

Automatic Stage Scoring of Single-Channel Sleep EEG using Discrete Wavelet Transform and a Hybrid Model of Simulated Annealing Algorithm and Neural Network

S. Sheykhivand¹, T. Yousefi Rezaii^{2*}, Z. Mousavi³, S. Meshgini⁴

¹M.Sc. Student, Biomedical Engineering Department, Faculty of Electrical and Computer Engineering, University of Tabriz, Tabriz, Iran

²Assistant Professor, Biomedical Engineering Department, Faculty of Electrical and Computer Engineering, University of Tabriz, Tabriz, Iran

³Ph.D Student, Department of Mechanical Engineering, Faculty of Mechanical Engineering, University of Tabriz, Tabriz, Iran

⁴Assistant Professor, Biomedical Engineering Department, Faculty of Electrical and Computer Engineering, University of Tabriz, Tabriz, Iran

Receipt in the Online Submission System: 24 February 2018, Received in Revised Form: 20 May 2018, Accepted: 25 May 2018

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 used to automatically identify sleep stages using discrete wavelet transform and a hybrid model of simulated annealing and neural network. The signal is decomposed using a discrete wavelet transform into seven levels and statistical properties of each level is calculated. To optimize and reduce the dimensions of feature vectors, hybrid model of simulated annealing algorithm and multi-layered neural network are used. Then ANOVA test is applied to validate the selected features. Finally the classification is performed on the validated features by a perceptron neural network with a hidden layer, 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 higher degree of success in classifying sleep stages compared to the existing methods.

Keywords: *Discrete Wavelet Transform, Automatic Sleep Stage Detection, Simulated Annealing Algorithm, Neural Network*

***Corresponding Author**

Address: Faculty of Electrical and Computer Engineering, University of Tabriz, P. O. Box: 5166616471, Tabriz, Iran
Tel: +98-41-33393748
Fax: +98-41-33300819
E-mail: yousefi@tabrizu.ac.ir

شناسایی خودکار مراحل خواب از سیگنال EEG تک کاناله با استفاده از تبدیل موجک گسسته و مدل ترکیبی الگوریتم تبرید و شبکه‌ی عصبی

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

^۱ دانشجوی کارشناسی ارشد مهندسی پزشکی، گروه مهندسی پزشکی، دانشکده‌ی مهندسی برق و کامپیوتر، دانشگاه تبریز، تبریز
^۲ استادیار، گروه مهندسی پزشکی، دانشکده‌ی مهندسی برق و کامپیوتر، دانشگاه تبریز، تبریز
^۳ دانشجوی دکتری مکانیک، گروه مهندسی مکانیک، دانشکده‌ی مهندسی مکانیک، دانشگاه تبریز، تبریز
^۴ استادیار، گروه مهندسی پزشکی، دانشکده‌ی مهندسی برق و کامپیوتر، دانشگاه تبریز، تبریز

تاریخ ثبت در سامانه: ۱۳۹۶/۱۲/۵، بازنگری: ۱۳۹۷/۲/۳۰، پذیرش قطعی: ۱۳۹۷/۳/۴

چکیده

در سال‌های اخیر، استفاده از روشی هوشمند برای تشخیص خودکار مراحل خواب در کاربردهای پزشکی، برای کاهش حجم کار پزشکان در تجزیه و تحلیل داده‌های خواب از طریق بازرسی بصری، یکی از چالش‌های مهم به حساب می‌آید. در این مقاله، الگوریتمی مبتنی بر EEG تک کاناله برای شناسایی خودکار مراحل خواب، با استفاده از تبدیل موجک گسسته و مدل ترکیبی الگوریتم تبرید و شبکه‌ی عصبی ارائه می‌شود. سیگنال با استفاده از تبدیل موجک گسسته به ۷ سطح تجزیه شده و ویژگی‌های آماری از هر یک از سطوح تجزیه شده، استخراج می‌گردد. جهت بهینه‌سازی و کاهش ابعاد بردارهای ویژگی، از یک مدل ترکیبی الگوریتم تبرید و شبکه‌ی عصبی چندلایه‌ی پس انتشار خطا استفاده شده، و سپس از آزمون ANOVA برای تأیید صحت ویژگی‌های بهینه استفاده می‌شود. طبقه‌بندی نهایی روی این ویژگی‌های بهینه‌شده توسط یک شبکه‌ی عصبی پرسپترون با یک‌لایه‌ی پنهان انجام می‌شود، که به طور میانگین برای طبقه‌بندی ۲-کلاس تا ۶-کلاس مراحل مختلف خواب دقت بالای ۹۰٪ را فراهم کرده 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 تبرید، شبکه‌ی عصبی

*نویسنده مسئول

نشانی: گروه مهندسی پزشکی، دانشکده‌ی مهندسی برق و کامپیوتر، دانشگاه تبریز، تبریز، ایران، کد پستی: ۵۱۶۶۶۱۶۴۷۱

