

بِسْمِ اللَّهِ الرَّحْمَنِ الرَّحِيمِ



دانشکده مهندسی برق و رباتیک
گروه الکترونیک

پایان نامه کارشناسی ارشد

شناسایی احساسات بامطالعه اثر ویژگی‌های فرکانسی و آماری
سیگنال الکتروانسفالوگرام

رقیه خدادادی طاقانکی

استاد راهنما:

دکتر علیرضا احمدی فرد

استاد مشاور:

دکتر سعیده فردوسی

بهمن ۱۳۹۴

دانشگاه شاهرود

دانشکده: برق و رباتیک

گروه: الکترونیک

پایان نامه کارشناسی ارشد خانم رقیه خدادادی طاقانکی

تحت عنوان:

شناسایی احساسات با مطالعه اثر ویژگی های فرکانسی و آماری

سیگنال الکتروانسفالوگرام

در تاریخ توسط کمیته تخصصی زیر جهت اخذ مدرک
کارشناسی ارشد مورد ارزیابی و با درجه
..... مورد پذیرش قرار گرفت.

امضاء	اساتید مشاور	امضاء	اساتید راهنما
	دکتر سعیده فردوسی		دکتر علیرضا احمدی فرد

امضاء	نماینده تحصیلات تکمیلی	امضاء	اساتید داور
	نام و نام خانوادگی :		نام و نام خانوادگی :
			نام و نام خانوادگی :
			نام و نام خانوادگی :
			نام و نام خانوادگی :

تقدیم به

پدر بزرگوار و مادر مهربانم که مهر آسمانی‌شان آرام‌بخش آلام زمینی‌ام
است

عزیزانی که بودنشان تاج افتخاری است بر سرم و نامشان دلیلی است بر
بودنم

و تقدیم به

همسر عزیزم که نشانه لطف الهی در زندگی من است.

تشکر و قدردانی

سپاس بی‌کران پروردگار یکتا را که هستی‌مان بخشید و به طریق علم و دانش رهنمونمان شد و به هم‌نشینی رهروان علم و دانش مفتخرمان نمود و خوشه‌چینی از علم و معرفت را روزی‌مان ساخت.

نمی‌توانم معنایی بالاتر از تقدیر و تشکر بر زبانم جاری سازم و سپاس خود را در وصف استادان خویش آشکار نمایم که هر چه گویم و سراپم، کم گفته‌ام.

از استاد گرامیم جناب آقای دکتر علیرضا احمدی فرد بسیار سپاسگزارم چراکه بدون راهنمایی‌های ایشان تأمین این پایان‌نامه بسیار مشکل می‌نمود.

از سرکار خانم دکتر سعیده فردوسی به دلیل یاری‌ها و راهنمایی‌های بی‌چشمداشت ایشان که بسیاری از سختی‌ها را برایم آسان‌تر نمودند نهایت تشکر را دارم.

تعهد نامه

اینجانب رقیه خدادادی طاقانکی دانشجوی دوره کارشناسی ارشد رشته الکترونیک دانشکده برق و رباتیک دانشگاه صنعتی شاهرود نویسنده پایان نامه شناسایی احساسات با مطالعه اثر ویژگی‌های فرکانسی و آماری سیگنال الکتروانسفالوگرام تحت راهنمایی دکتر علیرضا احمدی فرد متعهد می‌شوم .

- تحقیقات در این پایان نامه توسط اینجانب انجام شده است و از صحت و اصالت برخوردار است .
- در استفاده از نتایج پژوهش‌های محققان دیگر به مرجع مورداستفاده استناد شده است .
- مطالب مندرج در پایان نامه تاکنون توسط خود یا فرد دیگری برای دریافت هیچ نوع مدرک یا امتیازی در هیچ جا ارائه نشده است .
- کلیه حقوق معنوی این اثر متعلق به دانشگاه صنعتی شاهرود است و مقالات مستخرج با نام « دانشگاه صنعتی شاهرود » و یا « Shahrood University of Technology » به چاپ خواهد رسید .
- حقوق معنوی تمام افرادی که در به دست آمدن نتایج اصلی پایان نامه تأثیرگذار بوده اند در مقالات مستخرج از پایان نامه رعایت می‌گردد.
- در کلیه مراحل انجام این پایان نامه ، در مواردی که از موجود زنده (یا بافتهای آنها) استفاده شده است ضوابط و اصول اخلاقی رعایت شده است .
- در کلیه مراحل انجام این پایان نامه، در مواردی که به حوزه اطلاعات شخصی افراد دسترسی یافته یا استفاده شده است اصل رازداری ، ضوابط و اصول اخلاق انسانی رعایت شده است .

تاریخ

مالکیت نتایج و حق نشر

- کلیه حقوق معنوی این اثر و محصولات آن (مقالات مستخرج ، کتاب ، برنامه های رایانه ای ، نرم افزارها و تجهیزات ساخته شده است) متعلق به دانشگاه صنعتی شاهرود می باشد . این مطلب باید به نحو مقتضی در تولیدات علمی مربوطه ذکر شود .

* متن این صفحه نیز باید در ابتدای نسخه های تکثیر شده پایان نامه وجود داشته باشد .

چکیده

با توجه به تأثیر احساس بر زندگی انسان و اهمیت شناسایی آن تابه‌حال روش‌های بسیاری در حوزه زمان و فرکانس برای کلاسه‌بندی احساس ارائه شده‌اند. در این پایان‌نامه از چهار روش مختلف برای استخراج ویژگی‌های مربوط به احساس از سیگنال الکتروانسفالوگرام استفاده نموده و بر پایگاه داده DEAP اعمال کرده‌ایم.

اولین روش استخراج ویژگی تحلیل موجکی با عنوان DTCWPT است که در مقاله‌ای بر پایگاه داده DEAP اعمال شده بود. ما مجدداً این تحلیل را انجام دادیم تا نتایج خود را با نتایج به‌دست‌آمده در مقاله مقایسه کنیم. در دومین روش برای بهبود نتایج خود از کار در حوزه فرکانس خارج شده و بر روی ویژگی‌های زمانی سیگنال EEG متمرکز شده‌ایم. به همین منظور از روش CSP برای استخراج ویژگی‌های جدید استفاده نموده و این روش را بر سیگنال‌ها اعمال کرده‌ایم. روش سومی که برای استخراج ویژگی از داده‌های مربوط به سیگنال EEG به‌کاربرده‌ایم روش KNMF است. این روش را بر ویژگی‌های فرکانسی زمانی به‌دست‌آمده از روش DTCWPT اعمال کرده و ویژگی‌های جدیدی تولید کرده‌ایم و در نهایت به عنوان روش چهارم الگوریتم KSVD نیز بر داده‌ها اعمال شده است. در بین روش‌های اعمال‌شده روش‌های KNMF و KSVD، فرآیند بسیار کند و زمان‌بری دارند. در این میان روش CSP در مقایسه با سایر روش‌ها با سرعت بالاتری انجام می‌شود و با داشتن تعداد کمی از ویژگی‌ها نرخ قابل قبولی دارد.

کلیدواژه: شناسایی احساس، سیگنال EEG؛ تبدیل DTCWPT؛ تحلیل CSP؛ الگوریتم KNMF؛ الگوریتم KSVD.

لیست مقالات

- 1- Khodadadi Roghaye, Ahmadyfard Alireza, "Emotion Recognition Using Common Spatial Pattern Analysis on EEG Signal ", 22nd Iranian Conference of Biomedical Engineering(ICBME2015), Iran,Tehran.

فهرست مطالب

فصل ۱-مقدمه.....	۱
۱-۱- ضرورت شناخت احساس.....	۲
۲-۱- کاربرد شناخت احساس.....	۲
۳-۱- راه‌های شناخت احساس.....	۳
۴-۱- احساس و سیگنال مغزی.....	۴
۵-۱- محرک‌های احساسی.....	۵
۶-۱- موسیقی به‌عنوان محرک احساسی.....	۶
۷-۱- کلاس‌های احساس.....	۷
۸-۱- شاخص عدم تقارن.....	۸
فصل ۲- مروری بر کارهای انجام شده.....	۱۱
۱-۲- مقدمه.....	۱۲
۲-۲- تحلیل فرکانسی زمانی.....	۱۲
۳-۲- تحلیل زمانی.....	۲۰
۴-۲- تبدیل موجک.....	۲۳
۵-۲- تحلیل CSP.....	۲۵
۶-۲- ادغام ویژگی‌های فرکانسی و ویژگی‌های زمانی.....	۲۷
۷-۲- الگوریتم NMF.....	۲۹
فصل ۳- تئوری‌های استفاده شده در تحقیق.....	۳۱
۱-۳- تبدیل موجک.....	۳۲

۳۴: DTCWT ۱-۱-۳-تبدیل
۳۵: DTCWPT ۲-۱-۳-تبدیل
۳۷ CSP ۲-۳-تحلیل
۳۹: KNMF ۳-۳-الگوریتم
۴۱: کدگذاری پراکنده: ۴-۳
۴۳: انتخاب دیکشنری: ۱-۴-۳
۴۳: طراحی دیکشنری‌ها ۲-۴-۳
۴۴: پایگاه داده ۵-۳
۴۷: فصل ۴- نتایج شبیه‌سازی
۴۸: ۱-۴-بلوک دیاگرام بخشهای فصل
۵۰: ۲-۴-کلاسه‌بندی بر اساس افراد شرکت‌کننده
۵۰: DTCWPT ۱-۲-۴-اعمال روش
۵۷: ۱-۱-۲-۴- کلاسه‌بندی با کل ویژگیها
۵۷: ۲-۱-۲-۴- کلاسه‌بندی با ویژگیهای انتخاب شده
۶۰: ۳-۱-۲-۴- کلاسه‌بندی با ۲۲ ویژگی
۶۱: ۴-۱-۲-۴- بررسی تأثیر حذف جفت الکترودها
۶۲: CSP ۲-۲-۴-اعمال روش
۶۶: CSP ۱-۲-۲-۴- نرمال‌سازی ویژگی‌های
۶۷: EEG ۲-۲-۲-۴- تقطیع زمانی سیگنال
۷۱: DTCWPT و CSP ۳-۲-۴-ادغام ویژگی‌های دو روش
۷۲: KNMF ۴-۲-۴-اعمال روش
۷۴: ۱-۴-۲-۴- کلاسه‌بندی با بیشینه نرخ ۱۶ قسمت زمانی
۷۵: ۲-۴-۲-۴- کلاسه‌بندی با متوسط نرخ ۱۶ قسمت زمانی
۷۶: ۳-۴-۲-۴- کلاسه‌بندی با رأی‌گیری بین نتایج ۱۶ قسمت زمانی
۷۶: ۵-۲-۴- کلاسه‌بندی بر مبنای رأی‌گیری بین نتایج سه روش
۷۷: KSVD ۶-۲-۴-اعمال روش
۸۰: ۳-۴-کلاسه‌بندی بر اساس موسیقی
۸۰: DTCWPT ۱-۳-۴-اعمال روش

۸۲۲-۳-۴- اعمال روش CSP
۸۴۳-۳-۴- کلاسه بندی برای ۱۲ قطعه منتخب
۸۵۴-۴- پایگاه داده DEAP
۸۷فصل ۵- نتیجه گیری و پیشنهادها
۸۸۱-۵- مقدمه
۹۰۲-۵- بررسی نتایج به دست آمده
۱۰۳۳-۵- نتیجه گیری
۱۰۴۴-۵- پیشنهادها
۱۰۵مراجع

فهرست علائم و اختصارات

Electroencephalogram	EEG
Electrocardiogram	ECG
Electromyogram	EMG
Functional Magnetic Resonance Imaging	FMRI
Brain-Computer Interface	BCI
Asymmetry Index	AsI
International Affective Picture System	IAPS
Time-Frequency Distributions	TFDs
Short-Time Fourier transform	STFT
Hilbert-Huang Spectrum	HHS
Empirical Mode Decomposition	EMD
Intrinsic Mode Functions	IMFs
K-Nearest Neighbor	KNN
Radial Basis Function	RBF
Support Vector Machine	SVM
Mahalanobis Distance	MD
Multilayer Perceptron	MLP
Fast Fourier Transform	FFT
Mirror Neuron System	MNS
Self Assessment Manikin	SAM
Higher Order Crossings	HOC
Cross Correlation	CC

HOC-Emotion Classifier	HOC-EC
Quadratic Discriminant Analysis	QDA
Lifting Based Wavelet Transform	LBWT
Recoursing Energy Efficiency	REE
Discrete Wavelet Transform	DWT
Multi-Resolution Analysis	MRA
Low Valence Low Arousal	LVLA
Low Valence High Arousal	LVHA
High Valence High Arousal	HVHA
High Valence Low Arousal	HVLA
Laboratory Virtual Instrument Engineering Workbench	LabVIEW
Event-Related Potentials	ERPs
Event-Related Desynchronization	ERD
Event-Related Synchronization	ERS

فهرست جداول

- جدول ۱-۴ ترتیب اولویت ۱۶ زیر باند فرکانسی حاصل از اعمال روش DTCWPT بر سیگنال EEG. ۵۳
- جدول ۲-۴ نتایج کلاسه‌بندی قبل از کاهش تعداد ویژگی‌ها. ۵۷
- جدول ۳-۴ بهترین نرخ کلاسه‌بندی ویژگی‌های استخراج‌شده از روش DTCWPT. ۶۰
- جدول ۴-۴ نرخ متوسط کلاسه‌بندی با اعمال روش DTCWPT برای ۴ بُعد احساسی با در نظر گرفتن ۲۲ ویژگی. ۶۰
- جدول ۵-۴ درصد کلاسه‌بندی با حذف ویژگی‌های مربوط به ۱۴ جفت الکتروود متقارن در روش DTCWPT. ۶۱
- جدول ۶-۴ نرخ کلاسه‌بندی ویژگی‌های استخراج‌شده از روش CSP برای هر یک از ۳۲ شرکت‌کننده. ۶۴
- جدول ۷-۴ نرخ متوسط کلاسه‌بندی با اعمال روش CSP برای ۴ بُعد احساسی با در نظر گرفتن ۴ ویژگی برای هر دوره آزمایش. ۶۵
- جدول ۸-۴ نرخ کلاسه‌بندی بعد از نرمال‌سازی ویژگی‌های استخراج‌شده از روش CSP به چهار روش مختلف. ۶۷
- جدول ۹-۴ نرخ کلاسه‌بندی ویژگی‌های استخراج‌شده از هر ثانیه از سیگنال EEG به روش CSP. ۶۹
- جدول ۱۰-۴ ادغام ویژگی‌های فرکانسی حاصل از روش DTCWPT و ویژگی‌های مربوط به روش CSP. ۷۱
- جدول ۱۱-۴ نتایج به‌دست‌آمده از ادغام ویژگی‌های دو روش و نرمال‌سازی ویژگی‌ها. در این حالت بهترین تعداد ویژگی‌ها برای روش DTCWPT در نظر گرفته شده است. ۷۲
- جدول ۱۲-۴ نرخ کلاسه‌بندی برای بُعد اول با استفاده از روش KNMF برای مقادیر مختلف K. در این حالت بیشینه نرخ در ۱۶ بخش زمانی را در نظر گرفتیم. ۷۵
- جدول ۱۳-۴ نرخ کلاسه‌بندی برای بُعد اول با استفاده از روش KNMF برای مقادیر مختلف K. در این حالت متوسط نرخ ۱۶ بخش زمانی را در نظر گرفتیم. ۷۵
- جدول ۱۴-۴ نرخ کلاسه‌بندی برای هر ۴ بُعد با فرض $k=2$. این نرخ‌ها با متوسط‌گیری بین ۱۶ نرخ به‌دست‌آمده برای ۱۶ بخش زمانی در هر آزمایش به‌دست‌آمده‌اند. ۷۶
- جدول ۱۵-۴ نرخ کلاسه‌بندی برای بُعد اول با استفاده از روش KNMF برای مقادیر مختلف K. در این حالت کلاسه‌بندی بر اساس رأی‌گیری بین نتایج ۱۶ بخش زمانی انجام شده است. ۷۶
- جدول ۱۶-۴ نرخ کلاسه‌بندی برای هر بُعد با توجه به نتایج به‌دست‌آمده از هر سه روش. ۷۷
- جدول ۱۷-۴ درصد کلاسه‌بندی برای ۳۰ قسمت زمانی به روش KSVD. ۷۸

جدول ۴-۱۸ بیشترین نرخ به دست آمده در بین ۳۰ نرخ مربوط به ۳۰ قطعه زمانی. ۷۹.....

جدول ۴-۱۹ متوسط ۳۰ نرخ به دست آمده از روش KSVD. ۷۹.....

جدول ۴-۲۰ نرخ کلاسه بندی بر اساس موسیقی با استفاده از ۲۲ ویژگی استخراج شده از روش DTCWPT. ۸۰.....

جدول ۴-۲۱ نرخ کلاسه بندی و شماره قطعه هایی که نرخ بالاتر از ۶۰٪ دارند. (روش DTCWPT) ۸۱.....

جدول ۴-۲۲ بهترین تعداد ویژگی ها و نرخ به دست آمده با استفاده از آن ها. ۸۲.....

جدول ۴-۲۳ نرخ کلاسه بندی و شماره قطعه هایی که نرخ بالاتر از ۶۰٪ دارند. (روش CSP) ۸۳.....

جدول ۴-۲۴ متوسط نرخ کل قطعه ها و متوسط نرخ قطعه های با نرخ بالاتر از ۶۰٪. (روش DTCWPT) ۸۴.....

جدول ۴-۲۵ متوسط نرخ کل قطعه ها و متوسط نرخ قطعه های با نرخ بالاتر از ۶۰٪. (روش CSP) ۸۴.....

جدول ۴-۲۶ متوسط نرخ ۱۲ قطعه منتخب در دو روش CSP و DTCWPT. ۸۵.....

جدول ۵-۱ مقایسه نتیجه کلاسه بندی با تعداد ویژگی های مختلف در روش DTCWPT. ۹۰.....

جدول ۵-۲ تغییر نرخ در استفاده از بهترین تعداد ویژگی ها نسبت به ۲۲ ویژگی و ۵۵۲ ویژگی. ۹۰.....

جدول ۵-۳ تغییر نرخ با حذف ۱۴ جفت الکتروود متقارن. ۹۱.....

جدول ۵-۴ مقایسه نرخ های به دست آمده از روش CSP و DTCWPT. ۹۲.....

جدول ۵-۵ تغییر نرخ ها در روش CSP نسبت به روش DTCWPT. ۹۲.....

جدول ۵-۶ مقایسه نرخ کلاسه بندی ویژگی های CSP در حالت نرمال شده با حالت بدون نرمال سازی ویژگی ها. ۹۳.....

جدول ۵-۷ تغییر نرخ کلاسه بندی ویژگی های استخراج شده از روش DTCWPT در کلاسه بندی بر اساس موسیقی نسبت به کلاسه بندی بر اساس افراد شرکت کننده. این کلاسه بندی ها با ۲۲ ویژگی انجام شده اند. ۹۴.....

جدول ۵-۸ تغییر نرخ کلاسه بندی ویژگی های استخراج شده از روش DTCWPT در کلاسه بندی بر اساس موسیقی نسبت به کلاسه بندی بر اساس افراد شرکت کننده. این کلاسه بندی ها برای هر دو حالت کلاسه بندی با بهترین تعداد ویژگی در هر بُعد انجام شده اند. ۹۴.....

جدول ۵-۹ مقایسه بهترین تعداد ویژگی های استخراج شده از روش DTCWPT در دو حالت کلاسه بندی بر اساس ۱. افراد شرکت کننده، ۲. قطعه های موسیقی. ۹۵.....

جدول ۵-۱۰ تغییر نرخ کلاسه بندی ویژگی های استخراج شده از روش CSP در کلاسه بندی بر اساس موسیقی نسبت به کلاسه بندی بر اساس افراد شرکت کننده. ۹۵.....

جدول ۵-۱۱ تعداد قطعه هایی که در روش CSP نرخ بالاتر از ۶۰٪ داشتند و متوسط نرخ این قطعه های موسیقی. ۹۶.....

جدول ۵-۱۲ تعداد قطعه‌هایی که در روش DTCWPT نرخ بالاتر از ۶۰٪ داشتند و متوسط نرخ این قطعه‌های موسیقی. ۹۶

جدول ۵-۱۳ مقایسه نرخ کلاسه‌بندی در دو روش CSP و DTCWPT با استفاده از سیگنال‌های EEG مربوط به ۱۲ قطعه از ۴۰ قطعه موسیقی. ۹۷

جدول ۵-۱۴ مقایسه نتایج به‌دست‌آمده از هر دو روش CSP و DTCWPT با نرخ‌های گزارش‌شده در مقاله. نرخ کلاسه‌بندی برای روش CSP بر اساس افراد شرکت‌کننده و برای تبدیل DTCWPT بر اساس قطعه‌های موسیقی به‌دست‌آمده است. ۹۸

جدول ۵-۱۵ تغییر نرخ‌ها در نتیجه ادغام ویژگی‌های استخراج‌شده از دو روش CSP و DTCWPT نسبت به هر یک از این دو روش. این ویژگی‌ها بعد از ادغام نرمال شده‌اند. ۹۹

جدول ۵-۱۶ مقایسه نرخ کلاسه‌بندی ویژگی‌های حاصل از روش DTCWPT در حالت عادی نسبت به حالت تقطیع هر یک از زیرباندها و تشکیل ماتریس فرکانسی زمانی. ۱۰۰

جدول ۵-۱۷ تغییر نرخ کلاسه‌بندی در روش KNMF ($K=2$) نسبت به دو روش CSP و DTCWPT. در اینجا متوسط نرخ ۱۶ بخش زمانی به‌عنوان نرخ کلاسه‌بندی هر فرد استفاده‌شده است. ۱۰۱

جدول ۵-۱۸ مقایسه نرخ‌های به‌دست‌آمده از روش KNMF در دو حالت مختلف با روش‌های قبل. حالت اول. با در نظر گرفتن بیشینه ۱۶ نرخ به‌عنوان درصد کلاسه‌بندی برای هر فرد و حالت دوم. با در نظر گرفتن متوسط ۱۶ نرخ به‌عنوان درصد کلاسه‌بندی برای هر فرد. ۱۰۱

جدول ۵-۱۹ تغییر نرخ‌های به‌دست‌آمده از روش KNMF در دو حالت مختلف نسبت به روش‌های قبل. حالت اول. با در نظر گرفتن بیشینه ۱۶ نرخ به‌عنوان درصد کلاسه‌بندی برای هر فرد و حالت دوم. با در نظر گرفتن متوسط ۱۶ نرخ به‌عنوان درصد کلاسه‌بندی برای هر فرد. ۱۰۲

جدول ۵-۲۰ تغییر نرخ کلاسه‌بندی بعد از رأی‌گیری بین سه روش نسبت به هر یک از روش‌ها. ۱۰۲

فهرست اشکال

- شکل ۱-۱ مدل پیوسته (ابعادی) احساس در فضای دوبعدی ظرفیت و انگیزتگی [۱۱]. ۸
- شکل ۱-۲ الف. سیگنال EEG ب. نمایش TF آن در حوزه زمان فرکانس [۱۲]. ۱۳
- شکل ۲-۲ بخشی از تصاویر آزمون خودارزیابی آدمک [۱۶]. ۱۸
- شکل ۱-۳ تحلیل حوزه فرکانس DTCWT [۳۱]. ۳۲
- شکل ۲-۳ تحلیل حوزه فرکانس DWPT [۳۱]. ۳۳
- شکل ۳-۳ تحلیل حوزه فرکانس DTCWPT تحلیلیناپذیر [۳۱]. ۳۴
- شکل ۴-۳ تبدیل DTCWT با استفاده از دو بانک پالایه موازی اعمالشده است [۳۱]. ۳۵
- شکل ۵-۳ بانک پالایه موجک بسته‌ای اول تبدیل DTCWPT چهار مرحله‌ای. بانک پالایه دوم با جایگذاری $hi1(n-1)$ به جای $hi1(n)$ و $hi'(n)$ به جای $hi(n)$ برای $i \in \{0,1\}$ به دست می‌آید [۳۱]. ۳۶
- شکل ۶-۳ تحلیل حوزه فرکانس DTCWPT تحلیلیپذیر [۳۱]. ۳۷
- شکل ۷-۳ سیگنال EEG در حوزه زمان و شکل زمان فرکانسی این سیگنال که با خط چین نشان داده شده است [۳۴]. ۴۰
- شکل ۱-۴ سیگنال مغزی نمونه برداری شده با نرخ ۱۲۸ نمونه در ثانیه. ۵۰
- شکل ۲-۴ مرتب شدن زیرباندها از لحاظ اولویت فرکانسی. ۵۳
- شکل ۳-۴ نرخ متوسط به دست آمده برای بُعد اول با تغییر تعداد ویژگی‌ها از ۱ تا ۲۰۰ عدد ویژگی. ۵۸
- شکل ۴-۴ نرخ متوسط به دست آمده برای بُعد دوم با تغییر تعداد ویژگی‌ها از ۱ تا ۲۰۰ عدد ویژگی. ۵۸
- شکل ۵-۴ نرخ متوسط به دست آمده برای بُعد سوم با تغییر تعداد ویژگی‌ها از ۱ تا ۲۰۰ عدد ویژگی. ۵۹
- شکل ۶-۴ نرخ متوسط به دست آمده برای بُعد چهارم با تغییر تعداد ویژگی‌ها از ۱ تا ۲۰۰ عدد ویژگی. ۵۹
- شکل ۷-۴ مقدار به دست آمده برای ۴ ویژگی استخراج شده از روش CSP در چندین دوره آزمایش مربوط به کلاس Low. ۶۶
- شکل ۸-۴ اعمال روش CSP بر بخش‌های زمانی و استخراج بردارهای ویژگی. ۶۸
- شکل ۹-۴ قطعه‌های ویدئویی بر اساس برچسب‌های داده شده توسط شرکت کنندگان در آزمایش با دو بعد ظرفیت و انگیزتگی نمایش داده شده‌اند [۳۱]. ۸۶

فصل ۱

مقدمه

۱-۱- ضرورت شناخت احساس

داشتن سلامت کامل از لحاظ احساسی برای بهبود کیفیت زندگی انسان ضروری است. به عبارت دیگر پایین بودن سلامت احساسی انسان باعث ایجاد مشکلات اجتماعی و روانی در زندگی فرد می‌شود. برای داشتن حس بهتر باید احساس فعلی در فرد شناسایی شود. بر اساس نظریه هوش احساسی قبل از اینکه انسان بتواند احساس خود را تنظیم و کنترل کند ابتدا باید آن را بشناسد. طبق تحقیق‌های انجام‌شده شناخت احساس حتی در سازگاری افراد دارای فرهنگ‌های مختلف با یکدیگر نیز تأثیرگذار است [۱]. چراکه اطلاعات غیرزبانی مانند احساس نقش مهمی در روابط انسان‌ها با یکدیگر دارند.

۱-۲- کاربرد شناخت احساس

تغییر حالت مکرر در انسان ممکن است نشان‌دهنده بیماری‌های روانی باشد. حالت‌هایی مانند افسردگی، نگرانی و عصبانیت بر سیستم ایمنی بدن انسان تأثیر منفی می‌گذارند، بنابراین نظارت بر حالت‌های احساسی، اطلاعات پزشکی ارزشمندی در مورد افراد کهن‌سال و یا اشخاص دارای بیماری‌های مزمن در دسترس پزشکان قرار می‌دهد [۲]. با استفاده از سیستم^۱ BCI مبتنی بر سیگنال EEG^۲ هم فرد بیمار قادر به ارزیابی و کنترل احساسات خود خواهد بود و هم روانشناس از اطلاعات EEG به دست‌آمده برای انتخاب روش درمان مناسب استفاده خواهد کرد.

تشخیص احساس علاوه بر پزشکی در حوزه‌های دیگری نیز مورد استفاده قرار می‌گیرد. به‌عنوان مثال در رابطه با افزایش اشتیاق یک بازیکن برای ادامه بازی هم می‌توان از شناسایی احساس بر اساس سیگنال EEG استفاده کرد. به این صورت که میزان سختی بازی بر اساس احساس فرد نسبت به بازی کنترل می‌شود. احساس فرد از طریق سیگنال‌های فیزیولوژیکی مانند ضربان قلب، نوار

^۱ Brain Computer Interface

^۲ Electroencephalograph

عضله الکتریکی، هدایت پوست و سیگنال‌های مربوط به سیستم عصبی مرکزی مانند EEG سنجیده می‌شود [۳].

یکی دیگر از کاربردهای شناسایی احساس استفاده از سامانه‌های شناسایی احساس در ربات‌ها است [۴].

۱-۳- راه‌های شناخت احساس

تاکنون چندین روش برای ارزیابی احساس استفاده شده‌اند که متداول‌ترین آن‌ها استفاده از سیگنال‌های زیستی مانند EEG، EMG^۱، ECG^۲ و یا استفاده از هدایت پوست، تعرق، دما و BVP^۳ و یا صدای فرد است [۵].

علت اصلی استفاده از سیگنال‌های زیستی این است که احساس‌های مختلف باعث ایجاد فعالیت‌های خودکار مختلفی در بدن می‌شوند. مثلاً عصبانیت باعث افزایش ضربان قلب و دمای بدن، ترس باعث افزایش ضربان قلب و کاهش دمای بدن و خوشحالی باعث کاهش ضربان قلب شده و هیچ تغییری در دمای بدن ایجاد نمی‌کند.

همان‌طور که می‌دانیم افکار، احساسات و رفتار ما به سیستم عصبی و نورون‌های ما وابسته‌اند. در واقع می‌توان با استفاده از امواج مغزی احساس را شناسایی نمود. تحقیق‌های بسیاری در جهت توسعه تعامل کامپیوتر و انسان بر مبنای سیگنال‌های زیستی انجام شده‌اند. در برخی از آن‌ها از سیگنال EEG برای به دست آوردن اطلاعات در مورد فعالیت‌های مغزی استفاده شده است.

اگرچه هدف اصلی ما استخراج ویژگی‌های مربوط به احساس از روی سیگنال EEG است، اما چنانچه بخواهیم این روش را با روش‌های تصویربرداری مقایسه کنیم باید گفت که سیگنال EEG

^۱ Electromyograph

^۲ Electrocardiograph

^۳ Blood Volume Pulse

فعالیت مغزی ناشی از احساس را به‌طور مستقیم اندازه می‌گیرد اما روش‌های تصویربرداری مانند fMRI^۱ و PET^۲ تغییر جریان خون در مغز و فعالیت متابولیک آن را اندازه می‌گیرند.

۴-۱- احساس و سیگنال مغزی

با تغییر احساس، سیگنال‌های مغزی نیز تغییر می‌کنند. چنانچه احساس خستگی و خواب‌آلودگی بر ما چیره شده باشد فرکانس سیگنال مغزی ما کاهش می‌یابد؛ اما اگر میزان هوشیاری افزایش یابد فرکانس سیگنال مغز نیز افزایش می‌یابد. سیگنال‌های مغزی که در قسمت‌های مختلف مغز ایجاد می‌شوند بیانگر حالت‌ها و احساس‌های مختلفی هستند. با استفاده از این سیگنال‌ها می‌توان برخی بیماری‌های روانی را نیز درمان کرد. به‌عنوان مثال بیماری الکسی تایمیا^۳ صفتی اخلاقی است که در آن فرد قادر به بیان و ابراز احساسات خود نیست. این بیماری شامل ویژگی‌های خاصی مانند دشواری در تشخیص احساس و دشواری در بیان و توصیف احساس است. طبق مطالعه‌های انجام‌شده با استفاده از سیگنال EEG می‌توان احساس این بیماران را شناسایی کرد [۶].

این سیگنال‌ها بر اساس محدوده فرکانسی به چند دسته تقسیم می‌شوند:

امواج دلتا: این امواج پایین‌ترین فرکانس (۰.۵-۳ هرتز) را در سیگنال مغزی دارند ولی دامنه آن‌ها زیاد است و در حالت خواب عمیق ظاهر می‌شوند.

امواج تتا: فرکانس این امواج بالاتر از امواج دلتا بوده (۳-۸ هرتز) و در حالت خواب سبک غالب هستند. در واقع این امواج عامل یادگیری و حافظه می‌باشند. خیال‌پردازی، ترس، یادآوری خاطرات و کابوس‌ها با تولید این امواج به وجود می‌آیند.

امواج آلفا: این امواج (۸-۱۲ هرتز) در حالت آرامش و بسته شدن چشم‌ها در ناحیه پس‌سری تولید می‌شوند و باعث کاهش اضطراب، افزایش ایمنی بدن، خوشی و مثبت اندیشی می‌شوند.

¹ Functional Magnetic Resonance Imaging

² Position Emission Tomography

³ Alexythymia

امواج بتا: امواج بتا (۳۸-۱۲ هرتز) در حالت آگاهی کامل و بیداری امواج غالب مغز هستند. در حالت هشیاری، تمرکز کامل، قضاوت و یا هرگونه فعالیت ذهنی این امواج ظهور پیدا می کنند. امواج بتا خود به سه باند تقسیم می شوند. بتای پایین (Beta1)، بتای میانی (Beta2) و بتای بالا (Beta3) که در حالت تفکر پیچیده و یا اضطراب به وجود می آید.

امواج گاما: این امواج سریع ترین امواج مغز هستند (۳۸ هرتز و بالاتر) و در زمان پردازش همزمان اطلاعات از مناطق مختلف مغز به وجود می آیند.

در مطالعه ای که محققان ایرانی بر روی پایگاه داده DEAP انجام داده اند، طیف توان هر یک از این باندهای فرکانسی برای احساس های مختلف محاسبه شده است [۷]. بر اساس گزارش نویسندگان این مقاله، در زمان عصبانیت و شادی که هر دو دارای انگیزتگی بالایی هستند طیف توان در باندهای بتا و گاما قوی تر از سایر باندهاست درحالی که انگیزتگی پایین باعث افزایش توان در باند آلفا می شود. همچنین احساس مثبت یا خوشایندی زیاد باعث افزایش فعالیت نیم کره چپ مغز شده و احساس منفی یا خوشایندی پایین فعالیت نیم کره راست مغز را بالا می برد [۸]. در برخی از مطالعات نیز، نواحی پیشین مغز را نواحی حساس به تغییرات احساسی معرفی کرده اند [۹].

۱-۵- محرک های احساسی

به دلیل گسترده بودن طیف احساس های انسان محرک های متنوعی برای تحریک این احساس ها وجود دارند. در اکثر مطالعه هایی که تاکنون انجام گرفته است از محرک هایی مانند قطعه های موسیقی، فیلم، عکس و یا حتی یادآوری خاطرات توسط خود فرد استفاده شده است.

هنگامی که ما از محرک ها به خصوص محرک های تصویری استفاده می کنیم و به یک فرد تصویری از عمل شخص دیگری را نشان می دهیم در فرد ناظر همان فعالیت های مغزی ایجاد می شود که در اثر

انجام آن عمل در او ایجاد می‌شود. بر اساس تئوری MNS¹ از فرد انتظار نمی‌رود که دقیقاً احساس موردنظر را با دیدن عکس یا هر تحریک دیگری داشته باشد اما باید سیگنال EEG یکسانی نسبت به زمان تجربه واقعی آن حس داشته باشد [۱۰]. به‌عنوان مثال با دیدن یک تصویر خندان همان واکنش-های مغزی که مربوط به خندیدن است در فرد ناظر ایجاد خواهد شد.

