



Classification of EEG Signals in Two Levels of Normal and Anxious Using Nonlinear Features

Faezeh Daneshmand-Bahman¹, Ateke Goshvarpour^{2*}

¹ Department of Biomedical Engineering, Imam Reza International University, Mashhad, Razavi Khorasan, Iran.

² (Corresponding Author): Department of Biomedical Engineering, Imam Reza International University, Mashhad, Razavi Khorasan, Iran. ateke.goshvarpour@gmail.com

Citation: Daneshmand-Bahman F, Goshvarpour A. Classification of EEG Signals in Two Levels of Normal and Anxious Using Nonlinear Features. *Journal of Cognitive Psychology*. 2021; 9 (3): 54-69. [Persian].

Keywords

Electroencephalography, Anxiety, Nonlinear Features, Feature Selection, Multilayer Perceptron Network

Abstract

Anxiety is a natural reaction of humans to stress that occurs in the face of various factors. Anxiety is considered as a mental illness if it is excessive and uncontrollable in the form of fear and anxiety. Today, clinicians use certain criteria to diagnose anxiety disorders. This analytical-observational study was aimed at automatically classifying the two levels of anxious and normal by analyzing electroencephalogram signals. In this paper, the DASPS database was used, which contains a 14-channel electroencephalogram of 23 people (13 females and 10 males, mean age 30 years) during anxiety. Anxiety was presented in the form of flooding as actual exposure to the feared stimulus. Based on the results of the Self-Assessment Manikin, data were divided into two groups: (1) normal and low anxiety and (2) moderate and high anxiety. Approximate entropy, fractal dimension, and Lyapunov exponents were extracted from all channels as nonlinear properties. Maximum relevance and minimum redundancy were used to select the best feature to apply to the multilayer perceptron network. To evaluate the performance of the algorithm, different network structures were examined in terms of the number of features and neurons as well as different feature dimensions. Maximum accuracy, precision, f1-score, and sensitivity in 20 repetitions in all cases is equal to 100, and with an increasing number of neurons, the average accuracy increases. The best results were obtained for 5 features and 15 neurons, where the mean accuracy, precision, f1-score, and sensitivity for it were 80%, 92.75%, 84.15%, and 80.58%, respectively. The results of this paper indicated the capability of the proposed algorithm to distinguish anxious people from normal ones.

طبقه بندی EEG در دو سطح نرمال و دارای اضطراب با استفاده از ویژگی های غیر خطی

فائزه دانشمند بهمن^۱، عاتکه گشوارپور^۲

۱. دانشجوی کارشناسی ارشد، گروه مهندسی پزشکی، دانشگاه بین المللی امام رضا(ع)، مشهد، ایران.

۲. (نویسنده مسئول) استادیار، گروه مهندسی پزشکی، دانشگاه بین المللی امام رضا (ع)، مشهد، ایران.
ateke.goshvarpour@gmail.com

