

Automatic Stage Scoring of Single-Channel Sleep EEG using CEEMD of Genetic Algorithm and Neural Network

S. Sheykhivand, MSc Student¹, T. Yousefi Rezaii, Assistant Professor², Z. Mousavi³, PhD Student, S. Meshgini⁴, Assistant Professor

¹ Faculty of Electrical and Computer Engineering, University of Tabriz, Tabriz, Iran, s.sheykhivand95@tabrizu.ac.ir

² Faculty of Electrical and Computer Engineering, University of Tabriz, Tabriz, Iran, yousefi@tabrizu.ac.ir

³ Department of Mechanical Engineering, University of Tabriz, Tabriz, Iran, z.mousavi2014@yahoo.com

⁴ Faculty of Electrical and Computer Engineering, University of Tabriz, Tabriz, Iran, meshgini@tabrizu.ac.ir

Abstract:

Using an intelligent method to automatically detect sleep patterns in medical applications is one of the most important challenges in recent years to reduce the workload of physicians in analyzing sleep data through visual inspection. In this paper, a single-channel EEG-based algorithm is presented for automatic recognition of sleep stages using complete ensemble empirical mode decomposition and combined model of genetic algorithm and neural network. The signal is decomposed into IMFs using the complete ensemble empirical mode decomposition and statistical properties of each of the inherent state functions are extracted. In order to optimize and reduce the dimension of the feature vectors, a hybrid model of genetic algorithm and multi-layer propagation neural network is used. Then, McNemar's test is used to confirm the accuracy of the selected features. The final classification is performed on these optimized properties by a perceptron neural network with a hidden layer. On the average, classification accuracy of 98.9%, 97.1%, 96.7%, 94.8% and 93.8% are obtained respectively for 2, 3, 4, 5 and 6 classes with corresponding Kappa cohen coefficients of 0.98, 0.95, 0.95, 0.83 and 0.90. The results prove that the proposed sleep stage classification method has better performance compared to the previously existing methods.

Keywords: EEG, GA, CEEMD, Neural network, Statistical features.

شناسایی خودکار مراحل خواب از سیگنال EEG تک کاناله با استفاده از تجزیه حالت

تجربی دسته‌ای کامل و مدل ترکیبی الگوریتم ژنتیک و شبکه عصبی

سبحان شیخی‌وند^۱، توحید یوسفی رضایی^۲، زهره موسوی^۳، سعید مشگینی^۴

۱- دانشجوی کارشناسی ارشد، دانشکده مهندسی برق و کامپیوتر، دانشگاه تبریز، تبریز، ایران

۲- استادیار، دانشکده مهندسی برق و کامپیوتر، دانشگاه تبریز، تبریز، ایران

۳- دانشجوی دکتری، دانشکده مهندسی مکانیک، دانشگاه تبریز، تبریز، ایران

s.shekhivand95@ms.tabrizu.ac.ir, yousefi@tabrizu.ac.ir, z.mousavi2014@yahoo.com
meshgini@tabrizu.ac.ir

چکیده: استفاده از روشی هوشمند برای تشخیص خودکار مراحل خواب در کاربردهای پزشکی به منظور کاهش حجم کار پزشکان در تجزیه و تحلیل داده‌های خواب با بازرسی بصری یکی از مسئله‌های مهم در سال‌های اخیر است. در این مقاله، الگوریتمی مبتنی بر EEG تک‌کاناله برای شناسایی خودکار مراحل خواب با استفاده از روش تجزیه حالت تجربی دسته‌ای کامل و مدل ترکیبی الگوریتم ژنتیک و شبکه عصبی ارائه می‌شود. سیگنال با استفاده از تجزیه حالت تجربی دسته‌ای کامل به توابع حالت ذاتی خود، تجزیه و ویژگی‌های آماری از هریک از توابع حالت ذاتی استخراج می‌شود. برای بهینه‌سازی و کاهش ابعاد بردارهای ویژگی از مدل ترکیبی الگوریتم ژنتیک و شبکه عصبی چندلایه پس انتشار خطا استفاده شده است. سپس از آزمون مک‌نمار برای تأیید صحت و ویژگی‌های بهینه استفاده می‌شود. شبکه عصبی پرسپترون با یک لایه پنهان، طبقه‌بندی نهایی روی این ویژگی‌های بهینه‌شده را انجام می‌دهد و به‌طور میانگین برای طبقه‌بندی ۲-کلاس تا ۶-کلاس، مراحل مختلف خواب به ترتیب صحت ۹۸/۹۰٪، ۹۷/۱۰٪، ۹۶/۷۰٪، ۹۴/۸۰٪ و ۹۳/۸۰٪ ضریب کاپا کوهن ۰/۹۸، ۰/۹۵، ۰/۹۵، ۰/۸۳ و ۰/۹ را فراهم می‌کند و نشان می‌دهد روش پیشنهادی، درصد موفقیت بیشتری در طبقه‌بندی مراحل خواب نسبت به پژوهش‌های پیشین دارد.

واژه‌های کلیدی: EEG، الگوریتم ژنتیک، تجزیه حالت تجربی دسته‌ای کامل، شبکه عصبی، ویژگی‌های آماری

۱- مقدمه

دفاعی بدن را سبب می‌شود [۱]. همچنین باعث ایجاد خواب‌آلودگی، نداشتن تمرکز و کاهش حافظه خواهد شد [۲]. پزشک متخصص در درمان بالینی، تجزیه و تحلیل مراحل خواب را به‌طور معمول براساس بررسی بصری، با خوابیدن بیمار در بیمارستان و اندازه‌گیری‌های پلیسومنوگرافی^۱ (PSG) با مجموعه‌ای از توصیه‌های آکادمی پزشکی AASM انجام می‌دهد [۳]. اندازه‌گیری‌های PSG شامل الکتروانسفالوگرام^۲ (EEG)، الکترومایوگرام^۳ (EMG) و الکترواکولوگرام^۴ (EOG) است [۴]. در روش سنتی، در طول مدت ۸ ساعت خواب، بازرسی بصری ۲ تا ۴ ساعت روی فرد مدنظر انجام می‌شود. نظارت مراحل خواب به

فعالیت‌های سوخت‌وساز مغز در فرد پس از ۲۴ ساعت بیداری پایدار به‌طور چشمگیری کاهش می‌یابد. محرومیت از خواب، کاهش درجه حرارت بدن، کاهش آزادسازی هورمون رشد، تغییر ریتم ضربان قلب و ضعف سیستم

