

## Automatic Stage Scoring of Single-Channel Sleep EEG using Discrete Wavelet Transform and a hybrid model of ant colony optimizer and neural network based on RUSBoost Classifier

S. Sheykhivand<sup>1</sup>, S. Ghaemi<sup>2\*</sup>

<sup>1</sup>Ph.D. Student, Biomedical Engineering Department, Faculty of Electrical and Computer Engineering, University of Tabriz, Tabriz, Iran

<sup>2</sup>Associate Professor, Faculty of Electrical and Computer Engineering, University of Tabriz, Tabriz, Iran

Receipt in the Online Submission System: 31/12/2018, Received in Revised Form: 24/7/2019, Accepted: 8/9/2019

### Abstract

The automatic classification of sleep stages is essential for the timely detection of disorders and sleep-related studies. In this paper, a single-channel EEG-based algorithm is used to automatically identify sleep stages using discrete wavelet transform and a hybrid model of ant colony optimizer and neural network based on RUSBoost. The signal is decomposed using a discrete wavelet transform into four levels and statistical properties of each level are calculated. To optimize and reduce the dimensions of feature vectors, hybrid model of ant colony optimizer algorithm and multi-layered neural network are used. Then ANOVA test is applied to validate the selected features. Finally, the classification is performed on RUSBoost, which provides an average of 90% classification accuracy for 2 to 6-class classification of different steps of sleep EEG. Suggesting that the proposed method has a higher degree of success in classifying sleep stages compared to the existing methods.

**Key words:** *Discrete wavelet transform, Automatic sleep stage detection, Ant colony optimization algorithm, RUSBoost*

\* Corresponding author

**Address:** Faculty of Electrical and Computer Engineering, University of Tabriz, Tabriz, Iran.

**Tel:** 0098-413-3393740

**Fax:** 0098-413-3300819

**E-mail:** [ghaemi@tabrizu.ac.ir](mailto:ghaemi@tabrizu.ac.ir)



## شناسایی خودکار مراحل خواب از سیگنال *EEG* تک کاناله با استفاده از تبدیل موجک گسسته و مدل ترکیبی الگوریتم کلونی مورچگان و شبکه عصبی مبتنی بر طبقه‌بند *RUSBoost*

سبحان شیخی‌وند<sup>۱</sup>، سحرانه قائمی<sup>۲\*</sup>

<sup>۱</sup> دانشجوی دکتری مهندسی پزشکی، گروه مهندسی پزشکی، دانشکده مهندسی برق و کامپیوتر، دانشگاه تبریز، تبریز  
<sup>۲</sup> دانشیار، گروه مهندسی کنترل، دانشکده مهندسی برق و کامپیوتر، دانشگاه تبریز، تبریز

تاریخ ثبت در سامانه: ۱۳۹۷/۱۰/۱۰، بازنگری: ۱۳۹۸/۵/۲، پذیرش قطعی: ۱۳۹۸/۶/۱۷

### چکیده

طبقه‌بندی خودکار مراحل خواب به منظور تشخیص به موقع اختلالات و مطالعات مرتبط با خواب امری ضروری است. در این مقاله الگوریتمی مبتنی بر *EEG* تک کاناله برای شناسایی خودکار مراحل خواب با استفاده از تبدیل موجک گسسته و مدل ترکیبی الگوریتم کلونی مورچگان و شبکه عصبی مبتنی بر طبقه‌بند *RUSBoost* ارائه می‌شود. سیگنال با استفاده از تبدیل موجک گسسته به ۴ سطح تجزیه شده و ویژگی‌های آماری از هر یک از سطوح تجزیه شده، استخراج می‌شود. جهت بهینه‌سازی و کاهش ابعاد بردارهای ویژگی، از یک مدل ترکیبی الگوریتم کلونی مورچگان و شبکه عصبی چندلایه پس انتشار خطا استفاده شده، سپس از آزمون *ANOVA* برای تأیید صحت ویژگی‌های بهینه استفاده می‌شود. طبقه‌بندی نهایی بر روی این ویژگی‌های بهینه‌شده توسط طبقه‌بند *RUSBoost* انجام می‌شود و به‌طور میانگین برای طبقه‌بندی ۲-کلاس تا ۶-کلاس مراحل مختلف خواب صحت بالای ۹۰٪ را فراهم می‌کند و نشان می‌دهد که روش پیشنهادی، درصد موفقیت بالاتری در طبقه‌بندی مراحل خواب نسبت به پژوهش‌های پیشین دارد.

کلیدواژه‌ها: تبدیل موجک گسسته، شناسایی خودکار مراحل خواب، الگوریتم بهینه‌سازی کلونی مورچگان، *RUSBoost*

\*نویسنده مسئول

نشانی: ایران - تبریز - دانشگاه تبریز - دانشکده برق و کامپیوتر

تلفن: ۰۰۹۸۴۱۳۳۳۹۳۷۴۰

دورنگار: ۰۰۹۸۴۱۳۳۳۰۰۸۱۹

پست الکترونیکی: ghaemi@tabrizu.ac.ir

## ۱- مقدمه

خواب یک فرآیند ضروری برای حفظ و بهبود فعالیت‌های انسان است. انسان حدود یک سوم زندگی خود را صرف خواب می‌کند و شرایطی مانند آپنه انسدادی خواب<sup>۱</sup> (OSA) می‌تواند به شدت بر سلامت جسمی او تأثیر بگذارد [۱]. با توجه به نتایج تحقیقات در [۲] بیش از ۹۰٪ بیماران مبتلا به افسردگی از اختلالات خواب رنج می‌برند. آپنه خواب در حدود ۲ تا ۴ درصد بزرگسالان و در ۱ تا ۳ درصد کودکان رایج است. همچنین محرومیت از خواب باعث ایجاد خواب‌آلودگی، عدم تمرکز، تغییر ریتم ضربان قلب، کاهش حافظه و ضعف سیستم دفاعی بدن خواهد شد [۳]. در درمان بالینی، تجزیه و تحلیل مراحل خواب به طور معمول توسط یک پزشک متخصص یا کارشناس مربوطه بر اساس بازرسی بصری، از طریق خوابیدن بیمار در بیمارستان و اندازه‌گیری‌های پلی‌سومنوگرافی<sup>۲</sup> (PSG) به همراه مجموعه‌ای از توصیه‌های آکادمی پزشکی<sup>۳</sup> (AASM) و یا R&k<sup>۴</sup> انجام می‌گیرد. تجزیه و تحلیل مراحل خواب در تشخیص و درمان اختلالات خواب از جمله اختلال رفتاری<sup>۵</sup> (RBD) و نارکولپسی<sup>۶</sup> امری حیاتی است. اندازه‌گیری‌های PSG شامل سیگنال‌هایی مانند الکتروانسفالوگرام<sup>۷</sup> (EEG)، الکتروکولوگرام<sup>۸</sup> (EOG)، الکترومایوگرام<sup>۹</sup> (EMG)، الکتروکاردیوگرام<sup>۱۰</sup> (ECG)، اشباع اکسیژن (SpO2) و تنفس (Resp) است [۴]. اندازه‌گیری‌های PSG ابتدا به دوره‌های ۲۰ تا ۳۰ ثانیه‌ای تقسیم می‌شوند سپس توسط کارشناسان یا پزشک متخصص به دوره‌های مختلف خواب بر اساس بازرسی بصری طبقه‌بندی خواهند شد. این دوره‌ها در جدول ۱ نمایش داده شده است [۵].

## جدول (۱) - دسته‌بندی حالت‌های مختلف خواب بر اساس

## استاندارد R &amp; K

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

در روش سنتی، در طول مدت ۸ ساعته خواب، بازرسی بصری ۲ الی ۴ ساعته بر روی فرد مورد نظر انجام می‌شود. نظارت

