



طبقه‌بندی مراحل مختلف یادگیری تایپ با

استفاده از شاخص‌های نبود تقارن منحنی

رودونی EEG: تأکید بر تعداد بهینه گلبرگ‌ها

و کانال‌های مغزی

فاطمه جلالی^{۱،*}، عاتکه گشوارپور^{۲،۳}

کارشناسی ارشد گروه مهندسی پزشکی، دانشگاه بین‌المللی امام رضا (ع)، مشهد، ایران^۱

استادیار گروه مهندسی پزشکی، دانشگاه بین‌المللی امام رضا (ع)، مشهد، ایران^۲

مرکز تحقیقات فناوری‌های زیستی و سلامت، دانشگاه بین‌المللی امام رضا (ع)، مشهد، ایران^۳

چکیده

تحلیل داده‌های الکتروانسفالوگرافی (EEG) به‌عنوان ابزاری کلیدی در درک ساختارهای عصبی مرتبط با یادگیری مهارت‌های جدید از اهمیت بالایی در علوم اعصاب شناختی برخوردار است. با وجود پیشرفت‌های اخیر در روش‌های پردازش سیگنال، توسعه الگوریتم‌های نوین برای استخراج الگوهای معنادار از داده‌های EEG، به‌ویژه در بافتار پویایی مغزی حین یادگیری، همچنان به‌عنوان یک چالش پژوهشی مطرح است. هدف از انجام پژوهش حاضر، ارائه یک الگوریتم جدید جهت تحلیل داده‌های بیولوژیکی است. به‌طور خاص، روش پیشنهادی در توصیف داده‌های EEG در یادگیری یک مهارت جدید مورد بررسی قرار گرفته است. از داده‌های EEG ده شرکت‌کننده (شش زن و چهار مرد) در نه کانال مغزی (F3، Fz، F4، C3، Cz، C4، P3، POz و P4) موجود در IEEEDataPort استفاده شد که در حال یادگیری تایپ در رایانه در دوازده جلسه درسی، با استفاده از طرح صفحه کلید کولماک بودند. هر یک از درس‌ها پنج بار تکرار شد. ثبت‌های EEG در طی تکرارهای دروس چهارم، هشتم و یازدهم بررسی شد. برای نخستین بار روشی مبتنی بر منحنی رودونی برای تحلیل سیگنال معرفی شد که ساختاری شبیه گل با تعداد گلبرگ‌های قابل تنظیم دارد. در مطالعه حاضر، مدل با تعداد یک تا ده گلبرگ ارزیابی شد. سه شاخص جدید مبتنی بر نبود تقارن در منحنی رودونی برای جداسازی مراحل مختلف یادگیری به ماشین بردار پشتیبان (SVM) داده شد. نقش کانال‌های مغزی و تعداد گلبرگ‌های بهینه در مدل با ارزیابی نتایج طبقه‌بندی برای هر کانال و تعداد گلبرگ جداگانه بررسی شد. نتایج طبقه‌بندی دو کلاسی با رویکرد یک در مقابل همه، برای تفکیک پانزده جلسه (پنج تکرار × سه درس) بین ۷۹/۳ تا ۹۳/۳ به‌دست آمد. برای کانال‌های F3، Fz، C4، C3، POz و تعداد گلبرگ چهار بهترین نتایج حاصل شد. در طبقه‌بندی سه جلسه درسی، بالاترین صحت به‌ترتیب مربوط به جلسه یازدهم (۹۲٪)، چهارم (۹۰٪) و هشتم (۷۲/۶٪) بود. نتایج نشان می‌دهد در هنگام یادگیری تایپ کردن، مناطق خاصی از پیشانی، آهیانه و پس‌سری فعال می‌شود؛ علاوه‌براین، دینامیک‌های مغزی در هنگام تکمیل فرایند یادگیری (جلسه یازدهم) و در مراحل اولیه یادگیری (جلسه چهارم) قابلیت تفکیک بالاتری دارند. عملکرد بالای شاخص‌های منحنی رودونی بیان‌کننده پتانسیل آن در تحلیل سیگنال EEG است.

واژگان کلیدی: الکتروانسفالوگرافی، یادگیری، منحنی رودونی، پردازش سیگنال، طبقه‌بندی، نبود تقارن.

Classifying Various Stages of Typing Learning through EEG Rhodonea Curve Asymmetry Indices: A Focus on the Optimal Number of Petals and Brain Channels

Fateme Jalaly^{1,3}, Ateke Goshvarpour^{2,3*}

MSc., Department of Biomedical Engineering, Imam Reza International University, Mashhad, Razavi Khorasan, Iran¹

Assistant Professor, Department of Biomedical Engineering, Imam Reza International University, Mashhad, Razavi Khorasan, Iran²

Health Technology Research Center, Imam Reza International University, Mashhad, Razavi Khorasan, Iran³

* Corresponding author

* نویسنده عهده‌دار مکاتبات

سال ۱۴۰۴ شماره ۲ پیاپی ۶۴

• تاریخ ارسال مقاله: ۱۴۰۲/۰۲/۰۴ • تاریخ پذیرش: ۱۴۰۳/۱۲/۱۴ • تاریخ انتشار: ۱۴۰۴/۰۶/۲۲ • نوع مطالعه: پژوهشی

Abstract

Background: Electroencephalography (EEG) is a cornerstone in cognitive neuroscience, providing critical insights into the neural mechanisms underlying skill acquisition. Despite significant advancements in signal processing techniques, extracting meaningful patterns from EEG data—especially in the context of dynamic neural shifts during learning—remains a persistent challenge. Traditional analytical approaches often fail to account for the nonlinear temporal dynamics inherent in learning processes, which limits their ability to decode subtle neural reorganizations. This study addresses this gap by proposing an innovative computational framework based on Rhodonea curves—sinusoidal patterns resembling flower petals—to analyze EEG signals during the acquisition of a complex motor skill: touch-typing by the Colemak keyboard layout.

Objective and Innovation: The study aims to develop and validate a computationally efficient algorithm for classifying EEG data across distinct stages of skill learning. Central to this approach is the introduction of asymmetry indices derived from Rhodonea curves, which quantify nonlinear features of brain activity. This work represents the first application of Rhodonea-based analysis in EEG signal processing, providing a geometrically intuitive and computationally lightweight alternative to conventional nonlinear methods, such as entropy or fractal dimension analysis.

Methodology: The dataset, available on IEEEDataPort, consisted of EEG recordings from 10 participants (6 females and 4 males), focusing on 9 channels (F3, Fz, F4, C3, Cz, C4, P3, POz, P4) collected during 12 typing sessions. Data from sessions 4, 8, and 11—representing the early, intermediate, and advanced learning phases—were analyzed, with each session repeated five times to capture intra-session variability. For the first time, a Rhodonea curve-based method has been introduced for signal analysis, featuring a structure resembling a flower with an adjustable number of petals. The Rhodonea model was parameterized with one to ten petals, and three new indices based on asymmetry in the Rhodonea curve were computed to characterize spatiotemporal variations in EEG signals. A Support Vector Machine (SVM) utilizing a one-vs-all strategy was employed to classify 15 classes (5 repetitions $\times$ 3 sessions). Channel-specific optimizations and petal-count analyses were conducted to identify discriminative brain regions and optimal model configurations.

Key Findings: The analysis revealed robust classification performance, with two-class classification achieving accuracies ranging from 79.3% to 93.3%. Optimal results were observed in channels F3, Fz, C3, C4, and POz using a 4-petal Rhodonea configuration. In the three-session classification, the highest accuracy was recorded for the advanced learning phase (Session 11: 92%), followed by the early phase (Session 4: 90%) and the intermediate phase (Session 8: 72.6%). The lower accuracy in Session 8 suggests a transitional neural state marked by unstable skill consolidation, where neither novice nor expert patterns dominate. Neuroanatomically, the frontal (F3, Fz), central (C3, C4), and parieto-occipital (POz) regions demonstrated heightened discriminative power, consistent with prior studies implicating these areas in cognitive control, motor planning, and visuospatial integration during learning. Session-specific activation patterns indicated early-phase prefrontal engagement for attention allocation and advanced-phase parietal consolidation for skill automatization.