^۱ تاریخ ارسال مقاله: ۱۳۹۶/۱۱/۲۸

تاریخ پذیرش مقاله: ۱۳۹۷/۰۳/۲۳

نام نویسنده مسئول: توحید یوسفی رضایی

نشانی نویسنده مسئول: ایران، تبریز، دانشگاه تبریز، دانشکده برق و کامپیوتر

[۱۹] و تجزیه حالت تجربی^۵ [۲۰] برای پردازش سیگنال در جداسازی مراحل خواب استفاده می‌شوند. همچنین برای بخش طبقه‌بندی، مدل‌های مختلفی استفاده می‌شود که شامل ماشین بردار پشتیبان^۱ [۱۵]، شبکه عصبی^۷ [۱۷] و حداقل مربعات جزئی^۸ [۱۸] هستند. رونزینا و همکاران با استفاده از از چگالی طیفی توان^۹ (PSD) سیگنال‌های EEG به همراه شبکه عصبی مصنوعی، طرح مبتنی بر EEG تک‌کاناله را ارائه دادند [۲۱]. لاجنل و همکاران از ویژگی‌های مختلف از قبیل آنتروپی، خطای پیش‌بینی خطی، واریانس، چولگی، کشیدگی، آنتروپی پیمایش و ماشین بردار پشتیبان چندطبقه روی EOG، EMG و EEG برای ثبت خودکار مراحل خواب استفاده کردند [۸]. پکر و همکاران، ترکیبی از تبدیل موجک (DT-CWT) و شبکه عصبی مبتنی بر تاگوچی را برای ثبت خودکار مراحل خواب از یک کانال EEG استفاده کرده‌اند [۲۱]. کراکستا و همکاران، ویژگی‌های بسیاری از جمله دامنه متوسط، واریانس و قدرت طیفی را از داده‌های جمع‌آوری شده از شش کانال EEG، دو کانال EOG و یک کانال EMG، استخراج و با استفاده از معیارهای درجه دوم تحلیل و بررسی کردند [۲۲]. لیانگ و همکاران با استفاده از ویژگی‌های مبتنی بر آنتروپی Renyi استخراج شده، از توزیع فرکانس‌های مختلف برای شناسایی مراحل مختلف خواب با EEG تک‌کانال استفاده کردند [۲۳]. زو و همکاران، گراف دیداری و گراف افقی را از سیگنال EEG تک‌کاناله تولید کردند و نه ویژگی از آنها را برای طبقه‌بندی با استفاده از ماشین بردار پشتیبان به کار گرفتند [۱۵]. کیکسیگولو، طرح استخراج ویژگی مبتنی بر فناوری مدل خودبازگشتی^{۱۰} (AR) و الگوریتم حداقل مربعات جزئی^{۱۱} (PLS) را برای طبقه‌بندی مراحل خواب ارائه داد [۱۸].

روش تجزیه حالت تجربی از مهم‌ترین روش‌های پردازش سیگنال در حوزه زمان - فرکانس است که هوانگ و همکاران (۱۹۹۸) آن را معرفی و مطالعه کردند [۲۴]. با اعمال این روش هر سیگنال به تعدادی تابع حالت ذاتی تجزیه می‌شود و در پردازش سیگنال‌های غیرخطی و غیرثابت استفاده می‌شوند. امکان تعیین فرکانس لحظه‌ای سیگنال با ترکیب این روش با تبدیل هیلبرت از جمله مزایای روش تجزیه حالت تجربی است. اگرچه روش تجزیه حالت

شیوه سنتی براساس بررسی بصری به‌علت خستگی و نیازمند بودن به منابع انسانی متخصص، امری ناخوشایند، وقت‌گیر و همراه خطا است [۵، ۶]. همچنین موجب صحت زیر ۹۰٪ در تحلیل و تشخیص بیماری فرد مدنظر خواهد شد [۷]. در آزمایش‌های بالینی نیز در برخی موارد ممکن است به تشخیص سریع مراحل خواب نیاز باشد [۸، ۹]. تجزیه و تحلیل مراحل خواب به شیوه سنتی با چنین شرایطی مراحل خواب را نشان نمی‌دهد. عوامل ذکر شده اهمیت دسته‌بندی خودکار را نشان می‌دهد. همچنین، این عامل بر مطالعه روی افراد در مقیاس وسیع در تحقیقات خواب به شدت تأثیر می‌گذارد [۱۰، ۱۱]. بررسی خودکار فرایند تجزیه و تحلیل مراحل خواب علاوه بر اینکه موجب تشخیص سریع می‌شود افزایش صحت در تشخیص را نیز سبب خواهد شد [۱۲]. PSG فرایندی پرهزینه و برای بیمار ناخوشایند است و مناسب نیست [۱۳، ۱۴]؛ با این حال، ثبت داده و تجزیه و تحلیل با اندازه‌گیری‌های PSG با تعدادی از چالش‌های فنی به‌ویژه در خانه مواجه است؛ به همین دلیل سیگنال‌های EEG برای ثبت داده بسیار ساده‌تر هستند و جایگزین مناسبی برای نظارت بر خواب در خانه محسوب می‌شوند. بیشتر الگوریتم‌های شناسایی خودکار مراحل خواب به منظور تشخیص صحیح به بیش از یک کانال نیاز دارند. شناسایی خودکار مراحل خواب مبتنی بر چندکانال محدودیت‌هایی ایجاد می‌کند و باعث کاهش کیفیت ثبت داده خواهد شد [۱۵]؛ بدین ترتیب، استفاده از سیگنال‌های حاصل از EEG به الگوریتم مکان‌یابی سیگنال خواب برای استفاده از حداقل تعداد کانال‌های سیگنال فیزیولوژیک نیاز دارد [۱۶]. استفاده از کانال سیگنال EEG، ضمن راحتی بسیار برای بیمار، در دستگاه‌های پرتابل EEG باعث افزایش عمر باتری خواهد شد. همچنین، تشخیص تک‌کاناله سریع‌تر (حجم محاسباتی کمتر)، از نظر جایگذاری الکترودها راحت‌تر و از نظر هزینه ارزان‌تر خواهد بود [۱۱]؛ در نتیجه، شناسایی خودکار مراحل خواب مبتنی بر یک کانال، توجه جامعه تحقیق خواب را به خود جلب کرده است.

روش‌های مختلفی مانند توزیع زمان و فرکانس [۱۷]، نظریه گراف [۱۵]، مدل‌سازی سیگنال [۱۸]، تبدیل موجک

جدول (۱): شرح کلاس‌های مختلف در این کار

کلاس	حالت‌های خواب
۶	REM, AWA, S1, S2, S3, S4
۵	REM, AWA, S1, S2, SWS (S3-S4)
۴	REM, AWA, S1-S2, SWS (S3-S4)
۳	REM, AWA, NREM (S1-S4)
۲	Sleep (REM & NREM), AWA

ادامه مقاله به صورت زیر تدوین شده است؛ بخش ۲، طرح استخراج ویژگی‌ها را مشخص کرده است و عملکرد آن را تجزیه و تحلیل می‌کند. سپس انتخاب ویژگی‌ها، الگوریتم GA و شبکه عصبی توضیح داده می‌شود. در بخش ۳، داده‌های آزمایشی و نتایج تجربی بررسی می‌شوند. بخش ۴ درباره اهمیت نتایج بحث می‌کند؛ در نهایت، بخش ۵ به نتیجه‌گیری مربوط می‌شود.

۲- مواد و روش‌ها

در این بخش ابتدا استخراج ویژگی‌ها تشریح می‌شود و سپس انتخاب ویژگی‌ها، الگوریتم GA و شبکه عصبی بررسی می‌شوند. شکل (۱) طرح کلی از روش پیشنهادی را ارائه می‌دهد.



