

بهبود دقت در تشخیص احساسات با استفاده از سیگنال‌های EEG با نوآوری در ترکیب استخراج ویژگی

هانیه زمانیان^{۱*}، حسن فرسی^۲

• پذیرش مقاله: ۹۷/۲/۲

• دریافت مقاله: ۹۶/۱۱/۱۴

مقدمه: از آنجا که احساسات نقش مهمی در زندگی روزمره انسان بازی می‌کند، ایجاد روشی هوشمند جهت بهبود قابلیت تشخیص احساسات از سیگنال الکتروانفسالوگرافی (EEG)، مبتنی بر تکنیک‌های پردازش سیگنال، ضروری به نظر می‌رسد. به علاوه، استفاده از طبقه‌بند ماشین بردار پشتیبان بهینه شده با الگوریتم تکاملی ژنتیک، از نوآوری‌های این پژوهش در بخش طبقه‌بندی می‌باشد.

روش: روش پیشنهادی با تمرکز بر روی استخراج و طبقه‌بندی ویژگی‌ها بر مبنای سیگنال‌های دریافتی از مغز سعی بر بهبود تشخیص احساسات دارد. در این راستا با شناسایی کانال‌های EEG که در استخراج ویژگی نقش دارند، از ویژگی‌های زمان-فرکانس سیگنال‌های EEG استفاده شده و این ویژگی‌ها توسط یک طبقه‌بند مناسب، طبقه‌بندی می‌شوند. الگوریتم پیشنهادی بر روی پایگاه داده DEAP که با ثبت سیگنال EEG از ۳۲ شرکت‌کننده در هنگام تماشای ۴۰ نوع ویدئو-موسیقی تهیه شده است، مورد آزمایش قرار گرفت.

نتایج: نتایج به دست آمده نشان می‌دهد که انتخاب ۷٫۵ ثانیه و ۳ کانال از داده‌های ورودی، نتایج قابل قبولی را ارائه می‌دهد. به علاوه باعث کاهش حجم محاسبات و حافظه مورد نیاز برای پردازش شده و به دقت ۹۳/۸۶٪ در طبقه‌بندی ۴ احساس دست یافته است.

نتیجه‌گیری: بهبود دقت در تشخیص احساسات مبتنی بر سیگنال EEG گام‌های متعددی دارد که استخراج ویژگی‌های کارآمد و طبقه‌بندی مؤثر آن‌ها دو گام مهم در این راستا می‌باشد. بر اساس نتایج این تحقیق، در نظر گرفتن ویژگی‌های حوزه‌های زمان و فرکانس سیگنال‌های EEG و به کارگیری الگوریتم SVM چند کلاسه که توسط الگوریتم تکاملی ژنتیکی بهینه‌سازی شده است، عملکرد بهتری را فراهم می‌کند.

کلید واژه‌ها: تشخیص احساسات، EEG، شبکه‌های عصبی، ماشین بردار پشتیبان

• **ارجاع:** زمانیان هانیه، فرسی حسن. بهبود دقت در تشخیص احساسات با استفاده از سیگنال‌های EEG با نوآوری در ترکیب استخراج ویژگی. مجله انفورماتیک سلامت و زیست پزشکی ۱۳۹۷، ۱(۵): ۴۴-۵۵.

۱. دانشجوی دکتری مهندسی برق مخابرات، گروه مخابرات، دانشکده برق و کامپیوتر، دانشگاه بیرجند، بیرجند، ایران

۲. استاد، دکترای مهندسی برق - مخابرات، دانشکده برق و کامپیوتر، دانشگاه بیرجند، بیرجند، ایران

* **نویسنده مسئول:** بیرجند، دانشگاه بیرجند، دانشکده برق و کامپیوتر، گروه مخابرات

• **Email:** hanieh.zamaniaan@birjand.ac.ir

• **شماره تماس:** ۰۹۱۵۶۲۲۸۲۷۸۰

مقدمه

مغز انسان یک کامپیوتر با فرآیندهای الکتروشیمیایی است که اطلاعات حسی را به اطلاعات الکتریکی (ولتاژ) تبدیل می‌کند. احساسات مجموعه‌ای از دستورالعمل‌های پیچیده هستند که منعکس‌کننده تغییرات در بدن انسان می‌باشند. انواع مختلفی از احساسات مانند خشم، افسردگی، ناامیدی، امید، نفرت، ترس، ناراحتی، تعجب، شادی و غیره شناسایی شده است که برای مدل سازی سیستم‌های تشخیص احساسات استفاده می‌شوند. در سال‌های اخیر، تحقیق در مورد شناخت عاطفی از EEG (Electroencephalography)، در زمینه‌های بین رشته‌ای روان‌شناسی به مهندسی توجه زیادی را به خود جلب کرده است. از جمله آن‌ها مطالعات پایه‌ای در مورد نظریه‌های هیجان و برنامه‌های کاربردی تعامل مغز-کامپیوتر (Application of Brain Computer) ABCI (Interference Brain Computer) [۱]، می‌باشد، که باعث افزایش توانایی سیستم‌های (Brain Computer) BCI (Interference)، با پردازش و پاسخ‌دهی به حالت‌های عاطفی کاربر با استفاده از سیگنال‌های فیزیولوژیکی شده است. تغییرات در احساسات تأثیر قابل توجهی بر سیگنال‌های مغز دارند. به همین دلیل، الکتروانسفالوگرافی (EEG)، سیگنال‌هایی که اطلاعات الکتریکی مغز را نشان می‌دهند، در سال‌های اخیر به شدت مورد توجه بوده است. دستگاه‌های ضبط EEG، بسته به برنامه، از ۳ تا ۲۵۶ الکتروود روی پوست سر استفاده می‌کنند تا ولتاژ را ضبط کنند. برای برنامه‌های بالینی معمولاً ۸ تا ۳۲ کانال EEG مورد نیاز است [۲].

برای بروز احساسات مختلف، می‌توان از موسیقی، متن، ویدئو و تصاویر جهت تحریک فرد استفاده کرد و سپس سیگنال‌ها را هنگام بروز احساسات مختلف ثبت نمود. سپس، سیگنال ثبت شده به عنوان پایگاه داده برای الگوریتم‌های شناختی مورد استفاده قرار می‌گیرند [۲].

تفاوت روش‌های تشخیصی، در ویژگی‌های استخراج شده و الگوریتم‌های مختلف طبقه‌بندی می‌باشد. در مورد سیگنال EEG، همچنین انتخاب تعداد و نوع کانال‌ها می‌تواند به عنوان یک پارامتر در نظر گرفته شود [۲].

ویژگی‌های زیادی می‌توان از سیگنال‌های EEG استخراج نمود. این ویژگی‌ها با اعمال تبدیلات مختلف بر روی سیگنال‌های EEG به دست می‌آیند. به عنوان مثال، یکی از این

تبدیلات، تبدیل فوریه است که اطلاعات فرکانسی سیگنال را استخراج می‌کند [۲].

