

بکارگیری سیگنال EEG در تشخیص خستگی راننده با استفاده از ادغام میانی شبکه عصبی کانولوشنی چند جریانه^۱

هانیه بذرگزاده^۱، کامران کاظمی^۱ حبیب اله دانیالی^۱، اردلان اعرابی^۲
^۱دانشگاه صنعتی شیراز، {h.bazregarzadeh, kazemi,danyali}@sutech.ac.ir
^۲دانشگاه پیکاردی ژول ورن، ardalan.aarabi@u-picardie.fr

چکیده - خستگی و تاثیرات آن بر فعالیت های روزمره و رفتار اجتماعی افراد از جمله موضوعات تحقیقاتی مورد توجه در طی سال های اخیر بوده است؛ خصوصا در بحث سوانح رانندگی خستگی یکی از عوامل اصلی تصادفات و تلفات جانی در جاده ها است. از شاخص های فیزیولوژی متعددی برای پیوند دادن ارتباط فیزیولوژی و خستگی در سال های اخیر استفاده شده است که از این میان الکتروانسفالوگرافی (EEG) یکی از روش های قابل اعتماد برای ارزیابی مستمر سطح خستگی است. در این مقاله با بهره گیری از شبکه های یادگیری عمیق، روش جدیدی جهت تشخیص در حین رانندگی به وسیله سیگنال EEG ارائه شده است. به منظور بررسی روش پیشنهادی، از داده عمومی در هنگام رانندگی که در حالت هوشیار (اوایل رانندگی) و خسته (اواخر رانندگی) ثبت گرفته شده، استفاده شده است. بعد از پیش پردازش و حذف نویز سیگنال، ویژگی جگالی طیف توان سیگنال با بکارگیری مدل خودبازگشتی برآورد شده و کلاس بندی توسط شبکه عصبی کانولوشنی چند جریانه (MSCNN) انجام شده است. سیستم پیشنهادی توانسته است با دقت ۹۳/۴۹ درصد پنجره های زمانی را به درستی کلاس بندی کند.

کلید واژه- تشخیص خستگی، سیگنال EEG، یادگیری عمیق، شبکه عصبی کانولوشنی چند جریانه

در روش های تشخیصی مبتنی بر وسیله نقلیه، اگرچه این روش ها امکان تشخیص غیر تماسی را فراهم می کند و باعث برطرف

۱- مقدمه

کردن هرگونه مزاحمت برای راننده می شود، اما به دلیل تفاوت هایی مانند نوع وسیله نقلیه، شرایط رانندگی، تجربه راننده و شرایط هندسی و محیطی جاده تلاش برای پیدا کردن یک مدل مشترک دشوار است. علاوه بر این تغییرات در رفتار رانندگی منحصر به دلیل خستگی نیست، بلکه تحت تاثیر انگیزه، تجربه و شخصیت راننده قرار می گیرد. در روش های تشخیصی مبتنی بر تکنیک های جذب تصویر که برای ردیابی تغییرات رفتاری، درصد باز و بسته شدن چشم ها، موقعیت چهره، چرت زدن و جهت چشم استفاده می شود، علیرغم پیشرفت هایی که در سال های اخیر بدست آمده این گونه تصویر برداری به بازتاب نور اطراف حساس است و دقت اندازه گیری می تواند تحت تاثیر انعکاس نور قرار بگیرد.

روش های تشخیص خستگی مبتنی بر سیگنال های

خستگی راننده یک مشکل جدی در جامعه است که امروزه باعث افزایش تعداد تصادفات رانندگی شده است. این حالت که به دلیل طولانی بودن رانندگی و کاهش توانایی های روحی و جسمی در فرد رخ می دهد باعث اختلال در ادراک، شناخت و عدم توانایی کنترل وسیله نقلیه می شود. بنابراین تشخیص دقیق خستگی راننده و ایجاد یک سیستم عملی هشدار، برای کاهش تصادفات در جامعه مدرن امروزی بسیار حائز اهمیت است. روش های عینی و ذهنی^۲ بسیاری در سال های اخیر برای تشخیص خستگی ارائه شده است. روش های عینی شامل اندازه گیری پارامترهای رانندگی وسیله نقلیه مانند سرعت، چرخش فرمان اتومبیل، تجزیه و تحلیل پارامترهای فیزیولوژی راننده مانند الکتروکادیوگرام^۳ [۱]، الکترواکولوگرام^۴ [۲]، الکترومایوگرام^۵ [۳] و اندازه گیری ویژگی های رفتاری راننده مانند نرخ پلک زدن با استفاده از تکنیک های تصویربرداری ویدئویی است [۴].