چکیده

اضطراب واکنش طبیعی انسان ها در برابر فشار روانی است که در رویارویی با عوامل مختلف ایجاد می شود. امروزه، حالت های اضطرابی توسط متخصصان با استفاده از نشانه های اضطراب و با ارائه پرسش هایی تشخیص داده می شود. هدف از این مطالعه تحلیلی-مشاهده ای، طبقه بندی خودکار دو سطح اضطراب و نرمال با تحلیل سیگنال الکتروانسفالوگرام است. در این مقاله، از پایگاه داده DASPS استفاده شد که حاوی الکتروانسفالوگرام ۱۴ کاناله از ۲۳ نفر (۱۳ زن و ۱۰ مرد، میانگین سن ۳۰ سال) در حین ایجاد اضطراب است. تحریک اضطراب به صورت غرقه سازی، مواجهه واقعی با یک محرک ترسناک ارائه شده است. دادگان بر اساس نتایج آزمون خودارزیابی آدمک به دو گروه (۱) نرمال و اضطراب کم و (۲) اضطراب متوسط و زیاد تقسیم بندی شدند. آنتروپی تقریبی، بعد فرکتال و نمای لیپانوف به عنوان ویژگی های غیر خطی از تمام کانال ها استخراج شدند. از حداقل افزونگی حداکثر ارتباط برای انتخاب بهترین ویژگی جهت اعمال به شبکه پرسپترون چند لایه استفاده شد. برای ارزیابی عملکرد الگوریتم، ساختارهای مختلف شبکه از حیث تعداد ویژگی و نورون و همچنین ابعاد مختلف ویژگی بررسی شد. ماکزیمم صحت، دقت، f1-score و حساسیت در ۲۰ بار تکرار در تمامی حالات برابر با ۱۰۰ است و با افزایش تعداد نورون، میانگین صحت افزایش می یابد. بهترین نتایج برای تعداد ۵ ویژگی و ۱۵ نورون بدست آمد که میانگین صحت، دقت، f1-score و حساسیت برای آن به ترتیب ۸۰٪، ۹۲/۷۵٪، ۸۴/۱۵٪ و ۸۰/۵۸٪ بود. نتایج این مقاله نشان دهنده ی توانمندی الگوریتم پیشنهادی برای تشخیص افراد مضطرب از افراد نرمال می باشد.

تاریخ دریافت

۱۴۰۰/۰۳/۱۳

تاریخ پذیرش نهایی

۱۴۰۰/۰۷/۱۰

واژگان کلیدی

الکتروانسفالوگرافی، اضطراب، ویژگی های غیرخطی، انتخاب ویژگی، شبکه پرسپترون چندلایه

مقدمه

اضطراب یک مسئله بهداشت روان (بغدادی^۱ و همکاران، ۲۰۱۹) و از شایعترین اختلالات روان پزشکی است و شامل تغییرات جسمی، روانی و رفتاری است که در رویارویی با تهدید و خطر به طور خودکار رخ می دهد (عیزی و براتی، ۱۳۹۳) و می تواند پیامدهای جسمی بر بدن داشته باشد (بغدادی و همکاران، ۲۰۱۹) و بر بسیاری از جنبه های زندگی افراد مبتلا به آن، تاثیر بگذارد (طاهری و همکاران، ۱۳۹۶). شواهد نشان می دهد اضطراب بیش از حد منجر به تضعیف سیستم ایمنی (بغدادی و همکاران، ۲۰۱۹)، افزایش مرگ و میر، افزایش خطر خودکشی، استفاده مفرط از خدمات مراقبت سلامت و اختلال عملکرد می شود و با سایر اختلالات روان مانند اسکیزوفرنی، افسردگی، سوء مصرف مواد و بیماریهای جسمی همراه می باشد. علاوه بر بیماریهای روانی نام برده شده که از اضطراب ناشی می شوند ممکن است اضطراب تاثیر بر وضعیت جسمانی هم داشته باشد و احتمال ابتلا به پارکینسون، آلزایمر و میزان مرگ و میر به علل قلبی- عروقی و پرفشاری خون را افزایش دهد (عیزی و براتی، ۱۳۹۳). در نتیجه اختلال اضطراب اختلالی شایع و ناتوان کننده و همچنین هزینه بر در بین اختلالات روانی محسوب می شود (طاهری و همکاران، ۱۳۹۶).

در ایالات متحده آمریکا سالانه بیش از ۴۰ میلیون نفر به این اختلال مبتلا می شوند و از هر چهار نفر، یک نفر با آن درگیر است. آمار هشداردهنده ی اضطراب، بیانگر شیوع این اختلال در سطح جهان می باشد بطوری که قرن بیستم عصر اضطراب نامیده شده است، این در حالی است که تنها یک سوم افرادی که اضطراب دارند تحت درمان قرار گرفته اند (عیزی و براتی، ۱۳۹۳). تشخیص به موقع و درمان این اختلال در جلوگیری از عوارض بعدی از جمله تأثیرات منفی بر افراد از اهمیت بالایی برخوردار است. معمولاً، تشخیص اضطراب با استفاده از مصاحبه تشخیصی و پرسش نامه خود گزارشی انجام می شود که استفاده از هر یک از این ابزارها برای اهداف پژوهشی و درمانی به تنهایی کافی نیستند و نتایج قابل اطمینانی ندارند (موسوی و همکاران، ۱۳۸۷). برای کاهش این مشکل، چندین مطالعه سعی در حل این مشکل با استفاده

