طبقه‌بندی مراحل مختلف یادگیری تایپ با استفاده از شاخص‌های نبود تقارن منحنی رودونی EEG: تأکید بر تعداد بهینهٔ گلبرگ‌ها و کانال‌های مغزی

فاطمه جلالی[۳،۱]، عاتکه گشوارپور[۳،۲*]

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*]

مرکزتحقیقات 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، توسعهٔ 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، ارائهٔ 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 دَه شرکت‌کننده (شش زن و چهار مرد) در نُه 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 جلسهٔ 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 نخستین‌بار روشی مبتنی بر منحنی رودونی برای تحلیل سیگنال معرفی شد که ساختاری شبیه گل با تعداد گلبرگ‌های قابل تنظیم دارد. در مطالعهٔ 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، C3، C4، POz و تعداد گلبرگ چهار بهترین نتایج حاصل شد. در طبقه‌بندی سه جلسهٔ درسی، بالاترین صحت به‌ترتیب مربوط به جلسهٔ یازدهم (۹۲٪)، چهارم (۹۰٪) و هشتم (٪ ۷۲/۶) بود. نتایج نشان می‌دهد در هنگام یادگیری تایپ‌کردن، مناطق خاصی از پیشانی، آهیانه و پس‌سری فعال می‌شود؛ علاوه‌براین، دینامیک‌های مغزی در هنگام تکمیل فرایند یادگیری (جلسهٔ یازدهم) و در مراحل اولیهٔ یادگیری (جلسهٔ چهارم) قابلیت تفکیک بالاتری دارند. عملکرد بالای شاخص‌های منحنی رودونی بیان‌کنندهٔ 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, Iran[1]

Assistant Professor, Department of Biomedical Engineering, Imam Reza International University, Mashhad, Razavi Khorasan, Iran[2]

Health Technology Research Center, Imam Reza International University, Mashhad, Razavi Khorasan, Iran[3]

* Corresponding author

*نویسندهٔ عهده‌دار مکاتبات

• تاریخ ارسال مقاله: ۱۴۰۲/۰۲/۰۴ • تاریخ پذیرش: ۱۴۰۳/۱۲/۱۴ • تاریخ انتشار: ۱۴۰۴/۶/۲۲ • نوع مطالعه: پژوهشی

[Downloaded from jsdp.rcisp.ac.ir on 2026-11-25]

[DOI: 10.61882/jsdp.22.2.97]

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 × 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.

۱-مقدمه

یادگیری را می‌توان یکی از مهم‌ترین امور در زندگی روزمرهٔ 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 شناخت چنین فرایند کاربردی برای علت‌یابی، جهت‌دهی و بهبود مسائل مثبت مانند زبان‌آموزی، مهارت‌ها، موزش‌وپرورش 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.

[Downloaded from jsdp.rcisp.ac.ir on 2026-11-25]

[DOI: 10.61882/jsdp.22.2.97]

علوم شناختی یک حوزهٔ مطالعاتی بین رشته‌ای است که به مطالعهٔ ذهن و هوش می‌پردازد و شامل علوم فلسفه، روان‌شناسی، هوش مصنوعی، علم اعصاب، زبان‌شناسی و انسان‌شناسی است. واژهٔ «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 جملهٔ 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 سلسلهٔ معینی از محرک‌ها که فرد باید نسبت به آن واکنش دهد) می‌پردازد. شیوه‌های تصویربرداری تشدید مغناطیسی کارکردی[1] (**fMRI**) و الکتروانسفالوگرافی[2] (**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 حوزهٔ 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[3] 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 ایجادشدهٔ داخلی به‌عنوان نتیجهٔ 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؛ علاوه‌بر این، دلایل زیادی در ضرورت تبیین رابطهٔ علوم اعصاب شناختی و آموزش و یادگیری مطرح شده‌است. بهبود وضعیت آموزش‌وپرورش از مهم‌ترین اولویت‌های راهبردی بسیاری از کشورهاست. از آنجا که مغز عضو اصلی دخیل در فرایند یادگیری است، تولید و توسعهٔ دانش دربارهٔ 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 حوزهٔ یادگیری و یاددهی، یافته‌های علوم اعصاب را در عرصهٔ تعلیم‌وتربیت 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 دربارهٔ 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 آیین‌نامهٔ یادگیری، برخی از مطالعات بر یادگیری یک وظیفهٔ حسی-حرکتی متمرکز بوده‌اند[۱۳, ۱۶-۱۸] و برخی دیگر یادگیری بصری به‌وسیلهٔ تماشای یک انیمیشن یا ویدئو را مورد بررسی قرار داده‌اند[۱۲, ۱۵]. از آنجا که پروتکل‌های یادگیری در مقالات متفاوت است؛ ازاین‌رو

[1] Functional Magnetic Resonance Imaging (FMRI)
[2] Electroencephalography
[3] Synaptic pruning