¹ Multi-Stream Convolutional Neural Network

² Objective and subjective measures

³ Electrocardiogram

⁴ Electrooculogram

⁵ Electromyogram

متصل انجام می‌شود. به علاوه جهت بررسی موثرترین ناحیه در تشخیص، سیگنال‌های هر لوب به صورت جداگانه به شبکه تک جریانه^۴ اعمال شده است.

در ادامه در بخش دوم به تشریح پایگاه داده به کار برده شده و الگوریتم پیشنهادی پرداخته می‌شود. در بخش های سوم و چهارم به ترتیب نتایج ارائه و مورد بررسی قرار می‌گیرند.

۲- مواد و روش‌ها

در این مقاله روش جدیدی جهت تشخیص خستگی در حین رانندگی با استفاده از سیگنال *EEG* ثبت شده از داوطلبان سالم در دو حالت خسته و هوشیار ارائه می‌گردد. الگوریتم پیشنهادی شامل ۳ مرحله می‌باشد: (۱) پیش پردازش جهت حذف نویز و آرتیفکت، (۲) استخراج ویژگی و (۳) بکارگیری شبکه کانولوشنی برای کلاس‌بندی سیگنال *EEG* به دو حالت خسته و هوشیار.

با توجه به فعالیت مغزی در باند فرکانسی ۱ تا ۴۰ هرتز این محدوده از سیگنال برای بررسی‌های بعدی در نظر گرفته شده است. در این مقاله، جهت کلاس‌بندی، از شبکه عصبی کانولوشنی یک بعدی^۵ بهره برده ایم. از آنجا که مغز انسان دارای ۵ لوب اصلی پیشانی، مرکزی، گیجگاهی، جداری و پس‌سری است و هر کدام از این لوب‌ها اطلاعات خاصی را در بردارند، شبکه کانولوشنی ۵ جریانه^۶ طراحی شده است که ورودی هر جریان ویژگی استخراج شده از یکی از لوب‌ها می‌باشد.

هر جریان متشکل از سه لایه کانولوشنی است و در هر لایه کانولوشنی از ۶۴ فیلتر با کرنل ۳ بهره برده‌ایم. سپس خروجی لایه-های کانولوشنی به هم الحاق شده اند و در نهایت خروجی الحاق شده را برداری کرده و با استفاده از ۲ لایه تمام متصل کلاس‌بندی انجام شده است. بر اساس تحقیقات ما، این روش طراحی شبکه عمیق تا به حال جهت شناسایی خستگی مورد استفاده قرار نگرفته است و روشی جدید در این حوزه است.

۲-۱- ثبت سیگنال *EEG*

در این تحقیق از داده ای *EEG* ثبت شده از دوازده مرد جوان، سالم، که سن آنها بین ۱۹-۲۴ سال بود و در آزمایش شبیه‌ساز رانندگی بزرگراه شرکت کردند استفاده شده است [۹]. از همه شرکت-کنندگان خواسته شد که در طول آزمایش از مصرف هر نوع دارو و

فیزیولوژی از این واقعیت ناشی می‌شوند که کاهش کارایی در عملکرد و هوشیاری منجر به ایجاد تغییراتی در ویژگی‌های فیزیولوژی فرد می‌شود. از شاخص‌های فیزیولوژی متعددی برای پیوند دادن ویژگی‌های فیزیولوژیک و خستگی استفاده می‌شود که از میان این روش‌ها *EEG* قابل اعتمادترین روش برای ارزیابی مستمر سطح خواب‌آلودگی است. از جمله مزیت‌های این سیگنال‌ها رزولوشن زمانی بالای آنهاست که با تمرکز بر روی آنها می‌توان نواسانات وضعیت هوشیاری را با سرعت و دقت بالاتری دنبال نمود. مقالات بسیاری برای تشخیص خستگی توسط سیگنال‌های *EEG* منتشر شده است و این مطالعات که عمدتاً روی تکنیک‌های استخراج و طبقه‌بندی ویژگی‌ها تمرکز دارد، به دنبال یک ترکیب مطلوب از موقعیت الکترو، ویژگی‌ها و طبقه‌بندی برای بهبود عملکرد الگوریتم هستند.

