

بهره‌گیری از بیان تنک به منظور کلاس‌بندی مراحل خواب با استفاده از سیگنال الکتروانسفالوگرام

بهاره آزادیان^۱، کارشناس ارشد؛ توحید یوسفی رضایی^۲، استادیار؛ سعید مشگینی^۳، استادیار

۱- گروه مهندسی پزشکی - دانشکده مهندسی برق و کامپیوتر - دانشگاه تبریز - تبریز - ایران - bahareh.azadian94@ms.tabrizu.ac.ir

۲- گروه مهندسی پزشکی - دانشکده مهندسی برق و کامپیوتر - دانشگاه تبریز - تبریز - ایران - yousefi@tabrizu.ac.ir

۳- گروه مهندسی پزشکی - دانشکده مهندسی برق و کامپیوتر - دانشگاه تبریز - تبریز - ایران - meshgini@tabrizu.ac.ir

چکیده: در این مقاله، از بیان تنک سیگنال EEG به منظور طبقه‌بندی مراحل خواب استفاده شده است. در این راستا دو روند کلی تنک‌سازی پیشنهاد شده و تاثیر آن‌ها بر روند تشخیص مراحل چهارگانه خواب بررسی شده است. روش پیشنهادی اول مبتنی بر به‌کارگیری روش تحلیل مولفه اصلی تنک (SPCA) برای حالت‌های به‌کارگیری ویژگی‌های مختلف، از جمله زمانی، فرکانسی و زمان-فرکانسی و اعمال به کلاس‌بندی ماشین بردار پشتیبان (SVM) است. روش پیشنهادی دوم بر اساس به‌کارگیری طبقه‌بندی‌کننده مبتنی بر بیان تنک (SRC) است که از الگوریتم پیگیری تطبیق متعامد (OMP) در مرحله ایجاد دیکشنری و بیان تنک بهره می‌برد. به منظور ارزیابی کارایی الگوریتم‌های پیشنهادی، عملکرد آن‌ها با الگوریتم‌های موجود مشابه مقایسه شده است و بدین منظور از داده‌های ثبت شده در پایگاه داده بین‌المللی PhysioNet استفاده شده است. مقایسه نتایج روش‌های پیشنهادی نشان دهنده بالاتر بودن دقت میانگین روش پیشنهادی اول نسبت به روش PCA و روش یادگیری عمیق به ترتیب ۸/۳۶٪ و ۸/۲۶٪ است. همچنین سرعت اجرای روش پیشنهادی دوم نسبت به دو روش مذکور ۱۱۸٪ و ۷۲٪ بالاتر است.

واژه‌های کلیدی: کلاس‌بندی خواب، حسگری فشرده، تنک‌سازی، سیگنال الکتروانسفالوگرام.

Exploiting Sparse Representation for Sleep Stage Classification Using Electroencephalogram Signal

B. Azadian¹, MSc; T. Yousefi Rezaii², Assistant Professor; S. Meshgini³, Assistant Professor

1- Department of Biomedical Engineering, Faculty of Electrical and Computer Engineering, University of Tabriz, Tabriz, Iran, Email: bahareh.azadian94@ms.tabrizu.ac.ir

2- Department of Biomedical Engineering, Faculty of Electrical and Computer Engineering, University of Tabriz, Tabriz, Iran, Email: yousefi@tabrizu.ac.ir

3- Department of Biomedical Engineering, Faculty of Electrical and Computer Engineering, University of Tabriz, Tabriz, Iran, Email: meshgini@tabrizu.ac.ir

Abstract: In this paper, sparse representation of EEG signal is used to automatically classify sleep stages. In this regard, two general sparse representation trends are proposed to classify 4-class sleep stages. The first proposed method is based on sparse principal component analysis (SPCA) which uses different features including time, frequency, and time-frequency features applied to support vector machine (SVM) classifier. The second proposed method is based on sparse representation-based classifier (SRC) which uses orthogonal matching pursuit (OMP) algorithm to obtain sparse coding of the EEG signal. In order to evaluate the effectiveness of the proposed algorithms, their performance is compared with the conventional SVM classification based on PCA method using time, frequency, and time-frequency features. The study is carried out on EEG signal from Physionet international database. Simulation results show on the average 8.36% and 8.26% improvement of the first proposed method in terms of classification accuracy compared to the PCA and deep learning methods, respectively, while the second proposed method has achieved the running time of 118% and 72% faster than the existing PCA and deep learning methods, respectively.

Keywords: Sleep classification, compressed sensing (CS), sparse, electroencephalogram (EEG) signal.

تاریخ ارسال مقاله: ۱۳۹۸/۰۱/۱۷

تاریخ اصلاح مقاله: ۱۳۹۸/۰۲/۱۲

تاریخ پذیرش مقاله: ۱۳۹۸/۰۲/۲۵

نام نویسنده مسئول: توحید یوسفی رضایی

نشانی نویسنده مسئول: ایران - تبریز - بلوار ۲۹ بهمن - دانشگاه تبریز - دانشکده مهندسی برق و کامپیوتر.

۱- مقدمه

ناهنجاری‌های خواب از جمله مهم‌ترین دغدغه‌هایی است که مردم با آن مواجه می‌شوند. خواب نه تنها به بهبود عملکرد بدن کمک می‌کند، بلکه به صورت ناخودآگاه اطلاعات موجود در حافظه را سازماندهی کرده و یادگیری روزانه را تحکیم می‌بخشد. کمبود خواب مواردی چون سردرد، افسردگی، آلزایمر، دیابت، بیماری‌های قلبی و... را در پی دارد و همچنین باعث کاهش طول عمر می‌شود.

خواب متشکل از دو مرحله فیزیولوژیک تحت عنوان مرحله NON-REM^۱ و REM^۲ می‌باشد. مرحله NON-REM (مرحله بدون حرکات سریع چشم) خود از ۴ مرحله (مراحل ۱ تا ۴) تشکیل شده است. از مرحله REM یا همان خواب عمیق که با حرکات سریع چشم همراه است، به عنوان مرحله ۵ خواب یاد می‌شود. مرحله بیداری نیز در مرحله ۶ از طبقه‌بندی مراحل خواب قرار می‌گیرد [۱-۳].

از طبقه‌بندی مراحل خواب با استفاده از سیگنال‌های زیستی می‌توان در تشخیص و درمان انواع بیماری‌ها استفاده کرد. تحلیل اطلاعات ثبت شده در زمان خواب به وسیله متخصصین خواب به صورت شهودی انجام می‌شود. طبقه‌بندی شهودی مراحل خواب به دلیل طولانی بودن ثبت‌ها، کار زمان‌بر و خسته کننده‌ای است، بنابراین جهت بهبود تشخیص مراحل خواب از روش‌های خودکار استفاده می‌شود [۴، ۵]. در [۴] نتایج حاصل از آنالیز اتوماتیک کلاس‌بندی مراحل خواب با روش بصری آن مقایسه شده است. مقایسه سیستم کلاس‌بندی اتوماتیک، با تشخیص متخصص، به طور میانگین میزان تطابق ۸۲/۳٪ را در پی دارد و با افزودن نظارت متخصص بر دوره‌های زمانی، از ۸۲/۳٪ به ۹۰٪ افزایش یافته است.

کلاس‌بندی اتوماتیک مراحل خواب با استفاده از سیگنال EEG، یک ابزار مهم کمی را برای کمک به متخصصان مغز و اعصاب و متخصصان خواب در تشخیص و نظارت بر اختلالات خواب و نیز ارزیابی اثربخشی درمان فراهم می‌کند. یک بازرسی بصری کامل از ثبت سیگنال EEG در طول پلی‌سومنوگرافی^۲ شبانه وقت‌گیر، گران و اغلب غیر معقول به نظر می‌آید. بنابراین، استخراج ویژگی به عنوان یک گام ضروری در پردازش سیگنال، برای به‌دست آوردن داده کاهش یافته و دارای اطلاعات مفید برای کلاس‌بندی خودکار مراحل خواب به کار برده می‌شود [۶-۹].

سیگنال الکتروانسفالوگرام (EEG^۳) به صورت گسترده برای طبقه‌بندی خودکار مراحل خواب مورد استفاده قرار می‌گیرد. این سیگنال زیستی در صورت ثبت چندین کاناله به صورت بلند مدت دارای حجم بسیار زیادی است، بنابراین استفاده از روش‌های کاهش ابعاد جهت کلاس‌بندی آن امری ضروری است. در سال‌های اخیر نظریه نمایش تنک^۴ سیگنال روشی موثر را جهت کاهش ابعاد داده ارائه داده است. در [۱۰] یک نمایش تنک از سیگنال‌های یک بعدی براساس آنالیز زمان-فرکانسی با استفاده از روش RDSTFT^۵ پیشنهاد شده است.