مراحل خواب به شیوه سنتی بر اساس بررسی بصری، امری ناخوشایند، وقت‌گیر و خطا آلود بوده و همچنین، نیازمند منابع انسانی متخصص است [۶]. علاوه بر این، روش سنتی موجب صحت زیر ۹۰٪ در تحلیل و تشخیص بیماری فرد مدنظر خواهد شد [۷]. همچنین در برخی موارد، می‌تواند نیاز به تشخیص سریع مراحل خواب باشد؛ بنابراین تجزیه و تحلیل مراحل خواب به شیوه سنتی نمی‌تواند با چنین شرایطی مراحل خواب را نشان دهد. عوامل ذکر شده اهمیت دسته‌بندی خودکار مراحل خواب را نشان می‌دهد. همچنین مطالعه بر روی افراد در مقیاس وسیع در تحقیقات خواب به شدت تحت تأثیر این عوامل قرار می‌گیرد [۱]. بررسی خودکار فرآیند تجزیه و تحلیل مراحل خواب نه تنها موجب تشخیص سریع می‌شود بلکه باعث افزایش صحت در تشخیص نیز خواهد شد [۸]. پلی‌سومنوگرافی فرآیندی پرهزینه است و از آنجا که خواب در محیط ناآشنا ناراحت‌کننده هست، می‌تواند بر سلامت خواب بیمار تأثیر بگذارد [۹]. استفاده از سیگنال‌های EEG با توجه به ارزان بودن و قابل دسترس بودن، می‌تواند نسبت به PSG مناسب‌تر باشد [۱۰]. به با توجه به این چالش‌ها، تشخیص مراحل خواب به صورت خودکار بر اساس سیگنال EEG می‌تواند زمان تشخیص را برای پزشکان کاهش دهد، صحت تحلیل را در طبقه بندی مراحل خواب افزایش داده و تشخیص و درمان اختلالات خواب را بهبود بخشد [۱۱]. اکثر الگوریتم‌های شناسایی خودکار مراحل خواب به منظور تشخیص صحیح، نیاز به بیش از یک کانال دارند. شناسایی خودکار مراحل خواب مبتنی بر چند کانال محدودیت‌هایی ایجاد می‌کند و نیاز به مصرف انرژی بیشتری دارد، همچنین باعث کاهش کیفیت ثبت داده خواهد شد [۱۲]. به همین ترتیب، استفاده از سیگنال‌های حاصل از EEG نیاز به الگوریتم مکان یابی سیگنال خواب برای استفاده از حداقل تعداد کانال‌های سیگنال فیزیولوژیک را دارد [۱۳]. استفاده از یک کانال سیگنال EEG ضمن راحتی بسیار برای بیمار، باعث کاهش مصرف انرژی شده و در دستگاه‌های پرتابل EEG باعث افزایش عمر باتری خواهد شد. تشخیص تک کاناله سریع‌تر (حجم محاسباتی کمتر)، از نظر جایگذاری الکترودها راحت‌تر و از نظر هزینه ارزان‌تر خواهد بود [۱]. بر این اساس شناسایی خودکار مراحل خواب مبتنی بر یک کانال، توجه جامعه تحقیق خواب را به خود جلب کرده است.

<sup>۶</sup> Narcolepsy<sup>۷</sup> Electroencephalogram<sup>۸</sup> Electrooculogram<sup>۹</sup> Electromyogram<sup>۱۰</sup> Electrocardiogram<sup>۱</sup> Obstructive Sleep Apnea<sup>۲</sup> Polysomnography<sup>۳</sup> American Academy of Sleep Medicine<sup>۴</sup> Rechtschaffen and Kales<sup>۵</sup> REM Sleep Behavior Disorder

مراحل خواب ارائه داد. ورال و همکاران [۲۰] با استفاده از تبدیل Karhunen-Loeve به تجزیه سیگنال EEG چند کاناله پرداخته و از ویژگی‌های زمانی-فرکانسی برای استخراج ویژگی‌ها استفاده کردند، همچنین آن‌ها تجزیه مولفه اصلی<sup>۱۷</sup> (PCA) را برای کاهش بردار ویژگی‌ها و دسته‌بندی کلاس‌ها به کار گرفتند. دورشنکو و همکاران [۲۱] با استفاده از تبدیل فوریه سریع<sup>۱۸</sup> (FFT) به تجزیه سیگنال EEG به فرکانس‌های تتا، آلفا و دلتا پرداخته و از مدل پنهان مارکوف<sup>۱۹</sup> (HMM) برای طبقه‌بندی کلاس‌های مختلف خواب استفاده کردند. ژو و همکاران [۱۲] گراف دیداری و گراف افقی را از سیگنال EEG تک کاناله تولید کرده و ۹ ویژگی از آن‌ها را برای طبقه‌بندی با استفاده از ماشین بردار پشتیبان به کار بردند. صحت روش آن‌ها برای طبقه‌بندی ۶ کلاس حالت‌های مختلف خواب حدود ۸۷ درصد گزارش شده است. حسن و همکاران [۱۱] با استفاده از الگوریتم تجزیه حالت تجربی دسته‌ای<sup>۲۰</sup> (EEMD) به تجزیه سیگنال EEG تک کاناله پرداخته و ویژگی‌های آماری را از آن استخراج کرده‌اند. صحت طبقه‌بندی برای مراحل خواب ۶ کلاس با استفاده از الگوریتم آن‌ها در حدود ۸۸ درصد گزارش شده است. از جمله مزایای کار آن‌ها افزایش صحت در تفکیک مرحله S1 از REM بوده است. همچنین، از معایب پژوهش آن‌ها، می‌توان به اختلاط مودها در استفاده از EEMD اشاره داشت. سیلوریا و همکاران [۱۶] با استفاده از تبدیل موجک گسسته و استفاده از ویژگی‌های آماری از سیگنال EEG تک کاناله با استفاده از طبقه‌بند جنگل تصادفی به صحت حدود ۹۰ درصد برای طبقه‌بندی ۶ کلاس حالت‌های مختلف خواب دست یافته‌اند. از جمله مزایای کار آن‌ها می‌توان به کاهش بردار ویژگی در مقایسه با پژوهش‌های قبل اشاره داشت که موجب کاهش حجم محاسباتی الگوریتم شده است. همچنین از جمله معایب پژوهش آن‌ها می‌توان به پایین بودن صحت طبقه‌بندی کلاس‌های ۳ و ۴ اشاره داشت. با توجه به مطالعات صورت گرفته در پژوهش‌های پیشین این موضوع معلوم شد که اکثر الگوریتم‌های موجود برای شناسایی خودکار مراحل خواب، نیاز به بیش از یک کانال دارند لذا این موضوع برای بیمار ناراحت کننده بوده و مانع سنجش دستگاه نظارت خواب در خانه می‌شود.

اکثر روش‌های قبلی برای شناسایی خودکار مراحل خواب به دلیل کم بودن صحت (زیر ۹۰ درصد) و زمان محاسبات طولانی برای اجرای سخت‌افزاری، برای تشخیص مراحل خواب مناسب نیستند [۱۴].

روش‌های مختلفی مثل توزیع زمان و فرکانس [۱۱]، نظریه گراف [۱۲، ۱۵]، مدل‌سازی سیگنال [۱۲]، تبدیل موجک [۱۶]، تجزیه حالت تجربی<sup>۱۱</sup> (EMD) برای پردازش سیگنال سیگنال در جداسازی مراحل خواب استفاده شده است. همچنین برای بخش طبقه‌بندی، مدل‌های مختلفی استفاده می‌شود که شامل: ماشین بردار پشتیبان<sup>۱۲</sup> (SVM) [۵] و حداقل مربعات جزئی<sup>۱۳</sup> (MSE) [۱۲] هستند. در ادامه به بررسی مطالعات اخیر که در حوزه شناسایی خودکار مراحل خواب انجام شده است پرداخته می‌شود.

رونزینا و همکاران [۱۳] با استفاده از چگالی طیفی توان<sup>۱۴</sup> (PSD) سیگنال‌های EEG به همراه شبکه عصبی مصنوعی، یک طرح مبتنی بر EEG تک کاناله ارائه دادند. لاجنل و همکاران [۵] با استفاده از ویژگی‌های مختلف از قبیل آنتروپی، خطای پیش‌بینی خطی، واریانس، چولگی، کشیدگی، آنتروپی پیمایش و ماشین بردار پشتیبان چندطبقه بر روی EOG، EMG و EEG برای ثبت خودکار مراحل خواب استفاده کردند. پکر و همکاران [۱۷] ترکیبی از تبدیل موجک (DT-CWT) و شبکه عصبی مبتنی بر تاگوچی را برای ثبت خودکار مراحل خواب از یک کانال EEG را مورد بررسی قرار دادند. کراکستا و همکاران [۱۵] 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 کرده و با استفاده از معیارهای درجه دوم تحلیل و بررسی کردند. تیسنالس و همکاران [۷] تجزیه و تحلیل زمان-فرکانس را برای استخراج ویژگی انجام داده و برای طبقه‌بندی از الگوریتم رمزگذار خودکار انباشته شده استفاده کردند. لیانگ و همکاران [۱۸] با استفاده از ویژگی‌های مبتنی بر آنتروپی Renyi استخراج شده از توزیع فرکانس‌های مختلف برای شناسایی مراحل مختلف خواب با EEG تک کاناله استفاده کردند. کیسیگولو [۱۹] یک طرح استخراج ویژگی مبتنی بر فن‌آوری مدل خودبازگشتی<sup>۱۵</sup> (AR) و الگوریتم حداقل مربعات جزئی<sup>۱۶</sup> (PLS) را برای طبقه‌بندی

<sup>۱۶</sup> Partial Least Squares

<sup>۱۷</sup> Principal Component Analysis

<sup>۱۸</sup> Fast Fourier Transform

<sup>۱۹</sup> Hidden Markov Models

<sup>۲۰</sup> Ensemble Empirical Mode Decomposition

<sup>۱۱</sup> Empirical Mode Decomposition

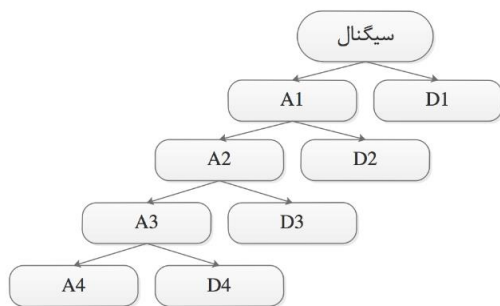
<sup>۱۲</sup> Support Vector Machine

<sup>۱۳</sup> Mean Squared Error

<sup>۱۴</sup> Power Spectral Density

<sup>۱۵</sup> Autoregressive

تبدیل موجک به این ترتیب است که با تجزیه سیگنال به دو قسمت فرکانس بالا و پایین و تکرار همین عمل برای خروجی‌های به دست آمده از هر مرحله تجزیه، امکان بررسی و تحلیل را به مراتب راحت‌تر می‌کند. شکل ۲ روند این تجزیه را نشان می‌دهد. ایده اصلی تبدیل موجک گسسته از فیلترهای بالا و پایین گذر گرفته شده است که سیگنال به ۲ قسمت فرکانس بالا یعنی جزئیات<sup>۲۴</sup> و فرکانس پایین یعنی تقریب<sup>۲۵</sup> تقسیم می‌شود که روند یادشده تا سطح دلخواه ادامه پیدا می‌کند تا بهترین سطح را جهت آنالیز ارائه نماید.



