



Driver Drowsiness Detection using Zero Crossing Rate Feature Extracted from EEG Signals Recorded by Consumer-Grade Headsets

Giveki, Ashkan¹ / Setarehdan, Seyed-Kamaleddin^{2*}

¹ - M.Sc., School of Electrical and Computer Engineering, College of Engineering, University of Tehran, Tehran, Iran

² - Professor, Biomedical Engineering Group, School of Electrical and Computer Engineering, College of Engineering, University of Tehran, Tehran, Iran

ARTICLE INFO

DOI: 10.22041/ijbme.2024.2037251.1916

Received: 1 August 2024

Revised: 31 August 2024

Accepted: 23 September 2024

KEYWORDS

Driver Drowsiness
EEG
Zero Crossing Rate
Muse Headsets
Real-Time Detection
Driving Simulator
ORD

ABSTRACT

Driver drowsiness is recognized as one of the leading causes of accidents and road incidents globally. In recent years, considerable efforts have been directed towards developing effective tools for detecting and predicting driver drowsiness using cost-effective methods suitable for public use. Biological signals, particularly electroencephalogram (EEG), have become highly valued for their immediate reflection of drowsiness-induced changes in detecting driver alertness and fatigue. Despite significant advancements in drowsiness detection, researchers continue to strive for enhanced accuracy in detection models by extracting novel and relevant features from EEG signals. In this study, we introduce a new set of features derived from EEG signals and develop an algorithm to predict driver drowsiness using these features. The dataset used in this study was gathered from 50 volunteers during driving activity in the Nasir driving simulator, employing consumer-grade headsets Muse 2 and Muse S to record EEG signals. Following preprocessing and segmentation of the signals into 30-second epochs, features including the zero-crossing rate of the original signal, as well as its first and second derivatives, were extracted. Statistical analysis identified 11 features which exhibited significant differences between the states of alertness and drowsiness. These features were then utilized to develop a predictive model employing KNN and SVM classifiers. The maximum accuracy achieved in predicting driver drowsiness using the proposed algorithm was 86.37%. Hence, the introduced features are proposed as effective parameters for enhancing the accuracy of drowsiness prediction.

***Corresponding Author**


Address: Biomedical Engineering Group, School of Electrical and Computer Engineering, College of Engineering, University of Tehran, Tehran, Iran

Postal Code: 14395-515

E-Mail: ksetareh@ut.ac.ir

Tel: +98-21-61114177





تشخیص خواب‌آلودگی رانندگان با استفاده از ویژگی‌های نرخ عبور از صفر استخراج شده از سیگنال‌های EEG ثبت شده با هدست‌های رده‌ی مصرف کننده

گیوه‌کی، اشکان^۱ / ستاره‌دان، سیدکمال‌الدین^{۲*}

^۱ - کارشناسی ارشد، دانشکده‌ی مهندسی برق و کامپیوتر، پردیس دانشکده‌های فنی، دانشگاه تهران، تهران، ایران
^۲ - استاد، گروه مهندسی پزشکی، دانشکده‌ی مهندسی برق و کامپیوتر، پردیس دانشکده‌های فنی، دانشگاه تهران، تهران، ایران

مشخصات مقاله

شناسه‌ی دیجیتال: 10.22041/ijbme.2024.2037251.1916

پذیرش: ۲ مهر ۱۴۰۳

بازنگری: ۱۰ شهریور ۱۴۰۳

ثبت در سامانه: ۱۱ مرداد ۱۴۰۳

چکیده

واژه‌های کلیدی

خواب‌آلودگی رانندگان به عنوان یکی از عمده‌ترین دلایل تصادفات و سوانح رانندگی در سرتاسر جهان شناخته می‌شود. در سالیان اخیر تلاش‌های زیادی جهت تشخیص خواب‌آلودگی رانندگان به وسیله‌ی ابزارهای با قیمت مقرون به صرفه به منظور امکان استفاده‌ی عمومی صورت گرفته است. سیگنال‌های حیاتی به ویژه سیگنال الکتروانسفالوگرام (EEG) به دلیل بازتاب آبی تغییرات ناشی از خواب‌آلودگی در تشخیص هوشیاری و خواب‌آلودگی رانندگان، کاربرد و محبوبیت زیادی پیدا کرده است. علی‌رغم پیشرفت شگرفی که در سالیان گذشته در تشخیص خواب‌آلودگی رانندگان ایجاد شده است، محققان همچنان به دنبال افزایش صحت مدل‌های تشخیص دهنده به وسیله‌ی استخراج ویژگی‌های جدید و مناسب از سیگنال EEG هستند. در این مقاله پس از معرفی یک دسته‌ی ویژگی‌های جدید از سیگنال EEG، الگوریتمی برای تشخیص خواب‌آلودگی رانندگان با استفاده از این ویژگی‌ها توسعه داده شده است. برای جمع‌آوری داده‌های مورد استفاده در این مطالعه سیگنال EEG از ۵۰ داوطلب در حین رانندگی در شبیه‌ساز رانندگی نصیر به وسیله‌ی هدست‌های تجاری Muse 2 و Muse S ثبت شده است. پس از پیش‌پردازش سیگنال‌ها و دسته‌بندی آن‌ها در اپیاک‌های ۳۰ ثانیه‌ای، ویژگی‌های نرخ عبور از صفر مربوط به سیگنال اصلی و مشتق اول و دوم این سیگنال استخراج شده است. پس از اعمال آزمون‌های آماری بر ویژگی‌های استخراج شده، از ۱۱ ویژگی که در دو کلاس هوشیاری و خواب‌آلودگی تفاوت معناداری داشتند برای توسعه‌ی مدل با استفاده از طبقه‌بندهای KNN و SVM بهره گرفته شده است. حداکثر صحت حاصل در تشخیص خواب‌آلودگی رانندگان با استفاده از الگوریتم پیشنهادی برابر با ۸۶/۳۷٪ می‌باشد. در نتیجه می‌توان ویژگی‌های پیشنهادی در این مقاله را به عنوان پارامترهایی موثر در جهت بهبود کیفیت تشخیص خواب‌آلودگی رانندگان معرفی کرد.

خواب‌آلودگی رانندگان
الکتروانسفالوگرام
نرخ عبور از صفر
هدست میوز
تشخیص بی‌درنگ
شبیه‌ساز رانندگی
ارزیابی ناظر از خواب‌آلودگی

*نویسنده‌ی مسئول

نشانی: گروه مهندسی پزشکی، دانشکده‌ی مهندسی برق و کامپیوتر، پردیس دانشکده‌های فنی، دانشگاه تهران، تهران، ایران

تلفن: ۶۱۱۱۴۱۷۷-۲۱-۹۸+

پست الکترونیک: ksetareh@ut.ac.ir

کد پستی: ۵۱۵-۱۴۳۹۵



۱- مقدمه

هوشیاری در بسیاری از موارد از جمله رانندگی، شغل‌های شیفیتی، نگهبانی شبانه، خلبانی و مشاغل عمرانی اهمیت زیادی دارد [۱]. اصلی‌ترین دلیل تصادفات رانندگی در سرتاسر جهان، خواب‌آلودگی بوده که ممکن است در حین رانندگی با هر وسیله‌ی نقلیه رخ دهد اما بیش‌تر موارد گزارش شده، مربوط به حمل و نقل راه دور می‌باشد [۲].

مطابق آمارهای اعلام شده، از سال ۲۰۱۷ تا سال ۲۰۲۱ بیش از ۹۱ هزار تصادف ناشی از خواب‌آلودگی رانندگان در آمریکا گزارش شده که حدود ۵۰۰۰۰ مصدوم و نزدیک به ۸۰۰ فوتی در پی داشته است [۳]. رانندگی در حالت خواب‌آلودگی به یک نگرانی مهم در حوزه‌ی ایمنی ترافیک تبدیل شده که از الگوهای زندگی مدرن سرچشمه می‌گیرد. در سال ۲۰۲۱ تعداد ۶۸۴ مرگ ناشی از تصادفات مربوط به خواب‌آلودگی گزارش شده که معادل ۱/۶٪ کل افراد فوت شده در سوانح رانندگی است.

گزارش‌های منتشر شده از سازمان ملی ایمنی ترافیک بزرگ‌راه‌های آمریکا بیان می‌کند که خواب‌آلودگی رانندگان در ۱/۸٪ سوانح رانندگی منجر به فوت در بین سال‌های ۲۰۱۷ تا ۲۰۲۱ نقش داشته است [۴]. هرچند بیش‌تر توجهات و پژوهش‌های ابتدایی در حوزه‌ی خواب‌آلودگی رانندگان، مختص به رانندگان کامیون‌های تجاری بوده، اما دامنه‌ی پیامدها بسیار وسیع‌تر است. برای مثال در سال ۲۰۱۴ در یک نظرسنجی از ۴۴۴۳۰۶ فرد بالای ۱۸ سال در آمریکا، بیش از یک‌سوم شرکت‌کنندگان اذعان داشته‌اند که میزان خواب آن‌ها در طول شبانه‌روز کم‌تر از ۷ ساعت (حداقل میزان خواب توصیه شده برای داشتن سلامت کافی) بوده است. طبق یافته‌های شاخص فرهنگ ایمنی ترافیک انجمن اتوموبیل آمریکا در سال ۲۰۱۷، از میان ۲۶۱۳ فرد شرکت‌کننده در مطالعه، بیش از ۴۰٪ افراد بیان کرده‌اند که در یک هفته‌ی کاملاً معمولی، به صورت میانگین کم‌تر از ۶ ساعت خواب شبانه داشته‌اند [۵]. همین انجمن در گزارش سال ۲۰۲۲ خود اعلام کرده است که از میان ۲۶۶۸ فرد شرکت‌کننده در نظرسنجی، ۱۷/۹٪ افراد در یک ماه منتهی به نظرسنجی، سابقه‌ی رانندگی در حالتی را داشته‌اند که از فرط خواب‌آلودگی به سختی می‌توانستند چشمان خود را باز نگه دارند. هم‌چنین ۰/۲٪ از شرکت‌کنندگان اذعان کرده‌اند که رانندگی در این حالت برای آن‌ها به یک امر کاملاً معمولی تبدیل شده و در یک ماه گذشته بارها آن را تجربه کرده‌اند [۶]. با در نظر گرفتن آمار و شواهد مطرح شده که خواب‌آلودگی را به عنوان عاملی مهم در تصادفات و مرگ و