Comparative Analysis: This study diverges from prior work by integrating geometric asymmetry metrics—rather than spectral or entropy-based features—to model learning-induced neural plasticity. The computational efficiency and interpretability of Rhodonea-based features (e.g., petal-count visualization) offer distinct advantages for real-time brain-computer interface (BCI) applications. Notably, the intermediate phase's lower accuracy (72.6%) highlights the methodological challenge of decoding transitional neural states, a limitation underrepresented in earlier literature.

Limitations and Future Directions: This research had limitations that should be considered in future studies. First, the small sample size ($N=10$) and fixed signal length (1280 samples) may limit generalizability; future work should incorporate larger datasets and variable-length signal analysis. Second, although the non-linear features presented are computationally simple and low-cost, using other complex features might enhance the model's performance. Third, while SVM demonstrated efficacy, comparative studies with deep learning models (e.g., CNNs, LSTMs) could further validate the method's robustness. Fourth, physiological validation via multimodal neuroimaging (e.g., fMRI/fNIRS) is needed to spatially localize the observed dynamics. Finally, statistical refinements—such as ANOVA or t-tests for feature selection—could enhance model rigor and mitigate overfitting risks.

Conclusion: This research pioneers the application of Rhodonea curves in EEG analysis, establishing a novel framework for decoding the neural correlation of skill learning. The high classification accuracies and neuroanatomically consistent results underscore the method's potential for both academic research and applied domains, including adaptive learning systems and neurorehabilitation. Future efforts should prioritize large-scale validation and integration with multimodal neuroimaging to advance our understanding of learning-related brain plasticity and refine real-world applications.

Keywords: Electroencephalography, Learning, Rhodonea curve, Signal processing, Classification, Asymmetry.

شناخت چنین فرایند کاربردی برای علت‌یابی، جهت‌دهی و بهبود مسائل مثبت مانند زبان‌آموزی، مهارت‌ها، آموزش و پرورش و یا کاستن مسائل منفی مانند اختلالات یادگیری، رفتارهای نابه‌هنجار، افکار و ارزیابی منفی و همچنین بهبود شیوه‌های فرزندپروری، اتخاذ درمان مؤثر برای بیماری‌ها و ناهنجاری‌ها ارزشی شایان توجه دارد.

۱- مقدمه

یادگیری را می‌توان یکی از مهم‌ترین امور در زندگی روزمره انسان‌ها دانست. با توجه به این نکته که انسان از بدو تولد درگیر تعامل با محیط اطراف خویش است، یادگیری را در جای‌جای زندگی و در تمام شئون آن می‌توان یافت؛ بنابراین آگاهی و

علوم شناختی یک حوزه مطالعاتی بین رشته‌ای است که به مطالعه ذهن و هوش می‌پردازد و شامل علوم فلسفه، روان‌شناسی، هوش مصنوعی، علم اعصاب، زبان‌شناسی و انسان‌شناسی است. واژه «شناختی» در این اصطلاح به معنای هر گونه ساختار یا عملیات ذهنی است که می‌توان آن را مورد مطالعه قرار داد [۱]. علوم اعصاب شناختی، به ارزیابی کارکردهای ذهن یا شناخت می‌پردازد. این کارکردها، دارای هم‌بستگی با فعالیت الکتروشیمیایی مغز و دستگاه عصبی بدن است. روش‌های مختلفی برای سنجش کارکرد ذهن وجود دارد؛ از جمله آن‌ها روش عصب‌شناختی است که مستقیم به ثبت فعالیت دستگاه عصبی آزمودنی هنگام مواجهه با محرک (برای مثال تحریک صوتی یا تصویری) یا تکلیف شناختی (به معنای سلسله معینی از محرک‌ها که فرد باید نسبت به آن واکنش دهد) می‌پردازد. شیوه‌های تصویربرداری تشدید مغناطیسی کارکردی^۱ (fMRI) و الکتروانسفالوگرافی^۲ (EEG) از جمله ثبت‌های فعالیت دستگاه عصبی به‌شمار می‌روند [۲]. در بیشتر این روش‌ها که به شیوه‌های نقشه‌برداری مغز معروف‌اند، فعالیت الکتروشیمیایی سلول‌های عصبی و میدان مغناطیسی حاصل از آن امکان سنجش پاسخ عصب‌شناختی فرد نسبت به محرک را فراهم می‌کند. دادگان الکتروانسفالوگرافی یکی از روش‌های نقشه‌برداری مغز است که امروزه در بین مطالعات شناختی و علوم اعصاب جایگاه خوبی پیدا کرده‌است. علوم اعصاب به‌طور فزاینده‌ای وارد حوزه‌های مختلف علمی و فنی شده‌است و روزبه‌روز بر اهمیت این علم نوپدید در علوم دیگر افزوده می‌شود و حدود بیش از بیست سال وجود پیوند عمیق بین کارکردهای مغزی و آموزش نشان شده‌است و امروزه تمامی شواهد مطالعاتی آن را تأیید می‌کنند. سازوکار یادگیری و حافظه به‌دلیل پیچیدگی، با چالش‌های بسیاری مواجه است که به‌تازگی مورد توجه پژوهش‌گران در حوزه علوم اعصاب قرار گرفته است. علوم اعصاب شناختی در پی کشف این است که دانش، بینش و تجربه چگونه در مغز پردازش می‌شوند و ارتباطات مغز چطور موجبات یادگیری جدید را فراهم می‌کند. یادگیری از نگاه علوم اعصاب، فرایند تغییرات در الگوی پیوند بین نورون‌ها با یکدیگر است که می‌تواند به چندین روش از طریق شکل‌گیری سیناپس‌های جدید، حذف سیناپسی^۳ و یا تقویت یا تضعیف پیوندها یا شبکه‌های عصبی موجود منعکس شود [۳]. پژوهش‌های اخیر در علوم شناختی و علوم اعصاب و ارتباط آن با نظریه و عملکرد تربیتی پیشرفت‌های قابل ملاحظه‌ای در درک ارتباط بین مغز و آموزش داشته است [۴]. حافظه به یادگیری و یادگیری به حافظه وابسته است و پژوهش‌گران علوم شناختی معتقدند

حافظه بدون یادگیری مفهومی ندارد. یادگیری به توانایی یا فرایند تبدیل امواج حسی دریافتی از محیط به دانش است که عملکردهای آینده را هدایت می‌کند. حافظه در مفهوم گسترده به دانش ایجادشده داخلی به‌عنوان نتیجه یادگیری اشاره دارد. مشخص شده توانایی یادگیری و فرایندهای حافظه (کدگذاری، نگهداری و یادآوری) مرتبط با دینامیک خود سازمان‌دهی مغز در مؤلفه‌های فعالیت مغزی مرتبط با مقیاس‌های زمانی و فرکانسی است [۵]. نقص در عملکردهای شناختی مانند یادگیری و حافظه ممکن است تغییرات رفتاری ایجاد کند که در بیشتر موارد با اختلالات شناختی شناخته شده‌است. بررسی چگونگی این عملکردها در مغز می‌تواند به تشخیص و درمان این اختلالات کمک کند؛ علاوه بر این، دلایل زیادی در ضرورت تبیین رابطه علوم اعصاب شناختی و آموزش و یادگیری مطرح شده‌است. بهبود وضعیت آموزش و پرورش از مهم‌ترین اولویت‌های راهبردی بسیاری از کشورهاست. از آنجا که مغز عضو اصلی دخیل در فرایند یادگیری است، تولید و توسعه دانش درباره کارکرد مغز می‌تواند به بهبود برنامه‌های آموزشی کمک کند؛ از طرفی، یافته‌های پژوهش‌گران موجی از بینش‌های جدید در مورد حافظه، توجه و هشیاری، تفکر، هیجان، انگیزش و یادگیری را به ارمغان آورده‌است به طوری که برنامه‌ریزی در مورد مسائل انسانی و موضوعات اجتماعی را آشکارا تحت تأثیر قرار داد است [۶-۸]. دانستن جزئیات کارکرد مغز در فرایند آموزش و یادگیری با بهره‌گیری از مطالعات تصویربرداری عصبی، اطلاعات ارزشمندی را در اختیار قرار داده‌است و در پرتو آن دانشمندان حوزه یادگیری و یاددهی، یافته‌های علوم اعصاب را در عرصه تعلیم و تربیت به‌کار گرفته‌اند [۹].

