

بِسْمِ اللَّهِ الرَّحْمَنِ الرَّحِيمِ



دانشکده مهندسی برق و رباتیک

پایان نامه کارشناسی ارشد مهندسی مخابرات سیستم

تشخیص خستگی با استفاده از بررسی فرکانسی سیگنال های EEG

نگارنده:

مهسا جمشیدی نیا

استاد راهنما:

دکتر حسین مروی

استاد مشاور:

دکتر سعیده فردوسی

شهریور ماه ۱۳۹۷

شماره ۱۵۸۹، ۵۰۶
تاریخ: ۷، ۶، ۹۷

باسمه تعالی



مدیریت تحصیلات تکمیلی

فرم شماره (۳) صورتجلسه نهایی دفاع از پایان نامه دوره کارشناسی ارشد

با نام و یاد خداوند متعال، ارزیابی جلسه دفاع از پایان نامه کارشناسی ارشد خانم / آقای مهسا جمشیدی نیا با شماره

دانشجویی ۹۴۰۵۱۸۴ رشته مهندسی برق- مخابرات گرایش سیستم تحت عنوان: تشخیص خستگی با استفاده

از بررسی فرکانسی سیگنال های EEG که در تاریخ ۱۳۹۷/۰۶/۰۷ با حضور هیأت محترم داوران در دانشگاه

صنعتی شاهرود برگزار گردید به شرح ذیل اعلام می گردد:

قبول (با درجه:): مردود
نوع تحقیق: نظری عملی

عضو هیأت داوران	نام و نام خانوادگی	مرتبه علمی	امضاء
۱- استاد راهنمای اول	علیرضا مراد	استاد	
۲- استاد راهنمای دوم	—	—	—
۳- استاد مشاور	سعید فزونی	استاد	
۴- نماینده تحصیلات تکمیلی	حیدر کاسیان	استاد	
۵- استاد ممتحن اول	ایرجا سرزهی	استاد	
۶- استاد ممتحن دوم	هادی کریمی	استاد	

نام و نام خانوادگی رئیس دانشکده:

تاریخ و امضاء و مهر دانشکده:

تبصره: در صورتی که کسی مردود شود حداکثر یکبار دیگر (در مدت مجاز تحصیل) می تواند از پایان نامه خود دفاع مجدد نماید. (باید زودتر از ۴ ماه برگزار شود).

تقدیم بہ

دروما



مہربانم

تقدیر و تشکر

شکرشایان نثار ایزدمنان که توفیق را رفیق را هم ساخت تا مقطع کارشناسی ارشد را به پایان برسانم. اکنون که به فضل الهی این پژوهش به ثمر رسیده است، بر خود واجب می‌دانم از همه کسانی که به نحوی در انجام این مهم مرایاری نموده‌اند، سپاسگزاری و قدردانی نمایم.

سپاسگزار کسانی، بسم که سرآغاز تولد من هستند، مقدس‌ترین واژه‌ها در لغت نامه دلم، آنان که مهر آسمانی شان آرام بخش آرام زمینی ام است...

استوارترین تکیه‌گاهم، دستان پر مهر پدرم و سبزترین نگاه زندگیم، چشمان سبز مادرم...

که هر چه آموختم در مکتب عشق شما آموختم و هر چه بلو شتم قطره‌ای از دریای بی‌کران مهربانیان را پاس توانم بگویم. امروز هستی ام به امید شماست و فردا کلید باغ بهشت رضای شما... ره آوردی کران سنگ تر از این ارزان نداشتم تا به خاک پایتان نثار کنم، باشد که حاصل تلاشم نسیم کونه غبار خشکیتان را برزاید. بوسه بردستان پر مهرتان...

بخنین از از زحمات و مساعدت های استاد راهنمای ارجمندم جناب آقای دکتر حسین مروی و استاد مشاور گرامی خود سرکار خانم دکتر سعیده فردوسی صمیمانه تشکر و قدردانی می‌نمایم.

تعهد نامه

اینجانب مهسا جمشیدی‌نیا دانشجوی دوره کارشناسی ارشد رشته مهندسی برق گرایش مخابرات-سیستم دانشکده مهندسی برق و رباتیک دانشگاه صنعتی شاهرود نویسنده پایان نامه تشخیص خستگی ذهنی با استفاده از بررسی فرکانسی سیگنال‌های EEG تحت راهنمایی آقای دکتر حسین مروی 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 مورد استفاده 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 می‌باشد 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

امضای دانشجو

مالکیت نتایج و حق نشر

- کلیه حقوق معنوی این اثر و محصولات آن (مقالات مستخرج، کتاب، برنامه‌های رایانه‌ای، نرم افزارها و تجهیزات ساخته شده است) متعلق به دانشگاه صنعتی شاهرود می‌باشد. این مطلب باید به نحو مقتضی در تولیدات علمی مربوطه ذکر شود.
- استفاده از اطلاعات و نتایج موجود در پایان نامه بدون ذکر مرجع مجاز نمی‌باشد.

چکیده

خستگی یک پاسخ مهم و طبیعی به فعالیت‌های جسمی زیاد، تنش‌های روحی طولانی مدت و کمبود خواب است. خستگی همچنین یکی از علائم مهم اختلالات جسمی یا روانی است. بدون شک همه‌ی افراد پس از یک فعالیت ذهنی شدید و یا فکرکردن بیش از حد احساس خستگی را تجربه کرده‌اند. این احساس دقیقاً مشابه خستگی ناشی از ورزش طولانی مدت است که در بدن انسان ایجاد می‌شود. به‌طور کلی مبحث خستگی به دو دسته کلی خستگی جسمی و ذهنی تقسیم‌بندی می‌شود. خستگی بر روی بسیاری از جنبه‌های زندگی فرد مؤثر است بطوریکه با تأثیر منفی بر توانایی فرد در اجرای فعالیت‌های روزمره، زندگی او را تحت الشعاع قرار می‌دهد. تحقیقات نشان داده است که در میان تکنیک‌های مختلف که برای ارزیابی خستگی، سیگنال‌های الکتروانسفالوگرام (EEG) با دقت بیشتر و بهتری عمل می‌کنند.

هدف از این پایان‌نامه تحلیل و بررسی علائم خستگی ذهنی است که در سیگنال‌های مغزی افراد ظاهر می‌شوند. به‌منظور بررسی سیگنال‌ها ابتدا از یک فیلتر برای پیش‌پردازش داده‌ها استفاده شد و سپس برای استخراج ویژگی، روش تجزیه حالت تجربی (EMD) به‌منظور تجزیه سیگنال به مؤلفه‌های فرکانسی آن، به کار برده شد. این مؤلفه‌های فرکانسی توابع مود ذاتی (IMF) نامیده می‌شوند که از طریق اعمال EMD بر روی سیگنال‌های EEG به دست آمده و به‌عنوان بردار ورودی به طبقه‌بند داده می‌شوند. همچنین برای بهبود نتایج ترکیبی از دو تکنیک EMD و STFT به‌عنوان روش پیشنهادی ارائه گردید.

به‌منظور طبقه‌بندی ویژگی‌های به‌دست آمده از دو طبقه‌بند شبکه عصبی مصنوعی و ماشین بردار پشتیبان استفاده شد. سپس از ویژگی‌های تبدیل فوریه زمان کوتاه، انرژی موجک در باندهای سیگنال EEG و ترکیب آنها به منظور مقایسه با روش پیشنهادی استفاده شد. نتایج حاصل از روش پیشنهادی با استفاده از دو طبقه‌بند FF-ANN و SVM به ترتیب برابر با ۹۱/۳٪ و ۹۰٪ است و همچنین از سه پارامتر دقت، حساسیت و ویژگی برای ارزیابی نتایج استفاده شد.

کلیدواژه: سیگنال‌های EEG، خستگی ذهنی، طبقه‌بند ماشین بردار پشتیبان، شبکه عصبی مصنوعی، تجزیه حالت تجربی.

فهرست مطالب

۱- مقدمه	۱
۱-۱- مقدمه	۲
۲-۱- سیگنال الکتروانسفالوگرام	۳
۳-۱- تاریخچه و نحوه ثبت سیگنال EEG	۴
۴-۱- تحلیل طیف سیگنال EEG	۶
۱-۴-۱- امواج دلتا	۶
۲-۴-۱- امواج گاما	۷
۳-۴-۱- امواج تتا	۷
۴-۴-۱- امواج آلفا	۷
۵-۴-۱- امواج بتا	۷
۵-۱- انواع الگوهای مغزی	۸
۶-۱- تعریف مسئله	۱۱
۷-۱- روش پیشنهادی	۱۲
۸-۱- ساختار پایان نامه	۱۲
۲- پیشینه تحقیق	۱۵
۲-۱- مروری بر کارهای گذشته	۱۶
۲-۲- جمع‌بندی	۳۹
۳- مبانی نظری	۴۱

- ۳-۱- مقدمه ۴۲
- ۳-۲- نویزهای مخلوط شده با سیگنال EEG و نحوه کاهش اثر آنها ۴۲
- ۳-۲-۱- امواج ناخواسته زیستی ۴۳
- ۳-۲-۲- امواج ناخواسته محیطی ۴۳
- ۳-۳- تجزیه و تحلیل طیفی سیگنال‌های متغیر ۴۴
- ۳-۳-۱- تبدیل فوریه زمان کوتاه (STFT) ۴۴
- ۳-۳-۲- استخراج ویژگی به روش تبدیل موجک [۳۶] ۴۵
- ۳-۳-۳- معرفی انواع موجک ۴۶
- ۳-۴- استخراج ویژگی به روش تجزیه حالت تجربی ۴۸
- ۳-۴-۱- ویژگی‌های زمانی از تحلیل IMFها ۵۰
- ۳-۴-۲- ویژگی‌های طیفی از تحلیل IMFها ۵۰
- ۳-۵- ماشین بردار پشتیبان (SVM) ۵۳
- ۳-۵-۱- ماشین بردار پشتیبان خطی در حالت جدایی‌پذیر ۵۳
- ۳-۵-۲- ماشین بردار خطی در حالت جدایی‌ناپذیر ۵۶
- ۳-۵-۳- ماشین بردار غیرخطی ۵۸
- ۳-۵-۴- تابع کرنل ۶۰
- ۳-۶- طبقه‌بند بر پایه‌ی شبکه‌ی عصبی ۶۰
- ۳-۷- جمع‌بندی ۶۲
- ۴- روش پیشنهادی ۶۳

۶۴	۱-۴- مقدمه
۶۶	۲-۴- پیش پردازش
۶۸	۳-۴- استخراج ویژگی به روش EMD
۷۱	۴-۴- استخراج ویژگی به روش STFT
۷۵	۵- نتایج
۷۶	۱-۵- داده EEG ثبت شده برای بررسی میزان خستگی
۸۱	۴-۵- استخراج ویژگی به روش تجمیع ویژگیهای EMD و STFT
	۵-۵- نتایج مقایسه روش پیشنهادی با روش‌های دیگر با استفاده از دو مدل طبقه‌بند FF-ANN و SVM
۸۳	۸۳
۸۸	۷-۵- جمع‌بندی
۸۹	۶- نتیجه‌گیری و پیشنهادات
۹۰	۱-۶- نتیجه‌گیری
۹۱	۲-۶- پیشنهادات برای کارهای آینده

فهرست جدول‌ها

- جدول ۱-۲: ارزیابی عملکرد طبقه‌بند شبکه‌های عصبی مصنوعی [۲۹] ۲۱
- جدول ۲-۲: انتخاب بهترین ویژگی‌ها مبتنی بر روش RF-RFE [۳۰] ۲۳
- جدول ۳-۲: ارزیابی عملکرد طبقه‌بندهای مختلف [۳۱] ۲۵
- جدول ۴-۲: مقادیر P-Value در آزمایش T-test برای مقایسه دو حالت نرمال و خسته در کانال‌ها [۴۱] ۳۱
- جدول ۵-۲: نتایج طبقه‌بندی ویژگی‌ها [۴۲] ۳۲
- جدول ۶-۲: مقایسه عملکرد روش میو با روش‌های پیشین [۴۶] ۳۶
- جدول ۷-۲: وزن ده الکتروود براساس مقدار وزن ۷ برای هر فرد [۴۷] ۳۸
- جدول ۸-۲: عملکرد چهار طبقه‌بندی به دست آمده با ترکیب ویژگی آنترپی در مقایسه با ویژگی پارامتر AR بر اساس داده‌های آموزش و آزمایش [۴۷] ۳۹
- جدول ۱-۵: مقایسه روش پیشنهادی با روش‌های دیگر بر اساس دو طبقه‌بند ANN و SVM برای ۴ کانال ۸۳
- جدول ۲-۵: مقایسه روش پیشنهادی با روش‌های دیگر بر اساس دو طبقه‌بند ANN و SVM برای ۱۰ کانال ۸۵
- جدول ۳-۵: عملکرد دو طبقه‌بند ANN و SVM برای مقایسه دو ویژگی EMD و روش پیشنهادی برای ۴ کانال ۸۶
- جدول ۴-۵: مقایسه روش پیشنهادی با روش‌های پیشین ۸۷

فهرست اشکال

- شکل ۱-۱: یک نمونه سیگنال EEG ثبت شده از ۲۴ کانال ۴
- شکل ۲-۱: کلاهیگ الکترودی برای ثبت EEG ۵
- شکل ۳-۱: نمایش مکان الکترودها با استفاده از اسم هر الکتروود- مکان الکترودها بر اساس سیستم ۲۰-۱۰ انتخاب شده است [۱۰]. ۶
- شکل ۴-۱: باندهای فرکانسی EEG [۱۱]. ۸
- شکل ۱-۲: مقایسه پارامترهای موجک EEG [۳۱]. ۲۴
- شکل ۲-۲: مقایسه پارامترهای ApEn و KC برای دو باند فرکانسی آلفا و بتا در دو حالت قبل و بعد از خستگی [۳۲]. ۲۶
- شکل ۳-۲: دقت طبقه‌بند LDA براساس چهار الگوریتم مختلف [۴۵]. ۳۵
- شکل ۴-۲: گراف ۴ ناحیه‌ی کانال توسط ۱۰ الکتروود مبتنی بر وزن در جدول ۲-۶ [۴۷]. ۳۸
- شکل ۱-۳: تبدیل موجک گسسته: $g[n]$ فیلتر بالاگذر و $h[n]$ فیلتر پایین‌گذر [۵۰]. ۴۸
- شکل ۲-۳: دیاگرام بلوکی الگوریتم EMD ۵۲
- شکل ۳-۳: جداکننده‌ی خطی SVM [۵۷]. ۵۴
- شکل ۴-۳: نمونه‌های جدایی ناپذیر به‌صورت خطی [۵۷]. ۵۷
- شکل ۵-۳: نمونه‌ای از نگاشت داده‌ها به‌منظور جداسازی غیرخطی داده‌ها [۵۸]. ۵۹
- شکل ۶-۳: شبکه عصبی پرسپترون چند لایه ۶۱
- شکل ۱-۴: دیاگرام بلوکی روش پیشنهادی ۶۵
- شکل ۲-۴: (الف) سیگنال‌های EEG پیش پردازش نشده برای حالت نرمال - (ب) سیگنال‌های EEG پیش پردازش نشده برای حالت خسته ۶۷
- شکل ۳-۴: (الف) سیگنال‌های EEG پیش پردازش شده برای حالت نرمال - (ب) سیگنال‌های EEG

پیش پردازش شده برای حالت خسته	۶۸
شکل ۴-۴: (الف) IMF های به دست آمده از پنجره اول سیگنال - (ب) IMF های به دست آمده از پنجره پنزدهم سیگنال	۷۰
شکل ۴-۵: طیف اسپکتوگرام مربوط به کانال T5 برای یک سیگنال EEG در حالت نرمال	۷۲
شکل ۵-۱: خروجی طبقه‌بند شبکه عصبی FF-ANN به ازای بردار ورودی ویژگی EMD	۷۷
شکل ۵-۲: منحنی‌های ROC طبقه‌بند شبکه عصبی FF-ANN به ازای ویژگی‌های EMD	۷۹
شکل ۵-۳: خروجی طبقه‌بند شبکه عصبی FF-ANN به ازای بردار ورودی ویژگی STFT	۸۰
شکل ۵-۴: منحنی‌های ROC طبقه‌بند شبکه عصبی FF-ANN به ازای ویژگی‌های STFT	۸۱
شکل ۵-۵: خروجی طبقه‌بند شبکه عصبی FF-ANN به ازای ویژگی‌های حاصل از ترکیب EMD و STFT	۸۲
شکل ۵-۶: منحنی‌های ROC طبقه‌بند شبکه عصبی FF-ANN برای ویژگی‌های ترکیب شده EMD و STFT	۸۲
شکل ۵-۷: نمودار میله‌ای مربوط به عملکرد دو طبقه‌بند FF-ANN و SVM برای ۴ کانال	۸۴
شکل ۵-۸: نمودار میله‌ای مربوط به عملکرد دو طبقه‌بند ANN و SVM برای ۱۰ کانال	۸۵

فصل اول

۱- مقدمه

مفهوم خستگی ذهنی برای اولین بار توسط گرنجدین^۱ مطرح شد [۱]، که به طور کامل خستگی ذهنی را از خستگی فیزیکی متمایز کرد. او علت خستگی بدنی و ذهنی را به ترتیب کاهش عملکرد سیستم‌های عضلانی و مغزی بیان کرد.

مطالعات به دفعات نشان داده‌اند که کمبود خواب و اختلال ریتم فیزیولوژیک می‌تواند جنبه‌های مختلف توانمندی و قابلیت‌های انسان را تحت تأثیر قرار دهد، به گونه‌ای که با افزایش خواب آلودگی خلق و خوی انسان را به هم ریخته و سطح عملکرد را به طرز قابل توجهی تضعیف می‌کند. وقوع این آسیب‌ها به راحتی زمینه بروز خطاهای انسانی و حوادث را فراهم نموده و ممکن است سایر افراد جامعه را در معرض خطر قرار دهد. بطور مشابه خستگی و ایجاد اختلال در خواب شبانه نیز یکی از عوامل تاثیر گذار بر تواناییهای فرد بوده و یکی از مهمترین عوامل وقوع تلفات جاده‌ای می‌باشد. با توجه به تحقیقات متعدد تقریباً ۳۵-۴۵٪ حوادث جاده‌ای به دلیل خستگی ذهنی رخ داده است [۳،۲].

این نوع از خستگی لزوماً فیزیکی نیست اما ممکن است فعالیت عادی شخص را تحت تأثیر قرار دهد. برخی از این اثرات شامل کاهش پشتکار، ضعف در برنامه‌ریزی [۴]، کاهش انگیزه، ضعف در نظارت بر عمل [۵،۶] و از همه مهمتر کاهش تمرکز افراد هستند. مشاغل با ساعت کار طولانی، کمبود استراحت و اختلال خواب که امروزه به یکی از شایع‌ترین بیماری‌های بشری تبدیل شده است، همگی در افزایش خستگی و اثرات ناشی از آن نقش دارند. در عین حال تغییر شکل زندگی، تغذیه نامناسب و فعالیت زیاد بدنی در ایجاد خستگی زودرس نقش دارند. امروزه مشاغل پر خطر بی‌شماری مانند حمل و نقل هوایی، امور نظامی و صنعتی بسیاری وجود دارند که در آنها افراد در طول روز با اعمال پیچیده سر و کار دارند و بایستی هوشیاری خود را در سطح قابل قبولی حفظ کنند. مدیریت خستگی نه تنها

^۱ Grandjean

برای افزایش بهره‌وری بلکه برای رعایت بهداشت شغلی نیز بسیار مهم است بطوریکه بسیاری از حوادث و پیش‌آمدهای مرتبط با خستگی معیاری از عملکرد پایدار محسوب می‌شوند [۷].


۱-۲- سیگنال الکتروانسفالوگرام

عبارت EEG، مخفف کلمه Electroencephalography است که ثبت فعالیت الکتریکی مغز در یک فاصله زمانی کوتاه را نشان می‌دهد. سیگنال EEG از جمله سیگنال‌های حیاتی است که رفتارهای پیچیده‌ی مغزی با دامنه‌ی کوچک دارد. محدوده‌ی دامنه‌ی این سیگنال حدود ۵۰ تا ۱۰۰ میکروولت تغییر می‌کند. با توجه به اینکه سیگنال‌های EEG سیگنال‌های ولتاژ پایین هستند و به راحتی تحت تاثیر نویزها که آرتیفکت^۱ نام دارند، قرار می‌گیرند. نویزهای EOG^۲ و EMG^۳ تا حد زیادی بر روی سیگنال EEG تاثیر می‌گذارند و ممکن است منجر به نتایج اشتباه در تجزیه و تحلیل داده‌ها بشوند. دامنه‌ی سیگنال EOG در محدوده ۵۰ تا ۲۰۰ میکروولت و برای سیگنال EMG نیز معمولا در محدوده ۲۰ تا ۲۰۰ میکروولت است. همچنین محدوده فرکانسی سیگنال‌های EEG ۰/۵ تا ۵۰ هرتز، سیگنال‌های EOG ۰ تا ۲۰ هرتز و برای EMG ۱۰ تا ۲۰۰۰ هرتز است [۸]. بنابراین واضح است هارمونیک‌های سازنده EEG با نویزهای EOG و EMG همپوشانی دارد. یکی از مهمترین ویژگی‌های سیگنال EEG نالیستا بودن آن است. علت این موضوع تغییر عوامل فیزیولوژیکی سیگنال EEG متناسب با زمان و تطبیق آن با محیط اطراف است. شکل ۱-۱ نمونه‌ای از یک سیگنال EEG را نشان می‌دهد.

^۱ Artifacts

^۲ Electrooculography

^۳ Electromyography



شکل ۱-۱: یک نمونه سیگنال EEG ثبت شده از ۲۴ کانال

۱-۳- تاریخچه و نحوه ثبت سیگنال EEG

در اوایل ۱۹۳۰ با افزایش تعداد آزمایشگاه‌های ثبت و بررسی EEG، روش‌ها و نحوه تفسیر فعالیت‌های ثبت شده از این سیگنال با سرعت چشمگیری پیشرفت کرد. بعدها امکان ثبت همزمان سیگنال از مناطق مختلف سطح سر میسر و با کمک آن حضور فعالیت‌های محلی مانند ریتم کشف شد.

هانس برگر^۱ [۹] برای اولین بار در سال ۱۹۲۹ سیگنال EEG را از سطح جمجمه انسان ثبت کرد. وی برای ثبت سیگنال، الکترودها را در قسمت جلو و عقب سر قرار داد و تا مدت‌ها از این روش استفاده کرد. اما بعدها مشخص شد که فعالیت‌های مغزی در موقعیت‌های مختلف متفاوت است.

سیگنال EEG با استفاده از یک سری الکترودها که در سطح مغز قرار می‌گیرند، فعالیت‌های الکتریکی مغز را اندازه‌گیری می‌کند. الکترودها به منظور جمع‌آوری ولتاژ در مکان‌های خاصی از مغز

^۱ Hans Berger

قرار می‌گیرند. قبل از اینکه الکترودها در سطح پوست قرار گیرند یک ژل هادی به منظور کاهش مقاومت روی پوست سر مالیده می‌شود، خروجی این الکترودها به ورودی یک تقویت کننده وصل شده و سپس از فیلترهای بالا گذر و پایین گذر عبور داده می‌شود. هدف محققین شناسایی مکان‌هایی از مغز است که در فعالیت‌های بدن نقش مهمی را ایفا می‌کنند. شکل ۱-۲ نمونه‌ای از کلاهک الکترودی برای ثبت سیگنال‌های EEG را نشان می‌دهد.




شکل ۱-۲: کلاهک الکترودی برای ثبت EEG

ثبت الکتروود به دو روش تک قطبی و دو قطبی انجام می‌شود. روش ثبت دو قطبی (که در آن یکی از الکترودها مرجع و دیگری فعال است) فعالیت سلول‌های عصبی مغزی را در ناحیه‌ی محصور بین دو الکتروود نشان می‌دهد. مزیت این روش، حذف اغتشاشات نواحی دیگر مغز به وسیله مد مشترک تقویت کننده‌ی تفاضلی است. در روش ثبت تک قطبی فعالیت مغزی درست در محل نصب الکترودها همراه با اغتشاشات نواحی دیگر ثبت می‌شود. معمولاً در این روش استخوان ماستوئید گوش به‌عنوان مرجع در نظر گرفته می‌شود؛ اما در بعضی موارد الکتروود مرجع وجود نداشته و ولتاژ مرجع از متوسط‌گیری ولتاژ تمام کانال‌ها به‌دست می‌آید.

در سال ۱۹۴۹ این سیستم به‌عنوان سیستمی با امکان مقایسه نتایج ثبت شده‌ی امواج مغزی معرفی شد. این اندازه‌گیری قبل از آن نیز در بسیاری از سیستم‌ها انجام می‌شد، اما معمولاً فاصله

استاندارد بین الکترودها برای هر بیمار متغیر بود. سازگاری و تکرارپذیری این روش موجب شد تا در آزمایشات مختلف از جمله مطالعات در مورد کودکان در حال رشد و اندازه‌گیری پتانسیل‌های برانگیخته به کار گرفته شود. معمولاً ثبت سیگنال‌های EEG براساس سیستم ۱۰-۲۰ بین‌المللی استفاده می‌شود. شکل ۱-۳ محل قرار گرفتن الکترودها در یک سیستم ۱۰-۲۰ را نشان می‌دهد.



شکل ۱-۳: نمایش مکان الکترودها با استفاده از اسم هر الکترودها - مکان الکترودها بر اساس سیستم ۱۰-۲۰ انتخاب شده است [۱۰].

۱-۴- تحلیل طیف سیگنال EEG

بطور کلی EEG از پنج طیف اصلی عمده تشکیل شده است که دارای محدوده فرکانسی مختلف هستند. این باندهای فرکانسی، آلفا (α)، تتا (θ)، بتا (β)، دلتا (δ) و گاما (γ) نامیده می‌شوند. این امواج به شرح زیر هستند.

۱-۴-۱- امواج دلتا

امواج دلتا در محدوده فرکانسی ۰/۵-۴ هرتز قرار دارند. معمولاً این امواج مربوط به خواب عمیق هستند ولی ممکن است در حالت بیداری نیز وجود داشته باشند. احتمال اینکه سیگنال‌های آرتیفکت

ایجاد شده به وسیله عضلات بزرگ گردن و فک با امواج دلتا اشتباه گرفته شوند، وجود دارد [۱۱].

۱-۴-۲- امواج گاما

فرکانس های بالاتر از ۳۰ هرتز (معمولاً تا ۴۵ هرتز) مربوط به محدوده موج گاما است (گاهی اوقات موج بتا سریع نامیده می شود). اگر چه دامنه این ریتمها بسیار کم و وقوع آنها نادر است، اما ثبت آنها می تواند برای تشخیص برخی از بیماری های مغزی مفید باشد [۱۲].

