

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

Sheykhivand, Sobhan¹ / Ghaemi, Sehraneh^{2*}

¹ - Ph.D. Student, Biomedical Engineering Department, Faculty of Electrical and Computer Engineering, University of Tabriz, Tabriz, Iran

² - Associate Professor, Faculty of Electrical and Computer Engineering, University of Tabriz, Tabriz, Iran

ARTICLE INFO

DOI: 10.22041/IJBME.2019.100663.1432

Received: 31 December 2018

Revised: 21/5/2019-24/7/2019

Accepted: 8 September 2019

KEYWORDS

Discrete Wavelet Transform
Automatic Sleep Stage Detection
Ant Colony Optimization Algorithm
Rusboost


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.

***Corresponding Author**

Address	Faculty of Electrical and Computer Engineering, University of Tabriz, Tabriz, Iran
Postal Code	5166616471
E-Mail	ghaemi@tabrizu.ac.ir
Tel	+98-41-33393740
Fax	+98-41-33300819





شناسایی خودکار مراحل خواب از سیگنال EEG تک‌کاناله با استفاده از تبدیل موجک گسسته و مدل ترکیبی الگوریتم کلونی مورچگان و شبکه‌ی عصبی مبتنی بر طبقه‌بند RUSBoost

شیخی‌وند، سبحان^۱ / قائمی، سحرانه^{۲*}

^۱ - دانشجوی دکتری مهندسی پزشکی، گروه مهندسی پزشکی، دانشکده‌ی مهندسی برق و کامپیوتر، دانشگاه تبریز، تبریز، ایران

^۲ - دانشیار، گروه مهندسی کنترل، دانشکده‌ی مهندسی برق و کامپیوتر، دانشگاه تبریز، تبریز، ایران

مشخصات مقاله

شناسه‌ی دیجیتال: 10.22041/IJBME.2019.100663.1432

پذیرش: ۱۷ شهریور ۱۳۹۸

بازنگری: ۱۳۹۸/۵/۲-۱۳۹۸/۲/۳۱

ثبت در سامانه: ۱۰ دی ۱۳۹۷

واژه‌های کلیدی	چکیده
تبدیل موجک گسسته شناسایی خودکار مراحل خواب الگوریتم بهینه‌سازی کلونی مورچگان RUSBoost	طبقه‌بندی خودکار مراحل خواب به منظور تشخیص به موقع اختلالات و مطالعات مرتبط با خواب امری ضروری است. در این مقاله یک الگوریتم مبتنی بر EEG تک‌کاناله برای شناسایی خودکار مراحل خواب با استفاده از تبدیل موجک گسسته و مدل ترکیبی الگوریتم کلونی مورچگان و شبکه‌ی عصبی مبتنی بر طبقه‌بند RUSBoost ارائه شده است. سیگنال با استفاده از تبدیل موجک گسسته به چهار سطح تجزیه شده و ویژگی‌های آماری از هر یک از این سطوح استخراج شده است. جهت بهینه‌سازی و کاهش ابعاد بردارهای ویژگی، از یک مدل ترکیبی الگوریتم کلونی مورچگان و شبکه‌ی عصبی چندلایه‌ی پس‌انتشار خطا استفاده شده و سپس از آزمون ANOVA برای تایید صحت ویژگی‌های بهینه بهره گرفته شده است. طبقه‌بندی نهایی روی این ویژگی‌های بهینه شده توسط طبقه‌بند RUSBoost صورت گرفته و مشاهده شده است که به طور میانگین صحت طبقه‌بندی ۲ تا ۶-کلاس مراحل مختلف خواب بالای ۹۰٪ بوده که نشان دهنده‌ی درصد موفقیت بالاتر روش پیشنهادی در طبقه‌بندی مراحل خواب نسبت به پژوهش‌های پیشین می‌باشد.

*نویسنده‌ی مسئول

نشانی	دانشکده‌ی برق و کامپیوتر، دانشگاه تبریز، تبریز، ایران
کد پستی	۵۱۶۶۶۱۶۴۷۱
پست الکترونیک	ghaemi@tabrizu.ac.ir
تلفن	+۹۸-۴۱-۳۳۳۹۳۷۴۰
دورنگار	+۹۸-۴۱-۳۳۳۰۰۸۱۹



۱- مقدمه

خواب یک فرایند ضروری برای حفظ سلامتی و بهبود فعالیت‌های انسان است. هر فرد حدود یک‌سوم زندگی خود را صرف خوابیدن کرده و شرایطی مانند آپنه‌ی انسدادی خواب^۱ (OSA) می‌تواند به شدت بر سلامت جسمی او تاثیر بگذارد [۱]. با توجه به نتایج مقاله‌ی [۲] بیش از ۹۰٪ بیماران مبتلا به افسردگی از اختلالات خواب رنج می‌برند. آپنه‌ی خواب در میان ۲-۴٪ بزرگسالان و ۱-۳٪ کودکان رایج است. همچنین محرومیت از خواب باعث ایجاد خواب‌آلودگی، عدم تمرکز، تغییر ریتم ضربان قلب، کاهش حافظه و ضعف سیستم دفاعی بدن می‌شود [۳]. در درمان بالینی، تجزیه و تحلیل مراحل خواب به طور معمول توسط یک پزشک یا کارشناس متخصص بر اساس بازرسی بصری، از طریق خوابیدن بیمار در بیمارستان و اندازه‌گیری‌های پلی‌سومنوگرافی^۲ (PSG) به همراه مجموعه‌ای از توصیه‌های آکادمی پزشکی^۳ (AASM) و یا R&K^۴ انجام می‌شود. تجزیه و تحلیل مراحل خواب در تشخیص و درمان اختلالات خواب از جمله اختلال رفتاری^۵ (RBD) و نارکولپسی^۶ امری حیاتی است. اندازه‌گیری‌های PSG شامل سیگنال‌هایی مانند الکتروانسفالوگرام (EEG)، الکترواکولوگرام (EOG)، الکترومایوگرام (EMG)، الکتروکاردیوگرام (ECG)، اشباع اکسیژن (SpO₂) و تنفس (Resp) است [۴]. اندازه‌گیری‌های PSG ابتدا به دوره‌های ۲۰ تا ۳۰ ثانیه‌ای تقسیم شده و سپس توسط کارشناس یا پزشک متخصص به دوره‌های مختلف خواب بر اساس بازرسی بصری طبقه‌بندی می‌شوند. (جدول ۱) [۵].

