

استفاده از رویکرد چند وظیفه‌ای به منظور انتخاب کانال و ویژگی مستقل از فرد برای طبقه‌بندی احساسات از روی سیگنال EEG

الهام کلهر^۱، بهزاد بختیاری^۲

^۱ کارشناسی ارشد مهندسی کامپیوتر، مهندسی کامپیوتر و فناوری اطلاعات، دانشگاه صنعتی سجاد، e.kalhor333@sadjad.ac.ir

^۲ استادیار، دانشکده‌ی مهندسی کامپیوتر و فناوری اطلاعات، دانشگاه صنعتی سجاد، bakhtiari@sadjad.ac.ir

پذیرش: ۱۳۹۹/۰۴/۰۷

ویرایش: ۱۳۹۸/۱۲/۱۹

دریافت: ۱۳۹۸/۰۴/۳۱

چکیده: تحقیقات نشان می‌دهد که احساس، یک فرآیند ذهنی و متوجه مغز انسان است و روی فرآیندهای مهمی چون حافظه، تمرکز، تفکر و تصمیم‌گیری اثر دارد. به همین دلیل مطالعه مکانیزم و عملکرد آن مورد توجه محققان علوم شناختی قرار گرفته است. مطالعه احساس از طریق پردازش سیگنال‌های بیولوژیکی، علاوه بر کاربردهای کلینیکی که در زمینه تشخیص و درمان به موقع ناهنجاری‌های روانی می‌تواند داشته باشد، در علوم مبتنی بر تعاملات انسان و رایانه نیز نقش مهمی بازی می‌کند و باعث پیشرفت‌های زیادی در این زمینه می‌گردد. اما با توجه به این که معمولاً تعداد کانال‌ها و ویژگی‌های استخراج شده از سیگنال مغز زیاد می‌باشد، انتخاب کانال‌های مرتبط، با هدف ویژگی‌های موثر، نقش بسزایی در کارایی این روش‌ها دارد. از طرفی این ویژگی‌ها بایستی به نحوی باشند که در مواجهه با افراد جدید نیز کارایی مناسبی داشته باشند. به همین منظور در این مقاله برای انتخاب کانال‌های مرتبط با احساسات و انتخاب ویژگی‌های مناسب مستقل از افراد، رویکرد چند وظیفه‌ای ارائه شده است. همچنین برای نشان دادن کارایی روش پیشنهادی از دادگان DREAMER و DEAP استفاده شد و با در نظر گرفتن دو بُعد احساسی برانگیختگی و ظرفیت آزمایشاتی برای نشان دادن کارایی مطلوب روش پیشنهادی در انتخاب کانال و ویژگی مستقل از فرد انجام شد. نتایج این آزمایشات نشان می‌دهد که روش پیشنهادی نسبت به روش‌های مطرح در این حوزه کارایی بهتری دارد.

کلمات کلیدی: تشخیص احساس، انتخاب ویژگی چند وظیفه‌ای، برانگیختگی، ظرفیت، پردازش سیگنال مغزی.

Subject-Independent Channel and Feature Selection for Emotion Classification Based on EEG Signal: A Multi-Task Approach

Elham Kalhor, Behzad Bakhtiari

Abstract: Several researches have shown that emotion is a mental process and relates to the human's brain. The emotion has impacts on important procedures, such as memory, concentration, thinking and decision-making. As a result, investigating the mechanism and performance of the emotion have attracted the cognitive science researchers' attentions. In addition to clinical applications on quick detection, diagnosis and treatment of psychological disorders, investigating the emotion through biological signal processing can play an important role in human-computer communication-based sciences. This will result in progressive improvements in this field. Due to the fact that number of channels and features extracted out of the EEG signal are usually high, selecting relevant channels, with the aim of obtaining effective features, can have a prominent role in the efficiency of these methods. On the other hand, these features should result in the appropriate efficiency when encounter new subjects. In this paper, a multi-task approach is represented for emotion-related channel selection and proper subject-independent feature selection purposes. Moreover, to demonstrate the efficiency of the proposed method, DREAMER and DEAP datasets are used. Also, considering two emotional dimensions, including arousal and valance, some experiments are performed to show the desired efficiency of the proposed method for channel selection and

subject-independent feature selection. Experimental results show that the proposed method has better efficiency in comparison with used methods.

Keywords: Emotion Recognition, Multi-Task Feature Selection, Arousal, Valence, EEG Signal Processing.

۱- مقدمه

مغز انسان یک کامپیوتر با فرآیندهای الکتروشیمیایی است که اطلاعات حسی را به اطلاعات الکتریکی (ولتاژ) تبدیل می‌کند. احساسات مجموعه‌ای از دستورالعمل‌های پیچیده هستند که منعکس کننده تغییرات در بدن انسان می‌باشند. انواع مختلفی از احساسات مانند خشم، افسردگی، ناامیدی، امید، نفرت، ترس، ناراحتی، تعجب، شادی و غیره شناسایی شده است که برای مدل‌سازی سیستم‌های تشخیص احساسات استفاده می‌شوند. تاکنون مطالعات زیادی به منظور شناخت احساسات بر اساس سیگنال‌های مختلف انجام شده است. بسیاری از تحقیقات برای تشخیص احساسات با استفاده از نمود خارجی احساس مانند وضعیت صورت [۱] و گفتار [۲] صورت گرفته است. با این حال، حالت‌های احساسی در بسیاری از مواقع به صورت ظاهری بروز نکرده و درونی باقی می‌مانند و قابل تشخیص و نمود خارجی نیستند. مانند مواردی که در آن فرد صحبتی نمی‌کند اما در واقع عصبانی است و یا در حالت‌های هیجانی منفی لبخند می‌زند. در واقع نمود ظاهری احساسات می‌تواند به صورت ذهنی کنترل شود و در نتیجه نشانه‌های ظاهری برای شناخت احساسات ناکافی است [۳]. هر احساسی با یک الگوی خاص از فعالیت فیزیولوژیکی همراه است. بر خلاف بیان صوتی و تصویری از احساسات، استفاده از فعالیت‌های فیزیولوژیکی جهت تشخیص احساس هدفمندتر و ساده‌تر است. در سال‌های اخیر، تحقیق در مورد شناخت عاطفی به کمک^۱ EEG، در زمینه‌های روانشناسی توجه زیادی را به خود جلب کرده است. مطالعات زیادی در زمینه ساخت مدل‌های محاسباتی برای تخمین وضعیت عاطفی از سیگنال EEG ارائه شده‌اند، که نشان دهنده کارایی این سیگنال‌ها برای شناسایی احساسات است.

دستگاه‌های ضبط EEG، بسته به برنامه، از ۳ تا ۲۵۶ الکتروود روی پوست سر استفاده می‌کنند تا ولتاژ را ضبط کنند [۳]. برای بروز احساسات مختلف، می‌توان از موسیقی، متن، ویدئو و تصاویر جهت تحریک فرد استفاده کرد و سپس سیگنال‌ها را هنگام بروز احساسات مختلف ثبت نمود [۳]. در مورد سیگنال EEG، همچنین انتخاب تعداد و نوع کانال‌ها می‌تواند به عنوان یک پارامتر در نظر گرفته شود. علاوه بر این می‌توان ویژگی‌های زیادی از سیگنال‌های EEG استخراج نمود.

تشخیص احساسات از روی سیگنال مغز کاربردهای فراوانی دارد. امروزه در بازاریابی و فروش از طریق اینترنت با بررسی سیگنال‌های مغزی

افراد در حین بازدید از صفحات وب، احساسات واقعی آن‌ها ارزیابی می‌شود [۴]. همچنین سنجش حالت روحی افراد هنگام تعامل با تکنولوژی کمک می‌کند تا میزان رضایت افراد مشخص شود [۵]. علاوه بر این بررسی حالت استرس افراد هنگام تحلیل‌های ذهنی برای سنجش درست یا غلط بودن تصمیم‌گیری‌ها [۶] و بازی‌های رایانه‌ای از مهمترین کاربردهای این حوزه است [۷].

با وجود پیشرفت‌های گسترده در حوزه‌ی پردازش و طبقه‌بندی احساسات از روی سیگنال مغز، اما همچنان چالش‌های زیادی پیش روی محققان این حوزه است. با توجه به اینکه تعداد ویژگی‌های زیاد باعث افزایش بُعد می‌شود و این مسئله باعث بیش‌برازش داده‌ها و کاهش کارایی طبقه‌بندی می‌شود، لذا مهمترین مسئله پیدا کردن زیرفضایی از ویژگی‌های مرتبط با احساسات افراد است که توصیف‌کننده‌ی احساسات مشترک بین آن‌ها باشد. پس با وجود تعداد ویژگی‌های زیاد، انتخاب ویژگی‌های مناسب از کانال‌های مرتبط با احساسات فرد، امری مهم و ضروری است. در این مقاله با استفاده از رویکرد چند وظیفه‌ای سعی شده است که ویژگی‌هایی انتخاب شوند که بین افراد مختلف مشترک باشند و بیان‌کننده‌ی برانگیختگی^۲ و ظرفیت^۳ احساسی آن‌ها باشند. همچنین با توجه به این که کانال‌های جلو سری بیشترین ارتباط را با احساسات افراد دارند [۱۱]، لذا در روش پیشنهادی علاوه بر انتخاب ویژگی، کانال‌هایی انتخاب می‌شوند که هم مرتبط با جلوی سر و هم مرتبط با ابعاد احساسی باشند. کارهای مختلفی در زمینه‌ی پردازش احساسات از روی سیگنال‌های مغزی صورت گرفته است.

بخش‌های مختلف مقاله‌ی حاضر عبارت‌اند از: بخش دوم کارهای انجام شده در حوزه تشخیص احساس از روی سیگنال مغز، بخش سوم معرفی مدل تشخیص احساس، بخش چهارم ارائه روش پیشنهادی، بخش پنجم آزمایشات صورت گرفته و بخش ششم نتیجه‌گیری ارائه خواهد شد.

۲- کارهای مرتبط

در زمینه‌ی انتخاب ویژگی‌های مناسب و در نظر گرفتن کانال‌های مرتبط کارهای بسیاری در سال‌های اخیر صورت گرفته است که در ادامه بیان خواهد شد. در [۸] از روش‌های تکاملی برای انتخاب ویژگی و انتخاب کانال استفاده شده است. این مقاله ۳۲ کانال و ۷۰۴ ویژگی در نظر گرفته است و از دو بُعد احساسی برانگیختگی و ظرفیت استفاده کرده است. بنابراین دو طبقه‌بند دو کلاس آموزش داده شده است. در واقع این مقاله سعی می‌کند با استفاده از روش‌های مبتنی بر تکاملی ویژگی‌های مناسب

³ valence

¹ Electroencephalography

² Arousal

اما در سال‌های اخیر استفاده از رویکرد چند وظیفه‌ای در حوزه‌های مختلف از جمله گفتار و تصویر بسیار مورد استفاده قرار گرفته و کاربرد است و مقالات متعددی در این دو حوزه وجود دارد که به کمک روش‌های چند وظیفه‌ای انتخاب ویژگی می‌کنند. روش‌های ارائه شده در این مقالات کارایی قابل قبولی دارند و به خوبی سبب انتخاب ویژگی‌های موثر و مناسب بین افراد می‌شوند. در حوزه گفتار علاوه بر افراد، دادگان نیز به عنوان وظیفه‌ها در نظر گرفته شده است. در حوزه تصویر نیز تصاویر مربوط به یک شی یا یک فرد به عنوان وظیفه در نظر گرفته می‌شود. در هر دو حوزه گفتار و تصویر مقالات مختلفی برای تشخیص احساس با رویکرد چند وظیفه‌ای ارائه شده است [۲۴-۲۸].

در سال‌های اخیر، استفاده از رویکرد چند وظیفه‌ای برای تشخیص احساس از روی سیگنال مغز مورد توجه قرار گرفت و مقالات مختلفی سعی کردند با استفاده از این رویکرد کانال‌های مرتبط با احساسات را شناسایی کنند و با انتخاب این کانال‌ها میزان کارایی را افزایش دهند. در واقع این مقالات با انتخاب کانال‌های مشترک بین افراد تعداد ویژگی‌ها را نیز کم می‌کنند. علاوه بر این، برخی مقالات با استفاده از چند مجموعه داده، هر مجموعه را به عنوان یک وظیفه در نظر گرفتند و با انتخاب ویژگی‌های مناسب بین وظیفه‌ها میزان کارایی را افزایش دادند [۲۹-۳۳].

بنابراین، با توجه به اینکه تاکنون از روش چند وظیفه‌ای در زمینه پردازش احساس از روی سیگنال مغز کار چندانی صورت نگرفته است و همچنین استفاده از این رویکرد در حوزه‌های دیگر بسیار موفقیت آمیز بوده و کارایی‌های خوبی را نتیجه داده است، ما نیز بر آن شدیم که از این روش در حوزه سیگنال‌های مغز استفاده کنیم.

اما هدف مقاله حاضر رسیدن به ویژگی‌های مستقل از افراد است که توصیف کننده‌ی مناسب برای حالات احساسی آن‌ها از روی سیگنال مغز باشند. برای این منظور یک تابع هدف چند وظیفه‌ای^۵ در نظر گرفته شده است که ویژگی‌های مشترک بین تمام افراد در هر یک از ابعاد احساسی برانگیختگی و ظرفیت را استخراج می‌کند. همچنین روش پیشنهادی کمک می‌کند تا کانال‌هایی انتخاب شوند که بیشترین ارتباط را با احساسات افراد دارند. بنابراین روش پیشنهادی علاوه بر انتخاب ویژگی‌های مناسب، انتخاب کانال نیز انجام می‌دهد.