میرهای جاده‌ای مطرح می‌کنند، تشخیص زودهنگام خواب‌آلودگی رانندگان به یک امر بسیار حیاتی برای جلوگیری از این گونه وقایع و افزایش ایمنی جاده‌ها تبدیل شده است. عوامل زیادی در تصادفات ناشی از خواب‌آلودگی موثر هستند که از جمله‌ی آن‌ها می‌توان به نوع خودرو، زمان وقوع، شرایط فیزیکی و روحی فرد و میزان خواب راننده پیش از شروع سفر اشاره کرد [۷]. صنایع خودروسازی تلاش‌های بسیاری در جهت توسعه‌ی روش‌های تشخیص خواب‌آلودگی رانندگان انجام داده‌اند [۸]. عمده‌ی تلاش‌های صورت گرفته به یکی از روش‌های استفاده از پارامترهای وسیله‌ی نقلیه، استفاده از پارامترهای رفتاری راننده و استفاده از ویژگی‌های فیزیولوژیکی راننده مرتبط می‌شود. در روش استفاده از پارامترهای وسیله‌ی نقلیه، مولفه‌هایی چون الگوی فشار وارد بر پدال‌ها، الگوی چرخش فرمان خودرو، انحراف از لاین‌ها و اطلاعات حس‌گر سیستم موقعیت‌یاب جهانی^۱ (GPS) مورد بررسی قرار می‌گیرد. مزیت این روش، نامحسوس و بدون تماس بودن ابزار مورد استفاده با راننده بوده اما علی‌رغم این موارد، روش مذکور دارای معایب متعددی است. برای مثال، عوامل خارجی مانند باد و وضعیت جاده می‌توانند منجر به ایجاد هشدار نادرست توسط سیستم شوند ضمن این که خواب‌آلودگی لزوماً باعث تغییر واضح در پارامترهای مورد استفاده در این روش نمی‌شود و ممکن است سیستم قادر به تشخیص خواب‌آلودگی نباشد. هم‌چنین وابسته بودن این روش به نوع خودرو باعث می‌شود که در کاربردهای دیگر مورد استفاده قرار نگیرد و هزینه‌ی بیش‌تری را در پی داشته باشد [۹]. در روش استفاده از پارامترهای رفتاری راننده، ویژگی‌هایی از جمله بسته بودن چشم، نرخ پلک زدن، الگوی حرکات سر و دمای صورت مورد استفاده قرار می‌گیرد. ابزار این روش نیز مانند مورد قبل، تماسی با راننده نداشته و مزاحمتی برای وی ایجاد نمی‌کند اما این روش نیز محدودیت‌ها و ضعف‌های خاص خود را دارد. برای مثال، استفاده‌ی راننده از عینک می‌تواند باعث کاهش صحت این روش شود. علاوه بر آن، استفاده از دوربین‌های حرارتی برای تشخیص دمای صورت، مقرون به صرفه نیست. هم‌چنین وجود دوربین در خودرو برای پایش پارامترهای مورد بررسی، باعث ایجاد شدن نگرانی‌های بسیاری از جهت مسائل امنیتی از جمله تحت نظارت قرار داشتن شده است [۱۰، ۱۱].

محدودیت‌ها و ضعف‌های دو روش مذکور سبب شده است تا در سالیان اخیر توجه زیادی به استفاده از پارامترهای فیزیولوژیکی رانندگان برای تشخیص خواب‌آلودگی آن‌ها شود. از جمله‌ی این

^۱ Global Positioning System

استخراج ۱۱ ویژگی آماری از سیگنال‌های EEG ثبت شده و استفاده از الگوریتم یادگیری ماشین K نزدیک‌ترین همسایه^۷ (KNN) به صحتی برابر با ۹۲٪ دست پیدا کرده‌اند [۲۱]. با توجه به مطالعات بررسی شده، تا به حال محققان از ویژگی‌های زیادی برای تشخیص خواب‌آلودگی رانندگان استفاده کرده‌اند و هم‌چنان تلاش برای یافتن ویژگی‌های مناسب دیگر که علاوه بر ایجاد تمایز کافی میان خواب‌آلودگی و هوشیاری رانندگان، از نظر هزینه‌ی محاسباتی نیز به صرفه باشند، ادامه دارد.

نرخ عبور از صفر^۸ (ZCR) که به عنوان یک ویژگی پرکاربرد در پردازش سیگنال‌های صوتی و زبان‌های طبیعی شناخته می‌شود [۲۲]، در مطالعات انگشت‌شماری در حوزه‌ی پردازش سیگنال الکتروانسفالوگرام و تشخیص خواب‌آلودگی رانندگان مورد استفاده قرار گرفته است. در این مطالعه با استخراج ویژگی‌های ZCR توسعه داده شده از دادگان ثبت شده، به تشخیص هوشیاری و خواب‌آلودگی رانندگان پرداخته شده است.

۲- مواد و روش‌ها

۲-۱-۱- دادگان

به منظور در اختیار داشتن یک مجموعه‌ی داده‌ی استاندارد و با شرایط مطلوب، فرایند ثبت سیگنال الکتروانسفالوگرام از داوطلبان در یک شبیه‌ساز رانندگی به وسیله‌ی هدست‌های تجاری و رده‌ی مصرف کننده صورت گرفته است.

۲-۱-۱- شرکت کنندگان

از ۵۰ داوطلب شامل ۲۸ مرد و ۲۲ زن برای ثبت دادگان دعوت شده است. شروط شرکت داشتن فرد در این مطالعه شامل سن بین ۲۰ تا ۵۰ سال، شاخص توده‌ی بدنی کم‌تر از ۴۰ kg/m² و سابقه‌ی حداقل دو سال رانندگی پس از دریافت گواهی‌نامه است. افراد دارای سابقه‌ی مصرف دخانیات، سابقه‌ی ناهنجاری‌های مرتبط به خواب و یا ابتلا به بیماری‌های قلبی دارای شرایط ورود به مطالعه نبوده‌اند. میانگین سنی فرد شرکت کننده در مطالعه برابر با ۲۷ سال و ۶ ماه و میانگین شاخص توده‌ی بدنی آن‌ها ۲۴/۷۲ kg/m² است.

۲-۱-۲- محیط اجرای آزمون

فرایند ثبت داده در شبیه‌ساز رانندگی نصیر واقع در دانشکده‌ی مکانیک دانشگاه خواجه نصیرالدین طوسی انجام شده است. این

پارامترها می‌توان به سیگنال‌های الکتروانسفالوگرام^۱ (EEG)، الکتروکاردیوگرام، الکترومیوگرام، اکترواوکولوگرام و فوتوپلتیسموگرام اشاره کرد. در میان این سیگنال‌ها، سیگنال EEG به دلیل ارتباط قوی با خواب‌آلودگی بهترین گزینه برای استفاده در تشخیص خواب‌آلودگی رانندگان است [۱۲-۱۴]. علاوه بر این، وجود هدست‌های بی‌سیم رده‌ی مصرف کننده‌ی تولید شده در سالیان اخیر باعث شده است که فرایند ثبت سیگنال مغزی از رانندگان در حین رانندگی، کاملاً عملی شود و بدون ایجاد هیچ‌گونه مزاحمتی برای فرد صورت پذیرد [۱۵]. الگوریتم‌های پردازش این نوع سیگنال نیز به راحتی روی ابزارهایی مانند گوشی‌های هوشمند قابل اجرا است. در مطالعات مقایسه‌ای نشان داده شده است که هدست‌های تجاری و رده‌ی مصرف کننده، کاملاً از کیفیتی قابل رقابت با هدست‌های کلینیکی برخوردار هستند [۱۶]. در سال‌های اخیر تحقیقات زیادی با استفاده از سیگنال EEG برای تشخیص خواب‌آلودگی رانندگان ارائه شده است. در اغلب این مطالعات، ابتدا سیگنال EEG توسط الگوریتم‌های موجود پیش‌پردازش شده و سپس برخی ویژگی‌ها از سیگنال استخراج شده است. پس از اطمینان از کارایی این ویژگی‌ها توسط آزمون‌های آماری، با بهره‌گیری از طبقه‌بندهای گوناگون، مدلی برای تشخیص خواب‌آلودگی در رانندگان به دست آمده است. در سال ۲۰۲۲ گواردا و هم‌کارانش پس از استخراج ویژگی چگالی طیف توان^۲ (PSD) از سیگنال به وسیله‌ی شبکه‌های عصبی کانولوشنی^۳ (CNN)، آن‌ها را طبقه‌بندی کرده و به صحت ۸۶/۴۴٪ در تشخیص هوشیاری رانندگان دست یافته‌اند [۱۷]. در همین سال چن و هم‌کارانش با استفاده از CNN برای طبقه‌بندی ویژگی‌های PSD و آنتروپی چندمقیاسه از سیگنال EEG به صحت ۹۴٪ در تشخیص خواب‌آلودگی رانندگان دست یافته‌اند [۱۸]. علاوه بر CNN، سایر تکنیک‌های یادگیری ماشین نیز نتایج درخشانی در این مساله داشته‌اند. در سال ۲۰۲۱ ژو و هم‌کارانش با استخراج ویژگی‌های PSD و آنتروپی و طبقه‌بندی آن‌ها با استفاده از الگوریتم‌های رگرسیون بردار پشتیبان^۴ (SVR) و جنگل تصادفی^۵ (RF) به صحت ۹۰٪ در تشخیص خواب‌آلودگی رانندگان دست یافته‌اند [۱۹]. در همین سال ژانگ و هم‌کارانش با استخراج دو دسته‌ی ویژگی مشابه از دادگان خود و استفاده از الگوریتم ماشین بردار پشتیبان^۶ (SVM) به صحت ۹۷٪ دست یافته‌اند [۲۰]. در سال ۲۰۲۱ سیواکومار و هم‌کارانش با