در [۱۱، ۱۲] از روش PCA جهت کاهش ابعاد سیگنال EEG استفاده شده است. [۱۲] از ۵ ویژگی زمانی شامل میانگین، انحراف استاندارد، فعالیت^۶، تحرک^۷ و پیچیدگی^۸ و ۱۱ ویژگی فرکانسی شامل طیف نسبی انرژی^۹ برای ۷ بازه فرکانسی، فرکانس مرکزی، پهنای باند، توان فرکانس مرکزی و لبه طیف فرکانسی برای تشخیص مراحل خواب مبتنی بر کلاس‌بندی نوع SVM و تحلیل PCA بهره گرفته است. در این مرجع حالت‌های مختلف به کارگیری ویژگی‌های زمانی، فرکانسی و زمان - فرکانسی بررسی و مقایسه شده است.

در [۱۳] روش یادگیری ماشین برای کلاس‌بندی اتوماتیک مراحل خواب با استفاده از EEG تک کاناله پیشنهاد و ارزیابی شده است. اساس این روش بر مبنای تجزیه و تحلیل زمان-فرکانسی و انکودر^{۱۰}های اتوماتیک تنک می‌باشد. با استفاده از تابع کرنل^{۱۱} SVM می‌تواند مرزها را با استفاده از ابرصفحه‌ها^{۱۲} در فضای ویژگی غیرخطی در ابعاد بالا یافته و بیشترین حاشیه‌های ابرصفحه‌ای را که می‌تواند به عنوان مرز خطی داده‌های آموزشی نشان دهد، تعیین کند [۱۴، ۱۵].

اجتناب از حوادث مرگبار ناشی از سطح پایین هوشیاری در رانندگی در زندگی روزمره افراد بسیار حائز اهمیت است. در [۱۶] یک روش پردازش سیگنال EEG برای تشخیص سطح هوشیاری با استفاده از باندهای فرکانسی در سه کلاس هوشیار، خواب‌آلود و خواب در محیط شبیه‌سازی شده رانندگی ارائه شده است. در مرحله اول، از هر باند فرکانسی در هر کانال EEG ویژگی استخراج شده، سپس از SRC برای طبقه‌بندی کلاس‌های هوشیاری استفاده می‌شود. این آزمایش حدود ۹۰٪ دقت متوسط با رزولوشن زمانی ۵ ثانیه برای پنج نفر نتیجه داشته است. در [۱۷] ثبت سیگنال‌های الکتروانسفالوگرام به صورت چندکاناله برای تشخیص مرحله بیداری و مرحله ۱ خواب جهت تشخیص مواردی چون آپنه و دیگر ناهنجاری‌های خواب با بهره‌گیری از روش ماشین بردار پشتیبان با دقت ۹۲/۵٪ صورت گرفته است.

آموزش ویژگی غیرنظارتی و آموزش عمیق، روش‌هایی برای آموزش ماتریس‌های وزنی در هر لایه در یک روش غیرنظارتی قبل از آموزش کل شبکه، به عنوان مرحله پیش‌پردازش در نظر گرفته می‌شود. این روش یک سبک جدید برای کلاس‌بندی مراحل خواب ارائه می‌دهد که در آن تمرکز اصلی آموزش نمایش ویژگی‌های معنی‌دار از داده خواب برچسب نشده است [۱۸-۲۱]. در [۲۲] یک روش کلاس‌بندی مراحل خواب با ترکیبی از یک شبکه SDB^{۱۳} و ترکیبی از طبقه‌بندی‌کننده‌های چندگانه برای سیگنال‌های الکتروانسفالوگرام، الکترواکولوگرام و الکترومایوگرام ارائه داده شده است. نتایج حاکی از آن است که شبکه SDB، یک روش استخراج ویژگی کارا برای داده‌های خواب بوده که دقت کل طبقه‌بندی مراحل خواب به وسیله آن ۹۱/۳۱٪ بدست آمده است.

در این مقاله، به دلیل نزدیک بودن ویژگی‌های تعدادی از مراحل خواب در حالت ۶ مرحله‌ای، با ادغام مراحل ۳ و ۴ همچنین مراحل ۱ و ۶، به بررسی و تحلیل مراحل خواب در ۴ مرحله پرداخته شده است.


هدف حذف نویزهای سیگنال مورد مطالعه، از فیلترهای مختلف استفاده می‌شود و نیز پنجره‌بندی سیگنال به دوره‌های زمانی با تعداد نمونه‌های مشخص صورت می‌گیرد، در مرحله استخراج ویژگی به دلیل بلند مدت بودن سیگنال‌های ثبت شده با مشخص کردن مهم‌ترین ویژگی‌های متمایزکننده سیگنال، به استخراج ویژگی‌های سیگنال پرداخته می‌شود تا بتوان در مرحله سوم به کلاس‌بندی مراحل مختلف خواب پرداخت.

در ادامه روند کلی روش‌های پیشنهادی به تفکیک شرح داده شده است.

۲-۱- روش بر پایه SPCA

شکل ۱ فلوچارت روش طبقه‌بندی پیشنهادی مراحل خواب با کلاس‌بندی نوع SVM براساس تحلیل SPCA را نشان می‌دهد. در این روش ابتدا داده‌های سیگنال EEG نمونه‌برداری شده با فرکانس ۱۰۰ هرتز، از فیلتر میان‌گذر دیجیتال مرتبه ۶ با باند گذر بین ۰/۵ تا ۴۵ هرتز برای حذف نوسانات و نویز عبور داده می‌شود. در گام بعد داده‌های ورودی به پنجره‌هایی متشکل از ۳۰۰۰ نمونه تقسیم‌بندی شده، سپس استخراج ویژگی برای هر پنجره به صورت مجزا در یکی از سه حوزه زمان، فرکانس یا زمان-فرکانس انجام می‌شود.

ویژگی‌های زمانی شامل میانگین، انحراف استاندارد، فعالیت، تحرک و پیچیدگی، ویژگی‌های فرکانسی شامل طیف نسبی انرژی برای ۷ بازه فرکانسی، فرکانس مرکزی، پهنای باند، توان فرکانس مرکزی و لبه طیف فرکانسی و ویژگی‌های زمان-فرکانسی که ترکیبی از مجموع ویژگی‌های زمان و فرکانسی ذکر شده هستند، می‌باشند [۱۲].



شکل ۱: فلوچارت کلاس‌بندی مراحل خواب با کلاس‌بندی نوع SVM بر اساس تحلیل SPCA پیشنهادی

در مرحله آموزش از مولفه‌های اصلی اول و دوم خروجی تحلیل SPCA برای آموزش طبقه‌بندی SVM استفاده می‌شود. در این مرحله طبقه‌بندی کننده SVM نوع کرنل با استفاده از ۶۰٪ داده آموزش داده می‌شود. در مرحله آزمایش، خروجی تحلیل SPCA داده تست به طبقه‌بندی SVM آموزش داده شده برای تشخیص مراحل خواب اعمال می‌شود. در نهایت میزان دقت روش طبقه‌بندی بر اساس تفکیک مراحل ۴ گانه خواب محاسبه می‌گردد.

دلیل ادغام مراحل ۳ و ۴ را می‌توان مشخص نبودن مرز دقیق بین این دو مرحله برشمرد. مرحله ۳، دوره گذار بین خواب سبک و خواب بسیار عمیق است که در خلال آن امواج مغزی عمیق و کند با فرکانس کمتر از ۳/۵ هرتز به نام امواج دلتا شروع به پدیدار شدن می‌کنند این مرحله ۲۵ تا ۵۰ درصد از فعالیت دلتا را شامل می‌شود. مرحله ۴ نیز به دلیل تولید امواج دلتا به نام خواب دلتا خوانده می‌شود که بیش از ۵۰ درصد فعالیت دلتا را دارا است [۳]. دو الگوریتم مبتنی بر تنک-سازی داده بر مبنای نظریه حسگری فشرده برای تفکیک مراحل خواب در سیگنال EEG پیشنهاد شده و با روش موجود مبتنی بر مولفه اصلی (PCA^{۱۴}) و روش کلاس‌بندی با مدل مخفی مارکوف (HMM^{۱۵}) و یادگیری غیرنظارتی مقایسه شده است. روش اول بر اساس تنک‌سازی PCA یا SPCA^{۱۶} است. در این روش برای ایجاد مولفه‌های اصلی از ترکیب خطی تنها تعدادی از متغیرها استفاده می‌شود که تعداد آن به میزان تنک‌سازی تنظیمی وابسته است. برای روش پیشنهادی SPCA، طبقه‌بندی کننده SVM^{۱۷} پس از اعمال فیلتر و پنجره‌بندی و استخراج ویژگی‌های زمانی، فرکانسی و زمان-فرکانسی به داده اعمال می‌شود. که طبق مرجع [۱۲] از بین ویژگی‌های زمانی و فرکانسی سیگنال EEG از متمایزکننده‌ترین ویژگی‌ها جهت کلاس‌بندی مراحل مختلف خواب استفاده شده است. در این مطالعه از ۶۰ درصد کل داده برای آموزش و از ۴۰ درصد بقیه برای تست استفاده شده است.

