

## Discovery of Shared Feature Mapping for EEG-based Emotion Recognition by Multi-Task Learning Approach

Elham Kalhor<sup>1</sup>, Behzad Bakhtiari<sup>2\*</sup>

1- Computer and Information Technology Engineering, Sadjad University of Technology, Mashhad, Iran.

2\*- Computer and Information Technology Engineering, Sadjad University of Technology, Mashhad, Iran.

<sup>1</sup> e.kalhor333@sadjad.ac.ir, <sup>2</sup> bakhtiari@sadjad.ac.ir

\* Corresponding author's address: Behzad Bakhtiari, Faculty of Computer and Information Technology Engineering, Sadjad University of Technology, Mashhad, Iran, Postal Code: 9188148848.

**Abstract-** Investigations have revealed that human emotions are resulted from their internal neural operations. The feedback of each emotion, sent from the skull surface, can be received and processed as a signal. Brain signals can be received and recorded by the EEG setup. In recent years, researchers and scholars have utilized various methods to capture and pre-process the signal, feature selection, dimensionality reduction and classification of brain signals. But, the number and type of extracted features play key roles in classification. Since it is unknown which feature operates more effectively and due to the fact that the number of used features are typically high and dependent on person, reduction in number of features and improving the efficiency of the classifier have been focused by many researchers. The purpose of this article is to provide a multi-task learning method to reduce the dimension and achieve a common space of features that describes the feelings of different people well. To show the efficiency of the proposed method, three well-known datasets are used, i.e. DEAP, SEED and DREAMER. Experiments are performed in two forms. In the first experiment, each channel is investigated separately. Channels with high efficiency are selected. The second experiment is performed by considering channels related to different parts of the brain (frontal, occipital, left hemisphere, right hemisphere). In the first experiment, the highest efficiency is about 80% and in the second experiment it is about 84%. Experimental results have shown that the proposed method have a higher efficiency than other comparing methods.

**Keywords-** EEG-based Emotion Recognition, Dimensionality Reduction, Multi-task Learning, Shared Feature Subspace.

## یافتن نگاشت ویژگی‌های مشترک برای سیستم‌های تشخیص احساس مبتنی بر سیگنال EEG با رویکرد یادگیری چند وظیفه‌ای

الهام کلهر<sup>۱</sup>، بهزاد بختیاری<sup>۲\*</sup>

۱- دانشکده مهندسی کامپیوتر و فناوری اطلاعات، دانشگاه صنعتی سجاد، مشهد، ایران.

۲- دانشکده مهندسی کامپیوتر و فناوری اطلاعات، دانشگاه صنعتی سجاد، مشهد، ایران.

<sup>۱</sup> e.kalhor333@sadjad.ac.ir, <sup>۲\*</sup> bakhtiari@sadjad.ac.ir

\* نشانی نویسنده مسئول: بهزاد بختیاری، مشهد، خیابان جلال آل احمد، جلال آل احمد ۶۴، دانشگاه صنعتی سجاد، دانشکده مهندسی کامپیوتر و فناوری اطلاعات، کد پستی: ۹۱۸۸۱۴۸۸۴۸

چکیده- پژوهش‌ها نشان می‌دهند که احساسات انسان نتیجه عملکرد نورونی داخل مغز وی است. در سال‌های اخیر پژوهشگران از شیوه‌های گوناگون در راستای اخذ و پیش‌پردازش سیگنال‌های مغزی، انتخاب ویژگی، کاهش بُعد و طبقه‌بندی استفاده کرده‌اند. اما تعداد و نوع ویژگی‌های استخراج شده نقش بسیار مهمی در طبقه‌بندی ایفا می‌کنند. با توجه به اینکه نمی‌دانیم کدام ویژگی‌ها در طبقه‌بندی موثرتر عمل می‌کنند و از طرفی مجموعه ویژگی‌های مورد استفاده معمولاً زیاد و مستقل از افراد نیستند، لذا کم کردن تعداد ویژگی‌ها و افزایش کارایی طبقه‌بند بسیار مورد توجه پژوهشگران قرار گرفته است. هدف این مقاله نیز ارائه روشی مبتنی بر یادگیری چند وظیفه‌ای برای کاهش بُعد و رسیدن به زیر فضای مشترکی از ویژگی‌ها می‌باشد که احساسات افراد مختلف را به خوبی توصیف کند. بنابراین با استفاده از یادگیری چند وظیفه‌ای، از فضای ویژگی‌های مورد استفاده نگاشتی یافت شود که بین افراد مختلف مشترک باشد. برای نشان دادن کارایی روش پیشنهادی از سه مجموعه داده بسیار معروف SEED، DEAP و DREAMER استفاده شد. آزمایشات به دو صورت انجام شد. در آزمایش اول هر کانال به صورت جدا بررسی شد و کانال‌هایی که کارایی بالا داشتند انتخاب شدند. آزمایش دوم با در نظر گرفتن کانال‌های بخش‌های مختلف مغز (جلو سر، عقب سر، نیمکره راست و نیمکره چپ) صورت گرفت. در آزمایش اول، بالاترین کارایی حدود ۸۰ درصد و در آزمایش دوم حدود ۸۴ درصد است. نتایج آزمایشات نشان می‌دهند که روش پیشنهادی نسبت به روش‌های مقایسه کارایی بهتری دارد.

واژه‌های کلیدی: تشخیص احساس مبتنی بر EEG، کاهش بُعد، یادگیری چند وظیفه‌ای، زیر فضای مشترک ویژگی‌ها.

### ۱- مقدمه

می‌کند. [۱] در واقع بیان احساسات پل ارتباطی انسان‌هاست.

احساس می‌تواند بر عملکرد یک فرد نیز تأثیر مستقیم بگذارد و به صورت عامیانه با بیان عباراتی مانند "حالم خوب نیست!"، "دل‌م شور می‌زند." و ...، که نمود بیرونی از یک سری اتفاقات درونی است، بروز پیدا کند. احساس یکی از حالت‌های مغزی است که به دنبال فعالیت الکتریکی میلیون‌ها عصب و تحریک آن‌ها تولید می‌شود و با تغییرات فیزیولوژیکی تمام بدن همراه است [۲].

احساس پدیده‌ی پیچیده‌ای است که از مسائل روزمره نشأت می‌گیرد و بر تصمیمات فرد تأثیرات بسزایی دارد. گستره‌ی این تصمیمات می‌تواند بر زندگی فردی و اجتماعی افراد یک جامعه اثر بگذارد. برای مثال، حالت احساسی یک فرد در هنگام رانندگی می‌تواند تأثیر مستقیمی بر واکنش‌های او بگذارد. احساسات در یادگیری و برقراری ارتباط از اهمیت زیادی برخوردارند و بیان آن‌ها نقش زیادی در روابط انسان‌ها بازی

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 و افزایش زمان اجرای الگوریتم می‌شود و این مسئله باعث بیش‌برازش داده‌ها و کاهش کارایی طبقه‌بند می‌شود، بنابراین می‌توان گفت مهم‌ترین مسئله پیدا کردن زیرفضایی از ویژگی‌های مرتبط با احساسات افراد است که با ابعاد کمتر توصیف‌کننده‌ی احساسات مشترک بین آن‌ها باشد. با وجود چالش‌های مطرح شده، هدف این مقاله رسیدن به زیر فضایی کاهش یافته از ویژگی‌هاست که بین افراد مختلف مشترک باشند و توصیف‌کننده‌ی ابعاد احساسی آن‌ها باشند.

ساختار بخش‌های مختلف مقاله عبارت‌اند از: بخش دوم به معرفی کامل کارهای انجام شده در حوزه تشخیص احساس از روی سیگنال‌های مغزی اختصاص یافته است. در بخش سوم به طور مختصر مدل تشخیص احساس معرفی می‌شود. در بخش چهارم این مطالعه، روش پیشنهادی به طور کامل بیان می‌شود. بخش پنجم به بررسی کامل آزمایشات و نتایج حاصل شده اختصاص یافته است. در پایان نتیجه‌گیری ارائه خواهد شد.

## ۲- کارهای مرتبط

یکی از مشکلات اساسی پژوهشگران در زمینه تشخیص احساس از روی سیگنال‌های مغزی بالا بودن بُعد ماتریس ویژگی‌هاست. این مسئله سبب افزایش زمان اجرای الگوریتم، بیش‌برازش داده‌ها و کاهش کارایی طبقه‌بند می‌شود. برای رفع این مشکلات کارهای مختلفی صورت گرفته است. در تمام کارهای انجام شده هدف ارائه الگوریتمی است که با کاهش فضای ویژگی‌ها، کارایی طبقه‌بند افزایش یابد. کارهای انجام شده به صورت کلی به چهار دسته تقسیم‌بندی می‌شوند که عبارت‌اند از: روش‌های انتخاب ویژگی، انتخاب کانال، کاهش بُعد و روش‌های مختلف شبکه عصبی. در ادامه به بررسی کارهای انجام شده در هر دسته خواهیم پرداخت.

انتخاب ویژگی‌های مناسب از میان تعداد ویژگی‌ها بالا امری مهم و ضروری است. زیرا هم سبب کاهش تعداد ویژگی‌ها و هم سبب افزایش دقت طبقه‌بند می‌شود. اما اینکه چه ویژگی‌هایی انتخاب شوند و یا انتخاب ویژگی با چه روشی صورت گیرد بسیار حائز اهمیت است. این روش‌ها تغییری در ماهیت ویژگی‌ها ایجاد نمی‌کنند. مقالات سال‌های اخیر، در زمینه انتخاب ویژگی کارهای متفاوتی انجام دادند. در ادامه برخی از مقالات بررسی خواهند شد. روش MRMR<sup>۲</sup> ارتباط یک ویژگی با کلاس را بررسی می‌کند. علاوه بر این ارتباط یک ویژگی با زیر مجموعه ویژگی‌های انتخاب

هنگام بروز احساسات، عملکرد دو نیمکره‌ی راست و چپ مغز بسیار قابل توجه است. اغلب یافته‌ها این فرضیه را مطرح می‌کنند که قشر پیش‌پیشانی شامل نواحی: ۸، ۹، ۱۰، ۱۱، ۱۲، ۱۳، ۱۴، ۲۴، ۲۵، ۳۲، ۴۴، ۴۵، ۴۶ و ۴۷ مغز است. این نواحی هم در جلوی سر و هم در پشت سر هستند. تحقیقات نشان داده است، بخش پیش‌پیشانی چپ بیشتر در واکنش‌های احساسی و بخش پیش‌پیشانی راست در واکنش‌های گوشه‌گیری درگیر است [۳].

به عبارت دیگر در دنیای امروز که امواج و سیگنال‌های مختلفی انسان را احاطه کرده‌اند استفاده از این سیگنال‌ها و امواج در موارد مختلف نه تنها یک امر اجتناب‌ناپذیر است، بلکه در زمینه‌های مختلف راه گشای بسیاری از مسائل نیز می‌باشد. بنابراین سیگنال‌های مغزی انسان انواع متفاوتی دارند که پرکاربردترین آن‌ها سیگنال‌های الکتروانسفالوگرافی<sup>۱</sup> است. این سیگنال یک سیگنال الکتریکی است که بر اثر فعالیت مغز تولید می‌شود و حاوی اطلاعات مختلفی است که می‌توان از آن در زمینه‌های متفاوتی بهره برد. از جمله این زمینه‌ها، تشخیص احساسات افراد در مقابل محرک‌های حسی مختلفی است که معمولاً از طریق مشاهده و گاهی از طریق گوش و از طریق شنوایی انسان به او القا می‌شوند.

