

Research Article

An Attention-Based Bi-LSTM Architecture for Distinct Temporal Feature Extraction in EEG-Based Motor Imagery Classification

Seyyed Mahdi Ghezi¹  | Hesam Hasanpour^{2*}  | Yasser Elmi³ 

¹Department of Computer Engineering and Information Technology, Islamic Azad University, Sabzevar Branch, Sabzevar, Iran, S.ghezi@iau.ac.ir

²Department of Computer Engineering and Information Technology, Islamic Azad University, Sabzevar Branch, Sabzevar, Iran, Hesamhasanpour@iau.ac.ir

³Department of Computer Engineering and Information Technology, Islamic Azad University, Sabzevar Branch, Sabzevar, Iran, Yasser.elmi@iau.ac.ir

Correspondence

*Hesam Hasanpour, Assistant Professor, Department of Computer Engineering and Information Technology, Islamic Azad University, Sabzevar Branch, Sabzevar, Iran, Hesamhasanpour@iau.ac.ir

Main Subjects: Feature Extraction**Received:** 8 August 2025**Revised:** 17 August 2025**Accepted:** 7 September 2025**Abstract**

Motor Imagery (MI)-based Brain-Computer Interfaces (BCIs) rely heavily on the precise extraction of discriminative features from EEG signals, which are inherently non-stationary and complex in temporal dynamics. In this study, we propose an advanced deep learning model based on a Bidirectional Long Short-Term Memory (Bi-LSTM) architecture integrated with an attention mechanism to enhance the performance of MI classification tasks. The proposed model is designed to automatically extract and weigh temporal features across both forward and backward time directions, allowing the network to focus on the most informative EEG segments related to MI tasks.

We evaluated our model using the BCI Competition IV-2a dataset, comprising four MI classes across nine subjects. A stratified 5-fold cross-validation approach was employed, with each fold split into 40% training, 20% validation, and 40% testing sets. The proposed Attention-Bi-LSTM model achieved an average accuracy of $91.2\% \pm 3.5$, F1-score of $91.1\% \pm 3.6$, and Cohen's kappa of 0.883 ± 0.04 , outperforming baseline CNN and LSTM models. Additionally, performance was analyzed separately across all four MI classes, highlighting the model's ability to generalize across different cognitive motor tasks.

The results indicate that incorporating attention with Bi-LSTM substantially improves the model's focus on discriminative EEG patterns, making it a promising architecture for robust and scalable EEG-based MI classification in real-world BCI applications.

<https://doi.org/10.82195/ntds.2025.1214039>

Keywords: Motor Imagery (MI), Brain-Computer Interface (BCI), EEG Signal Classification, Attention Mechanism, Bidirectional LSTM (Bi-LSTM), Deep Learning, Temporal Feature Extraction, MI-BCI

یک معماری Bi-LSTM مبتنی بر مکانیزم توجه برای استخراج ویژگی های زمانی متمايز در طبقه بندی تصویر سازی حرکتی مبتنی بر سیگنال های EEG

سید مهدی قزی^۱ | حسام حسن پور^{۲*} | یاسر علمی سولا^۳

چکیده:

واسطه های مغز-کامپیوتر (BCI) مبتنی بر تصویر سازی حرکتی (MI) ابزارهای نوینی برای بازگرداندن توانایی های ارتباطی و کنترلی به افراد با ناتوانی های حرکتی شدید هستند. با این حال، موفقیت آن ها به کیفیت استخراج ویژگی از سیگنال های الکتروانسفالوگرافی وابسته است. ماهیت غیرایستا، غیرخطی و پرنویز سیگنال های مذکور فرایند جداسازی الگوهای متمایز را دشوار می سازد. در این پژوهش، معماری یادگیری عمیق سرتاسری مبتنی بر شبکه حافظه طولانی کوتاه مدت دوطرفه (Bi-LSTM) همراه با مکانیزم توجه زمانی^۱ برای طبقه بندی وظایف تصور حرکتی پیشنهاد شده است. برخلاف مدل های بازگشتی معمول که همه گام های زمانی را به طور یکنواخت پردازش می کنند، مکانیزم توجه توانایی تمرکز پویا بر بازه های زمانی حاوی اطلاعات کلیدی مانند پدیده های گذرا^۲ را فراهم می آورد. عملکرد مدل با استفاده از مجموعه داده BCI Competition IV Dataset 2a شامل ۲۵۹۲ نمونه از ۹ آزمودنی در چهار وظیفه تصور حرکتی ارزیابی و با دو معماری مرجع شامل شبکه عصبی کانولوشنی^۳ بهینه سازی شده و LSTM استاندارد مقایسه شد. نتایج نشان داد مدل Attention-Bi-LSTM با میانگین دقت طبقه بندی $91.2\% \pm 3.5\%$ ، عملکرد به مراتب بهتری نسبت به مدل های LSTM ($85.7\% \pm 4.1\%$) و CNN ($83.1\% \pm 4.8\%$) ارائه می دهد. ($p < 0.01$) همچنین، مصور سازی وزن های توجه نشان داد مدل قادر به شناسایی الگوهای زمانی همسو با

^۱ گروه مهندسی کامپیوتر و فن آوری اطلاعات، واحد سبزوار، دانشگاه آزاد اسلامی، سبزوار، ایران؛

S.ghezi@iau.ac.ir

^۲ گروه مهندسی کامپیوتر و فن آوری اطلاعات، واحد سبزوار، دانشگاه آزاد اسلامی، سبزوار، ایران؛

Hesamhasanpour@iau.ac.ir

^۳ گروه مهندسی کامپیوتر و فن آوری اطلاعات، واحد سبزوار، دانشگاه آزاد اسلامی، سبزوار، ایران؛

Yasser.elmi@iau.ac.ir

نویسنده مسئول

*حسام حسن پور، استادیار، گروه مهندسی کامپیوتر و فناوری اطلاعات، واحد سبزوار، دانشگاه آزاد اسلامی، سبزوار، ایران، Hesamhasanpour@iau.ac.ir

عنوان اصلی: استخراج ویژگی

تاریخ دریافت: ۱۴ مرداد ۱۴۰۴

تاریخ بازنگری: ۲۶ مرداد ۱۴۰۴

تاریخ پذیرش: ۱۶ شهریور ۱۴۰۴

<https://doi.org/10.82195/ntds.2025.1214039>

فیزیولوژی مغز است. این یافته ها نشان می دهد ترکیب وابستگی های زمانی دوطرفه با مکانیزم توجه می تواند دقت و تفسیرپذیری سیستم های رابط مغز-کامپیوتر مبتنی بر تصور حرکتی را به طور چشمگیری ارتقا دهد.

کلمات کلیدی: تصویر سازی حرکتی، واسطه مغز-کامپیوتر، الکتروانسفالوگرافی، مکانیزم توجه، Bi-LSTM، یادگیری عمیق.

¹ Temporal attention

² ERD/ERS

³ Convolutional Neural Network (CNN)

۱. مقدمه

افزایش جمعیت سالمند و رشد شیوع بیماری های تحلیل برنده عصبی و آسیب های نخاعی، نیاز به فناوری های کمکی پیشرفته را بیش از پیش برجسته کرده است. در این میان، واسطه های مغز و رایانه به عنوان یکی از فناوری های نویدبخش، امکان برقراری ارتباط مستقیم بین مغز انسان و دستگاه های بیرونی را فراهم می سازند و به کاربران اجازه می دهند بدون نیاز به مسیرهای عصبی-عضلانی متداول، کنترل مؤثری بر محیط خود داشته است.

پارادایم تصویرسازی حرکتی، که طی آن کاربر تنها با تصور انجام یک حرکت، فعالیت مغزی مرتبط را فعال می کند، به دلیل شهودپذیری بالا و عدم نیاز به محرک خارجی، یکی از پرکاربردترین رویکردها در سیستم های کنترلی واسطه مغز-کامپیوتر به شمار می آید [۱]. فعالیت تصور حرکتی منجر به تغییرات مشخصی در قدرت باندهای فرکانسی خاص سیگنال های مغز عمدتاً μ و β در نواحی حسی-حرکتی مغز می شود. این تغییرات که به صورت کاهش یا افزایش هم زمانی وابسته به رویداد (ERD/ERS) ظاهر می شوند، حاوی اطلاعات کلیدی برای تمایز بین وظایف مختلف تصور حرکتی هستند [۲].

با این حال، تبدیل این الگوهای مغزی ظریف به فرمان های کنترلی قابل اعتماد با چالش هایی جدی مواجه است. سیگنال های الکتروانسفالوگرافی به شدت در معرض نویزهای مختلف (مانند پلک زدن و فعالیت عضلانی) قرار دارند و بین افراد و جلسات مختلف دچار تغییرپذیری زیادی هستند. روش های کلاسیک مانند الگوریتم الگوهای فضایی مشترک به همراه طبقه بندی های خطی، برای استخراج ویژگی نیازمند طراحی دستی دقیق و انتخاب حساس باندهای فرکانسی هستند که این امر فرآیند تحلیل را زمان بر و مستعد خطا می سازد [۳].

در مقابل، یادگیری عمیق تحولی بنیادین در تحلیل سیگنال مغزی ایجاد کرده است. معماری های یادگیری عمیق سرتاسری می توانند مستقیماً از داده های خام یا کم پیش پردازش شده، نمایش های سلسله مراتبی و بهینه ای از ویژگی ها را بیاموزند. شبکه های کانولوشنال، با الگوبرداری از ساختار قشر بینایی، در استخراج ویژگی های فضایی-زمانی موفق عمل کرده اند [۴]، اما میدان دید محدود لایه های کانولوشنال توانایی آن ها در مدل سازی وابستگی های زمانی بلندمدت - که در فرآیندهایی مانند تصور حرکتی حیاتی هستند - را محدود می سازد.