شکل (۲) - روند تجزیه سیگنال

در نتیجه می‌توان رابطه (۱) را برای این نوع تبدیل نوشت:

$$S = A4 + D1 + D2 + D3 + D4 \quad (1)$$

تاکنون خانواده‌های متعددی از تبدیل موجک‌ها ارائه شده که هر کدام دارای ویژگی‌های مختلفی هستند. از خانواده تبدیل موجک‌ها می‌توان به موجک هار، دابشیز، کویفلت، سیملت، مورلت و گویسین اشاره کرد [۲۲، ۲۳]. در این مقاله از موجک دابشیز ۱۵ (به‌طور تجربی و با سعی و خطا)، پاسخ مناسبی برای استخراج ویژگی مورد نظر یافت شد. همان‌طور که در شکل ۲ نمایش داده شده، سیگنال با استفاده از تبدیل موجک به ۴ زیر سطح تجزیه می‌شود. زیر سطح‌های ایجاد شده دارای اطلاعات دقیق‌تری نسبت به سیگنال‌های اصلی هستند و این امر باعث به دست آوردن تحلیل دقیق‌تری از سیگنال EEG می‌شود [۲۴]. تبدیلات موجک برای تجزیه و تحلیل الگوهای داده‌ای نامنظم بسیار مفید هستند. تبدیل موجک پیوسته (CWT) یک سیگنال  $x(t)$  از انتگرال سیگنال در تابع موجک  $\psi$  به صورت زیر ایجاد می‌کند:


$$CWT(a, b) = \int_{-\infty}^{\infty} x(t) \frac{1}{\sqrt{|a|}} \psi\left(\frac{t-b}{a}\right) dt \quad (2)$$

در این مقاله برای شناسایی خودکار مراحل خواب از روش تبدیل موجک گسسته و مدل ترکیبی الگوریتم کلونی مورچگان<sup>۲۱</sup> (ACO) و شبکه عصبی<sup>۲۲</sup> (MLP) مبتنی بر طبقه‌بند RUSBoost<sup>۲۳</sup> استفاده شده است. این پژوهش مبتنی بر ۲-۶ حالت خواب مطابق با استاندارد R & K است که شامل حالت بیدار (AWA)، مراحل حرکتی غیر سریع چشم (s1-s4) و حرکت سریع چشم (REM) است (مطابق با جدول ۱). در روش پیشنهادی سیگنال با استفاده از تبدیل موجک گسسته تجزیه شده و چند ویژگی زمانی-آماری از هر یک از سطوح تجزیه، استخراج می‌شود، سپس با استفاده از ترکیب الگوریتم ACO و شبکه عصبی ویژگی‌های مهم انتخاب شده و به‌عنوان ورودی طبقه‌بند RUSBoost، جهت تفکیک کلاس‌ها از یکدیگر مورد استفاده قرار می‌گیرد.

ادامه مقاله به صورت زیر تدوین شده است؛ بخش ۲ طرح استخراج ویژگی‌ها را مشخص کرده و عملکرد آن را تجزیه و تحلیل می‌کند، سپس انتخاب ویژگی‌ها، الگوریتم ACO و شبکه عصبی توضیح داده می‌شود، همچنین الگوریتم RUSBoost در این بخش شرح داده می‌شود. در بخش ۳ داده‌های آزمایشی و نتایج تجربی مورد بررسی قرار می‌گیرد. سرانجام، بخش ۴ مربوط به نتیجه‌گیری است.

## ۲- مواد و روش‌ها

در این بخش ابتدا به تشریح استخراج ویژگی‌ها پرداخته شده، سپس انتخاب ویژگی‌ها، الگوریتم ACO و طبقه‌بند RUSBoost مورد بررسی قرار می‌گیرد. شکل ۱ یک طرح کلی از روش پیشنهادی را ارائه می‌دهد.



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

### ۲-۱- تبدیل موجک گسسته (DWT)

تبدیل موجک گسسته به‌عنوان یکی از روش‌های مهم و محبوب در حوزه پردازش سیگنال به کار گرفته می‌شود. اساس کار

<sup>۲۴</sup> Details

<sup>۲۵</sup> Approximations

<sup>۲۱</sup> Ant Colony Optimization

<sup>۲۲</sup> Multilayer Perceptron

<sup>۲۳</sup> Random Undersampling Boosting

۲- میانگین

$$Mean(x(n)) = \frac{\sum_{n=1}^N x(n)}{N} \quad (5)$$

۳- گشتاور مرتبه‌ی ۴

مقدار نرمال شده سیگنال نسبت به میانگین را نشان می‌دهد، این ویژگی به صورت زیر قابل محاسبه است:

$$Mumentum 4 = \frac{\sum_{n=1}^N (x(n) - Mean(x(n)))^4}{(N-1)} \quad (6)$$

۴- کشیدگی<sup>۲۶</sup>

این ویژگی کشیدگی تابع چگالی احتمال سیگنال به یک سمت را نشان می‌دهد، پارامترهای  $\mu$  و  $\sigma$  به ترتیب بیانگر میانگین و واریانس هستند که به صورت زیر محاسبه می‌شود:

$$Kurtosis = \frac{1}{N} \sum_{i=1}^N \left( \frac{x_i - \mu}{\sigma} \right)^4 \quad (7)$$

۵- چولگی<sup>۲۷</sup>

چولگی معیاری از تقارن یا عدم تقارن تابع توزیع است و به صورت زیر قابل محاسبه هست:

$$Skewness = \frac{1}{N} \sum_{i=1}^N \left( \frac{x_i - \mu}{\sigma} \right)^3 \quad (8)$$

۶- فاکتور ضربه

این ویژگی ماهیت ضربه‌ای سیگنال را بیان می‌کند و برای پیش سیگنال‌های دارای تغییرات زیاد و گذرا بسیار کاربرد دارد که به صورت زیر قابل محاسبه است:

$$Impulse Factor = \frac{Max(x(n))}{\frac{1}{N} \sum_{n=1}^N |x(n)|} \quad (9)$$

۷- انرژی

میزان انرژی یک سیگنال بیانگر میزان اغتشاش آن است، این ویژگی به صورت زیر قابل محاسبه است:

$$Energy = \sum_{n=1}^N (x(n))^2 \quad (10)$$

۸- انحراف 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 باهم برابر می‌شوند.

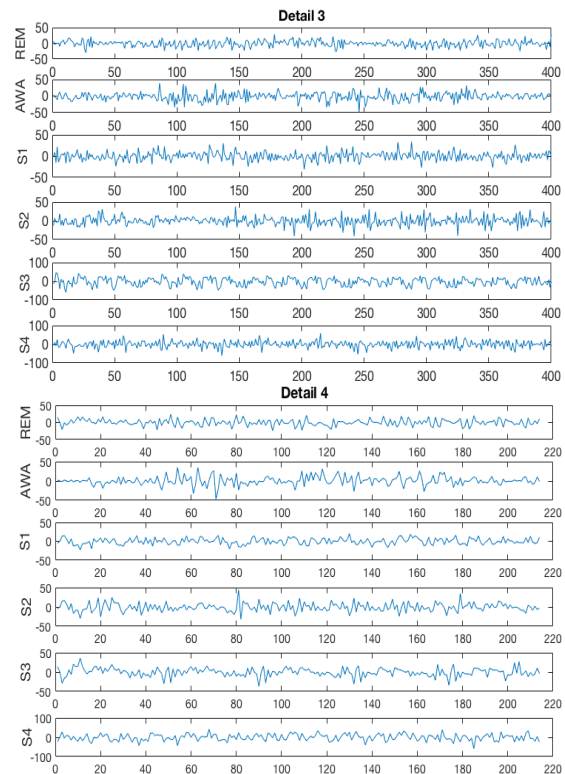
$$STD(x(n)) = \sqrt{\frac{\sum_{n=1}^N (x(n) - Mean(x(n)))^2}{N-1}} \quad (11)$$

در این مقاله ۴ سطح تجزیه موجک برای استخراج ویژگی به کار برده شده است (ابتدا سیگنال با استفاده از تبدیل موجک گسسته به ۴ سطح تجزیه شده، سپس ۸ ویژگی آماری-زمانی

که  $a$  و  $b$  به ترتیب پارامترهای مقیاس و جابجایی هستند. به دلیل اینکه محاسبه ضرایب موجک به ازای تمامی مقادیر پارامترهای  $a$  و  $b$  وقت گیر و از نظر محاسباتی پرهزینه است، در نتیجه برای دو پارامتر از توان‌های ۲ استفاده شده است و بر این اساس، تبدیل موجک گسسته به صورت زیر به دست می‌آید [۲۵]:

$$DWT(j, k) = \frac{1}{\sqrt{|2^j|}} \int_{-\infty}^{\infty} x(t) \cdot \psi\left(\frac{t-2^j k}{2^j}\right) dt \quad (3)$$

شکل ۳ نشان‌دهنده تفاوت در جزئیات سطوح ۳ و ۴ برای مراحل مختلف خواب است.



