

Automatic Classification of Emotions in Dreams Using Machine Learning and EEG Signals

Mahmoudi Ali¹, Alireza Talesh Jafadideh², Zarei Asghar^{3*}

Faculty of Biomedical Engineering, Sahand University of Technology, Tabriz, Tabriz, Iran^{1,3}

School of Engineering Science, College of Engineering, University of Tehran, Tehran, Iran²

E-mails: salimahmoudi01@gmail.com; alireza.talesh@ut.ac.ir; a.zarei@sut.ac.ir

Abstract

Since the content of dreams can mirror an individual's mental state, recognizing emotions during sleep can reveal valuable information about the state of mind. This research suggests a new method for the automated classification of emotions during the state of sleep known as the rapid eye movement (REM) state. In the suggested method, in the preprocessing step, electroencephalogram (EEG) signals are filtered with a Butterworth bandpass filter and are then broken into 20-second windows. Each filtered EEG window is then decomposed into five intrinsic mode functions (IMFs) with the empirical mode decomposition (EMD) algorithm. In the next step, the sample entropy feature is extracted from each IMF. The ReliefF algorithm is utilized to select the best subset of features, which are applied as an input to random forest (RF), support vector machine (SVM), and K-nearest neighbor (KNN) machine learning algorithms. Emotional states are classified in a three-class setting (positive, negative, and neutral) as well as in two binary classification scenarios: (1) positive versus negative, and (2) neutral versus a combination of positive and negative emotions. EEG signals from the publicly available dataset known as the DEED dataset are utilized to see brain activity patterns which are present in different states of emotions in dreams and to analyze the performance of the suggested method. The outcome reveals that the suggested method provides an accuracy of 93.08% in three-class classification and an accuracy of 97.45% in binary classification (emotions versus neutral), which indicates good performance in the classification of different states of dreams' emotions during sleep. These experimental results not only increase the knowledge of the brain's mechanisms involved in emotions during dreams but also open the gate to the EEG methodology for the application of diagnostic and intervention procedures in mental health-related matters in clinical settings.

Keywords

Dream Emotion Classification, EEG signal, Machine learning, Sample entropy

1- Short Paper

Understanding emotions in dreams is crucial for assessing mental health, as they reflect psychological states and potential disorders. This study aims to automatically classify emotions in dreams during REM sleep using EEG signals, providing insights into mental health. Leveraging the DEED dataset, we employ Empirical Mode Decomposition (EMD) and Sample Entropy (SampEn) features, selected via ReliefF, to enhance classification accuracy. Prior works, such as Liu *et al.* [11] and Moctezuma *et al.* [2], used features like Common Spatial Patterns (CSP) and Discrete Wavelet Transform (DWT) with classifiers like Gradient Boosting Decision Tree (GBDT) and EEGNet, achieving up to 88% accuracy, but our approach targets improved performance through optimized feature selection and machine learning.

2- Proposed Work and Methodology

The proposed method classifies emotions in REM sleep dreams using EEG signals from the DEED dataset. EEG signals are preprocessed with a Butterworth bandpass filter (1-45 Hz) and segmented into 20-second windows. Each segment is decomposed into five Intrinsic Mode Functions (IMFs) via EMD, and Sample Entropy (SampEn) is extracted for each IMF. The ReliefF algorithm selects the top 20 features, which are fed into Random Forest (RF), Support Vector Machine (SVM), and K-Nearest Neighbors (KNN) classifiers. Three scenarios are evaluated: a three-class problem (positive, negative, neutral emotions) and two binary problems (positive/negative versus neutral; positive versus negative). Performance is assessed using 10-fold cross-validation with metrics including accuracy, precision, sensitivity, F1-score, and AUROC.

Comparison and Results: The KNN classifier outperforms RF and SVM, achieving 93.08% accuracy in the three-class scenario, 97.45% in the emotions versus neutral scenario, and 90.39% in the positive versus negative scenario. Compared to Liu *et al.* [11] (88% accuracy for positive versus negative) and Moctezuma *et al.* [2] (64.70% for emotions versus neutral), our method shows significant improvement, with at least 8-10% higher accuracy across scenarios. Statistical analysis confirms significant feature differences (p -value < 0.05). IMF1-IMF3 contribute most to classification, indicating high-frequency EEG components are critical for emotion differentiation.

Discussion: The superior performance of KNN, enhanced by ReliefF feature selection, highlights the efficacy of SampEn in capturing emotional complexity in EEG signals. The method's high accuracy and low error rates suggest potential for clinical applications in mental health monitoring. Remarkably, the proposed method achieves these results using only the Sample Entropy feature, demonstrating its efficiency and effectiveness. Limitations include the lack of power spectral analysis and limited EEG channels (six), which may obscure brain region-specific insights. Future work will explore additional frequency band features and higher-channel EEG datasets to further refine emotion classification in dreams.

3- Conclusion

This study proposed a novel approach for classifying emotional states during REM sleep using EEG signals from the DEED dataset. In the proposed framework, sample entropy was computed for each of the five intrinsic mode functions obtained via empirical mode decomposition of EEG channels. Subsequently, the most relevant features were selected using the ReliefF algorithm and provided as input to three machine learning classifiers—K-nearest neighbors, support vector machines, and random forest to categorize dream-related emotional states. The results demonstrated that the proposed method achieved a strong classification performance, yielding an average accuracy of 93.08% in the three-class setting, 90.39% for the binary classification of positive versus negative dream emotions, and 97.45% for distinguishing emotional from neutral dreams. The feature selection process not only reduced dimensionality but also enhanced classification performance by identifying features strongly associated with distinct emotional states. Despite relying solely on sample entropy as the feature metric, the proposed method outperformed previous approaches in both multi-class and binary classification tasks. Consistent with prior research, our findings confirm that EEG signals carry sufficient discriminative information to distinguish among various emotional states during REM sleep with high precision. This capability holds particular promise for mental health applications, as it enables the reliable detection of affective states during sleep with minimal error. The high average accuracy and reliability underscore the potential of the proposed model for practical deployment in neuroscience and psychiatric diagnostics.

طبقه‌بندی خودکار احساسات در رویا با استفاده از یادگیری ماشین و سیگنال‌های EEG

علی محمودی

دانشجوی کارشناسی، دانشکده مهندسی پزشکی، دانشگاه صنعتی سهند، تبریز، ایران

علیرضا طالش جفادیده

استادیار، گروه مهندسی بین رشته‌ای، دانشکده علوم مهندسی، دانشکدگان فنی، دانشگاه تهران، تهران، ایران

اصغر زارعی

استادیار، گروه مهندسی پزشکی، دانشکده مهندسی پزشکی، دانشگاه صنعتی سهند، تبریز، ایران

چکیده

از آنجا که محتوای خواب می‌تواند بازتابی از سلامت روانی فرد باشد، شناسایی احساسات در طی خواب می‌تواند اطلاعات ارزشمندی درباره وضعیت روانی افراد ارائه دهد. در این مطالعه یک رویکرد جدید برای طبقه‌بندی خودکار احساسات تجربه‌شده در طول مرحله حرکت سریع چشم (REM) خواب ارائه می‌شود. در روش پیشنهادی، در مرحله پیش‌پردازش، ابتدا سیگنال‌های الکتروانسفالوگرام (EEG) توسط فیلتر میانگدر باترورث فیلتر شده و سپس به پنجره‌های ۲۰ ثانیه‌ای تقسیم می‌شوند. در ادامه هر یک از پنجره‌های فیلتر شده سیگنال EEG با استفاده از روش تجزیه حالت تجربی (EMD) به پنج تابع حالت ذاتی (IMF) تجزیه می‌شود. سپس، ویژگی آنترپی نمونه‌ای از هر یک از IMF ها استخراج می‌گردد. بهترین مجموعه از ویژگی‌ها توسط الگوریتم ReliefF انتخاب شده و به ورودی مدل‌های یادگیری ماشین جنگل تصادفی (RF)، ماشین بردار پشتیبان (SVM) و K نزدیک‌ترین همسایه (KNN) اعمال می‌شود. طبقه‌بندی حالات مختلف احساسات رویا در یک سناریو سه کلاسه و دو سناریو دو کلاسه (شامل احساسات مثبت یا منفی در برابر خنثی و احساسات مثبت در برابر احساسات منفی) انجام شد. سیگنال‌های EEG از مجموعه داده عمومی DEED جهت شناسایی الگوهای فعالیت مغزی مرتبط با حالات مختلف احساسات رویا و ارزیابی عملکرد رویکرد پیشنهادی تحلیل شدند. نتایج نشان می‌دهد که روش پیشنهادی، با فراهم نمودن میانگین صحت ۹۳/۰۸٪ در طبقه‌بندی سه کلاسه و میانگین صحت ۹۷/۴۵٪ در طبقه‌بندی دو کلاسه (احساسات در برابر حالت خنثی) دارای عملکرد مناسب در طبقه‌بندی حالات مختلف احساسات رویا در گزارش‌های خواب است. یافته‌های این مطالعه نه تنها می‌تواند درک مکانیزم‌های عصبی مرتبط با احساسات خواب را گسترش بدهد، بلکه می‌تواند مسیر توسعه روش‌های مبتنی بر EEG برای ارزیابی و مداخله در محیط‌های بالینی مرتبط با سلامت روان را هموار کند.

کلمات کلیدی

طبقه‌بندی احساسات در رویا، الکتروانسفالوگرام، یادگیری ماشین، آنترپی نمونه‌ای.

نام نویسنده مسئول: اصغر زارعی

ایمیل نویسنده مسئول: a.zarei@sut.ac.ir

تاریخ ارسال مقاله: ۱۴۰۴/۰۲/۱۹

تاریخ (های) اصلاح مقاله: ۱۴۰۴/۰۵/۰۷

تاریخ پذیرش مقاله: ۱۴۰۴/۰۶/۳۱

۱- مقدمه

است که رویا دیدن در خواب اتفاق می‌افتد [۴]. بنابراین، برای مطالعه‌ی برخی مشکلات روانی که رویا را تحت تأثیر قرار داده و منجر به کابوس می‌شوند، مطالعه‌ی مرحله‌ی REM خواب از اهمیت ویژه‌ای برخوردار است. روش‌های مختلفی برای تحلیل رؤیا به کار گرفته شده که شامل دو دسته‌ی اصلی: جمع‌آوری سیگنال‌های فیزیولوژیکی و گزارش‌های خوداظهاری است [۱]. تکنیک‌های جمع‌آوری داده شامل ثبت سیگنال‌های الکتروانسفالوگرام^۳ (EEG)، الکترومایوگرام^۴ (EMG)، الکترواکولوگرام^۵ (EOG) [۵] و تصویربرداری تشدید مغناطیسی عملکردی^۶ (fMRI) است [۱]. در عین حال که تصویربرداری fMRI هزینه‌ی بالایی دارد، به شدت تحت تأثیر نویزهای محیطی قرار می‌گیرد [۶]. از سوی دیگر، گزارش‌های خوداظهاری نیز به دلیل فراموش شدن سریع رؤیا پس از بیداری، از دقت بالایی برخوردار نیستند [۲].

