

Hand Gesture Recognition Based on EEG-EMG Coherence Analysis and Convolutional Neural Network with Application in Intelligent Police Control Systems

Iman. Ahanian^{1*}, Mohammadreza. Ansari¹, Fardad. Farokhi¹

¹ Department of Biomedical Engineering ST.C., Islamic Azad University, Tehran, Iran

* Corresponding author email address: Ahanian@iau.ac.ir

Article Info

Article type:

Original Research

How to cite this article:

Ahanian, I., Ansari, M., & Farokhi, F. (2026). Hand Gesture Recognition Based on EEG-EMG Coherence Analysis and Convolutional Neural Network with Application in Intelligent Police Control Systems. *Decision Science and Intelligent Systems*. 3(1), 1-18.



© 2026 the authors. Published by KMAN Publication Inc. (KMANPUB), Ontario, Canada. This is an open access article under the terms of the Creative Commons Attribution-NonCommercial 4.0 International (CC BY-NC 4.0) License.

ABSTRACT

Hand movement recognition using brain signals (EEG) and muscle signals (EMG) is one of the central topics in neuroscience and biomedical engineering and has many applications in areas such as neural prosthesis control, brain-computer interfaces (BCI), and rehabilitation of patients with motor disorders. Accurate and rapid identification of hand movements can help improve the quality of life of individuals with motor disabilities and plays an essential role in the development of intelligent motor control systems. In this research, a novel approach for hand movement recognition based on EEG and EMG signals and the use of deep neural networks is presented. In this method, by employing signal preprocessing steps, nonlinear feature extraction, and classification based on neural networks, the accuracy and speed of recognition have been improved. In addition, the concept of coherence relationship between EEG and EMG signals has been used to analyze the functional connection between brain and muscle. Evaluating changes in the coherence relationship between high-density EEG and EMG signal connections has provided more accurate recognition of hand movements. The experimental results show that the proposed method has higher accuracy compared to existing methods. The use of a deep convolutional neural network (CNN) along with the analysis of coherence relationships between signals has significantly increased the accuracy of hand movement recognition; quantitative evaluations show that the model on the training, test, and total data provides stable and reliable performance with AUC values of 0.987, 0.919, and 0.971, and R^2 coefficients of 0.9956, 0.9803, and 0.9679, respectively.

Keywords: Hand movement recognition, EEG signals, EMG signals, deep neural network, coherence relationship.

Extended Abstract

Introduction

Hand movement recognition using brain signals (EEG) and muscle signals (EMG) is one of the central topics in neuroscience and biomedical engineering, with extensive applications in neural prosthesis control, brain-computer interfaces (BCI), and rehabilitation of patients with motor disorders. Accurate and rapid identification of hand movements can improve the quality of life for individuals with motor disabilities and plays an essential role in developing intelligent motor control systems. Despite significant advances, most previous studies have either relied on independent features of each channel, neglecting the interactive network of channels, or have used linear regression models that are limited when dealing with noisy, nonlinear, and multivariate data. On the other hand, proposed neural networks in the literature (such as VGG-based models and transformers) are often very heavy and challenging for real-time applications. To address these limitations, the present study proposes a novel and lightweight framework for hand movement recognition. Instead of using raw signal values, a coherence connectivity matrix between pairs of channels (EEG-EMG and EMG-EMG) is computed. This matrix is extracted as a two-dimensional image representing the frequency connectivity map of muscles and brain. Then, this matrix is fed as input to a simplified convolutional neural network (CNN) consisting of three convolution layers and two fully connected layers. The aim of this research is to demonstrate that replacing complex causality computations with coherence relationship extraction and a lightweight CNN can significantly reduce the computational burden of the model while maintaining or improving recognition accuracy.

Methods and Materials

The proposed research method consists of four main stages: (1) signal preprocessing, (2) coherence connectivity matrix computation, (3) forming an image dataset from the matrices, and (4) classification using a convolutional neural network (CNN).

Signal Preprocessing: Raw recorded EEG and EMG signals first undergo a series of preprocessing operations. These include band-pass filtering to remove low-frequency noise (such as movement artifacts) and high-frequency noise (such as power line noise); the suitable frequency range for EMG signals is typically between 20 and 500 Hz, and for EEG signals depending on the desired frequency bands (e.g., alpha, beta). Normalization is performed to scale the amplitude of signals recorded from different channels to a standard range (e.g., -1 to 1). Segmentation divides continuous time signals into shorter overlapping segments using a sliding window; each segment or window constitutes one data sample for subsequent analyses.

Coherence Connectivity Matrix Computation: For each time window of preprocessed signals, a square matrix called the "coherence matrix" is computed. This matrix shows the functional connectivity between every pair of signal channels (EEG-EMG, EMG-EMG) in the frequency domain. The mathematical steps include: short-time Fourier transform to obtain frequency representations $X(f)$ and $Y(f)$; computation of power spectral density (PSD) for each signal; computation of cross power spectral density (CPSD) between two signals; and finally, computation of magnitude-squared coherence between two signals at frequency f using the formula: $C_{xy}(f) = \frac{|P_{xy}(f)|^2}{P_{xx}(f)P_{yy}(f)}$. The value of $C_{xy}(f)$ is a number between 0 (no linear relationship) and 1 (perfect linear relationship). By computing this value for all pairs

of available channels (e.g., N channels), a symmetric $N \times N$ matrix is formed, where element (i,j) indicates the coherence between channel i and channel j . This matrix is considered as a single-channel image.

Convolutional Neural Network Architecture: The computed coherence matrices are used as input to a CNN for classifying hand movement type. The proposed architecture is a simplified and lightweight version of common models such as VGG, designed to reduce computational load. The overall structure includes: input layer (coherence matrix with dimensions $N \times N \times 1$); three convolution layers with small filters (e.g., 3×3) for extracting spatial features from the connectivity map, followed by ReLU activation after each convolution layer; five max-pooling layers to reduce the dimensions of feature maps and increase model robustness to small shifts in patterns; and two fully connected layers at the end of the network that map extracted features to the movement class space.

Dataset and Evaluation Setup: The input signal database used in this research includes simultaneous recording of brain signals (EEG) and muscle signals (EMG) from 5 different participants. The experimental scenario includes three types of hand movements: flexion, extension, and fist clenching, each recorded in two separate repetitions per individual. For each record, four channels of data were collected, including one EEG channel from electrode C3 and three EMG channels from hand muscles (ECR, ECU, and EMG). Signals were recorded at a sampling frequency of $f_s = 1000$ Hz and passed through a band-pass filter in the frequency range of 20 to 450 Hz to remove unwanted noise. In the proposed method, filtered data were segmented using sliding time windows with a length of 256 samples and 128 samples overlap. Then, coherence matrices between all channel pairs were computed, and a 4×4 matrix was obtained for each window, which was fed as input (in the form of two-dimensional images) to the neural network. The data were divided into 80% training and 20% testing with a random seed of 42 for reproducibility. The CNN architecture included: input layer ($4 \times 4 \times 1$), convolution layer 1 (8 filters, 3×3 kernel, same padding), pooling layer 1 (2×2 window, stride 2), convolution layer 2 (16 filters, 3×3 kernel), fully connected layer 1 (32 neurons), and fully connected layer 2 (3 neurons for three-class output). The Adam optimizer was used with an initial learning rate of 0.01, and the number of epochs was 30.

Findings

The results of applying the model to training, test, and total datasets are summarized. Quantitative evaluation of the proposed CNN in training and testing stages showed: for training data, accuracy=0.9970, sensitivity=0.9968, specificity=0.9985, RMSE=0.0545, $R^2=0.9956$; for test data, accuracy=0.9901, sensitivity=0.9855, specificity=0.9934, RMSE=0.1091, $R^2=0.9803$; and for total data, accuracy=0.9928, sensitivity=0.9929, specificity=0.9964, RMSE=0.1463, $R^2=0.9679$. The confusion matrices showed that in the training set, values of 117, 106, and 112 on the main diagonal indicate very high accuracy in identifying all three classes, with only minor errors between classes. In the test set, values of 33, 32, and 28 on the main diagonal indicate appropriate generalization capability. The confusion matrix for all data showed values of 140, 140 on the main diagonal, indicating the model maintained its stability even after merging training and test data. The ROC curve analysis showed AUC values of 0.987 for training data, 0.919 for test data, and 0.971 for all data. The scatter plots of true versus predicted values showed that most data points are concentrated near the diagonal line, indicating high prediction accuracy. The R^2 coefficients for training, test, and total data were 0.9956, 0.9803, and 0.9679, respectively, indicating very high correlation between actual and predicted values. Comparison with previous studies showed that while improved coherence estimation led to classification accuracy of about 83.50% in those works, the present

method using coherence matrices and deep CNN architecture achieved much higher AUC and R^2 values, demonstrating that the two-dimensional coherence representation and deep learning significantly enhance the model's ability to discriminate movement classes.