۱-۴-۳- امواج تتا

فرکانس امواج تتا در محدوده ۴-۷/۵ هرتز قرار دارد. امواج تتا اغلب با فرکانس های دیگر همراه است و به نظر می رسد که این نوع ریتمها در هنگام تغییر حالت هوشیاری به خواب آلودگی ظاهر می شوند. همچنین این امواج ممکن است در طی پریشانی و ناامیدی در افراد بالغ نیز ظاهر شود [۱۳].


۱-۴-۴- امواج آلفا

به طور معمول امواج آلفا در نیمه عقبی و بالاتر از نواحی گوشه ای مغز یافت می شوند. این امواج در تمام قسمت های لوب های عقبی یافت می شوند. فرکانس امواج مغزی آلفا در محدوده ۸-۱۳ هرتز و دامنه آن کمتر از ۵۰ میکرو ولت است. با این حال، در موارد نادر ممکن است به صورت امواج تیز ظاهر شود. یعنی زمانی که میزان توجه فردی کم شود به این معناست که دامنه امواج در باند آن زیاد شده است [۱۴].

۱-۴-۵- امواج بتا

موج بتا فعالیت الکتریکی مغز در محدوده فرکانسی ۱۴ تا ۲۰ هرتز را نشان می دهد و دامنه آن معمولاً کمتر از ۳۰ میکرو ولت است. این موج یک ریتم بیداری معمول در مغز افراد بزرگسال است که با تفکر و توجه فعال، تمرکز بر محیط پیرامون و ممکن است در سطوح بالا در افراد مضطرب به وجود بیاید. فعالیت موج بتا به صورت ریتمیک بوده و عمدتاً در مناطق پیشانی و مرکزی مغز در طی یک فعالیت

زیاد سیستم عصبی یا تنش‌های عصبی دیده می‌شود. شکل ۴-۱ چهار ریتم طبیعی و غالب مغز را نشان می‌دهد [۱۱].



شکل ۴-۱: باندهای فرکانسی EEG [۱۱].

۵-۱- انواع الگوهای مغزی

از آنجا که حسگر مناسبی برای اندازه‌گیری مستقیم فعالیت‌های ذهنی وجود ندارد، اندازه‌گیری فعالیت الکتریکی سلول‌های عصبی، تنها راه ممکن استخراج ذهنیت است. برای این منظور یک سلول عصبی را که با توجه به فرکانس سطح تحریک شده خود یک جریان الکتریکی تولید می‌کند را در مکان خاصی از مغز در نظر می‌گیرند. به این ترتیب فعالیت الکتریکی این سلول عصبی نسبت به زمان، مکان و فرکانس تغییر می‌کند.

فعالیت‌های ذهنی مختلفی با ویژگی‌های نورولوژیکی شناخته شده وجود دارند و می‌توانند انتخاب مناسبی برای سیستم‌های خستگی ذهنی باشند. در واقع ویژگی‌های نورولوژیکی به گروهی از

الگوهای مغزی گفته می‌شود و به طور کلی به دو دسته الگوهای درون‌زا و الگوهای برون‌زا تقسیم‌بندی می‌شوند. الگوهای برون‌زا شامل پتانسیل‌های برانگیخته مانند P₃₀₀ و پتانسیل پایدار^۱ SSVEP، و الگوی درون‌زا شامل پتانسیل وابسته به حرکت^۲ MRP و نوسانات خود جوش مانند ویژگی‌های نوسانی ERD^۳ و ERS^۴ هستند. تفاوت اصلی این دو گروه در این است که الگوهای برون‌زا بر مبنای تحریک خارجی و الگوهای درون‌زا به صورت خود جوش و بدون اعمال تحریک خارجی و ارادی در مغز ایجاد می‌شوند.

۱-۵-۱-۱- پتانسیل وابسته به رخداد یا ERP^۵

ERP در واقع بررسی واکنش مغز به محرک‌ها در کمتر از یک ثانیه است و امکان ارزیابی کارکرد مغز در بیماران مبتلا به اختلالات شناختی را فراهم می‌آورد. در این روش با دادن یک تحریک مناسب (دیداری، شنیداری، شناختی و...) به فرد، سیگنال مغزی EEG ناشی از ادراک آن تحریک ثبت می‌شود. به این صورت که در یک آزمون ERP فعالیت مغزی فرد حین انجام یک تکلیف دیداری یا شنیداری ثبت می‌شود. از آنجا که ثبت فعالیت مغزی از طریق کلاهی که بر روی سر فرد قرار می‌گیرد، انجام می‌شود، بنابراین ERP به وسیله سه نوع تحریک کلی بصری، شنیداری و حرکتی ایجاد می‌شوند. بر اساس مدل پذیرفته شده هانس برگر، پتانسیل‌های وابسته به رخداد سیگنال‌هایی هستند که به وسیله جمعیت سلول‌های عصبی در زمان، نسبت به یک رخداد خاص تولید می‌شوند.

۱-۵-۱-۲- پتانسیل P₃₀₀

پتانسیل P₃₀₀، پتانسیل بسیار معروفی است که از شناخت آن مدت زمان زیادی نمی‌گذرد. در انجام پروژه‌های مربوط به علوم شناختی، مقالات زیادی بر اساس این پتانسیل مورد استفاده قرار گرفته

^۱ Steady state visual evoked potential

^۲ movement- related potential

^۳ event-related desynchronization

^۴ event-related synchronization

^۵ event-related potential

است. برجسته‌ترین مؤلفه در بین مؤلفه‌های شناختی مختلف موجود در ERP فرد، مؤلفه P₃₀₀ بوده که در حقیقت نوعی از ERP و یا به تعبیری دیگر موجی از ERP است که در شرایط خاصی ظاهر می‌شود.

P₃₀₀ از دو پیک معروف P_{300a} و P_{300b} تشکیل می‌شود. این سیگنال از سه کانال موجود بر روی خط وسط سر، یعنی Pz، Cz و Fz ثبت شده است. تحقیقات نشان داده است که در اکثر موارد، P₃₀₀ دارای بیشترین دامنه در ناحیه‌ی پاریتال Pz و کمترین دامنه در ناحیه‌ی فرونتال Fz می‌باشد [۱۵].

۱-۵-۱-۳- پتانسیل وابسته به حرکت (MRP)

انجام حرکات ارادی اندام‌ها باعث ایجاد پتانسیل وابسته به حرکت یا MRP در ناحیه‌ی ما قبل مرکزی قشر مغز که شامل ناحیه موتور تکمیلی^۱ (SMA) و ناحیه موتور اصلی^۲ (PMA) است، می‌شود. پتانسیل وابسته به حرکت تنها پتانسیل وابسته به رخدادی است که بدون نیاز به تحریک خارجی و به صورت درون‌زا با انجام حرکات بدن و یا تصور انجام آنها در سیگنال مغزی به وجود می‌آید.

۱-۵-۱-۴- الگوهای ERD و ERS

بر اساس نتایج پژوهش‌های حسی، حرکتی و شناختی مغز، باندهای مغزی با فرکانس بالا از جمله باندهای آلفا و بتا و در برخی موارد نیز گاما، در زیر باندهای فرکانسی ویژه و در نواحی خاصی از مغز دچار تغییرات آشکار می‌شوند. این تغییرات نوسانی به دو دسته‌ی (ERD) و (ERS) تقسیم‌بندی می‌شوند. هر دو نوع تغییر مانند پتانسیل‌های وابسته به رخداد، نسبت به زمان وقوع رخداد هم‌زمان اما غیر هم فاز هستند. به این معنی که این تغییرات همیشه در طول یک بازه زمانی معین نسبت به زمان شروع رخداد بروز می‌کنند ولی علامت دامنه‌ی آنها مانند پتانسیل‌های وابسته به رخداد همیشه مثبت

^۱ Supplementary Motor Area

^۲ Primary Motor Area

و منفی نیست. در واقع ناهمفازی وابسته به رخداد همان کاهش انرژی در ریتم‌های مغزی است که به دلیل فعال شدن شبکه‌های عصبی در فاز قبل و یا بعد از انجام حرکت در نواحی خاصی از قشر مغز دیده می‌شود.

۱-۶- تعریف مسئله

بطور کلی مطالعات اخیر نشان می‌دهند که سطح خطر به سه عامل انجام فعالیت در طول شب، افزایش مدت زمان کار در طول روز و نامنظم بودن ساعات کاری بستگی دارد. امروزه روش‌های بسیاری برای مطالعه بر روی خستگی ذهنی از جمله بررسی شاخص‌های رفتاری و یا سنجش‌های ذهنی مانند زمان واکنش، نرخ خطا، میزان دقت و حساسیت پیشنهاد شده است. در ارزیابی‌های روانشناسی توجه، معمولاً شاخص‌هایی مانند زمان واکنش^۱، نرخ خطای کمیسیون^۲، و خطاهای هشدار^۳ و... استفاده می‌شود [۱۶،۵].

اخیراً در برخی از مطالعات از سیگنال‌ها EEG برای ارزیابی خستگی در طول فعالیت‌های ذهنی استفاده شده است [۱۸،۱۷،۵]. در این تحقیقات از ویژگی‌های سیگنال مغزی در حوزه زمان، فرکانس یا هردو به منظور تشخیص خستگی استفاده می‌شود. بعنوان مثال، تغییرات طیفی سیگنال EEG یکی از علائم کاهش هوشیاری محسوب می‌شود [۲۱،۱۹]. لازم به ذکر است که شاخص‌های رفتاری و یا سنجش‌های ذهنی دارای محدودیت‌هایی نیز هستند، برای مثال ثبت لحظه ای نوسانات خستگی با این روش‌ها ممکن نیست و علاوه بر آن ممکن است که نتایج تحت تأثیر احساسات افراد قرار گیرد.

بررسی تحقیقات انجام شده در این زمینه حاکی از تفاوت‌های چشمگیر بین الگوریتم‌های فعلی و قبلی تشخیص خستگی بر اساس EEG است. اخیراً هدف از تحقیقات، انتخاب معیارهای صحیح‌تر برای ارزیابی وضعیت خستگی افراد است. اگر چه شاخص‌های فیزیولوژیکی متعددی برای توصیف

^۱ reaction time

^۲ commission error

^۳ false alarm error

حالت‌های خستگی فردی در دسترس است، ولی نتایج نشان می‌دهند که سیگنال‌های EEG قابل اعتمادترین روش برای تشخیص خستگی ذهنی هستند [۲۲].

با توجه به مطالب ذکر شده و لزوم انجام تحقیقات بیشتر در زمینه بررسی شاخص‌های خستگی ذهنی با استفاده از سیگنال‌های حیاتی، هدف از این تحقیق تشخیص خستگی ذهنی با استفاده از سیگنال‌های مغزی می‌باشد.

۱-۷- روش پیشنهادی

داده‌های استفاده شده در این پایان‌نامه شامل سیگنال‌های ثبت شده توسط ۴۰ الکتروود EEG از ۱۲ شخص راننده می‌باشد. به‌منظور مشخص نمودن میزان خستگی ذهنی، با استفاده از روش تجزیه حالت تجربی^۱ تعدادی از ویژگی‌های برجسته از سیگنال‌های ثبت شده استخراج و سپس به کمک طبقه‌بند ANN و SVM، داده‌ها دسته‌بندی شدند. نتایج بدست آمده نشان می‌دهد که سیگنال‌های بدست آمده از قسمت مرکزی و پیشانی خستگی ذهنی را بیشتر نشان می‌دهند. در این پایان‌نامه از روش ترکیبی EMD و STFT نیز برای استخراج ویژگی به منظور بهبود روش EMD استفاده شد و با استفاده از دو طبقه‌بند SVM و ANN نتایج به‌دست آمده با روش EMD و روش‌های STFT، انرژی موجک و ترکیب WT+STFT مقایسه گردید.

۱-۸- ساختار پایان‌نامه

مطالب عنوان شده در این پایان‌نامه در قالب پنج فصل تدوین شده‌اند. فصل اول شامل مقدمه ای بر تعریف خستگی و نحوه استفاده از سیگنال‌های EEG در تشخیص خستگی می‌باشد. فصل دوم به بررسی مهمترین تحقیقاتی که تاکنون بر روی خستگی ذهنی انجام شده است، می‌پردازد. فصل سوم شامل مبانی نظری است. در این فصل ابتدا روش حذف نویز از داده‌های ثبت شده شرح داده

^۱ Empirical mode decomposition (EMD)

می‌شود و سپس تئوری الگوریتم‌های استفاده شده در روش پیشنهادی بیان می‌شود. در فصل چهارم به توضیح روش پیشنهادی و در فصل پنجم به نتایج آن پرداخته می‌شود. فصل ششم نیز به نتیجه‌گیری و ارائه پیشنهادات می‌پردازد، بصورتیکه نتایج به دست آمده توسط روش پیشنهادی جمع بندی شده و پیشنهادها و مسیرهای جدیدی برای ادامه مسیر تحقیق ارائه می‌شود.

فصل دوم

۲- پیشینه تحقیق

۱-۲- مروری بر کارهای گذشته

از حدود ۲۰۰ سال قبل، متخصصان مغز و اعصاب به دنبال شناسایی وظایف مغز انسان و فعالیت‌های انجام شده در آن بوده‌اند. به‌منظور گسترش روشی برای مقابله با اثر خستگی ذهنی، فیزیولوژیکی و جنبه‌های مختلف آن، ابتدا این پدیده باید به طور کامل شناخته شده و سپس راه‌های بازگشت به حالت عادی شناسایی شود. بر اساس فیزیولوژی عصبی، در بررسی مسئله خستگی ذهنی، پیشانی و ناحیه‌ی اکسیپیتال^۱ مغز نواحی درگیر شده در هنگام بروز خستگی ذهنی هستند [۲۳].

از زمانی که مفهوم خستگی برای اولین بار معرفی شد، روش‌های متفاوتی برای بررسی و شناسایی آن ارائه شده است که به طور کلی می‌توان آنها را به دو گروه اصلی طبقه بندی کرد. روش اول بر پایه تغییرات در سطح آگاهی، زمان پاسخ گویی^۲ و میزان دقت فرد در انجام امور خاص استوار است. مشکل اساسی این تکنیک‌ها این است که چنین تغییراتی لزوماً نشان دهنده خستگی فرد نیست. به عنوان مثال میزان دقت در انجام یک فعالیت خاص تحت تاثیر عوامل خارجی مانند تجربه فرد در انجام آن کار است. روش دوم روشی است که بر پایه سیگنال‌های حیاتی مانند EEG^۳، EMG^۴ و ECG^۵ عمل می‌کند. در بین این روش‌ها به نظر می‌رسد سیگنال EEG معیارهای بهتری از میزان خستگی را ارائه می‌دهد و قدرت تخمین بالاتری برای تشخیص خستگی مغزی دارد [۲۴].

اولین بار در سال ۱۹۹۹ از سیگنال EEG برای مشخص کردن میزان خستگی استفاده شد [۲۵]. در این روش تنها از یک کانال EEG برای تخمین سطح خستگی استفاده شده بود و خروجی آن در هر لحظه عددی بود که مقدار آن متناسب با افزایش مقدار خستگی افزایش می‌یافت. اما با توجه به ماهیت پیچیده سیگنال EEG و خستگی مغزی و با توجه به اینکه این روش تنها از یک کانال

^۱ Occipital

^۲ Reaction time

^۳ Electroencephalogram

^۴ Electromyography

^۵ electrocardiogram

سیگنال EEG برای مشخص کردن خستگی استفاده می‌کرد، این الگوریتم نتایج خوبی ارائه نمی‌کرد. پس از آن روش‌های مختلفی برای تشخیص خستگی مورد بررسی قرار گرفتند که هر یک از استراتژی متفاوتی استفاده می‌کردند.

۲-۲- روش‌های تشخیص میزان خستگی

روش‌های مورد استفاده برای تشخیص خستگی از ساختارهای متفاوتی برای استخراج ویژگی و طبقه‌بندی استفاده می‌کنند که در ادامه به بررسی برخی از این روش‌ها می‌پردازیم. گرایش‌های فناوری و پیشرفت اتوماسیون، اهمیت نحوه اجرای مشاغل خاص که به عملکرد ذهنی بالا مانند پردازش اطلاعات و تجزیه و تحلیل تصمیم‌گیری نیاز دارد را، برجسته نموده است. اغلب متخصصان معتقدند که چنین محیط‌های کاری باعث افزایش فعالیت ذهنی و پیامدهای عمیق خستگی ذهنی و استرس می‌شوند. در نتیجه سنجش و بهبود فعالیت افراد کارمند^۱ و دانش‌ورزان^۲ به عنوان یک چالش و نگرانی اصلی به قوت خود باقی است.

در سال ۱۹۹۴ آکوگبا^۳ [۲۶] طی یک تحقیق تجربی به بررسی روابط نوروفیزیولوژیک خستگی ذهنی کارمندان با استفاده از سیگنال‌های EEG پرداخته است. برای این منظور یک پروژه آزمایشگاهی ۶ ساعته برای شبیه‌سازی خروجی کار طراحی و اجرا شد. در این تحقیق روش‌های به کار رفته برای بررسی خستگی، شامل آزمایشات ذهنی و اندازه‌گیری‌های فیزیولوژیکی مانند خواندن متون استاندارد شده، یافتن راه‌حلی برای مسائل ریاضیات-منطق و ترکیبی از هر دو کار بوده است. دو اندازه‌گیری ابتدایی به دست آمده شامل خروجی کار و امواج مغزی بود. برای تعیین رابطه بین خستگی ذهنی و امواج مغزی، از تبدیل فوریه سریع و آنالیز همبستگی استفاده شده بود. این تحقیق

^۱ white collar worker

^۲ knowledge worker

^۳ Okogbaa

مرحله مهمی برای توسعه مدلی بود که به بررسی ارتباط بین خستگی ذهنی و فاکتورهای عملکرد خروجی، دوره‌های بازسازی بهینه و متغیرهای مربوطه پرداخت. زمانی که این دسته از آنالیزها در فواصل زمانی مشخص (مثلا دقیقه به دقیقه) انجام می‌شوند، پیش بینی زمان مورد نظر برای اقدامات ضروری مانند استراحت یا سایر روش‌ها به منظور کم کردن اثرات ناشی از خستگی و به حداکثر رساندن بهره‌وری را تسهیل می‌کند. یکی از ضعفهای روش پیشنهادی اکوگبا استفاده از تبدیل فوریه سریع بود زیرا تبدیل فوریه معمولاً در تجزیه و تحلیل محتوای طیفی انواع سیگنال‌های زیستی قطعی (نویزدار یا بدون نویز) به کار می‌رود اما در مورد سیگنال‌های با مدت زمان کم عملکرد مناسبی ندارد.

مطالعات متعدد نشان می‌دهند انجام مشاغلی همچون طراحی مهندسی، تشخیص طبی، فرماندهی نظامی و کنترل، طی دوره‌های زمانی ثابت، امکان وقوع خستگی ذهنی و تغییر عملکرد قلب و عروق و نوروفیزیولوژیکی را افزایش می‌دهد. نتایج مطالعات اخیر حاکی از آن است که امکان خوابیدن رانندگان با چشم باز پس از طی مسافت طولانی وجود دارد در حالی که به نظر می‌رسد فرد هیجان زده است. از این رو مشخص نمودن میزان خستگی فرد، نقش مؤثری در کاهش میزان حوادث و افزایش قدرت عملکرد افراد دارد.

خستگی پیامدهای عمده‌ای برای ایمنی سیستم حمل و نقل دارد. در سال ۲۰۰۲ لعل^۱ و کریگ^۲ [۲۷] به بررسی ارتباطات روان شناختی با خستگی به منظور افزایش درک انسان و مدیریت خستگی در صنعت حمل و نقل پرداختند. آنها تغییرات روان شناختی را که طی عمل رانندگی برای رانندگان رخ می‌دهد در یک محیط شبیه‌سازی شده بررسی کردند. نتایج نشان داده است که تغییرات الکتروانسفالوگرافی در حین بروز خستگی به وجود می‌آید و فعالیت دلتا و تتا به طور معنی‌داری افزایش می‌یابد. در ضمن میزان ضربان قلب پس از رانندگی به طور قابل توجهی پایین بود و میزان نور

^۱ LAL

^۲ CRAIG

چشم نیز در حین خستگی دچار تغییر شده بود. بر اساس نتایج به دست آمده افزایش اضطراب، تنش، خستگی و کاهش فعالیت شدید منجر به تغییر شاخص‌های نوروفیزیولوژیک مانند افزایش فعالیت دلتا و تتامی‌شود. در این مطالعه لعل و کریگ به تغییرات ریتم‌های EEG در هنگام رانندگی توأم با خستگی پی بردند اما هنوز هیچ روش مناسبی برای مقابله با خستگی در صنعت حمل و نقل وجود ندارد.

در تحقیقی که در سال ۲۰۰۶ توسط بوکسیم^۱ و همکاران [۲۸] انجام شد اثرات خستگی ذهنی بر رفتار مورد بررسی قرار گرفت. آنها از معیاری به نام خطای منفی وابسته به عمل^۲ (Ne/ERN) استفاده کردند. آنها همچنین از پیک N2 و اجزای^۳ (CNV) برای بررسی خستگی ذهنی در این آزمایش استفاده کردند. وقوع تغییرات ناشی از خستگی در انجام کار که با کاهش دامنه Ne/ERN و N2 همراه است، منعکس کننده ضعف نظارت بر عمل، کاهش دامنه CNV و نشان دهنده تنزل سطح آمادگی پاسخگویی است. در این تحقیق، افزایش سطح انگیزشی افراد مورد آزمایش، موجب تغییر رفتار و فعالیت مغز شده که البته میزان این تغییرات در افراد مختلف متفاوت بوده است. افزایش میزان دقت عملکرد افراد با افزایش دامنه Ne/ERN همراه است، اما افرادی که سرعت پاسخگویی خود را بهبود بخشیده‌اند، دامنه CNV آنها افزایش یافته می‌یابد. در این مطالعه، نمونه‌های مورد آزمایش به دقت بالایی نیاز داشته و به مدت ۲ ساعت به طور مداوم تحت نظارت قرار گرفتند. علاوه بر این، تغییرات رفتاری و الکتروفیزیولوژیکی مشاهده شده، به فرآیندهای انگیزشی و تفاوت‌های فردی ارتباط داده شده است.

نتایج نشان دادند افرادی که دچار خستگی هستند توانایی آنها برای نظارت دقیق بر فعالیت و پاسخگویی کاهش می‌یابد. این اختلالات را می‌توان تا حد زیادی با افزایش پاداش^۴ کاهش داد که بر

^۱ Boksem

^۲ Negative Error related negativity

^۳ Contingent Negative Variation (CNV)

^۴ Rewards

این اساس عدم تعادل بین تلاش و پاداش را می‌توان به عنوان یکی از عوامل خستگی ذهنی در نظر گرفت. عملکرد پیوسته در یک بازه طولانی مدت، نیازمند حفظ دقت و تلاش فرد در یک سطح مطلوب است. زمانی که میزان پاداش کم می‌شود، فرد تمایلی به ادامه کار نداشته و دچار خستگی می‌شود. اما با افزایش پاداش در انتهای کار، مجدداً سطح کار و پاداش متعادل شده و باعث بهبود عملکرد فرد می‌شود.

در سال ۲۰۰۶ کینگ^۱ و همکاران [۲۹] خستگی ذهنی یک راننده را با استفاده از سیستم شبکه عصبی مصنوعی^۲ مورد بررسی قرار داده است. در این سیستم اطلاعات EEG به دست آمده از ۲۰ راننده حرفه‌ای و ۳۵ راننده غیرحرفه‌ای و داده‌های دامنه زمانی به صورت باندهای آلفا، بتا و تتا پردازش و سپس برای تشخیص نقطه شروع خستگی به شبکه عصبی ارائه شدند. شبکه عصبی از یک روش بهینه‌سازی آموزشی که با عنوان «تابع گرادیان مقداری»^۳ شناخته می‌شود، بهره می‌برد. این روش زمان مورد نیاز برای آموزش را از طریق بهینه‌سازی الگوریتم «انتشار به عقب استاندارد»^۴ کاهش می‌دهد. در این پژوهش، روشی برای بهبود سرعت همگرایی شبکه‌های عصبی feedforward چندلایه ارائه شده است. روش MGF قابلیت‌های جالبی از جمله کاهش زمان آموزش و تکرار را ایجاد می‌کند؛ این در حالی است که پیچیدگی‌های محاسباتی را به حداقل رسانده و بنابراین تأثیر کمی بر زمان آموزش

^۵ wall clock دارد. در روش پیشنهادی کینگ، خستگی ذهنی رانندگان حرفه‌ای و غیرحرفه‌ای با دقتی در محدوده ۸۱ تا ۸۳ درصد قابل اندازه‌گیری است. مشکل این روش عدم وجود تفاوت آشکار در دقت طبقه‌بندی بین ویژگی‌های خستگی رانندگان حرفه‌ای و غیر حرفه‌ای است. از

^۱ King

^۲ Artificial Neural Network

^۳ Magnified Gradient Function(MGF)

^۴ Standard Back Propagation (SBP)

^۵ wall clock training time

این رو در چنین مواردی مطالعات بیشتری جهت تعیین ویژگی‌های آماری نیاز است. در جدول ۱-۲ شاخص‌های محاسبه شده ارزیابی عملکرد طبقه‌بندی شبکه‌های عصبی مصنوعی در روش کینگ و همکاران نشان داده شده است.

جدول ۱-۲: ارزیابی عملکرد طبقه بند شبکه های عصبی مصنوعی [۲۹]

Driver Test Set	Sensitivity	Specificity	Overall Accuracy
Professional	80.53%	82.44%	81.49%
Non-Professional	84.04%	82.08%	83.06%

شن^۱ و همکاران در سال ۲۰۰۷ روشی برای تشخیص خستگی ذهنی ارائه کردند [۳۰] که در آن ابتدا چهار ویژگی زیر برای هر پنجره از داده محاسبه و سپس برای کاهش بُعد از دو روش استخراج ویژگی RF-INIT^۲ و RF-RFE^۳ استفاده کردند. روش RF-INIT در حقیقت روش انتخاب ویژگی RF موجود است که توسط بریمن^۴ پیشنهاد شده است. شن و همکاران کمترین میزان خطای تست را برای روش RF-INIT با استفاده از ۲۴ ویژگی برتر ۱۲/۳٪ بدست آوردند. اما روش RF-RFE ترکیبی از RF و یک روش حذف ویژگی‌های بازگشتی از الگوریتم SVM-RFE است که کمترین میزان خطای تست برای این روش ۱۵/۱٪ با استفاده از ۶۴ ویژگی برتر به دست آمده است. در نهایت آنها برای جداسازی ویژگی‌ها از یک طبقه‌بند چند سطحی استفاده کردند. آنها در مقاله خود از ویژگی‌های به دست آمده زیر استفاده کردند.

۱- فرکانس مربوط به بیشترین پیک که فرکانس غالب^۵ (DF) نامیده می‌شود.