[Downloaded from jsdp.rcisp.ac.ir on 2026-11-25]
[DOI: 10.61882/jsdp.22.2.97]

طبیعی است که نتایج حاصل از آن‌ها نیز مختلف باشد؛ درنتیجه نمی‌توان نتایج حاصل از همهٔ 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؛ درنتیجه، این رویکردها در فراهم‌کردن 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 به‌کار رفته است بار محاسباتی بالایی دارند. در این پژوهش درصدد ارائهٔ روش غیرخطی جدیدی هستیم تا علاوه‌بر چیره‌شدن بر محدودیت‌های پیشین تحلیل سیگنال **EEG** را با دقت و سرعت بالا انجام دهد؛ همچنین تاکنون هیچ پژوهشی در زمینهٔ جداسازی مراحل یادگیری انجام نشده‌است؛ ازاین‌رو در این پژوهش سعی شده‌است علاوه‌بر 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 تجزیه‌وتحلیل قرار گرفت[۱۰]. در این پایگاه داده دَه داوطلب در یک آزمایش با هدف آموزش تایپ در رایانه طی دوازده جلسهٔ درسی با استفاده از صفحه کلید کولماک (**Colemak**) شرکت کردند. شش داوطلب زن و چهار داوطلب مرد همگی راست دست با میانگین سنی ۳/۷±۲۹/۵ سال در مطالعه شرکت کردند. از شرکت‌کنندگان خواسته شد که هر یک از درس‌ها را پنج بار تکرار کنند (با فاصلهٔ استراحت دو دقیقه در میان آن‌ها). تمام آزمایش‌ها در یک ساعت از روز انجام و از همهٔ 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. به‌منظور 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 پاک‌کردن و بازنویسی واژگان به‌دلیل 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 نُه حس‌گر است که طبق استاندارد بین‌المللی ۱۰-۲۰ در **Fz**،**F3** ، **F4**، **C3**، **Cz**، **C4** ، **P3**، **POz** و **P4** قرار می‌گیرد. تمام داده‌ها با فرکانس نمونه‌برداری ۲۵۶ هرتز دریافت شده‌است و با پالایهٔ باتروث (**Butterworth**) مرتبهٔ 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 به‌ترتیب از یک، دو و سه خط کامل از کلیدهای صفحه کلید استفاده شد. این سه درس به‌عنوان 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 به‌مدت زمانی که موضوع متناظر برای تکمیل درس طول کشیده متفاوت است. در این مطالعه کمترین طول داده (حدود دو دقیقه) برای همهٔ شرکت‌کننده‌ها انتخاب و جدا شدند و همهٔ پردازش‌ها روی آن‌ها انجام شده‌است.

۲-۲- منحنی رودونی

یکی از روش‌هایی که برای شناسایی پویایی سیگنال‌های زیستی استفاده می‌شود، فضای فاز (نقشهٔ دوبعدی) است. به‌طور معمول برای ایجاد فضای فاز دوبعدی هر نمونه از سیگنال در مقابل نمونهٔ بعدی آن رسم می‌شود؛ هرچند، نقشه‌های مختلف دیگری نیز برای ارزیابی رفتار سیگنال معرفی شده‌است. رویکردی که برای نخستین‌بار در این پژوهش برای تجزیه‌وتحلیل سیگنال **EEG** مورد استفاده قرار گرفته، روشی است که بین سال‌های ۱۷۲۳ تا ۱۷۲۸ توسط ریاضی‌دان ایتالیایی، *گویدو گراندی*، رودونی (**Rhodonea**) نام گرفت[۲۳]. این منحنی که شبیه به گل رز است، به‌کمک دو معادلهٔ زیر در مختصات دکارتی تعریف می‌شود:

$$X = \cos(ka) \times \cos(a)$$
$$Y = \cos(ka) \times \sin(a) \quad (۱)$$

که در آن **k** تعداد گلبرگ‌های منحنی را تعیین می‌کند و **a** بیان‌کنندهٔ نمرهٔ استاندارد (**z-score**) سیگنال مغزی است و به‌صورت زیر محاسبه می‌شود:

$$a = \frac{data - mean(data)}{standard\ deviation(data)} \quad (۲)$$

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

شکل نمودار به‌شدت 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،

[Downloaded from jsdp.rcisp.ac.ir on 2026-11-25]

[DOI: 10.61882/jsdp.22.2.97]

۲/۵ و غیره، تعداد گلبرگ‌های نمودار **4k** 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 دَه 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[1]، تصادفی[2] 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 دَه نشان می‌دهد. طول هر سه سیگنال یادشده ۱۲۸۰ انتخاب شد و منحنی رودونی آن‌ها بعد از نرمال‌سازی سیگنال‌ها به‌دست آمد. گفتنی است، سیگنال دوره‌ای به‌کمک معادلهٔ سینوسی **sin (2πt)** و سیگنال تصادفی با توزیع یکنواخت با دستور **rand** متلب به‌دست آمده‌است. (همهٔ پردازش‌ها و شبیه‌سازی‌های این پژوهش به کمک نرم‌افزار متلب[3] انجام شده‌است.)