Conclusion

In this research, a novel method for processing and analyzing data (with emphasis on noise reduction, movement artifacts, and execution time) was presented, and its performance was evaluated on a set of real data. Experimental results showed that the proposed algorithm outperforms conventional methods in terms of accuracy, sensitivity, specificity, and area under the ROC curve, while its computational complexity is such that the total system execution time is significantly reduced. Achieving recognition accuracy of about 99% indicates that the model has high discriminatory power and can significantly reduce the probability of diagnostic error in practical scenarios. Analysis of ROC curves, scatter plots, and results on training, test, and total datasets showed that the proposed method has appropriate stability and acceptable resistance to data variations and possible noise. This is particularly important in sensitive applications where diagnostic errors can have serious consequences. The combination of high accuracy with noise and movement artifact reduction suggests that the proposed approach can help improve the quality of monitoring and decision-making in systems based on this type of data. Based on the obtained results, it is suggested that future research test the proposed algorithm on larger and more diverse datasets in terms of recording conditions, noise type, and statistical population to more comprehensively evaluate its generalizability. Also, combining this method with other deep learning techniques or advanced feature extraction methods can be used to further reduce execution time and computational resources while maintaining or increasing recognition accuracy. Developing a real-time version of this algorithm for implementation in practical systems and portable devices is another suggested path for future work. Finally, it is recommended that model interpretability aspects be considered so that, in addition to accuracy and efficiency, more analysis and trust of domain experts in system outputs can be provided.

تشخیص حرکات دست با بررسی تغییرات رابطه انسجامی بین اتصالات سیگنال EEG و EMG و شبکه عصبی کانولوشنی

ایمان آهانیان^{۱*}، محمدرضا انصاری^۱، فرداد فرخی^۱

۱. گروه مهندسی پزشکی، واحد تهران جنوب، دانشگاه آزاد اسلامی، تهران، ایران

*ایمیل نویسنده مسئول: Ahanian@iau.ac.ir

اطلاعات مقاله

چکیده

نوع مقاله

پژوهشی/اصیل

نحوه استناد به این مقاله:

آهانیان، ایمان، انصاری، محمدرضا، و فرخی، فرداد. (۱۴۰۵). تشخیص حرکات دست با بررسی تغییرات رابطه انسجامی بین اتصالات سیگنال EEG و EMG و شبکه عصبی کانولوشنی. علم تصمیم گیری و سیستم های هوشمند، ۳(۱)، ۱-۱۸.



© ۱۴۰۵ تمامی حقوق انتشار این مقاله متعلق به نویسنده است. انتشار این مقاله به صورت دسترسی آزاد مطابق با گواهی (CC BY-NC 4.0) صورت گرفته است.

تشخیص حرکت دست با بهره گیری از سیگنال های مغزی (EEG) و عضلانی (EMG) یکی از موضوعات محوری در علوم اعصاب و مهندسی پزشکی به شمار می رود و در حوزه هایی نظیر کنترل پروتزهای عصبی، رابط های مغز-رایانه و توانبخشی بیماران دچار اختلالات حرکتی کاربرد فراوان دارد. شناسایی دقیق و سریع حرکات دست می تواند به ارتقای کیفیت زندگی افراد دارای ناتوانی های حرکتی کمک کرده و در توسعه سامانه های هوشمند کنترل حرکتی نقشی اساسی ایفا کند. در این پژوهش، رویکردی نوین برای تشخیص حرکت دست مبتنی بر سیگنال های EEG و EMG و استفاده از شبکه های عصبی عمیق ارائه شده است. در این روش، با به کارگیری مراحل پیش پردازش سیگنال، استخراج ویژگی های غیرخطی و طبقه بندی مبتنی بر شبکه های عصبی، دقت و سرعت تشخیص بهبود یافته است. افزون بر این، مفهوم رابطه انسجامی میان سیگنال های EEG و EMG برای تحلیل ارتباط عملکردی مغز و عضله به کار گرفته شده است. ارزیابی تغییرات رابطه انسجامی بین اتصالات سیگنال های EEG و EMG با چگالی بالا، امکان تشخیص دقیق تر حرکات دست را فراهم کرده است. نتایج آزمایش ها نشان می دهد روش پیشنهادی در مقایسه با روش های موجود از صحت بالاتری برخوردار است. بهره گیری از شبکه عصبی کانولوشنی عمیق همراه با تحلیل روابط انسجامی میان سیگنال ها، دقت تشخیص حرکت دست را به شکل قابل توجهی افزایش داده است؛ ارزیابی های کمی نشان می دهند که مدل بر روی داده های آموزش، آزمون و کل داده ها به ترتیب با مقادیر AUC برابر ۰.۹۸۷، ۰.۹۱۹ و ۰.۹۷۱ و ضرایب تعیین R^2 برابر ۰.۹۹۵۶، ۰.۹۸۰۳ و ۰.۹۶۷۹، عملکردی پایدار و قابل اتکا ارائه می کند.

کلیدواژگان: تشخیص حرکت دست، سیگنال های EEG، سیگنال های EMG، شبکه عصبی عمیق، رابطه انسجامی.

۱. مقدمه

حرکات دست یکی از چالش‌های اساسی در توسعه سیستم‌های واسط مغز-رایانه (BCI^۱) و پروتزهای عصبی است. سیگنال‌های الکترومایوگرافی (EMG^۲) که نشان‌دهنده فعالیت الکتریکی عضلات هستند و عموماً توسط الکترودهای سطحی غیرتهاجمی ثبت می‌شوند، به همراه سیگنال‌های الکتروانسفالوگرافی (EEG^۳) نقش مهمی در درک مکانیزم‌های حرکتی ایفا می‌کنند (Maghsoudi et al., 2022; Valdivieso Caraguay et al., 2023). آنالیز همزمان این دو سیگنال و بررسی ارتباط عملکردی میان قشر حرکتی مغز و عضلات درگیر، رویکردی مؤثر برای رمزگشایی از قصد حرکتی انسان است.

یکی از روش‌های قدرتمند برای بررسی این ارتباط، استفاده از معیار «رابطه انسجامی»^۴ است. رابطه انسجامی ابزاری در حوزه فرکانس است که میزان همبستگی خطی بین دو سیگنال (مانند EEG و EMG) را در باندهای فرکانسی مختلف نشان می‌دهد. مطالعات متعددی نشان داده‌اند که بررسی این روابط می‌تواند الگوهای پنهان در هماهنگی عصبی-عضلانی را آشکار سازد. به عنوان مثال، شی و همکاران (۲۰۲۰) با تحلیل سیگنال‌های EEG و EMG به بررسی ارتباط عملکردی بین مغز و عضلات در هنگام برداشتن جسم در راستای عمود و افق پرداختند. آن‌ها با استفاده از پیش‌پردازش مبتنی بر استخراج نقاط انفجار فعالیت^۵ و طبقه‌بند ماشین بردار پشتیبان (SVM)، به دقت ۸۳.۵ درصد در تشخیص فعالیت عضلات دست یافتند (Xi et al., 2020). در مطالعه‌ای دیگر، گِروِوِندز و همکاران (۲۰۲۲) با استفاده از مجموعه داده استاندارد WAY-EEG-GAL، رابطه انسجام قشر-عضله را بین قشر حرکتی اولیه و عضلات اندام فوقانی در حین انجام وظایف رسیدن و گرفتن شیء^۶ تایید کردند (Guerrero-Mendez & Ruiz-Olaya, 2022).