تاکنون مطالعات زیادی در موضوع یادگیری و حافظه انجام شده است. اغلب مطالعات پیشین از روش‌های طیفی یا زمان-فرکانس برای پردازش سیگنال‌های مغزی استفاده کرده‌اند [۱۰-۱۴]. بیشتر آن‌ها بر روی تغییرات توان باندهای مغزی تمرکز داشته‌اند [۱۰-۱۲، ۱۴-۱۷]. با توجه به پژوهش‌های فراوان انجام‌شده درباره حافظه و یادگیری و ارتباط آن با سیگنال‌های مغزی، هنوز در زمینه‌های متعدد مرتبط با حافظه و یادگیری اختلاف نظر وجود دارد که از دلایل آن پیچیدگی ساختار حافظه و تأثیر عوامل مختلف شناختی مثل روحیه، میزان هوش و میزان توجه فرد بر یادگیری است.

از نقطه نظر آیین‌نامه یادگیری، برخی از مطالعات بر یادگیری یک وظیفه حسی-حرکتی متمرکز بوده‌اند [۱۳، ۱۶-۱۸] و برخی دیگر یادگیری بصری به‌وسیله تماشای یک انیمیشن یا ویدئو را مورد بررسی قرار داده‌اند [۱۲، ۱۵]. از آنجا که پروتکل‌های یادگیری در مقالات متفاوت است؛ از این‌رو

¹ Functional Magnetic Resonance Imaging (fMRI)

² Electroencephalography

³ Synaptic pruning

طبیعی است که نتایج حاصل از آن‌ها نیز مختلف باشد؛ در نتیجه نمی‌توان نتایج حاصل از همه آن‌ها را از یک منظر جمع‌بندی کرد.

سیگنال‌های الکتروانسفالوگرام دارای ماهیت غیرایستا و آشوبناک‌اند [۱۹]؛ هرچند، پیاده‌سازی روش‌های متداول فرکانسی و زمانی مستلزم برقراری فرض ایستایی در سری زمانی است؛ در نتیجه، این رویکردها در فراهم کردن اطلاعات کافی و مناسب از سیگنال‌های بیولوژیکی نظیر EEG ناتوان‌اند؛ برخلاف آن‌که ویژگی‌های غیرخطی توصیف خوبی از سیگنال EEG در اختیار قرار می‌دهند، تعداد کمی مقاله با استفاده از روش‌های غیرخطی در این زمینه انجام شده‌است [۲۰-۲۲]؛ از طرفی، بیشتر روش‌های غیرخطی و هندسی که در مطالعات به کار رفته است بار محاسباتی بالایی دارند. در این پژوهش درصدد ارائه روش غیرخطی جدیدی هستیم تا علاوه بر چیره‌شدن بر محدودیت‌های پیشین تحلیل سیگنال EEG را با دقت و سرعت بالا انجام دهد؛ همچنین تاکنون هیچ پژوهشی در زمینه جداسازی مراحل یادگیری انجام نشده‌است؛ از این‌رو در این پژوهش سعی شده‌است علاوه بر معرفی روشی جدید برای پردازش سیگنال‌های بیولوژیک این مسئله نیز مورد بررسی قرار گیرد.

۲- مواد و روش‌ها

۲-۱- دادگان الکتروانسفالوگرام در حین یادگیری

در این پژوهش داده‌های موجود در IEEEDataPort مورد تجزیه و تحلیل قرار گرفت [۱۰]. در این پایگاه داده ده داوطلب در یک آزمایش با هدف آموزش تایپ در رایانه طی دوازده جلسه درسی با استفاده از صفحه کلید کولماک (Colemak) شرکت کردند. شش داوطلب زن و چهار داوطلب مرد همگی راست دست با میانگین سنی 29.5 ± 3.7 سال در مطالعه شرکت کردند. از شرکت‌کنندگان خواسته شد که هر یک از درس‌ها را پنج بار تکرار کنند (با فاصله استراحت دو دقیقه در میان آن‌ها). تمام آزمایش‌ها در یک ساعت از روز انجام و از همه داوطلبان خواسته شد که از انجام هرگونه آموزش اضافی در هر جای دیگر خودداری کنند. برای جلوگیری از حواس‌پرتی داوطلبان، آموزش در یک اتاقک ضد صدا انجام شد. به منظور ارزیابی پیشرفت در توانایی تایپ هر یک از داوطلبان، تکرارهای آن‌ها ضبط شد. این تکرارها شامل زمان استفاده‌شده برای نوشتن صحیح تمام واژگان درس و همچنین مدت زمان پاک کردن و بازنویسی واژگان به دلیل هرگونه اشتباه بود. از هر یک از داوطلبان با استفاده از دستگاه بی‌سیم B-Alert X10، سیگنال EEG در چهار جلسه ثبت شده‌است. این دستگاه شامل ترکیبی از نه حس‌گر است که طبق استاندارد بین‌المللی ۱۰-۲۰ در C4, Cz, C3, F4, Fz, F3

، P3, POz و P4 قرار می‌گیرد. تمام داده‌ها با فرکانس نمونه‌برداری ۲۵۶ هرتز دریافت شده‌است و با پالایه باترورث (Butterworth) مرتبه پنجم و فرکانس قطع ۰/۱ و ۱۰۰ هرتز پالایه شده‌اند. اندازه‌گیری‌های EEG در طی تکرارهای عمل تایپ در دروس چهارم، هشتم و یازدهم در پایگاه داده ارائه شده‌است که در آن به ترتیب از یک، دو و سه خط کامل از کلیدهای صفحه کلید استفاده شد. این سه درس به عنوان نماینده‌ای از دشواری‌های سطح پایین، متوسط و سطح بالا در انجام کار فرض می‌شود. در طول آزمایش، داوطلب جلوی رایانه نشسته بود، درحالی‌که درس مربوطه در نمایش‌گر نشان داده می‌شد و تایپ می‌کرد [۱۲]. طول هر یک از سیگنال‌ها بین شرکت‌کنندگان و همچنین برای هر تکرار بسته به مدت زمانی که موضوع متناظر برای تکمیل درس طول کشیده متفاوت است. در این مطالعه کمترین طول داده (حدود دو دقیقه) برای همه شرکت‌کننده‌ها انتخاب و جدا شدند و همه پردازش‌ها روی آن‌ها انجام شده‌است.

۲-۲- منحنی رودونی

یکی از روش‌هایی که برای شناسایی پویایی سیگنال‌های زیستی استفاده می‌شود، فضای فاز (نقشه دوبعدی) است. به طور معمول برای ایجاد فضای فاز دوبعدی هر نمونه از سیگنال در مقابل نمونه بعدی آن رسم می‌شود؛ هرچند، نقشه‌های مختلف دیگری نیز برای ارزیابی رفتار سیگنال معرفی شده‌است. رویکردی که برای نخستین بار در این پژوهش برای تجزیه و تحلیل سیگنال EEG مورد استفاده قرار گرفته، روشی است که بین سال‌های ۱۷۲۳ تا ۱۷۲۸ توسط ریاضی‌دان ایتالیایی، گویدو رندی، رودونی (Rhodonea) نام گرفت [۲۳]. این منحنی که شبیه به گل رز است، به کمک دو معادله زیر در مختصات دکارتی تعریف می‌شود:


$$\begin{aligned} X &= \cos(ka) \times \cos(a) \\ Y &= \cos(ka) \times \sin(a) \end{aligned} \quad (1)$$

که در آن k تعداد گلبرگ‌های منحنی را تعیین می‌کند و a بیان‌کننده نمره استاندارد (z-score) سیگنال مغزی است و به صورت زیر محاسبه می‌شود:


$$a = \frac{\text{data} - \text{mean}(\text{data})}{\text{standard deviation}(\text{data})} \quad (2)$$

نمره استاندارد سیگنال برابر است با داده (data) منهای میانگین سری زمانی (mean(.)) تقسیم بر انحراف استاندارد سیگنال (standard deviation(.)).


