



# Investigating the specific spectral features of obsessive-compulsive disorder in quantitative electroencephalography

Amirreza Farokhzadi<sup>1,2</sup> , Hadi Motamedi<sup>1,2</sup>, Ali Shahbazi<sup>2\*</sup> , Mohammad Ghadirivasfi<sup>3</sup>, Mohammad Ali Nazari<sup>3</sup>

1. Student Research Committee, Faculty of Advanced Technologies in Medicine, Iran University of Medical Sciences (IUMS), Tehran, Iran

2. Department of Neuroscience, Faculty of Advanced Technologies in Medicine, Iran University of Medical Sciences (IUMS), Tehran, Iran

3. Research Center for Addiction and Risky Behaviors (ReCARB), Medical Faculty, Iran University of Medical Sciences (IUMS), Tehran, Iran

## Abstract

**Received:** 23 May, 2023

**Revised:** 17 Jul, 2023

**Accepted:** 15 Aug, 2023

### Keywords


Obsessive-compulsive disorder  
Spectral features  
Quantitative electroencephalography

### Corresponding author

Ali Shahbazi, Department of Neuroscience, Faculty of Advanced Technologies in Medicine, Iran University of Medical Sciences (IUMS), Tehran, Iran

**Email:** Shahbazi.a@iums.ac.ir



 doi.org/10.30514/icss.25.2.119

**Introduction:** Obsessive-compulsive disorder (OCD) is a debilitating mental illness with symptoms typically manifesting during childhood and adolescence. Quantitative electroencephalography (QEEG) is a favored brain mapping technique for investigating psychiatric disorders due to its accessibility and ease of use. Spectral features of QEEG, particularly differences in neural activity across frequency bands and brain regions, may underlie certain diseases. This study investigates the performance of a machine learning algorithm using spectral features as input to provide insight into the neural activities associated with OCD.

**Methods:** This analytical cross-sectional study obtained EEG signals from both healthy controls and OCD patients in a closed-eyes condition using a 21-channel cap. After noise removal via independent component analysis (ICA), features were calculated, augmented by 1-minute EEG segmentation, and used as input for the machine learning algorithm. Statistical tests were used to compare features between groups.

**Results:** The study included 42 participants, 27 OCD patients, and 14 healthy controls. All features followed a non-normal distribution. The Mann-Whitney test revealed no significant differences between groups for all features ( $P > 0.05$ ) except for frontal beta ( $P < 0.002$ ). The machine learning algorithm achieved an accuracy of 82.1% using 10-fold cross-validation, with a sensitivity of 83.3% and specificity of 80.0%. The false discovery rate (FDR) was 11.8%.

**Conclusion:** In the studied population, no significant differences were found between OCD patients and healthy controls for any of the investigated features except for the frontal beta feature. However, the machine learning algorithm accurately detected 82.1% of patients, comparable to the performance of other features and imaging methods reported in previous studies.

**Citation:** Farokhzadi A, Motamedi H, Shahbazi A, Ghadirivasfi M, Nazari MA. Investigating the specific spectral features of obsessive-compulsive disorder in quantitative electroencephalography. *Advances in Cognitive Sciences*. 2023;25(2):119-132.

## Extended Abstract

### Introduction

Obsessive-compulsive disorder (OCD) is a debilitating mental illness that often manifests in childhood and adolescence. It is among the top ten causes of “life with disability” and has a significant impact on society. The glob-

al lifetime prevalence of OCD is 2-3%, with a 12-month prevalence of up to 1%. In Iran, the prevalence of OCD in children and adolescents is estimated at about 10%. Moreover, The COVID pandemic has led to an increase

in obsessive symptoms (intrusive thoughts or images, compulsive behaviors, or both) and psychiatric referrals. Despite advances in understanding the neurophysiological processes of OCD, diagnosis remains primarily clinical. Quantitative electroencephalography (QEEG) has become a popular brain mapping technique for examining psychiatric diseases due to its ease of use and accessibility. On the other hand, machine learning methods have been applied to electroencephalography (EEG) and functional magnetic resonance imaging (fMRI) data to improve diagnosis. These techniques have the potential to advance diagnostic methods, treatment, and measurement of response to treatment. In particular, using QEEG spectral features as input for machine learning algorithms such as TREE can provide valuable information about neural activities involved in OCD. This study evaluated algorithm performance using widely recognized spectral features associated with OCD based on past research as input data.

## Methods

This cross-sectional analytical study examined a population of 42 individuals, comprising a combination of patients and healthy individuals with at least 40% patient dispersion. Patients were diagnosed based on the Yale-Brown questionnaire and confirmed by a psychiatrist in one visit for evaluation of neurocognitive disorders and entry criteria. Besides, healthy individuals were confirmed in terms of psychiatric issues and entered the study as the healthy group in one visit. The patients were referred to the Brain and Cognition Clinic, and their written consent was obtained upon entering the study.

EEG signals were obtained from patients and healthy individuals in resting state with eyes closed. This method was performed using a 21-channel cap. The cap's sensors were placed according to the 10-20 electrode placement standard. These signals were sampled at a frequency of 625 Hz and bandpass filtered between 0.5 Hz and 70 Hz.

In the first stage, common noise and artifacts related to facial movements present in the signals were removed using preprocessing methods. For this purpose, the MATLAB Field Trip toolbox was used. Furthermore, the ICA (Independent Component Analysis) algorithm was used for artifact removal using MATLAB EEG Lab toolbox by manual inspection of the components in time and frequency domains. At this stage, an EEG recording was divided into 1-minute segments to produce additional samples and enhance the dataset's diversity that is needed for the machine learning training.

In this study, based on findings from Prichep et al.'s study (11) and other main references (23), six features, including relative power in the theta band for bipolar central and temporal derivations, relative power in the theta band for monopolar frontal derivations, relative power in the alpha band for bipolar central and temporal derivations and the relative power in the beta band for frontal, and central and occipital derivations were calculated. Their medians were compared between patients and healthy individuals using the Mann-Whitney U test.

A nonlinear machine learning algorithm was used as a classifier, and the model hyperparameters were optimized using a Bayesian optimizer. The model cost was also modified to compensate for data imbalance using relative cost sensitivity. Finally, 10-fold cross-validation was used to evaluate the classification performance of the proposed method. Evaluation metrics used in this study were accuracy (AC), sensitivity (SE), specificity (SP), and false discovery rate (FDR).

## Results

This study included a total of 42 individuals, of which 27 were labeled as patients (cases) and 14 were labeled as healthy (controls). Three patients were excluded from the demographic analysis due to needing more consent, demographic information, and outlier removal. Among the

24 obsessive-compulsive patients in the patient group, 15 were female, and nine were male. The youngest individual was a 15-year-old woman, and the oldest was a 56-year-old woman. The average age of the control group was 30 years.

In order to compare the performance of the machine learning algorithm with other common statistical methods for group comparison, feature distributions were examined and compared between the two groups. The normality of the distribution of the extracted features was assessed using the Kolmogorov-Smirnov test. The results indicated that all of the features under examination exhibited a non-normal distribution, with p-values for all six features being less than 0.001.

