



Semnan University

# Journal of Modeling in Engineering

Journal homepage: <https://modelling.semnan.ac.ir/>

ISSN: 2783-2538



## Research Article

# Motor Imagery Signal Recognition Using Deep Learning

Louiza Dehyadegari<sup>a,\*</sup>, Razieh Rastgoo<sup>b</sup>

<sup>a</sup> Department of Electronic Engineering, Sirjan University of Technology, Sirjan, Iran

<sup>b</sup> Electrical and Computer Engineering Faculty, Semnan University, Semnan, Iran

## PAPER INFO

### Paper history:

Received: 2025-06-15

Revised: 2025-08-22

Accepted: 2025-09-08

### Keywords:

Electroencephalography signals;

Motor imagery;

Informer;

EEGNet;

Convolution.

## ABSTRACT

The identification of electroencephalography (EEG) signals related to motor imagery plays a key role in the analysis and evaluation of neural functions in brain-computer interface (BCI) systems. However, considerable individual differences in EEG patterns pose a significant challenge for designing accurate and generalizable models. Moreover, the ability to successfully recognize motor imagery from shorter signal durations has a direct impact on improving the efficiency and practical usability of these technologies. In this study, an innovative hybrid framework is proposed for classifying motor imagery EEG signals, introducing a two-stage architecture based on the combination of an enhanced Informer and the EEGNet model. In this architecture, the EEG signals, after initial frequency feature extraction, are first fed into the enhanced Informer module. This module, leveraging sparse attention mechanisms and adaptive frequency filters (FAA), effectively captures long-term temporal dependencies within the EEG data. The output of the Informer is then passed to the EEGNet model, which, through its specialized convolutional layers (spatial convolution, depthwise convolution, and separable temporal convolution), purposefully extracts spatial-temporal features from the EEG signals and generates a compact and discriminative representation for final classification. Experimental results demonstrate that the proposed model achieves 85.20% accuracy in cross-subject evaluation on the standard PhysioNet dataset with short 2-second trial durations. Comparative analyses with state-of-the-art models indicate that the proposed approach offers competitive and improved performance, particularly in handling shorter signal durations and participant diversity.

DOI: <https://doi.org/10.22075/jme.2025.38105.2864>

© 2026 Published by Semnan University Press.

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

\* Corresponding author.

E-mail address: [l.dehyadegari@sirjantech.ac.ir](mailto:l.dehyadegari@sirjantech.ac.ir)

## How to cite this article:

L. Dehyadegari and R. Rastgoo, "Motor Imagery Signal Recognition Using Deep Learning," Journal of Modeling in Engineering, 24 84 (2026): 139-151, doi: 10.22075/jme.2025.38105.2864

## شناسایی سیگنال‌های تصور حرکتی با استفاده از یادگیری عمیق

لوئیزا دهیادگاری<sup>۱\*</sup>، راضیه راستگو<sup>۲</sup>

اطلاعات مقاله	چکیده
دریافت مقاله: ۱۴۰۴/۰۳/۲۵	شناسایی سیگنال‌های الکتروانسفالوگرافی (EEG) مرتبط با فرآیند تصور حرکت نقش کلیدی در تحلیل و ارزیابی عملکردهای عصبی در سیستم‌های رابط مغز و رایانه (BCI) ایفا می‌کند. با این حال، تفاوت‌های فردی قابل توجه در الگوهای EEG چالشی جدی برای طراحی مدل‌های دقیق و عمومی‌پذیر ایجاد کرده است. از سوی دیگر، تشخیص موفق تصور حرکت از بازه‌های زمانی کوتاه‌تر سیگنال، تأثیر مستقیمی بر افزایش کارایی و قابلیت استفاده عملی این فناوری‌ها دارد. در این مقاله، یک چارچوب ترکیبی جدید ارائه شده است که به منظور طبقه‌بندی سیگنال‌های EEG ناشی از تصور حرکت، یک معماری دو مرحله‌ای مبتنی بر ترکیب اینفورمر بهبودیافته و شبکه EEGNet پیشنهاد می‌کند. در این ساختار ابتدا سیگنال‌های EEG پس از استخراج ویژگی‌های فرکانسی اولیه، به مدل اینفورمر بهبودیافته وارد می‌شوند. این ماژول با بهره‌گیری از مکانیزم توجه پراکنده و فیلترهای فرکانسی تطبیقی قادر است وابستگی‌های زمانی بلندمدت در داده‌های EEG را به طور مؤثر استخراج کند. خروجی اینفورمر سپس به مدل EEGNet منتقل می‌شود. با طراحی کانولوشن‌های خاص (کانولوشن فضایی، کانولوشن عمقی و کانولوشن تفکیک‌پذیر زمانی) به طور هدفمند ویژگی‌های فضایی-زمانی سیگنال‌های EEG استخراج می‌گردد و نمایه‌ای فشرده و قدرتمند برای طبقه‌بندی نهایی تولید می‌شود. نتایج تجربی حاصل از ارزیابی‌ها نشان می‌دهد که مدل پیشنهادی در سناریوی میان‌گروهی و با استفاده از دیتاست استاندارد PhysioNet موفق به دستیابی به دقت ۸۵.۲۰ درصد برای بازه‌های زمانی کوتاه ۲ ثانیه‌ای شده است. مقایسه عملکرد با مدل‌های موجود نشان می‌دهد که رویکرد پیشنهادی در مواجهه با داده‌های کوتاه‌تر و تنوع شرکت‌کنندگان عملکرد رقابتی و بهبودیافته‌ای دارد.
بازنگری مقاله: ۱۴۰۴/۰۵/۳۱	
پذیرش مقاله: ۱۴۰۴/۰۶/۱۷	
<b>واژگان کلیدی:</b> سیگنال‌های الکتروانسفالوگرافی، تصور حرکتی، اینفورمر، EEGNet، شبکه گراف کانولوشن.	

DOI: <https://doi.org/10.22075/jme.2025.38105.2864>

© 2026 Published by Semnan University Press.

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

می‌کنند. این فناوری با تحلیل سیگنال‌های مغزی و ترجمه‌ی آن‌ها به دستورات کنترلی، به افراد دارای معلولیت‌های حرکتی شدید اجازه می‌دهد تا با دنیای پیرامون خود تعامل داشته باشند و کنترل دستگاه‌های کمکی را در دست بگیرند [۲]. یکی از روش‌های پرکاربرد در رابط‌های مغز و رایانه، استفاده از سیگنال‌های

## ۱- مقدمه

در دهه‌های اخیر، پیشرفت در حوزه‌ی علوم اعصاب و مهندسی پزشکی منجر به ظهور فناوری نوینی به نام رابط مغز و رایانه (BCI) شده است [۱]. رابط‌های مغز و رایانه سیستم‌هایی هستند که امکان ارتباط مستقیم بین مغز و یک دستگاه خارجی، مانند رایانه یا اندام مصنوعی را فراهم

\* پست الکترونیک نویسنده مسئول: l.dehyadegari@sirjantech.ac.ir

۱. دانشکده مهندسی برق، دانشگاه صنعتی سیرجان، سیرجان، ایران

۲. دانشکده مهندسی برق و کامپیوتر، دانشگاه سمنان، سمنان، ایران

استناد به این مقاله:

استفاده شده است. شبکه‌های عصبی گرافی چارچوب قدرتمندی برای مدل‌سازی داده‌های سیگنال‌های الکتروانسفالوگرافی ناشی از تصور حرکتی فراهم می‌کنند، زیرا ارتباط بین کانال‌های الکتروانسفالوگرافی را به صورت یک گراف مدلسازی می‌کنند [۱۱]. به این ترتیب با نمایش الکترودهای الکتروانسفالوگرافی به عنوان گره‌های گراف و استفاده از روابط مکانی و عملکردی آن‌ها، مدل‌های مبتنی بر شبکه‌های عصبی گراف می‌توانند الگوهای پیچیده را به خوبی استخراج کرده و عملکرد طبقه‌بندی تخیل حرکتی را بهبود بخشند. در این روش ترکیبی توانایی استخراج ویژگی‌های زمانی اینفورمر با قدرت مدل‌سازی وابستگی‌های فضایی شبکه‌های گراف ترکیب می‌شود و استفاده ترکیبی ویژگی‌های زمانی و فضایی، طبقه بندی سیگنال الکتروانسفالوگرافی را بهبود می‌بخشد.