^۱ Shen

^۲ random forest (RF)-initial feature ranking scheme (INIT)

^۳ random forest (RF)- recursive feature elimination scheme (RFE)

^۴ Breiman

^۵ Dominant Frequency (DF)

۲- توان متوسط مربوط به پیک غالب^۱ (APDP).

۳- فرکانسی که انتظار می‌رود بیشترین انرژی حول آن جذب شده باشد^۲ (CGF) که به صورت زیر محاسبه می‌شود.

$$CGF = \frac{[\sum_i P(f_i) * f_i]}{[\sum_i P(f_i)]} \quad (1)$$

که در آن f_i فرکانس و $P(f_i)$ چگالی تخمین زده شده طیف توان است.

۴- تغییرات یا واریانس در حوزه فرکانس^۳ (FV) که از رابطه زیر محاسبه می‌شود:

$$FV = \frac{\sum_i P(f_i) * f_i^2 - \frac{(\sum_i P(f_i) * f_i)^2}{\sum_i P(f_i)}}{\sum_i P(f_i)} \quad (2)$$

سپس از یک طبقه‌بند چند سطحی برای جداسازی ویژگی‌ها استفاده شد. البته تعداد ویژگی‌ها در روش شن و همکاران زیاد بوده و آنها برای کاهش بُعد از الگوریتم جنگل تصادفی^۴ (RF) استفاده کردند. در روشی که توسط شن ارائه شد، مشخص شد که کدام یک از ویژگی‌های بالا و در چه باند فرکانسی، بهترین ویژگی برای هر کانال به شمار می‌آیند. به طور مثال همانطور که در جدول ۲-۲ دیده می‌شود در بیشتر کانال‌ها ویژگی دوم بهترین ویژگی است. همچنین آنها نشان دادند که روش‌های کاهش بُعد متفاوت ممکن است به تعداد ویژگی‌های متفاوتی نیاز داشته باشند. به طور مثال ممکن است یک روش کاهش بُعد با ۱۷ ویژگی، جواب بهینه تولید کند در حالی که روش دیگر برای ارائه جواب بهینه به ۶۰ ویژگی نیاز داشته باشد. علاوه بر این، در نظر گرفتن تعامل چهار باند فرکانسی برای تفسیر نتایج حاصل از این الگوریتم‌ها، تجزیه و تحلیل نتایج را دشوار می‌کند. جدول ۲-۲ نشان

^۱ Average Power of Dominant Peak (APDP)

^۲ Center of Gravity Frequency (CGF)

^۳ Frequency Variability(FV)

^۴ Random forest(RF)

می‌دهد که کدام یک از ویژگی‌های FV، APDP، CGF و DF در چه باند فرکانسی، بهترین ویژگی برای هر کانال به شمار می‌آیند.

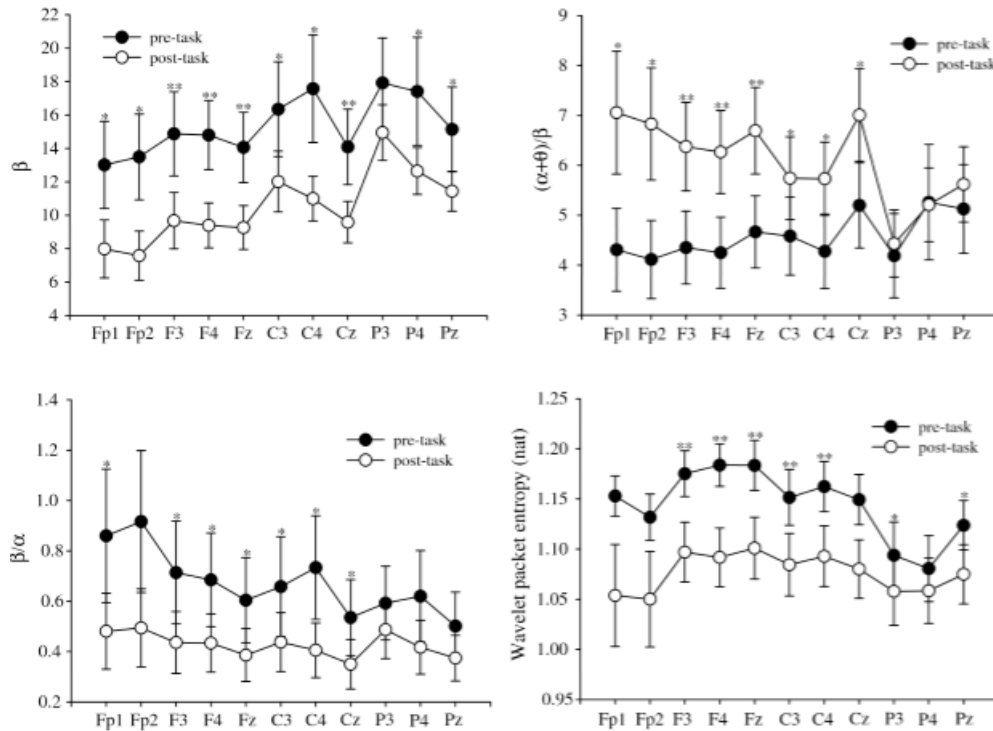
جدول ۲-۲: انتخاب بهترین ویژگی‌ها مبتنی بر روش RF-RFE [۳۰]

Feature Rank	Channel Name	Frequency Band	Feature Name
1	O2	β	APDP
2	P4	β	APDP
3	F3	α	APDP
4	Pz	θ	APDP
5	O2	α	APDP
6	F4	β	APDP
7	O1	β	APDP
8	T3	α	APDP
9	O1	δ	FV
10	T3	β	FV
11	F7	δ	CGF
12	F4	α	APDP
13	O2	θ	APDP
14	F3	θ	APDP
15	T6	δ	FV
16	F8	α	APDP
17	Fz	β	APDP

ژانگ^۱ و همکاران در سال ۲۰۰۹ [۳۱] از پارامترهای موجک EEG، به‌عنوان ویژگی‌های فعالیت مغز در حالت‌های مختلف خستگی استفاده کرده است. در این مطالعه بعد از ۸ مرحله تجزیه ویژگی‌های موجک مبنی بر چهار باند فرکانسی شامل آنتروپی بسته موجک، شاخص‌های نسبت $\frac{\beta}{\alpha}$ ، $\frac{\theta}{\alpha}$ ، $\frac{\alpha+\theta}{\beta}$ را استخراج کردند. سپس از SVM برای طبقه‌بندی ویژگی‌ها استفاده کردند. نتایج به دست آمده نشان می‌دهد که با رخ دادن خستگی، مقادیر متوسط $\frac{\beta}{\alpha}$ و آنتروپی موجک در جلوی پیشانی و الکترودهای مرکزی به طور قابل توجهی کاهش می‌یابد. این در حالی است که پس از اتمام کار مقدار میانگین $\frac{\alpha+\theta}{\beta}$ در الکترودهای جلویی و مرکزی به شدت افزایش می‌یابد. شکل ۱-۲ نتایج

^۱ Zhang

حاصل از مقایسه پارامترهای موجک EEG در دو مرحله‌ی قبل و بعد انجام فعالیت نشان داده شده است.



شکل ۲-۱: مقایسه پارامترهای موجک EEG [۳۱]

ژانگ و همکاران در تحقیق خود از سه مقیاس دقت، ویژگی و حساسیت برای ارزیابی عملکرد پنج طبقه‌بند استفاده کردند. نتایج تحقیق آنها نشان می‌دهد که طبقه‌بند KPCA-SVM نسبت به پنج طبقه‌بند Original-SVM، LPCA-SVM، KPCA-HMM، LPCA-HMM و Original-HMM عملکرد بهتری دارد. همچنین به دلیل ابعاد بالای ویژگی از روش KPCA برای کاهش بُعد استفاده کردند. طبقه‌بندهای KPCA-SVM، Original-SVM و Original-HMM به ترتیب با دقت ۸۵/۶۵٪، ۹۰/۷۱٪ و ۸۵/۶۰٪ سیگنال‌های EEG را طبقه‌بندی می‌کنند.

با توجه به نتایج به‌دست آمده در مقاله ژانگ و همکاران، بهترین روش برای طبقه‌بندی سیگنال‌های EEG، روش‌های SVM و شبکه‌ی عصبی می‌باشند. جدول ۲-۲ نتایج عملکرد

طبقه‌بندهای مختلف را نشان می‌دهد.

جدول ۲-۳: ارزیابی عملکرد طبقه‌بندهای مختلف [۳۱]

Techniques	(Ac, Sp, Se)	n
KPCA-SVM	(0.9004, 0.9053, 0.8949)	35
Original-SVM	(0.9146, 0.9158, 0.9106)	-
LPCA-SVM	(0.5546, 0.4880, 0.6119)	45
KPCA-HMM	(0.8565, 0.8467, 0.8669)	33
Original-HMM	(0.8560, 0.8616, 0.8510)	-
LPCA-HMM	(0.6063, 0.5173, 0.6868)	37

در روش پیشنهادی توسط لیو^۱ و همکاران در سال ۲۰۱۰ [۳۲]، از دو نوع آنتروپی به نام‌های آنتروپی تقریبی (ApEn)^۲ [۳۳،۳۴] و آنتروپی کولموگروف (KC)^۳ [۳۵] استفاده شده است. برای این روش ابتدا باندهای اصلی (آلفا، بتا، تتا و دلتا) سیگنال EEG برای هر پنجره از داده استخراج و سپس مقادیر ApEn و KC برای آن‌ها محاسبه شده است. روش‌های مبتنی بر تحلیل تغییرات آنتروپی^۴ سیگنال EEG، اساس تشخیص و پیگیری تغییرات آنتروپی و پیچیدگی موجود در سیگنال EEG است. روش‌های مختلفی برای مشخص کردن این تغییرات وجود دارد که برخی از آنها محاسبات را به طور مستقیم انجام می‌دهند و سایر روش‌ها پیچیدگی را در فضای حالت محاسبه می‌کنند.

در این تحقیق پس از اعمال دو پارامتر ApEn و KC قبل و بعد از خسته شدن فرد، مشاهده شد که پس از وقوع خستگی پیچیدگی سیگنال در بعضی از باندهای فرکانسی به ویژه آلفا و بتا افزایش یافته است. نتیجه اعمال این مقادیر بر سیگنال‌های به دست آمده قبل و بعد از خستگی در شکل ۲-۲ دیده می‌شود. در این شکل متوسط مقدار این پارامترها در باندهای فرکانسی آلفا و بتا برای افراد و کانال‌های مختلف به منظور ثبت سیگنال قبل و بعد از خسته شدن افراد نشان داده شده است. در این روش نیز بُعد ویژگی سیگنال بالا بوده و برای افزایش صحت این الگوریتم‌ها به روش‌های کاهش

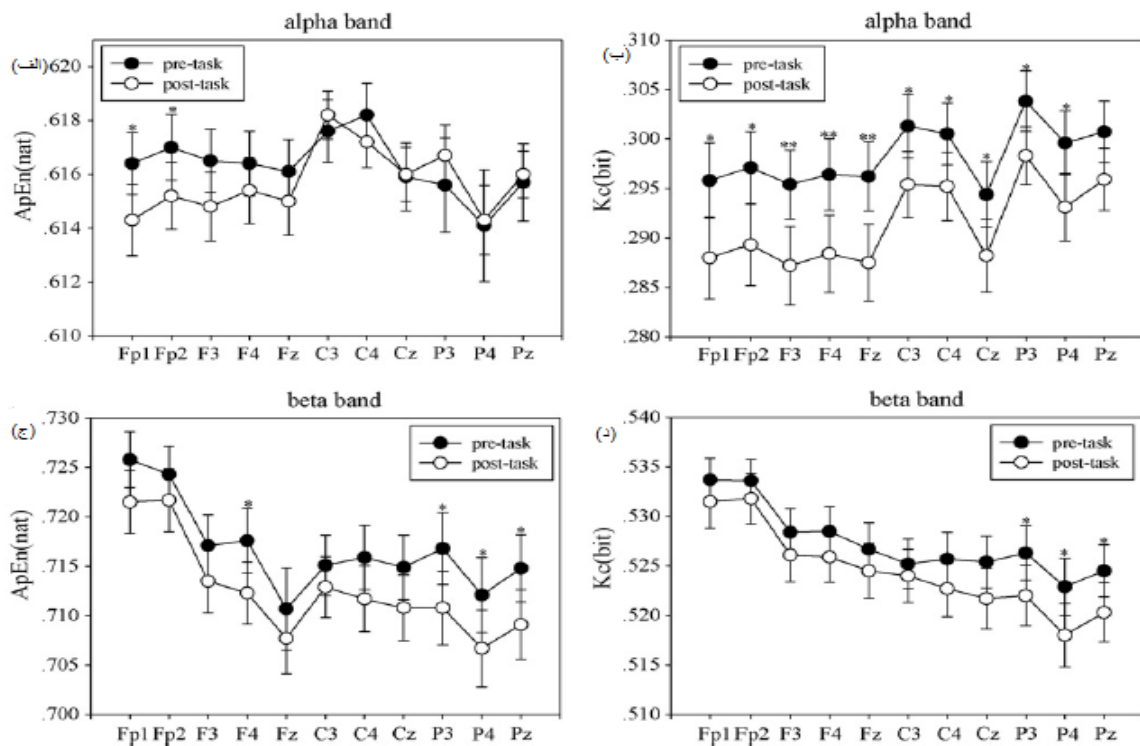
^۱ Liu

^۲ Approximate entropy

^۳ kolmogrov complexity

^۴ Entropy

بعد در داده نیاز است. شایان ذکر است که میزان صحت، به روش مورد استفاده برای کاهش بُعد نیز بستگی دارد.



شکل ۲-۲: مقایسه پارامترهای ApEn و KC برای دو باند فرکانسی آلفا و بتا در دو حالت قبل و بعد از خستگی [۳۲].

خوشابا^۱ و همکاران در سال ۲۰۱۱ [۳۶] اطلاعات مربوط به خواب آلودگی را در طول آزمون رانندگی شبیه سازی شده از یک مجموعه الکتروانسفالوگرام (EEG)، الکتروکولوگرافی (EOG) و سیگنال الکتروکاردیوگرام (ECG)، استخراج کرده اند. در این تحقیق یک روش استخراج ویژگی موجه مبتنی بر اطلاعات مؤثر فازی^۲ برای طبقه بندی سطوح مختلف خواب آلودگی راننده ارائه شده است. این روش اطلاعات دقیق و محتوا را بر اساس رویکرد جدیدی بر پایه میزان عضویت فازی محاسبه می کند. کیفیت ویژگی های استخراج شده بر روی داده های حاصل از ۳۱ راننده در یک آزمایش شبیه سازی مورد ارزیابی قرار گرفت. نتایج تجربی نشان دهنده اهمیت FMIWPT (دقت

^۱ Khushaba

^۲ mutual-information(MI)-based wavelet packet transform (FMIWPT)

طبقه بندی آنها ۹۵-۹۷٪) در استخراج ویژگی‌هایی است که به شدت با سطوح خواب آلودگی مختلف مرتبط هستند. این ویژگی‌ها با استفاده از دو روش، SR^۱ و KSR^۲ کاهش بُعد داده شده و در آخر چهار طبقه بندی متفاوت برای آزمایش میزان خطای طبقه بندی مورد استفاده قرار گرفته است. این طبقه‌بندی‌ها شامل LDA، LIBLINEAR^۳، KNN^۴ و LIBSVM^۵ هستند. دقت طبقه‌بندی با SR تقریباً ۹۵٪ و با KSR در حدود ۹۷٪ به دست آمده است.

در سال ۲۰۱۱ کوچکی [۳۷] روشی برای افزایش سرعت و دقت بررسی خستگی ذهنی ارائه داده است که در آن، اثرات خستگی بر قدرت و مکان منابع مغزی بررسی شده است. هدف اصلی این روش کاهش پیچیدگی محاسباتی روش‌های پیشین بوده است. روش‌های پیشین ابعاد ویژگی استخراج شده بالایی داشته و لذا برای کاهش بُعد و همچنین افزایش دقت به روش‌های کاهش بُعد نیاز دارند. صحت این روش‌ها به روش کاهش بُعد و تعداد ویژگی‌های استفاده شده در آنها بستگی دارد. هدف کوچکی مشخص کردن میزان خستگی افراد با کمک مکان یابی منابع خستگی و همچنین توان این منابع در حین فعالیت ذهنی است. به منظور مکان یابی از روش پرتوسازی استفاده شد. این مکان یاب بهینه‌ساز یک تابع هدف است که نشان دهنده نسبت میان فعالیت و نویز در نقطه هدف است. الگوریتم‌های مکان یابی مختلفی برای EEG پیشنهاد شده‌اند که فعالیت‌های عصبی مناطق مختلف از مغز و ارتباط بین فعالیت‌های الکترومغناطیسی در سر و سیگنال ثبت شده را نشان می‌دهند. پس از مشخص کردن مکان منابع با استفاده از روش پرتوسازی از قدرت منابع به عنوان ویژگی استفاده شده است. سپس از دو روش طبقه‌بندی SVM و K نزدیک‌ترین همسایه، برای آزمایش روش پیشنهادی استفاده شده است. میزان دقت به دست آمده برای SVM تقریباً ۷۸/۶۳ و ANN تقریباً ۷۸/۶۵ است.

^۱ Spectral regression (SR)

^۲ kernel- Spectral regression (KSR)

^۳ Library linear support vector machines

^۴ K-nearest neighbor (KNN)

^۵ Library linear kernel support vector machines

در سال ۲۰۱۱ مهدی آذرنوش [۳۸] از پارامترهایی مانند زمان پاسخ، پاسخ خطا و سیگنال‌های EEG برای نشان دادن تفاوت میان دو آزمایش ثبت شده استفاده کرد و همچنین پویایی نمادین به‌عنوان یک روش کیفی برای استخراج برخی توصیفات کمی مانند آنتروپی انتخاب شد. آنها در روش خود از واکنش زمان پاسخ و سیگنال‌های EEG برای تشخیص حالت‌های مختلف ذهنی استفاده کردند و نشان دادند که تغییرات آنتروپی یک کاهش در پیچیدگی فعالیت‌های مغز مانند وقوع خستگی را نشان می‌دهد. روش آنها بر اساس پاسخ‌گویی افراد به الگوهایی است که بر روی صفحه نمایش کامپیوتر نشان داده می‌شود. این الگوریتم‌ها در چهار آزمایش تکرار شدند و در هر یک از این چهار آزمایش ۶۰۰ الگو ارائه شده است، هر الگو شامل ۳، ۴ یا ۵ تا از نقطه‌های سفید بر روی پس زمینه سیاه صفحه‌ی کامپیوتر است. پاسخ افراد به الگوی شماره ۴ که معادل با الگوی هدف است، پاسخی صحیح بود و همچنین پاسخ افراد به الگوهای ۳ و ۵ نقطه که معادل با الگوی غیر هدف هستند، پاسخی ناصحیح بوده است. نتایج آنالیز غیرخطی زمان پاسخ و سیگنال‌های EEG از فرونتال و لوب مرکزی مغز می‌تواند تفاوت بین حالت توجه و وقوع خستگی را در آزمایشات نشان می‌دهد.

در سال ۲۰۱۲، بورگینی^۱ و همکاران [۳۹] به تجزیه و تحلیل وقوع خستگی ذهنی یا خواب‌آلودگی در حین رانندگی و در یک محیط شبیه‌سازی شده با استفاده از روش EEG با تفکیک بالا و همچنین متغیرهای نوروفیزیولوژیکی مانند ضربان قلب (HR) و سرعت پلک زدن (EBR) پرداخته است. تجزیه و تحلیل فعالیت فیزیولوژیکی و مغزی می‌تواند به فهم نحوه ارائه بازخورد مفید و سیگنال‌های هشدار به رانندگان به منظور جلوگیری از وقوع تصادف کمک کند. نتایج نشان داده است که می‌توان یک شاخص بار کاری (حجم کاری یا تراکم کاری) مغزی بر پایه EEG تعریف نمود که به فعالیت ذهنی راننده در حین رانندگی با درجات مختلف سختی حساس باشد. اساس این شاخص، تخمین افزایش طیف توان EEG در باند تتا در نواحی جلوی مغز و کاهش همزمان آن در باند آلفا در

^۱ Borghini

نواحی جداری (آهیانه‌ای) مغز در حین رانندگی با شرایط دشوار است. نتایج نشان می‌دهند که می‌توان از سیگنال‌های نوروفیزیولوژیکی برای بررسی خستگی ذهنی و حالات فیزیکی رانندگان، خواب‌آلودگی و یا هوشیاری در حین شرایط مختلف رانندگی و چگونگی ارتباط این پارامترها با عملکرد رانندگی بهره برد. مطالعه بورگینی و همکاران به شرح بهبود شاخص بار کاری خستگی ذهنی بر پایه EEG، ادغام اطلاعات آن با شاخص‌های اتونومیک مانند ضربان قلب و سرعت پلک زدن است.

سیستم نظارت بر حالت خستگی «رابط‌های مغز-رایانه منفعل آ.ک.ا»^۱ امکان بررسی دقیق و به موقع حالت شناختی اپراتور را فراهم می‌نماید. در سیستم‌های بر پایه EEG، اندازه‌گیری‌های مرسوم برای ارزیابی سطح بار کاری و برآورد پهنای توان باند در چندین باند فرکانسی مختلف است. خستگی ذهنی ناشی از زمان کاری^۲ افزایشدهنده، به طرز چشمگیری می‌تواند توزیع ویژگی‌های پهنای باند را تحت تأثیر قرار دهد. اگرچه تأثیر خستگی ذهنی بر ارزیابی بار کاری تاکنون مورد بررسی قرار نگرفته است. در سال ۲۰۱۳، رُوی^۳ و همکاران [۴۰] به تجزیه و تحلیل تأثیر WKL^۴ و TOT بر روی ویژگی‌های پهنای باند EEG و همچنین برهمکنش و اثرات آن بر روی فرآیند طبقه‌بندی پرداختند. برای این منظور ۲۰ شرکت‌کننده تحت آزمایشی قرار گرفتند که در آن هر دو فاکتور WKL (کم/ زیاد) و زمان صرف شده در کار (کوتاه/ طولانی) مدوله شده است. آنالیز آماری بر روی سیگنال‌های EEG و اطلاعات موضوعی و رفتاری انجام گرفته است. نتایج به دست آمده، تغییرات معکوس^۵ را بین TOT و WKL در توزیع پهنای باند، و همچنین کاهش تبعیض‌آمیز سطح WKL با افزایش TOT در تعداد تفاوت‌های آماری پهنای باند و اجرای طبقه‌بندی، نشان می‌دهند. طبقه‌بندی با کارایی بالا برای حالت خستگی ذهنی (۹۸/۰۴٪)، از طریق تقویت استاندارد پهنای باند LF با افزایش TOT به دست آمده است؛ اگرچه کاهش چشمگیری در پهنای باند HF مشاهده نشده است. بر این اساس با افزایش بار کار

^۱ brain-computer interfaces (BCI)

^۲ time-on-task (TOT)

^۳ Roy

^۴ mental fatigue on workload (WKL)

^۵ opposite changes

ذهنی، پهنای باند آلفا، خصوصاً در نواحی لوب‌های مرکزی کاهش می‌یابد. در این تحقیق افزایش قابل انتظار پهنای باند تتا در نواحی جلویی به واسطه بار کاری افزایش‌دهنده در شرایط TOT گزارش شده است. این نتایج به بیان تأثیر قابل توجه خستگی ذهنی بر اطلاعات ویژگی EEG کمک می‌کند، تأثیری که منجر به تخریب پیش‌بینی شده و قابل توجه عملکرد طبقه‌بندی می‌شود. علاوه بر این، زمانی که طبقه‌بند بر روی اطلاعات ثبت شده در شرایط مشابه، یعنی TOT طولانی آزمایش شد، کاهش ناچیزی در عملکرد طبقه‌بندی در مقایسه با نمونه TOT کوتاه مشاهده شد. این مشاهدات با افزایش پهنای باند LF، افزایشی که تفاوت‌های ظریف را برای یک طبقه‌بندی خوب از بین می‌برد، قابل تفسیر است.

در سال ۲۰۱۴ ژائو^۱ و همکاران [۴۱]، برای تشخیص خستگی ذهنی به بررسی سیگنال‌های تک کاناله EEG، که اساس آنها تجهیزات جمع‌آوری EEG پرتابل^۲ (قابل انتقال) بودند، پرداختند. علاوه بر این، بازسازی بهینه شده تک باند فرعی الگوریتم بسته کوچک موجک، برای حذف اثرات نامطلوب^۳ فرکانس پیشنهاد شده است. در فرآیند آنالیز سیگنال‌های EEG زمانی که از الگوریتم بسته کوچک سریع استفاده می‌شود، این پدیده نامطلوب به وجود می‌آید. دو پارامتر ویژگی، هشت نسبت انرژی از چهار ریتم EEG، و واریانس ضریب بسته‌های موجک باندهای فرعی مختلف، استخراج شدند. نتایج تجربی نشان دادند که پنج نسبت انرژی و واریانس سه ضریب بسته کوچک باند فرعی، دارای تفاوت چشمگیری بین حالت بیداری و خستگی ذهنی بوده و بنابراین انتخاب این ویژگی‌ها به عنوان شاخص‌های بررسی خستگی ذهنی امکان‌پذیر است. در نتیجه، استفاده از تجهیزات جمع‌آوری EEG پرتابل برای تشخیص خستگی ذهنی به عنوان یک روش مؤثر، عملی و سودمند شناخته می‌شود.

این تحقیق به بررسی روشی پرداخته است که سیگنال‌های EEG تک کاناله از تجهیزات جمع‌آوری پرتابل EEG برای تشخیص خستگی ذهنی استفاده می‌کند. در مقایسه با الگوریتم WPT

^۱ Zhao
^۲ portable
^۳ Aliasing

سریع، الگوریتم ISSBR-WPA به طور مؤثری می‌تواند مشکل فرکانس نامطلوب را حل کند و با دقت زیادی ضریب بسته‌های موجک باندهای فرعی مختلف را استخراج نماید. نتایج نشان می‌دهند که :

۱- باندهای فرعی فرکانس پایین سیگنال‌های EEG $s(7,1)$ ، $s(7,2)$ و $s(7,3)$ مربوط به واریانس

ضریب بسته‌های موجک، به راحتی بین حالت بیداری و خستگی قابل تمایز هستند.

۲- در مطالعه ویژگی هشت نسبت انرژی، ویژگی‌های F_2 ، F_3 ، F_4 ، F_6 و F_8 به عنوان شاخص‌های

مؤثر برای بررسی خستگی ذهنی قابل استفاده هستند.

آنها با استفاده از مقادیر $p - value < 0.05$ تفاوت قابل توجهی بین دو حالت نرمال و

خسته را در کانال‌های مختلف نشان دادند. برای مثال طبق گزارش آنها در جدول ۲-۴

مشاهده می‌شود که کانال F_5 برای همه‌ی افراد نتوانسته تفاوت قابل توجهی بین دو حالت

نرمال و خسته را نشان دهد.