After removing outliers for comparison between two independent groups with non-normal distribution, the Mann-Whitney (Wilcoxon) non-parametric test was used. The obtained results showed that only the fourth feature was significantly different between the healthy and patient groups ( $P=0.002$ ), but none of the first ( $P=0.692$ ), second ( $P=0.643$ ), third ( $P=0.406$ ), fifth ( $P=0.062$ ), sixth ( $P=0.057$ ) extracted features had significant difference between the two.

A total of 42 EEG signal recordings obtained for a duration of 4 minutes each were divided into 1-minute sections with similar labels, and eventually, the number of data reached 168 cases. Indicatively, 1-min slicing led to better results for the proposed method compared with other slicing times.

The proposed method achieved a sensitivity of 83.3% and a specificity of 80.0%. An accuracy of 82.1% was obtained with cross-validation of 10 folds using the algorithm. The false discovery rate (FDR) was found to be 11.8%.

## Conclusion

Quantitative electroencephalography (QEEG) is a non-invasive imaging technique that has been widely used to

diagnose and evaluate treatment responses in patients with OCD using spectral findings. This study aimed to evaluate the performance of the machine learning algorithm in differentiating patients with OCD from healthy individuals based on these spectral parameters. The performance of this algorithm was compared with common statistical methods (Wilcoxon and Mann-Whitney). The results showed that the nonlinear machine learning algorithm achieved an accuracy of 82.1%, sensitivity of 83.3%, specificity of 80.0%, and false discovery rate of 11.8% in differentiating between the healthy and patient groups.

Some suggestions for performance improvement of the machine learning algorithm in this study are presented. One possible improvement could be achieved by artifact removal from the prefrontal cortex using the ICA method, removing features such as eye blinking or muscle activity. Another improvement could be achieved by taking into account the generalizability factors between studies, such as differences in study populations, cultural, religious, and linguistic differences, and even differences in data recording methods. Lastly, keynotes such as the small sample size, the 10-fold cross-validation performed, and the hyperparameters of the selected machine learning algorithm are possible areas for improvement in this study. In addition, they could bring about a plausible performance of spectral features and their use in differentiating between patients with OCD and healthy individuals in the guidelines.

## Ethical Considerations

### Compliance with ethical guidelines

The studies involving human participants were reviewed and approved by the Ethics Committee of Iran University of Medical Sciences (IR.IUMS.FMD.REC.1401.451). Ethical considerations for participants in this study included obtaining written consent and respecting the prin-

ciple of confidentiality. The principle of confidentiality was respected by coding and removing names from questionnaires to protect participants' privacy. Additionally, all participants were provided with sufficient information about the research procedures to enable them to make an informed decision about their participation.

#### Authors' contributions

The study was designed and prepared by all five authors; data collection, data analysis, and preparation of the text of the article were conducted by the first two authors; the third author was responsible for the supervision and final review of the work as the corresponding author; the fourth and fifth authors were responsible for technical and scientific assistance during the data acquisition and

analysis respectively.

#### Funding

This research was conducted with the funding support of the Cognitive Sciences and Technologies Council (tracking code 10976) and Iran University of Medical Sciences (research code: 22171)

#### Acknowledgments

The authors want to thank the Brain and Cognition Clinic for providing the types of equipment and Doctor Mohammadreza Shalbfan for case evaluation and referral.

#### Conflict of interest

The authors declared no potential conflict of interest.



## بررسی ویژگی‌های طیفی مرتبط با اختلال وسواسی-جبری در الکتروانسفالوگرافی کمی

امیررضا فرخزادی<sup>۱</sup>، هادی معتمدی<sup>۲</sup>، علی شهبازی<sup>۳\*</sup>، محمد قدیری<sup>۲</sup>، محمدعلی نظری<sup>۲</sup>

۱. کمیته تحقیقات دانشجویی، دانشکده فناوری‌های نوین، دانشگاه علوم پزشکی ایران، تهران، ایران
۲. گروه علوم اعصاب، دانشکده فناوری‌های نوین پزشکی، دانشگاه علوم پزشکی ایران، تهران، ایران
۳. مرکز تحقیقات اعتیاد و رفتارهای پرخطر، دانشکده پزشکی، دانشگاه علوم پزشکی ایران، تهران، ایران

## چکیده

**مقدمه:** از میان تکنیک‌های نقشه‌برداری مغزی، الکتروانسفالوگرافی کمی با کاربری آسان‌تر جهت بررسی اختلالات روان‌پزشکی از جمله اختلال وسواسی-جبری مورد اقبال واقع شده است. ویژگی‌های طیفی، نمایان‌گر توزیع قدرت سیگنال در باندهای فرکانسی مختلف سیگنال الکتروانسفالوگرافی کمی می‌باشند و می‌توانند تفاوت فعالیت عصبی نواحی مختلف را که شاید زمینه‌ساز بیماری باشند مشخص کنند. در این مطالعه با استفاده از ویژگی‌های طیفی دخیل در اختلال وسواسی-جبری که بر اساس مطالعات گذشته شناخته شده است را بررسی کرده و به عنوان ورودی داده‌ها به عملکرد الگوریتم پیشنهادی عملکرد بررسی کردیم.

**روش کار:** این مطالعه یک مطالعه مقطعی-تحلیلی بود. سیگنال‌های الکتروانسفالوگرافی در حالت استراحت از افراد دارای اختلال و سالم در شرایط چشم بسته به دست آمد. این روش با استفاده از کلاهی ۲۱ کاناله انجام شد. پس از حذف نویز با روش ICA ویژگی‌های طیفی محاسبه و پس از افزایش داده‌ها از طریق تقسیم الکتروانسفالوگرام به سیگنال‌های یک دقیقه‌ای، به عنوان ورودی ماشین یادگیری استفاده شد. همچنین با استفاده از آزمون‌های آماری این ویژگی‌ها بین دو گروه سالم و افراد دارای اختلال مقایسه شد.

**یافته‌ها:** ۴۲ فرد وارد مطالعه شدند که ۲۷ نفر دارای اختلال و ۱۴ نفر سالم بودند. مشخص شد که هیچ یک از ویژگی‌های استخراج شده بین دو گروه اختلاف معناداری نداشتند. حساسیت ارایه شده توسط الگوریتم یادگیری ماشین ۸۳/۳ درصد، اختصاصیت ۸۰ درصد، دقت ۸۲/۱ درصد و نرخ نسبت یافتن غلط (FDR) ۱۱/۷ درصد به دست آمد.

**نتیجه‌گیری:** برخلاف مطالعات قبل اغلب ویژگی‌های طیفی بجز یک مورد (بتای ناحیه پیشانی) اختلاف معناداری نداشتند. الگوریتم یادگیری ماشین با دقت ۸۲/۱ درصد توانست افراد مبتلا را تشخیص دهد. این عملکرد قابل قبول و مشابه عملکرد دیگر الگوریتم‌ها با ویژگی‌های غیرطیفی و روش‌های تصویربرداری دیگر بود.