^۵ Random Forest

^۶ Support Vector Machine

^۷ K-Nearest Neighbors

^۸ Zero Crossing Rate

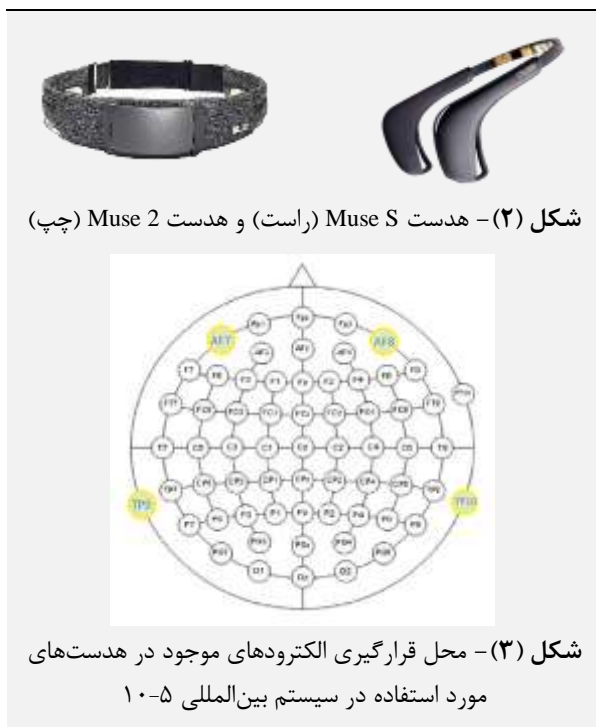
^۱ Electroencephalogram

^۲ Power Spectral Density

^۳ Convolutional Neural Networks

^۴ Support Vector Regression

برای ثبت سیگنال EEG از ۲۵ داوطلب به کار گرفته شده است. هر دو هدست مورد استفاده، سیگنال EEG را توسط چهار الکتروود در کانال‌های مشابه AF7، AF8، TP9 و TP10 ثبت می‌کنند. محل قرارگیری این الکتروودها روی سر در شکل (۳) با رنگ زرد نشان داده شده است.



علاوه بر این موارد، یک رایانه‌ی شخصی برای ثبت و ذخیره‌سازی داده‌های ثبت شده از آزمون دهنده در محل انجام آزمون قرار داشته است. جهت مشاهده‌ی بی‌درنگ سیگنال EEG فرد، پیش از شروع ثبت به منظور اطمینان از قرارگیری صحیح هدست روی پیشانی و عدم وجود نویز، از پلاگین Matlab LSL Viewer در جعبه‌ابزار EEGLAB موجود در نرم‌افزار MATLAB بهره گرفته شده است.

برای اتصال هدست‌های بلوتوثی به لپ‌تاپ از نرم‌افزار BlueMuse که مخصوص محصولات برند Muse طراحی شده استفاده گردیده است. هم‌چنین جهت ضبط سیگنال‌های EEG و ذخیره‌سازی آن‌ها از نرم‌افزار LabRecorder استفاده شده است که قابلیت ذخیره‌سازی سیگنال‌ها در فرمت xdf را دارد.

۲-۱-۴- نحوه‌ی انجام فرایند ثبت سیگنال

همانگی با هر یک از شرکت کنندگان، حداقل یک هفته پیش از روز ثبت داده از فرد آغاز شده و از آن‌ها خواسته شده است که در طول شب‌های هفته، خواب شبانه‌ی کافی (به میزان حداقل ۷ ساعت) داشته باشند و در شب منتهی به جلسه‌ی ثبت داده، میزان خواب شبانه‌ی خود را به طور چشم‌گیری

مرکز شامل چندین مدل شبیه‌ساز در انواع خودروی سواری، موتورسیکلت، دامپ‌تراک و خودروی سنگین بوده و قابلیت رانندگی در شرایط مختلف آب‌وهوایی در ساعات مختلف شبانه‌روز و در انواع مسیرهای درون شهری و برون شهری را فراهم آورده است. علاوه بر این به منظور القای دقیق‌تر حس رانندگی، سکوها‌ی متحرک با ربات‌های سه درجه‌ی آزادی طراحی و ساخته شده است تا راننده حس واقعی‌تری از شتاب و حرکات خودرو در شرایط مجازی داشته باشد. هم‌چنین از سه نمایش‌گر با میدان دید ۱۲۰ تا ۱۵۰ درجه برای پخش تصاویر استفاده شده است. در این مطالعه از شبیه‌ساز رانندگی خودروی سواری تک سرنشین بدون بدنه مطابق شکل (۱) استفاده شده است. به منظور جلوگیری از تاثیر دما بر نتایج، در ابتدای انجام هر آزمون اطمینان حاصل شده است که دمای محیط آزمون در نزدیکی دمای متعادل (۲۵ درجه‌ی سلسیوس) قرار داشته باشد. هنگام اجرای آزمون، اتاق برگزاری کاملاً تاریک شده است. دو ناظر در زمان اجرای آزمون در اتاق شبیه‌سازی حضور داشته که شرایط برگزاری آزمون را به صورت لحظه‌ای بررسی کرده و زمان پایان آزمون را به شرکت کننده اعلام نموده‌اند.



۲-۱-۳- ابزارهای مورد استفاده

علاوه بر شبیه‌ساز رانندگی که در بخش قبل به آن اشاره شده، از یک دوربین Full-HD برند A4Tech برای تصویربرداری از چهره‌ی راننده هنگام رانندگی استفاده شده است. سه نمایش‌گر جهت نمایش مطلوب با دید ۱۲۰-۱۵۰ درجه‌ی مسیر، روبه‌روی آزمون دهنده قرار داده شده است. نرم‌افزار ضبط تصاویر نمایش داده شده توسط نمایش‌گرها، روی سیستم شبیه‌ساز نصب شده و تصاویر نمایش داده شده روی نمایش‌گر میانی به منظور تحلیل‌های احتمالی آتی ضبط شده است. برای ثبت سیگنال‌ها از دو نوع هدست رده‌ی مصرف کننده و تجاری از برند Muse به نام‌های Muse 2 و Muse S استفاده شده که در شکل (۲) قابل مشاهده است. هر یک از هدست‌ها

حضور داشته‌اند که وظیفه‌ی ناظر اول اعلام زمان شروع و پایان آزمون، بررسی زنده‌ی ویدئوی در حال ضبط از راننده و انجام برچسب‌گذاری اولیه‌ی داده‌ها است. ناظر دوم نیز علاوه بر ثبت تمام وقایع رخ داده مانند حرکات شدید سر یا بدن، عطسه، سرفه، صحبت کردن، وجود نویز صوتی در محیط، کم و یا زیاد بودن سرعت حرکت، انحراف از مسیر، خروج از جاده و حرکات زیگزگی موظف بوده است تا در صورت نیاز به مواردی چون بازگرداندن خودرو به جاده به دلیل خروج از مسیر، شبیه‌ساز را کنترل نماید. در صورت رخ دادن هر یک از حالت‌های زیر به ثبت داده پایان داده شده است.

۱- گذشت ۷۵ دقیقه از شروع آزمون

۲- ثبت سه چرخه‌ی هوشیاری-خواب‌آلودگی از راننده با تشخیص ناظر اول

۳- سه مرتبه خروج از مسیر رانندگی و یا برخورد با موانع

۴- درخواست شرکت کننده مبنی بر اتمام ثبت به دلیل کلافگی پس از پایان ثبت نیز با یک میان وعده و هدیه‌ای به رسم یادبود از شرکت کنندگان قدردانی شده است.

۲-۱-۵- برچسب‌گذاری داده‌ها

با توجه به این که نوع یادگیری الگوریتم‌های یادگیری ماشین مورد نظر برای طبقه‌بندی از نوع یادگیری نظارتی^۱ بوده، نیاز به وجود برچسب برای هر نمونه از داده‌های ثبت شده مشهود است. با توجه به این که تغییر فاز فرد از هوشیاری به خواب‌آلودگی ممکن است در زمان بسیار کوتاهی رخ دهد، نیاز به استفاده از نمونه‌های با مدت زمان کوتاه، جهت تاثیرگذاری الگوریتم در دنیای واقعی احساس می‌شود. با علم به این موضوع و بررسی مطالعات گوناگون انجام شده، مدت زمان ۳۰ ثانیه به عنوان طول زمان هر ایپاک از داده‌ها انتخاب شده است. به منظور برچسب‌گذاری داده‌ها از ویدئوی ضبط شده از چهره‌ی شرکت کننده هنگام رانندگی بهره گرفته شده است. سه ناظر با استفاده از روش تخمین ناظر از میزان خواب‌آلودگی^۲ (ORD) در بازه‌های زمانی ۳۰ ثانیه‌ای متوالی به فرد امتیازی بین ۱ (کاملاً هوشیار) تا ۵ (کاملاً خواب‌آلوده) تخصیص داده‌اند. تخمین ناظرین بر اساس ویژگی‌های ظاهری فرد از جمله میزان بسته بودن چشم‌ها، سرعت حرکات چشم و سر، نرخ پلک زدن، میزان کلافگی و زل زدن‌های طولانی صورت گرفته است. ویژگی‌های سطوح مختلف خواب‌آلودگی در روش ORD در جدول (۱) ارائه شده است.