جدول (۱) - دسته‌بندی حالت‌های خواب طبق استاندارد R&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 ساعته‌ی خواب، بازرسی بصری ۲ تا ۴ ساعته روی فرد مورد نظر انجام می‌شود. نظارت مراحل خواب به شیوه‌ی سنتی بر اساس بررسی بصری، امری ناخوشایند، طولانی و توأم با خطا بوده و همچنین نیازمند منابع

انسانی متخصص است [۶]. علاوه بر این، صحت روش سنتی در تحلیل و تشخیص بیماری کم‌تر از ۹۰٪ بوده [۷] و در برخی موارد به تشخیص سریع مراحل خواب نیاز است. بنابراین تجزیه و تحلیل مراحل خواب به شیوه‌ی سنتی نمی‌تواند با چنین شرایطی مراحل خواب را نشان دهد. عوامل ذکر شده اهمیت دسته‌بندی خودکار مراحل خواب را نشان می‌دهد. همچنین مطالعه روی افراد در مقیاس وسیع در تحقیقات خواب به شدت تحت تاثیر این عوامل قرار دارد [۱۱]. بررسی خودکار فرایند تجزیه و تحلیل مراحل خواب نه تنها موجب تشخیص سریع شده بلکه باعث افزایش صحت در تشخیص نیز می‌شود [۸]. پلی‌سومنوگرافی فرایندی پرهزینه بوده و از آن‌جا که خواب در یک محیط ناآشنا ناراحت‌کننده است، می‌تواند بر سلامت خواب بیمار تاثیرگذار باشد [۹]. استفاده از سیگنال‌های EEG با توجه به ارزان بودن و در دسترس بودن، می‌تواند نسبت به PSG مناسب‌تر باشد [۱۰]. با توجه به این چالش‌ها، تشخیص مراحل خواب به صورت خودکار بر اساس سیگنال EEG می‌تواند باعث کاهش زمان تشخیص، افزایش صحت تحلیل طبقه‌بندی مراحل خواب و بهبود تشخیص و درمان اختلالات خواب شود [۱۱]. اکثر الگوریتم‌های شناسایی خودکار مراحل خواب برای تشخیص صحیح به بیش از یک کانال نیاز دارند. شناسایی خودکار مراحل خواب مبتنی بر چند کانال محدودیت‌هایی ایجاد کرده، به مصرف انرژی بیش‌تری نیاز داشته و باعث کاهش کیفیت ثبت داده می‌شود [۱۲]. به همین ترتیب، استفاده از سیگنال‌های حاصل از EEG به الگوریتم مکان‌یابی سیگنال خواب برای استفاده از حداقل تعداد کانال‌های سیگنال فیزیولوژیک نیاز 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 تک‌کاناله، سریع‌تر (حجم محاسباتی کم‌تر)، از نظر جای‌گذاری الکترودها راحت‌تر و از نظر هزینه ارزان‌تر می‌باشد [۱]. بر این اساس شناسایی خودکار مراحل خواب مبتنی بر یک کانال، توجه محققان را به خود جلب کرده است. اکثر روش‌های پیشین برای شناسایی خودکار مراحل خواب به دلیل پایین بودن صحت (زیر ۹۰٪) و طولانی بودن زمان محاسبات برای اجرای سخت‌افزاری، برای تشخیص مراحل خواب مناسب نمی‌باشند [۱۴].

^۱ Rechtschaffen and Kales

^۵ REM Sleep Behavior Disorder

^۶ Narcolepsy

^۱ Obstructive Sleep Apnea

^۲ Polysomnography


^۳ American Academy of Sleep Medicine

بردار ویژگی‌ها و دسته‌بندی کلاس‌ها بهره گرفتند. دورشنکو و هم‌کارانش [۲۱] با استفاده از تبدیل فوریه سریع^۸ (FFT) به تجزیه‌ی سیگنال EEG به فرکانس‌های تتا، آلفا و دلتا پرداخته و از مدل پنهان مارکوف^۹ (HMM) برای طبقه‌بندی کلاس‌های مختلف خواب استفاده کردند. ژو و هم‌کارانش [۱۲] گراف دیداری و گراف افقی را از سیگنال EEG تک‌کاناله تولید کرده و ویژگی از آن‌ها را برای طبقه‌بندی با استفاده از ماشین بردار پشتیبان به کار گرفتند. صحت روش آن‌ها برای طبقه‌بندی ۶-کلاسه‌ی حالت‌های مختلف خواب حدود ۸۷٪ گزارش شده است. حسن و هم‌کارانش [۱۱] با استفاده از الگوریتم تجزیه‌ی حالت تجربی دسته‌ای^{۱۰} (EEMD) به تجزیه‌ی سیگنال EEG تک‌کاناله پرداخته و ویژگی‌های آماری را از آن استخراج کردند. صحت طبقه‌بندی برای مراحل خواب ۶-کلاسه با استفاده از الگوریتم آن‌ها در حدود ۸۸٪ گزارش شده است. از مزایای روش آن‌ها می‌توان به افزایش صحت در تفکیک مرحله‌ی S1 از REM و از معایب پژوهش آن‌ها می‌توان به اختلاط مودها در استفاده از EEMD اشاره کرد. سیلوریا و هم‌کارانش [۱۶] با استفاده از تبدیل موجک گسسته و استخراج ویژگی‌های آماری سیگنال EEG تک‌کاناله با استفاده از طبقه‌بند جنگل تصادفی به صحت حدود ۹۰٪ برای طبقه‌بندی ۶-کلاسه‌ی حالت‌های مختلف خواب دست یافتند. از مزایای کار آن‌ها می‌توان به کاهش بردار ویژگی در مقایسه با پژوهش‌های پیشین اشاره کرد که موجب کاهش حجم محاسباتی الگوریتم شده است. همچنین از معایب پژوهش آن‌ها نیز می‌توان به پایین بودن صحت طبقه‌بندی کلاس‌های ۳ و ۴ اشاره کرد. با توجه به مطالعات انجام شده در پژوهش‌های پیشین مشخص شده است که اکثر الگوریتم‌های موجود برای شناسایی خودکار مراحل خواب، به بیش از یک کانال نیاز دارند که این موضوع برای بیمار ناراحت‌کننده بوده و مانع سنجش دستگاه نظارت خواب در خانه می‌شود.