طبقه‌بند، مرزهای تصمیم‌گیری را مطابق روش مطلوب به صورت غیرخطی تنظیم می‌کند. تاکنون روش‌های طبقه‌بندی مختلفی برای تشخیص احساسات سیگنال‌های EEG استفاده شده است. از جمله روش‌هایی مانند SVM، KNN و طبقه بندی‌های مبتنی بر شبکه عصبی [۲].

تاکنون مطالعات زیادی به منظور شناخت احساسات بر اساس سیگنال‌های مختلف انجام شده است. بسیاری از تحقیقات برای تشخیص احساسات با استفاده از بیان خارجی احساس مانند وضعیت صورت [۳] و گفتار [۴] صورت گرفته است. با این حال، حالت‌های احساسی در بسیاری از مواقع به صورت ظاهری بروز نکرده و درونی باقی می‌ماند و قابل تشخیص و نمود خارجی نیستند. مواردی که در آن فرد صحبتی نمی‌کند، اما در واقع عصبانی است و یا در حالت‌های هیجانی منفی لبخند می‌زند، بیان ظاهری احساسات می‌تواند به صورت ذهنی کنترل شود و در نتیجه نشانه‌های ظاهری برای شناخت احساسات ناکافی است [۲].

هر احساسی با یک الگوی خاص از فعالیت فیزیولوژیکی همراه است. بر خلاف بیان صوتی و تصویری از احساسات، استفاده از فعالیت‌های فیزیولوژیکی جهت تشخیص احساس هدفمندتر و ساده‌تر است. فعالیت فیزیولوژیکی را می‌توان از طریق سنسورهای غیر تهاجمی ضبط نمود. سیگنال‌های الکتریکی دریافتی توسط دستگاه‌های EEG ثبت و نمایش داده می‌شوند. بسیاری از مطالعات در زمینه ساخت مدل‌های محاسباتی برای تخمین وضعیت عاطفی از سیگنال EEG ارائه شده‌اند، که نشان‌دهنده کارایی این سیگنال‌ها برای شناسایی احساسات است. این پژوهش از تحریک احساسات با عکس‌ها، موسیقی و فیلم استفاده می‌کند. احساسات مورد بررسی در بسیاری از مطالعات، احساسات گسسته هستند. اکثر مطالعات دو مرحله داشتند، ابتدا استخراج ویژگی و سپس، انتخاب و استفاده از یک الگوریتم طبقه‌بندی. در ادامه، بر روی ویژگی‌های مختلف استخراج شده از سیگنال‌های EEG برای تشخیص احساسات تمرکز شد. برخی از این ویژگی‌ها از سیگنال‌های EEG در زمان استخراج می‌شوند در حالی که برخی دیگر از اطلاعات حوزه فرکانس به دست می‌آیند؛ بنابراین ویژگی‌ها را به سه بخش تقسیم شد: ویژگی‌های حوزه زمان، حوزه فرکانس و حوزه زمان - فرکانس [۵].

می‌توانند اطلاعات مضاعفی را با در نظر گرفتن تغییرات دینامیکی به ارمغان بیاورند [۵]. در این دسته می‌توان ویژگی‌های استخراج شده با استفاده از تبدیل موجک را ذکر کرد [۲۵]، [۲۴]. همچنین طیف Hilbert-Huang از توابع حالت ذاتی، توسط Hadjileontiadis و Hadjidimitriou [۲۶] استفاده شده است.

جدول ۱: بازه‌های باندهای فرکانسی و سطوح تجزیه موجک برای سیگنال EEG ضبط شده با فرکانس ۲۵۶ هرتز

سطح تجزیه Wavelet	باند فرکانسی	پهنای باند (Hz)
A6	δ	۱-۴
D6	θ	۴-۸
D5(8-16 Hz)	α slow	۸-۱۰
	α	۱۰-۱۲
D4(16-32 Hz)	β	۱۲-۳۰
D3(32-64 Hz)	γ	۳۰-۶۴

روش‌های استخراج ویژگی برخی مطالعات دیگر در جدول ۲ خلاصه شد. پس از استخراج ویژگی‌ها، باید با الگوریتم طبقه بندی مناسب آن‌ها را طبقه‌بندی نمود. بسیاری از الگوریتم‌های برای طبقه‌بندی ویژگی‌ها مورد استفاده قرار می‌گیرند، در میان آن‌ها، نزدیک‌ترین همسایگان (K Nearest Neighbor)، ماشین بردار پشتیبان (Support Vector KNN)، SVM (Machin)، تجزیه و تحلیل اختیاری خطی LDA (Linear Discriminant Analysis)، تجزیه و تحلیل دیجیتال چهارگانه (Quadratic Discriminant Analysis) QDA و شبکه عصبی بیشتر استفاده می‌شوند. برخی از تحقیقات چندین الگوریتم طبقه‌بندی را برای ویژگی‌های استخراجی خود استفاده می‌کنند و اکثر آن‌ها الگوریتم SVM را بهترین طبقه‌بند دانسته‌اند [۱۶].

روش

در تحقیقات انجام شده در زمینه تشخیص احساسات، هدف، ایجاد یک روش کارآمد برای یافتن ویژگی‌های مناسب و طبقه بندی آن‌ها است. در این تحقیق تمرکز بر نوآوری هم در بخش استخراج ویژگی‌ها و هم در تعیین طبقه‌بند می‌باشد، تا تشخیص احساسات از سیگنال‌های مغز را بهبود بخشد. اول از همه، تعداد کانال‌های EEG که در استخراج ویژگی مورد استفاده قرار می‌گیرند، باید شناسایی شوند.


ویژگی‌های حوزه زمان از سیگنال در حوزه اصلی آن استخراج می‌شود. اول از همه، عمدتاً از ویژگی‌های آماری سیگنال استفاده می‌شود. در میان آن‌ها، میانگین، انحراف معیار استاندارد و توان رایج‌تر است [۹-۶]. یکی دیگر از ویژگی‌های استفاده شده، آنتروپی است که نماد میزان پراکندگی داده‌ها است؛ اما همان گونه که Sleight و همکاران [۱۰] نشان دادند، تغییر در آنتروپی اطلاعات EEG می‌تواند نشان دهنده یک تغییر واقعی در ساختار عملکردی قشر مغز باشد؛ بنابراین اصطلاح "آنتروپی" بیشتر از آنکه صرفاً یک اندازه‌گیری آماری از الگوی EEG باشد، در واقع جریان اطلاعات داخل قشر مغز را منعکس می‌کند. همچنین Hjorth [۱۱] به معرفی برخی از ویژگی‌ها به نام فعالیت، تحرک و پیچیدگی می‌پردازد، که بعداً توسط محققان برای تشخیص احساسات EEG استفاده می‌شوند [۱۳، ۱۲]. سایر ویژگی‌های این حوزه شامل بعد فراکتال [۱۴]، شاخص غیرایستادگی [۱۵]، گذرگاه‌های مرتبه بالاتر [۱۷، ۱۶] و غیره است. توضیحات بیشتر در مورد این ویژگی‌ها توسط Jenke و همکاران ارائه شده است [۵].

