

تشخیص اتوماتیک دوک‌های خواب با استفاده از دسته‌بندی کننده دو مرحله‌ای متشکل از ماشین بردار پشتیبان و شبکه‌های عصبی مصنوعی

محمدحسین خاکسار^۱، امین اله گلرو^۲، سعید راحتی قوچانی^۳

۱- دانشجوی کارشناسی ارشد، مهندسی پزشکی، دانشگاه آزاد اسلامی واحد مشهد، mh_khaksar@yahoo.com

۲- دانشجوی کارشناسی ارشد، مهندسی پزشکی، دانشگاه آزاد اسلامی واحد مشهد، amingolrou@gmail.com

۳- استادیار گروه مهندسی برق، دانشگاه آزاد اسلامی واحد مشهد، rahati@mshdiau.ac.ir

چکیده

دوک‌های خواب یکی از مهم‌ترین شکل موج‌های زودگذر در سیگنال EEG در حالت خواب می‌باشند. در اینجا، یک روش دو مرحله‌ای بر پایه‌ی شبکه‌های عصبی مصنوعی برای شناسایی اتوماتیک دوک خواب در یک سیگنال ۱۹ کاناله‌ی EEG معرفی می‌شود که، در مرحله‌ی اول، از یک پرسپترون پیش‌طبقه‌بندی کننده به منظور افزایش کارایی کلی آشکارسازی و همچنین کاهش زمان محاسبه استفاده می‌گردد و در مرحله‌ی دوم، دوک‌های خواب منتخب، توسط یک شبکه‌ی عصبی مصنوعی پس‌طبقه‌بندی کننده، دسته‌بندی می‌شود. ابزارهای دسته بندی کننده در فرآیند پس طبقه بندی دو شبکه‌ی MLP و RBSVM بودند که عملکرد آنها در انتها مورد مقایسه قرار گرفت. بررسی دیداری سیگنال EEG ۱۹ کاناله ثبت شده از شش سوژه، توسط یک متخصص تشخیص دوک‌های بصری خواب، نشان می‌دهد که عملکرد RBSVM نسبت به MLP با آموزش پس انتشار خطا بهتر بوده و دارای حساسیت میانگین ۹۱/۴٪ و آشکار سازی اشتباه ۳/۸۵٪ است.

واژه‌های کلیدی

EEG، آشکارسازی دوک خواب، ماشین بردار پشتیبان، الگوریتم پس انتشار

۱- مقدمه

چهارم، فرکانس باز هم کاهش یافته و کمپلکس‌های K به صورت پراکنده دیده می‌شوند. این مرحله، زمان شروع خواب فعال می‌باشد [۲].

مدارک معتبری وجود دارد که فعالیت دوک‌های خواب را ناشی از هایپر پلاریزاسیون غشاء عصبی هسته‌های تالاموکورتیکال و کورتیکال می‌داند [۳]. در خلال خواب انفجارهای مرتبی از پتانسیل عمل در نورون‌های هسته تالاموس رخ می‌دهد، که باعث ایجاد نوسانات متناوب و منظمی می‌شود. این انفجارات نهایتاً به بخش‌های قشری مغز منتقل می‌شوند و در آنجا باعث القا شدن پتانسیل‌های پس‌سیناپسی^۶ تحریک شده و دوک‌های خواب را تولید می‌نمایند [۵ و ۹]. طبقه‌بندی مراحل خواب، یکی از روش‌های مهم تشخیصی در روانپزشکی و عصب‌شناسی به شمار می‌رود. تشخیص دیداری

به طور کلی خواب به دو قسمت خواب^۱ NREM یا خواب آرام و هماهنگ، و خواب^۲ REM یا خواب فعال و ناهماهنگ تقسیم می‌شود [۱]. خواب NREM خود به چهار مرحله تقسیم می‌شود، که هر یک بیانگر حالت فیزیولوژیک خاصی است. مرحله‌ی اول زمانی است که دامنه‌ی امواج آلفا ظاهر شوند. در مرحله دوم خواب^۳ ظاهر می‌شوند و امواج ورتکس^۴ همچنان وجود دارند. در مرحله سوم، کاهش بیشتری در فرکانس دیده می‌شود و کمپلکس‌های K^۵ (این کمپلکس‌ها در شناسایی مراحل خواب و در تشخیص انواع اختلالات مربوط به خواب و بعضی بیماری‌های روانی نقش کلیدی دارند) و خواب به صورت پراکنده وجود دارند [۲]. در این مرحله فعالیت دوک‌های خواب در محدوده‌ی ۱۰ تا ۱۶ هرتز و با مدت ۰/۵ تا ۳ ثانیه گزارش شده است [۱]. در مرحله

شعاعی (RBSVM) و یک پرسپترون چندلایه (Multilayer Perceptron) استفاده شده است. در پایان عملکرد طبقه‌بندی این دو شبکه با یکدیگر مقایسه شدند. ارزیابی نتایج نشان می‌دهد که ماشین بردار پشتیبان در زمینه تشخیص دوک‌های خواب عملکرد بهتری نسبت به پرسپترون چند لایه دارد.

