



Semnan University

Journal of Modeling in Engineering

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

ISSN: 2783-2538



Research Article

A Fusion of Transformer and EEGnet Models for Motor Imagery EEG Decoding

Arezoo Hamidi ^a, Kourosh Kiani ^{b,*}, Razieh Rastgoo ^b

^a Biomedical Engineering Department, Semnan University, Semnan, Iran

^b Electrical and Computer Engineering Faculty, Semnan University, Semnan, Iran

PAPER INFO

Paper history:

Received: 2025-01-20

Revised: 2025-06-30

Accepted: 2025-07-20

Keywords:

Motor Imagery;
EEG;
Transformer;
EEGNet;
Classification.

ABSTRACT

Decoding motor imagery electroencephalograph (EEG) signals is a critical aspect of cognitive impairment assessments within the realm of Brain-Computer Interface (BCI) research. The inherent variability of these signals across different individuals poses a significant challenge in developing models that can accurately recognize and interpret them universally. Furthermore, the ability to detect individual motor imagery using shorter signal durations is crucial for enhancing the reliability and practicality of BCI systems. In this study, we propose a novel hybrid model that combines Transformer and EEGnet architectures for the classification of motor imagery EEG signals. The integration of Transformer and EEGnet enables our model to leverage both spatial and temporal features inherent in EEG data. Our research demonstrates promising results, achieving an accuracy of 66.9% when evaluating 2-second trial data across diverse subjects using the Physionet dataset. Comparative evaluations against state-of-the-art models highlight the superior performance of our approach, particularly in achieving notable benchmarks with shorter trial durations.

DOI: <https://doi.org/10.22075/jme.2025.36652.2796>

© 2025 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: Kourosh.kiani@semnan.ac.ir

How to cite this article:

A. Hamidi , K. Kiani and R. Rastgoo, "A Fusion of Transformer and EEGnet Models for Motor Imagery EEG Decoding," Journal of Modeling in Engineering, 23 83 (2025): 191-202, doi: 10.22075/jme.2025.36652.2796

ترکیب مدل های ترنسفورمر و EEGNet برای شناسایی سیگنال های EEG تصور حرکتی

آرزو حمیدی^۱، کوروش کیانی^{۲*}، راضیه راستگو^۲

اطلاعات مقاله	چکیده
دریافت مقاله: ۱۴۰۳/۱۱/۰۱ بازنگری مقاله: ۱۴۰۴/۰۴/۰۹ پذیرش مقاله: ۱۴۰۴/۰۴/۲۹	شناسایی سیگنال های الکتروانسفالوگرافی (EEG) مربوط به تصور حرکت، جنبه ای حیاتی در ارزیابی های اختلالات شناختی در زمینه تحقیقاتی رابط مغز-رایانه (BCI) است. تنوع ذاتی این سیگنال ها در افراد مختلف، چالش بزرگی در توسعه مدل هایی ایجاد می کند که بتوانند به طور دقیق آن ها را شناسایی و تفسیر کنند. علاوه بر این، توانایی شناسایی تصور حرکت با استفاده از مدت زمان های کوتاه تر سیگنال، برای افزایش قابلیت اعتماد و کاربردپذیری سیستم های BCI اهمیت زیادی دارد. در این مطالعه، یک مدل هیبریدی نوآورانه پیشنهاد می شود که معماری های EEGNet و Transformer را برای طبقه بندی سیگنال های EEG تصور حرکتی ترکیب می کند. ادغام این دو معماری، به مدل ما این امکان را می دهد که از ویژگی های فضایی و زمانی موجود در داده های EEG استفاده کند. پژوهش انجام شده نتایج امیدوارکننده ای را نشان می دهد که در آن دقت ۶۶.۹٪ برای ترایال ۲ ثانیه ای با ارزیابی میان گروهی با استفاده از مجموعه داده Physionet به دست می آورد. ارزیابی های مقایسه ای در برابر مدل های پیشرفته نشان می دهند که عملکرد روش پیشنهادی به ویژه در دستیابی به معیارهای قابل توجه با مدت زمان های ترایال کوتاه تر، برتری دارد.

واژگان کلیدی:

تصور حرکت،

EEG.

Transformer.

EEGNet.

طبقه بندی.

DOI: <https://doi.org/10.22075/jme.2025.36652.2796>

© 2025 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/>)

۱- مقدمه

تصور حرکت است؛ در این فرآیند، افراد تنها با تصور انجام حرکات خاص، بدون اجرای فیزیکی آن ها، سیگنال های مغزی مربوطه را تولید می کنند [۳، ۴]. تشخیص دقیق این سیگنال ها نقش تعیین کننده ای در عملکرد مؤثر سامانه های BCI ایفا می کند.

در یک دهه گذشته، مجموعه ای از روش های یادگیری ماشین و یادگیری عمیق برای طبقه بندی سیگنال های EEG مبتنی بر تصور حرکت مورد استفاده قرار گرفته اند. روش های سنتی یادگیری ماشین معمولاً بر پایه استخراج دستی ویژگی ها توسط متخصصان و سپس به کارگیری

در سال های اخیر، رابط مغز-رایانه (BCI) به عنوان یک فناوری نوآورانه مطرح شده است که امکان تحلیل سیگنال های مغزی و تبدیل آن ها به دستورات قابل درک برای رایانه ها را فراهم می سازد. این فناوری، یک مسیر ارتباطی مستقیم میان مغز انسان و دستگاه های خارجی ایجاد می کند و مزایای چشمگیری برای افراد دارای ناتوانی های حرکتی یا اختلالات شناختی به همراه دارد [۱، ۲]. یکی از حوزه های کلیدی در پژوهش های BCI، شناسایی سیگنال های الکتروانسفالوگرافی (EEG) مرتبط با

* پست الکترونیک نویسنده مسئول: Kourosh.kiani@semnan.ac.ir

۱. دانشکده مهندسی پزشکی، دانشگاه سمنان، سمنان، ایران

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

استناد به این مقاله:

آرزو حمیدی، کوروش کیانی و راضیه راستگو، "ترکیب مدل های Transformer و EEGNet برای شناسایی سیگنال های EEG تصور حرکتی"، مدل سازی در مهندسی، ۸۳ (۱۴۰۴): ۲۷۹۱-۲۸۰۲، doi: 10.22075/jme.2025.36652.2796

EEG عملکرد قابل قبولی از خود نشان داده است. در مقابل، معماری ترنسفورمر با اتکا به سازوکار خود-توجه، توانایی مدل سازی وابستگی های زمانی بلندمدت در داده های سری زمانی را دارد. از آنجا که سیگنال های EEG دارای ابعاد زمانی و مکانی درهم تنیده هستند، ترکیب این دو معماری برای بهره برداری هم زمان از روابط فضایی و زمانی سیگنال، رویکردی کارآمد و امیدبخش محسوب می شود. مدل پیشنهادی با طراحی دو مرحله ای و پردازش داده ها در پنجره های زمانی کوتاه تر از حد معمول، با هدف افزایش دقت طبقه بندی و ارتقاء پایداری عملکرد در سناریوهای میان آزمودنی توسعه یافته است؛ عاملی که می تواند در طراحی سامانه های BCI در زمان واقعی کاربرد مستقیم داشته باشد.