در ادامه این مقاله در بخش دوم تحقیقات انجام شده در این زمینه مرور خواهند شد، بخش سوم مدل پیشنهادی را ارائه می‌نماید. نتایج به دست آمده در بخش چهارم و در نهایت، نتیجه‌گیری در بخش پنجم ارائه می‌شوند.

## ۲- مروری بر سوابق

پیشرفت‌های اخیر در هوش مصنوعی، رویکردهای جدید و قدرتمندی را برای طبقه‌بندی سیگنال‌های الکتروانسفالوگرافی ناشی از تصور حرکتی ارائه داده است [۱۳، ۱۲]. با آنکه تحقیقات اخیر در زمینه طبقه‌بندی سیگنال‌های الکتروانسفالوگرافی ناشی از تصور حرکتی پیشرفت قابل توجهی داشته‌اند، اما همچنان توسعه یک مدل کامل که تمام جنبه‌های مرتبط را در بر بگیرد، یک چالش حیاتی است [۹]. تحلیل سیگنال الکتروانسفالوگرافی باید بر تغییرات و روندها در بعد زمان تمرکز کند. مرجع [۱۴] از یک شبکه عصبی بازگشتی عمیق برای مدیریت روابط فرکانسی فضایی-زمانی سیگنال‌های الکتروانسفالوگرافی ناشی از تصور حرکتی استفاده کرده است. با این حال، شبکه بازگشتی استفاده شده در [۱۴] در استخراج وابستگی‌های طولانی‌مدت عملکرد ضعیفی دارد. برای رفع این محدودیت، محققان انواع بهبودیافته شبکه‌های بازگشتی مانند شبکه حافظه بلند مدت کوتاه [۱۵] و واحد بازگشتی گیت‌دار [۱۶] را بررسی کردند. این شبکه‌ها با معرفی مکانیزم‌های گیت‌دار، قابلیت گرفتن وابستگی‌های طولانی‌مدت را افزایش می‌دهند. با وجود

الکتروانسفالوگرافی ناشی از تصور حرکتی است [۳]. سیگنال‌های الکتروانسفالوگرافی ناشی از تصور حرکتی شامل ثبت فعالیت الکتریکی مغز در حین تصور انجام یک حرکت خاص بدون اجرای واقعی آن است [۴]. طبقه‌بندی دقیق سیگنال‌های الکتروانسفالوگرافی ناشی از تصور حرکتی چالش‌برانگیز است، زیرا سیگنال‌های الکتروانسفالوگرافی غیرایستا، نویزی و وابسته به خصوصیات افراد هستند [۵]. پردازش، تجزیه و تحلیل و تفسیر سیگنال‌های مغزی توسط الگوریتم‌های معمولی از نظر محاسباتی بسیار پرهزینه است. این امر عمدتاً به دلیل ماهیت غیرخطی و غیرایستای این سیگنال‌ها است. علاوه بر این، محدوده فرکانس و دامنه سیگنال‌های مغزی بسیار پایین است و سیگنال اغلب با انواع مختلف نویزها آلوده می‌شود [۶]. جدیدترین تحقیقات نشان داده است که الگوریتم‌های مبتنی بر هوش مصنوعی و یادگیری ماشین برای پردازش و تجزیه و تحلیل این سیگنال‌های پیچیده به دلیل توانایی آنها در پیش‌بینی، استدلال و یادگیری از تجربیات قبلی، بسیار امیدوارکننده می‌باشند [۷]. ترکیب دانش علوم اعصاب با مدل‌های یادگیری عمیق، مانند پیش‌آموزش بر اساس آناتومی مغز یا تحلیل شبکه‌های مغزی، می‌تواند به بهبود قابلیت تفسیر مدل‌ها کمک کند. ترکیبی از مدل‌های کارآمدتر، تفسیرپذیری بهتر و تکنیک‌های بهبود پردازش سیگنال می‌تواند به پیشرفت چشمگیر در حوزه رابط‌های مغز و کامپیوتر منجر شود. یکی از جدیدترین روش‌ها در زمینه پردازش سیگنال‌های الکتروانسفالوگرافی، شبکه ترانسفورمر می‌باشد. این روش محدودیت‌های روش‌های مبتنی بر شبکه‌های عصبی را پشت سر گذاشته و مکانیزم آموزش را شتاب داده است [۸-۹]. شبکه‌های ترانسفورمر در استخراج ویژگی‌های زمانی سیگنال‌های الکتروانسفالوگرافی عملکرد خوبی داشته‌اند، اما برای توالی‌های بسیار طولانی (مثلاً داده‌های چندساعته) بهینه نیستند. استفاده از شبکه‌های اینفورمر بجای شبکه‌های ترانسفورمر به کاهش پیچیدگی‌های محاسباتی کمک می‌کند و می‌تواند الگوهای بلندمدت مانند طبقه‌بندی حرکات ارادی یا تشخیص بیماری‌های عصبی در سیگنال‌های الکتروانسفالوگرافی را بهتر شناسایی کند [۱۰]. در این تحقیق از مزایای شبکه‌های عصبی گراف و ترکیب آن با شبکه‌های اینفورمر برای طبقه‌بندی سیگنال‌های الکتروانسفالوگرافی ناشی از تصور حرکتی

فراهم می‌کند. وجود ویژگی‌های مختلف زمانی، فضایی، فرکانسی و ویژگی‌های مختلف مبتنی بر تبدیل، پیچیدگی محاسبات را زیاد می‌کند. به همین دلیل با استفاده از یک طبقه‌بندی‌کننده بیزین گروهی دقت طبقه‌بندی تا حد مطلوبی بالا می‌رود [۲۳]. در مرجع [۲۴] برای طبقه‌بندی از یک شبکه چند طبقه استفاده شده است. این شبکه سیگنال‌های الکتروانسفالوگرافی را به صورت خام به عنوان ورودی می‌گیرد و نیاز به مراحل پیچیده پیش‌پردازش ندارد. سیگنال الکتروانسفالوگرافی در طبقه اول فیلتر، استخراج و نمونه‌برداری می‌شود، طبقه دوم همبستگی سیگنال را افزایش می‌دهد و طبقه سوم ارتباط معنادار و پیوستگی بین سیگنال‌ها را بهینه می‌کند.

تجزیه تنسور یک روش موثر برای استخراج ویژگی‌های چند دامنه‌ای از سیگنال‌ها است و به طور گسترده در زمینه سیگنال‌های الکتروانسفالوگرافی استفاده شده است. در مقایسه با روش‌های سنتی تجزیه تنسور، الگوریتم قطار تنسور با نظم پراکنده (SRTT) مزایایی مانند پیچیدگی زمان الگوریتمی کمتر و قابلیت‌های استخراج ویژگی برتر را ارائه می‌دهد [۲۵]. الگوریتم پیشنهادی فاکتورسازی ماتریس غیرمنفی گرادیان پیش‌بینی‌شده با قطار تنسور (TT-PGDNMF) ویژگی‌های چند دامنه‌ای را از سیگنال‌های الکتروانسفالوگرافی ناشی از تصور حرکتی استخراج می‌کند، و به طور موثر سیگنال‌های الکتروانسفالوگرافی ناشی از تصور حرکتی غیرخطی ابعاد بالا را کنترل می‌کند. به طور کلی این روش، از همه الگوریتم‌های پیشرفته شناخته شده در حال حاضر بهتر عمل می‌کند. علاوه بر این، این روش به طور موثر ویژگی‌های فضایی سیگنال‌های الکتروانسفالوگرافی ناشی از تصور حرکتی را استخراج می‌کند و تجزیه و تحلیل را از طریق تجسم توپوگرافی مغز امکان‌پذیر می‌کند.

