

کاربرد مدل‌های یادگیری عمیق در تشخیص افسردگی با استفاده از تبدیل زمان-فرکانس سیگنال الکتروانسفالوگرام

محسن سادات شهابی^۱، احمد شالباف^۲

مقاله پژوهشی

چکیده

مقدمه: افسردگی، یک بیماری روانی شایع در جهان می‌باشد و تشخیص دقیق و زودهنگام برای درمان به موقع ضروری می‌باشد. در این مطالعه کاربرد روش‌های هوش مصنوعی برای تشخیص دقیق و خودکار اختلال افسردگی عمده از روی سیگنال‌های مغزی بررسی شده است.

روش‌ها: در این مطالعه، از ۳۰ فرد مبتلا به افسردگی عمده و ۲۸ فرد سالم به عنوان جمعیت شاهد استفاده شد و ارزیابی روانی آنها توسط روانپزشک متخصص و پرسشنامه‌ی استاندارد بک انجام گرفته است. سیگنال مغزی ۱۹ کاناله الکتروانسفالوگرام از همه‌ی افراد در حالت استراحت و با چشمان بسته اخذ گردید. سیگنال مغزی افراد بعد از پیش پردازش با استفاده از تبدیل فوریه زمان کوتاه در بازه‌های متوالی به صورت یک ماتریس دوبعدی به عنوان ورودی شبکه‌های عصبی عمیق داده شدند. مدل هوش مصنوعی DeepEEGNet، که مبتنی بر مدل یادگیری عمیق کانولوشنی EEGNet توسعه یافته است، برای دسته‌بندی سیگنال‌های مغزی افراد سالم و افسرده استفاده شد. از داده تست دیده نشده توسط مدل در مرحله‌ی آموزش، برای گزارش دقت نهایی مدل استفاده شده است.

یافته‌ها: مدل DeepEEGNet که از تبدیل فوریه زمان کوتاه به عنوان ورودی استفاده می‌کند، می‌تواند افراد سالم و افسرده را با دقت ۸۴/۱ درصد، حساسیت ۸۶ درصد و ویژگی ۸۲/۷ درصد از یکدیگر تفکیک نماید.

نتیجه‌گیری: مدل یادگیری عمیق پیشنهاد شده در این مطالعه، می‌تواند سیگنال‌های مغزی بیماران افسرده را از افراد سالم با دقت بالا تفکیک نماید و برای کمک به پزشکان مورد استفاده قرار گیرد.

واژگان کلیدی: اختلال افسردگی عمده؛ الکتروانسفالوگرام؛ یادگیری عمیق؛ هوش مصنوعی

ارجاع: سادات شهابی محسن، شالباف احمد. کاربرد مدل‌های یادگیری عمیق در تشخیص افسردگی با استفاده از تبدیل زمان-فرکانس سیگنال

الکتروانسفالوگرام. مجله دانشکده پزشکی اصفهان ۱۴۰۳؛ ۴۲ (۷۹۶): ۱۱۲۳-۱۱۲۸.

مقدمه

سیگنال‌های الکتروانسفالوگرام (EEG) چندکاناله که نشان‌دهنده‌ی فعالیت‌های مغزی افراد در هر لحظه می‌باشد، به دلیل پذیرش کلینیکی، مقرون به صرفه بودن و دقت زمانی بالا به طور ویژه مورد توجه قرار گرفته است (۳). یکی از راهکارهای نوین در تشخیص خودکار بیماری افسردگی، استفاده از روش‌های پیشرفته‌ی هوش مصنوعی برای توسعه‌ی مدل‌های شخصی‌سازی شده می‌باشد (۴). روش‌های هوش مصنوعی سنتی که اغلب با عنوان روش‌های یادگیری ماشین شناخته می‌شوند، از استخراج ویژگی‌های منحصربفرد و مهندسی شده از سیگنال EEG

افسردگی، یکی از شایع‌ترین اختلالات روانی می‌باشد که می‌تواند کیفیت زندگی افراد را کاهش دهد (۱). روش مرسوم در تشخیص افسردگی استفاده از پرسشنامه‌های استاندارد و یا مصاحبه با یک متخصص می‌باشد. هرچند این یک روش پذیرفته شده در تشخیص بیماری‌های روانی می‌باشد ولی خروجی آن با توجه به تجربه پزشک و میزان همکاری بیمار می‌تواند متفاوت باشد. برای حل این مشکل می‌توان از روش‌های خودکار شخصی‌سازی شده استفاده نمود (۲). در میان روش‌های موجود، استفاده از

۱- دکتری تخصصی، گروه فیزیک و مهندسی پزشکی، دانشکده‌ی پزشکی، دانشگاه علوم پزشکی شهیدبهشتی، تهران، ایران.

