X \sim D}$ میلنگین روی نمونه‌های داده‌های آموزشی D است.

این روش باعث بهبود عملکرد مدل در داده‌های تست و کاهش احتمال بیش‌برازش¹¹ می‌شود و به شبکه اجازه می‌دهد تا ویژگی‌هایی معنادار و پایدارتر برای تشخیص بیماری پارکینسون از تصاویر MRI بیاموزد.

۳- روش پیشنهادی

در این بخش، مراحل انجام‌شده برای اجرای سیستم پیشنهادی تشخیص بیماری پارکینسون مبتنی بر تصاویر MRI مغزی شرح داده می‌شود. ساختار کلی روش شامل سه مرحله

$$Y_{i,j}^{(l,k)} = \sum_{m=0}^{M-1} \sum_{n=0}^{N-1} X_{i+m,j+n}^{(l-1)} \cdot W_{m,n}^{l,k} + b^{(l,k)} \quad (1)$$

که در آن k شاخص کانال خروجی (فیلتر) و $N \times M$ اندازه کرنل است.

تابع فعال‌سازی ReLU پس از هر لایه کانولوشن به صورت رابطه (۲) تعریف می‌شود:

$$f(x) = \max(0, x) \quad (2)$$

در انتهای شبکه، سه لایه کاملاً متصل قرار دارند که دو لایه اول هر کدام شامل ۴۰۹۶ نورون هستند و لایه آخر متناسب با تعداد کلاس‌ها طراحی شده است. در این پژوهش، لایه خروجی دنورونی است که به دو کلاس «پارکینسون» و «سالم» مربوط می‌شود. خروجی شبکه با استفاده از تابع Sigmoid برای محاسبه احتمال تعلق نمونه به هر کلاس به صورت رابطه (۳) بیان می‌شود:

$$\delta(z) = \frac{1}{1 + e^{-z}} \quad (3)$$

در این رابطه، z نمره خروجی حاصل از آخرین لایه کاملاً متصل است و $\delta(z)$ احتمال تعلق نمونه ورودی x به کلاس مثبت (مبتلا به پارکینسون) را بیان می‌کند.

در این پژوهش، از نسخه پیش‌آموزش‌دیده VGG16 بر روی دیتاست ImageNet بهره گرفته شده و از تکنیک انتقال یادگیری برای فاین‌تیون مدل بر روی داده‌های MRI مغزی استفاده شده است. به منظور جلوگیری از بیش‌برازش و کاهش هزینه محاسباتی، فقط لایه‌های تماماً متصل^{۱۲} آموزش‌پذیر باقی مانده‌اند و وزن لایه‌های اولیه فریز شده‌اند. مطالعات پیشین نیز اثربخشی شبکه VGG16 در کاربردهای تحلیل تصاویر پزشکی را نشان داده‌اند.

۳-۲- نرمال‌سازی جاکوبین

در این مطالعه، علاوه بر استفاده از شبکه پیش‌آموزش‌دیده VGG16، برای افزایش پایداری و تعمیم‌پذیری مدل، از تکنیک رگولاریزاسیون مشتق جاکوبین استفاده شده است. این روش با اعمال جریمه بر اندازه مشتق خروجی مدل نسبت به ورودی‌ها، مدل را به یادگیری نگاشت‌های صاف‌تر و مقاوم‌تر به تغییرات کوچک در داده‌های ورودی ترغیب می‌کند.


این تبدیل بدون افزودن اطلاعات جدید به تصویر، صرفاً ساختار ورودی را با مدل سازگار می‌کند.

۳-۱-۴- نرمال سازی نهایی

با وجود آنکه تصاویر MRI در مراحل ابتدایی پیش‌پردازش به بازه ۰ تا ۱ نرمال‌سازی شده بودند، نرمال سازی نهایی آنها الزامی است؛ زیرا این تابع، داده‌ها را مطابق توزیع آماری دیتاست ImageNet تنظیم می‌کند که مدل VGG16 بر پایه آن آموزش دیده است. این نرمال‌سازی شامل کسر میانگین‌های خاص هر کانال رنگی است تا ورودی‌ها دقیقاً با داده‌های آموزش دیده مدل هم‌تراز شوند. انجام این مرحله موجب کاهش اختلاف آماری^{۱۳} بین داده‌های MRI و داده‌های آموزش VGG می‌شود. در نتیجه، عملکرد مدل بهبود و دقت طبقه‌بندی افزایش می‌یابد.