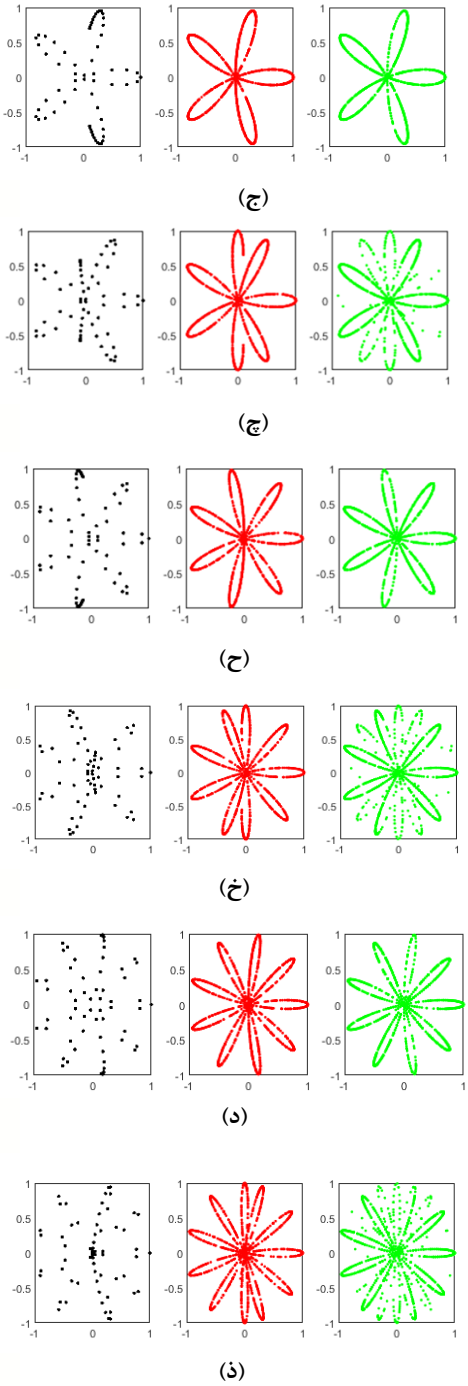

(شکل-۱): نمایش سری‌های زمانی دوره‌ای، تصادفی و الکتروانسفالوگرام به همراه منحنی رودونی (الف) سری‌های زمانی دوره‌ای، تصادفی و الکتروانسفالوگرام، (ب) منحنی رودونی با k=1، (پ) منحنی رودونی با k=2، (ت) منحنی رودونی با k=3، (ث) منحنی رودونی با k=4، (ج) منحنی رودونی با k=5، (چ) منحنی رودونی با k=6، (ح) منحنی 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.

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

[1] Periodic signal
[2] Random signal
[3] MATLAB

[Downloaded from jsdp.rcisp.ac.ir on 2026-11-25]
[DOI: 10.61882/jsdp.22.2.97]

به‌طوری 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 به‌صورت کامل شکل گرفته است. نکتهٔ جالب این است که برای سیگنال تصادفی در بعضی **k**ها (به‌ویژه در **k**های زوج) شکل نمودار رودونی به‌صورت کامل تشکیل نشده است؛ درحالی‌که از روی منحنی رودونی سیگنال **EEG** می‌توان تعداد گلبرگ‌های منحنی را حدس زد.

۲-۳- استخراج ویژگی

در این پژوهش، از ویژگی‌های نبود تقارن فضای فاز استفاده شده‌است. سامانه‌های بیولوژیک در شرایط عادی در حالت نبود تعادل عمل می‌کنند و قابلیت خودسازماندهی آن‌ها به نبود تقارن فرایندهای اساسی وابسته است؛ به‌عبارتی، توزیع سیگنال‌ها نامتعادل و این نبود تعادل به‌خوبی 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 ایدهٔ بررسی شاخص‌های نبود تقارن[1] در منحنی رودونی را به ما داد؛ ازاین‌رو 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** نشان‌دهندهٔ نقاط بالای محور **x** و **down** نشان‌دهندهٔ نقاط پایین محور **x** است.)

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

$$SP^2 = \frac{\sum p_{up}}{\sum p_{down}} \qquad (۳)$$

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

شاخص دوم: شاخص دوم به‌عنوان ضریبی از قدرمطلق حاصل‌جمع شیب نقاط بالای محور **x** به قدرمطلق مجموع شیب نقاط پایین محور **x** تعریف می‌شود و می‌توان آن را به‌صورت زیر نمایش داد:

$$SS^3 = \frac{\left|\sum sl_{up}\right|}{\left|\sum sl_{down}\right|} \qquad (۴)$$

در این معادله با فرض اینکه **n** نقطهٔ بالای محور افق و **l** نقطهٔ پایین محور افق داشته باشیم، $\mathbf{sl_{up}} = \mathbf{m_{1up}, m_{2up}, m_{3up}, \dots, m_{nup}}$ و $\mathbf{sl_{down}} = \mathbf{m_{1down}, m_{2down}, m_{3down}, \dots, m_{ldown}}$ است و **m** شیب هر نقطه در نمودار رودونی است.