در واقع می‌توان گفت، احساسات در انسان از ادراکات خودآگاه و ناخودآگاه او در شرایط مختلف نشأت می‌گیرد. مطالعه این موضوع در علوم مختلف مانند پزشکی، روانشناسی و مهندسی از اهمیت زیادی برخوردار است. در بسیاری از مطالعات مربوط به شناخت حالت مختلف مغز، احساسات به وسیله نمایش تصاویر یا پخش اصوات برای افراد برانگیخته می‌شوند و همزمان فعالیت‌های بیولوژیکی شامل سیگنال‌های مغزی و محیطی ثبت می‌شوند [۴]. در این میان واکنش‌های مغزی افراد، که سرچشمه اصلی بروز حالت احساسی است بیشتر مورد توجه قرار گرفته است. همچنین سیگنال‌های مغزی نیز ماهیتی غیرخطی و پیچیده دارند.

تشخیص احساسات از روی سیگنال مغز کاربردهای فراوانی دارد. امروزه با بررسی فعالیت‌های مغزی انسان‌ها هنگام بازید از اینترنت و خرید و فروش‌ها، احساسات واقعی آن‌ها ارزیابی می‌شود تا میزان تمایل افراد به سایت‌های مختلف سنجیده شود [۵]. همچنین با بررسی تصمیم‌های گرفته شده توسط افراد مختلف و درست و غلط بودن آن‌ها، میزان استرس افراد سنجیده می‌شود تا میزان تاثیر استرس در تصمیم‌گیری‌ها مشخص شود. تحلیل‌های ذهنی در بازی‌های رایانه‌ای نیز از اهمیت ویژه‌ای برخوردار است [۶].

با وجود پیشرفت‌های گسترده در حوزه‌ی پردازش و طبقه‌بندی

با توجه به اینکه بین نیمکره چپ و راست مغز اختلاف وجود دارد، [۱۵] یک مدل مبتنی بر شبکه عصبی بازگشتی برای یادگیری تفاوت‌های نامتقارن بین دو نیمکره چپ و راست ارائه کرده است که قادر است احساسات را تشخیص دهد. همچنین استفاده از مدل یادگیری ارائه شده در [۱۵] سبب می‌شود فضای ویژگی‌های بدست آمده تمایز دهنده بین احساسات باشند. بنابراین کارایی طبقه‌بند افزایش می‌یابد. ابتدا الکترودهای هر دو نیمکره شناسایی می‌شوند، فاصله بین آن‌ها محاسبه می‌شود، سپس از طریق مدل ارائه شده، اختلاف بین دو نیمکره بدست می‌آید.

به منظور یادگیری بهتر، یک روش یادگیری و طبقه‌بندی مبتنی بر شبکه عصبی کانولوشن (CNN) در [۱۶] ارائه شده است. این مدل بر اساس ویژگی‌های زمانی، فرکانسی و ترکیب آن‌ها عمل می‌کند. نتایج نشان داده است که مدل شبکه عصبی CNN بدون نیاز به انتخاب ویژگی، بهترین ویژگی‌ها را در نظر می‌گیرد.

همچنین در [۱۷] یک روش تشخیص احساسات عاطفی چند کاناله ارائه شده است که مبتنی بر مدل شبکه عصبی کانولوشن است. این روش به کمک ترسیم یک گراف پویا قابلیت این را دارد که بر اساس تفاوت احساسات در دو نیمکره چپ و راست تغییر کند و به فضایی از ویژگی‌های مناسب و مرتبط با هر دو نیمکره برسد. به عبارتی دیگر روش ارائه شده در [۱۷] به صورت پویا و به کمک ماتریس مجاورت، رابطه ذاتی بین کانال‌های مختلف را پیدا کرده و با آموزش شبکه عصبی کارایی طبقه‌بند را افزایش می‌دهد.

با استفاده از روش یادگیری مبتنی بر شبکه عصبی عمیق نیز می‌توان احساسات را از روی سیگنال‌های مغزی تشخیص داد. TSception [۱۸] روشی است که بر اساس لایه‌های کانولوشنی فضایی و زمانی به طور همزمان بر اساس حوزه‌های زمان و فضا آموزش می‌بیند. یادگیرنده‌ی زمانی از هسته‌های کانولوشنی یک بعدی تشکیل شده است که طول هر هسته بر اساس نرخ نمونه‌برداری سیگنال مشخص می‌شود. در مقابل یادگیرنده‌ی فضایی از ویژگی‌هایی که سبب عدم تقارن احساسات در ناحیه جلو مغز می‌شوند استفاده می‌کند تا بر اساس تفاوت‌های نیمکره چپ و راست مغز آموزش ببیند.

[۱۹] از شبکه باور عمیق (DBN)<sup>۲</sup> برای ساخت مدل‌های تشخیص احساسات (مثبت، منفی و خنثی) از روی سیگنال‌های مغزی استفاده کرده است. این مدل‌ها، با استفاده از ویژگی آنترابی استخراج شده از ۴ کانال مختلف مغز آموزش داده می‌شوند.

شده را هم ارزیابی می‌کند. سپس ویژگی را انتخاب می‌کند که همبسته با کلاس باشد و ارتباط آن با زیرمجموعه ویژگی‌های انتخاب شده کم باشد. در واقع این روش با در نظر گرفتن کمترین میزان افزونگی ویژگی‌های زائد را حذف می‌کند [۷]. [۸] با استفاده روش یادگیری پراکنده<sup>۳</sup> ویژگی‌های زائد را حذف می‌کند.

انتخاب ویژگی‌هایی که بیشترین وابستگی را به برجسب کلاس‌ها دارند سبب می‌شود ویژگی‌های موثر و حاوی اطلاعات مفید انتخاب شوند. روش‌های همبستگی شامل پیرسون، اسپیرمن و... است که مقاله [۹] به کمک این روش‌ها تعداد ویژگی‌ها را کم کرده و ویژگی‌های موثر را انتخاب می‌کند. همچنین روش اطلاعات متقابل (MI)<sup>۴</sup> کمک می‌کند تا ویژگی‌هایی که اطلاعات مفید بین داده‌ها را بهتر بیان می‌کنند، انتخاب شوند [۱۰].

از آنجایی که تعداد کانال‌های تاثیر زیادی در تعداد ویژگی‌ها دارد و هرچه تعداد کانال‌ها بیشتر باشد تعداد ویژگی‌ها نیز بیشتر است، بنابراین دسته‌ای دیگر از مقالات سعی کردند برای کم کردن تعداد ویژگی‌ها تعداد کانال‌ها را کاهش دهند. در واقع این مقالات با انتخاب کانال از مکان‌های مناسب مغز، تعداد ویژگی‌ها را کم کردند. در ادامه به بررسی برخی مقالات این دسته می‌پردازیم.

از روش‌های مختلفی می‌توان برای انتخاب کانال استفاده کرد. [۱۱] از روش‌های تکاملی برای انتخاب کانال از نواحی مختلف مغز استفاده کرده است. این مقاله ادعا دارد که به کمک روش‌های تکاملی می‌توان کانال‌هایی را انتخاب کرد که بیشترین ارتباط را با احساسات افراد دارند. اما [۱۲] از ESN<sup>۵</sup> که به نوعی ساختار شبکه عصبی بازگشتی است، استفاده کرده است. استاندارد ESN از سه بخش تشکیل شده است [۱۳]. به کمک این ساختار کانال‌های مناسب از نواحی مختلف مغز انتخاب می‌شوند.

همچنین می‌توان انتخاب کانال را بر اساس نیمکره راست و چپ مغز انجام داد. [۱۴] بیان می‌کند نیمکره چپ مغز بیشترین ارتباط را با احساسات دارد. بنابراین بهترین کانال‌ها در این قسمت قرار دارند. کانال‌های موجود در نواحی جلو مغز نیز ارتباط نزدیکی با احساسات دارند. بنابراین انتخاب کانال‌ها از این نواحی علاوه بر کاهش تعداد ویژگی‌ها، دقت طبقه‌بند را افزایش می‌دهد.

اما می‌توان بدون انتخاب ویژگی کارایی طبقه‌بند را افزایش داد. مقالاتی که از انواع روش‌های شبکه عصبی استفاده کرده‌اند، می‌توانند بدون انتخاب ویژگی طبقه‌بندی کنند و کارایی قابل قبولی داشته باشند. این روش‌ها ویژگی‌ها را یاد می‌گیرند به همین دلیل زمان آموزش و تست طولانی‌تری نسبت به سایر روش‌ها دارند. در ادامه به بررسی برخی از مقالات این دسته می‌پردازیم.

جدول ۱: خلاصه‌ای از کارهای انجام شده در حوزه تشخیص احساس از روی سیگنال EEG.

مرجع	سال	دادگان	طبقه‌بند	ویژگی‌ها	روش	
[۷]	۲۰۱۷	*	SVM	موجک- ویژگی‌های آماری	MRMR	انتخاب ویژگی
[۸]	۲۰۱۹	DEAP	SVM	انرژی - موجک- ویژگی‌های آماری	خلوت‌سازی	
[۹]	۲۰۱۶	VISH	SVM	۱۲ ضریب موجک	همبستگی	
[۱۰]	۲۰۱۸	DEAP و MAHNOB-HCI	SVM - KNN	موجک- ویژگی‌های آماری	MI	انتخاب کانال
[۱۱]	۲۰۱۸	DEAP	QDA	موجک	روش‌های تکاملی	
[۱۲]	۲۰۱۸	DEAP	SVM	موجک- توان- انرژی	ESN	شبکه عصبی
[۱۴]	۲۰۱۷	DEAP	KNN	موجک	دو نیمکره چپ و راست	
[۱۵]	۲۰۱۹	SEED	RNN	دریافت داده خام	شبکه عصبی بازگشتی	
[۱۶]	۲۰۱۹	DEAP	CNN	دریافت داده خام	یادگیری عمیق	
[۱۷]	۲۰۱۸	SEED	CNN	دریافت داده خام	کانولوشن	
[۱۸]	۲۰۲۰	*	DEEP	دریافت داده خام	یادگیری عمیق	
[۱۹]	۲۰۱۵	DEAP	DBN	دریافت داده خام	باور عمیق	
[۲۰]	۲۰۲۰	IADS و NIMSTIM	SVM - KNN	موجک	LDA	کاهش بُعد
[۲۱]	۲۰۱۹	DEAP	SVM	۵ ضریب موجک- انرژی- توان	PCA	
[۲۲]	۲۰۲۰	SEED	SVM - KNN- ANN	موجک و ویژگی‌های آماری	PCA	
[۲۳]	۲۰۱۹	DEAP	SVM	موجک	DM <sup>۱۰</sup>	

\* داده توسط نویسندگان مقاله تهیه شده است و از دادگان واقعی موجود استفاده نشده است.

و توصیف کننده ابعاد احساسی آن‌ها باشد. برای این منظور یک تابع هدف چند وظیفه‌ای در نظر گرفته شده است که به کمک آن ویژگی‌ها به یک فضای جدید نگاهت داده می‌شوند. سپس با در نظر گرفتن ابعاد مناسبی از این زیر فضا کارایی طبقه‌بند افزایش می‌یابد.

با توجه به اینکه در سال‌های اخیر استفاده از رویکرد چند وظیفه‌ای بسیار مورد توجه قرار گرفت و علاقه‌مندان در حوزه‌های مختلف از جمله گفتار و تصویر از این رویکرد استفاده‌های زیادی در زمینه‌های مختلف کرده‌اند، به نظر می‌آید که اگر در حوزه تشخیص احساس از روی سیگنال مغز نیز، از رویکرد چند وظیفه‌ای استفاده کنیم، مفید خواهد بود. کارهای انجام شده در این حوزه نشان می‌دهد که کار چندانی در حوزه‌ی تشخیص احساس از روی سیگنال‌های مغزی با استفاده از رویکرد چند وظیفه‌ای صورت نگرفته است [۲۸-۲۴].