علاوه بر تحلیل‌های آماری کلاسیک، در سال‌های اخیر استفاده از یادگیری عمیق برای پردازش این سیگنال‌ها مورد توجه قرار گرفته است. تاکنون محققان از یک شبکه عصبی عمیق برای طبقه‌بندی شش نوع حرکت دست بر مبنای سیگنال‌های EMG استفاده کردند که نتایج قابل قبولی به همراه داشت؛ با این حال، در مدل آن‌ها تحلیلی از روابط پنهان میان کانال‌های مختلف سیگنال ارائه نشد (Xi et al., 2020). همچنین، برخی یک چارچوب مبتنی بر شبکه‌های ترانسفورماتور بینایی^۷ برای تشخیص حرکت دست از روی سیگنال‌های HD-EMG پیشنهاد دادند که پیچیدگی محاسباتی بالایی دارد (Montazerin et al., 2023).

علیرغم پیشرفت‌های موجود، اکثر مطالعات پیشین یا از ویژگی‌های مستقل هر کانال استفاده کرده‌اند و تعاملات شبکه‌ای کانال‌ها را نادیده گرفته‌اند، و یا برای استخراج روابط، به مدل‌های رگرسیون خطی اتکا کرده‌اند که در برابر داده‌های نویزی، غیرخطی و دارای هم‌خطی چندگانه^۸ دچار محدودیت هستند. از سوی دیگر، شبکه‌های عصبی پیشنهادی در مقالات (مانند مدل‌های مبتنی بر VGG16 یا ترانسفورماتورها) اغلب بسیار سنگین بوده و برای کاربردهای بلادرنگ چالش‌برانگیز هستند.

برای رفع این محدودیت‌ها، پژوهش حاضر یک چارچوب نوین و سبک برای تشخیص حرکات دست پیشنهاد می‌دهد. در این راستا، ابتدا به جای استفاده از مقادیر خام سیگنال‌ها، ماتریس ارتباط انسجامی^۹ بین جفت کانال‌های سیگنال (به‌ویژه EMG) محاسبه می‌شود. این

¹ Brain-Computer Interface

² Electromyography (or Electromyogram)

³ Electroencephalography (or Electroencephalogram)

⁴ Coherence

⁵ Burst

⁶ Reach-Grasp-Hold

⁷ Vision Transformer

⁸ Multicollinearity

⁹ Coherence Matrix

ماتریس به عنوان یک تصویر دوبعدی که نمایانگر نقشه ارتباطات فرکانسی عضلات است، استخراج می‌گردد. سپس، این ماتریس به عنوان ورودی به یک شبکه عصبی کانولوشنی (CNN) ساده‌سازی شده (شامل سه لایه کانولوشن و دو لایه کاملاً متصل) تغذیه می‌شود. هدف از این پژوهش، نشان دادن این موضوع است که جایگزینی محاسبات پیچیده علیت با استخراج روابط انسجامی و استفاده از یک شبکه CNN سبک، می‌تواند ضمن حفظ یا ارتقای دقت تشخیص، بار محاسباتی مدل را به شدت کاهش دهد.

پیشینه مرتبط

تحلیل سیگنال‌های بیولوژیکی، به‌ویژه EEG و EMG، به منظور رمزگشایی از فعالیت‌های حرکتی انسان، دهه‌هاست که مورد توجه محققان قرار دارد. رویکردهای اولیه عمدتاً بر تحلیل ویژگی‌های آماری و زمانی هر سیگنال به صورت مجزا متمرکز بودند. با این حال، درک عمیق‌تر مکانیزم‌های عصبی-عضلانی نیازمند بررسی ارتباطات و هماهنگی‌های عملکردی بین مغز و عضلات است. در این راستا، تحلیل‌های حوزه فرکانس، به‌ویژه معیار انسجام، به ابزاری قدرتمند برای کمی‌سازی این ارتباطات تبدیل شده‌اند. انسجام، میزان همبستگی خطی دو سیگنال را در یک فرکانس خاص اندازه‌گیری می‌کند و می‌تواند الگوهای هماهنگی قشر-عضله^۱ را آشکار سازد (Guerrero-Mendez & Ruiz-Olaya, 2022).

در سال‌های اخیر، پژوهشگران برای بهبود عملکرد سیستم‌های تشخیص حرکت دست از روی سیگنال‌های سطحی الکترومایوگرافی، به طراحی معماری‌های عمیق توجه ویژه‌ای نشان داده‌اند. تلاش‌های گسترده‌ای برای طراحی معماری‌های یادگیری عمیق کارآمد به منظور بهبود دقت و قابلیت تعمیم این سیستم‌ها صورت گرفته است. یکی از رویکردهای پیشنهادی، یک معماری ترکیبی چندجریانی شامل شبکه‌های پیچشی زمانی، لایه‌های حافظه کوتاه‌مدت بلندمدت دوطرفه و واحدهای بازگشتی دروازه‌دار دوطرفه به همراه رمزگذار ترانسفورمر است که با استفاده از تابع اتلاف آرسی فیس، جدایی‌پذیری کلاس‌ها را افزایش می‌دهد (Çelik & Can, 2026). در راستای بهبود کارایی در شرایط وجود تغییرات بین افراد مختلف، یک روش تطبیق حوزه بدون نظارت خطی و غیرمحافظة کار مبتنی بر تحلیل تفکیک خطی و خوشه‌بندی ارائه شده است که به طور خاص برای کاهش اثر تغییرپذیری میان آزمودنی‌ها طراحی شده و توانسته است شکاف دقت بین مدل‌های درون‌فردی و بین‌فردی را به میزان قابل توجهی کاهش دهد (کولو و دیگران، ۲۰۲۶). از سوی دیگر، پژوهشگران به منظور کاهش وابستگی به آرایه‌های الکترومتراکم و حجیم، مفهوم شبکه مولد الکترومایوگرافی را معرفی کرده‌اند که قادر است با استفاده از تعداد بسیار محدودی کانال ورودی، فعالیت الکتریکی عضلانی را در نواحی پوشش داده‌نشده توسط حسگر بازسازی کند (Kim et al., 2026). در پژوهشی دیگر، یک چارچوب مبتنی بر تجزیه مد تجربی کامل همگروه با نویز تطبیقی پیشنهاد شده است که در آن سیگنال‌ها به توابع مد ذاتی تجزیه شده و هر تابع با استفاده از تبدیل فوریه زمان-کوتاه به تصویر طیف‌نگار تبدیل می‌شود (اورال و برگیل، ۲۰۲۶). همچنین، به منظور افزایش استواری در برابر نویز و حملات دشمنانه، یک شبکه ترانسفورمر با تنظیم دشمنانه و اختلال کانال-محور ارائه شده است که بهبود چشمگیری در دقت طبقه‌بندی و مقاومت در برابر حملات نشان داده است (Cha et al., 2026).

برخی رویکردها بر استخراج همزمان ویژگی‌های مکانی-زمانی با استفاده از بلوک‌های پیچشی-بازگشتی تأکید دارند. یکی از روش‌های پیشرفته، شبکه متقاطع مکانی-زمانی نام دارد که با بهره‌گیری از تکنیک پیچش غلتان و یک چارچوب یادگیری تطبیقی آگاه از آزمودنی، به طور مؤثر تغییرپذیری بین افراد مختلف را کاهش می‌دهد (Yang et al., 2025). در راستای بهبود دقت در حرکات پویا، روش دیگری با استفاده از یک شبکه عصبی پیچشی مبتنی بر مکانیزم توجه متقاطع ارائه شده است که سیگنال‌های گذرای الکترومایوگرافی را با سیگنال‌های نیروسنجی عضلانی ترکیب می‌کند (Oyemakinde et al., 2025). از سوی دیگر، رویکردهای نوینی برای افزایش قابلیت تعمیم در شرایط

