



Automatic Identification of Epileptic Seizures from EEG Signals based on Dictionary Learning

Sheykhivand, Sobhan¹ / Mousavi, Zohreh² / Yousefi Rezaii, Tohid^{3*}

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

² - Ph.D. Student, Department of Mechanical Engineering, Faculty of Mechanical Engineering, University of Tabriz, Tabriz, Iran

³ - Associate Professor, Biomedical Engineering Department, Faculty of Electrical and Computer Engineering, University of Tabriz, Tabriz, Iran

ARTICLE INFO

DOI: 10.22041/IJBME.2020.123628.1581

Received: 27 March 2020

Revised: 25 June 2020

Accepted: 15 July 2020

KEYWORDS

EEG
Epilepsy
Seizure
Sparse Representation-
based Classification
Dictionary Learning


ABSTRACT

Using a smart method to automatically detect different stages of epilepsy in medical applications, to reduce the workload of physicians in analyzing epilepsy data by visual inspection is one of the major challenges in recent years. One of the problems of automatic identification of different stages of epilepsy is extraction of desirable features which can make the most distinction between different stages of epilepsy. The process of finding the proper features is generally time consuming. This study presents a new approach for the automatic identification of different epileptic stages. In this paper, a sparse representation-based classification (SRC) with proposed dictionary learning is used to automatically identify the different stages of epilepsy using the EEG signal. The proposed method achieves 100% accuracy, sensitivity and specificity in 8 out of 9 scenarios. Also the proposed algorithm is resistant to Gaussian noise up to 0 decibels. The results show that using the proposed algorithm to identify different epileptic stages has a higher success rate than other similar methods.

***Corresponding Author**

Address	Room 215, Faculty of Electrical and Computer Engineering, University of Tabriz, Tabriz, Iran
Postal Code	5166616471
E-Mail	yousefi@tabrizu.ac.ir
Tel	+98-41-33393748
Fax	+98-41-33300819





شناسایی خودکار حالت‌های مختلف بیماری صرع از سیگنال EEG بر اساس یادگیری دیکشنری

شیخی‌وند، سبحان^۱ / موسوی، زهره^۲ / یوسفی رضایی، توحید^{۳*}

- ^۱ - دانشجوی دکتری، گروه مهندسی پزشکی، دانشکده‌ی مهندسی برق و کامپیوتر، دانشگاه تبریز، تبریز، ایران
^۲ - دانشجوی دکتری، گروه مهندسی مکانیک، دانشکده‌ی مهندسی مکانیک، دانشگاه تبریز، تبریز، ایران
^۳ - دانشیار، گروه مهندسی پزشکی، دانشکده‌ی مهندسی برق و کامپیوتر، دانشگاه تبریز، تبریز، ایران

مشخصات مقاله

شناسه‌ی دیجیتال: 10.22041/IJBME.2020.123628.1581

پذیرش: ۲۵ تیر ۱۳۹۹

بازنگری: ۵ تیر ۱۳۹۹

ثبت در سامانه: ۸ فروردین ۱۳۹۹

چکیده

استفاده از یک روش هوشمند برای تشخیص خودکار مراحل مختلف بیماری صرع در کاربردهای پزشکی جهت کاهش حجم کار پزشکان در تجزیه و تحلیل داده‌های صرع از طریق بازرسی بصری یکی از چالش‌های مهم در سال‌های اخیر بوده است. یکی از مشکلات شناسایی خودکار مراحل مختلف بیماری صرع، استخراج ویژگی‌های مطلوبی است که بتوانند بیش‌ترین تمایز را میان مراحل مختلف صرع ایجاد نمایند. فرایند یافتن ویژگی‌های مناسب عموماً امری زمان‌بر است. در این پژوهش رویکرد جدیدی برای شناسایی خودکار مراحل مختلف صرع ارائه شده است. در این مقاله از دسته‌بندی مبتنی بر نمایش تنک سیگنال (SRC) به همراه یادگیری دیکشنری آموزش دیده برای شناسایی خودکار مراحل مختلف بیماری صرع با استفاده از سیگنال EEG استفاده شده است. روش پیشنهادی در ۸ سناریو از ۹ سناریوی ارائه شده به صحت، حساسیت و اختصاصیت ۱۰۰٪ دست یافته و هم‌چنین در برابر نویز گوسی تا سطح صفر دسی‌بل مقاوم می‌باشد. نتایج به دست آمده نشان می‌دهد که استفاده از الگوریتم پیشنهادی برای شناسایی مراحل مختلف صرع موفقیت بیش‌تری نسبت به سایر روش‌های مشابه دارد.

واژه‌های کلیدی

الکتروانسفالوگرام
صرع
دسته‌بندی مبتنی بر نمایش
تنک (SRC)
یادگیری دیکشنری

*نویسنده‌ی مسئول

اتاق ۲۱۵، دانشکده‌ی مهندسی برق و کامپیوتر، دانشگاه تبریز، تبریز، ایران

نشانی

+۹۸-۴۱-۳۳۳۹۳۷۴۸

تلفن

۵۱۶۶۶۱۶۴۷۱

کد پستی

+۹۸-۴۱-۳۳۳۰۰۸۱۹

دورنگار

yousefi@tabrizu.ac.ir

پست الکترونیک



۱- مقدمه

با توجه به گزارش‌های سازمان سلامت جهانی، نزدیک به ۵۰ میلیون نفر در سراسر جهان از بیماری صرع^۱ رنج می‌برند [۱]. صرع به عنوان دومین اختلال مغزی شایع (بعد از سکتوی مغزی) شناخته شده که با وقوع غیرمنتظره‌ی تشنج مشخص می‌شود [۱]. در این بیماری سلول‌های عصبی در یک زمان محدود با ایجاد سیگنالی به طور غیرطبیعی سبب ایجاد رفتارهای غیرعادی، تشنج و از دست دادن هوشیاری می‌شوند [۲]. تشخیص صحیح و به موقع صرع برای شروع درمان دارویی و کاهش ریسک ابتلا به این بیماری امری ضروری است [۳]. در حال حاضر تشخیص صرع با استفاده از آزمایش‌های نورولوژی و آزمایش‌های کمکی مانند تصاویر مغزی و سیگنال‌های EEG^۲ انجام می‌شود. سیگنال‌های EEG می‌توانند ناهنجاری‌های مربوط به صرع Inter-Ictal و Ictal را تشخیص دهند [۴]. به طور معمول نوارها^۳ از طریق سیگنال‌های الکتریکی با هم در تماس بوده و بنابراین در فعالیت مغزی افراد عادی این سیگنال‌های الکتریکی به طور نرمال تنظیم شده است در حالی که در حین صرع یک فعالیت الکتریکی غیرطبیعی در شبکه‌ی عصبی شکل می‌گیرد که می‌تواند در یک محل باقی مانده و یا در کل سطح قشر مغز گسترش یابد.

به طور سنتی شناسایی ناهنجاری‌های صرعی با بازرسی پزشک متخصص اعصاب انجام می‌شود. تفسیر سیگنال‌های EEG با استفاده از ارزیابی شهودی امری زمان‌بر و خسته کننده بوده و نتایج به دست آمده متغیر و محدود به سطح دانش و تخصص پزشک مربوطه است. هم‌چنین داروهای ضدصرع دارای محدودیت بوده و در ۳۰٪ بیماران قادر به کنترل تشنج‌ها نمی‌باشند [۳]. بنابراین لازم است تا یک سیستم خودکار تشخیص کامپیوتری طراحی شود تا با استفاده از تکنیک‌های یادگیری ماشین به طور خودکار حالت‌های صرعی را از سیگنال EEG تشخیص دهد. این سیستم علاوه بر کمک به پزشک در تشخیص بیماری می‌تواند باعث درک و آشکارسازی مکانیسم‌های نهفته در بیمار شود.