نویسندگان این مقاله در پژوهش‌های قبلی خود از رویکرد چند وظیفه‌ای استفاده کرده و نشان دادند که این روش برای انتخاب ویژگی در حوزه پردازش گفتار [۳۰-۲۹] و پردازش سیگنال‌های مغزی کارایی قابل قبولی دارد [۳۱]

### ۳- مدل احساس

احساسات با طیف گسترده‌ای از افکار و رفتار انسان‌ها در ارتباط هستند. تئوری‌های مختلفی در علوم شناختی، روانشناسی، علوم اعصاب و سایر رشته‌ها ارائه شده است که ادعا می‌کنند تعریف‌های

در تمام کارهای اشاره شده در سه دسته قبل، یا انتخاب ویژگی و انتخاب کانال صورت گرفته است یا بدون انتخاب ویژگی کار انجام شده است. اما تمرکز ما در این مقاله انتخاب ویژگی و یا انتخاب کانال نیست بلکه هدف کاهش بُعد و داشتن زیر فضای مناسبی از ویژگی‌هاست. یکی از تفاوت‌های روش‌های کاهش بُعد و انتخاب ویژگی این است که در روش‌های کاهش بُعد، با نگاهت ویژگی‌ها به فضایی دیگر در واقع ویژگی‌های جدیدی خواهیم داشت که احتمالاً کارایی بهتری نسبت به ویژگی‌های اولیه دارند. اما روش‌های انتخاب ویژگی ماهیت ویژگی‌ها را تغییر نمی‌دهند بلکه از بین ویژگی‌های موجود بهترین‌ها را انتخاب می‌کنند.

کارهای انجام شده در سال‌های اخیر از روش‌های کاهش بُعد پایه استفاده کرده‌اند. برای مثال روش LDA<sup>۸</sup> برای کاهش بُعد ماتریس ویژگی‌ها بسیار مناسب است [۲۰]. LDA روشی با ناظر است. به این صورت که از برچسب کلاس‌ها برای یادگیری زیرفضای جدید ویژگی‌ها استفاده می‌کند. روش PCA<sup>۹</sup> و کرنل آن نیز در سال‌های اخیر بسیار مورد توجه قرار گرفته‌اند [۲۱، ۲۲]. روش PCA روش یادگیری بدون ناظر است بنابراین از برچسب کلاس‌ها برای یادگیری زیرفضای ویژگی‌ها استفاده نمی‌کند. علاوه بر این، [۲۳] از روش DM<sup>۱۰</sup> که روش کاهش بُعد غیر خطی است، برای نگاهت ویژگی‌ها به فضای جدید استفاده می‌کند. در جدول (۱) خلاصه‌ای از کارهای انجام شده آورده شده است.

با توجه به آنچه که ذکر شد، هدف این مقاله رسیدن به زیرفضای کاهش یافته‌ای از ویژگی‌هاست که بین افراد مختلف مشترک باشد

پس لازم است برای طبقه‌بندی احساسات هر فرد، طبقه‌بندی مخصوص آن طراحی شود تا احساساتش را تشخیص دهد. اما این کار علاوه بر زمانبر بودن، باعث می‌شود سیستم قادر به تشخیص احساسات فرد جدید نباشد. بنابراین برای راحتی کار لازم است تنها یک طبقه‌بند داشته باشیم و این طبقه‌بند به گونه‌ای باشد که برای افراد جدید هم خوب کار کند. از طرفی با توجه به اینکه برخی ویژگی‌های افراد در بیان احساسات مشترک است، می‌توان از این اطلاعات مشترک استفاده کرد و طبقه‌بندی آموزش داد که بر اساس زیرفضایی از ویژگی‌های مشترک بین افراد باشد تا برای افراد جدید کارایی قابل قبولی داشته باشد. برای این منظور می‌توان از رویکرد چند وظیفه‌ای استفاده نمود [۳۳].

این رویکرد کمک می‌کند تا بردار وزن طبقه‌بند بدست آمده برای هر فرد تنها حاوی اطاعات خود آن شخص نباشد، بلکه اطلاعاتی از سایر اشخاص نیز داشته باشد.

اگر فرض کنیم  $N$  تا نمونه مفروض است که مربوط به  $T$  نفر است، در این صورت ماتریس  $X \in \mathbb{R}^{N \times d}$  را ماتریس ویژگی در نظر می‌گیریم که  $d$  تعداد ویژگی‌هاست. همچنین فرض کنید  $X_t \in \mathbb{R}^{n_t \times d}$  ماتریس ویژگی‌های نفر  $t$ ام است و  $y_t$  برچسب داده‌های نفر  $t$ ام است که  $n_t$  تعداد داده‌های آن است و  $t \in \{1, 2, \dots, T\}$  که  $y_t \in \{+1, -1\}^{n_t}$ .

هدف این مقاله کاهش بُعد ماتریس ویژگی‌ها به منظور رسیدن به زیر فضایی موثر است که بین افراد مشترک باشد. برای این منظور از تابع هدف (۱) استفاده می‌شود:

$$\min_{\{v_t, w_t\}, \theta} \sum_{t=1}^T \left( \frac{1}{n_t} \mathcal{L}(w_t) + \alpha \|w_t\|^2 \right) \quad (1)$$

$$s. t. \theta \theta^T = I, w_t = u_t + \theta^T v_t$$

در این رابطه  $\mathcal{L}$  تابع ضرر،  $\|w_t\|^2$  ترم تنظیم‌ساز و  $\alpha$  نیز پارامتر تنظیم‌سازی است. همچنین  $\mathcal{L}(w_t) = \mathcal{L}(w_t(x, y))$  که برای سادگی  $\mathcal{L}(w_t)$  در نظر گرفتیم. با توجه به رابطه (۱) در می‌یابیم تفاوتی که این تابع هدف با توابع هدف معمول دارد این است که فرض شده بردار وزن نفر  $t$ ام ( $w_t$ ) از حاصل جمع دو بخش تشکیل شده است  $w_t = u_t + \theta^T v_t$  که  $u_t$  اطلاعات مربوط به نفر  $t$ ام،  $\theta$  اطلاعات مشترک بین تمام افراد و  $v_t$  بُعد کاهش یافته مشترک است.

مختلفی در احساسات وجود دارد و اینکه از نوع شناختی هستند یا غیر شناختی بسیار حائز اهمیت است. اما آنچه در حقیقت است نشان می‌دهد که فعالیت‌های شناختی یا به عبارت دیگر فعالیت‌های ذهنی برای بروز احساسات امری ضروری هستند [۳۲].

اما روانشناسان بیشتر احساسات را در فضای  $n$  بُعدی در نظر می‌گیرند. اما در واقع برای بیان احساسات دو مدل وجود دارد: ۱- مدل احساسات گسسته. ۲- مدل احساسات دو بُعدی. در مدل اول عواطف مختلف از جمله: عصبانیت، ترس، خوشحالی، ناراحتی، نفرت و تعجب معمولاً به عنوان احساسات اساسی شناخته می‌شوند. اما مدل دو بُعدی، برای نشان دادن حالت‌های عاطفی در دو مقیاس وسیع‌تر، برانگیختگی<sup>۱</sup> و ظرفیت<sup>۲</sup> استفاده می‌شود. علاوه بر این دو بُعد در برخی مواقع بُعد دیگری به نام تسلط<sup>۳</sup> نیز مورد استفاده قرار می‌گیرد.

در واقع 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. تسلط، بیانگر قدرت یا ضعف در بروز احساسات است.

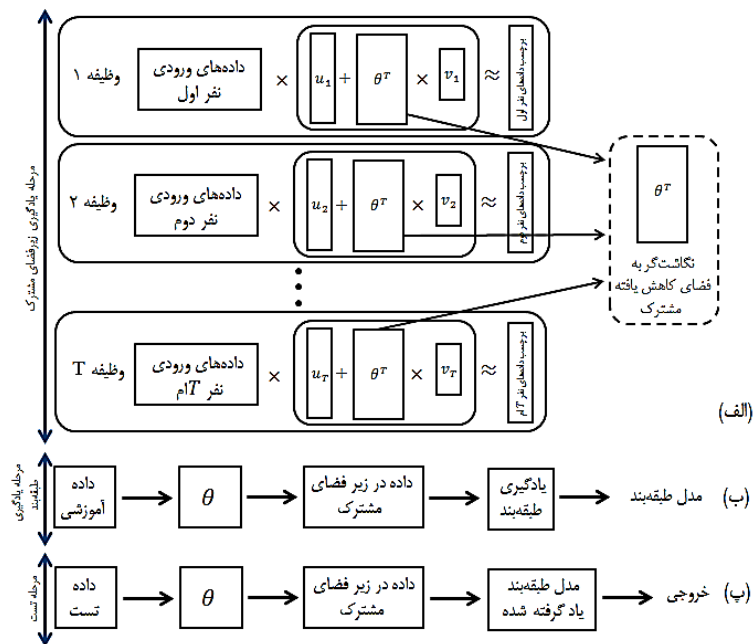
شکل (۱) برگرفته از مقاله‌ی [۱۴] مثالی از مدل احساس دو بُعدی را نشان می‌دهد. با توجه به شکل (۱) به میزانی که روی محور عمودی به سمت بالا حرکت کنیم هیجانان فرد افزایش می‌یابد و به میزانی که روی محور افقی به سمت راست حرکت کنیم وضعیت احساسی از منفی به مثبت عوض می‌شود، به این معنا که فرد از حالت ناراحتی و خستگی به حالت نسبتاً خوشحالی می‌رسد.



شکل ۱: احساسات مختلف روی دو بُعد برانگیختگی و ظرفیت [۱۴].

#### ۴- روش پیشنهادی

انسان‌ها در بروز احساسات با یکدیگر متفاوت‌اند. در نتیجه سیگنالی که از مغز آن‌ها گرفته می‌شود نیز با یکدیگر متفاوت خواهد بود.



شکل ۲: مراحل روش پیشنهادی (الف: مرحله یادگیری زیر فضای مشترک، ب: مرحله یادگیری طبقه‌بند، پ: مرحله تست).

می‌کند.  $\|w_t\|^2$  پیچیدگی توابع تخمین زده شده را کنترل می‌کند.

اگر  $\alpha = 0$  باشد رابطه (۲) کنترلی روی رابطه بین وظیفه‌ها ندارد. اگر  $\beta = 0$  باشد رابطه (۲) محدب نخواهد بود. بنابراین  $\beta$  نمی‌تواند صفر باشد. تابع هدف ارائه شده در رابطه (۲) با جایگزینی رابطه (۳) به صورت رابطه (۴) بازنویسی می‌شود:

$$\min_{\{v_t, w_t\}, \theta} \sum_{t=1}^T \left( \frac{1}{n_t} \mathcal{L}(w_t) + \alpha \|u_t - \theta^T v_t\|^2 + \beta \|w_t\|^2 \right) \quad (4)$$

s.t.  $\theta \theta^T = I, w_t = u_t + \theta^T v_t$   
 به جای  $v_t$  می‌توان  $v_t = \theta w_t$  قرار داد. با جایگزینی مقدار  $v_t$  در رابطه (۴) به رابطه (۵) می‌رسیم:

$$\min_{\{w_t\}, \theta} \sum_{t=1}^T \left( \frac{1}{n_t} \mathcal{L}(w_t) + \alpha w_t^T \left( \left( 1 + \frac{\beta}{\alpha} \right) I - \theta^T \theta \right) w_t \right) \quad (5)$$

s.t.  $\theta \theta^T = I, w_t = u_t + \theta^T v_t$   
 با فرض اینکه  $\eta = \frac{\beta}{\alpha}$  می‌باشد، رابطه (۶) برقرار است:

$$(1 + \eta)I - \theta^T \theta = \eta(1 + \eta)(\eta I + \theta^T \theta)^{-1} \quad (6)$$

با جایگزینی رابطه (۶) در رابطه (۵) به رابطه (۷) می‌رسیم:

$$\min_{\{w_t\}, \theta} \sum_{t=1}^T \left( \frac{1}{n_t} \mathcal{L}(w_t) + \alpha w_t^T (\eta(1 + \eta)(\eta I + \theta^T \theta)^{-1}) w_t \right) \quad (7)$$

لازم است اشاره شود  $W = [w_1, w_2, \dots, w_T]$  است و می‌توان به جای ماتریس  $\theta^T \theta$  ماتریس  $M$  را جایگزین کرد. بنابراین رابطه (۸) بدست می‌آید:

به عبارت دیگر فرض می‌شود بردار وزن هر نفر را می‌توان به دو بخش چنان تجزیه نمود که در یک بخش از آن نگاشتی مشترک ( $\theta$ ) بین همه افراد وجود داشته باشد. شکل (۲-الف) نحوه عملکرد این مطلب را نشان می‌دهد. بنابراین در مرحله یادگیری زیر فضای مشترک، داده‌ها به رابطه (۱) داده شده و  $\theta$  بدست می‌آید. سپس در مرحله یادگیری طبقه‌بند، داده‌ها به فضای جدید نگاشت شده و یادگیری طبقه‌بند با فضای جدید ویژگی‌ها صورت می‌گیرد (شکل (۲-ب)). در نهایت در مرحله آزمایش، با ورود داده جدید و نگاشت آن به فضای جدید، خروجی طبقه‌بند به ازای داده جدید مشخص می‌شود (شکل (۲-پ)).