از تحلیل الکتروانسفالوگرام (EEG) برای تشخیص اضطراب داشتند (لی^۲ و همکاران، ۲۰۱۹؛ جاناناکاکیس^۳ و همکاران، ۲۰۱۵؛ ترامبایولی^۴ و بیازولی^۵، ۲۰۲۰؛ پاسکالیس^۶ و همکاران، ۲۰۲۰؛ لیو^۷ و همکاران، ۲۰۱۹؛ شی^۸ و همکاران، ۲۰۲۰). EEG یک روش غیر تهاجمی برای ثبت فعالیت الکتروفیزیولوژیک مغز است (لی و همکاران، ۲۰۱۹). EEG را می توان به پنج باند $\delta(0 - 3/5 \text{ Hz})$ ، $\theta(3/5 - 8 \text{ Hz})$ ، $\alpha(8 - 12 \text{ Hz})$ ، $\beta(13 - 30 \text{ Hz})$ و $\gamma(30 - 70 \text{ Hz})$ تقسیم کرد (دپاسکالیس و همکاران، ۲۰۲۰). دلیل استفاده فراوان از آن وضوح زمانی بالا و توصیف فرآیندهای خاص مغز همچنین بدلیل مقرون به صرفه بودن و در دسترس بودن است (ترامبایولی و بیازولی، ۲۰۲۰).

در مطالعه لی و همکاران (۲۰۱۹)، اضطراب در دو حالت چشم باز و بسته در ۷۳ فرد سالم با استفاده از ویژگی های زمانی سنجیده شد. ویژگی های زمانی شامل میانگین، انحراف معیار، چولگی، میانه، میانه قدر مطلق انحراف، دامنه بین چارکی، میانگین پیراسته بودند. نتایج نشان دادند که مقادیر انحراف معیار، میانه قدر مطلق انحراف، دامنه بین چارکی، میانگین پیراسته برای حالت چشم بسته بالاتر از چشم باز است. همچنین سطح اضطراب فرد با ویژگی های انحراف معیار، میانه قدر مطلق انحراف، دامنه بین چارکی در حالت چشم باز در RT^9 ارتباط منفی دارد ولی با چولگی در حالت چشم بسته در ناحیه FCP^{۱۰} ارتباط مثبت دارد (لی و همکاران، ۲۰۱۹). در مطالعه دیگری (جاناناکاکیس و همکاران، ۲۰۱۵)، از ویژگی های زمانی، طیفی و غیرخطی استفاده شد. ویژگی های طیفی شامل عدم تقارن پیشانی با استفاده از باند آلفا، همدوسی و شاخص بار مغز^{۱۱}، ویژگی

² Li³ Giannakakis⁴ Trambaiolli⁵ Biazoli Jr⁶ De Pascalis⁷ Liu⁸ Xie⁹ Right temporal¹⁰ Frontal-central-parietal¹¹ Brain load index¹ Baghdadi

نتایج نشان دادند که صحت طبقه بندی ۶۷/۶۷٪ است (شی و همکاران، ۲۰۲۰).