۳- مدل تشخیص احساس

در دیدگاه‌های متفاوتی در تعریف احساس وجود دارد. یک دیدگاه مهم و معروف تئوری شناخت است [۳۴]. این تئوری ادعا می‌کند که مغز مرکز احساسات است و درباره‌ی خوشایندی و غیر خوشایندی رویدادهای اطراف قضاوت می‌کند. احساسات اگرچه پدیده‌های گسسته به نظر نمی‌آیند، اما روانشناسان بیشتر احساسات را در فضای n بُعدی نشان می‌دهند. از ساختارهای متداولی که به منظور توصیف و شناخت در نظر

از کانال‌های مناسب را انتخاب کند. اما در [۹] از ESN^۱ که به نوعی ساختار شبکه عصبی بازگشتی دارد، استفاده شده است. استاندارد ESN از سه بخش تشکیل شده است [۱۰]: لایه‌ی ورودی، گره‌های ذخیره شده و لایه‌ی خروجی. این مقاله نیز از دو بُعد احساسی برانگیختگی و ظرفیت استفاده کرده است. در این مقاله آزمایشات به صورت مستقل و وابسته به فرد صورت گرفته است.

اما [۱۱] انتخاب کانال را بر اساس احساسات مثبت مرتبط با نیمکره‌ی چپ مغز و احساسات منفی مرتبط با نیمکره‌ی راست مغز انجام می‌دهد. لذا سعی می‌کند کانال‌هایی را انتخاب کند که با بُعدهای احساسی مرتبط هستند. همچنین کانال‌های مربوط به جلوی سر که بیشترین ارتباط را با احساسات دارند در نظر می‌گیرد. بنابراین دو طبقه‌بند دو کلاسه آموزش داده می‌شود. همچنین [۱۲] انتخاب کانال را بر اساس احساسات مثبت و منفی انجام می‌دهد و ویژگی و یولت به عنوان بهترین ویژگی در این مقاله معرفی شده است که بیشترین تاثیر را در انتخاب کانال دارد.

همچنین [۱۳، ۱۴] از روش $mRMR^2$ برای انتخاب ویژگی از سیگنال مغز استفاده می‌کند. این روش از همبستگی بین ویژگی‌ها استفاده کرده و ویژگی‌های زائد را حذف می‌کند. همچنین در [۱۵] ابتدا ماتریس ویژگی‌ها اسپارس می‌شود، ویژگی‌هایی که نامرتب هستند صفر یا نزدیک به صفر می‌شوند و در نهایت حذف می‌شوند. در پایان ویژگی‌های مرتبط انتخاب می‌شوند.

[۱۶، ۱۷] از همبستگی بین ویژگی‌ها و برجسب کلاس‌ها برای انتخاب ویژگی‌های مناسب استفاده می‌کنند. [۱۸] از روش فیشر برای انتخاب ویژگی از سیگنال مغز استفاده می‌کند. در [۱۹] از روش اطلاعات متقابل^۳ (MI) برای انتخاب ویژگی استفاده شده است. اما در [۲۰] ابتدا سعی شده است که منطقه‌ای از مغز که به احساسات مرتبط است و بیان کننده‌ی میزان اضطراب فرد می‌باشد شناسایی شود، سپس الکترودها در این ناحیه قرار گیرند و میزان استرس فرد تشخیص داده شود.

در [۲۱] چهار حالت احساسی (ترس، خوشحالی، ناراحت، استراحت) بر اساس دو بُعد برانگیختگی و ظرفیت در نظر گرفته شده و از آنالیز تحلیل یولت استفاده شده است. ویژگی‌های انتخاب شده بر اساس باندهای فرکانسی مختلف از ویژگی و یولت هستند. طبقه‌بند استفاده شده در این مقاله k -نزدیکترین همسایه است. [۲۲] یک روش برای استخراج ویژگی و شناخت احساسات بر اساس تجزیه حالت تجربی معرفی می‌کند. با استفاده از EMD، سیگنال EEG به طور خودکار به توابع (IMFs)^۴ تجزیه می‌شود. با استفاده از تجزیه حالت درونی کارایی طبقه‌بند بهبود یافته است. علاوه بر این با داشتن چند مجموعه داده می‌توان آزمایشات را به صورت Cross-Corpus انجام داد. به عنوان مثال، در [۲۳] یک مجموعه داده برای آموزش و مجموعه داده دیگری برای تست استفاده شده است.

^۴ Intrinsic Mode Functions

^۵ multi-task

^۱ Echo State Network

^۲ Min-Redundancy-Max- Relevance

^۳ Mutual Information

$$\min_W \frac{1}{2} \sum_{p=1}^T \left\| y_p - \frac{1}{2} x_p w_p \right\|_2^2 + \theta \|W\|_{2,1} \quad (1)$$

که $W \in \mathbb{R}^{d \times T}$ ماتریس وزن، $w_p \in \mathbb{R}^{d \times 1}$ ستون p ام ماتریس W و ماتریس وزن نفر p ام است و θ پارامتر تنظیم است که مقدار آن میزان خلوت‌سازی ماتریس ویژگی‌ها را مشخص می‌کند.

هدف جمله اول رابطه (۱) در نظر گرفتن ارتباط بین برجسب کلاس و ویژگی‌های مختلف می‌باشد. برای این منظور یک رگرسیون حداقل مربعات خطا در نظر گرفته شده است. به عبارت دیگر این رابطه سعی می‌کند به کمک ویژگی‌های مختلف، کلاس نمونه را تخمین بزند. لذا در این حالت هر چقدر مولفه‌ی w_p بزرگتر باشد به این معنی خواهد بود که برای نفر p ام، ویژگی i ام نقش بیشتری در تعیین کلاس نمونه‌ها دارد. اما از طرفی برای جمله دوم رابطه‌ی (۱) داریم:

$$\|W\|_{2,1} = \sum_{i=1}^d \left(\sum_{j=1}^T (w(i,j))^2 \right)^{1/2} = \sum_{i=1}^d \|w^i\|_2 \quad (2)$$

که w^i ردیف i ام ماتریس W می‌باشد. بنابراین $\|W\|_{2,1}$ معادل مجموع $\sum_{i=1}^d$ ردیف‌های ماتریس W می‌باشد [۳۵]. اما از آنجایی که ردیف i ام ماتریس W مربوط به ویژگی i ام و ستون‌های آن مربوط به افراد مختلف می‌باشد، کمینه‌سازی آن معادل حذف ویژگی‌های کمتر مرتبط برای همه افراد خواهد بود.

شکل (۲) نحوه‌ی کار $\sum_{i=1}^d$ را نشان می‌دهد. با توجه به شکل، ابتدا $\sum_{i=1}^d$ روی ردیف‌های ماتریس ویژگی‌ها اعمال می‌شود. مقادیر بدست آمده نشان دهنده‌ی میزان موثر بودن آن ویژگی برای تمام افراد است. سپس روی نتیجه بدست آمده از $\sum_{i=1}^d$ ها، $\sum_{i=1}^d$ اعمال می‌شود.


با توجه به فرمول $\sum_{i=1}^d$ - ۲ (رابطه ۲) در می‌یابیم که عمل خلوت‌سازی به کمک $\sum_{i=1}^d$ سبب می‌شود برخی از $\sum_{i=1}^d$ ها به صفر میل کنند. به صفر میل کردن معادل این است که $\sum_{i=1}^d$ کل ردیف به صفر میل کند و در نتیجه آن ویژگی انتخاب نمی‌شود. این درحالی است که آن ویژگی بین همه وظیفه‌ها (افراد) مشترک است. همچنین به صفر میل نکردن برخی از ویژگی‌ها معادل این است که آن ویژگی انتخاب شده و بین وظیفه‌ها مشترک می‌باشد.

با توجه به رابطه‌ی (۱) در نهایت ردیف‌های W به نحوی محاسبه خواهد شد که برای ویژگی‌های مرتبط و مشترک بین وظیفه‌ها مقدار غیر

گرفته می‌شود، نمایش احساسات در یک فضای سه بُعدی شامل برانگیختگی، ظرفیت و میزان تسلط^۱ است.

در این صورت، برانگیختگی درجه‌ی هیجاناتی است که توسط فرد کنترل می‌شود و شامل دو دسته برانگیختگی بالا و پایین است. ظرفیت درجه منفی یا مثبت بودن حالت احساس فرد یا به عبارتی میزان خوشایند و یا ناخوشایند بودن یک موضوع برای فرد را مشخص می‌کند.

میزان تسلط بیانگر قدرت یا ضعف در بروز احساسات است. معروف‌ترین ساختاری که در این زمینه معرفی شده است یک مدل دو بُعدی از احساسات است که برانگیختگی و ظرفیت را در نظر می‌گیرد. شکل (۱) برگرفته از مقاله‌ی [۸] مثالی از مدل احساسی دو بُعدی را نشان می‌دهد. با توجه به شکل (۱) وقتی ظرفیت از عدد ۱ به ۵ تغییر می‌کند، وضعیت احساسی از منفی به مثبت عوض می‌شود، به این معنا که فرد از حالت ناراحتی و خستگی به حالت نسبتاً خوشحالی می‌رسد. همچنین با تغییر برانگیختگی از عدد ۱ به ۵ هیجان‌ها فرد افزایش می‌یابد.




شکل ۱: مدل تشخیص احساسات [۸]


۴- انتخاب ویژگی مبتنی بر یادگیری چند وظیفه‌ای

فرض کنید $x_p \in \mathbb{R}^{n_p \times d}$ ماتریس ویژگی‌های مربوط به کل نمونه‌های نفر p ام می‌باشد که n_p تعداد نمونه‌های نفر p ام، d تعداد ویژگی‌های استخراج شده از هر سیگنال نمونه و $p \in \{1, 2, \dots, T\}$ که T تعداد افراد است. همچنین $y_p \in \mathbb{R}^{n_p \times 1}$ برجسب نمونه‌های نفر p ام است که $y_p(i) \in \{+1, -1\}$ و $y_p(i)$ مولفه‌ی i ام بردار y_p است. با توجه به این که هدف این مقاله بدست آوردن زیر مجموعه‌ای از ویژگی‌هاست که با ابعاد احساسات افراد مرتبط هستند، تابع هدف چند وظیفه‌ای (۱) پیشنهاد می‌شود [۳۵]:

¹ dominance



شکل ۲: نحوه‌ی کار ترم ۱-۲



شکل ۳: مراحل روش پیشنهاد

در این بخش ابتدا دادگان مورد استفاده شرح داده می‌شود. سپس ویژگی‌های استخراج شده معرفی می‌شوند. روش‌های مقایسه و جزئیات پیاده‌سازی بیان می‌شود و در پایان نتایج گزارش می‌شود.

۵-۱ شرح دادگان


برای انجام آزمایشات از دو مجموعه داده استفاده شده است. دادگان DREAMER شامل داده‌های ۲۳ نفر است (۹ زن، ۱۴ مرد). همچنین شامل ۱۴ کانال (F3 - FC5 - T7- P7 - O1 - - F7 - AF3) - AF4 - F8 - F4 - FC6 - T8 - P8 - O2) می‌باشد. برای ضبط دادگان مربوط به هر فرد، ۱۸ ویدیو احساسی پخش شده است. زمان نمونه برداری سیگنال بین ۶۵ تا ۳۹۳ ثانیه است. عکس العمل هر فرد نسبت به هر ویدیو ذخیره شده است. بعد از تماشای ویدیوها از افراد خواسته شده است که به هر ویدیو از عدد ۱ تا ۵ امتیاز دهند. این دادگان دارای هر سه بُعد احساسی برانگیختگی، ظرفیت و میزان تسلط است که در این مقاله از دو بُعد برانگیختگی و ظرفیت استفاده شده است. همچنین اطلاعات گرفته شده از هر فرد شامل سیگنال‌های مغز و قلب است که در این مقاله فقط از دادگان مربوط به سیگنال مغز استفاده شده است. در این مجموعه داده فرکانس نمونه‌برداری ۱۲۸ هرتز است [۳۷].

صفر داشته و این ویژگی‌ها انتخاب می‌شوند و برای ویژگی‌های نامناسب مقدار صفر خواهد داشت و این ویژگی‌ها انتخاب نمی‌شوند. مراحل روش پیشنهادی در شکل (۳) نشان داده شده است. با توجه به شکل (۳-الف) ابتدا داده‌های آموزشی به تابع هدف (۱) داده می‌شود. سپس بعد از بدست آوردن ویژگی‌های مشترک بین تمام افراد، یادگیری طبقه‌بند دو کلاسه انجام می‌شود. لازم به ذکر است که بعد از انتخاب ویژگی می‌توان از هر طبقه‌بندی استفاده نمود. در مرحله‌ی تست طبق شکل (۳-ب) ابتدا ویژگی‌هایی که در بخش آموزش طبقه‌بند انتخاب شدند، از داده تست استخراج می‌شوند. سپس ویژگی‌های بدست آمده به مدل طبقه‌بند آموزش دیده دو کلاسه داده می‌شود، در پایان تخمینی از برجسب داده تست محاسبه می‌شود.