#### ۴-۱-۱-۴ مراحل حل رابطه (۱)

رابطه (۱) محدب نیست. لذا با پیشنهاد [۳۵، ۳۴] رهاسازی محدب<sup>۴</sup> برای آن به کار می‌رود. برای این منظور، در رابطه (۱) به جای  $\alpha \|w_t\|^2$  جایگزین می‌شود و رابطه (۲) بدست می‌آید:

$$\min_{\{v_t, w_t\}, \theta} \sum_{t=1}^T \left( \frac{1}{n_t} \mathcal{L}(w_t) + G_t(u_t, v_t, \theta) \right) \quad (2)$$

s.t.  $\theta \theta^T = I, w_t = u_t + \theta^T v_t$   
 $G_t(u_t, v_t, \theta)$  به صورت رابطه (۳) تعریف می‌شود. اطلاعات

بین وظیفه‌ها و فضای مشترک بین آن‌ها را نشان می‌دهد.

$$G_t(u_t, v_t, \theta) = \alpha \|u_t - \theta^T v_t\|^2 + \beta \|w_t\|^2 \quad (3)$$

در رابطه (۳)،  $\|u_t - \theta^T v_t\|^2$  رابطه بین وظیفه‌ها را کنترل

استفاده شد. مجموعه دادگان DEAP و DREAMER شامل سه بُعد احساسی برانگیختگی، ظرفیت و میزان تسلط می‌باشند که در این مقاله تنها از دو بُعد برانگیختگی و ظرفیت استفاده شده است. مجموعه داده SEED شامل ۳ کلاس (احساسات مثبت و منفی و طبیعی) است. در این پژوهش تنها از دو کلاس احساسات مثبت و منفی استفاده شده است. اطلاعات مربوط به هر سه مجموعه داده در جدول (۲) آورده شده است. همچنین کانال‌های در نظر گرفته شده در هر مجموعه داده نیز در شکل (۳) نشان داده شده است.

در هر سه مجموعه داده، ابتدا برای افراد شرکت‌کننده ویدیوهایی با مضمون‌های احساسی مختلف پخش شد. بعد از دیدن هر ویدیو، هنگام بروز احساسات توسط فراد، سیگنال مغز آن‌ها توسط دستگاه ثبت شد. در دادگان DREAMER، از افراد خواسته شد به هر ویدیو از عدد ۱ تا ۵ امتیاز دهند. در دادگان DEAP، ۴۰ ویدیو با مضمون‌های مختلف احساسی پخش شد سپس از افراد خواسته شد که از ۱ تا ۹ به هر ویدیو امتیاز دهند. از این امتیازات برای جدا کردن داده‌ها به صورت دو کلاسه (برانگیختگی بالا و پایین، ظرفیت مثبت و منفی) استفاده شد. در داگان SEED، ویدیوهای پخش شده در سه کلاس مثبت، منفی و خنثی قرار گرفتند.

#### ۵-۲- استخراج ویژگی

با توجه به اینکه سیگنال گرفته شده از کانال‌های مختلف مغز افراد در هنگام بروز احساسات مختلف با یکدیگر متفاوت است، بنابراین اگر فرض کنیم که سیگنال یک نمونه دارای  $k$  کانال باشد و طول داده‌های مربوط به هر نمونه برابر  $n$  باشد، استخراج ویژگی از هر کانال صورت می‌گیرد و سپس همه‌ی ویژگی‌ها در یک بردار ذخیره می‌شوند. این بردار حاوی ویژگی‌های استخراج شده از داده‌ای با طول  $n$  است. برای استخراج ویژگی‌ها از ۴ باند فرکانسی مختلف (تتا، آلفا، بتا، گاما) استفاده شد. رنج مربوط به هر یک از باندهای فرکانسی در جدول (۳) آورده شده است.

ابتدا هر کانال به ۴ باند فرکانسی تقسیم‌بندی شد. از داده‌های موجود در هر باند فرکانسی ۱۱ ویژگی زمانی شامل: ماکزیمم، مینیمم، میانگین، واریانس، چولگی<sup>۱۷</sup>، کشیدگی<sup>۱۸</sup>، توان، فعالیت<sup>۱۹</sup>، انرژی، آنتروپی و نرخ عبور از صفر<sup>۲۰</sup> استخراج شد.

$$\min_{\{w_t, \theta\}} \sum_{t=1}^T \left( \frac{1}{n_t} \mathcal{L}(w_t) + G_1(W, M) \right) \quad (۸)$$

$$s. t. M \in \{M_e | M_e = \theta^T \theta, \theta^T \theta = I, \theta \in \mathbb{R}^{h \times d}\}$$

در رابطه (۸)  $h \leq \min(t, d)$  است.  $h$  ابعادی از فضای ویژگی‌هاست که بین وظیفه‌ها مشترک است.  $G_1(W, M)$  به صورت رابطه (۹) تعریف می‌شود:

$$G_1(W, M) = \alpha \eta (1 + \eta) \text{tr}(W^T (\eta I + M)^{-1} W) \quad (۹)$$

با جایگزینی رابطه (۹) در رابطه (۸) به رابطه (۱۰) می‌رسیم:

$$\min_{\{w_t, \theta\}} \sum_{t=1}^T \left( \frac{1}{n_t} \mathcal{L}(w_t) + \alpha \eta (1 + \eta) \text{tr}(W^T (\eta I + M)^{-1} W) \right) \quad (۱۰)$$

$$s. t. M \in \{M_e | M_e = \theta^T \theta, \theta^T \theta = I, \theta \in \mathbb{R}^{h \times d}\}$$

حال برای نمونه  $x$  با برچسب  $y$ ، به جای تابع ضرر  $\mathcal{L}(w_t)$  تابع ضرر لاجستیک در نظر گرفته می‌شود:

$$\mathcal{L}(w_t) = \log(1 + \exp(-y(w_t x + c))) \quad (۱۱)$$

با جایگذاری (۱۱) در (۱۰) خواهیم داشت:

$$\min_{\{W, C\}} \sum_{t=1}^T \sum_{i=1}^{n_t} \log(1 + \exp(-Y_{t,i} (W_i^T X_{t,i} + c_t))) + \alpha \eta (1 + \eta) \text{tr}(W^T (\eta I + M)^{-1} W) \quad (۱۲)$$

$$s. t. M \in \{M_e | M_e = \theta^T \theta, \theta^T \theta = I, \theta \in \mathbb{R}^{h \times d}\}$$

در رابطه (۱۲)،  $X_{t,i}$  نمونه  $i$ ام از وظیفه  $t$ ام است.  $Y_{t,i}$  همان‌طور که گفته شد برچسب داده‌های نفر  $t$ ام است.  $w_t$  و  $c_t$  مدل‌هایی برای وظیفه  $t$ ام هستند.  $\alpha$  پارامتر تنظیم‌سازی است. برای حل رابطه (۱۲) از روش گرادیان کاهشی<sup>۱۵</sup> استفاده شده است.

در پیاده‌سازی روش پیشنهادی از کدهای آماده استفاده شده است. کدها از طریق وبگاه<sup>۱۶</sup> قابل دسترس می‌باشد.

#### ۵- آزمایشات

در این بخش ابتدا دادگان مورد استفاده شرح داده می‌شود. سپس ویژگی‌های استخراج شده به طور کامل معرفی می‌شوند. روش‌های مقایسه و جزئیات پیاده‌سازی بیان می‌شود و در پایان نتایج مربوط به هر مجموعه داده به طور جداگانه گزارش می‌شود.

#### ۵-۱- شرح دادگان

در این پژوهش، از سه مجموعه داده که در حوزه تشخیص احساس از روی سیگنال مغز بسیار معروف هستند استفاده شد. این مجموعه داده‌ها عبارت‌اند از: DEAP، SEED و DREAMER





کردن ناحیه‌ای از مغز است که بیشترین تاثیر را روی احساسات دارد. در ادامه توضیحات مربوطه به طور جداگانه بیان خواهد شد.

**الف) در نظر گرفتن هر کانال به صورت جدا:** در این آزمایش روش پیشنهادی روی هر کانال انجام شد. با توجه به اینکه تعداد ویژگی‌های هر کانال ۵۲۴ است (در بخش ۵-۲ توضیح داده شد)، بُعد فضای نگاشت یافته جدید نیز ۵۲۴ است که برای هر کانال فقط از ۱۰۰ بُعد استفاده شد. در پایان کانال‌هایی که کارایی برابر یا بالای ۷۰ درصد داشتند در هر بُعد احساسی انتخاب شدند. در جدول (۵) کانال‌های انتخاب شده آورده شده است. با توجه به تعداد کانال‌های انتخاب شده در هر مجموعه داده، تعداد ویژگی‌ها متفاوت خواهد بود.

بعد از اینکه کانال‌های مناسب از هر بُعد احساسی انتخاب شدند، با در نظر گرفتن کانال‌های انتخاب شده و با استفاده از روش پیشنهادی، مجدد ویژگی‌ها به فضای جدید نگاشت داده شد. با توجه به اینکه تعداد ویژگی‌ها معمولاً زیاد است، ابعاد فضای جدید بزرگ است، بنابراین لازم است از این فضا ابعاد مناسبی انتخاب شود. تعداد بُعد انتخابی در بازه  $\{100, \dots, 900, \dots, 1000\}$  در نظر گرفته شد و بهترین بُعد بدست آمد. این ابعاد در جدول (۵) آورده شده است. برای مقایسه عادلانه برای سایر روش‌های مقایسه نیز کانال‌ها و ابعاد ذکر شده در جدول (۵) در هر دو بُعد احساسی در نظر گرفته شد. در روش‌های شبکه عصبی با توجه به اینکه فضای نگاشت یافته توسط خود روش به دست می‌آید، بنابراین نیازی به در نظر گرفتن ابعاد ذکر شده در جدول (۵) نیست.

دادگان SEED با داشتن بیشترین کانال، تعداد کانال انتخاب شده بالاتری نسبت به سایر مجموعه‌ها دارد. بنابراین در قسمت بهترین بُعد انتخابی تنها دارای یک ستون است. در دادگان DREAMER چون تعداد کانال‌ها نسبتاً کمتر است، بنابراین تعداد کانال‌های انتخاب شده نیز نسبتاً کمتر خواهد بود.

**ب) در نظر گرفتن کانال‌های مربوط به هر ناحیه:** این آزمایش با در نظر گرفتن کانال‌ها در چهار ناحیه مختلف مغز (جلو سر-عقب سر-نیمکره راست-نیمکره چپ) صورت گرفت و نتایج برای هر سه دادگان به طور جداگانه گزارش شد. در شروع آزمایشات ابتدا تمام کانال‌ها در نظر گرفته شد.