۳-۲- معماری شبکه عمیق پیشنهادی

در این پژوهش، برای تشخیص بیماری پارکینسون با استفاده از تصاویر MRI، مدل ترکیبی بر پایه شبکه عصبی کانولوشنی پیش‌آموزش دیده VGG16 توسعه یافته است. ورودی مدل تصاویر MRI با ابعاد $256 \times 256 \times 3$ هستند که پس از پیش‌پردازش وارد مدل می‌شوند.



شکل (۲): نمای کلی مدل پیشنهادی

مدل پیشنهادی (شکل ۲) شامل دو بخش اصلی است:

اصلی است: پیش‌پردازش داده‌ها، استخراج ویژگی با استفاده از شبکه VGG16 و به‌کارگیری نرمال‌سازی جاکوبین برای بهبود تعمیم‌پذیری مدل. جزئیات هر مرحله در ادامه آمده است.

۳-۱-۳- پیش‌پردازش داده‌ها

پیش‌پردازش تصاویر MRI نقشی مهم در بهبود عملکرد مدل‌های یادگیری عمیق دارد، به ویژه زمانی که مدل بر پایه شبکه‌های از پیش‌آموزش دیده مانند VGG16 ساخته می‌شود. در این مطالعه، مجموعه‌ای از مراحل پردازش اولیه و استانداردسازی بر روی تصاویر ورودی اعمال شد تا تصاویر برای استفاده در شبکه عصبی عمیق مناسب شوند.

۳-۱-۳-۱- نرمال سازی شدت تصاویر

اولین مرحله در پیش‌پردازش داده‌ها نرمال‌سازی شدت تصاویر است که در داده‌ها از محدوده ۰ تا ۲۵۵ به محدوده ۰ تا ۱ نگاشت می‌شوند. رابطه (۷) روش نگاشت را نشان می‌دهد که در آن I تصویر اولیه و I' تصویر نرمال شده است.

$$I' = \frac{I - \min(I)}{\max(I) - \min(I)} \times 255 \quad (8)$$

۳-۱-۳-۲- فیلتر کردن ابعاد نامناسب

برای تطبیق با نیازهای معماری‌های متداول شبکه‌های کانولوشنی، کلیه تصاویر به ابعاد استاندارد بازنمونه‌برداری شدند. این اندازه‌گذاری مجدد با حفظ نسبت ابعاد کلی ساختار مغز انجام شده است. همچنین، تنها تصاویری که عرض آنها معادل ۲۴۰ پیکسل بود (از نظر کیفیت و ساختار مناسب‌تر)، وارد مرحله پردازش شدند.

۳-۱-۳-۳- افزایش کانال‌های رنگی تصویر

با توجه به اینکه مدل VGG16 به عنوان یک شبکه از پیش‌آموزش دیده بر روی دیتاست ImageNet طراحی شده است، ورودی‌های آن باید سه‌کاناله^{۱۲} باشند. از آنجا که تصاویر MRI ورودی خاکستری (تک‌کاناله) هستند، تبدیل آنها به فرمت سه‌کاناله ضروری بود. این کار با کپی کردن کانال تکراری سه‌باره (رابطه ۸) انجام شد:

$$I_{RGB} = \text{Stack}(I, I, I) \quad (9)$$

در جدول (۲) پارامترهای مدل پیشنهادی قرار داده شده‌اند.

جدول (۲): پارامترهای مدل پیشنهادی

مقدار	پارامتر
تقریباً ۱۸۳۸۵۰۰۰	تعداد کل پارامترها
۳۶۷۰۲۷۳	پارامترهای آموزش‌پذیر
۱۴۷۱۴۶۸۸	پارامترهای فریز شده
10^{-4}	نرخ یادگیری
Binary Crossentropy + Jacobian regularization	تابع زیان
۱۲	تکرار
۳۲	اندازهٔ بچ
۰/۵	نرخ دورانداز
۰/۱	وزن منظم‌سازی Jacobian
۲۰٪	درصد بچ‌های اعمال Jacobian

این معماری به صورت کامل و حرفه‌ای امکان استخراج ویژگی‌های پیچیده از تصاویر MRI را فراهم می‌آورد و با اضافه کردن منظم‌سازی ژاکوبین باعث بهبود تعمیم‌پذیری و کاهش حساسیت به نویزهای کوچک می‌شود.

۳-۳- مجموعه آموزش، ارزیابی و تست

برای ارزیابی عملکرد مدل و جلوگیری از بیش‌برازش، مجموعه داده‌ها به سه بخش آموزش، اعتبارسنجی و آزمون تقسیم شد. در گام نخست، داده‌ها به همراه برچسب‌های متناظرشان، به کمک تابع shuffle از کتابخانه Scikit-learn، به صورت تصادفی بازآرایی شدند تا هرگونه وابستگی احتمالی ناشی از ترتیب داده‌ها حذف شود.