در این مقاله برای شناسایی خودکار مراحل خواب از روش تبدیل موجک گسسته و مدل ترکیبی الگوریتم کلونی مورچگان^{۱۱} (ACO) و شبکه‌ی عصبی^{۱۲} (MLP) مبتنی بر طبقه‌بند^{۱۳} RUSBoost استفاده شده است. این پژوهش مبتنی بر ۲-۶ حالت خواب مطابق با استاندارد R&K شامل حالت بیدار

از روش‌های مختلفی مانند توزیع زمان و فرکانس [۱۱]، نظریه‌ی گراف [۱۲، ۱۵]، مدل‌سازی سیگنال [۱۲]، تبدیل موجک [۱۶] و تجزیه‌ی حالت تجربی^۱ (EMD) [۱] برای پردازش سیگنال در جداسازی مراحل خواب استفاده شده و برای طبقه‌بندی نیز از مدل‌های مختلفی مانند ماشین بردار پشتیبان^۲ (SVM) [۵] و حداقل مربعات جزئی^۳ (MSE) [۱۲] استفاده می‌شود. در ادامه به بررسی مطالعات اخیر در حوزه‌ی شناسایی خودکار مراحل خواب پرداخته شده است. رونزینا و هم‌کارانش [۱۳] با استفاده از چگالی طیفی توان^۴ (PSD) سیگنال‌های EEG به همراه شبکه‌ی عصبی مصنوعی، یک طرح مبتنی بر EEG تک‌کاناله را ارائه دادند. لاجنل و هم‌کارانش [۵] از ویژگی‌های مختلفی مانند 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. پکر و هم‌کارانش [۱۷] ترکیبی از تبدیل موجک (DT-CWT) و شبکه‌ی عصبی مبتنی بر تاگوچی را برای ثبت خودکار مراحل خواب از یک کانال EEG مورد بررسی قرار دادند. کراکستا و هم‌کارانش [۱۵] ویژگی‌های بسیاری از جمله دامنه‌ی 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 درجه‌ی دوم تحلیل و بررسی کردند. تیسنالس و هم‌کارانش [۷] از تجزیه و تحلیل زمان-فرکانس برای استخراج ویژگی و از الگوریتم رمزگذار خودکار انباشته شده برای طبقه‌بندی استفاده کردند. لیانگ و هم‌کارانش [۱۸] از ویژگی‌های مبتنی بر آنتروپی Renyi استخراج شده از توزیع فرکانس‌های مختلف برای شناسایی مراحل مختلف خواب با EEG تک‌کاناله استفاده کردند. کیکسیگولو [۱۹] یک طرح استخراج ویژگی مبتنی بر مدل خودبازگشتی^۵ (AR) و الگوریتم حداقل مربعات جزئی^۶ (PLS) را برای طبقه‌بندی مراحل خواب ارائه کرد. ورال و هم‌کارانش [۲۰] با استفاده از تبدیل Karhunen-Loeve به تجزیه‌ی سیگنال EEG چندکاناله پرداخته، از ویژگی‌های زمانی-فرکانسی برای استخراج ویژگی‌ها استفاده کرده و از تجزیه‌ی مولفه‌ی اصلی^۷ (PCA) برای کاهش

^۸ Fast Fourier Transform^۹ Hidden Markov Models^{۱۰} Ensemble Empirical Mode Decomposition^{۱۱} Colony Optimization^{۱۲} Multilayer Perceptron^{۱۳} Random Undersampling Boosting^۱ Empirical Mode Decomposition^۲ Support Vector Machine^۳ Mean Squared Error^۴ Power Spectral Density^۵ Autoregressive^۶ Partial Least Squares^۷ Principal Component Analysis



در نتیجه می‌توان رابطه‌ی (۱) را برای این تبدیل در نظر گرفت.

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

تا کنون خانواده‌های متعددی از تبدیل موجک‌ها ارائه شده که هر کدام دارای ویژگی‌های مختلفی هستند. از جمله خانواده‌های تبدیل موجک می‌توان به موجک هار، دابشیز، کوپفلت، سیملت، مورلت و گویسین اشاره کرد [۲۲، ۲۳]. در این مقاله از موجک دابشیز ۱۵ (به طور تجربی و با سعی و خطا)، پاسخ مناسبی برای استخراج ویژگی مورد نظر به دست آمده است. همان‌طور که در شکل (۲) مشاهده می‌شود، سیگنال با استفاده از تبدیل موجک به چهار زیرسطح تجزیه می‌شود. زیرسطح‌های ایجاد شده دارای اطلاعات دقیق‌تری نسبت به سیگنال‌های اصلی بوده و این امر باعث به دست آمدن تحلیل دقیق‌تری از سیگنال می‌شود [۲۴]. تبدیلات موجک برای تجزیه و تحلیل الگوهای داده‌ای نامنظم بسیار مفید هستند. تبدیل موجک پیوسته‌ی (CWT) یک سیگنال، از انتگرال سیگنال در تابع موجک ψ به دست می‌آید (رابطه‌ی ۲).