ساختار مقاله به گونه ای تنظیم شده است که ابتدا در بخش دوم، مطالعات مرتبط با حوزه طبقه بندی سیگنال های تصور حرکتی مرور می شود. سپس، در بخش سوم، معماری مدل پیشنهادی و داده های مورد استفاده به تفصیل معرفی می گردد. بخش چهارم به ارائه و تحلیل نتایج تجربی اختصاص دارد و در نهایت، جمع بندی و نتیجه گیری در بخش پنجم ارائه خواهد شد.

۲- مطالعات مرتبط

تحلیل سیگنال های EEG در کاربردهای تصور حرکتی به ویژه در سامانه های BCI، طی دهه گذشته با تحولی چشمگیر از روش های مبتنی بر ویژگی های استخراج شده دستی به سمت مدل های یادگیری عمیق همراه بوده است. شبکه های CNN، به ویژه در قالب مدل های سبک و مؤثری مانند EEGNet، نقش مهمی در این گذار ایفا کرده اند [۲۶]. معماری EEGNet با استفاده از کانولوشن های عمقی و جداسازی، به صورت خاص برای داده های EEG طراحی شده و در بسیاری از پژوهش ها به عنوان پایه ای کارآمد برای طبقه بندی سیگنال های مغزی مورد استفاده قرار گرفته است.

در راستای تقویت درک از ساختار زمانی سیگنال EEG، استفاده از معماری ترنسفورمر نیز در پژوهش های اخیر جایگزین مناسبی برای ساختارهای بازگشتی مانند شبکه های عصبی حافظه طولانی کوتاه مدت (LSTM) و واحد بازگشتی دروازه دار (GRU) تلقی شده است. این معماری با تکیه بر مکانیزم توجه، توانایی شناسایی وابستگی های بلندمدت در داده های ترتیبی را فراهم

الگوریتم های طبقه بندی انجام می شوند [۵، ۶]. در مقابل، مدل های یادگیری عمیق با حذف وابستگی به استخراج دستی، فرآیند شناسایی ویژگی های مؤثر را به طور خودکار انجام می دهند و امکان مدل سازی بهتر وابستگی های زمانی و فضایی در سیگنال را فراهم می سازند [۷].

در میان معماری های یادگیری عمیق، طیف متنوعی از مدل ها برای استخراج خودکار ویژگی های مؤثر از سیگنال های EEG مورد استفاده قرار گرفته اند. شبکه های عصبی بازگشتی (RNN) [۸] و به ویژه ترنسفورمرها [۹] در مدل سازی وابستگی های زمانی و ساختارهای توالی محور عملکرد چشمگیری داشته اند؛ به طوری که ترنسفورمر به عنوان جایگزینی نوین برای RNN، با کاهش زمان آموزش و افزایش قابلیت پردازش موازی، به مدلی کارآمد برای تحلیل سیگنال های EEG تبدیل شده است [۱۰، ۱۱]. از سوی دیگر، شبکه های عصبی کانولوشنی (CNN) به طور خاص در استخراج ویژگی های فضایی محلی مؤثر عمل می کنند [۱۲-۱۴]، در حالی که معماری های گراف کانولوشن (GCN) به منظور مدل سازی ساختارهای ارتباطی مغز و تحلیل شبکه های مغزی به کار گرفته شده اند [۱۵، ۱۶]. برخی مطالعات نیز با بهره گیری از ترکیب این معماری ها، از لایه های کانولوشنی چندمقیاسی، شبکه های بازگشتی، سازوکار توجه، یا گراف های ساختاریافته برای تقویت نمایه سازی ویژگی ها استفاده کرده اند [۱۷-۲۰]. علاوه بر آن، دسته ای از پژوهش ها به جای تکیه بر استخراج دستی ویژگی ها، از سیگنال های خام یا پیش پردازش شده EEG به طور مستقیم در معماری های یادگیری عمیق بهره برده اند [۲۱، ۲۲]. در برخی موارد، سیگنال ها پیش از ورود به مدل، به حوزه های فرکانسی یا فازی تبدیل می شوند تا استخراج مؤلفه های طیفی و مرحله ای بهینه شود [۲۳، ۲۴]. همچنین، در مواجهه با چالش کمبود داده، به ویژه در زمینه های پزشکی، از شبکه های مولد رقابتی (GAN) برای افزایش حجم داده و بهبود آموزش مدل های پیچیده استفاده شده است [۳، ۲۵].

در این پژوهش، یک مدل هیبریدی نوین پیشنهاد شده است که با هدف تحلیل مؤثر سیگنال های EEG مربوط به تصور حرکتی، از ترکیب معماری ترنسفورمر و شبکه EEGNet بهره می برد. معماری EEGNet که مبتنی بر شبکه های عصبی کانولوشنی طراحی شده، با ساختاری سبک و بهینه، در استخراج ویژگی های فضایی سیگنال های

سیگنال‌هایی با بازه زمانی ۳ تا ۴ ثانیه متکی هستند که ممکن است در کاربردهای زمان‌واقعی محدودکننده باشد. در پاسخ به این چالش، مطالعه حاضر با ارائه یک معماری دومرحله‌ای شامل ترنسفورمر رمزگذار و EEGNet رمزگشا، به گونه‌ای طراحی شده است که قادر به تحلیل دقیق سیگنال‌های تصور حرکت تنها با ۲ ثانیه از داده EEG در یک سناریوی میان‌آزمودنی باشد. این ویژگی، مزیتی عملی برای استفاده در سامانه‌های BCI تعاملی و زمان‌واقعی محسوب می‌شود.