۲- مشخصات داده Sleep EEG

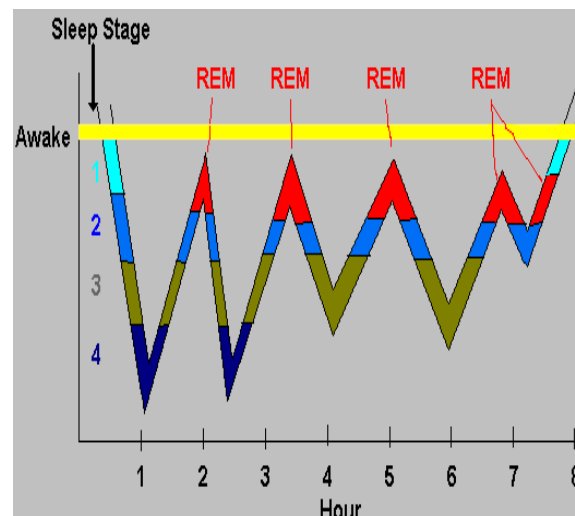
سیگنال EEG مورد استفاده در این مطالعه، از بانک داده Physionet دریافت شده است [۱۰]. داده‌های ثبت شده از ۶ سوژه سفید پوست ۲۱ تا ۳۵ ساله می‌باشد، که ۴ نفر از آنها مرد و ۲ نفر زن هستند. ثبت‌ها توسط الکترودهای غیرپلاریزه Ag/AgCl و بر اساس استاندارد بین المللی ۱۰-۲۰ اخذ شده است. این ثبت‌ها دارای آرتیفکت‌های EMG^{11} و EOG^{12} افقی بوده و نرخ نمونه برداری نیز ۱۰۰ هرتز و میان‌گذر شده در محدوده ۱ تا ۵۰ هرتز می‌باشد. نحوه ذخیره شدن سیگنال‌ها با فرمت EDF می‌باشد، که برای تبدیل آن به فرمت MIT از نرم افزار WFDB موجود در سایت Physionet استفاده شده است.

همه داده‌های دریافت‌شده، توسط یک متخصص مورد بررسی قرار گرفته و نامزدهای دوک خواب^{۱۳} استخراج شده‌اند. مجموعاً طول داده‌ها ۴۸ ساعت (متوسط ۸ ساعت برای هر داده) می‌باشد، که از ۶ ثبت، ۴ تا برای آموزش شبکه و ۲ تا برای آزمون استفاده می‌شود. متخصص تشخیص دوک‌های خواب تعداد ۵۳۱ دوک خواب را در مجموع داده‌ها شناسایی کرده که ۴۱۶ دوک خواب در داده‌های آموزش و ۱۱۵ دوک مربوط به داده‌های آزمون می‌باشد. میانگین سن روی سوژه‌های آموزش، ۲۷ سال و روی داده‌های آزمون ۳۰ سال می‌باشد.

۳- استخراج ویژگی

در این مطالعه از مدل خود بازگشتی خودکار (AAR^{14}) برای استخراج ویژگی استفاده شده است [۱۱]. اگر سیگنال با زمان تغییر نکند، می‌توان از شیوه‌های خود بازگشتی (AR^{15}) متعارف استفاده نمود؛ اما در حالت واقعی، سیگنال EEG تحت تاثیر عوامل زیادی می‌باشد، که قابل کنترل نیستند. از این رو ممکن است که شیوه‌های بلوک AR نتوانند تغییرات کوچک در طیف غیرایستاد سیگنال EEG را ردیابی نمایند. با تخمین تطبیقی پارامترهای AR به وسیله استفاده از روش LMS^{16} می‌توان بر این مشکل روش AR نیز غلبه کرد. در شکل (۲) بلوک دیاگرام پیشگویی‌کننده خطی تطبیقی مشاهده می‌شود [۱۱].


دوک‌های خواب در یک ثبت EEG⁷ از یک خواب کامل شبانه، خیلی وقت‌گیر و خسته‌کننده است؛ زیرا تقریباً ۱۰۰ دوک در یک ثبت خواب کامل شبانه موجود است. یک سیستم تشخیص اتوماتیک می‌تواند گام موثری در کم کردن و تسهیل نمودن کار پزشکان و محققان در این زمینه باشد [۴ و ۹].