ویژگی‌های حوزه فرکانس بر مبنای نمایش سیگنال در حوزه فرکانس است. ارائه یک سیگنال در حوزه فرکانس، با استفاده از تبدیل فوریه امکان‌پذیر است. الگوریتم‌های مورد استفاده برای این تبدیل، اغلب تبدیل فوریه دیجیتال (Discrete Fourier Transform) DFT و تبدیل سریع فوریه (Fast Fourier Transform) FFT هستند. محبوب‌ترین ویژگی در زمینه شناخت احساسات از EEG، ویژگی توان باندهای فرکانسی مختلف [۲۰-۱۸] است. برای این منظور، سیگنال در مدت زمان آزمایش ایستاد فرض می‌شود. نمایش باندهای فرکانسی مختلف توسط تبدیل موجک انجام می‌شود. دامنه باندهای فرکانسی سیگنال EEG در مطالعات مختلف کمی متفاوت است. در جدول ۱ باندهای فرکانسی و سطح تجزیه موجک مناسب برای سیگنال EEG ضبط شده با فرکانس ۲۵۶ هرتز نشان داده شد. ویژگی‌های استخراج شده از نمایش سیگنال در حوزه فرکانس عبارت‌اند از: متوسط (میانگین) قدرت باندهای فرکانسی [۲۳-۲۱]، حداقل، حداکثر و واریانس آن‌ها. علاوه بر این، میانگین نسبی قدرت باند، برای هر کانال محاسبه می‌شود. گروهی دیگر از ویژگی‌های حوزه فرکانس، ویژگی‌های معرفی شده توسط حسینی و همکاران است [۱۸]، که طیف‌های مرتبه بالاتر نامیده می‌شوند [۵].

اگر سیگنال غیر ایستاد باشد، روش‌های زمانی-فرکانسی

جدول ۲: برخی از روش‌های استخراج ویژگی برای تشخیص احساسات سیگنال EEG

نویسنده	سال	روش استخراج ویژگی	تعداد کلاس‌ها	(%) دقت
Pachori و Bajaj [۲۷]	۲۰۱۵	انواع موجک	۴	۷۹/۸۴
Sourina و Lin [۲۸]	۲۰۱۴	ویژگی‌های آماری و بعد فراکتال HOC	۴	۸۰
Park و همکاران [۲۹]	۲۰۱۳	توان در هر باند فرکانسی، همبستگی و عدم تقارن نیمکره‌های مغز	۳	۶۶/۳
Kwon و همکاران [۳۰]	۲۰۱۳	اختلاف توان نیمکره راست و چپ در باند فرکانسی آلفا و گاما	۳	۷۸/۶۴
Yoon و Chung [۳۱]	۲۰۱۳	چگالی طیف توان	۳	۵۲/۲
Khalilzadeh و Hosseini [۳۲]	۲۰۱۰	موجک و بعد فراکتال	۲	۷۸/۲۰
Roham و Khosrowabadi [۳۳]	۲۰۱۰	بعد فراکتال	۴	۸۱




شکل ۱: بلوک دیاگرام روش پیشنهادی

بین ۱۹ تا ۳۲ ساله قرار داشته‌اند و همچنین نیمی از شرکت کنندگان زن بودند. ویدئو-موسیقی‌هایی که به عنوان محرک احساسات مورد استفاده قرار گرفته‌اند، با برجسب‌های عاطفی طبقه‌بندی شده‌اند [۳۴]. سیگنال‌های EEG ضبط شده از شرکت کنندگان قبل از استفاده، به فرکانس ۱۲۸ هرتز تبدیل شده است.

وب سایت

[Http://www.eecs.qmul.ac.uk/mmv/datasets/deap](http://www.eecs.qmul.ac.uk/mmv/datasets/deap) اجازه می‌دهد این پایگاه داده را در قالب مناسب برای نرم‌افزار Matlab بارگیری کنید.

سپس، روش استخراج ویژگی پیشنهادی، باید روی سیگنال‌های پایگاه داده اعمال شود و در نهایت، ویژگی‌های استخراج شده باید طبقه‌بندی و کارایی روش ارزیابی شود. در شکل ۱ بلوک دیاگرام روش پیشنهادی ارائه شد. الگوریتم پیشنهادی بر روی یک مجموعه داده معروف به نام پایگاه داده DEAP که با ثبت سیگنال EEG از ۳۲ شرکت‌کننده در هنگام تماشای ۴۰ نوع ویدئو-موسیقی تهیه شده، مورد آزمایش قرار گرفت. داده‌ها در این مجموعه داده با سیستم ۳۲ کانالی BioSemi ضبط شده‌اند. شکل ۲، محل قرارگیری الکترودها روی پوست سر را نشان می‌دهد. تمامی افرادی که شرکت داشتند سالم بوده‌اند و در سنین



شکل ۲: محل قرارگیری الکترودها روی پوست سر

گابور با چهار یا پنج مقیاس و شش یا هشت جهت استفاده می کنند، که در نتیجه یک بانک فیلتر با ۲۴ یا ۴۰ فیلتر گابور ایجاد می شود [۳۷]. در این پژوهش، ماتریسی که باید به بانک فیلتر گابور دوبعدی متصل شود، تا تبدیل روی آن اعمال گردد، توسط داده های کانال های انتخابی که در ردیف های پشت سر هم چیده شده اند، ساخته می شود. گام بعدی استخراج ویژگی های مناسب از ماتریس ساخته شده پس از کانولوشن است. در این مطالعه، سه ویژگی از جمله انرژی، میانگین دامنه و الگوی همبستگی فاز گابور جهت دار (Oriented Gabor Phase Congruency Pattern) OGPCP استفاده شد، که به شرح زیر هستند:

انرژی: با توجه به کانولوشن فیلترهای گابور و ماتریس دو بعدی ایجاد شده، به تعداد فیلترها ماتریس دو بعدی به عنوان خروجی وجود دارد. برای محاسبه انرژی، تبدیل فوریه دو بعدی برای هر ماتریس خروجی دو بعدی باید اعمال گردد. به عنوان مثال، اگر فیلترهای گابور با ۵ مقیاس و ۸ جهت مختلف محاسبه شود، در کل ۴۰ فیلتر وجود دارد که باید به سیگنال EEG متصل شوند؛ بنابراین ۴۰ ماتریس ساخته می شود که انرژی آن ها به عنوان بخشی از ویژگی ها مورد استفاده قرار می گیرند.

میانگین دامنه: این ویژگی با محاسبه میانگین کل عناصر ماتریس خروجی حاصل می شود.