شکل نمودار به شدت به مقدار k وابسته است. اگر k یک عدد صحیح زوج باشد، نمودار شبیه یک گل کلاسیک با $2k$ گلبرگ خواهد بود و اگر k فرد باشد، نمودار k گلبرگ دارد؛ همچنین اگر k نیمی از یک عدد صحیح باشد، مانند ۱/۵،




(ج)




(ج)




(ح)



(خ)



(د)




(ذ)

(شکل-۱): نمایش سری‌های زمانی دوره‌ای، تصادفی و الکتروانسفالوگرام به همراه منحنی رودونی (الف) سری‌های زمانی دوره‌ای، تصادفی و الکتروانسفالوگرام، (ب) منحنی رودونی با $k=1$ ، (پ) منحنی رودونی با $k=2$ ، (ت) منحنی رودونی با $k=3$ ، (ث) منحنی رودونی با $k=4$ ، (ج) منحنی رودونی با $k=5$ ، (چ) منحنی رودونی با $k=6$ ، (ح) منحنی رودونی با $k=7$ ، (خ) منحنی رودونی با $k=8$ ، (د) منحنی رودونی با $k=9$ ، (ذ) منحنی رودونی با $k=10$


(figure-1): Representation of periodic, random, and electroencephalogram time series along with Rhodonea curve (a) Periodic, random, and electroencephalogram time series, (b) Rhodonea curve with $k=1$, (c) Rhodonea curve with $k=2$, (t) Rhodonea curve with $k=3$, (d) Rhodonea curve with $k=4$, (c) Rhodonea curve with $k=5$, (g) Rhodonea curve with $k=6$, (h) Rhodonea curve with $k=7$, (x) Rhodonea curve with $k=8$, (d) Rhodonea curve with $k=9$, (z) Rhodonea curve with $k=10$.

همان‌طور که در شکل (۱) نشان داده شده، پراکندگی نقاط در نمودار رودونی سیگنال دوره‌ای زیاد است؛


$\frac{2}{5}$ و غیره، تعداد گلبرگ‌های نمودار k خواهد بود، اما آن‌ها با هم هم‌پوشانی دارند که برای عدد صحیح این مورد رخ نمی‌دهد. در این پژوهش، برای یافتن تعداد گلبرگ بهینه، مقادیر صحیح یک تا ده برای k مورد بررسی قرار گرفت. ابتدا الگوی پیشنهادی برای سیگنال‌هایی با ماهیت متفاوت بررسی شد. هدف مقایسه و ارزیابی مدل برای سیگنال‌های مختلف مانند دوره‌ای^۱، تصادفی^۲ و الکتروانسفالوگرام بود. شکل (۱) سری‌های زمانی در سه حالت دوره‌ای، تصادفی و الکتروانسفالوگرام را به همراه منحنی رودونی آن‌ها برای تعداد گلبرگ یک تا ده نشان می‌دهد. طول هر سه سیگنال یادشده ۱۲۸۰ انتخاب شد و منحنی رودونی آن‌ها بعد از نرمال‌سازی سیگنال‌ها به‌دست آمد. گفتنی است، سیگنال دوره‌ای به کمک معادله سینوسی $\sin(2\pi t)$ و سیگنال تصادفی با توزیع یک‌نواخت با دستور rand متلب به‌دست آمده‌است. (همه پردازش‌ها و شبیه‌سازی‌های این پژوهش به کمک نرم‌افزار متلب^۳ انجام شده‌است).




(الف)




(ب)



(پ)



(ت)



(ث)

¹ Periodic signal
² Random signal
³ MATLAB

$m_{1down}, m_{2down}, m_{3down}, \dots, m_{l_{down}}$ است و m شیب هر نقطه در نمودار رودونی است.

شاخص سوم: شاخص سوم نسبت مجموع فاصله اقلیدسی^۴ نقاط بالای محور x از مبدأ به مجموع فاصله اقلیدسی نقاط پایین محور x از مبدأ است. اگر فرض کنیم n نقطه در بالای محور x و m نقطه در پایین محور x داشته باشیم، آنگاه مجموع فاصله اقلیدسی نقاط بالای محور و مجموع فاصله اقلیدسی نقاط پایین محور به ترتیب از معادله‌های (۵) و (۶) به دست می‌آید.

$$d_{up} = \sqrt{x_{1u}^2 + y_{1u}^2} + \sqrt{x_{2u}^2 + y_{2u}^2} + \dots + \sqrt{x_{nu}^2 + y_{nu}^2} \quad (5)$$

$$d_{down} = \sqrt{x_{1d}^2 + y_{1d}^2} + \sqrt{x_{2d}^2 + y_{2d}^2} + \dots + \sqrt{x_{md}^2 + y_{md}^2} \quad (6)$$

بنابراین شاخص سوم به صورت زیر است:

$$SD^5 = \frac{d_{up}}{d_{down}} \quad (7)$$

در این مقاله سه رابطه (روابط ۳، ۴ و ۷) برای محاسبه نبود تقارن پیشنهاد شده است.

شکل (۲) نمایش گرافیکی ویژگی‌های نبود تقارن را به صورت نمادین نشان می‌دهد. اگر مقدار صورت کسر در هر کدام از شاخص‌ها از مقدار مخرج آن بیشتر شود، حاصل بزرگ‌تر از یک خواهد بود و بالعکس؛ همچنین اگر مقدار ضرایب گفته شده برابر یک شود (مساوی بودن صورت و مخرج) نشانه متقارن بودن نمودار خواهد بود.

سه شاخص ارائه شده برای n کانال $k=1,2,3,\dots,10$ گلبرگ، برای ده فرد شرکت کننده و پانزده جلسه یادگیری به دست آمد (در مجموع ۲۷۰ ویژگی برای هر شخص). ویژگی‌های محاسبه شده برای نرمال سازی، در بازه [۱-۱] قرار گرفتند.

برای این کار ابتدا از معادله (۸) استفاده شد که در آن $\min(x_i)$ کران پایینی و $\max(x_i)$ کران بالایی داده‌ها در نظر گرفته شده است.

مقدار نرمال شده یک ویژگی x_i به صورت زیر به دست می‌آید:

$$x_i = \frac{x_i - \min(x_i)}{\max(x_i) - \min(x_i)} \quad (8)$$

پس از این نوع نرمال سازی $\min(x_{new}) = 0$ و $\max(x_{new}) = 1$ است. برای قرارگرفتن ویژگی‌های نرمال شده در بازه [۱-۱] از رابطه زیر استفاده شد:

$$x_{new} = x_i \times 2 - 1 \quad (9)$$

به طوری که شکل کامل آن تشخیص داده نمی‌شود. در داده‌های تصادفی تمرکز نقاط در شکل‌گیری شکل واقعی نمودار رودونی است، در سری زمانی EEG نیز منحنی کمابیش به صورت کامل شکل گرفته است. نکته جالب این است که برای سیگنال تصادفی در بعضی k ها (به ویژه در k های زوج) شکل نمودار رودونی به صورت کامل تشکیل نشده است؛ در حالی که از روی منحنی رودونی سیگنال EEG می‌توان تعداد گلبرگ‌های منحنی را حدس زد.

۳-۲- استخراج ویژگی

در این پژوهش، از ویژگی‌های نبود تقارن فضای فاز استفاده شده است. سامانه‌های بیولوژیک در شرایط عادی در حالت نبود تعادل عمل می‌کنند و قابلیت خودسازماندهی آن‌ها به نبود تقارن فرایندهای اساسی وابسته است؛ به عبارتی، توزیع سیگنال‌ها نامتعادل و این نبود تعادل به خوبی در نمودارهای فضای فاز قابل مشاهده است [۱۹]. فرض ما بر این است، هنگام انجام فعالیت‌های شناختی مانند یادگیری این مورد دست‌خوش تغییر شود. این مورد ایده بررسی شاخص‌های نبود تقارن^۱ در منحنی رودونی را به ما داد؛ از این رو سه شاخص زیر برای کمی‌سازی منحنی رودونی محاسبه و نبود تقارن نسبت به محور افقی بررسی شد. در ادامه، به معرفی این شاخص‌ها می‌پردازیم. (در فرمول‌های زیر up نشان‌دهنده نقاط بالای محور x و $down$ نشان‌دهنده نقاط پایین محور x است.)

شاخص نخست: نسبت مجموع تعداد نقاط بالای محور x به مجموع تعداد نقاط پایین محور x است. این شاخص به صورت زیر تعریف می‌شود:

$$SP^2 = \frac{\sum p_{up}}{\sum p_{down}} \quad (3)$$

که در آن p_{up} نقاط بالای محور x و p_{down} نقاط پایین محور x است.