کاهش داده، به حداکثر ۴ ساعت برسانند و هر روز پس از بیداری مدت زمان خواب خود را یادداشت کنند. هم‌چنین از افراد خواسته شده است که در طول هفته از مصرف هر گونه نوشیدنی الکلی و انواع داروهای تاثیرگذار بر خواب بپرهیزند. به منظور افزایش احتمال تجربه‌ی خواب‌آلودگی در طول آزمون رانندگی، تمام آزمون‌ها در ظهر (از ساعت ۱ تا ۳) و یا بعد از ظهر (از ساعت ۳ تا ۵) برگزار شده است. در روز آزمون و پیش از شروع ثبت داده، با یک وعده‌ی غذایی نسبتاً سنگین و نوشیدنی یکسان از شرکت کنندگان پذیرایی شده است تا علاوه بر افزایش احتمال خواب‌آلودگی پس از صرف غذا، از تاثیرات احتمالی ناشی از مصرف وعده‌های غذایی گوناگون اجتناب شود. پس از صرف وعده‌ی غذایی، توضیحات کلی مربوط به فرایند ثبت داده به صورت کتبی و شفاهی به شرکت کننده ارائه شده و رضایت کتبی آن‌ها بابت شرکت در طرح دریافت شده است. در این مرحله برای ایجاد شناخت بیش‌تر نسبت به شبیه‌ساز، فرصتی بین ۵ تا ۱۰ دقیقه به شرکت کننده جهت قلق‌گیری و رانندگی با خودروی شبیه‌ساز داده شده است. پس از این مرحله، نوبت به قرارگیری هدست بر پیشانی فرد و ثبت سیگنال بررسی کیفیت^۱ (QC) رسیده که به صورت زنده به وسیله‌ی ابزار MATLAB LSL Viewer توسط ناظرین پایش شده است. در صورت وجود کیفیت مطلوب در سیگنال‌ها، فرایند ثبت داده‌ی EEG از شرکت کننده با اعلام ناظر آغاز شده است. علی‌رغم عدم استفاده از خودروهای دیگر در سناریوی شبیه‌سازی و خالی بودن جاده که به منظور کاهش فعالیت‌های تحریک کننده مغز شرکت کننده و افزایش احتمال خواب‌آلودگی بوده، از راننده درخواست شده است که در هنگام رانندگی در لاین سمت راست جاده حضور داشته باشد و از رانندگی در لاین مخالف بپرهیزد. هم‌چنین از شرکت کنندگان خواسته شده است که با سرعتی در محدوده‌ی ۷۰ تا ۹۰ کیلومتر بر ساعت رانندگی کنند و از رانندگی با سرعت بالا یا پایین اجتناب نمایند. به منظور افزایش احتمال تجربه‌ی خواب‌آلودگی، از حالت اتوماتیک گیربکس در شبیه‌ساز استفاده شده است. هم‌چنین از داوطلب درخواست شده است که تا حد امکان از نگاه کردن طولانی به صفحه‌ی کیلومترشمار خودرو و آینه‌های کناری بپرهیزد و به روبه‌رو نگاه کند. این عمل، افزایش کیفیت تصویر ضبط شده از چهره‌ی داوطلب به خصوص جزئیات چشم‌ها را در پی داشته که برای مرحله‌ی برچسب‌گذاری داده‌ها ضروری است. در اتاق ثبت داده دو ناظر

^۲ Observer Rating of Drowsiness

^۱ Quality Check

^۲ Supervised Learning

جدول (۱) - ویژگی‌های رانندگان در سطوح مختلف خواب‌آلودگی در روش ORD

پلک زدن سریع	۱ هوشیار
تکان‌های مختصر و معمولی روی صندلی	
چهره‌ی بشاش	
نگاه‌های سریع به محیط اطراف	۲ اندکی خواب‌آلوده
کم شدن شادابی صورت نسبت به راننده‌ی هوشیار	
کند شدن پلک زدن نسبت به راننده‌ی هوشیار	
طولانی‌تر شدن نگاه‌ها به اطراف	۳ خواب‌آلودگی متوسط
مالش صورت و چشم	
بی‌قراری روی صندلی	
نشانه‌های مقابله با خواب‌آلودگی	
خاراندن صورت و گردن	
نفس عمیق	
خیره شدن چشم	
چشم شیشه‌ای (اشک‌آلود بودن چشم)	
افت بشاشیت صورت	
کند شدن سرعت پلک زدن	
بسته شدن چشم برای ۱ تا ۲ ثانیه	
رفتن چشم‌ها (unfocused rolling)	
نشانه‌های مقابله با خواب‌آلودگی	۴ خیلی خواب‌آلوده
کاهش شدید فعالیت بدنی (رها کردن فرمان، ولو شدن روی صندلی، تکیه دادن به فرمان)	
کاهش شدید بشاشیت صورت	
حرکات مارپیچ رانندگی	
واکنش‌های شدید	
بسته شدن چشم بیش از ۲ ثانیه	۵ شدیدا خواب‌آلوده
حرکت‌های مارپیچ شدید	
واکنش‌های بسیار شدید	

Muse در حالت ثبت سیگنال EEG برابر با ۲۵۶ هرتز ثبت شده، اما فرکانسی که در واقعیت در فرایند نمونه‌برداری وجود داشته دارای نوسانی حول این عدد بوده به همین سبب تعداد نمونه‌های ثبت شده در هر ثانیه ثابت نبوده و حول عدد ۲۵۶ نوسان داشته است. به منظور ثابت نگه داشتن تعداد نمونه‌های موجود در هر ایپاک، هر ایپاک ۳۰ ثانیه‌ای فارغ از مدت زمانی که آن را در بر می‌گیرد، برابر با یک توالی از سیگنال که شامل ۷۸۶۰ نمونه بوده در نظر گرفته شده است. سپس نوبت به فیلتر کردن سیگنال‌ها رسیده است. در ابتدا با استفاده از یک فیلتر بالاگذر با فرکانس قطع ۰/۱ هرتز مقدار آفست DC سیگنال از بین رفته است. با توجه به وجود نویز ناشی از برق شهر در فرکانس ۵۰ هرتز و علم به این موضوع که محتوای فرکانسی مفید سیگنال EEG در بازه‌ی فرکانسی کم‌تر از ۴۰ هرتز می‌باشد، سیگنال در این مرحله با یک فیلتر پایین‌گذر با فرکانس قطع ۴۰ هرتز فیلتر شده است. در نهایت ایپاک‌هایی با طول ۳۰ ثانیه (۷۸۶۰ نمونه) و با تداخل زمانی ۱۵ ثانیه‌ای

با بررسی مطالعات و مشاهدات انجام شده در طول مدت ثبت داده، مشخص شده که سطح ۳ در روش ORD آخرین سطحی بوده که فرد در آن هوشیاری کافی برای رانندگی را دارد و با بیش‌تر شدن خواب‌آلودگی فرد از این سطح، خواب‌آلودگی وی بیش از حد مجاز برای رانندگی است. برای وجود امکان اعلام هشدار خواب‌آلودگی به رانندگان پیش از بروز خطرات احتمالی، سطح ۳ که ویژگی‌های آخرین سطح هوشیاری را دارد، به عنوان اولین سطح خواب‌آلودگی در نظر گرفته شده است. بدین ترتیب در یک دسته‌بندی دو کلاسه، ایپاک‌های برچسب زده شده با سطوح ۱ و ۲ به عنوان ایپاک‌های مربوط به هوشیاری و ایپاک‌های برچسب زده شده با سطوح ۳ تا ۵ به عنوان ایپاک‌های مربوط به خواب‌آلودگی در نظر گرفته شده است.

۲-۲- پیش‌پردازش داده‌ها

پس از جمع‌آوری داده‌های برچسب‌گذاری شده، پیش‌پردازش داده‌ها آغاز شده است. علی‌رغم این که فرکانس هدست‌های

در این رابطه $x[n]$ مقدار سیگنال در نمونه‌ی n -ام، N تعداد کل نمونه‌های سیگنال و 1 تابع مشخصه‌ای بوده که خروجی آن در صورت برقراری شرط $x[n].x[n-1] < 0$ برابر 1 و در غیر این صورت برابر صفر است. برای محاسبه‌ی ZCR سیگنال x در نرم‌افزار متلب از قطعه کد زیر استفاده شده است.

```
function output = ZCR(x)
s1 = x;
s2 = [0, x(1:end-1)];
s = s1.*s2;
output = (sum(s<0))/numel(s1);
end
```

در مطالعات پیشین تنها از ZCR سیگنال EEG ثبت شده استفاده شده است. در این مطالعه علاوه بر ZCR سیگنال EEG ثبت شده، از ZCR مشتق اول و مشتق دوم این سیگنال نیز بهره گرفته شده است. با توجه به این که علامت (مثبت یا منفی) مشتق اول نشان‌گر صعودی یا نزولی بودن سیگنال اصلی است، پس می‌توان گفت تعداد دفعات عبور از صفر مشتق اول سیگنال EEG برابر با شمار دفعات تغییر سیگنال EEG از حالت صعودی به نزولی و یا برعکس بوده که خود برابر با تعداد اکسترمم‌های محلی^۱ سیگنال می‌باشد. هم‌چنین نقاطی که مشتق دوم سیگنال در آن از صفر عبور می‌کند، معادل نقاطی از سیگنال اصلی است که تقعر سیگنال در آن تغییر علامت می‌دهد. با توجه به این که سیگنال EEG توسط هدست‌های Muse در چهار کانال ضبط شده و هم‌چنین به ازای سیگنال ضبط شده از هر کانال، ویژگی‌های ZCR سیگنال EEG اصلی، مشتق اول و مشتق دوم آن استخراج شده است، تعداد ویژگی‌های موجود به ازای هر ایپاک برابر ۱۲ می‌باشد.

۲-۴- آزمون آماری

از آزمون‌های آماری به منظور اطلاع از وجود اختلاف معنادار به ازای هر یک از ویژگی‌های استخراج شده بین دو دسته‌ی خواب‌آلودگی و هوشیاری استفاده شده است. به منظور جلوگیری از هر گونه تاثیرگذاری داده‌های تست در فرایند آموزش مدل، در این مرحله ۲۰٪ از داده‌های موجود به عنوان مدل‌های طبقه‌بند، از این بخش داده‌ها استفاده نشده است. در نتیجه در طی فرایندهای انجام آزمون آماری و آموزش مدل، صرفاً ۸۰ درصد داده‌ها که به عنوان داده‌های آموزش و اعتبارسنجی^۲ معرفی شده، به کار گرفته شده است. با توجه به غیرنرمال بودن توزیع داده‌های هر دو گروه، برای بررسی

(۳۸۴۰ نمونه‌ای) با ایپاک‌های مجاور، از سیگنال‌ها تولید شده است. تعداد مجموع ایپاک‌های موجود برابر ۳۹۰۴ ایپاک بوده که از میان آن‌ها ۱۸۷۴ ایپاک (۴۸٪) مربوط به حالت هوشیاری و ۲۰۳۰ ایپاک (۵۲٪) مربوط به حالت خواب‌آلودگی است.

