

Stress Detection Based on Fusion of Multimodal Physiological Signals Using Dempster-Shafer Evidence Theory**Sara Majlesi^{1,2}, M.Sc., Mahdi Khezri^{1,2}, Assistant Professor**

¹Department of Electrical Engineering- Najafabad Branch, Islamic Azad University, Najafabad, Iran
²Digital Processing and Machine Vision Research Center- Najafabad Branch, Islamic Azad University, Najafabad, Iran

saramajlesi74@gmail.com, mahdi.khezri@pel.iaun.ac.ir

Abstract

Detecting and controlling stress levels in drivers is especially important to reduce the potential risks while driving. Accordingly, in this study, a detection system was presented to identify four levels of stress (low, neutral, high and very high) in drivers based on physiological signals. The proposed method used the *drivedb* database, which includes the recording of physiological signals from 17 healthy volunteers while driving on specific routes on city streets and highways. A set of statistical and entropy features along with morphological features that were calculated only for the ECG signals, were used. The calculated features were applied as inputs to the classification units to detect stress levels. Support vector machine (SVM), k nearest neighbors (kNN) and decision tree (DT) were evaluated as classification methods. The main purpose of this study was to improve the accuracy of stress level detection using the idea of classifiers fusion. To achieve this goal, the combination of individual classification units, each of which used only the features of one of the ECG, EMG and GSR signals, was performed by the Dempster-Shafer method. Using genetic algorithm as feature selection method, SVM classifier and Dempster-Shafer fusion strategy, the best stress detection accuracy of 96.9% was obtained. While the highest detection accuracy among individual classifiers was 75% and obtained by a subsystem that used ECG features. The results show significant performance of the proposed method compared to previous studies that used the same dataset.

Keywords: Dempster-Shafer fusion method, stress detection, physiological signals, SVM classifier

Received: 18 June 2021

Revised: 28 June 2021

Accepted: 20 August 2021

Corresponding Author: Dr Mahdi Khezri

تشخیص استرس بر مبنای همجوشی سیگنال‌های فیزیولوژیکی چندگانه با استفاده از نظریه شواهد دمپستر-شفر

سارا مجلسی^{۱،۲}، دانش‌آموخته کارشناسی ارشد، مهدی خضری^{۱،۲}، استادیار

۱- دانشکده مهندسی برق- واحد نجف‌آباد، دانشگاه آزاد اسلامی، نجف‌آباد، ایران

۲- مرکز تحقیقات پردازش دیجیتال و بینایی ماشین- واحد نجف‌آباد، دانشگاه آزاد اسلامی، نجف‌آباد، ایران
saramajlesi74@gmail.com, mahdi.khezri@pel.iaun.ac.ir

چکیده: تشخیص و کنترل سطح استرس در رانندگان به منظور کاهش خطرات ناشی از آن، از اهمیت ویژه‌ای برخوردار است. در این مطالعه سیستمی برای تشخیص چهار سطح استرس کم، متوسط، زیاد و خیلی زیاد در رانندگان براساس سیگنال‌های فیزیولوژیکی ارائه شده است. در روش پیشنهادی از پایگاه داده drivedb استفاده شده که شامل ثبت سیگنال‌های فیزیولوژیکی از هفده نفر داوطلب سالم هنگام رانندگی در مسیرهای مشخص از جمله خیابان‌های شهر و بزرگراه است. مجموعه‌ای از ویژگی‌های آماری و آنتروپی به همراه ویژگی‌های ریخت‌شناسی که فقط برای سیگنال ECG محاسبه شدند، به کار رفته است. ویژگی‌های تعیین شده به عنوان ورودی واحدهای طبقه‌بندی برای تشخیص سطوح استرس اعمال شدند. ماشین بردار پشتیبان (SVM)، k نزدیکترین همسایه (kNN) و درخت تصمیم (DT) به عنوان روش‌های طبقه‌بندی مورد ارزیابی قرار گرفتند. هدف اصلی این مطالعه، بهبود دقت تشخیص سطوح استرس با استفاده از ایده همجوشی در سطح نتایج واحدهای طبقه‌بندی است. به این منظور ترکیب واحدهای طبقه‌بندی منفرد، که هر کدام تنها از ویژگی‌های یکی از سیگنال‌های قلبی (ECG)، عضلات (EMG) و هدایت پوست (GSR) بهره گرفته‌اند، توسط روش دمپستر-شفر انجام شد. با انتخاب ویژگی‌های مؤثر با الگوریتم ژنتیک، طبقه‌بندی‌کننده SVM و روش همجوشی دمپستر-شفر، بهترین دقت تشخیص سطوح استرس برابر با ۹۶/۹ درصد به دست آمد. در حالی که بالاترین دقت تشخیص بین طبقه‌بندهای منفرد ۷۵ درصد بود و توسط زیر سیستمی که از ویژگی‌های سیگنال ECG استفاده کرده بود به دست آمد. نتایج به دست آمده عملکرد قابل توجه روش پیشنهادی را نسبت به مطالعات گذشته که از مجموعه داده مشابه استفاده کرده‌اند، نشان می‌دهد.

کلمات کلیدی: شناسایی استرس، سیگنال‌های فیزیولوژیکی، طبقه‌بند SVM، همجوشی دمپستر-شفر

تاریخ ارسال مقاله: ۱۴۰۰/۳/۲۸

تاریخ بازنگری مقاله: ۱۴۰۰/۴/۷

تاریخ پذیرش مقاله: ۱۴۰۰/۵/۲۹

نام نویسنده‌ی مسئول: دکتر مهدی خضری

نشانی نویسنده‌ی مسئول: نجف‌آباد- بلوار دانشگاه- دانشگاه آزاد اسلامی واحد نجف‌آباد- دانشکده مهندسی برق

۱- مقدمه

استرس یک حالت احساسی طبیعی است که انسان هنگام رویارویی با موقعیت‌های جدید و ناشناخته که باعث برهم خوردن آرامش ذهنی وی می‌شود، خواهد داشت. استرس واکنش بدن در برابر یک چالش یا تقاضا است. به عبارت دیگر استرس تنش عاطفی یا جسمی است که می‌تواند در اثر واقع‌های ایجاد شده و باعث ناامیدی، عصبانیت یا نگرانی شود. زمانی که استرس به مدت طولانی بر فرد غلبه کند، می‌تواند به سلامت فرد آسیب برساند [۱]. بدن انسان با ترشح هورمون کورتیزول توسط غده فوق کلیوی (آدرنال) به استرس واکنش نشان می‌دهد. این هورمون باعث فعالیت بهتر مغز و حافظه، افزایش تنش عضلات و نبض، افزایش سریع انرژی به منظور مقابله بدن، افزایش توان دفاعی بدن، کاهش حس درد و کمک به حفظ تعادل در فعالیت‌های حیاتی بدن می‌شود. در کوتاه مدت این واکنش‌ها خوب هستند زیرا می‌توانند به افراد کمک کنند تا شرایط ایجاد کننده استرس را کنترل کنند. این روش بدن برای محافظت از خود است. اما در هنگام استرس طولانی مدت، بدن همواره هوشیار باقی می‌ماند، حتی اگر خطری وجود نداشته باشد. با گذشت زمان این عمل باعث می‌شود فرد در معرض خطراتی از جمله فشار خون بالا، کاهش کیفیت خواب، احساس خستگی همیشگی، مشکلات قلبی عروقی، ناراحتی‌های معده، دیابت، مشکلات پوستی و همچنین افزایش وزن قرار بگیرد [۱].