یک تشنج صرعی (فعالیت‌های مغزی فرد مبتلا به صرع) دارای مراحل مختلفی بوده که در فرایند پیش‌بینی این تشنج‌ها نقش عمده‌ای دارند. تحقیقات پیشین نشان داده که فرایند تشنج

شامل چهار مرحله‌ی فاصله‌ی بین تشنج‌ها^۴، حالت پیش از تشنج^۵، حین تشنج^۶ و پس از تشنج^۷ است. شواهد نشان می‌دهد که تشنج‌ها از یک حالت قابل شناسایی مغز به نام Preictal به وجود آمده و پیش‌بینی آن‌ها با تمایز قائل شدن بین حالت‌های Preictal و Interictal امکان‌پذیر است [۴-۶].

در ادامه به بررسی مطالعات اخیر در حوزه‌ی شناسایی خودکار تشنج‌های صرعی پرداخته شده است. در مقاله‌ی تالاس و هم‌کارانش [۷] چگالی طیف توان^۸ (PSD) سیگنال EEG با استفاده از توزیع فرکانس زمانی محاسبه شده و از PSD به‌عنوان یک ویژگی برای طبقه‌بندی مراحل مختلف بیماری صرع استفاده شده است. در تحقیق آدلی و هم‌کارانش [۸] از تبدیل موجک گسسته^۹ و ویژگی‌های مبتنی بر پویایی غیرخطی مانند بعد همبستگی برای طبقه‌بندی مراحل مختلف بیماری صرع استفاده شده است. در پژوهش اوپس و هم‌کارانش [۹] ویژگی‌های فرکانسی از تبدیل هیلبرت-هوانگ^{۱۰} استخراج شده، برای تایید صحت این ویژگی‌ها از آزمون t استفاده شده و صحت و حساسیت الگوریتم برای طبقه‌بندی حالت‌های صرع و نرمال به ترتیب برابر با ۹۴٪ و ۹۶٪ گزارش شده است. در مقاله‌ی باجاج و هم‌کارانش [۱۰] از تجزیه‌ی حالت تجربی^{۱۱} (EMD) برای استخراج ویژگی‌ها استفاده شده، از ماشین بردار پشتیبان و الگوریتم حداقل مربعات (LS-SVM) برای طبقه‌بندی داده‌ها بهره گرفته شده، آزمون آماری Kruskal-Wallis برای تایید صحت ویژگی‌ها به کار گرفته شده و حساسیت، صحت و اختصاصیت الگوریتم برای طبقه‌بندی حالت‌های صرع و نرمال به ترتیب برابر با ۱۰۰، ۹۹ و ۹۹ درصد گزارش شده است. در تحقیق علم و هم‌کارانش [۱۱] از توابع مود ذاتی^{۱۲} (IMF) استخراج شده توسط EMD و شبکه‌های عصبی مصنوعی^{۱۳} (ANN) برای شناسایی حالت‌های مختلف بیماری صرع استفاده شده که از جمله مشکلات این کار می‌توان به استفاده از EMD به دلیل اختلاط در IMF-ها اشاره کرد. در پژوهش پکر و هم‌کارانش [۱۲] با استفاده از تبدیل موجک گسسته ۵ ویژگی آماری از سیگنال EEG استخراج شده، برای طبقه‌بندی از شبکه‌های عصبی مصنوعی در ۴ سناریوی مختلف استفاده شده و معیار اعتبارسنجی ۱۰-برابر به کار گرفته شده است. در مقاله‌ی وانگ و هم‌کارانش [۱۳] برای تشخیص خودکار مراحل

^۸ Power Spectrum Density^۹ Discrete Wavelet Transform^{۱۰} Hilbert Huang Transform^{۱۱} Empirical Mode Decomposition^{۱۲} Intrinsic Mode Functions^{۱۳} Artificial Neural Network^۱ Epilepsy^۲ Electroencephalography^۳ Neuron^۴ Interictal^۵ Preictal^۶ Ictal^۷ Postictal

طبقه‌بندی حالت‌های مختلف صرعی دارد. در مقاله‌ی ژانگ و هم‌کارانش [۲] از ویژگی‌های طیف توان شامل طیف توان نسبی^{۱۰}، نسبت طیف توان^{۱۱} و ضرایب همبستگی متقابل^{۱۲} بین تمام جفت الکترودها به عنوان دو مجموعه‌ی مستقل از ویژگی‌ها استفاده شده، فیلتر کالمن مرتبه‌ی دو^{۱۳} به منظور مرتب‌سازی ویژگی‌های انتخابی مورد استفاده قرار گرفته، از سه طبقه‌بند شامل AdaBoost، SVM با هسته‌ی RBF و شبکه‌ی عصبی مصنوعی برای طبقه‌بندی حالت‌های مختلف صرعی بهره گرفته شده و بهترین نتیجه‌ی طبقه‌بندی با حساسیت ۱۰۰٪ و میانگین نرخ کاذب ۰/۰۳۲۴ گزارش شده است. در تحقیق ترونگو و هم‌کارانش [۲۲] از شبکه‌های یادگیری عمیق^{۱۴} روی داده‌های EEG با پنجره‌های ۳۰ ثانیه‌ای با هم‌پوشانی ۵۰٪ به منظور استخراج ویژگی استفاده شده و حساسیت با تعداد ۶ کانال برابر با ۸۹/۱٪ گزارش شده است. در پژوهش پارک و هم‌کارانش [۲۳] طبقه‌بندی حالت‌های Interictal و Preictal تشنج با استخراج چگالی طیف توان سیگنال و با استفاده از طبقه‌بند ماشین بردار پشتیبان حساس به هزینه انجام شده، حساسیت الگوریتم برابر با ۹۷٪ گزارش شده و ثابت شده است که طیف‌های توان در باند بالای گاما بیش‌ترین تمایز را بین حالت Interictal و Preictal دارند. در مقاله‌ی آچاربا و هم‌کارانش [۲۴] با استفاده از شبکه‌های یادگیری عمیق و با به کارگیری ۱۰ لایه‌ی کانولوشنال و ۳ لایه‌ی تماماً متصل به جداسازی خودکار مراحل Preictal، Interictal و نرمال پرداخته شده و صحت ۸۸٪ و حساسیت ۹۵٪ به دست آمده است.

چالش عمده در الگوریتم‌های شناسایی خودکار تشنج‌های صرعی انتخاب ویژگی متمایز کننده‌ی مراحل مختلف صرع است. در اکثر مطالعات پیشین برای شناسایی خودکار تشنج‌های صرعی ویژگی‌ها با استفاده از روش‌های مرسوم آماری و پردازشی استخراج شده و سپس ویژگی‌های مطلوب و بهینه با روش‌های کاهش ویژگی انتخاب شده است. استخراج این ویژگی‌ها به صورت غیرخودکار در طبقه‌بندی مراحل مختلف تشنج‌های صرعی باعث پیچیدگی بار محاسباتی الگوریتم شده و علاوه بر این ویژگی‌های مطلوب و بهینه در یک مساله ممکن است برای مساله‌ی دیگر ویژگی بهینه محسوب نشود. بنابراین استفاده از روشی که بتواند ویژگی‌های مناسب را بسته به نوع