الگوی همگرایی فاز گابور جهت دار (OGPCP): اندازه گابور به آرامی با موقعیت مکانی تغییر می کند، بر خلاف فاز آن، که می تواند مقادیر بسیار متفاوتی داشته باشد، حتی اگر در مکان هایی از تصویر که تنها چند پیکسل با هم فاصله دارند، محاسبه گردد. این واقعیت باعث می شود، که در استخراج ویژگی های قابل اعتماد و افتراقی از پاسخ فاز مشکل ایجاد شود. این موضوع، اصلی ترین دلیلی است که بسیاری از روش های موجود، تنها از اندازه گابور برای ساخت بردار ویژگی گابور استفاده می کنند [۳۸]. برای غلبه بر این مشکل، Struc و [۳۷] Pavesic روشی جدید برای استخراج این ویژگی ها عنوان شده است که OGPCP نامیده می شود. طبق نتایج، این ویژگی ها تاکنون برای شناخت احساسات از EEG مورد استفاده قرار نگرفته است، برای ماتریس خروجی گابور $G_{u \otimes v}(x \otimes y)$ ، OGPCP به صورت زیر محاسبه می شود:

$$OGPCP_v(x \otimes y) = \frac{\sum_{u=1}^{\rho-1} A_{u \otimes v}(x \otimes y) \Delta \varphi_{u \otimes v}(x \otimes y)}{\sum_{u=1}^{\rho-1} (A_{u \otimes v}(x \otimes y) + \epsilon)} \quad (1)$$

همان طور که ذکر شد، مجموعه داده مورد استفاده برای آزمایش الگوریتم پیشنهادی شامل ۳۲ کانال داده است که در ۶۳ ثانیه با فرکانس ۱۲۸ هرتز در دسترس است؛ بنابراین حجم زیادی از اطلاعات برای هر شخص جهت پردازش وجود دارد. این مسئله سبب می شود که دو مشکل ایجاد شود: اول، حجم زیاد اطلاعات، نیاز به حافظه ذخیره سازی زیاد دارد و دوم، مدت زمان پردازش طولانی می شود. به همین دلیل، حجم داده ها کاهش داده شد به طوری که دقت طبقه بندی کاهش نمی یابد. برای داده های مورد استفاده در این پژوهش، ۷،۵ ثانیه از هر سیگنال برای استخراج ویژگی مناسب با الگوریتم مطالعه حاضر مناسب است. اگر چه این انتخاب باعث کاهش شدید داده های مورد پردازش می شود، اما می توان با انتخاب برخی از کانال های خاص و استفاده از فقط داده های آن ها، حجم داده های مورد پردازش را بسیار کاهش داد. اگر الگوریتم برای برنامه های آنی طراحی شده باشد، زمان لازم برای استخراج ویژگی ها و تعداد کانال های مورد استفاده باید حداقل باشد. در صورت استفاده از الکترودهای بیشتر، میزان راحتی کاربر مصرف کننده نیز کاهش می یابد؛ بنابراین هدف اصلی، پیشنهاد یک الگوریتم با دقت کافی در اجرای برنامه های کاربردی در زمان واقعی است [۱۶].

با مشاهده سایر تحقیقات در این زمینه، نشان داده شد که محققان از روش های مختلفی برای تعیین کانال های مؤثر تشخیص احساسات استفاده می کنند که عمدتاً بر اساس الگوریتم های بهینه سازی، آزمایش و خطا و یا روش های اکتشافی هستند [۱۴، ۳۵، ۱۲]. در این تحقیق، بر اساس نتایج تحقیقات قبلی، دو گروه کانال مقایسه شده اند. گروه اول، شامل ۳ کانال P3، P7 و PZ است و گروه دیگر شامل ۷ کانال P3، P7، PZ، PO3، O1، CP2 و C4 می باشد. با انتخاب یکی از آن دو گروه حجم داده ها نسبت به داده های ۳۲ کانال به میزان قابل توجهی کاهش می یابد.

روش استخراج ویژگی پیشنهاد شده شامل ۲ بخش کلی است: ویژگی های موجک گابور و ویژگی های تابع حالت ذاتی. فیلترهای گابور (موج برها یا هسته های گابور نیز نامیده می شوند) ثابت کرده اند که ابزار قدرتمندی برای استخراج ویژگی ها هستند. آن ها فیلترهای باند محدودی، با محلی سازی بهینه در حوزه های فضایی و فرکانسی هستند [۳۶]. محققان معمولاً از فیلترهای

که در آن:

$$A_{u \oplus v}(x \oplus y) = \sqrt{(Re(G_{u \oplus v}(x \oplus y)))^2 + (Im(G_{u \oplus v}(x \oplus y)))^2} \quad (2)$$

$$\varphi_{u \oplus v}(x \oplus y) = \tan^{-1} \frac{Im(G_{u \oplus v}(x \oplus y))}{Re(G_{u \oplus v}(x \oplus y))} \quad (3)$$

$$\Delta\varphi_{u \oplus v}(x \oplus y) = \cos(\varphi_{u \oplus v}(x \oplus y) - \overline{\varphi_v}(x \oplus y)) - |\sin(\varphi_{u \oplus v}(x \oplus y) - \overline{\varphi_v}(x \oplus y))| \quad (4)$$

ب) به دست آوردن پوش $\varepsilon_{max}(t)$ و $\varepsilon_{min}(t)$ با اتصال به ترتیب حداکثرها و حداقل‌های سیگنال.
ج) محاسبه میانگین $\varepsilon_{max}(t)$ و $\varepsilon_{min}(t)$ با فرمول ۵:

$$\alpha(t) = \frac{\varepsilon_{max}(t) + \varepsilon_{min}(t)}{2} \quad (5)$$

د) استخراج $d(t)$ از $s(t)$ به صورت فرمول ۶:

$$d(t) = s(t) - \alpha(t) \quad (6)$$

ه) بررسی این که آیا $d(t)$ شرایط فوق را برای IMF برآورده می‌کند یا خیر.

و) تکرار مراحل الف تا ه برای $d(t)$ تا زمانی که شرایط مورد نیاز برای IMF را برآورده سازد.

زمانی که IMF به دست آمد، باید $IMF_1(t) = d(t)$ تعریف شود. حال سیگنال باقی مانده $g(t)$ را می‌توان به صورت:

$$g(t) = s(t) - IMF_1(t)$$

جدید برای استخراج IMF با استفاده از فرایند غربالگری فوق استفاده می‌شود. فرایند غربالگری تا زمانی که مقدار باقی مانده، تابع مونوتونیک شود، ادامه می‌یابد. که به معنای این است IMF دیگری نمی‌تواند استخراج شود.

در نهایت سیگنال $s(t)$ را می‌توان به صورت مجموع IMF ها و یک باقی‌مانده مانند فرمول ۷ نشان داد [۴۱]:

$$s(t) = \sum_{i=1}^M IMF_i(t) + R(t) \quad (7)$$

یک کانال را نشان می‌دهد، که در آن محور افقی و عمودی به ترتیب نشان‌دهنده زمان و دامنه هر سیگنال است.

که در آن‌ها u شماره مقیاس و v شماره جهت فیلتر گابور است. مثلاً اگر مقیاس عدد ۵ انتخاب شود، تمام اعداد بین ۱ تا ۵ را اختیار می‌کند. $\varphi_{u \oplus v}(x \oplus y)$ نشان دهنده زاویه فاز فیلتر گابور در مقیاس u و جهت v در محل مکانی $(x \oplus y)$ است، اما $\overline{\varphi_v}(x \oplus y)$ نشان دهنده میانگین فاز در v -مین جهت است [۳۹].