۲-۳- استخراج ویژگی

در مطالعات صورت گرفته روی مساله‌ی تشخیص خواب‌آلودگی رانندگان به وسیله‌ی سیگنال مغزی، از ویژگی‌های متعددی از سیگنال EEG استفاده شده است که از آن جمله می‌توان به چگالی طیف توان مطلق، چگالی طیف توان نسبی، آنتروپی، ضرایب تبدیل موجک در زیرباندهای فرکانسی و ویژگی‌های غیرخطی اشاره کرد. با توجه به این که هدف نهایی از توسعه‌ی الگوریتم‌های تشخیص خواب‌آلودگی رانندگان، ایجاد روشی با صحت بالا و قابلیت استفاده برای عموم رانندگان است، کمینه کردن هزینه‌های لازم برای توسعه‌ی این روش‌ها ضروری به نظر می‌رسد. یکی از رویکردهای موجود جهت کاهش هزینه‌ها، استفاده از سیستم‌های نهفته و گوشی‌های تلفن همراه برای اجرای پردازش‌های موجود در روش‌های توسعه یافته است که نیازمند کاهش حداکثری پیچیدگی‌ها و هزینه‌های محاسباتی الگوریتم‌های تشخیص خواب‌آلودگی می‌باشد. برای استخراج ویژگی‌هایی مانند چگالی طیف توان و تبدیل موجک به عملیاتی مانند انتقال سیگنال از حوزه‌ی زمان به فرکانس و محاسبات متعدد برای استخراج این ویژگی‌ها از باندهای فرکانسی گوناگون نیاز است که از نظر هزینه‌ی محاسباتی چندان مطلوب نیست. یکی از ویژگی‌هایی که در مطالعات محدودی در این زمینه مورد استفاده قرار گرفته، ویژگی نرخ عبور از صفر (ZCR) است. در برخی مطالعات انگشت‌شمار مربوط به تشخیص خواب‌آلودگی، از این ویژگی موجود در حوزه‌ی زمان به عنوان یک ویژگی تکمیلی و در کنار چندین دسته ویژگی دیگر استفاده شده است. ویژگی ZCR که در پردازش و تشخیص سیگنال‌های صوتی بسیار کاربرد دارد به صورت نسبت تعداد دفعات گذشتن یک سیگنال در حوزه‌ی زمان از مقدار صفر به تعداد کل نمونه‌های آن سیگنال تعریف می‌شود. به بیان دیگر ZCR متناسب با تعداد دفعات تغییر علامت یک سیگنال زمانی از منفی به مثبت و یا برعکس می‌باشد. برای محاسبه‌ی ZCR سیگنال x از رابطه‌ی (۱) استفاده می‌شود.

$$ZCR_x = \frac{1}{N} \sum_{n=1}^N 1(x[n].x[n-1] < 0) \quad (1)$$

^۱ Validation

^۲ Local Extrema

گرفتن سطح اهمیت^۲ آزمون آماری برابر با مقدار ۰/۰۱، ویژگی ZCR سیگنال ثبت شده از کانال TP10 در دو کلاس دارای تفاوت معنادار نیست و از این ویژگی در طبقه‌بندی استفاده نشده است. سایر ویژگی‌ها مطابق جدول (۲) دارای اختلاف معنادار در دو گروه خواب‌آلودگی و هوشیاری بوده‌اند.

معناداری ویژگی‌ها از یک آزمون غیرپارامتری به نام من-ویتنی^۱ (Mann-Whitney U test) استفاده شده است. نتایج این آزمون که برای مقایسه‌ی دو دسته گروه مستقل از هم به کار گرفته می‌شود، پس از اعمال بر ۱۲ ویژگی استخراج شده از ایپاک‌ها در جدول (۲) ارائه شده است. طبق این جدول و با در نظر

جدول (۲) - مقادیر p-value محاسبه شده توسط آزمون Mann-Whitney U برای ویژگی‌های استخراج شده

مشق دوم سیگنال EEG				مشق اول سیگنال EEG				سیگنال EEG				سیگنال
TP10	AF8	AF7	TP9	TP10	AF8	AF7	TP9	TP10	AF8	AF7	TP9	کانال
۱/۳e-۲۹	۱/۸e-۱۴	۵/۸e-۱۰	۲/۵e-۸	۷/۱e-۱۱	۶/۲e-۵	۲/۹e-۱۱	۰/۰۰۲	۰/۵۲	۵/۴e-۵۰	۵e-۱۶	۱/۵e-۷	p-value

نظر در نظر گرفته می‌شود. از مهم‌ترین پارامترهای موجود در KNN می‌توان به تعداد همسایه‌ها (K)، نوع فاصله‌ی مورد بررسی و روش وزن‌دهی به همسایگان اشاره کرد. در این مطالعه مقادیر K برابر با ۳، ۵، ۷، ۹ و ۱۱ در نظر گرفته شده و از فاصله‌های اقلیدسی (رابطه‌ی ۲)، منهن (رابطه‌ی ۳)، چبی شف (رابطه‌ی ۴)، مینکوفسکی (رابطه‌ی ۵)، اقلیدسی استاندارد شده (رابطه‌ی ۶) و کانبرا (رابطه‌ی ۷) استفاده شده است.

$$d(x, y) = \sqrt{\sum (x_i - y_i)^2} \quad (۲)$$

$$d(x, y) = \sum (|x_i - y_i|) \quad (۳)$$

$$d(x, y) = \max(|x_i - y_i|) \quad (۴)$$

$$d(x, y) = \sqrt[p]{\sum (|x_i - y_i|)^p} \quad (۵)$$

$$d(x, y) = \sqrt{\sum_{i=1}^n \frac{(x_i - y_i)^i}{v_i}} \quad (۶)$$

$$d(x, y) = \sum \frac{|x_i - y_i|}{|x_i| + |y_i|} \quad (۷)$$

هم‌چنین نحوه‌ی وزن‌دهی به همسایگان به سه صورت یکسان، متناسب با معکوس فاصله و متناسب با معکوس مربع فاصله در نظر گرفته شده است.

۲-۵-۲- SVM طبقه‌بند

ماشین بردار پشتیبانی (SVM) یک الگوریتم یادگیری نظارتی است که با هدف یافتن ابرصفحه‌ای که قادر به جداسازی داده‌های مربوط به کلاس‌های مختلف در بین داده‌های یادگیری باشد، عمل می‌کند. از مهم‌ترین پارامترهای الگوریتم SVM می‌توان به کرنل مورد استفاده اشاره کرد. کرنل تابعی است که داده‌ها را از فضای ورودی به فضای ویژگی بالاتری منتقل

۲-۵-۲- طبقه‌بندی

همان‌طور که پیش‌تر بیان شد، ۲۰ درصد از داده‌های موجود برای فرایند آزمون نهایی مدل توسعه داده شده کنار گذاشته شده و از ۸۰ درصد داده‌ها در فرایند آموزش و اعتبارسنجی مدل استفاده شده است. جهت آموزش و اعتبارسنجی مدل، روش صحت‌سنجی متقابل k-دسته‌ای^۳ مورد استفاده قرار گرفته است. در این روش به ازای هر ترکیب مورد نظر از ابرپارامترها، تمام داده‌های موجود در بخش ۸۰ درصدی به k دسته‌ی مساوی تقسیم شده، فرایند آموزش مدل با استفاده از k-۱ دسته صورت گرفته و یک قسمت برای اعتبارسنجی کنار گذاشته می‌شود. این فرایند k بار تکرار می‌شود تا زمانی که از هر یک از k دسته، یک بار برای اعتبارسنجی استفاده شود. در نتیجه به ازای هر ترکیب از ابرپارامترها، k مقدار صحت، k مقدار حساسیت و k مقدار اختصاصیت به دست می‌آید که با محاسبه‌ی میانگین و انحراف معیار این k مقدار می‌توان به معیارهایی جهت مقایسه‌ی کیفیت مدل‌های توسعه داده شده با هر ترکیب از ابرپارامترها دست یافت. در این مطالعه مقدار k برابر با ۵ در نظر گرفته شده و هم‌چنین برای طبقه‌بندی از الگوریتم‌های KNN و SVM استفاده شده است.

۲-۵-۱- SVM طبقه‌بند

الگوریتم KNN الگوریتمی پرکاربرد بوده که در مسائل طبقه‌بندی و رگرسیون به کار رفته و در آن برای تشخیص خروجی متناظر با یک ورودی جدید، از نزدیک‌ترین داده‌ها در بین داده‌های آموزش در فضای ویژگی‌ها به داده‌ی جدید استفاده می‌شود. به این صورت که K داده‌ی آموزشی که کم‌ترین فاصله را با داده‌ی مورد نظر دارند انتخاب شده و پرتکرارترین مقدار خروجی میان آن‌ها به عنوان خروجی مورد

^۲ K-Fold Cross Validation

^۱ Kolmogorov-Smirnov Test

^۳ Significance Level

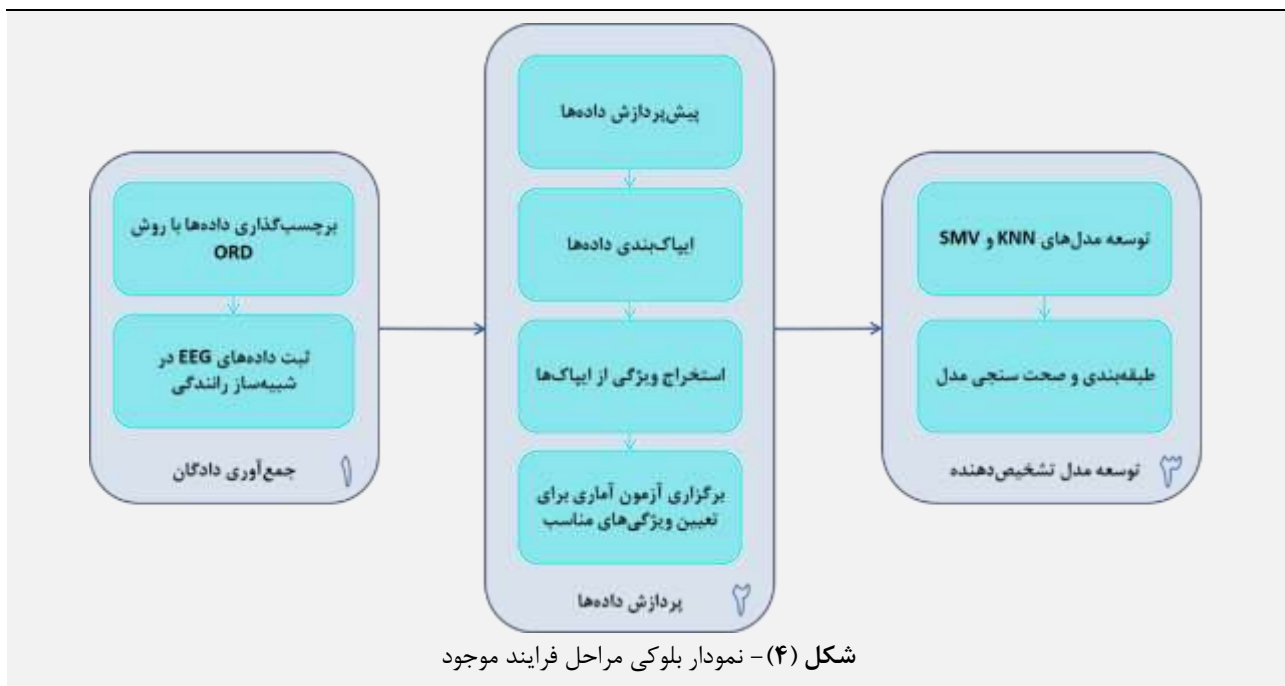
دودویی^۵ بوده، صحت، حساسیت و اختصاصیت مدل با روابط (۸) تا (۱۰) محاسبه شده که در آن TP مثبت واقعی^۶، TN منفی واقعی^۷، FP مثبت کاذب^۸ و FN منفی کاذب^۹ می‌باشد. نمودار بلوکی فرایند طی شده در شکل (۴) قابل مشاهده است.