خواب نقش اساسی در تنظیم احساسات و خلق‌وخو ایفا می‌کند. در این فرآیند، مغز اطلاعات جدید را پردازش و سازمان‌دهی کرده و خاطرات را تثبیت می‌کند، که برای حفظ سلامت و تعادل روانی ضروری است. انسان‌ها تقریباً یک‌سوم عمر خود (معمولاً بین ۶ تا ۸ ساعت در شبانه‌روز) را در خواب سپری می‌کنند، که بخش قابل توجهی از این زمان به رؤیا دیدن اختصاص دارد [۱، ۲]. مطالعات پیشین نشان داده‌اند که محتوای رؤیاها می‌تواند بازتابی از وضعیت روانی فرد باشد. درواقع، تغییرات رؤیاها گاهی می‌تواند پیش از ظهور علائم در بیداری، نشانگر مشکلات روانی یا اختلالات عصبی باشد [۳]. به‌طور کلی، خواب شامل سه مرحله‌ی بیداری، حرکت غیرسریع چشم^۱ (NREM) و حرکت سریع چشم^۲ (REM) است. در بین مراحل مختلف خواب، مرحله‌ی REM خواب زمانی

^۴ Electromyogram

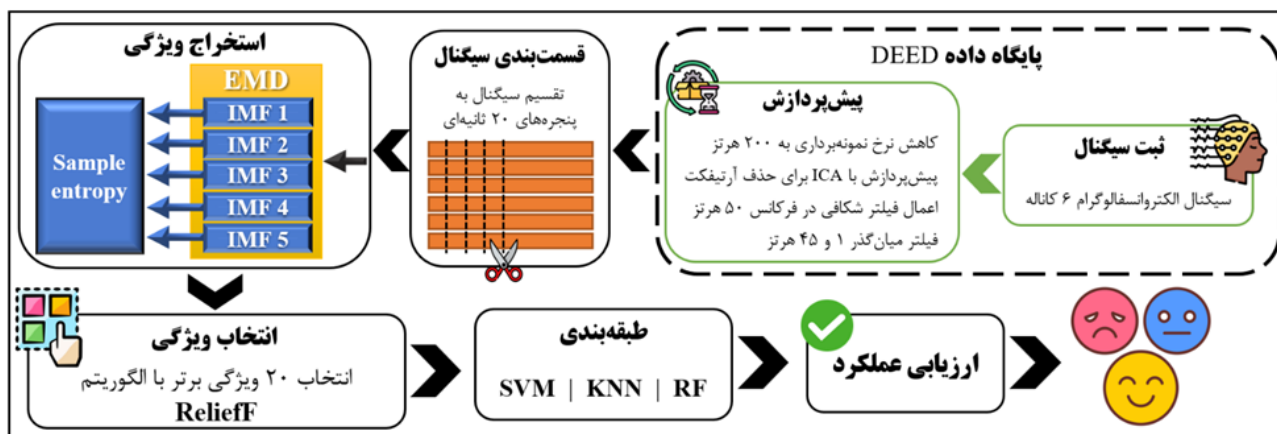
^۵ Electrooculogram

^۶ Functional Magnetic Resonance Imaging

^۱ Non-Rapid Eye Movement

^۲ Rapid Eye Movement

^۳ Electroencephalogram



شکل ۱- روندنمای رویکرد پیشنهادی برای طبقه‌بندی حالات مختلف احساسات در رویا با استفاده از یادگیری ماشین و سیگنال‌های EEG.

احساسی رؤیا در مرحله REM خواب جمع‌آوری شده است که در آن، سیگنال‌های EEG افراد شرکت‌کننده در طول خواب ثبت شده است [۱۱]. در این مطالعه، ویژگی‌هایی مانند چگالی طیفی توان (PSD)، آنالیز توافقی (DE) و الگوهای فضایی مشترک از سیگنال‌های EEG استخراج شده و به ورودی طبقه‌بندی‌های مختلف از جمله K نزدیک‌ترین همسایگی (KNN)، ماشین بردار پشتیبان (SVM)، الگوریتم LightGBM، درخت‌های تصمیم‌گیری تقویتی (GBDT) و جنگل تصادفی (RF) اعمال شده است. طبق نتایج گزارش شده، در طبقه‌بندی دوکلاسه‌ی رؤیاهای مثبت در برابر منفی و با پنجره‌بندی ۲۰ ثانیه‌ای، بالاترین صحت ۸۸٪ با استفاده از ویژگی CSP و طبقه‌بند GBDT به دست آمده است. همچنین، در طبقه‌بندی چندکلاسه، بالاترین صحت ۸۱٪ با استفاده از ویژگی DE و دسته‌بند LightGBM حاصل شده است [۱۱]. در مطالعه‌ی دیگری، نویسندگان سیستمی را برای طبقه‌بندی احساسات رؤیا مبتنی بر EEG از مجموعه داده‌ی DEED توسعه دادند [۱]. آن‌ها عملکرد روش‌های مختلف استخراج ویژگی از جمله PSD، تبدیل موجک گسسته^۵ (DWT) و تجزیه حالت تجربی^۶ (EMD) را بررسی کردند. همچنین، الگوریتم‌های یادگیری ماشین مانند تقویت گرادینان، RF، درخت تصمیم و SVM، در کنار مدل‌های یادگیری عمیق از جمله EEGNet و EEGNeX مورد استفاده قرار گرفتند. نتایج نشان داد که مدل EEGNeX با فراهم نمودن صحت ۷۱٪ قادر به تفکیک احساسات مثبت و منفی رؤیاهای است. Torvestad و همکارانش یک سیستم رابط مغز و رایانه (BCI) برای رمزگشایی رؤیا با استفاده از مجموعه داده‌ی DREAM توسعه دادند. آن‌ها با استفاده از ویژگی‌های EMD و PSD و به‌کارگیری طبقه‌بند تقویت گرادینان شدید^۷ (XGBoost)، به دقت ۹۱٪ در تفکیک تجربه‌ی رؤیا و عدم تجربه‌ی رؤیا دست یافتند. نتایج این مطالعه نشان داد که باندهای فرکانسی تتا و بتا، تفاوت‌های قابل‌توجهی بین این دو کلاس ایجاد می‌کنند [۸]. در مطالعه‌ی دیگر، Moctezuma و همکارانش بر روی طبقه‌بندی خودکار محتوای احساسی رؤیاهای با استفاده از مجموعه داده‌ی DEED تحقیق کردند. آن‌ها با بهره‌گیری از DWT برای استخراج ویژگی و ترکیب الگوریتم‌های استاندارد مانند GB و RF با شبکه‌ی عصبی کانولوشنی، دقت ۶۴٪ را در طبقه‌بندی رؤیاهای خنثی در برابر رؤیاهای مثبت یا منفی به

در میان روش‌های موجود، EEG به دلیل مزایایی مانند مقرون‌به‌صرفه بودن، وضوح زمانی مناسب (امکان ثبت لحظه‌ای تغییرات در عملکرد مغز)، قابلیت حمل و دسترسی آسان، بیشتر مورد استفاده‌ی محققان در سیستم‌های تشخیص احساسات قرار گرفته است. این ویژگی‌ها، EEG را به ابزاری مناسب برای مطالعات رؤیا تبدیل کرده است [۷]. به عبارت دیگر، EEG امکان رمزگشایی خودکار محتوای احساسی رؤیاهای بدون نیاز به بیدار کردن فرد فراهم کرده و می‌تواند اطلاعات ارزشمندی را برای تحلیل احساسات رویا در محیط‌های بالینی و پژوهشی ارائه دهد [۸].

تحقیقات اخیر در حوزه تشخیص تجربیات رویا با استفاده از سیگنال‌های EEG پیشرفت‌های قابل‌توجهی را نشان داده‌اند. Moctezuma و همکاران رویکردی نوین برای طبقه‌بندی خودکار خواب با تجربه رویا و بدون رویا با استفاده از داده‌های EEG ارائه کردند [۹]. این مطالعه با بهره‌گیری از روش‌های استخراج ویژگی نظیر الگوهای فضایی مشترک^۱ (CSP) و تبدیل موجک گسسته (DWT) و به‌کارگیری الگوریتم ژنتیک چند هدفه (NSGA-II) برای انتخاب بهینه کانال‌های EEG، بر روی مجموعه داده DREAM (شامل داده‌های EEG ۵۸ کاناله از ۲۸ فرد در مراحل خواب REM و NREM) انجام شد. نتایج نشان داد که ترکیب CSP و طبقه‌بند K نزدیک‌ترین همسایگی (KNN) به دقتی بیش از ۸۵٪ در تمایز حالات رویا و بدون رویا دست یافت و مشخص شد که ۸ تا ۱۰ کانال EEG برای تشخیص رویا کافی است. در مطالعه‌ی دیگر، Packiyathan و Torvestad امکان شناسایی تجربیات رویا را با استفاده از روش‌های تحلیل مؤلفه‌های اصلی^۲ (PCA)، CSP و چگالی طیفی توان^۳ (PSD) به همراه تجزیه تجربی مد چندمتغیره^۴ (MEMD) بررسی کردند [۱۰]. این پژوهش از مجموعه‌های داده عمومی Zhang & Wamsley (۵۸ کانال) و Tononi (۲۵۶ کانال) در مراحل خواب REM و NREM استفاده کرد. نتایج نشان داد که در مجموعه داده Zhang & Wamsley و مرحله REM، ترکیب PCA، MEMD و CSP با طبقه‌بند KNN به دقت ۹۹/۸٪ و در مجموعه داده Tononi و مرحله REM، ترکیب MEMD و PSD با طبقه‌بند XGB به دقت ۹۹/۳٪ در تمایز بین حالت‌های تجربه رویا و عدم تجربه رویا دست یافت.

مجموعه داده‌ی DEED توسط Liu و همکارانش به منظور ارزیابی حالات

^۵ Discrete Wavelet Transform

^۶ Empirical Mode Decomposition

^۷ Extreme Gradient Boosting

^۱ Common Spatial Patterns

^۲ Principal Component Analysis

^۳ Power Spectral Density

^۴ Multivariate Empirical Mode Decomposition

۳۸ شرکت‌کننده (۱۸ زن و ۲۰ مرد) با میانگین سنی ۲۱/۱۶ سال است. تمامی شرکت‌کنندگان از سلامت کامل برخوردار بوده، راست‌دست و دارای ملیت چینی بوده‌اند و هیچ‌گونه سابقه‌ای از اختلالات عصبی، روانی یا ناتوانی جسمی نداشته‌اند. سیگنال‌های EEG با استفاده از شش الکترود (F3، F4، FT7، FT8، T7، T8) طبق سیستم ۱۰-۲۰ ثبت شده است.

در ابتدا، سیگنال‌ها در شرایط استراحت با چشمان باز و بسته به مدت چهار دقیقه ثبت شده‌اند. سپس، به هر شرکت‌کننده در سه جلسه‌ی جداگانه، فیلم‌هایی با محتوای احساسی مثبت، منفی یا خنثی نمایش داده شده و پس از هر بار نمایش، شرکت‌کننده فرم PANAS را تکمیل کرده است. پس از آن، ثبت شبانه‌ی EEG آغاز شده و مراحل خواب تحت نظارت قرار گرفته‌اند. در مرحله‌ی REM، شرکت‌کنندگان با هشدار صوتی بیدار شده و احساسات خود را گزارش کرده‌اند. این گزارش‌ها توسط پژوهشگران در پنج دسته‌ی احساسی طبقه‌بندی شده‌اند.

در نهایت، سیگنال‌های ثبت‌شده از مرحله‌ی REM که دارای برچسب احساسی معتبر بوده‌اند، برای تحلیل انتخاب شدند. پس از حذف داده‌های فاقد رؤیا، ۴۹۳ فایل mat. باقی مانده‌اند که شامل ۱۵۳ فایل احساسی مثبت (E4/E5)، ۹۶ فایل منفی (E1/E2) و ۲۴۴ فایل خنثی (E3) می‌باشند.

۲-۲- پیش‌پردازش

پیش‌پردازش سیگنال‌های EEG توسط گردآورندگان پایگاه داده DEED انجام شده است. این مراحل شامل کاهش نرخ نمونه‌برداری به ۲۰۰ هرتز، اعمال فیلتر شکافی ۵۰ هرتز برای حذف نویز خطوط برق، و فیلتر میان‌گذر در بازه ۱ تا ۴۵ هرتز برای حفظ باندهای فرکانسی مرتبط با فعالیت‌های مغزی احساسی است. همچنین، آرتیفکت‌های ناشی از حرکات چشم و عضلات با استفاده از الگوریتم AMICA در جعبه‌ابزار EEGLAB حذف شده و سیگنال‌ها با استفاده از الکترودهای M1 و M2 بازمرجع‌سازی شده‌اند. در نهایت، در این مطالعه، سیگنال‌های EEG فیلترشده به پنجره‌های ۲۰ ثانیه‌ای تقسیم شدند.