شکل (۳)- جزئیات ۳ و جزئیات ۴ ناشی از تجزیه DWT

۲-۲- ویژگی‌ها

پس از این که سیگنال به ۴ زیر سطح خود تجزیه شد ۸ ویژگی آماری از هر سطح تجزیه شده گرفته می‌شود. این ویژگی‌ها در زیر ارائه شده‌اند:

۱- توان

$$power(x(n)) = \frac{\sum_{n=1}^N (x(n))^2}{N} \quad (4)$$

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

<sup>۲۷</sup> Skewness

<sup>۲۶</sup> Kurtosis

به طور تصادفی بین ۰ و ۱ تولید می شود و  $q_0$  نیز پارامتری است که توسط کاربر تعیین می شود و بین ۰ و ۱ است.  $j$  نیز یک متغیر تصادفی است و براساس تابع توزیع احتمال ارائه شده در معادله ۱۳ تولید می شود. در معادله ۱۳،  $P_k(i, j)$  احتمال انتخاب مسیر  $j$  ام است.

$$P_k(i, j) = \begin{cases} \frac{[\lambda(i, j)] \cdot [v(i, j)]^\beta}{\sum_{r \in T_k(i)} [\lambda(i, r)] \cdot [v(i, r)]^\beta} & \text{if } j \in T_k(i) \\ 0 & \text{otherwise} \end{cases} \quad (13)$$

معادله ۱۴ برای به روزرسانی محلی اثر فرمون استفاده می شود. این به روزرسانی محلی زمانی اتفاق می افتد که مورچه  $k$  ام از محل مسیر  $i$  به محل مسیر  $j$  می رود. در این معادله  $\rho$  پارامتر محو شدن اثر فرمون محلی روی مسیر است و مقدار آن بین ۰ و ۱ تعریف می شود و  $\lambda_0$  مقدار فرمون اولیه بر روی مسیرها است.

$$\begin{aligned} \lambda(i, j) &= (1 - \rho)\lambda(i, j) + \rho\Delta\lambda(i, j), \\ \Delta\lambda(i, j) &= \lambda_0 \end{aligned} \quad (14)$$

پس از آن که مورچه ها مسیرهای خود را تولید نمودند، به روزرسانی کلی اثر فرمون طبق معادله ۱۵ انجام می گیرد که در آن  $\alpha$  پارامتر محو شدن اثر فرمون کلی روی مسیر است و مقدار آن بین ۰ و ۱ تعریف می شود. همچنین  $L_{gb}$  طول بهترین مسیر از ابتدای حل است.

$$\lambda(i, j) = (1 - \alpha)\lambda(i, j) + \alpha \frac{1}{L_{gb}} \quad (15)$$

شبکه عصبی، یک شبکه چندلایه پرسپترون تحت قاعده پس انتشار خطا با استفاده از تابع آموزش تحت عنوان لوبنبرگ-مارکوات است. معماری شبکه عصبی به صورت feed-forward در نظر گرفته شده است [۲۷]. در هر بار آموزش شبکه عصبی مقدار ۵۰٪ داده ها به عنوان مجموعه آموزشی و ۵۰٪ داده ها به عنوان مجموعه آزمایشی به کار گرفته می شود. در نهایت مقدار MSE شبکه برای هر بردار ویژگی ورودی محاسبه شده و برای محاسبه خطای شبکه عصبی از روابط زیر استفاده می شود:

$$net_j = \sum_{i=0}^m w_{ji}(n)y_i(n) \quad (16)$$

$$y_j = f_j(net_j) \quad (17)$$

$$e_j(n) = d_j(n) - y_j(n) : \text{Error} \quad (18)$$

که  $d$  خروجی هدف و  $y$  خروجی حاصل از شبکه است. همچنین مقدار  $e$  خطای عملکردی شبکه است. لذا خطای کل خروجی شبکه عصبی  $\xi$ ، به ازای  $c$  نورون در لایه خروجی برابر است با:

از سیگنال های جزئیات، تقریب آخر و ضرایب موجک گرفته شده است. که در مجموع  $48 = 8 \times (4+2)$  ویژگی استخراج می شود.

### ۲-۳- انتخاب و کاهش ویژگی های آماری مطلوب

پس از استخراج ویژگی، باید ویژگی های مطلوب انتخاب شده و ویژگی های نامطلوب حذف شوند. انتخاب ویژگی راه حل قطعی ندارد ولی می توان با تبدیل آن به یک مسئله بهینه سازی و با کمک الگوریتم های متنوع خصوصاً الگوریتم های هوشمند ویژگی های مناسب را انتخاب نمود. در روش پیشنهادی برای یافتن ویژگی های مناسب از مدل ترکیبی الگوریتم ACO و شبکه عصبی MLP استفاده شده است و در ادامه از آزمون anova برای تأیید صحت ویژگی های مطلوب که دارای سطح معناداری آماری هستند، استفاده می شود.

### ۲-۴- ساختار ترکیبی شبکه MLP و ACO

به منظور تعیین بهترین ویژگی ها از نظر متمایز کنندگی در روش پیشنهادی از ترکیب الگوریتم ACO و شبکه عصبی MLP استفاده شده است.

الگوریتم ACO یک روش فراابتکاری برای حل مسائل بهینه سازی است که برای اولین بار توسط مارکو دوریگو مطرح شد [۲۶]. این الگوریتم مبتنی بر رفتار کلونی مورچه های واقعی است. در واقع مورچه های واقعی نابینا هستند، اما توانایی یافتن کوتاهترین مسیر به سمت منبع غذایی را دارا می باشند و این کار را به کمک برجای گذاری اثر فرمون انجام می دهند. مورچه های مصنوعی از قوانین انتقال (معادله ۱۲ و ۱۳) استفاده نموده و رفتار مورچه های واقعی را تقلید نموده و مقصد بعدی را می یابند. همچنین مورچه های مصنوعی از قوانین به روزرسانی اثر فرمون (معادله ۱۳ و ۱۴) استفاده می نمایند و از آن برای به روزرسانی اثر فرمون روی مسیرها استفاده می کنند.

$$j = \begin{cases} \arg \max_{r \in T_k(i)} \{[\lambda(i, r)] \cdot [v(i, r)]^\beta\} & \text{if } q \leq q_0 \\ J & \text{otherwise} \end{cases} \quad (12)$$

در رابطه ۱۲،  $k$  یک مورچه ی مصنوعی است که وظیفه ی آن ایجاد مسیر است. همراه با مورچه ی  $k$  ام لیستی تحت عنوان  $T_k(i)$  شامل تمامی مسیرهایی که ملاقات نشده اند، وجود دارد.  $\lambda(i, r)$  نشان دهنده مقدار اثر فرمون بر روی کمان بین دو محل  $i$  و  $r$  است.  $v(i, r)$  یک مقدار ابتکاری است و از معکوس فاصله بین دو مسیر  $i$  و  $r$  حاصل می شود و  $\beta$  پارامتری است که اهمیت نسبی  $v(i, r)$  را نشان می دهد.  $q$  مقداری است که

### الگوریتم RUSBoost:

در مرحله اول، به هر نمونه آموزشی وزن اولیه  $\frac{1}{m}$  اختصاص داده می‌شود که  $m$  تعداد نمونه‌های آموزشی است. سپس  $T$  طبقه‌بندی پایه ضعیف، به‌طور مکرر طبق مراحل زیر آموزش داده می‌شود:

(الف) با انجام روش تصادفی زیر نمونه‌برداری برای حذف نمونه‌های کلاس اکثریت،  $N$  درصد از نتایج در مجموعه داده‌ی آموزشی جدید (موقتی)  $S_t$  به‌کاربرده می‌شوند.

(ب)  $D_t$  و  $S_t$  برای ایجاد طبقه‌بندی پایه ضعیف  $h_t$  در گام  $c$  به‌عنوان ورودی یادگیرنده‌ی ضعیف در نظر گرفته می‌شوند.

(ج) طبقه‌بندی پایه جدید  $h_t: X \times Y \rightarrow [0, 1]$  که تمامی نمونه‌های  $x_i$  را در اختیار دارد، جهت پیش‌بینی درستی یا نادرستی برچسب کلاس ایجاد می‌شود.