۳- روش‌ها

۳-۱- ساختار مدل پیشنهادی


با توجه به ماهیت خاص سیگنال‌های EEG تصور حرکتی که حاوی اطلاعات توزیع‌یافته در هر دو بعد زمانی و مکانی هستند، بهره‌گیری از معماری‌هایی که به‌صورت مکمل قادر به استخراج این نوع ویژگی‌ها باشند، از اهمیت بالایی برخوردار است. در مدل پیشنهادی، از یک ترنسفورمر رمزگذار مبتنی بر مکانیزم خودتوجه برای شناسایی وابستگی‌های زمانی پیچیده استفاده شده است؛ قابلیت که به‌ویژه در مدل‌سازی روابط بلندمدت سیگنال‌ها در بازه‌های زمانی کوتاه مؤثر است. پس از این مرحله، داده‌های غنی‌شده به یک شبکه EEGNet با ساختار کانولوشنی سبک منتقل می‌شوند تا ویژگی‌های فضایی استخراج و فرآیند طبقه‌بندی تکمیل شود. انتخاب این دو معماری با هدف بهره‌برداری از توانایی‌های مکمل آن‌ها صورت گرفته است؛ به گونه‌ای که ترنسفورمر بر تحلیل زمانی و EEGNet بر تحلیل فضایی تمرکز دارد.

نمای کلی معماری پیشنهادی در شکل (۱) نمایش داده شده است. این مدل شامل یک ترنسفورمر پیش‌آموزش‌دیده در مرحله نخست و یک CNN در مرحله دوم است. ابتدا، یک ترنسفورمر دولایه برای طبقه‌بندی سیگنال‌های تصور حرکت آموزش داده می‌شود و وزن‌های به‌دست‌آمده از این آموزش برای غنی‌سازی ویژگی‌های زمانی سیگنال‌های خام به کار می‌رود. خروجی این مرحله سپس به عنوان ورودی به مدل EEGNet منتقل می‌شود که با استفاده از لایه‌های کانولوشنی عمقی و جداسازی، ویژگی‌های مکانی را استخراج کرده و عملیات طبقه‌بندی نهایی را انجام می‌دهد.

می‌سازد. برای نمونه، شارما و همکاران [۲۷] عملکرد برتر ترنسفورمر را در طبقه‌بندی داده‌های EEG مبتنی بر تصور حرکت نسبت به مدل‌های مبتنی بر RNN گزارش کرده‌اند. همچنین، ژانگ و همکاران [۲۸] با معرفی معماری Cross-Attention Transformer، بهبود معناداری در تعمیم‌پذیری میان‌آزمودنی را نشان داده‌اند.

در ادامه این روند، چندین مطالعه به طراحی مدل‌های ترکیبی پرداخته‌اند که به‌طور هم‌زمان از قابلیت استخراج ویژگی‌های محلی توسط CNN و درک روابط جهانی زمانی توسط ترنسفورمر بهره‌برداری می‌کنند. برای مثال، معماری ConTraNet با ساختار هیبریدی CNN-Transformer برای طبقه‌بندی چندکلاسه EEG مبتنی بر تصور حرکت توسعه داده شده و بهبود قابل توجهی در دقت نسبت به مدل‌های منفرد گزارش کرده است [۱۰]. همچنین، CSANet که توسط هوآنگ و همکاران [۲۹] معرفی شد، با ترکیب کانولوشن‌های لغزان و مکانیزم‌های توجه چندمقیاسی، امکان استخراج اطلاعات در سطوح مختلف زمانی و مکانی را فراهم کرده است. همچنین، معماری EEGNet Fusion V2 که توسط چودھاری و همکاران [۳۰] معرفی شده است، از پنج شاخه موازی تشکیل شده که هر یک با ابعاد کرنل متفاوت، به استخراج ویژگی‌های مکانی و زمانی از سیگنال EEG می‌پردازند. پس از استخراج ویژگی‌ها، خروجی شاخه‌ها با یکدیگر ادغام شده و به لایه‌های کاملاً متصل منتقل می‌شود تا فرآیند طبقه‌بندی نهایی انجام گیرد. در همین راستا، شی و همکاران [۳۱] نیز با طراحی مدلی مبتنی بر ترنسفورمر و اطلاعات مکانی-زمانی، موفق به بهبود دقت طبقه‌بندی چهارکلاسه میان‌آزمودنی نسبت به مدل‌های موجود شده‌اند.

زنجیره این تحولات در مطالعات بسیار جدید نیز ادامه داشته است. به عنوان نمونه، ژانگ و همکاران [۳۲] معماری هیبریدی جدیدی را معرفی کرده‌اند که با ترکیب CNN، سازوکار توجه و گراف کانولوشن در طبقه‌بندی میان‌آزمودنی عملکرد مناسبی نشان داده است. شیروودکار و همکاران [۳۳] نیز با استفاده از تبدیل‌های زمان-فرکانس، شبکه‌های CNN دوبعدی و داده‌های مصنوعی تولید شده توسط GAN، توانستند به دقت بالای ۹۳٪ در طبقه‌بندی تصور حرکتی دست یابند. با این حال، اکثر این مطالعات به



شکل ۱- معماری روش پیشنهادی

Dropout، Flatten و Dense است که به منظور طبقه‌بندی اولیه سیگنال‌های تصور حرکتی به کار گرفته می‌شود. به منظور کدگذاری اطلاعات مکانی توالی، از تعبیه موقعیتی نسبی (Relative Positional Embedding) استفاده شده است.

داده‌ها پس از ادغام کلیه آزمودنی‌ها، به صورت تصادفی مخلوط شده و به سه مجموعه آموزش، اعتبارسنجی و آزمون تقسیم می‌شوند. آموزش مدل بر روی مجموعه آموزش انجام شده و عملکرد آن به کمک مجموعه اعتبارسنجی پایش می‌گردد تا از بیش‌برازش جلوگیری شود. پس از دستیابی به نتایج مطلوب در دو مجموعه اعتبارسنجی و آزمون، وزن‌های آموزش‌دیده ترنسفورمر ذخیره شده و برای استخراج ویژگی از کل مجموعه داده اعمال می‌شوند. این فرآیند منجر به تولید مجموعه‌ای غنی‌شده با همان ابعاد اولیه می‌شود که به عنوان ورودی به مدل EEGNet منتقل شده و مرحله نهایی استخراج ویژگی‌های فضایی و طبقه‌بندی را تکمیل می‌کند. معماری دقیق مدل در جدول ۱ ارائه شده است.