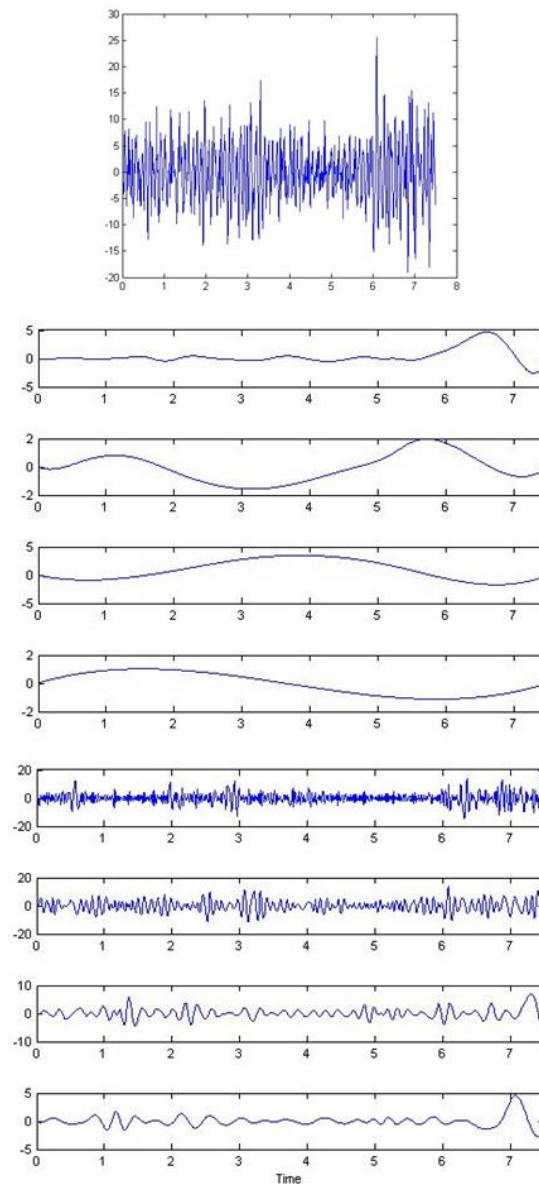
ویژگی‌های مبتنی بر توابع حالت ذاتی: هدف این بخش، استخراج ویژگی‌ها از اعمال توابع حالت ذاتی است. رویکرد تجزیه حالت تجربی EMD(Empirical Mode) یک تجزیه و تحلیل وابسته به داده است که سیگنال‌های غیر خطی و غیر ایستان را به اجزای متقارن تجزیه می‌کند، که به‌عنوان توابع حالت ذاتی IMF(Intrinsic Mode Function) شناخته می‌شوند [۴۰]. لازم به ذکر است که IMF هایی که از روش EMD به دست آمده، باید دو شرط زیر را برآورده کنند:
۱- تعداد حداکثرها و تعداد حداقل‌ها نباید بیشتر از یکی تفاوت داشته باشند.

۲- میانگین مقدار دو پوش، که یکی توسط اتصال حداکثرهای محلی و دیگری با اتصال حداقل‌های محلی سیگنال ایجاد شده‌اند، باید صفر باشد.

IMF های یک سیگنال $s(t)$ با استفاده از فرایند تکراری به نام پروسه خنثی‌سازی، که توسط مراحل زیر توضیح داده می‌شود، ساخته می‌شوند:

الف) استخراج حداکثرهای محلی و مینیمم‌های محلی از سیگنال $s(t)$.

که در آن M تعداد IMF های استخراج شده است و $R(t)$ باقی مانده است. به‌عنوان مثال، شکل ۳، IMF های داده‌های



شکل ۳: بخشی از سیگنال کانال P7 و IMFهای آن

انتخاب ۷ کانال، ۱۴ عنصر بردار ویژگی، با حداکثر فرکانس IMFها ارتباط دارند.

فرکانس مرکزی: فرکانس مرکزی برای IMF فرکانسی تعریف می‌شود که در قبل از آن ۵۰٪ انرژی سیگنال‌های IMF در دسترس است. در این پژوهش، تنها فرکانس مرکزی اولین IMF برای هر کانال به‌عنوان ویژگی در نظر گرفته شد.

آنتروپی: آنتروپی یک مدل آماری از سیگنال است که می‌تواند اطلاعات فیزیکی را نیز ارائه دهد. شواهد نوروفیزیولوژیک نشان می‌دهد که می‌توان اطلاعات آنتروپی را به‌عنوان یک اندازه

در این پژوهش، برای هر سیگنال فقط ۳ تابع حالت ذاتی اول محاسبه گردید و سپس ویژگی‌ها، از آن‌ها استخراج شده‌اند. برای هر IMF محاسبه، پنج ویژگی از جمله: (۱) حداکثر فرکانس (۲) فرکانس مرکزی (۳) ریشه میانگین مربعات (۴) آنتروپی و (۵) واریانس محاسبه شد. که توضیحات آن در ادامه آورده شد.

حداکثر فرکانس: حداکثر فرکانس IMF، فرکانسی است که از فرکانس صفر تا آن فرکانس ۹۵٪ انرژی سیگنال IMF وجود دارد. در این پژوهش، از حداکثر فرکانس IMF اول و دوم به‌عنوان ویژگی برای هر کانال استفاده می‌شود. برای مثال، با

اعمال می‌شود؛ بنابراین در این مرحله، هدف یافتن الگوریتم طبقه بندی مناسب برای بردار ویژگی تولید شده است.

ماشین بردار پشتیبان SVM یک الگوریتم یادگیری ماشین می باشد که ساده و دارای سرعت و دقت بالا در تشخیص است. ایده SVM پیدا کردن فضاهای دسته‌بندی بهینه شده با حداکثر حاشیه جدایی است.

در این پژوهش، از الگوریتم بهینه‌سازی ژنتیک برای یافتن فضاهای دسته‌بندی بهینه شده استفاده شد. با توجه به اطلاعات این مطالعه، تاکنون در مورد تشخیص احساسات سیگنال EEG، ماشین بردار پشتیبان بهینه شده استفاده نشده است؛ بنابراین علاوه بر نوآوری‌هایی که برای گام استخراج ویژگی ارائه شده است، ایده جدیدی در مرحله طبقه‌بندی وجود دارد، که استفاده از SVM چند کلاسه بهینه شده با الگوریتم ژنتیک است.

SVM دارای پارامترهای تعیین کننده‌ای است؛ برخی از آن‌ها به نوع تابع هسته برای الگوریتم SVM بستگی دارد. توابع هسته نقشه داده‌ها را، که به طور خطی در فضای اصلی آن قابل جدا شدن نیستند، به فضای دیگری با ابعاد بیشتر و قابلیت جداسازی خطی نگاشت می‌کند. برخی از توابع هسته معروف مانند توابع پایه شعاعی (RBF)، سیگموئید، خطی وجود دارند که در این مطالعه از تابع هسته RBF استفاده شد. با انتخاب این تابع هسته، دو پارامتر باید تعیین شود که گاما و C نامیده می‌شود. این مقادیر تأثیر مهمی در عملکرد طبقه‌بندی دارند. اثر این دو پارامتر بر دقت طبقه‌بندی در جدول ۳ نشان داده شد.