دریافت: ۱۴۰۲/۰۳/۰۲

اصلاح نهایی: ۱۴۰۲/۰۴/۲۶

پذیرش: ۱۴۰۲/۰۵/۲۴

## واژه‌های کلیدی

اختلال وسواسی-جبری  
ویژگی‌های طیفی  
الکتروانسفالوگرافی

## نویسنده مسئول

علی شهبازی، گروه علوم اعصاب، دانشکده فناوری‌های نوین پزشکی، دانشگاه علوم پزشکی ایران، تهران، ایران

ایمیل: Shahbazi.a@iums.ac.ir



doi:10.30514/iess.25.2.119

## مقدمه

شده است (۳، ۴). در ایران نیز شیوع این اختلال در جمعیت کودک و نوجوانان حدود ۱۰ درصد برآورد شده است (۵). علاوه بر این، ظهور پاندمی کووید باعث افزایش بروز علائم وسواسی و افزایش مراجعات روان‌پزشکی شده است (۶).

علائم بالینی این اختلال به صورت ظهور افکار یا تصاویر سرزده، رفتارهای جبری یا هر دو آنها می‌باشد. افکار وسواسی، افکاری ناخواسته

اختلال وسواسی-جبری (OCD) -compulsive disorder) یک اختلال اغلب ناتوان‌کننده روانی می‌باشد که علائم آن معمولاً از دوران کودکی و نوجوانی خود را نشان می‌دهند (۱). قرار گرفتن این اختلال در ۱۰ علت اول "زندگی با ناتوانی"، نشان‌دهنده بار مهم آن بر جامعه است (۲). شیوع مادام‌العمر جهانی اختلال وسواسی-جبری ۲ تا ۳ درصد و شیوع ۱۲ ماهه آن تا ۱ درصد گزارش



روش‌های موثرتر انتخاب ویژگی عملکرد الگوریتم‌ها بهبود پیدا می‌کند. یکی از الگوریتم‌های مورد استفاده یادگیری ماشین الگوریتم درخت (TREE machine learning algorithm) است که یک الگوریتم تحت نظارت خطی و برای طبقه‌بندی داده‌ها می‌باشد. در مطالعاتی الگوریتم SVM توانسته در تشخیص افراد OCD با استفاده از داده‌های EEG آنها موثر واقع شود؛ در یک مطالعه از مقیاس‌های وابستگی نیمکره‌ای و پیچیدگی‌های سیگنال برای تشخیص افراد OCD استفاده شده و در مطالعات دیگر توصیه به استفاده این روش در داده‌های EEG برای افراد OCD شده است (۲۰-۱۸).

در حال حاضر تشخیص این اختلال به صورت کاملاً بالینی می‌باشد و علائم بالینی متغیر باعث پیچیده شدن روند مطالعه نوروبیولوژی زمینهای، تعیین بیومارکرهای تشخیصی و توسعه درمان‌های نوین در OCD شده است (۲۳). استفاده از ویژگی‌های طیفی به عنوان ورودی الگوریتم یادگیری ماشین TREE و بررسی ویژگی‌های مهم با استفاده از انتخاب ویژگی‌ها می‌تواند اطلاعات ارزشمندی از فعالیت‌های عصبی دخیل در OCD به ما ارائه کند. در این مطالعه با استفاده از معروف‌ترین ویژگی‌های طیفی دخیل در OCD بر اساس مطالعات گذشته به عنوان ورودی داده‌ها عملکرد الگوریتم پیشنهادی عملکرد بررسی کردیم.

## روش کار

### نمونه‌ها

این مطالعه یک مطالعه مقطعی-تحلیلی بود. نمونه‌ها جمعیتی ۴۲ نفره شامل ترکیبی از افراد دارای اختلال و سالم با شرط حداقل ۴۰ درصد پراکندگی افراد دارای اختلال بود. افراد دارای اختلال بر اساس پرسشنامه Yale-Brown (نمره بیشتر یا مساوی ۹) تشخیص داده شده و با تایید روان‌پزشک در یک نوبت ویزیت جهت بررسی از لحاظ مسائل عصب‌شناختی (Neurocognitive Disorders) و داشتن معیارهای ورود انتخاب شدند. این افراد از مراجعه‌کنندگان به کلینیک مغز و شناخت بودند؛ افراد سالم از نظر مسائل روان‌پزشکی تایید شده و توسط متخصص روان‌پزشک در یک نوبت ویزیت، به عنوان گروه سالم وارد مطالعه شدند. از تمام افراد در بدو ورود به مطالعه رضایت‌نامه کتبی گرفته شد و هیچ‌گونه مداخله درمانی در قالب پژوهش در گروه مورد انجام نشد.

### ثبت داده

نمونه‌ها در یک فضای راحت از نظر میزان نور، صدا و دما نشستند. سیگنال‌های EEG در حالت استراحت از افراد دارای اختلال و سالم در شرایط چشم بسته به دست آمد. این روش با استفاده از

و سرزده می‌باشند که تکراری و مداوم هستند و جبر (وسواس عملی) به معنای رفتارهای تکراری، اعمال ذهنی یا تشریفات سخت‌گیرانه‌ای می‌باشند که فرد در واکنش به افکار وسواسی انجام می‌دهد (۷).

اگرچه ما از شناخت کامل فرآیند نوروفیزیولوژی اختلال وسواسی-جبری دور می‌باشیم اما به لطف مطالعات نوروبیولوژیکال زیادی که صورت گرفته است، مدارهای عصبی دخیل در این اختلال تا حدود زیادی شناخته شده می‌باشد. این به نحوی است که می‌توان ادعا کرد در میان اختلالات روان‌پزشکی، اختلال وسواسی-جبری یکی از موفق‌ترین‌ها در مطالعات مدار عصبی بوده است (۸). شناخت مسیرهای عصبی که شامل نواحی مختلف مغز از جمله قشر اوربیتوفرونتال، مناطقی از پری‌فرونتال و مدارهایی شامل مدارهای کورتیکو-استریاتال-تالاموس-قشری (Cortico-Striatal-Thalamic-Cortical) است اغلب از طریق مطالعات تصویربرداری مغزی به دست آمده است؛ به طور مثال در مطالعه‌ای، افزایش فعالیت قشر اوربیتوفرونتال و هسته کودیت در همراهی با تشدید علائم وسواس مشاهده شده است و نیز با درمان موفق، کاهش داشته است (۹). این موضوع می‌تواند نشان‌دهنده پتانسیل بالای تکنیک‌های نقشه‌برداری مغز جهت پیشرفت روش‌های تشخیصی، درمان و اندازه‌گیری پاسخ به درمان باشد (۱۰).