سپس به وسیله تابع train_test_split، ۷۰ درصد از کل داده‌ها به عنوان مجموعه آموزش انتخاب شد و ۳۰ درصد باقی‌مانده به عنوان یک مجموعه موقت (شامل داده‌های آزمون و اعتبارسنجی) نگهداری شد. در مرحله بعد، مجموعه موقت به طور مساوی و با نسبت ۵۰٪-۵۰٪-۵۰٪ بین داده‌های اعتبارسنجی و آزمون تقسیم شد. در تمامی مراحل تقسیم، پارامتر stratify برابر با برچسب‌ها تنظیم شد تا نسبت نمونه‌ها در هر کلاس در تمام مجموعه‌ها ثابت بماند.

۱. بخش استخراج ویژگی: در این بخش از شبکه،

VGG16 با وزن‌های پیش‌آموزش‌دیده روی دیتاست ImageNet استفاده شده است. این بخش به صورت Freeze (یخ‌زده) بوده و وزن‌های آن در طول آموزش تغییر نمی‌کنند. لایه‌های تماماً متصل بالای VGG16 حذف شده‌اند و فقط لایه‌های کانولوشنی برای استخراج ویژگی نگه داشته شده‌اند. خروجی این بخش برداری با ابعاد $8 \times 7 \times 512$ است.

۲. بخش طبقه‌بندی سفارشی: خروجی بخش استخراج


ویژگی پس از صاف‌شدن^{۱۴} به یک بردار یک‌بعدی با طول ۲۸۶۷۲ تبدیل می‌شود. این بردار سپس وارد یک لایه Dense با ۱۲۸ نورون و تابع فعال‌سازی ReLU می‌شود. برای جلوگیری از بیش‌برازش، لایه دورانداز^{۱۵} با نرخ ۰/۵ به کار گرفته شده است. در نهایت، یک لایه Dense با نورون خروجی ۱ و تابع فعال‌سازی سیگموید، احتمال تعلق نمونه به کلاس مثبت (مثلاً به پارکینسون) را پیش‌بینی می‌کند.

در ادامه، مدل با استفاده از بهینه‌ساز Adam و نرخ یادگیری 1×10^{-4} آموزش داده شد. تابع زیان اصلی BinaryCrossentropy است. برای بهبود پایداری و تعمیم‌پذیری مدل، منظم‌سازی مبتنی بر نرم هاتریس ژاکوبین در نظر گرفته شد؛ به این صورت که در هر دوره، برای ۲۰ درصد بچ‌ها، نرم ژاکوبین خروجی مدل نسبت به ورودی محاسبه و به تابع زیان اضافه می‌شود. وزن منظم‌سازی $\lambda = 0.1$ تعیین شده است تا تعادلی مناسب بین دقت مدل و پایداری آن برقرار شود. در جدول (۱)، جزئیات لایه‌ها و ابعاد ورودی-خروجی بیان شده است.


جدول (۱): جزئیات لایه‌های ورودی و خروجی مدل پیشنهادی

تابع فعال‌سازی	تعداد پارامترها	ابعاد خروجی	ابعاد ورودی	لایه
-	۰	$256 \times 240 \times 3$	$256 \times 240 \times 3$	input
-	۱۴۷۱۴۱۴۴	$8 \times 7 \times 512$	$256 \times 240 \times 3$	VGG16 Base
-	۰	۲۸۶۷۲	$8 \times 7 \times 512$	Flatten
ReLU	۳۶۷۰۱۴۴	۱۲۸	۲۸۶۷۲	Dense1
-	۰	۱۲۸	۱۲۸	Dropout
Sigmoid	۱۲۹	۱	۱۲۸	Dense 2

رسیده‌اند و مقدار خطا نیز به سطوح بسیار پایین کاهش یافته است.



شکل (۴): نمودار دقت در فرایند آموزش




شکل (۵): نمودار خطا در فرایند آموزش

در جدول (۳)، نتایج دقت و خطا برای هر دوره آموزشی بر اساس مجموعه‌های آموزشی و اعتبارسنجی گزارش شده است. همان‌گونه که مشاهده می‌شود، از دوره چهارم به بعد، مدل به دقت بیشتر از ۹۳ درصد در مجموعه آموزشی و ۱۰۰ درصد در مجموعه اعتبارسنجی دست یافته است. همچنین، در پایان دوره بیستم، دقت مدل بر روی مجموعه آزمون به ۱۰۰ درصد رسید که بیانگر توانایی بسیار زیاد مدل در تعمیم‌پذیری بر روی داده‌های جدید است.