بطور خلاصه، اضطراب یکی از رایج‌ترین اختلالات روانشناختی است که برای تشخیص آن به فردی متخصص نیاز است. این فرد با بهره‌گیری از روشهای بالینی و خودارزیابی به تشخیص حالات اضطرابی می‌پردازد. این رویکرد به دلایل مختلف از جمله کمبود/نبود نیروی متخصص در دسترس، وجود خطای انسانی، نیاز به پزشکی از راه دور و بکارگیری روزافزون سامانه‌های هوشمند در حال تغییر است. اخیراً، الگوریتم‌های مبتنی بر تحلیل الکتروآنسفالوگرام به عنوان یک نشانگر زیستی بالقوه در میان محققان مورد توجه قرار گرفته‌اند. علت آن می‌تواند در غیرتجانسی بودن، در دسترس بودن، و هزینه نسبتاً پایین الکتروآنسفالوگرافی نسبت به روش‌های تصویربرداری مغزی باشد. با بکارگیری چنین الگوریتم‌های هوشمندی، می‌توان تشخیص بالینی اضطراب را تسهیل کرد. با وجود تحقیقاتی که در این زمینه انجام شده است، هنوز نیاز به روش‌های دقیق‌تری برای تشخیص اضطراب وجود دارد. هدف از مطالعه حاضر، ارائه یک سیستم طبقه‌بندی است که افراد را در دو گروه طبقه‌بندی کند. گروه اول افرادی هستند که اضطراب ندارند یا دارای اضطراب کم هستند و گروه دوم افرادی هستند که اضطراب متوسط و بالایی دارند. برای دستیابی به هدف بیان شده، از ویژگی‌های غیر خطی سیگنال استفاده می‌شود، دلیل آن این است که سیگنال‌های پزشکی از جمله EEG دارای خاصیت ذاتی غیرخطی بودن هستند. در این مطالعه از انواع مختلفی از ویژگی‌های غیرخطی شامل بعد فرکتال، نمای لیپانوف و آنتروپی تقریبی استفاده شده است. در نتیجه ما پروتکلی ارائه دادیم که با استفاده از ویژگی‌های غیر خطی و شبکه عصبی بتواند عملکرد مناسبی برای تشخیص اضطراب ارائه دهد. الگوریتم پیشنهادی این مطالعه در شکل ۱ نمایش داده شده است.

های غیر خطی شامل ابعاد همبستگی و پارامتر جورث^۱ به عنوان ویژگی حوزه زمان مورد بررسی قرار گرفتند. برای انتخاب ویژگی از روش جستجوی مستقیم ترتیبی^۲ و جستجوی معکوس ترتیبی^۳ استفاده شد. ارزیابی اولیه توسط آزمون ویلکاکسون رتبه علامت‌دار انجام شد. نتایج نشان داد که عدم تقارن در هنگام اضطراب در مقایسه با حالت آرامش کاهش پیدا می‌کند. همچنین تجزیه و تحلیل همدوسی نشان داد که قادر به تمایز بین حالت‌های اصلی بین مکان‌های بین نیم کره از داخل نیمکره است (جاناناکاکیس و همکاران، ۲۰۱۵). بررسی رابطه بین شدت افسردگی و اضطراب با استفاده از اتصال سراسری^۴ EEG از اهداف مطالعه ترامبایولی و بیازولی جونیور (۲۰۲۰) بود. نتایج این مطالعه همبستگی اسپیرمن مثبت معنادار با افسردگی و علائم اضطراب با باند آلفا در اتصال سراسری نشان دادند (ترامبایولی و بیازولی جونیور، ۲۰۲۰). در پژوهشی دیگر (دپاسکالیس و همکاران، ۲۰۲۰)، ارزیابی اضطراب دانش‌آموزان در دو گروه اضطراب و آرامش انجام شد. ضریب همبستگی فرانکس متقابل بین مقادیر توان در فرانکس باند بتا و دلتا در دو گروه محاسبه شد. نتایج نشان داد که در گروه اضطراب همبستگی مثبت معنادار بین دلتا بتا وجود دارد در حالی که در گروه آرامش جداسازی دلتا بتا نتیجه شد (دپاسکالیس و همکاران، ۲۰۲۰). لیو و همکاران (۲۰۱۹) اضطراب در حین محاسبه مسئله ریاضی را مورد ارزیابی قرار دادند. تجزیه و تحلیل دامنه زمانی و فرانکس زمانی انجام شد. نتایج نشان داد افرادی که اضطراب ریاضی بالایی دارند نوسانات باند بتا و دامنه P300 قوی‌تری را نشان می‌دهند در حالی که افراد در حین حل مسئله، فعالیت باند گاما قوی‌تری دارند (لیو و همکاران، ۲۰۱۹). در مطالعه‌ای که اخیراً انجام شده است (شی و همکاران، ۲۰۲۰)، روشی برای تشخیص اضطراب و افسردگی بر اساس شبکه‌های مغزی و شبکه عصبی کانولوشن ارائه شد. در این روش، دادگان که توسط PLI^۵ پیش پردازش شدند به عنوان ورودی به شبکه عصبی داده شدند و شبکه برای این دادگان آموزش دید و طبقه‌بندی انجام شد.