$$accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (۸)$$

$$sensitivity = \frac{TP}{TP + FN} \quad (۹)$$

$$specificity = \frac{TN}{TN + FP} \quad (۱۰)$$

می‌کند به طوری که در این فضای جدید، داده‌ها به صورت خطی جداپذیر می‌شوند. به عبارت دیگر کرنل امکان می‌دهد که الگوریتم SVM بدون نیاز به محاسبه‌ی صریح مختصات در فضای ویژگی بالا، بتواند مسائل غیرخطی را حل کند. در این مطالعه از چهار کرنل خطی، تابع شعاعی پایه^۱ (RBF)، چندجمله‌ای و سیگموئید استفاده شده است. هم‌چنین به عنوان معیار مقایسه‌ی عمل کرد مدل‌های توسعه داده شده، از صحت^۲، حساسیت^۳ و اختصاصیت^۴ مدل بهره گرفته شده است. در مسائلی مانند مطالعه‌ی حاضر که از جنس مسائل طبقه‌بندی



۳ نوع روش وزن‌دهی به همسایگان که در توسعه‌ی مدل‌های KNN به کار گرفته شده، در مجموع تعداد ۹۰ ترکیب از پارامترها وجود داشته است. تعداد ۱۰ ترکیب دارای بالاترین درصد صحت تشخیص در جدول (۳) مشخص شده است. هم‌چنین در حالت توسعه‌ی مدل طبقه‌بندی کننده با استفاده از طبقه‌بند SVM از چهار کرنل خطی، چندجمله‌ای، سیگموئید و RBF بهره گرفته شده است. هم‌چنین مقدار پارامتر جریمه‌ی ناشی از خطا نیز در هر چهار حالت برابر با ۱ در نظر گرفته شده است. میانگین و انحراف معیار پارامترهای صحت، حساسیت و اختصاصیت به دست آمده با بهره‌گیری از مدل‌های SVM توسعه یافته در جدول (۴) ارائه شده است.

۳- یافته‌ها و بحث

با توجه به نتایج به دست آمده از آزمون آماری صورت گرفته روی ۱۲ ویژگی استخراج شده، به غیر از ویژگی ZCR سیگنال EEG در کانال TP10 که در بین دو گروه هوشیار و خواب‌آلوده دارای تفاوت معناداری نبوده، از ۱۱ ویژگی استخراج شده دیگر در توسعه‌ی مدل تشخیص خواب‌آلودگی رانندگان استفاده شده است. هم‌چنین به منظور طبقه‌بندی مدل از طبقه‌بندهای KNN و SVM استفاده گردیده است. میانگین و انحراف معیار صحت، حساسیت و اختصاصیت به دست آمده با استفاده از هر یک از مدل‌های توسعه یافته در جدول (۳) ارائه شده است. با توجه به ۶ نوع روش محاسبه‌ی فاصله، ۵ نوع تعداد همسایه و

^۶ True Positive

^۷ True Negative

^۸ False Positive

^۹ False Negative

^۱ Radial Basis Function

^۲ Accuracy

^۳ Sensitivity

^۴ Specificity

^۵ Binary Classification

جدول (۳) - صحت تشخیص خواب‌آلودگی توسط ۱۰ مدل برتر توسعه یافته با الگوریتم KNN

رتبه	تعداد همسایه	روش محاسبه‌ی فاصله	روش وزن‌دهی همسایگان	حساسیت (%)	اختصاصیت (%)	صحت (%)
۱	۷	کانبرا	معکوس مجذور فاصله	۸۹/۲۹±۱/۹۸	۸۳/۳۸±۲/۰۳	۸۶/۳۷±۱/۵۳
۲	۷	منتین	معکوس مجذور فاصله	۸۶/۳۲±۲/۳۴	۸۲/۲۴±۲/۴۸	۸۴/۲۷±۱/۷۹
۳	۵	مینکوفسکی	معکوس مجذور فاصله	۸۶/۲۵±۱/۹۲	۸۲/۳۰±۲/۲۵	۸۴/۲۷±۱/۰۹
۴	۹	مینکوفسکی	معکوس مجذور فاصله	۸۶/۰۷±۲/۲۷	۸۰/۶۶±۲/۳۴	۸۴/۲۲±۱/۸۵
۵	۹	کانبرا	معکوس مجذور فاصله	۸۸/۰۷±۲/۲۷	۸۰/۳۲±۲/۴۵	۸۴/۲۰±۱/۶۷
۶	۹	اقلیدسی استاندارد	معکوس مجذور فاصله	۸۵/۹۹±۲/۱۷	۸۲/۱۳±۱/۸۸	۸۴/۱۳±۱/۱۷
۷	۵	اقلیدسی استاندارد	معکوس مجذور فاصله	۸۶/۱۳±۲/۰۵	۸۱/۹۹±۲/۴۰	۸۴/۰۱±۱/۴۹
۸	۷	اقلیدسی	معکوس مجذور فاصله	۸۷/۵۱±۲/۳۷	۷۹/۹۸±۲/۶۸	۸۳/۹۸±۱/۹۱
۹	۵	کانبرا	معکوس مجذور فاصله	۸۵/۸۹±۲/۱۹	۸۱/۹۲±۲/۳۷	۸۳/۸۴±۱/۵۷
۱۰	۷	مینکوفسکی	معکوس مجذور فاصله	۸۵/۹۰±۱/۸۴	۸۱/۴۴±۲/۴۳	۸۳/۷۸±۱/۴۶

جدول (۴) - صحت تشخیص خواب‌آلودگی توسط الگوریتم SVM

رتبه	کرنل	حساسیت (%)	اختصاصیت (%)	صحت (%)
۱	تابع شعاعی پایه	۷۸/۲۶±۲/۶۳	۶۶/۴۲±۲/۴۹	۷۲/۱۳±۲/۱۱
۲	خطی	۷۴/۸۶±۲/۷۹	۶۹/۲۸±۲/۳۸	۷۱/۹۹±۲/۲۰
۳	چندجمله‌ای	۷۵/۲۳±۳/۰۴	۶۸/۴۹±۲/۶۸	۷۱/۸۹±۲/۳۸
۴	سیگموئید	۷۳/۵۵±۲/۵۳	۶۹/۶۳±۲/۱۴	۷۱/۵۶±۱/۷۸

از ابتدا به عنوان داده‌های تست و برای اجرای آزمون نهایی کنار گذاشته شده به این مدل اعمال گردیده که مدل KNN توسعه داده شده توانسته است صحت ۸۶/۱۱٪، حساسیت ۸۸/۲۲٪ و اختصاصیت ۸۴/۱۴٪ را ثبت کند.

در جدول (۵) برخی از مهم‌ترین مطالعات صورت گرفته در حوزه‌ی تشخیص خواب‌آلودگی با استفاده از سیگنال مغزی جمع‌آوری شده است. در این مطالعات از هدست‌های تولید شده توسط شرکت‌های Muse، Emotiv، Neurosky، OpenBCI و gtec (با نام g.Nautilus) در مرحله‌ی ثبت داده‌های EEG بهره گرفته شده است. تعداد کانال‌های هدست‌های مذکور از ۱ تا ۱۴ کانال متغیر است. در مرحله‌ی برچسب‌گذاری از روش PERCLOS (درصد بسته بودن چشم‌ها)، روشی مبتنی بر سیگنال EEG، روش‌های توسعه یافته‌ی اختصاصی و روش مقیاس خواب‌آلودگی کارولینسکا^۱ (KSS) استفاده شده است. فارغ از نوع برچسب‌گذاری، تمام مطالعات موجود در جدول (۵) در مرحله‌ی طبقه‌بندی، داده‌ها را به دو کلاس خواب‌آلوده و هوشیار تقسیم کرده‌اند. استفاده یا عدم استفاده از شبیه‌ساز رانندگی جهت جمع‌آوری داده‌ها نیز در جدول (۵) مشخص شده است. بیش‌ترین تعداد شرکت‌کننده در یک مطالعه مربوط به پژوهش عارف‌نژاد و هم‌کارانش بوده که از ۹۲ نفر در مطالعه استفاده شده در حالی که مطالعه‌ی محمد و هم‌کارانش با به کارگیری تنها ۱ شرکت‌کننده صورت گرفته است. مطالعه‌ی

نتایج جدول‌های (۳) و (۴) نشان می‌دهد که الگوریتم KNN نسبت به الگوریتم SVM در تشخیص خواب‌آلودگی با استفاده از ویژگی‌های ZCR استخراج شده از سیگنال EEG ثبت شده در حین رانندگی، به مراتب بهتر عمل کرده است. با وجود این که بیش‌ترین میانگین صحت در میان مدل‌های توسعه یافته با KNN برابر ۸۶/۳۷ درصد بوده، بهترین مدل SVM میانگین صحتی تنها به میزان ۷۲/۱۳ درصد را ثبت کرده است. بهترین عمل کرد الگوریتم KNN در حالتی ثبت شده که فاصله‌ی بین همسایه‌ها به روش کانبرا محاسبه شده است. در میان روش‌های وزن‌دهی به همسایگان که یکی از پارامترهای مهم روش KNN بوده، وزن‌دهی متناسب با معکوس مجذور فاصله با اختلاف فاحش دارای بهترین نتایج است. این مساله بدین معنا است که برای یک نمونه‌ی خاص، همسایگان نزدیک شباهت و اهمیت بسیار بیش‌تری در مقایسه با همسایگان دور از نمونه‌ی مذکور داشته‌اند. هم‌چنین در ارتباط با تعداد همسایگان مورد بررسی برای تشخیص کلاس نمونه‌ها می‌توان گفت که به ترتیب در نظر گرفتن ۷، ۵ و ۹ همسایه بهترین عمل کرد را به دنبال داشته است. مطابق جدول (۳) هر دو مدل KNN دارای بیش‌ترین صحت، با استفاده از مقادیر ۷ همسایه‌ی نزدیک به تشخیص خواب‌آلودگی پرداخته‌اند.