تابع هدف ارائه شده در رابطه (۱) از دو بخش هموار (جمله اول) و ناهموار (جمله دوم) تشکیل شده است. به دلیل وجود بخش ناهموار، این معادله حل بسته ندارد و نمی‌توان آن را حل کرد. بنابراین برای حل آن از الگوریتم [۳۶] استفاده شده است. همچنین برای پیاده‌سازی تابع هدف از کدهای آماده^۱ استفاده شده است.

۵- آزمایشات

¹ <http://research.microsoft.com/apps/pubs/?id=264770>



شکل ۴: کانال‌های در نظر گرفته شده در هر مجموعه داده

در این مقاله ۱۱ ویژگی حوزه‌ی زمان مانند: ماکزیمم، میانگین، واریانس، چولگی^۱، کشیدگی^۲، توان، فعالیت^۳، انرژی، آنروپی و نرخ عبور از صفر^۴ و همچنین از ویژگی‌های حوزه‌ی فرکانس ۱۲ ضریب ویولت در نظر گرفته شد [۴۶]. مقالات متعددی از ویژگی‌های ذکر شده در مقاله [۴۶] استفاده کرده‌اند [۴۷-۵۰]. استخراج ویژگی ویولت بر اساس دو تابع پایه ذکر شده در مقاله [۴۶] صورت گرفته است. بنابراین ۱۱ ویژگی حوزه‌ی زمان از هر کانال استخراج می‌شود که چون دادگان DREAMER دارای ۱۴ کانال می‌باشند، خواهیم داشت $11 \times 14 = 154$. همچنین برای ویژگی ویولت ابتدا روی هر کانال فریم‌بندی صورت گرفت (با توجه به مقالات این حوزه، تعداد ۱۰ فریم با طول ۳۰ ثانیه و میزان هم‌پوشانی ۳۰ درصد در نظر گرفته شد). سپس از هر فریم ۱۲ ضریب ویولت استخراج شد ($12 = 1680 = 10 \times 14 \times 10$). علاوه بر آن برای ویژگی ویولت مشتقات اول و دوم نیز در نظر گرفته شد. در نتیجه در مجموع، ۳۷۸۰ ویژگی برای ویولت بدست می‌آید. سپس در نهایت، برای هر سیگنال در دادگان DREAMER، ۱۵۴ ویژگی حوزه‌ی زمان و ۳۷۸۰ ویژگی حوزه‌ی فرکانس پشت سر هم در یک بردار قرار گرفتند که مجموع کل ویژگی‌های بدست آمده از هر سیگنال ۳۹۳۴ خواهد بود.

اما چون مجموعه داده DEAP شامل ۳۲ کانال می‌باشد، بنابراین خواهیم داشت: $11 \times 32 = 352$ ویژگی در حوزه‌ی زمان و با در نظر گرفتن ۱۲ ضریب ویولت ($12 = 3840 = 10 \times 32 \times 10$) و ویژگی ویولت و با مشتقات اول و دوم آن ۸۶۴۰ ویژگی خواهد بود. در مجموع ۸۹۹۲ ویژگی از هر سیگنال در دادگان DEAP بدست آمد.

۵-۲ معرفی روش‌های مقایسه و جزئیات پیاده‌سازی

کار انجام شده در این مقاله با تعدادی از روش‌های پایه انتخاب ویژگی مقایسه شد. این روش‌ها در جدول (۱) معرفی شده‌اند.

P4 دادگان DEAP: شامل ۳۲ نفر و همچنین شامل ۳۲ کانال (-FP1- FP2- F3- F4- F7- F8- FC5- FC6- FC1- FC2 AF3- AF4- C3- P3 - CP6 - CP5 - CP2 - CP1- C4 - T7- T8- FZ- CZ - P7- P8 - PO3 - PO4 - O2 - O1 - PO4 - PO3 - P8 - P7- مغز است.

در این مجموعه داده نیز ۴۰ ویدیو با مضمون‌های مختلف احساسی پخش شده است. بعد از پخش ویدیوها عکس العمل عاطفی افراد هنگام تماشای ویدیوها ذخیره شده است. زمان نمونه برداری سیگنال تقریباً ۵ دقیقه است.

سیس از آن‌ها خواسته شده است که از ۱ تا ۹ به هر ویدیو امتیاز دهند. این دادگان نیز دارای هر سه بُعد احساسی برانگیختگی، ظرفیت و میزان تسلط است که در این مقاله از دو بُعد برانگیختگی و ظرفیت استفاده شده است. فرکانس نمونه‌برداری ۵۱۲ هرتز است [۳۸]. هر دو مجموعه داده DREAMER و DEAP بسیار معروف هستند و مقالات زیادی در حوزه پردازش سیگنال مغز از آن‌ها استفاده کرده‌اند [۳۹-۴۵]. کانال‌های ذکر شده برای هر دو مجموعه داده در شکل (۴) نشان داده شده است.

استخراج ویژگی

فرض کنید سیگنال یک نمونه‌ی S دارای k کانال باشد که طول داده‌های هر یک برابر n می‌باشد. استخراج ویژگی از هر کانال صورت می‌گیرد و سپس همه‌ی ویژگی‌ها در یک بردار ذخیره می‌شوند. لازم به ذکر است که برخی از ویژگی‌ها نیاز به فریم‌بندی ندارند و مستقیم از هر کانال استخراج می‌شوند اما برخی دیگر از ویژگی‌ها نیاز به فریم‌بندی دارند. لذا برای این منظور ابتدا نمونه‌های هر کانال به M فریم تقسیم می‌شوند و سپس استخراج ویژگی از هر فریم صورت می‌گیرد.

³ activity⁴ zero crossing¹ Skewness² kurtosis

استفاده از اعتبار سنجی به روش یک نفر بیرون (LOSO³)، همیشه داده‌های یک نفر برای تست کنار گذاشته می‌شود و با داده‌های افراد باقی مانده عملیات آموزش انجام می‌شود. در این مقاله در مرحله‌ی آموزش با استفاده از داده‌های آموزش و استفاده از استراتژی LOSO، پارامترهای مختلفی برای انتخاب ویژگی و یادگیری طبقه‌بند بررسی شد. در نهایت بهترین پارامترها انتخاب شدند.

در مرحله تست از پارامترهای بدست آمده در مرحله آموزش استفاده شد. انتخاب ویژگی برای فردی که به عنوان تست بود انجام شد به این صورت که، یادگیری طبقه‌بند با کل داده‌های آموزشی صورت گرفت. سپس با استفاده از داده‌های نفری که برای تست کنار گذاشته شده بود، تست انجام شد. کل عملیات آموزش و تست به تعداد افراد تکرار شد، در نهایت بین کارایی‌های بدست آمده از تمام افراد میانگین گرفته شد.

۵-۳ نتایج آزمایشات

آزمایشات به سه صورت انجام شد. در آزمایش اول کانال‌های جلوی سر در نظر گرفته شد و انتخاب ویژگی با روش پیشنهادی و سایر روش‌ها صورت گرفت. در آزمایش دوم با در نظر گرفتن تمام کانال‌ها انتخاب ویژگی انجام شد. سپس مشخص شد ویژگی‌های انتخاب شده از کدام کانال‌ها هستند. در آزمایش سوم کانال‌های انتخاب شده توسط روش پیشنهادی برای تمام روش‌ها در نظر گرفته شد. در ادامه نتایج بدست آمده از هر یک از آزمایشات تحلیل خواهد شد.

۵-۴-۱ در نظر گرفتن کانال‌های جلو سر

در شروع آزمایشات با توجه به اینکه کانال‌های جلو سر بیشترین ارتباط را با احساسات افراد دارند و هنگام بروز احساسات بیشتر تحت تاثیر قرار می‌گیرند [۱۱]، ابتدا از این کانال‌ها استفاده شد و عملیات انتخاب ویژگی برای روش پیشنهادی و سایر روش‌ها با استفاده از این کانال‌ها صورت گرفت. کانال‌های جلو سر مربوط به هر دو نیمکره‌ی چپ و راست و مرتبط با احساسات مثبت و منفی و دو بُعد احساسی هستند. برای این منظور آزمایشات با تعدادی مختلفی کانال صورت گرفت. تعداد کانال‌های در نظر گرفته شده در دادگان DEAP ۱۰، ۱۴ و ۱۸ و در دادگان DREAMER ۴، ۸ و ۱۲ می‌باشد. کانال‌های در نظر گرفته شده در جدول (۲) آورده شده است.

آزمایشات با کانال‌های ذکر شده در جدول (۲) برای هر دو مجموعه داده و هر سه طبقه‌بند انجام شد. نتایج بدست آمده برای دادگان DREAMER در جداول (۳) و (۴) گزارش شده است. با توجه به جدول (۳) با در نظر گرفتن ۴ کانال جلوسری در بُعد ظرفیت، طبقه‌بند

جدول ۱: معرفی روش‌های مقایسه

روش‌ها	انواع
پایه و عام	PCA, FFS
مبتنی بر همبستگی	اسپیرمن، پیرسون [۱۷،۱۶]، اطلاعات متقابل (MI) [۱۹]، mRMR [۱۳،۱۴]
غیره	فیشر [۱۸]، Relief [۵۱، ۵۰]

از سه طبقه‌بند SVM^۱، ELM^۱ و درخت تصمیم استفاده شد. با توجه به اینکه دو بُعد برانگیختگی و ظرفیت در نظر گرفته شد، برای هر بُعد احساسی طبقه‌بند‌های دو کلاس آموزش داده شد. در دادگان DREAMER برای هر بُعد امتیازات داده شده بین اعداد ۱ تا ۵ است که امتیازات بزرگتر و مساوی ۳، در کلاس +۱ و امتیازات کمتر از ۳، در کلاس -۱ قرار گرفتند. در دادگان DEAP برای هر بُعد امتیازات داده شده بین اعداد ۱ تا ۹ است که امتیازات بزرگتر و مساوی ۵، در کلاس +۱ و امتیازات کمتر از ۵، در کلاس -۱ قرار گرفتند.

ابتدا عملیات نرمال‌سازی روی داده‌های مربوط به هر نفر صورت گرفت [۵۲]. با توجه به منفی بودن مقدار برخی از ویژگی‌ها رنج داده‌های بدست آمده بین -۱ و +۱ می‌باشد. از طرفی به دلیل کوچک بودن مقادیر برخی از ویژگی‌ها، همه‌ی ویژگی‌های نرمال شده‌ی هر نفر در عدد ۱۰۰۰ ضرب شد. تمام پارامترهای مناسب مربوط به روش پیشنهادی و سایر روش‌ها و برای تمام طبقه‌بند‌ها به کمک اعتبار سنجی^۲ محاسبه شد. همچنین با توجه به این که تعداد ویژگی‌های مناسب برای روش پیشنهادی با استفاده از اعتبار سنجی بین ۱۰۰ تا ۲۰۰ ویژگی است، پس برای مقایسه عادلانه برای هر یک از روش‌های مقایسه هم ۲۰۰ ویژگی در نظر گرفته شد. اکثر ویژگی‌های انتخاب شده در روش پیشنهادی، ویولت‌ها، مشتقات اول ویولت و مشتقات دوم هستند و این ویژگی‌ها از ضرایب مختلف ۱ تا ۱۲ در کانال‌های مختلف انتخاب شده‌اند. جدول مربوط به ویژگی‌های مشترک در هر دو مجموعه داده در بخش ضمیمه قابل مشاهده است.