شکل (۱): فلوچارتی از طرح پیشنهادی برای شناسایی خودکار مراحل خواب

۲-۱- تجزیه حالت تجربی دسته‌ای کامل^{۱۷} (CEEMD)

هر سیگنال با استفاده از روش تجزیه حالت تجربی به مجموعه‌ای از توابع تک مؤلفه‌ای به نام توابع حالت ذاتی تجزیه خواهد شد. یک تابع حالت ذاتی مشابه یک تابع هارمونیک است، با این تفاوت که مانند یک تابع هارمونیک دامنه و بسامد ثابت ندارد و بسامدهای گوناگونی با

تجربی یکی از قوی‌ترین روش‌های پردازش سیگنال است، مشکلاتی همچون پدیده اختلاط حالت‌ها و نداشتن معیار توقف قوی در فرایند غربال را دارند. فلاندرین و همکاران (۲۰۰۵) برای رفع برخی از مشکلات روش تجزیه حالت تجربی، افزودن نویز سفید را پیشنهاد کردند [۲۵]. هوانگ و همکاران (۲۰۰۹)، روش تجزیه حالت تجربی دسته‌ای^{۱۸} را برای رفع مشکل اختلاط حالت‌ها معرفی کردند [۲۶]. تیسنالس و همکاران، تجزیه و تحلیل زمان فرکانس را برای استخراج ویژگی انجام دادند و برای طبقه‌بندی از الگوریتم رمزگذار خودکار انباشته شده استفاده کردند [۱۷]. باتوجه به مطالعات انجام شده در پژوهش‌های پیشین، معلوم شد بیشتر الگوریتم‌های موجود برای شناسایی خودکار مراحل خواب به بیش از یک کانال نیاز دارند؛ بنابراین، این موضوع برای بیمار ناراحت‌کننده است و مانع سنجش دستگاه نظارت خواب در خانه می‌شود. همچنین معلوم شد پژوهش‌های پیشین در طبقه‌بندی مراحل مختلف خواب صحت زیر ۹۰٪ ارائه دادند و از نظر محاسباتی پیچیده و زمان‌بر هستند. این نکته کلیدی پژوهشی است که در این مقاله بررسی خواهد شد.

در این مقاله برای شناسایی خودکار مراحل خواب از روش تجزیه حالت تجربی دسته‌ای کامل و مدل ترکیبی الگوریتم ژنتیک و شبکه عصبی استفاده شده است. این پژوهش مبتنی بر شش حالت خواب مطابق با استاندارد R & K^{۱۹} است که شامل حالت بیدار (AWA)، مراحل حرکتی غیرسریع چشم (S1-S4) و حرکت سریع چشم (REM) است. این کلاس‌ها در جدول (۱) شرح داده شده است. در روش پیشنهادی، سیگنال با استفاده از روش تجزیه حالت تجربی دسته‌ای کامل به توابع حالت ذاتی خود، تجزیه و چند ویژگی آماری از هر یک از توابع حالت ذاتی استخراج می‌شود. سپس با استفاده از ترکیب الگوریتم ژنتیک^{۱۴} (GA) و شبکه عصبی (MLP^{۱۵}) ویژگی‌های مهم، انتخاب و به‌منزله ورودی طبقه‌بند (BPNN^{۱۶}) برای تفکیک کلاس‌ها از یکدیگر استفاده می‌شوند.

$$r_k = r_{(k-1)} - IMF_k \quad (4)$$


۵- برای محاسبه IMF_{k+1} ام از $i=1, 2, 3, \dots$ مقدار IMF مانند قسمت اول حساب می‌شود.

$$IMF_{(k+1)} = \frac{1}{I} \sum_{i=1}^I E_1[r_k + \varepsilon E_k[w_i]] \quad (5)$$

۶- این فرایند تا زمانی تکرار می‌شود که باقی‌مانده بیش از ۲ اکستریم نداشته باشد.

حال با داشتن IMFها، فرکانس لحظه‌ای با تبدیل هیلبرت محاسبه می‌شود. فرکانس لحظه‌ای به دست آمده از هر IMF با تبدیل هیلبرت به صورت نمایشی دوبعدی از فرکانس لحظه‌ای متغیر نمایش داده می‌شود.

CEEMD به طور کامل بر داده‌ها مبتنی است و برخلاف تبدیل موجک به عمل پیش فرض پایه تکیه نمی‌کند. این دو ویژگی، CEEMD را به ابزار مناسب برای تحلیل سیگنال‌های غیرخطی و غیرثابت مانند EEG تبدیل می‌کند. CEEMD، مسئله اختلاط موج‌ها را نیز حل خواهد کرد. شکل (۲) نشان دهنده تفاوت در میان IMFها برای مراحل مختلف خواب است.



شکل (۲): IMF4 و IMF5 استخراج شده از CEEMD

دامنه‌های متفاوت دارد. در هر مرحله از تجزیه سیگنال به مؤلفه‌های فرکانسی آن، ابتدا مؤلفه‌هایی با فرکانس بالا جدا می‌شوند و این روند ادامه پیدا می‌کند تا در نهایت مؤلفه‌ای با کمترین فرکانس باقی بماند [۲۴]. اختلاط حالت‌ها شاید رایج‌ترین مسئله‌ای است که هنگام کار با الگوریتم تجزیه حالت تجربی با آن مواجه خواهیم شد. یک سیگنال خاص ممکن است هر بار به توابع حالت ذاتی یکسانی جداسازی نشود؛ این مشکل، کار را برای استخراج ویژگی، آموزش مدل و تشخیص الگو سخت می‌کند. روش تجزیه حالت تجربی دسته‌ای با نظریه اضافه کردن نویز سفید در تمام مراحل تجزیه سیگنال برای حل این مشکل معرفی شد. این کار پدیده اختلاط حالت‌ها را به طور مؤثری از بین خواهد برد. همه داده‌ها تقریباً به نویز آغشته‌اند. در مواردی داده‌ها از مشاهدات جداگانه‌ای به دست می‌آیند که خود به نویزهای مختلفی آغشته‌اند [۲۶، ۲۷]. روش تجزیه حالت تجربی دسته‌ای کامل در جداسازی طیفی حالت‌ها نسبت به روش تجزیه حالت تجربی دسته‌ای عملکرد بهتری را نشان می‌دهد و در تکرارهای کمتری به جواب می‌رسد؛ در نتیجه، از لحاظ محاسباتی هزینه کمتری دارد.

روش تجزیه حالت تجربی دسته‌ای کامل در مراحل زیر بیان می‌شود [۲۸]:

۱- ابتدا در هر مرحله، درصدی از نویز گوسین به داده اضافه می‌شود. برای I نویز مختلف گوسی EMD انجام می‌شود و مقدار IMF اول از میانگین I مود به دست می‌آید.

$$IMF_1 = \frac{1}{I} \sum_{i=1}^I E_1[x + \varepsilon w_i] \quad (1)$$

۲- سپس مقدار r_1 از رابطه زیر محاسبه می‌شود.

$$r_1 = x - IMF_1 \quad (2)$$

۳- برای به دست آوردن IMF2 باید از مقدار $IMF, r_{1+\varepsilon} E_1[w_i]$ را به دست آورد که مانند قسمت اول $i=1, 2, 3, \dots$ است.

$$IMF_2 = \frac{1}{I} \sum_{i=1}^I E_1[r_1 + \varepsilon E_1[w_i]] \quad (3)$$

۴- برای $K=2, \dots, k$ مقدار باقی‌مانده K ام به صورت زیر حساب می‌شود.

۲-۲- ویژگی‌ها

پس از تجزیه سیگنال به توابع حالت ذاتی خود، نه ویژگی آماری از هر یک از توابع حالت ذاتی گرفته می‌شود. این ویژگی‌ها در زیر ارائه شده‌اند:

۱- توان

$$power(x(n)) = \frac{\sum_{n=1}^N (x(n))^2}{N} \quad (6)$$

که $x(n)$ سیگنال اصلی و N تعداد نمونه‌های سیگنال خواهد بود.