پس از مشخص شدن ترکیب ابرپارامترهای برترین مدل تشخیص دهنده‌ی خواب‌آلودگی، بخش ۲۰ درصدی داده‌ها که

^۱ Karolinska Sleepiness Scale

خواب‌آلودگی با استفاده از سیگنال EEG ثبت شده در شبیه‌سازهای رانندگی سرتاسر دنیا است.

حاضر با به کارگیری ۵۰ شرکت کننده، دارای دومین دادگان بزرگ در بین تمام مطالعات انجام شده در حوزه‌ی تشخیص

جدول (۵) - مشخصات و صحت حاصل از برخی از مطالعات صورت گرفته در زمینه‌ی تشخیص خواب‌آلودگی رانندگان با استفاده از سیگنال الکتروانسفالوگرام

مرجع	شبیه‌ساز رانندگی	هدست	کانال	برچسب‌زنی	افراد	ویژگی‌ها	طبقه‌بند	صحت
[۲۳]	خیر	Muse	۴	-	۳	PSD	SVM - LDA	۷۳/۸۰
[۲۴]	خیر	Muse	۴	-	۴۸	آنترپپی	Shallow ANN - KNN - SVM - Naïve Bayes - Decision Tree	۷۷/۵۰
[۲۵]	بله	Muse	۴	-	۲۸	PSD	Shallow ANN - KNN - SVM	۸۶/۰۰
[۲۶]	خیر	Muse	۷	-	۲۳	PSD	SVM	۸۷/۰۰
[۲۷]	خیر	Muse	۴	KSS	۵۰	ویژگی‌های مرتبط با پلک زدن	SVM	۹۲/۰۰
[۲۸]	خیر	Muse	۴	الگوریتم اختصاصی	۲۹	PSD	Negative Unlabeled Learning Algorithm	۹۳/۷۷
[۲۹]	بله	Muse	۴	-	۱	-	Deep Network	۹۵/۷۶
[۳۰]	خیر	Emotiv	۱۴	بر اساس EEG	۱۴	-	Deep Network	۹۰/۴۲
[۳۱]	خیر	Emotiv	۱۴	KSS	۳۰	ویژگی‌های آماری	KNN - SVM	۹۶/۰۰
[۳۲]	خیر	Emotiv	۱۴	-	۱۳	PSD	KNN	۹۶/۸۰
[۳۳]	خیر	Emotiv	۱۴	-	۳	آنترپپی	Shallow ANN	۹۸/۰۰
[۳۴]	خیر	NeuroSky	۱	-	۶۰	ویژگی‌های آماری	Shallow ANN	۹۷/۶۰
[۳۵]	بله	OpenBCI	۸	-	۱۲	PSD	Decision Trees - DA - LR - Naïve Bayes - SVM - KNN - Ensemble classifiers	۸۵/۶۰
[۳۶]	بله	g.Nautilus	۴	درصد بسته بودن چشم	۹۲	امواج آلفا و تتا	CNN	۹۰
مطالعه‌ی حاضر	بله	Muse	۴	ORD	۵۰	ZCR	SVM - KNN	± ۱/۵۳ ۸۶/۳۷

از این ویژگی‌ها در تشخیص خواب‌آلودگی رانندگان بهره برده است که از آن می‌توان به عنوان نوآوری مهم این مقاله یاد کرد. برای مقایسه‌ی نتایج این مقاله با مطالعات انجام شده‌ی پیشین می‌توان گفت که در مرحله‌ی طبقه‌بندی و آموزش مدل، از الگوریتم‌ها و طبقه‌بندهای متعددی از جمله ماشین بردار پشتیبانی (SVM)، آنالیز تشخیصی خطی^۱ (LDA)، شبکه‌های عصبی مصنوعی کم‌عمق^۲ (Shallow ANN)، شبکه‌های عمیق^۳، K نزدیک‌ترین همسایه (KNN)، درخت تصمیم^۴، دسته‌بندی کننده‌ی بیز ساده^۵، الگوریتم یادگیری بدون برچسب منفی^۶، طبقه‌بند گروهی^۷، شبکه‌ی عصبی کانولوشنی^۸

در میان ویژگی‌های استخراج شده، PSD پرکاربردترین ویژگی در مطالعات موجود بوده در حالی که در مطالعات مورد بررسی از ویژگی‌های دیگری مانند آنترپپی، ویژگی‌های مرتبط با پلک زدن، ویژگی‌های آماری سیگنال و ویژگی‌های امواج در زیرباندهای آلفا و تتا نیز استفاده شده است. در بسیاری از مطالعات برای افزایش صحت مدل تشخیص دهنده، به صورت هم‌زمان چند دسته ویژگی استخراج و به کار گرفته شده است. مطالعه‌ی حاضر یکی از معدود مطالعات بررسی کننده‌ی ویژگی‌های ZCR سیگنال می‌باشد و اولین مطالعه‌ای بوده که ویژگی‌های ZCR مشتق اول و مشتق دوم سیگنال EEG را معرفی کرده و

^۱ Naïve Bayes

^۲ Negative Unlabeled Learning Algorithm

^۳ Ensemble Classifier

^۴ Convolutional Neural Networks

^۱ Linear Discriminant Analysis

^۲ Shallow Artificial Neural Networks

^۳ Deep Networks

^۴ Decision Tree

استفاده از هدست‌های رده‌ی مصرف کننده پیشنهاد شده است. در این راه از ویژگی نرخ عبور از صفر سیگنال‌های الکتروانسفالوگرام ثبت شده و ZCR مشتق اول و دوم آن‌ها بهره گرفته شده است. به منظور برچسب‌گذاری داده‌ها روش ORD به کار گرفته شده و در نهایت دو طبقه‌بند KNN و SVM جهت توسعه‌ی مدل تشخیص دهنده‌ی خواب‌آلودگی مورد استفاده قرار گرفته است. در این مقاله از مجموعه‌ی دادگان جمع‌آوری شده‌ی اختصاصی به وسیله‌ی هدست‌های Muse در شبیه‌ساز رانندگی نصیر که در ۴ کانال TP9، AF7، AF8 و TP10 ثبت شده، استفاده گردیده است. با به کارگیری چارچوب پیشنهادی، حداکثر صحت حاصل از این مطالعه برابر با ۸۶/۳۷ درصد به دست آمده که با استفاده از طبقه‌بند KNN که با ۷ همسایه‌ی نزدیک، محاسبه‌ی فاصله به روش کانبرا و وزن‌دهی متناسب با معکوس مجذور فاصله آموزش داده شده، حاصل گشته است. با توجه به صحت بالای حاصله در تشخیص خواب‌آلودگی با استفاده از ویژگی نرخ عبور از صفر، یکی از روش‌های بهبود صحت تشخیص خواب‌آلودگی، استفاده از ویژگی ZCR در کنار سایر ویژگی‌های کاربردی و موثر این حوزه از جمله PSD و آنتروپی خواهد بود. همچنین با توجه به برچسب‌گذاری داده‌ها در ۵ کلاس به روش ORD، بررسی امکان طبقه‌بندی میزان خواب‌آلودگی افراد در تعداد سطوح بیشتر به جای سطوح دودویی، موضوعی پرکاربرد جهت انجام مطالعات تکمیلی خواهد بود. ضمن این که ایجاد امکان آموزش مجدد مدل بر اساس داده‌های ثبت شده از شخص راننده در گذشت زمان، امری موثر در راستای بهبود درصد صحت تشخیص و شخصی‌سازی دقیق‌تر مدل به شمار می‌رود.

۵- سپاس‌گزاری

در مراحل جمع‌آوری و پیش‌پردازش دادگان از امکانات و سخت‌افزارهای تهیه شده با حمایت‌های مادی و غیرمادی مرکز شتاب دهنده‌ی بن‌دا و استارت‌آپ فرکانس استفاده شده است. بدین وسیله از سرکار خانم جواهرحقیقی و هم‌کاران محترم ایشان در تیم فرکانس، تشکر و قدردانی می‌شود.

۶- مراجع

- [1] C. Watt-Coombes, "How tired is too tired? A study of sleepiness and fatigue incidents reported among UK airline pilots and implications for policy and practice". 2023, UCL (University College London).