در سوی دیگر، شبکه های بازگشتی مانند LSTM، با استفاده از مکانیزم های گیت برای مقابله با محوشدگی گرادین، به طور خاص برای مدل سازی دنباله های زمانی طراحی شده اند [۵]. با این وجود، LSTM های سنتی تمامی گام های زمانی را با وزن یکسان پردازش می کنند، حال آن که اطلاعات حیاتی در سیگنال های تصور حرکتی معمولاً در بازه های زمانی خاصی متمرکز هستند. برای حل این مسئله، مکانیزم توجه به کار گرفته می شود که با ایجاد یک بردار زمینه وزن دار، به مدل امکان می دهد تمرکز خود را به طور پویا بر نواحی مهم تر متمرکز سازد [۶].

در این مقاله، ما معماری Attention-Bi-LSTM را برای طبقه بندی سیگنال های MI-EEG معرفی می کنیم. استفاده از Bi-LSTM امکان درک وابستگی های زمانی در هر دو جهت گذشته و آینده را فراهم می آورد، در حالی که مکانیزم توجه، تمرکز مدل را بر ویژگی های زمانی تمایزبخش تقویت می کند.

۲- مروری بر کارهای پیشین

استفاده از مدل های یادگیری عمیق به ویژه شبکه های عصبی بازگشتی^۱ و مکانیزم های توجه، پیشرفت چشمگیری در طبقه بندی سیگنال های تصویرسازی حرکتی مبتنی بر الکتروانسفالوگرافی ایجاد کرده است. این مدل ها به دلیل توانایی بالا در استخراج ویژگی های زمانی پیچیده و پویا از سیگنال های مغزی، مورد توجه گسترده قرار گرفته اند در همین راستا هانگ و همکاران در سال ۲۰۲۳ با بهره گیری از مدل های یادگیری عمیق برای تحلیل سیگنال های الکتروانسفالوگرافی یک چارچوب ترکیبی مبتنی بر شبکه عصبی کانولوشنال، Bi-LSTM و مکانیزم توجه برای طبقه بندی احساسات از روی سیگنال های مغزی ارائه کرده اند. این مدل به عنوان یک روش یادگیری عمیق سرتاسری، بدون نیاز به استخراج ویژگی های دستی، قادر است داده های خام را مستقیماً پردازش کرده و ویژگی های زمانی-مکانی مرتبط با حالات احساسی را به صورت خودکار استخراج نماید. در معماری پیشنهادی، شبکه های کانولوشنی ابتدا برای استخراج ویژگی های مکانی از سیگنال های چندکاناله به کار گرفته می شوند، سپس این ویژگی ها به یک لایه Bi-LSTM داده می شود تا وابستگی های زمانی دوطرفه میان داده ها مدل سازی گردد سپس در مرحله نهایی، مکانیزم توجه، نقش مهمی در تعیین وزن و اهمیت نسبی کانال های سیگنال های مورد نظر ایفا می کند و به مدل اجازه می دهد تا تمرکز بیشتری بر کانال های مؤثرتر داشته باشد. این ویژگی به افزایش تفسیرپذیری مدل نیز کمک کرده است. آزمایش ها بر روی پایگاه داده SEED نشان دادند که مدل یادشده در دو وظیفه طبقه بندی چندکلاسه (سه کلاس و

¹ Recurrent Neural Network (RNN)

چهار کلاس) به دقت میانگین قابل توجهی معادل ۹۹.۵۵٪ و ۹۹.۷۹٪ دست یافته است که به طور محسوسی بهتر از روش‌های پیشین عمل می‌کند. این پژوهش با تأکید بر کارایی ترکیب ساختارهای زمانی-مکانی و مکانیزم توجه در تحلیل سیگنال‌های مغزی، زمینه‌ساز الهام‌بخشی برای توسعه معماری‌های مشابه در حوزه‌هایی چون طبقه‌بندی تصویرسازی حرکتی نیز بوده است [۷].

ترکیب مکانیزم توجه و مدل‌های یادگیری عمیق به عنوان یک توسعه نوآورانه و هدفمند در تشخیص خودکار ناهنجاری‌های عصبی مورد توجه اما و همکاران در سال ۲۰۲۳ برای طراحی یک مدل ترکیبی مبتنی بر شبکه‌های کانالوشنال، Bi-LSTM و مکانیزم توجه برای طبقه‌بندی و پیش‌بینی صرع قرار گرفته است، هدف اصلی، استخراج ویژگی‌های مکانی-زمانی و تشخیص خودکار وضعیت‌های مغزی شامل سه وضعیت "نرمال"، "پیش‌ازحمله" و "حین حمله" بوده است. شبکه کانالوشنال به عنوان مرحله ی ابتدایی کار برای استخراج ویژگی‌های مکانی از کانال‌های مربوط به سیگنال‌های الکتروانسفالوگرافی طراحی شده و سپس، شبکه Bi-LSTM برای مدل‌سازی وابستگی‌های زمانی در دنباله‌های سیگنال استفاده شده است، مکانیزم توجه با وزن‌دهی خودکار به کانال‌های مؤثرتر، در فیلتر کردن اطلاعات غیرضروری و تمرکز بر کانال‌های مرتبط‌تر با وضعیت صرعی نقش کلیدی ایفا کرده است. این معماری، با وجود استفاده از پیش‌پردازش بسیار ساده (نرمال‌سازی)، توانسته است دقت میانگین ۹۴.۸۳٪ را در پایگاه داده CHB-MIT و دقت ۷۷.۶۲٪ را در مجموعه داده UCI برای وظایف طبقه‌بندی سه کلاسه و پنج کلاسه به دست آورد. نتایج نشان می‌دهد که ترکیب مؤثر ویژگی‌های زمانی و مکانی همراه با مکانیزم توجه می‌تواند در تحلیل و پیش‌بینی خودکار این سیگنال‌ها نقش بسزایی داشته باشد. اگرچه تمرکز اصلی این مدل بر پیش‌بینی صرع بوده، اما ساختار معماری آن به‌ویژه در استفاده هم‌زمان از Bi-LSTM و مکانیزم توجه، الگویی الهام‌بخش برای توسعه سامانه‌های رابط‌های واسط کامپیوتر و مغز مبتنی بر تصور حرکتی نیز محسوب می‌شود [۸].

بهره‌گیری از یادگیری عمیق در تحلیل سیگنال‌های مغزی با استفاده از ترکیب معماری تلفیقی و مکانیزم توجه برای تشخیص زودهنگام بیماری آلزایمر توسط خسروی و همکاران در سال ۲۰۲۴ مورد استفاده قرار گرفته شده در این پژوهش مدلی ترکیبی با نام CL-ATBiLSTM از تلفیق شبکه‌های کانولوشنی، Bi-LSTM مبتنی بر توجه، و بهینه‌سازی بیزی استفاده شده است. هدف تمایز بین بیماران آلزایمر، افراد با اختلال شناختی خفیف، و افراد سالم از طریق تحلیل سیگنال‌های الکتروانسفالوگرافی است. سیگنال‌ها با استفاده از تبدیل موجک گسسته به باندهای فرکانسی مختلف تجزیه شده و به تصاویر طیف‌نگاری در مرحله پیش‌پردازش تبدیل می‌شوند تا ویژگی‌های زمانی-فرکانسی مغز بهتر نمایان شوند. لایه‌های کانولوشنی برای استخراج ویژگی‌های مکانی، Bi-LSTM برای مدل‌سازی وابستگی‌های زمانی، و مکانیزم توجه برای تمرکز بر داده‌های بحرانی‌تر به کار گرفته شده‌اند. استفاده از بهینه‌سازی بیزی نیز موجب بهبود دقیق تنظیمات مدل و ارتقاء دقت آن شده است. این رویکرد، دقتی معادل ۹۶.۵۲٪ را روی مجموعه داده Figshare در دسته‌بندی سه‌گانه MCI، AD و افراد سالم کسب کرده و عملکردی برتر از بسیاری از الگوریتم‌های دوکلاسه متداول ارائه داده است. ویژگی بارز این تحقیق، توجه به مرحله MCI به عنوان پیش‌نشانگر بالقوه آلزایمر است که آن را برای کاربردهای بالینی با محوریت مداخله زودهنگام، بسیار ارزشمند کرده است. ساختار ترکیبی CL-ATBiLSTM و عملکرد دقیق آن، این مدل را به الگویی قابل تعمیم برای تحلیل سایر اختلالات عصبی مبتنی بر سیگنال‌های مغزی نیز تبدیل کرده است و نقش توجه در تقویت تمایزپذیری الگوهای زمانی مغزی را به‌خوبی برجسته می‌سازد [۹].

ترکیب شبکه حافظه طولانی کوتاه‌مدت دوطرفه (Bi-LSTM) و مکانیزم توجه زمانی به عنوان یک معماری مؤثر توسط مو و همکاران در سال ۲۰۲۱ در دانشگاه هانگ‌کونگ برای طبقه‌بندی سیگنال‌های الکتروانسفالوگرافی مورد استفاده قرار گرفته شده است. این مدل، با هدف بهبود طبقه‌بندی سیگنال‌های مغزی در وظایف ادراک بصری توسعه یافته که می‌تواند به‌طور مؤثری به ویژگی‌های پویای موجود در این گونه از سیگنال‌ها توجه کند، برخلاف روش‌های سنتی که اغلب فقط اطلاعات ایستا را مدنظر قرار می‌دهند در این رویکرد، شبکه Bi-LSTM قادر است اطلاعات زمانی را در هر دو جهت گذشته و آینده مدل‌سازی کند و با بهره‌گیری از مکانیزم توجه، مدل به‌صورت پویا بر بازه‌های زمانی تمرکز می‌کند که بیشترین اطلاعات تشخیصی را دارند از جمله پدیده‌های گذرای که در جریان تصور حرکتی یا ادراک بصری رخ می‌دهند. افزون بر این، استفاده از تابع فعال‌سازی Swish در معماری پیشنهاد شده، به بهبود همگرایی و کارایی مدل کمک کرده است. نتایج این پژوهش نشان می‌دهد که مدل Bi-LSTM مجهز به مکانیزم توجه توانسته دقت ۹۴.۱۵٪ را در طبقه‌بندی الکتروانسفالوگرافی‌های مربوط به تحریکات بصری کسب کند. این امر بیانگر آن است که استفاده از مکانیزم توجه در کنار مدل‌های دنباله‌ای مانند Bi-LSTM می‌تواند به طرز چشمگیری عملکرد رابط‌های مغز-رایانه را در پردازش سیگنال‌های پیچیده الکتروانسفالوگرافی ارتقا بخشد [۱۰].