¹ Cortico-Muscular Coherence

تغییر توزیع حسگرها میان افراد مختلف پیشنهاد شده است. یک چارچوب سبک مبتنی بر مدل زبانی-دیداری ارائه گردیده که با تولید برجسب‌های شبه‌آموزشی برای قصد حرکتی، صحت رمزگشایی را در حضور تغییرات میان افراد به حداکثر می‌رساند (دره و دیگران، ۲۰۲۵). علاوه بر این، مطالعات نشان داده‌اند که برای کاربردهای خاص توانبخشی مانند عمل ریختن آب، استفاده از روش‌های محاسبات دانه‌ای و همجوشی ویژگی‌های دست‌ساخت با معماری کانویمیکسر می‌تواند دقت شناسایی را به طور چشمگیری افزایش دهد (Zhang et al., 2025). علاوه بر رویکردهای مبتنی بر یادگیری عمیق، پژوهش‌های گسترده‌ای نیز بر استفاده از یادگیری ماشین کلاسیک برای طبقه‌بندی سیگنال‌های الکترومایوگرافی متمرکز شده‌اند. در مطالعه‌ای با استفاده از سیگنال‌های هشت کاناله ثبت‌شده توسط دستبند مایو و استخراج مجموعه‌ای از ده ویژگی حوزه زمان و فرکانس، عملکرد چهار طبقه‌بند مختلف شامل رگرسیون لجستیک، ماشین بردار پشتیبان، کی‌نزدیک‌ترین همسایه و جنگل تصادفی برای تشخیص هفت حرکت دست ارزیابی گردید (Kadavath et al., 2024). نتایج این پژوهش نشان داد که طبقه‌بند جنگل تصادفی با دقت کلی ۹۵٫۳۸ درصد و سطح زیر منحنی راک برابر ۹۹٫۷۲ درصد، برتری قابل توجهی نسبت به سایر روش‌ها دارد. در راستای بهبود کارایی محاسباتی و دقت تشخیص، رویکردی کارآمد مبتنی بر استخراج ویژگی‌های مؤثر و انتخاب ویژگی ارائه گردیده است که با به‌کارگیری روش جدیدی برای بخش‌بندی حرکت معنادار سیگنال مبتنی بر میانگین قدرمطلق انحرافات و پنجره لغزان، عملکرد الگوریتم پیشنهادی را بر روی دو مجموعه داده عمومی ارزیابی کرده است (Miah et al., 2024). استفاده از الگوریتم رگرسیون لجستیک برای انتخاب ویژگی‌های مؤثر، همراه با طبقه‌بند درخت فوق‌پارامتر، منجر به دستیابی به دقت‌های ۹۷٫۳۳ درصد و ۹۹٫۸۸ درصد به ترتیب برای دو مجموعه داده گردید. در مطالعه‌ای دیگر، تأثیر الگوریتم‌های پس‌پردازش و نیز معماری شبکه عصبی پیچشی-حافظه کوتاه‌مدت بلندمدت در تشخیص حرکات دست مورد بررسی قرار گرفته است (López et al., 2024). پژوهشگران با استفاده از مجموعه داده بزرگ شامل ۶۱۲ فرد نشان دادند که افزودن یک الگوریتم پس‌پردازش ساده می‌تواند دقت شناسایی را برای مدل شبکه عصبی پیچشی به میزان چشمگیر ۴۱٫۸۶ درصد افزایش دهد.

مطالعات متعددی از این معیار برای کاربردهای مختلف استفاده کرده‌اند. به عنوان مثال، گِروِ مندر و همکاران (۲۰۲۲) با تحلیل داده‌های عمومی WAY-EEG-GAL، وجود انسجام معنادار بین سیگنال‌های EEG ثبت‌شده از قشر حرکتی اولیه و سیگنال‌های EMG عضلات درگیر در وظیفه رسیدن و گرفتن شیء را به اثبات رساندند (Guerrero-Mendez & Ruiz-Olaya, 2022). این پژوهش نشان داد که الگوهای انسجام می‌توانند به عنوان شاخصی از ارتباط عملکردی مغز و عضله عمل کنند. در مطالعه‌ای دیگر، شی و همکاران (۲۰۲۰) چارچوبی برای تشخیص فعالیت‌های عضلانی حین برداشتن اجسام ارائه دادند که در آن، تحلیل همزمان سیگنال‌های EEG و EMG نقش کلیدی داشت. اگرچه روش طبقه‌بندی آن‌ها مبتنی بر ماشین بردار پشتیبان (SVM^1) بود، اما کار آن‌ها اهمیت استخراج ویژگی‌های مبتنی بر ارتباط این دو نوع سیگنال را برجسته ساخت (Xi et al., 2020).

در همین راستا، ژانگ و همکاران با معرفی پایگاه‌داده «تشخیص حرکات انگشت با استفاده از الکترومایوگرافی سطحی با چگالی بالا از عضلات درون‌زاد و برون‌زاد دست» مجموعه‌ای از سیگنال‌های HD-sEMG و EMG ساعد را به‌صورت همزمان با زاویه مفاصل انگشتان در چند نوع حرکت و سه وضعیت بازو برای ۲۰ فرد سالم ثبت کردند. در این پژوهش از آرایه‌های ۶۴ کاناله روی دست و ۸ کاناله روی ساعد، همراه با تحلیل‌های آماری و کاهش بُعد مانند PCA، برای بررسی الگوهای فضایی فعالیت عضلانی و تمایز بین حرکات تک‌انگشتی و چندانگشتی استفاده شد. با این حال دارای چالش‌هایی مانند حساسیت الگوهای EMG به تغییر وضعیت اندام و تفاوت‌های بین‌فردی است که تعمیم‌پذیری

¹ Support Vector Machine

مدل های تشخیصی را محدود می کند و نیاز به استفاده از رویکردهای پیشرفته تر مبتنی بر همبستگی و انسجام بین کانال ها را برجسته می سازد (Zhang et al., 2019).

در مطالعه «تحلیل اتصال مندی مبتنی بر انسجام سیگنال های EEG و EMG در حرکت دستیابی و گرفتن با دو وزن مختلف» یک رویکرد کاملاً مهندسی برای کمی سازی اتصال قشر-عضله در حین حرکات عملکردی دست ارائه شده است که با استفاده از پایگاه داده عمومی WAY-EEG-GAL، سیگنال های EEG سه کانال ناحیه حرکتی و EMG پنج عضله اندام فوقانی راست ۱۲ فرد سالم را در حین توالی حرکات رسیدن، گرفتن، نگه داشتن و برگرداندن اجسام با دو وزن ۰.۱۶۵ و ۰.۶۶۰ کیلوگرم استخراج و با الگوریتم انسجام در حوزه فرکانس، الگوی اتصال مندی قشری-عضلانی را بین کانال های EEG و عضلات مختلف مقایسه کردند و نتایج نشان داد وزن سبک تر به طور کلی انسجام EEG-EMG بیشتری نسبت به وزن سنگین ایجاد می کند و علاوه بر این، رفتارهای هم طرفی و پاد طرفی در الگوهای انسجام مشاهده شد که بیانگر درگیر شدن شبکه های حرکتی دو نیم کره در کنترل دقیق نیروی گرفتن است (Guerrero-Mendez & Ruiz-Olaya, 2022).

در مطالعه «تحلیل بهبود یافته انسجام EEG-EMG بر پایه حرکات دست» یک روش پیش پردازش و تحلیل جدید برای افزایش دقت برآورد انسجام بین مغز و عضله پیشنهاد شده است؛ نویسندگان ابتدا سیگنال های EEG هم زمان را بر اساس نقاط انفجار فعالیت EMG نمونه برداری و با یک میانگین گیری متحرک مبتنی بر تابع پنجره صاف کرده و سپس دوباره بر مبنای همان نقاط EMG باز نمونه برداری و باز آرای می کنند تا سیگنال EEG باز ترکیب شده، بازتاب دقیق تری از دینامیک حرکت عضله ارائه دهد و در ادامه انسجام EEG-EMG با دو رویکرد انسجامی در باندهای بتا و گاما برای حرکات خودخواسته دست محاسبه می شود (Xi et al., 2020).


با ظهور یادگیری عمیق، رویکردهای جدیدی برای طبقه بندی حرکات دست توسعه یافته است. هوو و همکاران (۲۰۲۲) یک شبکه عصبی عمیق (DNN^1) را برای پردازش سیگنال های EMG و تشخیص شش نوع حرکت دست به کار گرفتند. مدل آن ها به دقت بالایی دست یافت، اما یک محدودیت عمده داشت: این مدل صرفاً بر ویژگی های استخراج شده از هر کانال EMG به صورت مستقل تکیه داشت و اطلاعات غنی نهفته در روابط متقابل بین کانال ها را نادیده می گرفت (Hu et al., 2022). این در حالی است که هماهنگی بین عضلات مختلف (ارتباطات EMG-EMG) نقش حیاتی در اجرای یک حرکت یکپارچه دارد. در لبه دیگر فناوری، منتظریان و همکاران (۲۰۲۳) معماری های پیشرفته تری مانند شبکه های ترانسفورماتور را برای تحلیل سیگنال های HD-EMG پیشنهاد کردند که با وجود دقت بالا، از پیچیدگی محاسباتی قابل توجهی برخوردارند و پیاده سازی آن ها در سیستم های بلادرنگ دشوار است (Montazerin et al., 2023).