در یک مطالعه [۵] با استفاده از تجزیه تحلیل مولد بازگشتی^۱ تنها از یک الکتروود پیشانی سیگنال *EEG* ثبت شده و برای طبقه بندی از ترکیب طبقه بند ماشین بردار پشتیبان و بیزین استفاده شده است. در مطالعه دیگری [۶]، با محاسبه توان باندهای تتا، آلفا و بتا به عنوان ویژگی‌های استخراج شده از ناحیه پس‌سری، طبقه بندی با استفاده از مدل غیرخطی ماشین بردار پشتیبان انجام شده است. دقت نتایج بدست آمده ۹۱/۲۵٪، ۸۳٪/۸۷ و ۹۱/۹۲٪ به ترتیب برای گروه های هوشیار، هشدار زود هنگام و گروه خسته بود. یادگیری ماشینی در سال‌های اخیر به ویژه در زمینه یادگیری عمیق پیشرفت‌های چشم‌گیر داشته است. بنابراین، استفاده از این تکنیک‌ها و روش‌های جدید نه تنها برای افزایش کارایی سیستم تشخیص خستگی راننده در دنیای واقعی موثر است، بلکه ابزاری را فراهم می‌کند که مورد استفاده گسترده رانندگان باشد.

اخیراً، رویکردهای یادگیری عمیق، به ویژه شبکه‌های عصبی کانولوشنی (*CNN*) در حل مشکلات طبقه‌بندی چالش برانگیز برجسته شده اند. این شبکه‌ها در کارهای مختلف بینایی کامپیوتری^۲ از جمله ناحیه‌بندی تصاویر، تشخیص احساسات، تشخیص اشیاء موجود در تصویر و طبقه‌بندی تصاویر پیشرفت‌های غیر منتظره‌ای داشته‌اند [۷] و [۸]. در این مقاله یک سیستم جدید برای تشخیص خستگی هنگام رانندگی بر اساس سیگنال‌های *EEG* ارائه شده است. در سیستم پیشنهادی برآورد ویژگی چگالی طیف توان سیگنال‌های هر لوب مغز به جریان‌های^۳ شبکه *CNN* اعمال می‌شوند و پس از گذر از سه لایه کانولوشنی یک بعدی کلاس‌بندی توسط دو لایه تمام

⁴ Single stream

⁵ One-dimensional convolutional neural network

⁶ Five-stream middle fuion

¹ Recurrent Neural Network

² Computer vision

³ Stream

۲۵۰ نمونه در ثانیه کاهش داده شد.

۲-۳- استخراج ویژگی

استخراج ویژگی فرآیندی است که در آن با انجام عملیاتی بر روی داده‌ها، ویژگی‌های بارز و تعیین‌کننده آن مشخص می‌شود. به عبارت دیگر می‌توان این گونه مطرح کرد که استخراج ویژگی منجر به کاهش منابع مورد نیاز برای توصیف یک مجموعه داده بزرگ می‌شود. در این تحقیق از طیف توان سیگنال هر پنجره زمانی به عنوان ویژگی ورودی به شبکه کانولوشنی استفاده می‌شود.

تخمین تابع چگالی طیف توان جهت استخراج اطلاعات نهفته در آن از اهمیت بالایی برخوردار است و این برآورد معمولاً به دو روش انجام می‌شود. یکی روش غیرپارامتری است که در این روش هیچ الگویی از قبل فرض نمی‌شود و با استفاده از توابعی مانند دوره نگار^۳ و دوره نگار وزنی، تابع چگالی طیف توان برآورد می‌گردد. روش دوم که روشی پارامتری است تابع چگالی طیف توان از طریق یک مدل برآورد می‌گردد [۱۳] و [۱۴] و [۱۵]. یکی از روش‌های برآوردیابی که در دو دهه اخیر بیشتر مورد توجه قرار گرفته است، روش برآورد با کمترین واریانس است. این روش دارای قدرت تفکیک پذیری بالا می‌باشد که برای اولین بار توسط کپون^۴ در حالت یک متغیره مطرح گردید [۱۶]. اگر متغیرهای تصادفی X_0, X_1, \dots, X_{n-1} را برای یافتن پارامترهای مدل خودبازگشتی $AR(p)$ در اختیار داشته باشیم، برآورد کننده خطی X_n به صورت معادله (۱) خواهد بود:

$$\hat{X}_n = \sum_{k=1}^p a_p(k) X_{n-k} = X'_n a_p \quad (1)$$

که در آن

$$X_n = (X_0, X_1, \dots, X_{n-1})'$$

$$a_p = (a_p(0), a_p(1), \dots, a_p(p))$$

به ترتیب بردار مشاهدات و بردار ضرایب می‌باشند. یک روش متداول برای یافتن بردار ضرایب این است که آنها را به گونه ای انتخاب کنیم تا واریانس $\hat{X}(n)$ کمینه شود. کمترین مقدار واریانس $\hat{X}(n)$ را می‌توان به صورت معادله (۲) نمایش داد.

$$\text{var}(\hat{X}_n)_{\min} = \frac{1}{L_p'(w)R_p^{-1}L_p(w)} \quad (2)$$

در معادله (۲) $L_p(w) = (1, e^{jw}, \dots, e^{ipw})'$ و $R_p = E(X_n X_n')$ می‌باشد که با بهره‌گیری از این روش برآورد تابع چگالی طیف توان برای پنجره‌های یک ثانیه ای انجام شد.

محرك مانند الكل يا قهوه خودداری کنند. شرکت کنندگان افراد توانا و دارای خواب معمولی بودند. قبل از آزمایش، شرکت کنندگان به مدت ۵ دقیقه کار رانندگی را تمرین کردند تا با روش‌ها و اهداف آزمایش آشنا شوند. تمام مراحل آزمایش با یک شبیه‌ساز رانندگی ساکن در یک آزمایشگاه کنترل شده انجام شد. کار رانندگی از ساعت ۹ صبح و در یک بزرگراه کم تراکم بود. پس از ۵ دقیقه جلسه تمرینی، به شرکت کنندگان ۱۰ دقیقه استراحت داده شد تا از محیط شبیه‌ساز فاصله بگیرند و سپس بعد از بررسی سریع تمام ابزارالات حدود ۲-۱ ساعت شروع به رانندگی کردند.

ضبط داده‌های EEG در دو مرحله انجام شد. نخست، پس از گذشت ۲۰ دقیقه از رانندگی، ۵ دقیقه آخر سیگنال‌های EEG ضبط و به عنوان حالت عادی برچسب گذاری شد. در مرحله دوم، پس از گذشت ۱۰۰-۴۰ دقیقه از رانندگی با توجه به مقیاس خستگی چالدر [۱۰] و مقیاس خستگی موضعی لی [۱۱] که به صورت پرسش‌نامه در اختیار شرکت کنندگان قرار گرفته بود، خستگی راننده ارزیابی شد و ۵ دقیقه آخر از سیگنال‌های EEG ضبط و به عنوان حالت خستگی برچسب گذاری شد.

جهت ثبت سیگنال‌ها از یک کلاه الکتروود ۳۲ کانال (شامل ۳۰ کانال مؤثر و ۲ کانال مرجع) استفاده شد که مکان الکتروودها بر اساس سیستم بین المللی ۱۰-۲۰ تنظیم و سیگنال‌ها با فرکانس نمونه برداری ۱۰۰۰ هرتز توسط دستگاه دیجیتال شدند و در یک کامپیوتر جهت پردازش آفلاین ذخیره شدند. سیگنال‌های پیوسته ثبت شده در هر دو دسته هوشیاری و خستگی به پنجره‌های زمانی یک ثانیه ای تقسیم شده و تمام فرآیند تشخیص خستگی در سیستم پیشنهادی بر روی پنجره‌ها ارزیابی شده است.