برای پارامتر C در طبقه‌بند SVM، مقدار در بازه‌ی {0.001, ..., 0.009, 0.01, 0.03, ..., 0.09, 0.1, ..., 1, 1.5, 2}، در نظر گرفته شد. همچنین برای تابع فعال‌ساز طبقه‌بند ELM، تابع سیگموئید در نظر گرفته شد و برای تعداد نرون‌های لایه پنهان آن ۱۰ مقدار به صورت {10, 20, ..., 100} مورد استفاده قرار گرفت. برای طبقه‌بند درخت تصمیم نیز تعداد گره‌های پدر ۱۹ مقدار در بازه‌ی {2, 3, 4, 5, 6, 7, 8, 9, 10, ..., 20} در نظر گرفته شد. ۸ مقدار برای پارامتر θ (رابطه (۱)) در بازه‌ی $10^4 \times \{10, 12, 14, 16, 18, 20, 30, 40\}$ در نظر گرفته شد. ابتدا داده‌ها به دو دسته تست و آموزش تقسیم شدند. با

³ Leave-One-Subject-Out

¹ extreme learning machine

² Cross-Validation

جدول ۲: کانال‌های در نظر گرفته شده برای هر دو مجموعه داده DEAP، DREAMER

کانال‌های در نظر گرفته شده	تعداد کانال‌ها	دادگان
FP1- FP2- F3- F4- F7- F8- FC5- FC6- FC1- FC2	۱۰	DEAP
FP1- FP2- F3- F4- F7- F8- FC5- FC6- FC1- FC2- AF3- AF4- C3- C4	۱۴	
FP1- FP2- F3- F4- F7- F8- FC5- FC6- FC1- FC2- AF3- AF4- C3- C4- T7- T8- FZ- CZ	۱۸	
F8- F7- AF4- AF3	۴	DREAMER
F8- F7- AF4- AF3- F3- F4- T7- T8	۸	
F8- F7- AF4- AF3- F3- F4- T7- T8- FC5- FC6- P8- P7	۱۲	

جدول ۳: نتایج کارایی با در نظر گرفتن کانال‌های جلوی سر برای بُعد ظرفیت روی دادگان DREAMER

درخت تصمیم			ELM			SVM			روش‌ها
۱۲ کانال	۸ کانال	۴ کانال	۱۲ کانال	۸ کانال	۴ کانال	۱۲ کانال	۸ کانال	۴ کانال	
۷۲.۰۳	۷۲.۰۰	۷۱.۱۵	۷۲.۵۴	۷۱.۱۴	۷۰.۹۸	۷۹.۱۹	۷۸.۶۷	۷۵.۳۲	روش پیشنهادی
۷۱.۳۳	۶۹.۲۳	۷۰.۶۴	۷۰.۲۸	۶۹.۸۷	۶۹.۰۶	۷۴.۱۹	۷۰.۵۸	۷۱.۱۹	اسپیرمن
۷۰.۹۷	۷۰.۵۲	۶۹.۱۳	۷۰.۲۳	۶۹.۱۲	۶۸.۴۲	۷۰.۹۲	۷۲.۷۶	۷۲.۷۶	پیرسون
۶۸.۴۵	۶۷.۶۹	۶۷.۶۰	۷۰.۱۱	۷۱.۷۸	۷۰.۰۰	۶۹.۵۴	۶۸.۷۸	۶۸.۳۵	فیشر
۶۹.۷۸	۶۹.۶۷	۷۰.۳۴	۶۹.۰۹	۶۹.۱۵	۷۰.۴۱	۶۹.۰۰	۶۹.۳۱	۶۸.۳۴	mRMR
۶۶.۱۴	۶۶.۹۳	۶۵.۱۱	۶۰.۵۴	۶۰.۳۲	۵۸.۱۲	۶۵.۲۳	۶۵.۸۷	۶۱.۶۷	Relief
۵۷.۱۹	۵۶.۱۲	۵۶.۸۷	۶۳.۷۶	۶۱.۰۴	۶۰.۲۰	۵۹.۰۰	۵۷.۶۵	۵۵.۰۰	FFS
۷۰.۲۱	۶۹.۸۴	۶۹.۷۵	۷۱.۸۹	۷۰.۳۲	۶۹.۶۵	۷۰.۰۰	۶۹.۷۶	۷۰.۵۴	MI
۶۲.۷۱	۶۲.۰۴	۶۱.۱۳	۶۶.۴۲	۶۵.۳۹	۶۳.۰۲	۶۹.۸۲	۶۸.۰۰	۶۵.۷۶	PCA

جدول ۴: نتایج کارایی با در نظر گرفتن کانال‌های جلوی سر برای بُعد برانگیختگی روی دادگان DREAMER

درخت تصمیم			ELM			SVM			روش‌ها
۱۲ کانال	۸ کانال	۴ کانال	۱۲ کانال	۸ کانال	۴ کانال	۱۲ کانال	۸ کانال	۴ کانال	
۶۹.۰۳	۶۸.۱۴	۶۹.۲۱	۷۲.۰۹	۷۲.۳۴	۷۱.۱۶	۷۲.۷۶	۷۱.۳۴	۶۹.۴۳	روش پیشنهادی
۶۶.۲۴	۶۵.۱۱	۶۵.۴۵	۷۰.۴۳	۷۰.۱۲	۶۹.۳۹	۶۹.۶۵	۶۹.۲۱	۶۷.۸۳	اسپیرمن
۶۷.۳۴	۶۷.۶۵	۶۶.۰۹	۷۰.۴۲	۶۹.۷۶	۶۸.۳۱	۶۹.۷۶	۷۰.۱۳	۶۷.۰۹	پیرسون
۶۳.۱۲	۶۲.۷۶	۶۱.۰۸	۶۶.۰۹	۶۵.۲۱	۶۳.۹۷	۶۵.۸۷	۶۵.۵۴	۶۴.۱۲	فیشر
۶۷.۵۴	۶۹.۲۳	۶۸.۰۲	۷۱.۶۲	۷۱.۲۷	۷۰.۰۲	۶۹.۰۰	۶۸.۱۲	۶۷.۷۱	mRMR
۵۹.۴۹	۵۹.۰۲	۵۸.۲۱	۶۴.۴۲	۶۴.۰۸	۶۳.۱۰	۶۵.۱۳	۶۶.۸۵	۶۵.۲۹	Relief
۵۳.۵۱	۵۲.۵۱	۵۱.۳۹	۵۸.۰۵	۵۷.۸۲	۵۶.۷۲	۵۶.۹۸	۵۵.۲۱	۵۴.۲۸	FFS
۶۶.۵۴	۶۵.۱۲	۶۴.۳۱	۶۹.۲۱	۶۸.۹۳	۶۹.۳۱	۷۰.۴۹	۷۰.۱۳	۶۹.۸۲	MI
۵۳.۴۸	۵۲.۵۶	۵۱.۲۸	۵۵.۸۲	۵۵.۲۹	۵۴.۱۱	۵۷.۰۳	۵۷.۷۲	۵۶.۰۳	PCA

افزایش یافته است. در طبقه‌بند ELM نیز به جز روش mRMR این اتفاق قابل مشاهده است. در طبقه‌بند درخت تصمیم برای روش پیشنهادی تنها یک درصد افزایش کارایی وجود دارد و برخی از روش‌ها با کاهش میزان کارایی مواجه شده‌اند. با افزایش تعداد کانال‌ها به ۱۲، در روش پیشنهادی میزان کارایی تقریباً دو درصد افزایش یافته است. اما در سایر روش‌ها معمولاً در کارایی یا بهبودی حاصل نشده و حتی کاهش وجود داشته مثل

SVM نسبت به سایر طبقه‌بندها در روش پیشنهادی دارای بالاترین میزان کارایی است. برخی از روش‌ها مثل فیشر و mRMR (با در نظر گرفتن ۴ کانال) در طبقه‌بند ELM کارایی بالاتری نسبت به SVM دارند. همچنین مشاهده می‌شود که با افزایش تعداد کانال‌ها و در نظر گرفتن ۸ کانال جلو سر، کارایی روش پیشنهادی و سایر روش‌ها در طبقه‌بند SVM

کانال‌ها تأثیری در میزان کارایی ندارند. این مسئله نشان می‌دهد که برای برخی از روش‌ها برخی از کانال‌های جلوسر مناسب نیستند و باعث کاهش میزان کارایی می‌شوند. همچنین روش انتخاب ویژگی FFS نسبت به سایر روش‌ها دارای کارایی پایین‌تری در تمام طبقه‌بندهاست.

نتایج بدست آمده برای دادگان DEAP در جداول (۵) و (۶) گزارش شده است. در جدول (۵) برای بُعد ظرفیت، با در نظر گرفتن ۱۰ کانال جلو سری کارایی طبقه‌بند ELM نسبت به سایر طبقه‌بندها برای روش پیشنهادی و تمام روش‌های مقایسه بالاتر است و هر چه تعداد کانال‌های انتخابی جلو سر افزایش می‌یابد، میزان کارایی در تمام طبقه‌بندها افزایش می‌یابد. این مسئله در بُعد برانگیختگی نیز قابل مشاهده است. با این تفاوت که روش پیشنهادی در این بُعد احساسی با طبقه‌بند

روش mRMR در طبقه‌بند ELM، یا تنها یک درصد افزایش کارایی مشاهده می‌شود مثل روش‌های پیرسون، فیشر و برخی روش‌های دیگر.

با توجه به جدول (۴) برای بُعد برانگیختگی نیز با افزایش تعداد کانال‌های جلوی سر کارایی افزایش می‌یابد. میزان افزایش کارایی در روش پیشنهادی نسبت به سایر روش‌ها بالاتر است و معمولاً روش‌های اسپیرمن، پیرسون، mRMR و اطلاعات متقابل کارایی نزدیک‌تری به روش پیشنهادی دارند.

نتایج بدست آمده از این مجموعه داده نشان می‌دهد که روش پیشنهادی با در نظر گرفتن تقریباً هر طبقه‌بندی کارایی مناسبی دارد. در مقابل در برخی از روش‌ها تنها برخی از طبقه‌بندها می‌توانند خوب عمل کنند. همچنین افزایش کانال‌های جلوسر، در روش پیشنهادی باعث افزایش میزان کارایی می‌شود، در حالیکه در برخی از روش‌ها افزایش تعداد

جدول ۵: نتایج کارایی در نظر گرفتن کانال‌های جلوی سر برای بُعد ظرفیت روی دادگان DEAP

درخت تصمیم			ELM			SVM			روش‌ها
۱۸ کانال	۱۴ کانال	۱۰ کانال	۱۸ کانال	۱۴ کانال	۱۰ کانال	۱۸ کانال	۱۴ کانال	۱۰ کانال	
۷۰.۲۱	۶۹.۰۲	۷۰.۴۱	۸۰.۰۰	۷۹.۰۳	۷۹.۶۵	۷۹.۳۲	۷۷.۴۳	۷۵.۲۳	روش پیشنهادی
۶۷.۸۷	۶۷.۱۲	۶۶.۳۵	۷۸.۱۳	۷۶.۴۵	۷۳.۵۴	۷۶.۳۳	۷۳.۲۳	۷۱.۴۱	اسپیرمن
۶۸.۳۲	۶۷.۵۴	۶۵.۲۳	۷۵.۸۵	۷۵.۳۷	۷۳.۹۶	۷۳.۳۸	۷۱.۲۸	۷۰.۳۵	پیرسون
۶۶.۰۰	۶۵.۰۴	۶۳.۳۲	۷۰.۳۲	۶۹.۶۵	۷۰.۵۷	۶۹.۱۲	۶۸.۸۹	۶۸.۲۱	فیشر
۶۹.۳۲	۶۹.۲۱	۶۷.۴۵	۷۳.۵۹	۷۲.۵۰	۷۳.۶۵	۷۳.۵۹	۷۲.۷۸	۷۲.۴۵	mRMR
۶۴.۲۸	۶۲.۱۱	۶۱.۴۹	۶۶.۳۱	۶۵.۷۶	۶۵.۲۴	۶۵.۳۱	۶۴.۲۳	۶۱.۳۵	Relief
۵۴.۰۰	۵۳.۶۵	۵۱.۱۲	۵۶.۲۵	۵۷.۱۲	۵۶.۴۵	۵۸.۷۵	۵۷.۴۳	۵۵.۶۵	FFS
۶۷.۲۴	۶۶.۰۳	۶۵.۰۵	۷۵.۲۱	۷۴.۰۸	۷۳.۲۷	۷۲.۴۱	۷۰.۴۲	۶۹.۵۴	MI
۵۶.۳۶	۵۵.۷۸	۵۳.۳۳	۵۷.۵۸	۵۷.۰۰	۵۶.۵۸	۵۹.۳۱	۵۸.۳۲	۵۸.۲۳	PCA

جدول ۶: نتایج کارایی با در نظر گرفتن کانال‌های جلوی سر برای بُعد برانگیختگی روی دادگان DEAP

درخت تصمیم			ELM			SVM			روش‌ها
۱۸ کانال	۱۴ کانال	۱۰ کانال	۱۸ کانال	۱۴ کانال	۱۰ کانال	۱۸ کانال	۱۴ کانال	۱۰ کانال	
۷۵.۵۹	۷۵.۰۰	۷۴.۳۲	۷۸.۳۹	۷۸.۶۸	۷۷.۲۳	۸۱.۰۳	۸۰.۴۵	۷۹.۹۸	روش پیشنهادی
۷۲.۱۶	۷۲.۴۳	۷۱.۶۵	۷۵.۴۵	۷۵.۲۱	۷۴.۳۴	۷۸.۶۵	۷۶.۸۷	۷۵.۳۵	اسپیرمن
۷۳.۶۲	۷۳.۱۸	۷۰.۷۸	۷۶.۶۷	۷۵.۴۹	۷۳.۳۲	۷۵.۴۱	۷۳.۵۴	۷۱.۱۷	پیرسون
۶۳.۵۹	۶۳.۰۹	۶۱.۳۴	۶۷.۵۳	۶۵.۳۱	۶۴.۲۹	۶۸.۴۷	۶۶.۲۷	۶۵.۴۲	فیشر
۷۱.۴۶	۷۰.۳۲	۶۹.۴۳	۷۵.۳۹	۷۳.۳۴	۷۲.۳۲	۷۵.۵۰	۷۴.۵۶	۷۱.۰۴	mRMR
۶۴.۰۰	۶۳.۸۷	۶۳.۲۳	۶۶.۰۴	۶۵.۱۸	۶۴.۳۴	۶۸.۴۳	۶۷.۷۸	۶۷.۳۴	Relief
۶۱.۹۴	۶۱.۳۷	۶۰.۰۳	۶۶.۴۵	۶۶.۸۳	۶۵.۴۰	۶۴.۷۸	۶۲.۳۴	۶۱.۰۴	FFS
۶۵.۲۱	۶۴.۲۱	۶۴.۳۵	۷۱.۲۹	۶۸.۴۱	۶۸.۴۵	۷۱.۵۹	۷۰.۱۹	۶۹.۳۴	MI
۶۰.۵۳	۵۸.۸۲	۵۷.۷۲	۶۴.۰۳	۶۳.۷۲	۶۲.۴۲	۶۰.۹۷	۵۹.۸۱	۵۸.۲۱	PCA

افزایش تعداد کانال‌های جلو سر معمولاً میزان کارایی در روش پیشنهادی و سایر روش‌ها در هر سه طبقه‌بند افزایش می‌یابد.