شاخص دوم: شاخص دوم به عنوان ضریبی از قدرمطلق حاصل جمع شیب نقاط بالای محور x به قدرمطلق مجموع شیب نقاط پایین محور x تعریف می‌شود و می‌توان آن را به صورت زیر نمایش داد:

$$SS^3 = \frac{|\sum sl_{up}|}{|\sum sl_{down}|} \quad (4)$$

در این معادله با فرض اینکه n نقطه بالای محور افق و l نقطه پایین محور افق داشته باشیم، $sl_{up} =$ و $sl_{down} = m_{1up}, m_{2up}, m_{3up}, \dots, m_{nup}$

¹ Asymmetry

² Sum Points

³ Sum Slopes

⁴ Euclidean Distance

⁵ Sum Distances

پیچیدگی محاسبات اشاره کرد. در این پژوهش طبقه‌بندی پنج تکرار هر جلسه (پانزده طبقه) با SVM با کرنل خطی^۳ انجام شد؛ به‌طور دقیق‌تر، نمی‌خواهیم یادگیری را تنها به سه درس محدود، بلکه می‌خواهیم به جزئیات و پیشرفت‌های تدریجی هر جلسه توجه کنیم؛ چرا که ممکن است، یک درس خاص به‌تنهایی نتواند تمامی ابعاد یادگیری را نشان دهد؛ همچنین نتایج طبقه‌بندی برای کانال‌های مختلف مغزی و گلب‌های متفاوت بررسی شد. هدف این کار، یافتن کانال مغزی فعال و گلب‌برگ بهینه در منحنی رودونی هنگام انجام فرایند یادگیری بود؛ برای این منظور از رویکرد یک در مقابل همه^۴ استفاده شد که در آن هر جلسه به‌عنوان یک کلاس در نظر گرفته می‌شود؛ به این صورت که برای هر جلسه، آن جلسه به‌عنوان کلاس یک انتخاب شده و همه جلسات دیگر به‌عنوان کلاس دو طبقه‌بندی می‌شوند. این رویکرد به ما این امکان را می‌دهد که نتایج به‌دست‌آمده را دقیق‌تر تحلیل کنیم و تأثیرات یادگیری را در هر جلسه به‌طور مستقل ارزیابی کنیم؛ برای مثال در این رویکرد، جلسه نخست درس هشت به‌عنوان کلاس یک و چهار جلسه دیگر آن درس و تمام جلسات دروس دیگر به‌عنوان کلاس دو در نظر گرفته می‌شود (طبقه‌بندی دودویی) و سپس طبقه‌بندی انجام می‌شود. این کار برای تمام جلسات تمام دروس تکرار می‌شود و هر بار یک جلسه به‌عنوان کلاس یک و سایر جلسات باقی‌مانده در کلاس دو قرار می‌گیرند؛ به‌علاوه به‌کمک روش اعتبارسنجی متقابل k-fold با k=۱۰ ارزیابی شد. سه شاخص صحت^۵، حساسیت^۶، و امتیاز F1^۷ برای ارزیابی عملکرد محاسبه شد. شاخص‌های بالا به‌ترتیب از معادلات (۱۰) - (۱۲) به‌دست می‌آیند:

$$Acc = \frac{TP + TN}{FP + FN + TP + TN} \quad (10)$$

$$Sn = \frac{TP}{TP + FN} \quad (11)$$

$$F_1 = \frac{2TP}{2TP + FP + FN} \quad (12)$$

هر یک از متغیرها در معادلات بالا به‌صورت زیر تعریف می‌شوند:

TP (True Positive): موارد مثبتی که مثبت تخمین زده شده‌اند.

FP (False Positive): موارد منفی که مثبت تخمین زده شده‌اند.

FN (False Negative): موارد مثبتی که منفی تخمین زده شده‌اند.

TN (True Negative): موارد منفی که منفی تخمین زده شده‌اند.


³ Linear kernel

⁴ One vs. all

⁵ Accuracy


⁶ Sensitivity

⁷ F1 score



الف


$$sl_{up} = m_{1up} + m_{2up} + m_{3up} + m_{4up}$$



$$sl_{down} = m_{1down} + m_{2down} + m_{3down}$$

ب

$$d_{up} = l_{1up} + l_{2up} + l_{3up} + l_{4up}$$



$$d_{down} = l_{1down} + l_{2down} + l_{3down}$$

ج

(شکل-۲): نمایش گرافیکی شاخص‌های نبود تقارن نمودار

رودونی (الف) SP، (ب) SS و (ج) SD

(Figure-2): Graphic representation of asymmetry indices of Rhodonea diagram (a) SP, (b) SS, and (c) SD

۲-۴- طبقه‌بندی

در این مطالعه از طبقه‌بند معروف و کاربردی ماشین بردار پشتیبان^۱ (SVM) استفاده شده‌است. از نقاط قوت طبقه‌بند SVM می‌توان به امکان انتخاب تابع کرنل^۲ با توجه به شرایط توسط کاربر، مناسب‌بودن برای کار روی داده‌های کوچک، مصرف بهینه در حافظه، فرایند آموزش ساده، درگیرنشدن در نقاط بیشینه محلی، وجود تناسب بین میزان خطا و

¹ Support vector machine

² Kernel Function

۳- ارائه مدل

روش پیشنهادی این پژوهش مبتنی بر تحلیل سیگنال‌های EEG در فرایند یادگیری تایپ با استفاده از منحنی رودونی و شاخص‌های نبود تقارن است. در مرحله نخست، داده‌های ده داوطلب از پایگاه IEEEDataPort شامل سیگنال‌های EEG ثبت‌شده در نه کانال مغزی جمع‌آوری شد [۱۰]. این داده‌ها با تمرکز بر سه درس با سطوح دشواری متفاوت (پایین، متوسط و بالا) و انتخاب بازه‌های زمانی دو دقیقه‌ای از هر شرکت‌کننده پیش‌پردازش شدند. فرایند پیش‌پردازش شامل پالایه‌کردن با پالایه باترورث (مرتبه پنجم، فرکانس قطع ۰/۱ و ۱۰۰ هرتز) و نرمال‌سازی داده‌ها با روش z-score بود تا سیگنال‌ها برای تحلیل آماده شوند.

در مرحله بعد، سیگنال‌های نرمال‌شده با استفاده از معادلات منحنی رودونی به مختصات دوبعدی تبدیل شدند. این منحنی با تنظیم پارامتر k (از ۱ تا ۱۰) به عنوان تعداد گلب‌ها ساخته شد تا رفتار دینامیکی سیگنال‌ها در فضای فاز بررسی شود؛ سپس سه شاخص نبود تقارن مبتنی بر توزیع نقاط، شیب و فاصله اقلیدسی نقاط نسبت به محور افقی محاسبه شد. این شاخص‌ها برای هر یک از نه کانال مغزی و ده مقدار k استخراج شدند که در نهایت ۲۷۰ ویژگی‌های استخراج‌شده به بازه [۱، -۱] نرمال‌سازی شدند تا مقایسه‌پذیری افزایش یابد.



(شکل-۳): روش پیشنهادی
(Figure-3): Proposed approach

در مرحله نهایی، از طبقه‌بند ماشین بردار پشتیبان با کرنل خطی برای طبقه‌بندی پانزده کلاس متناظر با پنج تکرار در سه جلسه آموزشی استفاده شد. رویکرد «یک در مقابل همه» به کار گرفته شد تا عملکرد مدل در تشخیص پیشرفت یادگیری در هر جلسه ارزیابی شود، مطابق شکل (۳). هدف اصلی، شناسایی کانال‌های مغزی فعال و مقدار بهینه k در منحنی رودونی بود که بیشترین

ارتباط را با تغییرات شناختی طی فرایند یادگیری نشان می‌دهند. این روش با ترکیب ریاضیات منحنی رودونی و یادگیری ماشین، چهارچوبی نوین برای تحلیل پویایی سیگنال‌های مغزی در فعالیت‌های شناختی ارائه می‌کند.

۴- یافته‌ها

در این پژوهش، طبقه‌بندی پانزده جلسه یادگیری انجام شد؛ علاوه بر این، عملکرد طبقه‌بند در هر جلسه برای گلب‌های مختلف به منظور پیداکردن گلب‌گ بهینه بررسی شد؛ همچنین جداسازی جلسات برای کانال‌های مختلف نیز انجام شد تا کانال یا کانال‌های فعال در حین یادگیری مشخص شوند. جدول (۱) نتایج طبقه‌بندی پانزده جلسه بدون در نظر گرفتن گلب‌گ‌ها و کانال‌ها به همراه مقدار میانگین و انحراف معیار آن‌ها را نشان می‌دهد. تعداد ویژگی‌های اعمالی برای هر تعداد گلب‌گ ۲۷ (سه ویژگی نبود تقارن $\times$ نه کانال مغزی) بوده است. برای تعداد گلب‌گ یک تا ده تعداد ۲۷ ویژگی وارد طبقه‌بندی شد و معیارهای ارزیابی عملکرد طبقه‌بندی‌کننده برای طبقه‌بندی پانزده جلسه محاسبه شد؛ در نهایت، مقادیر میانگین و انحراف معیار، مقادیر صحت، حساسیت و امتیاز F1 گزارش شد.