۲-۲- پیش پردازش

عمل پیش پردازش جهت حذف نویز پلک زدن و نویزهای دیگر همچون نویز ماهیچه‌ای به وسیله جعبه ابزار $FORCE^1$ [۱۲] صورت پذیرفته است. این جعبه ابزار ضرایب موجکی که از تجزیه سیگنال EEG بدست می‌آید را از طریق آنالیز مولفه‌های مستقل (ICA)^۲ به مولفه‌های مستقل تجزیه می‌کند. سپس اجزای سازنده از طریق ترکیبی از آستانه نرم و سخت تغییر یا حذف می‌شوند که این آستانه‌ها قبلاً در سایر مجموعه داده‌های مستقل دیگر آموزش داده شده‌اند. پس از انجام مراحل پیش‌پردازش، فرکانس نمونه برداری به

³ Periodogram

⁴ Capon

¹ Fully online and automated artifact removal for brain-computer interfacing

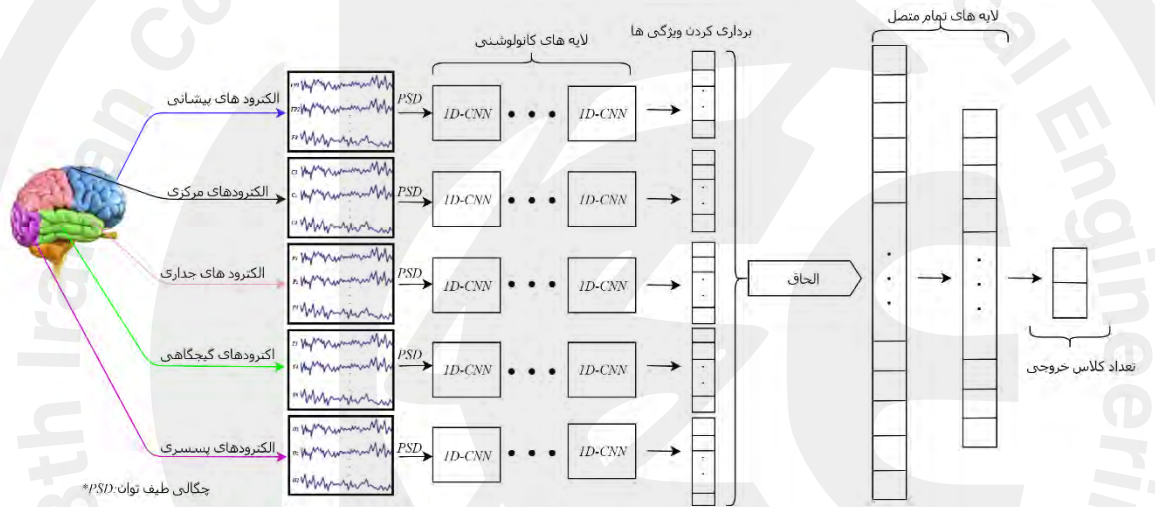
² Independent Component Analysis

۲-۴- شبکه عصبی کانولوشنی

سیستم خودکار پیشنهادی برای تشخیص خستگی با استفاده از سیگنال‌های EEG در شکل ۱ نشان داده شده است. این سیستم از سه قسمت مهم تشکیل شده است. در قسمت اول سیگنال‌های EEG هر لوب مغز جدا می‌شوند. در قسمت دوم چگالی طیف توان هر کانال از سیگنال توسط مدل خودبازگشتی با کم‌ترین واریانس برآورد می‌شود. در قسمت آخر سیگنال‌های ویژگی توسط مدل شبکه عصبی عمیق یک بعدی طبقه‌بندی می‌شوند. مولفه اصلی سیستم، مدل شبکه عصبی عمیق یک بعدی است که از سه نوع لایه کانولوشنی، کاهش اندازه و تمام متصل تشکیل شده است.

۲-۵- ارزیابی کارایی

برای بررسی کارایی الگوریتم خودکار پیشنهادی کلاس‌بندی سیگنال‌های EEG به دو حالت هوشیار و خسته از معیارهای دقت، حساسیت، و تشخیص بهره برده‌ایم. توانایی یک سیستم در تشخیص صحیح موارد خسته و هوشیار دقت نامیده می‌شود. برای محاسبه دقت باید نسبت مجموع موارد مثبت حقیقی و منفی حقیقی را به کل موارد آزمون شده بدست آورد. توانایی یک آزمون برای پیدا کردن موارد خستگی را حساسیت و توانایی آن برای پیدا کردن موارد هوشیار را تشخیص می‌گویند. مثبت حقیقی مواردی است که به وسیله سیستم به درستی خسته و مثبت کاذب مواردی است که به اشتباه هوشیار