رانندگی عمل پیچیده‌ای است که نیاز به تمرکز و آرامش کامل دارد. احساسات منفی مانند خشم یا استرس، با توجه به کاهش سطح تمرکز و آرامش فرد می‌توانند به‌طور چشمگیری توانایی رانندگان در تشخیص و پاسخ به خطرات را مختل کنند. تحقیقات نشان می‌دهد رانندگانی که از استرس ناشی از کار رنج می‌برند به احتمال زیاد در هنگام رانندگی سرعت خود را افزایش داده و در تصادفات جدی نیز درگیر می‌شوند. همه رانندگان در معرض شرایط رانندگی استرس‌زا هستند، حتی اگر به‌طور کلی در زندگی روزمره دچار استرس نباشند. رفت و آمد طولانی، آب و هوای نامناسب و ترافیک و ... می‌توانند استرس رانندگان را بیشتر کنند. بعضی از رانندگان با عصبانیت نسبت به شرایط رانندگی استرس‌زا واکنش نشان می‌دهند، که می‌تواند بسیار خطرناک باشد. رانندگی تهاجمی می‌تواند به نوبه خود میزان استرس را افزایش داده و به یک حلقه باطل تبدیل شود. متأسفانه بسیاری از عوامل بر میزان استرس فرد تأثیر می‌گذارند. رانندگی در مناطق شلوغ احتمالاً بیشترین استرس را ایجاد می‌کند. احساس گیر افتادن در ترافیک، عدم توانایی در انجام هر کاری و حتی پس از تغییر چراغ راهنمایی از قرمز به سبز می‌تواند سطح استرس را بالا ببرد [۲].

بسیاری از گروه‌های تحقیقاتی سعی کردند راه‌حل‌ها و ابزارهایی را برای وسایل نقلیه و رانندگان به منظور بهبود ایمنی، کارایی و کیفیت در بخش حمل و نقل ارائه دهند. با پیشرفت‌های فناوری، استفاده از حسگرهای پوشیدنی نه تنها نظارت بر شرایط فیزیولوژیکی را در زمان واقعی ارائه می‌دهد، بلکه ابزاری برای ارزیابی حالات عاطفی و شناختی انسان هنگام رانندگی فراهم می‌کند. در همین راستا مطالعات زیادی در سال‌های گذشته در زمینه نظارت بر استرس رانندگان به منظور تشخیص و کاهش سطح آن انجام شده است. سطح استرس راننده با روش‌های مختلف و از طریق بررسی پاسخ‌های فیزیولوژیکی و فیزیکی فرد قابل تشخیص است. پاسخ‌های فیزیولوژیکی مانند ضربان قلب^۱ (HR)، نرخ تنفس، فعالیت الکتریکی پوست^۲ (GSR)، دمای بدن، فعالیت عضلات اسکلتی^۳ (EMG) و فعالیت الکتریکی مغز^۴ (EEG) و همچنین پاسخ‌های فیزیکی مانند بیان‌های چهره‌ای، حرکات بدن و گفتار را می‌توان برای این منظور به کار برد. استفاده از اطلاعات سیگنال‌های چندگانه به منظور بهبود عملکرد سیستم و تشخیص دقیق میزان استرس می‌تواند مورد توجه قرار بگیرد [۳،۴].

مطالعه انجام شده توسط هیلی و پیکارد پیشگام در زمینه‌ی تشخیص استرس است [۳]. در این مطالعه جمع‌آوری و تحلیل داده‌های فیزیولوژیکی در حین رانندگی برای تعیین سطح استرس راننده، مدنظر قرار گرفته است. سیگنال‌های فعالیت قلب^۵ (ECG)، EMG، GSR و تنفس به‌طور پیوسته از ۲۴ راننده در حداقل زمان ۵۰ دقیقه، هنگام رانندگی در یک مسیر از پیش تعیین شده ثبت شدند. داده‌ها به دو روش تحلیل شدند. در تحلیل اول از ویژگی‌های استخراج شده از بازه‌های ۵ دقیقه‌ای داده‌ها در حالت استراحت و هنگام رانندگی در بزرگراه و در شهر برای تشخیص سه سطح استرس راننده استفاده شد. در این حالت دقت تشخیص بالاتر از ۹۷ درصد برای چند راننده طی چندین روز رانندگی به دست آمد. در تحلیل دوم ویژگی‌های پیوسته در بازه‌های یک ثانیه‌ای هنگام رانندگی که با معیارهای سنجش استرس از روی تصاویر ویدیویی تعیین شده بود را

مقایسه کردند. برای سیگنال‌ها در هر بخش، ۹ ویژگی آماری از آزمایش شامل مرحله استراحت، رانندگی در بزرگراه و رانندگی در شهر محاسبه شدند. از جمله این ویژگی‌ها، میانگین به‌هنگار شده‌ی سیگنال EMG و میانگین و واریانس به‌هنگار شده برای سیگنال تنفس، نرخ ضربان قلب و هدایت پوست هستند. نتایج به‌دست آمده در این مطالعه نشان می‌دهد که برای بیشتر رانندگان مورد مطالعه، میزان هدایت پوست و ضربان قلب با سطح استرس راننده همبستگی بیشتری دارند. این یافته‌ها نشان می‌دهد که سیگنال‌های فیزیولوژیکی می‌توانند معیاری از استرس راننده را در اتومبیل‌های آینده با قابلیت نظارت فیزیولوژیکی فراهم کنند.

آکماندور و همکاران یک سیستم تشخیص و کاهش استرس^۶ (SODA) معرفی کردند [۴]. این سیستم از حسگرهای پزشکی پوشیدنی که شامل سیگنال‌های ECG، GSR، نرخ تنفس، فشار خون و اکسیمتری خون بود برای نظارت پیوسته سطح استرس و کاهش آن استفاده کرد. این دستگاه، تشخیص و کاهش استرس را در روشی که فرد بتواند حرکت داشته باشد بدون نیاز به مداخله کاربر انجام می‌دهد. هنگامی که استرس را تشخیص می‌دهد، SODA برای کاهش استرس از یک روش تطبیقی مبتنی بر پاسخ استرس کاربر استفاده می‌کند. اثربخشی روش پیشنهادی از طریق تجزیه و تحلیل دقیق اطلاعات جمع‌آوری شده از ۳۲ شرکت کننده بررسی شد. در این مطالعه چهار عامل استرس‌زا و سه روش کاهش استرس به کار گرفته شدند. عوامل استرس‌زا شامل بازی حافظه، صدای پرواز، سیستم تصاویر عاطفی بین‌المللی^۷ (IAPS) و تست یخ و روش‌های کاهش استرس شامل گوش دادن به موسیقی کلاسیک، میکرومدیتیشن، لمس سنگ گرم و شنیدن اخبار خوب بودند. پس از انجام مراحل پیش‌پردازش و آماده‌سازی سیگنال‌ها، ویژگی‌های زمانی و فرکانسی شامل ۵۷ ویژگی از سیگنال ECG، ۱۶ ویژگی از سیگنال GSR، ۹ ویژگی از سیگنال تنفس، ۲ ویژگی از اکسیمتری و ۶ ویژگی از فشار خون به‌دست آمدند. روش تجزیه و تحلیل مولفه‌های اصلی^۸ (PCA) برای کاهش ابعاد مجموعه ویژگی‌ها استفاده شد. همچنین روش‌های ماشین بردار پشتیبان^۹ (SVM) و k نزدیک‌ترین همسایه^{۱۰} (kNN) برای طبقه‌بندی داده‌ها و تشخیص سطح استرس به کار رفتند. در مرحله تشخیص استرس، SODA با ترکیب روش‌های انتخاب ویژگی با نظارت و کاهش ابعاد ویژگی بدون نظارت به دقت ۹۵/۸ درصد دست یافت. در مرحله کاهش استرس، SODA با موقعی که کاهش استرس صورت نگرفته مقایسه شد و اثربخشی آن در پاسخ به استرس و کاهش آن تایید شد.