عواملی مانند شخصیت، تجربه‌های شخصی و حالت‌های خاص هر فرد در زمان تحریک احساس توسط محرک‌ها بر عکس‌العمل او اثرگذارند. در نتیجه به‌محض اینکه احساسی توسط تحریک خارجی در فرد ایجاد می‌شود این سؤال مطرح می‌شود که این احساس تا چه اندازه در فرد موردنظر تحریک شده است و بالاخره سیگنال EEG تا چه حد بیانگر آن احساس هست.

۱-۶- موسیقی به‌عنوان محرک احساسی

علاقه ما به یک نوع موسیقی خاص و یا قطعه‌های موسیقی مشخص و ترجیح دادن آن به سایر انواع و قطعه‌های موسیقی دیگر، بخشی از شخصیت ماست که بر عادت‌های روزانه و روابط اجتماعی تأثیر به‌سزایی دارد. این میل طبیعی توسط عامل‌های بسیار زیادی که به‌تدریج در حین تکامل انسان پدید آمده‌اند، به وجود آمده است. در رشته فیزیولوژی اعصاب نشانه‌های فعالیت مغزی به دلیل هیجان احساسی حاصل از شنیدن موسیقی گزارش شده است. نتایج fMRI نشان داده‌اند که بخش‌های مختلف مغز که به‌عنوان مرکز احساس شناخته شده‌اند، با گوش دادن به موسیقی فعال می‌شوند [۱۱]؛ بنابراین می‌توان از پدیده‌های عاطفی که در مغز انسان منعکس می‌شوند به‌عنوان شاخصی در تشخیص میزان علاقه افراد به موسیقی استفاده کرد.

موسیقی درمانی یکی از روش‌هایی است که امروزه برای درمان بیماری‌های احساسی به کار می‌رود.

¹ Mirror Neuron System

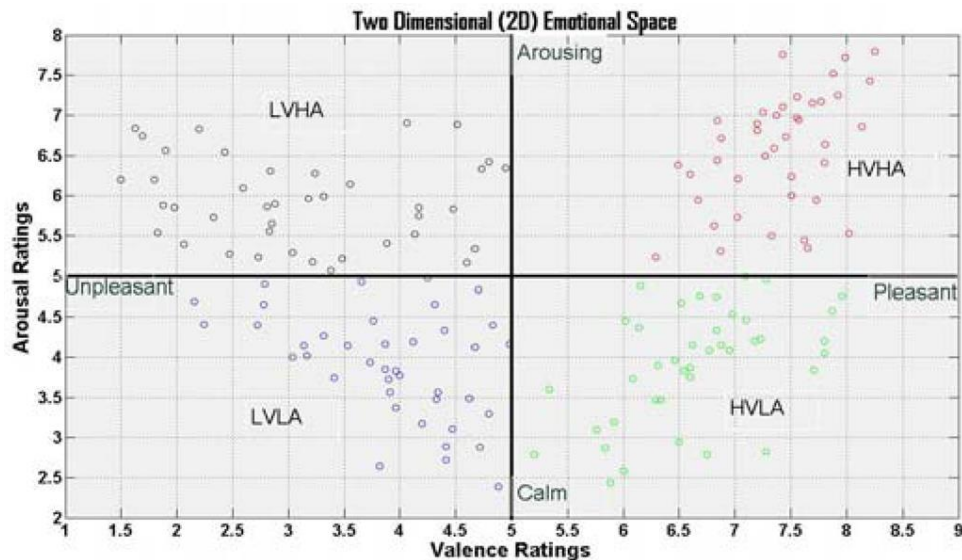
۱-۷- کلاس‌های احساس

احساس به دو صورت گسسته و پیوسته (ابعادی) تعریف می‌شود. بر اساس تفسیر گسسته احساس، مشخصه‌های روانشناسی و رفتاری یکتایی برای هر احساس مانند عصبانیت، شادی و ... وجود دارد، یعنی احساس‌های مختلف به صورت هویت‌های جدا از هم با مرزبندی‌های مشخص هستند. اشکال این مدل این است که کل طیف احساس را پوشش نمی‌دهد. برخلاف آن در تفسیر پیوسته، حالت‌های احساسی مختلف با دو عامل خوشایندی (مطلوب تا نامطلوب) و برانگیختگی (آرام تا پرهیجان) مشخص می‌شوند. در این حالت می‌توان احساس را صفحه دوبعدی در نظر گرفت که یک بعد آن خوشایندی و بعد دیگر آن برانگیختگی است. این روش نیز خالی از اشکال نیست چراکه احساس ما ناشی از عوامل مختلفی بوده و دارای مؤلفه‌های بی‌شماری است که ما تنها دو بعد آن را در نظر می‌گیریم و با این کار هر احساس خاص را به فضای پایین‌تری نگاشت داده و بسیاری از اطلاعات را از دست می‌دهیم. بااینکه دو رویکرد گسسته و پیوسته تا حدودی با یکدیگر مطابقت دارند، ولی اکثر تحقیقات از مدل پیوسته استفاده کرده‌اند، چراکه این مدل حالت‌های احساسی را بهتر از مدل‌های دیگر تفسیر می‌کند. در این مدل بُعد خوشایندی از جذابیت و لذت شروع شده و تا گریز و نفرت ادامه دارد یعنی خوشایندی مثبت مربوط به احساسات مثبت است و خوشایندی منفی مربوط به احساسات منفی است. درحالی‌که برانگیختگی معنای عام‌تری دارد و به سطح تحریک مربوط می‌شود. درواقع برانگیختگی به سطح فعال‌سازی برمی‌گردد و به جهت آن ربطی ندارد یعنی به لذت یا نفرت مربوط نبوده و سطح هر احساس را می‌سنجد [۱۱].

بر مبنای طبیعت دوبعدی مدل احساس تصاویر پایگاه تصویر IAPS^۱ در دودسته خوشایندی و برانگیختگی مورداستفاده قرار می‌گیرند. در این سیستم احساس‌ها به صورت نقاطی در فضای دوبعدی در نظر گرفته می‌شوند. با ترکیب این دو بعد ۴ دسته احساسی به دست می‌آیند که این ۴ دسته شامل احساس‌های مختلفی در انسان مانند لذت، هیجان، دلگیری، عصبانیت، ترس و ... می‌شوند.

^۱ International Affective Picture System

درواقع این ایده بر مبنای این واقعیت است که خوشایندی و برانگیختگی دو بعد احساسی متعامد و نا وابسته‌اند، بنابراین هر احساسی را می‌توان برحسب این دو بعد بیان کرد. فضای احساس توصیف‌شده به صورت شکل ۱-۱ است.



شکل ۱-۱ مدل پیوسته (ابعادی) احساس در فضای دوبعدی ظرفیت و انگیزندگی [۱۱].

۱-۸- شاخص عدم تقارن

با توجه به عدم تقارن فعالیت بخش پیشین مغز، شاخصی به نام شاخص عدم تقارن (AsI)^۱ تعریف شده است. این تعریف با تحلیل سیگنال‌های EEG قسمت‌های مختلف دو نیمکره مغز، انجام گرفته است. عدم تقارن نیمکره‌های راست و چپ مغز باعث می‌شود که تأثیر احساس در سیگنال مغزی بیشتر دیده شود به این صورت که تجربه احساس منفی با افزایش فعالیت در سمت راست این بخش همراه است در حالی که احساس مثبت سمت چپ بخش پیشین مغز را فعال می‌کند. زمانی که فرد مورد آزمایش آرامش دارد مقدار کل اطلاعاتی که در سیگنال‌های EEG مخفی هستند و بین بخش راست و چپ مغز تبادل می‌شوند به بیشترین مقدار خود می‌رسند و زمانی که فرد برانگیخته است کمترین مقدار را خواهند داشت. شاخص ASI برای دور انداختن سیگنال‌هایی که اطلاعاتی در مورد احساسات ندارند استفاده می‌شود و قابلیت اطمینان را بالا می‌برد.

^۱ Asymmetry Index

در ادامه پایان نامه به بررسی بیشتر این موضوعات و توضیح روند تحقیق خواهیم پرداخت. به این صورت که در فصل دوم مطالعه‌های انجام شده در حوزه شناسایی احساس با استفاده از سیگنال EEG مورد بررسی قرار خواهند گرفت. در فصل سوم روش‌های استفاده شده در طول تحقیق توضیح داده می‌شوند. در فصل چهارم روند انجام تحقیق و نتایج به دست آمده گزارش خواهند شد و در فصل آخر نتیجه‌گیری کلی انجام می‌شود.

فصل ۲

مروری بر کارهای انجام شده

۲-۱- مقدمه

برای بهبود شناسایی احساس بر اساس سیگنال‌های EEG باید به دنبال ویژگی‌های مربوط به احساس در این سیگنال‌ها و راه‌های سودمند برای کلاسه‌بندی آن‌ها باشیم. انتخاب ویژگی‌ها بخش مهمی از فرآیند را تشکیل می‌دهد و باید قبل از کلاسه‌بندی انجام شود. باید ویژگی‌هایی انتخاب شوند که دارای بیشترین اطلاعات هستند. ویژگی‌های استخراج‌شده از سیگنال بخش پیشین مغز، اطلاعات متمایزکننده‌ای برای کلاسه‌بندی ارائه می‌دهند. این ویژگی‌ها به افراد مورد آزمایش وابسته نیستند.

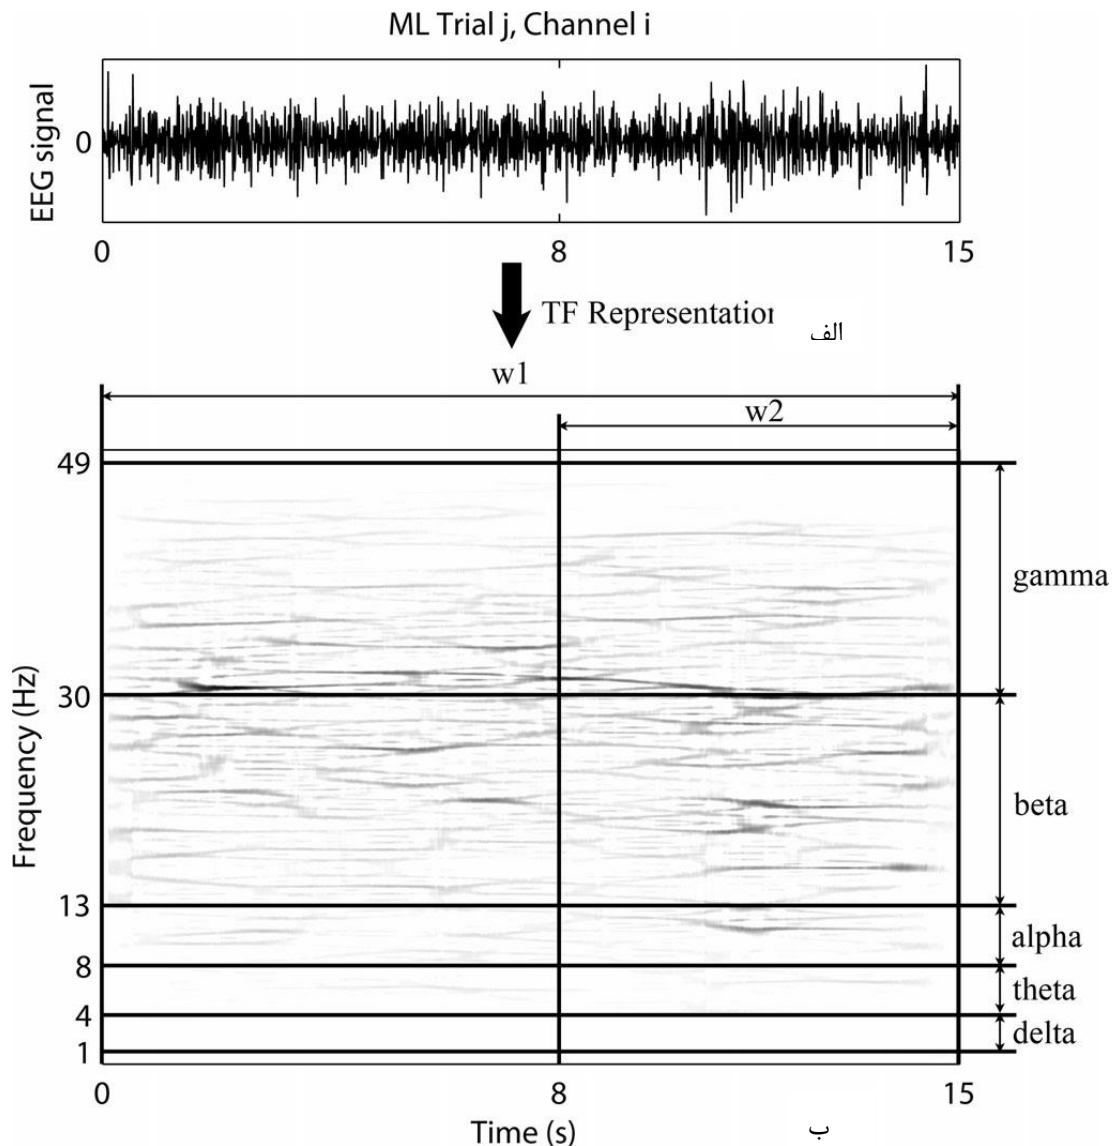
۲-۲- تحلیل فرکانسی زمانی

یکی از روش‌هایی که تاکنون برای استخراج ویژگی معرفی شده است استفاده از پنجره زمانی بر اساس تحلیل فرکانسی زمانی (TF)^۱ است. در واقع TFD^۲ شامل نمایش طیفی دوبعدی از سیگنال در حوزه زمان و فرکانس است. این نوع نمایش شامل دو کلاس عمده است؛ TF خطی و TF درجه دوم. کلاس اول مربوط به تجزیه خطی عناصر اولیه سیگنال است. این عناصر اتم نامیده می‌شوند. عضو برجسته این کلاس تبدیل فوریه زمان کوتاه (STFT)^۳ است. این تبدیل شامل پنجره گذاری یک سیگنال حول زمان ثابت t و محاسبه تبدیل فوریه حول t است. شکل (۱-۲) قسمت الف، یک سیگنال EEG را در حوزه زمان نشان می‌دهد. این سیگنال در حین گوش دادن به موسیقی ثبت شده است. شکل (۱-۲) قسمت ب، نمایش TF سیگنال EEG نشان داده شده است.

¹ Time Frequency

² Time Frequency Distribution

³ Short Time Fourier Transform



شکل ۱-۲ الف. سیگنال EEG ب. نمایش TF آن در حوزه زمان فرکانس [۱۲].

در مطالعه‌ای مبتنی بر BCI تحریک احساس از طریق قطعه‌های موسیقی انجام شده است و سیگنال‌های EEG توسط الکترودها ثبت شده‌اند. به منظور استخراج ویژگی‌ها از سیگنال EEG، بعد از جمع‌آوری داده‌ها تمام سیگنال‌های EEG از فرکانس ۱ تا ۴۹ هرتز پالایش و با استفاده از سه روش TF (طیف نگاره^۱، توزیع Zhao-Atlas-Marks و طیف HHS^۲)، ویژگی‌ها در هر یک از باندهای دلتا، تتا، آلفا، بتا و گاما استخراج شده‌اند [۱۲]. از ۴ کلاس به بند QDA^۳، MD^۴، K-NN^۱ و SVM^۲ برای قرار

^۱ Spectrogram

^۲ Hilbert Huang Spectrum

^۳ Quadratic Discriminant Analysis

^۴ Mahalanobis Distance

دادن ویژگی‌ها در دو کلاس like و dislike بر اساس موردعلاقه بودن و یا نبودن قطعه‌های موسیقی پخش‌شده، استفاده‌شده است. با استفاده از کلاسه بند K-NN بهترین نرخ کلاسه‌بندی ۸۶.۵۲٪ به‌دست‌آمده است. تعداد افراد شرکت‌کننده در آزمایش ۹ نفر است و همه آن‌ها راست‌دست بوده و اختلال شنوایی نداشتند. در طول آزمایش، شرکت‌کنندگان به ۶۰ قطعه موسیقی منتخب از ۴ نوع موسیقی و ۱۵ قطعه نویز پهن باند، گوش دادند. نویز به‌صورت موسیقی ناخوشایند استفاده‌شده است. در این آزمایش از موسیقی همراه با آواز استفاده‌نشده است تا از فعالیت مغزی ناشی از شنیدن اشعار غنائی جلوگیری شود. در انتهای هر قطعه موسیقی، از شرکت‌کنندگان خواسته‌شده تا میزان علاقه خود را به آن قطعه از شماره ۱ تا ۵ بیان کنند به‌طوری‌که هر یک از شماره‌ها بیانگر معنای خاصی باشد. (۱: اصلاً دوست نداشتم، ۲: دوست نداشتم، ۳: مردد، ۴: دوست داشتم، ۵: خیلی دوست داشتم).

در مطالعه دیگری سیگنال‌های EEG مربوط به ۹ نفر در حین گوش دادن به موسیقی ثبت‌شده و افراد مورد آزمایش در حین گوش دادن به قطعه موسیقی میزان علاقه خود به آن و میزان آشنایی قطعه موسیقی را گزارش داده‌اند [۱۳]. هدف این روش به دست آوردن شکل زمانی سیگنال‌های EEG مربوط به تأثیرات موسیقی بر مبنای میزان آشنا بودن قطعه‌های موسیقی بوده است. ویژگی‌های سیگنال EEG از باندهای بتا و گاما توسط پنجره‌های زمانی با طول‌های مختلف و با استفاده از سه توزیع TF استخراج‌شده سپس کلاسه بندهای K-NN و SVM برای کلاسه‌بندی بردارهای ویژگی به دو کلاس like و dislike مورد استفاده قرار گرفته‌اند. ابتدا بدون در نظر گرفتن میزان آشنایی قطعه موسیقی، آزمایش انجام‌شده سپس موسیقی آشنا و درنهایت موسیقی ناآشنا برای آزمایش استفاده‌شده‌اند. نتایج نشان داده‌اند که بهترین دقت کلاسه‌بندی در مورد موسیقی آشنا به دست می‌آید. میزان دقت در این مورد ۹۱.۰۲٪ است درحالی‌که با موسیقی ناآشنا دقت کلاسه‌بندی ۸۷.۱٪ به‌دست‌آمده است.

¹ K-Nearest Neighbor

² Support Vector Machine

روش سومی به نام HHS برای نمایش TF یک سیگنال وجود دارد که به کلاس‌های ذکر شده قبلی تعلق ندارد. در این روش از تجزیه موده‌های تجربی (EMD) ^۱ یک سیگنال به توابع موده‌های داخلی ^۲ (IMFs) و در نهایت اعمال تبدیل Hilbert بر روی هر IMF استفاده می‌شود.

روش EMD روشی برای شکستن یک سیگنال به اجزای کوچک‌تر بدون خارج شدن از حوزه زمان است. این روش با روش تبدیل فوریه سریع و روش تجزیه موجک قابل‌مقایسه است و برای سیگنال‌های طبیعی که بیشتر غیرخطی و نا ایستا هستند مناسب است. توابع حاصل از شکستن سیگنال توسط EMD، با این‌که لزوماً متعامد نیستند برای توصیف سیگنال مناسب‌اند. استخراج IMF از سیگنال‌های طبیعی بسیار حائز اهمیت است چراکه فرآیندهای طبیعی اغلب چندین عامل دارند و هر یک از این عوامل ممکن است در فاصله زمانی خاصی اتفاق بیفتد. این نوع اطلاعات در تحلیل EMD آشکار می‌شوند در حالی‌که در حوزه فوریه و یا تحلیل موجک این اطلاعات مخفی می‌مانند.

در مطالعه دیگری روشی وفقی برای تقطیع سیگنال EEG در حوزه زمان - فرکانس ارائه شده است با این هدف که بتوان اطلاعات مربوط به احساس را از سیگنال EEG استخراج نمود [۱۴]. به این منظور از شاخص ASI در این تحقیق استفاده شده است. همان‌طور که در بخش اول گفته شد شاخص ASI در نتیجه عدم تقارن قسمت چپ و راست بخش پیشین مغز به وجود می‌آید. با توجه به این ویژگی از این شاخص در فرآیند تقطیع استفاده شده است. عملکرد مطلوب پالایه‌های احساس مبتنی بر ASI با کلاسه‌بندی‌های بسیاری اثبات شده است. با استفاده از HOC^۳ و CC به‌عنوان روش‌های استخراج بردار ویژگی و همچنین SVM به‌عنوان کلاسه‌بند، این کلاسه‌بندی‌ها برای شش حالت مختلف احساسی در فضای ظرفیت و انگیزتگی انجام شده است. برای مشاهده تغییرات زمانی حاصل از عکس‌العمل‌های احساسی افراد مورد آزمایش و همچنین وابستگی فرکانسی بخش‌های احساسی سیگنال EEG، الگوریتم ASI بر روی سیگنال EEG اعمال شده است تا این سیگنال از تمام اطلاعات

¹ Empirical Mode Decomposition

² Intrinsic Mode Functions

³ Higher Order Crossings

غیراحساسی پاک شده و فقط اطلاعات مربوط به احساس را شامل شود. این عمل در حوزه زمان انجام می‌گیرد. AsI در پنجره‌های زمانی به سیگنال EEG اعمال شده و با این روش هر سیگنال EEG به بازه‌های مشخصی تقطیع می‌شود و از این طریق می‌توان عملیات استخراج ویژگی را در هر یک از این قطعات برای استخراج ویژگی‌های مربوط به احساس انجام داد. این کار در مقایسه با استخراج ویژگی از سیگنال خام EEG نتایج بهتری خواهد داشت. در این تحقیق از روش EMD برای نمایش فرکانسی-زمانی سیگنال EEG استفاده شده است؛ بنابراین می‌توان AsI را یا به صورت کلی، یعنی بر روی همه قطعه‌های IMF اعمال کرد و یا به صورت محلی در یک پنجره زمانی از آن استفاده نمود. هر بار یک بازسازی صورت می‌گیرد و بردار ویژگی استخراج می‌شود. در این آزمایش EMD سیگنال EEG مربوط به ۱۶ نفر ثبت شده است و اطلاعات مربوط به احساسات با سه نوع تقطیع سیگنال EEG استخراج شده‌اند. اولین روش تقطیع $wAsI^1$ است که در آن از AsI در یک پنجره زمانی استفاده شده است. روش دوم $EMD-AsI^2$ است که شامل کاربرد AsI در حوزه EMD است و باهدف انتخاب مناسب‌ترین قطعه‌های IMF که دارای اطلاعات احساسی هستند انجام شده است و آخرین روش $EMD-wAsI^3$ است که بر روی هر IMF به صورت محلی کار می‌کند و قطعاتی از آن را که بیشترین اطلاعات را در مورد احساس دارند استخراج می‌نماید. متوسط نتایج به دست آمده در این مطالعه، دارای دقت بین ۶۴.۱۷٪ تا ۸۲.۹۱٪ هستند.

در برخی از گزارش‌ها نیز ویژگی‌ها بر اساس تغییرات طیف توان به دست آمده‌اند. طیف توانی اجزای سیگنال EEG قابل قبول‌ترین ویژگی‌ها هستند که در آن اجزای سیگنال EEG طبق بازه فرکانسی تعریف شده‌اند. در مطالعه‌ای برای دست آوردن طیف توانی، STFT با ۵۱۲ نقطه و پنجره Hanning به طول یک ثانیه به هر یک از سی کانال EEG اعمال شده و سری‌های زمانی طیفی در پنج باند فرکانسی دلتا، تتا، آلفا، بتا و گاما محاسبه شده و دسته‌بندی ویژگی‌ها با استفاده از دو کلاسه

¹ Window -AsI

² Empirical Mode Decomposition- AsI

³ Empirical Mode Decomposition – window AsI

بند MLP^۱ و SVM انجام گرفته است [۱۵]. کلاسه بند MLP دارای یک لایه ورودی، یک لایه مخفی با تابع sigmoid و یک لایه خروجی بوده و بر اساس نوع ویژگی به کاررفته تعداد نرون های مخفی استفاده شده در لایه مخفی و ورودی متغیر هستند؛ اما لایه خروجی دارای ۴ نرون است که مربوط به ۴ حالت حسی است. از SVM برای دسته بندی احساس مربوط به سیگنال های EEG برچسب زده شده استفاده شده است. یادگیری مکرر توسط SVM باعث می شود که بیشینه حاشیه بین کلاس ها به دست آید. دقت کلاسه بندی با استفاده از این کلاسه بند $89.29 \pm 3.06\%$ به دست آمده است. همچنین از نسبت واریانس بین کلاسی به واریانس داخل کلاسی برای مرتب نمودن ویژگی ها به ترتیب نزولی استفاده شده است. نتایج نشان می دهند که عدم تقارن دیفرانسیلی ۱۲ جفت الکتروود (DASM12)^۲ که باعث عدم تقارن طیف توان در باندهای فرکانسی مختلف است، معیار اندازه گیری حساسی برای توصیف فعالیت مغز در پاسخ به حالت های احساسی است.

در مقاله ای نیز بعد از اعمال STFT مقدار توان هر جزء EEG در طول زمان به دست آمده است [۱۶]. در این مطالعه از SVM برای کلاسه بندی استفاده شده است. دقت به دست آمده 82.37% برای تشخیص احساسات خوشی، ناراحتی، عصبانیت و لذت بوده و با استفاده از تحلیل خطی فیشر دقتی برابر با 92.3% به دست آمده است.

در مقاله دیگری طیف توان سیگنال EEG با استفاده از تبدیل فوریه سریع (FFT)^۳ ۲۵۶ نقطه ای محاسبه شده است [۱۷]. قبل از اعمال FFT بخش های اصلاح شده سیگنال با تابع Hanning توسط نرم افزار شبیه ساز LabVIEW^۴ پنجره گذاری شده اند تا از نشت طیفی جلوگیری شود. با تعریف باندهای فرکانسی برای سیگنال EEG نظیر باندهای تتا، آلفا و بتا، میانگین توان سیگنال EEG در فرکانس های ۴-۷ هرتز، ۸-۱۳ هرتز و ۱۴-۴۰ هرتز محاسبه شده است. برای کاهش واریانس متوسط توان هر باند سیگنال EEG، این توان توسط خط پایه (baseline) مربوط به همان باند فرکانسی نرمال

^۱ Multi Layer Perceptron


^۲ Differential Asymmetry of 12 electrode pairs

^۳ Fast Furier Transform

^۴ Laboratory Virtual Instrument Engineering

شده است. بعد از استخراج ویژگی‌ها، کلاسه‌بندی توسط کلاسه بند SVM انجام گرفته است. نتایج SVM نشان داده‌اند که برای ۲۸ فرد مورد آزمایش دقتی بیشتر از ۸۰٪ به دست می‌آید. در این مطالعه از نرم‌افزار پخش موسیقی که به‌طور همزمان فعالیت مغز را در زمان واقعی تحلیل می‌کند استفاده شده و اطلاعات به دست آمده از این تحلیل در اختیار روانشناسان قرار گرفته است تا برای شناسایی احساس افراد، مورد استفاده قرار گیرند. در این مطالعه ۲۸ نفر شرکت کرده‌اند و سیگنال EEG افراد در حین پخش موسیقی با ۵ الکتروود ثبت شده است.

در مطالعه دیگری که برای یافتن ارتباط بین سیگنال‌های EEG و احساس انسان انجام شده است مجدداً از تبدیل فوریه FFT با یک پنجره یک‌ثانیه‌ای برای محاسبه طیف هر کانال و هر باند فرکانسی استفاده شده و لگاریتم انرژی هر کانال به‌عنوان ویژگی در نظر گرفته شده است [۱۸]. ابتدا ویژگی‌ها از داده‌های EEG اصلی استخراج شده سپس به‌جای استفاده مستقیم از ویژگی‌ها با استفاده از یک سیستم دینامیک خطی این ویژگی‌ها هموار شده‌اند. محرکی که برای تحریک احساسات در این آزمایش مورد استفاده قرار گرفته است انواع مختلفی از کلیپ‌های ویدئویی ۴ ثانیه‌ای است. این کلیپ‌ها دارای محتوای موسیقی، عشق، جنگ، فاجعه و چشم‌انداز هستند. برای اندازه‌گیری محتویات احساسی هر یک از کلیپ‌ها از آزمون خودارزیابی تصاویر آدمک (SAM)^۱ استفاده شده است که دارای ۹ سطح برای خوشایندی و برانگیختگی است. این آزمون از شکل‌های آدمک برای هر یک از ابعاد عاطفی استفاده می‌کند.



شکل ۲-۲ بخشی از تصاویر آزمون خودارزیابی آدمک [۱۶].

در آزمایش ذکر شده در حدود ۱۲ کلیپ ویدئویی یعنی تقریباً در حدود ۶ کلیپ برای هر احساس استفاده شده است. در طول آزمایش تمام این کلیپ‌ها به‌طور تصادفی نمایش داده شده و سیگنال مغزی هر سوژه با استفاده از یک کلاه ۶۲ کانالی ثبت شده است. بعد از نمایش هر کلیپ از سوژه

^۱ Self-Assessment Manikin

خواسته شده تا فرم SAM را پر کند. روش استخراج ویژگی‌ها به این صورت بوده است که با توجه به برگه‌های SAM، دوره‌ای از آزمایش که دارای امتیاز ۳ و یا بیشتر است انتخاب می‌شود. چراکه اگر امتیاز یک دوره از آزمایش‌ها کمتر از ۳ باشد به این معناست که آن آزمایش موفق به تحریک یک احساس خاص در فرد نبوده است. در این تحقیق فقط دو نوع احساس در نظر گرفته شده‌اند، احساس مثبت و احساس منفی، بنابراین احساس بر اساس بعد اول یعنی خوشایندی برچسب‌زنی می‌شود. اگر امتیاز این بعد کمتر از ۵ باشد در این صورت احساس مربوط به کلاس منفی است در غیر این صورت احساس مثبت خواهد بود. بعد از اینکه امواج زمانی سیگنال EEG مورد بررسی قرار گرفتند مجموعه‌ای از پالایه‌های میان‌گذر برای تفکیک سیگنال EEG به باندهای دلتا (۴-۱ هرتز)، تتا (۸-۴ هرتز)، آلفا (۱۳-۸ هرتز)، بتا (۳۰-۱۳ هرتز) و گاما (۴۰-۳۶ هرتز) مورد استفاده قرار گرفته‌اند. پنج روش SVM با کرنل خطی برای آموزش و آزمودن ویژگی‌ها به کار رفته است. در نهایت تمام این ویژگی‌ها به صورت یک بردار ویژگی با یکدیگر ترکیب شده‌اند و ششمین SVM خطی بر روی آن‌ها اعمال شده است. هدف اصلی این مطالعه یافتن ارتباط بین سیگنال EEG و احساسات بشر است. این ارتباط باید قابل پیاده‌سازی بر زندگی روزمره بشر باشد. در صورتی که استفاده از یک کلاه ۶۲ الکترودی در طول روز راحت نیست؛ بنابراین انتخاب نواحی و باندهای مرتبط با احساسات بسیار مهم است. در این مطالعه به این نکته اشاره شده است که روش‌های کاهش ابعاد بدون نظارت مانند (PCA)^۱ همیشه پاسخ مطلوبی ندارند. به جای آن ضرایب همبستگی بین ویژگی‌ها و برچسب‌ها در مجموعه آموزش برای هر کانال و هر باند محاسبه شده‌اند. سپس ضرایب همبستگی به‌طور نزولی مرتب‌شده و هر بار ویژگی مربوط به N عدد از بالاترین ضرایب انتخاب می‌شوند تا با هم در SVM خطی استفاده شوند. متوسط دقت به دست آمده برای مجموعه آزمودنی با استفاده از تمام ویژگی‌ها و کلاسه بند SVM ۸۷.۵۳٪ به دست آمده است. سپس ابعاد ویژگی‌ها با استفاده از ضرایب همبستگی کاهش داده شده است به این

^۱ Principle Component Analysis

صورت که ۱۰۰ و ۵۰ ویژگی اول برای کلاسه‌بندی استفاده شده‌اند که در این حالت دقت به‌دست‌آمده به ترتیب ۸۹.۲۲٪ و ۸۴.۹۴٪ است.

در یکی از تحقیقات نیز که از تبدیل فوریه برای استخراج ویژگی‌ها استفاده شده است انتخاب ویژگی‌ها بر اساس ضرایب همبستگی پیرسون انجام گرفته است [۱۹]. در این مطالعه از کلاسه بند احتمالاتی بیزین استفاده شده و یادگیری با نظارت با استفاده از الگوریتم پرسپترون انجام شده است. در کلاسه بند بیزین تابع وزن‌دهی لگاریتمی پسین^۱ برای بردارهای ویژگی معرفی شده که در آن وزن هر ویژگی با استفاده از همگرایی الگوریتم پرسپترون تنظیم می‌شود. برای ارزیابی روش پیشنهادی از پایگاه داده DEAP برای تحلیل احساس با استفاده از سیگنال‌های فیزیولوژیکی استفاده شده و یک احساس خاص به‌صورت کلاس دوسطحی و کلاس سه سطحی برای بُدهای خوشایندی و برانگیختگی تعریف شده است. این کار بر مبنای مقادیر SAM انجام شده و برای کلاس دوسطحی متوسط دقت بُد خوشایندی و برانگیختگی ۷۰.۹٪ و ۷۰.۱٪ به‌دست‌آمده است و برای کلاس سه سطحی به ترتیب برای بُدهای خوشایندی و برانگیختگی دقت کلاسه‌بندی ۵۵.۴٪ و ۵۵.۲٪ به‌دست‌آمده است.