شکل ۱: دیاگرام بلوکی الگوریتم خودکار پیشنهادی بر مبنای شبکه‌های عصبی کانولوشنی چند جریانه جهت تشخیص خستگی با استفاده از سیگنال‌های EEG

تشخیص داده شده‌اند. منفی حقیقی مواردی که به‌وسیله داده ارزیابی به درستی هوشیار و منفی کاذب مواردی که به وسیله داده ارزیابی به اشتباه خسته تشخیص داده شده‌اند. روش محاسبه دقت و حساسیت و تشخیص در معادلات (۳) و (۴) و (۵) آمده است.

$$\text{دقت} = \frac{\text{مثبت حقیقی} + \text{منفی حقیقی}}{\text{مثبت و منفی کاذب و حقیقی}} \quad (۲)$$

$$\text{حساسیت} = \frac{\text{مثبت حقیقی}}{\text{منفی کاذب} + \text{مثبت حقیقی}} \quad (۴)$$

$$\text{تشخیص} = \frac{\text{منفی حقیقی}}{\text{منفی حقیقی} + \text{مثبت کاذب}} \quad (۵)$$

یک مدل شبکه عصبی عمیق ساختار ویژگی‌های سیگنال‌های EEG را به طور خودکار می‌آموزد و طبقه‌بندی را بر این اساس انجام می‌دهد [۱۷] و [۱۸]. از آنجا که سیگنال EEG سری زمانی یک بعدی است برای طبقه‌بندی آن از شبکه عصبی عمیق یک بعدی بهره برده ایم. لایه‌های کانولوشن و تمام متصل یک سلسله مراتب از ویژگی‌های سطح پایین تا بالا را از سیگنال ورودی داده شده که برآورد چگالی طیف توان سیگنال اصلی هستند، می‌آموزند. ویژگی‌های سطح بالا با بازنمایی معنایی پس از فرآیند برداری کردن الحاق شده و به عنوان ورودی به لایه تمام متصل اعمال می‌شود. خروجی لایه تمام متصل آخر با بهره‌گیری از تابع *softmax* به برداری از احتمالات تبدیل شده تا کلاس مربوط به سیگنال EEG ورودی را پیش بینی کنند. در لایه‌های کانولوشن و تمام متصل از تابع فعالسازی *ReLU* استفاده شده است.

است، روش پیشنهادی این مقاله عملکرد بهتری در تشخیص خستگی در هنگام رانندگی دارد.

۳- نتایج

۳-۱- تعیین مرتبه مدل خودبازگشتی

جدول ۲: مقایسه دقت سیستم پیشنهادی به ازاء طبقه‌بندی‌های مختلف

طبقه بندی کننده	دقت (%)
K نزدیک ترین همسایه ^۱ [۹]	۸۹/۹۶
ماشین بردار پشتیبان (خطی) ^۲ [۱۹]	۷۸/۱۰
ماشین بردار پشتیبان (غیرخطی) ^۳ [۹]	۸۲/۳۲
جنگل تصادفی ^۴ [۹]	۸۷/۶۰
آنالیز تشخیصی خطی ^۵ [۲۰]	۷۸/۲۷
پرسپترون چند لایه ^۶ [۲۱]	۹۲/۰۴
روش پیشنهادی	۹۳/۴۹

علاوه بر این جهت بررسی تاثیر نواحی مغزی با هدف داشتن کمترین تعداد الکتروود جهت تشخیص خستگی یک شبکه کانولوشنی عمیق تک جریانه^۷ طراحی شده است. این شبکه متشکل از سه لایه کانولوشنی و دو لایه تمام متصل می‌باشد که در این قسمت ویژگی‌های استخراج شده از الکتروودهای هر ناحیه به صورت جداگانه به شبکه اعمال می‌شود. نتایج حاصل از دقت، حساسیت و تشخیص بدست آمده از هر کدام از نواحی در جدول ۳ آمده است.