شاخص سوم: شاخص سوم نسبت مجموع فاصله اقلیدسی[4] نقاط بالای محور **x** از مبدأ به مجموع فاصلهٔ 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 فاصلهٔ اقلیدسی نقاط بالای محور و مجموع فاصلهٔ اقلیدسی نقاط پایین محور به‌ترتیب از معادله‌های (۵) و (۶) به‌دست می‌آید.

$$d_{up} = \sqrt{x_{1u}^2 + y_{1u}^2} + \sqrt{x_{2u}^2 + y_{2u}^2} + \cdots + \sqrt{x_{nu}^2 + y_{nu}^2} \qquad (۵)$$

$$d_{down} = \sqrt{x_{1d}^2 + y_{1d}^2} + \sqrt{x_{2d}^2 + y_{2d}^2} + \ldots + \sqrt{x_{md}^2 + y_{md}^2} \qquad (۶)$$

بنابراین شاخص سوم به صورت زیر است:

$$SD^5 = \frac{d_{up}}{d_{down}} \qquad (۷)$$

در این مقاله سه رابطه (روابط ۳، ۴ و ۷) برای محاسبهٔ نبود تقارن پیشنهاد شده‌است.

شکل (۲) نمایش گرافیکی ویژگی‌های نبود تقارن را به‌صورت 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 گفته‌شده برابر یک شود (مساوی‌بودن صورت و مخرج) نشانهٔ متقارن‌بودن نمودار خواهد بود.

سه شاخص ارائه‌شده برای نُه کانال **k**=۱,۲,۳,…,۱۰ گلبرگ، برای ده فرد شرکت‌کننده و پانزده جلسهٔ یادگیری به‌دست آمد (درمجموع ۲۷۰ ویژگی برای هر شخص). ویژگی‌های محاسبه‌شده برای نرمال‌سازی، در بازه [۱ ۱-] قرار گرفتند.

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

مقدار نرمال‌شدهٔ یک ویژگی $\mathbf{x_i}$ به‌صورت زیر به‌دست می‌آید:

$$x_i = \frac{x_i - \min(x_i)}{\max(x_i) - \min(x_i)} \qquad (۸)$$

پس از این نوع نرمال‌سازی $\mathbf{min}(\boldsymbol{x_{new}}) = \mathbf{0}$ و $\mathbf{max}(\boldsymbol{x_{new}}) = \mathbf{1}$ است. برای قرارگرفتن ویژگی‌های نرمال‌شده در بازه [۱ ۱-] از رابطهٔ زیر استفاده شد:

$$x_{new} = x_i \times 2 - 1 \qquad (۹)$$

[1] Asymmetry
[2] Sum Points
[3] Sum Slopes
[4] Euclidean Distance
[5] Sum Distances

[Downloaded from jsdp.rcisp.ac.ir on 2026-11-25]
[DOI: 10.61882/jsdp.22.2.97]