۲-۳- استخراج ویژگی

استخراج ویژگی در یادگیری ماشین نقش مهمی ایفا می‌کند، زیرا به‌طور مستقیم بر عملکرد مدل و قابلیت تفسیر آن تأثیر می‌گذارد [۱۴]. در این مطالعه، ویژگی‌ها در حوزه‌ی زمان-فرکانس استخراج می‌شوند. ابتدا، هر یک از کانال‌های EEG در پنجره‌های پیش‌پردازش‌شده، با استفاده از روش EMD به پنج IMF تجزیه می‌شوند. سپس، آنتروپی نمونه‌ای برای هر یک از این IMFها محاسبه می‌شود. در بخش‌های بعدی، جزئیات مربوط به روش EMD و آنتروپی نمونه‌ای به‌طور مفصل شرح داده خواهد شد.

۲-۳-۱- تجزیه حالت تجربی

در روش EMD سیگنال $x(t)$ به‌صورت تکراری به مجموعه‌ای از مؤلفه‌های نوسانی محدود، موسوم به IMF، و یک باقی‌مانده تجزیه می‌شود [۱۵]. هر IMF دارای دو ویژگی اساسی است:

(۱) تعداد تقاطع‌های صفر نباید بیش از یک واحد با تعداد نقاط اکسترمم اختلاف داشته باشد.

(۲) پوش‌هایی که توسط مقادیر حداکثر و حداقل محلی تشکیل می‌شوند، باید در اطراف خط صفر به‌صورت متقارن قرار گیرند.

این ویژگی‌ها از اهمیت بالایی برخوردارند، زیرا تضمین می‌کنند که هر IMF به‌طور مؤثر یک مؤلفه نوسانی منفرد را در یک فرکانس خاص نمایش

دست آورده‌اند. همچنین، در تفکیک رؤیاهای مثبت از منفی، دقت ۶۵٪ حاصل شد [۲]. در مطالعه‌ای دیگر، نویسندگان از داده‌های EEG ثبت‌شده در مرحله‌ی NREM خواب به‌منظور طبقه‌بندی تجربی رؤیا و عدم تجربه‌ی رؤیا در خواب استفاده کرده‌اند. در این مطالعه، Packiyannathan و همکاران با به‌کارگیری سیگنال‌های EEG ۵۸ کاناله، به صحت ۹۴٪، مساحت زیر منحنی مشخصه عملکرد^۱ (AUROC) برابر با ۰/۹۱، و ضریب کاپای ۰/۸۴ دست یافتند. این نتایج با استفاده از ترکیب الگوریتم‌های تجزیه حالت تجربی چندمتغیره (MEMD)، تحلیل مؤلفه‌های اصلی (PCA)، CSP، و در نهایت طبقه‌بند KNN حاصل شد [۱۲]. همچنین در مطالعه‌ای دیگر، نویسندگان سه تابع حالت ذاتی^۲ (IMF) اول را از سیگنال‌های EEG پایگاه داده‌ی DEAP با استفاده از روش EMD استخراج کردند. پس از تقسیم این سیگنال‌ها به پنجره‌های کوچک‌تر، توان هر بخش به‌عنوان ویژگی در نظر گرفته شد. سپس، ویژگی‌های استخراج‌شده با استفاده از نگاشت منطبق بر سیستم بین‌المللی ۱۰-۲۰ به تصاویر تبدیل شدند. این تصاویر، که بیانگر الگوهای احساسی مرتبط با EEG بودند، با استفاده از یک شبکه‌ی یادگیری عمیق مورد طبقه‌بندی قرار گرفتند. نتایج نشان داد که این روش قادر به طبقه‌بندی احساسات مختلف با میانگین دقت ۷۸٪ بر اساس سیگنال‌های EEG است [۱۳].

بررسی تحقیقات پیشین نشان می‌دهد که اگرچه مطالعات گسترده‌ای در زمینه طبقه‌بندی سیگنال‌های EEG برای شناسایی خواب با تجربه رؤیا یا بدون رؤیا انجام شده، اما تحقیقات در حوزه طبقه‌بندی احساسات مرتبط با رؤیا بسیار محدود است. یکی از چالش‌های اصلی، فقدان پایگاه داده جامع و استاندارد برای تشخیص احساسات در رؤیا است. از طرفی دیگر عملکرد روش‌های موجود بر روی تنها پایگاه داده‌ی موجود (مجموعه داده DEED) همچنان پایین است. برای رفع این چالش‌ها، در این پژوهش یک الگوریتم خودکار برای طبقه‌بندی احساسات در رؤیا با استفاده از مجموعه داده DEED پیشنهاد شده است. در روش پیشنهادی، سیگنال‌های EEG پیش‌پردازش‌شده به پنجره‌های ۲۰ ثانیه‌ای تقسیم شده و با استفاده از روش تجزیه مد تجربی (EMD) به پنج مؤلفه مد ذاتی (IMF) تجزیه می‌شوند. سپس، آنتروپی نمونه‌ای برای هر IMF محاسبه شده و ویژگی‌های بهینه با الگوریتم Relief انتخاب می‌شوند. این ویژگی‌ها به طبقه‌بندهای یادگیری ماشین شامل جنگل تصادفی (RF)، ماشین بردار پشتیبان (SVM) و K نزدیک‌ترین همسایه (KNN) وارد می‌شوند. عملکرد مدل‌ها با استفاده از روش اعتبارسنجی متقابل ۱۰-فولد و معیارهای کمی نظیر صحت، دقت، حساسیت، امتیاز F1 و AUROC ارزیابی شده است. روند کلی روش پیشنهادی در شکل ۱ نمایش داده شده است. این رویکرد با بهبود استخراج ویژگی‌ها و انتخاب بهینه آن‌ها، عملکرد طبقه‌بندی احساسات در رؤیا را به‌طور قابل‌توجهی ارتقا داده و راهکاری مؤثر برای غلبه بر محدودیت‌های موجود ارائه می‌کند.

این مقاله در چهار بخش تنظیم شده است. بخش ۲ به توصیف داده‌ها و جزئیات روش پیشنهادی می‌پردازد. بخش ۳ به ارائه، تحلیل نتایج و بحث پیرامون آن اختصاص دارد. در بخش ۴، جمع‌بندی پژوهش و پیشنهادهایی برای مطالعات آینده ارائه می‌شود.

۲- مواد و روش‌ها

۲-۱- پایگاه داده

در این مطالعه، از مجموعه داده‌ی DEED که به‌طور عمومی در دسترس است، استفاده شده است [۱۱]. این مجموعه شامل داده‌های EEG ثبت‌شده از

به بردارهایی همپوشان و با طول m تقسیم می‌شود، که در آن m به‌عنوان بعد جاسازی^۳ انتخاب شده است. هر بردار X_i به صورت زیر تعریف می‌شود:

$$X_i = (x_i, x_{i+1}, \dots, x_{i+m-1}), \quad i = 1, 2, \dots, N - m + 1 \quad (5)$$

سپس، شباهت بین دو بردار X_i و X_j با استفاده از معیار فاصله زیر اندازه‌گیری می‌شود:

$$d(X_i, X_j) = \max_{k=0,1,\dots,m-1} |x_{i+k} - x_{j+k}| \quad (6)$$

در ادامه، یک آستانه r برابر با $0.25 \times$ انحراف معیار سیگنال ورودی تعیین شد. این انتخاب موجب می‌شود تا مقدار آستانه به‌صورت وقتی با تغییرات سیگنال تنظیم گردد. این موضوع به‌ویژه در مواردی که سیگنال دارای نوسانات اندک باشد از اهمیت ویژه‌ای برخوردار است؛ چراکه در صورت استفاده از مقدار آستانه ثابت 0.25 بدون در نظر گرفتن انحراف معیار، مقدار آستانه ممکن است نسبت به مقیاس سیگنال نامتناسب باشد و در نتیجه محاسبه آنتروپی به خروجی‌های نامعتبر منجر شود. این مسئله می‌تواند عملکرد طبقه‌بند را مختل سازد. از این‌رو، استفاده از آستانه‌ی وقتی، علاوه بر سازگاری بیشتر با ویژگی‌های آماری سیگنال، پایداری خروجی‌ها را نیز تضمین می‌نماید. دو بردار X_i و X_j مشابه در نظر گرفته می‌شوند اگر مقدار فاصله بین آن‌ها کوچکتر یا مساوی با آستانه‌ی r باشد ($d(X_i, X_j) \leq r$). برای هر بردار X_i تعداد بردارهایی که (با فرض $j \neq i$) مشابه آن هستند شمارش می‌شود و نتیجه آن در متغیر $N_m(i)$ ذخیره می‌شود. در گام بعدی این فرآیند برای بردارهایی با طول $m + 1$ یعنی $Y_i = (x_i, x_{i+1}, \dots, x_{i+m})$ تکرار می‌شود. تعداد بردارهایی که مشابه به Y_i هستند در متغیر $N_{m+1}(i)$ ذخیره می‌شود. در نهایت، احتمال شباهت برای بردارهای دو طول m و $m + 1$ ، به‌صورت زیر محاسبه می‌شود:

$$P_m = \frac{1}{N - m} \sum_{i=1}^{N-m} N_m(i) \quad (7)$$

$$P_{m+1} = \frac{1}{N - m - 1} \sum_{i=1}^{N-m-1} N_{m+1}(i) \quad (8)$$

متغیرهای فوق مقدار احتمال این که یک بردار که به‌طور تصادفی از سری زمانی انتخاب‌شده، برداری مشابه در مجموعه داده شده داشته باشد را بیان می‌کند. در نهایت، SampEn به‌صورت منفی لگاریتم طبیعی نسبت احتمالات P_{m+1} و P_m تعریف می‌شود:

$$\text{SampEn}(m, r) = -\ln\left(\frac{P_{m+1}}{P_m}\right) \quad (9)$$

این نسبت تغییر نسبی در تعداد الگوهای مشابه را هنگام انتقال از بردارهای با طول m به $m + 1$ به صورت کمی اندازه‌گیری می‌کند.

به‌طور خلاصه، بعد از تقسیم کردن ۴۹۳ فایل mat. به پنجره‌های ۲۰ ثانیه‌ای، تعداد ۶۱۹۶ سیگنال EEG پنجره‌بندی شده به‌دست آمد که هر کدام از آنها دارای ۶ کانال هستند. در ادامه، از هر کانال EEG تعداد پنج تا IMF استخراج شده و برای هر یک از آنها دو ویژگی آنتروپی نمونه‌ای محاسبه شد. در مجموع، ماتریس ویژگی‌ها با اندازه‌ی (۶۰، ۶۱۹۶) به‌دست آمد. همانطور که مشاهده می‌شود، در روش فوق تعداد ۶۰ ویژگی به‌دست می‌آید که بیانگر ۶ کانال در ۵ زیرباند IMF در دو ویژگی آنتروپی (۶۰ = ۲ × ۵ × ۶) می‌باشد.