با بررسی کارهای پیشین، یک شکاف تحقیقاتی مشخص می شود: نیاز به روشی که بتواند اطلاعات ارتباطی بین کانال های سیگنال را به شیوه ای مؤثر استخراج کرده و آن را به یک مدل یادگیری عمیق سبک و کارآمد برای طبقه بندی ارائه دهد. پژوهش حاضر با هدف پر کردن این شکاف، استفاده از ماتریس انسجام را به عنوان یک نمایش دوبعدی غنی از ارتباطات عملکردی پیشنهاد می کند و نشان می دهد که این نمایش می تواند با یک شبکه CNN ساده، به دقت بالایی در تشخیص حرکات دست منجر شود.

¹ Deep Neural Network

روش پیشنهادی

روش تحقیق پیشنهادی در این پژوهش شامل چهار مرحله اصلی است: (۱) پیش پردازش سیگنال‌ها، (۲) محاسبه ماتریس ارتباط انسجامی، (۳) تشکیل مجموعه داده تصویری از ماتریس‌ها، و (۴) طبقه‌بندی با استفاده از شبکه عصبی کانولوشنی (CNN^۱). در ادامه، هر یک از این مراحل به تفصیل شرح داده می‌شوند.



شکل ۱- فلوچارت روش پیشنهادی

پیش پردازش سیگنال

سیگنال‌های خام EEG و EMG ثبت شده، ابتدا تحت یک سری عملیات پیش پردازش قرار می‌گیرند تا برای تحلیل آماده شوند. این مراحل شامل موارد زیر است:

فیلتر میان‌گذر^۲: برای حذف نویزهای فرکانس پایین (مانند آرتیفکت‌های حرکتی) و فرکانس بالا (مانند نویز برق شهر)، یک فیلتر میان‌گذر اعمال می‌شود. محدوده فرکانسی مناسب برای سیگنال‌های EMG معمولاً بین ۲۰ تا ۵۰۰ هرتز و برای EEG بسته به باندهای فرکانسی مورد نظر (مثلاً آلفا، بتا) انتخاب می‌شود.

نرمال‌سازی^۳: به منظور هم‌مقیاس کردن دامنه سیگنال‌های ثبت شده از کانال‌های مختلف، مقادیر هر سیگنال به بازه استاندارد (مانند ۱- تا ۱+) نرمال‌سازی می‌شود. این کار از بایاس شدن مدل به سمت کانال‌هایی با دامنه بزرگتر جلوگیری می‌کند.

بخش‌بندی^۴: سیگنال‌های پیوسته زمانی با استفاده از یک پنجره متحرک به قطعات کوتاه‌تر و هم‌پوشان تقسیم می‌شوند. هر قطعه یا پنجره، یک نمونه داده برای تحلیل‌های بعدی را تشکیل می‌دهد.

^۱ Convolutional Neural Network

^۲ Band-pass Filtering

^۳ Normalization

^۴ Segmentation

محاسبه ماتریس ارتباط انسجامی

این مرحله، هسته اصلی نوآوری این پژوهش است. برای هر پنجره زمانی از سیگنال‌های پیش‌پردازش‌شده، یک ماتریس مربعی به نام «ماتریس انسجام» محاسبه می‌شود. این ماتریس، ارتباط عملکردی بین هر جفت کانال سیگنال (EEG-EMG, EMG-EMG) را در حوزه فرکانس نشان می‌دهد. مراحل ریاضی این محاسبه به شرح زیر است:

۱. تبدیل فوریه زمان-کوتاه: برای هر سیگنال $x(t)$ و $y(t)$ در یک پنجره زمانی، تبدیل فوریه اعمال می‌شود تا نمایش فرکانسی آن‌ها $X(f)$ و $Y(f)$ به دست آید.

۲. محاسبه طیف توان: چگالی طیف توان برای هر سیگنال از رابطه (۱) محاسبه می‌شود:

$$P_{xx}(f) = X(f)X^*(f) \quad (1)$$

$$P_{yy}(f) = Y(f)Y^*(f)$$

که در آن $X^*(f)$ مزدوج مختلط $X(f)$ است.

۳. محاسبه طیف توان متقاطع (CPSD): چگالی طیف توان متقاطع بین دو سیگنال نیز به صورت رابطه (۲) محاسبه می‌شود:

$$P_{xy}(f) = X(f)Y^*(f) \quad (2)$$

۴. محاسبه انسجام: در نهایت، مقدار انسجام مجذوری^۱ بین دو سیگنال x و y در فرکانس f از طریق رابطه (۳) به دست می‌آید:

$$C_{xy}(f) = \frac{|P_{xy}(f)|^2}{P_{xx}(f)P_{yy}(f)} \quad (3)$$

مقدار $C_{xy}(f)$ عددی بین ۰ (عدم ارتباط خطی) و ۱ (ارتباط خطی کامل) است. با محاسبه این مقدار برای تمام جفت کانال‌های موجود (مثلاً N کانال)، یک ماتریس متقارن $N \times N$ شکل می‌گیرد که در آن، نشان‌دهنده میزان انسجام بین کانال i و کانال j است. این ماتریس به عنوان یک تصویر تک کاناله^۲ در نظر گرفته می‌شود.

معماری شبکه عصبی کانولوشنی

ماتریس‌های انسجام محاسبه‌شده به عنوان ورودی به یک شبکه CNN برای طبقه‌بندی نوع حرکت دست استفاده می‌شوند. معماری پیشنهادی، یک نسخه ساده‌شده و سبک از مدل‌های رایج مانند VGG است که برای کاهش بار محاسباتی طراحی شده است. ساختار کلی این شبکه به شرح زیر است:

لایه ورودی: ماتریس انسجام با ابعاد $N * N * 1$

لایه‌های کانولوشن: شامل سه لایه کانولوشن با فیلترهای کوچک (مثلاً 3×3) برای استخراج ویژگی‌های فضایی از نقشه ارتباطات.

پس از هر لایه کانولوشن، از تابع فعال‌سازی ReLU استفاده می‌شود.

لایه‌های ادغام: پنج لایه مکس پولینگ^۳ برای کاهش ابعاد نقشه‌های ویژگی و افزایش مقاومت مدل به جابجایی‌های کوچک در الگوها

به کار می‌رود.

لایه‌های تماماً متصل: در انتهای شبکه، دو لایه تماماً متصل قرار دارد که ویژگی‌های استخراج‌شده را به فضای کلاس‌های حرکتی

نگاشت می‌کنند.

¹ Magnitude-Squared Coherence

² Grayscale

³ Max-Pooling

لایه خروجی: یک لایه Softmax با تعدادی نرون برابر با تعداد حرکات دست، که احتمال تعلق ورودی به هر کلاس را محاسبه می‌کند.

یافته‌های پژوهش

در این بخش به بررسی محیط و تنظیمات آزمایشی و یافته‌های حاصل از آزمایش روش پیشنهادی با روشهای مورد مقایسه پرداخته می‌شود و در انتهای این بخش نیز مقایسه‌ای بین این روش و روش‌های پیشین صورت گرفته است. انجام آزمایشات روشها در نرم افزار MATLAB در محیط یک دستگاه سیستم لپ تاپ با حافظه RAM با مقدار هشت مگابایت، پردازنده اینتل هفت هسته ای و سیستم عامل ویندوز ده در نسخه ۶۴ بیتی استفاده گردید همچنین از نظر فضای ذخیره‌سازی محدودیت خاصی وجود نداشته و از یک دیسک سخت با ظرفیت یک ترابایت که نزدیک ۷۰۰ گیگابایت آن خالی بوده است، استفاده شده است. همچنین از نرم افزار متلب با نسخه 2019a برای انجام آزمایشات روش پیشنهادی و روش مورد مقایسه استفاده شد.

پارامترهای تنظیمی بکار رفته در طبقه بند پیشنهادی و روشهای مورد مقایسه در جدول ۱ آورده شده است. لازم به ذکر است که مقایسه روشها در شرایط پارامترهای تنظیمی یکسان صورت گرفت. نوع و مقادیر پارامترهای تنظیمی براساس آزمون سعی و خطا انتخاب شد.