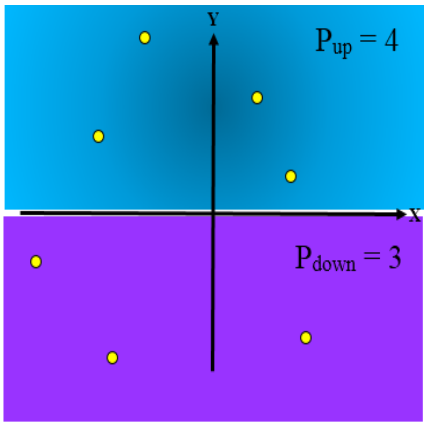

الف

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

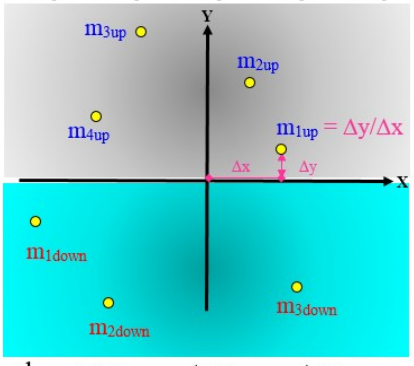

$$sl_{down} = m_{1down} + m_{2\ down} + m_{3\ down}$$

ب

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

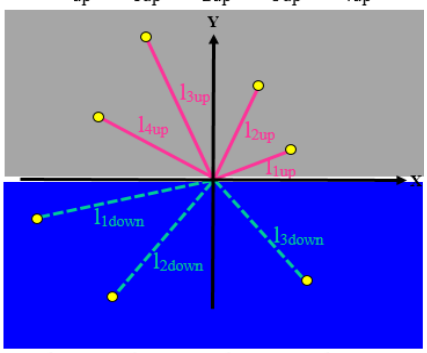

$$d_{down} = l_{1down} + l_{2\ down} + l_{3\ down}$$

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[1] (**SVM**) استفاده شده‌است. از نقاط قوت طبقه‌بند **SVM** می‌توان به امکان انتخاب تابع کرنل[2] با توجه به شرایط توسط کاربر، مناسب‌بودن برای کار روی دادگان کوچک، مصرف بهینه در حافظه، فرایند آموزش ساده، درگیرنشدن در نقاط بیشینهٔ محلی، وجود تناسب بین میزان خطا و پیچیدگی محاسبات اشاره کرد. در این پژوهش طبقه‌بندی پنج تکرار هر جلسه (پانزده طبقه) با **SVM** با کرنل خطی[3] 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 گلبرگ‌های متفاوت بررسی شد. هدف این کار، یافتن کانال مغزی فعال و گلبرگ بهینه در منحنی رودونی هنگام انجام فرایند یادگیری بود؛ برای این منظور از رویکرد یک در مقابل همه[4] 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 همهٔ 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، جلسهٔ نخست درس هشت به‌عنوان کلاس یک و چهار جلسهٔ 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[5]، حساسیت[6]، و امتیاز **F1**[7] برای ارزیابی عملکرد محاسبه شد. شاخص‌های بالا به‌ترتیب از معادلات (۱۰) - (۱۲) به‌دست می‌آیند:

$$\mathrm{Acc} = \frac{TP + TN}{FP + FN + TP + TN} \qquad (۱۰)$$

$$\mathrm{Sn} = \frac{TP}{TP + FN} \qquad (۱۱)$$

$$\mathrm{F_1} = \frac{2TP}{2TP + FP + FN} \qquad (۱۲)$$

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.

[1] Support vector machine
[2] Kernel Function
[3] Linear kernel
[4] One vs. all
[5] Accuracy
[6] Sensitivity
[7] F1 score

[Downloaded from jsdp.rcisp.ac.ir on 2026-11-25]
[DOI: 10.61882/jsdp.22.2.97]

۳- ارائهٔ 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 مرحلهٔ نخست، داده‌های دَه داوطلب از پایگاه IEEEDataPort شامل سیگنال‌های EEG ثبت‌شده در نُه 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 پالایهٔ باتروورث (مرتبهٔ پنجم، فرکانس قطع ۰٫۱ و ۱۰۰ هرتز) و نرمال‌سازی داده‌ها با روش z-score بود تا سیگنال‌ها برای تحلیل آماده شوند.

در مرحلهٔ بعد، سیگنال‌های نرمال‌شده با استفاده از معادلات منحنی رودونی به مختصات دوبعدی تبدیل شدند. این منحنی با تنظیم پارامتر k (از ۱ تا ۱۰) به‌عنوان تعداد گلبرگ‌ها ساخته شد تا رفتار دینامیکی سیگنال‌ها در فضای فاز بررسی شود؛ سپس سه شاخص نبود تقارن مبتنی بر توزیع نقاط، شیب و فاصلهٔ اقلیدسی نقاط نسبت به محور افقی محاسبه شد. این شاخص‌ها برای هر یک از نُه کانال مغزی و دَه مقدار k استخراج شدند که درنهایت ۲۷۰ ویژگی برای هر شرکت‌کننده تولید کرد. ویژگی‌های استخراج‌شده به بازه [۱, ۱-] نرمال‌سازی شدند تا مقایسه‌پذیری افزایش یابد.