جدول ۳: مقایسه دقت الکتروودهای لوب‌های مختلف مغز

کانال‌ها	دقت (%)	تشخیص (%)	حساسیت (%)
کل الکتروودها	۹۳/۴۹	۹۵/۶۹	۹۰/۹۲
ناحیه پیشانی	۸۱/۸۸	۸۳/۶۱	۸۰/۰۴
ناحیه مرکزی	۷۰/۹۸	۶۹/۲۰	۷۲/۴۱
ناحیه جداری	۷۴/۴۴	۸۰/۷۲	۶۷/۷۷
ناحیه پسری	۸۲/۰۶	۸۴/۶۴	۷۹/۳۰
ناحیه گیجگاهی	۸۲/۱۴	۸۶/۳۴	۷۷/۶۸

۴- نتیجه گیری

در این مقاله روش جدیدی برای تشخیص خستگی توسط

مسئله اصلی در برآورد چگالی طیف توان، انتخاب مرتبه مناسب برای مدل خودبازگشتی می‌باشد. در جهت رفع این مسئله، دقت سیستم با تغییر پارامترها بر روی داده ارزیابی مورد بررسی قرار گرفته و با توجه به نتایج مرتبه ۴ به عنوان حالت بهینه انتخاب شده است. نتایج دقت سیستم با تغییر مرتبه‌ها در جدول ۱ آمده است.

جدول ۱: مقایسه مرتبه مناسب برای برآورد چگالی طیف توان

مرتبه	دقت (%)
۳	۹۲/۵۲
۴	۹۳/۴۹
۵	۹۲/۷۰
۶	۹۲/۹۶
۸	۹۰/۶۸

۳-۲- ارزیابی عددی

اکثر مطالعات در تشخیص خستگی حین رانندگی، از یادگیری ماشینی برای طبقه‌بندی اطلاعات استفاده کرده‌اند. اخیراً، در دسترس بودن مجموعه‌های بزرگ داده EEG و پیشرفت در یادگیری ماشینی، هر دو به استقرار معماری یادگیری عمیق منجر شده‌اند. به ویژه در تجزیه و تحلیل سیگنال‌های EEG و درک اطلاعاتی که ممکن است برای عملکرد مغز داشته باشد، طبقه‌بندی خودکار قوی این سیگنال‌ها یک گام مهم در جهت عملی‌تر کردن کاربرد EEG است. به منظور مقایسه عملکرد شبکه عمیق طراحی شده با روش‌های متداول یادگیری ماشینی که در مقالات مختلف مورد استفاده قرار گرفته‌اند، دقت سیستم پیشنهادی جدید با سیستم‌های تشخیص خستگی آرایه شده تا کنون در جدول ۲ مورد مقایسه قرار گرفته‌اند. پارامترهای انتخاب شده برای هر روش برابر با پارامترهای تعیین شده در مقالات مرجع می‌باشد.

در این مقاله، جهت ارزیابی سیستم پیشنهادی ابتدا ۲۰٪ از بازه‌های پنج دقیقه‌ای برای تست و ۸۰٪ آنها برای آموزش جدا شده‌اند. ویژگی‌ها می‌توان محاسبه شده در حوزه فرکانس به‌عنوان ورودی طبقه‌بند استفاده شده است. همانطور که در جدول نشان داده شده

⁵ Linear Discriminant Analysis

⁶ Multilayer perceptron

⁷ Single stream deep convolutional network

¹ K-Nearest Neighbor

² Support vector machine (linear)

³ Support vector machine (non-linear)

⁴ Random forest

[21] R. Jabbar, K. Al-Khalifa, M. Kharbeche, W. Alhajyaseen, M. Jafari, and S. Jiang, "Real-time Driver Drowsiness Detection for Android Application Using Deep Neural Networks Techniques," *Procedia Computer Science*, vol. 130, pp. 400-407, Jan. 2018, doi: 10.1016/j.procs.2018.04.060.

سیگنال‌های EEG با استفاده از یک شبکه عصبی عمیق ارائه شده است. برای مقایسه، ویژگی‌های استخراج شده با طبقه‌بندهای پیشنهادی مختلف طبقه‌بندی شده‌اند و نتایج نشان می‌دهد که الگوریتم پیشنهادی از دقت بالاتری در مقایسه با الگوریتم‌های یادگیری ماشینی برخوردار است.