شکل ۱- نمودار طبقه بندی مراحل خواب

روش‌های اتوماتیک بسیاری برای آشکارسازی دوک‌های خواب تا به حال پیشنهاد شده است. بعضی از این روش‌ها بر پایه‌ی منطق کردن الگوها^{۱۴} می‌باشند [۴]. در این روش‌ها، از مقایسه تشابه بین سیگنال و یک الگوی از پیش تعریف شده استفاده می‌شود. عیب این روش این است که تعیین مشخصه‌های الگو، وابسته به سوژه می‌باشد [۳]. از روش‌های دیگری که در این زمینه به کار گرفته شده‌اند، می‌توان به استفاده از آنالیزهای طیفی اشاره کرد که مشکل این روش نیز این است که قادر به تفکیک دوک‌ها از شکل موج‌های هم فرکانس با دوک‌ها نمی‌باشند. روش‌های دیگری نیز برای پیدا کردن دوک‌ها وجود دارد، که مبتنی بر استفاده از تعقیب همسان^۹ و تبدیل موجک^{۱۰} می‌باشند [۴، ۵]. شیوه‌ی آشکارسازی دوک‌های خواب در سیگنال EEG بایستی نسبت به تغییرات الگوها پایدار بوده و همچنین بتواند عملکرد بهینه‌ای در حوزه زمان و حافظه مورد نیاز داشته باشد [۸ و ۶].

در این مقاله، یک روش مبتنی بر استفاده از شبکه‌های عصبی مصنوعی به کار گرفته شده است. روش پیشنهاد شده از دو مرحله تشکیل شده است. در مرحله اول که مرحله پیش طبقه‌بندی می‌باشد، از یک پرسپترون گسسته استفاده شده و در مرحله پس طبقه‌بندی نیز از دو شبکه، یعنی ماشین بردار پشتیبان



شکل ۳- ساختار پرسپترون گسسته که برای پیش طبقه‌بندی تطبیق یافته است [۷].

$$W[k+1] = w[k] + \eta(d^S - y^S)x^S \quad (1)$$

که $W = [w_1, w_2, \dots, w_{16}]^T$ بردار وزن ارتباط، y^S خروجی واقعی و d^S خروجی مورد انتظار است، که توسط متخصص مشخص شده است. η نرخ آموزش است و x^S بردار ورودی است، که از ۱۵ ویژگی تشکیل شده است (متناسب با ضرایب AAR). خروجی واقعی به وسیله رابطه‌ی ورودی - خروجی پرسپترون گسسته محاسبه می‌شود:

$$y^S = \text{sign}(W^T X^S - \tau) \quad (2)$$

که τ مقدار آستانه است و :

$$\text{sign}(u) = \begin{cases} +1 & u \geq 0 \\ -1 & u < 0 \end{cases} \quad (3)$$


پرسپترون گسسته چند بار آموزش می‌بیند، تا زمانی که بهترین نتیجه بدست آید؛ که در این حالت خروجی باید برای محدوده‌ی SS و SS شبیه non-SS برابر +۱ و برای محدوده‌های non-SS برابر -۱ باشد.

بنابراین، الگوهای پنجره‌ای شده که از آستانه آزمون عبور می‌کنند، به دو زیر گروه مجزا تقسیم می‌شوند:

(I) الگوهای محدوده‌ی SS و SS شبیه non-SS شبیه

(II) الگوهای محدوده‌ی non-SS (شکل (۴))

چهار ثبت EEG که شامل ۴۱۶ دوک خواب هستند، برای آموزش پرسپترون استفاده می‌شوند، در حالی که یک مجموعه دیگر شامل ۲ ثبت با ۱۱۵ دوک خواب، برای اهداف آزمون شبکه استفاده می‌شود. با استفاده از پیش طبقه‌بندی، تقریباً ۷۵٪ از الگوها در گروه



شکل ۲- بلوک دیاگرام پیشگویی کننده خطی تطبیقی [۱۱].

همان گونه که قبلاً توصیف شد، مدت زمان دوک‌های خواب بین ۰/۵ ثانیه تا ۳ ثانیه می‌باشد. این فاصله‌ی زمانی برای مشخص کردن اندازه‌ی پنجره بسیار اهمیت دارد.

تولید ویژگی برای مراحل آموزش و آزمون بدین شکل می‌باشد که: اولاً داده‌ی EEG با نرخ ۲۵۰ هرتز و با یک پنجره ۳ ثانیه (۷۵۰ نقطه) نمونه برداری می‌شود. سپس ضرایب AAR محاسبه می‌شوند. این ضرایب برای مقدار $k=15$ (که مقدار بهینه‌ی مرتبه‌ی AAR است) با استفاده از معیار Akaike بدست می‌آیند. بنابراین، سائز ورودی شبکه‌های عصبی مصنوعی در مقدار ۱۵ تنظیم می‌شود. این روند با استفاده از جابجا کردن ۱۷ پنجره‌ی داده‌ی ورودی، برای هر داده‌ی EEG پنجره‌ای شده تکرار می‌شود. در همه مراحل، اندیس زمانی هر نقطه‌ی داده‌ی پنجره‌ای شده ذخیره می‌شود، تا موقعی که به آن نیاز داریم استفاده شود (به عنوان مثال برای مشخص کردن محل دوک).