مرجع [۲۶] دو معماری شبکه عصبی جدید به نام شبکه‌های CSP-توانمند (CSP-Nets) معرفی می‌کند، که دانش حاصل از الگوریتم سنتی الگوی فضایی مشترک را با قابلیت‌های یادگیری عمیق شبکه‌های عصبی کانولوشنی ترکیب می‌کنند. در این روش یک لایه الگوی فضایی مشترک قبل از یک شبکه عصبی کانولوشنی بهبود قابلیت تفکیک ورودی اضافه می‌شود و یک لایه کانولوشنی با یک لایه الگوی فضایی مشترک جایگزین می‌گردد. این روش‌ها به ویژه هنگامی که تعداد نمونه‌های آموزشی بسیار

برخی پیشرفت‌ها در تحلیل سیگنال الکتروانسفالوگرافی، روش‌های موجود معمولاً به استخراج و تحلیل ویژگی‌های یک‌بعدی متکی هستند، که بیان ویژگی‌ها را محدود می‌کند. چنین روش‌هایی ممکن است ویژگی‌های تناوبی پیچیده در سیگنال‌های الکتروانسفالوگرافی را نادیده بگیرند. استفاده از ویژگی‌های دو بعدی می‌تواند الگوهای ذاتی داده‌های سری زمانی را بهتر ثبت کند [۱۷].

شبکه‌های عصبی عمیق [۱۸] در زمینه طبقه‌بندی سیگنال‌های الکتروانسفالوگرافی ناشی از تصور حرکتی نتایج مطلوبی داشته است. در مرجع [۱۹] از یک طبقه‌بندی‌کننده یادگیری عمیق جدید به نام شبکه کپسولی کانولوشن دوگانه استفاده می‌کند که هدف آن دسته‌بندی دقیق برچسب‌های مختلف تخیل افراد است. ویژگی اصلی این روش معرفی یک لایه کانولوشن دوگانه برای مدیریت ویژگی‌های اتصال و طیف نگاری مغز می‌باشد. مرجع [۲۰] از یک شبکه عصبی کانولوشنی استفاده می‌کند که لایه‌های عمیق شبکه کانولوشن را با داده‌های الکتروانسفالوگرافی سه‌بعدی ترکیب می‌کند، تا یک طبقه بندی با پنج کلاس مختلف روی داده‌های سیگنال‌های الکتروانسفالوگرافی ناشی از تصور حرکتی انجام دهد. در مرجع [۲۱] از یک ترنسفورم آینه‌ای کم عمق برای طبقه بندی استفاده شده است. اما استفاده از روش‌های ترکیبی برای طبقه‌بندی این سیگنال‌ها نتایج بهتری داشته است. در مرجع [۹] شبکه‌های کانولوشن گراف و ترانسفورم برای رسیدن به دقت بالاتر طبقه‌بندی ترکیب شده‌اند. از مدل ترنسفورم برای پیش آموزش با توجه به مشخصات زمانی سیگنال و شبکه گراف برای بررسی مشخصات فضایی سیگنال استفاده شده است. نتایج این مقاله نشان می‌دهد که ترکیب مشخصات فرکانسی، فاز، مکانی و زمانی دقت طبقه بندی سیگنال‌های الکتروانسفالوگرافی ناشی از تصور حرکتی را تا حد قابل توجهی بهبود می‌دهد. مرجع [۱۷] یک شبکه کانولوشن چند بعدی با الگوهای با مقیاس‌های متفاوت را برای طبقه‌بندی سیگنال‌های الکتروانسفالوگرافی ناشی از تصور حرکتی پیشنهاد می‌کند. در این روش سیگنال یک بعدی الکتروانسفالوگرام به سیگنال چند بعدی با دوره‌های تناوب مختلف تبدیل می‌شود و از ویژگی‌های متناوب سیگنال برای طبقه‌بندی استفاده می‌کند. مرجع [۲۲] با استفاده از تجزیه و تحلیل مؤلفه‌های مشابه، امکان شناسایی کامل ناحیه عصبی محرک حرکات مختلف را

شکل (۱) نمای کلی روش پیشنهادی را نشان می‌دهد. این معماری شامل یک مدل اینفورمر بهبودیافته به‌عنوان استخراج‌کننده اولیه ویژگی‌های زمانی و یک مدل EEGNet مبتنی بر شبکه‌های عصبی کانولوشنی [۳۰] برای استخراج ویژگی‌های ترکیبی زمانی-فضایی و انجام طبقه‌بندی نهایی است. ابتدا، یک مدل اینفورمر بهبودیافته سبک و کارآمد برای پردازش داده‌های خام الکتروانسفالوگرافی آموزش داده می‌شود. این مدل به‌منظور غنی‌سازی داده‌ها و استخراج ویژگی‌های زمانی با دقت بالا استفاده می‌شود. سپس خروجی اینفورمر بهبودیافته به‌عنوان داده‌های ورودی به مدل EEGNet منتقل شده و فرآیند استخراج ویژگی‌های فضایی-زمانی و طبقه‌بندی تکمیل می‌شود. ایده اصلی مدل پیشنهادی، ترکیب ظرفیت مدل‌سازی وابستگی‌های بلندمدت زمانی اینفورمر با قدرت استخراج ویژگی‌های محلی فضایی شبکه عصبی کانولوشنی می‌باشد. نوآوری کلیدی این کار، ترکیب مکانیزم توجه پراکنده با ماژول توجه آگاه به فرکانس است که به مدل امکان می‌دهد سیگنال‌های الکتروانسفالوگرافی را نه تنها از منظر زمانی، بلکه از منظر فرکانسی نیز تحلیل کند. این ترکیب منجر به استخراج ویژگی‌های عمیق‌تر و غنی‌تر از سیگنال‌های الکتروانسفالوگرافی خواهد شد.

مدل اینفورمر یک معماری بهبودیافته بر پایه ترنسفورمر [۳۱] است که برای پردازش داده‌های سری زمانی بلندمدت طراحی شده است [۳۱]. این مدل با بهره‌گیری از مکانیزم توجه پراکنده و کاهش پیچیدگی زمانی، قادر است وابستگی‌های طولانی‌مدت موجود در داده‌های الکتروانسفالوگرافی را به شکل کارآمد مدل‌سازی کند. برخلاف ترنسفورمرهای کلاسیک که از توجه کامل استفاده می‌کنند و برای داده‌های طولانی ناکارآمد هستند [۳۲]، اینفورمر با استفاده از نمونه‌گیری هوشمندانه، تنها مهم‌ترین وابستگی‌ها را مدل‌سازی کرده و کارایی محاسباتی را به شکل قابل توجهی افزایش می‌دهد. معماری به کار رفته در این مطالعه تنها شامل بخش کدگذار مدل اینفورمر است که برای استخراج ویژگی‌های زمانی از داده‌های الکتروانسفالوگرافی مورد استفاده قرار می‌گیرد و بخش رمزگشا به دلیل ماهیت مسئله حذف شده است.