¹ Hjorth

² sequential forward selection (SFS)

³ sequential backward selection (SBS)

⁴ global connectivity


⁵ Phase Lag Index



شکل ۱. الگوریتم کلی مطالعه

روش

تحقیق حاضر از نوع تحلیلی-مشاهده‌ای است. در این آزمایش از دادگان موجود در پایگاه داده DASP استفاده شده است (بغدادی و همکاران، ۲۰۱۹). سیگنال‌ها از ۲۳ فرد سالم شامل ۱۳ زن و ۱۰ مرد با میانگین سنی ۳۰ سال که هیچگونه بیماری‌های روان شناختی نداشتند گرفته شد. قبل از شروع آزمایش، هدف برای هر شرکت کننده توضیح داده شد. برای جلوگیری از نویزها و برای تضمین تمرکز کامل آزمودنی، آزمایش در یک محیط ایزوله انجام شد. تحریک اضطراب به صورت غرقه‌سازی^۱ در مواجهه درمانی مستقیم^۲، مواجهه واقعی با یک محرک ترسناک انجام شد (بغدادی و همکاران، ۲۰۱۹). بدین منظور، تحریک روانی رو در رو به صورت حرفه‌ای توسط روان درمانگر انجام شد. برای ثبت سیگنال از هدست Emotiv EPOC که دارای ۱۴ کانال و بی‌سیم است، استفاده شد. نحوه قرارگیری کانال‌ها روی سر مطابق سیستم بین المللی ۱۰-۲۰ بود و در موقعیت AF3، F7، F3، FC5، T7، P7، O1، O2، P8، T8، FC6، F4، F8 و AF4 به پوست سر متصل شدند که در شکل ۲ نشان داده شده است.




شکل ۲. (الف) هدست Emotive EPOC+، (ب) نحوه قرار گرفتن الکترودها روی سر

سنسور ماستوئید M1 به عنوان یک نقطه مرجع زمین برای مقایسه با ولتاژ سنسورهای دیگر عمل می‌کرد، در حالی که سنسور ماستوئید M2 یک مرجع غیر مستقیم برای به حداقل رساندن تداخل الکتریکی از خارج بود.

¹ Flooding


² in-vivo exposure therapy

سنجیده می شود. تمام مراحل پروتکل تحریک در شکل ۴ ارائه شده است.



شکل ۳. یک نمونه آزمون خودارزیابی آدمک

سپس شرکت کنندگان با چشمان بسته و به حداقل رساندن حرکات و گفتار، آزمایش را آغاز می کنند. ۶ موقعیت شامل از دست دادن (۶۸٪)، مسائل خانوادگی (۶۴٪)، مسائل مالی (۵۴٪)، مهلت مقرر (۴۶٪)، شاهد تصادف مرگبار (۴۵٪) و بدرفتاری (۴۰٪) برای اعمال تحریک تصویرسازی ذهنی به افراد استفاده شده است. روان درمانگر از وضعیت اول شروع می کند و وضعیت را به مدت ۱۵ ثانیه بازخوانی و به آزمودنی در تصور آن کمک می کند سپس به مدت ۱۵ ثانیه به شرکت کننده زمان داده می شود تا آن وضعیت را به یاد بیاورد. پس از اتمام زمان ۳۰ ثانیه ای، از فرد خواسته