در مطالعه دیگری سبحانی و همکارانش، یک ساختار یادگیری ماشین^{۱۱} (ML) برای تحلیل سیگنال‌های EEG شرکت کنندگانی که استرس داشتند، ارائه کردند [۵]. در این مقاله، فرایند محاسبات ذهنی مبتنی بر کامپیوتر برای ایجاد استرس به کار گرفته شد. همچنین تصویربرداری استرس مونترال^{۱۲} (MIST) مورد استفاده قرار گرفت. آزمایش به کار گرفته شده شامل سه جزء اصلی استرس، کنترل و استراحت بود. شرایط استرس با تعیین زمان مشخص برای انجام یک کار (فشار زمانی) همراه با القای نظرات منفی ایجاد شد. در مقابل، شرایط کنترل شامل انجام محاسبات بدون چالش اضافی فشار زمان یا نظرات منفی بود. سیستم تصویربرداری استرس مونترال دارای ویژگی منحصر به فردی برای مقایسه شرایط استرس با شرایط کنترل در یک وضعیت مشابه است. شرایط استراحت شامل نشستن راحت همراه با چشمان باز بود. نوزده کانال EEG مطابق با سیستم ۱۰-۲۰ انتخاب شدند. چارچوب پیشنهادی ML شامل استخراج ویژگی‌های سیگنال EEG، انتخاب ویژگی (منحنی مشخصه عملکرد گیرنده، آزمون t و فاصله باتاچاریا)، طبقه‌بندی (رگرسیون لجستیک، SVM و طبقه بندی کننده بیز) و روش اعتبار سنجی ده لایه است. نتایج نشان داد که سیستم طراحی شده، دقت ۹۴/۶ درصد برای شناسایی دو سطح استرس و دقت ۸۳/۴ درصد برای شناسایی سطوح چندگانه کسب می‌کند. در نتیجه، ساختار ML مبتنی بر EEG پیشنهاد شده می‌تواند به ایجاد یک ابزار تشخیصی کامپیوتری برای تشخیص استرس کمک کند.

مینهوچوی و همکاران یک سیستم مبتنی بر دستگاه پوشیدنی برای نظارت بر شرایط غیر طبیعی راننده مثل استرس، خستگی و خواب‌آلودگی پیشنهاد کردند [۶]. سیستم موردنظر، اطلاعات حرکتی و فیزیولوژیکی راننده را با استفاده از دستگاه پوشیدنی قرار گرفته از روی مچ دست اندازه‌گیری می‌کند. پیش‌پردازش برای جداسازی بخش‌های معتبر سیگنال با توجه به آنکه نویزهای مختلفی بر روی سیگنال‌های ثبت شده از حسگرهای پوشیدنی قرار می‌گیرد، انجام شد. برای ایجاد شرایط استرس‌زا، رانندگی به مدت ۳۰ دقیقه در خیابان‌های شلوغ شهر با وجود سروصداها و مزاحم و ترافیک انجام شد. همچنین برای ایجاد

شرایط خواب‌آلودگی، رانندگی به مدت ۲ ساعت در بزرگراه خلوت و اجرای یک صدای آرام و یکنواخت برای راننده و برای ایجاد شرایط خستگی، رانندگی به مدت ۳۰ دقیقه در شرایط عادی در نظر گرفته شد. ویژگی‌های زمانی و فرکانسی برای سیگنال‌های پالس حجم خون^{۱۳} (PPG)، نرخ ضربان قلب^{۱۴} (HRV)، دمای پوست و GSR و همچنین شتاب و سرعت حرکات راننده که در حین رانندگی ثبت می‌شوند، تعیین شدند. مجموعه‌ای از ویژگی‌های بهینه با روش‌های آنالیز واریانس^{۱۵} (ANOVA) و انتخاب ترتیبی شناور رو به جلو^{۱۶} (SFFS) تعیین شدند. همچنین برای طبقه‌بندی و به‌منظور تشخیص حالت-های راننده، از طبقه‌بندی کننده‌ی SVM استفاده شد. آزمایش‌ها بر روی یک شبیه‌ساز رانندگی با ۲۸ نفر برای جمع‌آوری اطلاعات برای هر حالت فرد، انجام شد. دقت طبقه‌بندی با اعتبارسنجی پنج لایه در داده‌ها برابر با ۹۸/۴۳ درصد به‌دست آمد. در یک آزمون مستقل از کاربر، دقت تشخیص برای چهار حالت ۶۸/۳۱ درصد و برای سه حالت از حالات عادی، استرس، خستگی و حالت‌های خواب‌آلود ۸۴/۴۶ درصد به‌دست آمد. با استفاده از سیستم پیشنهادی، شرایط غیر طبیعی حین رانندگی را می‌توان تشخیص داد که این به راحتی بیشتر و ایمنی راننده کمک می‌کند.

لیو و همکاران استفاده از تحلیل تفکیک‌کننده خطی^{۱۷} (LDA) بر اساس سیگنال فعالیت الکتریکی پوست^{۱۸} (EDA) را برای ایجاد تمایز بین سه سطح استرس کم، متوسط و زیاد بررسی کردند [۷]. در این مطالعه از یازده سیگنال EDA پا در پایگاه داده استرس آزمایشگاه MIT Media استفاده شد. تعداد ۱۸ ویژگی از سیگنال‌های ثبت شده در حالت استراحت، رانندگی در بزرگراه و رانندگی در شهر استخراج شد. برای طبقه‌بندی سطوح استرس از نگاشت فیشر و روش LDA و برای اعتبارسنجی نتایج از روش یک نمونه بیرون^{۱۹} (LOO) استفاده شد. توسط سیستم پیشنهادی، سطح استرس با دقت ۸۱/۸۲ درصد تشخیص داده شد. مزیت این سیستم در مقایسه با سیستم‌های طراحی شده با سیگنال‌های چندگانه، کاهش پیچیدگی محاسباتی آن است.

حسابی و همکاران، یک سیستم تشخیص الگو مبتنی بر یادگیری عمیق جهت شناسایی حالت‌های عاطفی مثبت^{۲۰} (PA) و منفی^{۲۱} (NA) معرفی کردند [۸]. در این مطالعه دو روش همجوشی داده‌های چندگانه با شبکه‌های عصبی کانولوشنی عمیق برای تخمین PA و NA و همچنین طبقه‌بندی احساسات پایه، استرس و تفریح پیشنهاد شده است. فرایند آموزش و ارزیابی روش‌ها با استفاده از چهار سیگنال فیزیولوژیکی (تنفس، دمای پوست، سیگنال EMG و ECG که از ناحیه قفسه سینه و از ۱۵ نفر ثبت شده، انجام شد. مدل پیشنهادی در این مطالعه عملکرد بهتری نسبت به روش‌های یادگیری ماشین سنتی و ویژگی-های رایج دارد. با استفاده از تنها دو سیگنال، مدل پیشنهادی PA را با همبستگی ۰/۶۹ در مقابل ۰/۵۹ روش‌های یادگیری ماشین سنتی تخمین زد. مقدار همبستگی برای برآورد NA مقدار ۰/۷۹ در برابر ۰/۷۳ بود. بهترین روش طبقه‌بندی سنتی حالت‌های احساسی، مقادیر f1-score برابر ۷۹ درصد و ۸۰ درصد با استفاده از همه سیگنال‌های فیزیولوژیکی به‌دست آورد. این در حالی است که تنها با دو سیگنال، روش یادگیری عمیق، مقادیر f1-score برابر با ۷۸ درصد و ۷۹ درصد را کسب کرد.