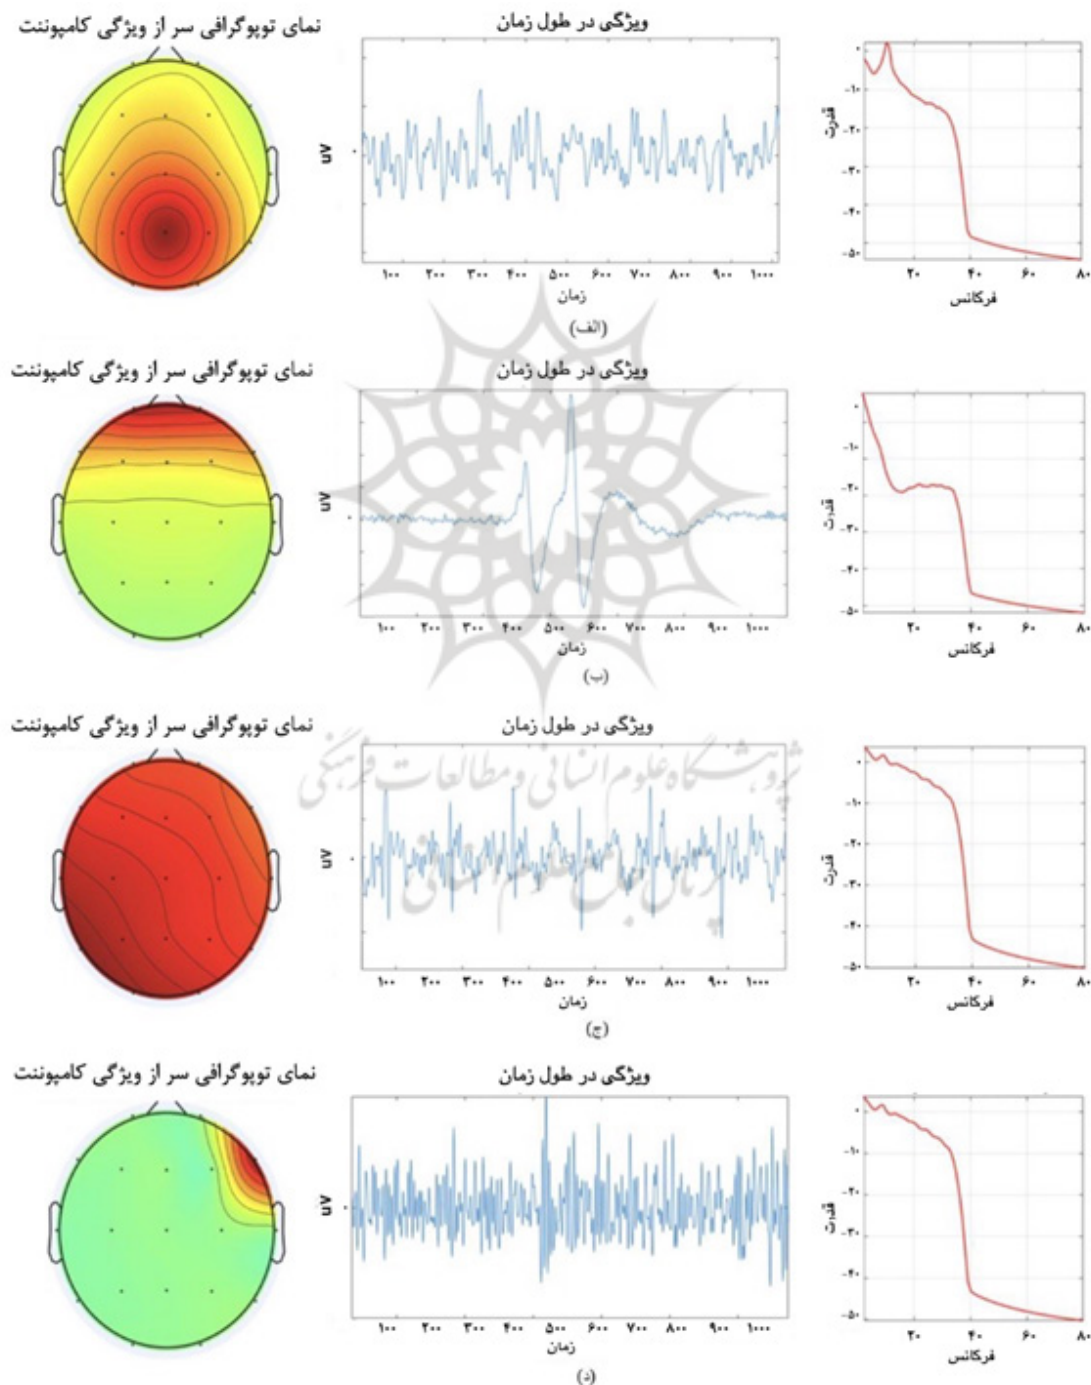
از میان تکنیک‌های نقشه‌برداری مغزی، الکتروانسفالوگرافی کمی به علت کاربری و دسترسی آسان‌تر جهت بررسی اختلالات روان‌پزشکی مورد اقبال واقع شده است. مطالعات نشان‌دهنده امکان استفاده از این روش در تشخیص اختلال وسواسی-جبری نیز بوده است (۱۱). ویژگی‌های طیفی نمایان‌گر توزیع قدرت سیگنال در باندهای فرکانسی مختلف سیگنال EEG می‌باشند و می‌توانند تفاوت فعالیت عصبی نواحی مختلف را که شاید زمینه‌ساز بیماری باشند مشخص کنند. در مطالعات انجام شده توسط Prichep و همکارانش طی سال‌های ۱۹۹۳ تا ۲۰۰۷ بر تشخیص، طبقه‌بندی و ارزیابی پاسخ به درمان در افراد مبتلا به اختلال وسواسی-جبری ویژگی‌های طیفی نقش کلیدی در اجرای ارزیابی‌ها بوده‌اند (۱۵-۱۱).

استفاده از روش یادگیری ماشین در تشخیص این اختلال با داده‌های تصویربرداری عملکردی مغناطیسی مغز (fMRI) و الکتروانسفالوگرافی (EEG) در سال‌های اخیر گسترش یافته است (۱۶، ۱۷). مزیت این روش بر روش‌های قبلی استفاده از کل داده ثبت شده از جمله اطلاعات مربوط به پردازش شبکه ارتباطات بین نواحی، می‌باشد. انتخاب ویژگی مرحله مهمی از یادگیری ماشینی است که طی آن ویژگی‌های مطلوب و مهمتر برای ماشین انتخاب می‌شوند. این امر در مطالعات بالینی که داده‌های کمتری وجود دارد اهمیت دوچندان پیدا می‌کند. با استفاده از

## پیش‌پردازش سیگنال

در مرحله اول، نویزهای معمولی و مخدوش‌گر مربوط به حرکات صورت موجود در سیگنال‌ها با استفاده از روش پیش‌پردازش کاهش یافتند. برای این منظور از ابزار FieldTrip برای پردازش اولیه و روش ((Independent Component Analysis (ICA) برای کاهش نویزها مخدوش‌گر استفاده شد. شکل ۱ نمونه‌ای از آنالیز ICA و چند نمونه از نمای اجزای مخدوش‌گر شامل پلک زدن، فعالیت قلبی و حرکات عضلانی می‌باشد.

۲۱ کاناله انجام شد. سنسورهای کلاهیک مطابق با استاندارد قرار دادن الکتروود ۱۰-۲۰ قرار گرفتند. به عبارت دیگر، سیگنال‌های EEG از مناطق فرونتال (Fz, F۸, F۷, F۴, F۳, Fp۲, Fp۱)، گیجگاهی (T۳)، T۴، T۵، T۶)، پاریتال (Pz, P۴, P۳)، پس‌سری (O۲, O۱)، مرکزی (Cz, C۴, C۳) و دو عضله ماستر (M۲, M۱) به عنوان رفرنس ثبت شد. این سیگنال‌ها با فرکانس ۶۲۵ هرتز نمونه‌برداری شده و با باند ۰/۵ هرتز تا ۷۰ هرتز فیلتر شدند.