مختلف بیماری صرع از الگوریتم رگرسیون^۱ چندمتغیره بر اساس طبقه‌بند ماشین بردار پشتیبان^۲ (SVM) استفاده شده است. در تحقیق سمیه و هم‌کارانش [۱۴] برای طبقه‌بندی حالات Ictal از روش تبدیل فوریه‌ی سریع^۳ استفاده شده است. در پژوهش داس و هم‌کارانش [۱۵] از پارامترهای گوسی معکوس در دامنه‌ی موجک گسسته برای جداسازی حالات Ictal در بیماری صرع استفاده شده است. در مقاله‌ی گلر و هم‌کارانش [۱۶] یک طرح تشخیص خودکار حالت Ictal با استفاده از ضرایب موجک و یک ماشین بردار پشتیبان چندطبقه پیشنهاد شده است. در تحقیق گو و هم‌کارانش [۱۷] یک مدل تشخیص خودکار تشنج‌های صرعی با استفاده از ویژگی‌های طول خط زیرباند موجک EEG ارائه شده و از شبکه‌های عصبی مصنوعی برای طبقه‌بندی استفاده شده است. در پژوهش سوامی و هم‌کارانش [۱۸] ویژگی‌هایی مانند انرژی، آنترپی شانون^۴ و چند ویژگی آماری دیگر از زیرباندهای موجک سیگنال EEG استخراج شده و طبقه‌بندی آن‌ها با ترکیب شبکه‌های عصبی و رگرسیون انجام شده است. در مقاله‌ی حسن و هم‌کارانش [۱۹] تشخیص خودکار مراحل صرع در ۶ سناریوی مختلف مبتنی بر موجک بسته‌ای و طبقه‌بند بوت‌استرپ^۵ انجام شده و میزان صحت برای ۶ سناریوی پیشنهادی در حدود ۹۸٪ گزارش شده است. در تحقیق شارما و هم‌کارانش [۲۰] با استفاده از تبدیل موجک تحلیل فرکانس تحلیلی^۶ و محاسبه‌ی ابعاد فراکتال^۷ به جداسازی حالت‌های Preictal و Interictal پرداخته شده و صحت روش بر اساس طبقه‌بند LS-SVM برابر با ۹۸/۵٪ گزارش شده است. در پژوهش پنگ و هم‌کارانش [۲۱] چند الگوریتم برای پیش‌بینی تشنج روی ۲ نمونه‌ی انسانی و ۵ نمونه‌ی حیوانی اعمال شده، ویژگی‌ها از تمام کانال‌های سیگنال EEG شامل آنترپی شانون در ۴۶ باند فرکانسی با استفاده از پنجره‌های ۶۰ ثانیه‌ای با هم‌پوشانی ۵۰٪ استخراج شده، از طبقه‌بندهای Logistic Regression، Lasso LR و SVM با هسته‌های RBF^۸ و KNN^۹ به منظور طبقه‌بندی حالت‌های صرعی استفاده شده و نشان داده شده است که طبقه‌بند SVM با صحت ۹۷/۲٪، حساسیت ۸۱/۵٪ و دقت ۹۰/۹٪ برای نمونه‌ی حیوانی و طبقه‌بند Lasso LR با صحت ۹۵/۴٪، حساسیت ۹۰٪ و دقت ۹۳/۸٪ برای نمونه‌ی انسانی بهترین عمل کرد را برای

^۱ Radial Basis Functions

^۲ K Nearest Neighbor

^{۱۰} Relative Power Spectrum

^{۱۱} Power Spectrum Ratio

^{۱۲} Mutual Correlation

^{۱۳} Kalman Filter

^{۱۴} Deep Learning Networks

^۱ Regression

^۲ Support Vector Machine

^۳ Fast Fourier Transform

^۴ Shannon Entropy

^۵ Bootstrap

^۶ Analytic Time-Frequency Flexible Wavelet Transform

^۷ Fractal Dimension

حین بیداری ثبت شده است. زیرمجموعه‌های C و D مربوط به ۵ بیمار در حالت فاصله‌ی میان دو تشنج با محل ثبت متفاوت بوده و زیرمجموعه‌ی E مربوط به حالت Ictal است. فرکانس نمونه‌برداری در حدود ۱۷۳/۶۱۰ هرتز بوده و طول سیگنال ثبت شده برابر با ۲۳/۶ ثانیه (حاوی ۴۰۹۷ نمونه) است. این پژوهش مبتنی بر ۹ سناریوی مختلف تشنج‌های صرعی بوده که در جدول (۱) ارائه شده است.

جدول (۱) - سناریوهای مختلف پزشکی برای جداسازی

سناریو	کلاس	شرح کلاس
۱	E-A	تشنج - سالم (حالت چشم باز)
۲	E-B	تشنج - سالم (حالت چشم بسته)
۳	E-B-D	تشنج - سالم (حالت چشم بسته) - فاصله‌ی میان دو تشنج (الکتروُد تماسی)
۴	E-C	تشنج - فاصله‌ی میان دو تشنج (الکتروُد کاشته شده)
۵	E-D	تشنج - فاصله‌ی میان دو تشنج (الکتروُد تماسی)
۶	AB-E	تشنج - سالم (حالت چشم بسته و حالت چشم باز)
۷	E-CD	تشنج - فاصله‌ی میان دو تشنج (الکتروُد تماسی به الکتروُد کاشته شده)
۸	AB-CD	سالم (حالت چشم باز و حالت چشم بسته) - فاصله‌ی میان دو تشنج (الکتروُد تماسی به الکتروُد کاشته شده)
۹	ABCD-E	سالم (حالت چشم باز و چشم بسته) به همراه حالت فاصله‌ی میان دو تشنج (الکتروُد تماسی به الکتروُد کاشته شده) - تشنج

طبق جدول (۱) مشاهده می‌شود که مراحل مختلف صرعی در ۹ سناریوی مختلف و کاربردی در حوزه‌ی پزشکی طراحی و ارائه شده است. سناریوهای پیشنهاد شده برای طبقه‌بندی در این پژوهش در مقایسه با سایر پژوهش‌ها (ارزیابی تنها چند سناریو) به عنوان کامل‌ترین و جامع‌ترین مجموعه‌ی سناریوها (از لحاظ تعداد بررسی) برای ارزیابی شناخته می‌شود.

۲-۲- دسته‌بندی مبتنی بر نمایش تنک (SRC)

از نظر ریاضی به سیگنالی مانند $x \in \mathbb{R}^N$ هرگاه k نمونه‌ی سیگنال غیرصفر و بقیه صفر باشد k -تنک گفته می‌شود. از آن‌جا که اکثر سیگنال‌ها از جمله سیگنال‌های EEG خاصیت تنک بودن را ندارند لازم است یک ماتریس پایه مانند $\Phi \in \mathbb{R}^{N \times M}$ تعریف شود تا به وسیله‌ی آن امکان نمایش تنک سیگنال فراهم گردد. در

مساله و داده یاد بگیرد امری ضروری بوده و هدف پژوهش حاضر به شمار می‌رود. در این مقاله یک سامانه‌ی تماماً خودکار دسته‌بندی برای شناسایی خودکار حالت‌های مختلف یک تشنج صرعی با صحت و سرعت پیش‌بینی بالا و با استفاده از سیگنال‌های EEG بر مبنای نمایش تنک سیگنال و یادگیری دیکشنری طراحی شده است تا سیگنال خام اولیه را به منظور یادگیری ویژگی‌ها و شناسایی خودکار مراحل مختلف تشنج‌های صرعی پردازش کند.


در ادامه در بخش ۲ داده‌های آزمایشی مورد بررسی قرار گرفته، دسته‌بندی مبتنی بر نمایش تنک^۱ تجزیه و تحلیل شده و شبکه‌ی عصبی توضیح داده شده است. در بخش ۳ الگوریتم پیشنهادی ارائه شده، در بخش ۴ نتایج شبیه‌سازی و مقایسه با پژوهش‌های پیشین مورد بحث قرار گرفته و در بخش ۵ نتیجه‌گیری انجام شده است.

۲- مواد و روش‌ها

در این بخش ابتدا به تشریح دادگان آزمایشی و سپس به بررسی دسته‌بندی مبتنی بر نمایش تنک پرداخته شده است.

۲-۱- دادگان آزمایشی

در این مقاله از بانک اطلاعاتی EEG ایجاد شده توسط آندرزاک و هم‌کارانش که به طور گسترده در مطالعات صرع به کار گرفته شده استفاده شده است [۲۰]. این مجموعه از ۵۰۰ دوره‌ی سیگنال EEG تک‌کانال در ۵ زیرمجموعه (A, B, C, D و E) از افراد عادی و افراد مبتلا به تشنج (۱۰۰ دوره از هر زیرمجموعه) تشکیل شده است. نمونه‌ای از دوره‌های EEG متعلق به زیرمجموعه‌های A, B, C, D و E در شکل (۱) نشان داده شده است.