۲- دانشیار، گروه فیزیک و مهندسی پزشکی، دانشکده‌ی پزشکی، دانشگاه علوم پزشکی شهیدبهشتی، تهران، ایران.

نویسنده‌ی مسؤول: احمد شالباف؛ دانشیار، گروه فیزیک و مهندسی پزشکی، دانشکده‌ی پزشکی، دانشگاه علوم پزشکی شهیدبهشتی، تهران، ایران

Email: Shalbf@sbmu.ac.ir

استراحت و با چشمان بسته و فرکانس نمونه برداری ۲۵۶ هرتز نسبت به الکترود گوش ثبت شده است. پیش پردازش سیگنال EEG توسط نرم افزار EEGLAB در محیط MATLAB استفاده شده است. ابتدا مرجع سیگنال به مرجع میانگین تبدیل شده است و یک فیلتر فرکانسی بین ۰٫۵ تا ۴۰ هرتز برای حذف اختلالات برق شهر و جابجایی دی سی سیگنال الکترودها اعمال شده است (۱۳). سپس سایر اغتشاش های سیگنال شامل پلک زدن و انقباض ماهیچه ای از طریق اعمال تحلیل مولفه مستقل (ICA) حذف شده اند.

تبدیل زمان فرکانس سیگنال EEG

سیگنال EEG اخذ شده از ۵۸ شرکت کننده که از ۱۹ کانال مجزا باید به عنوان ورودی برای شبکه کانولوشنی آماده سازی شود. در این پژوهش از تبدیل فوریه زمان کوتاه (STFT) برای استخراج اطلاعات زمان-فرکانس موجود در سیگنال مغزی استفاده می شود. برای اینکار سیگنال EEG به بخش هایی به طول ۳ ثانیه و همپو شانی ۸۰ در صد تقسیم می شود. تبدیل STFT حاصل از هر بخش دارای ابعاد ۱۳۳*۶۴ و کل داده آماده شده به صورت ماتریس (28607,133,64) خواهد بود. برای محاسبه تبدیل STFT از کلاس signal در پکیج Scipy با پارامترهای پیش فرض استفاده شده است.

توسعه مدل هوش مصنوعی

در این پژوهش از مدل EEGNet برای دسته بندی افراد افسرده و سالم استفاده شده است (۱۴، ۱۵) و مدل جدیدی مبتنی بر EEGNet که دارای عمق بیشتری می باشد با عنوان DeepEEGNet توسعه داده شده است. همچنین از سه مدل یادگیری ماشین SVM، DT و KNN به عنوان مدل های پایه برای مقایسه با مدل های یادگیری عمیق استفاده شده است. برای آموزش این مدل ها از استخراج ویژگی چگالی طیف توان نسبی همه ی الکترودها در باندهای فرکانسی مختلف سیگنال EEG استفاده شده است.

آموزش و ارزیابی مدل

تمام افراد حاضر در پژوهش به دو بخش آموزش و تست تقسیم شدند. به این ترتیب ۸۰ درصد از کل افراد (معادل ۴۶ فرد) به عنوان داده آموزش و ۲۰ درصد به عنوان داده تست نهایی در نظر گرفته شدند. برای تعیین پارامترهای مدل از ارزیابی متقابل با (۱۰ بخش 10-fold Cross-Validation) استفاده شده است. در آخر دقت مدل روی داده تست نهایی گزارش می گردد. علاوه بر دقت مدل، حساسیت (Sensitivity)، خاصیت (Specificity) و ضریب F1 نیز گزارش می شوند. توسعه مدل های معرفی شده توسط پکیج Keras با زیربنای Tensorflow و زبان برنامه نویسی پایتون در محیط Google Colaboratory روی کارت گرافیک Tesla4 با ۱۲ گیگابایت رم انجام شده است.

استفاده می کنند (۵، ۶). در مقابل نوع خاصی از روش های یادگیری ماشین با عنوان روش های یادگیری عمیق می توانند به صورت خودکار بهترین ویژگی های تفکیک کننده را از داده ی خام استخراج نمایند. استفاده از این مدل ها سبب افزایش دقت و کارایی در دسته بندی و تعمیم پذیری بیشتر می گردد (۷).