در روش پیشنهادی دوم برای کلاس‌بندی مراحل خواب، از طبقه‌بندی کننده برپایه بیان تنک (SRC^{۱۸}) با بهره‌گیری از الگوریتم OMP^{۱۹} به منظور تنک‌سازی سیگنال استفاده شده است بدین صورت که الگوریتم OMP بیان تنک داده آموزش را بدست آورده و دیکشنری مورد استفاده برای آن را ذخیره می‌کند که در مرحله تست برای بیان تنک داده تست به کار می‌رود.

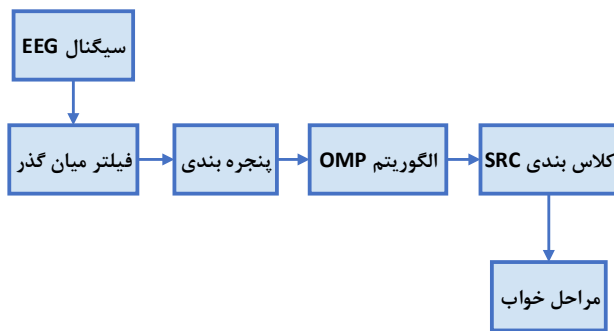
نوآوری‌های انجام شده در این پژوهش به شرح زیر است:

۱. به کارگیری تحلیل تنک‌سازی SPCA در کلاس‌بندی مراحل خواب با طبقه‌بندی کننده SVM در حالت‌های مختلف استفاده از ویژگی‌های زمانی، فرکانسی و زمان-فرکانسی سیگنال EEG مربوط به خواب
۲. استفاده از الگوریتم SRC بر پایه الگوریتم OMP برای ایجاد دیکشنری بیان تنک

در ادامه، ابتدا در بخش ۲ الگوریتم‌های پیشنهادی و جزئیات مربوط به آنها آورده شده است. در بخش ۳ پایگاه داده‌های مورد استفاده در شبیه‌سازی معرفی شده و در نهایت در بخش ۴ شبیه‌سازی و نتایج حاصل از کلاس‌بندی مراحل خواب برای الگوریتم‌های پیشنهادی شرح داده شده است.

۲- الگوریتم‌های پیشنهادی

طبقه‌بندی خودکار مراحل در ۳ مرحله اصلی پیش پردازش، استخراج ویژگی و کلاس‌بندی صورت می‌گیرد. در مرحله نخست با



شکل ۲: کلاس‌بندی مراحل خواب با کلاس‌بندی نوع SRC بر اساس الگوریتم OMP پیشنهادی

کلاس‌بندی با روش SRC شامل دو گام اصلی تنک‌سازی (آموزش) و تشخیص (تست) است. گام تنک‌سازی به‌صورت حل رابطه $y = Dx$ انجام می‌شود که y سیگنال مورد نظر (در اینجا سیگنال EEG) بوده، D ماتریس تنک‌سازی (دیکشنری) با ساختار $D = [D_{i,1}, D_{i,2}, \dots, D_{i,N_i}]$ است که C و $i = 1, 2, \dots, C$ تعداد کلاس‌های مورد نظر و N_i تعداد مولفه‌های آموزش برای کلاس i ام است. x بردار نامعلوم ضرایب تنک است. در این مقاله با توجه به در نظر گرفتن چهار مرحله برای خواب N_i برابر با ۴ است.

در گام تنک‌سازی، بردار ضرایب x با حل معادله بهینه‌سازی از طریق مینیمم‌سازی نرم یک بصورت زیر قابل بازیابی است:

$$\min_x \|x\|_1 \quad \text{subject to } y = Dx \quad (1)$$

در این مقاله از الگوریتم OMP به‌منظور حل مسئله بهینه‌سازی فوق استفاده شده که دارای حجم محاسباتی کمتر نسبت به دیگر روش‌های موجود است. با استفاده از بردار ضرایب x با مینیمم‌سازی نرم یک تشخیص کلاس‌ها به‌صورت زیر است:

$$\text{class}(y) = \min_i e_i(y) \quad (2)$$

که در رابطه فوق $e_i(y) = \|y - A_i x_i\|_2$ خطای بیان تنک کلاس i است. بنابراین، برچسب کلاس سیگنال تست y مرتبط با کمترین خطا تشخیص داده می‌شود.

۳- داده‌های مورد استفاده

به منظور ارزیابی عملکرد روش‌های پیشنهادی برای کلاس‌بندی مراحل خواب مبتنی بر نظریه حسگری فشرده از سیگنال EEG ۱۰ شخص بین سنین ۱۸ تا ۶۶ سال مطابق آرایش استاندارد ۲۰-۱۰ (با موقعیت Fpz-Cz1 و Pz-Oz برای الکترودها) با فرکانس نمونه‌برداری ۱۰۰ هرتز از پایگاه داده بین‌المللی بایگانی PhysioNet استفاده شده PhysioNet استفاده شده [۲۳] و شبیه‌سازی روش‌های پیشنهادی در نرم افزار MATLAB پیاده‌سازی شده است.

مراحل الگوریتم روش SPCA بر اساس حل مساله شبکه الاستیک در [۱۷] به‌صورت زیر است:

- ۱- با فرض $K < P$ که K تعداد بردارهای لودینگ اصلی تنک برای تخمین است،
- ۲- با فرض A ماتریسی $p \times K$ شامل K بردار لودینگ اصلی باشد،
- ۳- (شروع حلقه for) برای $k = 1, \dots, K$ انجام بده:
- ۴- (شروع حلقه while) مادامی که بردار لودینگ تنک β_k همگرا نشود انجام بده:
- ۵- (شروع if) اگر $\delta = \infty$ آنگاه:

$$\hat{\beta}_k = (|X^T X \alpha_k| - \lambda) + \text{sign}(X^T X \alpha_k) \quad \text{حل شود.}$$

۶- در غیر این صورت:

شبکه الاستیک برای مساله

$$\hat{\beta}_k = \arg \min_{\beta_k} \|X \alpha_k - X \beta_k\|^2 + \delta \|\beta_k\|^2 + \lambda \|\beta_k\|_1$$

۷- (پایان if)

$$\beta_k = \beta_k / \sqrt{\beta_k^T \beta_k} \quad \text{۸- نرمال سازی در واحد طول}$$

۹- به روزرسانی k امین ستون ماتریس نگاشت شده A به‌صورت

$$\alpha_k = (I - A_{(k-1)} A_{(k-1)}^T) X^T X \beta_k$$

$$\alpha_k = \alpha_k / \sqrt{\alpha_k^T \alpha_k} \quad \text{۱۰- نرمال سازی در واحد طول:}$$

۱۱- (پایان while)

۱۲- (پایان for)

$$B = [\beta_1 \dots \beta_K] \quad \text{۱۳- قرار دادن ضرایب}$$

در الگوریتم فوق X ماتریس داده با سایز $n \times p$ ، δ ضریب پنالتی لبه بر روی نرم دوم بردار لودینگ و α_k نگاشت ماتریس A است.

۲-۲ روش SRC مبتنی بر الگوریتم OMP

روش پیشنهادی دوم کلاس‌بندی مراحل خواب با استفاده از طبقه‌بندی نوع SRC مبتنی بر الگوریتم OMP است. در این روش مشابه روش قبلی، ابتدا داده‌های سیگنال EEG مورد مطالعه از فیلتر میان‌گذر برای حذف نوسانات و نویز عبور داده می‌شود. در گام بعد داده‌های ورودی پنجره‌بندی می‌شود. در این روش نیازی به استخراج ویژگی‌های سیگنال نیست و در مرحله آموزش برای هر یک از مراحل خواب توسط الگوریتم OMP دیکشنری ایجاد شده و ذخیره می‌گردد. در مرحله آزمایش داده تست به کلاس‌بندی SRC همراه با دیکشنری‌های ذخیره شده برای هر مرحله خواب برای تشخیص مراحل خواب اعمال می‌شود (شکل ۲). در نهایت میزان دقت روش طبقه‌بندی بر اساس تفکیک مراحل خواب محاسبه می‌گردد.