تلفن: ۳۳۳۹۳۷۴۸ (۴۱) ۹۸+

دورنگار: ۳۳۳۰۰۸۱۹ (۴۱) ۹۸+

پست الکترونیکی: yousefi@tabrizu.ac.ir

۱- مقدمه

خواب نقش اساسی در عملکرد فردی، توانایی یادگیری و حرکت فیزیکی دارد. انسان حدود یک سوم زندگی خود را صرف خواب می‌کند و شرایطی مانند آپنه‌ی انسدادی خواب^۱ (OSA) می‌تواند به شدت بر سلامت جسمی او تاثیرگذار باشد [۱]. با توجه به نتایج تحقیقات در [۲]، بیش از ۹۰٪ بیماران مبتلا به افسردگی، از اختلالات خواب رنج می‌برند. آپنه‌ی خواب میان در حدود ۲ تا ۴ درصد از بزرگسالان و حدود ۱ تا ۳ درصد از کودکان رایج است. هم‌چنین محرومیت از خواب، باعث ایجاد خواب‌آلودگی، عدم تمرکز و کاهش حافظه خواهد شد [۳]. در درمان بالینی، تجزیه و تحلیل مراحل خواب به‌طور معمول توسط یک پزشک 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) انجام می‌گیرد. تجزیه و تحلیل مراحل خواب در تشخیص و درمان اختلالات خواب حیاتی است. اندازه‌گیری‌های PSG شامل سیگنال‌هایی مانند الکتروانسفالوگرام^۴ (EEG)، الکترواکولوگرام^۵ (EOG)، الکترومایوگرام^۶ (EMG)، الکتروکاردیوگرام^۷ (ECG)، اشباع اکسیژن (SpO₂) و تنفس (Resp) می‌باشد [۴]. اندازه‌گیری‌های PSG، ابتدا به دوره‌های ۲۰ تا ۳۰ ثانیه‌ای تقسیم شده، سپس بر اساس بازرسی بصری توسط کارشناسان به دوره‌های مختلف خواب طبقه‌بندی خواهند شد. این دوره‌ها در جدول (۱) نمایش داده شده است [۵]. در روش سنتی، در طول مدت ۸ ساعته‌ی خواب، بازرسی بصری ۲ الی ۴ ساعته روی فرد مورد نظر انجام می‌شود. نظارت مراحل خواب به شیوه‌ی سنتی بر اساس بررسی بصری، ناخوشایند، وقت‌گیر و دارای خطا بوده و نیازمند منابع انسانی متخصص می‌باشد [۶]. هم‌چنین موجب کاهش دقت در تشخیص بیماری فرد مورد نظر نیز خواهد شد [۷]. علاوه بر این، در آزمایش‌های بالینی ممکن است در برخی موارد نیاز به تشخیص سریع مراحل خواب باشد. 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 می‌دهند. هم‌چنین مطالعه روی افراد در مقیاس وسیع در تحقیقات خواب به‌شدت تحت تاثیر این عامل قرار می‌گیرد [۱]. بررسی خودکار

فرایند تجزیه و تحلیل مراحل خواب، نه تنها موجب تشخیص سریع شده، بلکه باعث افزایش دقت در تشخیص نیز خواهد شد [۸]. PSG فرایندی پرهزینه بوده و از آن‌جا که خواب در محیط ناآشنا ناراحت‌کننده است، می‌تواند بر سلامت خواب بیمار تاثیر منفی بگذارد [۹]. با توجه به این چالش‌ها، تشخیص مراحل خواب به صورت خودکار، می‌تواند زمان تشخیص را برای پزشکان کاهش داده، دقت تحلیل را در طبقه‌بندی مراحل خواب افزایش دهد و تشخیص و درمان اختلالات خواب را بهبود بخشد [۱۰].

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، و هم‌چنین باعث کاهش کیفیت ثبت داده خواهد شد [۱۱]. به همین ترتیب، استفاده از سیگنال‌های حاصل از EEG، به الگوریتم مکان‌یابی سیگنال خواب برای استفاده از حداقل تعداد کانال‌های سیگنال فیزیولوژیک نیاز دارد [۱۲]. 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 خواهد بود [۱]. در نتیجه شناسایی خودکار مراحل خواب مبتنی بر یک کانال، توجه جامعه‌ی تحقیق خواب را به خود جلب می‌کند. اکثر روش‌های قبلی برای شناسایی خودکار مراحل خواب، به دلیل کم بودن دقت (زیر ۹۰ درصد) و زمان محاسبات طولانی برای اجرای سخت‌افزاری، برای تشخیص مراحل خواب مناسب نیستند [۱۳].

تشخیص خودکار مراحل خواب شامل ۳ مرحله پیش‌پردازش (در صورت نیاز)، استخراج ویژگی و طبقه‌بندی است. روش‌های مختلفی مثل توزیع زمان و فرکانس [۱۰]، نظریه‌ی گراف [۱۱]، [۱۴]، مدل‌سازی سیگنال [۱۱]، تبدیل موجک [۱۵] و تجزیه‌ی حالت تجربی^۸ (EMD) [۱] برای پردازش سیگنال در جداسازی مراحل خواب استفاده شده است. هم‌چنین برای بخش طبقه‌بندی، مدل‌های مختلفی استفاده می‌شود که شامل: ماشین بردار پشتیبان^۹ (SVM) [۵] و حداقل مربعات جزئی^{۱۰} (MSE) [۱۱] هستند.


^۶ Electromyogram^۷ Electrocardiogram^۸ Empirical Mode Decomposition^۹ Support Vector Machine^{۱۰} Mean Squared Error^۱ Obstructive Sleep Apnea^۲ Polysomnography^۳ American Academy of Sleep Medicine^۴ Electroencephalogram^۵ Electrooculogram

[۱۰] با استفاده از الگوریتم تجزیه‌ی حالت تجربی دسته‌ای^۸ (EEMD) به تجزیه‌ی سیگنال EEG تک‌کاناله پرداخته و ویژگی‌های آماری را از آن استخراج کردند. آن‌ها از طبقه‌بند RUSBoost برای طبقه‌بندی مجموعه‌ی داده‌ها استفاده کرده‌اند. دقت طبقه‌بندی برای مراحل خواب ۶ کلاسه با استفاده از الگوریتم آن‌ها در حدود ۸۸ درصد گزارش شده است. سیلوریا و هم‌کاران [۱۵] با استفاده از تبدیل موجک گسسته و ویژگی‌های آماری از سیگنال EEG تک‌کاناله، با بهره‌گیری از طبقه‌بند جنگل تصادفی به دقت حدود ۹۰ درصد برای طبقه‌بندی ۶ کلاسه‌ی حالت‌های مختلف خواب دست یافتند. با توجه به مطالعات صورت گرفته در پژوهش‌های پیشین، این موضوع مشخص شد که اکثر الگوریتم‌های موجود برای شناسایی خودکار مراحل خواب، نیاز به بیش از یک کانال دارند، که این موضوع برای بیمار ناراحت کننده بوده و مانع حضور دستگاه نظارت خواب در خانه می‌شود. هم‌چنین مشخص شد که پژوهش‌های پیشین در طبقه‌بندی مراحل مختلف خواب دقت زیر ۹۰٪ را ارائه داده و از نظر محاسباتی پیچیده و زمان‌بر هستند. این نکته‌ی کلیدی پژوهشی است که در این مقاله به آن پرداخته خواهد شد. در این مقاله، برای شناسایی خودکار مراحل خواب از روش تبدیل موجک گسسته و مدل ترکیبی الگوریتم تبرید^۹ (SA) و شبکه‌ی عصبی^{۱۰} (MLP) استفاده شده است. این پژوهش مبتنی بر ۶ حالت خواب، مطابق با استاندارد R & K^{۱۱} است که شامل حالت بیدار (AWA)، مراحل حرکتی غیرسریع چشم (s1-s4) و حرکت سریع چشم (REM) می‌باشد. این کلاس‌ها در جدول (۱) شرح داده شده است. در روش پیشنهادی، سیگنال با استفاده از تبدیل موجک گسسته، تجزیه شده و چند ویژگی آماری از هر یک از سطوح تجزیه استخراج می‌شود. سپس با استفاده از ترکیب الگوریتم SA و شبکه‌ی عصبی، ویژگی‌های مهم انتخاب شده و به‌عنوان ورودی طبقه‌بند (BPNN^{۱۲})، جهت تفکیک کلاس‌ها از یک‌دیگر مورد استفاده قرار می‌گیرد.