با استفاده از رویه فوق، مجموعه‌ی آموزش و آزمون را می‌توان با محاسبه و استخراج کردن ضرایب AAR دوک‌های خواب از سیگنال پایه در فواصل مشخص بدست آورد.


۴- پیش طبقه بندی

از مرحله پیش طبقه‌بندی برای حذف محدوده‌های غیر دوک استفاده می‌شود. الگوهای باقی‌مانده، یعنی محدوده‌های SS و SS شبیه non-SS، تنها ورودی‌های پس طبقه‌بندی کننده هستند. در این راه نه فقط زمان محاسبه کل روند طبقه‌بندی کاهش می‌یابد، بلکه همچنین کارایی کلی آشکار سازی نیز افزایش می‌یابد. پروسه‌ی پیش طبقه‌بندی به شرح زیر است:

۴-۱- پیش طبقه بندی کننده پرسپترون گسسته^{۱۸}

از یک پرسپترون گسسته که با ویژگی‌های ذکر شده در بخش استخراج ویژگی تغذیه می‌شود، برای جدا کردن محدوده‌های SS و SS شبیه non-SS از بقیه قسمت‌های سیگنال استفاده شده است (شکل (۳)). از روش آموزش پرسپترون گسسته نیز برای آموزش شبکه استفاده می‌شود.

پشتیبان شناخته می‌شوند. رای یک مساله طبقه‌بندی جداپذیر خطی با ساختار یک ابرصفحه $w^T X + b = 0$ ، حاشیه‌ی بین ابرصفحه و نزدیک‌ترین نقطه بیشینه می‌شود.



شکل ۵- ساختار ماشین بردار پشتیبان استفاده شده برای پس طبقه بندی [۱۲].

۲-۵- پیاده سازی


پس از مرحله پیش‌طبقه‌بندی، تنها الگوهای داده پنجره‌ای شده‌ای که به شکل SS و SS های شبیه non-SS هستند، به ورودی پس‌طبقه‌بندی کننده یعنی ماشین بردار پشتیبان داده می‌شوند. ویژگی مورد نظر نیز همان ویژگی‌های ذکر شده در مرحله پیش‌طبقه‌بندی می‌باشد.

کارایی کلی سیستم به وسیله اندازه‌گیری میزان حساسیت^{۲۱} و نرخ آشکارسازی اشتباه^{۲۲} طبقه‌بندی کننده انجام می‌پذیرد. نسبت تعداد دوک‌هایی که توسط شبکه درست تشخیص داده شده‌اند، به تعداد دوک‌هایی که برای آزمون به سیستم داده شده‌اند را حساسیت گویند. آشکارسازی اشتباه نیز، نسبت تعداد غیر دوک‌هایی است که توسط شبکه به عنوان دوک شناخته شده‌اند، تقسیم بر کل تعداد دوک‌های داده شده به شبکه برای آزمایش.

برای مشاهده تأثیر اندازه پنجره ورودی بر عملکرد ماشین بردار پشتیبان، پیاده‌سازی توسط اندازه‌های مختلف پنجره ورودی تکرار می‌شود (جدول ۱). نکات بدست آمده از این جدول نشان می‌دهد که تعداد ۷۵۰ نقطه برای داده ورودی، که متناظر با زمان ۳ ثانیه است، بهترین نتیجه را می‌دهد. بررسی مطالعات دوک‌های خواب نیز به این نکته اشاره دارد که مدت زمان دوک‌های خواب در حدود ۳ ثانیه است [۱].

این مساله ثابت شد که اندازه پنجره بر عملکرد ماشین بردار پشتیبان تأثیر می‌گذارد [۱۲]. در ابتدا، مجموعه داده شامل ۷۵۰ نقطه (متناظر با ۱۵ ضریب AAR) برای هر الگو می‌باشد؛ سپس،

دوم می‌افتند. ۲۵٪ تقریبی باقیمانده‌ی الگوها به گروه اول متعلق است و به عنوان ورودی به پس‌طبقه‌بندی کننده داده می‌شوند؛ در نتیجه مرحله‌ی پیش‌طبقه‌بندی دارای حساسیت میانگین و آشکارسازی اشتباه به ترتیب ۹۸/۶٪ و ۳۲۱/۸٪ خواهد بود. بدین وسیله، حجم مجموعه‌ی آموزش و زمان آموزش پس‌طبقه‌بندی-کننده به طور چشمگیری کاهش می‌یابد.



○ SS × non-SS

شکل ۴- الگوها به دو گروه زیر طبقه بندی می‌شوند: گروه I محدوده‌های SS و SS شبیه non-SS را نشان داده و گروه II محدوده‌های non-SS را نشان می‌دهد [۱۲].