جدول ۱: اطلاعات ۱۰ شخص و سیگنال EEG ثبت شده مورد مطالعه [۲۳]


داده شخص	سن	جنس	تعداد دوره مرحله ۱	تعداد دوره مرحله ۲	تعداد دوره مرحله ۳	تعداد دوره مرحله ۴	تعداد دوره مرحله ۵	تعداد دوره مرحله ۶	تعداد کل دوره‌ها
ST7011-PSG	۶۰	مرد	۱۰۱	۵۲۹	۹۳	۴۳	۱۲۲	۲۰۵	۱۰۹۳
ST7022-PSG	۳۵	زن	۷۴	۳۵۳	۱۲۷	۱۵۷	۱۵۹	۷۵	۹۴۵
ST7041-PSG	۱۸	زن	۶۶	۵۳۶	۶۱	۷۱	۲۱۸	۵۶	۱۰۰۸
ST7052-PSG	۳۲	زن	۱۲۱	۳۹۶	۵۳	۱۲۷	۲۲۶	۱۱۲	۱۰۳۵
ST7061-PSG	۳۵	زن	۸۹	۵۸۹	۱۰	۰	۲۷۱	۵۰	۱۰۰۹
ST7082-PSG	۶۶	زن	۱۷۱	۴۵۰	۴۵	۰	۱۱۱	۱۵۵	۹۳۲
ST7101-PSG	۲۰	مرد	۷۲	۳۰۳	۱۷۹	۱۲۶	۲۳۱	۱۳۲	۱۰۴۳
ST7112-PSG	۲۱	زن	۳۷	۳۸۸	۶۴	۱۴۷	۲۹۳	۵۰	۹۷۹
ST7121-PSG	۲۱	مرد	۳۴	۴۵۲	۱۲۰	۸۳	۲۶۷	۷۱	۱۰۲۷
ST7151-PSG	۲۰	مرد	۷۸	۳۰۴	۱۴۲	۱۲۶	۱۴۳	۱۰۵	۸۹۸

روش‌های پیشنهادی و روش موجود مبتنی بر PCA به‌منظور مقایسه جامع نتایج برای ۱۰ شخص در پایگاه داده [۲۳] پیاده‌سازی و بررسی شده‌اند. پایگاه داده، هر سیگنال EEG را به صورت دوره‌های زمانی ۳۰ ثانیه‌ای در فرکانس نمونه‌برداری ۱۰۰ هرتز ارائه می‌دهد. جدول ۱ اطلاعات مربوط به این ۱۰ شخص و تعداد دوره‌های هر یک از مراحل خواب را برای هر شخص نمایش می‌دهد. سیگنال‌های مورد استفاده، پلی‌سومنوگراف‌هایی (PSG) شامل الکتروانسفالوگرام (EEG)، الکتروکول-سوگرام (EEG)، الکترومیوگرام (EMG) و الکتروکاردیوگرام (ECG) است، که در این مطالعه تنها سیگنال الکتروانسفالوگرام آن‌ها مورد بررسی قرار گرفته است که پس از ثبت، به فواصل زمانی ۳۰ ثانیه‌ای (دوره) تقسیم می‌شود.

در این مقاله نتایج مربوط به پیاده‌سازی روش‌های پیشنهادی کلاس‌بندی مراحل خواب برای یک نمونه سیگنال به تفصیل بیان شده و با روش موجود مبتنی بر تحلیل PCA و روش HMM مبتنی بر DBN^{۱۰} مقایسه شده است و در پایان نتایج مربوط به پیاده‌سازی روش‌های مذکور برای ۱۰ سیگنال EEG ارائه شده است. نمونه داده انتخاب شده برای مطالعه سیگنال ST7112-PSG بوده که مربوط به سنجش خواب از دور (ST^{۱۱}) یک زن سالم با ۲۱ سال سن برای حدود ساعت و ۱۶ دقیقه در شب دوم از ساعت ۹:۱۵ شب در سال ۱۹۹۴ ثبت شده که شامل ۹۷۹ دوره می‌باشد.

در این مقاله نتایج مربوط به پیاده‌سازی روش‌های پیشنهادی کلاس‌بندی مراحل خواب برای یک نمونه سیگنال به تفصیل بیان شده و با روش موجود مبتنی بر تحلیل PCA و روش HMM مبتنی بر DBN^{۱۰} مقایسه شده است و در پایان نتایج مربوط به پیاده‌سازی روش‌های مذکور برای ۱۰ سیگنال EEG ارائه شده است. نمونه داده انتخاب شده برای مطالعه سیگنال ST7112-PSG بوده که مربوط به سنجش خواب از دور (ST^{۱۱}) یک زن سالم با ۲۱ سال سن برای حدود ساعت و ۱۶ دقیقه در شب دوم از ساعت ۹:۱۵ شب در سال ۱۹۹۴ ثبت شده که شامل ۹۷۹ دوره می‌باشد.

در شکل ۳ دامنه سیگنال نمونه برداری شده EEG بر حسب زمان



شکل ۳: مراحل خواب سیگنال الکتروانسفالوگرام ST7112-PSG

۴- نتایج

به‌منظور ارزیابی عملکرد الگوریتم پیشنهادی طبق جدول ۲ از ۶۰٪ تعداد دوره‌های هر مرحله خواب برای آموزش کلاس‌بندی و از ۴۰٪ باقی به عنوان داده تست استفاده می‌شود. در ادامه نتایج حاصل از اعمال روش‌های PCA، SPCA، SRC و DBN در حوزه‌های مختلف زمانی، فرکانسی و زمان-فرکانسی بر روی داده ST7112-PSG به تفصیل بیان شده است.

جدول ۲: تعداد دوره‌های زمانی مراحل خواب داده ST7112-PSG برای

آموزش و تست در کلاس‌بندی

شماره مرحله	مرحله ۱ و ۶	مرحله ۲	مرحله ۳ و ۴	مرحله ۵
آموزش	۵۲	۲۳۲	۱۲۶	۱۷۵
تست	۳۵	۱۵۶	۸۵	۱۱۸
کل	۸۷	۳۸۸	۲۱۱	۲۹۳

باشد که الگوریتم موفق به تشخیص ۸۷ دوره زمانی از ۱۱۸ دوره شده است. طبق جدول، دقت کل در این روش ۸۶/۰۴٪ بدست آمده است.

۴-۱-۲- تحلیل فرکانسی

در تحلیل فرکانسی ویژگی‌های فرکانسی سیگنال EEG پس از عبور از فیلتر استخراج شده و در مرحله بعد با روندی مشابه حالت تحلیل زمانی، با استفاده از روش کاهش ابعاد PCA مولفه‌های اصلی بردار ویژگی برای مراحل مختلف خواب داده تست محاسبه می‌شود.

جدول ۵: ویژگی‌های فرکانسی به‌کار رفته در تحلیل

مراحل خواب

ویژگی شماره	ویژگی فرکانسی
۱	طیف نسبی انرژی باند دلتا ۱ (۲/۵ - ۰/۵ هرتز)
۲	طیف نسبی انرژی باند دلتا ۲ (۴ - ۲/۵ هرتز)
۳	طیف نسبی انرژی باند تتا ۱ (۶ - ۴ هرتز)
۴	طیف نسبی انرژی باند تتا ۲ (۸ - ۶ هرتز)
۵	طیف نسبی انرژی باند آلفا (۱۲ - ۸ هرتز)
۶	طیف نسبی انرژی باند بتا ۱ (۲۰ - ۱۲ هرتز)
۷	طیف نسبی انرژی باند بتا ۲ (۴۵ - ۲۰ هرتز)
۸	فرکانس مرکزی
۹	پهنای باند
۱۰	توان فرکانس مرکزی
۱۱	لبه طیف فرکانسی

در جدول ۵ ویژگی‌های فرکانسی به‌کار رفته در مقاله نشان داده شده است. بردار ویژگی در این حالت فرکانسی برای هر دوره یک بردار ۱۱ × ۱ است.