جدول ۳: اثر پارامترهای گاما و C بر دقت طبقه‌بندی

Gamma ($\times 10^{-5}$)	C		C	
	۹	۱۰	۹	۱۰
Dقت (%)	۹۱/۱۶	۸۹/۰۹	۹۳/۸۶	۹۱/۰۸

نتایج

در این پژوهش، یک الگوریتم تشخیص احساسات از EEG ارائه شد. داده‌های EEG از مجموعه داده DEAP در فرکانس ۱۲۸ هرتز نمونه برداری شده‌اند. در اینجا، فقط ویژگی‌های ذکر شده گابور و IMF از داده‌های EEG بدون پیش‌پردازش استخراج شده‌اند. طبقه‌بند SVM چند کلاسه با هسته RBF بهینه شده توسط الگوریتم ژنتیک، برای طبقه‌بندی ویژگی‌های استخراج شده به چهار کلاس انتخاب شد. برای استفاده از کل مجموعه

گیری از عملکرد قشر مغز برآورد کرد. تغییر در آنتروپی سیگنال EEG نشان‌دهنده تغییر واقعی در عملکرد قشر مغز است؛ بنابراین آنتروپی، علاوه بر اندازه‌گیری آماری از الگوی EEG، در برخی موارد می‌تواند اطلاعات قشر مغز را نیز منعکس کند [۱۰]. در این مطالعه، آنتروپی شانون برای استخراج ویژگی‌های IMF محاسبه می‌شود.

میانگین مربعات ریشه (Root Mean Square)

RMS: به طور کلی، متوسط ریشه سیگنال در واقع نشان دهنده قدرت متوسط سیگنال است. در این پژوهش، میانگین مربع ریشه IMFها به عنوان ویژگی‌های استخراج شده مورد استفاده قرار می‌گیرند. در این پژوهش، برای اولین بار از سه IMF برای میانگین مربع ریشه استفاده شد.

انحراف: در نظریه آمار و احتمالات، واریانس، معیاری برای پراکندگی است. در این پژوهش، از داده‌های آماری IMFها برای استخراج ویژگی استفاده شد. همچنین، مانند آنتروپی و میانگین مربع ریشه، داده‌های ۳ IMF برای استخراج ویژگی‌های هر کانال استفاده می‌شود، بنابراین ۳ ویژگی متعلق به واریانس برای هر کانال است.

تولید بردارهای ویژگی:

مطابق آنچه تاکنون توضیح داده شد، دو مجموعه از ویژگی‌ها استخراج شده‌اند: مجموعه اول مربوط به استفاده از تبدیل موجک گابور در تصویر است. این مجموعه شامل ویژگی‌هایی مانند متوسط و انرژی و همچنین خصوصیات فاز به نام OGPCP می‌باشد. دوم، مجموعه ویژگی‌های به دست آمده از توابع حالت ذاتی است. ویژگی‌های استخراج شده از این مجموعه عبارت‌اند از فرکانس حداکثر و فرکانس مرکزی، آنتروپی، میانگین مربع ریشه و واریانس. داده‌های این دو مجموعه ویژگی را باید به صورت برداری در کنار هم قرار داد تا نهایتاً یک بردار ویژگی ساخته شود.

طبقه‌بندی:

در این مرحله، الگوریتم طبقه‌بندی مناسب برای بهبود دقت تشخیص احساس با توجه به بردار ویژگی ورودی **اعتبار سنجی متقابل:** بر اساس تکنیکی به نام اعتبار سنجی متقابل، داده‌های آموزش شی به k زیر مجموعه تقسیم می‌شوند. $k-1$ زیر مجموعه برای آموزش استفاده می‌شود و زیر مجموعه استفاده نشده برای ارزیابی عملکرد استفاده می‌شود. این عمل k بار تکرار می‌شود و هر بار یک زیر مجموعه جدید برای ارزیابی در نظر گرفته می‌شود. در این فرایند، تمام داده‌های آموزش یک‌بار برای ارزیابی استفاده می‌شوند. در این پژوهش از $k=10$ استفاده شد.

دهد. آزمایش‌ها با دو فیلتر گابور متفاوت انجام می‌شود، یکی فیلتر با چهار مقیاس و شش جهت (4×6) و دیگری فیلتر با پنج مقیاس و هشت جهت (8×5) است. گروه اول شامل کانال‌های PZ، P3، P7 و PZ و P3 و گروه دوم شامل کانال‌های PZ، P3، P7، PO3، C4، O1 و CP2 است.

داده‌ها برای آموزش و تست الگوریتم طبقه‌بندی، از طرح اعتبارسنجی متقابل با ۱۰ پوشه استفاده گردید و عملکرد طبقه‌بندی از طریق میزان دقت طبقه‌بندی ارزیابی شد. جدول ۴ اثر انتخاب دو گروه مختلف از کانال‌های سیگنال EEG را بر دقت طبقه‌بندی احساسات برای ۴ کلاس نشان می‌دهد.

جدول ۴: دقت طبقه‌بندی دو گروه از کانال‌ها با بانک فیلتر گابوری در دو سایز مختلف

تعداد کانال‌های انتخابی	سایز فیلتر گابور	دقت طبقه‌بندی (%)
۳	۴×۶	۹۳/۸۶
	۵×۸	۹۰/۲۸
۷	۴×۶	۹۳/۷۴
	۵×۸	۹۰/۴۱

EEG، برخی از عوامل باید بین آن‌ها یکسان باشند. از آنجایی که مجموعه داده‌های مختلف با فرکانس‌های مختلف، اطلاعات مختلفی برای سیستم تشخیص فراهم می‌کنند، لازم است سیگنال ورودی یکسان باشد. علاوه بر این، محرک‌های احساسی مختلف موجب واکنش‌های مختلفی در افراد مختلف می‌شوند. عامل دوم، تعداد کلاس‌های مورد طبقه‌بندی است که باید مشابه باشند. جدول ۵، مقایسه روش پیشنهاد شده و چند روش اخیر را نشان می‌دهد. همان‌طور که مشاهده می‌شود، روش پیشنهادی می‌تواند به طور قابل توجهی باعث بهبود دقت تشخیص احساسات EEG شود. در این جدول، تنها روش گزارش شده توسط Zheng و همکاران در [۲] همانند روش پیشنهادی از داده‌های DEAP به عنوان ورودی استفاده کرده است. واضح است که الگوریتم پیشنهاد شده، دقت تشخیص احساسات را در مقایسه با الگوریتم‌های دیگر افزایش می‌دهد.