۵- مراجع

- [1] R. Fu and H. Wang, "Detection of driving fatigue by using noncontact EMG and ECG signals measurement system," *Int J Neural Syst*, vol. 24, no. 3, p. 1450006, May 2014, doi: 10.1142/S0129065714500063.
- [2] J.-X. Ma, L.-C. Shi, and B.-L. Lu, "An EOG-based Vigilance Estimation Method Applied for Driver Fatigue Detection," 2015, doi: 10.2174/2213385202666141218104855.
- [3] H. Wang, "Detection and Alleviation of Driving Fatigue Based on EMG and EMS/EEG Using Wearable Sensor," *EAI Endorsed Transactions on Smart Cities*, vol. 1, no. 2, pp. 155-157, Dec. 2015.
- [4] J. Jo, S. J. Lee, K. R. Park, I.-J. Kim, and J. Kim, "Detecting driver drowsiness using feature-level fusion and user-specific classification," *Expert Systems with Applications*, vol. 41, no. 4, Part 1, pp. 1139-1152, Mar. 2014, doi: 10.1016/j.eswa.2013.07.108.
- [5] K. He, X. Zhang, S. Ren, and H. Shabani, M. Mikaili, and S. M. R. Noori, "Assessment of recurrence quantification analysis (RQA) of EEG for development of a novel drowsiness detection system," *Biomed. Eng. Lett.*, vol. 6, pp. 196-204, 2016.
- [6] G. Li, B.-L. Lee, and W.-Y. Chung, "Smartwatch-based wearable EEG system for driver drowsiness detection," *IEEE Sensors J.*, vol. 15, no. 12, pp. 7169-7180, Dec. 2015.
- [7] J. Sun, "Deep Residual Learning for Image Recognition," *arXiv:1512.03385 [cs]*, Dec. 2015.
- [8] J. Long, E. Shelhamer, and T. Darrell, "Fully convolutional networks for semantic segmentation," in *2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2015, pp. 3431-3440, doi: 10.1109/CVPR.2015.7298965.
- [9] J. Min, P. Wang, and J. Hu, "Driver fatigue detection through multiple entropy fusion analysis in an EEG-based system," *PLoS ONE*, vol. 12, no. 12, p. e0188756, 2017, doi: 10.1371/journal.pone.0188756.
- [10] K. A. Lee, G. Hicks, and G. Nino-Murcia, "Validity and reliability of a scale to assess fatigue," *Psychiatry Res*, vol. 36, no. 3, pp. 291-298, Mar. 1991, doi: 10.1016/0165-1781(91)90027-m.
- [11] G. Borg, "Psychophysical scaling with applications in physical work and the perception of exertion," *Scand J Work Environ Health*, vol. 16 Suppl 1, pp. 55-58, 1990, doi: 10.5271/sjweh.1815.
- [12] I. Daly, R. Scherer, M. Billinger, and G. Müller-Putz, "FORCE: Fully Online and Automated Artifact Removal for Brain-Computer Interfacing," *IEEE Trans Neural Syst Rehabil Eng*, vol. 23, no. 5, pp. 725-736, Sep. 2015, doi: 10.1109/TNSRE.2014.2346621.
- [13] D. R. Brillinger, *Time Series: Data Analysis as a Theory*. Holden-Day, 1981.
- [14] P. J. Brockwell, *Time Series: Theory and Methods*, 2nd ed. 1991. 2nd printing 2009. Softcover reprint of the original 2nd ed. 1991 edition. New York, NY: Springer, 2009.
- [15] M. B. Priestley, *Spectral analysis and time series*. London ; New York: Academic Press, 1981.
- [16] J. Capon, "High Resolution Frequency-Wave Number Spectrum Analysis," *Proc. IEEE*, 57, 1408-1418, 1969.
- [17] Y. Lecun, L. Bottou, Y. Bengio, and P. Haffner, "Gradient-based learning applied to document recognition," *Proceedings of the IEEE*, vol. 86, no. 11, pp. 2278-2324, Nov. 1998, doi: 10.1109/5.726791.
- [18] K. Simonyan and A. Zisserman, "Very Deep Convolutional Networks for Large-Scale Image Recognition," *arXiv:1409.1556 [cs]*, Apr. 2015.
- [19] M. V. M. Yeo, X. Li, K. Shen, and E. P. V. Wilder-Smith, "Can SVM be used for automatic EEG detection of drowsiness during car driving?," *Safety Science*, vol. 47, no. 1, pp. 115-124, Jan. 2009, doi: 10.1016/j.ssci.2008.01.007.
- [20] G. B. Huang, "What are extreme learning machines? Filling the gap between Frank Rosenblatt's dream and John von Neumann's puzzle," *Cognit. Comput.*, vol. 7, no. 3, pp. 263-278, 2015.