در مطالعه دیگری راجاکندا و همکاران برای شناسایی و مدیریت استرس در چارچوب مراقبت‌های بهداشتی هوشمند، یک سیستم جدید مبتنی بر یادگیری عمیق ارائه کردند [۹]. سیستم طراحی شده با استفاده از معیارهایی چون دمای بدن، میزان حرکت و تعریق، سطح استرس فرد را تعیین می‌کند. روش پیشنهادی با استفاده از ۲۶۰۰۰ نمونه برای هر داده آموزش داده شده است و بهترین دقت ۹۹/۷ درصد را کسب کرده است. داده‌های جمع‌آوری شده به فضای ابری منتقل و ذخیره می‌شود و می‌تواند به نظارت زمان واقعی سطح استرس فرد کمک کنند؛ در نتیجه خطر مرگ و هزینه‌های درمانی را کاهش می‌دهد. سیستم طراحی شده می‌تواند با ارائه بازخورد فوری به خودآگاهی و تغییر سبک زندگی فرد برای داشتن زندگی سالم کمک-کند.

در این مطالعه طراحی یک سیستم تشخیص سطح استرس بر مبنای اطلاعات سیگنال‌های فیزیولوژیکی چندگانه مدنظر قرار گرفته است. هدف تشخیص تا حد ممکن دقیق سطوح استرس نسبت به وضعیت عادی فرد است. در این راستا از روش‌های پردازشی با کارایی مطلوب برای سیگنال‌های فیزیولوژیکی و همجوشی در سطح نتایج واحدهای طبقه‌بندی در طراحی سیستم استفاده شده است. استفاده از اطلاعات سیگنال‌های چندگانه با روش همجوشی می‌تواند به بهبود دقت تشخیص سطوح استرس کمک کند. به‌علاوه اینکه استفاده از همجوشی در سطح نتایج واحدهای طبقه‌بندی و اعمال ویژگی‌های سیگنال‌ها در


چند زیرمجموعه به چند واحد طبقه‌بندی می‌تواند، زمان پاسخ‌دهی را در نتیجه کاهش زمان آموزش واحدهای طبقه‌بندی کاهش دهد. در ادامه در بخش ۲ روش‌های مورد استفاده در طراحی سیستم معرفی شده است. همچنین بخش‌های ۳ و ۴ به ارائه نتایج، ارزیابی عملکرد سیستم و نتیجه‌گیری اختصاص خواهند داشت.

۲- مواد و روش‌ها

۲-۱- مجموعه داده استفاده شده

در این مطالعه از پایگاه داده *drivedb* که توسط جنیفر هیلی و همکاران ایجاد شده، استفاده می‌شود [۳]. این پایگاه داده شامل ثبت پارامترهای حیاتی *ECG*، *EMG*، *GSR* و تنفس^{۲۲} (*Resp*) از ۱۷ نفر داوطلب سالم هنگام رانندگی (۶۵-۹۳ دقیقه) در مسیری مشخص در خیابان‌های شهر و بزرگراه است. هدف بررسی امکان شناسایی خودکار میزان استرس بر اساس سیگنال‌های ثبت شده است. شکل (۱) نمونه‌ای از سیگنال‌های ثبت شده را برای یک نفر نمایش می‌دهد [۳، ۱۰]. ثبت سیگنال‌ها با دستگاه *FlexComp* انجام شده است. الکترودهای *ECG* به صورت لید II اصلاح شده قرار گرفتند تا آرتیفکت‌های حرکتی را به حداقل و دامنه امواج R را به مقدار بیشینه برسانند، به دلیل اینکه هر دو معیار *HR* و *HRV* که از روی سیگنال قلب تعیین می‌شوند، به مقدار پیک موج R وابسته هستند.

سیگنال *EMG* با قرار دادن الکترودهایی از روی عضله ذوزنقه‌ای (ناحیه شانه) ثبت شد؛ که در مطالعات دیگری نیز به عنوان شاخصی برای ارزیابی استرس به کار گرفته شده است. سیگنال *GSR* در دو محل اندازه‌گیری شد: دست چپ با استفاده از الکترودهایی که روی انگشت اول و میانی قرار گرفتند و در کف پای چپ با استفاده از الکترودهایی که در هر انتهای قوس پا قرار گرفتند. تنفس از طریق انبساط حفره قفسه سینه با استفاده از یک سنسور الاستیک اثر هال که حول دیافراگم راننده بسته شده بود، اندازه‌گیری شد. هر سیگنال با نرخ نمونه‌برداری مناسب برای استخراج اطلاعات موجود در سیگنال، ثبت شد. سیگنال *ECG* با نرخ ۴۹۶ هرتز، هدایت پوست و تنفس با نرخ ۳۱ هرتز و *EMG* با نرخ ۱۵/۵ هرتز بعد از اولین عبور از فیلتر میانگین‌گیر ۰/۵ ثانیه نمونه‌برداری شدند.



شکل (۱): (الف) محل الکترودها برای ثبت سیگنال‌های فیزیولوژیکی [۱۰] و (ب) نمونه‌ای از سیگنال‌های ثبت شده در پایگاه داده *drivedb* برای یک نفر [۳]

Figure (1): a) Location of electrodes for recording physiological signals [10], b) An example of the signals recorded in the *drivedb* database for one person [3].

سیگنال‌ها توسط یک کامپیوتر جاسازی شده در ماشین جمع‌آوری شدند. آزمایشگری به‌طور بصری ثبت سیگنال‌های فیزیولوژیکی را کنترل می‌کند. با استفاده از یک لپ-تاپ که دارای برنامه نمایش از راه دور است، سیگنال‌ها مشاهده می‌شوند. فرایند ثبت و وضعیت راننده توسط سه دوربین ضبط می‌شود. به‌طور کلی داده‌ها در حین ۲۷ رانندگی ثبت شدند. تعداد شش رانندگی توسط رانندگانی انجام شد که فقط یک بار در آزمایش شرکت کردند؛ و هفت نفر دیگر سه بار طی سه روز در آزمایش شرکت کردند. تعداد ۲۴ داده از ۲۷ داده اولیه توسط هیلی و همکارانش مورد استفاده قرار گرفت. به‌دلیل آن‌که سه مجموعه داده ناقص بود؛ یکی به‌دلیل افتادن حسگر هدایت پوست از دست، یک مجموعه داده به‌دلیل اینکه سیگنال ECG بسیار نویزی بود و مجموعه داده دیگر به‌دلیل اینکه به‌طور تصادفی بیش از حد ثبت شده بود، کنار گذاشته شدند. در مطالعه حاضر با توجه به‌اینکه تنها داده‌های ۱۷ رانندگی در پایگاه فیزیوت در دسترس بود، از این تعداد داده استفاده شده است.

۲-۲- پیش‌پردازش و آماده‌سازی سیگنال‌ها

پس از فرایند ثبت داده‌ها از رانندگان خواسته شد تا با تکمیل یک پرسش‌نامه، میزان استرس در هر یک از بخش‌های رانندگی را با مقادیر ۱ تا ۵ رتبه‌بندی کنند. مقدار یک حالت بدون استرس و مقدار ۵ حالت استرس زیاد را نشان می‌دهد. جدول (۱) میانه میزان استرس را در موقعیت‌های مختلف نشان می‌دهد. سیگنال‌ها با استفاده از یک فیلتر باترورت مرتبه ده به‌منظور حذف اثرات نویزی و تداخلی فیلتر شدند. همچنین به‌منظور کاهش بازه زمانی و تغییر پذیری سیگنال‌ها و همچنین ایجاد شرایط ایستایی، سیگنال‌ها به بازه‌های زمانی یک دقیقه‌ای تقسیم‌بندی شده و ویژگی‌های موردنظر برای هر بخش محاسبه شدند.