ادامه‌ی مقاله به صورت زیر تدوین شده است: در بخش ۲، طرح استخراج ویژگی‌ها مورد بررسی قرار گرفته، و عمل کرد آن تجزیه و تحلیل می‌شود، و پس از آن انتخاب ویژگی‌ها، الگوریتم SA و شبکه‌ی عصبی توضیح داده می‌شود. در بخش ۳، داده‌های

رونژینا و هم‌کارانش [۱۲] با استفاده از چگالی طیفی توان^۱ (PSD) سیگنال‌های EEG به همراه شبکه‌ی عصبی مصنوعی، یک طرح مبتنی بر EEG تک‌کاناله ارائه دادند. لاجنل و هم‌کاران [۵] 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. پکر و هم‌کارانش [۱۶] ترکیبی از تبدیل موجک (DT-CWT) و شبکه‌ی عصبی مبتنی بر تاگوچی را برای ثبت خودکار مراحل خواب از یک کانال EEG مورد استفاده قرار دادند. کراکستا و هم‌کاران [۱۴] 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] تجزیه و تحلیل زمان-فرکانس را برای استخراج ویژگی انجام داده و برای طبقه‌بندی از الگوریتم رمزگذار خودکار انباشته‌شده استفاده کردند. لیانگ و هم‌کاران [۱۷] از ویژگی‌های مبتنی بر آنتروپی Renyi استخراج شده از توزیع فرکانس‌های مختلف برای شناسایی مراحل مختلف خواب با EEG تک‌کاناله استفاده کردند. کیکسیگولو [۱۸] یک طرح استخراج ویژگی مبتنی بر فن‌آوری مدل خودبازگشتی^۲ (AR) و الگوریتم حداقل مربعات جزئی^۳ (PLS) را برای طبقه‌بندی مراحل خواب ارائه داد. ورال و هم‌کاران [۱۹] با استفاده از تبدیل کاران-لوف^۴ به تجزیه‌ی سیگنال EEG چندکاناله پرداخته و از ویژگی‌های زمان-فرکانس برای استخراج ویژگی‌ها استفاده کردند. آن‌ها هم‌چنین تجزیه‌ی مولفه‌ی اصلی^۵ (PCA) را برای کاهش بردار ویژگی‌ها و دسته‌بندی کلاس‌ها به کار گرفتند. دورشنکو و هم‌کارانش [۲۰] با استفاده از تبدیل فوریه‌ی سریع^۶ (FFT) به تجزیه‌ی سیگنال EEG به فرکانس‌های تتا، آلفا و دلتا پرداخته و از مدل پنهان مارکوف^۷ (HMM) برای طبقه‌بندی کلاس‌های مختلف خواب استفاده کردند. ژو و هم‌کاران [۱۱] گراف دیداری و گراف افقی را از سیگنال EEG تک‌کاناله تولید کرده و ۹ ویژگی از آن‌ها را برای طبقه‌بندی با استفاده از ماشین بردار پشتیبان به کار بردند. دقت روش آن‌ها برای طبقه‌بندی ۶ کلاسه‌ی حالت‌های مختلف خواب حدود ۸۷ درصد گزارش شده است. حسن و هم‌کارانش

^۸ Hidden Markov Models^۹ Ensemble Empirical Mode Decomposition^{۱۰} Simulated Annealing^{۱۱} Multilayer Perceptron^{۱۲} Rechtschaffen and Kales^{۱۳} Back Propagation Neural Network^۱ Power Spectral Density^۲ Autoregressive^۳ Partial Least Squares^۴ Karhunen-Loeve^۵ Principal Component Analysis^۶ Fast Fourier Transform



شکل (۲) - روند تجزیه سیگنال

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

$$S = A7 + D1 + D2 + D3 + D4 + D5 + D6 + D7 \quad (1)$$

تاکنون خانواده‌های متعددی از تبدیل موجک‌ها ارائه شده که هر کدام دارای ویژگی‌های مختلفی هستند. از خانواده‌ی تبدیل موجک‌ها، می‌توان به موجک هار، دابیشیز، کویفلت، سیملت، مورلت و گویسین اشاره کرد [۲۱]. در این مقاله، از موجک دابیشیز ۶، به‌طور تجربی و با سعی و خطا، پاسخ مناسبی برای استخراج ویژگی مورد نظر یافت شد. همان‌طور که در شکل (۲) نمایش داده شده است، سیگنال با استفاده از تبدیل موجک به ۷ زیرسطح تجزیه می‌شود. زیرسطح‌های ایجاد شده دارای اطلاعات دقیق‌تری نسبت به سیگنال‌های اصلی هستند و این امر موجب به دست آوردن تحلیل دقیق‌تری از سیگنال EEG می‌شود. تبدیل‌های موجک برای تجزیه و تحلیل الگوهای داده‌ای نامنظم بسیار مفید هستند. تبدیل موجک پیوسته‌ی (CWT) یک سیگنال $x(t)$ ، از انتگرال سیگنال در تابع موجک ψ ، با پارامترهای جابه‌جایی (b) و مقیاس (a) متفاوت ایجاد می‌شود:

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

که a و b به ترتیب پارامترهای مقیاس و جابه‌جایی هستند. به دلیل این‌که محاسبه‌ی ضرایب موجک به ازای تمامی مقادیر پارامترهای a و b وقت‌گیر و از نظر محاسباتی پرهزینه است، برای دو پارامتر از توان‌های ۲ استفاده شده و بر اساس تبدیل موجک گسسته به‌صورت زیر به دست می‌آید [۲۲]:

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

شکل (۳) نشان‌گر تفاوت در میان جزئیات برای مراحل مختلف خواب است.