در مرحله دوم مدل پیشنهادی، از معماری EEGNet به عنوان یک شبکه عصبی کانولوشنی سبک و بهینه جهت تحلیل سیگنال‌های EEG استفاده می‌شود. این معماری شامل سه لایه اصلی کانولوشنی است که هر یک با هدف استخراج جنبه‌ای خاص از ویژگی‌های سیگنال طراحی شده‌اند. نخست، یک لایه کانولوشن زمانی (Temporal

مدل ترنسفورمر، نخستین بار توسط واسوانی و همکاران برای پردازش داده‌های ترتیبی معرفی شد [۳۴]. برخلاف معماری‌های سنتی مانند RNN و CNN، این مدل مبتنی بر سازوکار خود-توجه (Self-Attention) است که توانایی بالایی در شناسایی وابستگی‌های پیچیده در توالی داده‌ها دارد. نوآوری اصلی ترنسفورمر در همین سازوکار نهفته است؛ جایی که مدل می‌تواند اهمیت نسبی اجزای مختلف یک توالی ورودی را به صورت دینامیک وزن‌دهی کرده و در نتیجه، تعامل بین موقعیت‌های مختلف را به طور هم‌زمان مدل‌سازی کند. عملکرد موازی این سازوکار باعث شده است ترنسفورمرها در تحلیل توالی‌های طولانی، هم از نظر دقت و هم از نظر کارایی محاسباتی، برتری داشته باشند.

در ساختار اولیه، معماری ترنسفورمر شامل دو بخش اصلی کدگذار و رمزگشا است. بخش کدگذار وظیفه پردازش ورودی‌ها و استخراج ویژگی‌های سطح بالا را بر عهده دارد و بخش رمزگشا با استفاده از اطلاعات کدگذار، خروجی نهایی را تولید می‌کند. هرچند این معماری در ابتدا برای پردازش زبان طبیعی طراحی شد، اما به سرعت کاربرد آن به حوزه‌های متنوعی همچون بینایی ماشین، شناسایی گفتار و تحلیل داده‌های سری‌زمانی گسترش یافت [۹، ۳۱، ۳۵، ۳۶]. در این مطالعه، با توجه به ماهیت سری‌زمانی سیگنال‌ها EEG و هدف استخراج ویژگی‌های زمانی، تنها از بخش کدگذار ترنسفورمر استفاده شده است. مدل طراحی‌شده شامل دو لایه ترنسفورمر به همراه لایه‌های

است [۳۷]. ثبت سیگنال‌ها در سه وضعیت مختلف انجام شده است: حالت استراحت (با دو کلاس چشم‌ها باز و چشم‌ها بسته)، اجرای حرکتی (چهار کلاس مشت راست، مشت چپ، هر دو مشت، و هر دو پا)، و تصور حرکت (با همان چهار کلاس). داده‌ها از طریق یک کلاسه EEG با ۶۴ کانال و با نرخ نمونه‌برداری ۱۶۰ هرتز جمع‌آوری شده‌اند.

برای اهداف این مطالعه، چهار کلاس از داده‌ها انتخاب شد: تصور حرکت مشت راست، مشت چپ، هر دو پا، و حالت استراحت با چشم‌های باز. هر شرکت‌کننده تقریباً ۸۴ آزمایش ارائه داده که شامل ۲۱ آزمایش برای هر یک از این چهار کلاس است. در کلاس‌های تصور حرکت، هر آزمایش ۶ ثانیه طول داشته که شامل ۲ ثانیه استراحت و ۴ ثانیه اجرای وظیفه است. در این مطالعه، تنها ۲ ثانیه ابتدایی از دوره اجرای تکلیف برای تحلیل مورد استفاده قرار گرفت. شرکت‌کنندگانی که تعداد آزمایش‌هایشان کمتر از ۸۴ بود، از تحلیل حذف شدند. در نهایت، داده‌های مربوط به ۱۰۵ شرکت‌کننده برای مراحل بعدی تحلیل به کار گرفته شد.

۳-۳- پیاده‌سازی و ارزیابی مدل پیشنهادی

فرآیند پیاده‌سازی مدل‌ها با استفاده از کتابخانه‌های Keras و TensorFlow در محیط Python 3.10 انجام شد. اجرای مدل‌ها در بستر Google Colab Pro صورت گرفت که از ۳۵ گیگابایت حافظه RAM و یک واحد پردازش گرافیکی NVIDIA T4 GPU بهره می‌برد.

برای مدل ترنسفورمر، کلیه آزمایش‌ها از تمامی شرکت‌کنندگان گردآوری و سپس به صورت تصادفی درهم آمیخته شدند. مجموعه داده حاصل به سه بخش تقسیم شد: ۷۳ درصد برای آموزش، ۱۰ درصد برای اعتبارسنجی و ۱۷ درصد برای آزمون نهایی. این مدل بر پایه طبقه‌بندی در سطح گروه آموزش دید. در مقابل، مدل EEGNet نیز با رویکرد طبقه‌بندی گروهی، اما با استفاده از اعتبارسنجی متقاطع پنج‌فولدی (5-fold cross-validation) آموزش داده شد. در هر فولد، داده‌های مربوط به ۸۴ شرکت‌کننده جهت آموزش و داده‌های ۲۱ شرکت‌کننده باقی‌مانده برای آزمون به کار گرفته شدند. میانگین صحت به دست آمده در طول این پنج فولد به عنوان صحت نهایی مدل گزارش گردید. جزئیات مربوط به تنظیمات و مقادیر هایپر پارامترهای به کاررفته برای هر دو مدل در جدول ۳ ارائه شده‌اند.

(Convolution) در امتداد محور زمان اعمال می‌شود تا الگوهای فرکانسی اولیه (مانند ریتم‌های مغزی در باندهای مختلف) را شناسایی کند؛ این لایه عملکردی مشابه فیلترهای باند-گذر دارد.