۲- میانگین

$$Mean(x(n)) = \frac{\sum_{n=1}^N x(n)}{N} \quad (7)$$

۳- واریانس

$$\sigma^2 = \frac{1}{M} \sum_{i=0}^M (x_i - \mu)^2 \quad (8)$$

۴- انحراف از معیار استاندارد

این ویژگی میزان پراکندگی مقادیر سیگنال نسبت به میانگین را نشان می‌دهد. هنگامی که میانگین سیگنال به سمت صفر میل کند، انحراف از معیار و میزان مؤثر سیگنال با هم برابر می‌شوند.

$$STD(x(n)) = \sqrt{\frac{\sum_{n=1}^N (x(n) - Mean(x(n)))^2}{N-1}} \quad (9)$$

۵- کشیدگی

این ویژگی کشیدگی تابع چگالی احتمال سیگنال به یک سمت را نشان می‌دهد که به صورت زیر محاسبه می‌شود:

$$Kurtosis = \frac{1}{N} \sum_{i=1}^N \left(\frac{x_i - \mu}{\sigma} \right)^4 \quad (10)$$

۶- چولگی

چولگی، معیاری از تقارن یا عدم تقارن تابع توزیع است و به صورت زیر محاسبه می‌شود.

$$Skewness = \frac{1}{N} \sum_{i=1}^N \left(\frac{x_i - \mu}{\sigma} \right)^3 \quad (11)$$

۷- گشتاور مرتبه ۴

مقدار نرمال شده سیگنال نسبت به میانگین را نشان می‌دهد؛ این ویژگی به صورت زیر محاسبه می‌شود.

$$Mumentum_4 = \frac{\sum_{n=1}^N (x(n) - Mean(x(n)))^4}{(N-1)} \quad (12)$$

۸- فاکتور ضربه

این ویژگی، ماهیت ضربه‌ای سیگنال را بیان می‌کند و برای پایش سیگنال‌های با تغییرات زیاد و گذرا بسیار کاربرد دارد؛ این ویژگی به صورت زیر محاسبه می‌شود.

$$Impulse Factor = \frac{Max(x(n))}{\frac{1}{N} \sum_{n=1}^N |x(n)|} \quad (13)$$

۹- انرژی

میزان انرژی یک سیگنال بیان‌کننده میزان اغتشاش آن است؛ این ویژگی به صورت زیر محاسبه می‌شود.

$$Energy = \sum_{n=1}^N (x(n))^2 \quad (14)$$

در این مقاله، یازده حالت ذاتی اول برای استخراج ویژگی به کار برده شده است که در مجموع $9 \times 11 = 99$ ویژگی استخراج می‌شود. با در نظر گرفتن وابستگی ویژگی‌های ۳ و ۴ و همچنین ویژگی‌های ۶ و ۷ به یکدیگر با استخراج ویژگی از هر IMF، ویژگی‌های مطلوب انتخاب شده است.

۲-۳- انتخاب و کاهش ویژگی‌های آماری مطلوب

پس از استخراج ویژگی‌ها، ویژگی‌های مطلوب، انتخاب و ویژگی‌های نامطلوب حذف می‌شوند. انتخاب ویژگی راه‌حل قطعی ندارد؛ ولی با تبدیل آن به مسئله بهینه‌سازی و با کمک الگوریتم‌های متنوع، به خصوص الگوریتم‌های هوشمند، ویژگی‌های مناسب انتخاب می‌شوند. در روش پیشنهادی برای یافتن ویژگی‌های مناسب از مدل ترکیبی الگوریتم GA و شبکه عصبی MLP استفاده شده است و در ادامه از آزمون مک‌نمار (McNemar's) برای تأیید صحت ویژگی‌های مطلوب استفاده می‌شود که سطح معناداری آماری دارند.

۲-۴- ساختار ترکیبی شبکه MLP و GA

در روش پیشنهادی برای جستجوی ویژگی‌های بهینه به کمک الگوریتم ژنتیک، ابتدا جمعیت اولیه شامل ۲۰

$$fitness\ function = \frac{1}{MSE(net)} \quad (20)$$

در این مقاله پس از استخراج ویژگی‌ها از هریک از توابع حالت ذاتی، برای انتخاب ویژگی‌های مطلوب، از مدل ترکیبی الگوریتم ژنتیک و شبکه عصبی استفاده می‌شود و ۹۹ ویژگی استخراج شده از توابع حالت ذاتی به ۲۹ ویژگی کاهش می‌یابد.

۲-۴-۱- تأیید ویژگی‌های انتخابی با استفاده از

آنالیز آماری

در این مقاله از آزمون مک‌نمار برای تأیید صحت ویژگی‌های بهینه‌شده حاصل از الگوریتم ژنتیک استفاده می‌شود. آزمون‌ها در نرم‌افزار پایتون در سطوح اطمینان ۹۵٪ انجام می‌شوند. ویژگی‌ها قبل و بعد از بهینه‌سازی با استفاده از این آزمون آزمایش می‌شوند. اگر p-value حاصل شده بعد از انجام این آزمون، کوچک‌تر از ۰/۰۵ باشد، صحت ویژگی‌های انتخابی تأیید خواهد شد.

۳- بررسی نتایج

۳-۱- مجموعه داده‌های EEG

ثبت داده استفاده شده برای آزمایش و ارزیابی مربوطه از مردان و زنان قفقازی (۲۱-۳۵ ساله) بدون استفاده از هیچ دارویی به دست آمده است. این داده‌ها از بانک Sleep-EDF در پایگاه Physionet Data Bank دریافت می‌شوند که پایگاه عمومی برای دریافت داده EEG است [۳۱].

هشت داده در دو زیرمجموعه با عنوان‌های st و sc طول خواب ثبت شده است. چهار داده اول با عنوان sc مربوط به افراد سالم و چهار داده دوم با عنوان st مربوط به افراد دچار خواب‌آلودگی خفیف است. برای ثبت داده از الکترودهای Pz-Oz و Fpz-Cz استفاده شده است. همچنین، فرکانس نمونه‌برداری ۱۰۰ هرتز است [۳۲].

مطالعات پیشین نشان می‌دهد سیگنال EEG ثبت شده از کانال Pz-Oz نسبت به کانال Fpz-Cz عملکرد بهتری در طبقه‌بندی ارائه می‌دهد [۱۲، ۲۳]؛ بنابراین در این مطالعه از کانال Pz-Oz استفاده شده است. هر ۳۰ ثانیه داده‌های EEG مطابق با دستورالعمل‌های R & K از پایگاه Sleep-EDF به

کروموزوم تولید می‌شود. ژن‌های این کروموزوم‌ها به صورت باینری است و تنها مقادیر صفر و یک دارند؛ مقدار یک نشان‌دهنده وجود ویژگی با اندیس مربوطه و مقدار صفر نشان‌دهنده نبود ویژگی مدنظر در ساختار الگوی ژنی است. مراحل الگوریتم ژنتیک با تقابل تک‌نقطه‌ای و جهش‌های وارونه‌ساز صورت گرفته است. در مسئله بهینه‌سازی، فضای جستجو باتوجه به قاعده شمارش n^r برابر است با:

$$Energy\ function : 2^{\text{number of features}} = 2^{99} = 6.33 \times 10^{29}$$

مشاهده می‌شود ابعاد فضای جستجو برابر $10^{29} \times 6.33$

حالت است.