۲-۳- تحلیل زمانی

در مقاله مرجع [۲۰] از طریق پردازش غیرخطی سیگنال EEG تأثیر احساسات بر فعالیت مغز مورد مطالعه قرار گرفته است. اکثر مقاله‌ها از تصاویر برای تحریک احساسات استفاده کرده‌اند، در این مقاله از موسیقی استفاده شده است. پنج فرد راست‌دست و مؤنث سالم، بین سنین ۲۲ تا ۲۵ سال، در این مطالعه شرکت کرده‌اند. برای درک بهتر دینامیک سیستم از تحلیل سری‌های زمانی غیرخطی استفاده شده است. سیگنال EEG از ۱۹ قسمت مغز، در حالت‌های مختلف گرفته شده که این حالت‌ها با تحریک‌های ناشی از موسیقی ایجاد شده‌اند و همچنین دوره‌ی استراحت نیز در نظر گرفته شده است که در آن هیچ فعالیت مغزی توسط فرد انجام نمی‌گیرد. سپس سیگنال EEG دوره استراحت با

^۱ weighted-log-posterior

سیگنال مربوط به هر یک از حالت‌های احساسی مقایسه شده و مکان تغییر ابعاد همبستگی، در حالت‌های مختلف مشخص شده است. ابتدا برای کاهش عملیات محاسباتی ابعاد همبستگی برای ۱۰ ثانیه از سیگنال EEG محاسبه شده‌اند. سپس برای ارزیابی اثر طول سیگنال بر ابعاد همبستگی بازه ۲۰ ثانیه‌ای دیگری از سیگنال EEG در نظر گرفته شده و مجدداً ابعاد همبستگی محاسبه شده‌اند. نتایج نشان داده‌اند که ابعاد همبستگی در حین تجربه احساسی در مقایسه با حالت استراحت کاهش می‌یابند. در واقع انجام یک کار، پیچیدگی بعدها را کاهش می‌دهد. هر چه ابعاد همبستگی به دست آمده برای یک ناحیه از مغز نسبت به حالت استراحت پایین‌تر باشد نشان می‌دهد که آن ناحیه در آن تجربه احساسی نقش فعال‌تری داشته است. در این مطالعه ۴ قطعه موسیقی، از موسیقی سنتی هندی و موسیقی غربی کلاسیک در دو حالت (خوشایندی پایین و خوشایندی بالا) انتخاب شده‌اند. تقریباً تمامی سری‌های زمانی، حرکت‌های بالا و پایین محلی و سرتاسری امواج، سیگنال‌ها و یا توابع را در طول زمان نشان می‌دهند. این رفتار که در سری‌های کران‌دار با میانگین صفر دیده می‌شود می‌تواند با شمارش تعداد گذر از صفرها بیان شود. چرا که این نوع سری‌های زمانی در نقطه صفر نوسان می‌کنند. زمانی که پالایه‌ای به یک سری زمانی اعمال می‌شود نوسانات آن سری زمانی را تغییر می‌دهد؛ بنابراین تعداد گذر از صفرها نیز تغییر خواهد کرد. با توجه به این موضوع روشی تکراری در نظر گرفته می‌شود. به این صورت که ابتدا پالایه‌ای به سری‌های زمانی اعمال می‌شود و تعداد عبور از صفرها در سری‌های زمانی پالایش شده شمارش می‌شوند سپس پالایه دیگری مجدداً به سری‌های زمانی اصلی اعمال شده و دوباره تعداد عبور از صفرها شمارش می‌شوند و این عمل تکرار می‌شود. تعداد عبور از صفرهای حاصل از این عملیات همان HOC خواهد بود. زمانی که دنباله خاصی از پالایه‌ها به یک سری زمانی اعمال می‌شوند دنباله‌ای از تعداد عبور از صفرها به دست می‌آید که دنباله HOC نامیده می‌شود.

در مقاله‌ای مجموعه بردارهای ویژگی بر اساس دو روش HOC و ¹CC ساخته شده‌اند و SVM با کرنل چندجمله‌ای درجه پنج برای کلاسه‌بندی مورد استفاده قرار گرفته است [۲۱]. روش پیشنهاد شده در این مقاله به سیگنال‌های EEG سه کانالی ثبت شده از ۱۶ فرد سالم و راست دست اعمال شده است. برای ارزیابی عملکرد ASI کلاسه‌بندی با استفاده از دو روش استخراج بردار ویژگی HOC و CC و کلاسه بند SVM برای ۶ حالت مختلف انجام شده است. برای جمع‌آوری پایگاه داده سیگنال‌های EEG، ۱۶ نفر (۹ مرد و ۷ زن) سالم و راست دست (بین سنین ۱۹ تا ۳۲ سال) مورد آزمایش قرار گرفته‌اند. نرخ کلاسه‌بندی در حالت بدون وابستگی به فرد مورد آزمایش ۶۲.۵۸٪ و برای حالت وابسته به فرد ۹۴.۴٪ به دست آمده است.

در مطالعه دیگری نیز روش HOC برای استخراج ویژگی‌ها استفاده شده است و روش کلاسه‌بندی HOC-EC^۲ به ویژگی‌ها اعمال شده است [۲۲]. در این روش کلاسه‌بندی از ۴ کلاسه بند مختلف استفاده شده است: QDA، K-NN، MD و SVM. اطلاعات EEG با استفاده از چند گروه تصویر چهره که هر گروه بیانگر احساس خاصی هستند از شانزده فرد سالم جمع‌آوری شده‌اند. در طول دوره آزمایش ۶۰ تصویر که هر ۱۰ عدد از آن‌ها متعلق به یک احساس خاص است به‌طور تصادفی به مدت ۵ ثانیه (بعد از ۵ ثانیه دیدن صفحه سیاه) بر روی صفحه‌نمایش داده شده‌اند. بعد از دیدن همه تصاویر از فرد مورد نظر خواسته شده تا احساس خود را نسبت به هر یک از تصاویر بیان کند. این احساس در غالب ۶ نوع حس مختلف، بیان می‌شود. چنانچه حس فرد مربوط به هیچ‌یک از ۶ نوع احساس فرض شده نباشد، شرکت‌کننده باید گزینه "سایر" را انتخاب نماید. ثبت سیگنال EEG در این آزمایش از ۴ قسمت مختلف مغز انجام شده است. دو حالت مختلف برای ثبت سیگنال در نظر گرفته شده: حالت اول اینکه از یک کانال و حالت دوم اینکه از ترکیبی از کانال‌ها برای ثبت سیگنال EEG استفاده شود. کلاسه‌بندی بین ۶ احساس شادی، شگفت‌زدگی، عصبانیت، ترس، نفرت و ناراحتی انجام شده است. دقت کلاسه‌بندی در حالت یک کانالی ۶۲.۳٪ و در حالت چند کانالی ۸۳.۳۳٪ به دست آمده است.

¹ Cross Correlation

² HOC-Emotion Classifier

۲-۴- تبدیل موجک

در مقاله‌ای تبدیل موجک برای استخراج ویژگی‌ها و Fuzzy C-Means برای خوشه‌بندی حالت-های احساسی ناراحتی، شادی، نفرت و ترس استفاده شده است [۲۳]. در این مطالعه شش شرکت‌کننده سالم در گروه سنی ۲۷-۲۱ سال مورد آزمایش قرار گرفته‌اند. این آزمایش با استفاده از ۶۳ حس‌گر برای ثبت سیگنال EEG انجام شده است. برای تحریک احساسات از قطعه‌های ویدئویی تجاری استفاده شده است. بعد از انجام عملیات پیش‌پردازش بر روی سیگنال‌های ثبت‌شده، دو روش مختلف تبدیل موجک LBWT^۱ برای استخراج ۳ ویژگی آماری به کار گرفته شده‌اند. ویژگی اول انرژی است. این ویژگی با به توان ۲ رساندن ضرایب موجک در هر زیرباند فرکانسی به دست می‌آید. ویژگی دوم اثربخشی بازگشتی انرژی (REE)^۲ است. این اثربخشی به صورت نسبت انرژی زیرباند فرکانسی به کل انرژی بردار ضریب تجزیه، تعریف می‌شود. ویژگی سوم ریشه دوم و یا همان RMS^۳ است. این ویژگی با جذر گرفتن از ضرایب موجک اثربخشی بازگشتی انرژی در باند آلفا به دست می‌آید. تبدیل موجک این امکان را فراهم می‌سازد که بتوان در مواقع نیاز به اطلاعات دقیق فرکانس پایین از فاصله‌های زمانی بلند و اطلاعات فرکانس بالا از فاصله‌های زمانی کوتاه رسید.

تبدیل موجک گسسته (DWT)^۴ روشی قوی در تحلیل‌های چند کیفیتی (MRA)^۵، آشکارسازی قله و استخراج ویژگی سیگنال‌های فیزیولوژیکی و تصاویر پزشکی است.

انواع مختلف احساس، شکل موج متفاوتی دارند؛ بنابراین موجک بهینه‌ای که برای شناسایی همه احساسات مناسب باشد وجود ندارد. از جمله مشکلاتی که در استفاده از تبدیل موجک وجود دارد این است که این تبدیل پیچیدگی محاسباتی بالایی داشته و حافظه زیادی نیاز دارد. روش lifting روش جدیدی برای ساختن موجک با مشخصات مطلوب است.

^۱ Lifting Based Wavelet Transform

^۲ Recoursing Energy Efficiency

^۳ Root Mean Square

^۴ Discete Wavelet Transform

^۵ Multi Resolution Analysis

در مطالعه دیگری ویژگی‌های دامنه و تأخیر برای مؤلفه‌های پتانسیلی P100, N100, P200, N200, P300 استخراج شده و فعالیت نوسانی باندهای فرکانسی دلتا، تتا و آلفا با استفاده از تبدیل موجک گسسته به دست آمده‌اند [۲۴]. تصاویر پایگاه داده IAPS برای تحریک احساس در این تحقیق استفاده شده‌اند. در این مطالعه سیگنال‌های EEG در ۴ کلاس احساسی HVLA^۱، LVHA^۲، HVHA^۳ و LVL^۴ قرار داده شده‌اند و پتانسیل‌های استخراج شده از سه الکتروود مرکزی Fz, Cz, Pz مورد تحلیل قرار گرفته‌اند. این پتانسیل‌ها، پتانسیل‌های ERPs^۵ نامیده می‌شوند. در این آزمایش برای سادگی از تعداد الکتروودهای کمی استفاده شده است، چراکه هدف این مقاله ارائه روش مؤثر اما ساده و مناسب برای کاربردهای واقعی در زندگی روزمره است؛ بنابراین باید بین شناخت دقیق احساسات و استفاده حداقل از الکتروودها مصالحه‌ای صورت گیرد. برای هر الکتروود پنج مؤلفه مورد بررسی قرار گرفته‌اند. هر مؤلفه بر اساس قطبیت با P، یعنی جهت مثبت و یا با N، به معنی جهت منفی و با یک شماره که نشان‌دهنده میزان تأخیر آن نسبت به آغاز تحریک است نام‌گذاری می‌شود. روش کلاسه‌بندی ارائه شده مجدداً بر اساس دو بعد خوشایندی و برانگیختگی است. کلاسه‌بندی در دو مرحله انجام شده است. در مرحله اول کلاسه‌بندی بر اساس میزان برانگیختگی و در مرحله بعد تفکیک بر مبنای تفاوت خوشایندی صورت گرفته است. کلاسه‌بندی سطح برانگیختگی برای ۱۱۲ مجموعه احساس در مرحله اول با در نظر گرفتن دو حالت مستقل از جنسیت فرد و وابسته به جنسیت فرد انجام شده است؛ بنابراین بلوک‌های کلاسه‌بندی برای هر دو گروه مرد و زن دارای تعداد برابری از نمونه‌ها (۵۶ عدد) هستند و باید تعداد زن‌ها و مرد‌های شرکت‌کننده در این آزمایش با یکدیگر برابر باشند. بعد از به دست آوردن بعد برانگیختگی، کلاسه‌بندی بعد خوشایندی با در نظر گرفتن اطلاعات برانگیختگی و جنسیت انجام شده است. در اینجا از کلاسه‌بندهای MD و SVM استفاده شده است. دقت برای هر یک از کلاسه‌بندها، به ترتیب ۷۹.۵٪ و ۸۱.۳٪ به دست آمده است.

¹ High Valence High Arousal

² Low Valence High Arousal

³ High Valence Low Arousal

⁴ Low Valence Low Arousal

⁵ Event Related Potentials

۲-۵- تحلیل CSP

یکی از روش‌های موفق در BCI مبتنی بر تصور حرکتی روش CSP^۱ است. در روش CSP برای استخراج ویژگی، پالایه‌های مشترک فضایی بر کل سیگنال EEG در یک مقطع زمانی اعمال می‌شوند. با در نظر گرفتن اینکه ERD/ERS^۲ در طول زمان ثابت نمی‌ماند، نویسندگان مقاله‌ای، سیگنال EEG را به تعدادی زیر بخش تقسیم کرده‌اند [۲۵]. در واقع آن‌ها بر این باور بوده‌اند که میزان اهمیت کانال‌های EEG برای کلاسه‌بندی، در بخش‌های مختلف زمانی تغییر می‌کند، به همین دلیل ویژگی‌ها از هر بخش زمانی به‌طور جداگانه با استفاده از تحلیل CSP استخراج می‌شوند. این روش دارای دو حالت آموزش و آزمون است.

هدف آموزش این است که کلاسه‌بندی برای دسته‌بندی نمونه‌های EEG طراحی شود. این فاز از گام‌های زیر تشکیل شده است:

۱. پیش‌پردازش: قبل از تعریف پالایه‌های فضایی فرکانس نمونه‌های EEG به ۱۰۰ هرتز کاهش یافته است و بعد نمونه‌ها از ۸ تا ۳۰ هرتز پالایش شده‌اند.

۲. تقطیع زمانی: طول بازه زمانی به‌عنوان یک پارامتر معرفی شده است، چراکه ممکن است با در نظر گرفتن یک میزان تداخل مشخص بین بازه‌های زمانی، طول بازه‌ها برای افراد مختلف متفاوت به دست آیند.

۳. استخراج پالایه‌های فضایی: در این گام روش CSP اعمال شده است.

۴. ویژگی‌های آموزش

۵. آموزش کلاسه بند

^۱ Common Spatial Pattern

^۲ Event-Related Desynchronization/ Event-Related Synchronization

برای کلاسه‌بندی سیگنال‌های EEG تصور حرکتی، از کلاسه بند LDA مبتنی بر OVR¹ برای طبقه‌بندی ویژگی‌های استخراج‌شده استفاده شده است. در این مقاله ۴ کلاس تصور حرکت دست راست، دست چپ، پا و زبان در نظر گرفته شده است و از پایگاه داده 2a که متعلق به چهارمین دوره مسابقات BCI است، استفاده شده است. سیگنال‌های EEG ثبت‌شده، علاوه بر سیگنال‌های ERD و ERS با سیگنال‌های مربوط به فعالیت‌های طبیعی مغزی و اثرات تصنعی مانند EMG و EOG همراه‌اند. با وجود این اعوجاج‌ها، نسبت سیگنال به نویز در سیگنال EEG کاهش می‌یابد، بنابراین شناسایی وقایع ERD/ERS در سیگنال‌های EEG بسیار دشوار خواهد شد. همچنین به‌علت استخوانی بودن بافت جمجمه، سیگنال‌های تولیدشده در غشای مغز، قبل از رسیدن به جمجمه با یکدیگر تداخل می‌کنند. این امر به این معنی است که سیگنال کانال‌های EEG، مجموع تعداد زیادی سیگنال تولیدشده در زیر جمجمه انسان هستند؛ بنابراین انتخاب کانال‌های مناسب برای طبقه‌بندی کلاس‌ها و استخراج ویژگی‌های مهم از کانال‌های EEG انتخاب‌شده، دشوار است. برای استخراج ویژگی‌های متمایزکننده از سیگنال‌های EEG، الگوریتم‌های پردازش سیگنال و شناسایی الگوی بسیار زیادی استفاده شده‌اند که یکی از مهم‌ترین روش‌های استفاده‌شده برای کاهش تعداد کانال‌ها، CSP است. در این مقاله برای مقایسه روش پیشنهادشده با سایر روش‌ها از معیاری به نام امتیاز Kappa استفاده شده است. این معیار روشی است که در اکثر مسابقات BCI برای ارزیابی استفاده می‌شود. نتایج به‌دست‌آمده در این مطالعه نسبت به روش CSP معمولی و نتایج بهترین شرکت‌کننده در چهارمین مسابقات BCI، بهتر بوده است.

در تحقیق دیگری نیز که در حوزه تصور حرکتی انجام شده از تحلیل CSP برای استخراج ویژگی‌های مربوط به حرکت دست راست و چپ استفاده شده است [۲۶]. در این مطالعه ۳ نفر در آزمایش‌ها شرکت کرده‌اند. دوره آموزش ۳ روز طول کشیده است. الگوهای استخراج‌شده با استفاده از تحلیل CSP فعال شدن ناحیه قشری مغز را منعکس می‌کنند. تحلیل CSP با توجه به اهمیت هر

¹ One-Versus the Rest

الکتروود در جداسازی کلاس‌ها، وزنی را به آن نسبت می‌دهد و با استفاده از همبستگی بین الکتروودهای همسایه نویز را در هر کانال کاهش می‌دهد. با این روش درصد خطا برای هر یک از شرکت‌کننده‌ها به ترتیب ۰.۲٪، ۰.۶٪ و ۰.۱۴٪ به دست آمده است.

۲-۶- ادغام ویژگی‌های فرکانسی و ویژگی‌های زمانی

مقاله دیگری از روشی به نام W-CSP^۱ برای استخراج ویژگی‌های مربوط به سرعت حرکت دست از سیگنال EEG استفاده کرده است [۲۷]. به این منظور آزمایشی برای جمع‌آوری اطلاعات EEG از افراد مورد مطالعه انجام شده است. این آزمایش در حین حرکت دست راست با دو سرعت متفاوت، حرکت به صورت آهسته و حرکت سریع دست و در چهار جهت مختلف صورت گرفته است. ویژگی‌هایی که اطلاعات قابل توجهی به همراه داشتند با استفاده از الگوریتم W-CSP استخراج شده‌اند. سپس کاربرد این ویژگی‌ها برای کلاسه‌بندی دو سرعت مختلف و بازسازی مجدد پروفایل سرعت مورد مطالعه قرار گرفته است. کلاسه‌بندی سرعت برای ۷ نفر، با استفاده از کلاسه بند فیشر (FLD)^۲، دقت متوسطی برابر با ۸۳.۷۱٪ داشته است. عنصرهای مربوط به سرعت با استفاده از چند رگرسیون خطی به دست آمده‌اند و به طور متوسط همبستگی بین سرعت‌های ثبت شده و بازسازی شده ۰.۵۲٪ گزارش شده است. الگوهای فضایی ویژگی‌های استخراج شده با روش W-CSP، واکنش‌هایی را در بخش‌های دیواره‌ای و حرکتی مغز نشان داده‌اند.

در مقاله دیگری از ECoG^۳ برای تحلیل تغییر ایجاد شده در سیگنال EEG در اثر حرکت بازو استفاده شده است [۲۸]. در روش ECoG قسمتی از مجسمه برداشته شده و الکتروودها مستقیماً بر روی مغز قرار داده می‌شوند. نویسنده این مقاله نشان داده است که مدولاسیون دامنه طیف در

^۱ Wavelet-Common Spatial Pattern

^۲ Fisher Linear Discriminant

^۳ Electrocorticography

فرکانس‌های پایین و باند فرکانسی بالای گاما، در بخش‌های پیش حرکتی، بخش‌های جلویی و دیواره‌ای مغز، اطلاعات مربوط به جهت حرکت دست را تولید می‌کند.

برای استخراج ویژگی‌های مربوط به سرعت حرکت از بخش فرکانس پایین سیگنال EEG، نیاز به الگوریتم استخراج ویژگی است که دقت بالایی در تجزیه سیگنال‌های موجود در فرکانس‌های بسیار پایین داشته باشد. در اینجا از تحلیل موجک برای استخراج ویژگی‌های متمایزکننده استفاده شده است. الگوریتم Wavelet-CSP پیشنهادشده، پالایش فضایی را نیز با استفاده از الگوریتم CSP به کار می‌برد. می‌توان الگوریتم CSP را با استفاده از روش‌های مختلف بهینه‌سازی باند فرکانسی، مانند FBCSP¹ بهبود داد، ولی باینکه FBCSP در کلاسه‌بندی تصور حرکت دست راست و چپ عملکرد قابل قبولی دارد اما فرکانس ثابت و عملکرد نامطلوب آن در فرکانس‌های پایین باعث شده است که امکان استفاده از این روش برای به دست آوردن پارامترهای مربوط به حرکت، مانند سرعت، وجود نداشته باشد؛ بنابراین روش Wavelet-CSP به کار گرفته شده در این مقاله از تبدیل موجک به جای بانک فیلتری استفاده کرده است. نتایج به دست آمده نشان می‌دهند که با روش پیشنهادی می‌توان سامانه‌هایی را که شامل کنترل سرعت حرکت هستند، بهتر پیاده‌سازی کرد.

در مطالعه دیگری که بر روی تصور حرکتی انجام شده است ابتدا حذف نویز سیگنال‌های EEG با استفاده از تبدیل موجک انجام شده و بعد ویژگی‌ها توسط تحلیل CSP استخراج شده‌اند و در نهایت کلاسه بند SVM برای کلاسه‌بندی ویژگی‌ها استفاده شده است [۲۹]. در واقع در این تحقیق از کیفیت خوب تبدیل موجک در پردازش سیگنال‌های نا ایستا برای بهبود ویژگی‌های سیگنال استفاده شده، سپس سیگنال توسط تحلیل پالایه CSP پردازش شده تا بیشینه تفاوت انرژی بین دو کلاس به دست آید؛ بنابراین اطلاعات مهم دو کلاس حفظ شده و نویز حذف می‌شود. ثابت شده است که روش Wavelet+CSP پایداری مقادیر ویژه را حفظ می‌کند. دقت کلاسه‌بندی ۹۳.۵٪ به دست آمده است.

¹ Filter Bank CSP

۷-۲- الگوریتم NMF

الگوریتم دیگری که تاکنون برای استخراج ویژگی از سیگنال EEG استفاده شده است الگوریتمی به نام NMF^۱ است. در مطالعه‌ای از این الگوریتم برای استخراج ویژگی‌های مربوط به تصور حرکتی و افزایش تمایز بین دو کلاس استفاده شده است [۳۰]. درصد کلاس‌بندی داده‌های پایگاه داده IDIAP با استفاده از این روش ۷۵٪ به دست آمده است.


^۱ Nonnegative Matrix Factorization

فصل ۳

تئوری‌های استفاده‌شده در تحقیق

۳-۱- تبدیل موجک

همان‌طور که می‌دانیم موجک‌ها دسته‌ای از توابع ریاضی هستند که برای تجزیه سیگنال پیوسته به مؤلفه‌های فرکانسی آن به کار می‌روند. تبدیل موجک گسسته بسته‌ای (DWPT)^۱ یک دیکشنری می‌سازد که بر اساس آن می‌توان یک سیگنال را نمایش داد [۳۱]. روش‌های DWT و DWPT هر دو وابسته به زمان‌اند و با جابه‌جایی زمانی تغییر می‌کنند. همچنین زمانی که این دو روش در فضای دوبعدی مورد استفاده قرار می‌گیرند از لحاظ هندسی منجر به یک تحلیل جهت‌دار نمی‌شوند. تبدیل موجک مختلط با دوگانه (DTCWT)^۲ تقریباً مستقل از زمان بوده و با جابه‌جایی تغییر نمی‌کند و در حالت‌های چندبعدی نیز تحلیل جهت‌داری نتیجه می‌دهد. علاوه بر فیلتر بانک^۳ استفاده‌شده در DWT، روش DTCWT فیلتر بانک دومی نیز دارد که با استفاده از معیار خاصی طراحی شده است. فیلتر بانک دوم طوری طراحی شده است که پاسخ‌های ضربه آن تقریباً برابر با تبدیل هیلبرت پاسخ‌های ضربه فیلتر بانک اول باشند. سپس با در نظر گرفتن فیلتر بانک اول به‌عنوان بخش حقیقی و فیلتر بانک دوم به‌عنوان بخش موهومی یک تبدیل مختلط فرکانسی مطابق شکل (۳-۱) دست می‌آید.



شکل ۳-۱ تحلیل حوزه فرکانس DTCWT [۳۱].


برای به دست آوردن مشخصات دلخواه از الگوریتم DTCWT، تحلیل‌پذیر بودن پاسخ فرکانسی هر کانال اهمیت زیادی دارد.

^۱ Discrete Wavelet Packet Transform

^۲ Dual Tree Complex Wavelet Transform

^۳ Filter Bank

یکی از روش‌های عمومی‌سازی DWT برای تولید یک دیکشنری ساختاریافته از پایه‌ها، استفاده از روش تبدیل موجک گسسته بسته‌ای (DWPT) است. این تبدیل با تجزیه یک فیلتر بانک در هر دو خروجی بالا گذر و پایین گذر به دست می‌آید و یک تحلیل در حوزه فرکانس به صورت شکل (۲-۳) ایجاد می‌کند.




شکل ۲-۳ تحلیل حوزه فرکانس DWPT [۳۱].

البته مانند تحلیل DWT، تحلیل DWPT نیز متغیر با زمان بوده و جهت‌های عمودی را در حالت چندبعدی مخلوط می‌کند.

با استفاده از روش درخت دوگانه می‌توان مدل مختلط تحلیل DWPT را به دست آورد. همانند DTCWT، روش تبدیل موجک بسته‌ای مختلط با درخت دوگانه (DTCWPT)^۱ نیز باید مستقل از زمان بوده و در حالت چندبعدی از لحاظ هندسی جهت‌دار باشد. بهترین راه برای تولید یک درخت دوگانه مختلط از DWPT این است که هر یک از دو DWT را که برای ساخت DTCWT استفاده شده‌اند با استفاده از همان مجموعه فیلترها به بسته‌هایی توسعه دهیم. هرچند در چند زیرباند انرژی فراوانی به باند فرکانسی منفی نشت می‌کند شکل (۳-۳).

^۱ Dual Tree Complex Wavelet Packet Transform



شکل ۳-۳ تحلیل حوزه فرکانس DTCWPT تحلیل ناپذیر [۳۱].

این زیرباندها تحلیل پذیر نیستند و متأسفانه این ساختار مشخصات مطلوب DTCWPT را نخواهد داشت.

۳-۱-۱- تبدیل DTCWT:

این تبدیل شامل دو تبدیل موجک است که به طور موازی بر روی سیگنال ورودی اعمال می شوند. موجک مربوط به فیلتر بانک اول را با $\psi(t)$ و موجک مربوط به فیلتر بانک دوم را با $\psi'(t)$ نشان می دهیم. موجک $\psi'(t)$ به شکل زیر تعریف می شود.

$$\psi(t) = \sqrt{2} \sum_n h_1(n) \phi(2t - n) \quad (1-3)$$

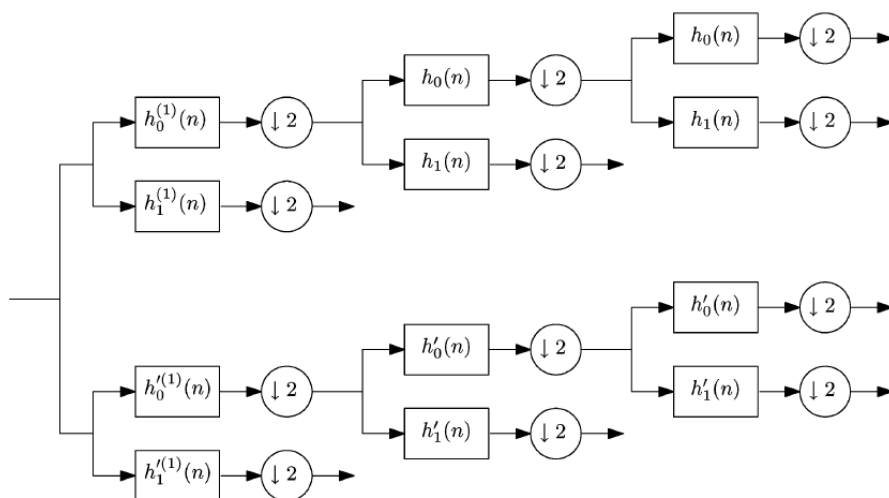
که در آن

$$\phi(t) = \sqrt{2} \sum_n h_0(n) \phi(2t - n) \quad (2-3)$$

به طور مشابه موجک دوم برحسب $\{h'_0(n), h'_1(n)\}$ تعریف می شود. در DTCWPT موجک دوم تبدیل هیلبرت موجک اول است.

$$\psi'(t) = \mathcal{H}\{\psi(t)\} \quad (3-3)$$

در مرجع [۳۲] ثابت شده است که اگر فیلتر پایین گذر $h'_0(n)$ برابر با تأخیر یافته $h_0(n)$ به اندازه نصف نمونه باشد در این صورت موجک تولیدشده توسط DTCWPT رابطه (۳-۳) را برآورده می کند. برای ساختن DTCWPT که حالت بسته ای DTCWPT است هم استفاده از رابطه بین فیلترهای بالا گذر $h_1(n)$ و $h'_1(n)$ دارای اهمیت است. فرض بر آن است که جفت های $\{h_0(n), h_1(n)\}$ و $\{h'_0(n), h'_1(n)\}$ فیلترهای FIR توأم مربع ایجاد می کنند.



شکل ۳-۴ تبدیل DTCWPT با استفاده از دو بانک پالایه موازی اعمال شده است [۳۱].

۳-۱-۲- تبدیل DTCWPT:

برای ساختن فرم بسته‌ای DTCWPT، هر یک از زیرباندها باید با استفاده از فیلتر بانک‌های بالا گذر و پایین گذر تجزیه شوند. این فیلتر بانک‌ها باید به گونه‌ای انتخاب شوند که پاسخ هر شاخه بسته موجک فیلتر بانک دوم تبدیل هیلبرت گسسته شاخه مشابه در بسته موجک فیلتر بانک اول باشد. در این صورت هر زیرباندها DTCWPT تحلیل‌پذیر خواهد بود. با استفاده از یک قانون ساده این شرایط به وجود می‌آیند.

اگر یک فیلتر داده شده $g(n)$ تبدیل هیلبرت گسسته فیلتر دیگری مانند $h(n)$ باشد یعنی:

$$G(e^{j\omega}) = jsgn(\omega)H(e^{j\omega}), \quad |\omega| < \pi \quad (4-3)$$

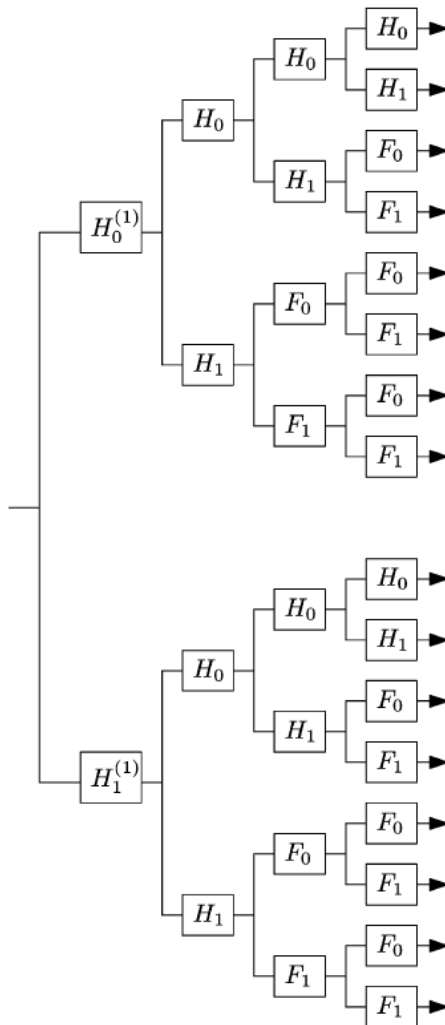
در این صورت اگر $g(n)$ با یک دنباله مانند $c(n)$ کانوالو شود داریم:

$$G(e^{j\omega})C(e^{j\omega}) = jsgn(\omega)H(e^{j\omega})C(e^{j\omega}), \quad |\omega| < \pi \quad (5-3)$$

همان‌طور که رابطه (۵-۳) نشان داده شده است اگر $h(n)$ و $g(n)$ یک جفت تبدیل گسسته هیلبرت


باشند در این صورت $g(n)*c(n)$ و $h(n)*c(n)$ نیز جفت‌های تبدیل هیلبرت گسسته خواهند بود.

تبدیل DTCWPT شامل دو فیلتر بانک موجک بسته‌ای است که به‌طور موازی با یکدیگر کار می‌کنند. برخی از فیلترها در فیلتربانک دوم دقیقاً مانند فیلترهای فیلتربانک اول هستند. فیلتربانک اول در شکل (۵-۳) آمده است. فیلتربانک دوم با جایگذاری فیلترهای طبقه اول یعنی $h_i^{(1)}(n)$ به وسیله $h_i^{(1)}(n-1)$ و جایگذاری $h_i(n)$ به وسیله $h_i'(n)$ برای $i \in \{0,1\}$ به دست می‌آیند. فیلترهایی که با F_i نمایش داده شده اند در فیلتر بانک اول و دوم دقیقاً مشابه یکدیگرند.



شکل ۵-۳ بانک پالایه موجک بسته‌ای اول تبدیل DTCWPT چهار مرحله‌ای. بانک پالایه دوم با جایگذاری $h_i^{(1)}(n-1)$ به جای $h_i^{(1)}(n)$ و $h_i'(n)$ به جای $h_i(n)$ برای $i \in \{0,1\}$ به دست می‌آید [۳۱].

پاسخ فرکانسی تبدیل DTCWPT چهار مرحله‌ای در شکل (۳-۶) نشان داده شده است. مشخص است که این پاسخها تقریباً تحلیلی پذیرند.



شکل ۳-۶ تحلیل حوزه فرکانس DTCWPT تحلیلی پذیر [۳۱].

۳-۲- تحلیل CSP

روش CSP ابتدا برای کلاسه‌بندی تصور حرکت دست‌ها مورداستفاده قرار گرفت. این روش برای افزایش واریانس بین کلاس‌ها استفاده می‌شود [۳۳]. ایده اصلی CSP تعیین ماتریس نگاشتی است که با آن بتوان سیگنال EEG چندکاناله را به یک زیر فضا با ابعاد کمتر نگاشت داد. در این روش سیگنال EEG در دو کلاس قرار می‌گیرد. اگر داده‌های کلاس اول را با X_1 و داده‌های کلاس دوم را با X_2 نمایش دهیم. ابعاد هر یک از این ماتریس‌ها $N \times T$ است که در آن N تعداد کانال‌های EEG و T تعداد نمونه‌های گرفته شده از هر کانال هست. کوواریانس فضایی نرمال شده به شکل زیر محاسبه می‌شود:

$$R_H = \frac{X_H X_H^T}{\text{trace}(X_H X_H^T)} \quad R_L = \frac{X_L X_L^T}{\text{trace}(X_L X_L^T)} \quad (۳-۶)$$

که در آن $\text{Trace}(A)$ مجموع عنصرهای قطری ماتریس A را نشان می‌دهد. با متوسط‌گیری بر روی تمامی آزمایش‌ها مربوط به هر کلاس کوواریانس فضایی متوسط به دست خواهد آمد. با تجزیه ترکیب کوواریانس فضایی متوسط دو کلاس خواهیم داشت:

$$R = \overline{R_H} + \overline{R_L} = U_0 \Sigma U_0^T \quad (۳-۷)$$

در رابطه بالا R کوواریانس نرمال مشترک دو کلاس است. ستون‌های ماتریس U_0 بردارهای ویژه برای R هستند و Σ یک ماتریس قطری از مقادیر ویژه R است. ماتریس سفیدسازی¹ P به صورت زیر تعریف می‌شود:

$$P = \Sigma^{-1/2} U_0^T \quad (۸-۳)$$

با استفاده از ماتریس سفیدسازی کوواریانس‌های فضایی متوسط دو کلاس به فضای جدید منتقل می‌شوند.

$$S_H = P \overline{R_H} P^T \quad S_L = P \overline{R_L} P^T. \quad (۹-۳)$$

ماتریس‌های S_H و S_L بردارهای ویژه مشترک دارند. اگر این ماتریس‌ها را تجزیه کنیم مجموع ماتریس‌های مقادیر ویژه آن‌ها ماتریس واحد خواهد بود.

$$S_H = U \Sigma_H U^T \quad S_L = U \Sigma_L U^T \quad \Sigma_H + \Sigma_L = I \quad (۱۰-۳)$$

معادله (۱۰-۳) بیان می‌کند که با این نگاشت کوواریانس مشترک R ماتریس واحد می‌شود. ماتریس نگاشت W به صورت زیر تعریف می‌شود:

$$W = U^T P \quad (۱۱-۳)$$

برای نگاشت سیگنال‌های EEG به فضای مشترک جدید باید ماتریس نگاشت در ماتریس حاوی نمونه‌های سیگنال‌های EEG ضرب شود.

$$Z = WX \quad (۱۲-۳)$$

به این صورت ویژگی‌ها در فضای جدید به دست می‌آیند.