مرحله‌بندی خواب از طریق پردازش سیگنال‌های الکتروانسفالوگرافی از دیگر مسیرهای پژوهشی است که با استفاده از روش نوآورانه ای مبتنی بر یادگیری عمیق توسط چن و همکاران در سال ۲۰۲۳ معرفی شده است که دارای معماری ترکیبی شامل شبکه‌های عصبی کپسولی

با مکانیزم خود توجهی و مدل Bi-LSTM است. مرحله بندی خواب، نقشی حیاتی در ارزیابی کیفیت خواب دارد و روش های دستی، پرهزینه و زمان بر هستند، اگرچه روش های یادگیری عمیق پیشرفت های قابل توجهی داشته اند اما بسیاری از آن ها در بهره برداری کامل از وابستگی های زمانی بین ویژگی های سیگنال مغزی ناکام مانده اند.

ویژگی های برجسته در ابتدا از سیگنال مذکور با استفاده از شبکه های عصبی پیچشی استخراج می شوند و در ادامه برای مدل سازی وابستگی های زمانی بین مراحل خواب، از Bi-LSTM استفاده می گردد که توانایی درک وابستگی دوطرفه در زمان را دارد و در گام سوم، از یک شبکه کپسولی مبتنی بر مسیر خود توجهی بهره گرفته می شود تا همبستگی های زمانی درونی میان ویژگی های استخراج شده را مجدداً رمزگذاری و بر اساس شباهت های زمانی اهمیت بندی کند. این رویکرد باعث افزایش تمایز بخشی بین کلاس های خواب می شود.

ارزیابی مدل روی دو مجموعه داده عمومی Sleep-EDF-39 و Sleep-EDF-153 با استفاده از دو کانال سیگنال های الکتروانسفالوگرافی تک کاناله Fpz-Cz و Pz-Oz صورت گرفته است. دقت کلی مدل به ترتیب ۸۵.۸٪ و ۸۳.۴٪ با مقادیر کاپای ۰.۸ و ۰.۷۷ گزارش شده که حاکی از عملکرد سطح بالای مدل در مقایسه با سایر روش ها است. این مدل نه تنها دقت بالایی دارد، بلکه زمینه را برای کاربرد گسترده تر شبکه های کپسولی در مرحله بندی خواب با سیگنال های مغزی تک کاناله فراهم می سازد [۱۱].

دقت پایین در تشخیص الگوهای سیگنال های الکتروانسفالوگرافی در سیستم های رابط مغز کامپیوتر به عنوان یک چالش عمده در بکارگیری تکنیک های یادگیری عمیق در پردازش سیگنال های مذکور بوده است و در سال ۲۰۲۵ مورد توجه لیا و همکاران قرار گرفته است که غلبه بر آن میتواند سهم ارزشمندی در توسعه و بکارگیری روش های یادگیری عمیق در اینگونه سیگنال های داشته باشد، برای غلبه بر این محدودیت، مدلی نوین با نام CIACNet معرفی گردیده که این معماری از یک شبکه ی دو-شاخه ای کانولوشنی برای استخراج ویژگی های غنی زمانی استفاده می کند و با به کارگیری ماژول توجه بهبود یافته (CBAM)، قدرت مدل در شناسایی ویژگی های متمایز را افزایش داده است. علاوه بر این، بهره گیری از شبکه ی کانولوشنی زمانی امکان استخراج ویژگی های سطح بالاتر در بُعد زمانی را فراهم ساخته و اتصال چندسطحی ویژگی ها موجب نمایش جامع تری از اطلاعات سیگنال شده است. نتایج آزمایش ها بر روی پایگاه های داده BCI و BCI IV-2a و BCI IV-2b نشان داده است که مدل پیشنهادی به دقت های ۸۵.۱۵٪ و ۹۰.۰۵٪ به همراه امتیاز کاپای ۰.۸۰ دست یافته است. تحلیل بیشتر نشان داد که حذف هر یک از بلوک های طراحی شده سبب افت عملکرد مدل می شود که نشان دهنده اهمیت هر بخش در افزایش دقت کلی است. یافته های این پژوهش نشان می دهد که معماری CIACNet علاوه بر بهبود دقت، هزینه محاسباتی پایینی داشته و از این رو، قابلیت کاربرد عملی در سیستم های MI-BCI برای توانبخشی و کنترل دستگاه های کمکی را دارد [۱۲]. این نتایج اهمیت توجه به استخراج ویژگی های ترکیبی و چندسطحی در ارتقای معماری های طبقه بندی الکتروانسفالوگرافی را برجسته می سازد اما باید توجه داشت کاربرد های مختلف این سیگنال ها از جمله شناسایی وظایف در چهارچوب تصور حرکتی ممکن است چالش های جدیدی را برای این گونه معماری ها در حفظ دقت عملکرد به همراه داشته باشد برای همین منظور و با هدف رفع چالش های اساسی مانند دقت پایین ناشی از محدودیت های تفکیک پذیری فضایی اینگونه سیگنال ها در سال ۲۰۲۴ میرزایی و همکاران چارچوبی نوآورانه ارائه کرده اند که ترکیبی از خود رمزگذار ConvLSTM و BiLSTM مبتنی بر مکانیزم توجه را شامل می شود. در این معماری، ConvLSTM به طور مؤثر الگوهای مکانی-زمانی سیگنال های مذکور را استخراج کرده و یک نمایش فشرده و نهفته تولید می کند سپس، AtBiLSTM با بهره گیری از مکانیزم توجه بر بخش های بحرانی سیگنال تمرکز کرده و با در نظر گرفتن وابستگی های زمانی دوسویه، دقت مدل در شناسایی وظایف تصور حرکتی را افزایش می دهد. نتایج تجربی بر روی مجموعه داده BCI Competition IV-2a نشان داده است که مدل پیشنهادی با دستیابی به دقت ۸۹.۷۰٪ و مقدار کاپای ۸۷.۹۶٪ عملکردی بهتر از بسیاری از روش های موجود دارد. همچنین، بررسی استفاده از تبدیل فوری کوتاه مدت حاکی از بهبود ۱۰.۹۱٪ در دقت طبقه بندی است [۱۳]. این نتایج نشان دهنده توانایی بالای معماری پیشنهادی در یادگیری نمایش های مؤثر و کاهش انحراف معیار نتایج است. در مجموع، این پژوهش نشان می دهد که چارچوب معرفی شده نه تنها محدودیت های طبقه بندی سیگنال های الکتروانسفالوگرافی تصور حرکتی را برطرف می کند، بلکه قابلیت تعمیم و کارایی بالاتری در توسعه سامانه های رابط مغز کامپیوتر دارد.

جدول شماره ۱: مزایا و معایب مطالعات پیشین و بیان راهکارها


Table 1: Advantages and limitations of previous studies, along with proposed solutions