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

در این رابطه a و b به ترتیب پارامترهای مقیاس و جابه‌جایی هستند. از آن‌جا که محاسبه‌ی ضرایب موجک به ازای تمامی مقادیر پارامترهای a و b وقت‌گیر و پرهزینه است، برای دو پارامتر از توان‌های ۲ استفاده شده و بر این اساس تبدیل موجک گسسته به صورت زیر به دست می‌آید [۲۵].


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

تفاوت جزئیات سطوح ۳ و ۴ مراحل مختلف خواب در شکل (۳) نشان داده شده است.

(AWA)، مراحل حرکتی غیرسریع چشم (s1-s4) و حرکت سریع چشم (REM) است (جدول ۱). در این روش، سیگنال با استفاده از تبدیل موجک گسسته تجزیه شده و چند ویژگی زمانی-آماری از هر یک از سطوح تجزیه شده استخراج می‌شود. سپس با ترکیب الگوریتم ACO و شبکه‌ی عصبی، ویژگی‌های مهم انتخاب شده و از آن‌ها به عنوان ورودی طبقه‌بند RUSBoost برای تفکیک کلاس‌ها از یک‌دیگر استفاده می‌شود. در ادامه، در بخش ۲ به توصیف و تجزیه و تحلیل عمل‌کرد روش استخراج ویژگی و توضیح نحوه‌ی انتخاب ویژگی‌ها، الگوریتم ACO، RUSBoost و شبکه‌ی عصبی پرداخته شده است. در بخش ۳ داده‌های آزمایشی و نتایج تجربی مورد بررسی قرار گرفته و در بخش ۴ نتیجه‌گیری انجام شده است.

۲- مواد و روش‌ها

در این بخش به تشریح استخراج ویژگی‌ها و بررسی انتخاب ویژگی‌ها، الگوریتم ACO و طبقه‌بند RUSBoost پرداخته شده است. طرح کلی روش پیشنهادی در شکل (۱) ارائه شده است.



۲-۱- تبدیل موجک گسسته

تبدیل موجک گسسته (DWT) یکی از روش‌های مهم و محبوب در حوزه‌ی پردازش سیگنال است. اساس کار تبدیل موجک به این ترتیب است که با تجزیه‌ی سیگنال به دو قسمت فرکانس بالا و پایین و تکرار این عمل برای خروجی‌های به دست آمده از هر مرحله‌ی تجزیه، امکان بررسی و تحلیل به مراتب راحت‌تر می‌شود. شکل (۲) روند این تجزیه را نشان می‌دهد. ایده‌ی اصلی تبدیل موجک گسسته از فیلترهای بالا و پایین‌گذر گرفته شده است که سیگنال به دو قسمت فرکانس بالا (جزئیات) و فرکانس پایین (تقریب) تقسیم می‌شود. این روند تا سطح دلخواه ادامه پیدا کرده تا بهترین سطح را جهت آنالیز ارائه کند.

[†] Approximations

[‡] Details

۲-۲-۵- چولگی

چولگی^۲ معیاری از تقارن یا عدم تقارن تابع توزیع است و به صورت زیر محاسبه می‌شود.

$$Skewness = \frac{1}{N} \sum_{i=1}^N \left(\frac{x_i - \mu}{\sigma} \right)^3 \quad (۸)$$

۲-۲-۶- فاکتور ضربه

این ویژگی ماهیت ضربه‌ای سیگنال را بیان کرده که برای پایش سیگنال‌های دارای تغییرات زیاد و گذرا بسیار کاربرد دارد و به صورت زیر محاسبه می‌شود.

$$Impulse Factor = \frac{Max(x(n))}{\frac{1}{N} \sum_{n=1}^N |x(n)|} \quad (۹)$$

۲-۲-۷- انرژی

میزان انرژی یک سیگنال بیان‌گر میزان اغتشاش آن است و به صورت زیر محاسبه می‌شود.

$$Energy = \sum_{n=1}^N (x(n))^2 \quad (۱۰)$$

۲-۲-۸- انحراف معیار استاندارد


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

$$STD(x(n)) = \sqrt{\frac{\sum_{n=1}^N (x(n) - Mean(x(n)))^2}{N - 1}} \quad (۱۱)$$

در این مقاله ۴ سطح تجزیه‌ی موجک برای استخراج ویژگی به کار گرفته شده است. ابتدا سیگنال با استفاده از تبدیل موجک گسسته به ۴ سطح تجزیه شده و سپس ۸ ویژگی آماری-زمانی از سیگنال‌های جزئیات، تقریب آخر و ضرایب موجک گرفته شده و در مجموع $4 \times 8 = 32$ ویژگی استخراج شده است.

۲-۳- انتخاب و کاهش ویژگی‌های آماری مطلوب

پس از استخراج ویژگی، باید ویژگی‌های مطلوب انتخاب شده و ویژگی‌های نامطلوب حذف شوند. انتخاب ویژگی راه حل قطعی ندارد اما می‌توان با تبدیل آن به یک مساله‌ی بهینه‌سازی و با کمک الگوریتم‌های متنوع خصوصاً الگوریتم‌های هوشمند، ویژگی‌های مناسب را انتخاب نمود. در روش پیشنهادی برای یافتن ویژگی‌های مناسب از مدل ترکیبی الگوریتم ACO و



شکل (۳) - جزئیات سطوح ۳ و ۴ ناشی از تجزیه‌ی DWT

۲-۲-۲- ویژگی‌ها

پس از تجزیه‌ی سیگنال به چهار زیرسطح، ۸ ویژگی آماری از هر سطح تجزیه شده گرفته می‌شود که در ادامه به این ویژگی‌ها اشاره شده است.