شبکه عصبی، شبکه چندلایه پرسپترون تحت قاعده پس‌انتشار خطا با استفاده از تابع آموزش با عنوان لونبرگ - مارکوات است. معماری شبکه عصبی به صورت feed-forward در نظر گرفته شده است [۲۹]. در هر بار آموزش شبکه عصبی مقدار ۵۰٪ داده‌ها، مجموعه آموزشی و ۵۰٪ داده‌ها مجموعه آزمایشی به کار گرفته می‌شوند؛ در نهایت مقدار MSE^{18} شبکه برای هر بردار ویژگی ورودی، محاسبه و برای محاسبه خطای شبکه عصبی از روابط زیر استفاده می‌شود:

$$net_j = \sum_{i=0}^m w_{ji}(n)y_i(n) \quad (15)$$

$$y_j = f_j(net_j) \quad (16)$$

$$e_j(n) = d_j(n) - y_j(n) : Error \quad (17)$$

که d، خروجی هدف و y_j خروجی حاصل از شبکه است. مقدار e نیز خطای عملکردی شبکه است؛ بنابراین، خطای کل خروجی شبکه عصبی ξ ، به‌ازای c نورون در لایه خروجی برابر است با:


$$\xi(n) = \sum_{j=c} e^2(n) : total\ Error \quad (18)$$

همچنین، مقدار MSE شبکه برای N داده آموزشی برابر خواهد بود با:

$$MSE = \xi_{ave} = \frac{1}{N} \sum_{n=1}^N \xi(n) \quad (19)$$

پس از آموزش شبکه عصبی برای هر ۲۰ کروموزوم ورودی اولیه به شبکه، مقدار $\frac{1}{MSE}$ ، تابع برازندگی الگوریتم ژنتیک، به صورت زیر محاسبه می‌شود [۳۰]:

جدول (۴)، نتایج حاصل از آزمون مک‌نمار را نشان می‌دهد. طبق جدول (۴) برای مدل اول ۹۹ ویژگی (قبل از بهینه‌سازی) و برای مدل دوم ۲۹ ویژگی (بعد از بهینه‌سازی) با الگوریتم ژنتیک) در آزمون استفاده شده است که پس از انجام آزمایش مشخص شد ویژگی‌های بهینه‌شده با $p\text{-value} = 3/64 * e^{-11}$ صحت کافی را ندارند. باتوجه به جدول (۳) و جدول (۴) نتیجه گرفته می‌شود ۲۹ ویژگی انتخابی از مدل ترکیبی الگوریتم ژنتیک و شبکه عصبی ویژگی‌های مطلوبی هستند.



شکل (۳): همگرایی GA در ترکیب با شبکه عصبی MLP

۲-۳- طبقه‌بندی با استفاده از BPNN

در این بخش، طبقه‌بند، جزئیات و نتایج آزمایش‌ها، بررسی و برخی از اهمیت نتایج بیان می‌شود. مشخصات رایانه‌ای استفاده‌شده در شبیه‌سازی این مقاله،

دست آمده است [۳۳]. طول مدت زمان هر دوره در این مطالعه ۳۰ ثانیه یا ۳۰۰۰ نمونه است. متخصصان خواب، هر دوره را در یکی از هشت کلاس AWA، S1، S2، S3، S4، REM، MVT (زمان حرکت) و UNS (حالت‌های ناشناخته) دسته‌بندی کرده‌اند. جدول (۲) خلاصه‌ای از دوره‌های مختلف کلاس‌های استفاده‌شده در این کار را نشان می‌دهد. با توجه به جدول (۲)، تعداد کل دوره‌های ۳۰ ثانیه‌ای ۱۵۱۸۸ است که در این مطالعه استفاده می‌شود. برای انجام آزمایش‌ها نیمی از مجموعه داده‌های خواب-Sleep-EDF به‌طور تصادفی برای آموزش مجموعه و بقیه داده‌ها برای ارزیابی مجموعه انتخاب شده‌اند؛ بدین ترتیب، اطمینان حاصل شده است که تمام مجموعه داده‌های Sleep-EDF برای آموزش یا آزمون استفاده می‌شوند.

جدول (۲): توزیع دوره‌ها از مجموعه داده‌های پایگاه Sleep-EDF

	AWA	S1	S2	S3	S4	REM
تعداد	۱۸۰۵۵	۶۰۴	۳۶۲۱	۶۷۲	۶۲۷	۱۶۰۹
ایبک						

۲-۴- نتایج حاصل از بهینه‌سازی

پس از ۲۰ بار تولید نسل، آموزش‌های مداوم شبکه عصبی MLP و تولید بردارهای ویژگی تصادفی، در نهایت الگوریتم ژنتیک به سمت نسل بهینه همگرا می‌شود؛ شکل (۳) این همگرایی را نشان می‌دهد. تمام نسل‌ها در خروجی آن، بردارهایی کاملاً یکسان و بهینه خواهند بود. جدول (۳)، مقادیر p-value و ویژگی‌های انتخاب‌شده

جدول (۳): p-value و ویژگی‌های انتخاب‌شده از IMFها

	توان	میانگین	انحراف معیار	کشیدگی	چولگی	فاکتور ضربه	گشتاور مرتبه ۴	انرژی	واریانس
IMF1	-	۰/۰۰	-	-	-	-	-	-	-
IMF2	-	۰/۰۰	۰/۰۰	۱/۸۹e-۱۱۷	-	-	۱/۳۹e-۷۰	-	-
IMF3	-	-	-	-	۰/۰۰	-	۰/۰۰	-	۰/۰۰
IMF4	-	-	-	-	۰/۰۰	-	۲/۶۳e-۱۶۱	-	-
IMF5	-	-	-	-	-	-	۵/۱۲e-۱۰۳	۵/۵۹e-۲۵	-
IMF6	۷/۰۹e-۲۰۱	-	۱/۲۳e-۹۱	۱/۸۵e-۲۲۸	۴/۱۸e-۲۲۴	۲/۲۸e-۱۲۵	-	-	۴/۷۶e-۱۱۶
IMF7	۲/۴e-۷۰	-	۳/۹۰e-۸۶	-	-	-	۸/۴۲e-۲۲۶	-	۱/۸۱e-۱۷۱
IMF8	-	-	-	۰/۰۰	-	۰/۰۰	-	-	-
IMF9	۰/۰۰	-	۹/۲۴e-۳۶	-	-	-	-	-	-
IMF10	-	-	-	-	-	-	-	۰/۰۰	-
IMF11	-	-	۳/۵۳e-۱۵۹	۰/۰۰	-	-	-	-	-

جدول (۴): تأیید ویژگی‌های قبل و بعد از بهینه‌سازی با استفاده از آزمون مک‌نمار

مدل اول با	مدل اول با
۹۹ ویژگی	۹۹ ویژگی
(نادرست)	(صحیح)
۳۰۹	۵۴۱۲
۹۳	۴۹۸

p-value حاصل شده از آزمون مک‌نمار = $e^{-11} * 3/64$

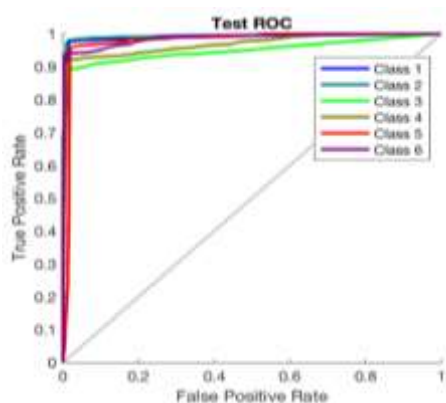
اینتل Core (TM) i5-3470، پردازنده ۱/۶ گیگاهرتز و رم ۸ گیگابایت است.