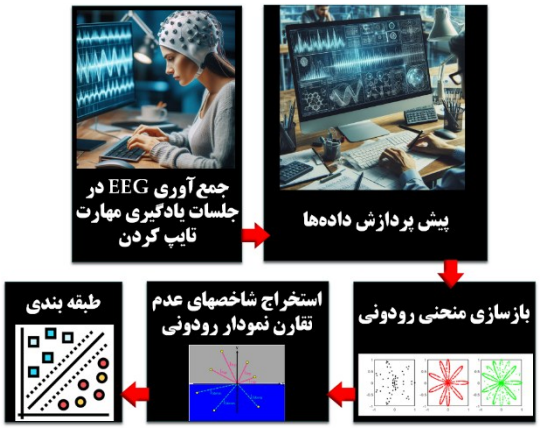

(شکل-۳): روش پیشنهادی
(Figure-3): Proposed approach

در مرحلهٔ نهایی، از طبقه‌بند ماشین بردار پشتیبان با کرنل خطی برای طبقه‌بندی پانزده کلاس متناظر با پنج تکرار در سه جلسهٔ آموزشی استفاده شد. رویکرد «یک در مقابل همه» به‌کار 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 جلسهٔ یادگیری انجام شد؛ علاوه‌بر این، عملکرد طبقه‌بند در هر جلسه برای گلبرگ‌های مختلف به‌منظور پیداکردن گلبرگ 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 درنظرگرفتن گلبرگ‌ها و کانال‌ها به همراه مقدار میانگین و انحراف معیار آن‌ها را نشان می‌دهد. تعداد ویژگی‌های اعمالی برای هر تعداد گلبرگ ۲۷ (سه ویژگی نبود تقارن × نُه کانال مغزی) بوده‌است. برای تعداد گلبرگ یک تا دَه تعداد ۲۷ ویژگی وارد طبقه‌بندی شد و معیارهای ارزیابی عملکرد طبقه‌بندی‌کننده برای طبقه‌بندی پانزده جلسه محاسبه شد؛ درنهایت، 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	F1امتیاز	حساسیت
جلسهٔ ۱	۹۱.۳±۴.۴	۹۵.۴±۲.۵	۹۳.۱±۳.۰
جلسهٔ ۲	۹۰.۶±۴.۶	۹۴.۹±۲.۸	۹۳.۹±۲.۱
جلسهٔ ۳	۹۰±۴.۷	۹۴.۶±۲.۶	۹۳±۳.۰
جلسهٔ ۴	۸۹.۳±۴.۶	۹۴.۳±۲.۶	۹۳±۳.۰
جلسهٔ ۵	۹۳.۳±۰	۹۶.۵±۰.۰۸	۹۴±۲.۸
جلسهٔ ۶	۹۰±۳.۵	۹۴.۷±۱.۹	۹۳±۲.۰
جلسهٔ ۷	۸۸±۵.۲	۹۳.۴±۳.۸	۹۲.۴±۷.۰
جلسهٔ ۸	۹۰±۴.۷	۹۴.۶±۲.۶	۹۳±۳.۰
جلسهٔ ۹	۹۱.۳±۳.۲	۹۵.۴±۱.۷	۹۳.۱±۲.۰
جلسهٔ ۱۰	۹۰±۶.۴	۹۴.۶±۳.۸	۹۳±۵.۰
جلسهٔ ۱۱	۹۲±۴.۲	۹۵.۷±۲.۲	۹۳.۸±۲.۱
جلسهٔ ۱۲	۹۲±۲.۸	۹۵.۸±۱.۵	۹۳.۲±۰.۲
جلسهٔ ۱۳	۸۹.۳±۶.۴	۶۴.۲±۳.۸	۹۳±۰.۵
جلسهٔ ۱۴	۹۰.۶±۳.۴	۹۵±۱.۹	۹۳.۸±۲.۱
جلسهٔ 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 جلسهٔ پنجم که آخرین تکرار جلسهٔ چهارم است، است؛ پس از آن، جلسهٔ یازدهم و دوازدهم بیشترین صحت را دارد؛ علاوه‌بر این جلسهٔ هفت، سیزده و چهار به‌ترتیب کمترین مقدار طبقه‌بندی را دارند. میانگین صحت برای تکرارهای هر درس در جدول (۲) نشان داده شده‌است؛ به‌طور دقیق‌تر، میانگین عملکرد طبقه‌بندی‌کننده در جلسات یک تا پنج مربوط به درس چهارم،

[Downloaded from jsdp.rcisp.ac.ir on 2026-11-25]
[DOI: 10.61882/jsdp.22.2.97]

جلسات شش تا دَه مربوط به درس هشتم و جلسات یازده تا پانزده مربوط به درس یازدهم محاسبه و در جدول (۲) گزارش شده‌است؛ همان‌طورکه در جدول (۲) قابل ملاحظه است، بالاترین صحت و پایین‌ترین صحت به‌ترتیب برای دروس یازدهم و هشتم است. برای بررسی بیشتر نتایج، ویژگی‌های هر کانال و دَه گلبرگ در هر جلسه جداگانه به طبقه‌بند داده شد. در این حالت، ویژگی‌های واردشده به طبقه‌بند سه ویژگی نبود تقارن بوده‌است؛ به‌طور دقیق‌تر، سه ویژگی نبود تقارن از کانال F3 برای تعداد گلبرگ یک وارد طبقه‌بندی‌کننده شد و معیارهای ارزیابی عملکرد طبقه‌بندی‌کننده محاسبه شد. در ادامه، برای همین کانال با افزایش تعداد گلبرگ‌ها به دو بار دیگر محاسبات انجام و این کار برای تمام کانال‌ها (نُه کانال) به تفکیک و برای تعداد گلبرگ‌های یک تا دَه به طور مجزا انجام شد؛ پس از محاسبهٔ معیارها، بالاترین درصد صحت عملکرد طبقه‌بندی‌کننده مشخص شد و کانال مغزی و تعداد گلبرگ‌هایی که منجر به حصول بالاترین درصد صحت عملکرد طبقه‌بندی‌کننده شده‌است، مشخص شد. جدول (۳) نتایج حاصل از این مورد را نشان می‌دهد. در ستون دوم کانال و گلبرگ‌هایی که بهترین نتایج را داشت، آمده‌است.