مطالعه	معایب	مزایا	راهکار پیشنهادی
طبقه‌بندی احساسات از EEG پایگاه SEED Huang et al. (2023)	نیاز به تنظیم دقیق پارامترها برای پایگاه‌های داده مختلف	مدل end-to-end بدون نیاز به استخراج دستی ویژگی ترکیب CNN + Bi-LSTM + Attention برای استخراج ویژگی‌های زمانی-مکانی تفسیرپذیری بالا به واسطه توجه بر کانال‌ها	افزودن <i>temporal attention</i> در کنار <i>spatial attention</i> جهت تمرکز هم‌زمان بر زمان و کانال‌ها استفاده از <i>dual-attention Bi-LSTM</i> برای پوشش جامع‌تر ویژگی‌ها در دامنه EEG
تشخیص حملات صرع از EEG Ma et al. (2023)	عدم استفاده از ویژگی‌های فرکانسی عدم ارزیابی در وظایف BCI یا MII	عملکرد بالا با پیش‌پردازش ساده بهره‌گیری از <i>attention</i> برای وزن‌دهی کانال‌ها کارایی بالا در طبقه‌بندی سه کلاس	تلفیق Bi-LSTM با <i>attention</i> سلسله‌مراتبی برای تحلیل زمانی-فرکانسی-مکانی استفاده از Spectrogram یا DWT به‌عنوان ورودی به Bi-LSTM-Attention
تشخیص آلزایمر از EEG (CL-ATBiLSTM) Khosravi et al. (2024)	پیچیدگی بالا در پیاده‌سازی وابستگی به تبدیل DWT و تصویرسازی طیفی	بهره‌گیری از ویژگی‌های زمانی-فرکانسی بهینه‌سازی بیزی برای تنظیمات مدل تمایز مؤثر بین AD، MCI و CO	ساده‌سازی معماری با استفاده از <i>attention</i> سبک‌تر مثل <i>lightweight attention</i> استفاده از <i>attention</i> کانالی + زمانی برای جایگزینی بخشی از پیچیدگی موجد
طبقه‌بندی EEG ادراک بصری Mo et al. (2021)	عدم استفاده از ویژگی‌های مکانی (فقط دنباله زمانی) وابستگی به داده‌های بصری خاص	تمرکز پویا بر بازه‌های زمانی مهم با <i>attention</i> استفاده از تابع Swish برای بهبود یادگیری	افزودن CNN اولیه برای استخراج ویژگی‌های مکانی پیش از Bi-LSTM استفاده از Multi-head Attention جهت بهبود تعمیم در زمان‌های مختلف تحریک
مرحله‌بندی خواب با EEG Chen et al. (2023)	پیچیدگی زیاد <i>attention</i> و <i>routing</i> نیاز به داده زیاد عدم تعمیم‌پذیری روی کاربردهای BCI	ترکیب CNN + Bi-LSTM + Capsule + Self-Attention دقت بالا با داده تک‌کاناله	جایگزینی Capsule با Bi-LSTM <i>attention</i> -based جهت سادگی بیشتر استفاده از <i>attention</i> هم‌زمان روی اپوک و کانال برای مرحله‌بندی دقیق‌تر خواب
بهبود دقت تشخیص الگوها و طبقه‌بندی MI-EEG – Liao et al. (2025)	نیاز به ساختار پیچیده چندمأزولی؛ وابستگی به تنظیمات داده‌های رقابتی BCI	استخراج جامع ویژگی‌های زمانی و مکانی؛ بهبود دقت (۸۵.۱۵٪ و ۹۰.۰۵٪)؛ هزینه محاسباتی پایین؛ نقش مؤثر هر بلوک در عملکرد کلی	استفاده از معماری ترکیبی CNN دو شاخه CBAM + TCN + با اتصال چندسطحی ویژگی‌ها (CIACNet)
محدودیت‌های تفکیک‌پذیری فضایی در تصور حرکتی MI-EEG – Mirzaie et al. (2024)	نیاز به محاسبات بیشتر در بخش ConvLSTM؛ وابستگی به پیش‌پردازش فرکانسی (STFT)	بهبود چشمگیر دقت (۸۹.۷۰٪ و ۸۷.۹۶٪)؛ ارتقای ۱۰.۹۱٪ STFT؛ افزایش ۱۷.۷۴٪ با جایگزینی SVM با AtBiLSTM؛ تعمیم‌پذیری بالا و انحراف معیار پایین	بهره‌گیری از ConvLSTM بهره‌گیری از Autoencoder برای استخراج ویژگی‌های فشرده و AtBiLSTM برای مدل‌سازی وابستگی‌های دوسویه

در جمع‌بندی، اگرچه کارهای پیشین پایه‌های محکمی را بنا نهاده‌اند، اما پس از بررسی مزایا و معایب هر کدام به این درک از روش‌ها خواهیم رسید که همچنان شکافی در زمینه طراحی معماری‌هایی وجود دارد که به طور خاص برای استخراج ویژگی‌های زمانی متمایز^۱ بهینه‌سازی شده است (جدول شماره ۱). پژوهش حاضر با الهام از نقاط قوت مدل‌های Bi-LSTM و مکانیزم توجه، یک معماری جدید ارائه می‌دهد که هدف اصلی آن شناسایی و جداسازی دقیق آن دسته از الگوهای زمانی است که به صورت منحصربه‌فرد معرف هر کلاس تصویرسازی حرکتی هستند. برخلاف رویکردهای موجود که یک بردار زمینه کلی تولید می‌کنند، مدل ما به دنبال یادگیری مجموعه‌ای از ویژگی‌های زمانی تفکیک‌پذیر است تا هم دقت طبقه‌بندی و هم درک ما از دینامیک‌های عصبی زیربنایی فعالیت‌های حرکتی را بهبود بخشد.

۳- مواد و روش‌ها

مجموعه داده عمومی BCI Competition IV, Dataset 2a با توجه به ویژگی‌های منحصر به فرد خود در دقت اندازه‌گیری و انتخاب آزمودنی‌های مناسب به عنوان داده‌های مرجع برای بررسی روش پیشنهاد و انطباق آن نتایج با سایر پژوهش‌های انتخاب گردیده است، این مجموعه شامل داده‌های سیگنال‌های مغزی الکتروانسفالوگرافی ثبت‌شده از ۹ شرکت‌کننده سالم و راست‌دست (۶ مرد و ۳ زن، با



شکل ۱: مراحل پیش‌پردازش

Figure 1: EEG signal preprocessing steps

میانگین سنی ۲۴.۵ سال و انحراف معیار ۲.۱ سال) است. ثبت سیگنال‌ها با استفاده از ۲۲ الکترواد Ag/AgCl مطابق با سیستم بین‌المللی ۱۰-۲۰ بر روی کلاهک الکتروانسفالوگرافی و با نرخ نمونه‌برداری ۲۵۰ هرتز انجام شده است. امپدانس الکترودها در طول ثبت کمتر از ۵ کیلو اهم حفظ شد. پروتکل آزمایشی شامل چهار وظیفه‌ی تصور حرکتی شامل موارد حرکت دست چپ، دست راست، هر دو پا و زبان بوده است.

به منظور حذف نویز و آماده‌سازی داده‌ها برای استفاده در مدل‌های یادگیری عمیق، یک پیش‌پردازش استاندارد بر روی سیگنال‌های خام مغزی اعمال گردیده است، برای این منظور ابتدا از فیلتر میان‌گذر دیجیتال باترورث مرتبه ۵ برای استخراج بازه فرکانسی ۸ تا ۳۰ هرتز استفاده شد. این بازه شامل باندهای μ (۸-۱۳ هرتز) و β (۱۴-۳۰ هرتز) است که بیشترین مدولاسیون توان را در حین اجرای وظایف تصور حرکتی نشان می‌دهند، در مرحله ی بعد با استفاده از قطعه‌بندی^۲ سیگنال‌های پیوسته به قطعاتی با طول ۴ ثانیه تفکیک شدند. هر قطعه از بازه‌ی زمانی ۰.۵ تا ۴.۵ ثانیه پس از نمایش نشانه‌ی بصری در زمان $t = 2s$ استخراج گردید. این بازه به گونه‌ای انتخاب شد که فعالیت‌های پیش از اجرای حرکت و طی اجرای تصور حرکتی را به طور کامل پوشش دهد (شبه کد شماره ۱). در نتیجه، هر قطعه شامل ۱۰۰۰ نمونه

¹ Distinctive temporal features

² Epoching

زمانی ۲۵۰×۴ برای هر کانال است سپس از نرمال سازی برای کاهش واریانس و تسهیل فرآیند یادگیری، تمامی قطعات به صورت کانال به کانال با استفاده از نرمال سازی Z-score (میانگین صفر و واریانس یک) نرمال سازی شدند.

```
Input: Raw EEG signals (multi-channel, continuous)
Output: Preprocessed EEG epochs (cleaned and normalized)

Begin
For each EEG signal do
  .¹Bandpass Filtering:
  Apply a 5th-order Butterworth filter
  Set frequency range to [8–30] Hz
  //Covers µ-band (8–13 Hz) and β-band (14–30 Hz)
  .²Epoching:
  For each trial:
  Extract a segment from 0.5 to 4.5 seconds after cue onset
  //Assuming cue onset is at t = 2s
  Set epoch length = 4 seconds
  Resulting in 1000 time points at 250 Hz sampling rate

  .³Normalization:
  For each channel:
  Apply Z-score normalization
  //x_normalized = (x - mean) / std

End For
Return preprocessed EEG epochs
End
```

شبه کد ۱: پیش پردازش سیگنال EEG
Pseudo-code 1: EEG signal preprocessing.

بعد از آماده سازی داده های ورودی یک معماری یادگیری عمیق سرتاسری نوآورانه مبتنی بر شبکه حافظه بلندمدت دوطرفه (Bi-LSTM) همراه با مکانیزم توجه زمانی مسوولیت طبقه بندی دقیق سیگنال های الکتروانسفالوگرافی مربوط به وظایف تصور حرکتی را برعهده می گیرد. این مدل دارای سه بخش کلیدی لایه ی Bi-LSTM، لایه توجه زمانی و بردار زمینه و طبقه بندی است. در ابتدا، سیگنال های الکتروانسفالوگرافی با ابعاد ۲۲×۱۰۰۰ به عنوان ورودی به یک لایه LSTM دوطرفه با ۶۴ واحد پنهان برای هر جهت تغذیه می شود. خروجی این لایه دنباله ای از بردارهای پنهان $H = [h_1, h_2, \dots, h_T]$ با ابعاد ۱۲۸ است که به صورت خروجی های forward و backward به یکدیگر الحاق شده اند (شبه کد شماره ۲). در مرحله بعد، مکانیزم توجه زمانی وارد عمل می شود که نقش اساسی در تقویت عملکرد مدل دارد. در این مرحله، برای هر بردار زمانی، یک امتیاز هم راستایی با استفاده از یک شبکه عصبی ساده و ضرب برداری محاسبه می شود. برای هر بردار h_t ، امتیاز هم راستایی به صورت $e_t = v_a^T \tanh(W_a h_t + b_a)$ محاسبه شده، سپس از طریق softmax به وزن توجه $a_t = \frac{\exp(e_t)}{\sum_{k=1}^T \exp(e_k)}$ تبدیل می شود. این وزن ها اهمیت زمانی هر گام را نشان می دهند. به عنوان گام نهایی یک بردار زمینه ای با وزندهی به تمام گام های زمانی تولید می شود و به عنوان نماینده فشرده ای از سیگنال برای لایه های طبقه بندی استفاده می شود. ترکیب LSTM دوطرفه و توجه زمانی، قدرت تمایز مدل را در تشخیص الگوهای پیچیده مغزی افزایش می دهد. بردار زمینه نهایی به صورت میانگین وزن دار خروجی ها به شکل زیر محاسبه می شود:

$$c = \sum_{t=1}^T a_t \cdot h_t \quad (1)$$

این بردار سپس به یک لایه Dense با تابع فعال سازی Softmax برای پیش بینی تعلق به یکی از چهار کلاس تصور حرکتی ارسال می شود (شبه کد شماره ۲).

```

Function Calculate_Attention_Weights(BiLSTM_Outputs, Query_Vector):
    attention_scores = []
    For each h_t in BiLSTM_Outputs:
        energy_t = tanh(W_a • h_t + U_a • Query_Vector)
        score_t = v_a • energy_t
        attention_scores.append(score_t)
    attention_weights = softmax(attention_scores)
    Return attention_weights
Function Compute_Context_Vector(attention_weights, BiLSTM_Outputs):
    context_vector = sum(attention_weights[t] * BiLSTM_Outputs[t] for all t)
    Return context_vector
// Model Flow:
BiLSTM_Outputs = Apply_BiLSTM(EEG_Epochs)
context_vector = Compute_Context_Vector(
    Calculate_Attention_Weights(BiLSTM_Outputs, Learned_Query_Vector),
    BiLSTM_Outputs)
Classification_Output = Softmax(Dense_Layer(context_vector))