¹ Whitening

۳-۳- الگوریتم KNMF:

الگوریتم NMF به دنبال تجزیه یک ماتریس نامنفی $X \geq 0$ به حاصل ضرب ماتریس‌های نامنفی $U \geq 0$ و $V \geq 0$ سازنده‌اش است [۳۴]. به طوری که تفاوت بین X و UV^T کمینه شود. چنانچه $X \in \mathbb{R}^{n \times m}$ ، در این صورت $U \in \mathbb{R}^{n \times r}$ و $V \in \mathbb{R}^{m \times r}$ خواهند بود. بردارهای ستونی V بردارهای پایه‌ای هستند که r مشخصه طیفی را منعکس می‌کنند. این مشخصه‌ها به وسیله مجموعی از نمونه‌های سیگنال EEG آموزش داده شده‌اند. بردارهای سطری U ویژگی‌ها هستند. این بردارها نشان می‌دهند که تا چه اندازه الگوهای طیفی آموزش داده شده برای بردارهای داده طیفی که مربوط به بردارهای سطری X بوده‌اند رمزگذاری شده‌اند.

از این روش برای استخراج ویژگی‌های طیفی از نمایش فرکانسی زمانی سیگنال EEG استفاده شده است. زمانی که KNMF^۱ با کرنل خطی استفاده شود ویژگی‌های طیفی به آسانی توسط ضرب ماتریسی محاسبه می‌شوند، درحالی که در NMF استاندارد باید با ثابت نگه داشتن سایر عامل‌ها به روزرسانی‌های بسیاری به صورت تکراری انجام شوند و یا اینکه باید ماتریس شبه معکوس یک ماتریس را به دست آورد. بعلاوه در KNMF به دلیل طبیعت پراکنده بودن آن می‌توان انتخاب ویژگی‌ها را به راحتی انجام داد.

ماتریس داده‌ها $X \in \mathbb{R}^{n \times m}$ را از سیگنال EEG حوزه زمان می‌سازیم. به طوری که هر بردار ستونی X یک فرکانس خاص را نشان دهد. سیگنال EEG اندازه‌گیری شده توسط کانال k در حوزه زمان را با $c_t^{(k)}$ ($k = 1, \dots, K$) نشان می‌دهیم. نمایش زمان فرکانسی سیگنال $c_t^{(k)}$ را با $P_{t,f}^{(k)}$ ($t = 1, \dots, T$, $f = 1, \dots, F$) نشان می‌دهیم که این نمایش زمان فرکانسی به طور عمده به وسیله تبدیل فوریه زمان کوتاه (STFT) و یا تبدیل موجک به دست می‌آید. بنابراین ماتریس طیفی به صورت $P^{(k)} = [P_{t,f}^{(k)}] \in \mathbb{R}^{n \times F}$ است. در مورد داده EEG با N آزمایش، اندیس زمان به صورت

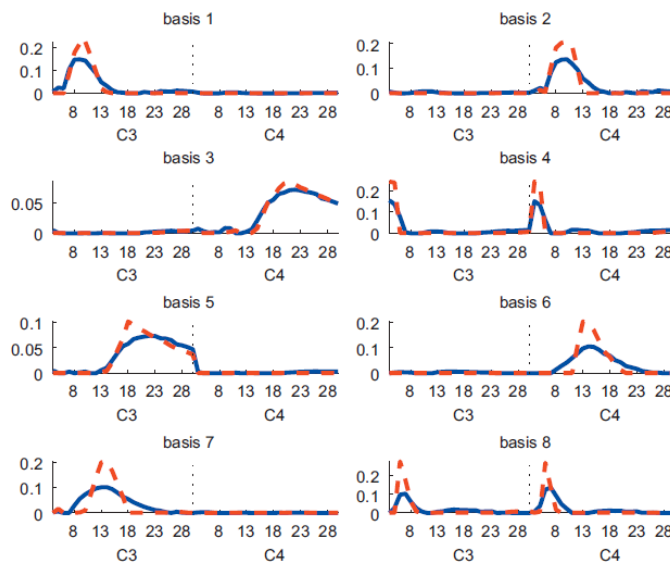
^۱ Kernel NMF

$n = TN$ است که T تعداد نمونه‌ها در هر آزمایش را نشان می‌دهد. ماتریس داده‌ها با جمع‌آوری ماتریس‌های طیفی با ابعاد $n \times F$ در K کانال مختلف به صورت زیر ساخته می‌شود.

$$X = [P^{(1)}, P^{(2)}, \dots, P^{(K)}] \in \mathbb{R}^{n \times m} \quad (۱۳-۳)$$

که در آن $m = KF$.

شکل (۷-۳) سیگنال EEG حوزه زمان را نشان می‌دهد (خط توپر) که در ۸ کانال مختلف $(C_3, C_z, C_4, CP_1, CP_2, P_3, P_z, P_4)$ اندازه‌گیری شده‌اند و شکل زمان فرکانسی آن‌ها به صورت خط‌چین نشان داده شده است. محور افقی فرکانس و محور عمودی زمان را نشان می‌دهد. تعداد باندهای فرکانسی ۱۲ عدد است (فرکانس‌های ۳۰ و ۲۸ و ۰ و ۱۲ و ۱۰ و ۸). بنابراین در این مورد خاص ماتریس داده‌های $X \in \mathbb{R}^{n \times 96}$ با کنار هم قرار دادن ۱۲ باند فرکانسی در هر کانال ساخته می‌شود ($۸ \times ۱۲ = ۹۶$).



شکل ۷-۳ سیگنال EEG در حوزه زمان و شکل زمان فرکانسی این سیگنال که با خط‌چین نشان داده شده است [۳۴].

۳-۴- کدگذاری پراکنده:

این روش که روشی موفق در انتخاب ویژگی‌هاست، بردارهای داده را به صورت ترکیب خطی تعداد کمی از مؤلفه‌های یک دیکشنری بیان می‌کند. در این حالت برخلاف تحلیل PCA لزومی بر متعامد یکپه بودن مؤلفه‌های پایه نیست و امکان تطبیق وجود دارد.

کدگذاری پراکنده به معنی مدل کردن بردارهای داده به صورت ترکیب خطی پراکنده‌ای از عناصر پایه است. این روش به طور وسیعی در یادگیری ماشین، علم عصب‌شناسی، پردازش سیگنال و آمار استفاده می‌شود.

در سال‌های اخیر علاقه رو به افزایشی در مطالعه نمایش پراکنده سیگنال‌ها وجود داشته است. با استفاده از یک دیکشنری که شامل سیگنال‌های الگوی اولیه است، سیگنال‌ها توسط ترکیبات خطی پراکنده‌ای از این اتم‌ها توصیف می‌شوند [۳۵]. فعالیت اخیر در این زمینه به طور عمده بر روی مطالعه الگوریتم‌هایی که سیگنال را با توجه به یک دیکشنری پیش فرض تجزیه می‌کنند متمرکز شده است. طراحی دیکشنری‌هایی که بهتر با این مدل تطبیق داشته باشند به دو صورت انجام می‌شود. روش اول انتخاب انتقالات خطی از قبل تعیین شده و روش دوم تطبیق دیکشنری به مجموعه‌ای از سیگنال‌های آموزش است. در مقاله مرجع [۳۵] الگوریتم جدیدی برای تطبیق دیکشنری‌ها به منظور رسیدن به نمایش پراکنده‌ای از سیگنال ارائه شده است. در این روش با داشتن مجموعه‌ای از سیگنال‌های آموزش به دنبال دیکشنری هستیم که با توجه به شروط پراکنده‌گی بهترین نمایش را برای هر عضو از این مجموعه داشته باشد. در این مقاله روش جدیدی معرفی می‌شود که به فرآیند خوشه‌بندی K-means عمومیت می‌بخشد. KSVD^۱ یک روش تکراری است که ابتدا نمونه‌ها را بر مبنای دیکشنری فعلی کدگذاری کرده و سپس اتم‌های دیکشنری را به روزرسانی می‌کند و این عمل را به صورت متناوب تکرار می‌کند تا زمانی که اتم‌های دیکشنری به میزان مطلوب با داده‌ها مطابقت

^۱ Kernel Singular Value Decomposition

پیدا کنند. به روزرسانی ستون‌های دیکشنری با به‌روزرسانی نمایش پراکنده داده‌ها ترکیب شده است، در نتیجه همگرایی سریع‌تر می‌شود.

با استفاده از یک ماتریس دیکشنری $D \in \mathbb{R}^{n \times K}$ که شامل k سیگنال اتم الگو برای ستون‌ها، $\{d_j\}_{j=1}^K$ است، یک سیگنال $y \in \mathbb{R}^n$ به صورت ترکیب خطی پراکنده‌ای از این اتم‌ها قابل نمایش است. نمایش y یا دقیقاً $y = DX$ است و یا تخمین $y \approx DX$ است که در رابطه $\|y - DX\|_p \leq \varepsilon$ صدق کند. بردار $X \in \mathbb{R}^K$ شامل ضرایب نمایش سیگنال y است. در روش‌های تخمین، معدل‌های نوعی که برای اندازه‌گیری انحراف استفاده می‌شوند معدل‌های ℓ^p برای $p = 1, 2, \dots, \infty$ هستند.

اگر $n < K$ و D یک ماتریس با رنک^۱ کامل باشد، تعداد نامتناهی راه‌حل برای مسئله وجود دارد، بنابراین شرط‌هایی بر روی راه‌حل باید گذاشته شوند. راه‌حلی که کم‌ترین تعداد ضرایب غیر صفر را داشته باشد به طور یقین راه‌حل مطلوب است. این پراکنده‌ترین نمایش، راه‌حل رابطه زیر است:

$$(P_0) \quad \min_X \|X\|_0 \quad (۱۴-۳)$$

به طوری که $y = DX$ یا

$$(P_0) \quad \min_X \|X\|_0 \quad (۱۵-۳)$$

با شرط اینکه $\|y - DX\|_2 \leq \varepsilon$

که در آن $\| \cdot \|_0$ معدل ℓ^0 است که عناصر غیر صفر یک بردار را شمارش می‌کند.

^۱ Rank

۳-۴-۱ - انتخاب دیکشنری:

دیکشنری D که به نمایش پراکنده منجر می‌شود می‌تواند به صورت مجموعه از قبل تعیین شده‌ای از توابع انتخاب شود و یا به وسیله تطبیق محتوای دیکشنری با مجموعه‌ی داده شده‌ای از سیگنال‌های نمونه طراحی شود.

انتخاب یک ماتریس تبدیل از پیش تعیین شده به دلیل سادگی روش بهتری است. همچنین در موارد بسیاری به الگوریتم‌های ساده و سریع برای ارزیابی نمایش پراکنده منجر می‌شود. موفقیت این گونه دیکشنری‌ها بستگی به این دارد که تا چه اندازه برای توصیف پراکنده سیگنال مورد سؤال مناسب باشند.

در مقاله مرجع [۳۵] روش متفاوتی برای طراحی دیکشنری بر اساس یادگیری بررسی شده است. هدف یافتن دیکشنری است که به نمایشی پراکنده از سیگنال‌های آموزش بینجامد. چنین دیکشنری‌هایی قابلیت این را دارند که از دیکشنری‌های از پیش تعیین شده متداول عملکرد بهتری داشته باشند. با توجه به قابلیت‌های محاسباتی رو به رشد، هزینه محاسباتی نسبت به بهبود عملکرد با استفاده از روش‌های تطبیق دیکشنری برای کلاس‌های خاص سیگنال در اولویت دوم قرار می‌گیرد.

به روزرسانی ستون‌های دیکشنری به‌طور پیوسته با به‌روزرسانی ضرایب نمایش پراکنده مربوط به هر ستون انجام می‌شود که باعث سریع‌تر شدن و شتاب در همگرایی می‌شود.

این نوع کدگذاری فرآیند محاسبه ضرایب نمایش X بر اساس سیگنال داده شده y و دیکشنری D است. این فرآیند به‌طور معمول با عنوان "تجزیه‌اتم" به کار می‌رود و نیاز به حل معادله‌های (۳-۱۴) و (۳-۱۵) دارد که به وسیله یک "الگوریتم پیگیری یا تعقیب" انجام شده و یک‌راه حل تقریبی پیدا می‌کند. کدگذاری پراکنده یک مرحله ضروری در روش KSVD است.

۳-۴-۲ - طراحی دیکشنری‌ها

اکنون به موضوع اصلی می‌پردازیم یعنی آموزش دیکشنری‌ها بر اساس مجموعه‌ای از مثال‌ها. با داشتن مجموعه $Y = \{y_i\}_{i=1}^N$ ، فرض می‌کنیم که یک دیکشنری D وجود دارد که با استفاده از

ترکیبات پراکنده، سیگنال‌های نمونه داده‌شده را تولید می‌کند. به عبارت دیگر ما فرض می‌کنیم که D وجود دارد بنابراین حل (P_0) برای هر مثال y_k یک نمایش پراکنده X_k می‌دهد.

رابطه جالب و خیره‌کننده‌ای بین نمایش پراکنده و خوشه‌بندی (به عبارت دیگر پله‌ای کردن (کوانتیزاسیون) بردار) وجود دارد. در خوشه‌بندی مجموعه‌ای از بردارهای توصیفی یاد داده می‌شود و هر نمونه به وسیله یکی از آن بردارها نمایش داده می‌شود (برداری که به آن نزدیک‌تر است معمولاً در مقیاس فاصله ℓ^2). می‌توان به خوشه‌بندی به عنوان نمایش بسیار پراکنده نگاه کرد که در آن فقط یک اتم در تجزیه سیگنال استفاده شده است و علاوه بر آن ضریب ضرب شده در آن باید یک باشد. در حالی که در نمایش پراکنده هر سیگنال به صورت ترکیب خطی از چندین بردار $\{d_k\}_{k=1}^K$ نمایش داده می‌شود؛ بنابراین می‌توان به نمایش پراکنده عنوان خوشه‌بندی تعمیم یافته را نسبت داد.

فرآیند K-means شامل دو مرحله در هر دوره تکرار است: در مرحله اول با داشتن مجموعه بردارهای $\{d_k\}_{k=1}^K$ داده‌های آموزش را به نزدیک‌ترین همسایگی‌شان نسبت می‌دهیم در مرحله دوم بردارهای $\{d_k\}_{k=1}^K$ به روزرسانی می‌شوند تا با داده‌های نزدیکشان متناسب‌تر شوند.

طراحی دیکشنری نیز تا حدودی مشابه با این دو مرحله انجام می‌شود. مرحله اول ضرایب را با توجه به دیکشنری داده‌شده پیدا می‌کند مرحله‌ای که به آن کدگذاری پراکنده می‌گوییم و سپس دیکشنری با توجه به ضرایب به روزرسانی می‌شود. در روش‌های مختلف تفاوت در روش محاسبه ضرایب و نحوه اصلاح دیکشنری است.

۳-۵- پایگاه داده

از بین پایگاه‌های داده‌ای که برای تحلیل احساس بر اساس سیگنال EEG ثبت شده‌اند می‌توان به پایگاه داده DEAP اشاره کرد [۳۶]. در این پایگاه داده سیگنال EEG و سیگنال‌های زیستی دیگر از سی‌و‌دو نفر شرکت‌کننده در حین تماشای چهار قطعه ویدئو- موسیقی یک دقیقه‌ای گرفته شده‌اند. شرکت‌کنندگان احساس خود نسبت به قطعات ویدئویی را بر اساس مثبت یا منفی بودن احساس (بعد

اول)، سطح احساس یا میزان انگیزختگی (بعد دوم)، میزان غالب شدن احساس بر فرد (بعد سوم)، میزان رضایتمندی علاقه‌مندی خود نسبت به قطعه ویدئویی (بعد چهارم) و میزان آشنا بودن قطعه، بیان نمودند. بعد اول خوشایندی (Valence)، بعد دوم برانگیختگی (Arousal)، بعد سوم غلبه (Dominance) و بعد چهارم علاقه‌مندی (Like) نامیده شده‌اند. هر یک از این ابعاد دارای محدوده خاصی است. این محدوده‌ها به این صورت قابل‌تعریف‌اند: بعد اول از احساس ناراحتی تا حالت خوشی، بعد دوم از خونسردی و بی‌حوصلگی تا هیجان‌زدگی، بعد سوم از حالت بدون کنترل و غلبه تا حالت کاملاً غالب و بعد چهارم از ناپسند بودن تا موردعلاقه بودن تعریف‌شده‌اند. هر یک از این ۴ بعد از ۱ تا ۹ بر اساس احساس هر فرد نسبت به قطعه ویدئویی برچسب‌گذاری می‌شود. بعد پنجم که مربوط به میزان آشنا بودن قطعه است از ۱ (هرگز قبل از آزمایش این قطعه شنیده نشده است) تا ۵ (این آهنگ کاملاً شناخته‌شده است) برچسب‌گذاری می‌شود. برای ۲۲ نفر از ۳۲ نفر حالت‌های چهره نیز به‌صورت ویدئویی ضبط‌شده‌اند. با بررسی همبستگی بین فرکانس سیگنال EEG و احساسات گزارش‌شده از طرف شرکت‌کنندگان مشاهده‌شده است که برای بعد دوم (سطح احساس یا انگیزختگی) همبستگی بین باندهای آلفا، تتا و گاما منفی است و برای حالت‌های انگیزختگی بالاتر توان مرکزی باند آلفا کاهش می‌یابد. بعد ظرفیت بیشترین همبستگی را با سیگنال‌های EEG نشان داده است. در فرکانس‌های پایین افزایش بعد ظرفیت یا مثبت بودن احساس باعث افزایش توان سیگنال EEG می‌شود، همچنین هنگام علاقه‌مندی به قطعه موردنظر توان آلفا و تتا در سمت چپ بخش پیشین مغز افزایش می‌یابد. سه نوع کلاسه‌بندی در این مطالعه استفاده‌شده است: کلاسه‌بندی بر مبنای انگیزختگی بالا یا پایین، ظرفیت بالا یا پایین و علاقه‌مندی زیاد یا کم. گزارش شرکت‌کنندگان به‌عنوان مبنای درستی کلاسه‌بندی در نظر گرفته‌شده است. برای انتخاب محرک‌های احساسی که در واقع از نوع موسیقی هستند یک روش نیمه‌خودکار در این مقاله ارائه‌شده است. تحریک احساسات از طریق ویدئو-موسیقی برای اولین بار در این پایگاه داده انجام‌شده است. اکثر تحقیقات از حالت‌های چهره و مکالمه

افراد برای تشخیص احساس آن‌ها استفاده کرده‌اند و به سیگنال‌های فیزیولوژیکی کمتر توجه شده است.

پایگاه داده دیگری به نام MAHNOB-HCI برای شناسایی احساسات معرفی شده است که در آن حالت‌های چهره، سیگنال‌های صوتی، اطلاعات مربوط به جهت نگاه و همچنین اطلاعات مربوط به سیستم عصبی (EEG) ثبت شده‌اند [۳۷]. بیست‌وهفت نفر مرد و زن از فرهنگ‌های متفاوت در این مطالعه شرکت کرده‌اند. این مطالعه طی دو آزمایش انجام شده است. در اولین آزمایش، شرکت‌کنندگان ۲۰ ویدئوی محرک احساس را تماشا کرده و احساسات خود را نسبت به آن‌ها گزارش داده‌اند. در آزمایش دوم ویدئوها و تصاویر کوتاه ابتدا بدون عنوان نمایش داده شده و سپس با عنوان‌های درست و یا نادرست احساسی نمایش داده شده‌اند. پس از نمایش محرک‌های تصویری از شرکت‌کنندگان خواسته شده است موافقت یا مخالفت خود را با عنوان‌ها اعلام کنند. سیگنال‌های EEG با استفاده از الکترودهای از جنس AgCl گرفته شده و به همراه ویدئوهای ضبط شده و پاسخ‌های بدنی افراد در پایگاه داده ذخیره شده‌اند. به شرکت‌کنندگان قبل از آزمایش، مراحل آزمایش توضیح داده شده و معانی کلماتی مانند انگیختگی، ظرفیت و ... به آن‌ها گفته شده است. پنج سؤالی که از آن‌ها در حین آزمایش پرسیده شده شامل: ۱. برجسب احساسی ۲. میزان انگیختگی ۳. ظرفیت ۴. میزان غالب بودن احساس و ۵. قابل پیش‌بینی بودن درون‌مایه احساسی می‌شود. برجسب احساسی شامل کلمات خنثی یا بدون احساس، نگرانی، سرگرمی، ناراحتی، لذت، نفرت، عصبانیت، شگفت‌زدگی و ترس است.

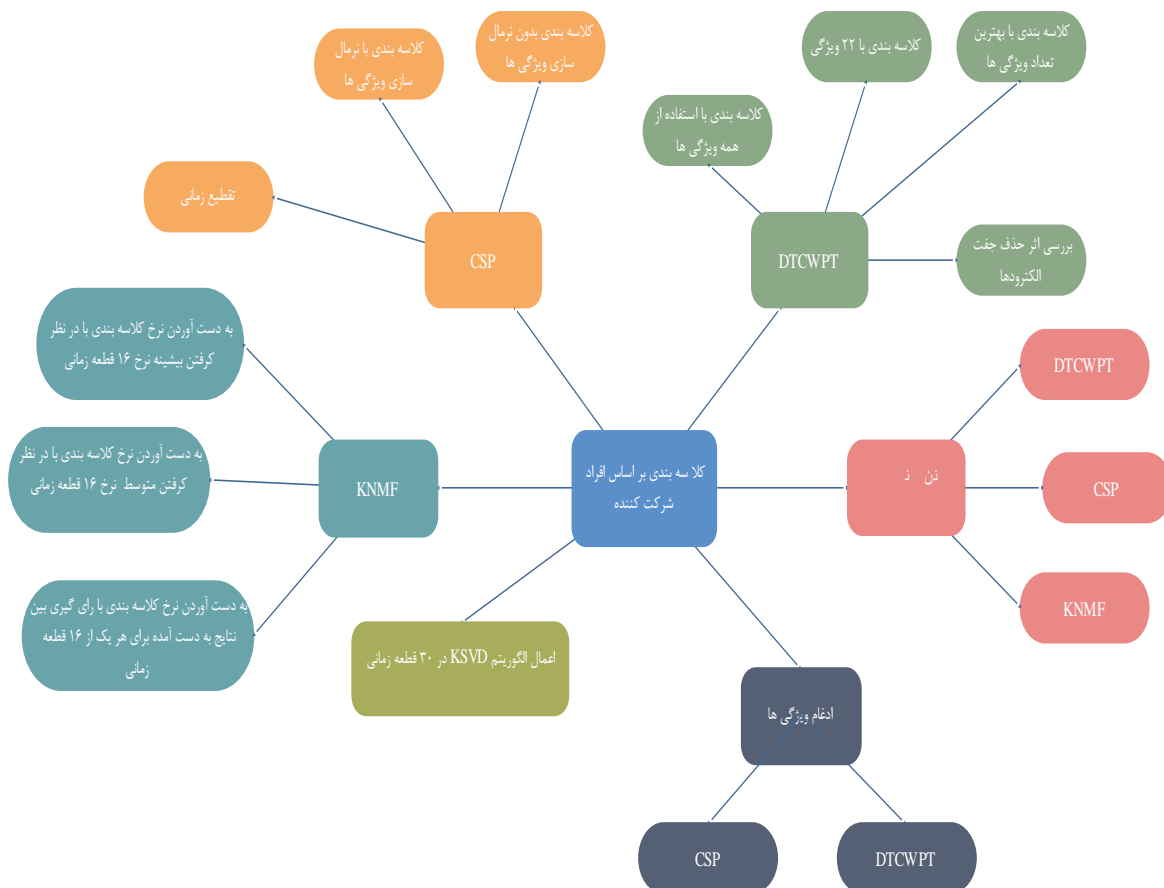
در این مطالعه دو کلاسه‌بندی انجام گرفته است. اولین کلاسه‌بندی در بُعد انگیختگی انجام شد و سه کلاس آرامش، برانگیختگی متوسط و هیجان‌زدگی در نظر گرفته شدند و کلاسه‌بندی دوم مربوط به بُعد ظرفیت است و شامل سه کلاس ناخوشایند، خنثی و خوشایند می‌شود.

فصل ۴

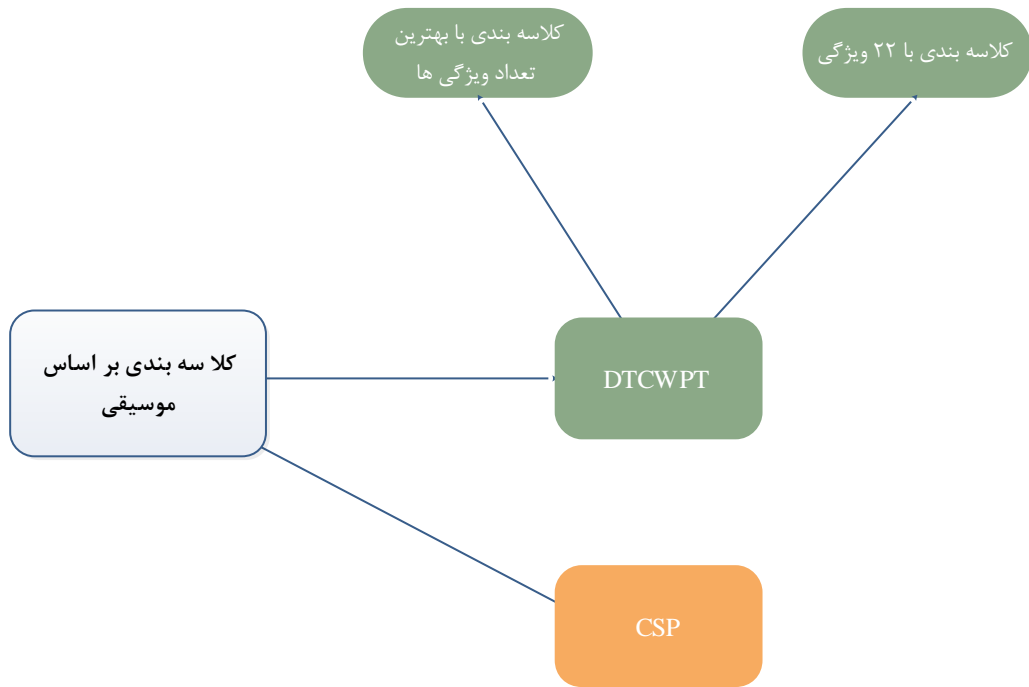
نتایج شبیه‌سازی

۴-۱- بلوک دیاگرام بخش‌های فصل

کلاس‌بندی بر اساس افراد شرکت‌کننده



کلاسه بندی بر اساس قطعه های موسیقی




۲-۴- کلاسه‌بندی بر اساس افراد شرکت‌کننده

۱-۲-۴ اعمال روش DTCWPT

در مطالعات اخیر روش استخراج ویژگی مبتنی بر موجک بانام DTCWPT بر روی پایگاه داده DEAP اعمال شده است [۳۸]. ما ابتدا به‌عنوان اولین کار این روش را بر روی پایگاه داده DEAP اعمال کردیم تا نتایج خود را با نتایج مقاله مقایسه کنیم.

سیگنال EEG ثبت شده توسط هر یک از الکترودهای مغزی در این پایگاه داده با نرخ ۱۲۸ نمونه در ثانیه نمونه‌برداری شده است به این معنا که در هر آزمایش که به مدت ۶۳ ثانیه (۳ ثانیه دوره استراحت بین هر دو آزمایش و ۶۰ ثانیه ثبت سیگنال مغزی ناشی از تحریک) بوده است ۸۰۶۴ نمونه از سیگنال مغزی هر یک از الکترودها گرفته شده است. نمونه‌ای از این سیگنال‌ها در شکل (۱-۴) نشان داده شده است. در این شکل ۳ ثانیه اول حذف شده چراکه این ۳ ثانیه مربوط به دوره استراحت بوده و فاقد اطلاعات مربوط به احساس است؛ بنابراین تعداد نمونه‌ها در ۶۰ ثانیه تحریک احساسی برابر با ۷۶۸۰ نمونه است.



شکل ۱-۴ سیگنال مغزی نمونه‌برداری شده با نرخ ۱۲۸ نمونه در ثانیه.

پایگاه داده DEAP از ۳۲ نفر در آزمایش استفاده کرده است. برای هر یک از این ۳۲ نفر ۴۰ قطعه موسیقی به طور متوالی پخش شده و سیگنال مغزی آنها در حین گوش دادن به موسیقی توسط ۳۲ الکتروود مغزی ثبت شده است. کلاسه‌بندی داده‌ها بسته به این که افراد شرکت کننده را مبنای آموزش و آزمون قرار دهیم و یا قطعه‌های موسیقی مبنای کار ما باشند می‌تواند به دو حالت انجام شود.

ما ابتدا حالت اول را در نظر گرفتیم و از روش اعتبار سنجی یکی در مقابل بقیه^۱ استفاده کردیم. به این صورت که یکی از ۳۲ نفر را به عنوان مجموعه آزمون در نظر گرفته و ۳۱ نفر باقی مانده را آموزش دادیم و این عمل را ۳۲ بار تکرار کردیم و در هر دوره آموزش و آزمون یک نرخ کلاسه‌بندی به دست آوردیم که در نهایت بین ۳۲ نرخ به دست آمده متوسط گیری نمودیم. تعداد دوره‌های آموزش 31×1240 (شرکت کننده) $\times 40$ (قطعه موسیقی) است.

در روش DTCWPT چهار سطحی هر سیگنال ۷۶۸۰ نمونه‌ای به ۱۶ زیرباند فرکانسی در هر یک از درخت‌های حقیقی و موهومی تجزیه می‌شود. سیگنال هر یک از این زیرباندهای خروجی ۴۸۰ نمونه از ۷۶۸۰ نمونه را داراست؛ که از این ۱۶ زیرباند ۱۲ زیرباند که در محدوده ۰-۴۸ هرتز هر درخت قرار دارند انتخاب می‌شوند. در واقع زیرباندهایی که در اولویت فرکانسی قرار دارند برای تولید ویژگی‌های مربوط به هر سیگنال استفاده می‌شوند.

زیرباندهای حاصل از تبدیل موجک بسته‌ای به ترتیب افزایش فرکانس مرتب نشده‌اند. تبدیل موجک بسته‌ای در هر مرحله بر روی ضرایب تقریب و جزئیات اعمال می‌شود. در این تبدیل A مربوط به فیلتر پایین گذر^۲ (تقریب)^۳ بعلاوه پایین آورنده نرخ^۴ و D مربوط به فیلتر بالا گذر^۵ (جزئیات)^۶ بعلاوه پایین آورنده نرخ است. با این تعریف ترتیب زیرباندهای فرکانسی حاصل از اعمال این تبدیل در

¹ Leave-One-Out Cross Validation

² Lowpass filter

³ Approximation

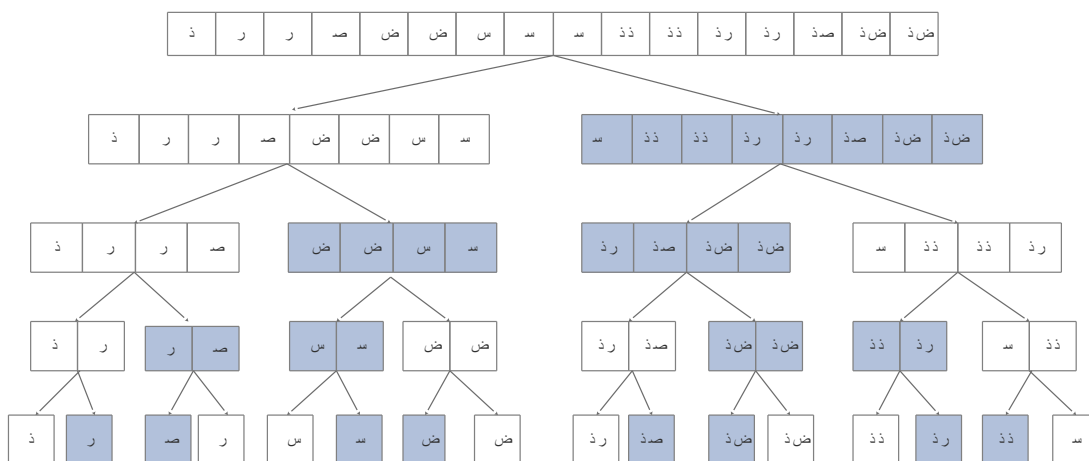
⁴ Downsampler

⁵ Highpass filter

⁶ Detail

دو مرحله باید به صورت AA, DA, AD, DD باشد. این ترتیب به ترتیب پلی^۱ معروف است، اما به دلیل همپوشانی ناشی از پایین آوردن نرخ، محتوای فرکانسی استخراج شده با استفاده از عملگر AD بالاتر از محتوای فرکانسی استخراج شده با استفاده از عملگر DD است. بنابراین ترتیب زیرباندها از لحاظ فرکانسی به صورت AA, DA, DD, AD است. به عنوان مثال اگر اندیس زیرباندها در ترتیب پلی به صورت ۳،۴،۵،۶ باشد، ترتیب فرکانسی آنها به شکل ۳،۴،۶،۵ است. با توجه به شکل (۲-۴) اگر دو آرایه ایجاد شده توسط تبدیل موجک در مرحله اول را در نظر بگیریم. تبدیل موجک استاندارد به آرایه سمت چپ اعمال می شود در این حالت حاصل اعمال فیلتر پایین گذر به این آرایه در نیمه سمت چپ قرار گرفته و نتیجه اعمال فیلتر بالا گذر در نیمه سمت راست قرار می گیرد، اما به آرایه سمت راست تبدیل موجک تغییر یافته اعمال می شود و نتیجه اعمال فیلتر بالا گذر در نیمه سمت چپ قرار گرفته و نتیجه اعمال فیلتر پایین گذر در نیمه سمت راست قرار می گیرد. به این معنی که اگر آرایه سمت راست حاصل از اعمال تبدیل در مرحله اول که همان آرایه مربوط به جزئیات سیگنال اصلی است را در نظر بگیریم، تقریب این آرایه دارای محتویات فرکانسی بیشتری نسبت به جزئیات آن است. در تمام آرایه های سمت راستی این جابه جایی فرکانسی انجام می شود.

^۱ Paley ordering



شکل ۴-۲ مرتب شدن زیرباندها از لحاظ اولویت فرکانسی.

با توجه به توضیحات داده شده ترتیب اولویت برای ۱۶ زیر باند در جدول (۴-۱) آمده است.

جدول ۴-۱ ترتیب اولویت ۱۶ زیر باند فرکانسی حاصل از اعمال روش DTCWPT بر سیگنال EEG.