۲-۴- انتخاب ویژگی

انتخاب ویژگی یکی از مراحل کلیدی در یادگیری ماشین و تحلیل داده‌ها

می‌دهد. فرآیند تجزیه با جداسازی^۱ مؤلفه‌ها آغاز می‌شود که طی آن IMFها استخراج می‌شوند. گام ابتدایی در این فرآیند، شناسایی تمام قله‌ها و دره‌های محلی سیگنال $x(t)$ است. این نقاط سپس برای ایجاد دو پوش مورد استفاده قرار می‌گیرند: پوش بالایی $e_{upper}(t)$ که از درون‌یابی نقاط اوج ایجاد می‌شود و پوش پایینی به نام $e_{lower}(t)$ که از درون‌یابی نقاط دره ایجاد می‌شود. در ادامه، میانگین این دو پوش به‌صورت زیر محاسبه می‌شود [۱۵]:

$$m_1(t) = \frac{e_{upper}(t) + e_{lower}(t)}{2} \quad (1)$$

این پوش میانگین بیانگر روند یا مؤلفه‌ی تغییرات آهسته سیگنال است. با کسر این مقدار از سیگنال اصلی، اولین مؤلفه‌ی جزئیات، $h_1(t)$ ، به‌دست می‌آید:

$$h_1(t) = x(t) - m_1(t) \quad (2)$$

اگر مؤلفه $h_1(t)$ معیارهای لازم را داشته باشد، به‌عنوان اولین IMF با نام $c_1(t)$ در نظر گرفته می‌شود. در غیر این صورت، فرآیند جداسازی بر روی $h_1(t)$ تکرار می‌شود تا زمانی که یک IMF مناسب استخراج گردد. پس از بدست آمدن اولین IMF با نام $c_1(t)$ ، این مؤلفه از سیگنال اصلی کسر می‌شود تا باقی‌مانده به‌دست آید:

$$r_1(t) = x(t) - c_1(t) \quad (3)$$

باقی‌مانده $r_1(t)$ به‌عنوان سیگنال جدید برای تجزیه بیشتر در نظر گرفته می‌شود. این فرآیند به صورت تکراری ادامه می‌یابد تا IMFهای بعدی با نام‌های $c_1(t), c_2(t), \dots, c_n(t)$ استخراج شوند. این روند تا زمانی ادامه دارد که سیگنال باقی‌مانده $r_n(t)$ به یک تابع یکنواخت تبدیل شود یا دیگر مؤلفه‌های نوسانی در آن وجود نداشته باشد. در نهایت، سیگنال اصلی را می‌توان به‌صورت مجموع تمامی IMFهای استخراج‌شده و باقی‌مانده بازسازی کرد:

$$x(t) = \sum_{i=1}^n c_i(t) + r_n(t) \quad (4)$$

که در آن $c_i(t)$ ها نشان دهنده مؤلفه‌های IMF و $r_n(t)$ باقی‌مانده‌ی نهایی است که معمولاً روند کلی سیگنال را نشان می‌دهد.

در پیاده‌سازی انجام‌شده، تعداد تکرارها برای فرآیند جداسازی برابر با ۱۰ و آستانه‌ی همگرایی روی مقدار پیش‌فرض ۰.۰۵ تنظیم شده است. از میان IMFهای استخراج‌شده، صرفاً پنج IMF نخست هر سیگنال مورد استفاده قرار گرفته است.

۲-۳-۲- آنتروپی نمونه‌ای

آنتروپی نمونه‌ای^۲ یک معیار آماری برای اندازه‌گیری پیچیدگی و بی‌نظمی در داده‌های سری زمانی است. این شاخص می‌تواند در تحلیل رفتار دینامیکی سیگنال‌ها در مقیاس‌های مختلف مفید باشد [۱۶]. مقدار بالاتر SampEn نشان‌دهنده پیچیدگی و بی‌نظمی بیشتر در سری زمانی است، در حالی که مقدار پایین‌تر آن به منظم‌تر بودن سری زمانی اشاره دارد [۱۷]. محاسبه آنتروپی نمونه برای هر مد ذاتی به ما اجازه می‌دهد تا سطح نظم یا آشفتگی سیگنال را در هر مؤلفه فرکانسی به‌صورت جداگانه ارزیابی کنیم. بنابراین، ترکیب روش EMD با محاسبه آنتروپی، اطلاعات معناداری را نسبت به تحلیل مستقیم آنتروپی از کل سیگنال خام در اختیار مدل یادگیری ماشین قرار می‌دهد، چرا که هر مد ذاتی نماینده یک بازه خاص فرکانسی با ویژگی‌های فیزیولوژیکی متفاوت در تشخیص احساسات است [۱۸].

برای محاسبه آنتروپی نمونه‌ای، ابتدا سری زمانی ورودی $\{x_1, x_2, \dots, x_n\}$

^۳ embedding dimension

^۱ Sifting

^۲ Sample Entropy

۵-۲- طبقه‌بندی و معیارهای ارزیابی عملکرد

در این مطالعه، سه الگوریتم طبقه‌بندی مختلف شامل KNN، SVM و RF برای دسته‌بندی بردارهای ویژگی مورد استفاده قرار گرفتند. به منظور ارزیابی عملکرد مدل‌ها و بررسی قابلیت تعمیم آن‌ها، از روش اعتبارسنجی متقابل ۱۰-فولد استفاده شد. در این روش، کل داده‌ها به ۱۰ بخش تقسیم شده و در هر تکرار، مدل بر روی ۹ بخش آموزش داده می‌شود و در بخش باقی‌مانده مورد ارزیابی قرار می‌گیرد. این فرآیند ۱۰ بار تکرار شده و میانگین نتایج حاصل از بخش «آزمایش» به عنوان عملکرد نهایی مدل گزارش می‌شود. علاوه بر این، برای تحلیل کمی و دقیق از اثربخشی هر طبقه‌بند، از معیارهای ارزیابی عملکرد مانند صحت، دقت، حساسیت، امتیاز F1 و AUROC برای هر طبقه‌بند استفاده شد.

۶-۲- تحلیل آماری

در این مطالعه، به منظور ارزیابی معناداری آماری تفاوت میان ویژگی‌های انتخاب‌شده در دو کلاس، از تابع `f_oneway()` متعلق به کتابخانه `scipy.stats` در زبان برنامه‌نویسی پایتون استفاده شده است. این تابع با بهره‌گیری از توزیع F، مقدار p-value را محاسبه می‌کند تا وجود تفاوت معنادار بین گروه‌ها را مشخص سازد. در این روش مقدار آماره F بر اساس نسبت واریانس بین گروهی تقسیم بر واریانس درون گروهی محاسبه می‌شود.

$$F = \frac{MSB}{MSW} \quad (12)$$

که در آن متغیر MSB بیانگر واریانس بین گروهی و متغیر MSW بیانگر واریانس درون گروهی هستند.

۳- نتایج و بحث

در این مطالعه، سه سناریوی مختلف برای طبقه‌بندی حالات مختلف احساسات افراد در مرحله REM خواب با استفاده از سیگنال‌های EEG پیاده‌سازی شد. سناریوی اول شامل یک سناریوی سه کلاسه بود که در آن سه حالت احساسی مختلف در رویا طبقه‌بندی شدند: حالات احساسات مثبت رویا، احساسات منفی رویا و خنثی. به طور خاص، در این سناریو، داده‌ها به سه کلاس مختلف برچسب‌گذاری شدند: کلاس ۰ برای حالات احساسی منفی در رویا، کلاس ۱ برای حالات احساسات مثبت و نسبتاً ناراحت؛ کلاس ۲ برای حالات احساسات مثبت در رویا، شامل خوشحال و بسیار خوشحال. علاوه بر این، دو سناریوی دوکلاسه در نظر گرفته شد که در سناریوی اول، احساسات مثبت رویا در برابر احساسات منفی رویا طبقه‌بندی شدند و داده‌ها به دو دسته حالات با احساسات مثبت (کلاس ۲) در برابر احساسات منفی (کلاس ۰) تقسیم شدند. در سناریوی دوم، طبقه‌بندی احساسات مثبت و منفی در رویا در برابر خنثی انجام شد و داده‌ها به دو دسته حالات با احساسات (کلاس ۰ و کلاس ۲) و بدون احساسات (کلاس ۱ یا خنثی) برچسب‌گذاری شدند. پس از برچسب‌گذاری داده‌ها در سناریوهای مختلف، سیگنال‌های EEG جهت آماده‌سازی برای استخراج ویژگی، به پنجره‌هایی با طول‌های متفاوت تقسیم شدند. این تقسیم‌بندی به منظور بررسی تأثیر اندازه پنجره بر نتایج طبقه‌بندی انجام گرفت. برای این منظور، سه طول پنجره ۵، ۱۰ و ۲۰ ثانیه مورد ارزیابی قرار گرفت. سناریو سه کلاسه با استفاده از طبقه‌بند KNN روی هر یک از این حالت‌ها اجرا شد و نتایج به دست آمده در جدول ۱ گزارش شده است. همان‌طور که در جدول ۱ مشاهده می‌شود، پنجره‌های ۲۰ ثانیه‌ای عملکرد بهتری در تفکیک حالات احساسی نشان داده‌اند. بنابراین، در ادامه‌ی فرآیند تحلیل، از این

است. این فرآیند با انتخاب مجموعه‌ای بهینه از ویژگی‌ها می‌تواند ضمن حفظ یا حتی بهبود عملکرد مدل، پیچیدگی محاسباتی را کاهش داده و قابلیت تفسیرپذیری مدل را افزایش دهد. به عبارت دیگر، با کاهش ابعاد داده‌ها، این روش منجر به کاهش پیچیدگی محاسباتی و همچنین کاهش احتمال بیش‌برازش می‌شود. بنابراین، انتخاب ویژگی می‌تواند توانایی مدل را در تعمیم به داده‌های جدید بهبود ببخشد.

در مطالعه‌ی حاضر، انتخاب ویژگی بلافاصله پس از مرحله استخراج ویژگی و پیش از تقسیم داده‌ها برای آموزش و ارزیابی انجام شده است. برای این منظور، الگوریتم‌های ReliefF [۱۹]، حداقل افزونگی-حداکثر ارتباط^۱ (mRMR) و اطلاعات متقابل^۲ (MI) پیاده‌سازی شدند. لازم به ذکر است که هر سه رویکرد مذکور اهمیت ویژگی‌ها را به صورت مستقل از مرحله طبقه‌بندی تعیین می‌کنند.

الگوریتم ReliefF ویژگی‌ها را بر اساس توانایی آن‌ها در تفکیک نمونه‌های متعلق به کلاس‌های مختلف ارزیابی می‌کند. هدف اصلی ReliefF اختصاص دادن یک وزن به هر ویژگی است که نشان‌دهنده‌ی میزان ارتباط آن ویژگی با برچسب کلاس داده‌ها باشد. ویژگی‌هایی که تأثیر بیشتری در تفکیک کلاس‌ها دارند، وزن بالاتری دریافت می‌کنند، در حالی که ویژگی‌های کم‌اهمیت یا نویزی وزن کمتری خواهند داشت. فرض کنید مجموعه داده شامل m نمونه و d ویژگی باشد. در هر تکرار، یک نمونه‌ی تصادفی X از مجموعه داده‌ها انتخاب می‌شود. سپس، نزدیک‌ترین نمونه به X که همان برچسب را دارد (H) به همراه نزدیک‌ترین نمونه به X با برچسب متفاوت (M) بر اساس معیار فاصله اقلیدسی انتخاب می‌شوند.


$$d(X, Y) = \sqrt{\sum_{j=1}^d (X_j - Y_j)^2} \quad (10)$$

که در آن X_j بیانگر مقدار ویژگی j-ام در نمونه X است. این مقایسه به منظور محاسبه‌ی میزان تمایزپذیری هر ویژگی انجام می‌شود و نقش کلیدی در اختصاص وزن به ویژگی‌ها دارد. وزن ویژگی j-ام طبق رابطه زیر به‌روزرسانی می‌شود:

$$W_j = W_j - \frac{(X_j - H_j)^2}{N} + \frac{(X_j - M_j)^2}{N} \quad (11)$$

که در آن X_j مقدار ویژگی j-ام برای نمونه‌ی انتخابی، H_j مقدار همان ویژگی برای نمونه‌ی H، M_j مقدار همان ویژگی برای نمونه‌ی M و N تعداد کل تکرارها است.