```


شبه کد ۲: الگوریتم مدل پیشنهادی مبتنی بر BiLSTM و مکانیزم توجه

Pseudo-code 2: Algorithm of the proposed BiLSTM-based model with an attention mechanism

جهت بررسی عملکرد مدل پیشنهادی و مقایسه آن با سایر معماری های استاندارد ۲ مدل یادگیری عمیق برای انجام تحلیل مقایسه ای پیاده سازی و ارزیابی شدند این مدل ها شامل یک معماری پایه ی شبکه عصبی کانولوشنال، یک مدل مبتنی بر معماری LSTM استاندارد و همچنین معماری پیشنهادی است (شکل شماره ۲).

معماری های مبتنی بر شبکه های عصبی کانولوشنال برای استخراج ویژگی های ترکیبی فضایی-زمانی طراحی شده اند که معماری استفاده شده در این پژوهش شامل دو بلوک کانولوشنال به همراه یک طبقه بند چندلایه پرسپترون^۱ است. هر بلوک کانولوشنال از یک لایه Conv1D با ۴۰ فیلتر و اندازه کرنل ۱۰، به دنبال آن Batch Normalization، تابع فعال سازی ReLU، یک لایه MaxPooling1D با ضریب کاهش ۲، و یک لایه Dropout با نرخ ۰.۵ تشکیل شده است.

مدل شبکه LSTM استاندارد استفاده شده در این پژوهش به عنوان نماینده ای از شبکه های بازگشتی عمیق برای بررسی عملکرد آن در مقایسه با روش پیشنهادی انتخاب شده است. معماری آن شامل دو لایه LSTM با ۱۲۸ واحد پنهان در هر لایه است. برای کاهش بیش برازش، از Dropout با نرخ ۰.۵ برای ورودی ها و Recurrent Dropout با همان نرخ برای حالت های بازگشتی استفاده گردید.



شکل ۲: نمای مقایسه ای از معماری سه مدل یادگیری عمیق

Figure 2: Comparative illustration of the architectures of the three deep learning models:

خروجی آخرین گام زمانی از لایه دوم به طبقه بند نهایی متصل شد که (a) مدل پایه CNN و طبقه بند MLP، (b) مدل پایه LSTM با دو لایه بازگشتی متوالی، و (c) مدل پیشنهادی هستند.

¹ Multi layer perceptron

تمام مدل‌ها در محیط TensorFlow 2.x با استفاده از یک کارت گرافیک Nvidia غیر حرفه‌ای آموزش داده شده‌اند. برای آموزش از بهینه‌ساز Adam با نرخ یادگیری اولیه 0.003 معادل 10^{-3} استفاده شده است، تابع هزینه entropy Categorical Cross و مکانیزم توقف زودهنگام^۱ با آستانه ۱۵ دوره بدون بهبود در خطای اعتبارسنجی استفاده شد. ارزیابی مدل‌ها در قالب اعتبارسنجی متقابل درون-سوژه‌ای ۱۰-لایه‌ای انجام شد که با توجه به واریانس بالای بین‌فردی در سیگنال‌های مغزی، به‌عنوان استاندارد معتبر در مطالعات واسطه‌مغز- کامپیوتر شناخته می‌شود.

شاخص‌های ارزیابی شامل دقت^۲، امتیاز F1^۳، کاپای کوهن^۴ بودند. کاپای کوهن به دلیل در نظر گرفتن توافق تصادفی و مناسب بودن برای داده‌های دارای عدم تعادل کلاس، معیار ارزیابی ترجیحی در این مطالعه در نظر گرفته شد. همچنین برای تحلیل آماری نتایج و بررسی معنی‌داری تفاوت‌ها، از آزمون t زوجی با اصلاح بونفرونی جهت مقایسه‌های چندگانه استفاده شد.

علاوه بر معیارهای عملکرد طبقه‌بندی عنوان شده، جهت ارزیابی کارایی محاسباتی مدل‌ها، زمان اجرا نیز به‌عنوان یک شاخص تکمیلی در نظر گرفته شد. بدین منظور، میانگین زمان آموزش هر دوره و همچنین زمان پیش‌بینی هر نمونه^۵ برای هر مدل ثبت گردید. این معیارها با استفاده از ماژول زمان‌سنج در محیط TensorFlow محاسبه شدند. تمامی آزمایش‌ها بر روی یک کارت گرافیک Nvidia غیر حرفه‌ای با ۱۶ گیگابایت حافظه RAM و پردازنده Intel Core i7 انجام گردید. انتخاب این شاخص امکان مقایسه‌ی عادلانه‌ی میزان بهره‌وری محاسباتی معماری پیشنهادی با مدل‌های مرجع و سایر روش‌های پیشرفته را فراهم می‌سازد.

۴- نتایج

نتایج کمی حاصل از ارزیابی مقایسه‌ای سه معماری مدل در جدول شماره ۲ ارائه شده‌اند. این مقادیر، میانگین و انحراف معیار عملکرد

جدول ۲: مقایسه عملکرد کمی مدل‌ها

Table 2: Quantitative performance comparison

مدل	تعداد آزمودنی ^۱	تعداد سیگنال‌ها (کل)	نوع وظایف تصور حرکتی	تقسیم داده (آموزش/اعتبارسنجی/آزمون)	ضریب کاپای کوهن	F1-Score (%)	دقت (%)
CNN مدل پایه ۱	۹	۲۵۹۲	۴ کلاس MI	40% / 20% / 40%	0.775 ± 0.06	82.9 ± 5.1	83.1 ± 4.8
LSTM مدل پایه ۲	۹	۲۵۹۲	۴ کلاس MI	40% / 20% / 40%	0.809 ± 0.05	85.5 ± 4.3	85.7 ± 4.1
Attention-Bi-LSTM پیشنهادی	۹	۲۵۹۲	۴ کلاس MI	40% / 20% / 40%	0.883 ± 0.04	91.1 ± 3.6	91.2 ± 3.5

مدل‌ها را در میان ۹ شرکت‌کننده و طی ۱۰ لایه اعتبارسنجی متقابل نشان می‌دهند.

همان‌گونه که مشاهده می‌شود، مدل پیشنهادی Attention-Bi-LSTM عملکرد به‌مراتب بهتری نسبت به دو مدل پایه دارد. این مدل به دقت میانگین 91.2% دست یافته که نسبت به مدل LSTM، معادل کاهش خطای نسبی ۳۸.۵% است.

$$Relative\ Error\ Reduction = 1 - \frac{Accuracy_{LSTM}-1}{Accuracy_{Proposed}-1} \quad (38.5\%) \quad (2)$$

این بهبود در تمامی متریک‌ها از نظر آماری معنادار است ($p < 0.01$) علاوه بر آن در نتایج جزیی‌تر نیز پایداری نتایج و همچنین عملکرد مدل پیشنهادی نسبت به مدل‌های پایه به خوبی مشهود است (جدول شماره ۳).

¹ Early stopping

² Accuracy

³ F1-Score

⁴ Cohen's kappa


⁵ Inference time per trial

جدول شماره ۳: عملکرد تفکیکی مدل‌ها

Table 3: Class-wise performance


مدل	MI Task	(%) دقت	ضریب کاپای	F1-Score (%)	زمان آموزش هر epoch (ثانیه)	زمان پیش‌بینی هر نمونه (ms)
CNN (پایه ۱)	دست چپ	80.5 ± 5.2	0.740 ± 0.06	80.1 ± 5.5	12.4 ± 1.1	2.3 ± 0.4
	دست راست	84.2 ± 4.6	0.776 ± 0.05	83.9 ± 4.8	12.4 ± 1.1	2.3 ± 0.4
	پاها	82.8 ± 5.0	0.772 ± 0.06	83.0 ± 5.2	12.4 ± 1.1	2.3 ± 0.4
	زبان	85.0 ± 4.3	0.790 ± 0.05	84.6 ± 4.7	12.4 ± 1.1	2.3 ± 0.4
LSTM (پایه ۲)	دست چپ	86.7 ± 3.9	0.810 ± 0.04	86.5 ± 4.1	18.9 ± 1.6	2.8 ± 0.5
	دست راست	84.8 ± 4.4	0.800 ± 0.05	84.5 ± 4.6	18.9 ± 1.6	2.8 ± 0.5
	پاها	85.5 ± 4.0	0.805 ± 0.04	85.3 ± 4.2	18.9 ± 1.6	2.8 ± 0.5
	زبان	86.0 ± 3.8	0.820 ± 0.04	85.7 ± 3.9	18.9 ± 1.6	2.8 ± 0.5
Attention-Bi-LSTM (پیشنهادی)	دست چپ	92.3 ± 3.2	0.892 ± 0.03	92.0 ± 3.3	15.7 ± 1.4	1.6 ± 0.3
	دست راست	90.7 ± 3.5	0.880 ± 0.04	90.5 ± 3.6	15.7 ± 1.4	1.6 ± 0.3
	پاها	89.5 ± 3.7	0.872 ± 0.04	89.3 ± 3.8	15.7 ± 1.4	1.6 ± 0.3
	زبان	92.2 ± 3.4	0.888 ± 0.03	92.0 ± 3.5	15.7 ± 1.4	1.6 ± 0.3