رتبه	۱	۲	۳	۴	۵	۶	۷	۸	۹	۱۰	۱۱	۱۲	۱۳	۱۴	۱۵	۱۶
شماره زیرباند	۱	۲	۴	۳	۷	۸	۶	۵	۱۳	۱۴	۱۶	۱۵	۱۱	۱۲	۱۰	۹

با توجه به رتبه‌های به دست آمده، ۱۲ زیر باند با رتبه بهتر برای ایجاد ویژگی‌ها استفاده می‌شوند.

بنابراین زیرباندهای شماره ۹، ۱۰، ۱۲، ۱۱ حذف می‌شوند.

زیر باندهای درخت موهومی، تبدیل هیلبرت زیرباندهای درخت حقیقی هستند و دامنه

$$((Real - tree subband) - j * (Imaginary - tree subband))$$

تقریباً تحلیل پذیر است. اگر این دامنه را H بنامیم، از لگاریتم مجموع مربعات دامنه H به عنوان

ویژگی استفاده می‌کنیم. که به صورت لگاریتم انرژی زیرباند درخت حقیقی بعلاوه انرژی زیرباند درخت

موهومی به دست می‌آید.

$$E_i = \log \sum_{k=1}^N |H_i|^2 = \log \sum_{k=1}^N |H_{ik}^R - jH_{ik}^I|^2 = \log \sum_{k=1}^N (H_{ik}^R)^2 + (H_{ik}^I)^2 \quad (1-4)$$

در این رابطه E_i ، H_i^R و H_i^I برای $i = 1, 2, \dots, 16$ به ترتیب انرژی لگاریتمی، زیرباند درخت حقیقی و زیرباند درخت موهومی هستند و N تعداد ضرایب موجک چهار سطحی الگوریتم DTCWPT است. ابتدا با استفاده از سیگنال‌های EEG هر شرکت‌کننده برای هر ویدئو، ویژگی‌ها استخراج می‌شوند. برای استخراج ویژگی، هر کانال از ۳۲ کانال EEG، توسط DTCWPT تجزیه می‌شود و ۱۲ ویژگی انرژی همان‌طور که توضیح داده شد استخراج می‌شوند.

بعلاوه اختلاف بین ویژگی‌های انرژی تمام جفت الکترودهای متقارن در نیمکره راست و چپ قشر مغز نیز به‌عنوان ویژگی جدید در این الگوریتم استفاده شده‌اند. این کار برای نشان دادن نابرابری فعالیت نیم‌کره راست و چپ مغز در مقابل تحریک احساسی انجام شده است. انرژی ۱۴ جفت الکترودها که حاصل تفاضل انرژی‌های جفت الکترودهای متقارن است به ویژگی‌های قبل اضافه شده‌اند. بنابراین در هر دوره آزمایش تعداد ویژگی‌ها برابر است با:

$$552 = 12 \times (32+14) \text{ (الکترودهای متقارن + جفت الکترودهای متقارن)}$$

با داشتن ۱۲۸۰ دوره آزمایش ($1280 = 32 \times 40$) (شرکت‌کننده) $40 \times$ (قطعه موسیقی))، اگر ۱۲۴۰ دوره را به‌عنوان دوره‌های آموزش در نظر بگیریم، باید $684480 = 1240 \times 552$ ویژگی در هر دوره، آموزش داده شده و $22080 = 40 \times 552$ ویژگی آزموده شوند. تعداد ویژگی‌های آموزش بسیار زیاد است. برای کاهش تعداد ویژگی‌ها از روش‌های انتخاب ویژگی استفاده می‌کنیم. نویسندگان مقاله مرجع [۳۷] از بین روش‌های انتخاب و کاهش ویژگی از دو روش F-Ratio و فاکتورگیری QRcp^۱ استفاده کرده‌اند، البته قبل از اعمال روش فاکتورگیری QRcp از روش SVD نیز استفاده شده است.

با اعمال روش SVD بر ماتریس ویژگی‌ها به این نتیجه رسیدیم که با ۱۱ عدد از مقادیر منفرد می‌توان بیش از ۹۹.۵٪ انرژی حاصل از تمام مقادیر منفرد را به دست آورد.

فاکتورگیری QRcp در واقع تجزیه یک ماتریس به حاصل ضرب دو ماتریس است [۳۹]. به این صورت

:

^۱ QR column pivoting factorization

$$B = QR \quad (۲-۴)$$

در این رابطه Q یک ماتریس متعامد و R یک ماتریس بالا مثلثی است. فاکتورگیری QRcp به معنای چرخش ستون‌های ماتریس B برای بیشینه کردن اندازه اقلیدسی در جهت‌های متوالی همزمان با اعمال فاکتورگیری QR بر روی ماتریس B است. ترتیب انتخاب متوالی ستون‌های B در یک ماتریس به نام ماتریس جایگشت ثبت می‌شود. ماتریس B طبق رابطه (۳-۴) به سه ماتریس Q، R و P تجزیه می‌شود.

$$B = QRP^T \quad (۳-۴)$$

که در آن P ماتریس جایگشت است.

F-Ratio یک اندازه‌گیری آماری در تحلیل واریانس برای داده‌های چند کلاسه است. اگر تعداد k خوشه داشته باشیم و هر خوشه شامل n داده باشد داریم:

$$F - Ratio = \frac{\frac{1}{k} \sum_{j=1}^k (\mu_j - \bar{\mu})^2}{\frac{1}{k} \sum_{j=1}^k \frac{1}{n} \sum_{i=1}^n (a_{ij} - \mu_j)^2} \quad (۴-۴)$$

که در آن a_{ij} مربوط به سطر i از کلاس j است و μ_j بردار میانگین کلاس j و $\bar{\mu}$ بردار میانگین کل داده‌هاست. مقدار F-Ratio با دور شدن خوشه‌ها از یکدیگر و یا با نزدیک شدن داده‌های هر خوشه به یکدیگر افزایش می‌یابد.

تمام ویژگی‌ها به یک اندازه دارای اطلاعات نیستند. چنانچه همبستگی میان ویژگی‌ها قابل توجه باشد برای کاهش نویز و پیچیدگی محاسباتی برخی از این ویژگی‌ها حذف می‌شوند. چراکه این دسته از ویژگی‌ها اطلاعات جدیدی ندارند. در اینجا ترکیبی از روش‌های SVD، QRcp و F-Ratio برای انتخاب یک زیرمجموعه از ویژگی‌ها استفاده می‌شود.

فرآیند انتخاب ویژگی به این ترتیب انجام می‌شود:

۱. اگر ابعاد ماتریس ویژگی‌های ورودی را $m \times n$ در نظر بگیریم به طوری که $m \geq n$. هدف پیدا کردن یک زیرمجموعه A_1 با ابعاد $m \times g$ ($g < n$) است که مهم‌ترین بخش اطلاعات ماتریس A را در بر دارد.

۲. روش SVD را بر ماتریس A اعمال می‌کنیم: $A = USV^T$.

۳. تعداد g عدد از ویژگی‌ها را که به ازای آن‌ها انرژی مقادیر منفرد 99.5% کل انرژی مربوط به n مقدار منفرد است را پیدا می‌کنیم.

۴. فاکتورگیری QRcp بر روی ماتریس A اعمال می‌شود.

۵. رتبه ترکیبی مربوط به هر یک از ویژگی‌ها با استفاده از روش QRcp و F-Ratio با توجه به رابطه زیر به دست می‌آید.

$$(Combined\ Score)_i = \frac{(QRcp\ Rank + F-Ratio\ Rank)}{2} \quad (5-4)$$

اگر رتبه به دست آمده برای دو ویژگی مشابه باشد ویژگی با رتبه QRcp بهتر در اولویت قرار می‌گیرد. مدل کاهش یافته، $(n - g)$ عدد از ویژگی‌های رتبه پایین را نادیده می‌گیرد. تعداد ویژگی‌ها در ابتدای کار ۵۵۲ عدد است.

برای پیدا کردن بهترین حالت، همسایگی $(g - 6)$ تا $(g + 6)$ بررسی می‌شوند تا بهترین ویژگی‌های ورودی به دست آیند. بنابراین نتایج بهتر با هزینه محاسباتی کمتر خواهیم داشت. برای کلاسه‌بندی از کلاسه بند SVM با کرنل RBF استفاده شده است. مقدار ضریب γ تابع RBF، عکس تعداد ویژگی‌ها $(1/num - features)$ که حالت پیش فرض این تابع است در نظر گرفته شده است.

ابتدا کلاسه‌بندی را برای بُعد اول انجام دادیم و نرخ متوسط حاصل از کلاسه‌بندی سیگنال‌های مربوط به ۳۲ نفر را با تعداد ویژگی‌های مختلف به دست آوردیم.

۴-۲-۱-۱- کلاسه‌بندی با کل ویژگی‌ها

ابتدا بدون در نظر گرفتن مرحله انتخاب ویژگی با استفاده از کل ۵۵۲ ویژگی مربوط به هر یک از دوره‌های آزمایش، آموزش و آزمون را انجام دادیم. نتایج کلاسه‌بندی در جدول (۴-۲) آمده‌اند.


جدول ۴-۲ نتایج کلاسه‌بندی قبل از کاهش تعداد ویژگی‌ها.

بُعد	DTCWPT
اول	٪۶۳.۱۲
دوم	٪۶۳.۲۸
سوم	٪۶۶.۷۲
چهارم	٪۶۹.۵۳

با در نظر گرفتن همه ویژگی‌ها نرخ کلاسه‌بندی در دو بُعد اول نزدیک به یکدیگر به دست آمده است. با توجه به جدول (۴-۲) مشاهده می‌کنیم که نرخ بازشناسی در بُعد سوم بهتر از دو بُعد اول بوده و در بُعد چهارم که مربوط به میزان علاقه افراد به قطعه‌های پخش شده است این نرخ بهتر از ابعاد دیگر است.

۴-۲-۱-۲- کلاسه‌بندی با ویژگی‌های انتخاب شده

با اضافه کردن مرحله انتخاب ویژگی تعداد ویژگی‌ها را بین ۱ تا ۲۰۰ تغییر دادیم و هر بار نرخ متوسط را به دست آوردیم. شکل (۴-۲) نرخ متوسط کلاسه‌بندی را با تعداد ویژگی‌های متفاوت نشان می‌دهد.




شکل ۳-۴ نرخ متوسط به دست آمده برای بُعد اول با تغییر تعداد ویژگی‌ها از ۱ تا ۲۰۰ عدد ویژگی.

با توجه به شکل (۳-۴) بیشینه نرخ متوسط برای بُعد اول برابر است با ۶۳.۵۲٪ و با ۸ ویژگی به دست می‌آید. بنابراین با انتخاب ۸ ویژگی به جای ۵۵۲ ویژگی ضمن کاهش بسیار زیاد ابعاد، به نرخ بالاتری نیز می‌رسیم. این موضوع اهمیت و درستی مرحله انتخاب ویژگی‌ها را نشان می‌دهد. با توجه به شکل مشاهده می‌شود که بعد از تقریباً ۱۲۵ ویژگی، نرخ کلاسه بندی ثابت می‌ماند. این شکل نشان می‌دهد که برای تشخیص میزان خوشایندی قطعه‌ها با داشتن ۸ ویژگی نرخ بهتری نسبت به تعداد ویژگی‌های بالاتر به دست می‌آوریم.


فرآیند ذکر شده را برای بُعد دوم نیز تکرار می‌کنیم. نتیجه به دست آمده در شکل (۴-۴) نشان

داده شده است.




شکل ۴-۴ نرخ متوسط به دست آمده برای بُعد دوم با تغییر تعداد ویژگی‌ها از ۱ تا ۲۰۰ عدد ویژگی.

در شکل (۴-۴) مشاهده می‌شود که بیشترین نرخ کلاسه‌بندی متوسط برای بُعد دوم با ۳۹ ویژگی به دست می‌آید و برابر ۶۴.۳٪ است. در بُعد دوم نسبت به بُعد اول تغییرات با افزایش تعداد ویژگی‌ها همچنان ادامه داشته و مانند حالت قبل به مقدار ثابتی نمی‌رسد. برای بُعد سوم نیز با توجه به شکل (۵-۴) بیشترین نرخ کلاسه‌بندی ۶۶.۸۸٪ است و با ۶۲ ویژگی به دست می‌آید. البته همان‌طور در شکل مشاهده می‌شود با داشتن یک ویژگی نرخ بالاتری داریم که برابر ۶۷.۴۲٪ است.



شکل ۴-۵ نرخ متوسط به دست آمده برای بُعد سوم با تغییر تعداد ویژگی‌ها از ۱ تا ۲۰۰ عدد ویژگی.

برای بُعد چهارم بالاترین نرخ را ۶۹.۷۷٪ با ۱۲ ویژگی به دست آوردیم شکل (۴-۶). مشاهده می‌کنیم که نرخ کلاسه‌بندی در بُعد چهارم از ۲۰ ویژگی به بعد مقدار ثابتی می‌شود.



شکل ۴-۶ نرخ متوسط به دست آمده برای بُعد چهارم با تغییر تعداد ویژگی‌ها از ۱ تا ۲۰۰ عدد ویژگی.

خلاصه نتایج کلاسه‌بندی در جدول (۳-۴) آمده است. در بهترین حالت و با داشتن بهترین تعداد ویژگی‌ها در هر یک از ابعاد همچنان نرخ بازشناسی در بُعد چهارم بهتر از سایر ابعاد بوده و نرخ به دست آمده برای بُعد سوم نیز از دو بُعد اول بالاتر است.

جدول ۳-۴ بهترین نرخ کلاسه‌بندی ویژگی‌های استخراج‌شده از روش DTCWPT.

بُعد	بهترین تعداد ویژگی‌ها	نرخ کلاسه‌بندی
اول	۸ ویژگی	٪۶۳.۵۲
دوم	۳۹ ویژگی	٪۶۴.۳
سوم	۶۲ ویژگی و ۱ ویژگی	٪۶۶.۸۸، ٪۶۷.۴۲
چهارم	۱۲ ویژگی	٪۶۹.۷۷

۳-۱-۲-۴ - کلاسه‌بندی با ۲۲ ویژگی

با توجه به اینکه تعداد ویژگی‌ها برای داشتن بیشینه نرخ متوسط در ۴ بعد احساسی با یکدیگر برابر نیست حالت بهینه‌ای که در آن هر ۴ بُعد پاسخ مطلوبی دارند را در نظر می‌گیریم. با در نظر گرفتن ۲۲ عدد ویژگی در هر ۴ بُعد نتیجه به صورت جدول (۴-۴) به دست می‌آید.

جدول ۴-۴ نرخ متوسط کلاسه‌بندی با اعمال روش DTCWPT برای ۴ بُعد احساسی با در نظر گرفتن ۲۲ ویژگی.

بُعد	DTCWPT
اول	٪۶۳.۱۲
دوم	٪۶۱.۸۷
سوم	٪۶۴.۶۹
چهارم	٪۶۹.۵۳

در این حالت برخلاف حالت‌های قبل نرخ به دست آمده برای بُعد دوم از بُعد اول پایین‌تر است. نکته جالب تغییر بسیار کم نرخ بازشناسی بُعد چهارم در همه حالت‌هاست.

۴-۲-۱-۴ - بررسی تأثیر حذف جفت الکترودها

در مقاله مرجع [۳۷] با در نظر گرفتن اختلاف میان انرژی جفت الکترودهای متقارن علاوه بر ۳۲ انرژی به دست آمده برای ۳۲ الکترودها، ۱۴ انرژی دیگر نیز برای ۱۴ جفت الکترودهای متقارن استفاده شده است. این انرژی‌ها حاصل تفاضل بین انرژی‌های جفت الکترودهای متقارن است. برای بررسی اثر انرژی جفت الکترودها بر نرخ بازشناسی چهار بُعد احساسی، بار دیگر کلاسه‌بندی را بدون در نظر گرفتن انرژی ۱۴ جفت الکترودهای متقارن با ۲۲ ویژگی انجام دادیم. با توجه به جدول (۴-۵) نرخ بازشناسی در بُعد اول تغییری نکرده و در بُعد دوم و چهارم کاهش یافته و فقط در بُعد سوم این نرخ بهبود پیدا کرده است. بنابراین می‌توان گفت احتمالاً اطلاعات موجود در انرژی حاصل از تفاضل انرژی جفت الکترودها در تشخیص میزان خوشایند بودن یک واقعه بی‌تأثیر است و در واقع شاید انرژی سیگنال‌های تولید شده در نیمه راست و چپ مغز در اثر یک واقعه خوشایند و یا ناخوشایند تقریباً با یکدیگر برابرند. این نتیجه با این واقعیت که احساس خوشایند فعالیت نیمه چپ مغز و احساس ناخوشایند فعالیت نیمه راست مغز را افزایش می‌دهد هم‌خوانی ندارد. اما نتیجه به دست آمده در رابطه با میزان برانگیختگی احساس نشان می‌دهد که اختلاف انرژی جفت الکترودهای اطلاعاتی در رابطه با میزان انگیزتگی احساس دارند که با حذف آن‌ها نرخ بازشناسی در این بُعد کاهش می‌یابد.

جدول ۴-۵ درصد کلاسه‌بندی با حذف ویژگی‌های مربوط به ۱۴ جفت الکترودهای متقارن در روش DTCWPT.

بُعد	DTCWPT
اول	٪۶۳.۱۲
دوم	٪۶۱.۸۰
سوم	٪۶۶.۶۴
چهارم	٪۶۹.۴۵

۴-۲-۲- اعمال روش CSP

با توجه به نتایج به دست آمده از روش DTCWPT به دنبال روش دیگری بودیم که با استفاده از آن بتوان با کاهش هزینه محاسباتی نرخ کلاسه‌بندی قابل قبولی به دست آورد. از بین روش‌های موجود، روش CSP را انتخاب کردیم. این روش در مطالعات مربوط به کلاسه‌بندی تصور حرکتی با استفاده از سیگنال EEG نتایج قابل قبولی داشته است. بنابراین تصمیم گرفتیم این روش را در کلاسه‌بندی احساسات مورد بررسی قرار دهیم. برای مقایسه با روش DTCWPT، روش CSP را نیز بر پایگاه داده DEAP اعمال کردیم. در این پایگاه داده بر اساس امتیازات داده شده توسط شرکت‌کنندگان، می‌توان سیگنال‌های EEG را در دو کلاس High و Low قرارداد. با توجه به اینکه محدوده امتیازات بین ۱ تا ۹ است آستانه مورد نظر برای قرار دادن سیگنال‌ها در دو کلاس را ۴.۵ در نظر گرفتیم. بنابراین زمانی که برچسب مربوط به یک سیگنال بیش از ۴.۵ است سیگنال در کلاس High قرار گرفته و در غیر این صورت سیگنال متعلق به کلاس Low است. با توجه به این‌که ۱۲۸۰ دوره آزمایش داریم (۳۲ شرکت‌کننده × ۴۰ قطعه ویدئو) بعد از اعمال نگاشت CSP بر سیگنال مربوط به هر آزمایش یک ماتریس نگاشت Z با ابعاد ۳۲×۷۶۸۰ خواهیم داشت. بعد اول ماتریس Z تعداد کانال‌ها و بعد دوم تعداد نمونه‌ها در هر کانال در فضای جدید است. در واقع CSP میزان اهمیت کانال‌ها در هر بعد احساسی را مشخص می‌کند و نشان می‌دهد که چه بخش‌هایی از مغز مهم‌ترین نقش را در هر یک از ۴ بعد احساسی دارند.

اهمیت سطرهای ماتریس Z از سطر اول تا سطر میانی کاهش یافته و از سطر میانی تا سطر آخر افزایش می‌یابد [۱۷]. ما دو سطر اول و دو سطر آخر Z را به عنوان مهم‌ترین کانال‌های نگاشت شده در نظر گرفته و ۴ ویژگی را بر اساس رابطه (۴-۶) استخراج می‌کنیم:

$$F1 = \log\left(\frac{\text{var}(Z(1))}{\text{var}(Z(1)) + \text{var}(Z(2)) + \text{var}(Z(31)) + \text{var}(Z(32))}\right)$$

$$F2 = \log\left(\frac{\text{var}(Z(2))}{\text{var}(Z(1)) + \text{var}(Z(2)) + \text{var}(Z(31)) + \text{var}(Z(32))}\right)$$

$$F3 = \log\left(\frac{\text{var}(Z(3))}{\text{var}(Z(1)) + \text{var}(Z(2)) + \text{var}(Z(31)) + \text{var}(Z(32))}\right)$$

$$F4 = \log\left(\frac{\text{var}(Z(4))}{\text{var}(Z(1)) + \text{var}(Z(2)) + \text{var}(Z(31)) + \text{var}(Z(32))}\right)$$

(۶-۴)

بنابراین از هر آزمایش که شامل سیگنال‌های ثبت‌شده توسط ۳۲ کانال است و هر کانال شامل ۷۶۸۰ نمونه در حوزه زمان است، ۴ ویژگی استخراج می‌کنیم و در کلاسه‌بندی احساس از این ویژگی‌ها استفاده می‌کنیم. بنابراین این روش نیازی به کاهش ابعاد ویژگی‌ها ندارد و به دلیل اینکه تعداد ویژگی‌ها بسیار کم است پیچیدگی محاسباتی الگوریتم نیز بسیار پایین خواهد بود.

نرخ‌های کلاسه‌بندی برای ۳۲ بار آموزش و آزمون در هر ۴ بُعد احساسی در جدول (۶-۴) نشان داده شده‌اند. در هر یک از این ۳۲ دوره آموزش و آزمون، ویژگی‌های استخراج‌شده از سیگنال‌های مغزی یکی از شرکت‌کنندگان به‌عنوان مجموعه آزمودنی و ویژگی‌های مربوط به سیگنال‌های مغزی ۳۱ نفر دیگر به‌عنوان مجموعه آموزش در نظر می‌گیریم. با توجه به مقادیر این جدول مشاهده می‌کنیم که بیشترین نرخ کلاسه‌بندی بُعد اول، دوم، سوم و چهارم به ترتیب ۸۲.۵٪، ۸۷.۵٪، ۱۰۰٪ و ۹۵٪ است. در بُعد اول بالاترین نرخ کلاسه‌بندی مربوط به آموزش و آزمون شماره ۶، در بُعد دوم مربوط به آموزش و آزمون شماره ۹، در بُعد سوم مربوط به آموزش و آزمون شماره ۱ و ۶ و در بُعد چهارم مربوط به آموزش و آزمون شماره ۳۲ است. هر یک از این ۳۲ دوره مربوط به آزمودن یک از ۳۲ نفر بعد از آموزش ۳۱ نفر دیگر است. بنابراین سیگنال‌های مربوط به شرکت‌کننده‌های شماره ۳۲ و ۹، ۶، ۱ دارای نرخ بازشناسی بالاتری بوده‌اند. از بین این شرکت‌کننده‌ها با توجه به جدول (۶-۴) نرخ‌های به‌دست‌آمده برای نفر ششم در هر چهار بُعد نرخ‌های قابل‌قبولی هستند. در این جدول درصدهای بالاتر از ۷۰٪ را با تأکید بیشتری نشان داده‌ایم. مشاهده می‌کنیم که تنها برای نفر ششم در سه بُعد نرخ بالاتر از ۷۰٪ به دست‌آمده و در چهارمین بُعد دقیقاً ۷۰٪ است.

جدول ۴-۶ نرخ کلاسه‌بندی ویژگی‌های استخراج‌شده از روش CSP برای هر یک از ۳۲ شرکت‌کننده.

شماره مجموعه آزمودنی:	بُعد اول	بُعد دوم	بُعد سوم	بُعد چهارم
شرکت‌کننده ۱	%۵۵	%۷۲.۵	%۱۰۰	%۵۵
شرکت‌کننده ۲	%۷۲.۵	%۵۲.۵	%۶۰	%۷۲.۵
شرکت‌کننده ۳	%۷۰	%۶۲.۵	%۷۵	%۵۲.۵
شرکت‌کننده ۴	%۵۷.۵	%۶۷.۵	%۶۰	%۶۰
شرکت‌کننده ۵	%۶۲.۵	%۵۰	%۷۰	%۶۷.۵
شرکت‌کننده ۶	%۸۲.۵	%۷۰	%۱۰۰	%۸۵
شرکت‌کننده ۷	%۶۷.۵	%۵۰	%۶۷.۵	%۷۷.۵
شرکت‌کننده ۸	%۶۰	%۷۷.۵	%۹۲.۵	%۶۷.۵
شرکت‌کننده ۹	%۴۷.۵	%۸۷.۵	%۶۵	%۵۷.۵
شرکت‌کننده ۱۰	%۸۰	%۴۰	%۹۰	%۵۲.۵
شرکت‌کننده ۱۱	%۵۵	%۷۲.۵	%۷۰	%۶۵
شرکت‌کننده ۱۲	%۶۲.۵	%۸۰	%۶۵	%۶۵
شرکت‌کننده ۱۳	%۷۰	%۸۵	%۵۵	%۷۲.۵
شرکت‌کننده ۱۴	%۶۵	%۷۰	%۶۷.۵	%۷۲.۵
شرکت‌کننده ۱۵	%۷۵	%۶۰	%۹۰	%۶۵
شرکت‌کننده ۱۶	%۶۵	%۶۵	%۹۵	%۶۵
شرکت‌کننده ۱۷	%۴۲	%۵۰	%۵۲.۵	%۵۲.۵
شرکت‌کننده ۱۸	%۵۵	%۵۵	%۵۲.۵	%۶۷.۵
شرکت‌کننده ۱۹	%۵۰	%۶۷.۵	%۵۲.۵	%۷۵
شرکت‌کننده ۲۰	%۵۰	%۸۷.۵	%۵۵	%۶۷.۵
شرکت‌کننده ۲۱	%۵۷.۵	%۸۷.۵	%۵۰	%۶۰
شرکت‌کننده ۲۲	%۶۷.۵	%۴۵	%۷۵	%۵۵
شرکت‌کننده ۲۳	%۶۰	%۵۷.۵	%۶۵	%۷۷.۵
شرکت‌کننده ۲۴	%۵۷.۵	%۷۲.۵	%۴۵	%۹۰
شرکت‌کننده ۲۵	%۶۵	%۷۷.۵	%۷۰	%۹۰
شرکت‌کننده ۲۶	%۷۷.۵	%۶۲.۵	%۵۵	%۹۲.۵
شرکت‌کننده ۲۷	%۸۲.۵	%۴۷.۵	%۶۵	%۷۲.۵

شرکت‌کننده ۲۸	%۷۰	%۶۲.۵	%۴۵	%۶۲.۵
شرکت‌کننده ۲۹	%۴۲.۵	%۴۵	%۳۷.۵	%۵۵
شرکت‌کننده ۳۰	%۷۵	%۲۲.۵	%۵۵	%۹۰
شرکت‌کننده ۳۱	%۷۲.۵	%۶۷.۵	%۷۰	%۷۰
شرکت‌کننده ۳۲	%۵۰	%۶۲.۵	%۶۷.۵	%۹۵

با توجه به جدول (۴-۶) مشاهده می‌شود که هیچ‌یک از افراد در هر چهار بُعد نرخ بالاتر از %۷۰ نداشته است. اما با این حال شرکت‌کنندگان شماره ۶، ۱۲، ۱۴، ۱۶، ۲۵ و ۳۱ در هر چهار بُعد دارای نرخ بازشناسی بالاتر از %۶۰ بوده‌اند.

برای به دست آوردن یک نرخ کلاسه‌بندی برای هر بُعد احساسی، بین ۳۲ نرخ به‌دست‌آمده برای هر بُعد متوسط‌گیری کرده‌ایم. متوسط نرخ‌های به‌دست‌آمده برای ۴ بُعد در جدول (۴-۷) نشان داده شده‌اند.

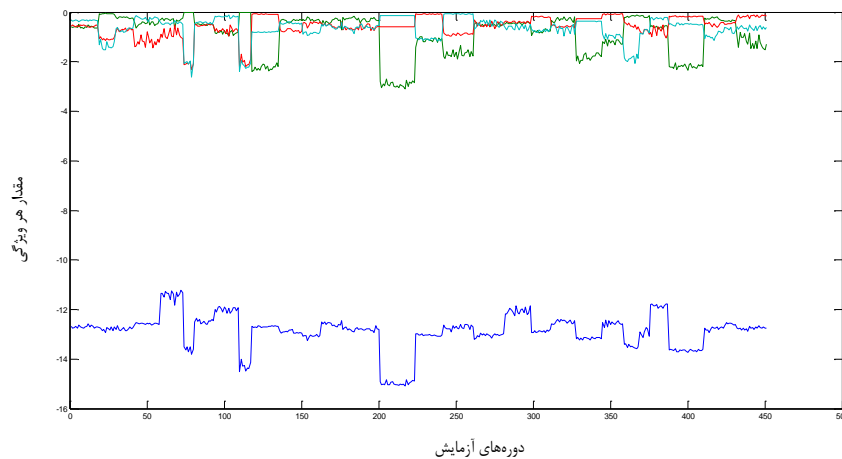
جدول ۴-۷ نرخ متوسط کلاسه‌بندی با اعمال روش CSP برای ۴ بُعد احساسی با در نظر گرفتن ۴ ویژگی برای هر دوره آزمایش.

بُعد	CSP
اول	%۶۳.۱۲
دوم	%۶۳.۵۱
سوم	%۶۶.۷۲
چهارم	%۶۹.۵۳

نرخ کلاسه‌بندی در بُعد اول و دوم نسبت به روش DTCWPT با ۲۲ ویژگی تغییری نکرده است و همان %۶۳.۱۲ و %۶۹.۵۳ باقی‌مانده است. در بُعد دوم %۶۳.۵۱ به‌دست‌آمده که نسبت به روش قبل که درصد کلاسه‌بندی %۶۱.۸۷ بود افزایش یافته است. در بُعد سوم نیز با نرخ %۶۶.۷۲ نسبت به %۶۴.۶۹، نرخ کلاسه‌بندی بهبود یافته است.

۴-۲-۱-۴ - نرمال‌سازی ویژگی‌های CSP

در شکل (۷-۴) چهار ویژگی استخراج شده از روش CSP مربوط به تعدادی از دوره‌های آزمایش نشان داده شده‌اند. این شکل مربوط به کلاس Low بوده اما محدوده مقادیر ویژگی‌ها برای کلاس High نیز تا حدودی به همین صورت است. با توجه به این شکل واضح است که از میان چهار ویژگی استخراج شده، مقدار سه ویژگی تقریباً در یک محدوده قرار دارد ولی مقدار یکی از ویژگی‌ها خارج از محدوده مقادیر سه ویژگی دیگر است.



شکل ۷-۴ مقدار به دست آمده برای ۴ ویژگی استخراج شده از روش CSP در چندین دوره آزمایش مربوط به کلاس Low

زمانی که تفاوت زیادی میان محدوده مقادیر ویژگی‌های مختلف وجود داشته باشد برای داشتن محدوده یکسانی از مقادیر، از نرمال‌سازی ویژگی‌ها استفاده می‌کنیم. برای نرمال کردن ویژگی‌های CSP از چهار روش نرمال‌سازی داده‌ها مطابق با رابطه‌های (۷-۴) تا (۱۰-۴) استفاده کرده ایم.

$$TrainNew(feature) = \frac{Train(feature)}{Mean(feature)} \quad (۷-۴)$$

$$TrainNew(feature) = \frac{Train(feature) - Mean(feature)}{STD(feature)} \quad (۸-۴)$$

$$TrainNew(feature) = \frac{(Train(feature) - Min(feature))}{(Max(feature) - Min(feature))} \quad (۹-۴)$$

زمانی که ساختار درونی نمونه‌ها موردعلاقه است و نه تفاوت‌های مطلق بین نمونه‌ها، از رابطه (۴-۱۰) برای نرمال‌سازی استفاده می‌شود.

$$TrainNew(feature) = \frac{Train(feature)}{Max(feature)} \quad (10-4)$$

$Mean(feature)$ میانگین یک ویژگی در کل دوره‌های آموزش و $STD(feature)$ انحراف معیار یک ویژگی در تمام دوره‌های آموزش است. واضح است که $Max(feature)$ و $Min(feature)$ هم به ترتیب کمترین و بیشترین مقدار یک ویژگی در کل دوره‌های آموزش هستند. داده‌های آزمون نیز دقیقاً به همین صورت نرمال‌سازی می‌شوند. در جدول (۴-۸) ویژگی‌های استخراج شده از روش CSP نرمال‌سازی شده و نرخ کلاسه‌بندی محاسبه شده است. نتایج نشان می‌دهند استفاده از روش اول و سوم برای نرمال‌سازی این ویژگی‌ها مناسب‌تر است.

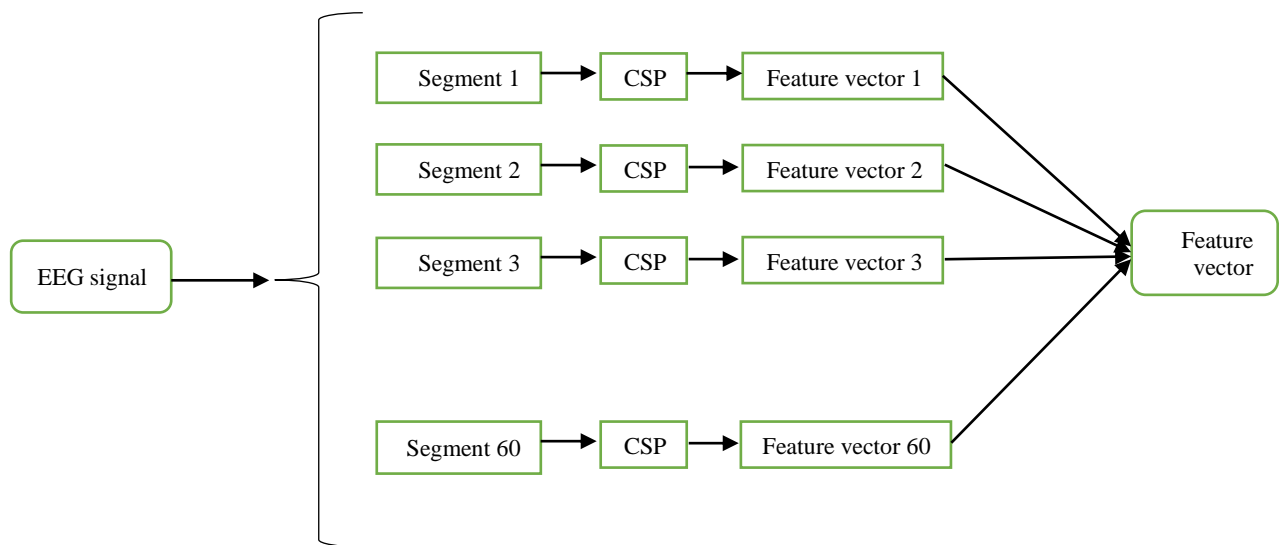
جدول ۴-۸ نرخ کلاسه‌بندی بعد از نرمال‌سازی ویژگی‌های استخراج شده از روش CSP به چهار روش مختلف.