نتایج آزمایشات این بخش در هر دو بُعد احساسی نشان می‌دهد که روش پیشنهادی از کانال‌های جلوی سر ویژگی‌های مناسب‌تری را انتخاب می‌کند، از این رو نسبت به سایر روش‌ها مؤثرتر عمل می‌کند. به عبارت

SVM کارایی بالاتری با ۱۰، ۱۴ و ۱۸ کانال نسبت به سایر طبقه‌بندها دارد. پایین‌ترین میزان کارایی مربوط به روش PCA است. می‌توان گفت چون PCA یک روش بدون ناظر است و برچسب کلاس‌ها در کاهش بُعد نقشی ندارند، سبب می‌شود کارایی پایین‌تری داشته باشد. روش‌های اسپیرمن، پیرسون، mRMR و اطلاعات متقابل در هر سه طبقه‌بند کارایی مناسبی داشته و معمولاً نزدیک به روش پیشنهادی هستند. در این دادگان نیز با

با این طبقه‌بند دارند. برای بُعد برانگیختگی، در روش پیشنهادی و سایر روش‌ها طبقه‌بند SVM نسبت به سایر طبقه‌بندها کارایی بالاتری دارد. در این بُعد، کارایی درخت تصمیم در روش‌های پرسون، mRMR و PCA به شدت کاهش یافته است.

نتایج مربوط به دادگان DEAP نیز در جدول (۷-سمت چپ) گزارش شده است. در هر دو بُعد ظرفیت و برانگیختگی کارایی روش پیشنهادی نسبت به سایر روش‌ها بالاتر است. طبقه‌بند درخت تصمیم در اغلب روش‌ها کارایی بسیار پایینی دارد. در مقابل طبقه‌بند ELM در روش پیشنهادی، اسپیرمن، پرسون و PCA نسبت به سایر طبقه‌بندها بهتر عمل کرده است. به صورت کلی در این مجموعه داده کارایی روش‌های FFS، PCA و اطلاعات متقابل در هر دو بُعد احساسی و برای هر سه طبقه‌بند نسبت به سایر روش‌ها پایین‌تر است. با توجه به اینکه در این مقاله از روش یک نفر بیرون (LOSO) استفاده شد، هر بار که یک نفر برای تست در نظر گرفته شد، ویژگی‌های آن فرد بدست آمد.

دیگر هنگام بروز احساسات افراد، کانال‌های موجود در جلوی سر بیشترین تحریک را دارند و بیشتر تحت تاثیر احساسات قرار می‌گیرند.

۲-۴-۵ در نظر گرفتن همه کانال‌ها

با توجه به اینکه علاوه بر کانال‌های جلو سر ممکن است کانال‌های نواحی دیگر نیز در بروز احساسات تاثیر داشته باشند، در آزمایشات این بخش تمام کانال‌های موجود در دادگان در نظر گرفته شد. نتایج بدست آمده برای هر دو مجموعه داده و هر سه طبقه‌بند در جدول (۷) گزارش شده است. برای مجموعه داده DREAMER جدول (۷-سمت راست) برای بُعد ظرفیت نشان می‌دهد که کارایی روش پیشنهادی در هر سه طبقه‌بند نسبت به سایر روش‌ها بالاتر است. در روش‌های مقایسه روش mRMR در طبقه‌بند SVM بالاترین میزان کارایی را دارد.

در سایر روش‌ها طبقه‌بند ELM کارایی مناسب‌تری دارد. کارایی بدست آمده با طبقه‌بند درخت تصمیم نسبت به سایر طبقه‌بندها پایین‌تر است و روش‌های Relief و PCA نسبت به سایر روش‌ها کارایی پایین‌تری

جدول ۷: نتایج طبقه‌بندی روی هر دو مجموعه داده با در نظر گرفتن همه کانال‌ها و در هر سه طبقه‌بند

DEAP			DREAMER			DREAMER			DREAMER			دادگان
برانگیختگی			ظرفیت			برانگیختگی			ظرفیت			روش‌ها
درخت تصمیم	ELM	SVM	درخت تصمیم	ELM	SVM	درخت تصمیم	ELM	SVM	درخت تصمیم	ELM	SVM	
۸۰.۱۹	۸۴.۱۸	۸۲.۳۰	۷۵.۴۲	۸۲.۶۵	۸۰.۱۳	۶۸.۵۹	۷۰.۵۴	۷۲.۹۸	۷۳.۷۸	۷۷.۶۷	۷۹.۱۱	روش پیشنهادی
۷۴.۶۴	۷۷.۸۷	۷۳.۶۹	۷۳.۴۳	۷۸.۶۵	۷۷.۵۴	۵۸.۰۷	۶۵.۱۲	۶۳.۴۳	۶۷.۱۹	۷۴.۱۹	۷۲.۰۹	اسپیرمن
۷۵.۰۰	۷۶.۵۴	۷۹.۶۵	۷۴.۰۸	۷۸.۵۴	۷۵.۴۳	۵۷.۴۲	۶۶.۶۵	۶۴.۹۸	۶۹.۶۷	۷۲.۴۳	۷۰.۶۵	پرسون
۷۵.۱۱	۷۴.۳۲	۷۳.۰۵	۷۲.۶۵	۷۷.۴۳	۷۳.۲۳	۶۳.۵۱	۶۳.۶۵	۶۱.۴۹	۶۸.۹۲	۷۰.۰۰	۶۸.۱۴	فیشر
۷۳.۲۱	۷۶.۰۳	۷۲.۹۶	۷۵.۴۳	۷۶.۰۴	۷۷.۳۲	۵۷.۴۳	۶۶.۲۹	۶۸.۳۹	۶۶.۳۱	۷۰.۷۸	۷۳.۴۳	mRMR
۷۱.۶۴	۷۴.۴۰	۷۰.۵۳	۷۳.۰۰	۷۵.۳۲	۷۷.۲۷	۶۱.۰۸	۶۲.۳۷	۶۴.۴۹	۶۳.۱۱	۶۸.۸۶	۶۷.۱۴	Relief
۶۹.۲۱	۷۰.۴۳	۶۸.۷۶	۷۳.۰۰	۷۴.۵۳	۷۲.۸۷	۶۰.۰۴	۶۳.۵۶	۶۰.۶۲	۶۷.۵۴	۶۹.۳۲	۶۶.۶۳	FFS
۶۸.۶۵	۷۱.۰۸	۷۰.۳۱	۷۴.۶۵	۷۳.۴۰	۷۶.۸۴	۶۰.۲۱	۵۷.۲۸	۶۵.۲۷	۷۱.۱۳	۷۲.۶۹	۶۹.۵۴	MI
۶۶.۲۳	۶۸.۷۱	۶۲.۳۲	۷۳.۰۰	۷۳.۴۲	۷۰.۷۲	۵۷.۰۹	۶۰.۸۲	۶۲.۱۹	۶۵.۰۳	۶۷.۴۵	۶۵.۲۶	PCA

جدول ۸: درصد ویژگی‌ها و تعداد کانال‌های مشترک برای بُعد ظرفیت روی دادگان DREAMER (برای حالتی که تمام کانال‌ها در نظر گرفته شد)

درخت تصمیم		ELM		SVM		روش‌ها
تعداد کانال‌های مشترک	درصد ویژگی‌های مشترک	تعداد کانال‌های مشترک	درصد ویژگی‌های مشترک	تعداد کانال‌های مشترک	درصد ویژگی‌های مشترک	
۷	۶۹.۴۱%	۷	۷۵.۵۶%	۵	۷۳.۵۸%	روش پیشنهادی
۸	۶۱.۸۷%	۹	۶۳.۸۵%	۸	۶۱.۵۴%	اسپیرمن
۱۰	۶۳.۴۳%	۹	۶۵.۳۴%	۹	۶۲.۳۲%	پرسون
۹	۵۶.۱۳%	۱۰	۶۰.۳۲%	۹	۵۸.۲۵%	فیشر
۹	۶۱.۳۲%	۹	۶۲.۶۵%	۷	۶۵.۳۴%	mRMR
۱۰	۵۹.۳۴%	۱۱	۵۸.۳۲%	۱۰	۵۵.۰۰%	Relief
۱۱	۵۱.۵۸%	۱۰	۵۷.۴۳%	۹	۵۵.۳۱%	FFS
۱۰	۶۳.۴۳%	۹	۶۹.۱۳%	۸	۶۶.۱۹%	MI
چون روش کاهش بُعد است، نمی‌توان درصد تعداد ویژگی‌های مشترک و کانال‌های مشترک را محاسبه کرد.						PCA

جدول ۹: درصد ویژگی‌ها و تعداد کانال‌های مشترک برای بُعد برانگیختگی روی دادگان DREAMER (برای حالتی که تمام کانال‌ها در نظر گرفته شد)

درخت تصمیم		ELM		SVM		روش‌ها
تعداد کانال‌های مشترک	درصد ویژگی‌های مشترک	تعداد کانال‌های مشترک	درصد ویژگی‌های مشترک	تعداد کانال‌های مشترک	درصد ویژگی‌های مشترک	
۷	۷۱.۴۳%	۶	۷۵.۲۳%	۶	۷۴.۵۰%	روش پیشنهادی
۱۰	۶۵.۴۳%	۸	۶۷.۳۴%	۸	۶۵.۲۱%	اسپیرمن
۱۰	۶۶.۵۳۲۸%	۹	۶۵.۱۵%	۹	۶۴.۵۰%	پیرسون
۱۲	۵۸.۷۶%	۱۲	۶۶.۸۷%	۱۱	۶۳.۳۱%	فیشر
۹	۶۱.۵۴%	۹	۶۳.۲۸%	۸	۶۰.۴۸%	mRMR
۱۰	۵۳.۵۴%	۱۱	۵۲.۴۸%	۱۰	۴۹.۷۳%	Relief
۹	۵۱.۸۷%	۹	۵۴.۱۵%	۱۰	۵۰.۷۱%	FFS
۹	۶۱.۵۹%	۸	۶۳.۵۶۹۸%	۸	۶۰.۱۵%	MI
چون روش کاهش بُعد است، نمی‌توان درصد تعداد ویژگی‌های مشترک و کانال‌های مشترک را محاسبه کرد.						PCA

پیشنهادی در ۷۵ درصد مواقع ویژگی‌های مشترک بین ۲۳ نفر را انتخاب می‌کند که در سایر روش‌ها حدود ۶۰ درصد است و در روش‌های Relief و FFS به ۵۰ درصد هم می‌رسد. اما تعداد پایین کانال‌های مشترک نشان می‌دهد که روش پیشنهادی از کانال‌های یکسانی انتخاب ویژگی انجام می‌دهد.

سپس بین ویژگی‌های بدست آمده از تمام افراد اشتراک گرفته شد و درصد اشتراک ویژگی‌ها محاسبه شد. این نتایج برای دادگان DREAMER در جداول (۸) و (۹) گزارش شده است و بیان‌کننده این است که روش پیشنهادی در هر دو بُعد احساس برای افراد مختلف ویژگی‌های یکسانی را انتخاب می‌کند. نتایج نشان می‌دهد که روش

جدول ۱۰: درصد ویژگی‌ها و تعداد کانال‌های مشترک برای بُعد ظرفیت روی دادگان DEAP (برای حالتی که تمام کانال‌ها در نظر گرفته شد)

درخت تصمیم		ELM		SVM		روش‌ها
تعداد کانال‌های مشترک	درصد ویژگی‌های مشترک	تعداد کانال‌های مشترک	درصد ویژگی‌های مشترک	تعداد کانال‌های مشترک	درصد ویژگی‌های مشترک	
۱۲	۷۳.۴۶%	۱۲	۷۸.۷۶%	۱۱	۷۹.۶۵%	روش پیشنهادی
۱۶	۶۸.۸۹%	۱۴	۷۲.۷۶%	۱۵	۷۱.۴۳%	اسپیرمن
۱۴	۶۹.۴۵%	۱۵	۷۱.۴۳%	۱۶	۶۹.۳۴%	پیرسون
۱۸	۶۰.۳۴%	۱۷	۶۳.۷۸%	۱۹	۶۱.۴۵%	فیشر
۱۸	۶۷.۵۸%	۱۶	۷۱.۷۶%	۱۴	۷۱.۰۹%	mRMR
۱۷	۶۰.۳۲%	۱۸	۶۴.۵۱%	۱۶	۶۳.۴۳%	Relief
۲۱	۶۱.۴۳%	۲۳	۶۶.۴۳%	۲۰	۶۴.۷۶%	FFS
۱۷	۶۹.۰۰%	۱۷	۷۳.۵۶%	۱۵	۷۱.۸۷%	MI
چون روش کاهش بُعد است، نمی‌توان درصد تعداد ویژگی‌های مشترک و کانال‌های مشترک را محاسبه کرد.						PCA

جدول ۱۱: درصد ویژگی‌ها و تعداد کانال‌های مشترک برای بعد برانگیختگی روی دادگان DEAP (برای حالتی که تمام کانال‌ها در نظر گرفته شد)

درخت تصمیم		ELM		SVM		روش‌ها
تعداد کانال‌های مشترک	درصد ویژگی‌های مشترک	تعداد کانال‌های مشترک	درصد ویژگی‌های مشترک	تعداد کانال‌های مشترک	درصد ویژگی‌های مشترک	
۱۱	۷۸.۳۴%	۱۳	۷۹.۲۳%	۱۳	۸۱.۴۳%	روش پیشنهادی
۱۴	۶۸.۶۳%	۱۵	۷۱.۰۰%	۱۵	۷۱.۵۸%	اسپیرمن
۱۴	۶۹.۲۳%	۱۴	۶۹.۵۶%	۱۶	۷۳.۳۴%	پیرسون
۱۷	۶۱.۳۴%	۱۶	۶۳.۵۹%	۱۹	۶۸.۳۲%	فیشر
۱۶	۶۱.۶۵%	۱۵	۷۰.۷۶%	۱۳	۷۲.۴۳%	mRMR
۲۱	۶۰.۴۵%	۱۸	۶۸.۸۹%	۱۹	۶۷.۵۹%	mRMR
۲۴	۶۱.۰۰%	۲۱	۶۵.۷۸%	۲۱	۶۴.۳۸%	FFS
۱۹	۷۰.۷۶%	۱۶	۷۲.۴۵%	۱۶	۷۴.۳۴%	MI
چون روش کاهش بعد است، نمی‌توان درصد تعداد ویژگی‌های مشترک و کانال‌های مشترک را محاسبه کرد.						PCA

روش‌های Relief، فیشر و FFS نسبت به سایر روش‌ها تعداد کانال‌های مشترک آن‌ها بیشتر است. این مسئله نشان می‌دهد که در این روش‌ها ویژگی‌های افراد مختلف از کانال‌های متفاوتی انتخاب می‌شوند، بنابراین با انتخاب ویژگی انتخاب کانال وجود ندارند. در سایر روش‌های مقایسه مثل اسپیرمن، پیرسون و mRMR تعداد کانال‌های مشترک نسبتاً کمتر است بنابراین این روش‌ها تا حدودی انتخاب کانال دارند.