۲-۳- طراحی سیستم تشخیص استرس

به‌منظور کسب اطلاعات سیگنال‌ها و شناسایی سطح استرس در افراد شرکت‌کننده، مجموعه‌ای از ویژگی‌های زمانی، فرکانسی و همچنین ویژگی دینامیکی آنتروپی مورد استفاده قرار گرفتند. برای سیگنال ECG تعدادی از ویژگی‌های ریخت‌شناسی^{۲۳} رایج نیز به‌کار گرفته شدند. جدول (۲) ویژگی‌های استفاده شده برای هر سیگنال را ارائه می‌کند. با تعیین ویژگی‌ها، با استفاده از الگوریتم ژنتیک بهترین ویژگی‌ها برای هر سیگنال تعیین شدند [۱۱]. در این مطالعه شناسایی سطح استرس رانندگان یک بار با استفاده از همه ویژگی‌های سیگنال‌ها و بار دیگر پس از اعمال الگوریتم ژنتیک و انتخاب ویژگی‌های مؤثرتر صورت گرفت. در واقع عملکرد روش انتخاب ویژگی و تأثیر آن در نتایج مورد بررسی قرار گرفت. به‌منظور تعیین سطوح استرس، سه نوع طبقه‌بندی کننده SVM، kNN و درخت تصمیم^{۲۴} (DT) به‌کار گرفته شدند [۱۵-۱۲].

همچنین به‌منظور تعیین بهترین سیگنال‌ها و بهترین ویژگی‌ها در شناسایی سطح استرس، عملکرد هر یک از سیگنال‌ها به‌طور منفرد مورد ارزیابی قرار گرفت. به‌علاوه اینکه سیستم با استفاده از هم‌جوشی سیگنال‌ها نیز طراحی شد و نتایج به‌دست آمده ارائه شدند. در ساختار هم‌جوشی از روش هم‌جوشی دمپستر شفر^{۲۵} (DS) در سطح نتایج طبقه‌بندی‌کننده‌ها استفاده شد. با استفاده از روش‌های هم‌جوشی می‌توان با استفاده از اطلاعات تعداد بیشتری از سیگنال‌ها، قابلیت سیستم را در شناسایی استرس افزایش داد. در ساختار هم‌جوشی به‌کار گرفته شده در این مطالعه، ابتدا نتایج طبقه‌بندی حاصل از دو سیگنال با یکدیگر ترکیب شده و سپس نتیجه به‌دست آمده وارد هم‌جوشی با نتایج طبقه‌بندی حاصل از سیگنال سوم می‌شود. به‌این ترتیب ما سه سیستم تشخیص استرس با استفاده از ساختار هم‌جوشی ارائه شده خواهیم داشت. یکی از صورت‌های سیستم طراحی شده مطابق با شکل (۲) است.

۲-۳-۱- هم‌جوشی نتایج واحدهای طبقه‌بندی با استفاده از نظریه ترکیب دمپستر-شفر

طبق نظریه دمپستر-شفر، فضای نمونه Ω متشکل از گزاره‌های منطقی ناتهی و دو به دو مستقل A_i است که پیشامد نامیده می‌شوند. تابع جرم احتمال یا تابع تشخیص مجموعه برای هر پیشامد به‌صورت $m(A_i)$ نمایش داده شده و دارای شرایط زیر است [۱۶، ۱۷]:

Table (1): Driving events and stress ratings in each situation [10]

جدول (۱): موقعیت‌های رانندگی و رتبه‌بندی استرس در هر موقعیت [۱۰]

شماره ردیف	موقعیت رانندگی	میزان استرس
۱	شروع دوره‌ی رانندگی	۱
۲	خارج شدن از پارکینگ	۲
۳	رانندگی در شهر ۱	۴
۴	عوارضی ۱	۳
۵	رانندگی در بزرگراه ۱	۳
۶	عوارضی ۲	۳
۷	دور برگردان	۵
۸	عوارضی ۳	۳
۹	رانندگی در بزرگراه ۲	۳
۱۰	ادغام دوخط در بزرگراه	۵
۱۱	عوارضی ۴	۳
۱۲	عبور از پل	۴
۱۳	رانندگی در شهر ۲	۴
۱۴	ورود به پارکینگ	۱
۱۵	پایان دوره‌ی رانندگی	۱

Table (2): Features used for the signals in the design of stress detection system.

جدول (۲): ویژگی‌های استفاده شده برای سیگنال‌ها در طراحی سیستم تشخیص استرس

سیگنال مورد استفاده	ویژگی‌های محاسبه شده
EMG	میانگین، واریانس، چولگی ^{۲۶} ، کشیدگی ^{۲۷} ، چگالی طیف توان، آنتروپی شانون، آنتروپی بولتزمن، آنتروپی طیف نرمال شده، فاصله بیشترین کمترین ^{۲۸} (MMD)، لگاریتم ریشه مجموع تغییرات متوالی ^{۲۹} (LRSSV)، تعداد عبور از صفر، دامنه تبدیل فوریه.
ECG	میانگین، واریانس، چولگی، کشیدگی، چگالی طیف توان، آنتروپی شانون، آنتروپی بولتزمن، آنتروپی طیف نرمال شده، فاصله بیشترین کمترین (MMD)، لگاریتم ریشه مجموع تغییرات متوالی (LRSSV)، تعداد عبور از صفر، دامنه تبدیل فوریه، میانگین نرخ ضربان (HR)، میانگین فاصله RR، میانگین تغییرات نرخ ضربان (HRV)، انحراف استاندارد RR، انحراف استاندارد HR و میانگین مربعات ریشه‌ها از تفاضلات متوالی ^{۳۰} (RMSSD).
GSR	میانگین، واریانس، چولگی، کشیدگی، چگالی طیف توان، آنتروپی شانون، آنتروپی بولتزمن، آنتروپی طیف نرمال شده، فاصله بیشترین کمترین (MMD)، لگاریتم ریشه مجموع تغییرات متوالی (LRSSV)، تعداد عبور از صفر، دامنه تبدیل فوریه.

$$\begin{aligned}
 &A_i \subset \Omega, \quad i = 1, 2, \dots, M \\
 &m(A_i) \geq 0, \quad m(\emptyset) = 0 \\
 &\sum_{A_i \subset \Omega} m(A_i) = 1
 \end{aligned} \tag{۱}$$

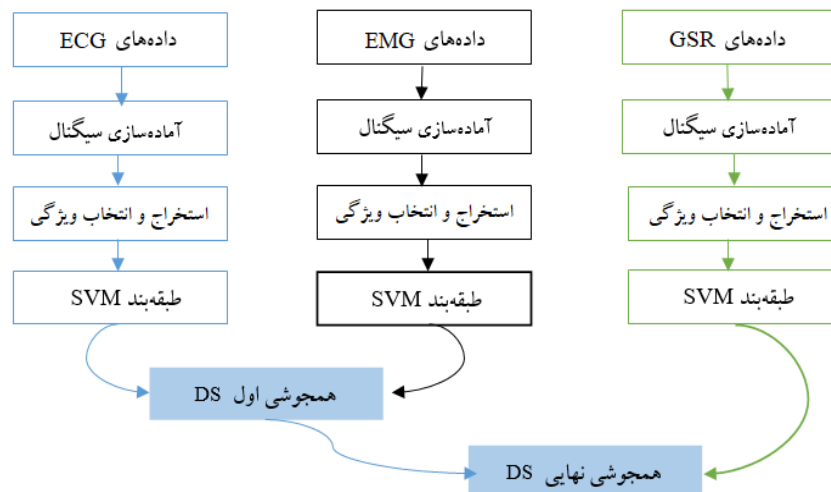
تابع باور^{۳۱} میزان اطمینان به یک موضوع خاص است که برابر با مجموع توابع جرم احتمال به عناصری است که در زیرمجموعه A_i قرار دارند و به صورت زیر محاسبه می‌شود:

$$\text{bel}(A) = \sum_{B \subset A, B \neq \emptyset} m(B) \tag{۲}$$

$\text{bel}(A) = 0$ بیانگر کمبود شواهد در مورد مجموعه A و $\text{bel}(A)$ برابر یک بیانگر اطمینان از رخداد پیشامد A است. بیشترین مقدار باور برای مجموعه A بر اساس شواهد موجود با عنوان امکان^{۳۲} یاد می‌شود:

$$\text{pl}(A) = \sum_{B \cap A \neq \emptyset} m(B) \tag{۳}$$

مقدار باور، کران پایین و امکان کران بالای عدم قطعیت را تشکیل می‌دهند. بنابراین احتمال وقوع A بین باور و امکان قرار دارد.