مقادیر برخی از ویژگی‌ها، همه‌ی ویژگی‌های نرمال شده مربوط به هر نفر در عدد ۱۰۰۰ ضرب شد.

در تمام آزمایشات از طبقه‌بند SVM استفاده شد. برای پارامتر C در این طبقه‌بند، ۱۹ مقدار در بازه‌ی  $\{0.1, 0.2, \dots, 1, 0.02, 0.03, \dots, 0.09\}$  در نظر گرفته شد. در ابتدای آزمایشات، داده‌ها به دو دسته تست و آموزش تقسیم‌بندی شدند. با استفاده از اعتبار سنجی به روش یک نفر بیرون (LOSO)<sup>۲۱</sup>، همیشه داده‌های یک نفر برای تست کنار گذاشته شد و با داده‌های افراد باقی مانده عملیات آموزش انجام شد و زیر فضای مشترک بدست آمد. پارامتر C در طبقه‌بند SVM برای روش پیشنهادی و سایر روش‌ها به کمک اعتبار سنجی<sup>۲۲</sup> محاسبه شد.

در مرحله‌ی آموزش با استفاده از داده‌های آموزشی و استفاده از استراتژی LOSO، مجدد یک نفر برای تست کنار گذاشته شد و با سایر افراد باقی‌مانده عملیات آموزش صورت گرفت. مقادیر مختلفی برای پارامتر C در نظر گرفته شد. در نهایت بهترین مقدار که بالاترین میزان کارایی را داشت انتخاب شد.

در مرحله تست، از بهترین مقدار C بدست آمده از مرحله آموزش استفاده شد. یادگیری طبقه‌بند با کل داده‌های آموزشی صورت گرفت. سپس عملیات تست با داده نفری که بیرون بود انجام شد. کل عملیات آموزش و تست به تعداد افراد تکرار شد، در نهایت بین کارایی بدست آمده از تمام افراد میانگین گرفته شد.

جداسازی داده‌ها در کلاس‌های مختلف به این صورت انجام شد که، در دادگان DREAMER با توجه به اینکه برای هر بُعد امتیازات داده شده بین اعداد ۱ تا ۵ است، 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، بنابراین امتیازات بزرگتر و مساوی ۵، در کلاس +۱ و امتیازات کمتر از ۵، در کلاس -۱ قرار گرفتند. در دادگان SEED داده‌های احساسی مثبت در کلاس +۱ و داده‌های احساسی منفی در کلاس -۱ قرار گرفتند.

## ۵-۵- نتایج آزمایشات

روش پیشنهادی به دو صورت روی هر سه مجموعه داده آزمایش شد. در آزمایش اول هر کانال به صورت جداگانه در نظر گرفته شد. هدف این آزمایش مشخص شدن کانال‌هایی است که بیشترین تاثیر را در احساسات دارند. در آزمایش دوم کانال‌های هر ناحیه‌ی مغز جداگانه مورد بررسی قرار گرفت. هدف آزمایش دوم پیدا

جدول ۵: کانال‌های انتخاب شده روی هر مجموعه داده.

کانال‌های انتخاب شده	بهترین تعداد بعد انتخاب شده		تعداد ویژگی‌ها		تعداد کانال‌های انتخاب شده		تعداد کانال‌های اصلی	دادگان	
	ظرفیت	برانگیختگی	ظرفیت	برانگیختگی	ظرفیت	برانگیختگی			
AF3-AF4-F3-F4-T7-O2	AF4-F7-F3-FC5-T7	۳۰۰	۲۰۰	۳۱۴۴	۲۶۲۰	۶	۵	۱۴	DREAMEAR
AF3-AF4-FC5-FC1-FC2-C3-CP5-CP1-P7-O2	AF4-F7-F3-F4-FC5-FC1-C3-CP5-P3-PO3-O2	۴۰۰	۴۰۰	۵۲۴۰	۵۷۶۴	۱۰	۱۱	۳۲	DEAP
FP1-AF4-F7-F5-F1-F2-FC5-FC1-C5-C3-CZ-CPZ-CP4-TP7-P2-P3-P5-PO3-CB1		۸۰۰		۹۹۵۶		۱۹		۶۲	SEED (دوکلاسه، شامل احساسات مثبت و منفی)

جدول ۶: بهترین تعداد بعد انتخابی از هر ناحیه مغز، روی دادگان SEED، DEAP، DREAMEAR.

کانال‌های در نظر گرفته شده	بهترین تعداد بعد انتخاب شده (برانگیختگی)	بهترین تعداد بعد انتخاب شده (ظرفیت)	تعداد ویژگی‌های هر ناحیه	تعداد کانال‌ها	کانال‌ها	دادگان
همه کانال‌ها	۴۵۰	۳۰۰	۷۳۳۶	۱۴	همه	DREAMEAR
AF3- AF4- F7- F8- FC5- FC6- F3- F4	۳۵۰	۳۰۰	۴۱۹۲	۸	جلو سر	
P7- P8- O1- O2	۲۰۰	۲۰۰	۲۰۹۶	۴	عقب سر	
F8- F4- FC6- T8- P8	۲۰۰	۱۵۰	۲۶۲۰	۵	نیمکره راست	
F7- F3- FC5- T7- P7	۱۵۰	۱۵۰	۲۶۲۰	۵	نیمکره چپ	
همه کانال‌ها	۵۵۰	۵۰۰	۱۶۷۶۸	۳۲	همه	DEAP
FP1- FP2- F3- F4- F7- F8- FC5- FC6- FC1- FC2- AF3- AF4 - FZ	۲۰۰	۲۰۰	۶۸۱۲	۱۳	جلو سر	
CP1- CP2- CP5- CP6- P3- P4- P7- P8- Pz- PO3- PO4- O1- O2- Oz	۲۰۰	۲۵۰	۷۳۳۶	۱۴	عقب سر	
FP2- AF4- F4- F8- FC2- FC6- C4- T8- CP2- CP6- P4- P8- PO4- O1	۱۵۰	۱۵۰	۷۳۳۶	۱۴	نیمکره راست	
FP1- AF3- F3- F7- FC1- FC5- C3- T7- CP1- CP5- P3- P7- PO3- O2	۲۰۰	۳۰۰	۷۳۳۶	۱۴	نیمکره چپ	
همه کانال‌ها	۱۵۰۰		۳۲۴۸۸	۶۲	همه	SEED (دوکلاسه، شامل احساسات مثبت و منفی)
FP1- FP2- AF3- AF4- F1- F2- F3- F4- F5- F6- F7- F8- Fz- FC1- FC2- FC3- FC4- FC5- FC6- FT7- FT8- PCz	۵۰۰		۱۱۵۲۸	۲۲	جلو سر	
CP1- CP2- CP3- CP4- CP5- CP6- TP7- TP8- CPZ- P1- P2- P3- P4- P5- P6- P7- P8- Pz- PO3- PO4- PO5- PO6- PO7- PO8- POZ- CB1- CB2- O1- O2- Oz	۷۰۰		۱۵۷۲۰	۳۰	عقب سر	
FP2- AF4- F2- F4- F6- F8- FC2- FC4- FC6- FT8- C2- C4- C6- T8- CP2- CP4- CP6- TP8- P2- P4- P6- P8- PO4- PO6- PO8- CB2- O2	۷۵۰		۱۴۱۴۸	۲۷	نیمکره راست	
FP1- AF3- F1- F3- F5- F7- FC1- FC3- FC5- FT7- C1- C3- C5- T7- CP1- CP3- CP5- TP7- P1- P3- P5- P7- PO3- PO5- PO7- CB1- O1	۸۰۰		۱۴۱۴۸	۲۷	نیمکره چپ	

فضای جدیدی که ویژگی‌ها به آن نگاشت پیدا می‌کنند، ابعادی برابر تعداد ویژگی‌های هر ناحیه دارد. با توجه به اینکه تعداد ویژگی‌ها معمولاً زیاد است، ابعاد این فضا بزرگ است. بنابراین لازم است از این فضای جدید، ابعاد مناسبی انتخاب شود. ابعاد مختلف در بازه {۱۰۰، ۱۵۰، ۲۰۰، ...، ۱۹۵۰، ۲۰۰۰} در نظر گرفته شد و آزمایشات انجام شد. در نهایت بهترین بعد بدست آمده در جدول (۶) برای

در آزمایش بعدی برای درک بهتر تاثیر کانال‌های هر ناحیه، هر قسمت جداگانه بررسی شد و نتایج روی هر ناحیه جداگانه گزارش شد. همان طور که در آزمایش قبلی (۵-۵-الف) اشاره شد، تعداد ویژگی‌های هر ناحیه با توجه به تعداد کانال‌های مربوط به آن متفاوت است. اطلاعات ذکر شده در جدول (۶) این موضوع را نشان می‌دهد.

کرده است. با توجه به اینکه اکثر کانال‌های انتخاب شده از نیمکره چپ مغز هستند، این مسئله نشان می‌دهد که نیمکره چپ مغز بیشترین ارتباط را با احساسات افراد دارد.

در روش‌های مقایسه نیز از کانال‌های انتخابی روش پیشنهادی استفاده شد. بررسی نتایج بدست آمده نشان داد که کارایی این روش‌ها همچنان خوب است و حتی روش شبکه عصبی [۱۸] در بُعد برانگیختگی به روش پیشنهادی بسیار نزدیک است. بنابراین می‌توان نتیجه گرفت کانال‌هایی که روش پیشنهادی انتخاب می‌کند، کانال‌های مرتبط با احساسات است و برای اکثر روش‌ها بسیار مناسب است.

جدول ۷: نتایج بر اساس کانال‌های انتخاب شده در شکل (۴).

#### روى دادگان DEAP

کانال‌های در نظر گرفته شده بر اساس شکل (۴) است.			
برانگیختگی	ظرفیت	بُدهای احساسی	
		روش‌ها	
۷۹.۱۹	۸۰.۳۹	روش پیشنهادی	
۷۷.۴۵	۷۸.۳۳	شبکه	
		عصبی	
۷۸.۱۲	۷۶.۳۲	یادگیری عمیق [۱۶]	
کاهش بُعد	۷۶.۶۴	LDA [۲۰]	
	۷۴.۷۸	PCA [۲۱]	
	۷۳.۲۲	PCA [۲۲]	
	۷۳.۱۴	DM [۲۳]	

(ب) در نظر گرفتن کانال‌های مربوط به هر ناحیه:

در این آزمایش نیز برای هر دو بُعد احساسی به طور جداگانه طبقه‌بند دو کلاس SVM آموزش داده شد و عملیات تست با استراتژی LOSO انجام شد. برای هر بُعد ۵ آزمایش انجام شد. نتایج در جدول (۸) نشان می‌دهد که در هر بُعد احساسی روش پیشنهادی نسبت به سایر روش‌ها فضای کاهش یافته مناسب‌تری پیدا می‌کند. در بُعد ظرفیت، کانال‌های موجود در جلو سر و نیمکره چپ بالاترین میزان کارایی را نسبت به سایر روش‌ها دارند. این مسئله بیانگر این است که روش پیشنهادی در نگاشت ویژگی‌ها به فضای جدید خیلی خوب عمل کرده است طوری که با انتخاب ۳۰۰ بُعد از ۷۰۰۰ بُعد، کارایی قابل قبول است.

روش‌های شبکه عصبی نسبت به روش‌های کاهش بُعد کارایی بهتری دارند و در ناحیه مربوط به نیمکره چپ به روش پیشنهادی نزدیکتر هستند.

هر ناحیه و هر مجموعه داده به طور جداگانه گزارش شد. برای مقایسه عادلانه، برای روش‌های کاهش بُعد در مقایسات، تعداد ابعاد ذکر شده در جدول (۶) در نظر گرفته شد. همان‌طور که در آزمایش قبلی (۵-۵-الف) اشاره شد، در روش شبکه عصبی با توجه به اینکه فضای نگاشت یافته توسط خود روش به دست می‌آید، بنابراین نیازی به در نظر گرفتن ابعاد ذکر شده در جدول (۶) نیست.