۲-۲-۱- توان

$$power(x(n)) = \frac{\sum_{n=1}^N (x(n))^2}{N} \quad (۴)$$

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

۲-۲-۲- میانگین

$$Mean(x(n)) = \frac{\sum_{n=1}^N x(n)}{N} \quad (۵)$$

۲-۲-۳- گشتاور مرتبه‌ی چهار

این ویژگی مقدار نرمال شده‌ی سیگنال نسبت به میانگین را نشان داده و به صورت زیر محاسبه می‌شود.

$$Mumentum4 = \frac{\sum_{n=1}^N (x(n) - Mean(x(n)))^4}{(N - 1)} \quad (۶)$$

۲-۲-۴- کشیدگی

این ویژگی کشیدگی^۱ تابع چگالی احتمال سیگنال به یک سمت را نشان داده و به صورت زیر محاسبه می‌شود.

$$Kurtosis = \frac{1}{N} \sum_{i=1}^N \left(\frac{x_i - \mu}{\sigma} \right)^4 \quad (۷)$$

پارامترهای μ و σ به ترتیب بیان‌گر میانگین و واریانس هستند.

^۲ Skewness

^۱ Kurtosis

پارامتر محو شدن اثر فرمون محلی روی مسیر بوده (بین ۰ و ۱) و λ_0 نیز مقدار فرمون اولیه 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 مورچه‌ها مسیرهای خود را تولید نمودند، به‌روزرسانی کلی اثر فرمون طبق رابطه‌ی (۱۵) انجام می‌شود که در آن α پارامتر محو شدن اثر فرمون کلی روی مسیر (بین ۰ و ۱) و L_{gb} طول بهترین مسیر از ابتدای حل است.

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

شبکه‌ی عصبی، یک شبکه‌ی چندلایه‌ی پرسپترون تحت قاعده‌ی پس‌انتشار خطا با استفاده از تابع آموزش تحت عنوان لونیگ-مارکوات است. معماری شبکه‌ی عصبی به صورت feed-forward در نظر گرفته شده است [۲۷]. در هر بار آموزش شبکه‌ی عصبی، ۵۰٪ داده‌ها به عنوان مجموعه‌ی آموزش و ۵۰٪ داده‌ها به عنوان مجموعه‌ی آزمایش در نظر گرفته می‌شود. در نهایت، مقدار MSE شبکه برای هر بردار ویژگی ورودی محاسبه شده و برای محاسبه‌ی خطای شبکه‌ی عصبی از روابط زیر استفاده می‌شود.

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

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

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

در این روابط، d خروجی هدف، y خروجی حاصل از شبکه و e خطای عمل کردی شبکه است. لذا خطای کل خروجی شبکه‌ی عصبی (۵)، به ازای c نورون در لایه‌ی خروجی به صورت زیر به دست می‌آید.

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

هم‌چنین مقدار MSE شبکه برای N داده‌ی آموزشی به صورت زیر محاسبه می‌شود.

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

پس از آموزش شبکه، مقدار $1/MSE$ به عنوان تابع برازندگی الگوریتم ACO به صورت زیر محاسبه می‌شود [۲۸].

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

شبکه‌ی عصبی MLP استفاده شده و در ادامه از آزمون anova برای تایید صحت ویژگی‌های مطلوب که دارای سطح معناداری آماری هستند، بهره گرفته شده است.

۲-۴- ساختار ترکیبی شبکه‌ی MLP و ACO

به منظور تعیین بهترین ویژگی‌ها از نظر متمایزکنندگی در روش پیشنهادی از ترکیب الگوریتم ACO و شبکه‌ی عصبی MLP استفاده شده است. الگوریتم ACO یک روش فراابتکاری برای حل مسائل بهینه‌سازی بوده که برای اولین بار توسط مارکودوریگو مطرح شده است [۲۶]. این الگوریتم مبتنی بر رفتار کلونی مورچه‌های واقعی است. در واقع مورچه‌ها نابینا هستند، اما توانایی یافتن کوتاه‌ترین مسیر به سمت منبع غذایی را داشته و این کار را به کمک برجای‌گذاری اثر فرمون انجام می‌دهند. مورچه‌های مصنوعی از قوانین انتقال (روابط ۱۲ و ۱۳) استفاده کرده، رفتار مورچه‌های واقعی را تقلید نموده و مقصد بعدی را می‌یابند. هم‌چنین مورچه‌های مصنوعی از قوانین به‌روزرسانی اثر فرمون (روابط ۱۳ و ۱۴) استفاده کرده و از آن برای به‌روزرسانی اثر فرمون روی مسیرها استفاده می‌کنند.

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

در رابطه‌ی (۱۲)، k یک مورچه‌ی مصنوعی بوده که وظیفه‌ی آن ایجاد مسیر است. همراه با مورچه‌ی k -ام لیستی تحت عنوان $T_k(i)$ شامل تمامی مسیرهایی که ملاقات نشده‌اند، وجود دارد. $\lambda(i, r)$ نشان‌دهنده‌ی مقدار اثر فرمون روی کمان بین دو محل i و r است. $v(i, r)$ یک مقدار ابتکاری بوده و از معکوس فاصله‌ی بین دو مسیر i و r حاصل می‌شود. β پارامتری است که اهمیت نسبی $v(i, r)$ را نشان می‌دهد. q مقداری است که به طور تصادفی بین ۰ و ۱ تولید شده و q_0 نیز پارامتری بین ۰ و ۱ است که توسط کاربر تعیین می‌شود. J یک متغیر تصادفی است و بر اساس تابع توزیع احتمال ارائه شده در رابطه‌ی (۱۳) تولید می‌شود که در آن $p_k(i, j)$ احتمال انتخاب مسیر j -ام است.

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

برای به‌روزرسانی محلی اثر فرمون از رابطه‌ی (۱۴) استفاده می‌شود. این به‌روزرسانی محلی زمانی رخ می‌دهد که مورچه‌ی k -ام از محل مسیر i به محل مسیر j می‌رود. در این رابطه، ρ

۲-۶- طبقه‌بند RUSBoost

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

۳- نتایج و بحث

در این بخش به بررسی پایگاه داده‌ی مورد استفاده و ارائه‌ی نتایج حاصل از بهینه‌سازی و طبقه‌بندی پرداخته شده است.