شکل (۶) کانال‌های مشترک بین ویژگی‌های انتخاب شده (در ۳۲ بار اجرا) در روش پیشنهادی و در هر سه طبقه‌بند روی دادگان DEAP را نشان می‌دهد و بیان‌گر این است که با در نظر گرفتن تمام کانال‌های مجموعه داده DEAP، روش پیشنهادی برای انتخاب ویژگی‌های مناسب کانال‌های جلوی سر را انتخاب می‌کند. این اتفاق در هر سه طبقه‌بند قابل مشاهده است و اکثر کانال‌های انتخاب شده در هر سه طبقه‌بند مشترک هستند.

آزمایشات این بخش نشان می‌دهد که ویژگی‌های انتخاب شده در روش پیشنهادی در هر بار تکرار آزمایش از کانال‌های تقریباً یکسانی انتخاب می‌شوند. در حالی که در سایر روش‌های مقایسه ویژگی‌های انتخاب شده از کانال‌های متفاوتی هستند. بنابراین می‌توان گفت روش پیشنهادی علاوه بر انتخاب ویژگی‌های مناسب، در هر دو مجموعه داده کانال‌هایی را انتخاب می‌کند که حاوی ویژگی‌های موثرتری هستند. همچنین شکل‌های (۵) و (۶) نشان می‌دهند که روش پیشنهادی ویژگی‌های مناسب را از کانال‌های جلوی سر که بیشترین ارتباط را با احساسات دارند، انتخاب می‌کند که این مسئله کاملاً منطبق با مقاله [۱۱] و آزمایشات بخش ۴-۵ می‌باشد.

به عبارت دیگر روش پیشنهادی علاوه بر انتخاب ویژگی‌های مناسب، سعی می‌کند ویژگی‌ها را از کانال‌های مناسبی که بیشترین ارتباط را با احساسات افراد دارند، انتخاب کند. از این رو روش پیشنهادی همان طور که اشاره شد، علاوه بر انتخاب ویژگی انتخاب کانال نیز انجام می‌دهد و این عمل مستقل از طبقه‌بند صورت می‌گیرد.

بنابراین در روش پیشنهادی انتخاب کانال نیز صورت می‌گیرد. در برخی از روش‌ها مثل Relief، FFS، فیشر و پیرسون به دلیل اینکه تعداد کانال‌های مشترک بالاست، نشان می‌دهد که این روش‌ها انتخاب ویژگی را از کانال‌های متفاوتی انجام می‌دهند بنابراین انتخاب کانال ندارند. برای PCA چون یک روش کاهش بعد است نمی‌توان درصد اشتراک ویژگی‌ها و تعداد کانال‌های مشترک را محاسبه کرد.

این روش‌ها انتخاب ویژگی را از کانال‌های متفاوتی انجام می‌دهند بنابراین انتخاب کانال ندارند. برای PCA چون یک روش کاهش بعد است نمی‌توان درصد اشتراک ویژگی‌ها و تعداد کانال‌های مشترک را محاسبه کرد.

شکل (۵) روی دادگان DREAMER و در هر سه طبقه‌بند برای روش پیشنهادی کانال‌هایی را نشان می‌دهد که ویژگی‌های مشترک از آن‌ها انتخاب شده‌اند. با توجه به شکل (۵)، روش پیشنهادی در هر دو بعد احساسی و در هر سه طبقه‌بند ویژگی‌ها را معمولاً از کانال‌های جلو سر انتخاب می‌کند. همانطور که اشاره شد کانال‌های جلو سر بیشترین ارتباط را با احساسات افراد دارند و بسیار موثر در تشخیص احساسات هستند [۱۱]. به عبارت دیگر با وجود ۱۴ کانال در مجموعه داده DREAMER، روش پیشنهادی سراغ کانال‌های جلوی سر می‌رود و ویژگی‌های مناسب را از این کانال‌ها انتخاب می‌کند.

جداول (۱۰) و (۱۱) برای دادگان DEAP، نشان می‌دهند که روش پیشنهادی تقریباً در ۸۰ درصد مواقع در ۳۲ بار اجرا، ویژگی‌های یکسانی را برای تمام افراد انتخاب می‌کند. به عبارت دیگر در ۸۰ درصد ویژگی‌های انتخاب شده بین افراد در هر دو بعد احساسی مشترک هستند. در روش‌های اسپیرمن، پیرسون و اطلاعات متقابل این مقدار در هر دو بعد احساسی به ۷۰ درصد می‌رسد و در سایر روش‌ها تقریباً ۶۰ درصد است. همچنین تعداد کانال‌های مشترک در این مجموعه داده در روش پیشنهادی نسبت به سایر روش‌ها در هر دو بعد احساسی کمتر است.

نتایج بدست آمده از آزمایشات این بخش نشان می‌دهد که روش پیشنهادی در هر دو بُعد احساسی کانال‌های مناسبی را انتخاب کرده است چرا که تنها با در نظر گرفتن این کانال‌ها در میزان کارایی روش پیشنهادی و سایر روش‌های مقایسه، بهبودی در هر دو مجموعه داده حاصل شده است. این مسئله نشان می‌دهد که روش پیشنهادی این مقاله علاوه بر انتخاب کانال‌های جلو سر که مرتبط با احساسات هستند [۱۱]، کانال‌هایی از سایر نقاط سر نیز انتخاب می‌کند که سبب بهبود کارایی روش پیشنهادی و سایر روش‌ها می‌شود. به عبارت دیگر اگر فقط کانال‌های انتخابی روش پیشنهادی را در نظر بگیریم، مشاهده می‌شود که علاوه بر روش پیشنهادی، سایر روش‌ها نیز انتخاب ویژگی موثرتری خواهند داشت.

۶- بحث و نتیجه‌گیری

آزمایشات انجام شده در این مقاله نشان می‌دهد که اگر عمل انتخاب ویژگی را تنها با کانال‌های جلو سر انجام دهیم، روش پیشنهادی نسبت به سایر روش‌ها بهتر عمل می‌کند و با افزایش تعداد کانال‌های جلو سر کارایی افزایش می‌یابد. اما زمانی که تمام کانال‌ها در نظر گرفته می‌شود باز هم روش پیشنهادی برای انتخاب ویژگی‌های مناسب سراخ کانال‌های جلو سر می‌رود و به طور میانگین تقریباً ۷۵ درصد ویژگی‌هایی را انتخاب می‌کند که مربوط به کانال‌های جلو سر هستند.

بنابراین کاملاً منطبق با مقاله [۱۱] و آزمایشات اولیه، روش ارائه شده در این مقاله انتخاب ویژگی را به صورت موثر و از کانال‌های مناسبی انجام می‌دهد. همچنین با در نظر گرفتن کانال‌های انتخاب شده توسط روش ارائه شده، علاوه بر افزایش کارایی روش پیشنهادی، سایر روش‌های انتخاب ویژگی نیز بهبود می‌یابند.

علاوه بر این با توجه به انتخاب برخی از کانال‌های جلو سر توسط روش پیشنهادی، واضح است که فقط تمام کانال‌های جلو سر مناسب

جدول ۱۲: نتایج طبقه‌بندی با کانال‌های انتخابی روش پیشنهادی روی هر دو مجموعه داده و در هر سه طبقه‌بند

DEAP			DREAMER			DREAMER			DEAP			دادگان
برانگیختگی			ظرفیت			برانگیختگی			ظرفیت			روش‌ها
درخت تصمیم	ELM	SVM	درخت تصمیم	ELM	SVM	درخت تصمیم	ELM	SVM	درخت تصمیم	ELM	SVM	
۸۱.۰۹	۸۵.۲۲	۸۴.۱۰	۷۶.۰۹	۸۶.۱۲	۸۳.۳۷	۷۰.۱۱	۷۱.۶۲	۷۶.۴۳	۷۵.۳۲	۷۹.۲۱	۸۱.۶۵	روش پیشنهادی
۷۵.۱۲	۷۸.۰۳	۷۶.۴۹	۷۵.۱۹	۷۹.۱۲	۷۸.۰۸	۶۰.۴۹	۶۷.۵۱	۶۵.۴۳	۶۹.۸۷	۷۴.۶۹	۷۴.۵۲	اسپیرمن
۷۵.۸۶	۷۷.۱۲	۸۰.۴۳	۷۴.۸۹	۷۹.۱۹	۷۶.۰۳	۵۹.۰۴	۶۷.۳۸	۶۶.۲۲	۷۰.۰۴	۷۳.۰۵	۷۱.۲۹	پیرسون
۷۵.۹۷	۷۵.۸۱	۷۴.۴۱	۷۳.۱۹	۷۵.۸۵	۷۴.۲۹	۶۵.۳۱	۶۵.۳۱	۶۲.۰۸	۶۹.۲۹	۷۱.۷۹	۶۹.۰۲	فیشر
۷۵.۲۰	۷۸.۸۹	۷۳.۸۶	۷۶.۱۰	۷۷.۸۳	۸۰.۰۴	۵۹.۳۲	۶۷.۳۹	۶۸.۷۸	۶۸.۰۳	۷۱.۴۵	۷۳.۰۴	mRMR
۷۴.۷۲	۷۶.۰۹	۷۴.۶۹	۷۳.۸۹	۷۸.۲۳	۷۹.۳۹	۶۸.۴۶	۶۲.۲۸	۶۴.۶۹	۶۵.۴۳	۶۹.۲۵	۶۹.۰۵	Relief
۷۲.۰۳	۷۳.۴۷	۷۲.۰۲	۷۵.۶۸	۷۶.۲۹	۷۵.۹۲	۶۳.۲۹	۶۵.۵۹	۶۳.۶۹	۶۹.۰۰	۶۵.۲۶	۶۶.۲۱	FFS
۷۱.۳۲	۷۲.۲۹	۷۳.۷۴	۷۶.۹۵	۷۵.۴۲	۷۷.۰۳	۶۳.۷۴	۶۱.۶۹	۶۹.۴۸	۷۳.۱۳	۷۵.۶۵	۷۲.۲۸	MI
۶۸.۳۸	۶۹.۷۸	۶۳.۶۹	۷۳.۷۹	۷۳.۴۹	۶۹.۲۸	۵۹.۲۳	۶۰.۵۸	۶۴.۴۲	۶۷.۲۲	۶۷.۶۹	۶۶.۳۸	PCA

۳-۴-۵ در نظر گرفتن کانال‌های انتخاب شده توسط روش پیشنهادی برای نشان دادن این که کانال‌های انتخاب شده در روش پیشنهادی مرتبط با بُعد‌های احساسی هستند، آزمایش دیگری انجام شد. به این صورت که در روش پیشنهادی و تمام روش‌های مقایسه برای هر دو بُعد احساسی، کانال‌های انتخاب شده در شکل‌های (۵) و (۶)، در نظر گرفته شد. سپس انتخاب ویژگی برای دادگان DREAMER و DEAP صورت گرفت. نتایج این آزمایش در جدول (۱۲) گزارش شده است.