شکل ۱. نمای توپوگرافی، سری زمانی و طیف توان موج حاصل از اجزای خروجی ICA. (الف) نمونه‌ای از جز مربوط به فعالیت مغزی، (ب) نمونه‌ای از جز مربوط به پلک زدن، (ج) نمونه‌ای از جز مربوط به فعالیت قلبی، (د) نمونه‌ای از جز مربوط به فعالیت عضلانی.

## افزایش داده‌ها

در برنامه‌های یادگیری ماشین، از تقویت داده‌ها برای افزایش تعداد نمونه‌ها بدون جمع‌آوری نمونه‌های جدید استفاده می‌شود. افزایش داده‌های سری زمانی معمولی بر اساس تقسیم سیگنال است که یک سیگنال را به بخش‌های کوچک‌تر با طول مساوی و برچسب‌های یکسان تقسیم می‌کنند. در این مطالعه، هر نمونه EEG به برش‌هایی با طول ۱ دقیقه تقسیم شد تا نمونه‌های جدید تولید شود و تنوع مجموعه داده افزایش یابد. شایان ذکر است که برش ۱ دقیقه‌ای منجر به نتایج بهتری برای روش پیشنهادی در مقایسه با زمان‌های دیگر برش شد. پس از انجام این روش افزایش داده، یک مجموعه داده EEG از افراد با نمونه‌های بیشتر به دست آمد که شامل ۱۰۸ نمونه مورد و ۵۶ نمونه سالم بود.

## استخراج ویژگی

در این مطالعه، بر اساس یافته‌های مطالعه Prichep و همکاران (۱۱) سه ویژگی شامل موارد زیر محاسبه شد:

۱- توان نسبی بازه فرکانسی تتا برای لیدهای قرینه مرکزی و گیجگاهی (ویژگی اول)

۲- توان نسبی بازه فرکانسی تتا برای لیدهای پیشانی (ویژگی دوم)

۳- توان نسبی بازه فرکانسی آلفا برای لیدهای قرینه مرکزی و گیجگاهی (ویژگی سوم)

همچنین با توجه به استفاده گسترده و مطالعات قبلی در تفسیرهای بالینی در اضطراب و اختلال وسواس-جبری، توان نسبی بازه فرکانسی بتا برای لیدهای پیشانی (ویژگی چهارم)، مرکزی (ویژگی پنجم) و پس‌سری (ویژگی ششم) محاسبه و به عنوان ورودی به الگوریتم ماشین استفاده گردید (۲۳).

## طبقه‌بندی بر اساس الگوریتم پیشنهادی

طبقه‌بندی بخشی اساسی از شناسایی خودکار الگوها در بسیاری از مسائل تشخیص الگوی آماری است. در مطالعه حاضر، طبقه‌بندی‌کننده‌های مختلفی مانند الگوریتم درخت (TREE) برای یادگیری ماشین استفاده شد. لازم به ذکر است که ابرپارامترهای مدل‌های طبقه‌بندی با استفاده از بهینه‌ساز بیزین بهینه شدند. همچنین به دلیل عدم همگنی تعداد نمونه‌ها در دو گروه دارای اختلال و سالم، از تابع هزینه (Cost function) اصلاح شده به نسبت تعداد نمونه‌ها برای خنثی کردن این اثر در یادگیری ماشین استفاده گردید. به بیان ساده‌تر، گروهی که تعداد کمتری داشت دارای تابع هزینه بالاتری بود تا خطاهای الگوریتم

متعادل گردد. از این روش به عنوان الگوریتم درخت حساس به هزینه (Cost-sensitive TREE) نیز یاد می‌گردد.

## ارزیابی الگوریتم

در مطالعه حاضر، اعتبارسنجی متقاطع ۱۰ برابری (۱۰ فولدی) برای ارزیابی نسبت عملکرد طبقه‌بندی روش پیشنهادی مورد استفاده قرار گرفت. در این روش، مجموعه داده در ابتدا به ۱۰ فولد تقسیم می‌شود که ۹ تا به طور تصادفی به عنوان یک مجموعه آموزشی استفاده می‌شود و ۱۰ بار تکرار می‌شود تا زمانی که هر فولد به عنوان یک مجموعه تست استفاده شود. در طول هر تکرار، مجموعه تست بر روی مدل آموزش‌دیده اعمال می‌شود که منجر به ۱۰ مقدار معیار ارزیابی مختلف می‌شود. برای بررسی عملکرد طبقه‌بندی کلی، میانگین و انحراف معیار معیارهای ارزیابی در نظر گرفته شد. معیارهای ارزیابی مورد استفاده در این مطالعه، دقت (AC)، حساسیت (SE)، ویژگی (SP) و نرخ کشف نادرست (FDR) بودند. نحوه محاسبه هر یک از پارامترها به صورت زیر می‌باشد.

$$AC = \frac{TP + TN}{TP + FN + TN + FP}$$

$$SE = \frac{TP}{TP + FN}$$

$$SP = \frac{TN}{FP + TN}$$

$$FDR = \frac{FP}{FP + TN}$$

## یافته‌ها

در مجموع ۴۲ فرد وارد مطالعه شده که ۲۷ نفر آنها تحت عنوان دارای اختلال (مورد) و ۱۴ نفر آنها تحت عنوان سالم (کنترل) برچسب‌گذاری شدند. به علت عدم رضایت، عدم دسترسی به اطلاعات جمعیت‌شناختی و حذف داده‌های پرت، ۳ فرد از گروه مورد در آنالیز اطلاعات جمعیت‌شناختی حذف شدند. در بین ۲۴ فرد وسواسی-جبری در گروه مورد، ۱۵ نفر از گروه مورد جنسیت مونث و ۹ نفر از آنها جنسیت مذکر داشتند. جوان‌ترین فرد یک خانم ۱۵ ساله و مسن‌ترین فرد یک خانم ۵۶ ساله بود. میانگین سنی گروه کنترل ۳۰ سال بود. ۹ نفر از افراد دارای اختلال، مورد جدید بدون مصرف دارو درمانی برای اختلال وسواس-جبری و ۱۵ نفر از ۲۷ نفر تحت درمان با داروهای از دسته



تست کولموگروف-اسمیرنوف استفاده شده که نتایج حاصل برای ویژگی اول نتیجه تست غیر نرمال یا  $(P < 0/001)$ ، برای ویژگی دوم نتیجه تست  $(P < 0/001)$  و برای ویژگی سوم نتیجه تست  $(P < 0/001)$  بود. که به این معناست که تمامی ویژگی‌ها از توزیع غیر نرمال تبعیت می‌کردند. این نتایج برای سه ویژگی بعدی نیز همگی  $(P < 0/001)$  بود.