۳-۱- مجموعه‌ی داده‌های EEG

در بخش انتخاب داده‌ها، از مجموعه‌ی داده‌های Sleep-EDF از پایگاه Physionet Data Bank (یک پایگاه عمومی برای دریافت داده‌ی EEG) به عنوان مجموعه‌ی داده‌ی آزمایش و ارزیابی استفاده شده است [۲۹]. داده‌های مورد نظر از مردان و زنان قفقازی (۲۱-۳۵ سال) بدون استفاده از هیچ دارویی به دست آمده است. هشت داده در دو زیرمجموعه با عنوان‌های SC و ST در هنگام خواب ثبت شده است. چهار داده‌ی اول با عنوان SC مربوط به افراد سالم و چهار داده‌ی دوم با عنوان ST مربوط به افراد دچار خواب‌آلودگی خفیف است. برای ثبت داده از کانال‌های Pz-Oz و Fpz-Cz استفاده شده [۳۰] و فرکانس نمونه‌برداری برابر با ۱۰۰ هرتز است. مطالعات پیشین نشان می‌دهد که سیگنال EEG ثبت شده از کانال Pz-Oz عمل‌کرد بهتری نسبت به کانال Fpz-Cz در طبقه‌بندی 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 به دست آمده است. طول مدت زمان هر اپیک در این مطالعه برابر با ۳۰ ثانیه یا ۳۰۰۰ نمونه است. هر اپیک توسط متخصصان خواب در یکی

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

۲-۵- تایید ویژگی‌های انتخابی با آنالیز آماری

در این مقاله از آزمون Anova (واریانس یک‌طرفه) برای تایید صحت ویژگی‌های انتخاب شده استفاده می‌شود. آزمون‌ها در جعبه‌ی آمار MATLAB در سطوح اطمینان ۹۵٪ انجام می‌شوند. در این آنالیز، ویژگی‌هایی با مقادیر p -value کم‌تر از ۰/۰۵، بیان‌گر ویژگی‌های مطلوب هستند.

الگوریتم RUSBoost

در مرحله‌ی اول، به هر نمونه‌ی آموزشی وزن اولیه‌ی $1/m$ اختصاص داده شده که m تعداد نمونه‌های آموزشی است. سپس T طبقه‌بندی پایه‌ی ضعیف، به طور مکرر طبق مراحل زیر آموزش داده می‌شود. الف) با انجام روش تصادفی زیر نمونه‌برداری برای حذف نمونه‌های کلاس اکثریت، N درصد از نتایج در مجموعه‌ی داده‌ی آموزشی جدید (موقتی) S_t به کار برده می‌شوند.

ب) S_t و D_t برای ایجاد طبقه‌بندی پایه‌ی ضعیف h_t در گام c به عنوان ورودی یادگیرنده‌ی ضعیف در نظر گرفته می‌شوند.

ج) طبقه‌بندی پایه‌ی 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 ε_t مبتنی بر مجموعه‌ی آموزشی اصلی S و توزیع وزن D_t ، در این مرحله محاسبه می‌شود.

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

ه) در این مرحله پارامتر به‌روزرسانی وزن محاسبه می‌شود.

$$\alpha_t = \frac{\varepsilon_t}{1 - \varepsilon_t}$$

و) اگر برچسب نمونه‌ی آموزشی درست پیش‌بینی شود وزن آن در توزیع وزن برای ایجاد فرضیه‌ی جدید در تکرار بعدی ثابت باقی ماند و در غیر این صورت به میزان α_t افزایش وزن خواهد داشت.

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

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 $H(x)$ به عنوان رای وزن‌دار شده‌ی فرضیه‌های ضعیف برگشت داده می‌شود.

$$H(x) = \operatorname{argmax}_{y \in Y, t=1}^T h_t(x, y) \log \frac{1}{\alpha_t}$$


شکل (۴) - شبه‌کد مربوط به الگوریتم RUSBoost



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



الف



ب

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

از هشت کلاس AWA، S1، S2، S3، S4، REM، MVT (زمان حرکت) و UNS (حالت‌های ناشناخته) دسته‌بندی شده است. خلاصه‌ای از ایپاک‌های مختلف کلاس‌های مورد استفاده در این پژوهش در جدول (۲) ارائه شده است. همان‌طور که مشاهده می‌شود، تعداد کل ایپاک‌های ۳۰ ثانیه‌ای مورد استفاده در این مطالعه برابر با ۱۵۱۸۸ است. برای انجام آزمایش‌ها، نیمی از مجموعه‌ی داده‌های خواب Sleep-EDF به طور تصادفی برای آموزش مجموعه و سایر داده‌ها به عنوان ارزیابی مجموعه انتخاب شده‌اند. به این ترتیب، اطمینان حاصل شده است که تمام مجموعه‌ی داده‌های Sleep-EDF را می‌توان برای آموزش یا آزمون مورد استفاده قرار داد.

جدول (۲) - تعداد ایپاک‌ها از داده‌های Sleep-EDF

REM	S4	S3	S2	S1	AWA	ایپاک
۱۶۰۹	۶۲۷	۶۷۲	۳۶۲۱	۶۰۴	۸۰۵۵	

۳-۲- نتایج حاصل از بهینه‌سازی

با تنظیم مقدار ۱ برای مقدار اولیه‌ی فرمون، جمعیت ۲۰ تایی، نرخ تبخیر فرمون ۰/۰۵، وزن نمایشی ۱، تعداد ۸۰ تکرار، آموزش‌های مداوم شبکه‌ی عصبی MLP و تولید بردارهای ویژگی تصادفی، الگوریتم ACO سرانجام به سمت مقدار بهینه هم‌گرا شده که این هم‌گرایی در شکل (۵) نشان داده شده است. مقادیر p-value ویژگی‌های انتخاب شده با استفاده از آزمون Anova در جدول (۳) و شکل (۶) ارائه شده است. در این آزمون ویژگی‌هایی با p-value کمتر از ۰/۰۵، 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 شبکه‌ی عصبی، ویژگی‌های مطلوبی هستند.