در این مقاله برای طبقه‌بندی حالت‌های مختلف خواب از شبکه عصبی پرسپترون چندلایه با الگوی پس‌انتشار خطا با استفاده از تابع آموزشی لونیبرگ - مارکوات استفاده می‌شود. شبکه BPNN استفاده شده در این مقاله شبکه‌ای دولایه بوده و تعداد ورودی‌های شبکه برابر تعداد ویژگی‌های بهینه شده است. برای تعیین تعداد نورون‌های لایه مخفی چندین بار آموزش شبکه عصبی با تعداد نورون‌های مختلف انجام گرفته است. در هر بار آموزش شبکه، خطای طبقه‌بندی، محاسبه و در انتها بهترین تعداد برای نورون‌های لایه مخفی شبکه تعیین می‌شود. برای این منظور از کل داده‌های موجود از پایگاه sleep-EDF برای شبیه‌سازی استفاده شده است؛ به گونه‌ای که ۵۰٪ داده‌ها برای مجموعه آموزشی، ۲۰٪ داده‌ها برای مجموعه اعتبارسنجی و ۳۰٪ داده‌ها برای مجموعه آزمایشی استفاده شده‌اند. نتیجه گرفته می‌شود با در نظر گرفتن ۳۰ نورون در لایه مخفی، شبکه بهترین عملکرد را در طبقه‌بندی حالت‌های مختلف خواب از خود نشان می‌دهد. گفتنی است تابع انتقال لایه مخفی به صورت سیگموئید است و از تابع softmax برای تبدیل مقادیر لایه خروجی به احتمال استفاده شده است. همچنین، سه شرط هم‌زمان برای توقف

آموزش شبکه عصبی [۳۴] به صورت زیر در نظر گرفته می‌شود:





۱. تعداد ۵۰۰ تکرار در هر اپاک؛
 ۲. همگرایی در میانگین مربعات خطا در مقدار 10^{-6} ؛
 ۳. همگرایی در نزول مقدار گرادیان خطا در 10^{-6} .
- در نهایت، صحت نهایی شبکه با میانگین‌گیری از صحت‌های حاصل شده در ده بار اجرای برنامه به دست آمده است.

همچنین، به غیر از BPNN، از طبقه‌بندهای نزدیک‌ترین همسایه، Discriminant Analysis، Naive Bayes و جنگل تصادفی از ویژگی‌های استخراج شده برای طبقه‌بندی استفاده شد. برای DA، عملکرد سه تابع شناخته شده خطی، Mahalanobis بررسی شد. شکل (۴)، عملکرد درجه دو و روش پیشنهادی را برای کلاس‌های مختلف نشان می‌دهد. با توجه به شکل (۴)، BPNN بهترین مدل طبقه‌بندی شکل (۴) در بین طبقه‌بندهای دیگر است. همچنین، سرعت و زمان اجرای طبقه‌بند پیشنهادی در مقایسه با طبقه‌بندهای شبیه‌سازی شده در شکل (۴)، در جدول (۵) نمایش داده شده است. طبق جدول (۵)، زمان اجرای طبقه‌بند پیشنهادی نسبت به سایر طبقه‌بندها بیشتر است؛ اما ضریب صحت بالای ۹۰٪ برای طبقه‌بندی ۶-کلاس مراحل خواب خواهد بود. جدول (۶)، مقادیر صحت روش‌های مختلفی را نشان می‌دهد که از مجموعه داده sleep-EDF استفاده کرده‌اند. با توجه به جدول (۶)، تمامی مقادیر گزارش شده برای روش پیشنهادی، ضریب صحت بالای ۹۰٪ دارند. همچنین، طبق جدول (۶) با توجه به صحت پژوهش‌های [۱۰] و [۱۹] برای طبقه‌بندی ۶-کلاس خواب که به ترتیب ۸۸/۶۲٪ و ۹۰/۵۰٪ هستند، صحت روش پیشنهادی ۹۳/۹۳٪ است. شکل (۵)، نمودار ROC برای طبقه‌بندی مطابق با جدول (۱) را نشان می‌دهد. با توجه به شکل (۵)، کلیه کلاس‌ها در شکل (۵) بازه ۰/۹ تا ۱ قرار دارند که بیان‌کننده عملکرد مطلوب الگوریتم پیشنهادی است. در مجموع نتیجه گرفته می‌شود عملکرد روش پیشنهادی از لحاظ اعتبار و



شکل (۵): منحنی ROC برای هر یک از ۶ حالت خواب

قابلیت اطمینان امیدوارکننده است. همچنین عملکرد روش پیشنهادی به طور جداگانه برای طبقه بندی شش حالت خواب در جدول (۷) مشاهده می شود. طبق جدول (۷)، حساسیت روش پیشنهادی برای ۲-کلاس تا ۶-کلاس مراحل خواب بالای ۸۸٪ است. جدول (۸)، مقادیر ضریب کاپا کوهن روش پیشنهادی را در مقایسه با مطالعات پیشین نشان می دهد. با توجه به جدول (۸)، مشخص مقادیر کاپا کوهن روش پیشنهادی برای ۶-کلاس مراحل خواب در حدود ۰/۹ است که در مقایسه با مقالات [۱۰]، [۱۵] و [۲۳] که به ترتیب ضریب کاپای ۰/۸۸، ۰/۸۱ و ۰/۷۴ دارند، ضریب کاپای بیشتری دارد.



شکل (۴): عملکرد روش پیشنهادی برای کلاس های مختلف

جدول (۵): زمان اجرای طبقه‌بند پیشنهادی در مقایسه با طبقه‌بندهای دیگر برای داده SC4002 از پایگاه Sleep-EDF

طبقه‌بند	بهینه‌سازی	داده	زمان (ثانیه)
KNN	-	SC4002	۲۳۱
DA (Linear)	-	SC4002	۱۵۹
DA (Quadratic)	-	SC4002	۲۸۷
DA (Mahalanobis)	-	SC4002	۲۵۶
Naïve Bayes	-	SC4002	۲۴۳
RF	-	SC4002	۳۹۲
BPNN	GA	SC4002	۴۶۶

جدول (۶): عملکرد الگوریتم پیشنهادی در مقایسه با پژوهش‌های پیشین در مجموعه داده خواب پایگاه Sleep-EDF

۶-کلاس	۵-کلاس	۴-کلاس	۳-کلاس	۲-کلاس	الگوریتم‌های مختلف
-	٪۷۱/۲۰	٪۷۴/۵	٪۸۸/۳۰	٪۹۵/۴	Berthomier et al.[35]
٪۶۱/۰۸	-	-	-	-	Doroshenkov et al.[36]
٪۶۹/۹۸	-	-	-	-	Vural and Yildiz [37]
-	٪۷۷/۹۸	-	-	-	Liang et al. [23]
-	٪۸۷/۲۰	-	-	-	Hsu et al. [9]
٪۷۶/۷۰	-	٪۸۱/۴۲	٪۸۸/۹۷	٪۹۶/۹۰	Ronzhina et al. [21]
٪۸۷/۵۰	٪۸۸/۹۰	٪۸۹/۳۰	٪۹۲/۶۰	٪۹۷/۹۰	Zhu et al. [15]
٪۸۸/۶۲	٪۹۰/۱۱	٪۹۱/۲۰	٪۹۳/۵۵	٪۹۷/۷۳	Hassan and Bhuiyan [10]
٪۹۰/۵۰	٪۹۱/۵۰	٪۹۲/۳۰	٪۹۳/۹۰	٪۹۷/۳۰	T. Silveir et al. [19]
٪۹۳/۸۰	٪۹۶/۷۰	٪۹۶/۷۰	٪۹۷/۸۰	٪۹۸/۹۰	روش پیشنهادی

جدول (۷): ماتریس درهم‌ریختگی برای هریک از شش حالت خواب از پایگاه داده Sleep-EDF

Expert	REM	AWA	S1	S2	S3	S4	SEN(%)
REM	۳۸۹۲	۷۰	۱۴۷	۱۴۴	۰	۰	۹۷/۵٪
AWA	۱۱	۳۹۹۵	۱۶۷	۱۳	۰	۰	۹۷/۱٪
S1	۴۴	۱۳	۳۵۵۸	۹۴	۲۶	۰	۸۸/۶٪
S2	۴۴	۲۴	۷۱	۳۶۵۷	۱۰۲	۳۷	۹۱/۲٪
S3	۰	۱۱	۷۴	۹۸	۳۸۰۰	۲۳۴	۹۵/۱٪
S4	۰	۰	۰	۴	۶۷	۳۷۶۸	۹۳/۳٪