(د) نرخ خطا  $\epsilon_t$  مبتنی بر مجموعه آموزشی اصلی  $S$  و توزیع وزن  $D_t$ ، در این مرحله محاسبه می‌شود.

$$\epsilon_t = \sum_{(i,y):y \neq y_i} D_t(i)(1-h_t(x_i,y_i)+h_t(x_i,y))$$

(ه) در این مرحله پارامتر به‌روزرسانی وزن  $\alpha = \frac{\epsilon_t}{1-\epsilon_t}$  محاسبه می‌شود.

(و) اگر برچسب نمونه‌ی آموزشی درست پیش‌بینی شود وزنش در توزیع وزن برای ایجاد فرضیه‌ی جدید در تکرار بعدی ثابت می‌ماند؛ در غیر این صورت به میزان  $\alpha_t$  افزایش وزن خواهد داشت.

$$D_{t+1}(i) = D_t(i) \alpha_t^{\frac{1}{2}(1+h_t(x_i,y_i))-h_t(x_i,y; y \neq y_i)}$$

(ز) در این مرحله عمل نرمال‌سازی در توزیع وزن صورت می‌گیرد.

$$Z_t = \sum_i D_{t+1}(i)$$

$$D_{t+1}(i) = \frac{D_{t+1}(i)}{Z_t}$$

بعد از  $T$  بار تکرار گام‌های ۲، فرضیه‌ی نهایی  $H(x)$  به‌عنوان رأی وزن‌دار شده فرضیه‌های ضعیف برگشت داده می‌شود.

$$H(x) = \arg \max_{y \in Y} \sum_{i=1}^T h_i(x, y) \log \frac{1}{\alpha_i}$$

شکل (۴) - شبه کد مربوط به الگوریتم RUSBoost

### ۳- نتایج و بحث

در این بخش ابتدا به بررسی پایگاه داده‌ی مورد استفاده برای آزمایش پرداخته می‌شود، سپس نتایج حاصل از بهینه‌سازی و طبقه‌بندی ارائه خواهد شد.

#### ۳-۱- مجموعه‌ی داده‌های EEG

در بخش انتخاب داده‌ها، از مجموعه‌ی داده‌های Sleep-EDF از پایگاه Physionet Data Bank که یک پایگاه عمومی برای دریافت داده EEG می‌باشد، به‌عنوان مجموعه‌ی داده آزمایش و ارزیابی استفاده شده است [۲۹]. ثبت داده مربوطه از مردان و زنان قفقازی (۲۱-۳۵ ساله) بدون استفاده از هیچ دارویی به‌دست آمده است. هشت داده در دو زیرمجموعه با عنوان‌های sc و st در طول خواب ثبت شده است. چهار داده‌ی اول با عنوان sc مربوط با افراد سالم و چهار داده دوم با عنوان st مربوط به افرادی است که دچار خواب‌آلودگی خفیف بوده‌اند. برای ثبت

$$\xi(n) = \sum_{j=c} e^2(n) : \text{total Error} \quad (19)$$

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

$$MSE = \xi_{ave} = \frac{1}{N} \sum_{n=1}^N \xi(n) \quad (20)$$

پس از آموزش شبکه، مقدار  $\frac{1}{MSE}$  به‌عنوان تابع برازندگی الگوریتم ACO به‌صورت زیر محاسبه می‌شود [۲۸]:

$$\text{fitness function} = \frac{1}{MSE(\text{net})} \quad (21)$$


در روش پیشنهادی پس از استخراج ویژگی‌ها با تبدیل موجک گسسته، برای انتخاب ویژگی‌های مطلوب، از مدل ترکیبی الگوریتم ACO و شبکه عصبی استفاده شده و ۴۸ ویژگی استخراج‌شده از توابع تجزیه به ۲۵ ویژگی کاهش می‌یابد.

### ۲-۵- تایید ویژگی‌های انتخابی با استفاده از آنالیز آماری

در این مقاله از آزمون Anova (واریانس یک‌طرفه) برای تأیید صحت ویژگی‌های انتخاب‌شده از بخش ۲-۴ استفاده می‌شود. آزمون‌ها در جعبه آمار MATLAB در سطوح اطمینان ۰/۹۵ انجام می‌شوند. در این آنالیز ویژگی‌هایی که مقادیر p-value آن‌ها کمتر از ۰/۰۵ باشد بیانگر ویژگی‌های مطلوب خواهند بود.

### ۲-۶- طبقه‌بند RUSBoost

RUSBoost یکی از الگوریتم‌های نمونه‌برداری مبتنی بر boosting است که برای کنترل مجموعه داده‌های نامتوازن طراحی شده است [۲۹]. این الگوریتم روش تصادفی زیر نمونه‌برداری و Adaboost را با یکدیگر ترکیب می‌کند. در این روش نمونه‌ها به‌طور تصادفی تا زمانی که به میزان مطلوب توازن برسند، از کلاس اکثریت حذف می‌شوند.  $X_i$  نقطه‌ای در فضای ویژگی  $x$  و  $y_i$  به‌عنوان برچسب کلاسی در مجموعه‌ای از برچسب‌های کلاس  $Y = \{0, +1\}$  فرض می‌شوند.  $m$  نمونه در مجموعه داده‌ی  $s$  توسط زوج مرتب  $i = \{1, 2, \dots, m\} (x_i, y_i)$  نشان داده می‌شوند.  $t$  تکرار آموزش و  $T$  کل تکرار الگوریتم تا ساخت طبقه‌بندی نهایی است.  $h_t$  طبقه‌بندی پایه ضعیف است که در تکرار  $t$  ام توسط الگوریتم طبقه‌بندی آموزش داده می‌شود و  $h_t(x_i)$  خروجی طبقه‌بندی  $h_t$  است.  $D_t(i)$  وزن  $i$  امین نمونه در تکرار  $t$  ام است (وزن‌ها عموماً به عدد یک نرمالیزه شده‌اند). شکل ۴ شبه‌کد این طبقه‌بند را نشان می‌دهد.



شکل (۵) - همگرایی ACO در ترکیب با شبکه عصبی MLP

### ۳-۳- طبقه‌بندی با RUSBoost

در این بخش، طبقه‌بند، جزئیات، نتایج آزمایش‌ها و برخی نتایج مهم بیان می‌شود. مشخصات رایانه‌ای که در شبیه‌سازی این مقاله مورد استفاده قرار گرفته اینتل Core (TM) i5-3470، پردازنده ۱/۶ گیگاهرتز و رم ۸ گیگابایت است. در این مقاله ۲۵ ویژگی تایید شده توسط ANOVA، به‌عنوان ورودی طبقه‌بند RUSBoost مورد استفاده قرار می‌گیرد. پارامترهای مربوط به طبقه‌بند با تعداد چرخه‌های یادگیری ۱۰۰۰، نرخ یادگیری ۰/۱ و تعداد تکرار ۱۰۰ تنظیم شده است. تنظیم پارامترهای طبقه‌بند، به‌واسطه‌ی سعی و خطا بوده است. برای این منظور از کل داده‌های موجود از پایگاه EDF برای شبیه‌سازی استفاده شده است، به‌گونه‌ای که ۵۰٪ داده‌ها به‌عنوان مجموعه آموزشی، ۲۰٪ داده‌ها به‌عنوان مجموعه اعتبارسنجی و ۳۰٪ داده‌ها به‌عنوان مجموعه‌ی آزمایشی استفاده شده است. علاوه بر این، برای نشان دادن عملکرد مطلوب طبقه‌بند پیشنهادی، به غیر از RUSBoost، از طبقه‌بندهای نزدیک‌ترین همسایه [۳۱]، Naive Bayes [۳۲]، Discriminant Analysis [۳۳] و جنگل تصادفی [۴] برای طبقه‌بندی استفاده شده است. برای DA، عملکرد سه تابع شناخته شده خطی، درجه دو و Mahalanobis مورد بررسی قرار گرفته است. شکل ۷ عملکرد روش پیشنهادی را برای کلاس‌های مختلف نشان می‌دهد. همان‌طور که از شکل ۷ مشاهده می‌شود، RUSBoost به‌عنوان بهترین مدل طبقه‌بندی در بین طبقه‌بندهای دیگر عمل می‌کند.