مدل اینفورمر شامل چندین بلوک کدگذار است که هر یک از آنها ترکیبی از لایه‌های توجه پراکنده، شبکه عصبی رو به جلو، نرمال‌سازی و حذف تصادفی است. همچنین برای

کم باشد، مفید می‌باشد. استفاده از شبکه‌های عصبی تقویت شده با حافظه مانند ماشین تورینگ عصبی و کامپیوتر عصبی تفضلی برای طبقه‌بندی فعالیت مغزی در داده‌های الکتروانسفالوگرافی، عملکرد شبکه را در طبقه‌بندی فعالیت‌های مغزی و تصویرسازی حرکتی به طور قابل توجهی بهبود می‌بخشد [۲۷]. در مرجع [۲۸] از الگوریتم ماشین گرادین تقویتی سبک که با الگوریتم بهینه‌سازی جهان چندگانه ترکیب شده است، برای طبقه‌بندی استفاده شده است. داده‌های این مرجع، امواج دلتا که از سیگنال الکتروانسفالوگرافی استخراج شده‌اند، می‌باشند و تحلیل داده‌ها به صورت زمانی و فضایی انجام شده است. در مرجع [۲۹]، شبکه IFBCLNet که یک بانک فیلتر قابل تفسیر را با شبکه عصبی کانولوشنی و ماژول حافظه بلندمدت کوتاه ادغام می‌کند، استفاده می‌شود. این روش قابلیت‌های منحصر به فرد استخراج ویژگی فضایی-زمانی-فرکانسی و امکان تفسیر دقیق‌تر نیت انسانی را دارد. در این تحقیق از شبکه‌های کانولوشن گراف و اینفورمر به عنوان دو ابزار پیشرفته و مکمل در حوزه یادگیری عمیق، به‌ویژه در طبقه‌بندی سیگنال‌های پیچیده، استفاده شده است. در این پژوهش، از مدل اینفورمر به‌عنوان ابزاری برای پیش‌آموزش استفاده شده است تا به تحلیل دقیق ویژگی‌های زمانی سیگنال پرداخته و در کنار آن، از شبکه گراف برای ارزیابی عمیق مشخصات فضایی سیگنال بهره گرفته شده است. این ترکیب مدل‌ها امکان استخراج ویژگی‌های پیچیده و متمایز را از داده‌های دینامیک فراهم می‌آورد و به تقویت عملکرد طبقه‌بندی کمک می‌کند. نتایج به‌دست آمده در این مطالعه نشان‌دهنده این است که ادغام مشخصات فرکانسی، فاز، مکانی و زمانی سیگنال‌های مغزی، به‌طوری چشم‌گیر دقت طبقه‌بندی را بهبود بخشیده و منجر به کاهش خطاها در تشخیص نواحی مختلف سیگنال می‌شود. به‌ویژه در زمینه کاربردهای بالینی، این رویکرد می‌تواند به شناسایی زودهنگام اختلالات عصبی و بهبود فرآیندهای تصمیم‌گیری بالینی کمک شایانی نماید. بدین ترتیب، این مقاله نه تنها به تشریح جزئیات فنی و الگوریتم‌های بکارگرفته شده در این رویکرد می‌پردازد، بلکه نتایج تجربی حاصل از آزمایش‌های مختلف را بررسی کرده و چالش‌های موجود در زمینه به‌کارگیری این مدل‌ها را تحلیل می‌کند.


### ۳- مدل پیشنهادی

پراکنده در یک ماژول ادغامی وزن‌دار ترکیب می‌شوند.

- این ترکیب به مدل کمک می‌کند تا به الگوهای فرکانسی غالب الکتروانسفالوگرافی که مرتبط با فعالیت‌های ذهنی مختلف هستند حساس‌تر شود. مدل پیشنهادی علاوه بر وابستگی‌های زمانی، به ویژگی‌های فرکانسی بحرانی الکتروانسفالوگرافی نیز توجه می‌کند. علاوه بر این، منجر به

کدگذاری موقعیت، از کدگذاری موقعیتی نسبی استفاده می‌شود. در این مقاله، یک اینفورمر دو لایه به‌عنوان استخراج‌کننده ویژگی‌های زمانی استفاده می‌شود. برای افزایش دقت استخراج ویژگی‌های الکتروانسفالوگرافی، یک ماژول توجه آگاه به فرکانس در مسیر توجه پراکنده افزوده شده است که به شکل زیر عمل می‌کند:

- ابتدا تبدیل فوریه سریع بر روی سیگنال‌های ورودی اعمال می‌شود تا نمای فرکانسی سیگنال به دست آید.
- ویژگی‌های فرکانسی به همراه خروجی مکانیزم توجه



شکل ۱- نمای کلی مدل پیشنهادی (شامل یک مدل اینفورمر بهبودیافته به‌عنوان استخراج‌کننده اولیه ویژگی‌های زمانی و یک مدل EEGNet مبتنی بر شبکه‌های عصبی کانولوشنی برای استخراج ویژگی‌های ترکیبی زمانی-فضایی و انجام طبقه‌بندی نهایی)

سیگنال در حوزه فرکانس پس از اعمال  $FFT$  است. برای کاهش ابعاد و تمرکز بر فرکانس‌های معنادار الکتروانسفالوگرافی، (مثلاً باندهای آلفا، بتا، گاما)، یک فیلتر فرکانسی  $G$  اعمال می‌شود:

$$F_{filtered} = G(F) \in \mathbb{R}^{B \times C} \quad (3)$$

که  $F$  ماتریس سیگنال‌های حوزه فرکانس برای تمام کانال‌ها است.  $G(\cdot)$  عملیات انتخاب یا فیلتر کردن باندها را انجام می‌دهد.  $B$  تعداد باندهای فرکانسی انتخابی است. به منظور استخراج ویژگی‌های زمانی با اینفورمر، برای همان ورودی  $X$ ، مکانیزم توجه پراکنده اینفورمر خروجی زیر را تولید می‌کند:

$$Z_{time} = Attention(Q, K, V) \in \mathbb{R}^{T \times d} \quad (4)$$

$$Q = XW_Q, \quad W_Q \in \mathbb{R}^{C \times d} \quad (5)$$

$$K = XW_K, \quad W_K \in \mathbb{R}^{C \times d} \quad (6)$$

افزایش دقت مدل به‌ویژه برای سیگنال‌های دارای نویز یا تغییرات فرکانسی جزئی می‌گردد. هدف از توجه آگاه به فرکانس این است که اطلاعات فرکانسی استخراج‌شده از سیگنال الکتروانسفالوگرافی را به طور تطبیقی با خروجی مکانیزم توجه پراکنده اینفورمر ترکیب کنیم تا مدل علاوه بر وابستگی‌های زمانی، به الگوهای فرکانسی الکتروانسفالوگرافی نیز حساس باشد. برای این منظور، ابتدا برای هر نمونه سیگنال الکتروانسفالوگرافی ورودی:

$$X \in \mathbb{R}^{T \times C} \quad (1)$$

که  $T$  طول توالی (تعداد نمونه‌ها) و  $C$  تعداد کانال‌ها است. روی هر کانال به طور جداگانه تبدیل فوریه سریع انجام می‌شود:

$$F_c = FFT(X_c), \quad \forall c = 1, \dots, C \quad (2)$$

که  $X_c$  سیگنال مربوط به کانال  $c$ -ام است.  $F_c$  نمایش آن

پراکنده است دچار مشکل می‌شوند، و در نتیجه بیش‌تر بر نوسانات محلی تمرکز کرده و از یادگیری دینامیک‌های زمانی کلی باز می‌مانند. در مقابل، مدل اینفورمر با معرفی مکانیزم توجه پراکنده احتمالی میزان افزونگی را به‌طور چشمگیری کاهش می‌دهد و اجازه می‌دهد تا وابستگی‌های بلندمدت با کارایی و هزینه محاسباتی کمتر مدل‌سازی شوند. افزون بر این، عملیات تقطیر در مکانیزم توجه، نمایش‌های زمانی را فشرده کرده در حالی که ویژگی‌های برجسته را حفظ می‌کند؛ موضوعی که در تشخیص سیگنال‌های تصویرسازی حرکتی مبتنی بر سیگنال‌های الکتروانسفالوگرافی بسیار اهمیت دارد، زیرا اطلاعات تمایزدهنده اغلب در تغییرات ظریف زمانی نهفته‌اند. بنابراین، در مقایسه با ترنسفورمرهای معمولی، اینفورمر یک راهکار مقیاس‌پذیرتر و مقاوم‌تر برای مدل‌سازی توالی‌های طولانی سیگنال‌های الکتروانسفالوگرافی فراهم می‌کند و موجب بهبود همزمان بازده محاسباتی و دقت تشخیص در وظایف تصویرسازی حرکتی می‌شود.