جدول ۱- معماری دقیق مدل ترنسفورمر

نوع لایه	ابعاد خروجی	تعداد پارامترها
ورودی	۳۲۰,۶۴	-
ترنسفورمر	۳۲۰,۶۴	۲۶۵,۵۳۶
ترنسفورمر	۳۲۰,۶۴	۲۶۵,۵۳۶
نرمال‌سازی لایه	۳۲۰,۶۴	۱۲۸
Flatten	۲۰۴۸۰	-
Dropout	۲۰۴۸۰	-
Dense	۱۶	۳۲۷,۶۹۶
Dense	۴	۶۸

در مرحله دوم، از کانولوشن عمقی-فضایی (Depthwise Spatial Convolution) بهره گرفته می‌شود که در امتداد کانال‌ها اعمال شده و هدف آن استخراج الگوهای مکانی مرتبط با فعالیت‌های مغزی است. برخلاف کانولوشن معمول، در این لایه برای هر فیلتر مکانی، فقط یک کانال به صورت مستقل پردازش می‌شود، که ضمن کاهش تعداد پارامترها، به مدل اجازه می‌دهد ویژگی‌های فضایی هر کانال را به خوبی بیاموزد. سپس، یک لایه کانولوشن قابل تفکیک عمقی (Depthwise Separable Convolution) برای ترکیب اطلاعات مکانی و زمانی به کار می‌رود. این لایه از دو بخش تشکیل شده است: ابتدا یک کانولوشن عمقی (Depthwise) که برای هر کانال جداگانه اعمال می‌شود، و سپس یک کانولوشن نقطه‌ای (Pointwise) که ترکیب ویژگی‌های استخراج شده از کانال‌های مختلف را انجام می‌دهد. این ساختار منجر به استخراج ویژگی‌های سطح بالاتر و کاهش چشمگیر تعداد پارامترها می‌شود.

هر یک از این لایه‌ها با نرمال‌سازی دسته‌ای (Batch Normalization) همراه شده‌اند تا پایداری آموزش و سرعت همگرایی مدل افزایش یابد. در انتها، یک لایه کاملاً متصل به همراه تابع فعال‌سازی Softmax، طبقه‌بندی نهایی سیگنال EEG را انجام می‌دهد. معماری دقیق این مدل در جدول ۲ ارائه شده است.

۳-۲- مجموعه داده

در این پژوهش از مجموعه داده PhysioNet بهره گرفته شد که شامل داده‌های EEG ثبت شده از ۱۰۹ شرکت‌کننده

جدول ۲- معماری دقیق مدل EEGNet

تعداد پارامترها	ابعاد خروجی	هسته	پدینگ	تعداد فیلتر	لایه
۰	۱,۳۲۰,۶۴	-	-	-	ورودی
۱۰۲۴	۸,۳۲۰,۶۴	۱۲۸,۱	same	۸	کانولوشن ۲ بعدی
۲۵۶	۸,۳۲۰,۶۴	۱,۶۴	-	-	نرمال سازی دسته ای
۱۰۲۴	۱۶,۳۲۰,۱	-	valid	۱۶	کانولوشن عمقی
۴	۱۶,۳۲۰,۱	-	-	-	نرمال سازی دسته ای
۰	۱۶,۳۲۰,۱	-	-	-	فعال سازی
۰	۱۶,۴۰,۱	۸,۱	valid	-	میانگین گیری ۲ بعدی
۰	۱۶,۴۰,۱	-	-	-	Dropout
۵۱۲	۱۶,۴۰,۱	۱۶,۱	same	۱۶	کانولوشن قابل تفکیک
۴	۱۶,۴۰,۱	-	-	-	نرمال سازی دسته ای
۰	۱۶,۴۰,۱	-	-	-	فعال سازی
۰	۱۶,۵,۱	۸,۱	valid	-	میانگین گیری ۲ بعدی
۰	۱۶,۵,۱	-	-	-	Dropout
۰	۸۰	-	-	-	flatten
۳۲۴	۴	-	-	-	dense
۰	۴	-	-	-	softmax

طریق ترنسفورمر و ویژگی های مکانی میان کانال های EEG از طریق EEGNet است.

یکی از مزیت های بارز این ساختار، توانایی آن در ارائه عملکرد قابل قبول تنها با ۲ ثانیه از داده هر تریال است؛ امری که اهمیت زیادی برای کاربردهای زمان واقعی در سامانه های BCI دارد. جدول ۴ نشان دهنده عملکرد مدل ها در این مطالعه است.

جدول ۴- نتایج روش پیشنهادی

مدل	EEGNet	ترنسفورمر	مدل پیشنهادی
صحت (%)	۶۵/۰۷	۶۱/۹۲	۶۶/۹

جزئیات نتایج در جدول ۴ ارائه شده است. ابتدا عملکرد مدل EEGNet با شرایط مشابه مطالعه [۲۶] که از ۴ ثانیه داده در هر تریال استفاده کرده بود، بازتولید شد. سپس مدل ترنسفورمر به تنهایی بر روی داده های خام آموزش داده شد و دقت آزمون و منحنی های اعتبارسنجی آن بررسی گردید. اگرچه عملکرد مستقل ترنسفورمر رضایت بخش نبود، اما پس از پیش آموزش مدل ترنسفورمر و اعمال آن بر کل مجموعه داده، ویژگی های زمانی غنی شده ای استخراج شد که در مرحله بعد به عنوان ورودی به مدل EEGNet داده شد. این بهبود در دقت، بدون افزایش زمان ثبت

جدول ۳- مقادیر هابیر پارامترهای مدل های ترنسفورمر و EEGNet

پارامتر	ترنسفورمر	EEGNet
نرخ یادگیری	1×10^{-5}	LearningRateScheduler
اندازه بچ	۲۰	۵۱۲
تعداد اپوک ها	۳۰۰	۲۰۰
تعداد سرها	۱۶	-
Dropout of multi-head attention	۰/۱	-
Dropout	۰/۵	۰/۲
پارامتر تنظیم	-	۰/۲۵

۴- نتایج و بحث

۴-۱- ارزیابی مدل پیشنهادی

نتایج تجربی حاصل از پیاده سازی مدل پیشنهادی نشان می دهد که ترکیب ترنسفورمر و EEGNet به صورت دو مرحله ای، عملکرد بهتری نسبت به استفاده مستقل از هر یک از این معماری ها ارائه می دهد. با آن که صحت مدل ترنسفورمر به تنهایی کمتر از EEGNet بود، استفاده از آن برای استخراج ویژگی های زمانی و انتقال این ویژگی های غنی شده به EEGNet منجر به بهبود قابل توجه دقت نهایی شد. این یافته مؤید کارآمدی طراحی ترکیبی برای بهره برداری همزمان از وابستگی های زمانی بلندمدت از