(جدول-۱): مقادیر خروجی طبقه‌بندی پانزده جلسه
(Table-1): The classification output values of 15 sessions

جلسات	صحت	امتیاز F1	حساسیت
جلسه ۱	۹۱.۳±۴.۴	۹۵.۴±۲.۵	۹۳.۱±۳.۰
جلسه ۲	۹۰.۶±۴.۶	۹۴.۹±۲.۸	۹۳.۹±۲.۱
جلسه ۳	۹۰.۴±۴.۷	۹۴.۶±۲.۶	۹۳±۳.۰
جلسه ۴	۸۹.۳±۴.۶	۹۴.۳±۲.۶	۹۳±۳.۰
جلسه ۵	۹۳.۳±۰	۹۶.۵±۰.۸	۹۴±۲.۸
جلسه ۶	۹۰±۳.۵	۹۴.۷±۱.۹	۹۳±۲.۰
جلسه ۷	۸۸±۵.۲	۹۳.۴±۳.۸	۹۲.۴±۷.۰
جلسه ۸	۹۰±۴.۷	۹۴.۶±۲.۶	۹۳±۳.۰
جلسه ۹	۹۱.۳±۳.۲	۹۵.۴±۱.۷	۹۳.۱±۲.۰
جلسه ۱۰	۹۰±۶.۴	۹۴.۶±۳.۸	۹۳±۵.۰
جلسه ۱۱	۹۲±۴.۲	۹۵.۷±۲.۲	۹۳.۸±۲.۱
جلسه ۱۲	۹۲±۲.۸	۹۵.۸±۱.۵	۹۳.۲±۰.۲
جلسه ۱۳	۸۹.۳±۶.۴	۹۴.۲±۳.۸	۹۳±۰.۵
جلسه ۱۴	۹۰.۶±۳.۴	۹۵±۱.۹	۹۳.۸±۲.۱
جلسه ۱۵	۹۱.۳±۳.۲	۹۵.۴±۱.۷	۹۳.۱±۰.۱

همان طور که نتایج جدول (۱) نشان می‌دهد بالاترین نتیجه از آن جلسه پنجم که آخرین تکرار جلسه چهارم است، پس از آن، جلسه یازدهم و دوازدهم بیشترین صحت را دارد؛ علاوه بر این جلسه هفت، سیزده و چهار به ترتیب کمترین مقدار طبقه‌بندی را دارند. میانگین صحت برای تکرارهای هر درس در جدول (۲) نشان داده شده است؛ به طور دقیق‌تر، میانگین عملکرد طبقه‌بندی‌کننده در جلسات یک تا پنج مربوط به درس چهارم،

نتایج جدول (۳) حاکی از آن است که در بیشتر جلسات تمام کانال‌ها نتایج مطلوبی داشته‌اند، به ویژه کانال‌های F3، Fz، C3، C4، P4 و Poz که بیشترین تکرار در نتایج جلسات یادگیری را داشته‌اند. از بین ده گلیبرگ بررسی شده، تعداد گلیبرگی که در بیشترین جلسات بالاترین نتیجه طبقه‌بندی را داشته مربوط به $K=4$ است؛ پس از آن ویژگی‌های استخراج شده از منحنی رودونی با $K=2,3,6,7,9,10$ گلیبرگ در مقایسه با سایر گلیبرگ‌ها نتایج بهتری داشته‌اند. در جدول (۳) جلسات (۵ و ۶) بهترین عملکرد طبقه‌بندی مشاهده می‌شود. جلسات (۲ و ۷) و پس از این دو، جلسه (۴) به ترتیب پایین‌ترین نتایج را در جدول (۳) داشته‌اند این مورد هم در نتایج جدول (۱) وجود دارد (جلسه ۴ و ۷)؛ در مجموع، نتایج حاصل از طبقه‌بندی بین $79/3$ تا $93/3$ درصد در نوسان است که نشان‌دهنده عملکرد موفق طبقه‌بندی در پژوهش است.

۵- بحث و نتیجه‌گیری

هدف از انجام این مطالعه ارائه یک روش جدید برای تجزیه و تحلیل سیگنال‌های زیستی بود. به طور خاص، روش پیشنهادی با طبقه‌بندی دادگان EEG در حین یادگیری چندطبقه مورد آزمایش و ارزیابی قرار گرفت؛ به علاوه، مدل برای سری‌های زمانی مختلف شامل دوره‌ای، تصادفی و EEG بررسی و در این ارزیابی، طول هر سه سیگنال ۱۲۸۰ انتخاب شد. این در حالی است که استقلال طول سیگنال از الگوی مسیر پیش‌تر ثابت شده است [۲۴]. در مقالات پیشین از ویژگی‌های غیرخطی برای مورد خاص یادگیری به ندرت استفاده شده است [۲۰-۲۲]؛ هرچند، ویژگی‌های ارائه شده در این پژوهش از نظر محاسباتی ساده و کم‌هزینه‌اند، پیشنهاد می‌شود در مطالعات آینده از سایر ویژگی‌ها نیز برای کمی‌سازی مدل پیشنهادی استفاده شود؛ علاوه بر این جلسات مختلف یادگیری به کمک یک طبقه‌بند با رویکرد یک در مقابل همه از یکدیگر تفکیک شدند؛ درحالی که مطالعات گذشته نوع طبقه‌بندی و دادگان متفاوت بوده است [۱۵]. نتایج طبقه‌بند، مقادیر بین $79/3$ تا $93/3$ درصد را نشان می‌دهد. بیشتر نتایج مربوط به بالاترین صحت و پایین‌ترین صحت در جدول (۱) با نتایج جدول (۳) مطابقت دارد. نزدیک بودن نتایج طبقه‌بندی هر جلسه یادگیری را می‌توان با کم بودن طول دادگان در جلسات یادگیری استدلال کرد. این امکان وجود دارد که اگر طول سیگنال را بیشتر در نظر بگیریم، تفاوت‌های آن‌ها بهتر قابل تشخیص باشد و نتایج متفاوت‌تر شود. نرمال‌سازی ویژگی‌های استخراج شده ممکن است بر روی نزدیک بودن نتایج به هم تأثیرگذار باشد؛ بنابراین، بهتر است در مطالعات آینده نبود نرمال‌سازی دادگان نیز مورد بررسی قرار گیرد؛ از طرف دیگر، در بیشتر موارد تکرار نخست نسبت به تکرار پنجم

جلسات شش تا ده مربوط به درس هشتم و جلسات یازده تا پانزده مربوط به درس یازدهم محاسبه و در جدول (۲) گزارش شده است؛ همان‌طور که در جدول (۲) قابل ملاحظه است، بالاترین صحت و پایین‌ترین صحت به ترتیب برای دروس یازدهم و هشتم است. برای بررسی بیشتر نتایج، ویژگی‌های هر کانال و ده گلیبرگ در هر جلسه جداگانه به طبقه‌بند داده شد. در این حالت، ویژگی‌های وارد شده به طبقه‌بند سه ویژگی نبود تقارن بوده است؛ به طور دقیق‌تر، سه ویژگی نبود تقارن از کانال F3 برای تعداد گلیبرگ یک وارد طبقه‌بندی کننده شد و معیارهای ارزیابی عملکرد طبقه‌بندی کننده محاسبه شد. در ادامه، برای همین کانال با افزایش تعداد گلیبرگ‌ها به دو بار دیگر محاسبات انجام و این کار برای تمام کانال‌ها (نه کانال) به تفکیک و برای تعداد گلیبرگ‌های یک تا ده به طور مجزا انجام شد؛ پس از محاسبه معیارها، بالاترین درصد صحت عملکرد طبقه‌بندی کننده مشخص شد و کانال مغزی و تعداد گلیبرگ‌هایی که منجر به حصول بالاترین درصد صحت عملکرد طبقه‌بندی کننده شده است، مشخص شد. جدول (۳) نتایج حاصل از این مورد را نشان می‌دهد. در ستون دوم کانال و گلیبرگ‌هایی که بهترین نتایج را داشت، آمده است.