همان‌طور که در جدول (۶) مشاهده می‌شود، داده SEED دارای بیشترین تعداد کانال می‌باشد. بنابراین تعداد ویژگی‌ها در این مجموعه داده نسبت به دو مجموعه دیگر بیشتر است. لازم است اشاره شود که داده SEED چون دارای دو کلاس احساسات مثبت و منفی می‌باشد، بنابراین بهترین بُعد این مجموعه داده تنها دارای یک ستون است. همچنین بهترین تعداد بُعد انتخاب شده آن نسبت به سایر مجموعه داده‌ها بیشتر است.


#### ۵-۵-۱- تحلیل و بررسی نتایج بدست آمده روی دادگان DEAP

همان‌طور که در ابتدای این بخش اشاره شد، آزمایشات به دو شکل انجام شد. در این بخش نتایج بدست آمده برای هر آزمایش روی دادگان DEAP بررسی خواهد شد.

الف) در نظر گرفتن هر کانال به صورت جدا:

دادگان DEAP شامل دو بُعد برانگیختگی و ظرفیت است. در هر بُعد احساسی، هر کانال با ۵۲۴ ویژگی به الگوریتم پیشنهادی داده شد. زیر فضای جدید ویژگی‌ها با ابعاد ۵۲۴، به بُعد ۱۰۰ کاهش یافت. سپس طبقه‌بندی صورت گرفت. هدف از انجام این آزمایش یافتن کانال‌هایی است که کارایی نسبتاً بهتری دارند. نتایج در شکل (۴) برای تک تک کانال‌ها نشان داده شده است. با توجه به شکل (۴) روی هر دو بُعد احساسی کانال‌هایی که کارایی برابر یا بالاتر از ۷۰ درصد دارند انتخاب شدند. در شکل (۴)، کانال‌های انتخاب شده با رنگ نارنجی مشخص شده است. اکثر کانال‌هایی که در هر دو بُعد احساسی انتخاب شده‌اند، مربوط به نیمکره چپ مغز می‌باشند. اطلاعات کامل در مورد کانال‌های انتخاب شده و تعداد ویژگی‌ها در جدول (۵) قابل مشاهده است.

در ادامه آزمایشات، کانال‌های انتخاب شده در هر دو بُعد احساسی، (با توجه به شکل (۴)) برای روش پیشنهادی و سایر روش‌های مقایسه در نظر گرفته شد. نتایج در جدول (۷) گزارش شده است و نشان می‌دهد روش پیشنهادی نسبت به سایر روش‌ها بهتر عمل



شکل ۴: نتایج با در نظر گرفتن تک تک کانال‌ها روی دادگان DEAP (الف) ظرفیت، (ب) برانگیختگی).

جدول ۸: نتایج با دو بُعد ظرفیت و برانگیختگی روی دادگان DEAP.

برانگیختگی					ظرفیت					بُدهای احساسی	
نیمکره چپ	نیمکره راست	عقب سر	جلو سر	همه کانال‌ها	نیمکره چپ	نیمکره راست	عقب سر	جلو سر	همه کانال‌ها	کانال‌ها	روش‌ها
۸۱.۳۲	۷۹.۸۹	۷۵.۴۴	۷۸.۲۱	۷۵.۱۳	۸۴.۲۷	۸۰.۰۸	۷۹.۳۱	۸۱.۴۵	۷۸.۲۴		روش پیشنهادی
۷۸.۱۲	۷۷.۳۷	۷۰.۲۰	۷۵.۳۰	۷۲.۵۴	۸۰.۹۸	۷۹.۴۰	۷۳.۸۰	۷۷.۲۱	۷۵.۴۳	[۱۶]	شبکه یادگیری عمیق
۸۰.۴۰	۷۶.۹۳	۷۱.۵۴	۷۵.۱۲	۷۴.۰۱	۸۱.۳۰	۷۳.۵۰	۷۲.۶۱	۷۵.۲۳	۷۶.۸۰	[۱۸]	عصبی یادگیری عمیق
۷۵.۳۰	۷۳.۵۵	۷۰.۱۰	۷۰.۴۵	۶۸.۳۴	۷۵.۲۱	۷۲.۱۷	۷۵.۷۵	۷۲.۰۱	۷۱.۲۳	[۲۰]	LDA
۷۳.۰۴	۶۸.۸۹	۷۱.۵۳	۷۳.۰۸	۷۱.۲۹	۷۴.۳۱	۶۸.۲۴	۷۱.۴۷	۷۳.۴۷	۷۰.۲۰	[۲۱]	PCA
۷۴.۵۳	۷۱.۱۲	۷۳.۰۲	۷۵.۹۸	۷۲.۱۹	۶۸.۳۸	۷۰.۴۶	۷۲.۷۴	۷۵.۶۰	۶۹.۹۵	[۲۲]	PCA
۷۳.۰۴	۷۲.۴۹	۷۰.۸۱	۷۲.۱۷	۷۰.۱۲	۷۳.۱۹	۷۰.۷۱	۶۹.۸۲	۷۲.۳۱	۷۰.۰۳	[۲۳]	DM

نتایج نشان می‌دهد که کانال‌های موجود در نیمکره چپ مغز با بروز احساسات نسبت به سایر نواحی تحریک بیشتری دارند. این مسئله در [۲۲] نیز اشاره شده است. لازم است اشاره شود که میزان پراکندگی داده‌ها در این مجموعه داده بین ۳ تا ۴ است.

#### ۵-۲- تحلیل و بررسی نتایج روی دادگان DREAMER

در این مجموعه داده نیز آزمایشات به دو شکل انجام شد. نتایج در ادامه بررسی خواهد شد.

#### الف) در نظر گرفتن هر کانال به صورت جدا:

روی هر دو بُعد ظرفیت و برانگیختگی تک تک کانال‌ها مورد بررسی قرار گرفت. در این دادگان نیز مشابه دادگان DEAP، هر کانال با ۵۲۴ بُعد به ۱۰۰ بُعد کاهش یافت و طبقه‌بندی روی هر دو بُعد احساسی به طور جداگانه انجام شد. نتایج ارائه شده در شکل (۵) نشان می‌دهد کانال‌هایی که مربوط به نیمکره چپ مغز هستند کارایی بیشتری دارند.

با توجه به اینکه هدف این آزمایش انتخاب کانال با بالاترین کارایی

اما در روش‌های کاهش بُعد، LDA بهتر عمل کرده است و در ناحیه عقب مغز نسبت به سایر روش‌های مقایسه کارایی بهتری دارد. روش LDA یک روش کاهش بُعد با ناظر است و در نگاشت ویژگی‌ها به فضای جدید برجسب کلاس‌ها را در نظر می‌گیرد. بنابراین سبب می‌شود فضای بدست آمده مرتبط به برجسب کلاس‌ها بوده و کارایی بهتری داشته باشد. اما روش‌های مبتنی بر PCA چون در نگاشت ویژگی‌ها به فضایی جدید برجسب ویژگی‌ها را در نظر نمی‌گیرند، بنابراین در برخی مواقع مثل نیمکره راست مغز کارایی پایین‌تری دارند. روش DM در ناحیه عقب مغز نسبت به سایر نواحی کارایی پایین‌تری دارد. DM یک روش کاهش بُعد غیر خطی است که در نگاشت ویژگی‌ها به فضای جدید فاصله بین آن‌ها را در نظر می‌گیرد.

در بُعد برانگیختگی، در تمام نواحی روش پیشنهادی بهتر عمل کرده است. در برخی نواحی مغز مثل نیمکره راست روش [۱۶] و در نیمکره چپ روش [۱۸] به روش پیشنهادی نزدیک است. اما در برخی نواحی دیگر مثل عقب مغز روش کاهش بُعد [۲۲] PCA به روش پیشنهادی نزدیک‌تر می‌باشند.

ب) در نظر گرفتن کانال‌های مربوط به هر ناحیه:

در این آزمایش هم مشابه دادگان DEAP، ۵ آزمایش روی هر دو بُعد احساسی انجام شد. نتایج ارائه شده در جدول (۱۰) نشان می‌دهد، فضایی که روش پیشنهادی ویژگی‌ها را به آن نگاشت می‌دهد نسبت به سایر روش‌ها بهتر است.

همان طور که در جدول (۱۰) مشاهده می‌شود، اختلاف روش پیشنهادی با روش‌های شبکه عصبی ناچیز است. در بُعد ظرفیت، برای مثال در ناحیه نیمکره راست مغز اختلاف روش شبکه عصبی [۱۸] با روش پیشنهادی تقریباً ۱ درصد است. در ناحیه عقب سر روش [۱۸] کارایی تقریباً برابر با روش پیشنهادی دارد. اما تقریباً تمام روش‌های کاهش بُعد اختلاف چشمگیری با روش پیشنهادی دارند. در بُعد برانگیختگی هم مشابه بُعد ظرفیت، با در نظر گرفتن همه کانال‌ها و کانال‌های موجود در ناحیه عقب سر، روش پیشنهادی با روش‌های شبکه عصبی کارایی تقریباً برابر دارد. در روش‌های کاهش بُعد اختلاف یک تا سه درصد وجود دارد. نتایج نشان می‌دهد این مجموعه داده با داشتن تعداد کانال کمتر نسبت به دو مجموعه دیگر کارایی پایین‌تری دارد. در نتیجه نبودن برخی کانال‌ها باعث افت کارایی می‌شود. لازم است اشاره شود که میزان پراکندگی داده‌ها بین ۲.۵ تا ۳ است.

### ۵-۳- تحلیل و بررسی نتایج بدست آمده روی دادگان SEED


نتایج بدست آمده برای هر آزمایش در ادامه بررسی خواهد شد.

الف) در نظر گرفتن هر کانال به صورت جدا:

این مجموعه داده شامل دو کلاس احساسات مثبت و منفی است. ویژگی‌های هر کانال با استفاده از روش پیشنهادی به بُعد ۵۲۴ نگاشت داده شد. در نهایت تنها ۱۰۰ بُعد از این فضا مورد استفاده قرار گرفت. در پایان تک تک کانال‌ها SVM دو کلاسه آموزش داده شد.

مشابه سایر دادگان، کانال‌هایی که کارایی برابر یا بالاتر از ۷۰ درصد داشتند انتخاب شدند. کانال‌های انتخاب شده با رنگ مشکی در شکل (۶) مشخص شده‌اند. اکثر کانال‌های انتخاب شده از نیمکره چپ هستند. اطلاعات کامل در مورد کانال‌های انتخاب شده و تعداد ویژگی‌ها در جدول (۵) آورده شده است. کانال‌های انتخاب شده، برای روش پیشنهادی و روش‌های مقایسه در نظر گرفته شد و نتایج در جدول (۱۱) گزارش شد.

است، بنابراین کانال‌هایی که کارایی برابر یا بالاتر از ۷۰ درصد داشتند انتخاب شدند. کانال‌های انتخاب شده با رنگ زرد در شکل (۵) مشخص شده‌اند. اطلاعات در مورد کانال‌های انتخاب شده و تعداد ویژگی‌ها در جدول (۵) آورده شده است.



شکل ۵: نتایج با در نظر گرفتن تک تک کانال‌ها روی دادگان DREAMER (الف) ظرفیت، ب) برانگیختگی).