Figure 3. Mean Confusion Matrix of the Attention-Bi-LSTM Model




شکل ۳: میانگین ماتریس درهم‌ریختگی مدل پیشنهادی

Figure 3: Average confusion matrix of the proposed model



شکل ۴: عملکرد مدل پیشنهادی در مقایسه با مدل های پایه
Figure 4: Performance of the proposed model compared to baseline models


علاوه بر دقت بالاتر، انحراف معیار پایین تر نیز حاکی از پایداری و قابلیت تعمیم بیشتر مدل پیشنهادی در میان افراد مختلف است. برای بررسی کیفی خطاها، میانگین ماتریس درهم ریختگی مدل پیشنهادی در شکل ۳ نمایش داده شده است. مدل در تفکیک هر چهار کلاس عملکرد دقیقی از خود نشان می دهد (مقادیر بالا روی قطر اصلی). با این حال، خطاهای باقی مانده عمدتاً مربوط به سردرگمی میان "دست چپ" و "دست راست" هستند که با در نظر گرفتن نزدیکی نمایشی این دو حرکت در قشر مغز و تقارن نیم کره ای، از منظر نوروفیزیولوژیک قابل توجیه است همچنین مقایسه ی زمان اجرای مدل ها چنانکه در جدول شماره ۳ نشان داده شده است مدل پیشنهادی ضمن دستیابی



شکل ۵: روند همگرایی و افزایش دقت
Figure 5: Convergence trend and accuracy improvement

به بالاترین دقت، دارای زمان اجرای به مراتب کمتری نسبت به مدل های پایه است. به طور خاص، این مدل به طور میانگین حدود ۲۳٪ کاهش زمان اجرا نسبت به LSTM و ۳۰٪ کاهش نسبت به مدل پایه معماری کانالوشنال نشان می دهد. این موضوع بیانگر آن است که علاوه بر بهبود معنادار در دقت طبقه بندی، چارچوب پیشنهادی از نظر پیچیدگی محاسباتی نیز بهینه تر بوده و برای کاربردهای بلادرنگ یا تحلیل سیگنال های مغزی در مقیاس بزرگ مناسب تر است. این یافته ها اهمیت دوگانه ی مدل پیشنهادی را هم از نظر عملکرد پیش بینی و هم از نظر بهره وری محاسباتی نشان می دهد.


برای درک بهتر دینامیک یادگیری و فرآیند همگرایی مدل ها، نمودارهای عملکرد آن ها در طول دوره های آموزشی در شکل ۵ و شکل ۶ ترسیم شده اند. این نمودارها تحلیل کیفی و کمی ارزشمندی از برتری مدل پیشنهادی ارائه می دهند شکل ۵ به وضوح نشان می دهد که مدل پیشنهادی (خط سبز) نه تنها به دقت بالاتری دست می یابد، بلکه دارای سه ویژگی برجسته دیگر نیز هست.



شکل ۶: تعداد Epoch لازم برای رسیدن به بهترین دقت

Figure 6: Number of epochs required to achieve the best accuracy

این مدل در حدود ۳۰ دوره به پایداری و همگرایی می رسد، در حالی که مدل LSTM (خط نارنجی) در حدود ۴۰ دوره و مدل کانالوشنال (خط آبی) نزدیک به ۵۰ دوره به همگرایی می رسند. این امر نشان دهنده کارایی بالاتر مدل پیشنهادی در یادگیری الگوهای پیچیده و همگرایی سریع تر است، همچنین منحنی یادگیری مدل پیشنهادی دارای نوسانات بسیار کمتری نسبت به دو مدل پایه است. این پایداری نشان می دهد که مکانیزم توجه به مدل کمک می کند تا بر روی ویژگی های زمانی متمایز و پایدار تمرکز کرده و از تأثیر نویز و ویژگی های نامرتبط بکاهد ضمن اینکه شیب منحنی سبز رنگ تندتر از سایرین است که بیانگر سرعت بالاتر یادگیری در هر دوره آموزشی است البته



شکل ۷: مصورسازی وزن های توجه زمانی مدل پیشنهادی

Figure 7: Visualization of the temporal attention weights of the proposed model

شکل ۶ نیز نتایج نهایی دقت را به صورت یک مقایسه بصری و واضح خلاصه می کند. این نمودار تأیید می کند که مدل پیشنهادی با دقت ۹۱٪، به طور قابل توجهی نسبت به سایر مدل های عملکرد بهتری دارد. این مشاهدات بصری، برتری کمی مدل پیشنهادی که در جدول های ۲ و ۳ گزارش شد را کاملاً تأیید کرده و نشان می دهد که مکانیزم توجه نه تنها دقت نهایی را بهبود می بخشد، بلکه فرآیند آموزش را نیز کارآمدتر و پایدارتر می سازد.

برای تحلیل عمیق عملکرد مدل پیشنهادی و شناسایی نواحی زمانی کلیدی در سیگنال‌های الکتروانسفالوگرافی، از مصورسازی وزن‌های توجه که از لایه‌ی توجه زمانی استخراج می‌شوند، استفاده شده است. همان‌طور که در معماری مدل (بخش ۳-۳) تشریح گردید، خروجی لایه Bi-LSTM به‌صورت دنباله‌ای از بردارهای پنهان زمانی تولید شده و وزن‌دهی به این بردارها از طریق محاسبه امتیاز هم‌راستایی^۱ و تابع ارزیابی آن انجام می‌گیرد. این وزن‌ها بیانگر میزان تمرکز مدل روی هر گام زمانی هستند و نقش حیاتی در تولید بردار زمینه‌ای نهایی ایفا می‌کنند. برای درک رفتار توجه مدل، نقشه‌های حرارتی وزن‌های توجه برای سیگنال‌های صحیح و خطا دار تولید گردیدند. هر نقشه شامل محور افقی زمان (۱۰۰۰ نقطه نمونه در بازه ۰.۵ تا ۴.۵ ثانیه پس از نشانه بصری) و شدت رنگ (مقدار وزن توجه) است (شکل شماره ۷). نتایج مصورسازی نشان دادند که در نمونه‌های درست طبقه‌بندی‌شده، مدل بیشترین تمرکز را در بازه ۱ تا ۲.۵ ثانیه اعمال کرده که مطابق با مرحله فعال تصور حرکتی است. همچنین، نمونه‌های اشتباه‌شده اغلب دارای پراکندگی بالا در توجه بودند که نشان‌دهنده تردید مدل در تصمیم‌گیری است. این مشاهده، علاوه بر تقویت تفسیرپذیری، امکان اصلاح و بازطراحی مدل را در موارد لازم می‌دهد.

۴. بحث

در این پژوهش، نشان داده شد که ترکیب یک ساختار بازگشتی دوطرفه با مکانیزم توجه زمانی، رویکردی مؤثر و کارآمد برای بهبود طبقه‌بندی سیگنال‌های الکتروانسفالوگرافی تصور حرکتی به شمار می‌رود.

برتری مدل Attention-Bi-LSTM را می‌توان به توانایی آن در تقلید از فرایندهای توجه انتخابی در مغز نسبت داد. برخلاف سیگنال‌های ایستا، اطلاعات معنادار در سیگنال‌های تصور حرکتی به شکل الگوهای دینامیکی و گذرا ظاهر می‌شوند که در بازه‌های زمانی خاصی بعد از دریافت دستور حرکت، به اوج می‌رسند. مصورسازی وزن‌های توجه (ارائه‌شده در بخش پیشین) نشان داد که مدل ما قادر است به‌طور خودکار این بازه‌های زمانی بحرانی را شناسایی کرده و به آن‌ها وزن بیشتری اختصاص دهد، در حالی که بخش‌های نویزی یا نامرتبط را نادیده می‌گیرد. این تمرکز هدفمند منجر به تولید برداری زمینه‌ای آغنی شده و موجب بهبود چشمگیر عملکرد طبقه‌بندی می‌شود. در مقابل، مدل LSTM استاندارد به‌طور پیش‌فرض بیشتر به گام‌های زمانی پایانی وابسته است و مدل کانالوشنال نیز ویژگی‌ها را از طریق کرنل‌های با اندازه ثابت استخراج می‌کند که ممکن است انعطاف‌پذیری لازم برای دریافت الگوهای زمانی گذرا را نداشته است.