داده از کانال‌های Pz-Oz و Fpz-Cz استفاده شده است [۳۰]. همچنین فرکانس نمونه‌برداری ۱۰۰ هرتز است. مطالعات پیشین نشان می‌دهد سیگنال EEG ثبت‌شده از کانال Pz-Oz عملکرد بهتری در طبقه‌بندی نسبت به کانال Fpz-Cz ارائه می‌دهد [۱۲، ۱۳]؛ بنابراین در این پژوهش از کانال Pz-OZ استفاده شده است. هر ۳۰ ثانیه داده‌های EEG مطابق با دستورالعمل‌های R&K از پایگاه Sleep-EDF به‌دست آمده است. طول مدت‌زمان هر Epoch در این مطالعه ۳۰ ثانیه یا ۳۰۰۰ نمونه است. هر اپیک توسط متخصصان خواب در یکی از ۸ کلاس AWA، S1، S2، S3، S4، REM، MVT (زمان حرکت) و UNS (حالت‌های ناشناخته) دسته‌بندی شده است. جدول ۲ خلاصه‌ای از اپیک‌های مختلف کلاس‌های مورد استفاده در این پژوهش را نشان می‌دهد. همان‌طور که از جدول ۲ مشاهده می‌شود، تعداد کل اپیک‌های ۳۰ ثانیه‌ای که در این مطالعه مورد استفاده قرار می‌گیرند، ۱۵۱۸۸ است. برای انجام آزمایش‌ها، نیمی از مجموعه داده‌های خواب Sleep-EDF به‌طور تصادفی برای آموزش مجموعه و بقیه داده‌ها به‌عنوان ارزیابی مجموعه انتخاب شده‌اند. به این ترتیب، اطمینان حاصل شده است که تمام مجموعه داده‌های Sleep-EDF را می‌توان برای آموزش یا آزمون استفاده کرد.

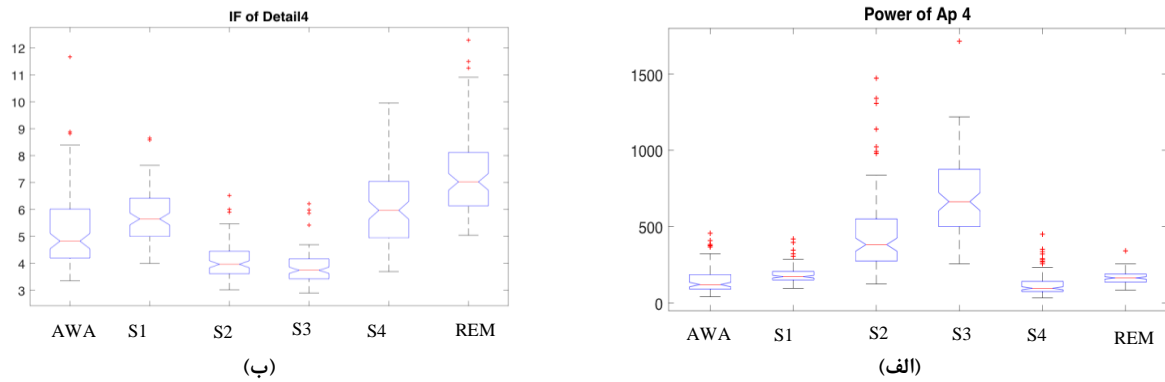
### جدول (۲) - تعداد اپیک‌ها از داده‌های Sleep-EDF

	AWA	S1	S2	S3	S4	REM
اپیک <sup>۲۸</sup>	۸۰۵۵	۶۰۴	۳۶۲۱	۶۷۲	۶۲۷	۱۶۰۹

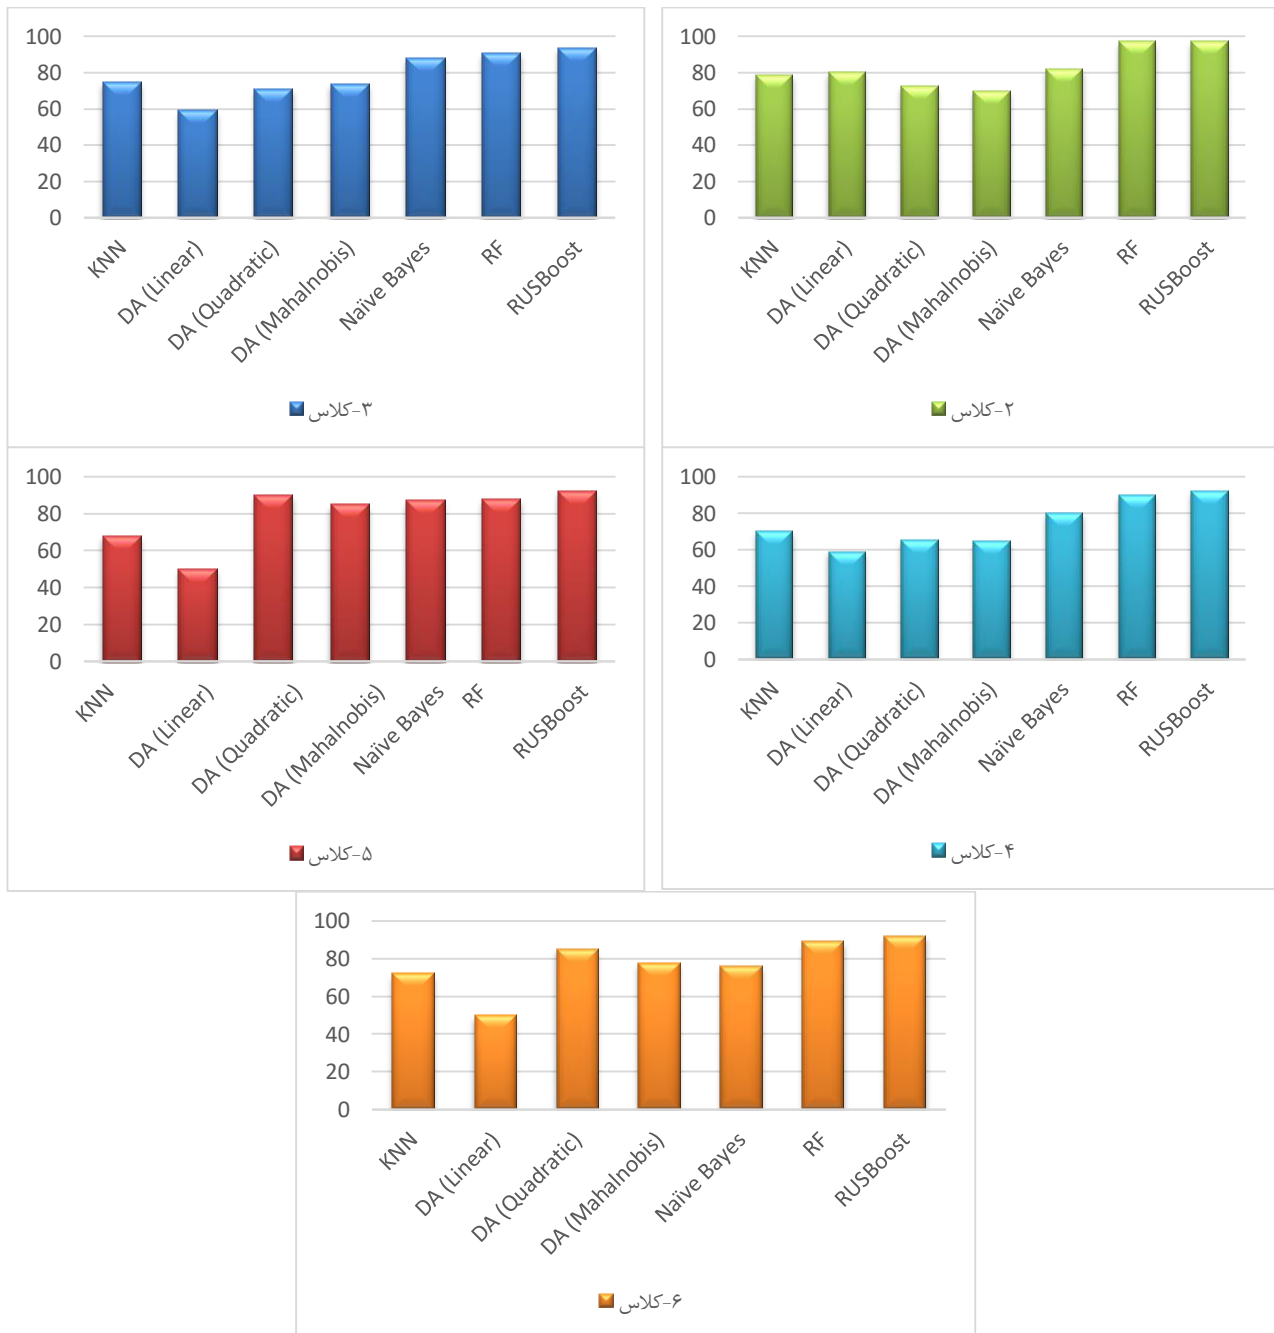
### ۳-۲- نتایج حاصل از بهینه‌سازی

با تنظیم مقدار ۱ برای مقدار اولیه فرمون، جمعیت ۲۰ تایی، نرخ تبخیر فرمون ۰/۰۵، وزن نمایی ۱، با تعداد ۸۰ تکرار و آموزش‌های مداوم شبکه عصبی MLP و تولید بردارهای ویژگی تصادفی، سرانجام الگوریتم ACO به سمت مقدار بهینه همگرا می‌شود، شکل ۵ این همگرایی را نشان می‌دهد. جدول ۳ و شکل ۶ مقادیر p-value ویژگی‌های انتخاب شده با استفاده از آزمون Anova را نشان می‌دهد. در این آزمون ویژگی‌هایی که p-value های آن‌ها کمتر از ۰/۰۵ باشد، بیانگر ویژگی‌های مطلوب است. با توجه به جدول ۳ و شکل ۶ می‌توان نتیجه گرفت که ۲۵ ویژگی انتخابی از مدل ترکیبی الگوریتم ACO و شبکه عصبی، ویژگی‌های مطلوبی هستند.