آزمایشی و نتایج تجربی به دست آمده، مورد بحث و بررسی قرار داده خواهد شد. بخش ۴، به بررسی اهمیت نتایج به دست آمده اختصاص داده شده است. در نهایت در بخش ۵، نتیجه‌گیری ارائه شده است.

جدول (۱) - شرح کلاس‌های مختلف در این پژوهش

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

۲- مواد و روش‌ها

در این بخش، ابتدا به تشریح استخراج ویژگی‌ها پرداخته شده، سپس انتخاب ویژگی‌ها، الگوریتم SA و شبکه‌ی عصبی مورد بررسی قرار می‌گیرند. شکل (۱)، طرح کلی از روش پیشنهادی را نشان می‌دهد.



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

۲-۱- تبدیل موجک گسسته (DWT)

تبدیل موجک گسسته، به عنوان یکی از روش‌های مهم و محبوب در حوزه‌ی پردازش سیگنال به کار گرفته می‌شود. اساس کار 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 مرحله‌ی تجزیه، امکان بررسی و تحلیل را به مراتب راحت‌تر می‌کند. شکل (۲) روند این تجزیه را نشان می‌دهد. ایده‌ی اصلی تبدیل موجک گسسته، از فیلترهای بالاگذر و پایین‌گذر گرفته شده است، که در آن سیگنال به دو قسمت فرکانس بالا (جزئیات) و فرکانس پایین (تقریب) تقسیم می‌شود. این روند یادشده، تا سطح دل‌خواه ادامه پیدا می‌کند تا بهترین سطح را جهت آنالیز ارائه نماید.

۵- چولگی

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

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

۶- فاکتور ضربه

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

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

۷- انرژی

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

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

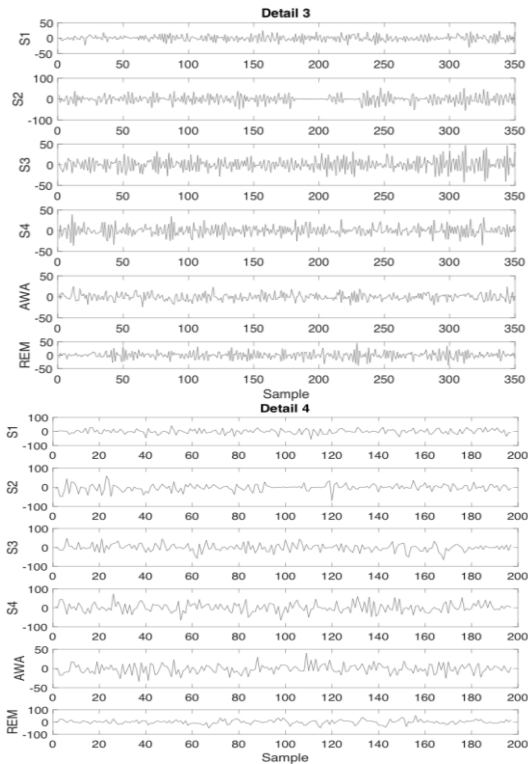
در این مقاله، ۷ سطح تجزیه‌ی موجک برای استخراج ویژگی به کار برده شده است (سیگنال با استفاده از تبدیل موجک گسسته به ۷ سطح تجزیه شده و ۷ ویژگی آماری از سیگنال‌های جزئیات، تقریب آخر و ضرایب موجک گرفته شده است)، که در مجموع ۶۳ ((۷+۲) × ۶۳) ویژگی استخراج می‌شود.

۲-۳- انتخاب و کاهش ویژگی‌های آماری مطلوب

پس از استخراج ویژگی، باید ویژگی‌های مطلوب، انتخاب شده و ویژگی‌های نامطلوب حذف شوند. انتخاب ویژگی راه‌حل قطعی ندارد، اما می‌توان با تبدیل آن به یک مسأله‌ی بهینه‌سازی و با کمک الگوریتم‌های متنوع، به خصوص الگوریتم‌های هوشمند، ویژگی‌های مناسب را انتخاب نمود. در روش پیشنهادی، برای یافتن ویژگی‌های مناسب از مدل ترکیبی الگوریتم SA و شبکه‌ی عصبی MLP استفاده شده است و در ادامه، از آزمون ANOVA برای تایید صحت ویژگی‌های مطلوب که دارای سطح آماری معناداری هستند، استفاده می‌شود.

۲-۴- ساختار ترکیبی شبکه‌ی MLP و SA

به منظور تعیین بهترین ویژگی‌ها از نظر متمایزکنندگی، در روش پیشنهادی از ترکیب الگوریتم SA و شبکه‌ی عصبی MLP استفاده شده است. الگوریتم SA برای حل مسأله‌ی بهینه‌سازی، ابتدا از یک جواب اولیه شروع کرده و در یک حلقه‌ی تکرار به جواب‌های همسایه حرکت می‌کند. اگر جواب همسایه بهتر از



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

۲-۲- ویژگی‌ها

پس از این که سیگنال به ۷ زیرسطح خود تجزیه شد، ۷ ویژگی آماری از هر سطح تجزیه‌شده گرفته می‌شود. در ادامه به این ویژگی‌ها اشاره شده است.

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 خواهد بود.

۲- میانگین

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

۳- واریانس

$$\sigma^2 = \frac{1}{M} \sum_{i=0}^M (x_i - \mu)^2 \quad (۶)$$

۴- کشیدگی

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

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

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

$$MSE = \xi_{ave} = \frac{1}{N} \sum_{n=1}^N \xi(n) \quad (16)$$

پس از آموزش شبکه، مقدار $\frac{1}{MSE}$ به عنوان تابع برازندگی الگوریتم SA به صورت زیر محاسبه می‌شود [۲۵]:

$$fitness\ function = \frac{1}{MSE(net)} \quad (17)$$

در روش پیشنهادی، پس از استخراج ویژگی‌ها با تبدیل موجک گسسته، برای انتخاب ویژگی‌های مطلوب، از مدل ترکیبی الگوریتم SA و شبکه‌ی عصبی استفاده شده و ۶۳ ویژگی استخراج شده از توابع تجزیه، به ۲۳ ویژگی کاهش می‌یابد.

۲-۵- تایید ویژگی‌های انتخابی با استفاده از 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 که مقادیر p-value آن‌ها کم‌تر از ۰/۰۵ باشد، بیان‌گر ویژگی‌های مطلوب خواهند بود.