شکل (۱) - سیگنال EEG هر یک از حالت‌های مختلف صرعی

زیرمجموعه‌های A و B حاوی داده‌های EEG بوده که از ۵ فرد سالم با چشمان باز (A) و چشمان بسته (B) در حالت آرام و

^۱ Sparse Representation-Based Classification



۳- روش پیشنهادی

در این بخش جزئیات روش پیشنهادی برای تشخیص خودکار مراحل مختلف بیماری صرع ارائه شده است. بلوک دیاگرام روش پیشنهادی بر اساس دسته‌بندی مبتنی بر نمایش تنک در شکل (۲) نشان داده شده است.



۳-۱- دیکشنری مبتنی بر همبستگی داده‌ها مبتنی

بر حداقل مربعات بازگشتی وزن دار (CBW-RLS)

در حالت کلی دیکشنری به مجموعه‌ای از اتم‌ها (ستون‌های ماتریس) گفته می‌شود که بتوان هر داده‌ی مرتبط با آن دیکشنری را به صورت ترکیب خطی از اتم‌های آن نمایش داد. در یادگیری دیکشنری دو پارامتر ضرایب تنک مربوط به اتم‌های دیکشنری (X) و خود اتم‌های دیکشنری (D) وجود داشته که باید بهینه شوند. هدف مرحله‌ی اول که کدگذاری تنک^۱ نام دارد پیدا کردن ضرایب تنک بوده که با در نظر گرفتن یک دیکشنری از پیش تعریف شده محاسبه می‌شوند. در مرحله‌ی دوم که به‌روزرسانی دیکشنری^۲ نام دارد از ضرایب تنک محاسبه شده در مرحله‌ی قبل برای به‌روزرسانی اتم‌های دیکشنری استفاده می‌شود. این دو مرحله تا زمانی که الگوریتم یادگیری دیکشنری همگرا شود تکرار می‌شوند. دیکشنری‌های مورد استفاده برای به دست آوردن نمایش تنک سیگنال‌ها دیکشنری‌های تنک نام داشته و به دو دسته‌ی دیکشنری بر اساس پایه‌های ثابت^۳ (مانند پایه‌های تبدیل فوریه^۴، تبدیل موجک^۵، تبدیل کسینوسی گسسته^۶) که طراحی آن وابسته به سیگنال اولیه نیست و دیکشنری بر پایه‌ی یادگیری که طراحی آن کاملاً وابسته به سیگنال اولیه است تقسیم می‌شوند. روش‌های یادگیری دیکشنری بر اساس به‌روزرسانی اتم‌های

این صورت سیگنالی مانند x را k -تنک نامیده زیرا می‌توان سیگنال را به صورت $x = \Phi c$ ($c \in \mathbb{R}^M$ و $\|c\|_0 \leq k$) نوشت. نمایش تنک برای نمونه‌های چند الکتروود EEG به صورت زیر است.

$$\begin{aligned} X &= \Phi C \\ X &= (x_1, x_2, \dots, x_S) \in \mathbb{R}^{N \times S} \\ \Phi &= (\phi_1, \phi_2, \dots, \phi_M) \in \mathbb{R}^{N \times M} \\ C &= (c_1, c_2, \dots, c_S) \in \mathbb{R}^{M \times S} \end{aligned} \quad (1)$$

در این رابطه X ماتریسی شامل S سیگنال EEG، هر ستون از ماتریس X نشان دهنده‌ی یک الکتروود، Φ همان ماتریس پایه و C نمایش تنک هر کدام از سیگنال‌های مغزی است به گونه‌ای که c_j نمایش تنک مربوط به الکتروود x_j می‌باشد.

هدف از دسته‌بندی مبتنی بر نمایش تنک، بیان نمونه‌ی آزمون به صورت ترکیب خطی نمونه‌های آموزش یک کلاس است [۲۵]. اگر مجموعه‌ی نمونه‌های آموزش ماتریس $X \in \mathbb{R}^{m \times n}$ را تشکیل دهد (به طوری که هر کدام از داده‌های آموزش در ستون‌های آن جای داشته و ماتریس به ترتیب کلاس‌ها در کنار هم قرار گرفته باشد) و بردار نمونه‌ی آزمون نیز به صورت $X \in \mathbb{R}^{m \times n}$ باشد، مساله‌ی دسته‌بندی مبتنی بر نمایش تنک به صورت زیر تعریف می‌شود.

$$\min_{\alpha} \|\alpha\|_2 \quad s.t. \quad x = X\alpha \quad (2)$$

در این رابطه $\alpha \in \mathbb{R}^n$ برداری تنک شامل درایه‌های غیرصفر مرتبط با دسته‌ی نمونه‌ی آزمون است. با محاسبه‌ی مانده‌های هر کلاس به ازای نمونه‌ی آزمون و یافتن کم‌ترین مانده‌ها می‌توان کلاس داده‌ی آزمون را به صورت زیر به دست آورد.

$$\hat{y} = \arg \min_{i=1, \dots, c} r_i(x) = \|x - X\delta_i\|_2 \quad (3)$$

در این رابطه اندیس i نشان دهنده‌ی تعداد کلاس‌ها و δ_i تابع انتخاب کننده برای کلاس i است.

$$\delta_i(\alpha_j) = \begin{cases} \alpha_j \\ 0 \end{cases} \quad (4)$$

اما در بسیاری از مسائل عملی داده‌ی آزمون با نویزی با انرژی محدود همراه بوده و SRC به صورت زیر تبدیل می‌شود که در آن ε عددی مثبت و کوچک متناوب با انرژی نویز است.

$$\min_{\alpha} \|\alpha\|_2 \quad s.t. \quad \|x - X\alpha\|_2 \leq \varepsilon \quad (5)$$

^۱ FFT

^۲ Discrete Wavelet Transform

^۳ Discrete Cosine Transform

^۴ Sparse Coding

^۵ Dictionary Update

^۶ Deterministic Dictionaries

در مرحله‌ی دوم از ضرایب تنک به دست آمده از مرحله‌ی قبل برای به‌روزرسانی اتم‌های دیکشنری با به حداقل رساندن تابع هدف زیر استفاده می‌شود [۲۷].

$$\bar{D} = \operatorname{argmin} \|Y - DX\|_F^2, \forall j \in \{1:n\}, \|d_j\|_2 = 1 \quad (A)$$

در این مطالعه برای به‌روزرسانی اتم‌های دیکشنری از روش CBW-RLS استفاده شده است. با فرض D_0 به عنوان دیکشنری اولیه و C_0 به عنوان مقدار اولیه‌ی ماتریس C اولیه که مانند روش RLS [۲۶] به صورت ماتریس همانی در نظر گرفته شده، مراحل گام‌به‌گام روش پیشنهادی در شکل (۳) ارائه شده است.