بُعد	روش اول	روش دوم	روش سوم	روش چهارم
اول	٪۶۳.۱۲	٪۶۲.۵۸	٪۶۳.۴۴	٪۶۳.۱۲
دوم	٪۶۳.۷۵	٪۶۲.۸۹	٪۵۹.۶۹	٪۶۳.۷۵
سوم	٪۶۶.۷۲	٪۶۶.۴۱	٪۶۵.۹۴	٪۶۶.۷۲
چهارم	٪۶۹.۵۳	٪۶۹.۵۳	٪۶۹.۵۳	٪۶۹.۵۳

۴-۲-۲-۲- تقطیع زمانی سیگنال EEG

الگوریتم‌هایی که تا به حال برای استخراج ویژگی از سیگنال EEG بر این سیگنال اعمال کردیم بر روی کل سیگنال اعمال شد و تمام ۶۰ ثانیه را یکجا در نظر گرفتیم. با در نظر گرفتن این واقعیت که احساس انسان در طول زمان متغیر است و در طول یک بازه زمانی خاص ثابت نمی‌ماند تصمیم گرفتیم که سیگنال EEG ۶۰ ثانیه‌ای را در بازه‌های زمانی کوچک‌تر مورد بررسی قرار دهیم. به این

منظور هر سیگنال را به ۶۰ بازه زمانی یک‌ثانیه‌ای تقسیم کردیم. در هر یک از بازه‌های یک‌ثانیه‌ای مطابق شکل (۴-۸)، با اعمال روش CSP ویژگی‌ها را استخراج کرده و مجدداً آموزش و آزمون را تکرار کردیم و نرخ‌های متوسط را در هر ثانیه جداگانه به دست آوردیم. این فرآیند را در هر بُعد احساسی انجام دادیم.



شکل ۴-۸ اعمال روش CSP بر بخش‌های زمانی و استخراج بردارهای ویژگی.

همان‌طور که انتظار داشتیم نرخ کلاسه‌بندی در هر یک از بخش‌های زمانی تا حدودی متفاوت بود اما نکته قابل‌توجه این بود که نرخ‌های بازشناسی برای قسمت‌های زمانی مختلف با نرخ بازشناسی برای کل سیگنال تفاوت چندانی نداشت.

جدول ۹-۴ نرخ کلاسه‌بندی ویژگی‌های استخراج‌شده از هر ثانیه از سیگنال EEG به روش CSP.

ثانیه شماره	بُعد اول	بُعد دوم	بُعد سوم	بُعد چهارم
۱	۶۳.۱۲٪	۶۳.۷۵٪	۶۶.۸۷٪	۶۹.۵۳٪
۲	۶۳.۳۵٪	۶۳.۶۷٪	۶۶.۲۵٪	۶۹.۵۳٪
۳	۶۳.۱۲٪	۶۳.۹۰٪	۶۶.۷۹٪	۶۹.۵۳٪
۴	۶۳.۱۲٪	۶۳.۷۵٪	۶۶.۷۱٪	۶۹.۵۳٪
۵	۶۲.۸۹٪	۶۳.۷۵٪	۶۶.۷۹٪	۶۹.۵۳٪
۶	۶۳.۰۴٪	۶۳.۷۵٪	۶۶.۲۵٪	۶۹.۵۳٪
۷	۶۲.۰۳٪	۶۲.۸۹٪	۶۶.۵۶٪	۶۹.۵۳٪
۸	۶۳.۲۸٪	۶۲.۲۶٪	۶۶.۷۱٪	۶۹.۵۳٪
۹	۶۳.۱۲٪	۶۳.۷۵٪	۶۶.۰۹٪	۶۹.۵۳٪
۱۰	۶۲.۱۸٪	۶۲.۸۹٪	۶۶.۷۱٪	۶۹.۵۳٪
۱۱	۶۳.۱۲٪	۶۳.۷۵٪	۶۶.۷۱٪	۶۹.۵۳٪
۱۲	۶۳.۴۳٪	۶۲.۳۴٪	۶۶.۳۲٪	۶۹.۵۳٪
۱۳	۶۳.۱۲٪	۶۳.۷۵٪	۶۶.۸۷٪	۶۹.۵۳٪
۱۴	۶۳.۲۰٪	۶۳.۸۲٪	۶۶.۷۱٪	۶۹.۵۳٪
۱۵	۶۳.۱۲٪	۶۳.۶۷٪	۶۶.۷۱٪	۶۹.۵۳٪
۱۶	۶۳.۱۲٪	۶۲.۲۶٪	۶۶.۷۱٪	۶۹.۵۳٪
۱۷	۶۲.۶۵٪	۶۳.۷۵٪	۶۷.۱۰٪	۶۹.۵۳٪
۱۸	۶۱.۸۷٪	۶۳.۱۲٪	۶۶.۷۱٪	۶۹.۵۳٪
۱۹	۶۳.۱۲٪	۶۳.۶۷٪	۶۶.۸۷٪	۶۹.۵۳٪
۲۰	۶۲.۹۶٪	۶۲.۶۵٪	۶۶.۷۱٪	۶۹.۴۵٪
۲۱	۶۳.۱۲٪	۶۳.۷۵٪	۶۶.۴۰٪	۶۹.۵۳٪
۲۲	۶۳.۱۲٪	۶۳.۷۵٪	۶۶.۷۱٪	۶۹.۵۳٪
۲۳	۶۳.۱۲٪	۶۳.۷۵٪	۶۶.۶۴٪	۶۹.۵۳٪
۲۴	۶۳.۲۰٪	۶۲.۴۲٪	۶۶.۶۴٪	۶۹.۵۳٪
۲۵	۶۱.۸۷٪	۶۳.۰۴٪	۶۶.۷۱٪	۶۹.۵۳٪
۲۶	۶۳.۱۲٪	۶۳.۱۲٪	۶۶.۴۰٪	۶۹.۵۳٪
۲۷	۶۲.۸۱٪	۶۲.۸۱٪	۶۷.۲۶٪	۶۹.۵۳٪
۲۸	۶۳.۱۲٪	۶۳.۷۵٪	۶۶.۵۶٪	۶۹.۵۳٪
۲۹	۶۳.۱۲٪	۶۳.۷۵٪	۶۶.۷۱٪	۶۹.۵۳٪
۳۰	۶۲.۹۶٪	۶۳.۷۵٪	۶۶.۷۱٪	۶۹.۵۳٪
۳۱	۶۳.۱۲٪	۶۳.۷۵٪	۶۶.۷۱٪	۶۹.۵۳٪
۳۲	۶۳.۱۲٪	۶۳.۷۵٪	۶۵.۶۲٪	۶۹.۵۳٪

۳۳	۶۳.۱۲٪	۶۳.۸۲٪	۶۶.۶۴٪	۶۹.۵۳٪
۳۴	۶۲.۴۲٪	۶۱.۹۵٪	۶۶.۲۵٪	۶۹.۵۳٪
۳۵	۶۳.۱۲٪	۶۳.۴۳٪	۶۶.۹۵٪	۶۹.۵۳٪
۳۶	۶۳.۱۲٪	۶۳.۷۵٪	۶۶.۷۱٪	۶۹.۵۳٪
۳۷	۶۳.۱۲٪	۶۳.۷۵٪	۶۵.۹۳٪	۶۹.۵۳٪
۳۸	۶۳.۱۲٪	۶۳.۷۵٪	۶۶.۲۵٪	۶۹.۵۳٪
۳۹	۶۳.۱۲٪	۶۳.۷۵٪	۶۶.۷۱٪	۶۹.۵۳٪
۴۰	۶۱.۷۹٪	۶۳.۷۵٪	۶۶.۷۱٪	۶۹.۵۳٪
۴۱	۶۳.۱۲٪	۶۲.۱۸٪	۶۶.۳۲٪	۶۹.۵۳٪
۴۲	۶۳.۱۲٪	۶۳.۷۵٪	۶۶.۵۶٪	۶۹.۵۳٪
۴۳	۶۳.۱۲٪	۶۳.۳۵٪	۶۶.۴۸٪	۶۹.۵۳٪
۴۴	۶۲.۸۹٪	۶۳.۳۵٪	۶۶.۷۱٪	۶۹.۵۳٪
۴۵	۶۲.۷۳٪	۶۳.۸۲٪	۶۶.۷۱٪	۶۹.۵۳٪
۴۶	۶۳.۱۲٪	۶۳.۷۵٪	۶۶.۷۱٪	۶۹.۵۳٪
۴۷	۶۲.۷۳٪	۶۲.۰۳٪	۶۵.۲۳٪	۶۹.۵۳٪
۴۸	۶۳.۲۰٪	۶۳.۱۲٪	۶۶.۶۴٪	۶۹.۵۳٪
۴۹	۶۲.۱۸٪	۶۳.۵۹٪	۶۶.۷۱٪	۶۹.۵۳٪
۵۰	۶۳.۰۴٪	۶۳.۸۲٪	۶۶.۵۶٪	۶۹.۵۳٪
۵۱	۶۲.۰۳٪	۶۴.۱۴٪	۶۶.۵۶٪	۶۹.۵۳٪
۵۲	۶۳.۱۲٪	۶۳.۷۵٪	۶۶.۷۱٪	۶۹.۵۳٪
۵۳	۶۳.۱۲٪	۶۳.۷۵٪	۶۶.۵۶٪	۶۹.۵۳٪
۵۴	۶۲.۹۶٪	۶۳.۶۷٪	۶۶.۸۷٪	۶۹.۵۳٪
۵۵	۶۳.۱۲٪	۶۳.۳۵٪	۶۶.۸۷٪	۶۹.۵۳٪
۵۶	۶۳.۲۰٪	۶۳.۷۵٪	۶۶.۷۱٪	۶۹.۵۳٪
۵۷	۶۳.۱۲٪	۶۳.۹۰٪	۶۶.۷۱٪	۶۹.۵۳٪
۵۸	۶۳.۱۲٪	۶۳.۶۷٪	۶۶.۷۱٪	۶۹.۵۳٪
۵۹	۶۳.۱۲٪	۶۳.۲۸٪	۶۶.۶۴٪	۶۹.۵۳٪
۶۰	۶۳.۱۲٪	۶۲.۷۳٪	۶۶.۶۴٪	۶۹.۵۳٪

همان‌طور که در جدول (۴-۹) مشاهده می‌شود تفاوت زیادی بین ۶۰ نرخ به دست آمده وجود ندارد. اما باید این نکته را نیز در نظر بگیریم که نرخ بازشناسی در طول ۶۰ ثانیه ثابت نمی‌ماند. در بُعد اول، دوم سوم بیشترین نرخ بازشناسی به ترتیب مربوط به ثانیه ۱۲، ۵۱ و ثانیه ۲۷ بود و در هر

یک از ابعاد به ترتیب برابر با ۶۳.۴۳٪، ۶۴.۱۴٪ و ۶۷.۲۷٪ به دست آمد. در بُعد چهارم نرخ بازشناسی تقریباً ثابت است.

۴-۲-۳- ادغام ویژگی‌های دو روش CSP و DTCWPT

با توجه به نتایج به دست آمده از روش CSP و DTCWPT و مقایسه نتایج به دست آمده از هر روش، ایده دیگری که به ذهن ما رسید ادغام ویژگی‌های به دست آمده از هر دو روش و کلاسه‌بندی با استفاده از آن ویژگی‌ها بود. به این صورت که با قرار دادن ویژگی‌های روش CSP در کنار ویژگی‌های روش DTCWPT در هر یک از دوره‌های آزمایش چهار ویژگی دیگر به ویژگی‌های روش DTCWPT افزوده می‌شود.

در صورتی که ۲۲ ویژگی پراهمیت‌تر در روش DTCWPT را انتخاب کنیم و ۴ ویژگی روش CSP را به آن‌ها اضافه کنیم در مجموع برای هر دوره آزمایش ۲۶ ویژگی داریم. در واقع از سیگنال EEG ثبت شده توسط هر الکتروود که ۷۶۸۰ نمونه در حوزه زمان داشت، ۲۶ ویژگی استخراج کردیم که ۲۲ ویژگی از طریق روش موجک و ۴ ویژگی از طریق روش CSP استخراج شده‌اند. اگر تعداد ویژگی‌های حاصل از روش DTCWPT را به ۵۰ ویژگی افزایش دهیم، نرخ کلاسه‌بندی مطابق با جدول (۴-۱۰) تغییر می‌کند. با توجه به جدول (۴-۱۰) مشاهده می‌کنیم که با افزایش تعداد ویژگی‌های استخراج شده از روش DTCWPT تغییر فراوانی در نرخ‌های بازشناسی به وجود نمی‌آید.

جدول ۴-۱۰ ادغام ویژگی‌های فرکانسی حاصل از روش DTCWPT و ویژگی‌های مربوط به روش CSP.

بُعد	موجک با ۲۲ ویژگی + CSP	موجک با ۵۰ ویژگی + CSP
اول	۶۳.۴۳٪	۶۳.۱۲٪
دوم	۶۲.۸۱٪	۶۳.۷۵٪
سوم	۶۶.۴۸٪	۶۶.۴۰٪
چهارم	۶۹.۵۳٪	۶۹.۵۳٪

با توجه به جدول (۴-۱۰) مشاهده می‌شود چنانچه ۲۲ ویژگی از تحلیل موجک را در نظر بگیریم نرخ بازشناسی در بُعد اول نسبت به هر یک از روش‌ها از ۶۳.۱۲٪ به ۶۳.۴۳٪ افزایش یافته و در بُعد دوم و سوم نسبت به روش موجک افزایش نرخ و نسبت به روش CSP کاهش نرخ داشتیم و در بُعد سوم هیچ تغییری مشاهده نشد. اگر تعداد ویژگی‌های موجک را به ۵۰ ویژگی افزایش دهیم در نرخ بازشناسی بُعد اول و چهارم تغییری ایجاد نمی‌شود. در بُعد دوم نسبت به هر دو روش افزایش نرخ، در بُعد سوم نسبت به روش موجک افزایش و نسبت به روش CSP کاهش نرخ داریم. در جدول (۴-۱۱) حاصل نرمال‌سازی ادغام روش DTCWPT با بهترین تعداد ویژگی‌ها و CSP نشان داده شده است.

جدول ۴-۱۱ نتایج به دست آمده از ادغام ویژگی‌های دو روش و نرمال‌سازی ویژگی‌ها. در این حالت بهترین تعداد ویژگی‌ها برای روش DTCWPT در نظر گرفته شده است.

بُعد	موجک + CSP	موجک + CSP نرمال شده به روش سوم	موجک + CSP نرمال شده به روش اول
اول	۶۲.۸۹٪	۶۳.۱۲٪	۶۲.۹۷٪
دوم	۶۳.۷۵٪	۶۳.۷۵٪	۶۳.۴۴٪
سوم	۶۶.۷۲٪ ۶۶.۳۳٪	۶۶.۷۲٪ ۶۶.۷۲٪	۶۶.۷۲٪ ۶۶.۷۲٪
چهارم	۶۹.۶۱٪	۶۹.۵۳٪	۶۹.۰۶٪

با نرمال کردن ویژگی‌ها نرخ در بُعد اول کمی کاهش یافته است، اما در ابعاد دیگر تغییر نرخ مثبت بوده است.

۴-۲-۴ اعمال روش KNMF

بعد از اعمال روش CSP بر روی داده‌ها و بررسی اثر ترکیب ویژگی‌های CSP و DTCWPT به دنبال روش سوم بودیم که بتوانیم با استفاده از آن درصد کلاسه‌بندی را افزایش دهیم. به همین منظور از روش KNMF به عنوان سومین روش استفاده کردیم.

در مقاله‌ای که به‌عنوان مقاله مرجع این بخش در نظر گرفتیم از ویژگی‌های به‌دست‌آمده از موجک مورلت^۱ به‌عنوان ماتریس داده‌ها استفاده شده است. موجک مورلت در پردازش داده‌های EEG بسیار پرکاربرد است. نمایش زمانی- فرکانسی داده‌های EEG با پالایش توسط موجک‌های مختلط مورلت به دست می‌آید. ما به‌جای استفاده از این موجک، از تبدیل DTCWPT استفاده کردیم. در حالت قبل برای استخراج ویژگی‌ها از سیگنال EEG با اعمال روش DTCWPT، هر سیگنال ۷۶۸۰ نمونه‌ای EEG، به ۱۶ زیرباند فرکانسی با ۴۸۰ نمونه در هر یک از دو درخت تبدیل شد و برای تولید ویژگی‌ها انرژی لگاریتمی این زیرباندها را به دست آوردیم.

در اینجا به ویژگی‌های زمان- فرکانسی نیاز داریم بنابراین برای نمایش ویژگی‌ها در حوزه زمان- فرکانس، هر زیرباند فرکانسی ۴۸۰ نمونه‌ای را به ۱۶ بخش ۳۰ نمونه‌ای تقسیم کردیم و انرژی هر یک از ۱۶ زیرباند فرکانسی را در ۱۶ قطعه جداگانه به دست آوردیم. برای ساخت ماتریس داده‌ها انرژی‌های به‌دست‌آمده باید به‌گونه‌ای مرتب شوند که سطرهاى این ماتریس دوره‌های آزمایش و ستون‌های آن ویژگی‌های مربوط به ۴۶ الکتروود را نشان دهد. سیگنال EEG ثبت‌شده توسط هر الکتروود به ۱۶ زیرباند فرکانسی تقسیم می‌شود. هر دوره آزمایش با الکتروودها ثبت‌شده و به ۱۶ زیرباند فرکانسی تقسیم می‌شود که این زیرباندها نیز به ۱۶ قطعه تقسیم می‌شود. در واقع ماتریس داده‌ها را به این شکل ساختیم که ستون‌های آن زیرباندهای فرکانسی و سطرها دوره‌های آزمایش باشند به این منظور اطلاعات فرکانسی هر یک از الکتروودها را در ۱۶ زیرباند نمایش دادیم و انرژی هر یک از این زیرباندها را در هر دوره آزمایش در ۱۶ قطعه به دست آوردیم. بنابراین با در نظر گرفتن انرژی مربوط به جفت الکتروودها تعداد ستون‌های ماتریس داده‌ها برابر با

$$736 = 16 \times (32 \text{ (الکتروود)}) + 14 \text{ (جفت الکتروود)}$$

¹ Morlet Wavelet

و تعداد سطرهای آن برابر با $20480 = 16 \times (\text{قطعه زمانی } 30 \text{ نمونه‌ای}) \times 1280$ (دوره آزمایش) است که البته از این تعداد، در هر دوره آموزش و آزمون 19840 سطر را به‌عنوان مجموعه آموزش و 640 سطر را به‌عنوان مجموعه آزمودنی استفاده کردیم.

درواقع هر دوره آزمایش با

$$11776 = 16 \times (\text{زیرباند}) \times 46 \times (32) \times (\text{الکتروود}) + 14 \times (\text{جفت الکتروود}) \times 16 \times (\text{قطعه زمانی})$$

عدد نمایش داده می‌شود و ما 1280 دوره آزمایش داریم. بنابراین تعداد کل درایه‌های موجود در ماتریس آموزش 14602240 و تعداد درایه‌های ماتریس آزمودنی 471040 است.

واضح است که به دلیل بالا بودن تعداد داده‌ها، آموزش و آزمون با سرعت کمی انجام شده و زمان زیادی نیاز دارند. ابتدا تصمیم گرفتیم برای کاهش تعداد داده‌ها، هر یک از 16 بخش زمانی را جداگانه مورد بررسی قرار دهیم و برای هر پنجره زمانی نرخی جدا به دست آوریم و در نهایت بین نرخ‌های به‌دست آمده برای 16 قطعه زمانی متوسط گیری انجام دهیم. در این حالت در هر دوره آموزش و آزمون $1240 = 16 / 19840$ سطر را برای آموزش و $40 = 640 / 16$ سطر را برای آزمون استفاده کردیم و این عمل را 16 بار برای 16 قطعه زمانی 30 نمونه‌ای تکرار کردیم.

۴-۲-۴-۱ - کلاسه‌بندی با بیشینه نرخ 16 قسمت زمانی

اگر در هر یک از 16 بخش زمانی به‌طور جداگانه بدون اعمال KNMF آموزش و آزمون را انجام دهیم در برخی از بخش‌ها نتایج بسیار خوبی خواهیم داشت که البته شماره این بخش در هر یک از 32 نفر متفاوت است. متوسط ماکسیمم 16 نرخ به‌دست آمده را برای کل افراد در بُعد اول، دوم، سوم چهارم به ترتیب 66.79% ، 69.69% ، 68.75% و 69.92% به دست آوردیم.

برای بررسی این روش بیشینه نرخ 16 قطعه زمانی را در نظر گرفتیم و بعد بین نرخ‌های بیشینه متوسط گیری کردیم با اعمال KNMF (با معیار توقف 1 و تعداد تکرار 10) نتایج با افزایش K به جدول (۴-۱۲) در بُعد اول تغییر می‌کنند:

جدول ۴-۱۲ نرخ کلاسه‌بندی برای بُعد اول با استفاده از روش KNMF برای مقادیر مختلف K. در این حالت بیشینه نرخ در ۱۶ بخش زمانی را در نظر گرفتیم.

K	۲	۲۰	۲۰۰	۴۰۰	۶۰۰	۷۰۰
بُعد اول	۶۴.۴۵٪	۶۵.۸۵٪	۶۶.۳۲٪	۶۶.۴۰٪	۶۶.۸۷٪	۶۶.۴۸٪

با افزایش ابعاد ویژگی‌ها نرخ کلاسه‌بندی به‌طور کاملاً یکنوا تغییر نمی‌کند و دارای نوساناتی است اما می‌توان گفت که این نرخ با افزایش ابعاد ویژگی‌ها بهبود می‌یابد. البته سرعت کلاسه‌بندی در این حالت بسیار پایین خواهد بود.

۴-۲-۲-۲ کلاسه‌بندی با متوسط نرخ ۱۶ قسمت زمانی

اگر به‌جای استفاده از بیشینه نرخ‌ها بین ۱۶ اسلام میانگین آن‌ها را بگیریم. بدون استفاده از KNMF نرخ به‌دست‌آمده برای بُعد اول، دوم، سوم و چهارم به ترتیب ۵۰.۸۵٪، ۵۱.۲۳٪، ۵۱.۵۹٪ و ۵۲.۰۳٪ خواهد بود. و با اعمال KNMF نتایج کلاسه‌بندی به‌صورت جدول (۴-۱۵) خواهد بود. برای بررسی تأثیر ابعاد ویژگی‌ها بر نتیجه کلاسه‌بندی با تغییر مقدار K این اثر را مجدداً در بُعد اول مورد بررسی قرار دادیم. نتایج به‌صورت جدول (۴-۱۳) به دست آمدند.

جدول ۴-۱۳ نرخ کلاسه‌بندی برای بُعد اول با استفاده از روش KNMF برای مقادیر مختلف K. در این حالت متوسط نرخ ۱۶ بخش زمانی را در نظر گرفتیم.

K	۲	۲۰	۲۰۰	۴۰۰	۶۰۰	۶۵۰	۷۰۰
بُعد اول	۶۱.۷۹٪	۵۱.۹۷٪	۴۸.۸۸٪	۵۰.۷۵٪	۵۰.۸۱٪	۵۰.۵۵٪	۵۰.۳۳٪

با توجه به دو جدول (۴-۱۲) و (۴-۱۳) می‌توان به این نتیجه رسید که در صورتی که بیشینه نرخ‌ها در ۱۶ قطعه زمانی را در نظر بگیریم با افزایش K تقریباً متوسط ماکسیمم‌ها به‌طور یکنوا افزایش می‌یابد اما در صورتی که میانگین نرخ‌ها در ۱۶ بخش زمانی در نظر گرفته شود با افزایش K نرخ به‌طور

یکنوا تغییر نکرده و همچنین نرخ‌های پایین‌تری نسبت به حالت قبل خواهیم داشت. نرخ کلاسه‌بندی بر اساس متوسط ۱۶ نرخ به‌دست‌آمده به ازای $k=2$ در هر ۴ بُعد در جدول (۴-۱۴) آمده است.

جدول ۴-۱۴ نرخ کلاسه‌بندی برای هر ۴ بُعد با فرض $k=2$. این نرخ‌ها با متوسط‌گیری بین ۱۶ نرخ به‌دست‌آمده برای ۱۶ بخش زمانی در هر آزمایش به‌دست‌آمده‌اند.

بُعد	اول	دوم	سوم	چهارم
K=2	٪۶۱.۷۹	٪۵۹.۲۶	٪۶۲.۹۱	٪۶۵.۸۱

۴-۲-۳-۴ کلاسه‌بندی با رأی‌گیری بین نتایج ۱۶ قسمت زمانی

چنانچه کلاسه‌بندی بر اساس رأی‌گیری بین نتایج ۱۶ قسمت انجام شود بدون اعمال KNMF نرخ متوسط رأی ۳۲ نفر در بُعد اول ۵۱.۳۲٪ است. با اعمال KNMF به نتایج جدول (۴-۱۵) برای بُعد اول رسیدیم.

جدول ۴-۱۵ نرخ کلاسه‌بندی برای بُعد اول با استفاده از روش KNMF برای مقادیر مختلف K . در این حالت کلاسه‌بندی بر اساس رأی‌گیری بین نتایج ۱۶ بخش زمانی انجام شده است.

k	۲	۲۰	۲۰۰	۴۰۰	۶۰۰	۷۰۰
بُعد اول	۶۰.۶۲٪	۵۰.۴۶٪	۴۷.۸۹٪	۵۰.۸۲٪	۴۹.۶۴٪	۴۸.۲۲٪

با توجه کاهش نرخ‌های به‌دست‌آمده می‌توان به این نتیجه رسید که استفاده از ایده رأی‌گیری در این حالت مناسب نیست.

۴-۲-۵ کلاسه‌بندی بر مبنای رأی‌گیری بین نتایج سه روش

حالت دیگری را با در نظر گرفتن هر سه روش DTCWPT و CSP و KNMF برای کلاسه‌بندی موردبررسی قرار دادیم. در این حالت از تقطیع زمانی استفاده‌نشده و سیگنال را به‌طور کامل توسط هر

یک از روش‌ها برای استخراج ویژگی به کار بردیم. الگوریتم KNMF با دو بعد به سیگنال آموزش اعمال شد و از روش رأی‌گیری بین نتایج به‌دست‌آمده بین ۱۶ قطعه زمانی سیگنال EEG برای مشخص کردن کلاس داده‌های مجموعه آزمودنی استفاده شد. بعد از به دست آوردن کلاس داده‌های آزمودنی توسط هر یک از سه روش، برای مشخص کردن برچسب نهایی هر داده بین سه نتیجه به‌دست‌آمده رأی‌گیری کردیم. نتایج کلاسه‌بندی در جدول (۴-۱۶) آمده‌اند.

جدول ۴-۱۶ نرخ کلاسه‌بندی برای هر بُعد با توجه به نتایج به‌دست‌آمده از هر سه روش.

بُعد	حاصل رأی‌گیری بین نتایج سه روش
اول	٪۶۳.۱۲
دوم	٪۶۳.۳۶
سوم	٪۶۶.۹۵
چهارم	٪۶۹.۵۳

با مقایسه نتایج به‌دست‌آمده با نتیجه هر یک از روش‌ها می‌توان گفت این حالت در بُعد دوم و سوم نرخ را تقریباً نسبت به هر سه روش کمی بهبود داده است.

۴-۲-۶ اعمال روش KSVD

در این روش سیگنال EEG به‌طور مستقیم آموزش داده می‌شود بدون اینکه استخراج ویژگی انجام شود. برای اعمال روش KSVD بر روی داده‌ها، هر سیگنال EEG را به ۳۰ قطعه زمانی شکسته و آموزش و آزمون را در هر یک از این ۳۰ قطعه جداگانه انجام دادیم. بنابراین ابعاد ماتریس داده‌های مربوط به هر کلاس در هر بار آموزش برابر است با:

(تعداد دوره‌های آموزشی کلاس) $8192 \times$ (نمونه در هر ۲ ثانیه از سیگنال) $32 \times$ (الکتروود)

در این حالت اندازه دیکشنری را ۱۲ و تعداد اتم‌های غیر صفر را ۶ در نظر گرفته‌ایم. در واقع ابعاد دیکشنری در هر بار آموزش برابر با $۱۲ \times ۸۱۹۲ \times ۲۵۶$ (نمونه در هر ۲ ثانیه از سیگنال) $\times ۳۲$ (الکتروود)) است. نتایج به صورت زیر برای ۳۰ قطعه زمانی دوثانیه‌ای به دست آمده‌اند.

جدول ۴-۱۷ درصد کلاسه‌بندی برای ۳۰ قسمت زمانی به روش KSVD.

قطعه زمانی	بُعد اول	بُعد دوم	بُعد سوم	بُعد چهارم
۲ ۱	۴۲.۴۲ ۶۲.۱۱	۳۷.۴۲ ۶۳.۴۴	۴۱.۴۱ ۳۸.۹۸	۵۴.۰۶ ۶۶.۴۸
۴ ۳	۳۷.۲۷ ۶۰.۷۰	۳۸.۸۳ ۳۹.۵۳	۶۴.۸۴ ۳۴.۴۵	۳۸.۲۰ ۵۲.۸۱
۶ ۵	۵۳.۱۳ ۶۰.۷۰	۳۶.۴۱ ۴۲.۷۳	۴۸.۳۶ ۳۳.۹۸	۵۷.۱۹ ۶۰.۰۸
۸ ۷	۵۲.۲۷ ۳۹.۲۲	۶۱.۸۰ ۳۷.۱۹	۶۴.۰۶ ۳۸.۵۲	۶۵.۱۶ ۳۴.۶۱
۱۰ ۹	۳۸.۶۷ ۶۱.۳۳	۴۷.۱۹ ۶۲.۰۳	۳۴.۳۰ ۶۶.۱۷	۳۶.۰۹ ۶۶.۳۳
۱۲ ۱۱	۳۷.۶۶ ۴۰.۹۴	۴۲.۱۹ ۵۶.۳۳	۳۴.۳۸ ۳۹.۰۶	۶۳.۴۴ ۳۳.۴۴
۱۴ ۱۳	۶۳.۵۹ ۳۸.۸۳	۶۳.۵۹ ۳۷.۰۳	۶۶.۶۴ ۶۴.۲۲	۶۷.۰۳ ۳۳.۲۰
۱۶ ۱۵	۴۸.۲۰ ۴۹.۱۴	۶۳.۲۰ ۴۴.۶۹	۳۴.۰۶ ۳۳.۷۵	۳۴.۹۲ ۳۷.۱۱
۱۸ ۱۷	۶۲.۷۳ ۵۳.۰۵	۶۲.۹۷ ۵۶.۰۹	۴۱.۶۴ ۳۷.۵۸	۳۵.۵۵ ۳۶.۲۵
۲۰ ۱۹	۶۳.۲۸ ۶۰.۷۰	۵۰.۴۷ ۶۰.۵۵	۵۲.۵۰ ۶۲.۸۹	۶۸.۹۱ ۶۲.۶۶
۲۲ ۲۱	۴۶.۲۵ ۶۱.۷۲	۴۰.۵۵ ۵۷.۸۱	۶۴.۲۲ ۳۸.۶۷	۶۶.۱۷ ۶۷.۸۹
۲۴ ۲۳	۵۳.۳۶ ۴۷.۸۱	۳۶.۸۰ ۳۹.۵۳	۵۱.۴۱ ۶۱.۴۱	۳۷.۰۳ ۵۹.۵۳
۲۶ ۲۵	۴۰.۰۸ ۵۷.۴۲	۳۶.۸۰ ۳۸.۳۶	۵۳.۵۲ ۳۴.۶۱	۳۷.۵۰ ۳۳.۹۸
۲۸ ۲۷	۴۲.۶۶ ۴۹.۳۰	۳۷.۰۳ ۴۱.۱۷	۶۲.۰۳ ۴۸.۴۴	۳۹.۲۲ ۳۱.۷۲
۳۰ ۲۹	۳۹.۴۵ ۳۷.۳۴	۳۸.۳۶ ۳۹.۱۴	۶۲.۴۲ ۶۳.۷۵	۳۴.۸۴ ۳۷.۱۹

در برخی از این قطعه‌های زمانی نرخ قابل قبولی به دست آمده است. از میان ۳۰ قطعه دوثانیه‌ای قطعه چهاردهم نرخ قابل قبولی در هر ۴ بُعد دارد. در جدول (۴-۱۸) بهترین درصد کلاسه‌بندی و شماره قطعه مربوط به آن در هر بُعد آمده است.

جدول ۴-۱۸ بیشترین نرخ به دست آمده در بین ۳۰ نرخ مربوط به ۳۰ قطعه زمانی.

بُعد	قسمت	درصد کلاسه بندی
اول	۱۴	٪۶۳.۵۹
دوم	۱۴	٪۶۳.۵۹
سوم	۱۴	٪۶۶.۶۴
چهارم	۲۰	٪۶۸.۹

همان طور که در جدول بالا نشان داده شده است دو ثانیه چهاردهم نرخ بازشناسی قابل قبولی در همه ابعاد داشته است. میانگین ۳۰ نرخ به دست آمده در هر بُعد در جدول (۴-۱۹) آمده است. با توجه به این جدول مشاهده می شود که نرخ متوسط در هیچ یک از ابعاد مقدار مطلوبی نداشته است.

جدول ۴-۱۹ متوسط ۳۰ نرخ به دست آمده از روش KSVD.

بُعد	متوسط ۳۰ نرخ
اول	٪۵۰.۰۴
دوم	٪۴۶.۹۷
سوم	٪۴۸.۲۸
چهارم	٪۴۹.۰۷

۴-۳- کلاسه‌بندی بر اساس موسیقی

تابه‌حال کلاسه‌بندی بر اساس افراد شرکت‌کننده در آزمایش انجام شد. به این معنا که ویژگی‌های استخراج‌شده از سیگنال مغزی ۳۱ نفر را به‌عنوان مجموعه آموزش و ویژگی‌های مربوط به فرد باقی‌مانده را به‌عنوان مجموعه آزمودنی در نظر گرفتیم. ایده دیگری که مورد بررسی قرار دادیم این بود که آموزش و آزمون را بر اساس موسیقی انجام دهیم. به این صورت که ویژگی‌های مربوط به سیگنال‌های EEG ایجادشده توسط ۳۹ قطعه موسیقی را به‌عنوان مجموعه آموزش و ویژگی‌های مربوط به سیگنال‌های مغزی تحریک‌شده توسط یک موسیقی را به‌عنوان مجموعه آزمودنی در نظر گرفتیم و این فرآیند را ۴۰ بار برای هر ۴۰ قطعه موسیقی تکرار کردیم و ۴۰ نرخ کلاسه‌بندی به دست آوردیم که درنهایت بین آن‌ها متوسط گرفتیم.

۴-۳-۱- اعمال روش DTCWPT

ابتدا برای هر دوره آزمایش ۲۲ ویژگی در نظر گرفته و کلاسه‌بندی را انجام دادیم. نتایج کلاسه‌بندی در جدول (۴-۲۰) آمده‌اند. قطعه‌هایی که درصد کلاسه‌بندی بالاتر از ۶۰ درصد داشتند در جدول (۴-۲۱) آمده‌اند.