جدول ۲-۴: مقادیر P-Value در آزمایش T-test برای مقایسه دو حالت نرمال و خسته در کانال‌ها [۴۱]

Feature	Subject 1	Subject 2	Subject 3	Subject 4
F_2	0.0264	0.0289	0.0248	0.0232
F_3	0.0429	0.0223	0.0356	0.0214
F_4	0.0116	0.0271	0.0245	0.0302
F_5	0.2628	0.1642	0.1639	0.2642
F_6	0.0313	0.0489	0.0316	0.0452
F_7	0.1315	0.0322	0.0412	0.0283
F_8	0.0364	0.0326	0.0376	0.0246

در سال ۲۰۱۵ وانگ^۱ و همکاران [۴۲] از مدل آنتروپی و ریتم انرژی، برای توصیف پیچیدگی

و بی‌نظمی داده‌های EEG تحت حالت‌های مختلف خستگی ذهنی و از تبدیل موجک برای استخراج

^۱ Wang

ویژگی‌های غیرخطی پارامترهای EEG در حالت‌های مختلف ذهن استفاده کردند و همچنین شبکه‌های عصبی Back-Propagation را برای بهبود کارایی مورد استفاده قرار دادند. از ویژگی‌های ترکیبی ریتم‌های انرژی و مدل آنتروپی نسبت به یک نوع ویژگی تنها، می‌توان برای طبقه‌بندی خستگی ذهنی با دقت بالاتر بهره برد. نتایج حاکی از آن است که با افزایش درجه‌ی خستگی، انرژی نسبی ریتم دلتا افزایش می‌یابد، درحالی که آنتروپی نمونه و انرژی نسبی ریتم آلفا کاهش می‌یابد. طبقه‌بندی سیگنال‌های EEG با استفاده از سه روش از قبیل انرژی، مدل آنتروپی و ترکیب همزمان این دو روش صورت گرفته است.

نتایج نشان می‌دهند که استفاده از روش ترکیبی انرژی و مدل آنتروپی باعث طبقه‌بندی سیگنال‌های EEG با دقت بالاتر می‌شود. جدول ۲-۵ نتایج طبقه‌بندی ویژگی‌ها برای افراد مختلف را نشان می‌دهد.

جدول ۲-۵: نتایج طبقه‌بندی ویژگی‌ها [۴۲]

	Rhythm Energy	Sample Entropy	Both
Subject 1	89.1%	90.5%	99.2%
Subject 2	84.5%	89.4%	98.3%
Subject 3	86.3%	87.6%	98.5%

در سال ۲۰۱۵ لیو^۱ و همکاران [۴۳] یک سیستم تخمین و پیش‌بینی بر پایه EEG را که اساس آن یک شبکه عصبی فازی خود تکاملی برگشت‌پذیر کاربردی^۲ است، به منظور بررسی خستگی ذهنی در حین رانندگی در آزاد راه، طراحی و پیشنهاد کرده‌اند. حالت‌های شناختی رانندگان به طرز چشمگیری ایمنی رانندگی را، خصوصاً در حالت خستگی و یا خواب‌آلودگی که یکی از رایج‌ترین عوامل

^۱ Liu

^۲ Functional-link recurrent self-evolving fuzzy neural network (FL-RSEFNN)

ایجاد خطر شخصی و عمومی است، تحت تأثیر قرار می‌دهد. در این تحقیق، سیستم FL-RSEFNN یک قانون یادگیری نزولی گرادیانی روی خط^۱ (GD) را برای رفع مشکل رگرسیون EEG در دینامیک مغز به منظور پیش‌بینی خستگی ناشی از رانندگی، به کار گرفته است. برای این منظور دینامیک مغز در حین رانندگی در یک محیط واقعیت مجازی شبیه‌سازی شده^۲ (VR) آنالیز شده است. سیستم پیش‌بینی بر پایه EEG با استفاده از روش cross-subject تعمیم یافته، مورد بررسی قرار می‌گیرد. نتایج نشان می‌دهند که FL-RSEFNN نسبت به مدل‌های با سطح بالا^۳ با توجه به استفاده از ساختارهای برگشت‌پذیر یا برگشت‌ناپذیر، برتری دارد.

در مطالعات قبلی، معمولاً محققین حالت شناختی را به عنوان یک فرآیند متراکم و پیوسته در نظر نمی‌گرفتند. برای تقویت عملکرد در کاربردهای حقیقی، استفاده از ساختار برگشت‌پذیر به علت «ویژگی حافظه» یکی از روش‌های مؤثر است. به منظور تعمیم دادن، درستی و صحت cross-subject مورد بررسی قرار گرفت تا تأثیر سیستم تخمین پیشنهادی بر اساس ساختار برگشت‌پذیر تأیید شود. سیستم FL-RSEFNN با روش cross-subject تعمیم یافته مورد بررسی قرار گرفت که نتایج به دست آمده، برتری این سیستم را نسبت به سیستم‌هایی با سطح بالا همچون SVR، SONFIN و TRFN، اثبات می‌کند. با توجه به نتایج تجربی، روش پیشنهادی تأثیر زیادی در پردازش سیستم‌هایی با تنوع زمانی از جمله سیگنال‌های EEG، و کارایی قابل توجهی برای تخمین حالات رانندگی در حین عمل رانندگی دارد.

چای^۴ و همکاران در سال ۲۰۱۶ [۴۴] روشی را برای طبقه بندی مبتنی بر EEG ارائه دادند که در بر اساس آن، خستگی ذهنی ۶۵ فرد سالم قبل و بعد از انجام بار کاری ذهنی مورد بررسی قرار گرفت. این سیستم از روش ترکیبی تجزیه و تحلیل مؤلفه اصلی (PCA) برای کاهش اندازه ۲۶ کانال

^۱ Gradient descent (GD)

^۲ virtual reality (VR)

^۳ state of the art

^۴ Chai

داده EEG، تراکم طیف توان (PSD) به منظور ویژگی استخراج کننده و شبکه عصبی بیزین (BNN) به عنوان طبقه‌بند استفاده می‌کند. پس از اعمال PCA، ابعاد داده‌ها از ۲۶ کانال EEG به ۶ مؤلفه اصلی با بیش از ۹۰ درصد اطلاعات ذخیره شده کاهش می‌یابد. پس از انجام کار میزان خستگی ذهنی با استفاده از شبکه عصبی بیزین با میزان حساسیت ۷۶/۸٪، ویژگی ۷۵/۱٪ و دقت ۷۶٪ به دست می‌آید.

در سال ۲۰۱۶ ژانگ^۱ و همکاران [۴۵] روش اطلاعات متقابل نرمال شده با وزن^۲ را برای انتخاب ویژگی پیشنهاد دادند. معیار W-NMIFS برآورد اطلاعات اضافی را در الگوریتم اطلاعات متقابل بهینه می‌کند و با در نظر گرفتن ویژگی‌های عمومی که در آنالیز EEG استفاده می‌شود، تعدادی از مهمترین آنها را انتخاب می‌کند. به منظور تضمین دقت آزمایش منابع مجموعه داده‌ها از ۱۰ داوطلب و با استفاده از سیستم EEG ۱۰-۲۰ جمع‌آوری شده است. سه عملکرد ذهنی متفاوت برای سه سطح خستگی ذهنی کم، متوسط و زیاد طراحی شده و از طبقه‌بند LDA برای بررسی خستگی ذهنی و مقایسه الگوریتم‌های انتخاب ویژگی متفاوت استفاده شده است. نتایج طبقه‌بندی خستگی ذهنی نشان داد که ویژگی‌های انتخاب شده به وسیله معیار W-NMIFS برای الگوریتم LDA مناسب بوده است. دقت طبقه‌بندی در مقایسه با الگوریتم‌های mRMR^۳، NMIFS^۴ و N-NMIFS^۵ بهینه شده است. این تحقیق نشان داد در مقایسه با ۲۰ عدد از بهترین ویژگی‌های انتخاب شده به وسیله mRMR، NMIFS و N-NMIFS، ویژگی‌های انتخاب شده به وسیله W-NMIFS سازگاری بیشتری با طبقه‌بند LDA دارند. به وضوح می‌توان مشاهده نمود که دقت طبقه‌بندی بهبود یافته است. استفاده از معیار W-NMIFS دقت متوسط به ۷۷/۵٪ و بالاترین میزان دقت به ۹۲/۸٪ رسیده است. ۲۰ ویژگی از میان ۱۶۸۰ ویژگی به وسیله معیار W-NMIFS انتخاب شدند. کانال‌های EEG O1، P4 و O3 و

^۱ Zhang

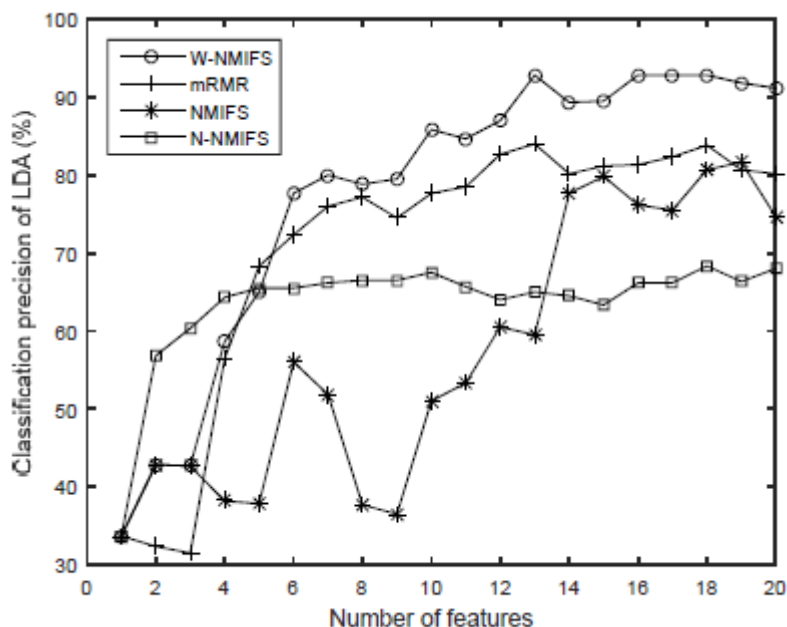
^۲ weighted-normalized mutual information feature selection (W-NMIFS)

^۳ minimal-redundancy-maximal-relevance(mRMR)

^۴ Normalized mutual information feature selection(NMIFS)

^۵ Novel normalized mutual information feature selection(N-NMIFS)

توزیع قدرت باندهای فرکانسی، به طور مؤثر منعکس کننده سطح خستگی ذهنی است. آنتروپی شانون^۱ و قدرت فرکانس غالب نیز می‌توانند به بهبود دقت برای طبقه‌بندی خستگی ذهنی کمک کنند. تفاوت‌های اثرگذار بین باندهای فرکانسی دلتا، تتا، آلفا، بتا و گاما بسیار کم است. حتی با وجود اینکه معیار W-NMIFS برای طبقه‌بندی خستگی ذهنی با استفاده از طبقه‌بند LDA مؤثر است، خستگی‌های ایجاد شده به وسیله وظایف خاص با خستگی‌های روزمره متفاوت است و تعیین ارتباط بین انواع خستگی‌ها به تحقیقات بیشتری در آینده نیاز دارد. شکل ۲-۳ دقت طبقه‌بند LDA را برای چهار ویژگی مختلف نشان می‌دهد.



شکل ۲-۳: دقت طبقه‌بند LDA بر اساس چهار الگوریتم مختلف [۴۵]

ژندونگ میو^۲ و همکاران در سال ۲۰۱۷ [۴۶] یک روش پردازش بر پایه‌ی آنتروپی مبتنی بر داده‌های EEG برای شناسایی خستگی راننده را ارائه کرده‌اند. خستگی راننده یکی از دلایل اصلی تصادفات رانندگی و در عین حال یک فرآیند فیزیولوژیک پیچیده است. با این وجود، هیچ روش مؤثری

^۱ Shonnon

^۲ Zhendong Mu

برای تشخیص خستگی راننده وجود ندارد. به دلیل اینکه سیگنال EEG، پیچیده، ناپایدار و غیر خطی است شاید روش های غیر خطی تجزیه و تحلیل، مانند آنتروپی، مناسب تر باشند. چهار نوع آنتروپی (آنتروپی طیفی، آنتروپی تقریبی، آنتروپی نمونه و آنتروپی فازی) برای استخراج ویژگی ها و شناسایی خستگی راننده استفاده شده است. برای این منظور الگوریتم طبقه بندی الکترودهای انتخابی و یک الگوریتم طبقه بندی بردار پشتیبانی (SVM) نیز پیشنهاد شده است. دقت تشخیص به طور میانگین ۹۸/۷۵٪ به دست آمده است. تجزیه و تحلیل تجربی EEG نشان داد که ویژگی های استخراج شده از الکترودهای T5، TP7، TP8 و FP1 ممکن است عملکرد بهتری را ارائه دهند. با استفاده از الگوریتم طبقه بندی SVM با استفاده از کرنل^۱ تابع پایه شعاعی^۲ نتایج بهتری به دست می آید. ژندونگ میو در مطالعه خود از یک روش مبتنی بر آنتروپی ترکیبی برای مشخص کردن خستگی ذهنی استفاده کرده است. جدول ۲-۶ نشان دهنده بهبود عملکرد روش پیشنهادی آنها نسبت به روش های پیشین است.

جدول ۲-۶: مقایسه عملکرد روش میو با روش های پیشین [۴۶]

Research Group	No. of Subjects	Feature Types	Classifier	Adopted Entropy	ACC
Zhang [2014]	20	EEG+EOG+EMG	Neural network	Approximate	96.50%
Khushaba [2011]	31	EEG+EOG	The fuzzy information based wavelet packet algorithm	Fuzzy	95%
Zhao [2013]	28	EEG	Thershold of ROC curve	Sample	95%
Zhendong Mu	12	EEG	SVM	Combined entropy	98.75%

با این وجود، یکی از مسائلی در آینده باید به آن پرداخته شود، پیچیدگی محاسباتی است که برای استفاده از انواع آنتروپی ها وجود دارد. بنابراین، یکی از اهداف مهم، کاهش پیچیدگی الگوریتم برای تشخیص خستگی راننده در زمان واقعی خواهد بود.

^۱ Kernel

^۲ radial basis function

در سال ۲۰۱۷ مین و همکاران [۴۷] به تشخیص خستگی ذهنی به منظور اهمیتی که پیامدهای ناشی از آن در صنعت حمل و نقل دارد، پرداختند. هدف از تحقیق آنها، تجزیه و تحلیل روشی است که از تلفیق چهار مدل آنتروپی طیفی، آنتروپی تقریبی، آنتروپی نمونه و آنتروپی فازی و همچنین از مدل خودکار رگرسیون^۱ به منظور مقایسه برای استخراج ویژگی استفاده کردند و چندین ناحیه ی کانال را که از اهمیت بالایی در تشخیص دقیق حالت خستگی راننده بر اساس ثبت EEG برخوردارند، ارزیابی کردند.

در این مطالعه، یک روش ساده برای انتخاب الکترود پیشنهاد شده است. در این روش به منظور تعیین الکترودها با اهمیت بیشتر، مقادیر وزن هر الکترود بر اساس میزان دقت آن محاسبه می شود. مراحل اصلی به دست آوردن مقدار وزن v برای i تا الکترود به شرح زیر است:

۱- میزان دقت برای هر الکترود $Acc(i)$ را با استفاده از روش تلفیقی آنتروپی چندگانه بر اساس داده های آموزش توسط طبقه بند SVM محاسبه می شود.

۲- مانند مرحله اول پس از بدست آوردن دقت هر الکترود، میزان دقت هر الکترود نسبت به الکترود دیگر $Acc(ij)$ با استفاده از ویژگی آنتروپی محاسبه می شود. در این مرحله $i \neq j$ و $Acc(ij) = Acc(ji)$ است.

۳- با استفاده از معادله ۲-۳ مقدار وزن هر الکترود (V_i) به دست می آید.

$$V_i = \frac{Acc(i) + \sum_{j=1, j \neq i}^{30} (Acc(ij) + Acc(i) - Acc(j))}{30} \quad 3-2$$

V_i برای الکترودها از ۱ تا ۳۰ محاسبه می شود.

ده نمونه از مهمترین الکترودها که شامل بیشترین وزن برای هر فرد است در جدول ۲-۷ ذکر شده

^۱ Autoregressive (AR)

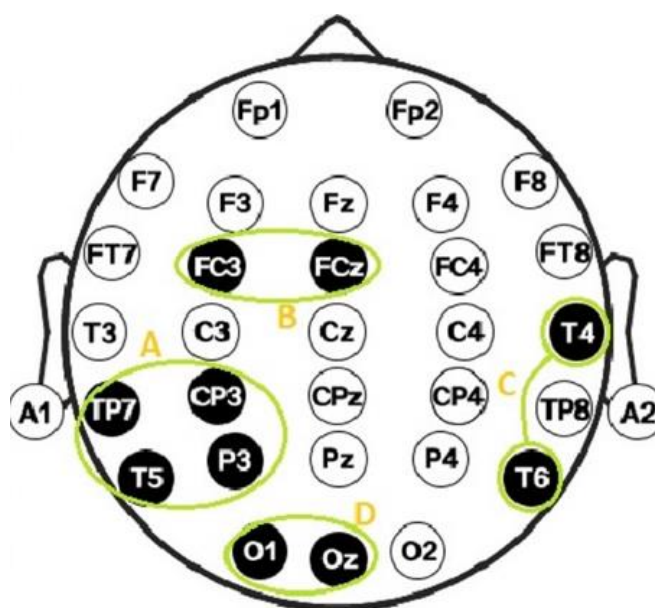
است.

جدول ۲-۷: وزن ده الکتروود براساس مقدار وزن ۷ برای هر فرد [۴۷]

Electrode	T6	P3	TP7	O1	Oz	T4	T5	FCz	FC3	CP3
Sub1	0.91	0.89	0.87	0.95	0.93	0.93	0.89	0.92	0.79	0.89
Sub2	1.01	0.92	1.01	0.98	0.99	0.81	1.01	0.79	0.84	0.90
Sub3	1.06	1.00	1.05	0.81	0.83	0.81	0.80	0.99	0.85	0.75
Sub4	0.99	0.91	1.05	0.88	0.80	0.72	1.05	0.74	0.86	1.02
Sub5	0.89	0.89	0.90	0.95	0.84	0.77	0.98	1.07	1.02	1.06
Sub6	1.03	0.62	0.92	0.67	0.85	1.05	0.85	0.63	0.69	0.59
Sub7	1.09	1.07	0.83	0.77	1.08	1.01	0.97	1.02	0.65	0.52
Sub8	0.68	0.77	0.86	0.82	0.83	0.78	0.90	0.67	1.05	0.73
Sub9	0.68	0.84	0.97	0.58	1.01	0.78	0.73	1.02	1.00	1.00
Sub10	1.13	1.10	0.91	1.12	0.68	0.90	0.54	0.52	1.00	0.80
Sub11	0.97	1.02	0.55	1.11	0.76	0.92	0.60	1.01	0.52	0.77
Sub12	0.95	0.99	0.89	1.07	1.05	0.83	0.99	0.88	0.87	1.06
Average	0.95	0.92	0.90	0.89	0.89	0.86	0.86	0.85	0.84	0.84

در نهایت، مدل ارزیابی برای تشخیص خستگی راننده با چهار طبقه بند بر اساس داده های

EEG از مناطق چهار کانال که مطابق شکل ۲-۴ نشان داده شده‌اند، ایجاد شد.



شکل ۲-۴: گراف ۴ ناحیه‌ی کانال توسط ۱۰ الکتروود مبتنی بر وزن در جدول ۲-۶ [۴۷].

عملکرد چهار طبقه‌بند ماشین بردار پشتیبان، شبکه عصبی انتشار به عقب^۱، جنگل تصادفی^۲

و k نزدیکترین همسایه در جدول ۸-۲ نشان داده شده است.

جدول ۸-۲: عملکرد چهار طبقه‌بندی به دست آمده با ترکیب ویژگی آنترپی در مقایسه با ویژگی پارامتر AR بر

اساس داده‌های آموزش و آزمایش [۴۷].

Classifiers	Selected features using entropy						Selected features using AR					
	Training Data			Testing Data			Training Data			Testing Data		
	Ac	Sn	Sp	Acc	Sn	Sp	Acc	Sn	Sp	Acc	Sn	Sp
SVM	97.0	96.8	96.7	95.6	95.0	95.7	93.9	93.7	94.1	91.3	92.3	90.2
BP	97.6	97.6	97.6	96.8	96.4	97.0	96.8	97.0	96.5	92.9	93.6	92.3
RF	96.9	96.9	97.0	95.2	95.6	95.0	93.3	93.0	93.5	92.7	92.4	92.9
KNN	95.3	95.1	95.4	94.2	94.3	93.9	85.0	85.9	84.0	84.2	85.	82.8

۲-۲- جمع بندی

محققان و پژوهشگران از روش‌های متنوعی برای تشخیص میزان خستگی استفاده کرده‌اند و هر کدام از این روش‌ها از تکنیک‌های متفاوتی برای این منظور بهره می‌برند. علی‌رغم نتایج قابل توجهی که در طول این مسیر به دست آمده است، هنوز هیچ الگوریتمی برای تعیین حالت کلی سطح خستگی در هر فرد به صورت تابعی پیوسته و در زمان به دقیق به دست نیامده است. همچنین روش‌های مختلف دارای محدودیت‌های متفاوت و پیچیدگی‌های زیادی هستند. بنابراین هدف این پروژه بهبود روش‌های موجود با به کارگیری تکنیک‌های مختلف است.

^۱ Back propagation neural network(BP)

^۲ Random forest (RF)

فصل سوم

۳- مبانی نظری

در فصل قبل روش‌های متفاوتی برای بررسی خستگی با استفاده از سیگنال EEG معرفی شد که هرکدام دارای مزیتها و محدودیت‌هایی بودند. بررسی مقالات اخیر در این زمینه نشان می‌دهد که اغلب روش‌ها سعی در یافتن شاخصی دارند که بتواند سطح خستگی را با کیفیت بهتری نشان دهد. هدف بسیاری از آنها، بررسی ویژگی‌های زمانی و فرکانسی سیگنال‌های ثبت شده از افراد است بگونه‌ای که بتوان با دسترسی به ویژگی‌های سیگنال EEG در هر دو بعد، به طور همزمان به بررسی میزان خستگی به صورت پیوسته و در حین فعالیت ذهنی پرداخت. بنابراین در این پروژه نیز هدف، استخراج ویژگی‌های فرکانس-زمان با استفاده از ترکیب روش‌های تجزیه حالت تجربی و تبدیل فوریه زمان کوتاه و در نهایت دسته‌بندی آنها با استفاده از روش‌های شبکه عصبی مصنوعی (ANN) و ماشین بردار پشتیبان (SVM) است. از آنجا که در این پروژه از سیگنال EEG به منظور بررسی خستگی استفاده شده است و نویزهای متفاوتی بر روی این سیگنال اثرگذار هستند، لذا انواع نویزها مورد بررسی قرار خواهد گرفت. همچنین روش‌های استفاده برای استخراج ویژگی، تجزیه حالت تجربی و تبدیل موجک و تبدیل فوریه زمان کوتاه و طبقه‌بندی آنها به روش‌های ANN و SVM بررسی خواهد شد. در نهایت مقایسه نتایج در فصل چهار ارائه می‌شود.

۳-۲- نویزهای مخلوط شده با سیگنال EEG و نحوه کاهش اثر آنها

امواج الکتریکی که از روی پوست سر ثبت می‌شوند لزوماً ناشی از فعالیت الکتریکی مغز نبوده و ممکن است ناشی از نویزها و امواج ناخواسته^۱ باشند. گاهی انرژی این امواج ناخواسته از انرژی سیگنال حاصل از فعالیت‌های الکتریکی نورونها بیشتر است. این امواج دارای منشأ زیست محیطی بوده و همواره نیاز به روشهای موثر حذف نویز برای تخمین ویژگیهای بامعنی از سیگنال وجود دارد.

^۱ Artifact

۳-۲-۱- امواج ناخواسته زیستی

غالباً در بسیاری از موارد، داده ثبت شده از الکترودها حاوی امواج ناخواسته زیستی است. نمونه‌هایی از این دسته از امواج به شرح زیر می‌باشند:

۱- امواج ناخواسته مربوط به چشم (حرکت چشم یا پلک زدن)^۱: امواج ناخواسته مربوط به حرکت چشم و پلک زدن که در اثر اختلاف پتانسیل بین قرنیه و شبکیه ایجاد می‌شود و نسبت به پتانسیل‌های مغزی بزرگتر است. معمولاً همیشه مقدار کمی حرکت چشم وجود دارد که باعث ایجاد این پتانسیل شده و در قسمت پیشانی قابل تشخیص است.

۲- امواج ناخواسته مربوط به فعالیت ماهیچه‌های چشم^۲: حرکت ماهیچه‌های اطراف چشم که باعث ایجاد پتانسیل EMG می‌شود. هرگونه انقباض ماهیچه‌های اطراف الکترودهای ثبت EEG باعث ایجاد این آرتیفکت می‌شود.

۳-۲-۲- امواج ناخواسته محیطی

علاوه بر امواج ناخواسته‌ای که به وسیله بدن بیمار تولید می‌شوند امواج دیگری نیز وجود دارند که دارای منشأ خارجی و باعث خراب شدن سیگنال EEG می‌شوند. وارد شدن ضربات ناگهانی به الکترودها در هنگام ثبت و یا حرکت بیمار، باعث ایجاد تغییرات آنی سیگنال ثبت شده در هر الکترودها می‌شود. انتخاب مکان‌های نامناسب الکترودها منجر به تشکیل امواج ناخواسته‌ای شود که در هنگام ثبت امواج الکتریکی مغزی باید به این مسئله توجه داشت.

^۱ Electrooculogram (EOG)

^۲ Electromyogram (EMG)

۳-۳- تجزیه و تحلیل طیفی سیگنال‌های متغیر

زمانی که آمارهای سیگنال (آمارهای مرتبه‌ی بالا- میانگین و واریانس) همراه با زمان تغییر کند، آن سیگنال متحرک است. زمانی که کاربر حدس بزند که توالی سیگنال مورد نظر در شرایط پایدار فیزیولوژیکی قرار ندارد، می‌توان از روش‌های تجزیه و تحلیل جایگزین برای تخمین طیفی که دارای محدودیت زمانی است، استفاده نمود. این روش‌ها در هر دو سیگنال قطعی و تصادفی نویزی به خوبی عمل می‌کنند. برخی از متداول‌ترین الگوریتم‌ها برای نمایش تخمین‌های طیفی بر اساس فرکانس-زمان شامل تبدیل فوریه زمان کوتاه و تبدیل موجک است.