جدول (۱۲) - سمت راست) نتایج روی دادگان DREAMER در هر بُعد احساسی را نشان می‌دهد. در بُعد ظرفیت، روش پیشنهادی با ۸۱ درصد کارایی روی طبقه‌بند SVM بالاترین میزان کارایی را دارد. در سایر روش‌ها معمولاً طبقه‌بند ELM بهتر عمل کرده است. در بُعد برانگیختگی روش پیشنهادی با حدود ۷۶ درصد کارایی روی طبقه‌بند SVM از همه روش‌ها بهتر است. روش‌های پیرسون، اسپیرمن و mRMR کارایی نزدیک‌تری به روش پیشنهادی دارند و در مقابل روش PCA در بُعد برانگیختگی و در هر سه طبقه‌بند کارایی پایین‌تری دارد. جدول (۱۲) - سمت چپ) نتایج بدست آمده با کانال‌های انتخابی روی دادگان DEAP را نشان می‌دهد. در بُعد ظرفیت روش پیشنهادی روی طبقه‌بند ELM تقریباً ۸۶ درصد کارایی از سایر روش‌ها و طبقه‌بندها بالاتر است. برای سایر روش‌های مقایسه طبقه‌بند SVM برای Relief, mRMR و اطلاعات متقابل تقریباً بهتر عمل کرده است و در روش mRMR کارایی ۸۰ درصد دارد. در طبقه‌بند درخت تصمیم روش فیشر در بُعد برانگیختگی با کارایی حدود ۷۶ درصد نسبت به سایر روش‌ها بالاتر است. همچنین در بُعد برانگیختگی میزان کارایی روش‌های FFS و PCA روی طبقه‌بند ELM نسبت به سایر روش‌ها پایین‌تر است.

PCA نسبتاً زمان زیادی صرف انتخاب ویژگی می‌کند و در مقابل روش FFS زمان بسیار زیادی را صرف تنها یک مرحله انتخاب ویژگی می‌کند. در نتیجه روش پیشنهادی با توجه به اینکه زمان نسبتاً کمتری دارد، بنابراین در اعتبار سنجی موثرتر عمل خواهد کرد و در زمان کمتری پارامترهای مطلوب محاسبه خواهند شد. روش‌هایی که دارای زمان انتخاب ویژگی بیشتری هستند، سبب می‌شوند عملیات اعتبار سنجی در زمان طولانی‌تری رخ دهد، بنابراین رسیدن به مقادیر مناسب برای پارامترها خسته کننده خواهد بود.

در پایان می‌توان گفت که نتایج بدست آمده نشان می‌دهد که ویژگی‌های انتخاب شده توسط روش پیشنهادی در هر بار تکرار آزمایش تقریباً مشترک هستند و از کانال‌های ثابتی انتخاب می‌شوند. لذا روش پیشنهادی علاوه بر انتخاب ویژگی انتخاب کانال نیز انجام می‌دهد و کانال‌های مربوط به جلوی سر که بیشترین ارتباط را با احساسات افراد دارند انتخاب می‌کند. مشترک بودن ویژگی‌ها در تکرار آزمایشات مختلف نشان دهنده‌ی مستقل از فرد بودن این ویژگی‌ها می‌باشد. لذا نتایج نشان می‌دهند که رویکردهای چند وظیفه‌ای برای انتخاب ویژگی و انتخاب کانال کارایی بهتری نسبت به دیگر روش‌ها در مواجهه با افراد جدید را دارند.

نیستند و با انتخاب برخی از آن‌ها و برخی دیگر هم کارایی قابل قبولی خواهیم داشت.


در کلیه آزمایشات انجام شده انحراف معیار بدست آمده در هر دو مجموعه داده در روش پیشنهادی حدود ۲/۵ تا ۳ و در سایر روش‌ها حدود ۴ تا ۶ می‌باشد. همچنین ۷۰ درصد ویژگی‌های انتخاب شده در تمام آزمایشات از ویولت‌ها هستند و این مسئله بیانگر این است که ویژگی ویولت بسیار موثر در تشخیص احساسات است.

لازم است اشاره شود با توجه به اینکه برای بدست آوردن مقادیر مناسبی برای پارامترهای الگوریتم‌ها و طبقه‌بندها، لازم است به صورت اعتبار سنجی عمل کنیم، زمان انتخاب ویژگی بسیار مهم است. با توجه به این که خود عملیات اعتبار سنجی نسبتاً طولانی است، بنابراین هر چه زمان انتخاب ویژگی کوتاه‌تر باشد رسیدن به مقادیر مناسبی برای پارامترها سریع‌تر و راحت‌تر خواهد بود.

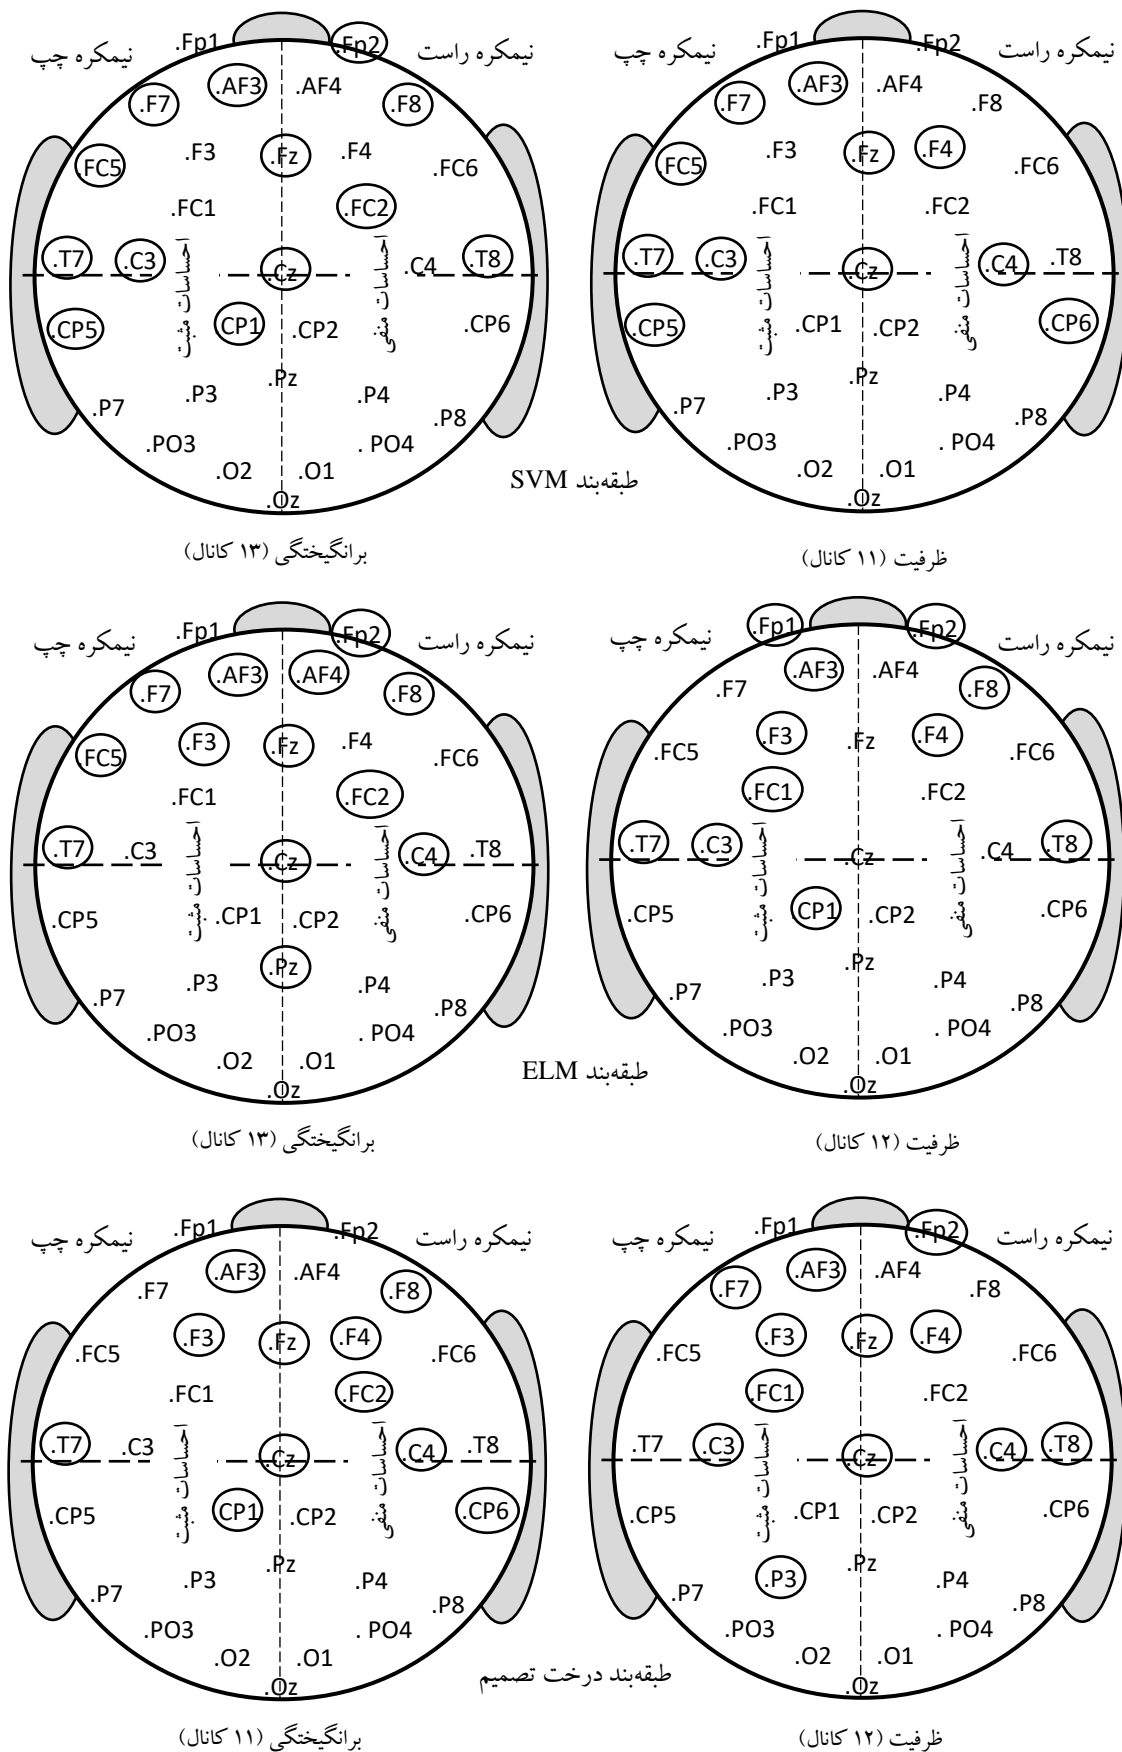
زمان انتخاب ویژگی روش پیشنهادی و هر یک از روش‌های مقایسه برای هر دو مجموعه داده زمانی که تمام کانال‌ها در نظر گرفته شد، در جدول (۱۳) آورده شده است. این زمان بر اساس فقط یک بار انجام عملیات انتخاب ویژگی برای تمام روش‌ها محاسبه شده است. همانطور که در جدول (۱۳) مشاهده می‌شود، زمان‌های ذکر شده برای تمام روش‌ها در هر دو مجموعه داده کاملاً با هم متفاوت است. مشاهده می‌شود روش پیشنهادی نسبت به سایر روش‌ها زمان کمتری دارد. روش‌های فیشر و

جدول ۱۳: زمان انتخاب ویژگی برای هر یک از روش‌ها با در نظر گرفتن همه کانال‌ها ("علامت ثانیه، 'علامت دقیقه)

دادگان DEAP (۳۲ کانال)		دادگان DREAMER (۱۴ کانال)	
زمان انتخاب ویژگی	روش‌ها	زمان انتخاب ویژگی	روش‌ها
۲۹"	روش پیشنهادی	۲۲"	روش پیشنهادی
۲':۴۵"	اسپیرمن	۲':۰۵"	اسپیرمن
۲':۳۲"	پیرسون	۱':۵۴"	پیرسون
۸':۰۳"	فیشر	۷':۲۰"	فیشر
۴':۴۶"	mRMR	۴':۲۱"	mRMR
۴':۴۸"	Relief	۴':۰۴"	Relief
۲۰':۲۹"	FFS	۲۰':۰۸"	FFS
۵':۱۷"	MI	۴':۵۹"	MI
۸':۴۶"	PCA	۸':۲۱"	PCA