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

مومنوم	انرژی	فاکتور ضربه	کشیدگی	چولگی	میانگین	توان	انحراف معیار	
-	-	$1/95e^{-88}$	$4/05e^{-77}$	۰/۰۱۱	-	۰	۰	جزئیات ۱
-	$6/22e^{-287}$	$2/65e^{-228}$	-	-	-	$6/22e^{-228}$	-	جزئیات ۲
$6/27e^{-121}$	$1/22e^{-243}$	-	$1/17e^{-62}$	-	۰/۰۶۳	-	-	جزئیات ۳
-	$5/17e^{-225}$	-	$1/39e^{-67}$	۰/۰۱۶	-	$9/74e^{-228}$	$1/42e^{-254}$	جزئیات ۴
-	$1/62e^{-124}$	-	-	-	$3/19e^{-44}$	$1/62e^{-124}$	$2/18e^{-197}$	تقریب ۴
-	۰	-	-	-	۰/۰۷۵	۰	۰	ضرایب

۳-۳- طبقه‌بندی با RUSBoost

در این بخش طبقه‌بند، جزئیات، نتایج آزمایش‌ها و برخی از نتایج مهم بیان شده است. رایانه‌ی مورد استفاده برای

شبیه‌سازی در این مقاله دارای مشخصات اینتل i5- Core (TM) 3470، پردازنده‌ی ۱/۶ گیگاهرتز و رم ۸ گیگابایت است. در این مقاله ۲۵ ویژگی تایید شده توسط Anova، به عنوان ورودی



شکل (۷) - عمل کرد روش پیشنهادی برای کلاس‌های مختلف

طبقه‌بند RUSBoost مورد استفاده قرار گرفته است. پارامترهای مربوط به طبقه‌بند با تعداد چرخه‌های یادگیری ۱۰۰۰، نرخ یادگیری ۰/۱ و تعداد تکرار ۱۰۰ تنظیم شده است. تنظیم پارامترهای طبقه‌بند، به واسطه‌ی سعی و خطا بوده که برای این منظور از کل داده‌های موجود در پایگاه EDF برای شبیه‌سازی استفاده شده است. به طوری که ۵۰٪ داده‌ها به عنوان مجموعه‌ی آموزشی، ۲۰٪ داده‌ها به عنوان مجموعه‌ی اعتبارسنجی و ۳۰٪ داده‌ها به عنوان مجموعه‌ی آزمایشی در نظر گرفته 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] نیز برای طبقه‌بندی استفاده شده است. برای DA، عمل‌کرد سه تابع شناخته شده‌ی خطی، درجه‌ی دو و Mahalanobis مورد بررسی قرار گرفته است. عمل‌کرد روش پیشنهادی برای کلاس‌های مختلف در شکل (۷) نشان داده شده است. همان‌طور که مشاهده می‌شود، RUSBoost عمل‌کرد بهتری نسبت به سایر طبقه‌بندها داشته است.

هم‌چنین سرعت و زمان اجرای طبقه‌بند پیشنهادی در مقایسه با طبقه‌بندهای شبیه‌سازی شده در شکل (۷)، در جدول (۴) ارائه شده است. مشاهده می‌شود که زمان اجرای طبقه‌بند پیشنهادی نسبت به سایر طبقه‌بندها بیش‌تر است اما دارای ضریب صحت بالای ۹۰٪ برای طبقه‌بندی ۶ کلاسه‌ی مراحل خواب می‌باشد. هم‌چنین برای نشان دادن عمل‌کرد مطلوب روش پیشنهادی، از یک شبکه‌ی عصبی پرسپترون چندلایه با الگوی پس‌انتشار خطا با استفاده از تابع آموزشی لونیگ-مارکوات استفاده شده است. شبکه‌ی BPNN استفاده شده در این مقاله یک شبکه‌ی دولایه بوده که با در نظر گرفتن ۳۰ نورون در لایه‌ی مخفی، شبکه به‌ترین عمل‌کرد را در طبقه‌بندی حالت‌های مختلف خواب از خود نشان داده است. لازم به ذکر است که تابع انتقال لایه‌ی مخفی به صورت سیگموئید بوده و از تابع softmax برای تبدیل مقادیر لایه‌ی خروجی به احتمال، استفاده شده است [۳۴]. مقایسه‌ی عمل‌کرد روش پیشنهادی با شبکه‌ی عصبی در جدول (۵) ارائه شده است. همان‌طور که مشاهده می‌شود، عمل‌کرد روش پیشنهادی در مقایسه با BPNN و ترکیب BPNN و ACO از لحاظ صحت امیدوارکننده است. مقادیر صحت^۱ روش‌های مختلفی که از مجموعه‌ی داده‌ی Sleep-EDF استفاده کرده‌اند در جدول (۶) ارائه شده است.