الگوریتم ReliefF به صورت تکراری اجرا شده و در هر دور، وزن ویژگی‌ها بر اساس توانایی آن‌ها در تمایز نمونه‌های مشابه و غیرمشابه به‌روزرسانی می‌شود. در ابتدا، تمام وزن‌ها برابر با صفر در نظر گرفته می‌شوند. سپس، در هر تکرار، ویژگی‌هایی که به طور مؤثر تفاوت‌های درون کلاسی را کاهش داده و تفاوت‌های بین کلاسی را افزایش می‌دهند، وزن‌های بالاتری دریافت می‌کنند. به عبارت دیگر، ویژگی‌های مهم‌تر در جداسازی کلاس‌ها تأثیر بیشتری بر مقدار وزن‌ها دارند. این فرآیند تا رسیدن به یک معیار توقف ادامه می‌یابد. معیار توقف می‌تواند شامل تعداد مشخصی از تکرارها یا همگرایی وزن‌ها باشد، به این معنا که با ادامه‌ی اجرا، تغییرات وزن‌ها به حدی کاهش یابند که دیگر به‌روزرسانی قابل توجهی رخ ندهد. در پایان، ویژگی‌هایی که وزن بالاتری دارند به عنوان مؤثرترین ویژگی‌ها انتخاب شده و سایر ویژگی‌های کم‌اهمیت یا نویزی حذف یا نادیده گرفته می‌شوند.



شکل ۲ صحت طبقه‌بند KNN در رویکرد سه کلاسه با انتخاب تعداد مختلفی از ویژگی‌های منتخب

عمدتاً از IMF1، IMF2 و IMF3 استخراج شده‌اند. همچنین، ویژگی‌های انتخاب شده از تمامی ۶ کانال EEG بودند و تفاوت قابل توجهی از نظر الگوریتم انتخاب ویژگی بین کانال‌های مختلف مشاهده نشد. نتایج بررسی آماری نشان داد که مقادیر p-value برای تمامی ویژگی‌های انتخاب شده کمتر از ۰/۰۵ بوده و این ویژگی‌ها قادر به ایجاد تفاوت معناداری بین سه کلاس احساسی مختلف هستند.

ویژگی‌های انتخاب شده برای سناریوی دو کلاسه رویا با احساسات خنثی در برابر رویا با احساسات مثبت یا منفی، همانطور که در جدول ۴ مشاهده می‌شود، از هر پنج IMF استخراج شده‌اند و شامل تمامی کانال‌ها می‌باشند. با این حال، تفاوت قابل توجهی بین کانال‌ها توسط الگوریتم انتخاب ویژگی مشاهده نشد. نتایج بررسی آماری برای این ویژگی‌ها نیز نشان می‌دهد که مقدار p-value ویژگی‌های انتخابی کمتر از ۰/۰۵ (به جز دو ویژگی) بوده و این ویژگی‌ها توانسته‌اند تفاوت معناداری بین دو کلاس مذکور ایجاد کنند.

همچنین، همانطور که در جدول ۵ مشاهده می‌شود، ویژگی‌های انتخابی در سناریو دو کلاسه رویا دارای احساسات مثبت در برابر رویا دارای احساسات منفی همانند سناریو سه کلاسه عمدتاً از IMF1، IMF2 و IMF3 استخراج شده‌اند. در این سناریو، ویژگی‌های انتخاب شده از همه ۶ کانال EEG هستند و همچنان تفاوت قابل توجهی بین کانال‌های انتخابی از نظر الگوریتم انتخاب ویژگی مشاهده نشد. نتایج بررسی آماری برای ویژگی‌های مذکور نیز مقادیر p-value کمتر از ۰/۰۵ (به جز دو ویژگی) را نشان می‌دهند.

بر اساس خروجی الگوریتم انتخاب ویژگی، تعداد تکرارهای هر یک از زیرباندها (IMF) و کانال‌ها در هر سناریو (یعنی تعداد دفعاتی که هر یک از IMF ها و کانال‌ها انتخاب شده‌اند)، مورد بررسی قرار گرفت و نتایج آن به ترتیب در شکل ۳ و شکل ۴ نمایش داده شده است. همانطور که در شکل ۳ مشاهده می‌شود، در میان باندهای فرکانسی مختلف، IMF1 بیشترین میزان تکرار را دارد در نهایت، می‌توان نتیجه گرفت که محتوای احساسی در سیگنال‌های EEG بیشتر در فرکانس‌های بالا (IMF1 تا IMF3) تفاوت قابل توجهی نشان می‌دهد، در حالی که در باندهای پایین (فرکانس‌های پایین‌تر مانند IMF4 و IMF5) تفاوت چندانی مشاهده نمی‌شود. همچنین، در شکل ۴ مشاهده می‌شود که بیشترین تکرار میان کانال‌های EEG در سناریوی طبقه‌بندی حالات خنثی و احساسات (مثبت یا منفی) مربوط به کانال T8 می‌باشد. با این حال، الگوی خاصی میان تکرار کانال‌ها در سایر سناریوها مشاهده نمی‌شود و تفاوت قابل توجهی در انتخاب کانال‌ها وجود ندارد.

جدول ۱- صحت طبقه‌بندها در سه سناریو با در نظر گرفتن طول پنجره‌های ۵ ثانیه، ۱۰ ثانیه و ۲۰ ثانیه.

رویکرد	طبقه‌بند	۵ ثانیه	۱۰ ثانیه	۲۰ ثانیه
سه کلاسه	KNN	0.581 ± 0.032	0.609 ± 0.097	0.930 ± 0.062
	SVM	0.612 ± 0.008	0.631 ± 0.125	0.924 ± 0.068
	RF	0.611 ± 0.003	0.644 ± 0.126	0.896 ± 0.009
خنثی - احساسات	KNN	0.706 ± 0.049	0.751 ± 0.121	0.974 ± 0.077
	SVM	0.725 ± 0.078	0.747 ± 0.079	0.954 ± 0.078
	RF	0.710 ± 0.040	0.752 ± 0.070	0.948 ± 0.123
احساس مثبت - احساس منفی	KNN	0.637 ± 0.114	0.640 ± 0.127	0.903 ± 0.070
	SVM	0.671 ± 0.094	0.663 ± 0.174	0.894 ± 0.069
	RF	0.674 ± 0.081	0.689 ± 0.202	0.889 ± 0.226

جدول ۲- مقایسه عملکرد طبقه‌بند KNN در طبقه‌بندی سه کلاسه با ۲۰ ویژگی منتخب الگوریتم‌های ReliefF، mRMR و روش MI.

الگوریتم انتخاب ویژگی	صحت	دقت	حساسیت	امتیاز F1	AUROC
mRMR	0.917 ± 0.096	0.920 ± 0.094	0.917 ± 0.096	0.917 ± 0.094	0.983 ± 0.037
MI	0.924 ± 0.099	0.927 ± 0.104	0.924 ± 0.099	0.924 ± 0.100	0.986 ± 0.030
ReliefF	0.930 ± 0.062	0.933 ± 0.069	0.930 ± 0.062	0.931 ± 0.062	0.988 ± 0.026

طول پنجره به‌عنوان مقدار بهینه استفاده شد. برای تحلیل باندهای فرکانسی مختلف در سیگنال‌های EEG، هر یک از کانال‌های سیگنال پنجره‌بندی شده به پنج IMF با استفاده از روش EMD تجزیه شد و سپس ویژگی آن‌تروپی نمونه‌ای برای هر زیرباند (برای هر IMF) محاسبه گردید. از بین این ویژگی‌ها، بهترین زیرمجموعه به‌عنوان ورودی برای الگوریتم‌های طبقه‌بندی به کار گرفته شدند تا حالات مختلف احساسات در مرحله خواب REM به‌طور دقیق طبقه‌بندی شوند.

به‌منظور شناسایی مؤثرترین مجموعه ویژگی‌ها، سه الگوریتم انتخاب ویژگی شامل ReliefF، mRMR و MI پیاده‌سازی و عملکرد آن‌ها در سناریوی طبقه‌بندی سه کلاسه مورد ارزیابی قرار گرفت. در هر یک از این روش‌ها، ۲۰ ویژگی برتر استخراج شد و معیارهای ارزیابی برای طبقه‌بند KNN با استفاده از این ویژگی‌ها محاسبه گردید. نتایج حاصل در جدول ۲ ارائه شده است و نشان می‌دهد که الگوریتم ReliefF در مقایسه با دو روش دیگر، بالاترین صحت طبقه‌بندی را به‌دست آورده و عملکرد مطلوب‌تری داشته است.


همچنین، عملکرد طبقه‌بند KNN با معیار صحت و برای تعداد مختلف ویژگی‌های منتخب ارزیابی شد. نتایج، همان‌طور که در شکل ۲ نشان داده شده، حاکی از آن است که کاهش ابعاد از ۶۰ به ۲۰ تا ۳۰ ویژگی، عملکرد طبقه‌بندی را بهبود می‌بخشد. با این حال، کاهش به کمتر از ۲۰ ویژگی باعث افت عملکرد می‌شود. استفاده از ۳۰ ویژگی، اگرچه دقت را ۰/۱٪ در مقایسه با انتخاب ۲۰ ویژگی افزایش می‌دهد، اما با ۵۰٪ افزایش پیچیدگی محاسباتی همراه است که این بهبود را توجیه نمی‌کند. بنابراین، انتخاب ۲۰ ویژگی به‌عنوان تعادل بهینه بین کاهش یک‌سومی پیچیدگی محاسباتی و بهبود عملکرد در نظر گرفته شد. مشخصات بهترین مجموعه از ویژگی‌ها برای سناریوهای مختلف، شامل سناریوهای سه کلاسه، دو کلاسه اول (احساسات خنثی در برابر احساسات مثبت یا منفی) و دو کلاسه دوم (احساسات مثبت در برابر احساسات منفی)، به ترتیب در جدول ۳، جدول ۴ و جدول ۵ به‌طور خلاصه ارائه شده است. همانطور که در جدول ۳ مشاهده می‌شود، در سناریوی سه کلاسه، ویژگی‌های انتخاب شده

جدول ۳- مشخصات ویژگی‌های انتخاب شده در سناریوی طبقه‌بندی سه‌کلاسه (احساسات مثبت رویا، احساسات منفی رویا و کلاس خنثی) با استفاده از الگوریتم ReliefF.


	تابع آنتروپی نمونه‌ای	کانال	IMF	p-value
۱	SampEn(imf, m=1, tau=2, MX=1)	T8	IMF1	3/66 e-37
۲	SampEn(imf, m=1, tau=2, MX=1)	F4	IMF1	7/01 e-20
۳	SampEn(imf, m=1, tau=2, MX=1)	FT8	IMF1	6/64 e-12
۴	SampEn(imf, m=1, tau=2, MX=1)	F3	IMF1	2/91 e-20
۵	SampEn(imf, m=1, tau=2, MX=1)	T7	IMF1	1/18 e-29
۶	SampEn(imf, m=1, tau=2, MX=1)	FT7	IMF1	2/57 e-12
۷	SampEn(imf, m=1, tau=2, MX=1)	F4	IMF1	5/61 e-20
۸	SampEn(imf, m=1, tau=2, MX=1)	FT8	IMF1	5/66 e-10
۹	SampEn(imf, m=2, tau=2, MX=1)	T7	IMF1	2/47 e-16
۱۰	SampEn(imf, m=1, tau=2, MX=1)	T8	IMF1	3/09 e-28
۱۱	SampEn(imf, m=1, tau=2, MX=1)	FT7	IMF1	1/34 e-09
۱۲	SampEn(imf, m=2, tau=2, MX=1)	T7	IMF2	6/93 e-19
۱۳	SampEn(imf, m=2, tau=2, MX=1)	F4	IMF2	1/74 e-03
۱۴	SampEn(imf, m=1, tau=2, MX=1)	T8	IMF2	2/16 e-22
۱۵	SampEn(imf, m=1, tau=2, MX=1)	FT7	IMF2	1/70 e-06
۱۶	SampEn(imf, m=1, tau=2, MX=1)	T8	IMF2	2/83 e-24
۱۷	SampEn(imf, m=2, tau=2, MX=1)	FT8	IMF2	1/12 e-03
۱۸	SampEn(imf, m=2, tau=2, MX=1)	F3	IMF2	2/08 e-02
۱۹	SampEn(imf, m=1, tau=2, MX=1)	T8	IMF3	3/23 e-16
۲۰	SampEn(imf, m=2, tau=2, MX=1)	F4	IMF3	2/30 e-04

جدول ۵- مشخصات ویژگی‌های انتخاب شده در سناریوی طبقه‌بندی دوکلاسه (احساسات مثبت رویا در برابر احساسات منفی رویا) با استفاده از الگوریتم ReliefF.