جدول ۶: نتایج کلاس‌بندی SVM مبتنی بر تحلیل PCA در حوزه

فرکانسی برای داده ST7112-PSG

شماره مرحله	مرحله ۱ و ۶	مرحله ۲	مرحله ۳ و ۴	مرحله ۵	دقت (%)
مرحله ۱ و ۶	۳۱	۰	۳	۱	۸۸/۵۷
مرحله ۲	۰	۱۴۳	۰	۱۳	۹۱/۶۷
مرحله ۳ و ۴	۴	۰	۸۱	۰	۹۵/۲۹
مرحله ۵	۰	۱۶	۵	۹۷	۸۲/۲۰
دقت کل (%): ۸۹/۳۴					واریانس دقت (%): ۳۰/۷۹

در جدول ۶ نتایج حاصل از روش PCA در حوزه فرکانسی آورده شده است. بالاترین دقت مربوط به مرحله مشترک ۳ و ۴ با نتیجه

۴-۱-۱- نتایج کلاس‌بندی روش SVM مبتنی بر تحلیل PCA برای

داده ST7112-PSG

در این بخش نتایج حاصل از کلاس‌بندی مراحل خواب با استفاده از روش SVM مبتنی بر تحلیل PCA در سه حوزه زمانی، فرکانسی و زمان-فرکانسی برای داده ST7112-PSG در حالی که از ۶۰٪ آن برای آموزش و از ۴۰٪ مابقی آن به عنوان داده تست استفاده شده، پس از پنجره‌بندی و اعمال فیلتر میان‌گذر ارائه و تشریح شده است.

۴-۱-۱- تحلیل زمانی

در تحلیل زمانی ویژگی‌های زمانی سیگنال EEG پس از عبور آن از فیلتر، استخراج شده سپس با استفاده از روش کاهش ابعاد PCA مولفه‌های اصلی بردار ویژگی برای مراحل مختلف خواب محاسبه می‌شود.

در جدول ۳ ویژگی‌های زمانی به‌کار رفته در مقاله نشان داده شده است. بردار ویژگی ایجاد شده در این حالت برای هر دوره یک بردار ۵ × ۱ است.

جدول ۳: ویژگی‌های زمانی

به‌کار رفته در تحلیل مراحل خواب

ویژگی شماره	ویژگی زمانی
۱	میانگین
۲	انحراف استاندارد
۳	فعالیت
۴	تحرک
۵	پیچیدگی

جدول ۴: نتایج کلاس‌بندی SVM مبتنی بر تحلیل PCA در حوزه

زمانی برای داده ST7112-PSG

شماره مرحله	مرحله ۱ و ۶	مرحله ۲	مرحله ۳ و ۴	مرحله ۵	دقت (%)
مرحله ۱ و ۶	۳۱	۰	۰	۴	۸۸/۵۷
مرحله ۲	۷	۱۵۴	۱	۳	۹۲/۹۵
مرحله ۳ و ۴	۰	۰	۷۶	۹	۸۹/۴۱
مرحله ۵	۳	۰	۲۸	۸۷	۷۳/۷۳
دقت کل (%): ۸۶/۰۴					واریانس دقت (%): ۷۲/۳۳

در جدول ۴ نتایج حاصل از روش PCA در حوزه زمانی بر روی داده‌های تست نشان داده شده است. بالاترین دقت مربوط به مرحله دوم خواب با دقت ۹۲/۹۵٪ و پایین‌ترین آن مربوط به مرحله ۵ خواب می‌-

است که با استفاده از این روش کلاس‌بندی درصد دقت کل حدود ۸۸/۰۷٪ می‌باشد.

جدول ۸: نتایج کلاس‌بندی SVM مبتنی بر تحلیل SPCA در حوزه

زمانی برای داده ST7112-PSG

شماره مرحله	مرحله ۱ و ۶	مرحله ۲	مرحله ۳ و ۴	مرحله ۵	دقت (%)
مرحله ۱ و ۶	۳۴	۱	۰	۰	۹۷/۱۴
مرحله ۲	۰	۱۵۲	۰	۴	۹۷/۴۳
مرحله ۳ و ۴	۹	۰	۷۶	۰	۸۹/۴۱
مرحله ۵	۰	۳۲	۰	۸۶	۷۲/۸۸
دقت کل (%): ۸۸/۳۲					واریانس دقت (%): ۱۳۲/۳۹

۴-۲-۲- تحلیل فرکانسی

در حوزه فرکانسی با استخراج ویژگی‌های فرکانسی و اعمال روش SPCA مولفه‌های اصلی بردار ویژگی با تنک‌سازی برای مراحل مختلف خواب محاسبه می‌شود.

جدول ۹: نتایج کلاس‌بندی SVM مبتنی بر ویژگی‌های فرکانسی و

تحلیل SPCA برای داده ST7112-PSG

شماره مرحله	مرحله ۱ و ۶	مرحله ۲	مرحله ۳ و ۴	مرحله ۵	دقت (%)
مرحله ۱ و ۶	۳۴	۰	۱	۰	۹۷/۱۴
مرحله ۲	۰	۱۵۶	۰	۰	۱۰۰/۰۰
مرحله ۳ و ۴	۳	۰	۸۲	۰	۹۶/۴۷
مرحله ۵	۰	۰	۰	۱۱۸	۱۰۰/۰۰
دقت کل (%): ۹۸/۹۸					واریانس دقت (%): ۳/۴۸

در جدول ۹ نتایج حاصل از ارزیابی روش کلاس‌بندی SVM در تحلیل فرکانسی SPCA به تفکیک برای هر یک از مراحل خواب مربوط به داده تست سیگنال EEG ارائه شده است. با توجه به نتایج مشخص است که درصد دقت کل کلاس‌بندی با این روش ۹۸/۹۸٪ است که نشان دهنده بالا بودن درصد دقت در تفکیک مراحل خواب می‌باشد. در این روش درصد دقت مراحل ۲ و ۵ کامل و برابر با ۱۰۰ بدست آمده است.

۴-۲-۳- تحلیل زمان - فرکانسی

در روش تحلیل SPCA با ویژگی‌های زمان-فرکانسی از ترکیب ویژگی‌های زمانی و فرکانسی برای ایجاد بردار ویژگی استفاده می‌شود. مشابه روش‌های قبل، در این حالت نیز بردار ویژگی ترکیبی ایجاد شده

۹۵/۲۹٪ بوده است. دقت کل در این روش ۸۹/۳۴٪ به دست آمده است.

۴-۱-۳- تحلیل زمان - فرکانسی

در تحلیل زمان-فرکانسی از ترکیب ویژگی‌های زمانی و فرکانسی برای ایجاد بردار ویژگی استفاده می‌شود که در این حالت بردار ویژگی ایجاد شده به‌صورت یک بردار 16×1 می‌باشد. مشابه روش‌های قبل، در این حالت نیز بردار ویژگی برای کاهش ابعاد به تحلیل PCA اعمال می‌شود تا مولفه‌های اصلی داده تست محاسبه شود. طبق جدول ۷ بالاترین درصد دقت در این روش مربوط به مرحله ۲ خواب با دقت ۱۰۰٪ بوده است، این در حالی است که دقت کل ۸۸/۵۸٪ محاسبه شده است که از دقت روش در تحلیل فرکانسی کمتر است. در این روش افزایش تعداد ویژگی موجب افزایش دقت کل نمی‌شود.

جدول ۷: نتایج کلاس‌بندی SVM مبتنی بر تحلیل PCA در حوزه زمان

- فرکانسی برای داده ST7112-PSG

شماره مرحله	مرحله ۱ و ۶	مرحله ۲	مرحله ۳ و ۴	مرحله ۵	دقت (%)
مرحله ۱ و ۶	۲۲	۰	۱۳	۰	۶۲/۸۶
مرحله ۲	۰	۱۵۶	۰	۰	۱۰۰/۰۰
مرحله ۳ و ۴	۱	۸	۶۶	۰	۷۷/۶۵
مرحله ۵	۰	۲۳	۰	۹۵	۸۰/۵۱
دقت کل (%): ۸۸/۵۸					واریانس دقت (%): ۲۳۳/۱۰

۴-۲-۲- نتایج کلاس‌بندی روش SVM مبتنی بر تحلیل SPCA

برای داده ST7112-PSG

در این بخش نتایج حاصل از کلاس‌بندی مراحل خواب با استفاده از روش کلاس‌بندی SVM با به‌کارگیری ویژگی‌های زمانی، فرکانسی و زمان-فرکانسی با روش کاهش ابعاد و تنک‌سازی SPCA برای داده ST7112-PSG ارائه و تشریح شده است. مشابه روش قبل از ۶۰٪ داده جهت آموزش و از ۴۰٪ مابقی به عنوان داده تست استفاده شده است.