۵- پس طبقه بندی

پس طبقه‌بندی کننده الگوهای پنجره‌ای شده‌ی گروه اول را از هم جدا می‌کند. به عبارت دیگر عمل جدا کردن SSها و SSهای شبیه non-SS را از یکدیگر انجام می‌دهد. ما در این پژوهش از یک ماشین بردار پشتیبان شعاعی و یک پرسپترون چند لایه به عنوان پس‌طبقه‌بندی کننده استفاده کرده‌ایم. نهایتاً عملکرد این دو شبکه از جهت معیارهای طبقه‌بندی با هم مقایسه می‌شود.

۱-۵- ماشین‌های بردار پشتیبان با مبنای شعاعی^{۱۹}

شکل (۵) ساختار یک ماشین بردار پشتیبان را نشان می‌دهد. M تعداد بردارهای پشتیبان است. SVM روش نسبتاً جدیدی برای حل مسائل طبقه‌بندی نظارت شده^{۲۰} به شمار می‌رود. اصولاً این چنین روشی حاشیه بین داده‌های آموزشی و محدوده-ی تصمیم‌گیری را بیشینه می‌کند، که می‌تواند به عنوان یک مساله بهینه‌سازی درجه دوم در نظر گرفته شود. زیرمجموعه‌هایی از الگوها که به محدوده‌ی تصمیم‌گیری نزدیک هستند، به عنوان بردارهای

که $net_j = \sum x_j w_{ji}$ و $y_j^{(k)}$ خروجی مورد نظر برای نورون J می‌باشد. f نشان‌دهنده تابع سیگموئید است. برای نورون‌های مخفی داریم:

$$\delta_j = \left(\frac{\partial f}{\partial net_j} \right) \sum_q w_{qj} \delta_q \quad (7)$$

معادله بالا خروجی مورد انتظار را ایجاد نمی‌کند؛ اختلاف بین خروجی مورد نظر و خروجی حقیقی لایه مخفی l با عبارت δ_l که جمع وزن دار نورون q متصل به خروجی J می‌باشد، جایگزین می‌شود. عبارت δ برای نورون‌های همه لایه‌ها و وزن‌های همه ارتباطها، طبق معادله ۵ محاسبه می‌گردد.

جدول ۱- تاثیر اندازه داده ورودی بر روی کارایی طبقه بندی کننده‌ی MLP

اندازه داده ورودی	حساسیت (%)	آشکارسازی اشتباه (%)
۴۵۰	۸۶/۱	۸/۴
۵۵۰	۸۹/۶	۵/۲
۶۵۰	۹۱/۴	۴/۶
۷۵۰	۹۴/۶	۳/۸
۸۵۰	۹۴/۶	۴/۲
۹۵۰	۹۴/۶	۴/۲
۱۰۵۰	۹۴/۲	۵/۲

شبکه MLP با استفاده از اعداد متفاوت برای تعداد نورون‌های مخفی، چند بار آموزش داده می‌شود، تا زمانی که بهترین عملکرد را داشته باشد. ما ابتدا از یک پنجره‌ی ورودی با اندازه‌ی مشابه که برای RB-SVM استفاده شد، یعنی ۷۵۰ نقطه داده (وابسته به ۱۵ ضریب AAR) استفاده نمودیم. سپس اعداد ۵۰۰، ۶۵۰ و ۹۰۰ نقطه آزمایش می‌شود. به نظر می‌رسد که پنجره‌ی ورودی با اندازه‌ی ۷۵۰ نقطه‌ی اطلاعات، دارای عملکرد بهینه‌ای می‌باشد.

در مرحله دوم پس‌طبقه‌بندی، از شبکه MLP به جای RBSVM استفاده می‌کنیم. اثر تغییر تعداد نورون‌های لایه مخفی بر کارایی کلی، این را نشان می‌دهد که با افزایش تعداد نورون‌های مخفی به ۱۴، کارایی بهبود می‌یابد. برای تعداد بیشتر نورون‌های مخفی، افزایشی در کارایی مشاهده نشد. پس تعداد نورون‌های

ضرایب AAR هر مجموعه داده که به ماشین بردار پشتیبان داده می‌شود، تغییر می‌کند. اندازه ورودی ماشین بردار پشتیبان، متناظر با مرتبه مدل AAR - که ۱۵ است - می‌باشد. الگوهای دوک و غیر دوک به ترتیب با اعداد +۱ و -۱ نشان داده می‌شوند. ۲ تا از سوژه‌های ثبت به عنوان داده آزمون انتخاب شده‌اند. عملکرد طبقه بندی کننده ماشین بردار پشتیبان با اندازه‌گیری نرخ حساسیت و آشکارسازی اشتباه بررسی می‌شود. آزمون ماشین بردار پشتیبان شعاعی نشان‌دهنده‌ی مقدار ۹۴/۶٪ برای حساسیت، و نرخ آشکارسازی اشتباه ۳/۸۵٪ است.