انتخاب کانال‌های بیشتر و فیلترهای گابور بزرگ‌تر موجب می‌شود که بردار ویژگی‌های بزرگ‌تری ایجاد شود، اما جدول ۴ نشان می‌دهد که طول بردار ویژگی به طور مستقیم با عملکرد سیستم متناسب نیست. به این معنا که، گاهی اوقات با افزایش طول بردار ویژگی، دقت تشخیص حتی کاهش می‌یابد؛ بنابراین می‌توان نتیجه گرفت که کارایی سیستم مربوط به ویژگی‌های استخراج شده مؤثر است و نه تعداد ویژگی‌های استخراج شده. از سوی دیگر، هنگامی که طول بردار ویژگی کمتر است، سرعت پردازش بیشتر می‌شود. جدول ۴ نشان می‌دهد که با انتخاب فقط ۳ کانال، به نام P7، P3 و PZ و فیلتر گابور با چهار مقیاس و شش جهت (6×4) بردار ویژگی مؤثری ایجاد می‌شود که نتیجه آن دقت بالاتری در طبقه‌بندی است. در این حالت، طول بردار ویژگی ۲۶۴ می‌باشد. برای مقایسه منصفانه روش‌های مختلف تشخیص احساسات از

جدول ۵: مقایسه روش پیشنهاد شده و چندین روش اخیر

نویسنده	الگوریتم طبقه‌بندی	دقت طبقه‌بندی (%)
Pachori و Bajaj [۲۷]	SVM	۸۴/۷۹
Zheng و همکاران [۲]	SVM	۶۹/۶۷
Lu و Li [۴۱]	LDA, KNN	۸۳/۰۴
Lin و همکاران [۴۲]	SVM	۸۲/۲۹
Wang و همکاران [۷]	SVM	۶۶/۵۰
Proposed method	Evolutionary SVM	۹۳/۸۶

داده مناسب است. در این مرحله پایگاه داده DEAP برای اعتبارسنجی الگوریتم پیشنهاد شده مورد استفاده قرار گرفت. گام دوم، استخراج ویژگی‌ها است که در این روش، ویژگی‌های نوآورانه، بر اساس فیلتر کردن داده‌ها با فیلترهای گابور و

بحث و نتیجه گیری

این پژوهش به منظور بهبود دقت در تشخیص احساسات مبتنی بر سیگنال EEG انجام شد. به طور کلی، مطالعاتی با این موضوع گام‌های اساسی متعددی دارند. اولین گام تهیه پایگاه

الگوریتم تکاملی ژنتیکی بهینه‌سازی شده است، عملکرد بهتری را فراهم می‌کند.

در پایان، بهبود قابل توجهی در دقت تشخیص احساسات از EEG نشان داده شد. $93/86\%$ دقت تشخیص الگوریتم پیشنهاد شده است که قادر است ۴ حالت مختلف احساسی را براساس سیگنال EEG تشخیص دهد.

همچنین استفاده از توابع حالت ذاتی، استخراج شده‌اند. نتایج تجربی نشان داد که انتخاب ۷،۵ ثانیه و ۳ کانال از داده‌های ورودی، نتایج قابل قبولی را ارائه می‌دهد. به علاوه باعث کاهش حجم محاسبات و حافظه مورد نیاز برای پردازش می‌شود. آخرین مرحله انتخاب الگوریتم طبقه‌بندی مناسب است. در این روش، نشان داده شد که الگوریتم SVM چند کلاسه که توسط

References

- Mühl C, Allison B, Nijholt A, Chanel G. A survey of affective brain computer interfaces: principles, state-of-the-art, and challenges. *Brain-Computer Interfaces* 2014;1(2):66-84.
- Zheng WL, Zhu JY, Lu BL. Identifying stable patterns over time for emotion recognition from EEG. *IEEE Transactions on Affective Computing*; IEEE; 2017.
- Savran A, Çiftçi K, Chanel G, Rombaut M. Emotion Detection in the Loop from Brain Signals and Facial Images. *Proceedings of the eNTERFACE*; 2066 Jul 11-17; Dubrovnik, Croatia: 2006.
- Chen L, Mao X, Xue Y, Cheng LL. Speech emotion recognition: Features and classification models. *Digital Signal Processing* 2012;22(6):1154-60.
- Jenke R, Peer A, Buss M. Feature extraction and selection for emotion recognition from EEG. *IEEE Transactions on Affective Computing* 2014; 5(3): 327 – 39.
- Liu Y, Sourina O. Real-time fractal-based valence level recognition from EEG. Berlin, Heidelberg: Springer; 2013.
- Wang XW, Nie D, Lu BL. EEG-based emotion recognition using frequency domain features and support vector machines. 18th International Conference, ICONIP; 2011 Nov 13-17; Shanghai, China: 2011. p. 734-43.
- Murugappan M, Rizon M, Nagarajan R, Yaacob S. Inferring of human emotional states using multichannel EEG. *European Journal of Scientific Research* 2010; 48(2): 281-99.
- Takahashi K, Tsukaguchi A. Remarks on emotion recognition from multi-modal bio-potential signals. *International Conference on Industrial Technology*; 2003 Oct 8; Washington, DC, USA: IEEE; 2004. p. 1138-43.
- Sleigh JW, Olofsen E, Dahan A, de Goede J, Steyn-Ross A. Entropies of the EEG: The effects of general anesthesia. 5th International Conference on Memory, Awareness and Consciousness; 2001 Jun 1-3; New York: 2001. p. 1-21.
- Hjorth B. EEG analysis based on time domain properties. *Electroencephalogr Clin Neurophysiol* 1970;29(3):306-10.
- Ansari-asl K, Chanel G, Pun T. A channel selection method for EEG classification in emotion assessment based on synchronization likelihood. 15th European Signal Processing Conference; 2007 Sep 3-7; Poznan, Poland, IEEE; 2007. p. 1241-5.
- Horlings R, Dacu D, Rothkrantz L. Emotion recognition using brain activity. 9th International Conference on Computer Systems and Technologies and Workshop for PhD Students in Computing; 2008 Jun 12-13; Gabrovo, Bulgaria; ACM; 2008. p. 1-6.
- Liu Y, Sourina O. EEG-based subject-dependent emotion recognition algorithm using fractal dimension. *IEEE International Conference on Systems, Man, and Cybernetics (SMC)*; 2014 Oct 5-8; San Diego, CA, USA, IEEE; 2014. p. 3166 –71.
- Kroupi E, Yazdani A, Ebrahimi T. EEG Correlates of Different Emotional States Elicited during Watching Music Videos. Berlin, Heidelberg: Springer; 2011.
- Petrantonakis PC, Hadjileontiadis LJ. Emotion recognition from EEG using higher order crossings. *IEEE Transactions on Information Technology in Biomedicine* 2010; 14(2): 186- 97.
- Petrantonakis PC, Hadjileontiadis LJ. A novel emotion elicitation index using frontal brain asymmetry for enhanced EEG-based emotion recognition. *IEEE Trans Inf Technol Biomed* 2011;15(5):737-46.
- Hosseini S, Khalilzadeh M, Naghibi-Sistani M, Niazmand V. Higher Order Spectra Analysis of EEG Signals in Emotional Stress States. *Second International Conference on Information Technology and Computer Science*; 2010 Jul 24-25; Kiev, Ukraine: IEEE; 2010. p. 60-3.
- Nie D, Wang XW, Shi LC, Lu BL. EEG-based emotion recognition during watching movies. 5th International IEEE/EMBS Conference on Neural Engineering; 2011 Apr-May 27-1; Cancun, Mexico: IEEE; 2011. p. 667-70.
- Liu Y, Sourina O. EEG-based dominance level recognition for emotion-enabled interaction. *International Conference on Multimedia and Expo*; 2012 Jul Melbourne, VIC Australia: IEEE; 2012. p. 1039-44.
- Reuderink B, Mühl C, Poel M. Valence, arousal and dominance in the EEG during game play. *International Journal of Autonomous and Adaptive Communications Systems* 2013; 6(1): 45-62.
- Rozgic V, Vitaladevuni SN, Prasad R. Robust EEG emotion classification using segment level decision fusion. *International Conference on Acoustics, Speech*