(جدول-۲): میانگین مقادیر خروجی تکرارهای سه درس یادگیری
(Table-2): Average output values of repetitions of three learning lessons

درس	صحت	امتیاز F1	حساسیت
درس چهارم	۹۰	۹۵.۱	۹۳.۳
درس هشتم	۷۲.۶	۹۴.۵	۹۳
درس یازدهم	۹۲	۹۵	۹۳

(جدول-۳): مقادیر خروجی طبقه‌بندی پانزده جلسه از حیث بهترین کانال و بهترین گلیبرگ

(Table-3): The output values of the classification of 15 sessions in terms of the best channel and the best petal

جلسات	بهترین گلیبرگ / بهترین کانال	صحت	امتیاز F1	حساسیت
جلسه ۱	۶، ۹، ۱۰ همه	90 ± 4.7	94.6 ± 2.6	93 ± 3.0
جلسه ۲	۲، ۷، ۱۰ همه	79.3 ± 7.9	88.1 ± 4.6	92.9 ± 2.5
جلسه ۳	C3/2	90 ± 4.7	94.6 ± 2.6	93 ± 3.0
جلسه ۴	F3, Fz, C3, C4, P3/1, 3, 4, 5	88.6 ± 6.3	93.8 ± 3.7	92.9 ± 0.5
جلسه ۵	۴ همه	92 ± 4.2	95.7 ± 2.2	93.8 ± 2.1
جلسه ۶	همه همه	92.6 ± 3.7	96.1 ± 2.0	93.8 ± 2.1
جلسه ۷	۴، ۵، ۶، ۹ همه	79.3 ± 7.9	88.2 ± 4.9	92.1 ± 0.7
جلسه ۸	همه همه	91.3 ± 3.2	95.4 ± 1.7	93.1 ± 0.2
جلسه ۹	P4, Poz/6	90 ± 6.4	94.6 ± 1.3	93 ± 0.5
جلسه ۱۰	۳، ۹ همه	90.6 ± 4.6	95 ± 2.6	93.1 ± 0.3
جلسه ۱۱	همه همه	91.3 ± 4.4	95.4 ± 2.4	93.8 ± 2.1
جلسه ۱۲	Fz, C3, C4, P3, P4/4	91.3 ± 3.2	95.4 ± 1.7	93.1 ± 0.2
جلسه ۱۳	۴، ۷، ۱۰ همه	90 ± 4.7	94.6 ± 1.8	93 ± 0.3
جلسه ۱۴	C4/3	90.6 ± 3.4	94.6 ± 1.8	93.7 ± 2.1
جلسه ۱۵	۷، ۲ همه	90.6 ± 3.4	95 ± 1.9	93.1 ± 0.2

در سه جلسه یادگیری بهبودی دیده نشده است، اما با توجه به نتایج جدول (۲) طبقه‌بند دروس چهارم و یازدهم را که به ترتیب به عنوان یادگیری با سطح دشواری کم و زیاد بوده‌اند، به خوبی تفکیک کرده است. می‌توان گفت در درس چهارم، یادگیری خیلی کم صورت گرفته است؛ در صورتی که در درس یازدهم یادگیری به صورت کامل انجام شده، اما درس هشتم که سطح یادگیری متوسط است، درصد صحت پایین‌تری دارد؛ زیرا در این درس نه یادگیری انجام نشده و نه یادگیری به طور کامل اتفاق افتاده است؛ از این رو، نتیجه کمتری را به دنبال داشته است. کانال‌های F3, Fz, C3, C4, Poz و P4 بالاترین نتایج در طبقه‌بندی را داشته‌اند. این بدین معنا است که نواحی جلویی، مرکزی و آهیانه هنگام یادگیری فعال‌اند. این نتیجه با نتایج مطالعات گذشته مطابقت دارد. در [۱۱] نشان داده شد در حین یادگیری لوب گیج‌گاهی و نواحی جلویی و آهیانه فعال می‌شود؛ همچنین، در [۱۵] آمده است که مناطق پیشانی و پس‌سری و آهیانه در طول یادگیری بیشتر فعال بوده‌اند؛ همچنین در [۲۵] چگالی طیف توان و ویژگی‌های غیرخطی سیگنال‌های پایگاه داده مطالعه حاضر [۱۲] قبل و بعد از یادگیری مورد بررسی قرار گرفت. نتایج این پژوهش نشان داد که در بین ویژگی‌های غیرخطی، در هفتاد درصد کانال‌های EEG تفاوت معنی‌داری در مقادیر آنتروپی مشاهده می‌شود که عمده این تفاوت در الکترودهای F3, Fz, C3, Cz, POz و P4 رخ داده است. نتایج مطالعه ما نشان داد که بهترین تعداد گلب‌گ چهار است؛ هرچند، با تعداد گلب‌گ غیر از پنج و هشت نیز نتایج خوبی حاصل شد؛ از این رو، زوج یا فرد بودن تعداد گلب‌گ‌های منحنی رودونی در نتایج طبقه‌بندی تأثیر چندانی نداشته است.

مطالعه حاضر دارای محدودیت‌هایی نیز بود که باید در پژوهش‌های آینده مورد توجه قرار گیرد. در این پژوهش، یک روش غیرخطی جدید با بار محاسباتی پایین معرفی شد؛ هرچند باید با استفاده از دادگان بیشتر اعتبار آن ارزیابی شود. داده‌های موجود محدود به تعداد جلسات و طول سیگنال‌ها بود. با وجود انتخاب طول ثابت ۱۲۸۰ برای سیگنال‌ها این احتمال وجود دارد که افزایش طول سیگنال‌ها تفاوت‌های معنادارتری بین جلسات یادگیری ایجاد کند؛ همچنین، کم‌بودن طول داده‌ها در برخی جلسات ممکن است به نزدیکی نتایج طبقه‌بندی منجر شده باشد. استفاده از دادگان بیشتر می‌تواند به بهبود صحت و تعمیم‌پذیری نتایج کمک کند؛ اگرچه ویژگی‌های غیرخطی ارائه‌شده کم‌هزینه و ساده‌اند، اما استفاده از سایر ویژگی‌های پیچیده‌تر ممکن است عملکرد مدل را بهبود بخشد. در اینجا بهترین کانال و بهترین گلب‌گ با توجه به عملکرد طبقه‌بند مشخص شدند؛ اگرچه کانال‌های خاصی (مانند F3, Fz, C3, Cz, POz و P4) نتایج بهتری نشان دادند، اما کاهش کانال‌ها و ویژگی‌ها با روش‌های

آماري دقیق‌تر بررسی نشد. پیشنهاد می‌شود در مطالعات آینده این موارد به کمک آزمون‌های آماری و مقایسه تفاوت معنادار بین جلسات نیز مورد بررسی قرار گیرد؛ از طرفی، محدودیت در تعداد کانال‌ها و ویژگی‌ها ممکن است بر عملکرد طبقه‌بند تأثیرگذار باشد. پیشنهاد می‌شود در مطالعات آینده از الگوریتم‌های جدید برای کاهش کانال‌ها و ویژگی‌ها به منظور بهبود عملکرد طبقه‌بند استفاده شود. در این مطالعه، درکل طبقه‌بندی پانزده جلسه یادگیری انجام شده است. می‌توان در کارهای بعدی طبقه‌بندی تکرارهای نخست تا پنجم هر جلسه را نیز ارزیابی کرد؛ به علاوه، این مطالعه تنها از یک طبقه‌بند (ماشین بردار پشتیبان) با رویکرد «یک در مقابل همه» استفاده کرد و مقایسه با الگوریتم‌های طبقه‌بندی دیگر انجام نشد. پیشنهاد می‌شود، بررسی عملکرد سایر طبقه‌بندها نیز بر روی این دادگان و مدل ارائه‌شده مورد مطالعه قرار گیرد؛ در نهایت، با وجود نتایج امیدوارکننده، اعتبار روش پیشنهادی نیازمند آزمایش روی پایگاه‌های داده متنوع‌تر و بزرگ‌تر است.