Khan و همکاران، از الگوریتم های یادگیری ماشین مبتنی بر ماشین بردار پشتیبان (SVM)، نزدیکترین همسایگی (KNN) و درخت تصمیم (DT) برای دسته بندی ویژگی های استخراج شده از سیگنال EEG افراد برای تشخیص وجود افسردگی استفاده کردند و به دقت حدود ۹۶ درصد دست یافتند (۸).

Zhang و همکاران از یک مدل یادگیری عمیق مبتنی بر مکانیسم توجه برای تشخیص افسردگی از روی سیگنال خام استفاده کردند و به دقت ۹۲ درصد رسیدند (۹). Shhababi و همکاران از اعمال تبدیل فوریه زمان کوتاه بر روی بخش های متوالی سیگنال EEG استفاده کردند تا بتوانند ورودی های مناسب برای مدل یادگیری عمیق کانولوشنی تولید نمایند. با این روش توانستند افراد سالم و افسرده را با دقت بیش از ۹۹ درصد از یکدیگر تفکیک نمایند (۱۰، ۱۱).

در این پژوهش تلاش می شود با استفاده از یک مدل کانولوشنی نسبتاً ساده، دسته بندی افراد سالم و افسرده از روی سیگنال مغزی انجام گردد. برای این کار از تبدیل فوریه زمان کوتاه روی بخش های متوالی سیگنال استفاده می شود تا ورودی دو بعدی مدل کانولوشنی ساخته شود.

روش ها

دادگان و پیش پردازش

در این مطالعه از سیگنال مغزی ۵۸ شرکت کننده شامل ۳۶ مرد و ۲۲ زن در بازه سنی ۱۸ تا ۶۵ سال با میانگین 39.3 ± 14.3 استفاده شده است. وجود افسردگی از طریق تکمیل پرسشنامه بک (BDI-II) و مصاحبه رودرو با یک روانپزشک متخصص بر مبنای اصول راهنمای آماری و تشخیصی شماره ۴ (DSM-IV) تشخیص داده شده است (۱۲). افراد دارای بارداری، سابقه تشنج و سوء مصرف مواد از این مطالعه خارج شده اند. به این ترتیب ۳۰ نفر دارای اختلال افسردگی و ۲۸ نفر به عنوان فرد سالم تشخیص داده شدند. رضایت آگاهانه از شرکت کنندگان در مطالعه جهت ورود به مطالعه و استفاده از داده آنها برای توسعه مدل هوش مصنوعی گرفته شد.

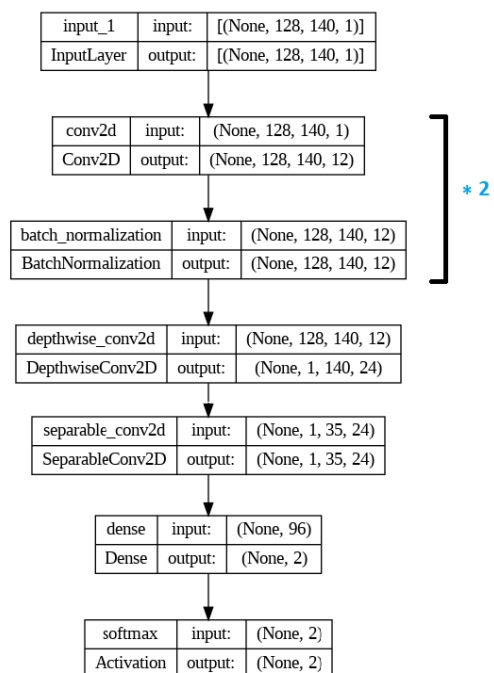
سیگنال مغزی الکتروانسفالوگرام ۱۹ کاناله کلاه ثبت EEG شرکت Brain Master Discovery و طبق استاندارد الکترونگذاری ۱۰-۲۰ اخذ شده است. سیگنال EEG به مدت ۵ دقیقه، در حالت

یافته ها


دو مدل یادگیری عمیق کانولوشنی با نام EEGNet و DeepEEGNet برای دسته بندی سیگنال EEG افراد سالم و افسرده آموزش داده شدند و توسط مؤلفه های ارزیابی عملکرد مدل با یکدیگر مقایسه شدند. ابرپارامترهای آموزش مدل شامل نرخ یادگیری، اندازه ی بسته آموزشی و تعداد گام آموزش در فرایند ارزیابی متقابل تنظیم شدند و پارامترهای بهینه برای آموزش مدل نهایی روی کل مجموعه آموزش و ارزیابی روی داده تست نهایی بدست آمدند. نمودار آموزش مدل DeepEEGNet در شکل ۲ نمایش داده شده است. نمودار آموزش مدل یادگیری عمیق شامل نمودار دقت و نمودار تابع هزینه برای دو مرحله ی آموزش و ارزیابی می باشد.