### آزمون مقایسه بین گروهی

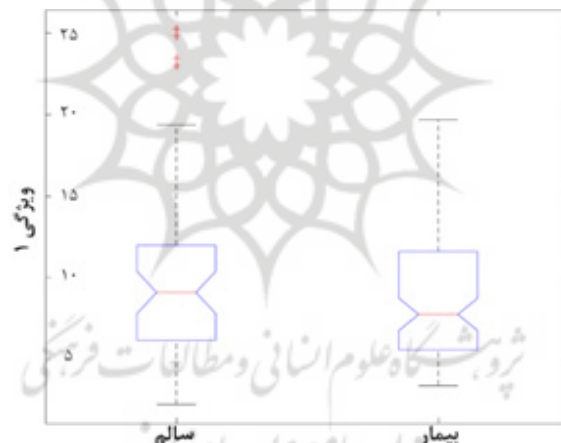
بعد از حذف داده‌های پرت برای مقایسه بین دو گروه مستقل با توزیع غیر نرمال از تست من ویتنی (ویل کاکسون) استفاده شد. نتایج حاصل نشان داد که ویژگی چهارم  $(P = 0/002)$  که نشان‌دهنده توان نسبی بازه فرکانسی بتا برای لیدهای پیشانی است به طور معناداری در بین گروه‌ها متفاوت است اما هیچ یک از ویژگی‌های اول  $(P = 0/692)$ ، دوم  $(P = 0/643)$ ، سوم  $(P = 0/406)$ ، پنجم  $(P = 0/062)$  و ششم  $(P = 0/057)$  استخراج شده بین دو گروه سالم و مورد اختلاف معناداری نداشته‌اند. در ادامه نمودارهای جعبه‌ای این نتایج آورده شده است.

SSRI بودند. اگرچه این افراد از هیچ یک از دسته داروهای باربیتورات، لیتیم، آنتی‌سایکوتیک‌ها و بنزودیازپین را مصرف نمی‌کردند و همچنین افراد مطالعه موادی مانند داروهای مخدر، الکل، سیگار، نیکوتین و محرک‌هایی مانند کافئین را در دو روز قبل از ثبت نوار مصرف نکردند. همه افراد دارای اختلال بر اساس ارزیابی روان‌پزشک دارای علائم فکری و رفتاری این اختلال بودند.


میانگین مقیاس بیل براون که بر اساس پرسشنامه YBOCS محاسبه شده در خانم‌های گروه وسواسی-جبری ۲۰ و همین مقیاس برای آقایان به طور متوسط ۱۷/۴ بود. این مقیاس در خانم‌های گروه کنترل ۳ و همین مقیاس برای آقایان به طور متوسط ۳/۱ بود.

### بررسی نرمالیتی


در این بخش جهت مقایسه عملکرد الگوریتم یادگیری ماشین با سایر روش‌های معمول آماری مقایسه بین دو گروه، ابتدا نرمالیتی توزیع ویژگی‌های محاسبه بررسی و سپس این ویژگی‌ها در دو گروه مقایسه می‌شوند. جهت بررسی نرمالیتی توزیع ویژگی‌های استخراج شده از




شکل ۲. نمودار جعبه‌ای مربوط به ویژگی اول در دو گروه سالم و مورد. در گروه سالم ۴ داده پرت بودند. میانه در گروه سالم ۰۹/۹ و در گروه مورد ۷۴/۷ بود.



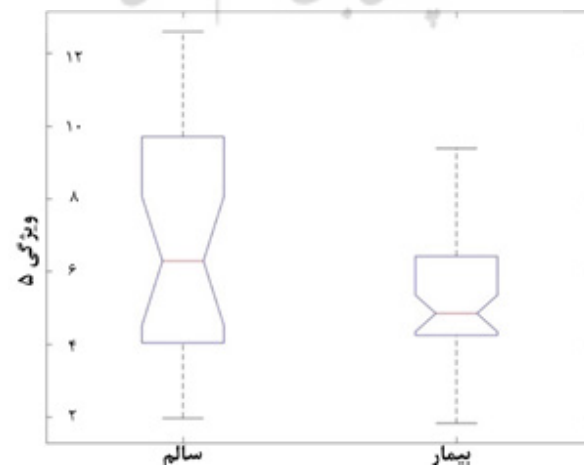
شکل ۳. نمودار جعبه‌ای مربوط به ویژگی دوم در دو گروه سالم و مورد. در گروه سالم یک داده پرت بود که حذف شد. میانه در گروه سالم ۳۳/۵ و در گروه مورد ۲۲/۵ بود.




شکل ۴. نمودار جعبه‌ای مربوط به ویژگی سوم در دو گروه سالم و مورد. در گروه سالم یک داده پرت بود که حذف شد. میانه در گروه سالم ۳۳/۱۹ و در گروه مورد ۴۴/۲۳ بود.



شکل ۵. نمودار جعبه‌ای مربوط به ویژگی چهارم در دو گروه سالم و مورد. در گروه مورد دو داده پرت بود که حذف شد. میانه در گروه سالم ۱۱ و در گروه مورد ۵/۶۶ بود.



شکل ۶. نمودار جعبه‌ای مربوط به ویژگی پنجم در دو گروه سالم و مورد. میانه در گروه سالم ۶/۲۹ و در گروه مورد ۴/۸۵ بود.



شکل ۷. نمودار جعبه‌ای مربوط به ویژگی ششم در دو گروه سالم و مورد. میانه در گروه سالم ۱۲/۸۰ و در گروه مورد ۸/۲۹ بود.

### نتایج حاصل از پیاده‌سازی الگوریتم

در این بخش، عملکرد روش یادگیری ماشینی پیشنهادی برای تشخیص افراد دارای اختلال وسواسی-جبری بر اساس سیگنال‌های EEG از جنبه تأثیر روش افزایش داده‌ها بر چارچوب پیشنهادی و عملکرد الگوریتم ارزیابی می‌شود.

### نتایج حاصل از افزایش داده

در مجموع ۴۲ ثبت سیگنال EEG اخذ شده به مدت ۴ دقیقه هر کدام

به بخش‌های ۱ دقیقه‌ای با برجسب‌های مشابه تقسیم شد و در نهایت، تعداد داده‌ها به ۱۶۸ مورد رسید. تقسیم ۱ دقیقه‌ای منجر به نتایج بهتری برای روش پیشنهادی در مقایسه با زمان‌های دیگر تقسیم سیگنال شد.

### عملکرد الگوریتم

حساسیت آرایه شده ۸۳/۳ درصد بود. اختصاصیت ۸۰ درصد بود. دقت ۸۲/۱ درصد با ارزیابی متقاطع ۱۰ فولدی با الگوریتم TREE به دست آمد. همچنین نرخ نسبت یافتن غلط (FDR) ۱۱/۷ درصد بود.