الگوریتم CBW-RLS
۱- مقداردهی اولیه برای C_0 و D_0
۲- شروع حلقه‌ی ۱ ($i=1:L$)
۳- دریافت داده‌ی جدید y_i
۴- محاسبه‌ی x_i تنک کدینگ داده‌ی جدید با روش OMP
۵- مشخص کردن $\{d_i\}$ مجموعه‌ی اتم‌هایی از D که در نمایش y_i نقش دارند
۶- مشخص کردن $Y(y_i) \in \mathbb{R}^{m \times o}$ داده‌های همبسته با اتم‌های انتخاب شده در مرحله‌ی ۵
۷- مشخص کردن $D(y_i)$ اتم‌های مورد نیاز برای نمایش داده‌های انتخاب شده
۸- شروع حلقه‌ی ۲ ($j=1:o$)
۹- محاسبه‌ی بردار $u_j(y_i) = C_{j-1}^{-1}(y_i)x_j(y_i)$
۱۰- محاسبه‌ی خطای نمایش تنک $r_j(y_i) = y_j(y_i) - D_{j-1}(y_i)x_j(y_i)$
۱۱- محاسبه‌ی ضریب تصحیح $W_j(y_i)$
۱۲- محاسبه‌ی ضریب گام $\alpha_j = (W_j(y_i)) / (1 + W_j(y_i)x_j^T(y_i)u_j(y_i))$
۱۳- به‌روزرسانی دیکشنری $D_j(y_i) = D_{j-1}(y_i) + \alpha_j r_j(y_i)u_j^T(y_i)$
۱۴- به‌روزرسانی ماتریس C برای تکرار بعدی $C_j^{-1}(y_i) = C_{j-1}^{-1}(y_i) - \alpha_j u_j(y_i)u_j^T(y_i)$
۱۵- نرمالیزه کردن اتم‌های دیکشنری $D_j(y_i)$
۱۶- پایان حلقه‌ی ۲
۱۷- جای‌گذاری اتم‌های به‌روزرسانی شده در دیکشنری D
۱۸- به‌روزرسانی ضریب نمایش تنک سیگنال مورد استفاده در مرحله‌ی ۳
۱۹- پایان حلقه‌ی ۱

شکل (۳) - شبه‌کد مربوط به الگوریتم پیشنهادی CBW-RLS

۳-۲- الگوریتم تعقیب تطبیقی متعامد (OMP)

در مرحله‌ی یافتن نمایش تنک سیگنال، برای هر دسته‌ی داده از الگوریتم کاربردی تعقیب تطبیقی متعامد^۳ (OMP) استفاده شده که یک الگوریتم بازگشتی مرحله‌ای حریص است. هدف

دیکشنری به دو دسته‌ی روش‌های یادگیری دسته‌ای و یادگیری متوالی تقسیم می‌شوند. روش یادگیری دیکشنری برخط^۱ (نوعی یادگیری متوالی) از یک حدس اولیه برای دیکشنری شروع شده و اتم‌های آن به صورت بازگشتی به عنوان داده‌های تعلیمی جدید به‌روزرسانی می‌شود. در روش پیشنهادی یک الگوریتم یادگیری دیکشنری برخط بر پایه‌ی همبستگی داده‌ها مبتنی بر حداقل مربعات بازگشتی وزن‌دار^۲ (CBW-RLS) برای به‌روزرسانی اتم‌های دیکشنری طراحی شده است. در روش‌های دسته‌ای در هر تکرار از الگوریتم از تمام داده‌های تعلیمی برای به‌روزرسانی دیکشنری استفاده می‌شود که باعث افزایش پیچیدگی محاسباتی شده و نیازمند حافظه برای نگه‌داری داده‌های تعلیمی است. در روش‌های یادگیری برخط در هر تکرار بدون در نظر گرفتن داده‌های تعلیمی پیشین فقط از داده‌های تعلیمی جدید برای به‌روزرسانی دیکشنری استفاده می‌شود. در روش پیشنهادی از همبستگی داده‌ی جدید با داده‌های پیشین به جای ضریب فراموشی، از داده‌های دارای همبستگی با داده‌ی جدید برای به‌روزرسانی اتم‌های دیکشنری و از ضریب تصحیح معرفی شده در [۲۶] استفاده شده است. روش پیشنهادی نسبت به روش دسته‌ای پیچیدگی محاسباتی کم‌تری داشته اما به دلیل نداشتن حافظه نمی‌تواند از داده‌های پیشین در به‌روزرسانی دیکشنری استفاده کند.

اگر $Y \in \mathbb{R}^{m \times L}$ سیگنال EEG، $D \in \mathbb{R}^{m \times n}$ ماتریس دیکشنری و $X \in \mathbb{R}^{n \times L}$ ضرایب تنک مرتبط با سیگنال باشد، برای مشخص کردن داده‌های همبسته با داده‌ی جدید از روش پیشنهادی در مقاله‌ی [۲۶] استفاده شده و $D(y_i)$ و $Y(y_i) \in \mathbb{R}^{m \times o}$ به دست می‌آید، به طوری که $L \geq 0$ و $Y(y_i)$ ماتریس کاهش بعد یافته‌ی ماتریس Y بوده که ستون‌های آن ستون‌هایی از ماتریس اصلی Y است که با بردار y_i همبستگی دارد. هدف یادگیری دیکشنری پیدا کردن ضرایب تنک (X) و اتم‌های دیکشنری (D) با به حداقل رساندن تابع هدف زیر است [۲۷].

$$\{\bar{D}, \hat{X}\} = \operatorname{argmin} \|Y - DX\|_F^2, \forall j \in \{1:n\} \|d_j\|_2 = 1, \forall i \in \{1:L\} \|x_i\|_0 \leq k \quad (6)$$

در این رابطه $\|\cdot\|_F$ نرم فروبینوس و $\|\cdot\|_2$ نرم ۲ است. حل رابطه‌ی (۱) شامل دو مرحله است. مرحله‌ی اول کدگذاری تنک بوده که در آن فرض می‌شود دیکشنری معلوم است و ضرایب تنک با به حداقل رساندن تابع هدف زیر به دست می‌آید [۲۷].

$$\forall i \in \{1:L\}, \hat{x}_i = \operatorname{argmin} \|y_i - Dx_i\|_2, \|x_i\|_0 \leq k \quad (7)$$

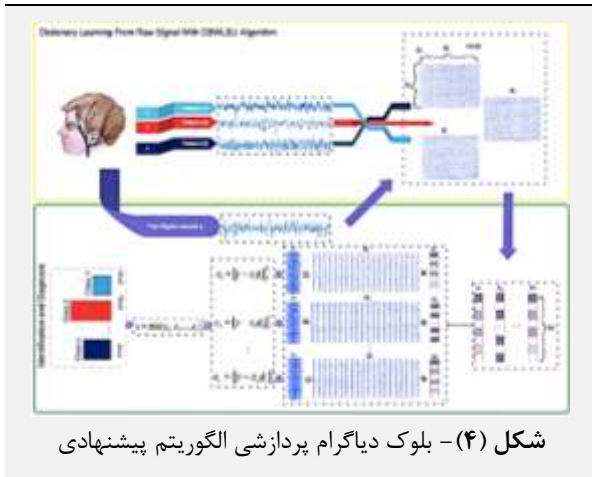
^۳ Orthogonal Matching Pursuit

^۱ Online Dictionary Learning

^۲ Correlation Based Weighted Recursive Least Squares Dictionary Update (CBW-RLS)



به طوری که از ۹۰٪ داده‌ها به طور تصادفی برای آموزش و از ۱۰٪ باقی‌مانده برای آزمایش و اعتبارسنجی استفاده شده است. مقدار پارامتر k -تنک برای یادگیری و طبقه‌بندی به صورت تجربی برابر با ۱۰ در نظر گرفته شده است.