شکل ۵: کانال‌های انتخاب شده توسط روش پیشنهادی در دادگان DREAMER



شکل ۶: کانال‌های انتخاب شده توسط روش پیشنهادی در دادگان DEAP

مراجع

- feature selection and kernel classifiers." *Expert Systems with Applications* 47 (2016): 35-41.
- [15] Yan, Yixin, Chenyang Li, and Shaoliang Meng. "Emotion recognition based on sparse learning feature selection method for social communication." *Signal, Image and Video Processing* (2019): 1-5.
- [16] M.Siems, et al. "Measuring the cortical correlation structure of spontaneous oscillatory activity with EEG and MEG." *NeuroImage* 129: 345-355, (2016).
- [17] J.Gao, W.Wang, and Ji Zhang. "Explore interregional EEG correlations changed by sport training using feature selection." *Computational intelligence and neuroscience* 2016: 30, (2016).
- [18] E.Kroupi, A. Yazdani, and T. Ebrahimi. "EEG correlates of different emotional states elicited during watching music videos." *Affective Computing and Intelligent Interaction*. Springer, Berlin, Heidelberg. 457-466,(2011).
- [19] L.Piho, and T. Tjahjadi. "A mutual information based adaptive windowing of informative EEG for emotion recognition." *IEEE Transactions on Affective Computing*,(2018).
- [20] M.Wang, et al. "Anxiety Level Detection Using BCI of Miner's Smart Helmet." *Mobile Networks and Applications* 23.2: 336-343, (2018).
- [21] V. Bajaj, S. Taran, and A. Sengur. "Emotion classification using flexible analytic wavelet transform for electroencephalogram signals." *Health information science and systems* 6.1: 12, (2018).
- [22] N.Zhuang, et al. "Emotion recognition from EEG signals using multidimensional information in EMD domain." *BioMed research international* 2017 (2017).
- [23] Rayatdoost, Soheil, and Mohammad Soleymani. "Cross-Corpus EEG-based emotion recognition." *2018 IEEE 28th International Workshop on Machine Learning for Signal Processing (MLSP)*. IEEE, 2018.
- [24] B.Zhang , E. M.Provost, & G.Essl, (2016, March). Cross-corpus acoustic emotion recognition from singing and speaking: A multi-task learning approach. In *2016 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)* (pp. 5805-5809). IEEE.
- [25] R.Xia , & Y.Liu, (2015). A multi-task learning framework for emotion recognition using 2D continuous space. *IEEE Transactions on affective computing*, 8(1), 3-14.
- [26] B.Zhang , E. M.Provost, & G.Essl, (2017). Cross-corpus acoustic emotion recognition with multi-task learning: Seeking common ground while preserving differences. *IEEE Transactions on Affective Computing*, 10(1), 85-99.
- [1] Savran A, Çiftçi K, Chanel G, Rombaut M. Emotion Detection in the Loop from Brain Signals and Facial Images. *Proceedings of the eNTERFACE*; 2066 Jul 11- 17; Dubrovnik, Croatia: 2006.
- [2] Chen L, Mao X, Xue Y, Cheng LL. Speech emotion recognition: Features and classification models. *Digital Signal Processing* 2012;22(6):1154-60.
- [3] Zheng WL, Zhu JY, Lu BL. Identifying stable patterns over time for emotion recognition from EEG. *IEEE Transactions on Affective Computing*; IEEE; 2017.
- [4] N .Sebe , et al. "Multimodal approaches for emotion recognition: a survey." *Internet Imaging VI*. Vol. 5670. International Society for Optics and Photonics, (2005).
- [5] D.Oude Bos, "EEG-based emotion recognition-The Influence of Visual and Auditory Stimuli." *Capita Selecta (MSc course)*,(2006)..
- [6] J.Gratch, and S. Marsella. "A domain-independent framework for modeling emotion." *Cognitive Systems Research*5.4: 269-306, (2004).
- [7] M.Grimm, and K. Kroschel. "Rule-based emotion classification using acoustic features." in *Proc. Int. Conf. on Telemedicine and Multimedia Communication.*(2005).
- [8] Y.Dai, et al. "Sparsity constrained differential evolution enabled feature-channel-sample hybrid selection for daily-life EEG emotion recognition." *Multimedia Tools and Applications*: 1-28, (2018).
- [9] F.Ren ,Y.Dong, and Wei Wang. "Emotion recognition based on physiological signals using brain asymmetry index and echo state network." *Neural Computing and Applications*,1-11, (2018).
- [10] H. Jaeger, Tutorial on training recurrent neural networks, covering BPPT, RTRL, EKF and the "echo state network" approach. Vol. 5. Bonn: GMD-Forschungszentrum Informationstechnik, (2002).
- [11] M. Li, et al. "Emotion recognition from multichannel EEG signals using K-nearest neighbor classification." *Technology and Health Care Preprint* (2018): 1-11.
- [12] Z.Mohammadi, J. Frounchi, and M. Amiri. "Wavelet-based emotion recognition system using EEG signal." *Neural Computing and Applications* 28.8: 1985-1990, (2017).
- [13] A R.Subhani, et al. "MRMR based feature selection for the classification of stress using EEG." *Sensing Technology (ICST)*, 2017 Eleventh International Conference on. IEEE, (2017).
- [14] Atkinson, John, and Daniel Campos. "Improving BCI-based emotion recognition by combining EEG

- Convolutional Neural Networks for Accurate Emotion Classification on DEAP Dataset. In *Twenty-Ninth IAAI Conference*.
- [40] S.Alhagry, A. A.Fahmy, & R. A. El-Khoribi (2017). Emotion recognition based on EEG using LSTM recurrent neural network. *Emotion*, 8(10), 355-358.
- [41] M. L. R.Menezes, A.Samara, L.Galway, A.Sant'Anna. (2017). Towards emotion recognition for virtual environments: an evaluation of eeg features on benchmark dataset. *Personal and Ubiquitous Computing*, 21(6), 1003-1013.
- [42] J.Atkinson, & D.Campos, (2016). Improving BCI-based emotion recognition by combining EEG feature selection and kernel classifiers. *Expert Systems with Applications*, 47, 35-41.
- [43] Song, Tengfei, et al. "EEG emotion recognition using dynamical graph convolutional neural networks." *IEEE Transactions on Affective Computing* (2018).
- [44] P.Arnau-Gonzalez, S.Katsigiannis, N.Ramzan, D.Tolson, & M. Arevalillo-Herrez, (2017, October). ES1D: A deep network for EEG-based subject identification. In *2017 IEEE 17th International Conference on Bioinformatics and Bioengineering (BIBE)* (pp. 81-85). IEEE.
- [45] Zhang, Tong, et al. "GCB-Net: Graph convolutional broad network and its application in emotion recognition." *IEEE Transactions on Affective Computing* (2019).
- [46] R.Jenke, A. Peer, and M. Buss. "Feature extraction and selection for emotion recognition from EEG." *IEEE Transactions on Affective Computing* 5.3: 327-339, (2014).
- [47] W. Zheng, (2016). Multichannel EEG-based emotion recognition via group sparse canonical correlation analysis. *IEEE Transactions on Cognitive and Developmental Systems*, 9(3), 281-290.
- [48] N. Zheng, Y. Zeng, L. Tong, C. Zhang, H. Zhang, & B. Yan, (2017). Emotion recognition from EEG signals using multidimensional information in EMD domain. *BioMed research international*, 2017.
- [49] B. Nakisa, M. Rastgoo, N. D.Tjondronegoro, & V. Chandran, (2018). Evolutionary computation algorithms for feature selection of EEG-based emotion recognition using mobile sensors. *Expert Systems with Applications*, 93, 143-155.
- [50] J. Zhang, M. Chen, S. Zhao, S. Hu, Z. Shi, & Y. Cao, (2016). ReliefF-based EEG sensor selection methods for emotion recognition. *Sensors*, 16(10), 1558.
- [51] M.Robnik-Šikonja and I. Kononenko. "Theoretical and empirical analysis of ReliefF and RReliefF." *Machine learning* 53.1-2: 23-69,(2003).
- [27] C.Wang, J.Zeng, S.Shan, & X.Chen, (2019, September). Multi-Task Learning of Emotion Recognition and Facial Action Unit Detection with Adaptively Weights Sharing Network. In *2019 IEEE International Conference on Image Processing (ICIP)* (pp. 56-60). IEEE.
- [28] D.Le, Z.Aldeneh, & E. M.Provost, (2017, August). Discretized Continuous Speech Emotion Recognition with Multi-Task Deep Recurrent Neural Network. In *Interspeech* (pp. 1108-1112).
- [29] M.Correa, J.Abdon, and Ioannis Patras. (2018) "A multi-task cascaded network for prediction of affect, personality, mood and social context using eeg signals." *13th IEEE International Conference on Automatic Face & Gesture Recognition*.
- [30] H. Sunhee, et al. 2020, "Subject-Independent EEG-based Emotion Recognition using Adversarial Learning." *2020 8th International Winter Conference on Brain-Computer Interface (BCI)*. IEEE.
- [31] Yang, F., Zhao, X., Jiang, W., Gao, P., & Liu, G. (2019). Multi-method fusion of cross-subject emotion recognition based on high-dimensional EEG features. *Frontiers in computational neuroscience*, 13.
- [32] H .Janati, T. Bazeille, B.Thirion, (2020). Multi-subject MEG/EEG source imaging with sparse multi-task regression. *NeuroImage*, 116847.
- [33] Y.Song, D .Wang, K.Yue,. (2019, July). EEG-Based Motor Imagery Classification with Deep Multi-Task Learning. In *2019 International Joint Conference on Neural Networks (IJCNN)* (pp. 1-8). IEEE.
- [34] G.Chanel, et al. "Emotion assessment: Arousal evaluation using EEG's and peripheral physiological signals." *International workshop on multimedia content representation, classification and security*. Springer, Berlin, Heidelberg, 2006.
- [35] G.Obozinski, B. Taskar, and M. Jordan. "Multi-task feature selection." *Statistics Department, UC Berkeley, Tech. Rep 2* (2006).
- [36] A .Beck and M.Teboulle. "A fast iterative shrinkage-thresholding algorithm for linear inverse problems." *SIAM journal on imaging sciences* 2.1: 183-202, (2009).
- [37] S.Katsigiannis, and N. Ramzan. "DREAMER: a database for emotion recognition through EEG and ECG signals from wireless low-cost off-the-shelf devices." *IEEE journal of biomedical and health informatics* 22.1: 98-107, (2018).
- [38] Koelstra, Sander, et al. "Deap: A database for emotion analysis; using physiological signals." *IEEE transactions on affective computing* 3.1 (2012): 18-31.
- [39] S.Tripathi, S.Acharya, R. D.Sharma, S.Mittal, & S. Bhattacharya (2017, February). Using Deep and

از کانال‌های ثابتی انتخاب شده‌اند. اکثر کانال‌ها مربوط به نواحی جلو سر هستند. همچنین ویژگی‌های انتخاب شده، ویولت‌ها، مشتقات اول ویولت و مشتقات دوم هستند و از ضرایب مختلف ۱ تا ۱۲ انتخاب شده‌اند. تعدادی از ویژگی‌های مشترک بین افراد در هر دو مجموعه داده، در جدول (۱) آورده شده است.

[52] Schuller, B., et al., Cross-corpus acoustic emotion recognition: Variances and strategies. IEEE Transactions on Affective Computing, 2010. 1(2): p. 119-131.

ضمیمه

با توجه به اینکه هدف مقاله حاضر انتخاب ویژگی‌های مستقل از افراد است، آزمایشات مختلفی انجام شد. با بررسی ویژگی‌های انتخاب شده به عنوان ویژگی‌های مشترک و مستقل از فرد، مشخص شد که اکثر ویژگی‌ها

جدول ۱: ویژگی‌های مشترک بین افراد در هر دو مجموعه داده

نام ویژگی	ردیف	نام ویژگی	ردیف	نام ویژگی	ردیف
کانال AF3 (در دادگان DEAP)		ضریب ۱۰ ویولت (مشتق ۱)	۴	کانال F3	
ضریب ۹ ویولت (مشتق ۲)	۱	کانال F7		ضریب ۱۲ ویولت (مشتق ۱)	۱
ضریب ۱۱ ویولت	۲	ضریب ۱۲ ویولت	۱	ضریب ۱۲ ویولت (مشتق ۲)	۲
ضریب ۱۱ ویولت (مشتق ۱)	۳	ضریب ۱۲ ویولت (مشتق ۱)	۲	ضریب ۱۰ ویولت (مشتق ۲)	۳
واریانس	۴	ضریب ۱۲ ویولت (مشتق ۲)	۳	ضریب ۵ ویولت (مشتق ۲)	۴
آنتروپی	۵	ضریب ۱۰ ویولت (مشتق ۲)	۴	ضریب ۸ ویولت	۵
انرژی	۶	ضریب ۹ ویولت (مشتق ۲)	۵	کانال F8	
کانال FP2 (در دادگان DEAP)		ضریب ۹ ویولت (مشتق ۱)	۶	ضریب ۱۲ ویولت (مشتق ۱)	۱
ضریب ۱۲ ویولت (مشتق ۲)	۱	ضریب ۸ ویولت (مشتق ۱)	۷	ضریب ۹ ویولت (مشتق ۱)	۲
ضریب ۱۱ ویولت	۲	کانال T8		ضریب ۹ ویولت (مشتق ۲)	۳
ضریب ۱۱ (مشتق ۱)	۳	ضریب ۳ ویولت (مشتق ۱)	۱	کانال F4	
آنتروپی	۴	ضریب ۹ ویولت	۲	ضریب ۱۰ ویولت (مشتق ۱)	۱
کانال C4 (در دادگان DEAP)		ضریب ۹ ویولت (مشتق ۱)	۳	ضریب ۹ ویولت (مشتق ۲)	۲
ضریب ۱۰ ویولت	۱	ضریب ۹ ویولت (مشتق ۲)	۴	ضریب ۱۲ ویولت (مشتق ۲)	۳
ضریب ۱۰ ویولت (مشتق ۱)	۲	ضریب ۴ ویولت	۵	ضریب ۱۲ ویولت (مشتق ۱)	۴
ضریب ۱۰ ویولت (مشتق ۲)	۳	میانگین	۶	کانال T7	
ضریب ۱۰ ویولت (مشتق ۱)	۴	چولگی	۷	ضریب ۸ ویولت	۱
انرژی	۵	آنتروپی	۸	ضریب ۸ ویولت (مشتق ۱)	۲
واریانس	۶	انرژی	۹	ضریب ۱۰ ویولت	۳