	تابع آنتروپی نمونه‌ای	کانال	IMF	p-value
۱	SampEn(imf, m=1, tau=2, MX=1)	F4	IMF1	1/37 e-3
۲	SampEn(imf, m=1, tau=2, MX=1)	FT8	IMF1	2/78 e-5
۳	SampEn(imf, m=1, tau=2, MX=1)	F3	IMF1	3/53 e-8
۴	SampEn(imf, m=1, tau=2, MX=1)	T7	IMF1	9/81 e-5
۵	SampEn(imf, m=1, tau=2, MX=1)	T8	IMF1	2/15 e-6
۶	SampEn(imf, m=1, tau=2, MX=1)	F4	IMF1	2/88 e-4
۷	SampEn(imf, m=1, tau=2, MX=1)	T7	IMF1	2/68 e-5
۸	SampEn(imf, m=2, tau=2, MX=1)	F4	IMF2	2/22 e-3
۹	SampEn(imf, m=1, tau=2, MX=1)	T7	IMF2	7/53 e-3
۱۰	SampEn(imf, m=1, tau=2, MX=1)	F3	IMF2	4/58 e-3
۱۱	SampEn(imf, m=1, tau=2, MX=1)	T8	IMF2	3/34 e-5
۱۲	SampEn(imf, m=1, tau=2, MX=1)	T7	IMF2	7/11 e-1
۱۳	SampEn(imf, m=2, tau=2, MX=1)	F4	IMF2	8/42 e-2
۱۴	SampEn(imf, m=2, tau=2, MX=1)	FT8	IMF2	1/78 e-4
۱۵	SampEn(imf, m=1, tau=2, MX=1)	FT8	IMF2	2/68 e-2
۱۶	SampEn(imf, m=2, tau=2, MX=1)	F3	IMF3	8/37 e-5
۱۷	SampEn(imf, m=2, tau=2, MX=1)	F4	IMF3	7/92 e-5
۱۸	SampEn(imf, m=1, tau=2, MX=1)	FT8	IMF3	5/71 e-7
۱۹	SampEn(imf, m=2, tau=2, MX=1)	FT7	IMF3	1/23 e-8
۲۰	SampEn(imf, m=1, tau=2, MX=1)	T8	IMF3	1/10 e-4



شکل ۳- تعداد تکرار IMF ها در هر سه سناریوی طبقه‌بندی بر اساس خروجی الگوریتم انتخاب ویژگی.



شکل ۴- تعداد تکرار کانال‌ها در هر سه سناریوی طبقه‌بندی بر اساس خروجی الگوریتم انتخاب ویژگی.

جدول ۴- مشخصات ویژگی‌های انتخاب شده در سناریوی طبقه‌بندی دوکلاسه (احساسات مثبت یا منفی در برابر احساسات خنثی) به وسیله الگوریتم ReliefF.

	تابع آنتروپی نمونه‌ای	کانال	IMF	p-value
۱	SampEn(imf, m=1, tau=2, MX=1)	F3	IMF1	3/71 e-14
۲	SampEn(imf, m=1, tau=2, MX=1)	F4	IMF1	1/90 e-18
۳	SampEn(imf, m=1, tau=2, MX=1)	FT7	IMF1	3/27 e-5
۴	SampEn(imf, m=1, tau=2, MX=1)	FT7	IMF1	4/66 e-7
۵	SampEn(imf, m=1, tau=2, MX=1)	FT8	IMF1	1/81 e-6
۶	SampEn(imf, m=2, tau=2, MX=1)	FT8	IMF1	4/69 e-9
۷	SampEn(imf, m=1, tau=2, MX=1)	T7	IMF1	6/95 e-27
۸	SampEn(imf, m=2, tau=2, MX=1)	T8	IMF1	4/83 e-32
۹	SampEn(imf, m=1, tau=2, MX=1)	T8	IMF1	4/93 e-33
۱۰	SampEn(imf, m=2, tau=2, MX=1)	F3	IMF2	8/42 e-1
۱۱	SampEn(imf, m=2, tau=2, MX=1)	F4	IMF2	6/99 e-2
۱۲	SampEn(imf, m=1, tau=2, MX=1)	T7	IMF2	2/61 e-18
۱۳	SampEn(imf, m=1, tau=2, MX=1)	T8	IMF2	6/81 e-21
۱۴	SampEn(imf, m=1, tau=2, MX=1)	T8	IMF2	3/51 e-28
۱۵	SampEn(imf, m=1, tau=2, MX=1)	T7	IMF3	2/73 e-10
۱۶	SampEn(imf, m=1, tau=2, MX=1)	T8	IMF3	2/56 e-13
۱۷	SampEn(imf, m=2, tau=2, MX=1)	T8	IMF3	3/67 e-18
۱۸	SampEn(imf, m=1, tau=2, MX=1)	T8	IMF4	1/85 e-21
۱۹	SampEn(imf, m=2, tau=2, MX=1)	T8	IMF5	2/54 e-32
۲۰	SampEn(imf, m=1, tau=2, MX=1)	T8	IMF5	2/09 e-36

جدول ۷- نتایج طبقه‌بندی حالات مختلف احساسات رویا در سه سناریوی مختلف با استفاده از پنج معیار ارزیابی برای روش‌های طبقه‌بندی SVM، KNN و RF.

رویکرد	طبقه‌بند	صحت	دقت	حساسیت	امتیاز F1	AUROC
سه کلاس	KNN	۰.۹۳/۰.۸ ±۰.۰۶۲	۰.۹۳/۰.۸ ±۰.۰۶۹	۰.۹۳/۰.۸ ±۰.۰۶۲	۰.۹۳/۰.۸ ±۰.۰۶۲	۰.۹۸۸۲ ±۰.۰۰۲۶
	SVM	۰.۹۲/۰.۴ ±۰.۰۶۸	۰.۹۴/۰.۰ ±۰.۰۶۴	۰.۹۲/۰.۴ ±۰.۰۸۶	۰.۹۲/۰.۴ ±۰.۰۸۶	۰.۹۸۲۳ ±۰.۰۰۳۵
	RF	۰.۸۹/۰.۶۷ ±۱/۰.۹	۰.۸۹/۰.۵۹ ±۱/۱.۳	۰.۸۹/۰.۶۷ ±۱/۰.۹	۰.۸۹/۰.۵۷ ±۱/۱.۳	۰.۹۷۲۳ ±۰.۰۰۴۹
دو کلاس احساسات	KNN	۰.۹۷/۰.۴۵ ±۰.۰۷۷	۰.۹۷/۰.۴۹ ±۰.۰۷۵	۰.۹۷/۰.۳۲ ±۰.۰۸۲	۰.۹۷/۰.۴۵ ±۰.۰۷۷	۰.۹۸۳۱ ±۰.۰۰۵۶
	SVM	۰.۹۵/۰.۴۸ ±۰.۰۷۸	۰.۹۵/۰.۵۱ ±۰.۰۷۸	۰.۹۵/۰.۳۶ ±۰.۰۷۶	۰.۹۵/۰.۴۸ ±۰.۰۷۸	۰.۹۸۵۰ ±۰.۰۰۳۷
	RF	۰.۹۴/۰.۸۰ ±۱/۰.۲۳	۰.۹۴/۰.۸۶ ±۱/۰.۲۳	۰.۹۴/۰.۶۱ ±۱/۰.۲۴	۰.۹۴/۰.۷۹ ±۱/۰.۲۳	۰.۹۶۸۵ ±۰.۰۰۹۵
احساس مثبت احساس منفی	KNN	۰.۹۰/۰.۳۹ ±۰.۰۷۰	۰.۹۰/۰.۴۲ ±۰.۰۶۷	۰.۹۱/۰.۶۷ ±۱/۰.۵۷	۰.۹۰/۰.۳۹ ±۰.۰۶۹	۰.۹۷۱۲ ±۰.۰۰۶۶
	SVM	۰.۸۹/۰.۴۶ ±۱/۰.۶۹	۰.۸۹/۰.۵۴ ±۱/۰.۷۱	۰.۹۱/۰.۰۴ ±۱/۰.۸۶	۰.۸۹/۰.۴۶ ±۱/۰.۹۰	۰.۹۴۴۰ ±۰.۰۰۶۳
	RF	۰.۸۸/۰.۹۲ ±۲/۰.۲۶	۰.۸۸/۰.۹۲ ±۲/۰.۲۴	۰.۹۱/۰.۵۶ ±۲/۰.۱۴	۰.۸۸/۰.۹۰ ±۲/۰.۲۶	۰.۹۵۹۲ ±۰.۰۰۹۱

علاوه بر معیارهای کمی، از منحنی مشخصه نسبی عملکرد (ROC) برای ارزیابی عملکرد سه الگوریتم دسته‌بندی KNN، SVM و RF استفاده شد. لازم به ذکر است که منحنی ROC بیان‌گر توانایی الگوریتم طبقه‌بندی در دسته‌بندی صحیح داده‌ها می‌باشد، بدین گونه که هرچه قدر سطح زیر منحنی این نمودار (AUC) به عدد یک نزدیک‌تر باشد الگوریتم مورد نظر عملکرد بهتری را ارائه می‌کند. منحنی‌های ROC بدست آمده برای هر سه روش مذکور در سناریوی طبقه‌بندی رویا با احساسات در برابر رویا با احساسات خنثی در شکل ۸ رسم و باهم مقایسه شده است.

همانطور که مشاهده می‌شود الگوریتم SVM با فراهم کردن میانگین AUC برابر با ۰/۹۸۵۰ دارای بهترین عملکرد در مقایسه با سایر روش‌ها می‌باشد. با این وجود، تفاوت چشمگیری در عملکرد طبقه‌بندها از نظر معیار ROC وجود ندارد. همچنین، در شکل ۹ نمودارهای ROC برای هر کدام از الگوریتم‌های طبقه‌بندی در سناریوی طبقه‌بندی رویا با احساسات مثبت در برابر رویا با احساسات منفی رسم شده‌اند. در این سناریو، همانطور که مشاهده می‌شود، الگوریتم KNN عملکرد بهتری را نسبت به سایر الگوریتم‌ها بدست آورده است. در طبقه‌بندی رویا با احساسات مثبت یا منفی در برابر رویا با احساسات خنثی، هر دو طبقه‌بند KNN و SVM عملکرد قابل مقایسه و مناسبی را فراهم کرده‌اند. علاوه بر این، ماتریس‌های درهم‌ریختگی برای ارائه جزئیات پیش‌بینی‌های طبقه‌بندها در هر سه سناریوی دسته‌بندی محاسبه شد. ماتریس‌های درهم‌ریختگی تعداد پیش‌بینی‌های صحیح و نادرست را در هر دسته نشان می‌دهند. با توجه به عملکرد بهتر طبقه‌بند KNN نسبت به سایر روش‌ها، ماتریس‌های درهم‌ریختگی فقط برای این روش در طبقه‌بندی سه کلاسه (شکل ۱۰)، طبقه‌بندی دو کلاسه رویا با احساسات خنثی در برابر رویا همراه با احساسات مثبت یا منفی (شکل ۱۱) و طبقه‌بندی رویا با احساسات مثبت در برابر رویا با احساسات منفی (شکل ۱۲) ارائه شده است. در شکل‌های مذکور میانگین درصد نمونه‌هایی که در هر کلاس به درستی یا به صورت نادرست در فرآیند ۱۰- فولد طبقه‌بندی شده‌اند، نمایش داده شده است.

جدول ۶- مقادیر بهینه پارامترهای هر یک از الگوریتم‌های طبقه‌بندی.