تعداد حقیقی	۰	۱
۰	۴۸	۱۲
۱	۱۸	۹۰
	تعداد پیش بینی شده	۰

شکل ۸. جدول پیش‌بینی مدل از تعداد موارد مشاهده شده مثبت کاذب (۱۲ عدد)، منفی کاذب (۱۸ عدد)، مثبت حقیقی (۹۰ عدد) و منفی حقیقی (۴۸ عدد) بعد از اجرای الگوریتم

مطالعه ارزیابی الگوریتم یادگیری ماشین TREE در افتراق افراد مورد OCD از افراد سالم بر اساس این پارامترهای طیفی بود. برای انجام این منظور عملکرد این الگوریتم یادگیری ماشین با روش‌های معمول آماری (ویلکاکسون و من‌ویتنی) مقایسه شد. نتایج حاصل نشان داد که الگوریتم هوش مصنوعی با دقت ۸۲/۱ درصد و حساسیت ۸۳/۳ درصد

### بحث

روش الکتروانسفالوگرافی کمی یک تکنیک تصویربرداری غیر تهاجمی است که مطالعات سال‌های گذشته نشان‌دهنده استفاده گسترده از یافته‌های طیفی حاصل شده برای تشخیص و ارزیابی پاسخ به درمان در افراد مبتلا به اختلال وسواسی-جبری بوده است. هدف از انجام این

اطلاعات زیادی در لیدهای EEG قرار می‌دهند.

### عدم تعمیم‌پذیری

از دیگر عوامل تفاوت نتایج این مطالعه و نتایج دیگر مطالعات مخصوصاً در مقایسه آماری ویژگی‌ها، می‌تواند عوامل مربوط به بسط‌پذیری باشد. تفاوت میان جمعیت مطالعه مورد بررسی، تفاوت‌های فرهنگی، مذهبی، زبانی و حتی تفاوت در روش ثبت داده می‌تواند بر عملکرد الگوریتم و ویژگی‌های طیفی تاثیر بگذارد. نتیجه آن می‌تواند تفاوت در ناحیه یا قدرت ویژگی‌های طیفی باشد که در این مطالعه به بررسی آن پرداخته نشده است.

### محدودیت‌های مطالعه

نکاتی همچون کم بودن تعداد نمونه‌ها، نحوه ارزیابی متقابل ۱۰ فولدی انجام شده، نوع الگوریتم انتخاب شده و تنظیم هایپر پارامترهای آن از محدودیت‌های این مطالعه است و می‌تواند علت احتمالی کاهش دقت الگوریتم یادگیری ماشین در این مطالعه باشد. از طرفی به علت تعداد نمونه و انتخاب جامعه آماری محدود، این نتایج قابل تعمیم به جامعه بزرگتر افراد دارای این اختلال نبوده و تفاوت‌های مشاهده شده در این مطالعه با دیگر مطالعاتی که از تحلیل‌های آنها به طور معمول در بالین نیز استفاده می‌شود، حاکی از نیاز به مطالعات بیشتر و دقیق‌تری در این زمینه و در تفسیر الکتروانسفالوگرافی کمی می‌باشد.

### نتیجه‌گیری

برخلاف مطالعات قبل اغلب ویژگی‌های طیفی بجز یک مورد (بتای ناحیه پیشانی) اختلاف معناداری نداشتند. الگوریتم یادگیری ماشین با دقت ۸۲/۱ درصد توانست افراد مبتلا را تشخیص دهد. این عملکرد قابل قبول و مشابه عملکرد دیگر الگوریتم‌ها با ویژگی‌های غیرطیفی و روش‌های تصویربرداری دیگر بود.

### ملاحظات اخلاقی

#### پیروی از اصول اخلاق در پژوهش

از تمام افراد در بدو ورود به مطالعه رضایت‌نامه کتبی گرفته شد. در ابتدای بررسی در رابطه با اختیاری بودن شرکت در پژوهش به همه افراد اطلاع‌رسانی صورت گرفت و همچنین در مورد محرمانه بودن اطلاعات به آنها اطمینان داده شد. هیچ‌گونه مداخله درمانی در قالب پژوهش در افراد مورد اختلال وسواس-جبری انجام نشد. اجازه اطلاع از نتایج و ثبت‌های به عمل آمده به شرکت‌کنندگان توضیح و این نتایج به آنها ارائه شد؛ هیچ هزینه مالی به شرکت‌کنندگان مطالعه تحمیل نشد و تاییدیه اخلاقی از کمیته اخلاق دانشگاه علوم پزشکی ایران

و اختصاصیت ۸۰ درصد و نرخ یافتن غلط ۱۱/۷ درصد توانست با نرخ قابل قبولی تمایز میان گروه سالم از مورد ایجاد کند. این نتایج برخلاف پارامترهای بررسی شده در مطالعه روی John و Prichep (۱۱) بود که در آن نشان داده شده بود که سه ویژگی طیفی مورد بررسی در آن مطالعه عملکرد مناسبی در تفکیک افراد مورد OCD به صورت معناداری داشتند اما در این مطالعه و در جمعیت مورد بررسی، همین ویژگی‌های مطالعه Prichep بر اساس تست‌های غیرپارامتری قدرت تمایز معناداری نداشتند ( $P > 0/1$ ). عملکرد الگوریتم TREE در این مطالعه پایین‌تر از عملکرد مدل ارائه شده در مطالعه Aydin ۲۰۱۵ و همکاران بود که در آن الگوریتم SVM دقت ۸۵ درصد با استفاده از ویژگی‌های آنتروپی و انرژی به دست آورده بود (۱۷). همچنین این ماشین عملکرد قوی‌تری نسبت به مدل Sen و همکاران (۲۱) داشت که در آن با استفاده از ویژگی‌های شبکه‌ای دقت ۸۰ درصد حاصل شده بود. از طرفی دیگر عملکرد این تکنیک تصویربرداری در مقایسه با سایر تکنیک‌های تصویربرداری از جمله fMRI (۱۲) که در مطالعه‌ای در سال ۲۰۱۹ دقت ۷۲ درصد داشت بالاتر بود.

در ادامه این بحث، به چند نکته که می‌تواند باعث افزایش دقت الگوریتم یادگیری ماشین شود، اشاره می‌شود.

### انتخاب ویژگی‌های طیفی

در این مطالعه از ویژگی‌های استخراج شده مشابه مطالعات Prichep (۱۵-۱۲) و دستورالعمل‌های قدیمی‌تر بر اساس نقشه مغزی (۲۳) استفاده شد در حالی که مطالعه مروری اخیر (۲۲) ویژگی‌های دیگری از جمله افزایش موج دلتای سراسری و افزایش الفا در فرونتال چپ را به عنوان ویژگی‌های متفاوت میان افراد سالم و مبتلایان به OCD را معرفی می‌کند.

### حذف فعالیت پلک زدن

یک علت احتمالی افت عملکرد می‌تواند مربوط به حذف فعالیت مخدوش‌گرانه قشر پری‌فرونتال باشد. در این مطالعه با استفاده از روش ICA، ابعاد مخدوش‌گر غیر سیگنالی که از جمله آنها کامپوننت فرونتال مربوط به پلک زدن بود حذف گردید. اما در مطالعات روی John و Prichep از این روش حذف نویز استفاده نشده و احتمال می‌رود یکی از موارد مهم تمییزدهنده افراد OCD از سالم، همین حرکات عضلات و فعالیت نویزی ناشی از پلک زدن باشد (۱۵). به بیان دیگر الگوریتم اهمیتی به ماهیت سیگنال نمی‌دهد و هر عامل تمییزدهنده این دو گروه را مهم تلقی کرده و استفاده می‌کند. این امر و سیگنال‌های پلک حتی در مطالعات ثبت داده با چشم بسته هم مشاهده می‌شود و حرکات مربوط به حرکت چشم و میزان فشار دادن پلک مانند پلک زدن



شناختی با کد پیگیری ۱۰۹۷۶ و دانشگاه علوم پزشکی ایران (کد طرح: ۲۲۱۷۱) انجام گرفته است.