۴- نتایج و بحث

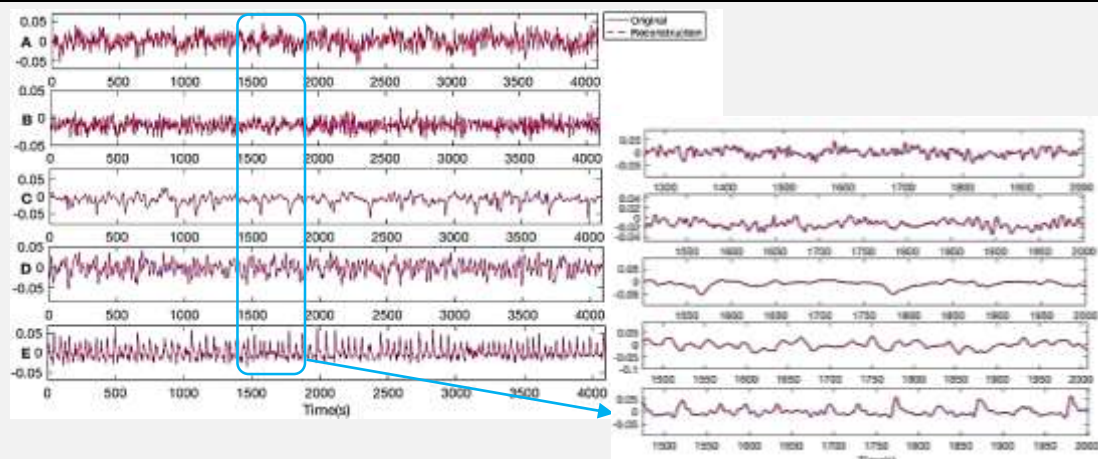
در این مقاله از رایانه‌ای با مشخصات Intel Core(TM) i5-3470 پردازنده ۱/۶ گیگاهرتز و رم ۸ گیگابایت استفاده شده است. به منظور ارزیابی عمل کرد طبقه‌بندی الگوریتم پیشنهادی ۹ سناریوی رایج در کاربردهای بالینی مطابق با جدول (۱) (مورد I تا IX) از ۵ زیرمجموعه‌ی موجود از داده‌های EEG در نظر گرفته شده (A, B, C, D, E) که در بخش ۲-۱ معرفی شده است. برای ارزیابی بصری عمل کرد بازسازی الگوریتم پیشنهادی یک نمونه‌ی تصادفی از هر یک از زیرمجموعه‌ها گرفته شده و سیگنال‌های اصلی و بازسازی شده در شکل (۵) نشان داده شده است. مشاهده می‌شود که سیگنال‌های بازسازی شده کاملاً با نمونه‌های اصلی سازگار است.

این روش با توجه به در نظر گرفتن $y \in \mathbb{R}^n$ و دیکشنری $D \in \mathbb{R}^{m \times n}$ یافتن \hat{y} به عنوان تقریب تنک سیگنال داده شده‌ی y روی دیکشنری D است. در هر مرحله اتم‌های دیکشنری دارای بزرگ‌ترین تصویر روی سیگنال باقی‌مانده ($r = y - \hat{y}$) انتخاب شده و سپس ضرایب نمایش تنک با کمک این اتم‌ها و روش حداقل مربعات محاسبه می‌شود. در این روش ابتدا $r_0 = y$ و $k=1$ در نظر گرفته شده و سپس مراحل زیر به ترتیب اجرا می‌شود.

- ۱- یک اتم جدید از دیکشنری با توجه به رابطه‌ی $d_k = \arg \max_{d_w} |r_{k-1}, d_w|$ انتخاب می‌شود
 - ۲- اتم انتخاب شده به مجموعه‌ی بردارهای مورد استفاده برای نمایش تنک y ($D_k = [d_1, d_2, \dots, d_k]$) اضافه می‌شود
 - ۳- تقریب y_k با توجه به D_k جدید به‌روزرسانی شده و ضرایب نمایش تنک با استفاده از روش حداقل مربعات محاسبه می‌شود
 - ۴- سیگنال باقی‌مانده ($r = y - \hat{y}$) به‌روزرسانی می‌شود
- شرط توقف الگوریتم می‌تواند بر اساس انتخاب تعداد مشخصی از اتم‌ها، نرم سیگنال باقی‌مانده و یا ماکسیمم ضرب داخلی (در مرحله ۱) تعیین شود. روش OMP از نظر پیاده‌سازی روشی ساده بوده و می‌تواند به نحوی برنامه‌ریزی شود تا نمایشی تنک از سیگنال با تعداد عناصر غیرصفر از پیش تعیین شده ارائه دهد که یک ویژگی مطلوب در تعلیم دیکشنری به شمار می‌رود [۲۵]. مراحل ذکر شده در شکل (۴) نمایش داده شده است.

۳-۳- پارامترهای مربوط به الگوریتم پیشنهادی

از روش آزمون و خطا برای تعیین پارامترهای روش پیشنهادی استفاده شده است. با توجه به این که طول هر بخش برابر با طول داده‌ها (۴۰۹۷ نمونه) در نظر گرفته شده، ابعاد دیکشنری برابر با 600×4097 تعیین شده است. در فرایند آموزش و آزمون داده‌ها نیز از معیار ارزیابی ۱۰-برابر^۱ استفاده شده است.




شکل (۵) - سیگنال‌های اصلی و بازسازی شده برای هر یک از زیرمجموعه‌های A, B, C, D, E برای نمونه‌ی شماره‌ی ۵۰


^۱ 10-Fold Cross Validation

در شکل (۷) ارائه شده است. مشاهده می‌شود که نمونه‌ها به کمک اتم‌های یاد گرفته شده‌ی دیکشنری پیشنهادی به طور موثر به ضرایب تنک خود رمزگذاری شده است. برای وضوح بیشتر یک نمونه از داده‌های آزمون زیرمجموعه‌های E-A انتخاب و ضرایب تنک آن‌ها در شکل (۸) نشان داده شده است.


برای درک بهتر مساله سیگنال‌های بازسازی شده‌ی ۹۰ نمونه از هر زیرمجموعه (برای داده‌های آموزشی) در شکل (۶) در یک نمونه‌ی زمانی خاص ارائه شده است. همچنین به عنوان یک اقدام کمی برای نمایش عمل کرد بازسازی الگوریتم پیشنهادی، خطای بازسازی ($E=y-\hat{y}/y$) برای سیگنال شکل (۶) محاسبه و



شکل (۶) - تعداد ۹۰ نمونه از سیگنال‌های بازسازی شده (برای مجموعه‌ی داده‌های آموزشی) در یک زمان خاص برای هر زیرمجموعه



شکل (۸) - ضرایب تنک رمزگذاری شده از نمونه‌های آزمون از ۵ زیرمجموعه



شکل (۷) - خطای بازسازی کمی برای نمونه‌های زیرمجموعه‌های شکل (۶)

در سال‌های اخیر چندین روش تشخیص خودکار مراحل مختلف بیماری صرع با استفاده از سیگنال EEG ارائه شده که نتایج این مطالعات بر اساس پایگاه داده‌ی مشابه در مقایسه با الگوریتم پیشنهادی در جدول (۳) ارائه شده است. مشاهده می‌شود که روش پیشنهادی ارائه شده بر اساس یادگیری دیکشنری آموزش دیده در مقایسه با سایر روش‌ها بالاترین میزان صحت، حساسیت و اختصاصیت را برای ۹ سناریو دارد. در مطالعات پیشین از روش‌های متداول مانند WT، EMD و غیره برای استخراج و انتخاب ویژگی‌های مهم سیگنال استفاده شده که شامل برخی از مشکلات رایج در رابطه با پارامترهای روش انتخاب و استخراج ویژگی مانند انتخاب نوع موج مادر، تعداد سطوح تجزیه و غیره است. در حالی که روش پیشنهادی بدون استفاده از روش‌های معمول طبقه‌بندی منجر به حذف بلوک انتخاب ویژگی شده و بدون استفاده از الگوریتم‌های

زمان اجرای الگوریتم پیشنهادی برای آموزش هر دیکشنری با استفاده از مجموعه‌ی داده‌ها (زیرمجموعه‌های A، B، C، D و E)، تقریباً برابر با ۲۸ دقیقه است. به عبارت دیگر در مجموع ۱۴۰ دقیقه برای آموزش ۵ دیکشنری (برای هر زیرمجموعه‌ی A تا E) زمان لازم بوده در حالی که برای طبقه‌بندی کل مجموعه‌ی داده‌های آزمون با توجه به دیکشنری آموزش دیده تنها ۶ ثانیه زمان صرف شده است. به منظور ارزیابی طبقه‌بندی روش پیشنهادی برای ۹ سناریوی از پیش تعریف شده‌ی مختلف، عمل کرد طبقه‌بندی از نظر معیارهای صحت، حساسیت و اختصاصیت در جدول (۲) ارائه شده است. مشاهده می‌شود که میزان صحت، حساسیت و اختصاصیت الگوریتم پیشنهادی برای ۸ سناریو از ۹ سناریوی تعریف شده برابر با ۱۰۰٪ بوده و سناریوی VIII نیز از لحاظ نتایج به دست آمده امیدوار کننده است.