۳-۳-۱- تبدیل فوریه زمان کوتاه^۱ (STFT)

این تبدیل که از سوی گابور پیشنهاد شده است، با افزایش سیگنالی همراه است که به وسیله‌ی یک پنجره زمانی کوتاه مدت پیرامون بازه‌ی زمانی کم متمرکز بوده و تخمینی از محتوای طیفی سیگنال در آن زمان ارائه می‌دهد. پنجره زمانی کوتاه مدت در راستای محور زمانی حرکت کرده تا با پوشش تمام مدت سیگنال بتواند به تخمینی از محتوای طیفی سیگنال مورد نظر در هر لحظه زمانی دست یابد. سیگنال درون پنجره کوتاه مدت ثابت فرض می‌شود. رابطه‌ی ۳-۱ تبدیل STFT را نشان می‌دهد.

$$STFT(x(t)) = X(\tau, \omega) = \int_{-\infty}^{+\infty} x(t)\omega(t - \tau)e^{-i\omega t} dt \quad ۳-۱$$

در این رابطه $\omega(t)$ تابع پنجره است. برای تابع پنجره معمولاً از تابع پنجره گوسی در اطراف صفر استفاده می‌شود. $x(t)$ سیگنالی است که تبدیل می‌شود و $X(\tau, \omega)$ همان تبدیل فوریه $x(t)\omega(t - \tau)$ است. در واقع این تابع یک تابع مختلط است که فاز و اندازه‌ی سیگنال را نسبت به زمان مشخص

^۱ short-time Fourier transform (STFT)

می‌کند. در صورتی که اندازه تبدیل STFT را به توان دو برسانیم، انرژی سیگنال به دست آمده نشان دهنده‌ی طیف نگاره یا اسپکتروگرام تابع خواهد بود. بنابراین تبدیل کوتاه مدت فوریه یک طیف وابسته به بازه زمانی کوتاه است که پنجره همراه آن تغییر می‌کند. انتخاب تابع گوسی برای پنجره کوتاه مدت به علت عدم محدودیت زمانی در تابع از ویژگی‌های مناسبی برخوردار است. از جنبه‌ی دیگر می‌توان این تبدیل را به عنوان یک فیلتر هموارکننده و متمرکز حول فرکانس فرض شده‌ی f برای سیگنال در نظر گرفت.

۳-۳-۲- استخراج ویژگی به روش تبدیل موجک^۱ [۳۶]

امروزه تبدیل موجک به عنوان ابزار قدرتمندی در استخراج ویژگی از سیگنال‌های حیاتی مورد استفاده قرار می‌گیرد. علاوه بر FFT، تبدیل موجک یک روش تجزیه و تحلیل سیگنال با استفاده از مجموعه‌ای از توابع پایه‌ی متعامد است که از طریق انبساط و انقباض و جابجایی‌های یک موجک حاصل می‌شود. موجک‌ها در ابعاد وسیعی برای پردازش سیگنال‌های حیاتی کاربرد دارند. تفاوت اصلی بین روش‌های مبتنی بر تبدیل فوریه (تبدیل فوریه زمان کوتاه) و تبدیل موجک‌ها این است که تبدیل فوریه از پنجره‌هایی با پهنای ثابت استفاده می‌کند در حالی که روش تبدیل موجک از پنجره‌های وابسته به سیگنال بهره می‌برد. تبدیل موجک‌ها از پنجره‌های باریک در اجزای با فرکانس بالا و پنجره‌های پهن در اجزا با فرکانس پایین استفاده می‌کنند و به این طریق امکان تفکیک زمانی مناسب دلخواه در اجزا با فرکانس بالا و فرکانس پایین را فراهم می‌آورند.

به‌طور کلی تبدیل موجک پیوسته از لحاظ ریاضی به صورت رابطه ۳-۲ نمایش داده می‌شود:

$$s(a, b) = \int x(t) \Psi_{a,b} dt$$

۳-۲

^۱ wavelet transform

در این معادله $x(t)$ سیگنال فرض شده و a و b به ترتیب ضریب مقیاس و زمان هستند. توابع مبنای متعامد با علامت $\Psi_{a,b}$ با روش مقیاس گذاری و جابجایی تابع موجک مدل $\Psi_{a,b}$ (موجک مادر نیز نامیده می شود) به ترتیب به وسیله مقیاس a و زمان b به دست می آیند که به صورت زیر نمایش داده می شود:

۳-۳

$$\Psi_{a,b}(t) = \frac{1}{\sqrt{|a|}} \Psi\left(\frac{t-b}{a}\right)$$

۳-۳-۳- معرفی انواع موجک

موجک هار اولین موجک شناخته شده است که اولین بار توسط آلفرد هار، ریاضیدان مجاری در سال ۱۹۰۹ پیشنهاد شد [۴۹]. موجک هار قدیمی ترین و ساده ترین نوع موجک است که دارای خاصیت تعامد^۱ می باشد. مشکل این موجک این است که پیوسته نیست و در نتیجه مشتق پذیر نمی باشد. موجک مادر هار به شکل پله ای است. موجک کلاه مکزیکی نوعی دیگر است که مشتق مرتبه دوم تابع گوسی است و از مهمترین مزایای آن می توان به هموار بودن آن اشاره نمود. موجک مورلت نیز یک موجک موجی می باشد که گراف آن برای مدت کوتاهی حول صفر نوسان می کند و از بین می رود. از معروف ترین خانواده های موجک، دابیشز است که اعضای این خانواده با یک شماره به صورت dbn مشخص و نامگذاری می شوند. اعضای خانواده دابیشز دارای n ممان صفر شونده می باشند و در این خانواده db1 همان موجک هار است. از مهمترین خاصیت های dbn، متعامد بودن آنهاست ولی تقارن ندارند. طول تابع موجک ψ و تابع مقیاس Φ ، $2N-1$ است و N تعداد ممان های صفر شونده است. هرچه مرتبه ی N بیشتر باشد عملکرد موجک دابیشز بهتر است.

از مهمترین مزیت های تبدیل موجک متغییر بودن پنجره ی آن است زیرا این امکان را به ما می دهد که در مواقعی که اطلاعات دقیق تری راجع به فرکانس های پایین مورد نیاز است از بازه های

^۱ Biorthogonal

زمانی طولانی‌تر و زمانی که اطلاعات فرکانس‌های بالا مورد نیاز است، از بازه‌های کوچکتر استفاده کنیم.

با تطبیق ضریب مقیاس می‌توان مدت پنجره را به دلخواه در فرکانس‌های مختلف تغییر داد. علاوه بر این، تبدیل موجک به دو نوع پیوسته (cwt^1) و گسسته (dwt^2) تقسیم می‌شود که با انتخاب مناسب a و b می‌توان نسخه‌ی زمانی گسسته توابع مبنای متعامد را به صورت زیر نمایش داد:

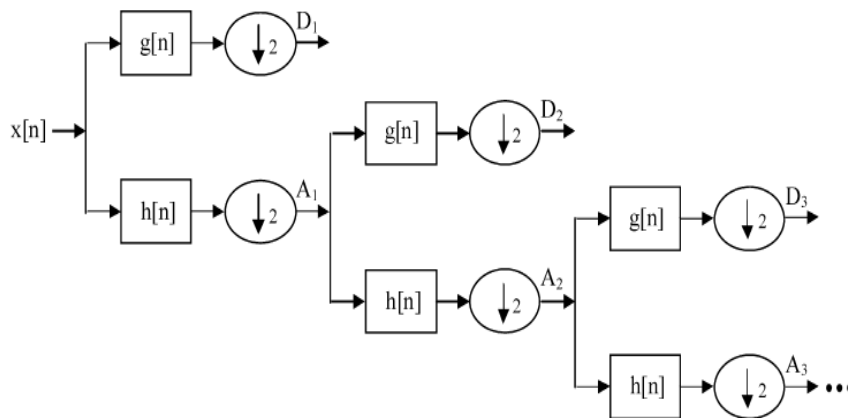
۴-۳

$$\Psi(m, n) = a_0^{-m/2} \psi(a_0^{-m}t - nb_0)$$

که در این معادله a_0 و b_0 به ترتیب ضریب مقیاس اصلی و تغییر زمان هستند و n نیز مضارب مقیاس و تغییر زمان را نشان می‌دهد. تجزیه و تحلیل موجک در سیگنال‌هایی مانند EEG که از مدت زمان کوتاه در اجزا با فرکانس بالا و مدت زمان طولانی در اجزا با فرکانس پایین برخوردارند و یا سیگنال‌هایی که دارای تغییراتی در فواصل پالس‌های قلبی و غیره هستند، به خوبی عمل می‌کند. اساس کار تبدیل موجک گسسته، عبور سیگنال از فیلترهای بالا گذر و پایین گذر بوده و هر طبقه شامل دو فیلتر دیجیتال و یک فیلتر کاهنده نرخ نمونه برداری بعد از هر فیلتر است.

¹ Continuous Wavelet Transform

² Discrete Wavelet Transform



شکل ۳-۱: تبدیل موجک گسسته: $g[n]$ فیلتر بالاگذر و $h[n]$ فیلتر پایین‌گذر [۵۰]

همچنین با اعمال تبدیل موجک به سیگنال مورد نظر، ضرایب موجک که شامل دو سیگنال تقریب و جزئیات هستند، به دست می‌آیند. استفاده از ضرایب موجک به عنوان بردار ویژگی موجب افزایش اندازه‌ی بردار ورودی طبقه‌بند می‌شود و این امر تأثیر نامطلوبی بر عملکرد طبقه‌بند خواهد داشت. به منظور کاهش اندازه بردار ویژگی می‌توان از روش‌های مختلفی استفاده نمود.

۳-۴- استخراج ویژگی به روش تجزیه حالت تجربی^۱

در این قسمت ویژگی‌ها و الگوریتم‌های استفاده شده در روش EMD توضیح داده می‌شوند. EMD یک روش وابسته به داده است که سیگنال را به تعدادی از مؤلفه‌های نوسانگر تحت عنوان توابع حالت ذاتی^۲ تجزیه می‌کند. هر IMF باید دارای دو شرط زیر باشد [۵۱].

۱- باید تعداد نقاط اکسترمم سیگنال با تعداد نقاط عبور از صفر یکسان باشند و یا حداکثر در یک مورد متفاوت باشند.

۲- انتگرال در بازه زمانی تعریف شده برابر صفر باشد، یا اینکه مساحت زیر این تابع برابر صفر باشد.

^۱ Empirical mode decomposition (EMD)

^۲ intrinsic mode functions

محاسبه IMF سیگنال $X(t)$ شامل مراحل زیر است:

۱- شناسایی تمام اکستریم‌های سیگنال (بیشینه و کمینه $X(t)$).

۲- درونیابی بین ماکزیمم‌ها و مینیمم‌ها و تولید پوش‌های $e_l(t)$ و $e_m(t)$.

$$3- \text{ تعیین میانگین محلی } a(t) = \frac{e_l(t) + e_m(t)}{2}$$

$$4- \text{ استخراج جزئیات } h_1(t) = X(t) - a(t)$$

۵- تعیین اینکه آیا $h_1(t)$ با توجه به دو ویژگی اساسی که باید هر IMF داشته باشد یک IMF هست یا نه.

۶- تکرار مرحله ۱ تا ۴ برای به دست آوردن IMF بعدی.

زمانی که اولین IMF به دست می‌آید، $c_1(t) = h_1(t)$ را تعریف کرده که کوچکترین مقیاس زمانی در $X(t)$ به شمار می‌آید. سیگنال باقی مانده به عنوان $r_1(t) = x(t) - c_1(t)$ محاسبه می‌شود. باقی مانده به عنوان سیگنال بعدی پردازش شده و مراحل ۱ تا ۵ تکرار می‌شود. در پایان تجزیه، سیگنال اصلی را می‌توان به صورت زیر بیان کرد:

$$x(t) = \sum_{m=1}^M c_m(t) + r_M(t) \quad 5-3$$

M تعداد IMFها، c_m ، m^{th} امین IMF و r_m باقی مانده سیگنال است.

پس از استخراج IMFها از سیگنال، نمایش تحلیلی سیگنال به صورت زیر به دست می‌آید:

$$y(t) = C_m(t) + iH\{C_m(t)\} \quad 6-3$$

که $\{H\{C_m(t)\}$ تبدیل هیلبرت $C_m(t)$ است و m^{th} امین IMF از سیگنال $X(t)$

استخراج شده است. پس از اعمال EMD از سیگنال، IMFها برای اهداف استخراج ویژگی استفاده می‌شوند.

۳-۴-۱- ویژگی های زمانی از تحلیل IMF ها

محققان نشان داده‌اند استفاده از ویژگی های آماری IMF ها برای تشخیص بین سیگنال های EEG فرد در حالت طبیعی و غیر طبیعی مفید هستند [۵۲]. برای یک IMF، این ویژگی ها را می توان با مقادیر زیر بدست آورد:

$$\mu_t = \frac{1}{N} \sum_{i=1}^N y_i \quad ۷-۳$$

$$\sigma_t = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \mu_t)^2} \quad ۸-۳$$

$$\beta_t = \frac{1}{N} \sum_{i=1}^N \left(\frac{y_i - \mu_t}{\sigma_t} \right)^3 \quad ۹-۳$$

که N تعداد نمونه های IMF است. μ_t میانگین، σ_t واریانس و B_t تقارن^۱، IMF مربوطه است.

۳-۴-۲- ویژگی های طیفی از تحلیل IMF ها

یک امتیاز مهم EMD این است که توانایی انجام تجزیه و تحلیل طیفی سیگنالها را دارد. اهمیت آن در طراحی سیستم های خودکار برای EEG بر اساس این حقیقت است که بیماری ها یا هرگونه تغییری در فعالیت نورونها موجب تغییرات در باند فرکانسی خاصی از سیگنال EEG می شوند [۵۳]، [۵۴]. بنابراین تجزیه و تحلیل فرکانسی می تواند برای استخراج ویژگی از سیگنال های EEG مفید باشد.

تفسیر مفهومی EMD این است که سیگنال را به تعدادی از اجزای (IMF) تجزیه می کند. ویژگی های طیفی IMF ها می تواند اطلاعاتی در مورد فیزیولوژی سیگنال های EEG را فراهم کند. به طور معمول هنگام استفاده از EMD، این تجزیه و تحلیل طیفی با استفاده از محاسبه فرکانس های لحظه ای^۲ انجام می شود [۵۵]. همچنین می توان، چگالی طیفی توان^۳ را نیز به عنوان یک توصیف کننده

^۱ Skewness

^۲ instantaneous frequencies(IF)

^۳ power spectral density(PSD)

برای هر IMF محاسبه کرد. رابطه ۳-۱۰ نحوه محاسبه PSD را نشان میدهد [۵۵].

$$p(\omega) = \sum_{-\infty}^{\infty} r_y[n]e^{-j\omega n} \quad 10-3$$

۱- محدوده طیفی: فرکانس مرکزی یک ویژگی متمایز است که برای تشخیص و خوشه‌بندی بین سیگنال‌های EEG فرد در حالت نرمال و غیر نرمال مورد استفاده قرار می‌گیرد [۵۵].

$$C_s = \frac{\sum_{\omega} \omega p(\omega)}{\sum_{\omega} p(\omega)} \quad 11-3$$

که $p(\omega)$ دامنه‌ی فرکانس ω^{th} در طیف است.

۲- ضریب تغییر: از آنجا که تنوع طیفی در IMFها برای سیگنال‌های EEG طبیعی و سایر شرایط پاتولوژیک متفاوت است، بنابراین می‌توان برای مشخص کردن تفاوت بین آنها از ضریب تغییرات استفاده کرد. این تغییرات را می‌توان به صورت زیر محاسبه کرد [۵۵].

$$\sigma_s^2 = \frac{\sum_{\omega} (\omega - C_s)^2 p(\omega)}{\sum_{\omega} p(\omega)} \quad 12-3$$

که در آن C_s مرکز ثقل طیف است.

۳- تقارن طیفی: Skewness، تقارن و عدم تقارن توزیع را اندازه‌گیری می‌کند [۵۵].

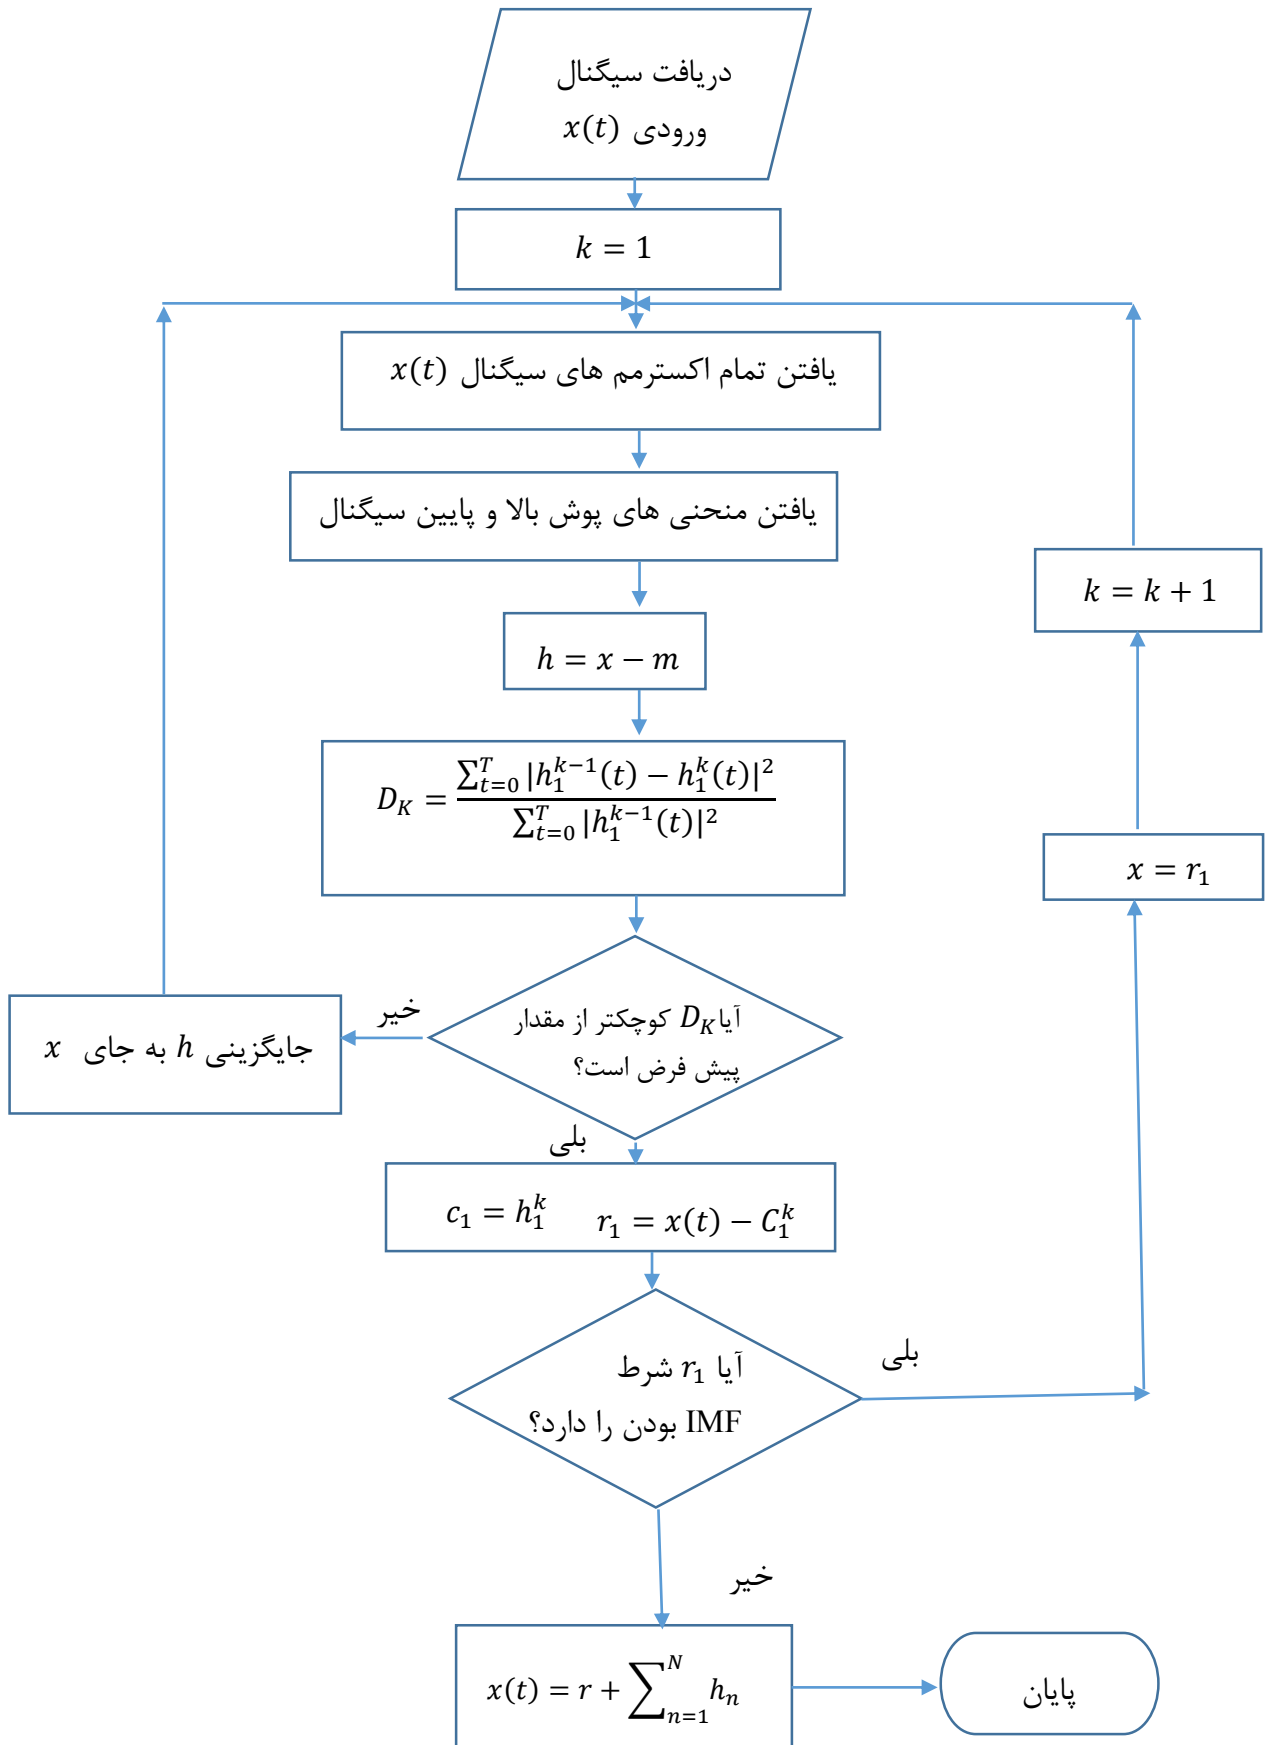
$$\beta_s = \frac{\sum_{\omega} \left(\frac{\omega - C_s}{\sigma_s}\right)^3 p(\omega)}{\sum_{\omega} p(\omega)} \quad 13-3$$

پس از استخراج ویژگی‌های زمانی و طیفی هر IMF، بردار ویژگی آن را می‌توان با ترکیب

آنها به شرح رابطه ۳-۱۴ بدست آورد که برای اهداف طبقه‌بندی استفاده می‌شوند [۵۵].

$$F = [\mu_t \ \sigma_t \ \beta_t \ C_s \ \sigma_s \ \beta_s] \quad 14-3$$

شکل ۳-۲ دیاگرام بلوکی الگوریتم EMD را نشان می‌دهد.



شکل ۲-۳: دیاگرام بلوکی الگوریتم EMD

۳-۵- ماشین بردار پشتیبان^۱ (SVM)

ماشین بردار پشتیبان یا SVM، از طبقه‌بندهای پرکاربردی است که توسط واپنیک^۲ در سال ۱۹۹۵ ارائه شد و به علت موفق بودن در تشخیص ارقام دست نویس، به شهرت دست یافت [۵۶]. اساس این طبقه‌بند، به حداقل رساندن خطا در مرز تفکیک دو کلاس است. شیب این مرز تابع تعدادی از بردارهای ورودی است که روی حاشیه‌ی مرز دو کلاس قرار گرفته و به این علت بردارهای پشتیبان مرز نامیده می‌شوند. این طبقه‌بند شامل هر دو نوع خطی و غیرخطی است که مدل‌های غیرخطی SVM از هسته‌های غیرخطی، خصوصاً توابع RBF استفاده می‌کنند.

۳-۵-۱- ماشین بردار پشتیبان خطی در حالت جدایی‌پذیر

فرض می‌شود که $x = \{x_1, x_2, \dots, x_n\}$ مجموعه‌ی نمونه‌ها و $y \in \{-1, 1\}$ برچسب کلاس‌ها باشند. هدف، یافتن مرز تصمیم خطی است که نمونه‌ها را به درستی طبقه‌بندی کرده و تا حد امکان از نمونه‌های دو کلاس دور باشد شکل ۳-۲ نمونه‌ای از طبقه‌بند SVM را نشان می‌دهد.

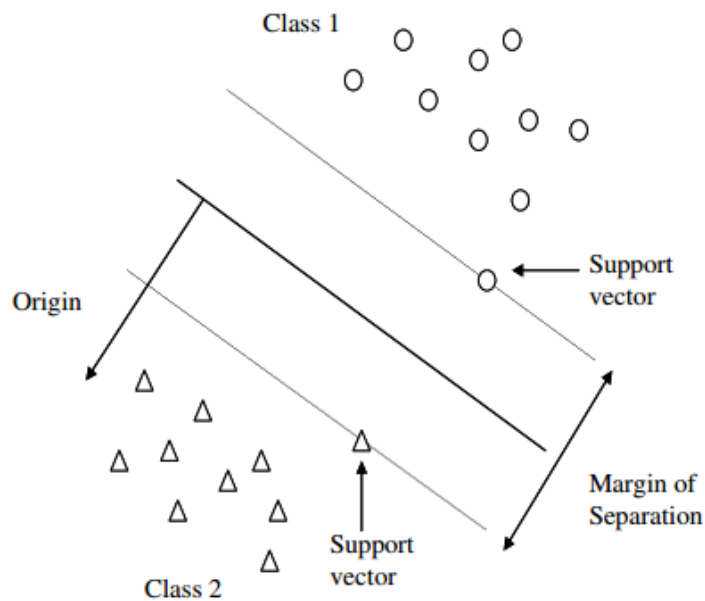
اگر این کلاس مطابق شکل ۳-۳ به صورت خطی جدایی‌پذیر باشد، یک ابرصفحه مانند

$H: \omega X + b = 0$ و تابع تمایز $f(x) = \text{sign}(\omega_0 X + b)$ آنها را از هم جدا می‌کند. چنانچه

فاصله‌ی بین این ابرصفحه‌ها را با H^+ و H^- و پهنای آن را با $m = \frac{2}{\|\omega\|}$ نشان دهیم (حاشیه‌ی مرز هم نامیده می‌شود)، طبقه‌بند دارای حاشیه‌ی اطمینان بزرگتر و در نتیجه در برابر نویز مقاوم‌تر خواهد بود.