۳- بررسی نتایج

۳-۱- مجموعه‌ی داده‌های EEG

ثبت داده‌ی مورد استفاده برای آزمایش و ارزیابی مربوطه، از مردان و زنان قفقازی (۳۵-۲۱ ساله) بدون استفاده از هیچ دارویی به دست آمده است. این داده‌ها را می‌توان از بانک Sleep-EDF در پایگاه Physionet Data Bank که یک پایگاه عمومی برای دریافت داده‌ی EEG است نیز دریافت کرد [۲۶]. هشت داده در دو زیرمجموعه با عنوان‌های sc و st در طول خواب ثبت شده است. چهار داده‌ی اول با عنوان sc مربوط به افراد سالم و چهار داده‌ی دوم با عنوان st مربوط به افرادی است که دچار خواب‌آلودگی خفیف بوده‌اند.

فدراسیون بین‌المللی انجمن‌های الکتروانسفالوگرافی، تنظیمات قراردادی الکتروود (که سیستم ۱۰-۲۰ نیز نامیده می‌شود) را برای ۲۱ الکتروود (به‌جز الکتروودهای نرمة‌ی گوش) وضع کرده است. اغلب، الکتروودهای نرمة‌ی گوش A1 و A2 نامیده می‌شوند، که به عنوان الکتروودهای مرجع استفاده می‌شوند. سیستم ۱۰-۲۰، برخی فاصله‌های ثابت را با استفاده از مشخصه‌های آناتومیکی خاص در نظر می‌گیرد که اندازه‌گیری‌ها بر اساس آن‌ها انجام شده و سپس ۱۰ یا ۲۰ درصد از آن فاصله‌ی

جواب فعلی باشد، الگوریتم آن را به عنوان جواب فعلی می‌پذیرد. در این الگوریتم، جواب‌های مساله معادل اتم‌های جسمی است که می‌خواهیم تبرید کنیم و تابع هدف کمینه کردن میزان بی‌نظمی و تنش بین مولکول‌ها می‌باشد. از این رو برای رسیدن به این هدف، باید دما را کاهش داد تا میزان تنش کاهش یابد. دما در هر مرحله‌ی این الگوریتم، آستانه‌ی مجاز بی‌نظمی را نشان می‌دهد. احتمال حرکت به‌سوی جواب جدید توسط رابطه‌ی بولتزمن تعیین می‌شود.

$$p = \min\{1, \exp(-\frac{f(x_{nh}) - f(x_{el})}{KT_i})\} \quad (11)$$

در رابطه‌ی (۱۱)، T_i دمای لحظه‌ای فرایند، k ثابت تعدیل دهنده‌ی بولتزمن و $f(x)$ تابع شایستگی است. با افزایش تعداد تکرارها و کاهش تدریجی دمای الگوریتم، جواب به نقطه‌ای همگرا می‌شود که کم‌ترین سطح انرژی (مقدار تابع هدف) را دارد. مدل ایجاد شده توسط شبکه‌ی عصبی به عنوان تابع شایستگی (تابع سطح انرژی) در الگوریتم تبرید مورد استفاده قرار گرفته است [۲۳]. در روش پیشنهادی، برای تعیین مقادیر اولیه‌ی الگوریتم، دمای اولیه ۱۰، ثابت تعدیل ۰/۹۹، تعداد تکرارها ۲۰ و تعداد زیرتکرارها ۵ در نظر گرفته می‌شود.

شبکه‌ی عصبی، یک شبکه‌ی چندلایه‌ی پرسپترون تحت قاعده‌ی پس‌انتشار خطا با استفاده از تابع آموزش تحت عنوان لونیبرگ-مارکوات است. معماری شبکه‌ی عصبی به صورت feed-forward در نظر گرفته شده است [۲۴]. در هر بار آموزش شبکه‌ی عصبی، مقدار ۵۰٪ از داده‌ها به عنوان مجموعه‌ی آموزشی و ۵۰٪ از داده‌ها به عنوان مجموعه‌ی آزمایشی به کار 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:

$$net_j = \sum_{i=0}^m w_{ji}(n) y_i(n) \quad (12)$$

$$y_j = f_j(net_j) \quad (13)$$

$$e_j(n) = d_j(n) - y_j(n) : Error \quad (14)$$

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

$$\xi(n) = \sum_{j=c} e^2(n) : total\ Error \quad (15)$$


برای آموزش مجموعه و بقیه‌ی 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 آزمودن استفاده کرد.

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

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

۲-۳- نتایج حاصل از بهینه‌سازی

پس از ۲۰ بار تکرار آموزش‌های مداوم شبکه‌ی عصبی MLP و تولید بردارهای ویژگی تصادفی، سرانجام الگوریتم SA 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 می‌دهند. در این آزمون، ویژگی‌هایی که p-value آن‌ها کم‌تر از ۰/۰۵ باشد بیان‌گر ویژگی‌های مطلوب هستند. با توجه به جدول (۳) و شکل (۶) می‌توان نتیجه گرفت که ۲۳ ویژگی انتخابی از مدل ترکیبی الگوریتم SA و شبکه‌ی عصبی، ویژگی‌های مطلوبی هستند.




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

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


	توان	میانگین	چولگی	کشیدگی	فاکتور ضربه	انرژی	واریانس
Detail 1	-	-	۲/۴e-۲۳۰	-	-	-	-
Detail 2	۰۰/۰	-	۳/۲e-۲۱۹	-	-	-	-
Detail 3	۵/۸e-۲۳۱	-	۳/۸۹e-۱۹	-	۴/۴e-۷۳	-	۴/۲۲e-۲۳
Detail 4	-	۲/۳۳e-۴۷	۳/۶e-۱۸۲	۳۶/۳e-۵۳	۶/۹۴e-۸۳	-	-
Detail 5	-	-	-	۰/۰۰۰۷	۳۹/۲e-۷۵	-	۰/۰۰
Detail 6	۰/۰۰	-	۳۶/۳e-۱۵	-	-	-	-
Detail 7	-	۳/۰۹e-۶	-	-	۳/۸۵e-۱۹	۰۰/۰	۲e-۱۰۲
Aproximate 7	-	-	-	۸۲/۱e-۷۵	-	-	-
Coefficients	-	-	-	-	۰/۰۰	۰۰/۰	-

تعیین‌شده را به عنوان فاصله‌ی الکترودی استفاده می‌کند. الکترودهای با شماره‌ی فرد در سمت چپ، و شماره‌های زوج در سمت راست قرار دارند. شکل (۴) موقعیت الکترودها را مطابق با استاندارد ۱۰-۲۰ در نواحی مختلف سر نشان می‌دهد [۲۷].