۳-۴- محدودیت‌های مطالعه

با وجود مزایای فوق، مطالعه حاضر با چند محدودیت روبرو است:

- ساختار دومرحله‌ای: استفاده جداگانه از دو مدل ترنسفورمر و EEGNet و پیاده‌سازی یک فرآیند استخراج ویژگی و سپس طبقه‌بندی، موجب افزایش پیچیدگی فنی و زمان اجرای کلی نسبت به معماری‌های end-to-end شده است، که استفاده این سامانه را برای کاربردهای زمان واقعی با محدودیت مواجه می‌کند.
- عملکرد مستقل ضعیف‌تر ترنسفورمر: نتایج نشان می‌دهند که ترنسفورمر به‌تنهایی از نظر صحت ضعیف‌تر از EEGNet عمل کرده و برای بهره‌وری مؤثر نیازمند ترکیب با مدل‌های مکمل است.
- مقایسه دشوار با برخی مدل‌های دودسته‌ای: برخی مطالعات دارای صحت بالاتری هستند، اما در شرایط ساده‌تر (دو کلاس و تریال‌های طولانی‌تر) ارزیابی شده‌اند، که محدودیت‌هایی برای مقایسه مستقیم ایجاد می‌کند.

۴-۴- پیشنهادات برای مطالعات آتی

با وجود بهره‌گیری از ترنسفورمر کلاسیک در این مطالعه، سایر معماری‌های مبتنی بر یادگیری توالی نیز می‌توانند در تحلیل داده‌های EEG مورد ارزیابی قرار گیرند. به‌ویژه، مدل‌هایی مانند LSTM، RNN و BiLSTM که پیش‌تر در طبقه‌بندی سیگنال‌های EEG به‌کار گرفته شده‌اند، دارای ظرفیت‌هایی در مدل‌سازی ساختارهای زمانی هستند. با این حال، ویژگی‌هایی همچون پردازش موازی، مدل‌سازی وابستگی‌های بلندمدت و استقلال از ترتیب زمانی، ترنسفورمر را به گزینه‌ای مناسب برای سامانه‌های BCI تبدیل کرده است. در ادامه این مسیر، بهره‌گیری از نسخه‌های پیشرفته‌تر نظیر Informer با پیچیدگی زمانی بهینه برای توالی‌های بلند [۴۰]، Performer با حافظه کارا در سازوکار توجه [۴۱] و Longformer قابل مقیاس‌پذیر برای توالی‌های بسیار طولانی [۴۲] پیشنهاد می‌شود. استفاده از این مدل‌ها می‌تواند به افزایش دقت طبقه‌بندی و کاهش هزینه محاسباتی در کاربردهای زمان واقعی منجر شود.

سیگنال، مزیتی مهم در سناریوهای عملیاتی واقعی محسوب می‌شود، به‌ویژه در مقایسه با مطالعاتی که برای دستیابی به دقت‌های مشابه از تریال‌هایی با طول ۳ تا ۴ ثانیه استفاده کرده‌اند.

۲-۴- مقایسه با مدل‌های پیشرفته اخیر

در این مطالعه، برخلاف اغلب پژوهش‌های پیشین که در سطح درون‌آزمودنی ارزیابی شده‌اند، سناریوی میان‌آزمودنی به‌کار گرفته شده است که با وجود پیچیدگی بیشتر، برای کاربردهای واقعی BCI مناسب‌تر است. همچنین از مجموعه داده‌ی استاندارد PhysioNet استفاده شده تا مقایسه مستقیم و عادلانه با دیگر مدل‌ها فراهم گردد. در جدول ۵، نتایج مدل پیشنهادی با مطالعات منتخب که همگی از همین مجموعه داده استفاده کرده‌اند، مقایسه شده است. با وجود استفاده از تریال‌های کوتاه‌تر، مدل پیشنهادی صحت بالاتری نسبت به EEGNet [۳۸]، Transformer-CNN [۳۱] و ConTraNet [۱۰] نشان داد. اگرچه صحت مدل پیشنهادی نسبت به روش‌هایی مانند Fusion V2 EEGNet [۳۰] و ترکیب ویژگی‌های فرکتالی و روش‌های یادگیری ماشین [۳۹] کمتر است، اما باید توجه داشت که این مطالعات صرفاً در حالت دودسته‌ای و با طول تریال طولانی‌تر اجرا شده‌اند. حتی در مطالعه [۳۹]، از اطلاعات تنها ۲۰ آزمودنی با طیف توان مناسب، استفاده شده است و مابقی آزمودنی‌ها کنار گذاشته شده‌اند. نقاط قوت مدل پیشنهادی:

- کارایی در شرایط با داده کوتاه‌تر: دستیابی به دقت ۶۶/۹ درصد تنها با ۲ ثانیه داده در یک وظیفه چهارکلاسه میان‌آزمودنی، کارایی مدل را برای کاربردهای زمان واقعی افزایش می‌دهد.
- ترکیب مؤثر اطلاعات زمانی و مکانی: استفاده از ترنسفورمر برای استخراج ویژگی‌های زمانی و EEGNet برای ویژگی‌های مکانی، به بهره‌برداری هم‌زمان از ابعاد کلیدی سیگنال EEG منجر شده است.
- عملکرد رقابتی نسبت به مدل‌های با شرایط مشابه: با وجود محدودیت زمانی تریال، مدل پیشنهادی صحت بهتری نسبت به نسخه‌های پیشین EEGNet و حتی ترکیب‌های CNN و ترانسفورمر در حالت چهارکلاسه ارائه داده است.