جدول (۸): ضرایب کاپا کوهن روش پیشنهادی در مقایسه با مطالعات پیشین از پایگاه داده Sleep-EDF

	Liang et al. [23]	Zhu et al. [15]	Hassan et al. [10]	روش پیشنهادی
۲-کلاس	-	۰/۹۶	۰/۹۸	۰/۹۸
۳-کلاس	-	۰/۸۷	۰/۹۴	۰/۹۵
۴-کلاس	-	۰/۸۳	۰/۹۳	۰/۹۵
۵-کلاس	-	۰/۸۳	۰/۸۴	۰/۸۳
۶-کلاس	۰/۷۴	۰/۸۱	۰/۸۸	۰/۹۰

۴- بحث

۵- نتیجه گیری

سیگنال EEG خواب شامل تعداد نمونه‌های یکسان برای هریک از شش حالت خواب نیست؛ در واقع، تعداد توزیع دوره‌ها در حالت‌های مختلف خواب بسیار بی‌ثبات است؛ جدول (۲) این حقیقت را ثابت می‌کند. در جدول (۲) مشاهده می‌شود بیش از نیمی از دوره‌ها به حالت AWA مربوط است. دوره‌های S1، S3 و S4 باتوجه‌به بقیه حالت‌های خواب سهم بسیار کمتری را در خواب افراد دارند. این مسئله باعث نبود تعادل بین کلاس‌ها در تجزیه و تحلیل سیگنال‌های EEG می‌شود. نبود تعادل بین کلاس‌ها مشکلی است که باعث ایجاد خطا و بایاس شدن طبقه‌بند در هنگام طبقه‌بندی داده‌ها به سمت کلاس اکثریت می‌شود. در روش پیشنهادی برای حل این مشکل از درون‌یابی مکعبی برای توازن بین کلاس‌ها استفاده شد.

در این مقاله، شناسایی خودکار مراحل خواب با استفاده از روش تجزیه حالت تجربی دسته‌ای کامل و مدل ترکیبی الگوریتم ژنتیک و شبکه عصبی ارائه شد. در روش پیشنهادی، سیگنال EEG تک‌کاناله با استفاده از روش تجزیه حالت تجربی دسته‌ای کامل به توابع حالت ذاتی خود، تجزیه و چند ویژگی آماری از هریک از توابع حالت ذاتی استخراج شد. سپس با استفاده از ترکیب الگوریتم ژنتیک و شبکه عصبی، ویژگی‌های مهم، انتخاب و به‌منزله ورودی طبقه‌بند برای تفکیک کلاس‌ها از یکدیگر استفاده شد. در این پژوهش، صحت ویژگی‌های بهینه انتخاب‌شده از مدل ترکیبی الگوریتم ژنتیک و شبکه عصبی با استفاده از آزمون مک‌نمار بررسی شد. نتایج نشان داد انتخاب ویژگی‌های آماری مطلوب در تشخیص حالت‌های مختلف خواب بسیار مؤثر است.

نتایج الگوریتم برای طبقه‌بندی ۲-کلاس تا ۶-کلاس، ضریب صحت و ضریب کاپا کوهن بالای ۹۰٪ را ارائه می‌دهد. همچنین باتوجه‌به بالابودن صحت الگوریتم، از آن برای تشخیص اختلالات خواب و رفتار و تشخیص بیماری‌ها از جمله بیماری پارکینسون استفاده می‌شود. روش پیشنهادی برای تشخیص خودکار مراحل خواب روند سرعت تشخیص اختلالات خواب را افزایش می‌دهد و برای داده‌های حجیم EEG نیز استفاده می‌شود.

مراجع

- [1] S. Kubicki, W. Scheuler, and H. Wittenbecher, "Short-term sleep EEG recordings after partial sleep deprivation as a routine procedure in order to uncover epileptic phenomena: an evaluation of 719 EEG recordings," *Epilepsy research. Supplement*, Vol. 2, pp. 217-230, 1991.
- [2] Y. Koshino et al., "The influence of light drowsiness on the latency and amplitude of P300," *Clinical Electroencephalography*, Vol. 24, No. 3, pp. 110-113, 1993.
- [3] L. Fraiwan, K. Lweesy, N. Khasawneh, H. Wenz, and H. Dickhaus, "Automated sleep stage identification system based on time-frequency analysis of a single EEG channel and random forest classifier," *Computer methods and programs in biomedicine*, Vol. 108, No. 1, pp. 10-19, 2012.

درون‌یابی، ابزاری برای تقریب داده‌های نامشخص در بین داده‌های معلوم است. از جمله کاربردهای درون‌یابی در پردازش تصویر و پردازش سیگنال است. از روش‌های مرسوم درون‌یابی یک‌بعدی به درون‌یابی چندجمله‌ای و درون‌یابی برپایه تبدیل فوریه اشاره می‌شود. در این مقاله برای توازن بین کلاس‌ها از درون‌یابی چندجمله‌ای استفاده شد. در این روش با استفاده از داده‌های موجود، یک تابع چندجمله‌ای بر داده‌ها برازش می‌شود و سپس مقدار تابع در نقاط میانی مدنظر محاسبه خواهد شد. روش‌های مختلفی برای درون‌یابی چندجمله‌ای وجود دارد که در روش پیشنهادی از درون‌یابی مکعبی برای به توازن رساندن داده‌ها استفاده شده است. در روش درون‌یابی مکعبی از الگوریتم درون‌یابی هرمیتی مکعبی تکه‌ای بین بردارهای X و Y استفاده می‌شود که به حافظه و زمان اجرای بیشتری نسبت به روش‌های دیگر درون‌یابی نیاز دارد؛ البته داده‌های حاصل از درون‌یابی پیوسته است؛ بدین ترتیب کلیه کلاس‌ها به بالاترین دوره درون‌یابی می‌شوند و مشکل توازن‌نداشتن کلاس‌ها حل خواهد شد [۳۸].