شکل (۴) - موقعیت قرارگیری الکترودها مطابق با استاندارد ۱۰-۲۰ [۲۷]

برای ثبت داده از الکترودهای Fpz-Cz و Pz-Oz استفاده شده است. هم‌چنین فرکانس نمونه‌برداری ۱۰۰ هر تتر است. مطالعات پیشین نشان می‌دهد سیگنال EEG ثبت‌شده از کانال Pz-Oz عمل‌کرد بهتری در طبقه‌بندی نسبت به کانال Fpz-Cz ارائه می‌دهد [۱۱، ۱۲]. 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 [۲۶]. طول مدت‌زمان هر دوره در این مطالعه، ۳۰ ثانیه یا ۳۰۰۰ نمونه است. هر دوره 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 دوره‌های مختلف کلاس‌های مورد استفاده در این پژوهش را نشان می‌دهد. همان‌طور که در جدول (۲) ملاحظه می‌شود، تعداد کل دوره‌های ۳۰ ثانیه‌ای که در این مطالعه مورد استفاده قرار می‌گیرند، ۱۵۱۸۸ است. برای انجام آزمایش‌ها، نیمی از مجموعه‌ی داده‌های خواب Sleep-EDF به طور تصادفی



شکل (۶) - نمودار Box-whisker (الف) میانگین از Detail 7 و (ب) چولگی از Approximate 7

۳-۳ طبقه‌بندی با استفاده از BPNN

در این بخش، به بررسی طبقه‌بند، جزئیات و نتایج آزمایش‌ها پرداخته و برخی از اهمیت‌های نتایج را بیان می‌کنیم. رایانه‌ای که در شبیه‌سازی این مقاله مورد استفاده قرار گرفته دارای اینتل Core (TM) i5-3470، پردازنده‌ی ۱/۶ گیگاهرتز و رم ۸ گیگابایت است. در این مقاله برای طبقه‌بندی حالت‌های مختلف خواب، از یک شبکه‌ی عصبی پرسپترون چندلایه با الگوی پس‌انتشار خطا با استفاده از تابع آموزشی لونبرگ-مارکوات، استفاده می‌شود. شبکه‌ی BPNN استفاده شده در این مقاله یک شبکه‌ی دولایه بوده و تعداد ورودی‌های شبکه برابر با تعداد ویژگی‌های بهینه شده است. برای تعیین تعداد نورون‌های لایه‌ی مخفی، چندین بار آموزش شبکه‌ی عصبی با تعداد نورون‌های مختلف انجام گرفته است. در هر بار آموزش شبکه، خطای طبقه‌بندی محاسبه شده و در انتها بهترین تعداد برای نورون‌های لایه‌ی مخفی شبکه تعیین می‌شود. برای این منظور، از کل داده‌های موجود در پایگاه EDF برای شبیه‌سازی استفاده شده است، به گونه‌ای که ۵۰٪ از داده‌ها به عنوان مجموعه‌ی آموزشی، ۲۰٪ از داده‌ها به عنوان مجموعه‌ی اعتبارسنجی و ۳۰٪ از داده‌ها به عنوان مجموعه‌ی آزمایشی استفاده شده است. می‌توان نتیجه گرفت که با در نظر گرفتن ۳۰ نورون در لایه‌ی مخفی، شبکه بهترین عمل کرد را در طبقه‌بندی حالت‌های مختلف خواب از خود نشان می‌دهد. 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. هم‌چنین، ۳ شرط هم‌زمان برای توقف آموزش شبکه‌ی عصبی [۲۵]، به صورت زیر در نظر گرفته می‌شود:

۱- تعداد ۵۰۰ تکرار در هر اپیک

۲- همگرایی در میانگین مربعات خطا در مقدار 10^{-6}

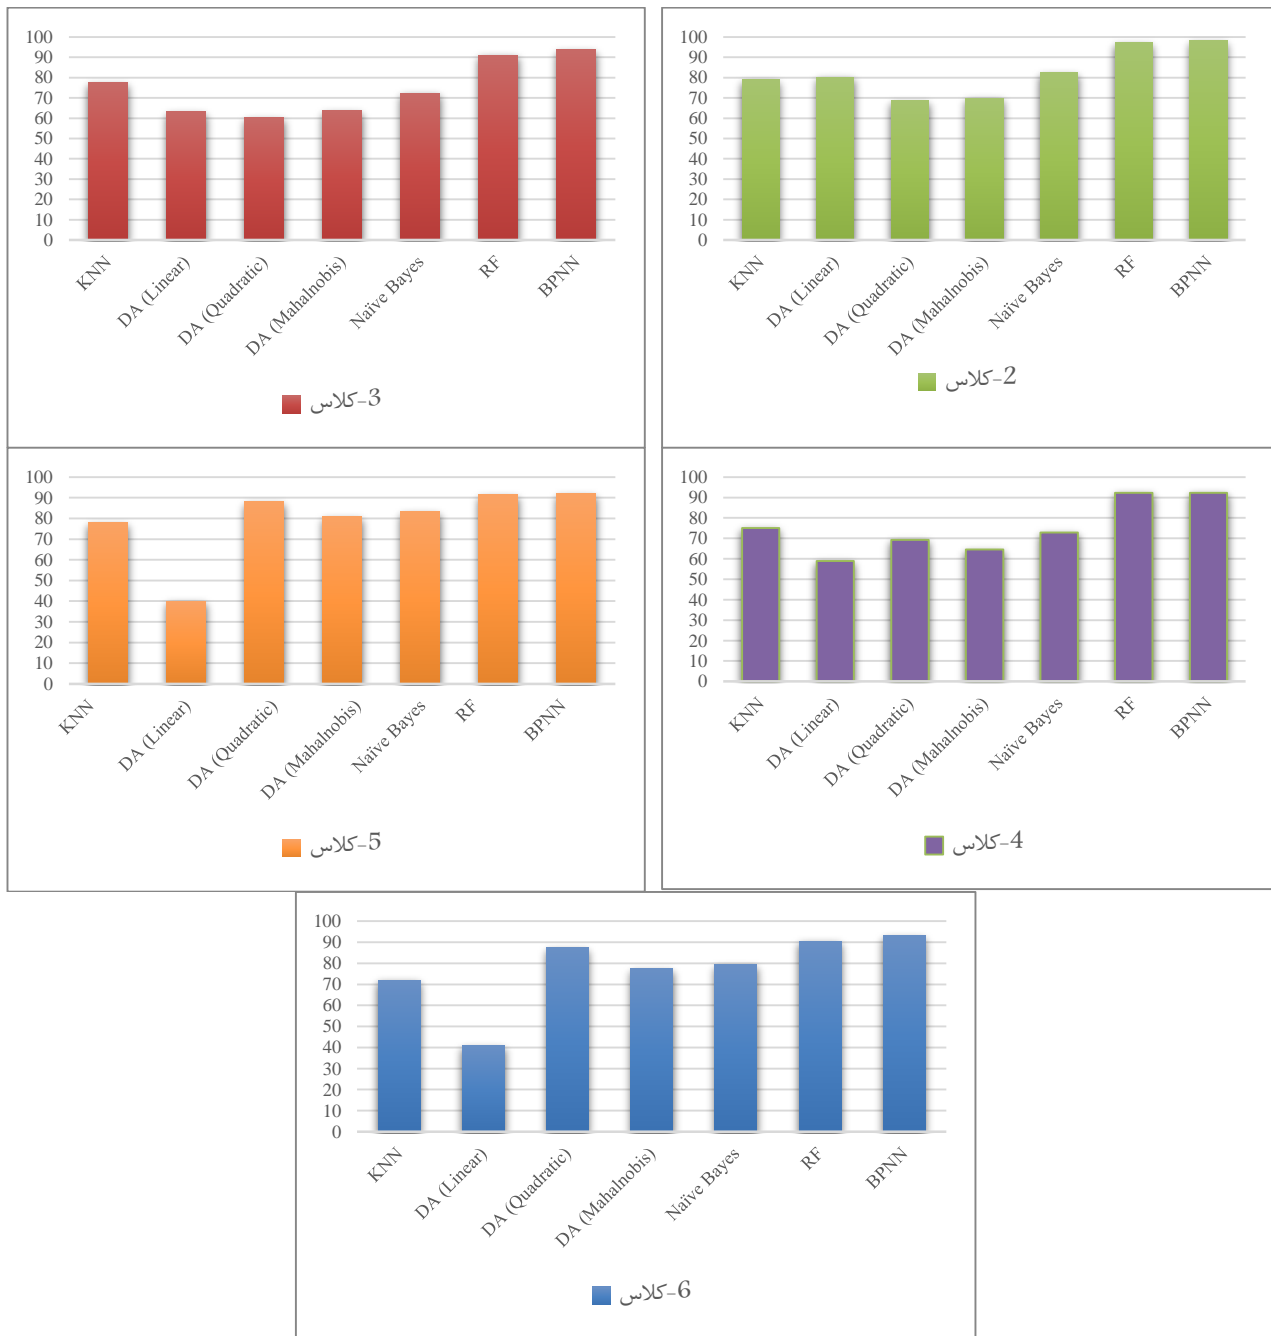
۳- همگرایی در نزول مقدار گرادیان خطا در 10^{-6}

در نهایت، دقت نهایی شبکه با میانگین‌گیری از دقت‌های حاصل شده در ۱۰ بار اجرای برنامه به دست آمده است. علاوه بر این، به غیر از BPNN، از طبقه‌بندهای نزدیک‌ترین همسایه [۲۸]، بیز ساده^۱ [۲۹]، آنالیز افتراقی^۲ [۳۰] و جنگل تصادفی [۴] از ویژگی‌های استخراج‌شده برای طبقه‌بندی استفاده شد. برای DA، عمل کرد سه تابع شناخته شده خطی، درجه‌ی دو و ماهالانوبیس^۳ مورد بررسی قرار گرفت. شکل (۷) عمل کرد روش پیشنهادی را برای کلاس‌های مختلف نشان می‌دهد. همان‌طور که مشاهده می‌شود، BPNN به عنوان بهترین مدل طبقه‌بندی در بین طبقه‌بندهای دیگر عمل می‌کند. هم‌چنین سرعت و زمان اجرای طبقه‌بند پیشنهادی در مقایسه با طبقه‌بندهای شبیه‌سازی‌شده (شکل (۷))، در جدول (۴) نشان داده شده است. طبق جدول (۴) زمان اجرای طبقه‌بند پیشنهادی نسبت به سایر طبقه‌بندها بیشتر است، اما دارای ضریب دقت بالای ۹۰٪ برای طبقه‌بندی ۶ کلاسه‌ی مراحل خواب می‌باشد. جدول (۵) مقادیر دقت روش‌های مختلفی که از مجموعه داده‌ی Sleep-EDF استفاده کرده‌اند را نشان می‌دهد. همان‌طور که از جدول (۵) مشاهده می‌شود، تمامی مقادیر گزارش‌شده برای روش پیشنهادی، دارای ضریب دقت بالای ۹۰٪ هستند. شکل (۸) نمودار ROC برای طبقه‌بندی مطابق با جدول (۱) را نشان می‌دهد. در مجموع، می‌توان نتیجه گرفت که عمل کرد روش پیشنهادی، از لحاظ اعتبار و قابلیت اطمینان، امیدوارکننده است. هم‌چنین عمل کرد روش پیشنهادی به‌طور جداگانه برای طبقه‌بندی ۶ حالت خواب در جدول (۶) مشاهده می‌شود. با توجه به دقت پژوهش‌های [۱۰] و [۱۵] برای طبقه‌بندی ۶-کلاسه‌ی خواب که به ترتیب ۸۸/۶۲٪ و ۵۰/۹۰٪ هستند، دقت روش پیشنهادی ۹۳/۲۰٪ درصد است.