<sup>۲۸</sup> Epoch



شکل (۶) - نمودار Box-whisker (الف) توان از Approximate 4 و (ب) فاکتور ضربه از Detail 4



شکل (۷) - عملکرد روش پیشنهادی برای کلاس‌های مختلف

جدول (۳) - p-value ویژگی های انتخاب شده از جزئیات، تقریب آخر و ضرایب موجک

	انحراف معیار	توان	میانگین	چولگی	کشیدگی	فاکتور ضربه	انرژی	مومنوم
Detail 1	۰	۰	-	۰/۰۱۱	$4/05e^{-77}$	$1/95e^{-88}$	-	-
Detail 2	-	$6/22e^{-228}$	-	-	-	$2/65e^{-228}$	$6/22e^{-287}$	-
Detail 3	-	-	۰/۰۶۳	-	$1/17e^{-62}$	-	$1/22e^{-243}$	$6/22e^{-121}$
Detail 4	$1/42e^{-254}$	$9/74e^{-228}$	-	۰/۰۱۶	$1/39e^{-67}$	-	$5/17e^{-225}$	-
Aproximate 4	$2/18e^{-197}$	$1/62e^{-124}$	$3/19e^{-4}$	-	-	-	$1/62e^{-124}$	-
Coefficiens	۰	۰	۰/۰۷۵	-	-	-	۰	-

جدول (۴) - زمان اجرای طبقه‌بند پیشنهادی در مقایسه با طبقه‌بندهای دیگر برای داده‌ی SC4002 از پایگاه Sleep-EDF

طبقه‌بند	بهینه‌سازی	داده	زمان (ثانیه)
KNN	-	SC4002	۲۳
DA (Linear)	-	SC4002	۱۵۹
DA (Quadratic)	-	SC4002	۲۸۷
DA (Mahalanobis)	-	SC4002	۲۵۶
Naïve Bayes	-	SC4002	۲۴۳
RF	-	SC4002	۳۹۲
RUSboost	ACO	SC4002	۴۰۱

جدول (۵) - مقایسه الگوریتم پیشنهادی با سایر الگوریتم‌ها برای طبقه‌بندی ۶-کلاسه خواب از پایگاه Sleep-EDF

استخراج ویژگی	بهینه‌ساز	طبقه‌بند	صحت طبقه‌بندی برای ۶ کلاس
D-WT	-	BPNN	٪۸۰
D-WT	ACO	BPNN	٪۸۲
D-WT	ACO	RUSBoost	٪۹۲

خروجی به احتمال، استفاده شده است [۳۴]. جدول ۵ مقایسه عملکرد روش پیشنهادی با شبکه عصبی را نشان می‌دهد. همان‌طور که از جدول ۵ مشخص است، عملکرد روش پیشنهادی در مقایسه با BPNN و ترکیب BPNN و ACO از لحاظ صحت امیدوارکننده است. جدول ۶ مقادیر صحت<sup>۲۹</sup> روش‌های مختلفی که از مجموعه داده Sleep-EDF استفاده کرده‌اند را نشان می‌دهد. همان‌طور که از جدول ۶ مشاهده می‌شود تمامی مقادیر گزارش شده برای روش پیشنهادی دارای ضریب صحت بالای ۹۰٪ است. با توجه این که صحت پژوهش‌های [۱۱] و [۱۶] برای طبقه‌بندی ۶-کلاس مراحل خواب که به ترتیب ۸۸/۶۲٪ و ۹۰/۵۰٪ هستند، صحت روش پیشنهادی ۹۳/۲۰٪ درصد است. شکل ۸ نمودار ROC برای طبقه‌بندی مطابق با جدول ۱ را نشان می‌دهد. با توجه به شکل

همچنین سرعت و زمان اجرای طبقه‌بند پیشنهادی در مقایسه با طبقه‌بندهای شبیه‌سازی شده در شکل ۷، در جدول ۴ نمایش داده شده است. طبق جدول ۴ زمان اجرای طبقه‌بند پیشنهادی نسبت به سایر طبقه‌بندها بیشتر است اما دارای ضریب صحت بالای ۹۰ درصد برای طبقه‌بندی ۶ کلاسه مراحل خواب خواهد بود. همچنین برای نشان دادن عملکرد مطلوب روش پیشنهادی، از یک شبکه عصبی پرسپترون چند لایه با الگوی پس‌انتشار خطا با استفاده از تابع آموزشی لونیبرگ-مارکوات استفاده شده است. شبکه BPNN استفاده شده در این مقاله یک شبکه دولایه بوده که با در نظر گرفتن ۳۰ نورون در لایه مخفی، شبکه بهترین عملکرد را در طبقه‌بندی حالت‌های مختلف خواب از خود نشان می‌دهد. لازم به ذکر است که تابع انتقال لایه مخفی به صورت سیگموئید است و از تابع softmax برای تبدیل مقادیر لایه

<sup>۲۹</sup> Accuracy


۸ چون همگی کلاس‌ها بین بازه ۰/۸۵ تا ۱ قرار دارند در مجموع می‌توان نتیجه گرفت عملکرد روش پیشنهادی از لحاظ

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


کلاس-۶	کلاس-۵	کلاس-۴	کلاس-۳	کلاس-۲	الگوریتم‌های مختلف
٪۰/۸۶۱	-	-	-	-	Doroshenkov et al. [21]
٪۹۸/۶۹	-	-	-	-	Vural and Yildiz [20]
-	٪۹۸/۷۷	-	-	-	Liang et al. [18]
-	٪۶۰/۸۳	-	-	-	Liang et al. [14]
-	٪۲۰/۸۷	-	-	-	Kayikcioglu et al. [19]
٪۷۶/۷۰	-	٪۴۲/۸۱	٪۸۸/۹۷	٪۹۶/۹۰	Ronzhina et al. [13]
٪۸۷/۵۰	٪۸۸/۹۰	٪۸۹/۳۰	٪۹۲/۶۰	٪۹۷/۹۰	Zhu et al. [12]
٪۸۸/۶۲	٪۱۱/۹۰	٪۹۱/۲۰	٪۹۳/۵۵	٪۹۷/۷۳	Hassan and Bhuiyan [11]
٪۹۰/۵۰	٪۹۱/۵۰	٪۹۲/۳۰	٪۹۳/۹۰	٪۳۰/۹۷	Silveir et al. [16]
٪۹۲/۰۰	٪۹۲/۱۰	٪۹۱/۱۰	٪۹۳/۹	٪۹۷/۲۶	روش پیشنهادی

جدول (۷) - ماتریس درهم‌ریختگی برای هر یک از ۶ حالت خواب از پایگاه داده Sleep-EDF

	REM	AWA	S1	S2	S3	S4	SEN (%)
REM	۷۸۰	۹۰	۴۴	۸	۰	۰	۸۴/۶
AWA	۱۵	۳۶۶۹	۱	۱۲۵	۰	۰	۹۶/۳
S1	۹	۲۵	۲۴۱	۹	۱	۰	۸۴/۶
S2	۱	۲۴۳	۱۶	۱۶۶۸	۱	۰	۸۶/۵
S3	۰	۰	۰	۰	۳۱۷	۵	۹۸/۴
S4	۰	۰	۰	۰	۱۷	۳۰۹	۹۴/۸



شکل (۹): درصد اثر بخشی ویژگی‌های منتخب روش پیشنهادی



شکل (۸) - منحنی ROC برای هر یک از ۶ حالت خواب

خواب در جدول ۷ مشاهده می‌شود. شکل ۹ نشان دهنده درصد اثر بخشی ویژگی‌های منتخب روش پیشنهادی می‌باشد. همچنین برای نشان دادن مقاوم بودن الگوریتم پیشنهادی در

اعتبار و قابلیت اطمینان امیدوارکننده است. همچنین عملکرد روش پیشنهادی به‌طور جداگانه برای طبقه‌بندی ۶-کلاسه

## ۶- نتیجه گیری


در این مقاله شناسایی خودکار مراحل خواب با استفاده از روش تبدیل موجک گسسته و مدل ترکیبی الگوریتم ACO و شبکه عصبی مبتنی بر طبقه‌بند RUSBoost ارائه شد. در روش پیشنهادی سیگنال EEG تک کاناله با استفاده از روش تبدیل موجک گسسته به ۴ سطح تجزیه شده و چند ویژگی آماری-زمانی از سطوح تجزیه استخراج شد. سپس با استفاده از ترکیب الگوریتم ACO و شبکه عصبی ویژگی‌های مهم انتخاب شد و به عنوان ورودی طبقه‌بند RUSBoost، جهت تفکیک کلاس‌ها از یکدیگر مورد استفاده قرار گرفت. در این پژوهش صحت ویژگی‌های بهینه انتخاب شده از مدل ترکیبی الگوریتم ACO و شبکه عصبی با استفاده از آزمون آماری Anova بررسی شد. نتایج نشان داد که انتخاب ویژگی‌های آماری-زمانی مطلوب، در تشخیص مراحل مختلف خواب بسیار مؤثر است.