(جدول-۲): میانگین مقادیر خروجی تکرارهای سه درس یادگیری

(Table-2): Average output values of repetitions of three learning lessons

درس	صحت	امتیازF1	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 گلبرگ

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

جلسات	بهترین گلبرگ /بهترین کانال	صحت	امتیازF1	حساسیت
جلسهٔ ۱	۶,۹,۱۰/ همه	۹۰±۴.۷	۹۴.۶±۲.۶	۹۳±۳.۰
جلسهٔ ۲	۲,۷,۱۰/همه	۷۹.۳±۷.۹	۸۸.۱±۴.۶	۹۲.۹±۲.۵
جلسهٔ ۳	C۳/۲	۹۰±۴.۷	۹۴.۶±۲.۶	۹۳±۳.۰
جلسهٔ ۴	F3,Fz,C3,C4,P3/ ۱,۳,۴,۵	۸۸.۶±۶.۳	۹۳.۸±۳.۷	۹۲.۹±۰.۵
جلسهٔ ۵	۴/همه	۹۲±۴.۲	۹۵.۷±۲.۲	۹۳.۸±۲.۱
جلسهٔ ۶	همه/همه	۹۲.۶±۳.۷	۹۶.۱±۲.۰۴	۹۳.۸±۲.۱
جلسهٔ ۷	۴,۵,۶,۹/همه	۷۹.۳±۷.۹	۸۸.۲±۴.۹	۹۲.۱±۰.۷
جلسهٔ ۸	همه/همه	۹۱.۳±۳.۲	۹۵.۴±۱.۷	۹۳.۱±۰.۲
جلسهٔ ۹	P4,Poz/6	۹۰±۶.۴	۹۴.۶±۸.۳	۹۳±۰.۵
جلسهٔ ۱۰	۳,۹/همه	۹۰.۶±۴.۶	۹۵±۲.۶	۹۳.۱±۰.۳
جلسهٔ ۱۱	همه/همه	۹۱.۳۳±۴.۴	۹۵.۴±۲.۴	۹۳.۸±۲.۱
جلسهٔ ۱۲	Fz,C3,C4,P3,P4/4	۹۱.۳±۳.۲	۹۵.۴±۱.۷	۹۳.۱±۰.۲
جلسهٔ ۱۳	۴,۷,۱۰/همه	۹۰±۴.۷	۹۴.۶±۱.۸	۹۳±۰.۳
جلسهٔ ۱۴	C۴/۳	۹۰.۶±۳.۴	۹۴.۶±۱.۸	۹۳.۷±۲.۱
جلسهٔ ۱۵	۷,۲/همه	۹۰.۶±۳.۴	۹۵±۱.۹	۹۳.۱±۰.۲

نتایج جدول (۳) حاکی از آن است که در بیشتر جلسات تمام کانال‌ها نتایج مطلوبی داشته‌اند، به ویژه کانال‌های **F3**، **Fz**، **C3**، **C4**، **Poz** و **P4** که بیشترین تکرار در نتایج جلسات یادگیری را داشته‌اند. از بین دَه گلبرگ بررسی‌شده، تعداد گلبرگی که در بیشترین جلسات بالاترین نتیجهٔ طبقه‌بندی را داشته مربوط به **K=۴** است؛ پس از آن ویژگی‌های استخراج‌شده از منحنی رودونی با **K=۲,۳,۶,۷,۹,۱۰** گلبرگ در مقایسه با سایر گلبرگ‌ها نتایج بهتری داشته‌اند. در جدول (۳) جلسات (۵ و ۶) بهترین عملکرد طبقه‌بندی مشاهده می‌شود. جلسات (۲ و ۷) و پس از این دو، جلسهٔ (۴) به‌ترتیب پایین‌ترین نتایج را در جدول (۳) داشته‌اند این مورد هم در نتایج جدول (۱) وجود دارد (جلسهٔ ۴ و ۷)؛ درمجموع، نتایج حاصل از طبقه‌بندی بین ۷۹/۳ تا ۹۳/۳ درصد در نوسان است که نشان‌دهندهٔ عملکرد موفق طبقه‌بندی در پژوهش است.