جدول (۳) - مقایسه‌ی عمل کرد الگوریتم پیشنهادی با سایر روش‌های رایج

پیشنهادی	BPNN	SVM	Case-I	یادگیری ویژگی از سیگنال خام
۱۰۰	۹۴/۳	۸۹/۷	Case-I	یادگیری ویژگی از سیگنال خام
۱۰۰	۹۴	۹۲/۲	Case-III	
۹۵	۸۸/۴	۸۱/۹	Case-VIII	
۹۷	۹۸/۷	۹۵/۴	Case-I	ویژگی دستی
۹۵/۳	۹۶	۹۴/۱	Case-II	
۹۲/۲	۹۳/۲	۹۱/۹	Case-VIII	

برای نمایش عمل کرد مطلوب روش پیشنهادی، صحت طبقه‌بندی با استفاده از سایر روش‌های رایج برای ۳ سناریوی از پیش تعریف شده‌ی مختلف (I, III و VIII) به دست آمده است. در این راستا چندین ویژگی دستی از داده‌های زمانی به همراه BPNN و SVM به عنوان روش‌های مقایسه‌ای انتخاب شده [۲۸] و از تابع RBF به عنوان تابع کرنل SVM استفاده شده است. به منظور دستیابی به نتایج بهتر از مدل BPNN تعداد لایه‌ها و پارامترها با انواع مختلف داده‌ی ورودی تنظیم شده است. ویژگی‌های حداقل^۱، حداکثر^۲، چولگی^۳، کشیدگی^۴، ضریب اوج^۵، واریانس^۶، خطای میانگین مربعات^۷ و میانگین^۸ به عنوان ویژگی‌های دستی (ویژگی‌های زمانی) انتخاب شده است [۲۸]. با مقایسه‌ی صحت روش‌های مختلف مبتنی بر یادگیری ویژگی‌ها بر اساس داده‌های خام و مبتنی بر ویژگی‌های دستی مشاهده می‌شود که یادگیری ویژگی از داده‌های خام با روش پیشنهادی (CBWRLSU) نتایج بهتری نسبت به ویژگی‌های دستی داشته و می‌تواند به طور خودکار از ویژگی‌های مفید برای طبقه‌بندی استفاده کند. هم‌چنین تمام مدل‌های آزمایش شده از جمله BPNN، CBWRLS و SVM نتایج تقریباً مشابهی با ویژگی‌های دستی دارند.

به منظور ارزیابی عمل کرد الگوریتم پیشنهادی در سناریوهای نویز آلود، نویز گوسی سفید با SNR -۲۰ تا ۲۰ دسی‌بل به سیگنال‌های EEG اضافه شده و صحت طبقه‌بندی ۹ سناریوی مختلف مراحل صرعی در هر طیف مورد بررسی قرار گرفته که نتایج آن در شکل (۹) ارائه شده است. مشاهده می‌شود که عمل کرد طبقه‌بندی الگوریتم پیشنهادی به طور قابل توجهی نسبت به نویز در طیف گسترده‌ای از SNR مقاوم است.

با وجود نوآوری در طراحی دیکشنری آموزش دیده و هم‌چنین حذف بلوک-دیاگرام استخراج و انتخاب ویژگی، این پژوهش نیز

استخراج ویژگی متداول مستقیماً از روی خود سیگنال EEG مراحل مختلف بیماری صرع را تشخیص می‌دهد.

جدول (۲) - مقایسه‌ی عمل کرد الگوریتم پیشنهادی با پژوهش‌های اخیر (*استفاده از ارزیابی ۱۰-برابر)

سناریو	مرجع	صحت	حساسیت	اختصاصیت
I	[۱۷]	۹۵/۲۰	۹۸/۱۷	۹۲/۱۲
	[۲۴]	۹۹	۹۹	۹۹
	*[۷]	۱۰۰	۱۰۰	۱۰۰
	*[۱۲]	۱۰۰	۱۰۰	۱۰۰
	[۱۴]	۹۹/۸۰	۹۹/۶	۹۹/۹
	*[۱۸]	۱۰۰	-	-
	[۱۹]	۱۰۰	۱۰۰	۱۰۰
	*[۲۰]	۱۰۰	۱۰۰	۱۰۰
	پیشنهادی*	۱۰۰	۱۰۰	۱۰۰
II	[۱۴]	۹۹/۳۰	۹۹	۹۹/۶
	[۱۸]	۹۸/۸۹	-	-
	*[۲۰]	۱۰۰	۱۰۰	۱۰۰
	پیشنهادی*	۱۰۰	۱۰۰	۱۰۰
III	[۱۷]	۹۳/۵	-	-
	*[۲۱]	۸۷/۷	۹۵	۹۰
	پیشنهادی*	۱۰۰	۱۰۰	۱۰۰
IV	[۱۴]	۹۸/۵۰	۹۹/۳	۹۷/۷
	*[۱۸]	۹۸/۷۲	-	-
	[۱۹]	۱۰۰	۱۰۰	۱۰۰
	*[۲۰]	۹۹	۱۰۰	۹۸
	پیشنهادی*	۱۰۰	۱۰۰	۱۰۰
V	[۱۱]	۱۰۰	-	-
	[۱۹]	۱۰۰	۱۰۰	۱۰۰
	*[۲۰]	۹۸/۵۰	۱۰۰	۹۷
	پیشنهادی*	۱۰۰	۱۰۰	۱۰۰
VI	[۱۸]	۹۹	-	-
	*[۲۰]	۱۰۰	۱۰۰	۱۰۰
	پیشنهادی*	۱۰۰	۱۰۰	۱۰۰
VII	*[۱۸]	۹۵/۱۵	-	-
	[۱۹]	۹۸/۶۷	۹۸/۶۷	۹۸/۶۷
	*[۲۰]	۹۸/۶۷	۱۰۰	۹۶
	پیشنهادی*	۱۰۰	۱۰۰	۱۰۰
VIII	*[۲۰]	۹۲/۵۰	۹۰/۵۰	۹۴/۵۰
	پیشنهادی*	۹۵	۹۵/۴۵	۹۵
IX	[۱۷]	۹۷/۷۷	۹۸/۶۱	۹۴/۶۰
	[۱۹]	۹۹/۶۰	۹۹/۴۹	۱۰۰
	*[۲۰]	۹۹/۲۰	۱۰۰	۹۶
	پیشنهادی*	۱۰۰	۱۰۰	۱۰۰

^۱ Crest Factor

^۲ Variance

^۳ Root Mean Square (RMS)