6-References

۶-مراجع

- [1] G. Lakoff, M. Johnson, and J.F. Sowa. "Review of Philosophy in the Flesh: The embodied mind and its challenge to Western thought," Computational Linguistics, Vol. 25, No. 4, pp. 631-634, 1999.
- [2] C. Yen, C. L. Lin, and M. C. Chiang, "Exploring the Frontiers of Neuroimaging: A Review of Recent Advances in Understanding Brain Functioning and Disorders," Life (Basel), Vol. 13, No. 1472, 2023. <https://doi.org/10.3390/life13071472>
- [3] P. Marzola, T. Melzer, E. Pavesi, J. Gil-Mohapel, and P. S. Brocardo, "Exploring the Role of Neuroplasticity in Development, Aging, and Neurodegeneration," Brain Sciences, Vol. 13, No. 1610, 2023. <https://doi.org/10.3390/brainsci13121610>
- [4] A. Nouri and M. Mehrmohammadi. "Defining the Boundaries for Neuroeducation as a Field of Study," Educational Research Journal, Vol. 27, No. 1 & 2, pp. 1-25, 2012.
- [5] H. U. Amin, and Malik A. S. "Learning and Memory Improvement: Evidence from Current Research and Neurofeedback Applications," Asia Pacific Journal of Neurotherapy, Vol. 1, No. 2, pp. 001-009, 2019.
- [6] S. Varma, B. D. McCandliss, and D.L. Schwartz. "Scientific and pragmatic challenges for bridging education and neuroscience," Educational researcher, Vol. 37, No. 3, pp. 140-152, 2008. <https://doi.org/10.3102/0013189X08317687>

- [16] D. Henz, A. John, C. Merz, and W. I. Schöllhorn, "Post-task effects on EEG brain activity differ for various differential learning and contextual interference protocols," *Frontiers in human neuroscience*, Vol. 12, No. 19, 2018. <https://doi.org/10.3389/fnhum.2018.00019>
- [17] F. Miraglia, F. Vecchio, and P. M. Rossini, "Brain electroencephalographic segregation as a biomarker of learning," *Neural networks: the official journal of the International Neural Network Society*, Vol. 106, pp. 168–174, 2018. <https://doi.org/10.1016/j.neunet.2018.07.005>
- [18] F. Vecchio, F. Miraglia, D. Quaranta, G. Lacidogna, C. Marra, and P. M. Rossini, "Learning processes and brain connectivity in a cognitive-motor task in neurodegeneration: evidence from EEG network analysis," *Journal of Alzheimer's Disease: JAD*, Vol. 66, No. 2, pp. 471–481, 2018. <https://doi.org/10.3233/JAD-180342>
- [19] H. Khandoker, C. Karmakar, M. Brennan, M. Palaniswami, and A. Voss, *Poincaré plot methods for heart rate variability analysis*, New York, NY: Springer, 2013. <https://doi.org/10.1007/978-1-4614-7375-6>
- [20] K. Lehnertz, "Nonlinear approaches to learning and memory," *First International IEEE EMBS Conference on Neural Engineering*, 2003. *Conference Proceedings.*, Capri, Italy, 2003, pp. 35–38, doi: 10.1109/CNE.2003.1196749.
- [21] M. Naderan, M. Ghoshuni, and E. Pour Afrouz, "The Effect of Mindfulness Training on Creativity in Healthy Subjects: A Pilot EEG Study," *Polish Psychological Bulletin*, Vol. 54, No. 4, pp. 327–333, 2021. doi: 10.24425/ppb.2021.139166
- [22] M. R. Arab, M. Nadjafi, R. Khosrowabadi, F. Setoudeh, and M. B. Tavakoli, "Organization the memory processes in the brain based on fractal analysis," *Advances in Cognitive Sciences*, Vol. 23, No. 1, pp. 128–139, 2021.
- [23] H. M. Cundy and A. P. Rollett, "Mathematical Models," 2nd Ed., Oxford University Press, 1961.
- [24] Goshvarpour and A. Goshvarpour, "A novel 2-piece rose spiral curve model: Application in epileptic EEG classification," *Computers in Biology and Medicine*, Vol. 142, No. 105240, 2022. <https://doi.org/10.1016/j.combiomed.2022.105240>
- [25] F. Jalaly and A. Goshvarpour, "Assessment of learning a new skill using nonlinear and spectral features of EEG," *SIViP*, Vol. 17, pp. 1199–1207, 2023. <https://doi.org/10.1007/s11760-022-02327-8>
- [7] P. Wolfe. *Brain matters: Translating research into classroom practice*, Alexandria, Virg: Association for Supervision and Curriculum Development, 2001.
- [8] J. M. Dubinsky, and A. A. Hamid, "The neuroscience of active learning and direct instruction," *Neuroscience and biobehavioral reviews*, Vol. 163, No. 105737, 2024. <https://doi.org/10.1016/j.neubiorev.2024.105737>
- [9] J. T. Bruer, "Education and the brain: A bridge too far," *Educational researcher*, Vol. 26, No. 8, pp. 4–16, 1997. <https://doi.org/10.3102/0013189X026008004>
- [10] D. Gutiérrez and M. A. Ramírez-Moreno, "Assessing a learning process with functional ANOVA estimators of EEG power spectral densities. *Cognitive Neurodynamics*, Vol. 10, No. 2, pp. 175–183, 2016. <https://doi.org/10.1007/s11571-015-9368-7>
- [11] H. U. Amin, A. S. Malik, N. Badruddin, and W. T. Chooi, "Brain behavior in learning and memory recall process: A high-resolution EEG analysis," *2014 15th International Conference on Biomedical Engineering, IFMBE Proceedings*, vol 43, 2014, Springer, Cham. https://doi.org/10.1007/978-3-319-02913-9_174
- [12] D. Gutiérrez, M. A. Ramírez-Moreno, and A. G. Lazcano-Herrera, "Assessing the acquisition of a new skill with electroencephalography," *2015 7th International IEEE/EMBS Conference on Neural Engineering (NER)*, Montpellier, France, 2015, pp. 727–730, doi: 10.1109/NER.2015.7146726.
- [13] J. Kaiser, R. Belenya, W. Y. Chung, A. Gentsch, and S. Schütz-Bosbach, "Learning something new versus changing your ways: distinct effects on midfrontal oscillations and cardiac activity for learning and flexible adjustments," *Neuroimage*, Vol. 226, No. 117550, 2021. <https://doi.org/10.1016/j.neuroimage.2020.117550>
- [14] J. A. G. Lum, L. K. Byrne, P. Barhoun, C. Hyde, A. T. Hill, P. G. Enticott, and G. M. Clark, "Resting state electroencephalography power correlates with individual differences in implicit sequence learning," *The European journal of neuroscience*, Vol. 58, No. 3, pp. 2838–2852, 2023. <https://doi.org/10.1111/ejn.16059>
- [15] S. Jawed, H. U. Amin, A. S. Malik, A. S., and I. Faye, "Classification of visual and non-visual learners using electroencephalographic alpha and gamma activities," *Frontiers in behavioral neuroscience*, Vol. 13, No. 86, 2019. <https://doi.org/10.3389/fnbeh.2019.00086>



فاطمه جلالی مدرک کارشناسی و کارشناسی ارشد را در سال‌های ۱۳۹۹ و ۱۴۰۱ در رشته مهندسی پزشکی گرایش بیوالکتریک از دانشگاه بین‌المللی امام رضا (ع) مشهد دریافت کرد. زمینه پژوهشی مورد علاقه ایشان پردازش سیگنال‌های بیولوژیکی به‌ویژه سیگنال‌های مغزی است. نشانی رایانامه ایشان عبارت است از:

fatmhjlaly128@gmail.com



عاتکه گشوارپور مدرک دکترای خود را در رشته مهندسی پزشکی-بیوالکتریک در سال ۱۳۹۶ از دانشگاه صنعتی سهند تبریز دریافت کرد.

زمینه‌های پژوهشی مورد علاقه ایشان شامل پردازش سیگنال زیست پزشکی، علوم اعصاب، تحلیل‌های غیرخطی و بازشناسی الگو است. ایشان تاکنون مقالات زیادی را در موضوعات مختلف مهندسی پزشکی منتشر کرده‌است و در حال حاضر عضو هیأت علمی گروه مهندسی پزشکی دانشگاه بین‌المللی امام رضا (ع) با مرتبه استادیاری است.

نشانی رایانامه ایشان عبارت است از:

ak_goshvarpour@imamreza.ac.ir