۵- بحث و نتیجه‌گیری

هدف از انجام این مطالعه ارائهٔ یک روش جدید برای تجزیه‌وتحلیل سیگنال‌های زیستی بود. به‌طور خاص، روش پیشنهادی با طبقه‌بندی دادگان **EEG** در حین یادگیری چندطبقه مورد آزمایش و ارزیابی قرار گرفت؛ به‌علاوه، 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 به‌ندرت استفاده شده است[۲۰-۲۲]؛ هرچند، ویژگی‌های ارائه‌شده در این پژوهش از نظر محاسباتی ساده و کم‌هزینه‌اند، پیشنهاد می‌شود در مطالعات آینده از سایر ویژگی‌ها نیز برای کمی‌سازی مدل پیشنهادی استفاده شود؛ علاوه‌بر این جلسات مختلف یادگیری به‌کمک یک طبقه‌بند با رویکرد یک در مقابل همه از یکدیگر تفکیک شدند؛ درحالی‌که مطالعات گذشته نوع طبقه‌بندی و دادگان متفاوت بوده است[۱۵]. نتایج طبقه‌بند، مقادیر بین ۷۹/۳ تا ۹۳/۳ درصد را نشان می‌دهد. بیشتر نتایج مربوط به بالاترین صحت و پایین‌ترین صحت در جدول (۱) با نتایج جدول (۳) مطابقت دارد. نزدیک‌بودن نتایج طبقه‌بندی هر جلسهٔ یادگیری را می‌توان با کم‌بودن 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 استخراج‌شده ممکن است بر روی نزدیک‌بودن 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

[Downloaded from jsdp.rcisp.ac.ir on 2026-11-25]

[DOI: 10.61882/jsdp.22.2.97]

در سه جلسهٔ یادگیری بهبودی دیده نشده‌است، اما با توجه به نتایج جدول (۲) طبقه‌بند دروس چهارم و یازدهم را که به‌ترتیب به‌عنوان یادگیری با سطح دشواری کم‌وزیاد بوده‌اند، به‌خوبی تفکیک کرده‌است. می‌توان گفت در درس چهارم، یادگیری خیلی کم صورت گرفته است؛ درصورتی‌که در درس یازدهم یادگیری به‌صورت 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 به‌طورکامل اتفاق افتاده است؛ ازاین‌رو، نتیجهٔ کمتری را به‌دنبال 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] آمده‌است 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 مطالعهٔ 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 عمدهٔ این تفاوت در الکترودهای F3، Fz، C3، Cz، POz و P4 رخ داده‌است. نتایج مطالعهٔ ما نشان داد که بهترین تعداد گلبرگ چهار است؛ هرچند، با تعداد گلبرگ غیر از پنج و هشت نیز نتایج خوبی حاصل شد؛ ازاین‌رو، زوج یا فردبودن تعداد گلبرگ‌های منحنی رودونی در نتایج طبقه‌بندی تأثیر چندانی نداشته است.

مطالعهٔ 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 گلبرگ 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 آماری دقیق‌تر بررسی نشد. پیشنهاد می‌شود در مطالعات آینده این موارد به‌کمک آزمون‌های آماری و مقایسهٔ 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 به‌منظور بهبود عملکرد طبقه‌بند استفاده شود. در این مطالعه، درکل طبقه‌بندی پانزده جلسهٔ یادگیری انجام شده‌است. می‌توان در کارهای بعدی طبقه‌بندی تکرارهای نخست تا پنجم هر جلسه را نیز ارزیابی کرد؛ به‌علاوه، 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؛ درنهایت، با وجود نتایج امیدوارکننده، اعتبار روش پیشنهادی نیازمند آزمایش روی پایگاه‌های داده متنوع‌تر و بزرگ‌تر است.

۶-مراجع 6-References

[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

[Downloaded from jsdp.rcisp.ac.ir on 2026-11-25]

[DOI: 10.61882/jsdp.22.2.97]

[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

[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.compbiomed.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

[Downloaded from jsdp.rcisp.ac.ir on 2026-11-25]

[DOI: 10.61882/jsdp.22.2.97]



فاطمه جلالی مدرک کارشناسی و کارشناسی ارشد را در سال‌های ۱۳۹۹ و ۱۴۰۱ در رشتهٔ مهندسی پزشکی گرایش بیوالکتریک از دانشگاه بین‌المللی امام رضا (ع) مشهد دریافت کرد. زمینهٔ پژوهشی مورد علاقهٔ ایشان پردازش سیگنال‌های بیولوژیکی به‌ویژه سیگنال‌های مغزی است.
نشانی رایانامهٔ ایشان عبارت است از:
fatmhjlaly128@gmail.com



عاتکه گشوارپور مدرک دکترای خود را در رشتهٔ مهندسی پزشکی-بیوالکتریک در سال ۱۳۹۶ از دانشگاه صنعتی سهند تبریز دریافت کرد. زمینه‌های پژوهشی مورد علاقهٔ 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 رایانامهٔ ایشان عبارت است از:
ak_goshvarpour@imamreza.ac.ir

[Downloaded from jsdp.rcisp.ac.ir on 2026-11-25]

[DOI: 10.61882/jsdp.22.2.97]