جدول ۱ نشان دهنده ی نتایج ارزیابی مدل های هوش مصنوعی مورد مطالعه برای دسته بندی سیگنال EEG افراد جامعه سنجنش است که قبلاً توسط مدل دیده نشده اند. به طور کلی مدل DeepEEGNet عملکرد بهتری را از نظر دقت ارائه نموده است. هرچند از دیدگاه مؤلفه ی ویژگی عملکرد مناسبی نداشته است.

برای درک بهتر عملکرد مدل های ارائه شده، ماتریس درهم ریختگی هر کدام از مدل ها در شکل ۳ نمایش داده شده اند.



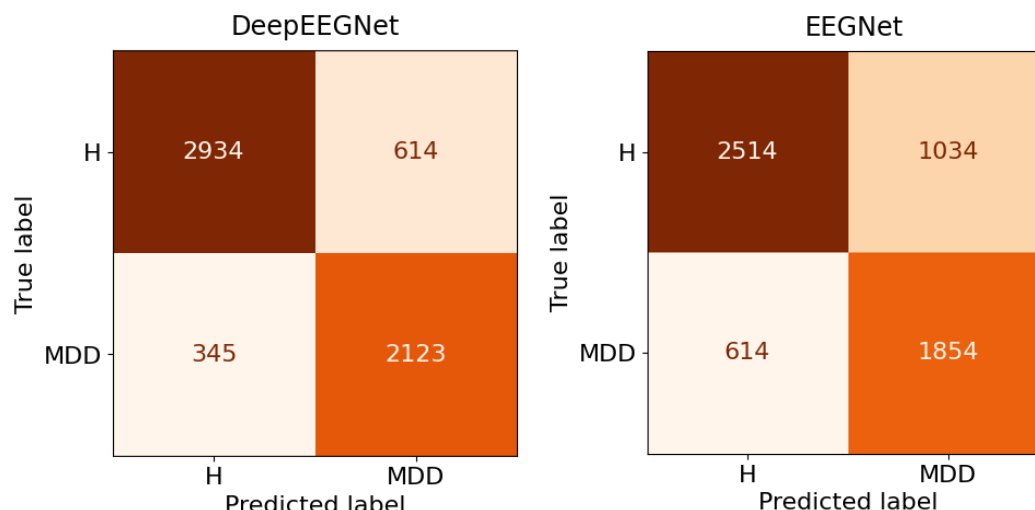
شکل ۱: بلوک دیاگرام مدل DeepEEGNet که در آن لایه ی کانولوشنی اولیه دو بار تکرار شده است. لایه های مربوط به نرمال سازی، فعال سازی، لایه ادغام برای ساده سازی نمایش داده نشدند.



شکل ۲: نمودار آموزش مدل DeepEEGNet. نمودارهای تغییرات تابع هزینه مرحله ی آموزش و ارزیابی (چپ) و نمودارهای دقت در مرحله ی آموزش و ارزیابی (راست).

جدول ۱: نتایج ارزیابی مدل های EEGNet و DeepEEGNet بر روی دادگان سنجنش نهایی.

دقت (درصد)	حساسیت (درصد)	ویژگی (درصد)	ضریب F1 (درصد)	
۷۳/۳	۶۲/۵	۸۵/۷	۷۱/۴	DT
۶۶/۷	۶۲/۵	۷۱/۴	۶۶/۷	SVM
۶۶/۷	۵۷/۱	۷۵/۰	۷۰/۶	KNN
۷۲/۶	۷۵/۱	۷۰/۹	۶۹/۲	EEGNet
۸۴/۱	۸۶/۰	۸۲/۷	۸۱/۶	DeepEEGNet



شکل ۳: ماتریس درهم‌ریختگی مدل‌های DeepEEGNet و EEGNet

یادگیری ماشین سنتی برای تشخیص افسردگی استفاده شده است که با وجود تفسیرپذیری بیشتر امکان استخراج بیشترین اطلاعات از سیگنال مغزی را ندارند و ممکن است ویژگی‌های ذاتی موجود در سیگنال مغزی را تخریب نمایند (۱۸). محدودیت اصلی مطالعه‌ی حاضر، استفاده از تعداد محدودی شرکت‌کننده بوده که بیانگر تمام تنوع موجود بین بیماران مبتلا به افسردگی و افراد سالم نیست. به این ترتیب افزایش تعداد نمونه‌ها می‌تواند خروجی‌های قابل اطمینان‌تری ایجاد نماید.