- and Signal Processing; 2013 May 26-31; Vancouver, BC, Canada: IEEE; 2013. p. 1286-90.
23. Soleymani M, Kolestra S, Patras I, Pun T. Continuous emotion detection in response to music videos. IEEE International Conference on Automatic Face & Gesture Recognition and Workshops (FG 2011), 2011 IEEE International Conference on; 2011 Mar 21-25; Santa Barbara, CA, USA, USA: IEEE; 2011. p. 803-8.
24. Stelios K, Hadjidimitriou LJ. Toward an EEG-based recognition of music liking using time-frequency analysis. IEEE Transactions on Biomedical Engineering 2012; 59(12): 3498 – 510.
25. Murugappan M, Nagarajan R, Yaacob S. Classification of human emotion from EEG using discrete wavelet transform. Journal of Biomedical Science and Engineering 2010; 3(4): 390-6.
26. Hadjidimitriou SK, Hadjileontiadis LJ. Toward an EEG-based recognition of music liking using time-frequency analysis. IEEE Trans Biomed Eng 2012;59(12):3498-510.
27. Bajaj V, Pachori RB. Detection of Human Emotions Using Features Based on the Multiwavelet Transform of EEG Signals. In: Hassanién AE, Azar AT, editors. Brain-Computer Interfaces: Current Trends and Applications. Cham: Springer International Publishing; 2015. p. 215-40.
28. Liu Y, Sourina O. Real-Time Subject-Dependent EEG-Based Emotion Recognition Algorithm. In: Gavrilova ML, Tan CJK, Mao X, Hong L, editors. Transactions on Computational Science XXIII: Special Issue on Cyberworlds. Berlin, Heidelberg: Springer Berlin Heidelberg; 2014. p. 199-223.
29. Park MS, Oh HS, Sohn JH. Eeg-based emotion recognition during emotionally evocative films. International Winter Workshop on Brain-Computer Interface (BCI); 2013 Feb 18-20; Gangwo, South Korea: IEEE; 2013.
30. Kwon M, Kang JS M, Lee M. Emotion classification in movie clips based on 3D fuzzy GIST and EEG signal analysis. International Winter Workshop on Brain-Computer Interface (BCI); 2013 Feb 18-20; Gangwo, South Korea: IEEE; 2013. p. 67-8.
31. Chung SY, Yoon HJ. Affective classification using Bayesian classifier and supervised learning. 12th International Conference on Control, Automation and Systems; 2012 Oct 17-21; Jeju Island, Korea: IEEE; 2012. p. 1768- 71.
32. Hosseini SA, Khalilzadeh MA, Naghibi-Sistani MB, Homam SM. Emotional stress recognition using a new fusion link between electroencephalogram and peripheral signals. Iran J Neurol 2015;14(3):142-51.
33. Khosrowabadi R, Rahman AW. Classification of EEG correlates on emotion using features from Gaussian mixtures of EEG spectrogram. Proceeding of the 3rd International Conference on Information and Communication Technology for the Moslem World (ICT4M); 2010 Dec 13-14; Jakarta, Indonesia: IEEE; 2010.
34. Koelstra S, Muhl C, Soleymani M, Lee JS, Yazdani A, Ebrahimi, T, et al. DEAP: a database for emotion analysis ;using physiological signals. IEEE Transactions on Affective Computing 2012; 3(1): 18-31.
35. Vijayan AE, Sen D, Sudheer AP. EEG-based emotion recognition using statistical measures. IEEE International Conference on Computational Intelligence & Communication Technology; 2015 Feb 13-14; Ghaziabad, India: IEEE; 2015.
36. Struc V, Pavesic N. Gabor-based kernel partial-least-squares discrimination features for face recognition. Journal of Informatica 2009; 20 (1):115-38.
37. Struc V, Pavesic N. From Gabor magnitude to gabor phase features: tackling the problem of face recognition under severe illumination changes. Face Recognition; 2010 Jan; Vienna, Austria: In-Tech; 2010. p. 215-38.
38. Zhang B, Shan S, Chen X, Gao W. Histogram of Gabor Phase Patterns (HGPP): a novel object representation approach for face recognition. IEEE Transactions on Image Processing 2007; 16(1): 57 – 68.
39. Huang NE, Shen Z, Long SR, Wu MC, Shih HH, Zheng Q, et al. The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis. Proceedings: Mathematical, Physical and Engineering Sciences 1998; 454(1971): 903-95.
40. Sharma R, Pachori RB. Classification of epileptic seizures in EEG signals based on phase space representation of intrinsic mode functions. Expert Systems with Applications 2014; 42(3): 1106-17.
41. Li M, Lu BL. Emotion classification based on gamma-band EEG. Conf Proc IEEE Eng Med Biol Soc 2009;1323-6.
42. Lin YP, Wang CH, Wu TL, Jeng SK, Duann JR, Chen JH. EEG-Based emotion recognition in music listening. IEEE Transactions on Biomedical Engineering 2010;57(7): 1798- 1806.

New Feature Extraction Method for Precision Improvement in Emotion Detection Using EEG Signals

Zamaniah Hanieh*¹, Farsi Hassan²

• Received: 3 Feb, 2018

• Accepted: 22 April, 2018

Introduction: Since emotions play an important role in human life, it requires providing an intelligent method to detect emotions using electroencephalogram (EEG) signal based on signal processing techniques. In addition, in this research, using support vector machine (SVM) classifier with genetic evolutionary algorithm is a novelty in classification part.

Methods: The proposed method focuses on feature extraction and classification of received signals from brain to improve emotion detection. In this way, firstly, effective EEG channels are identified and then time and frequency features of EEG signals are extracted and classified by an appropriate classifier. The proposed method is applied on DEAP database which includes recorded EEG signals by 32 people watching and listening 40 videos and music.

Results: The experiments show that selection of 7.5 seconds and 3 EEG channels provides acceptable results. In addition, the proposed method reduces computations and required memory and results in 93.86% accuracy for 4 emotion classification.

Conclusion: Improvement in emotion detection based on EEG signals contains several steps in which effective features extraction and classification are two important steps. According to this research, using time-frequency features of EEG signals and optimized SVM classifier with genetic algorithm provides better results.

Keywords: Emotion recognition, EEG signal, neural network and support vector machine (SVM)

• **Citation:** Zamaniah H, Farsi H. New Feature Extraction Method for Precision Improvement in Emotion Detection Using EEG Signals. *Journal of Health and Biomedical Informatics* 2018; 5(1): 44-55.

1. Ph.D Student in Electrical Engineering, Electrical and Computer Engineering Dept., University of Birjand, Birjand, Iran

2. Ph.D in Electrical Engineering, Professor, Electrical and Computer Engineering Dept., University of Birjand, Birjand, Iran

***Correspondence:** Electrical and Computer Engineering Dept., University of Birjand, Birjand, Iran

• **Tel:** 09156228287

• **Email:** hanieh.zamaniah@birjand.ac.ir