جدول ۱: پارامترهای تنظیمی

پارامتر	مقدار / تنظیم	توضیح مختصر
تعداد سوژه‌ها	۵	داده‌ها از پنج فرد ثبت شده‌اند
تعداد حرکات (کلاس‌ها)	۳	شامل سه نوع حرکت مجزا
تعداد تکرار برای هر حرکت	۲	هر حرکت دو بار تکرار شده است
تعداد کانال‌ها	۴	چهار کانال EMG برای هر سوژه
نرخ نمونه‌برداری	۱۰۰۰ Hz	دقت زمانی ثبت سیگنال‌ها
طول پنجره	۲۵۶ نمونه	بازه زمانی واحد تحلیل سیگنال
هم‌پوشانی پنجره	۱۲۸ نمونه	میزان اشتراک بین پنجره‌های متوالی
باند فیلتر	۲۰ – ۴۵۰ Hz	فیلتر میان‌گذر برای حذف نویز
پارامترهای انسجام (mscohere)	پنجره Hamming (۶۴)، هم‌پوشانی ۳۲، NFFT = ۲۵۶	تنظیمات استخراج ویژگی انسجامی
نسبت آموزش/آزمون	۸۰٪ / ۲۰٪	تقسیم تصادفی داده‌ها برای Train/Test
عدد تصادفی (rng)	۴۲	حفظ تکرارپذیری در تقسیم داده‌ها
لایه ورودی	۱ × ۴ × ۴	اندازه ماتریس ورودی شبکه
لایه کانولوشن ۱	کرنل ۳ × ۳، فیلتر ۸، Padding = same	استخراج ویژگی اولیه
لایه Pooling ۱	پنجره ۲ × ۲، Stride ۲	کاهش ابعاد ویژگی
لایه کانولوشن ۲	کرنل ۳ × ۳، فیلتر ۱۶	استخراج ویژگی‌های عمیق‌تر
لایه تمام‌متصل ۱ (FC۱)	۳۲ نرون	نگاشت ویژگی‌ها به فضای فشرده‌تر
لایه تمام‌متصل ۲ (FC۲)	۳ نرون	خروجی سه کلاس طبقه‌بندی
تابع بهینه‌سازی	Adam	روش یادگیری در شبکه عصبی
نرخ یادگیری اولیه	۰.۰۱	سرعت به‌روزرسانی وزن‌ها
تعداد epoch ها	۳۰	دفعات تکرار آموزش داده‌ها
نمایش آموزش (Verbose)	false	غیرفعال کردن نمایش جزئیات در حین آموزش

ویژگی های داده های ورودی و ساختار ارزیابی

پایگاه داده سیگنال ورودی مورد استفاده در این پژوهش، شامل ثبت همزمان سیگنال های مغزی (EEG) و عضلانی (EMG) از ۵ شرکت کننده مختلف است. سناریوی آزمایش شامل انجام سه نوع حرکت دست شامل خم کردن، باز کردن و مشت کردن می باشد که هر حرکت در دو تکرار مجزا برای هر فرد ثبت شده است. برای هر رکورد، چهار کانال داده شامل یک کانال سیگنال مغزی از الکترود C3 و سه کانال سیگنال الکترومایوگرافی از عضلات دست (شامل ECR، ECU و FD) جمع آوری شده است. سیگنال ها با فرکانس نمونه برداری $fs=1000$ هرتز ثبت شده و به منظور حذف نویزهای ناخواسته، از یک فیلتر میان گذر در بازه فرکانسی ۲۰ تا ۴۵۰ هرتز عبور داده شده اند. در روش پیشنهادی، داده های فیلترشده با استفاده از پنجره های زمانی لغزان با طول ۲۵۶ نمونه و هم پوشانی ۱۲۸ نمونه بخش بندی می شوند. سپس برای استخراج ویژگی های ارتباطی بین قشر مغز و عضلات درگیر، ماتریس انسجامی (همدوسی) بین تمامی جفت کانال ها محاسبه شده و برای هر پنجره یک ماتریس 4×4 به دست می آید که به عنوان ورودی (در قالب تصاویر دوبعدی) به شبکه عصبی تغذیه می شود.

یافته های پژوهش

به منظور بررسی دقیق عملکرد مدل در تشخیص و تفکیک کلاس های مختلف حرکتی، معیارهای استاندارد ارزیابی شامل دقت، صحت، حساسیت، ویژگی، خطای ریشه میانگین مربعات و ضریب تعیین محاسبه گردید.

باتوجه به اینکه معیارهای صحت، دقت، ویژگی و حساسیت براساس نرخ های مثبت منفی کاذب و حقیقی حاصل می شوند و این نرخ ها نیز براساس ماتریس آشفتگی یعنی در کنارهم قراردادن خروجی داده های واقعی (متغیر وابسته حقیقی) در کنار خروجی داده های پیش بینی شده (متغیر وابسته پیش بینی شده) حاصل می شود، در ابتدا به تعریف نرخ های مثبت منفی کاذب و حقیقی باتوجه به مسئله مورد بررسی مان پرداخته می شود.

پایگاه داده مورد استفاده در این پژوهش شامل یک متغیر خروجی با سه کلاس مختلف است. بنابراین مسئله به صورت یک طبقه بندی چندکلاسه در نظر گرفته می شود. برای ارزیابی عملکرد مدل، از ماتریس آشفتگی^۱ استفاده شده است که در آن سطرها بیانگر کلاس های واقعی^۲ و ستون ها نشان دهنده کلاس های پیش بینی شده توسط مدل^۳ هستند. تمرکز مقادیر بر روی قطر اصلی ماتریس بیانگر صحت بالای طبقه بندی است.

در مسئله طبقه بندی چندکلاسه، برای محاسبه شاخص های ارزیابی مانند حساسیت، ویژگی و دقت، هر کلاس به صورت جداگانه به عنوان کلاس مثبت در نظر گرفته شده و سایر کلاس ها در مجموع به عنوان کلاس منفی در نظر گرفته می شوند. بر این اساس مؤلفه های ماتریس آشفتگی به صورت زیر تعریف می شوند:

مثبت حقیقی^۴ (TP): تعداد نمونه هایی که واقعاً متعلق به کلاس مورد نظر هستند و مدل نیز آن ها را به درستی در همان کلاس پیش بینی کرده است.

مثبت کاذب^۵ (FP): تعداد نمونه هایی که در واقع متعلق به سایر کلاس ها هستند اما مدل آن ها را به اشتباه در کلاس مورد نظر طبقه بندی کرده است.

¹ Confusion Matrix

² True Class

³ Predicted Class

⁴ True Positive

⁵ False Positive

منفی حقیقی^۱ (TN): تعداد نمونه‌هایی که متعلق به سایر کلاس‌ها هستند و مدل نیز آن‌ها را به درستی خارج از کلاس مورد نظر پیش‌بینی کرده است.

منفی کاذب^۲ (FN): تعداد نمونه‌هایی که در واقع متعلق به کلاس مورد نظر هستند اما مدل آن‌ها را به اشتباه در یکی از کلاس‌های دیگر طبقه‌بندی کرده است.

بر اساس این تعاریف، شاخص‌های ارزیابی عملکرد مدل شامل دقت، حساسیت، ویژگی و دقت از مؤلفه‌های ماتریس آشفتگی محاسبه می‌شوند.

مجدداً معرفی هریک از فرمولهای ارزیابی راندمان روشها که در بالا توضیح داده شد در جدول ۲ آورده شد.

جدول ۲: معیارهای ارزیابی راندمان طبقه بندی

معیار	فرمول
دقت (Accuracy)	$(TN + TP) / (TN + TP + FN + FP)$
صحت (Precision)	$TP / TP + FP$
حساسیت (Sensitivity)	$TP / (TP + FN)$
ویژگی (Specificity)	$TN / (TN + FP)$

نتایج حاصل از اعمال مدل بر روی مجموعه داده‌های آموزش، آزمون و کل داده‌ها در جدول ۳ خلاصه شده است.