در شکل (۳)، توزیع نهایی تعداد داده‌ها در هر بخش به صورت زیر است:

- مجموعه آموزش: ۴۰۴ تصویر
- مجموعه اعتبارسنجی: ۸۷ تصویر
- مجموعه آزمون: ۸۷ تصویر

این روش تقسیم داده‌ها باعث شد تا مدل بتواند در طول فرایند آموزش، با استفاده از داده‌های اعتبارسنجی بهینه‌سازی شود و در عین حال، ارزیابی نهایی عملکرد آن بر اساس داده‌هایی که در هیچ مرحله‌ای از آموزش دیده نشده‌اند (مجموعه آزمون^{۱۶})، انجام شود.



شکل (۳): نمودار توزیع داده‌ها

۴- یافته‌ها

مدل پیشنهادی در طی ۱۲ دوره آموزشی با استفاده از داده‌های آموزشی و مجموعه اعتبارسنجی ارزیابی شد. به منظور مقابله با عدم توازن نمونه‌ها در کلاس‌های داده، از وزن‌دهی کلاس‌ها^{۱۷} در فرایند آموزش استفاده شد. این رویکرد موجب شد تا مدل نسبت به کلاس‌های کم نمونه حساسیت بیشتری نشان دهد و عملکرد کلی بهبود یابد.

شکل‌های مربوط به تغییرات دقت^{۱۸} و تابع هزینه در طول فرایند آموزش و اعتبارسنجی در نمودارهای شکل (۴) و شکل (۵) ارائه شده‌اند. این نمودارها نشان می‌دهند مدل پس از چند دوره اولیه به سرعت به همگرایی رسیده است و در ادامه آموزش، مقادیر دقت تقریباً به حالت پایدار نزدیک به ۱۰۰

جدول (۳): نتایج مدل در زمان آموزش

تکرار	دقت آموزش	زمان آموزش	دقت اعتبارسنجی	زمان اعتبارسنجی	زمان متوسط هر گام (ثانیه)
۱	۶۷/۵۹	۳/۹۹	۹۰/۷۰	۰/۵۷	۲
۵	۹۹/۰۵	۰/۳۰	۱/۰۰	۰/۰۰۱	۰/۲۵
۱۲	۹۹/۵۶	۰/۰۱	۱/۰۰	۰/۰۰۰۰۸۹	۰/۲۵

نرمال‌سازی Jacobian، موجب بهبود تعمیم‌پذیری مدل و کاهش حساسیت به تغییرات موضعی تصویر شد. فرآیند آموزش با تقسیم‌بندی دقیق داده‌ها به مجموعه‌های آموزش، اعتبارسنجی و آزمون و با حفظ توزیع کلاس‌ها انجام شد. ارزیابی نتایج نشان داد مدل پیشنهادی توانست با دقت زیاد در طبقه‌بندی دوکلاسه (بیمار/سالم) عمل کند که این امر بیانگر توانایی زیاد مدل در شناسایی الگوهای مرتبط با پارکینسون در داده‌های MRI مغزی است. به طور کلی، یافته‌های این پژوهش نشان می‌دهد ترکیب روش‌های پیش‌پردازش دقیق، استخراج ویژگی عمیق و آموزش مبتنی بر داده‌های واقعی می‌تواند به عنوان یک ابزار کمکی ارزشمند برای تشخیص زودهنگام بیماری پارکینسون در محیط‌های بالینی استفاده شود. در آینده، توسعه مدل با استفاده از مجموعه داده‌های بزرگ‌تر، بهبود ساختار معماری و بررسی روش‌های ترکیبی چندوجهی می‌تواند دقت و قابلیت اطمینان سیستم را بیش از پیش افزایش دهد.

مراجع

- [1] S. Basak, M. R. Patra, "Brain MRI Classification Using Deep Learning: A Review", Biomedical Signal Processing and Control, 2021.
- [2] M. Liu, J. Zhang, E. Adeli, D. Shen, "Deep Learning Based Multimodal Neuroimaging for Alzheimer's Disease Diagnosis", IEEE Transactions on Medical Imaging, 2020. <https://ieeexplore.ieee.org/document/8461452>
- [3] H. I. Suk, S. W. Lee, D. Shen, "Deep Ensemble Learning of Sparse Regression Models for Brain Disease Diagnosis", Medical Image Analysis, Vol. 37, pp. 101–113, 2017. <https://doi.org/10.1016/j.media.2017.01.008>
- [4] J. Bernal, K. Kushibar, D. S. Asfaw, S. Valverde, A. Oliver, R. Martí, X. Lladó, "Deep Convolutional Neural Networks for Brain Image Analysis on Magnetic Resonance Imaging: A Review", Artificial Intelligence in Medicine, Vol. 95, pp. 64–81, 2019. <https://doi.org/10.1016/j.artmed.2018.08.008>