^۱ Support Vector Machine (SVM)

^۲ Vapnik



شکل ۳-۳: جدا کننده‌ی خطی SVM [۵۷]

نزدیکترین داده‌های آموزشی به ابر صفحه‌های جدا کننده که در شکل ۳-۲ نشان داده می‌شود بردار پشتیبان است. طراحی ابر صفحه‌ی بهینه با ناحیه‌ی عرضی بیشینه به شرط دسته‌بندی دقیق همه نمونه‌ها یک مسئله‌ی بهینه‌سازی مفید، به صورت زیر نوشته می‌شود:

$$\text{minimize} \left(\frac{1}{2} \| \omega \|^2 \right) \quad ۱۵-۳$$

$$\text{Subject to } y_i(\omega^T X + b) \geq 1 \quad \forall i = 1, \dots, n \quad ۱۶-۳$$

مسئله‌ی بهینه‌سازی فوق یک مسئله‌ی مقید از نوع محدب و درجه دوم است. برای حل این مسئله تابع لاگرانژ زیر را تشکیل داده و ضرائب لاگرانژ $\alpha_i \geq 0$ را به دست می‌آیند:

$$L(\omega, \alpha, b) = \frac{1}{2} \omega^T \omega + \sum_{i=1}^n \alpha_i (1 - y_i(\omega^T X + b)) \quad ۱۷-۳$$

برای اینکه ω, α, b جواب مسئله باشد باید مشتق L نسبت به ω, α, b برابر صفر باشد. با مساوی صفر قرار دادن مشتق نسبت به ω, b معادله‌ی زیر به دست می‌آید:

$$\omega = \sum_{i=1}^n \alpha_i y_i X_i \quad 18-3$$

$$\sum_{i=1}^n \alpha_i y_i = 0 \quad 19-3$$

حال چنانچه رابطه ۱۹-۳ را در تابع لاگرانژ قرار دهیم به تابع لاگرانژ ۲۰-۳ می‌رسیم:

$$L(\alpha) = -\frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n \alpha_i \alpha_j y_i y_j X_i^T X_j + \sum_{i=1}^n \alpha_i \quad 20-3$$

در ادامه جواب مسئله می‌بایست مشتق تابع لاگرانژ را نسبت به متغیر سوم یعنی α_i برابر صفر قرار دهیم. از آنجایی که ترم اول رابطه ۲۰-۳ برابر با $\frac{1}{2} \|\omega\|^2 -$ است، و با در نظر گرفتن قید $\alpha_i \geq 0$ بدیهی است که مساوی قرار دادن مشتق رابطه ۲۰-۳ معادل با بیشینه‌سازی تابع لاگرانژ خواهد بود. بنابراین مسئله‌ی بهینه‌سازی دوگانه جدیدی را داریم که به صورت زیر است:

$$\text{maximize } \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n \alpha_i \alpha_j y_i y_j X_i^T X_j \quad 21-3$$

$$\text{Subject to } \alpha_i \geq 0 \forall i=1, \dots, n \text{ and } \sum_{i=1}^n \alpha_i y_i = 0 \quad 22-3$$

دوگانی این مسئله از آنجاست که تابع ضرائب لاگرانژ، α_i است. پس اگر بردار وزن ω را داشته باشیم، مقادیر ضرائب α_i را داریم و برعکس. حال در این مسئله با روش QP^۱ یک بیشینه‌ی سراسری به دست می‌آید و بسیاری از ضرائب لاگرانژ هم برابر با صفر می‌شوند. در واقع هرکدام از ضرائب لاگرانژ متناظر با یکی از نمونه‌های x_i است. نمونه‌هایی از x_i که متناظر با $\alpha_i \geq 0$ هستند را بردار پشتیبان مرزی می‌نامیم. مقدار بردار وزن ω و b طبق روابط ۲۳-۳ تا ۲۵-۳ به دست می‌آیند:

$$\omega = \sum_{i=1}^{N_{sv}} \alpha_i y_i S V_i \quad 23-3$$

^۱ Quadratic programming

$$b_j = y_i - \alpha_i y_i S V_i^T S V_j \quad ۲۴-۳$$

$$b = \frac{1}{Nsv} \sum_{j=1}^{Nsv} b_j \quad ۲۵-۳$$

تابع تمایز برای یک نمونه‌ی جدید به صورت تابع $f(z)$ خواهد بود:

$$f(z) = \text{Sign}\left(\sum_{i=1}^{Nsv} \alpha_i y_i S V_i^T Z + b\right) \quad ۲۶-۳$$

۳-۵-۲- ماشین بردار خطی در حالت جدایی ناپذیر


مطابق شکل ۳-۴ چنانچه نمونه‌ها جدایی ناپذیر باشند، به ازای هر نمونه یک خطای مجاز ξ_i وجود

دارد که به نام متغیر کمبود^۱ شناخته می‌شود به طوری که شروط زیر برقرار باشند:

$$y_i(\omega^T X_i + b) \geq 1 - \xi_i \quad ۲۷-۳$$

$$\xi_i \geq 0 \quad \forall i = 1, \dots, n$$

^۱ Slack Variable



شکل ۳-۴: نمونه‌های جدایی ناپذیر به صورت خطی [۵۷]

در این حالت مطلوب است که علاوه بر حداکثر کردن حاشیه‌ی مرزی، مجموعه خطاها را کم کنیم. بنابراین داریم:

$$\text{minimize} \left(\frac{1}{2} \| \omega \|^2 + C \sum_{i=1}^n \xi_i \right) \quad 28-3$$

$$\text{Subject to } y_i(\omega^T X + b) \geq 1 - \xi_i \text{ and } \xi_i \geq 0 \quad \forall i = 1, \dots, n \quad 29-3$$

پارامتر C در اینجا تعادلی بین مقدار خطا و حاشیه‌ی مرزی برقرار می‌کند. چنانچه مقدار C را کوچک انتخاب کنیم، خطای بیشتری را پذیرفته‌ایم ولی چنانچه C بزرگتر باشد با توجه به شکل زیر به ناچار حاشیه‌ی مرزی باریک خواهد شد و در نتیجه تعمیم‌پذیری کاهش می‌یابد. مسئله‌ی معادله‌ی دوگان

۲۱-۳ و ۲۲-۳ مشابه قبل به صورت روابط ۳۰-۳ و ۳۱-۳ به دست می‌آید:

$$\text{maximize } \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n \alpha_i \alpha_j y_i y_j X_i^T X_j \quad 30-3$$

$$\text{Subject to } 0 \leq \alpha_i \leq C_i \quad \forall i = 1, \dots, n \quad \text{and} \quad \sum_{i=1}^n \alpha_i y_i = 0 \quad 31-3$$

همانطور که ملاحظه می‌شود حل مسئله‌ی SVM در حالت جدایی ناپذیر مشابه حل آن در حالت جدایی پذیر است با این تفاوت که محدوده تغییرات ضرائب لاکرانژ فرق می‌کند. پس از به دست آوردن ضرائب لاکرانژ α_i ، نمونه‌هایی که ضرائب لاکرانژ آنها در رابطه‌ی $0 \leq \alpha_i \leq C_i$ صدق می‌کنند، پشتیبان به حساب می‌آیند. مقدار ω و شکل تابع تمایز هم مشابه حالت جدایی پذیر خواهد بود. ابر صفحه به دست آمده در حالت جدایی ناپذیر را ابر صفحه با ناحیه‌ی مرزی نرم می‌نامند.

3-5-3- ماشین بردار غیرخطی

ماشین بردارهای پشتیبان ذکر شده در قسمت‌های قبل، طبقه‌بند خطی با حاشیه‌ی مرزی بیشینه بودند و در واقع با حاصلضرب داخلی بردار ورودی با هر کدام از بردارهای پشتیبان در فضای D بُعدی، ورودی را محاسبه می‌کردند.

واپنیک با استفاده از مفهوم حاصلضرب داخلی در فضای هیلبرت و قضیه‌ی هیلبرت-اشمیت نشان داد که ابتدا می‌توان نمونه‌هایی که به صورت خطی در فضای D بُعدی ورودی جدایی ناپذیرند [۵۶]، به یک فضای چند بُعدی منتقل نمود تا در آنجا جدایی پذیر خطی باشند. وی همچنین ثابت کرد اگر یک هسته متقارن شرایط قضیه‌ی Mercer را داشته باشد، اعمال این هسته در فضای ورودی با بُعد کم معادل انجام حاصلضرب داخلی در فضایی با ابعاد بسیار است. به عبارت دیگر با قراردادن تابع هسته‌ی مناسب به جای انجام حاصلضرب داخلی در روابط قبل، به خوبی می‌توان مرز تصمیم غیرخطی با حاشیه‌ی مرز بیشینه را به دست آورد. تعدادی از توابع مرزی متداول تابع هسته‌ی چند جمله‌ای، هسته‌ی گوسی و هسته‌ی تانژانت هایپرپلیک هستند که به ترتیب مطابق روابط زیر تعریف می‌شوند:


$$K(X_1, X_2) = (X_1 \cdot X_2 + 1)^p \quad ۳۲-۳$$

$$K(X_1, X_2) = \exp\left(-\frac{\|X_1 - X_2\|^2}{2\sigma^2}\right) \quad ۳۳-۳$$

$$K(X_1, X_2) = \tanh(X_1 \cdot X_2 + \theta) \quad ۳۴-۳$$

از جمله مزایای SVM می‌توان به طراحی با حداکثر تعمیم، رسیدن به تابع هزینه بهینه، تعیین خودکار ساختار و توپولوژی بهینه (تعداد بردار پشتیبان) و امکان استفاده از مرزهای غیرخطی در فضای ویژگی اشاره کرد. از جمله معایب این روش نیز عدم وجود قانون کلی برای انتخاب هسته و پارامترهای آن و ضریب C است.

اولین پارامتر که مقدار و واریانس تابع RBF (ξ) است، هرچه کوچکتر باشد، RBF را تیزتر کرده و دقت را بالا می‌برد ولی در مقابل از میزان قابلیت تعمیم روش می‌کاهد. دومین پارامتر نیز ضریب جریمه‌ی C است که در نحوه عملکرد این طبقه‌بند نقش مهمی دارد. در اینجا انتخاب بهینه‌ی هر پارامتر با سعی و خطا روی داده‌گان آموزش انجام شده است. به طور کلی اگر امکان دسته‌بندی مجموعه داده با استفاده از یک خط وجود نداشته باشد، از نگاشت به فضایی با ابعاد بالاتر استفاده می‌شود. عملگرهای خطی در فضای ویژگی معادل عملگرهای غیرخطی در فضای ورودی هستند. در نتیجه با نگاشت تغییری در مسئله ایجاد نمی‌شود. شکل ۳-۵ نمونه‌ای از نگاشت داده‌های ورودی به فضای ویژگی را نشان می‌دهد. [۵۸].



شکل ۳-۵: نمونه‌ای از نگاشت داده‌ها به منظور جداسازی غیرخطی داده‌ها [۵۸]

۳-۵-۴- تابع کرنل^۱

بسیاری از مدل‌های پارامتری خطی را می‌توان به یک "نمایش دوگانه" معادل که در آن پیش‌بینی‌ها بر اساس ترکیبات خطی یک تابع کرنل در نقاط داده‌های آموزشی انجام می‌شود، مجدداً بازنویسی نمود. همانطور که قابل مشاهده است، برای مدل‌هایی که بر اساس نگاشت $\phi(X)$ در یک فضای ویژگی غیرخطی ثابت می‌شوند، تابع کرنل از رابطه‌ی زیر به دست می‌آید:

$$K(X, X') = \phi(X)^T \phi(X') \quad ۳۵-۳$$

این تعریف نشان می‌دهد که کرنل یک تابع متقارن است و آرگومان‌های آن به صورت زیر است:

$$K(X, X') = K(X', X) \quad ۳۶-۳$$

در سال ۱۹۶۴ آیزرمن^۲ و همکارانش مفهوم کرنل را در زمینه شناسایی الگو معرفی نمودند. اگرچه در ابتدا این مفهوم نادیده گرفته شده بود، بوسر^۳ و همکارانش در سال ۱۹۹۲ آموزش ماشین در زمینه‌ی طبقه‌بندی‌های گسترده‌تر و تکنیک‌های ماشین‌های بردار پشتیبانی را معرفی کردند [۵۹].

۳-۶- طبقه‌بند بر پایه‌ی شبکه‌ی عصبی

شبکه‌های مصنوعی بر اساس الگویی که از نحوه‌ی کارکرد سیستم‌های عصبی موجودات زنده در یادگیری و تشخیص وجود دارد، طراحی شده‌اند. در حالت کلی یک شبکه عصبی مصنوعی به صورت ارتباط میان سلول‌های عصبی به کمک وزنها می‌باشد. در واقع اندازه‌ی این وزنها می‌باشد که با آموزش سیستم تغییر کرده و خود را برای یافتن نتیجه‌ی مطلوب بهینه می‌کنند. شبکه‌های عصبی انواع مختلفی دارند که مشهورترین و پرکاربردترین آنها، شبکه‌های پرسپترون^۴ ساده و چند لایه است. در این طبقه‌بند یک ابر صفحه، به نحوی که بتواند داده‌های وابسته به کلاس‌های مختلف را جدا کند،


^۱ kernel

^۲ Aizerman

^۳ Boser

^۴ perceptron

مورد جستجو قرار می‌گیرد. بنابراین واضح است شبکه‌ای که یک لایه دارد، فقط وزن‌ها در این لایه دربرگیرنده‌ی ضرائب مربوط به این لایه می‌باشند. در بسیاری از موارد یافتن یک لایه صفحه به عنوان مرز جدا کننده با مشکل مواجه است، لذا ابتدا باید با اضافه کردن لایه‌های دیگر، ورودی‌ها را به فضایی که امکان جداسازی آنها با لایه صفحه در آنجا بیشتر است، نگاشت داده و سپس خروجی این لایه را از سیستمی مانند یک پرسپترون ساده عبور می‌دهیم. نمونه‌ای از شبکه عصبی پرسپترون چندلایه در شکل ۳-۶ نشان داده شده است.



شکل ۳-۶: شبکه عصبی پرسپترون چند لایه

به ترکیب کل این مجموعه پرسپترون چند لایه گفته می‌شود. لایه‌های f که توابع علامت نامیده می‌شوند، شبیه به علامت سیگموئید^۱ بوده و به صورت یک تابع خطی در نظر گرفته می‌شود. به این توابع که در آموزش شبکه چند لایه الگوریتم پس انتشار خطا^۲ کاربرد فراوانی دارند، تابع انتقال گفته می‌شود. در این روش برای کمینه کردن تابع خطا از خروجی آغاز کرده و برای گرفتن مشتقات جزئی از پارامترهای شبکه (وزن‌ها)، به سوی کمینه کردن تابع خطا پیش می‌رویم.

^۱ sigmoid

^۲ Back Propagation

۳-۷- جمع‌بندی

الگوریتم‌های شرح داده شده در این فصل، برای ارائه روش پیشنهادی به کار می‌روند. از ترکیب تبدیل موجک و روش تجزیه تجربی و تبدیل فوریه زمان کوتاه برای استخراج ویژگی و از ماشین بردار پشتیبان و شبکه عصبی مصنوعی به عنوان طبقه‌بند به کار می‌روند. روش پیشنهادی در فصل چهارم استخراج ویژگی به روش EMD و ترکیب آن با STFT است که در ادامه به آن پرداخته می‌شود.

فصل چهارم

۴- روش پیشنهادی

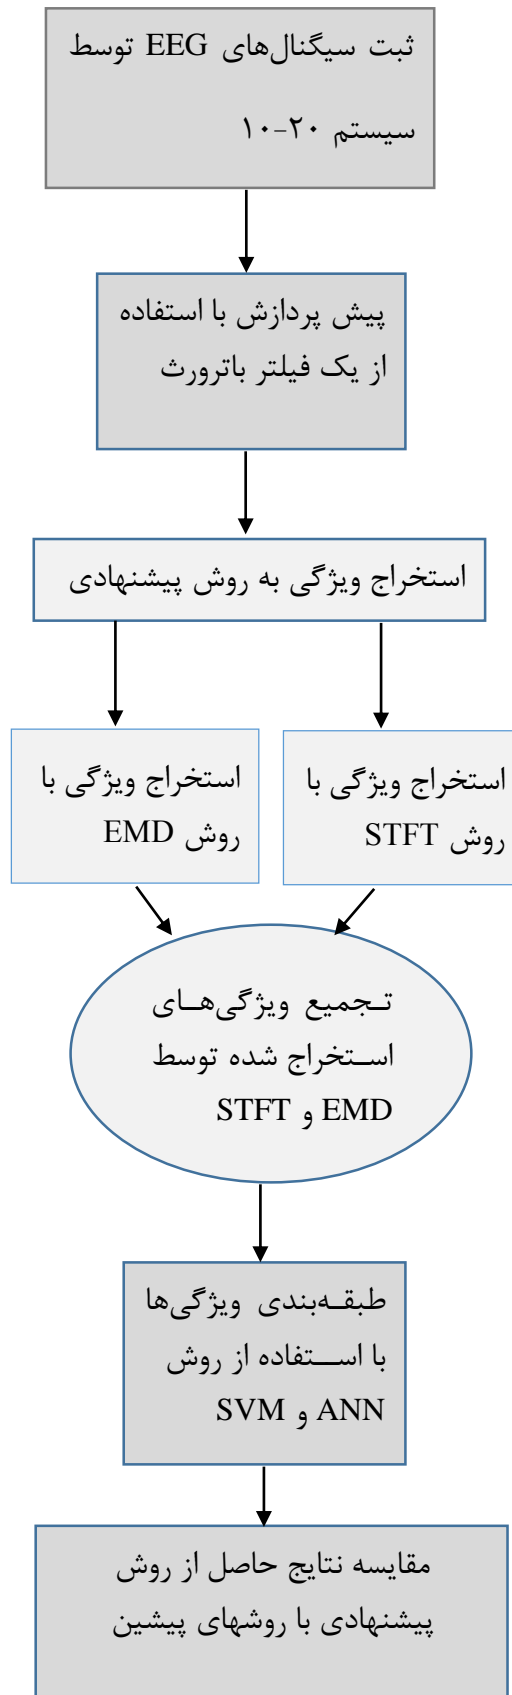
۴-۱- مقدمه

به‌طور کلی هدف از انجام این پایان نامه بررسی میزان خستگی ذهنی و اهمیت آن در زندگی روزمره است. در این فصل نتایج حاصل از اعمال روش پیشنهادی بر روی داده مورد نظر بررسی می‌شود و همچنین روش پیشنهادی با روش‌های پیشین دیگر مورد مقایسه قرار می‌گیرد. داده‌های استفاده شده در این پایان‌نامه از ۱۲ فرد مورد آزمایش در دو حالت نرمال و خسته ثبت شده‌اند.

در این بخش از روش تجزیه حالت تجربی یا (EMD) که در فصل سوم شرح داده شد، به‌منظور استخراج ویژگی استفاده شد و سپس با روش‌های دیگر استخراج ویژگی مانند انرژی موجک در باندهای EEG و تبدیل فوریه زمان کوتاه و ترکیب آنها مقایسه گردید. همچنین برای بهبود نتایج ویژگی STFT و EMD با هم ترکیب شدند و در نهایت ویژگی‌های استخراج شده به طبقه‌بندهای ماشین بردار پشتیبان (SVM) و شبکه عصبی مصنوعی (ANN) داده شد. نتایج نشان می‌دهد که ANN عملکرد بهتری نسبت به SVM برای طبقه بندی ویژگی‌های به‌دست آمده دارد.

علاوه براینکه مشخصات آماری سیگنال‌های حیاتی خصوصاً سیگنال‌های EEG به دلیل ناپایا بودن نسبت به زمان تغییر می‌کند، مختصات و مشخصات تبدیل فوریه آنها نیز در طول زمان قابل تغییر است. بطورکلی هر دو روش EMD و تبدیل موجک به دلیل آنالیز مؤلفه‌های زمان-فرکانسی سیگنال‌های EEG این خصوصیات را در نظر گرفته و به طبع می‌تواند ویژگی بهتری را از استخراج کنند.

در شکل ۴-۱ دیاگرام بلوکی روش پیشنهادی این پایان نامه مشاهده می‌شود.




شکل ۴-۱: دیاگرام بلوکی روش پیشنهادی


۲-۴- پیش پردازش

در این قسمت بخشی از داده‌ها که توسط EOG و EMG به شدت تحت تأثیر قرار گرفته‌اند، برای تجزیه و تحلیل در نظر گرفته نمی‌شوند. آرتیفکت EOG که ناشی از حرکات چشم و پلک زدن است شامل فرکانس‌های پایین‌تر از ۰,۵ هرتز هستند و همچنین آرتیفکت EMG نیز که بیانگر فعالیت عضلات بدن است، در محدوده فرکانسی بین ۲۰ تا ۱۵۰ هرتز قرار دارند. از آنجا که ثبت سیگنال EEG با آرتیفکت‌های EOG و EMG همراه است در این پایان‌نامه از یک فیلتر باترورث از درجه ۳۰ با فرکانس قطع پایین ۰,۵ هرتز و فرکانس قطع بالا ۳۰ هرتز، به‌عنوان پیش پردازش استفاده شده است. رابطه فیلتر باترورث بصورت رابطه ۱-۴ است.


$$|B(\omega)|^2 = \frac{1}{1 + \left(\frac{\omega}{\omega_C}\right)^{2N}} \quad 1-4$$

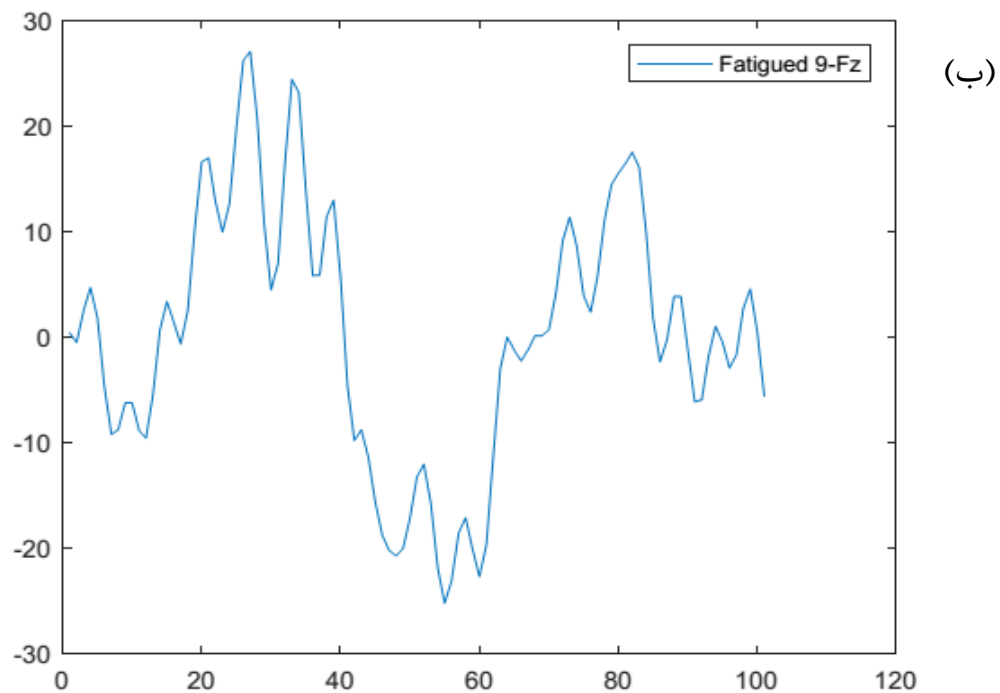
شکل ۲-۴ و ۳-۴ نمونه‌ای از سیگنال‌های EEG ثبت شده از کانال 9-Fz برای یک فرد را در دو حالت نرمال و خسته نشان می‌دهند که در شکل ۲-۴ نمونه‌ها پیش پردازش نشده ولی در شکل ۳-۴ نمونه‌ها پیش پردازش شده‌اند. محور عمودی این نمودارها مربوط به دامنه‌ی سیگنال و محور افقی آنها مربوط به فرکانس نمونه‌ها است.