جدول ۵- مقایسه نتایج طبقه‌بندی با روش‌های پیشرفته اخیر

مطالعه	سال	تعداد شرکت‌کنندگان	روش طبقه‌بندی	تعداد کلاس‌ها	مدت زمان آزمایش (ثانیه)	نوع داده ورودی	صحت (%)
[۳۱]	۲۰۲۲	۱۰۹	Transformer-CNN	۳	۳	داده خام	۷۴/۴۴
[۳۰]	۲۰۲۳	۱۰۳	EEGNet Fusion V2	۲	۴	داده پردازش‌شده	۸۷/۸۰
[۳۸]	۲۰۲۰	۱۰۵	EEGNet	۴	۳	داده خام	۶۵/۰۷
[۳۹]	۲۰۲۴	۲۰	ترکیب ویژگی‌های مبتنی بر بعد فرکتال و یادگیری ماشین	۲	۴	داده پردازش‌شده	۸۶/۰۰
[۱۰]	۲۰۲۴	۱۰۵	ConTraNet (CNN-Transformer)	۳	۴	داده خام	۷۴/۳۸
روش پیشنهادی	-	۱۰۵	Transformer-EEGNet	۴	۲	داده خام	۶۶/۹۰

۵- نتیجه‌گیری

در این پژوهش، یک چارچوب طبقه‌بندی نوین برای تحلیل سیگنال‌های تصور حرکت مبتنی بر EEG ارائه شد که از ترکیب دو معماری مکمل، شامل ترنسفورمر در نقش کدگذار و مدل EEGNet به‌عنوان طبقه‌بند، بهره می‌گیرد. این ساختار ترکیبی با هدف بهره‌برداری هم‌زمان از ظرفیت ترنسفورمر در مدل‌سازی وابستگی‌های زمانی بلندمدت و توانایی EEGNet در استخراج مؤلفه‌های فضایی طراحی شده است. نتایج تجربی نشان دادند که مدل پیشنهادی، حتی با استفاده از بازه زمانی کوتاه‌تر (۲ ثانیه)، نسبت به مدل‌های شناخته‌شده‌ای همچون EEGNet یا حتی مدل‌های ترکیبی ترانسفورمر و CNN عملکرد بهتری ارائه می‌دهد. این موضوع نه‌تنها کارآمدی الگوریتم پیشنهادی را در استخراج ویژگی‌های غنی و معنادار نشان می‌دهد، بلکه پتانسیل بالای آن را برای به‌کارگیری در سامانه‌های رابط مغز-رایانه زمان‌واقعی تأیید می‌کند.

در مجموع، یافته‌های این مطالعه بیانگر آن است که طراحی مدل‌های هیبریدی با بهره‌گیری هدفمند از معماری‌های مکمل، رویکردی مؤثر برای بهبود دقت طبقه‌بندی سیگنال‌های EEG در شرایط واقعی است. در ادامه، می‌توان

مسیرهای آتی را بر بهینه‌سازی ساختار مدل، ارزیابی عملکرد در مجموعه‌داده‌های متنوع، و بهره‌گیری از نسخه‌های پیشرفته‌تر معماری‌های ترنسفورمر متمرکز کرد.

تأییدیه اخلاقی

نویسندگان متعهد میشوند که مطالب این مقاله را در هیچ مجله دیگری به چاپ نرسانده‌اند.

مشارکت‌های نویسندگان

خانم آرزو حمیدی: ایده، پیاده‌سازی، نوشتن نسخه ابتدایی مقاله، ویرایش، ارائه نتایج

دکتر کوروش کیانی: ایده، نظارت، ویرایش، بررسی نتایج، اصلاحات

دکتر راضیه راستگو: نظارت، ویرایش، بررسی نتایج، اصلاحات

منابع مالی

این پژوهش از هیچ منبع تامین مالی دولتی، تجاری یا غیرانتفاعی، کمک مالی خاصی دریافت نکرده است.

تعارض منافع

نویسندگان اعلام می‌دارند که هیچ گونه تضاد منافع ندارند. دکتر راضیه راستگو، یکی از نویسندگان در این مقاله، کمک

سرمدبیر و مدیر داخلی فعلی مجله مدل‌سازی در مهندسی است، اما هیچ دخالتی در فرآیند ارزیابی این مقاله نداشته است. فرآیند داوری این مقاله توسط دکتر محمد دانایی، یکی از دبیران در مجله مذکور مدیریت شد.

مراجع

- [1] Maiseli, Baraka, Abdi T. Abdalla, Libe V. Massawe, Mercy Mbise, Khadija Mkocha, Nassor Ally Nassor, Moses Ismail, James Michael, and Samwel Kimambo. "Brain-computer interface: trend, challenges, and threats." *Brain informatics* 10, no. 1 (2023): 20.
- [2] Saha, Simanto, Khondaker A. Mamun, Khawza Ahmed, Raqibul Mostafa, Ganesh R. Naik, Sam Darvishi, Ahsan H. Khandoker, and Mathias Baumert. "Progress in brain computer interface: Challenges and opportunities." *Frontiers in systems neuroscience* 15 (2021): 578875.
- [3] Mishra, Shubhra, Osama Mahmudi, and Amin Jalali. "Motor imagery signal classification using adversarial learning: A systematic literature review." *IEEE Access* 12 (2024): 91053-91074.
- [4] Xu, Fangzhou, Yitai Lou, Yunqing Deng, Zhixiao Lun, Pengcheng Zhao, Di Yan, Zhe Han et al. "Motor imagery EEG decoding based on TS-former for spinal cord injury patients." *Brain Research Bulletin* 224 (2025): 111298.
- [5] Xu, Xiaoqi, Nicolas Drougard, and Raphaëlle N. Roy. "Does topological data analysis work for EEG-based brain-computer interfaces?." *Journal of Neural Engineering* 22, no. 3 (2025): 036026.
- [6] Zhang, Jing, Xuxu Yang, Zilin Liang, Huanzhi Lou, Tong Cui, Cheng Shen, and Zhijun Gao. "A brain-computer interface system for lower-limb exoskeletons based on motor imagery and stacked ensemble approach." *Review of Scientific Instruments* 96, no. 1 (2025).
- [7] Al-Saegh, Ali, Shefa A. Dawwd, and Jassim M. Abdul-Jabbar. "Deep learning for motor imagery EEG-based classification: A review." *Biomedical Signal Processing and Control* 63 (2021): 102172.
- [8] Zarbafi, Sahar, Kourosh Kiani, and Razieh Rastgoo. "Spoken Persian digits recognition using deep learning." *Journal of Modeling in Engineering* 21, no. 74 (2023): 163-172.
- [9] Anwar, Ayman, Yassin Khalifa, James L. Coyle, and Ervin Sejdic. "Transformers in biosignal analysis: A review." *Information Fusion* 114 (2025): 102697.
- [10] 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.
- [11] Vafaei, Elnaz, and Mohammad Hosseini. "Transformers in EEG Analysis: A review of architectures and applications in motor imagery, seizure, and emotion classification." *Sensors* 25, no. 5 (2025): 1293.
- [12] Bagherzadeh, Fahimeh, and Razieh Rastgoo. "Deepfake image detection using a deep hybrid convolutional neural network." *Journal of Modeling in Engineering* 21, no. 75 (2023): 19-28.
- [13] 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): 103-111.
- [14] Alinezhad, Fatemeh, Kourosh Kiani, and Razieh Rastgoo. "A Deep Learning-based Model for Gender Recognition in Mobile Devices." *Journal of AI and Data Mining* 11, no. 2 (2023): 229-236.
- [15] Li, Duan, Keyun Li, Yongquan Xia, Jianhua Dong, and Ronglei Lu. "Joint hybrid recursive feature elimination based channel selection and ResGCN for cross session MI recognition." *Scientific Reports* 14, no. 1 (2024): 23549.
- [16] Deng, Xin, Daijiang Xu, Huaxiang Huo, Xinyi Hong, and Bin Liu. "Multi-level hierarchical dynamic graph convolutional networks for motor imagery EEG analysis." *Neurocomputing* 626 (2025): 129594.
- [17] Hamidi, Arezoo, and Kourosh Kiani. "Motor Imagery EEG signals classification using a Transformer-GCN approach." *Applied Soft Computing* 170 (2025): 112686.
- [18] Shi, Ji, Jiaming Tang, Zhihuan Lu, Ruolin Zhang, Jun Yang, Qiuquan Guo, and Dongxing Zhang. "A brain topography graph embedded convolutional neural network for EEG-based motor imagery classification." *Biomedical Signal Processing and Control* 95 (2024): 106401.
- [19] Wu, Yelan, Pugang Cao, Meng Xu, Yue Zhang, Xiaoqin Lian, and Chongchong Yu. "Adaptive GCN and Bi-GRU-Based Dual Branch for Motor Imagery EEG Decoding." *Sensors* 25, no. 4 (2025): 1147.