طبقه‌بند	پارامترها
KNN	n_neighbors = ۳
SVM	kernel='rbf', C=۱۰, gamma= ۰/۲۵, random_state = ۱۰۰, probability= True
RF	n_estimators = ۱۰۰, bootstrap= True, random_state = ۱۰۰

همانطور که در بخش‌های قبلی ذکر شد، در این مطالعه طبقه‌بندی با استفاده از مدل‌های KNN، SVM و RF انجام شده است. مقدار بهینه پارامترهای این مدل‌ها با استفاده از روش اعتبارسنجی متقابل ۱۰- فولد ارزیابی و انتخاب شدند. مقادیر بهینه پارامترهای هر طبقه‌بند در جدول ۶ ارائه شده است.


عملکرد هر سه مدل طبقه‌بندی‌کننده با استفاده از معیارهای کمی صحت، حساسیت، اختصاصیت، دقت و AUCROC مقایسه شده و میانگین نتایج به‌دست آمده به همراه انحراف معیار آن‌ها به‌صورت خلاصه در جدول ۷ ارائه شده است. نتایج نشان می‌دهند که طبقه‌بند KNN بالاترین عملکرد را از نظر معیارهای مذکور در هر سه سناریوی طبقه‌بندی (دسته‌بندی‌های چندکلاسه و دوکلاسه) ارائه می‌دهد. در سناریوی دسته‌بندی سه کلاسه، طبقه‌بند KNN به ترتیب میانگین صحت ۰/۹۳/۰۸، میانگین دقت ۰/۹۳/۳۸، میانگین حساسیت ۰/۹۳/۰۸، میانگین AUROC برابر با ۰/۹۸ و میانگین امتیاز F1 برابر با ۰/۹۳/۱۵ را به‌دست آورده است. همچنین، در سناریوی طبقه‌بندی دوکلاسه (کلاس‌های رویا دارای احساسات مثبت یا منفی در برابر رویا با احساسات خنثی)، میانگین صحت ۰/۹۷/۴۵، میانگین دقت ۰/۹۷/۴۹، میانگین امتیاز F1 برابر با ۰/۹۷/۴۵، میانگین حساسیت ۰/۹۷/۳۲ و میانگین AUROC برابر با ۰/۹۸ به‌دست آمده است. در نهایت، در سناریوی طبقه‌بندی دوکلاسه رویا دارای احساسات مثبت در برابر رویا دارای احساسات منفی، میانگین صحت ۰/۹۰/۳۹، میانگین دقت ۰/۹۰/۴۲، میانگین امتیاز F1 برابر با ۰/۹۰/۳۹، میانگین حساسیت ۰/۹۱/۶۷ و میانگین AUROC برابر با ۰/۹۷ به‌دست آمده است.

در این مطالعه، تعداد نمونه‌ها در کلاس‌های منفی، خنثی و مثبت به ترتیب ۱۳۷۴ (۰/۲۲/۱۸)، ۲۸۵۵ (۰/۴۶/۰۸) و ۱۹۶۷ (۰/۳۱/۷۴) از مجموع ۶۱۹۶ نمونه است و مشاهده شد که دقت طبقه‌بندی سه کلاسه (۰/۹۳/۷۴) بالاتر از طبقه‌بندی دوکلاسه (۰/۹۰/۳۹) است. این تفاوت عمدتاً به علت نامتعادل بودن توزیع داده‌ها در کلاس‌های مختلف است، زیرا کلاس خنثی با ۰/۴۶/۰۸ از داده‌ها، اکثریت را تشکیل می‌دهد. در مجموعه‌های داده نامتعادل، عملکرد قوی مدل روی کلاس اکثریت می‌تواند دقت کلی را به‌طور قابل توجهی افزایش دهد.


به منظور بررسی تأثیر فرآیند انتخاب ویژگی بر عملکرد مدل‌های KNN، SVM و RF، طبقه‌بندی با استفاده از مجموعه کامل ویژگی‌ها و ویژگی‌های منتخب انجام شده و نتایج بر اساس میانگین معیارهای دقت، حساسیت، صحت، امتیاز F1 و AUROC در شکل ۵ الی شکل ۷ نمایش داده شده است. نتایج نشان می‌دهد که عملکرد الگوریتم‌های طبقه‌بندی هنگام استفاده از مجموعه ویژگی‌های انتخاب شده با الگوریتم Relief به‌طور قابل توجهی بهبود یافته است، که این بهبود در تمامی معیارهای ارزیابی مشاهده می‌شود. بنابراین، می‌توان مشاهده کرد که به هنگام استفاده از الگوریتم انتخاب ویژگی در اکثر سناریوهای دسته‌بندی می‌توان علاوه بر کاهش تعداد ویژگی‌ها (کاهش بار محاسباتی و بهبود قابلیت تعمیم مدل‌ها) عملکرد مدل را بهبود داد. با این وجود، نتایج طبقه‌بند SVM (بجز معیار AUC) در سناریوی دسته‌بندی احساسات رویا (مثبت یا منفی) در برابر خنثی بعد از استخراج ویژگی به مقدار ناچیز (کمتر از ۲ درصد) کاهش پیدا کرده است.



شکل ۸- نمودارهای ROC هر یک از طبقه‌بندها در سناریوی دسته‌بندی رویا با احساسات مثبت در برابر رویا با احساس خنثی.




شکل ۹- نمودارهای ROC هر یک از طبقه‌بندها در سناریوی دسته‌بندی رویا با احساسات مثبت در برابر رویا با احساسات منفی.




شکل ۱۰- ماتریس درهم‌ریختگی طبقه‌بند KNN در سناریوی دسته‌بندی سه کلاسه (احساسات مثبت رویا، احساسات منفی رویا و کلاس خنثی).




شکل ۵- مقایسه‌ی نتایج حاصل از طبقه‌بند KNN با استفاده از کل ویژگی‌ها در برابر عملکرد آن به هنگام استفاده از ویژگی‌های انتخاب شده.




شکل ۶- مقایسه‌ی نتایج حاصل از طبقه‌بند SVM با استفاده از کل ویژگی‌ها در برابر عملکرد آن به هنگام استفاده از ویژگی‌های انتخاب شده.



شکل ۷- مقایسه‌ی نتایج حاصل از طبقه‌بند RF با استفاده از کل ویژگی‌ها در برابر عملکرد آن به هنگام استفاده از ویژگی‌های انتخاب شده.



شکل ۱۱- ماتریس درهم‌ریختگی طبقه‌بند KNN در سناریوی دسته‌بندی رویا با احساسات در برابر رویا با احساسات خنثی.



شکل ۱۲- ماتریس درهم‌ریختگی طبقه‌بند KNN در سناریوی دسته‌بندی رویا با احساسات مثبت در برابر رویا با احساسات منفی.

در مقایسه با Moctezuma و همکارانش [۲] روش پیشنهادی در سناریوی طبقه‌بندی احساسات رویا در برابر خنثی بهبود چشمگیری داشته است (۹۷/۴۵٪ در برابر ۶۴/۷۰٪). علاوه بر این، در طبقه‌بندی احساسات مثبت رویا در برابر احساسات منفی رویا نیز میانگین صحت مدل پیشنهادی (۹۰/۳۹٪) از روش آن‌ها (۶۵/۹۰٪) به‌طور قابل توجهی بهتر بوده است. همچنین، مقایسه با روش ارائه شده توسط Packiyathan روش پیشنهادی در سناریوی طبقه‌بندی احساسات مثبت یا منفی رویا در برابر خنثی عملکرد بهتری دارد (۹۰/۳۹٪ در برابر ۸۲/۰۵٪). علاوه بر این، روش پیشنهادی در سناریوی سه کلاسه با میانگین صحت ۹۳/۰۸٪، عملکردی بهتری در مقایسه با همه روش‌های موجود دارد.

در مجموع، رویکرد پیشنهادی در این مقاله توانسته است بهبود قابل توجهی را در مقایسه با مطالعات مذکور فراهم کند. به طوری که در طبقه‌بندی سه کلاسه میانگین صحت روش پیشنهادی حداقل ۱۰٪ بیشتر از روش‌های موجود است. همچنین، میانگین صحت روش پیشنهادی در طبقه‌بندی احساسات مثبت رویا در برابر احساسات منفی رویا به میزان حداقل ۸٪ و برای سناریو طبقه‌بندی رویا با احساسات در برابر خنثی به میزان حداقل ۹٪ نسبت به روش‌های موجود بهبود یافته است.

همانطور که در شکل ۱۰ مشاهده می‌شود، طبقه‌بند KNN موفق شد بیش از ۹۰٪ داده‌های هر کلاس را به درستی پیش‌بینی کند. با این حال، بیشترین تعداد طبقه‌بندی نادرست بین نمونه‌های دو کلاس احساسات مثبت رویا در برابر احساسات منفی رویا است (شامل ۹/۳۰٪ از نمونه‌های دو کلاس مذکور).

ماتریس درهم‌ریختگی ارائه‌شده در شکل ۱۱ نشان‌دهنده عملکرد مدل KNN در سناریوی طبقه‌بندی دوکلاسه برای تشخیص بین حالت احساسی و حالت خنثی است. این ماتریس نشان می‌دهد که مدل توانسته با دقت بسیار بالایی نمونه‌های مربوط به هر کلاس را به درستی شناسایی کند. به‌طور خاص، مدل در ۹۸/۸۳٪ مواقع نمونه‌های حالت احساسی را به درستی تشخیص داده و تنها ۱/۱۶٪ از آن‌ها را به اشتباه به عنوان حالت خنثی طبقه‌بندی کرده است. از سوی دیگر، در مورد حالت خنثی، دقت مدل ۹۵/۸۲٪ بوده و تنها ۴/۱۷٪ از این نمونه‌ها به اشتباه در دسته حالت احساسی قرار گرفته‌اند. این نتایج نشان می‌دهند که مدل در مجموع عملکرد بسیار مطلوبی دارد و میزان خطای آن در پیش‌بینی هر دو کلاس بسیار پایین است. دقت بالا در هر دو دسته نشان می‌دهد که مدل به خوبی قادر به تفکیک داده‌های احساسی از داده‌های خنثی بوده و میزان خطاهای نوع اول و دوم در حداقل مقدار ممکن قرار دارد.

در شکل ۱۲ ماتریس درهم‌ریختگی حاصل از عملکرد مدل KNN در سناریوی طبقه‌بندی دوکلاسه جهت تشخیص حالات احساسات منفی رویا در برابر احساسات مثبت رویا نشان داده شده است. همانطور که مشاهده می‌شود، مدل با دقت ۸۸/۴۱٪ نمونه‌های کلاس احساسات منفی رویا را درست شناسایی کرده و تنها ۱۱/۵۸٪ آن‌ها را به اشتباه در کلاس احساسات مثبت رویا قرار داده است. در مورد نمونه‌های دسته احساسات مثبت رویا، دقت مدل ۹۱/۶۷٪ است، اما از این نمونه‌ها به اشتباه در دسته حالت منفی طبقه‌بندی شده‌اند. همانند سناریوهای قبلی در این حالت نیز عملکرد مدل مطلوب است، اما میزان خطای آن در دسته‌بندی احساسات مثبت رویا کمی بیشتر از احساسات منفی رویا است. اما همچنان دقت کلی رویکرد پیشنهادی بالا بوده و تفکیک احساسات مثبت و منفی رویا را به خوبی انجام می‌دهد.

در این پژوهش، طبقه‌بندی حالات مختلف احساسات در مرحله خواب REM با استفاده از سیگنال‌های EEG با عملکرد مناسبی (میانگین صحت بیشتر از ۹۰ درصد در همه سناریوهای طبقه‌بندی) انجام شد. نتایج حاصل از معیارهای ارزیابی کمی و کیفی نشان می‌دهند که میزان خطای روش پیشنهادی کم بوده و می‌توان از سیگنال EEG به عنوان ابزاری مناسب در دسته‌بندی حالت‌های احساسی مختلف در رویا استفاده کرد. همچنین، دقت و حساسیت بالای مدل، نویدبخش استفاده از رویکردهای مبتنی بر سیگنال EEG در پایش و درمان حوزه سلامت روان است.