- channel EEG signal," REM, Vol. 806, p. 803, 2014.
- [16] M. Ronzhina, O. Janoušek, J. Kolářová, M. Nováková, P. Honzík, and I. Provazník, "Sleep scoring using artificial neural networks," *Sleep medicine reviews*, Vol. 16, No. 3, pp. 251-263, 2012.
- [17] O. Tsinalis, P. M. Matthews, and Y. Guo, "Automatic sleep stage scoring using time-frequency analysis and stacked sparse autoencoders," *Annals of biomedical engineering*, Vol. 44, No. 5, pp. 1587-1597, 2016.
- [18] T. Kayikcioglu, M. Maleki, and K. Eroglu, "Fast and accurate PLS-based classification of EEG sleep using single channel data," *Expert Systems with Applications*, Vol. 42, No. 21, pp. 7825-7830, 2015.
- [19] T. L. da Silveira, A. J. Kozakevicius, and C. R. Rodrigues, "Single-channel EEG sleep stage classification based on a streamlined set of statistical features in wavelet domain," *Medical & biological engineering & computing*, Vol. 55, No. 2, pp. 343-352, 2017.
- [20] J. Dong et al., "Automated sleep staging technique based on the empirical mode decomposition algorithm: a preliminary study," *Advances in Adaptive Data Analysis*, Vol. 2, No. 02, pp. 267-276, 2010.
- [21] M. Ronzhina, O. Janoušek, J. Kolrov, M. Novkov, P. Honzk, I. Provaznk, "Sleep scoring using artificial neural networks", *Sleep Medicine Reviews*, Vol. 16, No. 3, pp. 251 – 263, 2012.
- [22] A. Krakovská and K. Mezeiová, "Automatic sleep scoring: A search for an optimal combination of measures," *Artificial intelligence in medicine*, Vol. 53, No. 1, pp. 25-33, 2011.
- [23] S.-F. Liang, C.-E. Kuo, Y.-H. Hu, Y.-H. Pan, and Y.-H. Wang, "Automatic Stage Scoring of Single-Channel Sleep EEG by Using Multiscale Entropy and Autoregressive Models," *IEEE Trans. Instrumentation and Measurement*, Vol. 61, No. 6, pp. 1649-1657, 2012.
- [24] N. E. Huang et al., "The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis," in *Proceedings of the Royal Society of London A: mathematical, physical and engineering sciences*, 1998, Vol. 454, No. 1971, pp. 903-995: The Royal Society.
- [25] P. Flandrin, P. Gonçalves, and G. Rilling, "EMD equivalent filter banks, from interpretation to applications," in *Hilbert–Huang transform and its applications: World Scientific*, pp. 99-116, 2014.
- [26] Z. Wu and N. E. Huang, "Ensemble empirical mode decomposition: a noise-assisted data analysis method," *Advances in adaptive data analysis*, Vol. 1, No. 01, pp. 1-41, 2009.
- [27] X. Zhang and J. Zhou, "Multi-fault diagnosis for rolling element bearings based on ensemble
- [4] A. Kales and A. Rechtschaffen, *A manual of standardized terminology, techniques and scoring system for sleep stages of human subjects*. US Department of Health, Education and Welfare, Public Health Service, National Institutes of Health, National Institute of Neurological Diseases and Blindness, Neurological Information Network, 1968.
- [5] B. Boashash and S. Ouelha, "Automatic signal abnormality detection using time-frequency features and machine learning: A newborn EEG seizure case study," *Knowledge-Based Systems*, Vol. 106, pp. 38-50, 2016.
- [6] S. B. Akben and A. Alkan, "Visual interpretation of biomedical time series using parzen window-based density-amplitude domain transformation," *PLoS one*, Vol. 11, No. 9, p. e0163569, 2016.
- [7] T. Penzel and R. Conradt, "Computer based sleep recording and analysis," *Sleep medicine reviews*, Vol. 4, No. 2, pp. 131-148, 2000.
- [8] T. Lajnef et al., "Learning machines and sleeping brains: automatic sleep stage classification using decision-tree multi-class support vector machines," *Journal of neuroscience methods*, Vol. 250, pp. 94-105, 2015.
- [9] Y.-L. Hsu, Y.-T. Yang, J.-S. Wang, and C.-Y. Hsu, "Automatic sleep stage recurrent neural classifier using energy features of EEG signals," *Neurocomputing*, Vol. 104, pp. 105-114, 2013.
- [10] A. R. Hassan and M. I. H. Bhuiyan, "Automated identification of sleep states from EEG signals by means of ensemble empirical mode decomposition and random under sampling boosting," *Computer methods and programs in biomedicine*, Vol. 140, pp. 201-210, 2017.
- [11] A. R. Hassan and M. I. H. Bhuiyan, "Automatic sleep scoring using statistical features in the EMD domain and ensemble methods," *Biocybernetics and Biomedical Engineering*, Vol. 36, No. 1, pp. 248-255, 2016.
- [12] Y. Li, M.-L. Luo, and K. Li, "A multiwavelet-based time-varying model identification approach for time–frequency analysis of EEG signals," *Neurocomputing*, Vol. 193, pp. 106-114, 2016.
- [13] A. Subasi, "A decision support system for diagnosis of neuromuscular disorders using DWT and evolutionary support vector machines," *Signal, Image and Video Processing*, Vol. 9, No. 2, pp. 399-408, 2015.
- [14] A. Subasi and M. I. Gursoy, "EEG signal classification using PCA, ICA, LDA and support vector machines," *Expert systems with applications*, Vol. 37, No. 12, pp. 8659-8666, 2010.
- [15] G. Zhu, Y. Li, and P. P. Wen, "Analysis and classification of sleep stages based on difference visibility graphs from a single-

- scoring system for sleep stages of human subjects. US Department of Health, Education and Welfare, Public Health Service, National Institutes of Health, National Institute of Neurological Diseases and Blindness, Neurological Information Network, 1968.
- [34] H. Pourghassem and H. Ghassemian, "Content-based medical image classification using a new hierarchical merging scheme," *Computerized Medical Imaging and Graphics*, Vol. 32, No. 8, pp. 651-661, 2008.
- [35] C. Berthomier, X. Drouot, M. Herman-Stoica, P. Berthomier, J. Prado, D. Bokar-Thire, O. Benoit, J. Mattout, M.-P. d'Ortho, "Automatic analysis of single-channel sleep EEG: validation in healthy individuals", *Sleep*, Vol. 30, No. 11, pp. 1587-1595, 2007.
- [36] L.G. Doroshenkov, V.A. Konyshev, S.V. Selishchev, "Classification of human sleep stages based on eeg processing using hidden Markov models", *Biomed. Eng.*, Vol. 41, No. 1, pp. 24-28, 2007.
- [37] C. Vural and M. Yildiz, "Determination of sleep stage separation ability of features extracted from EEG signals using principle component analysis," *Journal of medical systems*, Vol. 34, No. 1, pp. 83-89, 2010.
- [38] R. Keys, "Cubic convolution interpolation for digital image processing," *IEEE transactions on acoustics, speech, and signal processing*, Vol. 29, No. 6, pp. 1153-1160, 1981.
- empirical mode decomposition and optimized support vector machines," *Mechanical Systems and Signal Processing*, Vol. 41, No. 1-2, pp. 127-140, 2013.
- [28] M. E. Torres, M. A. Colominas, G. Schlotthauer, and P. Flandrin, "A complete ensemble empirical mode decomposition with adaptive noise," in *Acoustics, speech and signal processing (ICASSP), 2011 IEEE international conference on*, 2011, pp. 4144-4147: IEEE.
- [29] H. Pourghassem and S. Daneshvar, "A framework for medical image retrieval using merging-based classification with dependency probability-based relevance feedback," *Turkish Journal of Electrical Engineering & Computer Sciences*, Vol. 21, No. 3, pp. 882-896, 2013.
- [30] A. B. Sankar, J. A. V. Selvi, D. Kumar, and K. S. Lakshmi, "Effective enhancement of classification of respiratory states using feed forward back propagation neural networks," *Sadhana*, Vol. 38, No. 3, pp. 377-395, 2013.
- [31] B. Kemp, A. Zwinderman, B. Tuk, H. Kamphuisen, J. Obery, "Analysis of a sleep dependent neuronal feedback loop: the slow-wave microcontinuity of the eeg", *IEEE Trans. Biomed. Eng.* Vol 47, No.9, pp. 1185-1194, 2000.
- [32] M. T. Hagan, and H. B. Demuth, "Neural Network Design", PWS Publishing Company, China, 1996.
- [33] A. Kales and A. Rechtschaffen, *A manual of standardized terminology, techniques and*

¹ Polysomnography

² Electromyogram

³ Electroencephalogram

⁴ Electrooculogram

⁵ Empirical Mode Decomposition

⁶ Support vector machine

⁷ Neural Network

⁸ Mean Square Error

⁹ Power Spectral Density

¹⁰ Autoregressive

¹¹ Partial Least Squares

¹² Ensemble Empirical Mode Decomposition

¹³ Rechtschaffen and Kales

¹⁴ Genetic Algorithm

¹⁵ Multilayer Perceptron

¹⁶ Back Propagation Neural Network

¹⁷ Complete Ensemble Empirical Mode Decomposition

¹⁸ Mean Square Error