رگرسیون خطی^۱ (LR) و آنالیز تشخیصی^۲ (DA) استفاده شده است. بیش‌ترین صحت در میان مطالعات بررسی شده متعلق به پژوهش وانگ و هم‌کارانش است. این پژوهش که با بهره‌گیری از تنها ۳ شرکت کننده صورت گرفته، در تشخیص خواب‌آلودگی آن‌ها به صحت ۹۸ درصد دست یافته است. نوگراها و هم‌کارانش پس از ثبت سیگنال EEG از ۳۰ داوطلب به وسیله‌ی هدست Emotiv و برچسب‌گذاری آن‌ها با روش KSS توانسته‌اند با استخراج ویژگی‌های آماری و PSD به صحت ۹۶ درصد دست پیدا کنند. البته باید اشاره کرد که در روش KSS میزان خواب‌آلودگی فرد از خود شخص پرسیده می‌شود به همین دلیل با توجه به تفاوت میان معیارها در اعلام سطوح خواب‌آلودگی توسط اشخاص مختلف، برچسب‌گذاری و در نتیجه طبقه‌بندی و صحت مدل توسعه داده شده در این حالت نسبت به روش ORD که در آن فرایند برچسب‌گذاری به وسیله‌ی چندین کارشناس آموزش دیده صورت می‌گیرد، از اعتبار کم‌تری برخوردار است. عارف‌نژاد و هم‌کارانش نیز با ثبت داده‌های EEG از ۹۲ شرکت کننده در شبیه‌ساز رانندگی و برچسب‌گذاری داده‌ها با استفاده از پارامتر درصد بسته بودن چشم‌ها به صحت قابل توجه ۹۰٪ با استفاده از طبقه‌بند CNN دست یافته‌اند. لازم به ذکر است که هدست g.nautilus مورد استفاده در این مطالعه به دلیل شکل ساختاری و دست‌وپاگیر بودن، در شرایط رانندگی واقعی قابل استفاده نیست. در نهایت می‌توان گفت که پژوهش حاضر با جمع‌آوری مجموعه‌ی دادگان سیگنال EEG ثبت شده از ۵۰ نفر در شبیه‌ساز رانندگی با استفاده از هدست‌های Muse و برچسب‌گذاری ایپاک‌ها با استفاده از روش ORD موفق به ثبت یکی از بزرگ‌ترین معتبرترین دادگان این حوزه در سرتاسر دنیا شده است. همچنین با معرفی ویژگی نرخ عبور از صفر سیگنال الکتروانسفالوگرام و مشتقات اول و دوم آن و دست‌یابی به صحت بیش از ۸۶٪ در تشخیص خواب‌آلودگی رانندگان، گام بزرگی در راستای بهبود عمل‌کرد سیستم‌های تشخیص دهنده‌ی خواب‌آلودگی رانندگان برداشته شده است.

۴- نتیجه‌گیری

خواب‌آلودگی رانندگان به عنوان یکی از دلایل عمده‌ی تصادفات رانندگی در سرتاسر دنیا شناخته شده و بخش قابل توجهی از مرگ و میر ناشی از تصادفات را به خود اختصاص داده است. در این مقاله با استفاده از سیگنال EEG ثبت شده از رانندگان، مدلی برای تشخیص خواب‌آلودگی آن‌ها به صورت لحظه‌ای با

^۲ Discriminant Analysis

^۱ Linear Regression

- [16] F. Marini, C. Lee, J. Wagner, S. Makeig, and M. Gola, "A comparative evaluation of signal quality between a research-grade and a wireless dry-electrode mobile EEG system". *Journal of neural engineering*, 2019. 16(5): p. 054001.
- [17] R. M. Hussein, F. S. Miften, and L. E. George, "Driver drowsiness detection methods using EEG signals: a systematic review". *Computer methods in biomechanics and biomedical engineering*, 2023. 26(11): p. 1237-1249.
- [18] J. Chen, S. Wang, E. He, H. Wang, and L. Wang, "Two-dimensional phase lag index image representation of electroencephalography for automated recognition of driver fatigue using convolutional neural network". *Expert Systems with Applications*, 2022. 191: p. 116339.
- [19] C. Zhou, B. Li, S. Li, and K. Huang. Detection of vigilance in L3 autonomous driving based on EEG. in *2021 IEEE International Conference on Unmanned Systems (ICUS)*. 2021. IEEE.
- [20] T. Zhang, J. Chen, E. He, and H. Wang, "Sample-entropy-based method for real driving fatigue detection with multichannel electroencephalogram". *Applied Sciences*, 2021. 11(21): p. 10279.
- [21] P. Sivakumar, J. Selvaraj, K. Ramaraj, and A. Sahayadhas, "Analysis of alpha and theta band to detect driver drowsiness using electroencephalogram (EEG) signals". *Int. Arab J. Inf. Technol.*, 2021. 18(4): p. 578-584.
- [22] R. Bachu, S. Kopparthi, B. Adapa, and B. Barkana. Separation of voiced and unvoiced using zero crossing rate and energy of the speech signal. in *American Society for Engineering Education (ASEE) zone conference proceedings*. 2008. American Society for Engineering Education.
- [23] B. C. R. M. Araújo, "Drowsiness Detection Using a Headband and Artificial Neural Networks". 2019.
- [24] M. Azam, D. Jacoby, and Y. Coady. Classification of Fatigue in Consumer-grade EEG Using Entropies as Features. in *CS & IT Conference Proceedings*. 2020. CS & IT Conference Proceedings.
- [25] V. Bakshi, *Towards Practical Driver Cognitive Workload Monitoring via Electroencephalography*. 2018: University of Toronto (Canada).
- [26] F. Rohit, V. Kulathumani, R. Kavi, I. Elwarfalli, V. Kecojevic, and A. Nimbarte, "Real-time drowsiness detection using wearable, lightweight brain sensing headbands". *IET Intelligent Transport Systems*, 2017. 11(5): p. 255-263.
- [27] A. Mehreen, S. M. Anwar, M. Haseeb, M. Majid, and M. O. Ullah, "A hybrid scheme for drowsiness detection using wearable sensors". *IEEE Sensors Journal*, 2019. 19(13): p. 5119-5126.
- [28] R. Foong, K. K. Ang, Z. Zhang, and C. Quek, "An iterative cross-subject negative-unlabeled
- [2] K. C. OKAFOR, "Epworth Sleepiness Scale In Assessment of Sleepiness and Fatigue Among Commercial Long Distance Drivers In Benin City, Edo State, Nigeria". 2023.
- [3] N. Bharadwaj, P. Edara, and C. Sun, "Sleep disorders and risk of traffic crashes: A naturalistic driving study analysis". *Safety science*, 2021. 140: p. 105295.
- [4] N. S. S. Al-Bdairi, H. Zubaidi, and I. Obaid, "Injury severity of drowsy drivers involved in single vehicle crashes: Accounting for temporal instability and unobserved heterogeneity". *International Journal of Transportation Science and Technology*, 2023.
- [5] A. F. f. T. Safety, "2017 Traffic Safety Culture Index". 2017: Washington, D.C.
- [6] A. F. f. T. Safety, "2022 Traffic Safety Culture Index". 2022: Washington, D.C.
- [7] M. T. De Mello, F. V. Narciso, S. Tufik, T. Paiva, D. W. Spence, A. S. BaHammam, J. C. Verster, and S. R. Pandi-Perumal, "Sleep disorders as a cause of motor vehicle collisions". *International journal of preventive medicine*, 2013. 4(3): p. 246.
- [8] R. Alharbey, M. M. Dessouky, A. Sedik, A. I. Siam, and M. A. Elaskily, "Fatigue state detection for tired persons in presence of driving periods". *IEEE Access*, 2022. 10: p. 79403-79418.
- [9] A. Čolić, O. Marques, and B. Furht, *Driver drowsiness detection: Systems and solutions*. 2014: Springer.
- [10] B. G. Pratama, I. Ardiyanto, and T. B. Adji. A review on driver drowsiness based on image, bio-signal, and driver behavior. in *2017 3rd International Conference on Science and Technology-Computer (ICST)*. 2017. IEEE.
- [11] L. M. Bergasa, J. Nuevo, M. A. Sotelo, R. Barea, and M. E. Lopez, "Real-time system for monitoring driver vigilance". *IEEE Transactions on intelligent transportation systems*, 2006. 7(1): p. 63-77.
- [12] A. Kircher, M. Uddman, and J. Sandin, *Vehicle control and drowsiness*. 2002: Statens väg-och transportforskningsinstitut.
- [13] R. N. Khushaba, S. Kodagoda, S. Lal, and G. Dissanayake, "Driver drowsiness classification using fuzzy wavelet-packet-based feature-extraction algorithm". *IEEE transactions on biomedical engineering*, 2010. 58(1): p. 121-131.
- [14] A. Sahayadhas, K. Sundaraj, and M. Murugappan, "Detecting driver drowsiness based on sensors: a review". *Sensors*, 2012. 12(12): p. 16937-16953.
- [15] A. Palumbo, V. Gramigna, B. Calabrese, N. Ielpo, and A. Demeco, "A Wearable Device-Based System: The Potential Role in Real-time and Remote EEG Monitoring". *Frontiers in Biomedical Technologies*, 2024. 11(3): p. 375-388.



- [33] F. Wang, J. Lin, W. Wang, and H. Wang. EEG-based mental fatigue assessment during driving by using sample entropy and rhythm energy. in 2015 IEEE International Conference on Cyber Technology in Automation, Control, and Intelligent Systems (CYBER). 2015. IEEE.
- [34] A. Abdel-Rahman, A. F. Seddik, and D. M. Shawky. An affordable approach for detecting drivers' drowsiness using EEG signal analysis. in 2015 International Conference on Advances in Computing, Communications and Informatics (ICACCI). 2015. IEEE.
- [35] S. Arif, S. Munawar, and H. Ali, "Driving drowsiness detection using spectral signatures of EEG-based neurophysiology". *Frontiers in physiology*, 2023. 14: p. 1153268.
- [36] S. Arefnezhad, J. Hamet, A. Eichberger, M. Frühwirth, A. Ischebeck, I. V. Koglbauer, M. Moser, and A. Yousefi, "Driver drowsiness estimation using EEG signals with a dynamical encoder–decoder modeling framework". *Scientific reports*, 2022. 12(1): p. 2650.
- learning algorithm for quantifying passive fatigue". *Journal of neural engineering*, 2019. 16(5): p. 056013.
- [29] M. A. Almogbel, A. H. Dang, and W. Kameyama. Cognitive workload detection from raw EEG-signals of vehicle driver using deep learning. in 2019 21st International Conference on Advanced Communication Technology (ICACT). 2019. IEEE.
- [30] S. Chaabene, B. Bouaziz, A. Boudaya, A. Hökelmann, A. Ammar, and L. Chaari, "Convolutional neural network for drowsiness detection using EEG signals". *Sensors*, 2021. 21(5): p. 1734.
- [31] B. T. Nugraha, R. Sarno, D. A. Asfani, T. Igasaki, and M. N. Munawar, "CLASSIFICATION OF DRIVER FATIGUE STATE BASED ON EEG USING EMOTIV EPOC+". *Journal of Theoretical & Applied Information Technology*, 2016. 86(3).
- [32] A. Javed, M. U. Arshad, E. Saeed, and N. Naseer, "Real-time Drowsiness Detection and Emergency Parking using EEG". 2021.