پس از استخراج ویژگی‌های زمانی با استفاده از اینفورمر بهبودیافته، این خروجی به مدل EEGNet تغذیه می‌شود تا استخراج عمیق‌تر ویژگی‌های فضایی-زمانی انجام گیرد. ساختار EEGNet به صورت زیر سازماندهی شده است:

۱. کانولوشن دوبعدی برای استخراج ویژگی‌های فضایی: این لایه کانولوشن بر کل کانال‌ها اعمال می‌شود تا همبستگی‌های فضایی بین کانال‌های سیگنال‌های الکتروانسفالوگرافی را مدل‌سازی کند. هدف آن کشف تعاملات مکانی بین سیگنال‌های مختلف مغزی است.

۲. کانولوشن عمقی برای استخراج ویژگی‌های اختصاصی هر کانال: این لایه بر روی هر کانال به‌طور مجزا اعمال می‌شود. عملاً هر فیلتر تنها روی یک کانال اعمال شده و ویژگی‌های اختصاصی کانال‌ها را استخراج می‌کند. که منجر به کاهش تعداد پارامترها و افزایش کارایی مدل می‌شود.

۳. کانولوشن تفکیک‌پذیر زمانی برای استخراج دقیق‌تر الگوهای زمانی: این کانولوشن در امتداد محور زمانی اعمال می‌شود. هدف آن استخراج ویژگی‌های ظریف زمانی از خروجی هر کانال به‌طور جداگانه می‌باشد که منجر به افزایش دقت استخراج الگوهای زمانی پیچیده از سیگنال‌های الکتروانسفالوگرافی تقویت‌شده توسط اینفورمر می‌گردد. در هر مرحله کانولوشن، نرمال‌سازی

$$V = XW_V, \quad W_V \in \mathbb{R}^{C \times d} \quad (7)$$

که  $W_Q, W_K, W_V$  ماتریس‌های وزن مربوط به درخواست (Query)، کلید (Key) و مقدار (Value) هستند. برای ترکیب تطبیقی ویژگی‌های زمانی و فرکانسی، ابتدا ویژگی‌های فرکانسی را از طریق لایه تمام متصل به اندازه  $d \times T$  نگاشت می‌کنیم:

$$F_{mapped} = \phi(F_{filtered}) \in \mathbb{R}^{T \times d} \quad (8)$$

که  $\phi(\cdot)$  یک نگاشت غیرخطی می‌باشد. سپس ترکیب نهایی به صورت زیر انجام می‌شود:

$$Z = \alpha \cdot Z_{time} + (1 - \alpha) \cdot F_{mapped} \quad (9)$$

که  $\alpha \in [0, 1]$  یک پارامتر یادگیری‌پذیر می‌باشد که مدل در طول آموزش مقدار بهینه آن را یاد می‌گیرد. ضرب عنصر به عنصر را نشان می‌دهد. برای پایداری آموزش، خروجی ترکیب شده نرمال‌سازی می‌شود:

$$Z_{out} = LayerNorm(Z) \quad (10)$$

داده‌های سیگنال الکتروانسفالوگرافی مربوط به تمامی شرکت‌کنندگان ابتدا ترکیب و به‌صورت تصادفی جابه‌جا شده و سپس به مجموعه‌های آموزشی، اعتبارسنجی و آزمون تقسیم می‌شوند. مدل اینفورمر بر روی داده‌های آموزشی آموزش داده شده و با استفاده از مجموعه اعتبارسنجی نظارت می‌شود تا از بیش‌برازش جلوگیری شود. در نهایت عملکرد مدل بر روی داده‌های آزمون ارزیابی می‌شود و در صورت رضایت‌بخش بودن نتایج، خروجی‌های نهائی اینفورمر (ویژگی‌های استخراج‌شده) ذخیره می‌شوند. این ویژگی‌های غنی‌شده سپس برای آموزش مدل EEGNet به کار گرفته می‌شوند.

تشخیص سیگنال‌های تصویرسازی حرکتی بر تحلیل سیگنال‌های الکتروانسفالوگرافی است که ذاتاً غیرایستا، پر از نویز و دارای وابستگی‌های زمانی بلندمدت می‌باشند. در حالی که معماری‌های استاندارد ترنسفورمر در مدل‌سازی توالی‌ها نتایج امیدوارکننده‌ای داشته‌اند، پیچیدگی محاسباتی درجه دوم آن‌ها نسبت به طول توالی، باعث می‌شود برای سری‌های زمانی با وضوح بالای سیگنال الکتروانسفالوگرافی ناکارآمد باشند. علاوه بر این، ترنسفورمرها اغلب در ثبت وابستگی‌های بلندمدت در زمانی که سیگنال‌ها طولانی بوده و الگوهای اطلاعاتی در آن‌ها

انجام محاسبات از پلتفرم Google Colab Pro استفاده شد که دارای ۳۵ گیگابایت حافظه RAM و یک پردازنده گرافیکی T4 است. معیار ارزیابی عملکرد مدل‌ها دقت در نظر گرفته شد که نشان‌دهنده نسبت نمونه‌های صحیح طبقه‌بندی شده به کل نمونه‌ها است. برای اینفورمر، تمامی داده‌های ثبت شده از شرکت کنندگان ترکیب شده و به صورت تصادفی مخلوط شدند. سپس داده‌ها به سه بخش تقسیم گردیده است: ۷۳٪ برای آموزش، ۱۰٪ برای اعتبارسنجی و ۱۷٪ برای آزمون نهایی. مدل اینفورمر بر اساس طبقه‌بندی در سطح گروه آموزش داده شد. در مقابل، مدل EEGNet بر پایه اعتبارسنجی متقابل پنج‌تایی ارزیابی شده است. در هر مرحله از اعتبارسنجی، داده‌های ۸۴ شرکت کننده برای آموزش و داده‌های ۲۱ شرکت کننده برای آزمون اختصاص داده شد. میانگین دقت پنج فولد به عنوان معیار نهایی عملکرد EEGNet گزارش شده است.

#### ۴-۲- داده‌های مورد استفاده

در این پژوهش، از پایگاه داده PhysioNet بهره گرفته شد که شامل سیگنال‌های EEG ثبت شده از ۱۰۹ داوطلب است [۳۵]. این داده‌ها تحت سه وضعیت مختلف جمع‌آوری شده‌اند: حالت استراحت (با دو کلاس: چشم باز و چشم بسته)، اجرای حرکت واقعی (با چهار کلاس: مشت راست، مشت چپ، هر دو مشت، هر دو پا) و تصور حرکت (با همان چهار کلاس مشابه). ثبت سیگنال‌ها با استفاده از کلاه EEG دارای ۶۴ الکتروود و با نرخ نمونه‌برداری ۱۶۰ هرتز انجام شده است. در این مقاله، تمرکز بر چهار کلاس خاص قرار گرفت: تصور حرکت مشت راست، مشت چپ، هر دو پا و حالت استراحت با چشم باز. هر فرد تقریباً ۸۴ آزمایش انجام داده است (۲۱ نمونه برای هر کلاس). مدت زمان هر آزمایش در سه کلاس اول ۶ ثانیه بوده که شامل ۲ ثانیه پیش از شروع حرکت (استراحت) و ۴ ثانیه انجام تکلیف است. با این حال، در این مطالعه تنها ۲ ثانیه نخست دوره انجام تکلیف مورد استفاده قرار گرفته است. داده‌های شرکت کنندگانی که تعداد آزمایش‌های آنها کمتر از ۸۴ مورد بود از بررسی حذف شدند و در نهایت اطلاعات EEG مربوط به ۱۰۵ نفر برای تحلیل‌های نهایی استفاده شد.

#### ۴-۳- فرآیند ارزیابی

جدول ۱ عملکرد روش پیشنهادی را نشان می‌دهد. در ابتدا، برای اعتبارسنجی، مدل EEGNet را تحت شرایط مشابه

و حذف تصادفی برای بهبود همگرایی و جلوگیری از بیش‌برازش استفاده می‌شود. در نهایت، یک لایه کاملاً متصل برای انجام طبقه‌بندی نهایی سیگنال‌های تصور حرکت به کار گرفته می‌شود. لازم به ذکر است که ترکیب ویژگی‌های زمانی تقویت شده توسط اینفورمر با استخراج عمیق فضایی-زمانی توسط EEGNet باعث می‌شود مدل قادر به درک دقیق‌تر وابستگی‌های زمانی-فضایی و تفکیک پذیری بهتر کلاس‌ها باشد.