به صورت کلی همان‌طور که در جدول ۲ نشان داده شده است، مدل Attention-Bi-LSTM پیشنهادی به‌طور معناداری عملکرد بهتری نسبت به مدل‌های پایه، یعنی کانالوشنال و LSTM دارد. دقت متوسط طبقه‌بندی برابر با $3.5\% \pm 91.2\%$ به‌وضوح بیشتر از دقت مدل کانالوشنال $4.8\% \pm 83.1\%$ و $4.1\% \pm 85.7\%$ LSTM است. همچنین، انحراف معیار کمتر در مدل پیشنهادی نشان‌دهنده پایداری و قابلیت تعمیم بهتر آن در بین آزمودنی‌های مختلف است. بهبود مشابهی در سایر شاخص‌های ارزیابی مانند امتیاز F1 و ضریب کاپای کوهن نیز مشاهده می‌شود، که اثربخشی کلی رویکرد پیشنهادی در طبقه‌بندی تصور حرکتی مبتنی بر سیگنال‌های مغزی را تأیید می‌کند. ضریب کاپای کوهن که تأثیر توافق تصادفی را در نظر می‌گیرد، به‌ویژه در شرایط عدم تعادل بین کلاس‌ها، معیاری مهم محسوب می‌شود. مدل پیشنهادی ضریب کاپای 0.04 ± 0.883 را کسب کرده است که بالاتر از مقادیر مربوط به مدل‌های کانالوشنال (0.06 ± 0.775) و (0.05 ± 0.809) LSTM است، و نشان‌دهنده عملکرد طبقه‌بندی قابل اطمینان‌تر و پایدارتر نسبت به شانس تصادفی است.

علاوه بر عملکرد برتر معماری پیشنهادی نسبت به مدل‌های پایه کانالوشنال و LSTM، مدل پیشنهادی عملکرد رقابتی و در برخی موارد برتر نسبت به روش‌های پیشرفته‌ی اخیر در زمینه طبقه‌بندی تصور حرکتی مبتنی بر سیگنال‌های الکتروانسفالوگرافی دارد همچنین برخلاف معماری‌های پایه که به‌صورت یکنواخت داده‌های زمانی را پردازش می‌کنند، مدل پیشنهادی با تمرکز بر نواحی گذرا و بحرانی در سیگنال، دقت بالاتری در تشخیص فعالیت‌های مغزی مرتبط با تصور حرکتی حاصل کرده است.

برای مقایسه با روش‌های پیشرفته‌تر به بررسی یک روش سبک برای طبقه‌بندی سیگنال‌های الکتروانسفالوگرافی تصور حرکتی با استفاده از معماری Bi-LSTM سفارشی‌شده و ویژگی‌های فراکتالی مبتنی بر تبدیل موجک پیوسته که توسط بالندرا و همکاران در سال ۲۰۲۵ پیشنهاد شده است، می‌پردازیم. پژوهش حاضر با تمرکز بر معماری عمیق سرتاسری Bi-LSTM همراه با مکانیزم توجه زمانی، عملکرد بهتری از نظر دقت طبقه‌بندی ارائه می‌دهد. در پژوهش بالندرا، ویژگی‌های پیچیده‌ای مانند الگوهای مکانی مشترک، ضرایب CWT و فراکتال‌های مقیاس‌بندی‌شده استخراج شده و به یک Bi-LSTM فشرده با حجم کم داده می‌شود که برای کاربردهای بلادرنگ و تعبیه‌شده

¹ Alignment score

² Context vector

بسیار مناسب است. با این حال، دقت مدل آن‌ها روی مجموعه داده BCI Competition IV - 2a برابر با ۷۱.۷۶٪ در حالت بین‌آزمودنی گزارش شده است [۱۴] که در مقایسه با مدل پیشنهادی این پژوهش که دقتی برابر با ۹۱.۲٪/۳.۵± دارد، به مراتب پایین‌تر است. در پژوهش حاضر، بهره‌گیری از مکانیزم توجه، امکان تمرکز مدل بر بازه‌های زمانی بحرانی سیگنال‌های الکتروانسفالوگرافی را فراهم کرده و در نتیجه، وابستگی‌های زمانی مؤثرتر و دقیق‌تری نسبت به مدل بالندرا مدل‌سازی شده است. همچنین، برخلاف رویکرد سنگین پردازش ویژگی در پژوهش مذکور، مدل این پژوهش با پیش‌پردازش حداقلی و به‌صورت انتها به انتها عمل می‌کند که موجب ساده‌سازی فرآیند و افزایش قابلیت تعمیم می‌شود. در مجموع، مدل پیشنهادی نه تنها از نظر دقت و کارایی در طبقه‌بندی وظایف تصور حرکتی عملکرد بالاتری دارد، بلکه از نظر سادگی پیاده‌سازی نیز با حفظ دقت بالا، مزیت قابل توجهی نسبت به مدل‌های مبتنی بر استخراج ویژگی پیچیده دارد.

نتایج پژوهشی دیگر در سال ۲۰۲۴ توسط یاساسوینی و همکاران که از شبکه BiLSTM برای شناسایی حرکات دست با استفاده از سیگنال‌های الکتروانسفالوگرافی بهره می‌برد و با دستیابی به دقت ۹۵.۳۴ درصد نشان می‌دهد که این مدل قادر است وابستگی‌های زمانی دوسویه در داده‌های مذکور را به خوبی استخراج کرده و عملکرد بالایی در شناسایی حرکات تصور حرکتی ارائه دهد [۱۵]. با این حال، روش پیشنهادی ما با تمرکز بر تحلیل سیگنال‌های تصور حرکتی و استفاده از ترکیب معماری پیشنهادی همراه با مکانیزم توجه سلسله‌مراتبی، تلاش دارد تا از قابلیت استخراج ویژگی‌های فضایی-زمانی و وزن‌دهی به نواحی مهم مغزی بهره گیرد. برتری این رویکرد نسبت به مدل یاساسوینی صرف‌نظر از دقت نهایی، در بهره‌گیری از معماری‌های چندمسیره و توجه سلسله‌مراتبی برای تمرکز بر نواحی بحرانی سیگنال مغزی است که در فرآیندهای حرکتی نقش کلیدی دارند. همچنین، در روش ما مطابق داده‌های جدول شماره ۲ پایداری مدل در میان آزمودنی‌های مختلف اطمینان حاصل می‌شود. بنابراین، اگرچه روش BiLSTM در بازشناسی توالی‌ها موفق عمل کرده، اما مدل پیشنهادی ما با در نظر گرفتن جنبه‌های چندوجهی سیگنال الکتروانسفالوگرافی و تمرکز بر مناطق کلیدی مغز، پتانسیل بهبود بیشتر دقت و تعمیم‌پذیری را داراست از سوی دیگر روش پیشنهادی را میتوان با پژوهش بیسلا و همکاران در سال ۲۰۲۴ که به ارائه یک سیستم رابط مغز- کامپیوتر مبتنی بر تشخیص گفتار خیالی با استفاده از ترکیب معماری CNN-BiLSTM و بهینه‌سازی موجک گسسته با الگوریتم Firefly (FOA) پیشنهاد داده اند مقایسه نمود. این روش با بهره‌گیری از بهبود سیگنال‌های الکتروانسفالوگرافی و استخراج ویژگی‌های دامنه فرکانس، به‌ویژه در حوزه تشخیص گفتار خیالی، توانسته دقتی تا ۸۹.۵۷٪ در حالت چهارکلاسه به دست آورد [۱۶] این در حالیست که روش پیشنهادی به میانگین دقت خوبی از پاسخ‌ها (۳.۵٪/۹۱.۲±) در چهار وظیفه تصور حرکتی دست پیدا کرده است از سوی دیگر، پژوهش پیشنهادی بر طبقه‌بندی وظایف تصور حرکتی با اعمال مکانیزم توجه زمانی قادر به تمرکز بر بخش‌های اطلاعاتی بحرانی و گذرا در توالی سیگنال‌های مذکور است. در حالی که روش بیسلا و همکاران از لایه‌های پیچشی یک‌بعدی برای استخراج ویژگی‌های محلی و BiLSTM برای یادگیری وابستگی‌های زمانی بهره می‌برد، در مدل پیشنهادی مکانیزم توجه نقش مهمی در فیلتر کردن و تقویت نواحی زمانی مؤثر ایفا می‌کند. هرچند مدل بیسلا در کاربرد گفتار خیالی و با استفاده از روش‌های پیش‌پردازش پیشرفته و افزایش داده، دقت بالاتری در طبقه‌بندی ارائه داده، اما پیچیدگی محاسباتی و وابستگی به بهینه‌سازی پارامترهای موجک و الگوریتم FOA ممکن است مانعی در پیاده‌سازی بلادرنگ ایجاد کند در مقابل، مدل پیشنهادی بدون پیش‌پردازش پیچیده با داشتن دقت قابل توجه ۹۱.۲٪/۳.۵± را دارد که نشان از تعادل مناسب میان سادگی معماری و کارایی بالا مخصوصاً در پردازش‌های بلادرنگ است.