۳-۵- MLP و پیاده سازی آن

از یک شبکه‌ی MLP - که یکی از مرسوم‌ترین شبکه‌های عصبی مصنوعی است - برای انجام پس‌طبقه‌بندی استفاده شده است. الگوریتم استاندارد پس انتشار خطا برای آموزش شبکه استفاده شده است. این شبکه در ۳ لایه طراحی شده است: لایه ورودی، لایه‌ی مخفی و لایه خروجی. نورون‌ها در لایه‌ی ورودی به عنوان پردازشگر برای توزیع کردن سیگنال ورودی (x_i) به نورون‌های لایه‌ی مخفی عمل می‌کنند. هر نورون J در لایه‌ی مخفی، سیگنال‌های ورودی‌اش (x_i) را پس از اینکه در وزن ورودی w_{ji} ضرب می‌کند، با یکدیگر جمع می‌کند. سپس، خروجی‌اش را با عبور دادن مجموع از یک تابع غیر خطی که تابع دو قطبی سیگموئید نامیده می‌شود، محاسبه می‌کند؛ که در معادله‌ی ۴ نشان داده شده است:

$$y_j = \text{sigm} \left(\sum_i w_{ji} x_i \right) \quad (4)$$

الگوریتم پس انتشار خطا^{۲۳} یک الگوریتم گرادیان کاهش می‌باشد. وقتی که بخش گشتاور را به آن اضافه می‌کنیم، الگوریتم، تغییرات $\Delta w_{ji}(k)$ را در وزن ارتباط بین نورون i ، J ایجاد می‌کند:

$$\Delta w_{ji}(k) = \eta \delta_j x_i + \alpha \Delta w_{ji}(k-1) \quad (5)$$

که η یک پارامتر نرخ یادگیری، α ضریب گشتاور و δ_i فاکتوری وابسته به این است که آیا J یک نورون خروجی است یا نورون مخفی. برای نورون‌های خروجی داریم:

$$\delta_j = \left(\frac{\partial f}{\partial net_j} \right) (y_j^{(k)} - y_j) \quad (6)$$

جدول ۲- عملکرد کلی طبقه بندی کننده‌ها بر روی ۲ سوژه (پیش طبقه بندی کننده پرسپترون و پس طبقه بندی کننده MLP و SVM)

سوژه	شماره ۱	شماره ۲	میانگین
سن	۳۲	۲۸	۳۰
مدت زمان (ساعت)	۸	۸	۱۶
تعداد دوک‌های مجموعه آزمون	۵۴	۶۱	۱۱۵
حساسیت مرحله پیش طبقه بندی	۹۸/۱	۹۹/۲	۹۸/۶
آشکار سازی اشتباه مرحله پیش طبقه بندی	۳۲۱/۰	۳۷۲/۶	۳۲۱/۸
حساسیت MLP	۹۰/۱	۸۸/۲	۸۹/۱
آشکار سازی اشتباه MLP	۶/۴	۸/۲	۷/۳
حساسیت SVM	۹۲/۴	۹۰/۴	۹۱/۴
آشکار سازی اشتباه SVM	۳/۸	۳/۹	۳/۸۵

در مرحله دوم، محدوده‌های SS و SS شبیه non-SS مد نظر هستند که از هم جدا شوند. این کار توسط یک شبکه‌ی عصبی مصنوعی که به عنوان پس طبقه بندی کننده می‌تواند کار کند، انجام می‌شود. در این مرحله دو شبکه‌ی مختلف، یعنی MLP با آموزش پس انتشار خطا و RBSVM پیاده سازی می‌شوند و به عنوان پس طبقه بندی کننده مقایسه می‌شوند. تخمین دیداری تعداد دوک‌ها با کمک یک متخصص نشان می‌دهد که بهترین عملکرد با استفاده از RBSVM بدست می‌آید. این شبکه یک حساسیت میانگین ۹۱/۶٪ و نرخ آشکار سازی اشتباه میانگین ۳/۸۵٪ را فراهم می‌آورد.

سیستم‌های آشکار سازی دوک‌های خواب بر پایه‌ی شبکه‌های عصبی مصنوعی، عموماً دو روش اساسی را به کار می‌گیرند، که در ورودی اختلاف دارند [۶،۷]. در شیوه اول، پارامترهایی از پیش تعیین شده، از ثبت‌های EEG محاسبه می‌شوند و به عنوان ورودی به شبکه عصبی داده می‌شوند. در شیوه دوم، داده‌های EEG ردیفی شده به عنوان ورودی به شبکه عصبی مصنوعی داده می‌شوند. شیوه استفاده از ورودی‌های پارامتری شده، دارای این مزیت است که نیاز به استفاده از ویژگی‌های ورودی کمتری را دارد؛ البته بایستی تعاریف دقیق تری از ویژگی‌های ورودی انتخاب شده

مخفی، هم برای آموزش و هم برای آزمون به ۱۴ تغییر داده شد. آزمایش کردن شبکه‌ی MLP با مجموعه داده‌های مشابهی که در RBSVM هم استفاده شد، نشان دهنده‌ی حساسیت میانگین ۸۹/۱٪ و آشکار سازی اشتباه میانگین ۷/۳٪ بود.