جدول ۹: نتایج بر اساس کانال‌های انتخاب شده در شکل (۵)،

### روی دادگان DREAMER


کانال‌های در نظر گرفته شده بر اساس شکل (۵) است.			
روش‌ها	بعدهای احساسی		برانگیختگی
	ظرفیت	ظرفیت	
روش پیشنهادی	۷۶.۰۲	۷۵.۸۹	
شبکه عصبی	یادگیری عمیق [۱۶]	۷۵.۴۳	۷۵.۲۲
	یادگیری عمیق [۱۸]	۷۶.۵۴	۷۴.۶۰
کاهش بُعد	LDA [۲۰]	۷۳.۸۷	۷۳.۵۱
	PCA [۲۱]	۷۴.۲۹	۷۵.۰۶
	PCA [۲۲]	۷۲.۱۳	۷۳.۷۲
	DM [۲۳]	۷۰.۹۳	۷۱.۶۳

در ادامه آزمایشات این قسمت، کانال‌های انتخاب شده (در شکل (۵) مشخص شده‌اند) برای روش پیشنهادی و روش‌های مقایسه در نظر گرفته شد. نتایج گزارش شده در جدول (۹) نشان می‌دهد که کارایی روش پیشنهادی نسبت به روش‌های کاهش بُعد بالاتر است، اما روش‌های شبکه عصبی [۱۸] در بُعد ظرفیت و [۱۶] در بُعد برانگیختگی، به روش پیشنهادی نزدیک هستند. همچنین اختلاف ناچیز در بُعد ظرفیت نشان می‌دهد که کانال‌های انتخاب شده توسط روش پیشنهادی کانال‌های نسبتاً مناسبی است که سبب افت کارایی در روش‌های مقایسه نشده است.

جدول ۱۰: نتایج با دو بُعد ظرفیت و برانگیختگی روی دادگان DREAMER

برانگیختگی					ظرفیت					بُدهای احساسی	
نیمکره چپ	نیمکره راست	عقب سر	جلو سر	همه کانال‌ها	نیمکره چپ	نیمکره راست	عقب سر	جلو سر	همه کانال‌ها	کانال‌ها	روش‌ها
۷۴.۸۳	۷۰.۰۱	۷۱.۵۴	۷۲.۱۳	۷۱.۴۵	۷۸.۴۳	۷۵.۱۵	۷۳.۸۲	۷۶.۲۴	۷۳.۵۰	روش پیشنهادی	
۷۲.۳۱	۶۹.۳۶	۷۰.۸۲	۷۱.۴۳	۷۱.۰۲	۷۵.۱۷	۷۲.۶۳	۷۱.۴۱	۷۳.۴۶	۷۰.۱۴	[۱۶]	شبکه عصبی
۷۱.۲۱	۷۰.۸۱	۷۱.۱۴	۷۱.۴۷	۶۹.۵۶	۷۶.۳۵	۷۴.۰۲	۷۳.۸۴	۷۳.۲۹	۷۱.۲۰	[۱۸]	شبکه عصبی
۷۲.۱۵	۷۰.۰۴	۶۹.۳۱	۶۹.۵۲	۶۸.۱۳	۷۴.۳۲	۷۲.۴۷	۷۱.۷۹	۷۱.۷۳	۶۹.۴۶	[۲۰]	کاهش بُعد
۷۱.۵۶	۶۹.۱۴	۷۰.۹۶	۷۰.۸۳	۶۸.۹۳	۷۲.۰۳	۶۹.۷۰	۷۰.۶۳	۷۲.۱۶	۷۰.۲۰	[۲۱]	
۷۱.۰۹	۶۹.۸۴	۷۰.۴۱	۷۰.۰۲	۶۹.۰۲	۷۲.۱۳	۷۰.۷۷	۷۰.۱۲	۷۲.۶۹	۷۰.۰۶	[۲۲]	
۷۰.۵۷	۶۹.۰۸	۷۰.۲۱	۷۱.۴۳	۷۰.۴۶	۷۳.۹۳	۷۲.۸۳	۷۲.۵۶	۷۳.۰۱	۷۱.۲۷	[۲۳]	

احساسات مثبت و منفی



شکل ۶: نتایج با در نظر گرفتن تک تک کانال‌ها روی دادگان SEED (احساسات مثبت و منفی).

جدول ۱۱: نتایج بر اساس کانال‌های انتخاب شده در شکل (۶)، روی دادگان SEED.

کانال‌های در نظر گرفته شده بر اساس شکل (۶) است.	
کلاس احساسات مثبت و منفی	احساسات
۷۹.۱۸	روش پیشنهادی
۷۶.۴۵	شبکه عصبی
۷۷.۲۱	یادگیری عمیق [۱۸]
۷۵.۳۱	LDA [۲۰]
۷۳.۸۵	PCA [۲۱]
۷۵.۷۳	PCA [۲۲]
۷۱.۸۶	DM [۲۳]

علاوه بر اینکه روش پیشنهادی بالاترین میزان کارایی را در این مجموعه داده دارد، روش‌های مقایسه نیز با در نظر گرفتن کانال‌های انتخاب شده در شکل (۶) کارایی قابل قبولی دارند. روش [۱۸] به روش پیشنهادی نزدیک‌تر است. اما روش DM کارایی پایین‌تری دارد.

ب) در نظر گرفتن کانال‌های مربوط به هر ناحیه:

با توجه به اینکه تعداد کانال‌ها در این مجموعه نسبت به سایر مجموعه‌ها بیشتر است، واضح است که تعداد ویژگی‌ها نیز بیشتر خواهد بود. این تعداد در جدول (۶) قابل مشاهده است. همچنین بهترین تعداد بُعد انتخابی نیز در این مجموعه داده نسبت به سایر مجموعه داده‌ها ابعاد بالاتری دارد.

جدول ۱۲: نتایج با دو کلاس احساسات مثبت و منفی روی دادگان SEED.

احساسات مثبت و منفی					کلاس‌ها	
نیمکره چپ	نیمکره راست	عقب سر	جلو سر	همه کانال‌ها	کانال‌ها	روش‌ها
۸۳.۰۲	۸۰.۳۹	۷۹.۸۹	۸۱.۰۲	۷۹.۴۵	روش پیشنهادی	
۷۹.۸۸	۷۵.۲۷	۷۵.۷۰	۷۶.۵۱	۷۴.۹۱	[۱۶]	شبکه عصبی
۷۸.۱۲	۷۶.۵۹	۷۸.۱۴	۷۷.۱۳	۷۶.۲۹	[۱۸]	شبکه عصبی
۷۴.۵۶	۷۱.۸۹	۷۱.۲۰	۷۳.۰۲	۷۲.۳۸	[۲۰]	کاهش بُعد
۷۵.۲۱	۷۲.۶۳	۷۳.۸۴	۷۵.۲۱	۷۴.۹۳	[۲۱]	
۷۵.۱۳	۷۴.۳۳	۷۴.۳۷	۷۳.۴۷	۷۴.۱۸	[۲۲]	
۷۴.۱۱	۷۳.۵۴	۷۳.۶۹	۷۴.۰۹	۷۲.۳۱	[۲۳]	

مغز هستند. این مسئله نشان می‌دهد که وجود کانال‌های مرکزی مغز مهم است و با احساسات ارتباط نزدیکی دارد و نبود آن‌ها در DREAMER سبب کاهش کارایی شده است. اما دادگان SEED و DEAP با داشتن تعداد کانال بیشتر کارایی بهتری دارند. همچنین وجود ۶۲ کانال در داده SEED سبب می‌شود تعداد ویژگی‌های این مجموعه نسبت به DEAP و DREAMER بیشتر باشد. در نتیجه از زیر فضای بدست آمده تعداد بُعد بیشتری انتخاب شود و به همان نسبت کارایی افزایش یابد.

همچنین مقالات [۲۹-۳۰] در حوزه گفتار و به کمک روش‌های چند وظیفه‌ای انتخاب ویژگی انجام می‌دهند. مقاله [۳۱] نیز در حوزه سیگنال‌های مغزی است و به کمک روش چند وظیفه‌ای انتخاب ویژگی انجام می‌دهد. تفاوت مقاله [۳۱] با مقاله حاضر این است که: ۱- مقاله [۳۱] انتخاب ویژگی است. بنابراین ماهیت ویژگی‌ها تغییر نمی‌کند. ویژگی جدیدی ساخته نمی‌شود و فقط از بین ویژگی‌های موجود، آنهایی که بهتر هستند انتخاب می‌شوند. در حالی که مقاله حاضر کاهش بُعد است. در روش‌های کاهش بُعد یادگیری ویژگی اتفاق می‌افتد. در واقع با نگاشت ویژگی‌ها به فضای جدید ماهیت ویژگی‌ها تغییر می‌کند و ویژگی‌های جدیدی به وجود می‌آید. که نسبت به ویژگی‌های اولیه بهتر عمل می‌کنند. ۲- در مقاله [۳۱] از دو دادگان DEEP و DREAMER استفاده شده است. در حالی که در مقاله حاضر از سه مجموعه داده DEEP، DREAMER و SEED استفاده شده است. ۳- کارایی مقاله حاضر روی مجموعه دادگان مشترک از مقاله [۳۱] بالاتر است.

با توجه به نتایج بدست آمده، در هر سه مجموعه داده، کارایی نیمکره چپ بالاتر است، بنابراین می‌توان نتیجه گرفت کانال‌های موجود در ناحیه نیمکره چپ مغز بیشترین ارتباط را با احساسات افراد دارند.

همچنین با توجه به اینکه، زمان اجرای الگوریتم امری مهم است، تحقیقات نشان داد که مدت زمانی که طول می‌کشد تا ویژگی‌ها به یک فضای جدید نگاشت پیدا کنند در الگوریتم پیشنهادی نسبت به روش‌های مورد مقایسه کمتر است. مدت زمان مربوط به هر روش در جدول (۱۳) آورده شده است. بر اساس میانگین زمان نگاشت ویژگی‌ها به فضای جدید در تمام پنج آزمایش (تمام کانال‌ها- جلو سر- عقب سر- نیمکره راست- نیمکره چپ) بعلاوه زمان آموزش طبقه‌بند است.

مدت زمان ذکر شده برای دادگان DEAP و DREAMER مربوط به بُعد ظرفیت است (با توجه به این که تعداد ویژگی‌ها در هر دو بُعد یکسان است، برای بُعد برانگیختگی هم مدت زمان

نتایج جدول (۱۲) نشان می‌دهد که روش پیشنهادی، در نگاشت ویژگی‌ها به فضای جدید نسبتاً خوب عمل کرده است. میزان کارایی در ناحیه مربوط به نیمکره چپ مغز از سایر نواحی بالاتر است. بعد از آن، کانال‌های ناحیه جلو سر کارایی قابل قبولی دارند. روش‌های شبکه عصبی و کاهش بُعد نسبت به روش پیشنهادی اختلاف بالایی دارند. بالاترین میزان کارایی در روش‌های مقایسه مربوط به روش [۱۶] و [۱۸] در نیمکره چپ مغز است. میزان پراکندگی داده‌ها بین ۲.۵ تا ۴ است.

## ۶- بحث و نتیجه‌گیری

با توجه به اینکه معمولاً بُعد ماتریس ویژگی‌ها بالاست و بیش‌برازش داده سبب کاهش کارایی طبقه‌بند می‌شود، هدف از این پژوهش یادگیری ویژگی‌ها و نگاشت آن‌ها به فضایی است که موثرتر از فضای اولیه ویژگی‌ها عمل کند و با انتخاب ابعاد مناسبی از این فضا کارایی طبقه‌بند قابل قبول باشد. برای رسیدن به این هدف، روشی مبتنی بر رویکرد چندوظیفه‌ای ارائه شد که ویژگی‌ها را به یک فضای جدید انتقال می‌دهد و با انتخاب ابعاد مناسبی از این فضا کارایی طبقه‌بند افزایش می‌یابد. در این مقاله آزمایشات به دو شکل انجام شد. در آزمایش اول ابتدا تک تک کانال‌ها در نظر گرفته شد. در این آزمایش کانال‌هایی با کارایی بالا انتخاب شدند. در ادامه، آزمایش با کانال‌های انتخاب شده صورت گرفت. اکثر کانال‌های انتخاب شده در هر سه مجموعه داده DEEP، DREAMER و SEED مربوط به نیمکره چپ مغز هستند و با در نظر گرفتن کانال‌های انتخاب شده کارایی روش پیشنهادی و سایر روش‌ها قابل قبول است. آزمایش دوم روی کانال‌های مربوط به ۴ ناحیه مختلف مغز (جلو سر- عقب سر- نیمکره راست- نیمکره چپ) و روی هر سه مجموعه داده صورت گرفت. نتایج بدست آمده نشان داد که کارایی روش پیشنهادی در هر دو آزمایش نسبت به سایر روش‌های مورد مقایسه قابل قبول می‌باشد. بنابراین روش کاهش بُعد پیشنهادی باعث افزایش کارایی طبقه‌بندها شده است.