جدول ۴-۲۰ نرخ کلاسه‌بندی بر اساس موسیقی با استفاده از ۲۲ ویژگی استخراج‌شده از روش DTCWPT

بُعد	در صد کلاسه‌بندی با ۲۲ ویژگی
اول	٪۶۴.۶۹
دوم	٪۶۴.۲۲
سوم	٪۶۹.۹۲
چهارم	٪۷۰.۷۰

جدول ۴-۲۱ نرخ کلاسه‌بندی و شماره قطعه‌هایی که نرخ بالاتر از ۶۰٪ دارند. (روش DTCWPT)

بُعد اول		بُعد دوم		بُعد سوم		بُعد چهارم	
قطعه	نرخ	قطعه	نرخ	قطعه	نرخ	قطعه	نرخ
۱	۸۴.۳۷٪	۱	۶۸.۷۵٪	۱	۸۱.۲۵٪	۱	۹۰.۶۲٪
۲	۷۸.۱۲٪	۲	۷۸.۱۲٪	۲	۸۷.۵۰٪	۲	۹۰.۶۲٪
۳	۹۶.۸۷٪	۳	۷۵.۰۰٪	۳	۸۷.۵۰٪	۳	۹۰.۶۲٪
۴	۸۴.۳۷٪	۴	۶۸.۷۵٪	۴	۸۴.۳۷٪	۴	۸۴.۳۷٪
۵	۶۲.۵۰٪	۵	۶۸.۷۵٪	۵	۹۳.۷۵٪	۵	۸۱.۲۵٪
۶	۸۷.۵۰٪	۶	۷۱.۸۷٪	۶	۸۷.۵۰٪	۶	۸۴.۳۷٪
۷	۸۷.۵۰٪	۷	۷۱.۸۷٪	۷	۸۱.۲۵٪	۷	۸۷.۵۰٪
۸	۹۳.۷۵٪	۸	۷۵.۰۰٪	۸	۸۴.۳۷٪	۸	۹۰.۶۲٪
۹	۸۷.۵۰٪	۹	۶۸.۷۵٪	۹	۸۴.۳۷٪	۹	۹۰.۶۲٪
۱۱	۸۷.۵۰٪	۱۰	۷۵.۰۰٪	۱۰	۷۸.۱۲٪	۱۰	۶۵.۶۲٪
۱۲	۸۴.۳۷٪	۱۱	۷۱.۸۷٪	۱۱	۷۱.۸۷٪	۱۱	۹۰.۶۲٪
۱۳	۷۸.۱۲٪	۱۴	۶۲.۵۰٪	۱۲	۶۸.۷۵٪	۱۲	۷۵.۰۰٪
۱۴	۹۳.۷۵٪	۱۹	۷۵.۰۰٪	۱۳	۷۱.۸۷٪	۱۳	۹۳.۷۵٪
۱۵	۸۷.۵۰٪	۲۰	۶۵.۶۲٪	۱۴	۸۱.۲۵٪	۱۴	۹۳.۷۵٪
۱۷	۸۴.۳۷٪	۲۴	۶۸.۷۵٪	۱۵	۷۱.۸۷٪	۱۵	۷۵.۰۰٪
۱۸	۸۱.۲۵٪	۳۰	۷۸.۱۲٪	۱۶	۶۲.۵۰٪	۱۶	۶۵.۶۲٪
۱۹	۹۳.۷۵٪	۳۱	۷۵.۰۰٪	۱۷	۶۸.۷۵٪	۱۷	۷۸.۱۲٪
۲۰	۸۷.۵۰٪	۳۲	۷۸.۱۲٪	۱۸	۷۸.۱۲٪	۱۸	۹۳.۷۵٪
۲۶	۶۵.۶۲٪	۳۳	۶۲.۵۰٪	۱۹	۸۷.۵۰٪	۱۹	۹۳.۷۵٪
۲۷	۷۸.۱۲٪	۳۴	۶۵.۶۲٪	۲۰	۷۸.۱۲٪	۲۰	۷۸.۱۲٪
۴۰	۶۲.۵۰٪	۳۵	۷۵.۰۰٪	۲۱	۷۱.۸۷٪	۲۲	۷۱.۸۷٪
		۳۶	۸۱.۲۵٪	۲۶	۶۸.۷۵٪	۲۳	۷۱.۸۷٪
		۳۷	۷۵.۰۰٪	۲۷	۷۱.۸۷٪	۲۴	۷۸.۱۲٪
		۳۸	۷۸.۱۲٪	۳۲	۷۱.۸۷٪	۲۵	۷۸.۱۲٪
		۳۹	۶۸.۷۵٪	۳۳	۷۱.۸۷٪	۲۶	۷۸.۱۲٪
		۴۰	۶۵.۶۲٪	۳۴	۷۸.۱۲٪	۲۷	۷۱.۸۷٪
				۳۵	۷۱.۸۷٪	۲۸	۸۴.۳۷٪
				۳۶	۶۲.۵۰٪	۲۹	۶۸.۷۵٪
				۴۰	۷۸.۱۲٪	۳۰	۸۴.۳۷٪
						۳۱	۶۲.۵۰٪

از میان ۴۰ قطعه موسیقی ۱۲ قطعه (۱ تا ۹، ۱۱، ۱۹ و ۲۰) به‌طور مشترک در همه ابعاد نرخ بالاتر از ۶۰٪ و حتی ۷۰٪ داشته‌اند.

بعد از به دست آوردن نتایج با ۲۲ ویژگی، تعداد ویژگی‌ها را از در بازه‌ای تغییر دادیم و هر بار نرخ کلاسه‌بندی را محاسبه کردیم تا نرخ مطلوب به دست آید. نتایج به‌دست‌آمده و درصد‌های گزارش‌شده در مقاله مرجع در جدول (۴-۲۲) آمده‌اند.

جدول ۴-۲۲ بهترین تعداد ویژگی‌ها و نرخ به‌دست‌آمده با استفاده از آن‌ها

بُعد	تعداد ویژگی‌ها	درصد کلاسه‌بندی
اول	۱۳	۶۶.۰۱٪
دوم	۵۷	۶۶.۱۷٪
سوم	۲۰	۷۰٪
چهارم	۱۵	۷۱.۰۹٪

این تعداد ویژگی‌ها با تعدادی که در کلاسه‌بندی بر اساس افراد شرکت‌کننده به دست آوردیم برابر نیستند. با توجه به جدول نتایج به‌دست‌آمده در این حالت بالاتر از حالت کلاسه‌بندی بر اساس افراد شرکت‌کننده است.

۴-۳-۲ اعمال روش CSP

کلاسه‌بندی بر اساس موسیقی را برای روش CSP نیز در نظر گرفتیم. نتیجه به‌دست‌آمده از این روش در جدول (۴-۲۳) آمده است.

جدول ۴-۲۳ نرخ کلاسه‌بندی و شماره قطعه‌هایی که نرخ بالاتر از ۶۰٪ دارند. (روش CSP)

بُعد اول		بُعد دوم		بُعد سوم		بُعد چهارم	
قطعه	نرخ	قطعه	نرخ	قطعه	نرخ	قطعه	نرخ
۱	%۹۳.۷۵	۱	%۷۱.۸۸	۱	%۷۵	۱	%۸۷.۵
۲	%۸۴.۳۸	۲	%۷۵	۲	%۸۱.۲۵	۲	%۸۷.۵
۳	%۹۶.۸۸	۳	%۶۸.۷۵	۳	%۸۷.۵	۳	%۹۶.۸۸
۴	%۹۳.۷۵	۴	%۷۱.۸۸	۴	%۸۷.۵	۴	%۸۱.۲۵
۵	%۷۸.۱۳	۵	%۶۸.۷۵	۵	%۸۴.۳۸	۵	%۸۴.۳۸
۶	%۹۳.۷۵	۶	%۷۵	۶	%۸۴.۳۸	۶	%۸۱.۲۵
۷	%۸۴.۳۸	۷	%۶۸.۷۵	۷	%۸۴.۳۸	۷	%۸۱.۲۵
۸	%۸۷.۵	۸	%۶۸.۷۵	۸	%۸۴.۳۸	۸	%۹۳.۷۵
۹	%۸۷.۵	۹	%۶۵.۶۳	۹	%۸۴.۳۸	۹	%۹۳.۷۵
۱۱	%۹۳.۷۵	۱۰	%۶۸.۷۵	۱۰	%۶۸.۷۵	۱۱	%۹۳.۷۵
۱۲	%۹۰.۶۳	۱۱	%۶۸.۷۵	۱۱	%۸۴.۳۸	۱۲	%۸۱.۲۵
۱۳	%۷۸.۱۳	۱۹	%۷۵	۱۲	%۶۵.۶۳	۱۳	%۸۷.۵
۱۴	%۸۴.۳۸	۲۰	%۶۵.۶۳	۱۳	%۶۸.۷۵	۱۴	%۱۰۰
۱۵	%۸۴.۳۸	۲۴	%۶۲.۵	۱۴	%۷۸.۱۳	۱۵	%۷۱.۸۸
۱۷	%۸۷.۵	۳۱	%۶۸.۷۵	۱۵	%۷۱.۸۸	۱۶	%۶۸.۷۵
۱۸	%۹۳.۷۵	۳۲	%۷۵	۱۷	%۶۵.۶۳	۱۷	%۷۸.۱۳
۱۹	%۹۰.۶۳	۳۴	%۶۸.۷۵	۱۸	%۸۱.۲۵	۱۸	%۹۶.۸۸
۲۰	%۸۴.۳۸	۳۵	%۷۱.۸۸	۱۹	%۸۱.۲۵	۱۹	%۹۳.۷۵
۲۶	%۷۱.۸۸	۳۶	%۷۸.۱۳	۲۰	%۷۱.۸۸	۲۰	%۷۸.۱۳
۲۷	%۸۴.۳۸	۳۷	%۸۱.۲۵	۲۳	%۶۲.۵	۲۲	%۷۱.۸۸
۴۰	%۶۲.۵	۳۸	%۷۵	۳۴	%۶۲.۵	۲۳	%۶۲.۵
		۳۹	%۷۵	۳۶	%۶۸.۷۵	۲۴	%۸۷.۵
		۴۰	%۶۲.۵	۴۰	%۶۸.۷۵	۲۵	%۷۵
						۲۶	%۷۵
						۲۷	%۷۵
						۲۸	%۸۷.۵
						۲۹	%۷۱.۸۸
						۳۰	%۸۷.۵
						۳۱	%۶۲.۵

همان‌طور که در جدول (۴-۲۳) مشاهده می‌شود در هر دو روش CSP و DTCWPT قطعه‌های ۱ تا ۹، ۱۱، ۱۹ و ۲۰ در هر ۴ بُعد مشترک بوده و دارای نرخ کلاس‌بندی بیشتر از ۷۱٪ هستند. اگر متوسط نرخ‌های بالاتر از ۶۰٪ را به دست آوریم در هر یک از روش‌ها به نرخ بالایی در هر بُعد می‌رسیم این نرخ‌ها با عنوان نرخ جدید در جدول‌های (۴-۲۴) و (۴-۲۵) گزارش شده‌اند.

جدول ۴-۲۴ متوسط نرخ کل قطعه‌ها و متوسط نرخ قطعه‌های با نرخ بالاتر از ۶۰٪ (روش DTCWPT)

نرخ جدید	تعداد موسیقی‌ها	نرخ متوسط	بُعد
٪۸۳.۱۸	۲۱	٪۶۴.۶۹	اول
٪۷۱.۸۷	۲۶	٪۶۴.۲۲	دوم
٪۷۷.۱۵	۲۹	٪۶۹.۹۲	سوم
٪۸۱.۴۵	۳۰	٪۷۰.۷۰	چهارم

جدول ۴-۲۵ متوسط نرخ کل قطعه‌ها و متوسط نرخ قطعه‌های با نرخ بالاتر از ۶۰٪ (روش CSP)

نرخ جدید	تعداد موسیقی‌ها	نرخ متوسط	بُعد
۸۶.۰۱٪	۲۱	٪۶۱.۴۸	اول
٪۷۰.۹۲	۲۳	٪۶۰.۳۱	دوم
٪۷۵.۸۲	۲۳	٪۶۳.۹۱	سوم
٪۸۲.۵۴	۲۹	٪۶۹.۴۵	چهارم

نرخ متوسط ۱۲ قطعه موسیقی در این حالت پاسخ مناسبی نیست چراکه با آموزش دادن کل ۴۰ قطعه کلاس‌بندی انجام‌شده و سپس بین نرخ ۱۲ قطعه منتخب میانگین گرفته‌ایم. حالت صحیح این است که آموزش نیز فقط توسط همین ۱۲ قطعه انجام شود.

۴-۳-۳- کلاس‌بندی برای ۱۲ قطعه منتخب

واضح است که برچسب‌های داده‌شده توسط شرکت‌کنندگان به ۱۲ قطعه موسیقی با شماره‌های ۱ تا ۹، ۱۱، ۱۹ و ۲۰ با قطعیت بیشتری بوده و بنابراین به نرخ کلاس‌بندی بالاتری در هر دو روش و در همه ابعاد نیز منجر شده است. برای اطمینان از درستی این موضوع مجدداً آموزش و آزمون

ویژگی‌های CSP و DTCWPT را برای این ۱۲ قطعه موسیقی انجام دادیم و سیگنال‌های EEG مربوط به ۲۸ قطعه دیگر را نادیده گرفتیم. در این حالت نرخ کلاسه‌بندی هر دو روش در هر ۴ بعد احساسی نرخ‌های قابل قبولی به دست آمدند. (جدول ۴-۲۶).

جدول ۴-۲۶ متوسط نرخ ۱۲ قطعه منتخب در دو روش CSP و DTCWPT

بُعد	DTCWPT	CSP
اول	٪۹۲.۹۶	٪۹۲.۹۷
دوم	٪۷۸.۶۴	٪۷۳.۹۵
سوم	٪۸۵.۶۷	٪۸۴.۳۷
چهارم	٪۸۸.۵۴	٪۸۶.۴۵

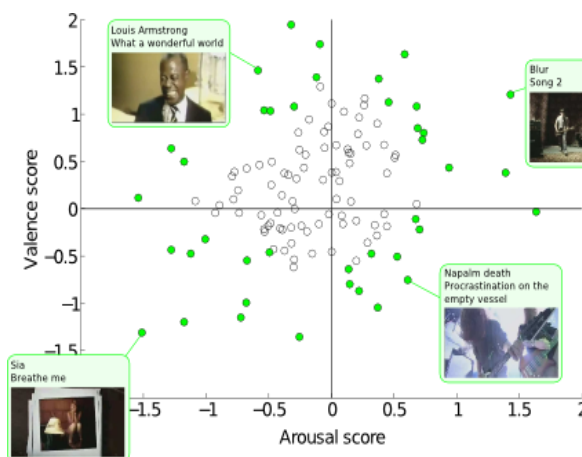
می‌توان نتیجه گرفت برچسب‌های داده‌شده توسط شرکت‌کنندگان به ۲۸ قطعه دیگر چندان قابل اطمینان نبوده‌اند. یکی از دلایل این موضوع می‌تواند محتوای پیچیده ویدئو موسیقی‌ها باشد و به احتمال زیاد در ۱۲ قطعه اشاره‌شده محتوای ویدئو موسیقی در هر بُعد احساسی در حد خوبی برای همه شرکت‌کنندگان قابل تشخیص بوده است.

۴-۴- پایگاه داده DEAP

پایگاه داده مورد استفاده در این مطالعه شامل سیگنال‌های EEG ثبت شده از ۳۲ شرکت‌کننده است. محدوده سنی این سوژه‌ها بین ۱۹ تا ۳۷ سال است. ۵۰ درصد شرکت‌کنندگان در آزمایش را خانم‌ها تشکیل می‌دهند. سیگنال‌های EEG هر فرد در زمان تماشای ۴۰ قطعه ویدئو موسیقی با استفاده از ۳۲ الکتروود ضبط شده است. طول هر ویدئو یک دقیقه است و بین آزمایش‌ها ۳ ثانیه فاصله وجود دارد تا حالت احساسی سوژه‌ها بازنشانی شود. تعداد نمونه‌های گرفته شده از هر سیگنال EEG در این پایگاه داده برابر ۸۰۶۴ نمونه است. در کنار ۳۲ الکتروود EEG، ۸ الکتروود دیگر برای ثبت سیگنال‌های فیزیولوژیکی مانند EMG، EOG، فشارخون (BVP) و دمای پوست استفاده شده است. ویدئوهای چهره نیز از ۲۲ سوژه گرفته شده‌اند.

بنابراین پایگاه داده به صورت ۳۲ ماتریس با ابعاد $40 \times 40 \times 8064$ نمایش داده می‌شود. هر یک از شرکت‌کنندگان بعد از تماشای ویدئوها ۴ امتیاز به هر ویدئو موسیقی نسبت می‌دهند. این امتیازات مربوط به ۴ بعد احساسی می‌باشند. مقدار امتیازات بین ۱ تا ۹ متغیر است. اولین عدد مربوط به بعد خوشایندی (Valence) است و میزان مثبت و یا منفی بودن احساس فرد را مشخص می‌کند، عدد دوم به بعد برانگیختگی (Arousal) مربوط می‌شود و میزان تحریک احساس را بیان می‌کند، سومین عدد میزان غالب بودن یک احساس خاص در محتوای یک ویدئو را بیان می‌کند (Dominance) و آخرین عدد میزان موردعلاقه واقع شدن قطع را نشان می‌دهد (Like).

در شکل (۴-۹) نمونه‌ای از نحوه انتخاب قطعه‌های ویدئو موسیقی نشان داده شده است. ویدئوهای انتخاب شده برای استفاده در آزمایش بارنگ سبز نشان داده شده‌اند. در هر ربع، ویدئویی که مقادیر بالاتری دارد با جزئیات بیشتری نمایش داده شده و نام موسیقی و قسمتی از ویدئو نشان داده شده است.



شکل ۴-۹ قطعه‌های ویدئویی بر اساس برچسب‌های داده شده توسط شرکت‌کنندگان در آزمایش با دو بعد ظرفیت و انگیختگی نمایش داده شده‌اند [۳۶].

با توجه به نتایج گزارش شده در این فصل، جمع‌بندی و نتیجه‌گیری کلی در فصل بعد ارائه می‌شود.

فصل ۵

نتیجه‌گیری و پیشنهادها

در حوزه شناسایی احساس بر مبنای سیگنال EEG مهم‌ترین چالش پیش رو، بحث استخراج ویژگی‌ها از این سیگنال است. تاکنون روش‌های مختلفی برای استخراج ویژگی از سیگنال EEG ارائه شده‌اند که غالباً مبتنی بر تحلیل فوریه و مشتقات طیفی سیگنال هستند. در روش‌های تحلیل طیف بر اساس تبدیل فوریه دقت زمانی و فرکانسی در تضاد هستند. از این رو در مورد این سیگنال بهتر است از ویژگی‌های زمان فرکانسی استفاده شود.

پایگاه‌های داده مختلفی برای شناسایی احساس بر مبنای سیگنال EEG معرفی شده‌اند که ما از میان آن‌ها پایگاه داده DEAP را برای اعمال روش‌های استخراج ویژگی انتخاب کردیم.

یکی از روش‌هایی که برای استخراج ویژگی از این پایگاه داده استفاده شده است تحلیل موجک خاصی به نام DTCWPT است. با استفاده از مقاله‌ای که اعمال این روش بر پایگاه داده DEAP را توضیح داده بود، ما نیز این روش را بر همان پایگاه داده اعمال کردیم تا نتایج خود را با نتایج گزارش شده در این مقاله مقایسه کرده و به دنبال روش‌های دیگری برای بهبود نتایج باشیم.

با توجه به مقالاتی که در حوزه تصور حرکتی ارائه شده‌اند مشاهده کردیم که روش CSP یکی از روش‌هایی است که در این حوزه نتایج قابل قبولی داشته است ولی در حوزه تشخیص احساس مقاله‌ای که به طور مستقیم از این روش به عنوان روش استخراج ویژگی استفاده کرده باشد مشاهده نکردیم؛ بنابراین تصمیم گرفتیم که این روش را بر پایگاه داده DEAP اعمال کنیم. بعد از به دست آوردن نتایج کلاسه‌بندی از روش CSP، به دنبال الگوریتم جدیدی برای بهبود نتایج بودیم. به این منظور الگوریتم KNMF که بر روی ویژگی‌های زمان فرکانسی اعمال شده بود را بر ویژگی‌های استخراج شده از روش DTCWPT اعمال کردیم و به این صورت مجموعه ویژگی‌های جدیدی تولید شد که در کلاسه‌بندی از این ویژگی‌های جدید استفاده کردیم. در این روش از حلقه‌های تکرار استفاده می‌شود که تا همگرایی مطلوب این حلقه‌ها تکرار می‌شوند.

معیار توقف و تعداد حلقه‌های تکرار و همچنین ابعاد ویژگی‌های جدید که همگی قابل تعیین و تغییرند، در سرعت استخراج ویژگی‌ها و در نتیجه در سرعت کلاسه‌بندی تأثیر بسزایی دارند. در یکی از حالت‌هایی که در اعمال این الگوریتم فرض کردیم به نتایج قابل قبولی رسیدیم.

به‌عنوان آخرین تلاش برای بهتر کردن نتایج از الگوریتم KSVD استفاده کردیم. این الگوریتم یک روش استخراج ویژگی نیست بلکه در این روش سیگنال‌های EEG مربوط به هر کلاس احساسی به‌طور مستقیم آموزش داده می‌شوند و یک دیکشنری برای هر کلاس ساخته می‌شود؛ بنابراین حجم محاسباتی این روش نسبت به روش‌های قبل بیشتر بوده و سرعت پردازش اطلاعات و آموزش داده‌ها بسیار پایین است چراکه در پیاده‌سازی این الگوریتم از تمام ۷۶۸۰ نمونه هر سیگنال مغزی برای آموزش و آزمون استفاده می‌شود. به همین دلیل هر سیگنال را به ۳۰ قسمت زمانی تقسیم کرده و در هر بخش زمانی جداگانه آموزش و آزمون را تکرار کردیم. در هر یک از روش‌های ذکر شده دو حالت کلاسه‌بندی را در نظر گرفتیم. در حالت اول کلاسه‌بندی را بر اساس افراد شرکت‌کننده در آزمایش انجام شده و در حالت دوم کلاسه‌بندی بر اساس موسیقی‌های پخش شده انجام دادیم.

در بخش‌های آینده این فصل به ارائه نتایج به‌دست‌آمده از روش‌های ذکر شده و مقایسه نتایج و تحلیل آن‌ها می‌پردازیم.

۵-۲- بررسی نتایج به دست آمده

اولین روشی که در مطالعه خود به عنوان روش استخراج ویژگی استفاده کردیم تبدیل DTCWPT است. ابتدا بدون کاهش ابعاد ویژگی‌ها و با ۵۵۲ ویژگی نرخ کلاسه‌بندی را به دست آوردیم. در مرحله بعد با استفاده از الگوریتم‌های انتخاب ویژگی تعداد ویژگی‌ها را کاهش دادیم و نرخ کلاسه‌بندی را محاسبه کردیم. برای به دست آوردن بهترین تعداد ویژگی‌ها، این تعداد را در بازه ۱ تا ۲۰۰ ویژگی تغییر دادیم و نرخ کلاسه‌بندی را به دست آوردیم. در هر یک از ابعاد تعداد ویژگی‌های متفاوتی به بهترین نرخ بازشناسی می‌انجامد. نتایج به دست آمده برای تعداد ویژگی‌های مختلف در جدول (۵-۱) و جدول (۵-۲) نشان داده شده‌اند.

جدول ۵-۱ مقایسه نتیجه کلاسه‌بندی با تعداد ویژگی‌های مختلف در روش DTCWPT.

بُعد	۵۵۲ ویژگی	۲۲ ویژگی	با بهترین تعداد ویژگی‌ها
اول	٪۶۳.۱۲	٪۶۳.۱۲	٪۶۳.۵۲
دوم	٪۶۳.۲۸	٪۶۱.۸۷	٪۶۴.۳
سوم	٪۶۶.۷۲	٪۶۴.۶۹	٪۶۶.۸۸، ٪۶۷.۴۲
چهارم	٪۶۹.۵۳	٪۶۹.۵۳	٪۶۹.۷۷

جدول ۵-۲ تغییر نرخ در استفاده از بهترین تعداد ویژگی‌ها نسبت به ۲۲ ویژگی و ۵۵۲ ویژگی.

افزایش نرخ نسبت به کلاسه‌بندی با:			
بُعد	تعداد ویژگی‌ها	۲۲ ویژگی	۵۵۲ ویژگی
اول	۸	٪۰.۴	٪۰.۴
دوم	۳۹	٪۲.۴۳	٪۱.۰۲
سوم	۱، ۶۲	٪۲.۷۳، ٪۲.۱۹	٪۰.۷، ٪۰.۱۶
چهارم	۱۲	٪۰.۲۴	٪۰.۲۴

مرحله بعد مربوط به حذف ویژگی‌های ۱۴ جفت الکتروود متقارن است. با حذف این بخش از ویژگی‌ها و در نظر گرفتن ۲۲ ویژگی برای هر دوره آزمایش نرخ‌های بازشناسی برای هر بُعد را به دست آوردیم. همان‌طور که قبلاً گفته شد استفاده از ویژگی‌های مربوط به جفت الکتروودهای متقارن برای نشان دادن عدم تقارن نیمکره‌های مغز است و با توجه به نتایج مطالعه‌های گذشته میزان خوشایندی یک واقعه بر فعالیت قسمت‌های راست و چپ بخش پیشین مغز اثر می‌گذارد. با توجه به این دو مورد انتظار داشتیم که حذف ویژگی‌های مربوط به جفت الکتروودهای متقارن باعث کاهش درصد کلاسه‌بندی در بُعد اول که مربوط به خوشایندی یک واقعه است شود اما نرخ به‌دست‌آمده برای بُعد اول همچنان ۶۳.۱۲٪ است و نسبت به حالت قبل تغییری نمی‌کند. برای بُعد دوم درصد کلاسه‌بندی ۰.۰۷٪ کاهش می‌یابد. این میزان کاهش نرخ چندان قابل‌توجه نیست اما احتمالاً ویژگی‌های مربوط به جفت الکتروودها دارای اطلاعاتی در مورد میزان برانگیختگی احساس بوده‌اند که نبود آن‌ها باعث کاهش نرخ بازشناسی شده است. در بُعد سوم درصد کلاسه‌بندی با حذف ویژگی‌های مربوط به جفت الکتروودهای متقارن از ۶۴.۶۹٪ به ۶۶.۶۴٪ می‌رسد که ۱.۹۵٪ افزایش یافته است. این بُعد مربوط به میزان تسلط و غلبه احساس است. در بُعد چهارم درصد کلاسه‌بندی از ۶۹.۵۳٪ به ۶۹.۴۵٪ رسیده و ۰.۰۸٪ کاهش یافته است (جدول ۳-۵).

جدول ۳-۵ تغییر نرخ با حذف ۱۴ جفت الکتروود متقارن.

بُعد	با ۱۴ جفت الکتروود	بدون ۱۴ جفت الکتروود	تغییر نرخ بازشناسی
اول	۶۳.۱۲٪	۶۳.۱۲٪	بدون تغییر
دوم	۶۱.۸۷٪	۶۱.۸۰٪	۰.۰۷٪ کاهش
سوم	۶۴.۶۹٪	۶۶.۶۴٪	۱.۹۵٪ افزایش
چهارم	۶۹.۵۳٪	۶۹.۴۵٪	۰.۰۸٪ کاهش

با اعمال روش CSP بر داده‌ها نرخ کلاسه‌بندی در بُعد اول و دوم نسبت به روش DTCWPT با ۲۲ ویژگی تغییری نکرده است و همان ۶۳.۱۲٪ و ۶۹.۵۳٪ باقی‌مانده است. در بُعد دوم ۶۳.۵۱٪

به دست آمده که نسبت به روش قبل که درصد کلاسه بندی ۶۱.۸۷٪ بود افزایش یافته است. در بُعد سوم نیز با نرخ ۶۶.۷۲٪ نسبت به ۶۴.۶۹٪، نرخ کلاسه بندی بهبود یافته است جدول (۴-۵) و (۵-۵).

جدول ۴-۵ مقایسه نرخ های به دست آمده از روش CSP و DTCWPT.

بُعد	CSP	DTCWPT با ۲۲ ویژگی	با بهترین تعداد ویژگی ها
اول	۶۳.۱۲٪	۶۳.۱۲٪	۶۳.۵۲٪
دوم	۶۳.۵۱٪	۶۱.۸۷٪	۶۴.۳٪
سوم	۶۶.۷۲٪	۶۴.۶۹٪	۶۶.۸۸٪، ۶۷.۴۲٪
چهارم	۶۹.۵۳٪	۶۹.۵۳٪	۶۹.۷۷٪

جدول ۵-۵ تغییر نرخ ها در روش CSP نسبت به روش DTCWPT.

بُعد	نسبت به ۲۲ ویژگی	نسبت به بهترین تعداد
اول	بدون تغییر	۰.۴٪ کاهش
دوم	۱.۶۴٪ افزایش	۰.۷۹٪ کاهش
سوم	۲.۰۳٪ افزایش	۰.۱۶٪ و ۰.۷٪ کاهش
چهارم	بدون تغییر	۰.۲۴٪ کاهش

در روش DTCWPT به دلیل زیاد بودن تعداد ویژگی ها وجود یک مرحله انتخاب ویژگی ضروری بود. در حالی که در روش CSP تعداد ویژگی های هر دوره آزمایش چهار عدد بود و نیازی به مرحله کاهش و یا انتخاب ویژگی نداشتیم؛ بنابراین هزینه محاسباتی تحلیل CSP در مقایسه با تبدیل DTCWPT کمتر است. ضمن اینکه نرخ بازشناسی در این تحلیل از نرخ که توسط روش DTCWPT با ۲۲ ویژگی به دست آوردیم در بُعد دوم و سوم تا حدودی بهتر بوده و در بُعد اول و چهارم مشابه اند.

با نرمال سازی ویژگی های CSP بهترین حالت برای بُعد اول ۶۳.۴۴٪، برای بُعد دوم ۶۳.۷۵٪، برای بُعد سوم ۶۶.۷۲٪ و برای بُعد چهارم ۶۹.۵۳٪ به دست آمده است.

جدول ۵-۶ مقایسه نرخ کلاسه‌بندی ویژگی‌های CSP در حالت نرمال شده با حالت بدون نرمال‌سازی ویژگی‌ها.

بُعد	بدون نرمال‌سازی ویژگی‌ها	با نرمال‌سازی ویژگی‌ها
اول	٪۶۳.۱۲	٪۶۳.۴۴
دوم	٪۶۳.۵۱	٪۶۳.۷۵
سوم	٪۶۶.۷۲	٪۶۶.۷۲
چهارم	٪۶۹.۵۳	٪۶۹.۵۳

بنابراین با نرمال‌سازی ویژگی‌ها نرخ بازشناسی در بُعد سوم و چهارم تغییری نمی‌کند ولی در بُعد اول و دوم به ترتیب ۰.۳۲٪ و ۰.۲۴٪ افزایش می‌یابد.

در حالت دیگری به‌جای اعمال روش CSP بر کل سیگنال EEG و استخراج ویژگی از آن، هر سیگنال EEG ۶۰ ثانیه‌ای را به ۶۰ قسمت تقسیم کرده و تحلیل را جداگانه بر هر قسمت اعمال کردیم. در این صورت می‌توانیم بخش‌هایی از سیگنال را که حاوی اطلاعات احساسی بیشتری هستند شناسایی کنیم. نتایج نشان دادند که در بُعد اول ثانیه ۱۲ بهترین نرخ کلاسه‌بندی را دارد، در بُعد دوم ثانیه ۵۱، در بُعد سوم ثانیه ۲۷ و در بُعد چهارم نرخ بازشناسی تقریباً در کل سیگنال ثابت است. با توجه به نرخ‌های به‌دست‌آمده در هر ثانیه برای هر ۴ بُعد و مقایسه آن‌ها با نرخ‌ها که از تحلیل کل سیگنال بدون تقطیع زمانی به دست آوردیم مشاهده می‌کنیم که این ۶۰ نرخ به نرخ کلی بسیار نزدیک‌اند؛ بنابراین به‌جای داشتن کل ۶۰ ثانیه اگر ۱ ثانیه از سیگنال‌های ثبت‌شده را در اختیار داشته باشیم بازهم می‌توانیم کلاسه‌بندی را با همان کیفیت قبلی انجام دهیم.

برای بررسی ایده دیگری در کلاسه‌بندی این بار کلاسه‌بندی را بر اساس موسیقی انجام دادیم و برای هر قطعه موسیقی به‌طور جداگانه سیستم را آموزش دادیم در این صورت ۴۰ دوره آموزش و آزمون در هر یک از ۴ بُعد احساسی داریم. با به دست آوردن نتایج کلاسه‌بندی و مقایسه آن با نتایج به‌دست‌آمده در حالت قبلی مشاهده می‌کنیم که با کلاسه‌بندی ۲۲ ویژگی استخراج‌شده از روش

DTCWPT نرخ کلاسه‌بندی نسبت به حالت مشابه قبل در همه ابعاد افزایش یافته است. جدول (۵-۷) (۷).

جدول ۷-۵ تغییر نرخ کلاسه‌بندی ویژگی‌های استخراج‌شده از روش DTCWPT در کلاسه‌بندی بر اساس موسیقی نسبت به کلاسه‌بندی بر اساس افراد شرکت‌کننده. این کلاسه‌بندی‌ها با ۲۲ ویژگی انجام شده‌اند.

تغییر نرخ	بُعد
۱.۵۶٪ افزایش	اول
۲.۳۵٪ افزایش	دوم
۵.۲۳٪ افزایش	سوم
۱.۱۷٪ افزایش	چهارم

چنانچه بهترین تعداد ویژگی‌ها را در نظر بگیریم مشاهده می‌کنیم که اگر کلاسه‌بندی بر اساس قطعه‌های موسیقی انجام شود نرخ کلاسه‌بندی نسبت به حالت مشابه آن در کلاسه‌بندی بر اساس افراد، بالاتر است. این موضوع با توجه به جدول (۵-۸) کاملاً واضح است. تعداد ویژگی‌هایی که بهترین نرخ را در هر حالت ایجاد می‌کنند متفاوت است. جدول (۵-۹).

جدول ۸-۵ تغییر نرخ کلاسه‌بندی ویژگی‌های استخراج‌شده از روش DTCWPT در کلاسه‌بندی بر اساس موسیقی نسبت به کلاسه‌بندی بر اساس افراد شرکت‌کننده. این کلاسه‌بندی‌ها برای هر دو حالت کلاسه‌بندی با بهترین تعداد ویژگی در هر بُعد انجام شده‌اند.

تغییر نرخ	بُعد
۲.۴۹٪ افزایش	اول
۱.۸۷٪ افزایش	دوم
۲.۵۸٪ افزایش	سوم
۱.۳۲٪ افزایش	چهارم

جدول ۹-۵ مقایسه بهترین تعداد ویژگی‌های استخراج‌شده از روش DTCWPT در دو حالت کلاسه‌بندی بر اساس ۱. افراد شرکت‌کننده، ۲. قطعه‌های موسیقی.