۶- نتایج

سیگنال EEG خواب مورد استفاده در این مطالعه، توسط ۱۹ کانال و از ۶ سوژه ثبت شده است، که این داده‌ها از بانک داده Physionet دریافت گردیده است. ۴ تا از این داده‌ها به منظور آموزش شبکه و از ۲ داده برای آزمون شبکه استفاده شده است. سیستم فرض شده با استفاده از نرم افزار MATLAB 7.1 Pentium Intel می‌شود. این عمل توسط یک سیستم 1.7 GHz انجام می‌شود. روند آشکار سازی به صورت off-line بر روی داده‌هایی که بر روی دیسک سخت ذخیره شده‌اند، انجام می‌شود.

جدول (۲)، نشان دهنده‌ی عملکرد سیستم برای هر مرحله، در مورد ۲ سوژه ۲ شبکه‌ی مختلف است. در هر مرحله، اندازه گیری حساسیت و نرخ آشکار سازی اشتباه، نشان داده شده است. به صورت کلی دیده می‌شود که مرحله‌ی پیش طبقه بندی دارای حساسیت میانگین ۹۸/۶٪ و آشکار سازی اشتباه میانگین ۳۲۱/۸٪ روی ثبت‌های EEG است، که خیلی زیاد است. از طرف دیگر، در مرحله‌ی پیش طبقه بندی تقریباً همه‌ی فعالیت‌های دوک‌ها آشکار سازی می‌شود، اما نرخ آشکار سازی اشتباه آن بالا است. به خاطر نرخ آشکار سازی اشتباه بالا، استفاده از یک پس طبقه بندی کننده الزامی است.

در خروجی مرحله‌ی پس طبقه بندی کننده، SVM نتیجه بهتری را نسبت به MLP نشان می‌دهد. توسط SVM، نرخ آشکار سازی اشتباه به ۳/۸۵٪ کاهش می‌یابد و حساسیت میانگین نیز مقدار ۹۱/۴٪ را خواهد داشت. در مورد MLP حساسیت میانگین برابر ۸۹/۱٪ و نرخ آشکار سازی اشتباه میانگین ۷/۳٪ است؛ در نتیجه در حالت کلی، SVM عملکرد بهتری نسبت به MLP خواهد داشت. در اینجا، یک روند دو مرحله‌ای بر اساس شبکه‌های عصبی مصنوعی، برای شناسایی اتوماتیک دوک‌های خواب در یک سیگنال EEG خواب چند کاناله معرفی می‌شود.

در مرحله‌ی اول، از یک مرحله پیش طبقه بندی به وسیله‌ی یک پرسپترون گسسته استفاده می‌شود، که می‌تواند با موفقیت، محدوده‌های غیردوک را حذف نماید. فرآیند پیش طبقه بندی موجب کاهش زمان محاسبه و همچنین موجب افزایش کارایی کلی فرآیند آشکار سازی خواهد داد.

۷- مراجع

- [1] W. R. Jankel, E. Niedermayer, "Sleep spindles", Elsevier, J. Clin. Neurophysiol, Vol. 2, pp. 1-35, 1985.
- [2] Eishi Asano, Temenuzhka ihaylova, Csaba Juhasz, Sandeep Sood, Harry T Chugani "Effect of sleep on interictal spikes and distribution of sleep spindles on electrocorticography in children with focal epilepsy", Elsevier, Clinical Neurophysiology, Vol. 118, pp. 1360-1368, 2007.
- [3] Errikos M. V entourasa, Efstratia A. Monoyiou, eriklis Y. Ktonas, Thomas Paparrigopoulos, Dimitris G. Dikeos, Niko K. Uzunoglu, Constantin R. Soldatos "Sleep spindle detection using artificial neural networks trained with filtered time-domain EEG: A feasibility study", Computer Methods and Programs in Biomedicine, Vol. 78, pp. 191-207, 2005.
- [4] Nurettin Acir, Cuneyt Guzelis "Automatic recognition of sleep spindles in EEG by using artificial neural networks", Elsevier, Expert Systems with Applications. Vol. 27, pp. 451-458, 2004.
- [5] E. Huupponen, A. Varri, L. Himanen, J. Hasan, M. Lehtokangas and J. Saarinen "Auto associative MLP in Sleep Spindle Detection", Journal of Medical Systems, Vol. 24, No. 3, 2000.
- [6] T. Shimada, T. Shiina and Y. Saito, "Detection of characteristic waves of sleep EEG by neural network analysis", IEEE Trans. Biomed. Eng. 47 (2000) 369-379.
- [7] E. Trenker, J. Hajek, P. Rappelsperber, P. Zeitlhofer, P. Anderer and G. Dorffner, "Automatic detection of sleep spindles using artificial neural networks", J. Sleep Res. 7, (1998), 280.
- [8] Allanorg Dorffner, Extractio Allan Kardec Barros, R.R., Mark Girolami, Georg Dorffner, "Extraction of Sleep-Spindles from the Electroencephalogram (EEG). Computing and Information Systems", 2003. 24.
- [9] Eero Huupponen a, G.n.G.m.-H., "Development and comparison of four sleep spindle detection methods", Artificial Intelligence in Medicine, 2007. 40: pp. 157-170.
- [10] Physionet database of sleep EEG at www.Physionet.org/physiobank/database/sleep-edf
- [11] Arnon Cohen "Biological signal processing", ISBN: 0-8493-5934-1; CRC Press, Boca Raton, Florida, 1986.