استفاده از EEGNet در مدل ترکیبی ما مزایای قابل توجهی برای شناسایی سیگنال‌های تخیل حرکتی فراهم می‌کند. ابتدا، EEGNet با بهره‌گیری از لایه‌های کانولوشنی تخصصی شامل کانولوشن مکانی، قادر است ویژگی‌های مکانی و زمانی سیگنال الکتروانسفالوگرافی را به‌طور همزمان استخراج کند و اطلاعات مهم مربوط به فعالیت‌های قشری و توزیع کانال‌ها را حفظ نماید. دوم، این معماری سبک، نمایش‌های فشرده و متمایزی تولید می‌کند که پیچیدگی محاسباتی مرحله بعدی مدل را کاهش داده و سرعت آموزش و استنتاج را افزایش می‌دهد. علاوه بر این، EEGNet به دلیل طراحی کارآمد خود، نسبت به شبکه‌های عمیق بزرگ‌تر کمتر مستعد بیش‌برازش است و حتی با داده‌های EEG محدود نیز عملکرد قابل قبولی ارائه می‌دهد. قابلیت تطبیق پذیری با داده‌های چند کاناله و چند باند فرکانسی، امکان بهره‌برداری از اطلاعات تمایزدهنده موجود در کانال‌های مختلف را فراهم می‌سازد. نهایتاً، خروجی‌های فشرده و غنی EEGNet به عنوان ورودی به مدل اینفورمر، امکان مدل‌سازی مؤثر وابستگی‌های بلندمدت زمانی را فراهم کرده و موجب افزایش دقت و کارایی پیش‌بینی در تخیل حرکتی می‌شود.

#### ۴- نتایج

در این بخش، یافته‌های به‌دست آمده از روش پیشنهادی مورد بررسی قرار می‌گیرد. ابتدا به تشریح جزئیات فنی پیاده‌سازی مدل پرداخته می‌شود. سپس مجموعه داده مورد استفاده معرفی خواهد شد. پس از ارائه نتایج حاصل از اجرای مدل پیشنهادی، این نتایج با مطالعات مرتبط پیشین مقایسه می‌گردد تا عملکرد روش ارائه شده تحلیل شود.

#### ۴-۱- جزئیات فنی پیاده‌سازی

مدل پیشنهادی با بهره‌گیری از کتابخانه‌های Keras و TensorFlow پیاده‌سازی گردیده است [۳۳-۳۴]. برای

۲ ثانیه داده حاصل شده است؛ در حالی که مطالعه مرجع برای رسیدن به بهترین عملکرد نیازمند استفاده از ۴ ثانیه داده بود. این موضوع نشان‌دهنده کارآمدی و قابلیت عملیاتی بالای روش پیشنهادی بوده و استفاده از آن را برای کاربردهای رابط مغز-رایانه در زمان واقعی مناسب‌تر می‌سازد.

جدول ۱- نتایج روش پیشنهادی

مدل	باز تولید نتایج EEGNet	اینفورمر	مدل پیشنهادی
دقت	۶۵.۰۷	۷۹.۹۰	۸۵.۲۰

مطالعه مرجع بازسازی کردیم، که در آن کل ۴ ثانیه دوره انجام تکلیف به کار رفته بود. در ادامه، مدل ترنسفورمر را بر روی داده‌های خام EEG آموزش دادیم و نتایج حاصل از آزمون و منحنی‌های اعتبارسنجی را تحلیل کردیم. با وجود اینکه عملکرد اینفورمر به تنهایی مطلوب نبود، ما نسخه پیش‌آموزش‌دیده آن را برای تقویت داده‌ها به کار گرفتیم. سپس این داده‌های تقویت‌شده به عنوان ورودی به مدل EEGNet داده شد. ترکیب خروجی این دو مدل باعث شد که عملکرد نهایی به طور قابل توجهی بهبود پیدا کند و از نتایج حاصل از استفاده جداگانه هر یک از مدل‌ها بهتر باشد. نکته مهم اینجاست که این افزایش دقت با استفاده از تنها

جدول ۲- مقایسه نتایج طبقه‌بندی با روش‌های پیشرفته اخیر

دقت	نوع داده ورودی	مدت زمان آزمایش	تعداد کلاس‌ها	سطح طبقه‌بندی	روش طبقه‌بندی	تعداد شرکت‌کنندگان	سال	مطالعه
۸۳.۳۱			۲					
۷۴.۴۴	داده خام	۳ ثانیه	۳	سطح گروه	Transformer-CNN	۱۰۹	۲۰۲۲	[۳۶]
۶۴.۲۲			۴					
۸۷.۸	داده پردازش‌شده	۴ ثانیه	۲	سطح گروه	EEGNet Fusion V2	۱۰۳	۲۰۲۳	[۳۷]
۶۵.۰۷	داده خام	۳ ثانیه	۴	سطح گروه / اعتبارسنجی ۵ فولد	EEGNet	۱۰۵	۲۰۲۰	[۳۸]
۸۶.۰۰	داده پردازش‌شده	۴ ثانیه	۳	سطح گروه / اعتبارسنجی ۵ فولد	استفاده از ابعاد فراکتالی به عنوان ویژگی تمایزی + یادگیری ماشین	۲۰ شرکت کننده با PSD برتر	۲۰۲۴	[۳۹]
۸۱.۰۰			۲					
۸۳.۶۱			۲					
۷۴.۳۸	داده خام	۴ ثانیه	۳	سطح گروه / اعتبارسنجی ۵ فولد	ConTraNet (CNN+Transformer)	۱۰۵	۲۰۲۴	[۴۰]
۶۵.۴۴			۴					
۶۶.۹۰	داده خام	۲ ثانیه	۴	سطح گروه / اعتبارسنجی ۵ فولد	Transformer + EEGNet	۱۰۵	۲۰۲۵	[۴۱]
۸۵.۲۰	داده خام	۲ ثانیه	۴	سطح گروه / اعتبارسنجی ۵ فولد	Enhanced Informer + EEGNet	۱۰۵	۲۰۲۶	روش پیشنهادی

#### ۴-۴- مقایسه با مدل‌های موجود

تمایز و قدرتمندی از سیگنال‌های EEG استخراج کند. ارزیابی‌های انجام‌شده نشان داد که این مدل، حتی با داده‌های کوتاه‌تر نسبت به بسیاری از روش‌های پیشرفته موجود، عملکرد بهتری ارائه می‌دهد. این نتایج نشان‌دهنده اثربخشی بالای رویکرد پیشنهادی در حوزه طبقه‌بندی تصور حرکت مبتنی بر سیگنال‌های الکتروانسفالوگرافی است و کارایی آن را برای استفاده‌های کاربردی، به ویژه در شرایطی که محدودیت زمانی وجود دارد، تقویت می‌کند. در مسیر آینده، تمرکز بر بهبود ساختار مدل و آزمایش آن در شرایط مختلف و مجموعه داده‌های متنوع خواهد بود تا قابلیت تعمیم آن بیشتر بررسی شود.