نتیجه‌گیری

با استفاده از مدل DeepEEGNet، دقت بیش از ۸۴ درصد در دسته‌بندی افراد سالم و افسرده امکان‌پذیر می‌گردد. افزایش تعداد عمق مدل کانولوشنی در کنار استفاده از وردی تبدیل STFT که ویژگی‌های فرکانسی سیگنال مغزی را برجسته‌تر می‌کند، توانایی دسته‌بندی سیگنال‌های پیچیده مغزی را افزایش می‌دهد.

تشکر و قدردانی

این مقاله منتج از طرح تحقیقاتی / پایان نامه مقطع دکتری تخصصی رشته مهندسی پزشکی می‌باشد که در دانشگاه علوم پزشکی شهیدبهشتی به تصویب رسیده و به انجام رسیده است.

برچسب صفر و یک به ترتیب معادل افراد سالم و بیمار می‌باشد و برچسب‌های پیش‌بینی شده و واقعی به ترتیب خروجی مدل هوش مصنوعی و برچسب داده اصلی می‌باشند.

بحث

در این پژوهش برای تشخیص افسردگی از دو مدل کانولوشنی DeepEEGNet و EEGNet برای دسته‌بندی سیگنال EEG خام اخذ شده از ۳۰ شرکت‌کننده مبتلا به افسردگی و ۲۸ فرد سالم استفاده شده است. مدل EEGNet که ترکیبی از سه لایه کانولوشنی متوالی است توانسته به دقت حدود ۷۳ درصد دست یابد در حالیکه مدل DeepEEGNet توانسته به دقت دسته‌بندی بیش از ۸۴ درصد برسد. یکی از دلایل دقت پایین‌تر مدل EEGNet ظرفیت کمتر این مدل به دلیل پارامترهای یادگیری کمتر می‌باشد. در مقابل مدل DeepConvNet به دلیل استفاده از دو لایه کانولوشنی ابتدایی به جای یک لایه کانولوشنی که در EEGNet وجود دارد، توانسته الگوهای پنهان موجود در داده ورودی را به صورت کارآمدتری استخراج نماید (۱۶).

نتایج حاصل از این پژوهش در حد نتایج منتشر شده در مطالعات روز دنیا برای تشخیص افسردگی از روی سیگنال EEG می‌باشد (۸، ۹، ۱۷). در مطالعه‌ی Khan و همکاران از روش‌های

References

1. World Health Organization. Institute of Health Metrics and Evaluation. Global Health Data Exchange (GHDx). World Health Organization; 2023.
2. Rostami R, Kazemi R, Nitsche MA, Gholipour F, Salehinejad M. Clinical and demographic predictors of response to rTMS treatment in unipolar and bipolar depressive disorders. Clin Neurophysiol 2017; 128(10): 1961-70.
3. Craik A, He Y, Contreras-Vidal JL. Deep learning for electroencephalogram (EEG) classification tasks: a