شکل (۲): بلوک دیاگرام ساختار پیشنهادی برای طراحی سیستم تشخیص استرس با استفاده از روش هم‌جوشی دمپستر-شفر
Figure (2): Block diagram of the proposed structure for the stress detection system using Dempster-Shafer fusion method

یکی از کاربردهای مهم نظریه دمپستر شفر در هم‌جوشی واحدهای طبقه‌بندی است. طبق قانون ترکیب دمپستر شفر، جمع متعامد توابع جرم منابع مستقل روی فضای مورد بررسی انجام می‌شود؛ یعنی خواهیم داشت:

$$m(Z) = \frac{\sum_{A_1 \cap A_2 = Z \neq \emptyset} m(A_1)m(A_2)}{1 - \sum_{A_1 \cap A_2 = \emptyset} m(A_1)m(A_2)} = \frac{\sum_{A_1 \cap A_2 = Z \neq \emptyset} m(A_1)m(A_2)}{\sum_{A_1 \cap A_2 \neq \emptyset} m(A_1)m(A_2)}, \quad A_1, A_2, Z \subseteq \Omega \quad (4)$$

با ترکیب توابع جرم طبق رابطه بالا سطح عدم قطعیت کاهش می‌یابد. در نهایت کلاسی که دارای بیشترین جرم باشد، به‌عنوان نتیجه نهایی طبقه‌بندی انتخاب می‌شود.

۳- نتایج

در این مطالعه هدف طراحی یک سیستم تشخیص سطح استرس با استفاده از سیگنال‌های فیزیولوژیکی چندگانه است. به‌این منظور سیگنال‌های ECG، GSR و EMG ثبت شده در حین رانندگی برای طراحی سیستم مورد استفاده قرار گرفتند. شرکت‌کنندگان در آزمایش پرسشنامه‌ای را تکمیل کردند که در هر بخش از مراحل رانندگی ذکر شده در جدول (۱) سطح استرس ایجاد شده را رتبه‌بندی کردند. امتیاز ۱ حالت بدون استرس و امتیاز ۵ استرس شدید راننده را نشان می‌دهد. مطابق با مقیاس-ها چهار سطح استرس به‌صورت استرس خیلی زیاد (موقعیت‌های ۷ و ۱۰)، استرس زیاد (موقعیت‌های ۳، ۱۲ و ۱۳)، استرس متوسط (موقعیت‌های ۴، ۵، ۶، ۸، ۹ و ۱۱) و استرس کم (۱، ۲، ۱۴ و ۱۵) در نظر گرفته شدند. برای هر یک از سیگنال‌ها تعداد ۱۶ ویژگی شامل ویژگی‌های زمانی، آماری و آنتروپی محاسبه شدند. همچنین سه روش طبقه‌بندی SVM، kNN و DT برای تشخیص سطوح استرس به‌کار گرفته شدند. پیاده‌سازی روش پیشنهادی و ارزیابی نتایج در نرم‌افزار متلب ۲۰۱۸ انجام شده است. به‌منظور استفاده از تمام داده‌ها در پیاده‌سازی سیستم تشخیص استرس و اعتبارسنجی نتایج کسب شده، روش k-fold با k برابر ۵ مورد استفاده قرار گرفت. در طراحی روش‌های طبقه‌بندی مورد استفاده سعی شد بهترین عملکرد روش با انتخاب پارامترهای مطلوب صورت پذیرد. توابع کرنل روش SVM، تعداد همسایگی روش kNN و ساختار و تعداد انشعابات در روش درخت تصمیم برای رسیدن به بهترین عملکرد طبقه‌بندی کننده ارزیابی شدند. در پیاده‌سازی طبقه‌بندی کننده SVM توابع کرنل مختلف شامل تابع پایه شعاعی^{۳۳} (RBF)، غیرخطی^{۳۴}، گوسی و خطی بررسی شدند؛ و بهترین عملکرد را تابع کرنل RBF کسب کرد. طبقه‌بندی کننده kNN با معیارهای فاصله و تعداد همسایگی‌های مختلفی مورد ارزیابی قرار گرفت و بهترین نتایج را فاصله اقلیدسی با تعداد همسایگی k برابر ۵ به‌دست آورد. همچنین روش درخت تصمیم درشت^{۳۵} با حداکثر انشعابات ۴ بهترین عملکرد را کسب نمود. عملکرد طبقه‌بندی کننده‌ها با معیارهای دقت^{۳۶}، حساسیت^{۳۷} و معین‌پذیری^{۳۸} که با روابط زیر تعریف می‌شوند، ارزیابی شدند [۱۲، ۱۸]:

$$\text{Accuracy} = \frac{TP + TN}{TP + FN + FP + TN} \quad (5)$$

$$\text{Sensitivity} = \frac{TP}{TP + FN} \quad (6)$$

$$\text{Specificity} = \frac{TN}{TN + FP} \quad (7)$$

در روابط بالا، TP بیانگر حالت مثبت حقیقی، TN منفی حقیقی، FP مثبت کاذب و FN بیانگر منفی کاذب هستند. TP مربوط به زمانی است که فرد بیمار به درستی بیمار تشخیص داده شده است. در TN فرد سالم به درستی سالم تشخیص داده شده است. در مورد FN، در فرد بیماری وجود دارد اما به طور اشتباه فرد سالم و بدون بیماری تشخیص داده شده است. و در حالت FP بیماری در فرد وجود ندارد، اما او به اشتباه بیمار تشخیص داده شده است. جدول (۳) نتایج کسب شده در تشخیص چهار سطح استرس را با استفاده از ویژگی‌های هر یک از سیگنال‌های مورد استفاده ارائه می‌کند. در این حالت از همه ویژگی‌های سیگنال‌ها استفاده شده است. نتایج به دست آمده نشان می‌دهد که طبقه‌بندی کننده SVM با استفاده از ویژگی‌های سیگنال ECG با کسب دقت تشخیص ۷۲/۱ درصد بهترین عملکرد را ارائه کرده است. به منظور بررسی اثر انتخاب ویژگی‌ها بر نتایج سیستم تشخیص سطوح استرس، الگوریتم ژنتیک بر روی ویژگی‌های هر یک از سیگنال‌ها اعمال شد. با اعمال الگوریتم ژنتیک تعداد ۱۰ ویژگی مؤثر برای سیگنال ECG تعیین شد. همچنین برای هر کدام از سیگنال‌های EMG و GSR تعداد ۶ ویژگی انتخاب شدند. نتایج کسب شده در تشخیص سطوح استرس برای هر کدام از سیگنال‌های مورد استفاده با اعمال الگوریتم ژنتیک به عنوان روش انتخاب ویژگی در جدول (۴) ارائه شده است. همان‌طور که در جدول (۴) مشاهده می‌شود، طبقه‌بند SVM در این حالت بهترین عملکرد را در تشخیص سطوح استرس ارائه کرده است. همچنین سیگنال ECG در مقایسه با دو سیگنال دیگر دقت تشخیص بالاتری کسب کرده است. با مقایسه نتایج جدول‌های (۳) و (۴) مشاهده می‌شود که اعمال مرحله انتخاب ویژگی‌ها با استفاده از الگوریتم ژنتیک باعث بهبود عملکرد سیستم و افزایش دقت تشخیص شده است. به منظور استفاده از اطلاعات همه سیگنال‌ها در طراحی سیستم و بهبود دقت تشخیص سطوح استرس، ساختار هم‌جوشی واحدهای طبقه‌بندی مدنظر قرار گرفت. به این منظور از روش دمپستر شفر و ساختاری همچون شکل (۲) بهره گرفته شد. همان‌طور که در شکل (۲) مشاهده می‌شود ابتدا نتایج کسب شده توسط دو زیر سیستم که با هر یک از سیگنال‌ها طراحی شده‌اند با روش دمپستر شفر با هم ترکیب شده و در ادامه هم‌جوشی مرحله دوم با نتیجه سیگنال سوم را خواهیم داشت.