مدل پیشنهادی اگرچه عملکرد مطلوبی در شناسایی سیگنال‌های الکتروانسفالوگرافی مربوط به تصور حرکتی ارائه می‌دهد، اما با محدودیت‌هایی نیز همراه است. از جمله این محدودیت‌ها می‌توان به پیچیدگی محاسباتی و نیاز به منابع پردازشی بیشتر در مقایسه با مدل‌های ساده‌تر اشاره کرد که می‌تواند کاربرد آن را در سیستم‌های رابط مغز و رایانه بلادرنگ دشوار کند. همچنین، وابستگی شدید به کیفیت استخراج ویژگی‌های فرکانسی ممکن است در شرایطی که سیگنال‌ها نویزی یا نامناسب باشند موجب افت عملکرد شود. علاوه بر این، غیرایستایی ذاتی سیگنال‌های الکتروانسفالوگرافی و تغییر شرایط ضبط می‌تواند تعمیم‌پذیری مدل را کاهش دهد. از سوی دیگر، استفاده از بازه‌های زمانی کوتاه ۲ ثانیه‌ای احتمال از دست رفتن الگوهای زمانی ظریف در فعالیت‌های آهسته‌تر مغزی را افزایش می‌دهد. در کارهای آینده، تلاش بر ارائه راه‌حل‌های مناسب جهت حل این مشکلات خواهد بود.

#### تعارض منافع

نویسندگان اعلام می‌کند که در مورد انتشار این مقاله تعارض منافع وجود ندارد. دکتر راضیه راستگو، یکی از نویسندگان در این مقاله، کمک سردبیر و مدیر داخلی فعلی مجله مدلسازی در مهندسی است، اما هیچ دخالتی در فرآیند ارزیابی این مقاله نداشته است. فرآیند داوری این مقاله توسط یکی از دبیران در مجله مذکور مدیریت گردیده است.

#### تأییدیه اخلاقی

نویسندگان متعهد می‌شوند که مطالب این مقاله را در هیچ

بر خلاف بسیاری از مطالعات قبلی که روی طبقه‌بندی شخصی تمرکز دارند، ما در این تحقیق طبقه‌بندی سطح گروه را مبنا قرار دادیم. این نوع طبقه‌بندی به دلیل تفاوت‌های فردی معمولاً با کاهش دقت همراه است، اما از نظر کاربردی برای محیط‌های واقعی مناسب‌تر محسوب می‌شود. برای ارزیابی عملکرد مدل، از مجموعه داده استاندارد PhysioNet بهره گرفتیم که مرجع رایج در حوزه تحلیل EEG تصور حرکت است و امکان مقایسه مستقیم با مطالعات پیشین را فراهم می‌کند. تمرکز ما روی مقایسه با مدل‌هایی بود که اخیراً بر روی همین مجموعه داده و با همین معیارها در سطح گروه آزمایش شده‌اند. جدول ۲ مقایسه‌ای از نتایج مدل پیشنهادی با مدل‌های برجسته قبلی در مراجع [۳۶-۴۱] را نمایش می‌دهد. در این بررسی، مدل ما در شرایطی مشابه (همان کلاس‌ها و افراد) و حتی با مدت زمان کوتاه‌تر تراپال‌ها، توانست عملکرد بهتری نسبت به مدل‌های معرفی شده در مراجع [۳۶، [۳۸]، [۴۰] و [۴۱] کسب کند. همچنین، در صورت استفاده از ۲ کلاس در مدل مرجع [۳۹]، دقت مدل پیشنهادی با در نظر گرفتن ۴ کلاس، بیشتر می‌باشد. با این وجود، مدل‌های مرجع [۳۷] با ۲ کلاس و مرجع [۳۹] با ۳ کلاس همچنان دقت بالاتری نسبت به مدل ما داشتند. علت اصلی این برتری، استفاده این مدل‌ها از تعداد کلاس حرکتی کمتر است که طبقه‌بندی را ساده‌تر می‌کند. علاوه بر این، تمامی مدل‌های مقایسه‌شده از طول تراپال بیشتری نسبت به مدل ما بهره می‌بردند. بنابراین، برتری مدل پیشنهادی در استفاده مؤثر از تراپال‌های کوتاه‌تر نشان‌دهنده قابلیت آن برای کاربردهای عملی و سناریوهای واقعی است، جایی که محدودیت زمانی در جمع‌آوری داده‌ها وجود دارد.

#### ۵- جمع‌بندی

در این پژوهش، یک چارچوب مؤثر برای طبقه‌بندی سیگنال‌های تصور حرکت مبتنی بر سیگنال الکتروانسفالوگرافی معرفی شد که مبتنی بر ترکیب معماری‌های اینفورمر بهبودیافته بر مبنای توجه آگاه به فرکانس و شبکه عصبی کانولوشنی EEGNet است. مدل ارائه‌شده با بهره‌گیری از قدرت مدل اینفورمر بهبودیافته در استخراج وابستگی‌های زمانی و ظرفیت بالای شبکه عصبی کانولوشنی در یادگیری الگوهای فضایی، توانست ویژگی‌های

مجله دیگری به چاپ نرسانده اند.

دکتر راضیه راستگو: ایده، پیاده‌سازی، تحلیل نتایج،

آماده‌سازی نسخه اولیه، ویرایش

مشارکت های نویسندگان

دکتر لوئیزا دهیادگاری: ایده، پیاده‌سازی، تحلیل نتایج،

آماده‌سازی نسخه اولیه، ویرایش

منابع مالی

منابع مالی مورد استفاده قرار نگرفته است.

## مراجع

- [1] Wolpaw, Jonathan, and Elizabeth W. Wolpaw. "Brain-Computer Interfaces: Principles and Practice." Oxford University Press, USA, 2012.
- [2] Wolpaw, Jonathan R., Niels Birbaumer, Donald J. McFarland, Gert Pfurtscheller, and Theresa M. Vaughan. "Brain-computer interfaces for communication and control." *Clinical Neurophysiology* 113, no. 6 (2002): 767-791.
- [3] Pfurtscheller, Gert, and Christa Neuper. "Motor imagery and direct brain-computer communication." *Proceedings of the IEEE* 89, no. 7 (2001): 1123-1134.
- [4] Hamidi, Arezoo, and Kouros Kiani. "Motor Imagery EEG signals classification using a Transformer-GCN approach." *Applied Soft Computing* 170 (2025): 112686.
- [5] Lotte, Fabien, Loïc Bougrain, Andrzej Cichocki, Maud Clerc, Alexandre Congedo, A. Rakotomamonjy, and F. Yger. "A review of classification algorithms for EEG-based brain-computer interfaces: A roadmap to algorithm design." *Journal of Neural Engineering* 15, no. 6 (2018): 1741-2552.
- [6] Altaheri, Hassan. "Deep learning techniques for classification of electroencephalogram (EEG) motor imagery (MI) signals: a review." *Neural Comput. Appl.* 35, no. 20 (2023): 14681-14722.
- [7] Hamidi, Arezoo, and Kouros Kiani. "Motor Imagery EEG signals classification using a Transformer-GCN approach." *Applied Soft Computing* 170, no. 10 (2025): 112686.
- [8] Ahmadi, Amir Mohammad, Kouros Kiani, and Razieh Rastgoo. "A Transformer-based model for abnormal activity recognition in video." *Journal of Modeling in Engineering* 22, no. 76 (2024): 213-221.
- [9] Esfandiari, Nura, Kouros Kiani, and Razieh Rastgoo. "A conditional generative chatbot using transformer model." *Journal of Modeling in Engineering* 23, no. 82 (2025): 99-113.
- [10] Ma, Zhen. "Transformed common spatial pattern for motor imagery-based brain-computer interfaces." *Front. Neurosci* 17, no. 3 (2023): 1116721.
- [11] Hou, Yanlong. "GCNs-net: a graph convolutional neural network approach for decoding time-resolved eeg motor imagery signals." *IEEE Trans. Neural Netw. Learn. Syst.* 35, no. 6 (2022): 7312 - 7323.
- [12] Ma, Yang, Yong Song, and Feng Gao. "A novel hybrid CNN-Transformer model for EEG Motor Imagery classification." In *Proceedings of the 2022 International Joint Conference on Neural Networks (IJCNN), IEEE, 2022.*
- [13] Barnova, Klara, Martina Mikolasova, Renata V. Kahankova, Renata Jarosa, Aliaksandr K. Sterniuk, Vlastimil Snasel, Seyed Mirjalili, Marek Pelcb, and Radek Martineka. "Implementation of artificial intelligence and machine learning-based methods in brain-computer interaction." *Computers in Biology and Medicine* 163 (2023): 107135.
- [14] Luo, Ting-Jie, Chun Zhou, and Fenlin Chao. "Exploring spatial-frequency-sequential relationships for motor imagery classification with recurrent neural network." *BMC Bioinforma* 19 (2018): 344.
- [15] Tortora, Simone, Simone Ghidoni, Carmela Chisari, Silvestro Micera, and Francesco Artoni. "Deep learning-based BCI for gait decoding from EEG with LSTM recurrent neural network." *Journal of Neural Engineering* 17 (2020): 046011.
- [16] Bang, Jong Sik, and Seung Woo Lee. "Motor imagery classification based on CNN-GRU network with spatio-temporal feature representation." In: Wallraven, C., Liu, Q., Nagahara, H. (eds) *Pattern Recognition. ACPR. Lecture Notes in Computer Science*, 13188. (2022): 104-115.
- [17] Dai, Yanning, Xiaowei Deng, Xiaoli Fu, and Yunjie Zhao. "Periodicity-based multi-dimensional interaction convolution network with multi-scale feature fusion for motor imagery EEG classification." *Journal of Neuroscience Methods* 415 (2025): 110356.