جدول ۳- نتایج کمی ارزیابی شبکه عصبی کانولوشنی پیشنهادی در مراحل آموزش و آزمون

مجموعه داده	دقت	دقت مثبت	حساسیت	ویژگی	RMSE	R ²
آموزش	۰.۹۹۷۰۲۴	۰.۹۹۷۰۵۰	۰.۹۹۶۸۸۵	۰.۹۹۸۵۱۲	۰.۰۵۴۵۵۴	۰.۹۹۵۶۳۲
آزمون	۰.۹۸۸۰۹۵	۰.۹۹۰۱۹۶	۰.۹۸۵۵۰۷	۰.۹۹۳۴۶۴	۰.۱۰۹۱۰۹	۰.۹۸۰۲۷۷
کل داده ها	۰.۹۹۲۸۵۷	۰.۹۹۲۹۴۱	۰.۹۹۲۸۵۷	۰.۹۹۶۴۲۹	۰.۱۴۶۳۸۵	۰.۹۶۷۸۵۷

ارزیابی توزیع پیش‌بینی‌های مدل نشان‌دهنده‌ی توانمندی بالای شبکه در یادگیری الگوهای پیچیده‌ی انسجام فرکانسی است. بر اساس ماتریس‌های آشفتگی ارائه شده برای داده‌های آموزش، آزمون و کل داده‌ها در شکل ۲، مدل طبقه‌بندی عملکرد بسیار مناسبی در تفکیک سه کلاس مورد بررسی داشته است.




شکل ۲- ماتریس آشفتگی

¹ True Negative

² False Negative

در مجموعه آموزش، مقادیر ۱۱۷، ۱۰۶ و ۱۱۲ بر روی قطر اصلی ماتریس نشان می‌دهد که مدل با دقت بسیار بالا نمونه‌های هر سه کلاس را به درستی شناسایی کرده است و تنها یک خطای جزئی بین کلاس‌ها مشاهده می‌شود. در مجموعه آزمون نیز الگوی مشابهی قابل مشاهده است؛ به گونه‌ای که مقادیر ۲۲، ۳۳ و ۲۸ بر روی قطر اصلی بیانگر توان تعمیم‌پذیری مناسب مدل هستند. میزان خطاهای خارج از قطر در داده‌های آزمون نیز بسیار محدود بوده و تنها شامل چند مورد جابه‌جایی بین کلاس‌های ۱ و ۲ است، که از نظر آماری قابل اغماض است. همچنین ماتریس مربوط به کل داده‌ها نشان‌دهنده توزیع یکنواخت و منظم پیش‌بینی‌هاست؛ مقادیر ۱۴۰، ۱۴۰ و ۱۳۷ بر روی قطر اصلی ماتریس حاکی از این است که مدل حتی پس از ادغام داده‌های آموزش و آزمون نیز پایداری خود را حفظ کرده است. این موضوع بیانگر آن است که مدل نه تنها دچار بیش‌برازش نشده، بلکه قادر به تعمیم رفتار خود بر روی داده‌های دیده‌نشده نیز هست. تمرکز غالب مقادیر بر روی قطر اصلی و تعداد بسیار کم نمونه‌های خارج از آن نشان می‌دهد که تداخل بین کلاس‌ها^۱ حداقل بوده و مدل توانسته است سه کلاس حرکتی را با تفکیک بالا شناسایی کند. این یافته‌ها با نتایج کمی گزارش‌شده در جدول ۲ (جدول عملکرد) سازگار بوده و عملکرد کلی روش پیشنهادی را تأیید می‌کند.

به منظور ارزیابی دقیق‌تر عملکرد مدل پیشنهادی، علاوه بر ماتریس اغتشاش، از تحلیل منحنی مشخصه عملکرد گیرنده (ROC^2) و نمودار پراکنش مقادیر واقعی در مقابل مقادیر پیش‌بینی‌شده نیز استفاده شده است. منحنی‌های ROC برای سه مجموعه داده شامل داده‌های آموزش، داده‌های آزمون و کل داده‌ها رسم شده‌اند و در شکل ۳ مشاهده می‌شود.



شکل ۳-ماتریس منحنی ROC


همان‌طور که در شکل ۳ مشاهده می‌شود، مقدار سطح زیر منحنی (AUC^3) برای داده‌های آموزش برابر با ۰.۹۸۷، برای داده‌های آزمون برابر با ۰.۹۱۹ و برای کل داده‌ها برابر با ۰.۹۷۱ به دست آمده است. مقدار AUC بزرگ‌تر از ۰.۵ نشان‌دهنده توانایی مدل در تمایز بین کلاس‌ها است و هرچه این مقدار به ۱ نزدیک‌تر باشد، عملکرد مدل بهتر خواهد بود. نتایج به دست آمده نشان می‌دهد که مدل در داده‌های آموزش توانایی قابل قبولی در تفکیک کلاس‌ها داشته و در داده‌های آزمون نیز عملکردی نزدیک به حالت تصادفی اما قابل قبول از خود نشان داده است. همچنین مقدار AUC برای کل داده‌ها بیانگر عملکرد کلی مناسب مدل در تفکیک کلاس‌های مختلف در مجموعه داده مورد بررسی است.

^۱ Cross-talk

^۲ Receiver Operating Characteristic

^۳ Area Under the Curve

علاوه بر این، برای بررسی میزان تطابق بین مقادیر واقعی و مقادیر پیش‌بینی‌شده توسط مدل، نمودار پراکنش بین کلاس واقعی^۱ و کلاس پیش‌بینی‌شده^۲ برای سه مجموعه داده آموزش، آزمون و کل داده‌ها در شکل ۴ ترسیم شده است.



شکل ۴- تطابق بین مقادیر واقعی و مقادیر پیش‌بینی‌شده

در این نمودارهای شکل ۴، خط قطری نشان‌دهنده حالت ایده‌آل است که در آن مقادیر پیش‌بینی‌شده دقیقاً با مقادیر واقعی برابر هستند. همان‌طور که در شکل مشاهده می‌شود، بیشتر نقاط داده در نزدیکی این خط قطری متمرکز شده‌اند که بیانگر دقت بالای مدل در پیش‌بینی کلاس صحیح نمونه‌ها است. همچنین ضرایب تعیین (R^2) به‌ترتیب برای داده‌های آموزش، آزمون و کل داده‌ها برابر با ۰.۹۹۵۶، ۰.۹۸۰۳ و ۰.۹۶۷۹ به دست آمده است که نشان‌دهنده همبستگی بسیار بالا بین مقادیر واقعی و پیش‌بینی‌شده است. این نتایج نشان می‌دهد که مدل پیشنهادی قادر است الگوهای موجود در داده‌ها را به‌خوبی یاد بگیرد و پیش‌بینی‌هایی با دقت بالا ارائه دهد.

در مجموع، نتایج حاصل از تحلیل منحنی ROC و نمودارهای پراکنش، در کنار نتایج ماتریس اغتشاش و معیارهای ارزیابی گزارش‌شده در جدول عملکرد، نشان می‌دهد که مدل پیشنهادی از توانایی مناسبی در طبقه‌بندی فازهای حرکتی و تشخیص صحیح کلاس‌های مختلف برخوردار است و می‌تواند با دقت بالا داده‌های جدید را نیز پیش‌بینی کند. این هم‌خوانی بین شاخص‌های مختلف ارزیابی، بیانگر پایداری و قابلیت تعمیم مناسب مدل در مسئله طبقه‌بندی مورد بررسی است.

برای ارزیابی بهتر جایگاه روش پیشنهادی در مقایسه با پژوهش‌های پیشین، عملکرد مدل با دو کار مرتبط مبتنی بر انسجام EEG-EMG مقایسه شده است. در این مطالعات، بهبود برآورد انسجام منجر به افزایش دقت طبقه‌بندی تا حدود ۸۳.۵۰ درصد شده است، در حالی‌که روش حاضر با بهره‌گیری از ماتریس‌های انسجامی و معماری عمیق CNN، مقادیر بسیار بالاتری برای شاخص‌های AUC و R^2 به دست آورده است. این موضوع نشان می‌دهد استفاده از نمایش دوبعدی انسجام و یادگیری عمیق، توان مدل را در تفکیک کلاس‌های حرکتی به‌طور معناداری ارتقا داده است.