این نتایج نشان‌دهنده آن است که ترکیب معماری شبکه عصبی پیشنهادی با تکنیک‌های بهبود تعمیم‌پذیری مانند وزن‌دهی کلاس‌ها، توانسته است در مسئله تشخیص بیماری پارکینسون بر اساس تصاویر MRI به عملکردی بهینه و پایدار دست یابد.

تحلیل رفتار مدل در طول فرایند آموزش نشان می‌دهد استفاده از Jacobian Regularization تأثیری جالب توجه در بهبود پایداری همگرایی و کاهش نوسانات خطا داشته است. این رفتار با یافته‌های وانگ و همکاران [۸] هم‌راستا است که استفاده از نرمال‌سازی مبتنی بر جاکوبین را در افزایش مقاومت مدل‌های CNN در برابر تغییرات موضعی گزارش کرده‌اند. اگرچه محاسبه جاکوبین بخشی از بار محاسباتی مرحله آموزش را افزایش می‌دهد، این هزینه نسبتاً محدود است و فقط در فاز یادگیری اعمال می‌شود. نتایج این پژوهش نشان می‌دهد مزایای حاصل از این تکنیک که شامل تعمیم‌پذیری بیشتر، کاهش حساسیت به نویز و کسب دقت ۱۰۰ درصد در داده‌های آزمون می‌شوند، به‌مراتب بیش از افزایش جزئی زمان آموزش هستند. از این رو، می‌توان نتیجه گرفت استفاده از Jacobian Regularization در مدل پیشنهادی، از نظر علمی و کاربردی، توجیه‌پذیر است و به طور مؤثر کیفیت طبقه‌بندی تصاویر MRI را ارتقا می‌دهد.

۵- نتیجه‌گیری

در این پژوهش، یک رویکرد مبتنی بر شبکه‌های عصبی پیچشی عمیق برای طبقه‌بندی تصاویر MRI مغزی به منظور تشخیص بیماری پارکینسون ارائه شد. داده‌های MRI پس از انجام پیش‌پردازش شامل نرمال‌سازی اولیه و تغییر ابعاد به اندازه $۲۵۶ \times ۲۵۶ \times ۳$ و اعمال تابع preprocess_input مختص معماری VGG16، برای استخراج ویژگی آماده شدند. استفاده از معماری VGG16 به عنوان استخراج‌گر ویژگی، همراه با

- [7] M. Camacho, R. T. Oguz, I. S. Gundersen, D. J. Dittrich, M. J. McKeown, "Explainable Classification of Parkinson's Disease Using Deep Learning Trained on a Large Multi-Center Database of T1-Weighted MRI Datasets", *NeuroImage: Clinical*, Vol. 27, p. 102240, 2020. <https://doi.org/10.1016/j.nicl.2020.102240>
- [8] J. Wang, Q. Li, Y. Chen, "Enhancing Brain MRI Classification via Jacobian Normalization and Deep CNN Ensembles", *Neurocomputing*, Vol. 619, p. 129109, 2024. <https://doi.org/10.1016/j.neucom.2024.129109>
- [5] X. Long, L. Chen, C. Jiang, L. Zhang, "Diagnosis of Parkinson's Disease Using Structural MRI Images Based on Deep Learning", *Frontiers in Neuroscience*, Vol. 11, p. 572, 2017. <https://doi.org/10.3389/fnins.2017.00572>
- [6] H. E. Kim, A. Cosa-Linan, N. Santhanam, M. Jannesari, M. E. Maros, T. Ganslandt, "Transfer learning for medical image classification: a literature review", *BMC Medical Imaging*, Vol. 22, Article 69, 2022. <https://doi.org/10.1186/s12880-022-00793-7>

¹ Magnetic Resonance Imaging (MRI)

² Convolutional Neural Networks

³ Transfer Learning

⁴ Parkinson's Progression Markers Initiative

⁵ PD

⁶ Healthy Controls - HC

⁷ Max Pooling

⁸ Fully Connected

⁹ Frobenius norm

¹⁰ Loss

¹¹ Overfitting

¹² RGB

¹³ Covariate shift

¹⁴ Flatten

¹⁵ Dropout

¹⁶ Test Set

¹⁷ Class Weights

¹⁸ Accuracy