شکل ۴-۲: (الف) سیگنال های EEG پیش پردازش نشده برای حالت نرمال - (ب) سیگنال های EEG پیش پردازش نشده برای حالت خسته



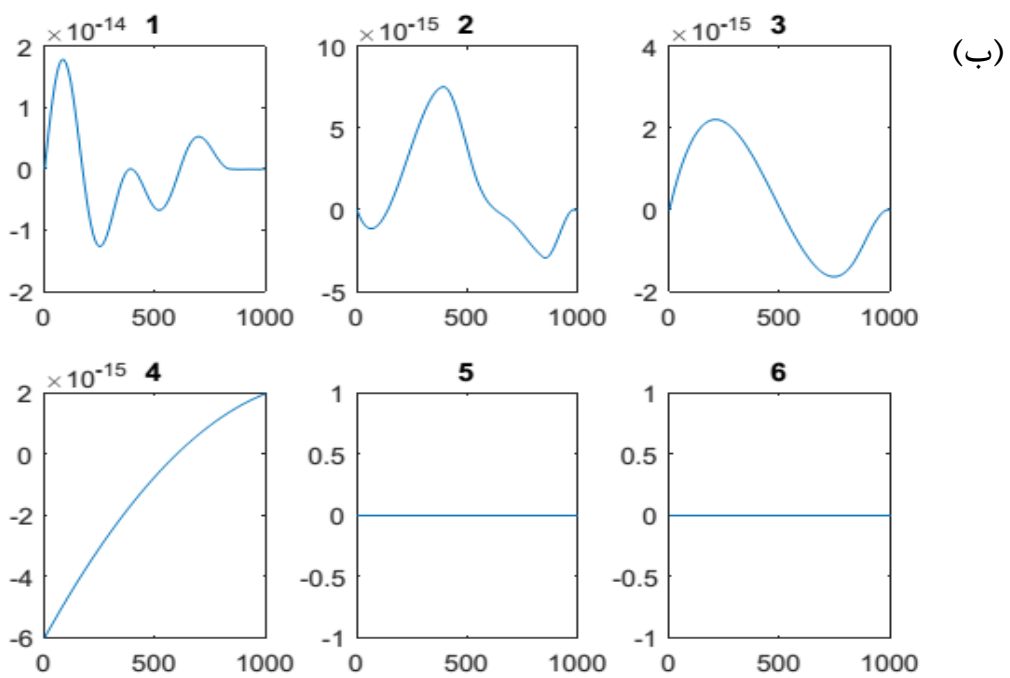
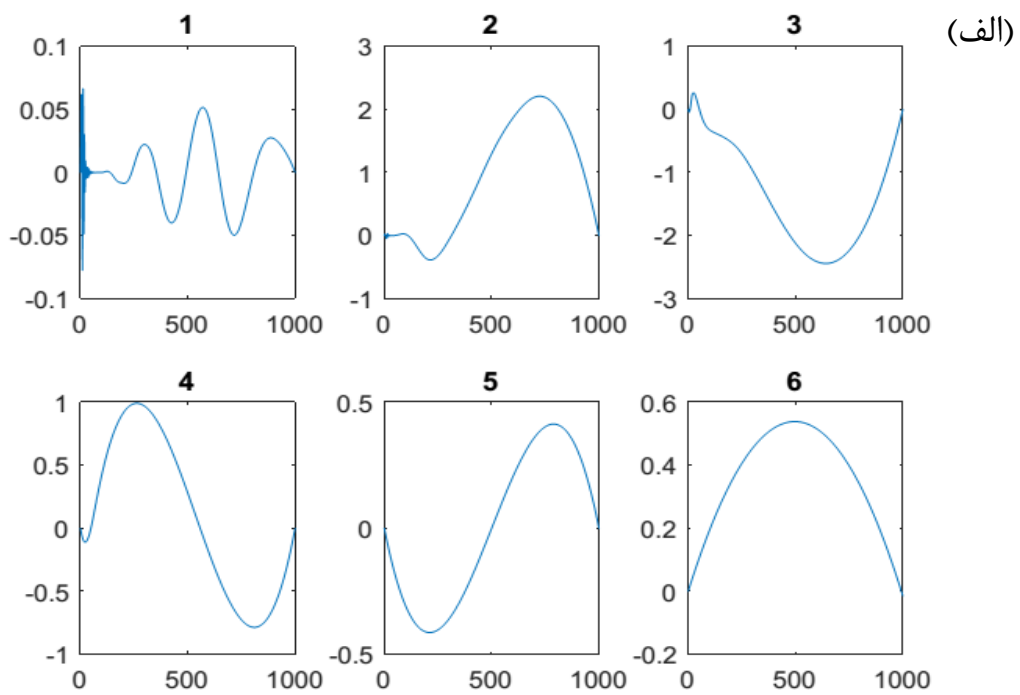


شکل ۴-۳: (الف) سیگنال های EEG پیش پردازش شده برای حالت نرمال- (ب) سیگنال های EEG پیش پردازش شده برای حالت خسته

۴-۳- استخراج ویژگی به روش EMD

هدف از استخراج ویژگی، استخراج مجموعه‌ای از خصوصیات است که به صورت بهینه حالت خستگی را از غیر خستگی متمایز کند. در این پایان نامه ویژگی EMD به عنوان منبع اطلاعات، به جای داده‌های EEG، برای طبقه بندی به کار می‌رود. بنابراین، پس از مرحله پیش پردازش داده توسط فیلتر باترورث، ابتدا سیگنال EEG که برای هر کانال دارای طول ۶۰۰۰۰۰ نمونه است را با یک پنجره به طول یک ثانیه معادل ۱۰۰۰ نمونه بخش بخش کرده و سپس الگوریتم EMD به هر ۶۰۰ بخش سیگنال اعمال می‌شود. EMD سیگنال را به مولفه‌های نوسانی آن تجزیه می‌کند و همچنین الگوریتمی کارآمد برای تحلیل زمان-فرکانس سیگنال‌های ناپایا مانند EEG است.

همانطور که در فصل سوم شرح داده شد، مولفه‌های نوسانی سیگنال یا همان IMFها، با استفاده از الگوریتم EMD به دست می‌آیند. IMFهای به دست آمده از هر بخش سیگنال که ویژگی‌های مطلوب هستند را در یک بردار کنار هم قرار داده می‌شوند. البته در هر بخش فقط ۶ IMF اول آن در نظر گرفته شده و مقادیری از IMFها که از بین رفته‌اند، حذف می‌شوند. شکل ۴-۴ نمونه‌ای از IMFها را در دو پنجره مختلف برای یک سیگنال EEG فرد در حالت نرمال از کانال T5 را نشان می‌دهد. در شکل ۴-۴ مشاهده می‌شود که ترتیب استخراج مودها به این گونه است که از مودهای فرکانس بالا آغاز شده تا به مودهای فرکانس پایین برسد.



شکل ۴-۴: (الف) IMF های به دست آمده از پنجره اول سیگنال - (ب) IMF های به دست آمده از پنجره پانزدهم سیگنال

همانطور که در شکل ۴-۴(ب) مشاهده می‌شود، مولفه‌های نوسانی شماره ۵ و ۶ حاوی هیچ اطلاعاتی نیستند. به عبارت دیگر اطلاعات مربوط به این مولفه‌ها از بین رفته یا گم شده‌اند. پس برای تشکیل بردار ویژگی این IMFها در نظر گرفته نمی‌شوند.

پس از اعمال الگوریتم EMD و به دست آمدن مولفه‌های نوسانی سیگنال‌ها، برای به دست آمدن فرکانس لحظه‌ای سیگنال از IMFهای به دست آمده تبدیل هیلبرت گرفته می‌شود. تبدیل هیلبرت خود به تنهایی فرکانس لحظه‌ای سیگنال را تا حدودی برای ما محاسبه می‌کند اما زمانیکه پدیده‌ی اختلاط مودها پیش می‌آید، تبدیل هیلبرت سیگنال قادر به مشخص کردن فرکانس‌های سیگنال و اینکه در چه لحظه‌ای از سیگنال وجود دارند، نیست. از این رو پس از تجزیه سیگنال به مولفه‌های نوسانی آن توسط الگوریتم EMD، از IMFها تبدیل هیلبرت گرفته می‌شود و همچنین با ترکیب تبدیل هیلبرت و تبدیل EMD فرکانس لحظه‌ای سیگنال بطور دقیق محاسبه می‌شود که این روش تحت عنوان هیلبرت-هوانگ شناخته شده است.

۴-۴- استخراج ویژگی به روش STFT


در این پایان نامه علاوه بر ویژگی EMD از ویژگی STFT نیز برای توصیف اطلاعات EEG افراد استفاده می‌شود. همانطور که در فصل ۳ بیان شد، طیف STFT که تحلیل زمان-فرکانس برای سیگنال انجام می‌دهد وابسته به یک پنجره است که در اینجا نوع این پنجره از نوع همینگ^۱ با طول ۳۰۰۰۰ نمونه استفاده شده است. پنجره همینگ از رابطه‌ی ۴-۲ محاسبه می‌شود.

$$\omega_n = \begin{cases} 1 & 0 \leq n < N \\ 0 & otherwise \end{cases} \quad ۲-۴$$

طول پنجره همینگ نباید کم باشد زیرا رزولوشن فرکانسی کم خواهد شد و به این معنی ایست که نمونه‌های حاصل از تبدیل فوریه کم هستند و بنابراین تحلیل در حوزه فرکانس با دقت

^۱ hamming

کمتری انجام خواهد شد. تعداد طیف‌های STFT به دست آمده برای یک کانال ۲۰ تا است. با توجه به طول دیتا برای هر کانال (۶۰۰ هزار) و طول پنجره همینگ (۳۰ هزار)، سیگنال به ۲۰ بخش تقسیم می‌شود. شکل ۴-۵ یک نمونه از طیف اسپکتوگرام مربوط به کانال T5 از یک سیگنال EEG فرد در حالت نرمال را نشان می‌دهد.



شکل ۴-۵: طیف اسپکتوگرام مربوط به کانال T5 برای یک سیگنال EEG در حالت نرمال

در این پایان نامه برای بهبود نتایج ویژگی‌های استخراج شده از تبدیل EMD و STFT با هم ترکیب شده و در یک ماتریس قرار داده می‌شوند. سپس این بردار حاصل از ترکیب EMD+STFT به ورودی طبقه‌بند داده می‌شوند. همچنین در این پایان نامه برای ارزیابی نتایج از دو نوع طبقه‌بند مختلف با نام‌های شبکه عصبی از نوع Feed Forward و ماشین بردار پشتیبان با استفاده از کرنل

درجه دوم^۱ استفاده شده است. میزان درصد دقت در این دو طبقه‌بند نشان می‌دهد که شبکه عصبی عملکرد بهتری نسبت به SVM دارد.

۴-۵- جمع‌بندی

در این پایان نامه ابتدا از تبدیل EMD برای استخراج ویژگی استفاده می‌شود که ویژگی‌های حاصل از EMD شامل یکسری IMF به نام مولفه‌های مود ذاتی است. سپس برای بهبود نتایج ویژگی‌های استخراج شده از این روش با ویژگی‌های به دست آمده توسط توصیفگر STFT ترکیب شده و در یک بردار قرار داده می‌شوند. در نهایت بردار حاصل از ترکیب ویژگی‌های EMD و STFT به طبقه‌بندهای مختلف از جمله ANN و SVM داده شده و نتایج حاصل از این دو طبقه‌بند با یکدیگر مقایسه می‌شوند. همچنین برای نشان دادن میزان دقت و صحت روش پیشنهادی، این روش با روش‌های دیگر مورد مقایسه قرار خواهد گرفت. نتایج آنها در جدول ۱-۵ در فصل ۵ ارائه خواهد شد.

^۱ Quadratic

فصل پنجم

۵- نتایج

۵-۱- داده EEG ثبت شده برای بررسی میزان خستگی


پایگاه داده استفاده شده در این پایان نامه مربوط به دوازده نفر راننده است که از سایت www.figshare.com تهیه شده است. داده‌های EEG در دو مرحله حالت نرمال و خستگی ثبت شده‌اند. ابتدا زمانیکه ۲۰ دقیقه از شروع رانندگی افراد گذشت، در ۵ دقیقه آخر سیگنال های EEG ثبت و به‌عنوان حالت عادی نامگذاری شد. حالت دوم زمانی است که راننده حدود ۶۰ تا ۱۴۰ دقیقه در حال رانندگی مداوم هستند، داده‌های سیگنال EEG در ۵ دقیقه آخر به‌عنوان وضعیت خستگی ثبت شده‌اند.

سیگنال‌های EEG با استفاده از ۴۰ الکتروود به وسیله‌ی سیستم بین‌المللی ۱۰-۲۰ برای مشخص کردن موقعیت الکتروودها استفاده شد. شماره کانال‌ها از ۱ تا ۴۰ به ترتیب (HEOR, HEOL, FP2, FP1, VEOU, VEOL, F7, F3, FZ, F4, F8, FT7, FC3, FCz, FC4, FT8, T3, C3, CZ, C4, T4, TP7, CP3, CPz, CP4, TP8, A1, T5, P3, Pz, P4, T6, A2, O1, Oz, O2, FT9, FT10, PO1, PO2) می‌باشد که A1 و A2 به‌عنوان الکتروود مرجع در نظر گرفته شدند.

فرکانس نمونه برداری برای دیتاست در هر دو حالت نرمال و خسته ۱۰۰۰ هرتز است. با توجه به اینکه زمان ثبت سیگنال‌های EEG برای هر فرد در هر دو حالت ۵ دقیقه است، طول دیتاست برای هر کانال ۶۰۰۰۰۰ نمونه است که ۳۰۰۰۰۰ تا نمونه برای حالت نرمال و ۳۰۰۰۰۰ تا نمونه برای حالت خسته وجود دارد. طول داده‌های هر دو حالت مساوی هستند و برای استخراج ویژگی‌ها و طبقه‌بندی بطور تصادفی به مجموعه‌های آموزشی و تست تقسیم شده‌اند.

۲-۵- بررسی نتایج حاصل از روش EMD

در این بخش نتایج حاصل از روش پیشنهادی بررسی و همچنین با روش‌های دیگر مقایسه می‌شود. همانطور که بیان شد، در این پایان نامه پس از پیش پردازش پایگاه داده از روش تبدیل EMD به عنوان استخراج ویژگی استفاده شد. در این پایان نامه به منظور کاهش بردار ویژگی تنها ۴ کانال p3, TP7, T5, و CP7 که کانال‌های برتری برای تشخیص خستگی ذهنی هستند، مورد استفاده قرار گرفت. ابعاد ماتریس ویژگی که به طبقه‌بند داده می‌شود، $12702 * 80$ است. پایگاه داده که شامل ۱۲ نفر راننده و در دو حالت مختلف تهیه شده است که در کل ۲۴ نمونه می‌شود و هر کدام از آنها شامل ۴ کانال ثبتی است. در نتیجه یک بعد ماتریس ویژگی EMD بصورت $4 * 2 * 12$ برابر با ۸۰ نمونه حاصل می‌شود و بعد دیگر آن ۱۲۷۰۲ تعداد IMFهایی است که در نتیجه‌ی تبدیل EMD به دست آمده‌اند. شکل ۵-۱ نمودار درهم‌ریختگی است که نتایج حاصل از عملکرد طبقه‌بند FF-ANN را به ازای ویژگی‌های به دست آمده از روش EMD نشان می‌دهد.



۵-۱: خروجی طبقه‌بند شبکه عصبی FF-ANN به ازای بردار ورودی ویژگی EMD

نمودار درهم ریختگی^۱ که کلاس خروجی شبکه برحسب خروجی هدف است، تعداد تشخیص‌های صحیح و ناصحیح برای هر دو کلاس صفر و یک را به همراه درصد‌هایشان نشان می‌دهد که کلاس یک مربوط به حالت نرمال افراد و کلاس صفر مربوط به حالت خسته افراد است. لازم به ذکر است برای این طبقه‌بند تعداد داده‌های آموزش ۷۰ درصد، تعداد داده‌های تست و اعتبارسنجی شبکه هر کدام ۱۵ درصد در نظر گرفته شده است. داده‌های تست برای تعیین کیفیت نهایی شبکه عصبی است، داده‌های آموزش برای هدایت پروسه آموزش یعنی به روز کردن وزن‌های شبکه عصبی به هنگام آموزش به کار می‌رود، داده‌های اعتبارسنجی برای نظارت بر کیفیت شبکه عصبی به هنگام فرآیند یادگیری است.

ماتریس درهم ریختگی خروجی شبکه عصبی است که خانه‌ی آبی آن میزان درصد نهایی تشخیص صحیح و میزان خطای تشخیص شبکه را بیان می‌کند. همانطور که در ماتریس درهم‌ریختگی ملاحظه می‌شود، اگر هدف تشخیص کلاس صفر باشد و خروجی شبکه نیز کلاس صفر را تشخیص دهد، برای ۲۷ تا نمونه دقت ۳۸٪ است و اگر هدف تشخیص کلاس یک باشد و خروجی شبکه نیز کلاس یک را تشخیص دهد، برای ۳۲ تا نمونه دقت ۴۵٫۱٪ است. اگر هدف تشخیص کلاس صفر باشد و خروجی شبکه عصبی کلاس یک را به اشتباه تشخیص دهد و برعکس، برای ۶ نمونه خطای خروجی شبکه ۸٫۵٪ است. در نهایت برای ۸۰ نمونه شبکه عصبی با دقت ۸۳٫۱٪ و خطای ۱۶٫۹٪ ویژگی‌های EMD افراد نرمال و خسته را طبقه‌بندی می‌کند.


علاوه بر نمودار درهم ریختگی تحلیل نمودار ROC برای بررسی عملکرد شبکه FF-ANN استفاده می‌شود. تحلیل‌های ROC به منظور مشخص کردن میزان حساسیت و ویژگی تشخیص‌ها به کار می‌روند. همانطور که در شکل ۵-۲ مشاهده می‌شود، منحنی ROC عملکرد شبکه FF-ANN را با مجموع کل داده‌ها شامل داده‌های آموزش، تست و اعتبارسنجی بیان می‌کند. هرچه این نمودار به

^۱ Confusion

سمت ضلع بالا سمت چپ نزدیک تر باشد، نشان دهنده عملکرد بهتر طبقه‌بند شبکه عصبی است.

شکل ۲-۵ مربوط به نتایج حاصل از عملکرد طبقه‌بند FF-ANN به ازای ویژگی‌های به دست

آمده از روش EMD است.



شکل ۲-۵: منحنی‌های ROC طبقه‌بند شبکه عصبی FF-ANN به ازای ویژگی‌های EMD

منحنی‌های ROC بین صفر و یک قرار می‌گیرند. منحنی‌هایی که در همسایگی نیمساز ۴۵

درجه هستند معرف عملکرد ضعیف شبکه عصبی است و همچنین نمودارهایی که مساحت زیر منحنی

ROC و مساوی یا کمتر از مساحت بالای منحنی باشد نشان‌دهنده‌ی تستی غیر قابل قبول است. پس

با توجه به منحنی‌های ROC شکل ۲-۵ می‌توان گفت که طبقه‌بند شبکه عصبی عملکرد قابل قبولی

برای طبقه‌بندی ویژگی‌های EMD داشته است.

۳-۵- بررسی نتایج حاصل از روش STFT

در این پایان نامه پ علاوه بر روش EMD، از روش تبدیل STFT نیز به‌عنوان استخراج ویژگی استفاده

شد. همچنین در روش STFT نیز به منظور کاهش بردار ویژگی ۴ کانال T5, p3, TP7 و CP7 مورد استفاده قرار گرفتند. ابعاد ماتریس ویژگی که به طبقه‌بند داده می‌شود، ۱۸*۲۱۳۰*۸۰ است. شکل ۵-۳ نمودار درهم‌ریختگی است که نتایج حاصل از عملکرد طبقه‌بند FF-ANN را به ازای ویژگی‌های به‌دست آمده از روش STFT نشان می‌دهد.


Confusion Matrix

Output Class	Target Class		
	0	1	
0	21 26.3%	4 5.0%	84.0% 16.0%
1	16 20.0%	39 48.8%	70.9% 29.1%
	56.8% 43.2%	90.7% 9.3%	75.0% 25.0%

شکل ۵-۳: خروجی طبقه‌بند شبکه عصبی FF-ANN به ازای بردار ورودی ویژگی STFT

خانه آبی از ماتریس درهم‌ریختگی ناشی از ویژگی STFT ارزیابی خروجی شبکه برای همه‌ی نمونه‌ها را نشان می‌دهد، که میزان تشخیص صحیح شبکه برای نمونه‌های قرار گرفته در خانه‌های سبز رنگ ۷۵٪ و میزان تشخیص ناصحیح شبکه برای نمونه‌های قرار گرفته در خانه‌های قرمز رنگ ۲۵٪ است.

همچنین شکل ۵-۴ نیز نمودار ROC به ازای ویژگی‌های STFT را نشان می‌دهد.




شکل ۴-۵: منحنی‌های ROC طبقه‌بند شبکه عصبی FF-ANN به ازای ویژگی‌های STFT

محور عمودی در نمودار ROC بیانگر میزان تشخیص صحیح شبکه به ازای تعداد نمونه‌هایی است که به‌عنوان کلاس هدف در نظر گرفته شده‌اند و همچنین محور افقی این نمودار بیانگر میزان تشخیص ناصحیح شبکه به ازای تعداد نمونه‌هایی است که در کلاس هدف قرار گرفته‌اند.

۴-۵- استخراج ویژگی به روش تجمیع ویژگی‌های EMD و STFT


در این پایان نامه برای بهبود نتایج روش پیشنهادی از توصیفگر STFT به منظور ترکیب با ویژگی EMD استفاده شد. نتایج زیر بهبود عملکرد روش پیشنهادی را نشان می‌دهد. ابعاد ماتریس حاصل از ویژگی EMD و STFT که به ورودی طبقه‌بند داده می‌شود $225720 * 80$ است. شکل ۵-۵ نمودار درهم ریختگی و شکل ۶-۵ نمودار ROC مربوط به خروجی شبکه FF-ANN را برای بردار ویژگی حاصل از ترکیب ویژگی‌های EMD و STFT نشان می‌دهد.



شکل ۵-۵: خروجی طبقه‌بند شبکه عصبی FF-ANN به ازای ویژگی‌های حاصل از ترکیب EMD و STFT

شکل ۵-۵ نشان می‌دهد که نتایج حاصل از روش پیشنهادی نسبت به استخراج ویژگی به روش EMD حدود ۸,۳٪ و نسبت به STFT حدود ۱۶,۳٪ افزایش یافته است.

بطور مشابه نمودار ROC مربوط به روش پیشنهادی در شکل ۵-۶ مشاهده می‌شود.



شکل ۵-۶: منحنی‌های ROC طبقه‌بند شبکه عصبی FF-ANN برای ویژگی‌های ترکیب شده EMD و STFT

۵-۵- نتایج مقایسه روش پیشنهادی با روش‌های دیگر با استفاده از دو مدل طبقه‌بند


SVM و FF-ANN

در مرحله‌ی آخر از دو طبقه‌بند SVM و FF-ANN برای جداسازی ویژگی‌های استخراج شده استفاده شده است. همانطور که در فصل ۳ توضیح داده شده، SVM در حالت عادی یک طبقه‌بند خطی است و باید به منظور استفاده از آن برای سیگنال‌های EEG که غیرخطی و نا ایستا هستند، از کرنل استفاده شود. FF-ANN ساده‌ترین شبکه عصبی مصنوعی است که شامل یک لایه ورودی (بردار ویژگی)، دو تا خروجی برای (کلاس‌بندهای گروه صفر و یک) و ۱۵ تا لایه پنهان است. در جدول ۵-۱ نتایج حاصل از روش پیشنهادی و روش‌های دیگر مبتنی بر دو طبقه‌بند ANN و SVM مشاهده می‌شود. لازم به ذکر است از آنجایی که SVM قادر به تفکیک حجم بالایی از ویژگی نیست، به منظور بررسی نتایج از ویژگی‌های ۴ کانال (P3, TP7, T5, CP3) که سطح خستگی رو بهتر از مابقی کانال‌ها مشخص می‌کنند، استفاده شده است.

جدول ۵-۱: مقایسه روش پیشنهادی با روش‌های دیگر بر اساس دو طبقه‌بند ANN و SVM برای ۴ کانال

	STFT	WT ENERGY	STFT+WT ENERGY	EMD	روش پیشنهادی EMD+STFT
FF-ANN	۷۵٪	۶۰٪	۷۸/۶٪	۸۳/۱٪	۹۱/۳٪
SVM	۷۰/۶٪	۵۸٪	۷۶/۵٪	۸۰/۶٪	٪۹۰

شکل ۵-۷ نمودار میله‌ای مربوط به نتایج به دست آمده در جدول ۵-۱ را نشان می‌دهد.



شکل ۵-۷: نمودار میله‌ای مربوط به عملکرد دو طبقه‌بند FF-ANN و SVM برای ۴ کانال

محور عمودی این نمودار بیانگر عملکرد هر دو نوع طبقه‌بند FF-ANN و SVM بر اساس ۵

ویژگی STFT, WT-ENERGY, STFT+WT-ENERGY, EMD و روش پیشنهادی EMD+STFT

ذکر شده در محور افقی است. همچنین در این نمودار میله‌ای خواهیم دید که برای هر ۵ ویژگی

استفاده شده، طبقه‌بند FF-ANN عملکرد بهتری نسبت به طبقه‌بند SVM دارد.

در این پایان نامه برای کاهش بردار ویژگی، استخراج ویژگی فقط از ۴ کانال P3, TP7, T5 و

CP3 که سطح خستگی را به خوبی مشخص می‌کنند، استفاده شد و نتایج آن در جدول ۵-۱ ذکر شد.

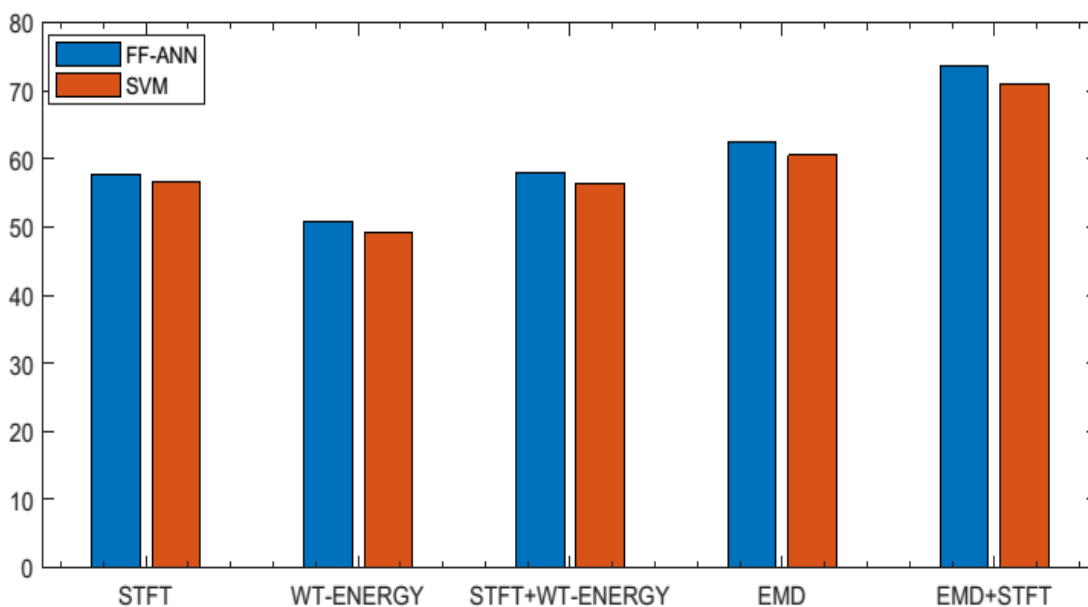
حال به منظور مقایسه با نتایج جدول ۵-۱، به جای ۴ کانال از ۱۰ کانال FC3, FCz, T5, T4, Oz,

O1, TP7, P3, T6 و CP3 ویژگی استخراج شده و نتایج آن در جدول ۵-۲ ذکر می‌شوند.

جدول ۲-۵: مقایسه روش پیشنهادی با روش‌های دیگر بر اساس دو طبقه‌بند ANN و SVM برای ۱۰ کانال

	STFT	WT ENERGY	STFT+WT ENERGY	EMD	روش پیشنهادی EMD+STFT
FF-ANN	۵۷/۷٪	۵۰/۹٪	۵۸٪	۶۲/۵٪	۷۳/۷٪
SVM	۵۶/۶٪	۴۹/۱٪	۵۶/۵٪	۶۰/۶٪	۷۱٪

با مقایسه جدول ۲-۵ با جدول ۱-۵ مشاهده می‌شود که با افزایش تعداد کانال‌ها و بزرگ شدن ابعاد بردار ویژگی نتایج افت خواهد کرد. شکل ۸-۵ نمودار میله‌ای جدول ۲-۵ را نشان می‌دهد.



۸-۵: نمودار میله‌ای مربوط به عملکرد دو طبقه‌بند ANN و SVM برای ۱۰ کانال

در جدول ۳-۵ عملکرد هر دو طبقه‌بند ANN و SVM برای ویژگی EMD در مقایسه با ویژگی EMD+STFT را بر اساس داده‌های آموزش و تست نشان داده می‌شود. پارامترهای ارزیابی در این

جدول مبتنی بر میزان دقت^۱، حساسیت^۲ و ویژگی^۳ داده‌ها می‌باشد.