در میان روش‌های مورد مقایسه روش‌های مبتنی بر شبکه عصبی نسبت به سایر روش‌ها کارایی بهتری داشته و در برخی موارد به روش پیشنهادی نزدیکتر می‌باشند. روش‌های کاهش بُعد در اکثر موارد نسبت به روش پیشنهادی اختلاف دارند.

بین نتایج بدست آمده از سه مجموعه داده، DREAMER کارایی پایین‌تری نسبت به سایر مجموعه‌ها دارد. DREAMER تعداد کانال کمتری نسبت به دو مجموعه دیگر دارد و اکثر کانال‌های در نظر گرفته شده در این مجموعه در نواحی اطراف



- [5] N .Sebe , et al. "Multimodal approaches for emotion recognition: a survey." *Internet Imaging VI*. Vol. 5670. International Society for Optics and Photonics, (2005).
- [6] M.Grimm, and K. Kroschel. "Rule-based emotion classification using acoustic features." in *Proc. Int. Conf. on Telemedicine and Multimedia Communication*.( 2005).
- [7] 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).
- [8] Y. Yan, Li .Chenyang, and M. Shaoliang. "Emotion recognition based on sparse learning feature selection method for social communication." *Signal, Image and Video Processing*, 1-5,(2019).
- [9] 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).
- [10] L.Piho, and T. Tjahjadi. "A mutual information based adaptive windowing of informative EEG for emotion recognition." *IEEE Transactions on Affective Computing*,(2018).
- [11] 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).
- [12] 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).
- [13] J. Jaeger, "Tutorial on training recurrent neural networks, covering BPPT, RTRL, EKF and the "echo state network" approach. Vol. 5. Bonn: GMD-Forschungszentrum Informationstechnik, (2002).
- [14] Z.Mohammadi, J. Frounchi, and M. Amiri. "Wavelet-based emotion recognition system using EEG signal." *Neural Computing and Applications* 28.8: 1985-1990, (2017).
- [15] Y.Li , W.Zheng, L.Wang , Y. Zong, & T. Song, "A Novel Bi-hemispheric Discrepancy Model for EEG Emotion Recognition". *arXiv preprint arXiv:1906.01704*, (2019).
- [16] J. X. Chen, P. W. Zhang, Z. J.Mao, & Zhang, Y. N. Accurate EEG-based emotion recognition on combined features using deep convolutional neural networks. *IEEE Access*, 7, 44317-44328, (2019).
- [17] T. Song, W. Zheng, P. Song, & , Z. Cui. "EEG emotion recognition using dynamical graph convolutional neural networks". *IEEE Transactions on Affective Computing*, (2018).
- [18] Y. Ding, N. Zeng, , & C. Guan, "TSception: A Deep Learning Framework for Emotion Detection Using EEG". *arXiv preprint arXiv:2004.02965*,. (2020).
- [19] W. L. Zheng , & B. L. Lu, "Investigating critical frequency bands and channels for EEG-based emotion recognition with deep neural networks". *IEEE Transactions on Autonomous Mental Development*, 7(3), 162-175. (2015).
- [20] M. Bilucaglia, G. M. Duma, G. Mento, L. Semenzato, & P ,Tressoldi. "Applying machine learning EEG signal classification to emotion-related brain anticipatory activity". *F1000Research*, 9(173), 173. (2020).
- [21] X. Xing, et al. "Diagnosis of OCD using functional connectome and Riemann kernel PCA." *Medical Imaging 2019: Computer-Aided Diagnosis*. Vol. 10950. International Society for Optics and Photonics, (2019).
- [22] M. A .Rahman, M. F. Hossain, & R. Ahmmed, "Employing PCA and t-statistical approach for feature extraction and classification of emotion from multichannel EEG signal". *Egyptian Informatics Journal*, 21(1), 23-35. (2020).
- [23] H. Ullah, M. Uzair , A. Mahmood, M. Ullah, S. D. Khan & F. A. Cheikh, "Internal emotion classification using EEG signal with sparse discriminative ensemble". *IEEE Access*, 7, 40144-40153. (2019).
- [24] 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).
- [25] B.Zhang , E. M.Provost, & G.Essl,"Cross-corpus acoustic emotion recognition from singing and speaking: A multi-task learning

صرف شده تقریباً اعداد داخل جدول (۱۳) است) و برای دادگان SEED مربوط به دو کلاس احساسات مثبت و منفی است. اعداد ذکر شده در جدول (۱۳) برای روش‌های شبکه عصبی مربوط به کل زمان انجام کار است. زیرا روش‌های شبکه عصبی زیرفضای نگاشت یافته را بدست می‌آورند و سپس طبقه‌بندی می‌کنند و با توجه به اینکه حالت‌های مختلفی را بررسی می‌کنند تا به زیرفضای مناسب برسند، بنابراین مدت زمان اجرای آن‌ها بالاست. روش‌های کاهش بُعد، هر چند کارایی پایین‌تری نسبت به روش‌های شبکه عصبی دارند، اما مدت زمان اجرای آن‌ها کمتر است.

در پایان می‌توان نتیجه گرفت که الگوریتم ارائه شده در این مقاله علاوه بر حل مشکل بیش‌برازش داده‌ها و بهبود کارایی، زمان اجرای کوتاه‌تری دارد و کاربر را در مدت زمان مطلوب به جواب دلخواه می‌رساند. اما با استفاده از سایر روش‌ها در زمان طولانی‌تری به جواب مناسب خواهیم رسید. بنابراین می‌توان گفت مدت زمان اجرای الگوریتم نیز بسیار مهم است، چرا که اگر طولانی باشد خسته کننده خواهد بود و سبب می‌شود الگوریتم ارائه شده کمتر مورد استفاده قرار گیرد.

جدول ۱۳: میانگین زمان نگاشت ویژگی‌ها به فضای جدید + مدت زمان آموزش طبقه‌بند (علامت دقیقه، "علامت ثانیه).

SEED	DREAMER	DEAP	دادگان	
۴':۳۶"	۲':۱۶"	۳':۰۶"	روش پیشنهادی	
۹':۴۸"	۶':۵۶"	۸':۱۱"	یادگیری عمیق [۱۶]	شبکه عصبی
۱۰':۰۱"	۶':۱۲"	۷':۳۶"	یادگیری عمیق [۱۸]	
۵':۳۲"	۴':۰۰"	۴':۱۶"	[۲۰] LDA	کاهش بُعد
۵':۵۰"	۳':۵۱"	۵':۲۸"	[۲۱] PCA	
۵':۱۲"	۳':۰۰"	۴':۴۲"	[۲۲] PCA	
۶':۴۱"	۴':۰۲"	۴':۲۳"	[۲۳] DM	

## مراجع

- [1] RW .Picard, E .Vyzas, J .Healey. "Toward machine emotional intelligence: Analysis of affective physiological state". *Pattern Analysis and Machine Intelligence*, IEEE Transactions on;23(10):1175-91. (2001).
- [2] P .Ekman, Levenson RW, Friesen WV. "Autonomic nervous system activity distinguishes among emotions." *Science*;221(4616):1208-10.(1983).
- [3] E. A . Murray, S. P Wise.. "the Evolution of Memory Systems: Ancestors, anatomy, and adaptations". Oxford University Press. (2017)
- [4] E. Douglas-Cowie, R. Cowie, & M. Schröder, "A new emotion database: considerations, sources and scope". In *ISCA tutorial and research workshop (ITRW) on speech and emotion*, (2000).

- <sup>3</sup> Sparse Learning
- <sup>4</sup> Mutual Information
- <sup>5</sup> Echo State Network
- <sup>6</sup> convolutional neural network
- <sup>7</sup> Deep Belief Network
- <sup>8</sup> Linear discriminant analysis
- <sup>9</sup> Principal Component Analysis
- <sup>10</sup> Diffusion Map
- <sup>11</sup> Arousal
- <sup>12</sup> Valance
- <sup>13</sup> dominance
- <sup>14</sup> Convex relaxation
- <sup>15</sup> Gradient Descent
- <sup>16</sup> <http://research.microsoft.com/apps/pubs/?id=264770>
- <sup>17</sup> Skewness
- <sup>18</sup> kurtosis
- <sup>19</sup> activity
- <sup>20</sup> zero crossing
- <sup>21</sup> Leave-One-Subject-Out (LOSO)
- <sup>22</sup> Cross-Validation

- approach". In *2016 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)* (pp. 5805-5809). IEEE. (2016).
- [26] R.Xia , & Y.Liu, "A multi-task learning framework for emotion recognition using 2D continuous space". *IEEE Transactions on affective computing*, 8(1), 3-14. (2015).
  - [27] B.Zhang , E. M.Provost, & G.Essl, "Cross-corpus acoustic emotion recognition with multi-task learning: Seeking common ground while preserving differences". *IEEE Transactions on Affective Computing*, 10(1), 85-99. (2017).
  - [28] F.Ma, W.Gu, W.Zhang, , S.Ni , S. L.Huang, & L.Zhang,. "Speech emotion recognition via attention-based dnn from multi-task learning". In *Proceedings of the 16th ACM Conference on Embedded*. (2018).
  - [29] Kalhor, E., & Bakhtiari, B. (2021). Speaker independent feature selection for speech emotion recognition: A multi-task approach. *Multimedia Tools and Applications*, 80(6), 8127-8146.
  - [30] Kalhor, E., & Bakhtiari, B. (2021). Multi-Task Feature Selection for Speech Emotion Recognition: Common Speaker-Independent Features Among Emotions. *Journal of AI and Data Mining*, 9(3), 269-282.
  - [31] Kalhor, E., & Bakhtiari, B. (2021). Subject-Independent Channel and Feature Selection for Emotion Classification Based on EEG Signal: A Multi-Task Approach. *Journal of Control*, 15(2), 139-157.
  - [32] D.Le, Z.Aldeneh , & E. M.Provost, "Discretized Continuous Speech Emotion Recognition with Multi-Task Deep Recurrent Neural Network". In *Interspeech* (pp. 1108-1112), (2017).
  - [33] 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).
  - [34] S. Liang, et al. "Efficient recovery of jointly sparse vectors." *Advances in Neural Information Processing Systems*. (2009).
  - [35] J. Chen, et al. "A convex formulation for learning shared structures from multiple tasks." *Proceedings of the 26th Annual International Conference on Machine Learning*. ACM, (2009).
  - [36] J. Zhou, C. Jianhui, and Ye .Jieping. "Clustered multi-task learning via alternating structure optimization." *Advances in neural information processing systems*. (2011).
  - [37] S. Koelstra, et al. "Deap: A database for emotion analysis; using physiological signals." *IEEE transactions on affective computing* 3.1: 18-31. (2012),
  - [38] S. Wright , and C. Osvaldo. "[Dataset:] Seed data per trap for 18 Barro Colorado Island tree species for the period 2008-2012." (2016).
  - [39] 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).
  - [40] 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).
  - [41] B. Schuller, et al., "Cross-corpus acoustic emotion recognition: Variances and strategies". *IEEE Transactions on Affective Computing*, 1(2): p. 119-131.(2010.).

پاورقی ها:

<sup>1</sup> Electroencephalography -EEG

<sup>2</sup> Min-Redundancy-Max-Relevance