انجام پذیرد. در حالت کلی، روش اول دارای صرفه‌جویی مناسبی در وقت و هزینه می‌باشد. سیستم‌های مبتنی بر شبکه‌های عصبی که در این مقاله معرفی شده است، دارای عملکرد طبقه‌بندی مناسبی است و همچنین بهینه‌سازی مناسبی در زمان و حافظه را نیز انجام می‌دهد.

انعطاف‌پذیری^{۲۴} سیستم آشکارسازی نیز مهم است. شکل موج‌ها ممکن است بین بیماران مختلف متفاوت باشد و یا اینکه در یک ثبت نیز پیوندهای مختلف آن با هم فرق کنند؛ بنابراین سیستم بایستی نسبت به این تغییرات انعطاف‌پذیر باشد. در سیستمی که در این مقاله بیان شده، از مدل AAR برای استخراج ویژگی استفاده شده است. ARهای متداول و یا روش‌های مشابه آن را می‌توان در وضعیتی استفاده نمود که سیگنال با زمان تغییر نکند؛ اما در موقعیت واقعی، سیگنال EEG تحت تاثیر چند فاکتور است، که غیر قابل کنترل می‌باشند. بنابراین روش AR، تغییرات آهسته در طیف غیر ایستان سیگنال، مثل سیگنال‌های EEG را دنبال نمی‌کند. در این پژوهش، با تخمین پارامترهای AAR با استفاده از روش LMS بر محدودیت‌های این چنین روش‌های متعارفی غلبه می‌شود. بنابراین، این روش، یک روش پایدارتر برای داده‌هایی از سوژه‌های متفاوت می‌باشد. مقایسه‌ی روش پیشنهادی ما در این مقاله با روش پیشنهادی در مرجع شماره‌ی [۳]، [۴] و [۷] حاکی از افزایش صحت تشخیص و آشکارسازی اتوماتیک دوک‌های خواب و کاهش چشمگیر زمان محاسبه می‌باشد، اگرچه که به نظر می‌رسد استفاده از روش‌های مبتنی بر هوش مصنوعی [۹] می‌تواند صحت نتایج خروجی را بیشتر کند. لازم به ذکر است که استفاده‌ی ما در این مقاله از ماشین‌های بردار پشتیبان در مقایسه با مراجع [۵]، [۶] و [۸] موجب تکمیل و توسعه‌ی راهکارهای پیشنهادی مقالات فوق جهت افزایش دقت و صحت پروسه‌ی آشکارسازی و تشخیص دوک‌های خواب شده است. پیشنهاد می‌شود در مطالعات آتی با انتخاب ۱۲ سوژه، برابر با تعداد سوژه‌های مرجع شماره‌ی [۹]، مقایسه‌ی بهینه‌ای بین روش پیشنهادی ما و روش مبتنی بر هوش مصنوعی صورت پذیرد.

[۱۲] امین‌الله گلرو، محمد حسین خاکسار و سعید راحتی قوچانی،
"آشکارسازی اتوماتیک دوک خواب توسط ماشین بردار
پشتیبان و شبکه‌های عصبی مصنوعی"، اولین کنفرانس
ملی برق ایران، دانشگاه آزاد اسلامی واحد نجف آباد، اسفند ماه
۱۳۸۶.

۸- پی‌نوشت‌ها

-
- 1 - Non Rapid Eye Movement
 - 2 - Rapid Eye Movement
 - 3 - Sleep spindle
 - 4 - Vertex waves
 - 5 - K-Complex
 - 6 - Post Synaptic Potentials
 - 7 - Electroencephalogram
 - 8 - Template matching
 - 9 - Matching pursuit
 - 10 - Wavelet transform
 - 11 - Electromyogram
 - 12 - Electrooculogram
 - 13 - Sleep spindle candidates
 - 14 - Adaptive Auto Regressive
 - 15 - Auto Regressive
 - 16 - Least mean square
 - 17 - Shifting
 - 18 - Discrete perceptron
 - 19 - Radial basis-support vector machine
 - 20 - Supervised classification problems
 - 21 - Sensitivity
 - 22 - False detection
 - 23 - Back propagation
 - 24 - Flexibility