- [20] Chen, Yuanling, Peisen Liu, and Duan Li. "MST-DGCN: A multi-scale spatio-temporal and dynamic graph convolution fusion network for electroencephalogram recognition of motor imagery." *Electronics* 13, no. 11 (2024): 2174.
- [21] Kabir, Md Humaun, Shabbir Mahmood, Abdullah Al Shiam, Abu Saleh Musa Miah, Jungpil Shin, and Md Khademul Islam Molla. "Investigating feature selection techniques to enhance the performance of EEG-based motor imagery tasks classification." *Mathematics* 11, no. 8 (2023): 1921.
- [22] Lin, Ruijing, Chaoyi Dong, Peng Zhou, Pengfei Ma, Shuang Ma, Xiaoyan Chen, and Huanzi Liu. "Motor imagery EEG task recognition using a nonlinear Granger causality feature extraction and an improved Salp swarm feature selection." *Biomedical Signal Processing and Control* 88 (2024): 105626.
- [23] Fan, Chengcheng, Banghua Yang, Xiaou Li, and Peng Zan. "Temporal-frequency-phase feature classification using 3D-convolutional neural networks for motor imagery and movement." *Frontiers in Neuroscience* 17 (2023): 1250991.
- [24] Djamal, E. C., and R. D. Putra. "Brain-computer interface of focus and motor imagery using wavelet and recurrent neural networks." *Telkomnika* 18, no. 5 (2020): 2748–2756.
- [25] Fahimi, Fatemeh, Strahinja Dosen, Kai Keng Ang, Natalie Mrachacz-Kersting, and Cuntai Guan. "Generative adversarial networks-based data augmentation for brain-computer interface." *IEEE transactions on neural networks and learning systems* 32, no. 9 (2020): 4039-4051.
- [26] 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.
- [27] Sharma, Neha, Avinash Upadhyay, Manoj Sharma, and Amit Singhal. "Deep temporal networks for EEG-based motor imagery recognition." *Scientific Reports* 13, no. 1 (2023): 18813.
- [28] Zhang, Dongxue, Huiying Li, and Jingmeng Xie. "MI-CAT: A transformer-based domain adaptation network for motor imagery classification." *Neural Networks* 165 (2023): 451-462.
- [29] Huang, Yuxuan, Jianxu Zheng, Binxing Xu, Xuhang Li, Yu Liu, Zijian Wang, Hua Feng, and Shiqi Cao. "An improved model using convolutional sliding window-attention network for motor imagery EEG classification." *Frontiers in Neuroscience* 17 (2023): 1204385.
- [30] 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.
- [31] 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.
- [32] Zhang, Jiayang, Kang Li, Banghua Yang, and Zhengrun Zhao. "Cross-dataset motor imagery decoding—A transfer learning assisted graph convolutional network approach." *Biomedical Signal Processing and Control* 102 (2025): 107213.
- [33] Shirodkar, Vaishali, Damodar Reddy Edla, and Annu Kumari. "Generative Adversarial Networks for Motor Imagery Classification using Wavelet Packet Decomposition and Complex Morlet Transform." *Multimedia Tools and Applications* (2025): 1-24.
- [34] Esfandiari, Nura, Kourosh Kiani, and Razieh Rastgoo. "A conditional generative chatbot using transformer model." *Journal of Modeling in Engineering* 23, no. 82 (2025): 99–113.
- [35] Esfandiari, Nura, Kourosh Kiani, and Razieh Rastgoo. "Transformer-based generative chatbot using reinforcement learning." *Journal of AI and Data Mining* 12, no. 3 (2025): 349–358.
- [36] Ahmadi, Amir Mohammad, Kourosh 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.
- [37] 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.
- [38] Wang, Xiaying, Michael Hersche, Batuhan Tömekce, Burak Kaya, Michele Magno, and 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)*, pp. 1-6. IEEE, 2020.

- [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] Xie, Xin, Feng Huang, Yefeng Long, Youyuan Peng, and Wenjuan Zhou. "An optimized informer model design for electric vehicle SOC prediction." *PloS one* 20, no. 3 (2025): e0314255.
- [41] Esfandiari, Nura, Kouros Kiani, and Razieh Rastgoo. "A conditional generative chatbot using transformer model." *Neural Computing and Applications* (2025): 1–32.
- [42] Sun, Dan, Jacky He, Hanlu Zhang, Zhen Qi, Hongye Zheng, and Xiaokai Wang. "A LongFormer-Based Framework for Accurate and Efficient Medical Text Summarization." In *2025 8th International Conference on Advanced Algorithms and Control Engineering (ICAACE)*, pp. 1527-1531. IEEE, 2025.