^۴ Mean

^۱ Minimum


^۲ Maximum

^۳ Skewness

^۴ Kurtosis

- [2] Z. Zhang and K. K. Parhi, "Seizure prediction using long-term fragmented intracranial canine and human EEG recordings," in *Signals, Systems and Computers, 2016 50th Asilomar Conference on*, 2016, pp. 361-365: IEEE.
- [3] K. Gadhomi, J.-M. Lina, F. Mormann, and J. Gotman, "Seizure prediction for therapeutic devices: A review," *Journal of neuroscience methods*, vol. 260, pp. 270-282, 2016.
- [4] Harvard Health Publications, Harvard Medical School, 2014. Seizure overview. <http://www.health.harvard.edu/mind-and-mood/seizure-overview>.
- [5] A. Theodorakopoulou, "Machine learning data preparation for epileptic seizures prediction," 2017.
- [6] Y. Park, L. Luo, K. K. Parhi, and T. Netoff, "Seizure prediction with spectral power of EEG using cost-sensitive support vector machines," *Epilepsia*, vol. 52, no. 10, pp. 1761-1770, 2011.
- [7] A. T. Tzallas, M. G. Tsipouras, and D. I. J. I. t. o. i. t. i. b. Fotiadis, "Epileptic seizure detection in EEGs using time-frequency analysis," vol. 13, no. 5, pp. 703-710, 2009.
- [8] H. Adeli, S. Ghosh-Dastidar, and N. J. I. T. o. B. E. Dadmehr, "A wavelet-chaos methodology for analysis of EEGs and EEG subbands to detect seizure and epilepsy," vol. 54, no. 2, pp. 205-211, 2007.
- [9] R.J. Oweis, E. W. J. B. e. o. Abdulhay, "Seizure classification in EEG signals utilizing Hilbert-Huang transform," vol. 10, no. 1, p. 38, 2011.
- [10] V. Bajaj and R. B. J. I. T. o. I. T. i. B. Pachori, "Classification of seizure and nonseizure EEG signals using empirical mode decomposition," vol. 16, no. 6, pp. 1135-1142, 2012.
- [11] S. S. Alam, M. I. H. J. I. j. o. b. Bhuiyan, and h. informatics, "Detection of seizure and epilepsy using higher order statistics in the EMD domain," vol. 17, no. 2, pp. 312-318, 2013.
- [12] M. Peker, B. Sen, D. J. I. j. o. b. Delen, and h. informatics, "A novel method for automated diagnosis of epilepsy using complex-valued classifiers," vol. 20, no. 1, pp. 108-118, 2016.
- [13] G. Wang et al., "Epileptic seizure detection based on partial directed coherence analysis," vol. 20, no. 3, pp. 873-879, 2016.
- [14] K. Samiee, P. Kovacs, M.J.I.t.o.B.E. Gabbouj, "Epileptic seizure classification of EEG time-series using rational discrete short-time Fourier transform," vol. 62, no. 2, pp. 541-552, 2015.
- [15] A. B. Das, M. I. H. Bhuiyan, S. S. J. S. Alam, Image, and V. Processing, "Classification of EEG signals using normal inverse Gaussian parameters in the dual-tree complex wavelet transform domain for seizure detection," vol. 10, no. 2, pp. 259-266, 2016.
- [16] I. Guler E.D.J.I.T.o.I. T. i. B. Ubeyli, "Multiclass support vector machines for EEG-signals classification," vol. 11, no. 2, pp. 117-126, 2007.

مانند سایر مطالعات پیشین دارای محدودیت‌هایی است. با وجود استفاده از پایگاه داده‌ی دانشگاه بن آلمان در اختیار داشتن یک پایگاه داده‌ی بزرگ‌تر برای ارزیابی مطالعات طبقه‌بندی مراحل مختلفی بیماری صرع ضروری به نظر می‌رسد. هم‌چنین زمان آموزش الگوریتم پیشنهادی نسبتاً زیاد است که این مورد می‌تواند با استفاده از سیستم‌های واحد پردازش گرافیکی^۱ (GPU) برطرف گردد.



شکل (۹) - مقایسه‌ی مقاومت الگوریتم پیشنهادی در برابر نویز

۵- نتیجه‌گیری

در این مقاله یک روش جدید برای شناسایی خودکار مراحل مختلف بیماری صرع با استفاده از دسته‌بندی مبتنی بر نمایش تنک (SRC) و یادگیری دیکشنری پیشنهادی ارائه شده است. در روش پیشنهادی از سیگنال‌های EEG برای جدا کردن ۲ تا ۵ کلاس در ۹ سناریوی مختلف با استفاده از مجموعه‌ی داده‌های ثبت شده در دانشگاه بن آلمان استفاده شده است. میزان صحت، حساسیت و اختصاصیت برای ۸ سناریو از ۹ سناریوی تعریف شده برابر با ۱۰۰٪ است. علاوه بر این الگوریتم پیشنهادی با روش‌های رایج طبقه‌بندی مقایسه شده و نشان داده شده که نتایج آن در مقایسه با پژوهش‌های پیشین و روش‌های کلاسیک طبقه‌بندی بسیار امیدوار کننده است. با توجه به عمل‌کرد مطلوب الگوریتم پیشنهادی می‌توان از آن برای تشخیص خودکار مراحل مختلف صرعی برای داده‌های حجیم EEG استفاده کرد. پیش‌بینی می‌شود که استفاده از الگوریتم پیشنهادی سبب کاهش حجم کار پزشکان و افزایش صحت در تشخیص مراحل مختلف صرعی خواهد شد.

۶- مراجع

- [1] T. Alotaiby, F. E. A. El-Samie, S. A. Alshebeili, and I. Ahmad, "A review of channel selection algorithms for EEG signal processing," *EURASIP Journal on Advances in Signal Processing*, vol. 2015, no. 1, p. 66, 2015.

^۱ Graphics Processing Unit (GPU)

- [23] Y. Park, L. Luo, K. K. Parhi, and T. Netoff, "Seizure prediction with spectral power of EEG using cost-sensitive support vector machines," *Epilepsia*, vol. 52, no. 10, pp. 1761-1770, 2011.
- [24] U. R. Acharya, S. L. Oh, Y. Hagiwara, J. H. Tan, and H. Adeli, "Deep convolutional neural network for the automated detection and diagnosis of seizure using EEG signals," *Computers in biology and medicine*, vol. 100, pp. 270-278, 2018.
- [25] T. F. Bastos-Filho, A. Ferreira, A. C. Atencio, S. Arjunan, and D. Kumar, "Evaluation of feature extraction techniques in emotional state recognition," in *Intelligent human computer interaction (IHCI), 2012 4th international conference on*, 2012, pp. 1-6: IEEE.
- [26] S. Mallat and Z. Zhang, "Matching pursuit with time-frequency dictionaries," *Courant Institute of Mathematical Sciences New York United States* 1993.
- [27] Naderahmadian, Yashar, Soosan Beheshti, and Mohammad Ali Tinati. "Correlation based online dictionary learning algorithm." *IEEE Transactions on signal processing* 64.3 (2016): 592-602.
- [28] Z. Mousavi, T. Yousefi Rezaii, S. Sheykhivand, A. Farzamnia, and S. N. Razavi. "Deep convolutional neural network for classification of sleep stages from single-channel EEG signals." *Journal of neuroscience methods* 324 (2019): 108312.
- [17] L. Guo, D. Rivero, J. Dorado, J. R. Rabunal, and A. J. J. o. n. m. Pazos, "Automatic epileptic seizure detection in EEGs based on line length feature and artificial neural networks," vol. 191, no. 1, pp. 101-109, 2010.
- [18] P. Swami, T. K. Gandhi, B. K. Panigrahi, M. Tripathi, and S. J. E. S. w. A. Anand, "A novel robust diagnostic model to detect seizures in electroencephalography," vol. 56, pp. 116-130, 2016.
- [19] A. R. Hassan, S. Siuly, Y. J. C. m. Zhang, and p. i. biomedicine, "Epileptic seizure detection in EEG signals using tunable-Q factor wavelet transform and bootstrap aggregating," vol. 137, pp. 247-259, 2016.
- [20] M. Sharma, R. B. Pachori, and U. R. Acharya, "A new approach to characterize epileptic seizures using analytic time-frequency flexible wavelet transform and fractal dimension," *Pattern Recognition Letters*, vol. 94, pp. 172-179, 2017.
- [21] X. Pang, "Seizure forecasting," Stanford University, Autumn 2014.
- [22] N. D. Truong, A. D. Nguyen, L. Kuhlmann, M. R. Bonyadi, J. Yang, and O. Kavehei, "A Generalised Seizure Prediction with Convolutional Neural Networks for Intracranial and Scalp Electroencephalogram Data Analysis," *arXiv preprint arXiv:1707.01976*, 2017.