۴-۲-۱- تحلیل زمانی

در تحلیل زمانی مبتنی بر روش SPCA ویژگی‌های زمانی سیگنال EEG پس از عبور از فیلتر استخراج شده و با به‌کارگیری روش کاهش ابعاد SPCA مولفه‌های اصلی بردار ویژگی با تنک‌سازی برای مراحل مختلف خواب محاسبه می‌شود.

در جدول ۸ نتایج به‌کارگیری کلاس‌بندی SVM با ویژگی‌های زمانی و تحلیل SPCA به تفکیک برای هر یک از مراحل خواب و نیز کل داده تست سیگنال EEG ارائه شده است. با توجه به نتایج مشخص

پیشنهادی برای کلاس‌بندی مراحل خواب این است که در این روش بدون نیاز به استخراج ویژگی می‌توان مراحل خواب سیگنال داده خام را پس از عبور از فیلتر جداسازی کرد. این امر موجب کاهش محاسبات مورد نیاز در طبقه‌بندی مراحل سیگنال EEG خواب شده و زمان مورد نیاز برای پروسه طبقه‌بندی را کاهش می‌دهد.

نتایج حاصل از به‌کارگیری کلاس‌بندی SRC با استفاده از الگوریتم OMP بر روی داده‌های تست در جدول ۱۱ نمایش داده شده است. در این روش دقت کل برای تشخیص همه مراحل خواب برابر با ۹۱/۳۷٪ است.

۴-۴ نتایج کلاس‌بندی HMM مبتنی بر DBN برای داده ST7112-PSG

در روش کلاس‌بندی مراحل خواب با کلاس‌بندی کننده HMM و یادگیری ویژگی غیرنظارتی با استفاده از روش DBN مشابه روش‌های پیشین ۶۰٪ داده‌های خواب پس از عبور از فیلتر برای آموزش به الگوریتم غیر نظارتی DBN برای یادگیری اعمال می‌گردد. برای ارزیابی این روش، ۴۰٪ بقیه داده خواب به طبقه‌بندی کننده HMM اعمال می‌شود. در این روش یک DBN دو لایه با ۲۰۰ واحد مخفی در هر لایه استفاده شده است.

نتایج حاصل از به‌کارگیری کلاس‌بندی HMM با استفاده از الگوریتم یادگیری غیرنظارتی DBN بر روی داده‌های تست در جدول ۱۲ نمایش داده شده است. در این روش دقت کل برای تشخیص همه مراحل خواب برابر با ۸۵/۷۸٪ است که از همه روش‌های موجود مبتنی بر تحلیل PCA پیاده‌سازی شده شامل به‌کارگیری ویژگی‌ها در حوزه زمان، فرکانس و زمان-فرکانسی بالاتر است. مشابه روش‌های پیشین، بالا بودن تعداد دوره‌های مراحل ۲ و ۵ در سیگنال EEG خواب مورد مطالعه بر عدم تشخیص درست این مراحل و درصد تشخیص کل تاثیر عمده‌ای دارد.

جدول ۱۲: نتایج کلاس‌بندی HMM مبتنی بر DBN داده ST7112-PSG

شماره مرحله	مرحله ۱ و ۶	مرحله ۲	مرحله ۳ و ۴	مرحله ۵	دقت (%)
مرحله ۱ و ۶	۳۳	۲	۰	۰	۹۴/۲۹
مرحله ۲	۱۳	۱۳۷	۵	۱	۸۳/۰۳
مرحله ۳ و ۴	۱	۴	۷۹	۱	۹۲/۹۴
مرحله ۵	۱۲	۳	۱	۱۰۲	۸۶/۴۴
دقت کل (%)					۸۹/۰۹
واریانس دقت (%)					۲۸/۵۳

برای کاهش ابعاد و تنک‌سازی به تحلیل SPCA اعمال می‌شود تا مولفه‌های اصلی تنک شده استخراج شود.

جدول ۱۰: نتایج کلاس‌بندی SVM مبتنی بر تحلیل SPCA در حوزه زمان-فرکانسی برای داده ST7112-PSG

شماره مرحله	مرحله ۱ و ۶	مرحله ۲	مرحله ۳ و ۴	مرحله ۵	دقت (%)
مرحله ۱ و ۶	۳۳	۰	۲	۰	۹۴/۲۹
مرحله ۲	۰	۱۵۶	۰	۰	۱۰۰/۰۰
مرحله ۳ و ۴	۱۶	۰	۶۹	۰	۸۱/۱۸
مرحله ۵	۰	۱۳	۴	۱۰۱	۸۵/۵۹
دقت کل (%)					۹۱/۱۲
واریانس دقت (%)					۵۵/۲۷

در جدول ۱۰ درصد دقت کل روش کلاس‌بندی SVM با تحلیل زمان-فرکانسی SPCA برابر با ۹۱/۱۲٪ است که از تحلیل با ویژگی‌های زمانی بالاتر اما از تحلیل فرکانسی پایین‌تر است. بنابراین می‌توان نتیجه گرفت لزوماً استفاده از ویژگی‌های بیشتر در کلاس‌بندی مراحل خواب در روش SPCA مشابه روش PCA موجب افزایش دقت تفکیک-پذیری کل مراحل خواب نمی‌شود.

۴-۳ نتایج کلاس‌بندی SRC مبتنی بر الگوریتم OMP برای داده ST7112-PSG


در این روش مشابه روش‌های پیشین ۶۰٪ داده‌های خواب پس از عبور از فیلتر برای آموزش به الگوریتم OMP برای ایجاد دیکشنری اعمال می‌شود. برای ارزیابی این روش، ۴۰٪ بقیه داده خواب به SRC اعمال می‌شود. مزیت عمده این روش نسبت به روش تحلیل SPCA

جدول ۱۱: نتایج کلاس‌بندی SRC مبتنی بر الگوریتم OMP برای داده ST7112-PSG


شماره مرحله	مرحله ۱ و ۶	مرحله ۲	مرحله ۳ و ۴	مرحله ۵	دقت (%)
مرحله ۱ و ۶	۳۲	۰	۱	۲	۹۱/۴۳
مرحله ۲	۰	۱۳۳	۱۳	۱۰	۸۵/۲۶
مرحله ۳ و ۴	۰	۲	۸۱	۲	۹۵/۲۹
مرحله ۵	۳	۰	۱	۱۱۴	۹۶/۶۱
دقت کل (%)					۹۱/۳۷
واریانس دقت (%)					۲۵/۹۱

۴-۵- مقایسه روش‌های پیشنهادی

در شکل ۴ مقایسه درصد دقت روش کلاس‌بندی SVM با تحلیل PCA برای مراحل مختلف خواب و نیز درصد دقت کل برای حالت‌های به‌کارگیری بردار ویژگی در حوزه زمان، فرکانس و زمان-فرکانس داده تست سیگنال ST7112-PSG نمایش داده شده است. با توجه به شکل مشخص است که دقت کل برای مراحل خواب در حوزه فرکانسی از حوزه زمان-فرکانسی، و حوزه زمان-فرکانسی از حوزه زمانی بالاتر است. این امر نشان دهنده آن است که لزوماً به‌کارگیری تعداد ویژگی‌های بیشتر در تحلیل PCA موجب افزایش درصد دقت کل با کلاس‌بندی SVM نمی‌شود. هر چند که به‌کارگیری ویژگی‌های حوزه زمان-فرکانسی موجب افزایش دقت کل مراحل خواب نسبت به روش به‌کارگیری ویژگی‌های حوزه زمانی به‌صورت تنها شده است.




شکل ۴: مقایسه نتایج کلاس‌بندی SVM با تحلیل PCA برای ویژگی‌های مختلف داده ST7112-PSG




شکل ۵: مقایسه نتایج کلاس‌بندی SVM با تحلیل SPCA برای ویژگی‌های مختلف داده ST7112-PSG

در شکل ۶ درصد دقت کل طبقه‌بندی مراحل خواب سیگنال ST7112-PSG در دو روش پیشنهادی SPCA در حوزه‌های زمانی، فرکانسی و زمان-فرکانسی و روش کلاس‌بندی SRC بر اساس الگوریتم OMP آورده شده و با روش PCA و HMM مبتنی بر DBN مقایسه شده است. با توجه به نتایج ارائه شده روش SPCA در حوزه فرکانس بالاترین دقت را دارد. با توجه به نتایج ارائه شده مشخص است که روش پیشنهادی SPCA در هر یک از حالت‌های به‌کارگیری ویژگی‌های مختلف نسبت به روش PCA درصد دقت کل بالاتری دارد.