جدول ۴- مقایسه روش پیشنهادی با برخی روش‌های موجود در پیشینه

منبع / روش	نوع مدل و ویژگی‌ها	متریک اصلی گزارش‌شده	عملکرد کلیدی
روش پیشنهادی	CNN عمیق بر روی ماتریس‌های انسجام EEG-EMG	AUC، R^2 ، دقت، حساسیت، ویژگی	AUC: آموزش ۰.۹۸۷، آزمون ۰.۹۱۹، کل ۰.۹۷۱؛ R^2 : آموزش ۰.۹۹۵۶، آزمون ۰.۹۸۰۳، کل ۰.۹۶۷۹
(هو و همکاران، ۲۰۲۲)	SVM بر پایه بردار ویژگی MSC و انسجام EEG-EMG بهبودیافته	میانگین دقت طبقه‌بندی	دقت SVM: ۷۹.۳۳٪، MSC: ۸۳.۵۰٪ بهبودیافته
(شی و همکاران، ۲۰۲۰)	SVM با ویژگی‌های انسجام EEG-EMG	میانگین دقت طبقه‌بندی	دقت SVM: ۷۹.۳۳٪، MSC: ۸۳.۵۰٪ بهبودیافته

¹ True Class

² Predicted Class

نتیجه گیری

در این پژوهش، یک روش نوین برای پردازش و تحلیل داده ها (با تأکید بر کاهش نویز، آرتیفکتهای حرکتی و زمان اجرا) ارائه شد و کارایی آن بر روی مجموعه ای از داده های واقعی ارزیابی گردید. نتایج تجربی نشان داد که الگوریتم پیشنهادی نسبت به روش های مرسوم، از نظر شاخص هایی مانند دقت، حساسیت، ویژگی و مساحت زیر منحنی ROC عملکرد بهتری دارد و در عین حال، پیچیدگی محاسباتی آن به گونه ای است که زمان اجرای کل سامانه به طور قابل ملاحظه ای کاهش یافته است. رسیدن به دقت تشخیص حدود ۹۹ درصد، حاکی از آن است که مدل از توان تفکیک بالایی برخوردار است و می تواند در سناریوهای عملی، احتمال خطای تشخیص را به میزان چشمگیری کاهش دهد. همچنین تحلیل نمودارهای ROC، نمودارهای پراکنش و نتایج حاصل بر روی داده های آموزش، آزمون و کل مجموعه داده نشان داد که روش پیشنهادی از پایداری مناسبی برخوردار بوده و نسبت به تغییرات داده و نویزهای احتمالی مقاومت قابل قبولی دارد. این موضوع، به ویژه در کاربردهای حساس که خطای تشخیصی می تواند تبعات جدی به همراه داشته باشد، اهمیت ویژه ای دارد. ترکیب دقت بالا با کاهش نویز و آرتیفکتهای حرکتی، نشان می دهد که رویکرد ارائه شده می تواند به بهبود کیفیت پایش و تصمیم گیری در سامانه های مبتنی بر این نوع داده ها کمک کند.

با توجه به نتایج به دست آمده، پیشنهاد می شود در تحقیقات آینده، الگوریتم پیشنهادی بر روی مجموعه داده های بزرگ تر و متنوع تر از نظر شرایط ثبت، نوع نویز و جمعیت آماری آزمون شود تا میزان تعمیم پذیری آن به صورت جامع تری ارزیابی گردد. همچنین می توان از ترکیب این روش با سایر تکنیک های یادگیری عمیق یا روش های پیشرفته ای استخراج ویژگی بهره برد تا ضمن حفظ یا افزایش دقت تشخیص، امکان کاهش بیشتر زمان اجرا و منابع محاسباتی فراهم شود. توسعه ای نسخه ی بلادرنگ این الگوریتم برای پیاده سازی در سامانه های عملی و تجهیزات قابل حمل نیز یکی دیگر از مسیرهای پیشنهادی برای ادامه ی کار است. در نهایت، پیشنهاد می شود جنبه های تفسیرپذیری مدل نیز مورد توجه قرار گیرد تا علاوه بر دقت و کارایی، امکان تحلیل و اعتماد بیشتر متخصصان حوزه ی کاربردی به خروجی های سیستم فراهم شود.

تعارض منافع

در انجام مطالعه حاضر، هیچ گونه تضاد منافی وجود ندارد.

مشارکت نویسندگان

در نگارش این مقاله تمامی نویسندگان نقش یکسانی ایفا کردند.

موازن اخلاقی

در انجام این پژوهش تمامی موازین و اصول اخلاقی رعایت گردیده است.

شفافیت داده ها

داده ها و مآخذ پژوهش حاضر در صورت درخواست از نویسنده مسئول و ضمن رعایت اصول کپی رایت ارسال خواهد شد.

References

- Çelik, Y., & Can, U. (2026). Surface EMG-Based Hand Gesture Recognition Using a Hybrid Multistream Deep Learning Architecture. *Sensors*, 26(7), 2281.
- Cha, D., Lee, D.-G., & Ahn, S. (2026). Adversarially regularized transformer with channel-wise noise for robust hand gesture recognition using surface electromyography. *Biomedical Engineering Letters*, 16(2), 463-472.
- Guerrero-Mendez, C. D., & Ruiz-Olaya, A. F. (2022). Coherence-based connectivity analysis of EEG and EMG signals during reach-to-grasp movement involving two weights. *Brain-Computer Interfaces*, 9(3), 140-154.
- Hu, X., Song, A., Wang, J., Zeng, H., & Wei, W. (2022). Finger movement recognition via high-density electromyography of intrinsic and extrinsic hand muscles. *Scientific Data*, 9(1), 373.
- Kadavath, M. R. K., Nasor, M., & Imran, A. (2024). Enhanced hand gesture recognition with surface electromyogram and machine learning. *Sensors*, 24(16), 5231.
- Kim, K. K., Zaluska, T. J., Skov, S., Lee, Y., Park, H., Zhong, D., Khatib, M., Nishio, Y., Jiang, Y., & Delp, S. L. (2026). A simplified wearable device powered by a generative EMG network for hand-gesture recognition and gait prediction. *Nature Sensors*, 1(1), 27-38.
- López, L. I. B., Ferri, F. M., Zea, J., Caraguay, Á. L. V., & Benalcázar, M. E. (2024). CNN-LSTM and post-processing for EMG-based hand gesture recognition. *Intelligent Systems with Applications*, 22, 200352.
- Maghsoudi, A., Shalbaf, A. J. J. o. B. P., & Engineering. (2022). Hand motor imagery classification using effective connectivity and hierarchical machine learning in EEG signals. 12(2), 161.
- Miah, A. S. M., Shin, J., & Hasan, M. A. M. (2024). Effective features extraction and selection for hand gesture recognition using sEMG signal. *Multimedia tools and applications*, 83(37), 85169-85193.
- Montazerin, M., Rahimian, E., Naderkhani, F., Atashzar, S. F., Yanushkevich, S., & Mohammadi, A. J. S. R. (2023). Transformer-based hand gesture recognition from instantaneous to fused neural decomposition of high-density EMG signals. 13(1), 11000.
- Oyemakinde, T. T., Kulwa, F., Peng, X., Liu, Y., Cao, J., Deng, X., Wang, M., Li, G., Samuel, O. W., & Fang, P. (2025). A novel sEMG-FMG combined sensor fusion approach based on an attention-driven CNN for dynamic hand gesture recognition. *IEEE Transactions on Instrumentation and Measurement*.
- Valdivieso Caraguay, Á. L., Vásconez, J. P., Barona López, L. I., & Benalcázar, M. E. J. S. (2023). Recognition of Hand Gestures Based on EMG Signals with Deep and Double-Deep Q-Networks. 23(8), 3905.
- Xi, X., Ma, C., Yuan, C., Miran, S. M., Hua, X., Zhao, Y.-B., & Luo, Z. (2020). Enhanced EEG-EMG coherence analysis based on hand movements. *Biomedical Signal Processing and Control*, 56, 101727.
- Yang, J., Cha, D., Lee, D.-G., & Ahn, S. (2025). STCNet: Spatio-temporal cross network with subject-aware contrastive learning for hand gesture recognition in surface EMG. *Computers in Biology and Medicine*, 185, 109525.
- Zhang, C., Zhou, D., Fang, Y., Kubota, N., & Ju, Z. (2025). Surface EMG Sensing and Granular Gesture Recognition for Rehabilitative Pouring Tasks: A Case Study. *Biomimetics*, 10(4), 229.
- Zhang, G., Davoodnia, V., Sepas-Moghaddam, A., Zhang, Y., & Etemad, A. J. I. S. J. (2019). Classification of hand movements from EEG using a deep attention-based LSTM network. 20(6), 3113-3122.