(IR.IUMS.FMD.REC.1401.451) اخذ شد.

### مشارکت نویسندگان

طراحی و آماده‌سازی اجرای مطالعه توسط هر پنج نویسنده صورت گرفت؛ جمع‌آوری، تحلیل داده‌ها و آماده‌سازی متن مقاله توسط دو نویسنده اول و دوم انجام شد؛ نظارت کلی و بررسی نهایی توسط نویسنده مسئول انجام گردید؛ نظارت علمی و همکاری تکنیکال به ترتیب با کمک نویسنده چهارم و پنجم صورت گرفت.

### تشکر و قدردانی

مقاله حاضر برگرفته از پایان‌نامه مشترک دکتری نویسنده نخست و دوم پژوهش در دانشگاه علوم پزشکی ایران می‌باشد. نویسندگان از کلینیک مغز و شناخت برای فراهم کردن تجهیزات و محمدرضا شالبافان برای ارزیابی شرکت‌کنندگان مطالعه و ارجاع افراد OCD تشکر می‌کنند.

### منابع مالی

این پژوهش با حمایت مالی ستاد راهبری توسعه علوم و فناوری‌های

### تعارض منافع

نویسندگان مقاله حاضر هیچ‌گونه تعارض منافی را گزارش نکرده‌اند.

### References

- Burdick KE, Robinson DG, Malhotra AK, Szeszko PR. Neurocognitive profile analysis in obsessive-compulsive disorder. *Journal of the International Neuropsychological Society*. 2008;14(4):640-645.
- Murray CJL, Lopez AD. The global burden of disease: A comprehensive assessment of mortality and disability from diseases, injuries, and risk factors in 1990 and projected to 2020. Boston, USA:Harvard School of Public Health on behalf of the World Health Organization and the World Bank;1996.
- Voderholzer U, Schlegl S, Kulz AK. Epidemiology and health care situation of obsessive-compulsive disorders. *Der Nervenarzt*. 2011;82:273-280. (Germany)
- Ruscio AM, Stein DJ, Chiu WT, Kessler RC. The epidemiology of obsessive-compulsive disorder in the National Comorbidity Survey Replication. *Molecular Psychiatry*. 2010;15(1):53-63.
- Mohammadi MR, Salmanian M, Hooshyari Z, Shakiba A, Alavi SS, Ahmadi A, et al. Lifetime prevalence, sociodemographic predictors, and comorbidities of oppositional defiant disorder: The National Epidemiology of Iranian Child and Adolescent Psychiatric disorders (IRCAP). *Brazilian Journal of Psychiatry*. 2019;42(2):162-167.
- Sulaimani MF, Bagadood NH. Implication of coronavirus pandemic on obsessive-compulsive-disorder symptoms. *Reviews on Environmental Health*. 2021;36(1):1-8.
- APA. Diagnostic and statistical manual of mental disorders (DSM-5®). 5th ed. Arlington, Virginia, USA:American Psychiatric Association;2013.
- Ducharme S, Dougherty DD, Drevets WC. Neuroimaging and neurocircuitry of obsessive-compulsive disorder and major depressive disorder. In: Camprodon JA, Rauch SL, Greenberg BD, Dougherty DD, editors. *Psychiatric neurotherapeutics*. New York:Springer;2016. pp. 51-77.
- Pittenger C. What does an OCD brain look like? [Internet]. medicine.yale.edu. 2014. Available from: <https://medicine.yale.edu/news-article/what-does-an-ocd-brain-look-like/>
- Kloppel S, Abdulkadir A, Jack Jr CR, Koutsouleris N, Mourao-Miranda J, Vemuri P. Diagnostic neuroimaging across diseases. *Neuroimage*. 2012;61(2):457-463.
- Prichep LS, Mas F, Hollander E, Liebowitz M, John ER, Almas M, et al. Quantitative electroencephalographic subtyping of obsessive-compulsive disorder. *Psychiatry Research: Neuroimaging*. 1993;50(1):25-32.
- Hansen ES, Prichep LS, Bolwig TG, John ER. Quantitative electroencephalography in OCD patients treated with paroxe-

tine. *Clinical Electroencephalography*. 2003;34(2):70-74.

13. John ER, Prichep LS, Winterer G, Herrmann WM, DiMichele F, Halper J, et al. Electrophysiological subtypes of psychotic states. *Acta Psychiatrica Scandinavica*. 2007;116(1):17-35.

14. John ER, Prichep LS, Almas M. Subtyping of psychiatric patients by cluster analysis of QEEG. *Brain Topography*. 1992;4:321-326.

15. John ER, Prichep LS. The relevance of QEEG to the evaluation of behavioral disorders and pharmacological interventions. *Clinical EEG and Neuroscience*. 2006;37(2):135-143.

16. Yang X, Hu X, Tang W, Li B, Yang Y, Gong Q, et al. Multivariate classification of drug-naive obsessive-compulsive disorder patients and healthy controls by applying an SVM to resting-state functional MRI data. *BMC Psychiatry*. 2019;19(1):210.

17. Aydin S, Arica N, Ergul E, Tan O. Classification of obsessive compulsive disorder by EEG complexity and hemispheric dependency measurements. *International Journal of Neural Systems*. 2015;25(03):1550010.

18. Shephard E, Stern ER, van den Heuvel OA, Costa DL, Batistuzzo MC, Godoy PB, et al. Toward a neurocircuit-based taxonomy to guide treatment of obsessive-compulsive disorder.

*Molecular Psychiatry*. 2021;26(9):4583-604.

19. Goodman WK, Storch EA, Sheth SA. Harmonizing the neurobiology and treatment of obsessive-compulsive disorder. *American Journal of Psychiatry*. 2021;178(1):17-29.

20. Denys D, Graat I, Mocking R, de Koning P, Vulink N, Figeet M, et al. Efficacy of deep brain stimulation of the ventral anterior limb of the internal capsule for refractory obsessive-compulsive disorder: A clinical cohort of 70 patients. *American Journal of Psychiatry*. 2020;177(3):265-271.

21. Sen B, Bernstein GA, Xu T, Mueller BA, Schreiner MW, Cullen KR, et al. Classification of obsessive-compulsive disorder from resting-state fMRI. 38th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC); 2016 August 16-20; Orlando, FL, USA; IEEE;2016. pp. 3606-3609.

22. Perera MP, Bailey NW, Herring SE, Fitzgerald PB. Electrophysiology of obsessive compulsive disorder: A systematic review of the electroencephalographic literature. *Journal of Anxiety Disorders*. 2019;62:1-14.

23. Swingle PG. Neurofeedback. In: Swingle PG, editor. Adding neurotherapy to your practice: Clinician's guide to the clinical, Neurofeedback, and Braindriving. Cham, Heidelberg:Springer International Publishing;2015. pp. 103-113.