جدول ۴: مقایسه عملکردی و تحلیلی روش پیشنهادی و سایر معماری‌ها

Table 4: Comparative and analytical evaluation of the proposed method and other architectures

مطالعه / سال	معماری مدل	نوع وظیفه	تعداد کلاس	معایب	مزایا	دقت (%)
روش پیشنهادی	Attention-Bi-LSTM	تصور حرکتی	4 کلاس	پیچیدگی نسبی در آموزش مدل	دقت بالا، استفاده از مکانیزم توجه برای تمرکز بر نواحی بحرانی، بدون نیاز به پیش‌پردازش پیچیده، مناسب برای پیاده‌سازی بلادرنگ	91.2 ± 3.5
LSTM پایه / مقایسه‌ای	LSTM معمولی	تصور حرکتی	4 کلاس	عدم توجه به اهمیت نسبی زمان‌ها، دقت پایین‌تر	مدل ساده با قابلیت یادگیری وابستگی زمانی	85.7 ± 4.1

83.1 ± 4.8	یادگیری ویژگی‌های محلی مناسب	ناتوانی در مدل‌سازی وابستگی زمانی	4 کلاس	تصور حرکتی	CNN بهینه شده برای EEG	CNN پایه / مقایسه‌ای
71.76	مدل بسیار سبک برای سیستم‌های تعبیه شده، استفاده از ویژگی‌های پیشرفته	دقت پایین، نیاز به استخراج ویژگی پیچیده	4 کلاس	تصور حرکتی	Bi-LSTM + فشرده + ویژگی‌های فراکتالی- CWT	بالندرا و همکاران / ۲۰۲۵
95.34	دقت بالا، یادگیری وابستگی دوسویه	عدم استفاده از مکانیزم توجه، تمرکز کمتر بر نواحی بحرانی	4 کلاس	حرکت دست	Bi-LSTM ساده	یاساسوینی / ۲۰۲۴
89.57 چهار کلاسه	دقت بالا، استخراج ویژگی فرکانسی قوی، بهینه‌سازی پیشرفته	پیچیدگی پردازشی زیاد، عدم مناسب بودن برای کاربرد بلندمدت	2/3/4 کلاس	گفتار خیالی	CNN + Bi-LSTM + FOA-DWT	بیسلا و همکاران / ۲۰۲۴

از منظر پیچیدگی محاسباتی، اگرچه معماری پیشنهادی پیچیده‌تر از معماری ساده LSTM است، اما استفاده از مکانیزم توجه افزایشی موجب افزایش بهره‌وری آن در مقایسه با مدل‌های پیچیده‌تری چون تبدیل دهنده‌ها می‌شود. مدل‌های مبتنی بر خود-توجه دارای پیچیدگی زمانی بالایی هستند، که با افزایش طول توالی T مثلاً تا ۱۰۰۰ در سیگنال‌های الکتروانسفالوگرافی، هزینه محاسباتی آن‌ها به شدت افزایش می‌یابد. در مقابل، مدل Attention-Bi-LSTM با حفظ توانایی در استخراج ویژگی‌های زمانی مهم، پیچیدگی محاسباتی پایین‌تری را ارائه می‌دهد (جدول شماره ۵).

جدول ۵: مقایسه پیچیدگی محاسباتی و فضایی مدل‌های مختلف
Table 5: Comparison of computational and spatial complexity of different models

مدل	ویژگی کلیدی	پیچیدگی فضایی (تعداد پارامترها)	پیچیدگی زمانی (FLOPs)
(مدل پایه ۱) CNN	استخراج محلی ویژگی‌های فضایی-زمانی	$O(K \cdot C_{in} \cdot C_{out})$	$O(K \cdot C_{in} \cdot C_{out})$
(مدل پایه ۲) LSTM	مدل‌سازی دنباله بدون توجه	$O(H^2)$	$O(T \cdot H^2)$
Attention-Bi-LSTM (پیشنهادی)	مدل‌سازی دوطرفه زمانی با توجه افزایشی	$O(H^2)$	$O(T \cdot H^2 + T^2 H)$
(خود-توجه) Transformer	مدل‌سازی بلندمدت با هزینه بالا	$O(H^2)$	$O(T \cdot H^2)$

این ارزیابی محاسباتی جایگاه عملیاتی مدل پیشنهادی را نسبت به معماری‌های پیچیده‌تر روشن ساخته و نشان می‌دهد که این مدل، ضمن حفظ دقت، گزینه‌ای مناسب‌تر برای کاربردهای بلندمدت و منابع محدود در واسط‌های مغز-رایانه است. با وجود نتایج امیدوارکننده، پژوهش حاضر با محدودیت‌هایی همراه است، مانند بسیاری از مطالعات مبتنی بر یادگیری عمیق، مدل پیشنهادی تنها بر روی یک مجموعه داده عمومی آموزش و ارزیابی شده است. برای تعمیم‌پذیری بهتر، آزمون مدل بر روی داده‌های واقعی و بالینی گامی حیاتی خواهد بود همچنین با توجه به پیچیدگی محاسباتی بالاتر در معماری پیشنهاد شده در این پژوهش، استفاده از آن در سامانه‌های واسط مغز-کامپیوتر بی‌درنگ و پوشیدنی با منابع محدود ممکن است چالش‌برانگیز باشد، در این راستا، روش‌هایی مانند تقطیر دانش^۱ یا استفاده از مکانیزم‌های توجه سبک‌تر نظیر توجه ضربی یا Linformer می‌توانند راهکارهایی عملی برای کاهش پیچیدگی است.

همچنین، ترکیب مکانیزم‌های توجه زمانی و فضایی به عنوان مسیر آتی پیشنهاد می‌شود. توجه فضایی می‌تواند به مدل اجازه دهد که کانال‌های مرتبط با وظایف مختلف تصور حرکتی نظیر C3، C4 و Cz را شناسایی و روی آن‌ها تمرکز کند. این تلفیق می‌تواند موجب افزایش

¹ Knowledge distillation

دقت و تفسیرپذیری مدل شود همچنین پیچیدگی محاسباتی به عنوان یک چالش کلیدی در نظر گرفته شده است که در سطح نظری، معماری پیشنهادی با پیچیدگی زمانی خطی نسبت به طول سیگنال (T) انتخاب شده است. این طراحی مدل را از هزینه محاسباتی بالای معماری های مبتنی بر خودتوجهی مانند Transformer و یا سایر معماری های مشابه با پیچیدگی درجه دو مصون می دارد که برای تحلیل سری های زمانی بلند مانند سیگنال های الکتروانسفالوگرافی ناکارآمد هستند این برتری نظری به صورت تجربی در بخش قبل نیز تأیید شده است؛ نتایج نشان می دهد که مدل پیشنهادی دارای زمان پیش بینی بهینه تر و همگرایی سریع تر در مقایسه با مدل های پایه است با تمام این اوصاف پیشنهاد می گردد پژوهش های آینده بر روی پیاده سازی مکانیزم های توجه سبک تر و استفاده از تکنیک هایی مانند تقطیر دانش برای کاهش بیشتر پیچیدگی متمرکز گردد. بنابراین، بهره وری محاسباتی یک جنبه کلیدی در طراحی بوده که از طریق انتخاب معماری و نتایج عملی در این مطالعه به آن پرداختیم و مسیرهای آتی چنانکه توصیف شد نیز برای توسعه مدل هایی که علاوه بر دقت بالا، تفسیرپذیر و اعتمادپذیر نیز است، برای پذیرش بالینی سیستم های واسط مغز-کامپیوتر ضروری است. رویکرد مبتنی بر توجه، با فراهم کردن نمایی شفاف از منطق تصمیم گیری مدل، گامی در راستای افزایش اعتماد کاربران نهایی و متخصصان بالینی برداشته است. این قابلیت همچنین می تواند به شخصی سازی دقیق تر سامانه های واسط مغز-کامپیوتر و درک بهتر الگوهای عصبی اختصاصی هر فرد کمک کند.

منابع:

1. Nicolas-Alonso, L.F. and J. Gomez-Gil, *Brain computer interfaces, a review*. Sensors (Basel), 2012. **12**(2): p. 1211-79.
2. Pfurtscheller, G. and C. Neuper, *Motor imagery and direct brain-computer communication*. Proceedings of the IEEE, 2001. **89**(7): p. 1123-1134.
3. Lotte, F., et al., *A review of classification algorithms for EEG-based brain-computer interfaces: a 10 year update*. Journal of neural engineering, 2018. **15**(3): p. 031005.
4. Lawhern, V.J., et al., *EEGNet: a compact convolutional neural network for EEG-based brain-computer interfaces*. J Neural Eng, 2018. **15**(5): p. 056013.
5. Hochreiter, S. and J. Schmidhuber, *Long Short-Term Memory*. Neural Computation, 1997. **9**: p. 1735-1780.
6. Cho, K., et al., *Learning phrase representations using RNN encoder-decoder for statistical machine translation*. arXiv preprint arXiv:1406.1078, 2014.
7. Huang, Z., et al., *A model for EEG-based emotion recognition: CNN-Bi-LSTM with attention mechanism*. Electronics, 2023. **12**(14): p. 3188.
8. Ma, Y., et al., *A multi-channel feature fusion CNN-Bi-LSTM epilepsy EEG classification and prediction model based on attention mechanism*. IEEE Access, 2023. **11**: p. 62855-62864.
9. Khosravi, M., et al., *Fusing convolutional learning and attention-based Bi-LSTM networks for early Alzheimer's diagnosis from EEG signals towards IoMT*. Scientific Reports, 2024. **14**(1): p. 26002.
10. Mo, L., et al. *A Bi-LSTM based network with attention mechanism for EEG visual classification*. in *2021 IEEE International Conference on Unmanned Systems (ICUS)*. 2021. IEEE.
11. Chen, J., et al., *EEG-based sleep staging via self-attention based capsule network with Bi-LSTM model*. Biomedical Signal Processing and Control, 2023. **86**: p. 105351.
12. Liao, W., et al., *A composite improved attention convolutional network for motor imagery EEG classification*. Frontiers in Neuroscience, 2025. **19**: p. 1543508.
13. Mirzaei, S., P. Ghasemi, and M. Bakhtyari, *EEG Motor imagery classification based on a ConvLSTM Autoencoder framework augmented by attention BiLSTM*. Multimedia Tools and Applications, 2025. **84**(19): p. 20545-20566.
14. Sharma, N. and S. Sharma, *A lightweight methodology for Motor Imagery EEG classification utilizing step scaled wavelet fractals and Bi-LSTM architecture*. 2025.
15. Yasaswini, P. and N. Devarakonda, *Optimizing Non-Invasive Brain-Computer Interfaces: Bi LSTM Networks for Hand Motion Recognition from EEG Data*. 2024. p. 1-6.
16. Bisla, M. and R.S. Anand, *Optimized CNN-Bi-LSTM-Based BCI System for Imagined Speech Recognition Using FOA-DWT*. Advances in Human-Computer Interaction, 2024. **2024**(1): p. 8742261.