- review. *J Neural Eng* 2019; 16(3): 031001.
4. Byeon H. Advances in machine learning and explainable artificial intelligence for depression prediction. *International Journal of Advanced Computer Science and Applications*. 2023;14.(6):
 5. Singhi SK, Liu H. Feature subset selection bias for classification learning. *Proceedings of the 23rd International Conference On Machine Learning*. New York, NY; 2006.
 6. Shahabi MS, Nobakhsh B, Shalbf A, Rostami R, Kazemi R. Prediction of treatment outcome for repetitive transcranial magnetic stimulation in major depressive disorder using connectivity measures and ensemble of pre-trained deep learning models. *Biomedical Signal Processing and Control* 2023; 85: 104822.
 7. Ay B, Yildirim O, Talo M, Baloglu UB, Aydin G, Puthankattil SD, et al. Automated depression detection using deep representation and sequence learning with EEG signals. *J Med Syst* 2019; 43(7): 205.
 8. Khan S, Umar Saeed SM, Frnda J, Arsalan A, Amin R, Gantassi R, et al. A machine learning based depression screening framework using temporal domain features of the electroencephalography signals. *PLoS One* 2024; 19(3): e0299127.
 9. Zhang Z, Meng Q, Jin L, Wang H, Hou H. A novel EEG-based graph convolution network for depression detection: incorporating secondary subject partitioning and attention mechanism. *Expert Systems with Applications* 2024; 239: 122356.
 10. Shahabi MS, Shalbf A, Maghsoudi A. Prediction of drug response in major depressive disorder using ensemble of transfer learning with convolutional neural network based on EEG. *Biocybernetics and Biomedical Engineering* 2021; 41(3): 946-59.
 11. Shahabi MS, Shalbf A, Rostami R. Prediction of response to repetitive transcranial magnetic stimulation for major depressive disorder using hybrid Convolutional recurrent neural networks and raw Electroencephalogram Signal. *Cogn Neurodyn* 2023; 17(4): 909-20.
 12. Mumtaz W, Xia L, Yasin MAM, Ali SSA, Malik AS. A wavelet-based technique to predict treatment outcome for major depressive disorder. *PLoS One* 2017; 12(2): e0171409.
 13. Bagherzadeh S, Shahabi MS, Shalbf A. Detection of schizophrenia using hybrid of deep learning and brain effective connectivity image from electroencephalogram signal. *Comput Biol Med* 2022; 146: 105570.
 14. Wan Z, Huang J, Zhang H, Zhou H, Yang J, Zhong N. HybridEEGNet: A Convolutional Neural Network for EEG Feature Learning and Depression Discrimination. *IEEE Access*. 2020; 8: 30332-42.
 15. Lawhern VJ, Solon AJ, Waytowich NR, Gordon SM, Hung CP, Lance BJ. EEGNet: a compact convolutional neural network for EEG-based brain-computer interfaces. *J Neural Eng* 2018; 15(5): 056013.
 16. Ellis CA, Sancho ML, Miller RL, Calhoun VD. Identifying EEG Biomarkers of Depression with Novel Explainable Deep Learning Architectures. *bioRxiv* 2024.
 17. Das AK, Naskar R. A deep learning model for depression detection based on MFCC and CNN generated spectrogram features. *Biomedical Signal Processing and Control* 2024; 90: 105898.
 18. Khan A, Sohail A, Zahoora U, Qureshi AS. A survey of the recent architectures of deep convolutional neural networks. *Artif Intell Rev* 2020; 53: 5455-516.

Application of Deep Learning Models in the Detection Depression Using Time-Frequency Transformation of Electroencephalogram Signals

Mohsen Sadat Shahabi¹, Ahmad Shalbfar²

Original Article

Abstract

Background: Major Depressive Disorder (MDD) is a prevalent mental disorder worldwide, and timely diagnosis is necessary for efficient treatment. In the present study, an electroencephalogram (EEG) signal was utilized to automatically and precisely detect MDD using deep learning models.

Methods: Thirty MDD and twenty-eight healthy subjects participated, and their psychological evaluation was conducted by a specialist psychiatrist using the standard Beck questionnaire. 19-channel EEG signals were acquired from all participants in a resting state with eyes closed. Short-Time Fourier Transform (STFT) was applied to the sequential segments of the EEG signals and resulted two-dimensional matrix fed to the deep learning models. DeepEEGNet model was developed based on the EEGNet model utilized for the MDD classification and Healthy subjects. A holdout data was used to test the final model.

Findings: The DeepEEGNet model proposed in this study classified MDD and healthy participants with 84.1% accuracy, 86% sensitivity, and 82.7% specificity.

Conclusion: The deep learning model proposed in this study could accurately classify Healthy subjects and MDD patients using EEG signals and can be utilized as a helpful tool by psychiatrists.

Keywords: Major depressive disorder; Deep learning; Electroencephalography; Artificial intelligence

Citation: Shahabi MS, Shalbfar A. Application of Deep Learning Models in the Detection Depression Using Time-Frequency Transformation of Electroencephalogram Signals. J Isfahan Med Sch 2025; 42(796): 1123-28.

1- PhD, Department of Physics and Biomedical Engineering, School of Medicine, Shahid Beheshti University of Medical Sciences, Tehran, Iran

2- Associate Professor, Department of Physics and Biomedical Engineering, School of Medicine, Shahid Beheshti University of Medical Sciences, Tehran, Iran

Corresponding Author: Ahmad Shalbfar, Associate Professor, Department of Physics and Biomedical Engineering, School of Medicine, Shahid Beheshti University of Medical Sciences, Tehran, Iran; Email: Shalbfar@sbsmu.ac.ir