Table (3): Accuracy of stress level detection using three different classifiers for ECG, EMG and GSR using all signal features
جدول (۳): دقت تشخیص سطوح استرس با استفاده از سه طبقه‌بند مختلف برای ECG, EMG و GSR با استفاده از همه ویژگی‌های

سیگنال‌ها

نوع طبقه‌بندی کننده	ECG	EMG	GSR
نزدیک‌ترین همسایه	۷۰/۶٪	۷۰٪	۶۳٪
درخت تصمیم	۶۴/۷٪	۶۹/۱٪	۶۶/۹٪
ماشین بردار پشتیبان	۷۲/۱٪	۷۱٪	۶۳/۵٪

Table (4): Accuracy of stress level detection using three different classifiers for ECG, EMG and GSR after selecting the effective features of the signals

جدول (۴): دقت تشخیص سطوح استرس با استفاده از سه طبقه‌بند مختلف برای سیگنال‌های ECG, EMG و GSR پس از انتخاب

ویژگی‌های مؤثر سیگنال‌ها

نوع طبقه‌بندی کننده	ECG	EMG	GSR
نزدیک‌ترین همسایه	۷۱/۶٪	۷۰/۶٪	۶۶/۲٪
درخت تصمیم	۶۵/۳٪	۶۹/۹٪	۶۶/۸٪
ماشین بردار پشتیبان	۷۵٪	۷۳/۶٪	۶۹/۱٪

نتایج به دست آمده توسط سه ساختار همجوشی مورد استفاده در جدول (۵) آرایه شده‌اند. با توجه به اینکه که در بررسی‌های اولیه طبقه‌بند SVM با استفاده از کرنل RBF عملکرد بهتری را نسبت به دو نوع روش طبقه‌بندی دیگر کسب کرد و ورودی-های طبقه‌بند نیز ویژگی‌های سه سیگنال مختلف هستند، در ساختارهای همجوشی تنها از طبقه‌بند SVM استفاده کردیم. استفاده از یک نوع طبقه‌بند در طراحی سیستم‌های همجوشی به دلیل مسأله همزمانی اهمیت دارد. در واقع موقعی که از طبقه‌بند‌های یکسان استفاده می‌کنیم، زمان آموزش طبقه‌بندها و تولید پاسخ توسط آن‌ها به هم نزدیک خواهد بود. همان‌طور که در جدول بالا مشاهده می‌شود، استفاده از ساختار همجوشی باعث بهبود دقت تشخیص سطوح استرس شده است. در هر کدام از سه ساختار در نظر گرفته شده عملکرد سیستم مطلوب و دقت تشخیص بالاتر از ۹۴ درصد به دست آمده است؛ که نسبت به بهترین سیگنال منفرد بیش از ۲۰ درصد بهبود را نشان می‌دهد. عملکرد سیستم طراحی شده همچنین در مقایسه با سیستم‌های طراحی شده قبلی که از مجموعه داده drivedb استفاده کرده‌اند بهبود یافته است. جدول (۶) نتایج مطالعات گذشته با مجموعه داده مشابه را با مطالعه حاضر مقایسه می‌کند. در تشخیص سطوح استرس بهترین عملکرد کسب شده در مطالعه مرجع ۲۰ به دست آمده است؛ که در آن مطالعه نیز اطلاعات سه نوع سیگنال فیزیولوژیکی مورد استفاده قرار گرفته‌اند. نتایج سیستم طراحی شده در مطالعه حاضر نسبت به بهترین سیستم در مطالعات گذشته برای تشخیص سطوح استرس، بهبود قابل توجهی را نشان می‌دهد. عملکرد مطلوب سیستم تشخیص استرس در این مطالعه، آن را برای کاربردهای واقعی مطلوب می‌سازد.

۴- نتیجه‌گیری

در این مطالعه هدف طراحی یک سیستم تشخیص الگو به منظور شناسایی تا حد ممکن دقیق چهار سطح استرس شامل استرس کم، استرس متوسط، استرس زیاد و استرس خیلی زیاد در حین فرایند رانندگی بوده است. شناسایی دقیق استرس در رانندگان و آرایه فیدبک‌های مناسب به آن‌ها می‌تواند به ایمنی فرد و بهبود فرایند رانندگی کمک کند. سیگنال‌های فیزیولوژیکی شامل ECG، EMG و GSR از مجموعه داده drivedb که برای رانندگان حین رانندگی در شهر و بزرگراه ثبت شده‌اند، در مطالعه حاضر برای طراحی سیستم تشخیص استرس مورد استفاده قرار گرفتند. ویژگی‌های زمانی و فرکانسی و آنتروپی برای کسب اطلاعات سیگنال‌ها و همچنین سه نوع روش طبقه‌بندی مختلف شامل SVM، kNN و DT مورد ارزیابی قرار گرفتند.

Table (5): Accuracy of stress levels detection using the proposed fusion structures.

جدول (۵): دقت تشخیص سطوح استرس با استفاده از ساختارهای همجوشی پیشنهادی

ساختار سیستم	دقت	حساسیت	معین پذیری
(EMG+GSR)+ECG	۹۴/۹۹٪	۸۹/۵۱٪	۹۲/۰۸٪
(ECG+GSR)+EMG	۹۵/۶۸٪	۹۱/۳۲٪	۹۲/۳۶٪
(ECG+EMG)+GSR	۹۶/۹۶٪	۹۱/۰۳٪	۹۴/۷۳٪

Table (6): Comparison of the results of stress detection systems in previous studies and the proposed method in the present study

جدول (۶): مقایسه‌ی نتایج سیستم‌های تشخیص استرس در مطالعات پیشین و روش پیشنهادی در مطالعه حاضر

مطالعه انجام شده	پایگاه داده	سیگنال‌های مورد استفاده	سطوح استرس	دقت تشخیص
[۱۹]	drivedb	ECG	۲ سطح	۸۱/۰۶٪ - ۱۰۰٪
[۲۰]	drivedb	EMG, HR, GSR	۵ سطح	۸۶/۱۴٪ همبستگی
[۲۱]	drivedb	ECG	۲ سطح	۹۸/۶٪
[۷]	drivedb	EDA	۴ سطح	۸۱/۸٪
روش پیشنهادی	drivedb	ECG, EMG, GSR	۴ سطح	۹۶/۹۶٪

در بررسی اولیه، عملکرد ویژگی‌ها با روش انتخاب ویژگی الگوریتم ژنتیک و همچنین عملکرد واحدهای طبقه‌بندی ارزیابی شد. نتایج نشان دادند که طبقه‌بند SVM با تابع کرنل RBF در مقایسه با دو روش طبقه‌بندی دیگر عملکرد بهتری ارائه می‌کند. همچنین نتایج سیستم تشخیص سطح استرس موقعی که از روش انتخاب ویژگی بهره می‌گیریم در مقایسه با حالتی که همه ویژگی‌های سیگنال‌ها استفاده می‌شوند، مطلوب‌تر است. به‌منظور بهبود دقت سیستم و همچنین کسب اطلاعات بیشتر از وضعیت فرد با استفاده از ویژگی‌های همه سیگنال‌ها، یک ساختار هم‌جوشی در سطح نتایج واحدهای طبقه‌بندی با استفاده از روش دمپستر شفر مورد توجه قرار گرفت. به این ترتیب که نتایج طبقه‌بندی سه سیگنال مختلف با طبقه‌بند SVM با استفاده از روش هم‌جوشی دمپستر- شفر با یکدیگر ترکیب شدند و دقت ۹۶/۹۶ درصد برای طبقه‌بندی ۴ سطح استرس به‌دست آمد. نتیجه کسب شده نسبت به نتایج واحدهای طبقه‌بندی منفرد تا ۲۰ درصد و نسب به مطالعات پیشین که از مجموعه داده مشابه استفاده کرده‌اند تا حدود ۱۰ درصد بهبود در دقت شناسایی را نشان می‌دهد. نتایج به‌دست آمده پیشنهاد می‌کند که ساختار معرفی شده در این مطالعه می‌تواند برای طراحی سیستم تشخیص استرس برای کاربردهای مختلف مورد توجه قرار گیرد.