بُعد	بهترین تعداد ویژگی‌ها در حالت اول	بهترین تعداد ویژگی‌ها در حالت دوم
اول	۸ ویژگی	۱۳ ویژگی
دوم	۳۹ ویژگی	۵۷ ویژگی
سوم	۶۲ ویژگی ، ۱۰ ویژگی	۲۰ ویژگی
چهارم	۱۲ ویژگی	۱۵ ویژگی

مقایسه نتایج به‌دست‌آمده از کلاسه‌بندی ویژگی‌های استخراج‌شده از روش CSP بر اساس قطعه‌های موسیقی با نتایج کلاسه‌بندی این ویژگی‌ها بر اساس افراد شرکت‌کننده در جدول (۵-۱۰) آمده است. نتایج نشان می‌دهند که در بُعد اول ۱.۶۴٪، در بُعد دوم ۳.۲٪، در بُعد سوم ۲.۸۱٪ و در بُعد چهارم ۰.۰۸٪ کاهش نرخ داشته‌ایم.

جدول ۱۰-۵ تغییر نرخ کلاسه‌بندی ویژگی‌های استخراج‌شده از روش CSP در کلاسه‌بندی بر اساس موسیقی نسبت به کلاسه‌بندی بر اساس افراد شرکت‌کننده.

بُعد	تغییر نرخ
اول	۱.۶۴٪ کاهش
دوم	۳.۲٪ کاهش
سوم	۲.۸۱٪ کاهش
چهارم	۰.۰۸٪ کاهش

با مقایسه نتایج به‌دست‌آمده در دو حالت فرض شده مشاهده می‌کنیم که چنانچه کلاسه‌بندی را بر اساس موسیقی انجام دهیم نتایج روش DTCWPT تا حد زیادی بهبود می‌یابند ولی برای کلاسه‌بندی ویژگی‌های روش CSP بهتر است کلاسه‌بندی بر اساس افراد شرکت‌کننده انجام شود. اگر فقط قطعه‌های موسیقی را که نرخ بالاتر از ۶۰ درصد دارند در نظر بگیریم به نرخ‌های قابل قبولی می‌رسیم. در تحلیل CSP مطابق جدول (۵-۱۱) برای بُعد اول ۲۱ قطعه از ۴۰ قطعه دارای نرخ بالاتر

از ۶۰ درصد هستند و متوسط نرخ کلاسه‌بندی این ۲۱ قطعه ۸۶.۰۱٪ است. برای بُعد دوم ۲۳ قطعه با نرخ متوسط ۷۰.۹۲٪، برای بُعد سوم ۲۳ قطعه با نرخ متوسط ۷۵.۸۲٪ و برای بُعد چهارم ۲۹ قطعه با نرخ متوسط ۸۲.۵۴٪ به دست می‌آید. در اعمال روش DTCWPT نیز کلاسه‌بندی برای برخی از قطعات موسیقی دارای نرخ بالاتر از ۶۰٪ است. متوسط این نرخ‌ها در جدول (۵-۱۲) نشان داده شده است.

جدول ۵-۱۱ تعداد قطعه‌هایی که در روش CSP نرخ بالاتر از ۶۰٪ داشتند و متوسط نرخ این قطعه‌های موسیقی.

بُعد	تعداد قطعه‌ها	نرخ متوسط
اول	۲۱	۸۶.۰۱٪
دوم	۲۳	۷۰.۹۲٪
سوم	۲۳	۷۵.۸۲٪
چهارم	۲۹	۸۲.۵۴٪

جدول ۵-۱۲ تعداد قطعه‌هایی که در روش DTCWPT نرخ بالاتر از ۶۰٪ داشتند و متوسط نرخ این قطعه‌های موسیقی.

بُعد	تعداد قطعه‌ها	نرخ متوسط
اول	۲۱	۸۳.۱۸٪
دوم	۲۶	۷۱.۸۷٪
سوم	۲۹	۷۷.۱۵٪
چهارم	۳۰	۸۱.۴۵٪

نرخ جدیدی که در این جدول‌ها آمده است، متوسط نرخ‌های مربوط به تعدادی از قطعات است که درصد کلاسه‌بندی بالاتر از ۶۰٪ داشته‌اند، درحالی‌که آموزش با کل قطعات انجام شده است. به همین منظور قطعه‌هایی که در هر ۴ بُعد، درصد کلاسه‌بندی بالاتر از ۶۰ درصد دارند را جداگانه برای آموزش و آزمون استفاده کردیم. در بین ۴۰ قطعه موسیقی بعد از اعمال هر دو روش DTCWPT و

CSP قطعه‌های شماره ۱ تا ۹، ۱۱، ۱۹ و ۲۰ به‌طور مشترک در هر ۴ بُعد نرخ بالاتر از ۶۰٪ و حتی ۷۰٪ داشتند؛ بنابراین این ۱۲ قطعه را به‌عنوان مجموعه جدید آموزش دادیم و مجموعه آزمون را نیز از بین همین ۱۲ قطعه انتخاب کردیم و بعد از کلاسه‌بندی ویژگی‌ها به نرخ‌های قابل قبولی رسیدیم. نتیجه روش CSP در بعد اول تقریباً برابر با نتیجه روش DTCWPT بود ولی در سه بُعد دیگر کمی پایین‌تر بود.

جدول ۵-۱۳ مقایسه نرخ کلاسه‌بندی در دو روش CSP و DTCWPT با استفاده از سیگنال‌های EEG مربوط به ۱۲ قطعه از ۴۰ قطعه موسیقی.

بُعد	روش DTCWPT	روش CSP
اول	٪۹۲.۹۶	٪۹۲.۹۷
دوم	٪۷۸.۶۴	٪۷۳.۹۵
سوم	٪۸۵.۶۷	٪۸۴.۳۷
چهارم	٪۸۸.۵۴	٪۸۶.۴۵

می‌توان نتیجه گرفت برچسب‌های داده‌شده توسط شرکت‌کنندگان به ۲۸ قطعه دیگر، چندان قابل‌اطمینان نبوده‌اند. یکی از دلایل این موضوع می‌تواند محتوای پیچیده ویدئو موسیقی‌ها باشد و به‌احتمال زیاد در ۱۲ قطعه اشاره‌شده محتوای ویدئو موسیقی در هر بُعد احساسی در حد خوبی برای همه شرکت‌کنندگان قابل تشخیص بوده است.

بنابراین برای اینکه سیستم احساس یک فرد را تشخیص دهد باید احساس فرد یک احساس قابل تشخیص و واضح باشد. مشخص است که چنانچه احساس فرد پیچیده بوده و خود فرد نیز نتواند دقیقاً احساس خود را بیان کند سیستم نیز در شناسایی آن موفق نخواهد بود. احتمالاً این ۲۸ ویدئوی حذف‌شده احساسات پیچیده و با ابعاد بالاتری را در فرد ایجاد کرده‌اند که خود فرد نیز قادر نبوده برچسب قطعی و مشخصی به احساس خود بدهد.

با مقایسه بهترین نتایج به دست آمده از روش DTCWPT و CSP و مقایسه آن با نتایج گزارش شده در مقاله مرجع مشاهده می‌کنیم که نرخ به دست آمده از روش CSP در هر ۴ بُعد از نتایج تحلیل موجک کمی پایین‌ترند ولی نکته‌ای که باید در نظر گرفته شود این موضوع است که در روش CSP به دلیل مرتب بودن تعداد ویژگی‌ها بر اساس میزان اهمیت دیگر نیازی به مرحله انتخاب ویژگی نداشتیم و این نتایج تنها با ۴ ویژگی در هر مرحله آزمایش به دست آمده‌اند. در حالی که تعداد ویژگی‌ها در روش DTCWPT به مراتب بالاتر است. بهترین نتایج برای روش DTCWPT در کلاسه‌بندی بر اساس قطعات موسیقی و برای روش CSP در کلاسه‌بندی بر اساس افراد شرکت‌کننده در آزمون به دست آمد.

جدول ۵-۱۴ مقایسه نتایج به دست آمده از هر دو روش CSP و DTCWPT با نرخ‌های گزارش شده در مقاله. نرخ کلاسه‌بندی برای روش CSP بر اساس افراد شرکت‌کننده و برای تبدیل DTCWPT بر اساس قطعه‌های موسیقی به دست آمده است.

درصد گزارش شده در مقاله	CSP	DTCWPT
٪۶۵.۳	٪۶۳.۴۴	٪۶۶.۰۱
٪۶۶.۹	٪۶۳.۷۵	٪۶۶.۱۷
٪۶۹.۱	٪۶۶.۷۲	٪۷۰
٪۷۱.۲	٪۶۹.۵۳	٪۷۱.۰۹

با توجه به جدول (۵-۱۴) مشاهده می‌کنیم که نرخ‌های که ما از اعمال دوباره روش DTCWPT بر داده‌ها به دست آوردیم، در بُعد اول و سوم کمی از نرخ گزارش شده در مقاله برای این دو بُعد بالاتر بوده ولی در دو بُعد دوم و چهارم نرخ به دست آمده کمی پایین‌تر از نرخ گزارش شده در مقاله است. در ادغام ویژگی‌های به دست آمده از روش CSP و DTCWPT در حالت کلاسه‌بندی بر اساس افراد شرکت‌کننده، چنانچه ۲۲ ویژگی از تحلیل موجک را در نظر بگیریم نرخ بازشناسی در بُعد اول نسبت به هر یک از روش‌ها از ٪۶۳.۱۲ به ٪۶۳.۴۳ افزایش یافته و در بُعد دوم و سوم نسبت به روش موجک افزایش نرخ و نسبت به روش CSP کاهش نرخ داشتیم و در بُعد سوم هیچ تغییری مشاهده نشد. چنانچه تعداد ویژگی‌های موجک را به ۵۰ ویژگی افزایش دهیم در نرخ بازشناسی بُعد اول و چهارم

تغییری ایجاد نمی‌شود. در بُعد دوم نسبت به هر دو روش افزایش نرخ، در بُعد سوم نسبت به روش موجک افزایش و نسبت به روش CSP کاهش نرخ داریم. اگر ویژگی‌های ادغام‌شده را با استفاده از روش نرمال‌سازی سوم، نرمال کنیم و نرخ کلاسه‌بندی را برای هر دو حالت ذکرشده به دست آوریم، مشاهده می‌کنیم که تعداد ویژگی‌های روش DTCWPT اهمیتی ندارد و حاصل ادغام ۲۲ ویژگی موجک با ویژگی‌های CSP بعد از نرمال شدن با حاصل ادغام ۵۰ ویژگی با ویژگی‌های CSP مشابه است و نرخ‌های مشابهی در همه ابعاد نتیجه می‌دهند. در جدول (۵-۱۵) مقایسه‌ای بین نرخ‌های به‌دست‌آمده از نرمال‌سازی حاصل ادغام ویژگی‌های DTCWPT و CSP و نرخ به‌دست‌آمده از تک‌تک روش‌ها انجام شده است.

جدول ۵-۱۵ تغییر نرخ‌ها در نتیجه ادغام ویژگی‌های استخراج‌شده از دو روش CSP و DTCWPT نسبت به هر یک از این دو روش. این ویژگی‌ها بعد از ادغام نرمال شده‌اند.

بُعد	نسبت به روش CSP	نسبت به روش DTCWPT
اول	بدون تغییر	بدون تغییر
دوم	۰.۲۴٪ افزایش	۱.۸۸٪ افزایش
سوم	بدون تغییر	۲.۰۳٪ افزایش
چهارم	بدون تغییر	بدون تغییر

کلاسه‌بندی ویژگی‌های مربوط به نمایش فرکانسی-زمانی حاصل از اعمال روش DTCWPT بر سیگنال EEG نیز در یک حالت خاص نتایج قابل قبولی داشت و آن‌هم در حالتی بود که بیشینه نرخ به‌دست‌آمده در ۱۶ قطعه زمانی را به‌عنوان نرخ کلاسه‌بندی برای هر یک از ۳۲ نفر در نظر گرفتیم. این کلاسه‌بندی را بر اساس افراد شرکت‌کننده انجام دادیم.

جدول ۵-۱۶ مقایسه نرخ کلاسه‌بندی ویژگی‌های حاصل از روش DTCWPT در حالت عادی نسبت به حالت تقطیع هر یک از زیرباندها و تشکیل ماتریس فرکانسی زمانی.

بُعد	نرخ کلاسه‌بندی با ویژگی‌های فرکانسی زمانی حاصل از روش DTCWPT	نرخ به‌دست‌آمده از روش DTCWPT
اول	٪۶۶.۷۹	٪۶۳.۱۲
دوم	٪۶۹.۶۹	٪۶۱.۸۷
سوم	٪۶۸.۷۵	٪۶۴.۶۹
چهارم	٪۶۹.۹۲	٪۶۹.۵۳

با توجه به جدول (۵-۱۶) مشاهده می‌کنیم که در هر یک از ۴ بُعد نرخ به‌دست‌آمده نسبت به حالت قبل بهبود یافته است.

با بررسی نتایج اعمال الگوریتم KNMF نیز می‌توان گفت بهترین نتایج به‌دست‌آمده با استفاده از روش KNMF مربوط به حالتی بود که بیشینه نرخ به‌دست‌آمده برای ۱۶ قسمت هر زیرباند فرکانسی را انتخاب کردیم. با توجه به نتایج به‌دست‌آمده می‌توان گفت این نرخ با افزایش ابعاد ویژگی‌ها یعنی افزایش مقدار K تقریباً به‌طور یکنوا افزایش می‌یابد؛ اما سرعت کلاسه‌بندی به‌شدت کاهش می‌یابد. چنانچه متوسط ۱۶ نرخ به‌دست‌آمده را در نظر بگیریم با تغییر K تغییرات یکنوایی در نرخ کلاسه‌بندی مشاهده نمی‌شود. واضح است که با در نظر گرفتن متوسط ۱۶ نرخ، نرخ کلاسه‌بندی نسبت به حالتی که بیشینه ۱۶ نرخ به‌دست‌آمده برای قطعه‌های ۳۰ نمونه‌ای را در نظر می‌گرفتیم پایین‌تر است و در مقایسه با دو روش قبل در حالتی که کلاسه‌بندی بر اساس افراد انجام شد، در بُعد اول نسبت به هر دو روش قبل ۱.۳۳٪ کاهش نرخ، در بُعد دوم نسبت به روش CSP، ۴.۲۵٪ کاهش و نسبت به روش DTCWPT، ۲.۶۱٪ کاهش نرخ داشته‌ایم. در دو بُعد دیگر نیز به همین ترتیب کاهش نرخ داشته‌ایم که در جدول (۵-۱۷) تغییرات نرخ کلاسه‌بندی گزارش شده‌اند.

جدول ۵-۱۷ تغییر نرخ کلاسه‌بندی در روش KNMF ($K=2$) نسبت به دو روش CSP و DTCWPT. در اینجا متوسط نرخ ۱۶ بخش زمانی به‌عنوان نرخ کلاسه‌بندی هر فرد استفاده شده است.

بُعد	تغییر نرخ نسبت به نتایج روش CSP	تغییر نرخ نسبت به نتایج روش DTCWPT
اول	کاهش ۱.۳۳٪	کاهش ۱.۳۳٪
دوم	کاهش ۴.۲۵٪	کاهش ۲.۶۱٪
سوم	کاهش ۳.۸۱٪	کاهش ۱.۷۸٪
چهارم	کاهش ۳.۷۲٪	کاهش ۳.۷۲٪

با مقایسه نرخ به‌دست‌آمده در دو بعد اول (با فرض $k=2$) با مقدار به‌دست‌آمده از دو روش قبل مشاهده می‌کنیم که در حالت اول نرخ به‌دست‌آمده برای بُعد اول نسبت به هر دو روش ۱.۳۳٪ افزایش یافته و در بُعد دوم نسبت به روش CSP و DTCWPT به ترتیب ۰.۳۱٪ کاهش و ۱.۳۳٪ افزایش یافته است. در حالت دوم نرخ کلاسه‌بندی در هر دو بُعد پایین‌تر از دو روش قبل است. در بُعد اول نسبت به هر دو روش ۱.۳۳٪ کاهش نرخ و در بعد دوم به ترتیب ۴.۲۵٪ و ۲.۶۱٪ کاهش نرخ داشته‌ایم.

جدول ۵-۱۸ مقایسه نرخ‌های به‌دست‌آمده از روش KNMF در دو حالت مختلف با روش‌های قبل. حالت اول. با در نظر گرفتن بیشینه ۱۶ نرخ به‌عنوان درصد کلاسه‌بندی برای هر فرد و حالت دوم. با در نظر گرفتن متوسط ۱۶ نرخ به‌عنوان درصد کلاسه‌بندی برای هر فرد.

بُعد	حالت اول	حالت دوم	CSP	DTCWPT
اول	۶۴.۴۵٪	۶۱.۷۹٪	۶۳.۱۲٪	۶۳.۱۲٪
دوم	۶۳.۲۰٪	۵۹.۲۶٪	۶۳.۵۱٪	۶۱.۸۷٪

جدول ۵-۱۹ تغییر نرخ‌های به‌دست‌آمده از روش KNMF در دو حالت مختلف نسبت به روش‌های قبل. حالت اول. با در نظر گرفتن بیشینه ۱۶ نرخ به‌عنوان درصد کلاسه‌بندی برای هر فرد و حالت دوم. با در نظر گرفتن متوسط ۱۶ نرخ به‌عنوان درصد کلاسه‌بندی برای هر فرد.

بُعد	حالت اول نسبت به:		حالت دوم نسبت به:	
	CSP	DTCWPT	CSP	DTCWPT
اول	٪۱.۳۳ افزایش	٪۱.۳۳	٪۱.۳۳ کاهش	٪۱.۳۳ کاهش
دوم	٪۰.۳۳ کاهش	٪۱.۳۳ افزایش	٪۴.۲۵ کاهش	٪۲.۶۱ کاهش

با مقایسه درصد‌های کلاسه‌بندی بعد از اعمال KNMF و قبل آن به این نتیجه می‌رسیم که با اعمال KNMF و کاهش ابعاد ویژگی‌ها نرخ کلاسه‌بندی کاهش می‌یابد؛ اما در حالتی که بیشینه ۱۶ نرخ را در نظر بگیریم با افزایش ابعاد ویژگی‌ها از ۲ تا ۷۰۰ نرخ کلاسه‌بندی به نحوی که قبل از اعمال KNMF داشتیم نزدیک می‌شود.

در حالتی دیگر بین برچسب داده‌شده به هر سیگنال آزمون توسط روش‌های DTCWPT، CSP و KNMF رأی‌گیری کردیم و برچسب نهایی را با توجه به رأی اکثریت، به سیگنال موردنظر نسبت دادیم و نرخ درستی برچسب‌های داده‌شده در هر بُعد را محاسبه کردیم.

جدول ۵-۲۰ تغییر نرخ کلاسه‌بندی بعد از رأی‌گیری بین سه روش نسبت به هر یک از روش‌ها.

بُعد	نسبت به CSP	نسبت به DTCWPT	نسبت به KNMF
اول	بدون تغییر	بدون تغییر	٪۱.۳۳ افزایش
دوم	٪۰.۱۵ کاهش	٪۱.۴۹ افزایش	٪۴.۰۱ افزایش
سوم	٪۰.۲۳ افزایش	٪۲.۲۶ افزایش	٪۴.۰۴ افزایش
چهارم	بدون تغییر	بدون تغییر	٪۳.۷۲ افزایش

با استفاده از الگوریتم KSVD نتایج نسبت به حالت‌های قبل بهبودی نیافت و نرخ‌های به‌دست‌آمده تا حد قابل توجهی پایین‌تر از روش‌های قبل بودند.

۵-۳- نتیجه‌گیری

به‌عنوان نتیجه‌گیری می‌توان گفت روش CSP که در حوزه زمان بر سیگنال EEG اعمال شده است در مقایسه با روش‌های دیگری که در این تحقیق مورد بررسی قرار دادیم با تعداد ویژگی‌های بسیار کمی نتیجه قابل قبولی دارد. سرعت پردازش داده‌ها نیز در این روش نسبت به الگوریتم‌های KNMF و KSVD بسیار بالاتر بوده و از این لحاظ عملکرد بهتری دارد. با توجه به نتایج به‌دست آمده در دو روش CSP و DTCWPT برای حالتی که کلاسه‌بندی را بر اساس موسیقی‌های پخش شده انجام دادیم می‌توان گفت از ۴۰ قطعه موسیقی که برای شرکت‌کنندگان پخش شده بود تعدادی از آن‌ها (به‌عنوان مثال ۱۲ عدد از آن‌ها) دارای محتوای احساسی کاملاً مشخصی بوده‌اند، به‌طوری که اکثر شرکت‌کنندگان این محتوا را به‌طور صحیح تشخیص داده و راجع به محتوای احساسی این قطعه‌ها با یکدیگر موافق بوده‌اند.

در مطالعه‌های گذشته به این نکته اشاره شده بود که با قرار دادن احساس در چند بُعد بسیاری از اطلاعات مربوط به آن از دست می‌روند. در این حالت فرضیه‌ای پیش می‌آید و آن اینکه احتمالاً قطعه‌هایی که نرخ بازشناسی پایینی داشتند نسبت به قطعه‌های با نرخ بالا احساس فرد را به‌گونه‌ای پیچیده‌تر تحریک کرده‌اند، به‌طوری که افراد قادر به بیان احساس خود در دو یا چند بُعد محدود نبوده‌اند؛ بنابراین هر یک، به‌گونه‌ای احساس خود را در این ابعاد بیان کرده و برچسب‌های متفاوتی به این قطعه‌های موسیقی داده‌اند و در نتیجه نرخ بازشناسی در این قطعه‌ها پایین آمده است. در حالت واقعی نیز بسیاری از احساس‌های انسان پیچیده‌تر از آن است که بتوان آن را در دو یا چند بُعد محدود بیان کرد.

به‌عنوان عامل دیگری برای خطای بازشناسی می‌توان به آستانه‌ای که برای برچسب‌ها جهت قرار دادن سیگنال در دو کلاس High و Low استفاده کردیم، اشاره نمود. برچسب‌هایی که شرکت‌کنندگان به قطعه‌های ویدئو موسیقی نسبت داده بودند در محدوده ۱ تا ۹ قرار دارد و ما آستانه

را ۴.۵ در نظر گرفته‌ایم. در این حالت چنانچه برجسبی برابر با ۴.۶ باشد به کلاس High تعلق می‌گیرد و اگر ۴.۴ باشد متعلق به کلاس Low است؛ بنابراین خطای زیادی ایجاد می‌شود.

۴-۵- پیشنهادها

با توجه به بالا بودن نرخ بازشناسی در برخی از قطعه‌های ویدئو-موسیقی می‌توان گفت استفاده از قطعه‌های ویدئو-موسیقی با محتوای احساسی مشخص احتمالاً نرخ کلاسه‌بندی را افزایش خواهد داد؛ بنابراین پیشنهاد می‌شود ابتدا محتوای احساسی محرک‌ها بررسی شده، سپس از این محرک‌ها در تحریک احساس استفاده شود چراکه با توجه به نتایج به‌دست‌آمده تشخیص محتوای برخی قطعه‌ها توسط شرکت‌کنندگان ساده نبوده و بنابراین در برجسب‌های داده‌شده توسط آن‌ها اتفاق نظر قابل قبولی به وجود نیامده است.

پیشنهاد دوم مربوط به بررسی اثر آستانه در نظر گرفته‌شده برای برجسب‌ها جهت مشخص نمودن کلاس‌های احساسی است. احتمالاً با حذف سیگنال‌های مربوط به برجسب‌های متعلق به محدوده نزدیک به ۴.۵ بتوان نرخ بازشناسی را بهبود بخشید.

مراجع

- [1] S. H. Yoo, D. Matsumoto, and J. A. LeRoux, "The influence of emotion recognition and emotion regulation on intercultural adjustment," *International Journal of Intercultural Relations*, vol. 30, pp. 345-363, 2006.
- [2] C. Frantzidis, C. Bratsas, M. Klados, E. Konstantinidis, C. D. Lithari, A. B. Vivas, *et al.*, "On the classification of emotional biosignals evoked while viewing affective pictures: an integrated data-mining-based approach for healthcare applications," *Information Technology in Biomedicine, IEEE Transactions on*, vol. 14, pp. 309-318, 2010.
- [3] G. Chanel, C. Rebetez, M. Bétrancourt, and T. Pun, "Emotion assessment from physiological signals for adaptation of game difficulty," *Systems, Man and Cybernetics, Part A: Systems and Humans, IEEE Transactions on*, vol. 41, pp. 1052-1063, 2011.
- [4] X. Huahu, Y. Jian, and G. Jue, "Application of speech emotion recognition in intelligent household robot," in *Artificial Intelligence and Computational Intelligence (AICI), 2010 International Conference on*, 2010, pp. 537-541.
- [5] A. Matsumoto, Y. Ichikawa, N. Kanayama, H. Ohira, and T. Iidaka, "Gamma band activity and its synchronization reflect the dysfunctional emotional processing in alexithymic persons," *Psychophysiology*, vol. 43, pp. 533-540, 2006.
- [6] یوسفی پور ف و فیروزآبادی م و اصغری ابراهیم آباد م، (۱۳۹۴) "بازشناسی الگوی احساسی در افراد الکسی تایمیک با استفاده از سیگنال EEG" کنفرانس مهندسی برق ایران، تهران.
- [7] یوسفی پور ف و فیروزآبادی م، (۱۳۹۳) "بررسی اسپکتوگرام سیگنال مغزی در فرآیند بازشناسی احساس با استفاده از نرم افزار EEGLAB" کنفرانس ملی مهندسی برق و الکترونیک ایران، گناباد.
- [8] M. Naji, M. Firoozabadi, and P. Azadfallah, "Classification of Music-Induced Emotions Based on Information Fusion of Forehead Biosignals and Electrocardiogram," *Cognitive Computation*, vol. 6, pp. 241-252, 2014.
- [9] R. H. Rad, M. Firoozabadi, and I. M. Rezazadeh, "Discriminating affective states in music induction environment using forehead bioelectric signals," in *Biomedical Engineering (MECBME), 2011 1st Middle East Conference on*, 2011, pp. 343-346.
- [10] G. Rizzolatti and L. Craighero, "The mirror-neuron system," *Annu. Rev. Neurosci.*, vol. 27, pp. 169-192, 2004.
- [11] Q. Zhang and M. Lee, "Emotion development system by interacting with human EEG and natural scene understanding," *Cognitive Systems Research*, vol. 14, pp. 37-49, 2012.
- [12] S. K. Hadjidimitriou and L. J. Hadjileontiadis, "Toward an EEG-based recognition of music liking using time-frequency analysis," *Biomedical Engineering, IEEE Transactions on*, vol. 59, pp. 3498-3510, 2012.
- [13] S. K. Hadjidimitriou and L. J. Hadjileontiadis, "EEG-based classification of music appraisal responses using time-frequency analysis and familiarity ratings," *Affective Computing, IEEE Transactions on*, vol. 4, pp. 161-172, 2013.

- [14] P. C. Petrantonakis and L. J. Hadjileontiadis, "Adaptive emotional information retrieval from EEG signals in the time-frequency domain," *Signal Processing, IEEE Transactions on*, vol. 60, pp. 2604-2616, 2012.
- [15] Y.-P. Lin, C.-H. Wang, T.-P. Jung, T.-L. Wu, S.-K. Jeng, J.-R. Duann, *et al.*, "EEG-based emotion recognition in music listening," *Biomedical Engineering, IEEE Transactions on*, vol. 57, pp. 1798-1806, 2010.
- [16] Y.-P. Lin, C.-H. Wang, T.-L. Wu, S.-K. Jeng, and J.-H. Chen, "EEG-based emotion recognition in music listening: A comparison of schemes for multiclass support vector machine," in *Acoustics, Speech and Signal Processing, 2009. ICASSP 2009. IEEE International Conference on*, 2009, pp. 489-492.
- [17] K. C. Tseng, B.-S. Lin, C.-M. Han, and P.-S. Wang, "Emotion recognition of EEG underlying favourite music by support vector machine," in *Orange Technologies (ICOT), 2013 International Conference on*, 2013, pp. 155-158.
- [18] D. Nie, X.-W. Wang, L.-C. Shi, and B.-L. Lu, "EEG-based emotion recognition during watching movies," in *Neural Engineering (NER), 2011 5th International IEEE/EMBS Conference on*, 2011, pp. 667-670.
- [19] S. Y. Chung and H. J. Yoon, "Affective classification using Bayesian classifier and supervised learning," in *Control, Automation and Systems (ICCAS), 2012 12th International Conference on*, 2012, pp. 1768-1771.
- [20] S. Hoseingholizade, M. R. H. Golpaygani, and A. S. Monfared, "Studying emotion through nonlinear processing of EEG," *Procedia-Social and Behavioral Sciences*, vol. 32, pp. 163-169, 2012.
- [21] P. C. Petrantonakis and L. J. Hadjileontiadis, "A novel emotion elicitation index using frontal brain asymmetry for enhanced EEG-based emotion recognition," *Information Technology in Biomedicine, IEEE Transactions on*, vol. 15, pp. 737-746, 2011.
- [22] P. C. Petrantonakis and L. J. Hadjileontiadis, "Emotion recognition from EEG using higher order crossings," *Information Technology in Biomedicine, IEEE Transactions on*, vol. 14, pp. 186-197, 2010.
- [23] M. Murugappan, M. Rizon, R. Nagarajan, S. Yaacob, I. Zunaidi, and D. Hazry, "Lifting scheme for human emotion recognition using EEG," in *Information Technology, 2008. ITSIM 2008. International Symposium on*, 2008, pp. 1-7.
- [24] C. Frantzidis, C. Bratsas, C. L. Papadelis, E. Konstantinidis, C. Pappas, and P. D. Bamidis, "Toward emotion aware computing: an integrated approach using multichannel neurophysiological recordings and affective visual stimuli," *Information Technology in Biomedicine, IEEE Transactions on*, vol. 14, pp. 589-597, 2010.
- [25] H. Ghaheri and A. Ahmadyfard, "Extracting common spatial patterns from EEG time segments for classifying motor imagery classes in a Brain Computer Interface (BCI)," *Scientia Iranica. Transaction D, Computer Science & Engineering, Electrical*, vol. 20, p. 2061, 2013.
- [26] C. Guger, H. Ramoser, and G. Pfurtscheller, "Real-time EEG analysis with subject-specific spatial patterns for a brain-computer interface (BCI)," *Rehabilitation Engineering, IEEE Transactions on*, vol. 8, pp. 447-456, 2000.
- [27] N. Robinson, A. P. Vinod, K. K. Ang, K. P. Tee, and C. T. Guan, "EEG-based classification of fast and slow hand movements using wavelet-CSP algorithm," *Biomedical Engineering, IEEE Transactions on*, vol. 60, pp. 2123-2132, 2013.

- [28] T. Ball, A. Schulze-Bonhage, A. Aertsen, and C. Mehring, "Differential representation of arm movement direction in relation to cortical anatomy and function," *Journal of neural engineering*, vol. 6, p. 016006, 2009.
- [29] L. Zhang, G. Liu, and Y. Wu, "Wavelet and common spatial pattern for EEG signal feature extraction and classification," in *Computer, Mechatronics, Control and Electronic Engineering (CMCE), 2010 International Conference on*, 2010, pp. 243-246.
- [30] M. Sakai, "Nonnegative Matrix Factorization Algorithms using a Constraint to Increase the Discriminability of Two Classes for EEG Feature Extraction," *International Journal of Computer Applications*, vol. 85, pp. 1-6, 2014.
- [31] I. Bayram and I. W. Selesnick, "On the Dual-Tree Complex Wavelet Packet and-Band Transforms," *Signal Processing, IEEE Transactions on*, vol. 56, pp. 2298-2310, 2008.
- [32] I. W. Selesnick, "Hilbert transform pairs of wavelet bases," *Signal Processing Letters, IEEE*, vol. 8, pp. 170-173, 2001.
- [33] Y. Wang, S. Gao, and X. Gao, "Common spatial pattern method for channel selection in motor imagery based brain-computer interface," in *Engineering in Medicine and Biology Society, 2005. IEEE-EMBS 2005. 27th Annual International Conference of the*, 2006, pp. 5392-5395.
- [34] H. Lee, A. Cichocki, and S. Choi, "Kernel nonnegative matrix factorization for spectral EEG feature extraction," *Neurocomputing*, vol. 72, pp. 3182-3190, 2009.
- [35] M. Aharon, M. Elad, and A. Bruckstein, "K-SVD: An Algorithm for Designing Overcomplete Dictionaries for Sparse Representation," *Signal Processing, IEEE Transactions on*, vol. 54, pp. 4311-4322, 2006.
- [36] S. Koelstra, C. Mühl, M. Soleymani, J.-S. Lee, A. Yazdani, T. Ebrahimi, *et al.*, "Deap: A database for emotion analysis; using physiological signals," *Affective Computing, IEEE Transactions on*, vol. 3, pp. 18-31, 2012.
- [37] M. Soleymani, J. Lichtenauer, T. Pun, and M. Pantic, "A multimodal database for affect recognition and implicit tagging," *Affective Computing, IEEE Transactions on*, vol. 3, pp. 42-55, 2012.
- [38] S. N. Daimi and G. Saha, "Classification of emotions induced by music videos and correlation with participants' rating," *Expert Systems with Applications*, vol. 41, pp. 6057-6065, 2014.
- [39] S. Chakroborty and G. Saha, "Feature selection using singular value decomposition and QR factorization with column pivoting for text-independent speaker identification," *Speech Communication*, vol. 52, pp. 693-709, 2010.

Abstract

Due to the effect of emotion on human life and the importance of its recognition, a lot of methods in time and frequency domain have been proposed for emotion classification. In this thesis we have used four different feature extraction methods and implemented them on DEAP dataset. This dataset has considered the emotion in four dimensions and used music-video excerpts for stimulation of the emotion.

The first feature extraction method is a kind of wavelet transform called DTCWPT which has been implemented on DEAP dataset in a former research. Again we did it to compare our results with those of the paper.

We classified the data by considering two different modes. First we performed the classification based on the participants, then we did it based on the music-video excerpts. The classification accuracy rates in the second mode were higher than the first one. In the first and third dimension the rates were slightly better than the reported ones in the paper but in the second and fourth dimension they were slightly less than the results of the paper. With the goal of improving the results we have left the frequency domain and focused on time domain features of EEG signal. For this purpose we have used CSP analysis as our feature extraction method and implemented it on the signals in two mentioned modes. This method has better results in the first mode, however its results are lower than the results of DTCWPT. In the next phase by combining the features of the two mentioned methods and by considering the first mode of the classification (based on the participants) the classification rate in the second and third dimension gets better in comparison with DTCWPT approach, and it improves in the second dimension compared with CSP analysis.

KNMF algorithm is the third method that we have used for feature extraction. This method is implemented on the time-frequency features extracted after the implementation of DTCWPT on EEG signals. By the use of KNMF a new group of features is produced. However this approach singly doesn't have better results than the previous methods but if we combine the results of this one with the results of the two former methods, the accuracy rates in the second and third dimension will improve.

In this study KSVD algorithm is applied too, however the classification rates are low.

Among the applied methods KNMF and KSVD algorithms are so slow but CSP analysis is less time consuming and also by the use of few features has acceptable results.

Keywords: Emotion recognition, EEG signal, DTCWPT transform, CSP analysis, KNMF algorithm, KSVD algorithm



Shahrood University of Technology
Faculty of Electrical Engineering and Robotics

Emotion recognition by studying effect of frequency and statistical features extracted from EEG

Roghaye Khodadadi Taghanaki

Supervisor:

Dr. Alireza Ahmadyfard

Advisor:

Dr.Saeede Ferdowsi

February, 2016