جدول ۳-۵: عملکرد دو طبقه‌بند ANN و SVM برای مقایسه دو ویژگی EMD و روش پیشنهادی برای ۴ کانال

Classifiers		EMD		روش پیشنهادی EMD+STFT	
		Training Data	Testing Data	Training Data	Testing Data
ANN	Acc	۹۸٪	۷۲/۷٪	٪۹۴/۶	٪۹۲/۹
	Sn	۹۶/۲۲٪	۶۶٪	٪۹۳	۱۰۰٪
	Sp	۱۰۰٪	٪۸۰	۹۲٪	۸۷/۵۶٪
SVM	Acc	٪۹۰	۷۰/۶٪	۹۲/۵٪	۹۰/۸٪
	Sn	۸۹/۶٪	٪۸۳	۹۱/۸٪	۹۰/۷٪
	Sp	۸۹/۷٪	۸۴/۵٪	۹۲/۶٪	۹۲/۸٪

معیارهای ارزیابی در جدول فوق براساس میزان دقت، حساسیت و ویژگی برای داده‌های

آموزش و تست است. حساسیت و ویژگی در واقع دو معیار نسبت TN و TP را به کل تشخیص‌ها بیان

می‌کنند. این سه معیار طبق رابطه‌های ۱-۵، ۲-۵ و ۳-۵ محاسبه می‌شوند.

$$ACC = \frac{TP + TN}{TP + TN + FP + FN} \quad ۱-۵$$

$$Sp = \frac{TN}{TN + FP} \quad ۲-۵$$

$$Sn = \frac{TP}{TP + FN} \quad ۳-۵$$

^۱ Accuracy

^۲ Specificity

^۳ Sensitivity

TP درصد تشخیص صحیح شبکه برای نمونه‌هایی که مربوط به کلاس صفر هستند. TN درصد تشخیص صحیح شبکه برای نمونه‌هایی که مربوط به کلاس یک هستند. FP درصد تشخیص ناصحیح شبکه برای نمونه‌هایی که مربوط به کلاس صفر هستند. یعنی شبکه نمونه‌هایی که مربوط به کلاس صفر هستند را کلاس یک تشخیص داده است. FN درصد تشخیص ناصحیح شبکه برای نمونه‌هایی که مربوط به کلاس یک هستند. یعنی شبکه نمونه‌هایی که مربوط به کلاس یک هستند را کلاس صفر تشخیص داده است.

۵-۶- مقایسه روش پیشنهادی با روش‌های پیشین ذکر شده در برخی مقالات

در این بخش روش پیشنهادی با برخی روش‌های پیشین ذکر شده در فصل دوم مورد مقایسه قرار می‌گیرد. روش‌های استفاده شده برای استخراج ویژگی و طبقه‌بندی در این مقالات به‌همراه نتایج آنها در جدول ۴-۵ ارائه شده است.

جدول ۴-۵: مقایسه روش پیشنهادی با روش‌های پیشین

گروه تحقیق	رفرنس	انواع ویژگی‌ها	استخراج ویژگی	روش طبقه‌بندی	ACC
کینگ و همکاران (۲۰۰۶)	[۲۹]	EEG	باند های EEG آلفا، بتا و تتا	FF-ANN	٪ ۸۱/۴۹
شن و همکاران (۲۰۰۷)	[۳۰]	EEG	RF-INIT RF-RFE	SVM	٪ ۸۷/۷ ٪ ۸۴/۹
ژانگ و همکاران (۲۰۰۹)	[۳۱]	EEG	Wavelet Transform	KPCA-SVM Original-SVM Original-HMM	٪ ۸۵/۶۵ ٪ ۹۰/۷۱
خوشابا و همکاران (۲۰۱۱)	[۳۶]	EEG+EOG	Fuzzy Entropy	The fuzzy information based wavelet	٪ ۹۵
چای و همکاران (۲۰۱۶)	[۴۴]	EEG	تراکم طیف توان (PSD)	BNN	٪ ۷۶
ژانگ و همکاران (۲۰۱۶)	[۴۵]	EEG	W-NMIFS	LDA	٪ ۹۲/۸
روش پیشنهادی (۲۰۱۸)		EEG	STFT+EMD	FF-ANN SVM	٪ ۹۱/۳ ٪ ۹۰

۵-۷- جمع‌بندی

در این فصل نتایج و آزمایشات مبتنی بر روش EMD ارائه و بررسی شد و به‌منظور بهبود نتایج دو توصیفگر EMD و STFT برای با هم ترکیب شدند. در این فصل بیان شد که نتایج حاصل از روش ترکیب EMD+STFT نسبت به روش EMD از میزان دقت بالاتری برخوردار است. همچنین نتایج و آزمایشات نشان دادند که هر دو طبقه‌بند ANN و SVM عملکرد بهتری برای روش ترکیبی نسبت به روش EMD داشتند. سپس برای تأیید صحت روش پیشنهادی، روش پیشنهادی با کارهای انجام شده در گذشته به‌منظور تشخیص خستگی ذهنی در جدول ۵-۴ مورد مقایسه قرار گرفت.

فصل ششم

۶- نتیجه‌گیری و پیشنهادات

۶-۱- نتیجه گیری

همانطور که بیان شد، منظور از خستگی لزوماً خستگی فیزیکی نیست اما ممکن است فعالیت عادی شخص را تحت تأثیر قرار دهد. خستگی ذهنی می‌تواند جنبه‌های مختلف توانمندی، قدرت تمرکز و تصمیم‌گیری صحیح در انجام امور کارهای روزانه و بطور کلی قابلیت‌های انسان را تحت تأثیر قرار دهد، به‌گونه‌ای که با افزایش خواب‌آلودگی سطح عملکرد انسان به طرز قابل توجهی تضعیف می‌شود. وقوع این آسیب‌ها به راحتی منجر به بروز خطاهای انسانی و حوادث شده و سایر افراد جامعه را در معرض خطر قرار می‌دهد. بطور مشابه خستگی و ایجاد اختلال در خواب شبانه نیز یکی از عوامل تأثیر گذار بر توانایی‌های فرد بوده و یکی از مهمترین عوامل وقوع تلفات جاده‌ای می‌باشد. همچنین مشاغل با ساعت کار طولانی، کمبود استراحت و اختلال خواب از جمله مواردی هستند که در افزایش خستگی و اثرات ناشی از آن نقش دارند.

امروزه پیشرفت اتوماسیون اهمیت بسیاری برای نحوه اجرای مشاغل خاص که به عملکرد ذهنی بالا مانند پردازش اطلاعات و تجزیه و تحلیل و تصمیم‌گیری مناسب نیاز دارد، قائل است. اغلب متخصصان معتقدند که چنین محیط‌های کاری باعث افزایش فعالیت ذهنی و پیامدهای عمیق خستگی ذهنی و استرس می‌شوند. از این رو محققان به منظور جلوگیری از پیامدهای ناشی از خستگی ذهنی به بررسی دقیق‌تر این موضوع پرداخته‌اند.

از زمانی که مفهوم خستگی برای اولین بار معرفی شد، روش‌های متفاوتی برای بررسی و شناسایی آن ارائه شده است که در بین این روش‌ها به نظر می‌رسد سیگنال EEG معیارهای بهتری از میزان خستگی را ارائه می‌دهد و قدرت تخمین بالاتری برای تشخیص خستگی مغزی دارد. روش‌های مورد استفاده برای تشخیص خستگی ساختارهای متفاوتی است که برای استخراج ویژگی و طبقه‌بندی استفاده می‌کنند.

هدف از این پایان نامه، انتخاب معیاری صحیح برای ارزیابی وضعیت خستگی افراد است که از

ویژگی‌های سیگنال مغزی در حوزه زمان-فرکانس به منظور تشخیص خستگی استفاده شد. ارزیابی عملکرد الگوریتم پیشنهادی با سنجش میزان دقت و نرخ خطا (نمودار درهم ریختگی) و همچنین میزان سنجش حساسیت و ویژگی (نمودار ROC) در فصل ۵ ارائه شد.

هدف از این پایان نامه ارائه روشی مناسب برای تشخیص خستگی ذهنی با بررسی فرکانسی سیگنال‌های EEG بوده است. داده‌ها از ۱۲ نفر راننده در دو حالت نرمال و خسته با استفاده از سیستم ۱۰-۲۰ ثبت شده‌اند. از افراد خواسته شده بود ۲۴ ساعت قبل از شروع آزمایش کاملاً استراحت کرده و از خوردن هر دارویی پرهیز کنند. مدت زمان ثبت EEG برای هر فرد در هر دو حالت ۵ دقیقه بود و فرکانس نمونه برداری سیگنال ۱۰۰۰ هرتز در نظر گرفته شده است. سیگنال‌ها از ۴۰ کانال مختلف ثبت شده‌اند، ۱۰ تا از مهمترین آنها که مربوط به مناطق مرکزی و پیشانی هستند، برای تشخیص خستگی ذهنی در این پایان نامه انتخاب شدند.

قبل از شروع به کار داده‌ها پیش پردازش شدند تا آرتیفکت‌های ناشی از سیگنال‌های EOG و EMG از بین روند. در این پایا نامه طول دیتا برای هر کانال ۶۰۰۰۰۰ نمونه به دست آمده است که به دلیل زیاد بودن طول دیتا از پنجره با طول ۱۰۰۰ برای بخش بخش کردن سیگنال استفاده شده و سپس الگوریتم EMD به منظور استخراج ویژگی از سیگنال‌های EEG بر روی هر بخش اعمال شده است. سپس این ویژگی‌ها از طریق روش SVM با استفاده از نگاشت غیرخطی آن طبقه‌بندی شده‌اند. برای نشان دادن قدرت روش استفاده شده در این پایان‌نامه الگوریتم پیشنهادی با روش‌های دیگر مورد مقایسه قرار گرفت که نتایج آن در فصل ۵ ارائه شد.

۲-۶- پیشنهادات برای کارهای آینده

نتایج حاصل نشان داد که روش پیشنهادی می‌تواند به خوبی سطح خستگی ذهنی را مشخص کند. از جمله کارهای پیشنهادی برای آینده می‌توان به کارهای زیر اشاره نمود:

۱- انتخاب سیگنال‌های حیاتی دیگر مانند ECG, EMG و یا EOG در کنار سیگنال EEG برای

انجام دیتا فیوژن و بهبود عملکرد در تشخیص خستگی ذهنی

دیتا فیوژن روشی مناسب برای ارتباط جمع آوری و همبستگی اطلاعات می‌باشد که در این روش اطلاعات از یک یا چند منبع ورودی وارد شده و نتیجه‌ی تجزیه و تحلیل اطلاعات بصورت برآیند داده‌ها نشان داده می‌شود. براساس روش دیتا فیوژن می‌توان همزمان از اطلاعات چند سیگنال حیاتی استفاده نموده و برآیند ویژگی‌های آنها به‌عنوان بردار ورودی برای تشخیص خستگی ذهنی به طبقه‌بند داده شود.

۲- استفاده از تبدیل موجک به‌منظور حذف نویز و استخراج ویژگی به روش EMD البته با

انتخاب روشی مناسب به‌منظور کاهش پیچیدگی الگوریتم EMD برای بهبود سرعت و همچنین استفاده از الگوریتم فازی-عصبی برای عملکرد بهتر دقت طبقه‌بندی

۳- استفاده از تکنیک‌های پردازش تصویر و بینایی ماشین برای استخراج حالت‌های ظاهری افراد

در هنگام انجام یک کار طولانی مدت مانند رانندگی

۴- استفاده از فیلتر Adaptive به منظور پیش پردازش داده‌ها و استفاده از الگوریتم Fisher

به‌منظور کاهش بعد ویژگی‌های موجک و طبقه‌بندی ویژگی‌ها به روش SVM

- [1] Grandjean, E. (1981) "Fitting the Task to the Man." *London: Taylor & Francis*, 4th Edition.
- [2] Rospa, (2001) "Driver Fatigue and Road Accidents- A Literature Review and Position Paper Birmingham" *The Royal Society for the Prevention of Accidents*.
- [3] Lal S. K. L. and Craig A. (2002), "Driver fatigue: Electroencephalography and psychological assessment", *Psychophysiology*, **39**, **3**, pp **313-321**.
- [4] Van der Linden D, Frese M. and Meijman TF. (2003) "Mental fatigue and the control of cognitive processes: effects on perseveration and planning". *Acta. Psychol.* **113**, **1**, pp **45-65**.
- [5] Boksem MAS, Meijman TF, Lorist MM. (2006), "Mental fatigue, motivation and action monitoring". *Biol. Psychol.* **72**, **2**, pp **123-132**.
- [6] Shallice T, Stuss DT, Alexander MP, Picton TW, Derkzen D. (2008), "The multiple dimensions of sustained attention". *Cortex*, **44**, **7**, pp **794-805**.
- [7] Zhang C., Zheng C-X. and Yu X-L. (2009) "Automatic recognition of cognitive fatigue from physiological indices by using wavelet packet transform and kernel learning algorithms", *Expert Systems with Applications*, **36**, **3**, pp **4664-4671**.
- [8] Hua J., Wang C-S., Wu M., Du Y-X., He Y. and Sheard J. (2015) "Removal of EOG and EMG artifacts from EEG using combination of functional link neural network and adaptive neural fuzzy inference system". *Neurocomputing*, **151**, **1**, pp **278-287**.
- [9] Berger, H. (1929) "On the Electroencephalogram of Man." *Journal fur Psychology and Neurology*, **40**, pp **160-179**.
- [10] Chandaka S., Chatterjee A. and Munshi Su. (2009) "Cross-correlation aided support vector machine classifier for classification of EEG signals" *Expert Systems with Applications*, **36**, pp **1329-1336**.
- [11] Sanei S. and Chambers J. A. (2007) "EEG SIGNAL PROCESSING", John Wiley &

Sons Ltd.

[12] Molina, G. A., Ebrahimi, T., and Vesin, J.-M. (2003) “Joint time–frequency–space classification of EEG in a brain computer interface application” *EURASIP J. on Appl. Sig. Proces.* **2003**, pp **713-729**.

[13] Donchin, E., Spencer, K. M., and Wijesinghe, R. (2000) “The mental prosthesis: assessing the speed of a P300-based brain–computer interface”, *IEEE Trans. Rehabil. Engng*, **8**, pp **174-179**.

[14] Bayliss, J. D. (2001) “A flexible brain–computer interface” PhD Thesis, *University of Rochester*, New York.

[15] Stelt O. V. D. and Belger A. (2007) “Application of Electroencephalography to the Study of Cognitive and Brain Functions in Schizophrenia” *Schizophrenia Bulletin*, **33**, **4**, pp **955-970**.

[16] Lorist M. M., Klein M., Nieuwenhuis S., Jong R. D., Mulder G. and Meijman TF (2000) “Mental fatigue and task control: planning and preparation” *Psychophysiology*, **37**, pp **614-625**.

[17] Boksem M. A. S., Meijman T. F. and Lorist M.M. (2005) “Effects of mental fatigue on attention: an ERP study”, *Cogn. Brain Res.* **25**, pp **107-116**.

[18] Shen K-Q., Li X-P., Ong C-J., Shao S-Y. and Wilder-Smith E. P. V. (2008) “EEG-based mental fatigue measurement using multi-class support vector machines with confidence estimate” *Clin Neurophysiol.* **119**, **7**, pp **1524-1533**.

[19] Klimesch, W. (1999) “EEG alpha and theta oscillations reflect cognitive and memory performance: A review and analysis” *Brain Research Reviews*, **29**, (2–3), pp **169-195**.

[20] Eoh, H. J., Chung, M. K., and Kim, S. H. (2005) “Electroencephalographic study of drowsiness in simulated driving with sleep deprivation” *International Journal of Industrial Ergonomics*, **35**, **4**, pp **307-320**.

[21] Trejo L. J., Knuth K., Prado R., Rosipal R., Kubitz K., Kochavi R., Matthews B. and

Zhang Y. (2007) "EEG-Based Estimation of Mental Fatigue: Convergent Evidence for a Three-State Model" *Lecture Notes in Computer Science*, **4565**, pp **201-211**.

[22] Lal, S. K. L., and Craig, A.A. (2001) "critical review of the psychophysiology of driverfatigue" *Biological Psychology*, **55**, **3**, pp **173-194**.

[23] Shen K.Q., Ong C.J., Li X.P., Hui Z. and Wilder-Sniith E.P.V. (2007) "feature selection method for multilevel mental fatigue EEG classification" *IEEE Trans. Biomed. Eng.* **54**, **7**, pp **1231-1237**.

[24] Lal, S.K.L., Craig, A., Boord, P., Kirkup, L. and Nguyen, H. (2003) "Development of an algorithm for an EEG based driver fatigue countermeasure." *Journal of Safety Research*, **34**, pp **321-328**.

[25] Mallis, M.M. (1999) "Evaluation of techniques for drowsiness detection: Experiment on performance-based validation of fatigue-tracking technologies" *Drexel University*, **21**, pp **210-215**.

[26] Okogbaa O. G., Shell R. L. and Filipusic D. (1994) "On the investigation of the neurophysiological Correlates of Knowledge Worker mental fatigue Using the EEG Signal" *Applied Ergonomics*, **25**, **6**, pp **355-365**.

[27] Lal S. K. L. and Craig A. (2002) "Driver fatigue: Electroencephalography and psychological assessment" *Psychophysiology*, **39**, **3**, pp **313-321**.

[28] Boksem M. A. S., Meijman T. F. and Lorist M. M. (2006) "Mental fatigue, motivation and action monitoring" *Biological Psychology*, **72**, **2**, pp **123-132**.

[29] King L. M., Nguyen H. T. and Lal S. K. L. (2006) "Early Driver Fatigue Detection from Electroencephalography Signals using Artificial Neural Networks" *International Conference of the IEEE Engineering in Medicine and Biology Society*, **9210727**.

[30] Shen K-Q., Ong C-J., Li X-P., Hui Z. and Wilder Smith E. P. V. (2007) "A Feature Selection Method for Multilevel Mental Fatigue EEG Classification" *IEEE Transactions on Biomedical Engineering*, **54**, **7**, pp **1231-1237**.

[31] Zhang C., Zheng C-X. and Yu X-L. (2009) "Automatic recognition of cognitive

fatigue from physiological indices by using wavelet packet transform and kernel learning algorithms” *Expert Systems with Applications*, **36**, **3**, pp **4664-4671**.

[32] Liu J., Zhang C. and Zheng C. (2010) “EEG-based estimation of mental fatigue by using KPCA–HMM and complexity parameters” *Biomedical Signal Processing and Control*, **5**, **2**, pp **124-130**.

[33] Pincus, S.M. (1991) “Approximate entropy as a measure of system complexity.” *PANS*, **88**, **6**, pp **2297-2301**.

[34] Hong B., Yang F.S., Tang Q.Y., Chan T.C. “Approximate entropy and its preliminary application in the field of EEG and cognition.” *The 20th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, **6396169**.

[35] Lempel A., Ziv J. (1976) “On the complexity of finite sequence.” *IEEE Transactions on Information Theory*, **22**, **1**, pp **75-81**.

[36] Rami N. Khushaba*, Sarath Kodagoda, Sara Lal, and Gamini Dissanayake,(2011), “Driver Drowsiness Classification Using Fuzzy Wavelet-Packet-Based Feature-Extraction Algorithm”,IEEE TRANSACTIONS ON BIOMEDICAL ENGINEERING, VOL. 58, NO. 1, JANUARY,

[37] کوچکی س، (۱۳۹۰)، پایان نامه ارشد: “ارائه یک شاخص نوین برای سنجش سطح خستگی مغزی در حین فعالیت ذهنی از روی سیگنال EEG”، دانشکده مهندسی، دانشگاه شیراز.

[38] Azarnoosh M., Motie N. A., Mohammadi M. R. and Firoozabadi M. (2011) “Investigation of mental fatigue through EEG signal processing based on nonlinear analysis: Symbolic dynamics” *Chaos, Solitons & Fractals*, **44**, pp **1054-1062**.

[39] Borghini G., Vecchiato G., Toppi J., Astolfi L., Maglione A., Isabella R., Caltagirone C., Kong W., Wei D., Zhou Z., Polidori L., Vitiello S. and Babiloni F. (2012) “Assessment of mental fatigue during car driving by using high resolution EEG activity and neurophysiologic indices” *34th Annual International Conference of the IEEE EMBS San Diego, California USA*, **13131276**.

[40] Roy R. N., Bonnet S., Charbonnier S. and Campagne A. (2013) “Mental fatigue and

working memory load estimation: Interaction and implications for EEG-based passive BCI” *35th Annual International Conference of the IEEE EMBS Osaka, Japan*, **13813095**.

[41] Zhao J., Pan P., Fu W. and Ma C. (2014) “Research on Mental Fatigue Detection Based on Portable EEG Acquisition Equipment” *Proceeding of the 11th World Congress on Intelligent Control and Automation Shenyang, China*, **14966844**.

[42] Wang F., Lin J., Wang W. and Wang H. (2015) “EEG-based mental fatigue assessment during driving by using sample entropy and rhythm energy” *The 5th Annual IEEE International Conference on Cyber Technology in Automation, Control and Intelligent Systems*, **15490319**.

[43] Liu Y-T. and Lin Y-Y. (2015) “Assessment of Mental Fatigue: An EEG-based Forecasting System for Driving Safety” *IEEE International Conference on Systems*, **15718881**.

[44] Chai R., Tran Y., Naik G. R., Nguyen T. N., Ling S. Ho., Craig A. and Nguyen H. T. (2016) “Classification of EEG based-Mental Fatigue using Principal Component Analysis and Bayesian Neural Network” *38th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, **16395076**.

[45] Zhang P., Wang X., Li X. and Dai P. (2016) “EEG Feature Selection Based on Weighted-Normalized Mutual Information for Mental Fatigue Classification” *IEEE International Instrumentation and Measurement Technology Conference Proceedings*, **16159822**.

[46] Mu Z., Hu J. and Min J. (2017) “Driver Fatigue Detection System Using Electroencephalography Signals Based on Combined Entropy Features” *Applied. Science*, **7, 2**, p **150**.

[47] Min J., Wang P. and Hu J. (2017) “Driver fatigue detection through multiple entropy fusion analysis in an EEG-based system” *PLoS ONE*, **12, 12**, **e0188756**.

[48] حافظى مطلق ن، خليلزاده م.ع، مقیمی ع “حذف آرتیفکت پلکزدن از سیگنال EEG: مقایسه

الگوریتم PCA و فیلتر تطبیقی” (۱۳۸۷) پانزدهمین کنفرانس مهندسی پزشکی ایران.

- [49] Haar, A. (1910) “Zur Theorie der orthogonalen Funktionensysteme” *Mathematische Annalen*, **69**, **3**, pp **331-371**.
- [50] Cvetkovic D., Übeyli E. D. and Cosic I. (2008) “Wavelet transform feature extraction from human PPG, ECG, and EEG signal responses to ELF PEMF exposures: A pilot study” *Digital Signal Processing*, **18**, **5**, pp **861-874**.
- [51] Riaz F., Hassan A., Rehman S., Niazi I. K. and Dremstrup K. (2015) “EMD based Temporal and Spectral Features for the Classification of EEG Signals Using Supervised Learning” *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, **24**, **1**, pp **28-35**.
- [52] Alam S. and Bhuiyan M. (2013) “Detection of seizure and epilepsy using higher-order statistics in the emd domain,” *Journal of Biomedical and Health Informatics, IEEE*, **17**, **2**, pp **312-318**.
- [53] Tzallas A., Tsipouras M., and Fotiadis D. (2007) “Automatic seizure detection based on time-frequency analysis and artificial neural networks” *Computational Intelligence and Neuroscience*, **80510**, pp **1-13**.
- [54] Adeli H., Ghosh-Dastidar S., and Dadmehr N. (2007) “A wavelet-chaos methodology for analysis of eegs and eeg subbands to detect seizure and epilepsy” *IEEE Transactions on Biomedical Engineering*, **54**, **2**, pp **205-211**.
- [55] Boashash B. (1992) “Estimating and interpreting the instantaneous frequency of a signal. i. fundamentals” *Proceedings of the IEEE*, **80**, **4**, pp **520-538**.
- [56] Cortes C. and Vapnik V. (1995) “Support vector networks” *Machine Learning*, **20**, **3**, pp **273-297**.
- [57] Chandaka S., Chatterjee A. and Munshi S. (2009) “Cross-correlation aided support vector machine classifier for classification of EEG signals” *Expert Systems with Applications*, **36**, **2**, pp **1329-1336**.
- [58] Hofmann M. (2006) “Support vector machines-Kernels and the kernel trick” *University of Bamberg*.

[59] Bishop C. M. (2006) “Pattern Recognition and Machine Learning” *Springer Science +Business Media, LLC*.

Abstract

Fatigue is an important and natural response to many physical activities, long-term mental stress, sleep deprivation and also a non-specific symptom of physical or mental disorder. Undoubtedly, all people experienced fatigue feeling after a severe mental activity or a lot thinking. This feeling is just like when the human body gets tired after long-term exercise. In general, fatigue topics are divided into "physical fatigue" and "mental fatigue" categories. Fatigue affects many aspects of a person's life. This vague and unpleasant symptom undermines his life by negatively affecting a person's ability to carry out daily activities. The past researches have shown that electroencephalogram signals (EEGs) are more accurate and high-performance among the various techniques of the fatigue testing.

The purpose of this study is to analyze the symptoms of mental fatigue that appears in people's brain signals. In order to evaluate the signals, first was used a filter to pre-processing the data then, to extract the features, empirical mode decomposition (EMD) method was applied to decompose the signal into its frequency components. These frequency components are called intrinsic mode functions (IMFs) which are obtained by applying EMD on EEG signals and used as input vector in a classifier. Also, to improve the results, a combination of two EMD and STFT techniques was presented as a proposed method.

The artificial neural network (ANN) and support vector machine (SVM) classifiers were used for the classification of the obtained features. Then, the Short Time Fourier transform, wavelet energy in EEG signal bands and the combination of these methods were compared with the proposed method. The results of the proposed method, using the two Classifier of ANN and SVM, are respectively 91.3% and 90%, respectively, and also three parameters Accuracy (ACC), sensitivity (Sn) and Specificity (Sp) were used to evaluate the results.

Keywords: EEG signals, Mental Fatigue, SVM Classifier, Artificial neural network, Empirical Mode Decomposition (EMD).



Shahrood University of Technology
Faculty of Electrical and Robotics Engineering

M. Sc. Thesis in Communication Systems Engineering

Mental fatigue detection using EEG power spectrum

By

Mahsa Jamshidi Nia

Supervisor

Dr. Hossein Marvi

Advisor

Dr. Saeedeh Ferdowsi

Aug 2018