^۳ Mahalanobis

^۱ Naive Bayes

^۲ Discriminant Analysis




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

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	۲۳۱
DA (Linear)	-	SC4002	۱۵۹
DA (Quadratic)	-	SC4002	۲۸۷
DA (Mahalanobis)	-	SC4002	۲۵۶
Naïve Bayes	-	SC4002	۲۴۳
RF	-	SC4002	۳۹۲
BPNN	SA	SC4002	۴۵۰



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

جدول (۵) - عمل کرد الگوریتم پیشنهادی در مقایسه با پژوهش‌های پیشین در مجموعه‌ی داده‌ی خواب پایگاه Sleep-EDF

الگوریتم‌های مختلف	کلاس-۲	کلاس-۳	کلاس-۴	کلاس-۵	کلاس-۶
Doroshenkov et al. [20]	-	-	-	-	٪۰/۶۱
Vural and Yildiz [19]	-	-	-	-	٪۹۸/۶۹
Liang et al. [17]	-	-	-	٪۹۸/۷۷	-
Liang et al. [13]	-	-	-	٪۶۰/۸۳	-
Kayikcioglu et al. [18]	-	-	-	٪۲۰/۸۷	-
Ronzhina et al. [12]	٪۹۶/۹۰	٪۸۸/۹۷	٪۴۲/۸۱	-	٪۷۶/۷۰
Zhu et al. [11]	٪۹۷/۹۰	٪۹۲/۶۰	٪۸۹/۳۰	٪۸۸/۹۰	٪۸۷/۵۰
Hassan and Bhuiyan [10]	٪۹۷/۷۳	٪۹۳/۵۵	٪۹۱/۲۰	٪۱۱/۹۰	٪۸۸/۶۲
Silveir et al. [15]	٪۳۰/۹۷	٪۹۳/۹۰	٪۹۲/۳۰	٪۹۱/۵۰	٪۹۰/۵۰
روش پیشنهادی	٪۹۸/۲۰	٪۹۳/۶۰	٪۹۲/۲۱	٪۹۲/۰۰	٪۹۳/۲۰

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

Expert	REM	AWA	S1	S2	S3	S4	SEN(%)
REM	۳۷۵۶	۴۸	۱۴۴	۱۶۶	۰	۱	۹۲/۴
AWA	۳	۳۸۸۴	۳۷	۶	۰	۰	۹۶/۷
S1	۲۲۸	۴۴	۳۸۹۳	۱۴۷	۰	۱۰	۹۵/۶
S2	۶۲	۳۴	۰	۳۵۰۲	۲۴۰	۷	۸۸/۱
S3	۱۷	۷	۰	۱۲۲	۳۶۱۶	۱۵۸	۹۰/۷
S4	۰	۱	۰	۳۳	۱۳۰	۳۸۶۹	۹۵/۶

است. در این روش، با استفاده از داده‌های موجود، یک تابع چند جمله‌ای بر داده‌ها برازش شده و سپس مقدار تابع در نقاط میانی مورد نظر 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 هریمیتی مکعبی تکه‌ای بین بردارهای x و y استفاده می‌شود، که نیاز به حافظه و زمان اجرای بیش‌تری نسبت به روش‌های دیگر درون‌یابی دارد؛ البته داده‌های حاصل از درون‌یابی پیوسته است. بدین ترتیب، کلیدی کلاس‌ها به بالاترین دوره درون‌یابی شده و مشکل عدم توازن کلاس‌ها حل خواهد شد.

۵- نتیجه‌گیری

در این مقاله، شناسایی خودکار مراحل خواب با استفاده از روش تبدیل موجک گسسته و مدل ترکیبی الگوریتم تبرید و شبکه‌ی عصبی ارائه شد. در روش پیشنهادی، سیگنال EEG تک‌کاناله با استفاده از روش تبدیل موجک گسسته به ۷ سطح تجزیه شد و چند ویژگی آماری از هر یک از سطوح تجزیه استخراج گردید. سپس با استفاده از ترکیب الگوریتم تبرید و شبکه‌ی عصبی

۴- بحث

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. مشاهده‌ی جدول (۲) این حقیقت را ثابت می‌کند. 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 حالت‌ها، 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. در روش پیشنهادی، برای حل این مشکل از درون‌یابی مکعبی برای توازن بین کلاس‌ها استفاده شده است.

درون‌یابی، ابزاری برای تقریب زدن داده‌های نامشخص در بین داده‌های معلوم است. از جمله کاربردهای درون‌یابی در پردازش تصویر و پردازش سیگنال است. از روش‌های مرسوم درون‌یابی یک‌بعدی می‌توان به درون‌یابی چندجمله‌ای و درون‌یابی بر پایه‌ی تبدیل فوری اشاره کرد [۳۲]. در این مقاله، برای برقراری توازن بین کلاس‌ها از درون‌یابی چندجمله‌ای استفاده شده

- [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] 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] 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.
- [12] 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
- [13] 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.
- [14] 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.
- [15] 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.
- [16] 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.
- [17] 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.
- [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] 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.
- [20] 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.

ویژگی‌های مهم انتخاب شد و به عنوان ورودی طبقه‌بند، جهت تفکیک کلاس‌ها از یکدیگر، مورد استفاده قرار گرفت. در این پژوهش، صحت ویژگی‌های بهینه‌ی انتخاب شده از مدل ترکیبی الگوریتم تبرید و شبکه‌ی عصبی، با استفاده از آزمون ANOVA بررسی شد. نتایج نشان داد که انتخاب ویژگی‌های آماری مطلوب در تشخیص حالت‌های مختلف خواب بسیار موثر است. نتایج الگوریتم برای طبقه‌بندی ۲-کلاس تا ۶-کلاس، ضریب دقت بالای ۹۰٪ را ارائه می‌دهد. علاوه بر این، با توجه به بالا بودن دقت الگوریتم، می‌توان از آن برای تشخیص اختلالات خواب، رفتار و همچنین برای تشخیص بیماری‌ها، از جمله بیماری پارکینسون، 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 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.

- [26] A. Rechtschaffen, "Techniques and Scoring Systems for Sleep Stages of Human Subjects," A Manual of Standardized Terminology, 1978.
- [27] R. W. Homan, J. Herman, and P. Purdy, "Cerebral location of international 10–20 system electrode placement," *Electroencephalography and clinical neurophysiology*, vol. 66, no. 4, pp. 376-382, 1987.
- [28] 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.
- [29] K. P. Murphy, "Naive bayes classifiers," *University of British Columbia*, vol. 18, 2006.
- [30] A. J. Izenman, "Linear discriminant analysis," in *Modern multivariate statistical techniques*: Springer, 2013, pp. 237-280.
- [31] C. Berthomier et al., "Automatic analysis of single-channel sleep EEG: validation in healthy individuals," *Sleep*, vol. 30, no. 11, pp. 1587-1595, 2007.
- [32] 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.
- [21] 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.
- [22] 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.
- [23] P. J. Van Laarhoven and E. H. Aarts, "Simulated annealing," in *Simulated annealing: Theory and applications*: Springer, 1987, pp. 7-15.
- [24] 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.
- [25] 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.