- [18] Bagherzadeh, Fahimeh, and Razieh Rastgoo. "Deepfake image detection using a deep hybrid convolutional neural network." *Journal of Modeling in Engineering* 21, no. 75 (2023): pp. 19–28.
- [19] Chowdhurya, Riya Sh, Sh. Boseb, S. Ghosha, and A. Konara. "Attention Induced Dual Convolutional-Capsule Network (AIDC-CN): A deep learning framework for motor imagery classification." *Computers in Biology and Medicine* 183 (2024): 109260.
- [20] Wang, Xiaoli, Yu Wang, Wei Qia, Dawei Kong, and Wei Wang. "Brain GridNet: A two-branch depth wise CNN for decoding EEG-based multi-class motor imagery." *Neural Networks* 170 (2024): 312-324.
- [21] Luo, Jian, Yong Wang, Shiqiang Xia, Ning Lu, Xiaoming Ren, Zhifeng Shi, and Xiaodong Hei. "A shallow mirror transformer for subject-independent motor imagery BCI." *Computers in Biology and Medicine* 164 (2023): 107254.
- [22] Thangaraj, Thenmozhi, Helen Rajendran, and S. Mythili. "Classification of motor imagery EEG with ensemble RNCA model." *Behavioural Brain Research* 479 (2025): 115345.
- [23] Saibenea, Aurora, Hafez Ghaemi, and Eda Dagdevir. "Deep learning in motor imagery EEG signal decoding: A Systematic Review." *Neurocomputing* 610 (2024): 128577.
- [24] Yang, Yong, Xia Zhang, Xia Zhang, and Cha. Yu. "MCMT Net: Advanced network architectures for EEG-based motor imagery classification." *Neurocomputing* 620 (2025): 129255.
- [25] Gao, Yan, Wen Xie, Zh. Luo, M. Houston, and Y. Zhang. "Multi-domain feature analysis of MI-EEG signals using tensor train decomposition and projected gradient Non-negative Matrix Factorization." *Neurocomputing* 623, no. 28 (2025): 129410.
- [26] Jiang, Xiaojun, Ling Meng, Xin Chen, Yiming Xu, and Dong Wu. "CSP-Net: Common spatial pattern empowered neural networks for EEG-based motor imagery classification." *Knowledge-Based Systems* 305, no. 3 (2024): 112668.
- [27] Karimian-Kelishadrokh, Mohammad, and Fatemeh Safi-Esfahani. "Application of the time-distributed layer in the controller of memory-augmented neural networks to classify brain activities into motor imagery and motor execution." *Applied Soft Computing* 162 (2024): 111771.
- [28] Abenna, Said, Mohammed Nahid, Hamid Bouyghf, Brahim Ouacha. "An enhanced motor imagery EEG signal prediction system in real-time based on delta rhythm." *Biomedical Signal Processing and Control* 79, no. 2 (2023): 104210.
- [29] Cao, Jian, Gang Li, Jin Shen, and Chuang Dai. "IFBCL Net: Spatio-temporal frequency feature extraction-based MI-EEG classification convolutional network." *Biomedical Signal Processing and Control* 92 (2024): 106092.
- [30] Lawhern, Vernon J., Amelia J. Solon, Nicholas R. Waytowich, Stephen M. Gordon, Chou P. Hung and Brent J Lance. "EEGNet: a compact convolutional neural network for EEG-based brain-computer interfaces." *Journal of Neural Engineering* 15, no. 5 (2018): 056013.
- [31] Zhou, Haoyi, Shanghang Zhang, Jieqi Peng, Shuai Zhang, Jianxin Li, Hui Xiong, Wancai Zhang. "Informer: Beyond Efficient Transformer for Long Sequence Time-Series Forecasting." *The Thirty-Fifth AAAI Conference on Artificial Intelligence (AAAI-21)*, pp. 11106-11115, 2021.
- [32] Vaswani, Ashish, Noam Shazeer, Niki Parmar, Jakob Uszkoreit, Llion Jones, Aidan N. Gomez, Lukasz Kaiser, and Illia Polosukhin. "Attention Is All You Need." *arXiv:1706.03762*, 2023.
- [33] Zarbafi, Sahar, Kourosh Kiani, and Razieh Rastgoo. "Spoken Persian digits recognition using deep learning." *Journal of Modeling in Engineering* 21, no. 74 (2023): pp. 163–172.
- [34] Rastgoo, Razieh, and Kourosh Kiani. "Face recognition using fine-tuning of Deep Convolutional Neural Network and transfer learning." *Journal of Modeling in Engineering* 17, no. 58 (2019): pp. 103–111.
- [35] Schalk, Gerwin, Dennis J. McFarland, Thilo Hinterberger, Niels Birbaumer, and Jonathan R. Wolpaw. "BCI2000: a general-purpose brain-computer interface (BCI) system." *IEEE Transactions on biomedical engineering* 51, no. 6 (2004): 1034-1043.
- [36] Xie, Jin, Jie Zhang, Jiayao Sun, Zheng Ma, Liuni Qin, Guanglin Li, Huihui Zhou, and Yang Zhan. "A transformer-based approach combining deep learning network and spatial-temporal information for raw EEG classification." *IEEE Transactions on Neural Systems and Rehabilitation Engineering* 30 (2022): 2126-2136.

- [37] Wang, Xiaying, Michael Hersche, Batuhan Tömekce, Burak Kaya, Michele Magno, Luca Benini. "An accurate eegnet-based motor-imagery brain-computer interface for low-power edge computing." in 2020 IEEE International Symposium on Medical Measurements and Applications (MeMeA). 2020. IEEE.
- [38] Chowdhury, Radia Rayan, Yar Muhammad, and Usman Adeel. "Enhancing cross-subject motor imagery classification in EEG-based brain-computer interfaces by using multi-branch CNN." *Sensors* 23, no. 18 (2023): 7908.
- [39] Moaveninejad, Sadaf, Valentina D'Onofrio, Franca Tecchio, Francesco Ferracuti, Sabrina Iarlori, Andrea Monteriù, and Camillo Porcaro. "Fractal Dimension as a discriminative feature for high accuracy classification in motor imagery EEG-based brain-computer interface." *Computer Methods and Programs in Biomedicine* 244 (2024): 107944.
- [40] Ali, Omair, Muhammad Saif-ur-Rehman, Tobias Glasmachers, Ioannis Iossifidis, and Christian Klaes. "ConTraNet: A hybrid network for improving the classification of EEG and EMG signals with limited training data." *Computers in biology and medicine* 168 (2024): 107649.
- [41] Hmaid, Arezoo, Kouros Kiani, Razieh Rastgoo. "A Fusion of Transformer and EEGnet Models for Motor Imagery EEG Decoding." *Journal of Modeling in Engineering* 23 (2025): 191-202.