شکل ۶: مقایسه دقت روش‌های مختلف کلاس‌بندی مراحل خواب داده ST7112-PSG

به‌علاوه روش SPCA در حالت‌های به‌کارگیری ویژگی‌های فرکانسی و ترکیبی نسبت به روش کلاس‌بندی HMM مبتنی بر DBN درصد دقت بالاتری دارد. همچنین بین همه روش‌ها، روش SPCA با ویژگی‌های فرکانسی بالاترین دقت کل را دارد. دقت کل در این روش ۹۸/۹۸ درصد است که نسبت به روش PCA با ویژگی‌های فرکانسی مشابه با دقت ۸۹/۳۴ درصد، به میزان ۹/۶۴ درصد و نسبت به روش HMM مبتنی بر DBN با دقت ۸۹/۰۹ درصد، به میزان ۹/۸۹ درصد بالاتر است. به‌علاوه، روش کلاس‌بندی SRC با الگوریتم OMP پیشنهادی از کلاس‌بندی با روش SVM برای تحلیل PCA موجود دقت کل بالاتری دارد. دقت کل در این روش برابر ۹۱/۳۷ درصد است که نسبت به روش تحلیل PCA مبتنی بر ویژگی‌های فرکانسی ۲/۰۳ درصد و نسبت به روش HMM مبتنی بر یادگیری غیرنظارتی DBN ۲/۲۸ درصد بالاتر است.



شکل ۷: مقایسه مدت زمان اجرای روش‌های مختلف کلاس‌بندی مراحل خواب داده ST7112-PSG

با توجه به شکل ۷ می‌توان اینطور نتیجه گرفت که در سیگنال ST7112-PSG روش کلاس‌بندی SRC با بهره‌گیری از الگوریتم OMP بدلیل عدم استفاده و محاسبه ویژگی برای هر دوره زمانی، نسبت به

مشابه روند تحلیل PCA برای بررسی تاثیر به‌کارگیری ویژگی‌های مختلف در روش SPCA پیشنهادی درصد دقت روش کلاس‌بندی SVM برای مراحل مختلف خواب و درصد دقت کل برای حالت‌ها به‌کارگیری بردار ویژگی سیگنال ST7112-PSG در حوزه زمان، فرکانسی و زمان-فرکانسی در روش SPCA در شکل ۵ نشان داده شده است. در این روش نیز مشابه روش PCA دقت کل برای مراحل خواب در حالت به‌کارگیری ویژگی‌های فرکانسی از حالت ترکیبی زمان-فرکانسی، و حالت ترکیبی از حالت به‌کارگیری ویژگی‌های زمانی بالاتر است. بنابراین در روش پیشنهادی SPCA نیز به‌کارگیری تعداد ویژگی‌های بیشتر موجب افزایش درصد دقت کل با کلاس‌بندی SVM نمی‌شود.

جدول ۱۳: نتایج دقت کلاس‌بندی مراحل ۴ گانه خواب برای ۱۰ نمونه

SRC _{OMP} (%)	SPCA _{Time-Freq} (%)	SPCA _{Freq} (%)	SPCA _{Time} (%)	HMM _{DBN} (%)	PCA _{Time-Freq} (%)	PCA _{Freq} (%)	PCA _{Time} (%)	روش داده
۹۰/۸۵	۸۹/۹۳	۹۸/۰۸	۸۸/۹۳	۹۰/۶۱	۸۸/۱۱	۸۹/۲۰	۸۵/۸۲	ST7011
۹۱/۴۳	۸۷/۴۱	۹۶/۷۲	۸۶/۵۶	۸۸/۰۷	۸۵/۱۹	۸۷/۷۲	۸۴/۷۶	ST7022
۸۹/۷۸	۸۸/۴۶	۹۷/۴۲	۸۷/۲۰	۸۹/۳۴	۸۷/۴۰	۸۹/۴۸	۸۵/۱۲	ST7041
۹۲/۱۷	۸۶/۹۰	۹۵/۳۶	۸۴/۴۸	۹۰/۱۰	۸۵/۸۹	۸۶/۳۸	۸۳/۹۶	ST7052
۹۴/۶۵	۹۲/۲۷	۹۹/۰۱	۸۸/۷۰	۹۰/۳۶	۸۹/۹۹	۹۱/۷۷	۸۷/۴۱	ST7061
۹۲/۳۸	۹۰/۲۴	۹۷/۴۲	۸۶/۸۰	۸۸/۵۸	۸۵/۶۲	۸۹/۱۶	۸۴/۲۲	ST7082
۸۹/۷۴	۸۹/۴۵	۹۶/۱۶	۸۵/۲۳	۸۷/۵۶	۸۴/۹۵	۸۸/۷۸	۸۴/۷۶	ST7101
۹۱/۳۷	۹۱/۱۲	۹۸/۹۸	۸۸/۳۲	۸۹/۰۹	۸۸/۵۸	۸۹/۳۴	۸۶/۰۴	ST7112
۹۲/۲۱	۹۳/۳۸	۹۹/۴۲	۸۹/۲۹	۸۹/۵۹	۸۸/۷۰	۹۱/۹۲	۸۷/۹۳	ST7121
۹۰/۸۷	۸۷/۷۵	۹۵/۱۰	۸۵/۰۸	۸۷/۸۲	۸۴/۲۹	۸۶/۴۱	۸۳/۳۰	ST7151
۹۱/۵۴	۸۹/۶۹	۹۷/۳۸	۸۷/۰۵	۸۹/۱۱	۸۶/۸۷	۸۹/۰۲	۸۵/۳۳	میانگین

۴-۶- نتیجه‌گیری

در این مقاله کلاس‌بندی خودکار مراحل چهارگانه خواب با بهره‌گیری از دو روش پیشنهادی SPCA و SRC براساس نظریه حسگری فشرده صورت گرفته و نتایج حاصل از آن‌ها با روش PCA و HMM مبتنی بر شبکه DB مقایسه شده است. سیگنال‌های EEG مورد مطالعه در این مقاله داده‌هایی با فرکانس نمونه‌برداری ۱۰۰ هرتز از پایگاه داده بین-المللی PhysioNet می‌باشند که پس از پیش پردازش جهت اعمال روش‌های پیشنهادی مورد استفاده قرار گرفته اند.

طبق نتایج بدست آمده دقت میانگین روش SPCA مبتنی بر ویژگی‌های فرکانسی و روش SRC پیشنهادی به ترتیب ۸/۳۶ و ۲/۴۳ درصد از روش PCA در حوزه فرکانسی و ۸/۲۶ و ۲/۴۳ درصد از روش HMM با یادگیری غیرنظارتی DBN بالاتر است. به علاوه، مدت زمان اجرای شبیه‌سازی روش کلاس‌بندی SRC مبتنی بر OMP بدلیل عدم استفاده و محاسبه ویژگی برای هر دوره زمانی و حجم محاسبات کمتر نسبت به روش‌های تحلیل PCA، SPCA و HMM مبتنی بر شبکه DB پایین‌تر است. زمان اجرای شبیه‌سازی در این روش ۱۸/۹۱ ثانیه است که نسبت به روش PCA موجود مبتنی بر ویژگی‌های فرکانسی بالاترین دقت با زمان اجرای ۴۱/۲۳ ثانیه، ۱۱۸ درصد و نسبت به روش HMM با یادگیری غیرنظارتی DBN با زمان اجرای ۳۲/۴۷ ثانیه، ۷۲ درصد کمتر است. از این رو با در نظر گرفتن هر دو معیار دقت تشخیص و سرعت تشخیص مراحل خواب، روش کلاس‌بندی SRC مبتنی بر الگوریتم OMP پیشنهاد عملکرد بالاتری نسبت به سایر روش‌های مورد مطالعه دارد.