References

مراجع

- [1] S.M. Ahmed, P.J. Hershberger, J.P. Lemkau, R. Rakel, D. Rakel, "Psychosocial influences on health", Textbook of Family Medicine E-Book, Elsevier Health Sciences, March, 2011.
- [2] L. Bowen, A. Smith, "Drive better, feel better: predicting well-being and driving behaviour in undergraduate psychology students", *Advances in Social Sciences Research Journal*, vol. 6, no. 2, pp. 302- 318, Feb. 2019 (doi: 10.14738/assrj.62.6221).
- [3] J.A. Healey, R.W. Picard, "Detecting stress during real-world driving tasks using physiological sensors", *IEEE Trans. on Intelligent Transportation Systems*, vol. 6, no. 2, pp. 156-166, June 2005 (doi: 10.1109/T-ITS.2005.848368).
- [4] A.O. Akmandor, N.K. Jha, "Keep the stress away with SoDA: Stress detection and alleviation system", *IEEE Trans. on Multi-Scale Computing Systems*, vol. 3, no. 4, pp. 269-282, Oct.-Dec. 2017 (doi: 10.1109/TMSCS.2017.2703613).
- [5] A. R. Subhani, W. Mumtaz, M. N. B. M. Saad, N. Kamel, A. S. Malik, "Machine learning framework for the detection of mental stress at multiple levels", *IEEE Access*, vol. 5, pp. 13545-13556, 2017 (doi: 10.1109/ACCESS.2017.2723622).
- [6] M. Choi, G. Koo, M. Seo, S. W. Kim, "Wearable device-based system to monitor a driver's stress, fatigue, and drowsiness", *IEEE Trans. on Instrumentation Measurement*, vol. 67, no. 3, pp. 634-645, Mar. 2017 (doi: 10.1109/TIM.2017.2779329).
- [7] Y. Liu, S. Du, "Psychological stress level detection based on electrodermal activity", *Behavioural brain research*, vol. 341, pp. 50-53, Apr. 2018 (doi: 10.1016/j.bbr.2017.12.021).
- [8] M. D. Hssayeni, B. Ghoraani, "Multi-modal physiological data fusion for affect estimation using deep learning", *IEEE Access*, vol. 9, pp. 21642-21652, 2021 (doi: 10.1109/ACCESS.2021.3055933).
- [9] L. Rachakonda, S. P. Mohanty, E. Kougianos, P. Sundaravadivel, "Stress-lysis: A DNN-integrated edge device for stress level detection in the IoMT," *IEEE Trans. on Consumer Electronics*, vol. 65, no. 4, pp. 474-483, Nov. 2019 (doi: 10.1109/TCE.2019.2940472).
- [10] J. Healey, R. Picard, "SmartCar: detecting driver stress", *Proceeding of the IEEE/ICPR*, pp. 218-221, Barcelona, Spain, Sept. 2000 (doi: 10.1109/ICPR.2000.902898).
- [11] Y. Zhou, J. Kang, X. Zhang, "A cooperative coevolutionary approach to discretization-based feature selection for high-dimensional data", *Entropy*, vol. 22, no. 6, p. 613, June 2020 (doi: 10.3390/e22060613.).
- [12] S. Karimi-Shahraki, M. Khezri, "Identification of ADHD patients using wavelet-based features of EEG signals", *Journal of Intelligent Procedures in Electrical Technology*, vol. 12, no. 47, pp. 1-11, Dec. 2021 (dor: 20.1001.1.23223871.1400.12.3.1.1) (in Persian).
- [13] S. R. Safavian D. Landgrebe, "A survey of decision tree classifier methodology", *IEEE Trans. on systems, man, cybernetics*, vol. 21, no. 3, pp. 660-674, May-June. 1991 (doi: 10.1109/21.97458).
- [14] C. Reinders, H. Ackermann, M.Y. Yang, B. Rosenhahn, "Chapter4- Learning convolutional neural networks for object detection with very little training data", *Multimodal Scene Understanding: Algorithms, Applications and Deep Learning Elsevie*, pp. 65-10, 2019 (doi:10.1016/B978-0-12-817358-9.00010-X).

- [15] N. Dashti, M. Khezri, "Recognition of motor imagery based on dynamic features of electroencephalography signals", *Journal of Intelligent Procedures in Electrical Technology*, vol. 11, no. 43, pp. 13-27, June 2020 (in Persian).
- [16] T. Denœux, "Logistic regression, neural networks and Dempster-Shafer theory: A new perspective", *Knowledge-Based Systems*, vol. 176, pp. 54-67, Jul. 2019 (doi: 10.1016/j.knosys.2019.03.030).
- [17] G. Shafer, "A mathematical theory of evidence", Princeton university press, 1976.
- [18] G. Mardanian, N. Behzadfar, "A new method for detection of breast cancer in mammography images using a firefly algorithm", *Journal of Intelligent Procedures in Electrical Technology*, vol. 10, no. 40, pp. 23-32, March 2020 (in Persian).
- [19] J.-S. Wang, C.-W. Lin, Y.-T. C. Yang, "A k-nearest-neighbor classifier with heart rate variability feature-based transformation algorithm for driving stress recognition", *Neurocomputing*, vol. 116, pp. 136-143, Sept, 2013 (doi: 10.1016/j.neucom.2011.10.047).
- [20] S. Pourmohammadi, A. Maleki, "A fuzzy C-means clustering approach for continuous stress detection during driving", *Signal and Data Processing*, vol. 14, no. 4, pp. 129-142, March 2018 (doi: 10.29252/jsdp.14.4.129) (in Persian).
- [21] M.F. Rizwan, R. Farhad, F. Mashuk, F. Islam, M.H. Imam, "Design of a biosignal based stress detection system using machine learning techniques", *Proceeding of the IEEE/ ICREST*, pp. 364-368, Dhaka, Bangladesh, Jan 2019 (doi: 10.1109/ICREST.2019.8644259).

زیر نویس‌ها

1. Heart Rate
2. Galvanic Skin response
3. Electromyogram
4. Electroencephalogram
5. Electrocardiogram
6. Stress detection and alleviation system
7. International Affective Pictures System
8. Principle component analysis
9. Support vector machine
10. K nearest neighbors
11. Machine learning
12. Montreal imaging stress task
13. Photo plethysmography
14. Heart rate variability
15. Analysis of variance
16. Sequential floating forward selection
17. Linear discriminant analysis
18. Electro dermal activity
19. Leave one out
20. Positive affect
21. Negative affect
22. Respiration
23. Morphological
24. Decision tree
25. Dempster shafer
26. Skewness
27. Kurtosis
28. Maximum minimum distance
29. Log root sum of sequential variations
30. Root Mean Square of the successive differences
31. Belief
32. Plausibility
33. Radial basis function
34. Quadratic
35. Coarse
36. Accuracy
37. Sensitivity
38. Specificity