نتایج الگوریتم برای طبقه‌بندی ۲-کلاس تا ۶-کلاس ضریب صحت بالای ۹۰٪ را ارائه می‌دهد، علاوه بر این با توجه به بالا بودن صحت الگوریتم، می‌توان از آن برای تشخیص اختلالات خواب، رفتار و همچنین برای تشخیص بیماری‌ها از جمله بیماری پارکینسون و نارسایی‌های لپسی استفاده کرد. روش پیشنهادی برای تشخیص خودکار مراحل خواب روند سرعت تشخیص اختلالات خواب را افزایش می‌دهد و همچنین می‌تواند برای داده‌های حجیم EEG مورد استفاده قرار گیرد.

## ۶- مراجع

- [1] 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.
- [2] S. Leistedt, M. Dumont, J.-P. Lanquart, F. Jurysta, and P. Linkowski, "Characterization of the sleep EEG in acutely depressed men using detrended fluctuation analysis," *Clinical neurophysiology*, vol. 118, no. 4, pp. 940-950, 2007.
- [3] 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.
- [4] 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.
- [5] 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.
- [6] B. Boashash and S. Ouelha, "Automatic signal abnormality detection using time-frequency features and machine learning: A newborn EEG seizure case

برابر نویز، نویز گوسی با SNR ۲۰ تا ۴- دسی‌بل به داده اضافه شد. همان‌طور که از شکل ۱۰ مشاهده می‌شود، صحت الگوریتم پیشنهادی تا ۱۰ دسی‌بل برای طبقه‌بندی ۶-کلاس خواب ثابت بوده است.



شکل (۱۰)- مقایسه‌ی صحت الگوریتم پیشنهادی با اعمال توان نویزهای مختلف برای طبقه‌بندی ۶-کلاس خواب.

## ۵- بحث

عوامل مختلفی به عملکرد شناسایی خودکار مراحل خواب پیشنهادی کمک می‌کنند. اولاً، استفاده از بهینه‌ساز ACO با هدف کاهش ابعاد ویژگی زمان آموزش را برای طبقه‌بند کوتاه می‌کند، این امر باعث می‌شود تا بتوان از الگوریتم پیشنهادی به‌عنوان دستیار پزشک و یا دستگاه‌های نظارت در خانه برای شناسایی خودکار مراحل خواب مورد استفاده قرار گیرد. دوم اینکه، سیگنال EEG خواب شامل تعداد نمونه‌های یکسان برای هر یک از ۶ حالت خواب نیست. در واقع، تعداد توزیع دوره‌ها در حالت‌های مختلف خواب بسیار بی‌ثبات است. مشاهده جدول ۲ این حقیقت را ثابت می‌کند. از جدول ۲ مشاهده می‌شود که بیش از نیمی از دوره‌ها مربوط به حالت AWA است. دوره‌های S1، S3 و S4 با توجه به بقیه حالت‌های خواب سهم کمتری را در خواب افراد دارند. این مسئله باعث عدم تعادل بین کلاس‌ها در تجزیه و تحلیل سیگنال‌های EEG می‌شود. عدم تعادل بین کلاس‌ها مشکلی است که باعث ایجاد خطا و بایاس شدن طبقه‌بند در هنگام طبقه‌بندی داده‌ها به سمت کلاس اکثریت می‌شود. اکثر پژوهش‌های پیشین این مشکل را حل نمی‌کنند [۳۶، ۳۵] از این رو، از عملکرد ضعیف طبقه‌بند رنج می‌برند. در روش پیشنهادی برای حل این مشکل از طبقه‌بند RUSBoost برای حل مشکل عدم توازن کلاس‌ها استفاده شده است. طبقه‌بند پیشنهادی به عدم توازن کلاس‌ها حساس نبوده و بهترین عملکرد را برای طبقه‌بندی مراحل خواب ایفا می‌کند.

- processing using hidden Markov models," *Biomedical Engineering*, vol. 41, no. 1, pp. 25-28, 2007.
- [22] Ocak, Hasan. "Optimal classification of epileptic seizures in EEG using wavelet analysis and genetic algorithm." *Signal processing* 88, no. 7 pp. 1858-1867, 2008
- [23] Ghosh-Dastidar, Samanwoy, Hojjat Adeli, and Nahid Dadmehr. "Mixed-band wavelet-chaos-neural network methodology for epilepsy and epileptic seizure detection." *IEEE transactions on biomedical engineering* 54, no. 9 pp: 1545-1551, 2007
- [24] C. S. Burrus, R. A. Gopinath, H. Guo, J. E. Odegard, and I. W. Selesnick, *Introduction to wavelets and wavelet transforms: a primer*. Prentice hall New Jersey, 1998.
- [25] A. S. Al-Fahoum and A. A. Al-Fraihat, "Methods of EEG signal features extraction using linear analysis in frequency and time-frequency domains," *ISRN neuroscience*, vol. 2014, 2014.
- [26] M. Dorigo, V. Maniezzo, A. Colomi, "the Ant System: Optimization by a Colony of Cooperating Agent", *IEEE Transactions on Systems, Man and Cybernetics, Part B* 26 (1), pp. 29-41, 1996.
- [27] 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.
- [28] 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.
- [29] T. Seiffert, J. Khoshgoftaar, A. Van Hulse, "Napolitano, Rusboost: a hybrid ap- proach to alleviating class imbalance", *IEEE Trans. Syst. Man Cybern. Part A Syst. Hum.* vol. 40 no. 1, pp 185-197, 2010.
- [30] S. Sheykhivand, T. Yousefi Rezaii, Z. Mousavi, S. Meshgini; "Automatic Stage Scoring of Single-Channel Sleep EEG using CEEMD of Genetic Algorithm and Neural Network"; *Iranian journal of Computational Intelligence in Electrical Engineering*, vol. 9, no. 4, pp 15-28, 2018.
- [31] Y. Liao and V. R. Vemuri, "Use of k-nearest neighbor classifier for intrusion detection1," *Computers & security*, vol. 21, no. 5, pp. 439-448, 2002.
- [32] K. P. Murphy, "Naive bayes classifiers," *University of British Columbia*, vol. 18, 2006.
- [33] Ahmadrhou, Mehran, and Hojjat Adeli. "Enhanced probabilistic neural network with local decision circles: A robust classifier." *Integrated Computer-Aided Engineering* 17, no. 3, pp: 197-210, 2010
- [34] A. J. Izenman, "Linear discriminant analysis," in *Modern multivariate statistical techniques*: Springer, 2013, pp. 237-280.
- [35] C. Berthomier et al., "Automatic analysis of single-channel sleep EEG: validation in healthy individuals," *Sleep*, vol. 30, no. 11, pp. 1587-1595, 2007.
- [۳۶] م. آذرنوش، م. اکبرزاده توتونچی، «تشخیص خودکار مراحل خواب با استفاده از جدول جستجوی فازی» مجموعه مقالات یازدهمین کنفرانس سالانه انجمن کامپیوتر، تهران، ایران، صفحه ۳۵۶-۳۶۰، آذر ۱۳۸۴.
- study," *Knowledge-Based Systems*, vol. 106, pp. 38-50, 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] 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.
- [9] 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.
- [10] Garrett, Deon, David A. Peterson, Charles W. Anderson, and Michael H. Thaut. "Comparison of linear, nonlinear, and feature selection methods for EEG signal classification." *IEEE Transactions on neural systems and rehabilitation engineering* 11, no. 2, pp 141-144, 2003
- [11] 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.
- [12] G. Zhu, Y. Li, and P. P. Wen, "Analysis and classification of sleep stages based on difference visibility graphs from a single-channel EEG signal," *IEEE journal of biomedical and health informatics*, vol. 18, no. 6, pp. 1813-1821, 2014.
- [13] M. Ronzhina, T. Potocnak, O. Janousek, J. Kolarova, M. Novakova, and I. Provaznik, "Spectral and higher-order statistical analysis of the ECG: Application to the study of ischemia in rabbit isolated hearts," *IEEE Transactions on Information Theory* vol.49, no. 6, pp. 645-648: 2012
- [14] S.F. Liang, C.E. Kuo, Y.H. Hu and Y.S. Cheng, "A rule-based automatic sleep staging method," *Journal of neuroscience methods*, vol. 205, no. 1, pp. 169-176, 2012.
- [15] 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.
- [16] 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.
- [17] M. Peker, "A new approach for automatic sleep scoring: Combining Taguchi based complex-valued neural network and complex wavelet transform," *Computer methods and programs in biomedicine*, vol. 129, pp. 203-216, 2016.
- [18] 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 Transactions on Instrumentation and Measurement*, vol. 61, no. 6, pp. 1649-1657, 2012.
- [19] 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.
- [20] 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.
- [21] L. Doroshenkov, V. Konyshev, and S. Selishchev, "Classification of human sleep stages based on EEG