روش SPCA، PCA و HMM مبتنی بر شبکه DB حجم محاسبات کمتر و در نتیجه سرعت تشخیص بالاتری دارد. همچنین در روش PCA و SPCA، مدت زمان اجرای شبیه‌سازی در حالت ویژگی زمانی کمتر از فرکانسی و زمان-فرکانسی است. علت این امر کمتر بودن تعداد ویژگی‌های زمانی و سادگی محاسبات آن‌ها نسبت به ویژگی‌های فرکانسی است. در بین روش‌های PCA و SPCA، در هر یک از حالت‌های ویژگی‌های زمانی، فرکانسی و زمان-فرکانسی زمان اجرای شبیه‌سازی در روش SPCA کمتر از روش PCA است. شبیه‌سازی در رایانه با پردازنده Intel® Core™ i5-2410M CPU 2.30 GHz اجرا شده است.

مقایسه بین تحلیل PCA و SPCA به لحاظ درجه پیچیدگی محاسبات نشان‌دهنده آن است که درجه پیچیدگی روش PCA برابر با $O(n^2)$ و روش SPCA برابر با $O(\hat{n}^2)$ است به نحوی که $\hat{n} \ll n$ می‌باشد. از این رو میزان بار محاسباتی روش SPCA پیشنهادی بسیار کمتر از روش PCA است [۲۴]. تنها بار محاسباتی قابل توجه روش مبتنی بر طبقه بندی SRC پیشنهادی مربوط به محاسبه و مینیمم‌سازی نرم یک است. در مجموع روش پیشنهادی دوم با توجه به عدم محاسبه ویژگی از روش پیشنهادی اول مبتنی بر SPCA بار محاسباتی پایین‌تری دارد.

در جدول ۱۳ جهت ارزیابی جامع‌تر دقت طبقه‌بندی روش‌های مختلف کلاس‌بندی مراحل ارائه شده نتایج برای ۱۰ نمونه داده آورده شده است، میانگین درصد دقت تشخیص مراحل خواب برای روش SPCA با به‌کارگیری ۱۱ ویژگی فرکانسی و روش SRC از سایر روش‌ها بالاتر و به ترتیب برابر با ۹۷/۳۸ و ۹۱/۵۴ درصد است که ۸/۳۶ و ۲/۴۳ درصد از روش PCA در حوزه فرکانسی و ۸/۲۶ و ۲/۴۳ درصد از روش HMM با یادگیری غیرنظارتی DBN بالاتر است.

مراجع

[20] M. Langkvist, L. Karlsson, and A. Loutfi, "Sleep stage classification using unsupervised feature learning", *Advances in Artificial Neural Systems*, Vol. 1, no. 1, pp. 1-9, 2012.

[21] Kunyang Li, Weifeng Pan, Qing Jiang, Guanzheng Liu, "A Method to Detect Sleep Apnea based on Deep Neural Network and Hidden Markov Model using Single-Lead ECG signal", *Neurocomputing*, Vol. 294, no. 1, pp. 94-101, 2018.

[22] K. Pillay, A. Dereymaeker, K. Jansen, G. Naulaers, S. V. Huffel, and M. D. Vos, "Automated EEG sleep staging in the term-age baby using a generative modelling approach", *Journal of Neural Engineering*, Vol. 15, no. 1, pp. 1-13, 2018.

[23] International Database PhysioNet Sleep Recordings: <http://www.physionet.org>.

[24] Y. Zhang and L. E. Ghaoui, "Large-Scale Sparse Principal Component Analysis with Application to Text Data", *The Neural Information Processing Systems Conference (NIPS)*, Granada, Spain, December 2011.

زیرنویس‌ها

- Rapid eye movement ^۱
- Polysomnography ^۲
- Electroencephalogram ^۲
- Sparse representation-based theory ^۴
- Rational discrete short-time Fourier transform ^۵
- Activity ^۶
- Mobility ^۷
- Complexity ^۸
- Relative spectral power ^۹
- Encoder ^۶
- Kernel ^۷
- Hyperplane ^۸
- Sparse deep belief network ^{۱۲}
- Principal component analysis ^{۱۴}
- Hidden markov model ^{۱۵}
- Sparse principal component analysis ^{۱۶}
- Support vector machine ^{۱۷}
- Sparse representation classifier ^{۱۸}
- Orthogonal matching pursuit ^{۱۹}
- Deep belief net ^{۲۰}
- Sleep telemetry ^{۲۱}

[1] M. Hamilton, "Development of a rating scale for primary depressive illness", *Br. J. Soc. Clin. Psychol.*, vol. 6, No. 4, pp. 278-296, 1967.

[2] S. Holm, "A simple sequentially rejective multiple test procedure", *Scand. J. Statist.*, vol. 6, No. 1, pp. 65-70, 1979.

[3] F. Ebrahimi, M. Mikaeili, E. Estrada, and H. Nazeran, "Automatic sleep stage classification based on EEG signals by using neural networks and wavelet packet coefficients", *30th Annual International IEEE EMBS Conference*, Vancouver, pp. 1151-1154, 2008.

[4] N. Schaltenbrand, R. Lengelle, M. Toussaint, R. Luthringer, G. Carelli, A. Jacqrnin, E. Lainey, A. Muzet, and J. P. Macher, "Sleep stage scoring using the neural network model: comparison between visual and automatic analysis in normal subjects and patients", *Sleep*, Vol. 19, No.1, pp. 26-35, 1996.

[5] S. Holm, "A simple sequentially rejective multiple test procedure", *Scand. J. Statist.*, vol. 6, No. 1, pp. 65-70, 1979.

[6] E. Oropesa, H. L. Cycon, M. Jobert, "Sleep Stage Classification using Wavelet Transform and Neural Network", *International Computer Science Institute (ICSI)*, 1999.

[7] M. Kiyimik, M. Akin, A. Subasi, "Automatic recognition of alertness level by using wavelet transform and artificial neural network", *J. Neuroscience Methods*, vol.139, No. 1, pp.231-240, 2004.

[8] H. Yu, H. Lu, T. Ouyang, H. Liu, and B. Lu, "Vigilance detection based on sparse representation of EEG", *Conf. Proc. IEEE Eng. Med. Biol. Soc.* pp. 2439-2442, 2010.

[9] S. Motamedi-Fakhr, M. Moshrefi-Torbati, M. Hill, C.M. Hill, and P.R. White, "Signal processing techniques applied to human sleep EEG signals— A review," *Biomed Signal Process Control*, vol. 10, No. 1, pp 21-33, 2014.

[10] K. Samieea, P. Kov'acsb, S. Kiranyaza, M. Gabbouja, T. Saram'aki, "Sleep stage classification using sparse rational decomposition of single channel EEG records", *Signal Processing Conference (EUSIPCO)*, pp. 1905-1909, 2015.

[11] H. T. Ocbagabir, K. A. I. Aboalayon, M. Faezipour, "Efficient EEG analysis for seizure monitoring in epileptic patients," *Systems, Applications and Technology Conference (LISAT)*, IEEE Long Island, pp.1-6, May 2013.

[12] K. Aboalayon, H. Ocbagabir, and M. Faezipour, "Efficient Sleep Stage Classification Based on EEG Signals", *Systems, Applications and Technology Conference (LISAT)*, 2014.

[13] H. Liu, H. Yu, Q. Ren, H. Lu, "Estimate vigilance level in driving simulation based on sparse representation", *International Conference on Machine Learning and Cybernetics (ICMLC)* pp.1111-1115, 2010.

[14] C. Vural, and M. Yildiz, "Determination of sleep stage separation ability of features extracted from EEG signals using Principle component analysis", *J. Med. Syst.*, Vol. 34, 83-89, 2010.

[15] M. Jobert, H. Escola E. Poiseau, p. Gaillard, "Automatic analysis of sleep using two parameters based on principal component analysis of electroencephalography spectral data", *Biological Cybernetics*, Vol. 71, No. 3, pp. 197-207, 1994.

[16] A. Subasi, "Automatic recognition of alertness level from EEG by using neural network and wavelet coefficients", *Expert Systems with Applications*, vol. 28, No. 1, pp. 701-711, 2005.

[17] Vatankhah, M.; Akbarzadeh-T, M-R; Moghimi, A., "An intelligent system for diagnosing sleep stages using wavelet coefficients," *International Joint Conference on Neural Networks (IJCNN)*, pp. 18-23, 2010.

[18] Faezeh Movahedi, James L. Coyle, Ervin Sejdi', "Deep belief networks for electroencephalography: A review of recent contributions and future utlooks", *IEEE Journal of Biomedical and Health Informatics*, Vol. 22, no. 3, pp. 642-652, 2018

[19] J. Zhang, Y. Wu, J. Bai, and F. Chen, "Automatic sleep stage classification based on sparse deep belief net and combination of multiple classifiers", *Computer Methods and Programs in Biomedicine*, Vol. 38, No. 4, pp. 2016.