در جدول ۸، عملکرد روش پیشنهادی با روش‌های موجود در حوزه تحلیل سیگنال EEG برای طبقه‌بندی حالات مختلف احساسات در رویا مقایسه شده است. نتایج نشان می‌دهد که روش ارائه‌شده در این تحقیق، با استفاده از ویژگی آنترپی نمونه‌ای و طبقه‌بند KNN، توانسته است عملکرد قابل توجهی را در سناریوهای مختلف طبقه‌بندی احساسات رویا ارائه دهد.

در مقایسه با روش Liu و همکارانش [۱۱] که از ویژگی‌های CSP و آنترپی تفاضلی همراه با طبقه‌بندهای GBDT و LightGBM استفاده کرده‌اند، روش پیشنهادی در سناریوی طبقه‌بندی احساسات مثبت یا منفی رویا در برابر خنثی عملکرد بهتری داشته و به میانگین صحت ۹۷/۴۵٪ دست یافته است، در حالی که این مقدار در روش‌های دیگر گزارش نشده است. همچنین در سناریوی طبقه‌بندی احساسات مثبت رویا در برابر احساسات منفی رویا، میانگین صحت ۹۰/۳۹٪ به‌دست آمده که بالاتر از بهترین نتیجه موجود (۸۸/۱۲٪) است.

باشد. بنابراین، برای بررسی این موضوع نیاز به داده‌هایی با تعداد کانال‌های بیشتر (پایگاه داده مرجع محدود به تعداد فقط ۶ الکترواست) وجود دارد که می‌تواند در جمع‌آوری داده‌های جدید در آینده مورد توجه قرار گیرد تا به درک بهتر ارتباط بین مناطق مختلف مغز در طول حالات مختلف احساسات در رویا منجر شود.

روش پیشنهادی، علی‌رغم استفاده از تنها یک ویژگی آنتروپی نمونه‌ای، عملکرد بهتری نسبت به مطالعات پیشین در هر دو سناریوی طبقه‌بندی چندکلاسه و دودویی ارائه کرد. مشابه پژوهش‌های گذشته، یافته‌های این مطالعه نیز نشان می‌دهد که سیگنال‌های EEG قادرند احساسات مختلف را در طول خواب REM با دقت بالایی تفکیک کنند. این موضوع از نظر نظارت و درمان در حوزه سلامت روان حائز اهمیت است، زیرا امکان شناسایی احساسات در خواب را با حداقل میزان خطا فراهم می‌کند. میانگین صحت و دقت بالا نشان می‌دهند که مدل پیشنهادی توانایی شناسایی حالات مختلف احساسی در رویا را با اطمینان بالا دارد، که این امر برای کاربردهای عملی در حوزه علوم اعصاب و سلامت روان از اهمیت ویژه‌ای برخوردار است.

دسترسی به داده‌ها و کد

مجموعه داده پیش پردازش شده و کدهای پایتون به منظور بازتولید نتایج ارائه شده در این مقاله از طریق درخواست منطقی به نویسنده مسئول قابل دسترس است.

مراجع

- [1] Packiyathan, M. (2023). Towards a Dream Decoder: A study Identifying Dream Emotions during REM sleep with Machine Learning and EEG Signals.
- [2] Moctezuma, L. A., Ipanaque, F., Molinas, M., & Abe, T. (2023, October). Dream emotions identified without awakenings by machine and deep learning from Electroencephalographic signals in REM sleep. In *2023 IEEE International Conference on Metrology for eXtended Reality, Artificial Intelligence and Neural Engineering (MetroXRINE)* (pp. 444-449). IEEE.
- [3] Fogli, A., Maria Aiello, L., & Quercia, D. (2020). Our dreams, our selves: automatic analysis of dream reports. *Royal Society open science*, 7(8), 192080.
- [4] Patel, A. K., Reddy, V., Shumway, K. R., & Araujo, J. F. (2024). Physiology, sleep stages. In *StatPearls [Internet]*. StatPearls Publishing.
- [5] عبدالمی، محمد، یوسفی رضایی، توحید و شیخی وند، سبحان. (۱۳۹۸). بازشناسی هیجانات القاشده توسط تحریک شنوایی از سیگنال EEG مبتنی بر طبقه‌بندی بر پایه‌ی نمایش تنک. مجله مهندسی برق دانشگاه تبریز، ۴۹(۱)، ۳۴۱-۳۴۱.
- [6] Afrasiabi, M., & Noroozian, N. (2015). Advantages and limitations of functional magnetic resonance imaging (fMRI) of the human visual brain. *Horizons in Neuroscience Research Series*, 17, 65-72.
- [7] شیخی‌وند، سبحان، قائمی، & سحرانه. (۲۰۱۹). شناسایی خودکار مراحل خواب از سیگنال EEG تک‌کاناله با استفاده از تبدیل موجک گسسته و مدل ترکیبی الگوریتم کلونی مورچگان و شبکه‌ی عصبی مبتنی بر طبقه‌بند RUSBoost. *نشریه علمی مهندسی پزشکی زیستی*، ۱۳(۳)، ۲۲۲-۲۲۲.
- [8] Torvestad, A., Packiyathan, M., Moctezuma, L. A., & Molinas, M. Unveiling Dreams: Moving Towards Automatic Dream Decoding via PSD-Based EEG Analysis and Machine Learning.
- [9] Moctezuma, L. A., Molinas, M., & Abe, T. (2025). Unlocking dreams and dreamless sleep: machine learning classification with optimal EEG channels. *BioMed Research International*, 2025(1), 3585125.
- [10] Packiyathan, M., & Torvestad, A. (2024). Towards a Dream Decoder: Classification and Analysis of Dream Experiences

جدول ۸- مقایسه عملکرد رویکرد پیشنهادی با مطالعات پیشین با استفاده از معیار صحت طبقه‌بندی. NR: به معنای گزارش نشده است.

منابع	سناریوهای طبقه‌بندی		
	احساسات مثبت رویا در برابر منفی	احساسات در برابر خنثی	سه کلاسه
Liu و همکاران [۱۱]	ویژگی	NR	CSP
	طبقه‌بند	NR	GBDT
	نتایج	NR	%۸۸/۱۲
Moctezuma و همکاران [۲]	ویژگی	DWT	DWT
	طبقه‌بند	EEGNet	EEGNet
	نتایج	%۶۴/۷۰	%۶۵/۹۰
Packiyathan [۱]	ویژگی	NR	DWT
	طبقه‌بند	NR	GB
	نتایج	NR	%۸۲/۰۵
روش ارائه شده در این مطالعه	ویژگی	آنتروپی نمونه‌ای	آنتروپی نمونه‌ای
	طبقه‌بند	KNN	KNN
	نتایج	%۹۷/۴۵	%۹۰/۳۹

۴- نتیجه‌گیری و ارائه پیشنهادها

در این مطالعه، یک روش نوین برای طبقه‌بندی احساسات در طول خواب REM با استفاده از سیگنال‌های EEG از مجموعه داده DEED ارائه شد. در رویکرد پیشنهادی، ویژگی آنتروپی نمونه‌ای برای هر یک از پنج IMF حاصل از تجزیه کانال‌های سیگنال EEG با استفاده از روش EMD محاسبه شد. سپس، بهترین مجموعه ویژگی‌ها با استفاده از الگوریتم ReliefF انتخاب و به ورودی مدل‌های یادگیری ماشین KNN، SVM و RF برای طبقه‌بندی حالات مختلف احساسات رویا اعمال شد.

نتایج نشان داد که روش پیشنهادی با ارائه میانگین صحت طبقه‌بندی ۹۳/۰۸٪ در سناریوی سه‌کلاسه، میانگین صحت برابر با ۹۰/۳۹٪ در سناریوهای طبقه‌بندی احساسات مثبت رویا در برابر احساسات منفی رویا و همچنین میانگین صحت برابر با ۹۷/۴۵٪ در تفکیک رویاهای احساسی از رویاهای خنثی دارای عملکرد مطلوبی در شناسایی حالات مختلف احساسی در رویا است. فرآیند انتخاب ویژگی با شناسایی ویژگی‌های مرتبط با حالات احساسی مختلف، ضمن کاهش ابعاد ویژگی‌ها، عملکرد طبقه‌بندی را بهبود بخشید.

یافته‌های این مطالعه آینده‌ای بسیار امیدوارکننده برای استفاده از سیگنال EEG به عنوان ابزاری کمک تشخیصی برای طیف گسترده‌ای از تحلیل احساسات رویا را پیش‌بینی می‌کنند. با این حال، این مطالعه محدودیت‌هایی نیز دارد. در این مطالعه، مفید بودن توان فرکانسی باندهای سیگنال EEG مورد بررسی قرار نگرفته است. در مطالعات آینده، برای تحلیل دقیق‌تر، ویژگی‌های توان هر یک از باندهای فرکانسی سیگنال‌های EEG که می‌توانند بینش‌های جدیدی فراهم کنند بررسی خواهد شد.

همان‌طور که در بخش نتایج ذکر شد، بر اساس خروجی فرآیند انتخاب ویژگی در هر سه سناریوی طبقه‌بندی، رابطه مشخصی بین نواحی مختلف مغز و حالات احساسی در رویا در این مطالعه مشاهده نشد. این نتیجه ممکن است در اثر کمبود تعداد کانال‌های سیگنال EEG استفاده شده در حین ثبت داده

- during Sleep using Electroencephalography (Master's thesis, NTNU).
- [11] Liu, W., Zhang, Y., Ma, P., Zheng, L., Zhou, D., Chen, Z., ... & Wang, X. (2022). DEED: A Dataset for Dream-related Emotion Research. *bioRxiv*, 2022-09.
- [12] Packiyathan, M., Torvestad, A., Moctezuma, L. A., & Molinas, M. Exploring High-and Low-Density Electroencephalography for a Dream Decoding Brain-Computer Interface.
- [۱۳] زاهدی حقیقی، سیده سعیده، سخایی، سید محمود و دلیری، محمدرضا. (۱۳۹۸). تشخیص حالت‌های احساسی مبتنی بر EEG با استفاده از شبکه‌ی یادگیری عمیق. نشریه‌ی علمی مهندسی پزشکی زیستی، ۱۳(۲)، ۹۵-۱۰۴. doi: 10.22041/ijbme.2019.97535.1419
- [14] Akhand, M. A. H., Maria, M. A., Kamal, M. A. S., & Murase, K. (2023). Improved EEG-based emotion recognition through information enhancement in connectivity feature map. *Scientific Reports*, 13(1), 13804.
- [15] Zhuang, N., Zeng, Y., Tong, L., Zhang, C., Zhang, H., & Yan, B. (2017). Emotion recognition from EEG signals using multidimensional information in EMD domain. *BioMed research international*, 2017(1), 8317357.
- [16] Kumar, Y., Dewal, M. L., & Anand, R. S. (2012, March). Features extraction of EEG signals using approximate and sample entropy. In *2012 IEEE Students' Conference on Electrical, Electronics and Computer Science* (pp. 1-5). IEEE.
- [17] Zarei, A., & Asl, B. M. (2018). Automatic detection of obstructive sleep apnea using wavelet transform and entropy-based features from single-lead ECG signal. *IEEE journal of biomedical and health informatics*, 23(3), 1011-1021.
- [18] Tonoyan, Y., Looney, D., Mandic, D. P., & Van Hulle, M. M. (2016). Discriminating multiple emotional states from EEG using a data-adaptive, multiscale information-theoretic approach. *International journal of neural systems*, 26(02), 1650005.
- [19] Jenke, R., Peer, A., & Buss, M. (2014). Feature extraction and selection for emotion recognition from EEG. *IEEE Transactions on Affective computing*, 5(3), 327-339.