^۱ Accuracy

جدول (۴) - زمان اجرای طبقه‌بند پیشنهادی در مقایسه با سایر

طبقه‌بندها 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) - مقایسه‌ی الگوریتم پیشنهادی با سایر الگوریتم‌ها

برای طبقه‌بندی ۶-کلاسه‌ی 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

همان‌طور که مشاهده می‌شود تمامی مقادیر گزارش شده برای روش پیشنهادی دارای ضریب صحت بالای ۹۰٪ است. صحت پژوهش‌های [۱۱] و [۱۶] برای طبقه‌بندی ۶-کلاسه‌ی مراحل خواب به ترتیب برابر با ۸۸/۶۲٪ و ۹۰/۵۰٪ و صحت روش پیشنهادی برابر با ۹۳/۲۰٪ است. نمودار ROC برای طبقه‌بندی مطابق با جدول (۱) در شکل (۸) نشان داده شده است. با توجه به شکل (۸)، از آن‌جا که تمام کلاس‌ها بین بازه‌ی ۰/۸۵ تا ۱ قرار دارند، در مجموع می‌توان نتیجه گرفت که عمل‌کرد روش پیشنهادی از لحاظ اعتبار و قابلیت اطمینان، امیدوارکننده است. همچنین عمل‌کرد روش پیشنهادی به طور جداگانه برای طبقه‌بندی ۶-کلاسه‌ی خواب در جدول (۷) ارائه شده است. شکل (۹) نشان دهنده‌ی درصد اثربخشی ویژگی‌های منتخب روش پیشنهادی است. همچنین برای نشان دادن مقاوم بودن الگوریتم پیشنهادی در برابر نویز، نویز گوسی با SNR ۲۰ تا ۴- دسی‌بل به داده اضافه شده است. همان‌طور که در شکل (۱۰) مشاهده می‌شود، صحت الگوریتم پیشنهادی تا ۱۰ دسی‌بل برای طبقه‌بندی ۶-کلاسه‌ی خواب ثابت بوده است.

جدول (۷) - ماتریس درهم‌ریختگی برای هر یک از ۶ حالت

خواب از پایگاه داده‌ی Sleep-EDF

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




شکل (۹) - درصد اثربخشی ویژگی‌های منتخب روش پیشنهادی

جدول (۶) - عمل‌کرد الگوریتم پیشنهادی در مقایسه با پژوهش‌های

پیشین در مجموعه‌ی داده‌ی خواب پایگاه Sleep-EDF

الگوریتم	کلاس ۲	کلاس ۳	کلاس ۴	کلاس ۵	کلاس ۶
[21]	-	-	-	-	٪۶۱/۰۸
[20]	-	-	-	-	٪۶۹/۹۸
[18]	-	-	-	-	٪۷۷/۹۸
[14]	-	-	-	-	٪۸۳/۶۰
[19]	-	-	-	-	٪۸۷/۲۰
[13]	٪۹۶/۹۰	٪۸۸/۹۷	٪۸۱/۴۲	-	٪۷۶/۷۰
[12]	٪۹۷/۹۰	٪۹۲/۶۰	٪۸۹/۳۰	٪۸۸/۹۰	٪۸۷/۵۰
[11]	٪۹۷/۷۳	٪۹۳/۵۵	٪۹۱/۲۰	٪۹۰/۱۱	٪۸۸/۶۲
[16]	٪۹۷/۳۰	٪۹۳/۹۰	٪۹۲/۳۰	٪۹۱/۵۰	٪۹۰/۵۰
این مقاله	٪۹۷/۲۶	٪۹۳/۹۰	٪۹۱/۱۰	٪۹۲/۱۰	٪۹۲/۰۰




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

تبدیل موجک گسسته به چهار سطح تجزیه شده و چند ویژگی آماری-زمانی از این سطوح استخراج شده است. سپس با استفاده از ترکیب الگوریتم ACO و شبکه‌ی عصبی، ویژگی‌های مهم انتخاب شده و به عنوان ورودی طبقه‌بند RUSBoost جهت تفکیک کلاس‌ها از یک‌دیگر مورد استفاده قرار گرفته است. در این پژوهش صحت ویژگی‌های بهینه‌ی انتخاب شده از مدل ترکیبی الگوریتم ACO و شبکه‌ی عصبی، با استفاده از آزمون آماری Anova بررسی شده است. نتایج نشان می‌دهد که انتخاب ویژگی‌های آماری-زمانی مطلوب، در تشخیص مراحل مختلف خواب بسیار موثر است.

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

۶- مراجع

- [1] 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] Boashash and S. Ouelha, "Automatic signal abnormality detection using time-frequency features and machine learning: A newborn EEG



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

۴- بحث

عوامل مختلفی به عمل‌کرد شناسایی خودکار مراحل خواب پیشنهادی کمک می‌کنند. استفاده از بهینه‌ساز ACO با هدف کاهش ابعاد ویژگی، زمان آموزش را برای طبقه‌بند کوتاه کرده که این امر باعث می‌شود تا بتوان از الگوریتم پیشنهادی به عنوان دست‌یار پزشک و یا دستگاه‌های نظارت در خانه برای شناسایی خودکار مراحل خواب استفاده نمود. سیگنال EEG خواب شامل تعداد نمونه‌های یک‌سان برای هر یک از ۶ حالت خواب نبوده و در واقع تعداد توزیع دوره‌ها در حالت‌های مختلف خواب بسیار بی‌ثبات است که این امر در جدول (۲) قابل مشاهده می‌باشد. در جدول (۲) مشاهده می‌شود که بیش از نیمی از دوره‌ها مربوط به حالت AWA است. دوره‌های S1، S3 و S4 با توجه به سایر حالت‌های خواب سهم کم‌تری را در خواب افراد دارند. این مساله 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. این مشکل در اکثر پژوهش‌های پیشین وجود داشته [۳۵، ۳۶] و منجر به عمل‌کرد ضعیف طبقه‌بند شده است. در روش پیشنهادی 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 دارد.

۵- نتیجه‌گیری

در این مقاله شناسایی خودکار مراحل خواب با استفاده از روش تبدیل موجک گسسته و مدل ترکیبی الگوریتم ACO و شبکه‌ی عصبی مبتنی بر طبقه‌بند RUSBoost انجام شده است. در روش پیشنهادی، سیگنال EEG تک‌کاناله با استفاده از روش

- 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] 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. Konyshchev, and S. Selishchev, "Classification of human sleep stages based on EEG 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] 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] 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. Coloni, "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] 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 approach 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.
- seizure case 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] 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] 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] 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*

[35] 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.

[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] Ahmadlou, 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] J. Izenman, "Linear discriminant analysis," in *Modern multivariate statistical techniques*: Springer, 2013, pp. 237-280.