شکل ۴. پروتکل تجربی تحریک اضطراب

می شود که احساس خود را در هنگام تحریک با استفاده از آزمون خودارزیابی آدمک ارزیابی کند (شکل ۳). آزمون خودارزیابی آدمک دو سطر برای رتبه بندی دارد: بازه ارزش از منفی تا مثبت و بازه برانگیختگی از آرام تا هیجان. هر ردیف شامل نه مورد برای رتبه بندی است. به منظور ارزیابی احساسات فعلی، هر داوطلب باید موارد را تیک بزند که فقط در دو بعد برای احساسات مناسب هستند (ارزش و برانگیختگی). این آزمایش تا وضعیت ششم تکرار می شود. در پایان آزمایش، سطح اضطراب با استفاده از همیلتون

در معادله فوق n : تعداد مراحل در شکل موج یا یکی کمتر از تعداد زوج نقاط (x, y) ، d : فضای مسطح شکل موج است و L طول کلی شکل موج است (کاتز^۵، ۱۹۸۷).
بعد فرکتال هیگوچی: برای به دست آوردن بعد فرکتال هیگوچی باید مجموعه‌ای از مشاهدات را در یک بازه منظم در نظر گرفت:

$$X(1), X(2), X(3), \dots, X(N) \quad ۲$$

از این مجموعه، یک X_k^m جدید باید ساخته شود، که به شرح زیر است:

$$x_m^k = \left\{ x(m), x(m+k), x(m+2k), \dots, x\left(m + \left\lfloor \frac{N-m}{k} \right\rfloor k\right) \right\} \quad ۱$$

با $m = 1, 2, 3, \dots, k$ ؛ و علامت Gauss را نشان می‌دهد و هر دو k و m صحیح هستند. k و m به ترتیب زمان اولیه و فاصله را نشان می‌دهند. طول منحنی مربوط به هر سری زمانی $L_m(k)$ با استفاده از X_k^m به شرح زیر است:

$$L_m(k) = \frac{1}{k} \left(\sum_{i=1}^{\left\lfloor \frac{N-m}{k} \right\rfloor} (X(m+ik) - X(m+(i-1)k)) \right) \left(\frac{N-1}{\left\lfloor \frac{N-m}{k} \right\rfloor k} \right) \quad ۴$$

که در آن اصطلاح

$$\frac{N-1}{\left\lfloor \frac{N-m}{k} \right\rfloor k} \quad ۵$$

یک عامل نرمال کردن را نشان می‌دهد (سروانتس-دلا توره و همکاران، ۲۰۱۳).^۶

بعد فرکتال پطروس-یان: سری زمانی $x(1), x(2), x(3), \dots, x(N)$ است. فرض می‌شود که شکل موج سیگنال از مجموعه‌ای از نقاط $\{y_1, y_2, \dots, y_N\}$ تشکیل شده است، در ابتدا باید دنباله را باینری کنید و ماتریس باینری Z_i را تنظیم کنید، سپس:

پس از جمع آوردی دادگان، پردازش روی آنها انجام می‌شود. دادگان موجود در پایگاه داده تمیز و پیش پردازش شده هستند به همین دلیل پیش پردازشی برای حذف نویز و آرتیفکت روی آنها انجام نمی‌شود و از همان دادگان موجود در پایگاه داده برای استخراج ویژگی استفاده می‌شود. برای استخراج ویژگی از ویژگی‌های غیرخطی استفاده می‌شود که دلیل آن الگوی آشفته در سیگنال‌های EEG است. ویژگی‌های غیر خطی استخراج شده عبارت‌اند از بعد فرکتال^۱ شامل ابعاد فرکتال هیگوچی، کاتز و پطروس-یان، نمای لیاپونوف و آنتروپی تقریبی. همه این ویژگی‌ها برای هر ۱۴ کانال محاسبه می‌شود (۷۰ ویژگی = 14×5 = تعداد ویژگی‌های غیرخطی $\times$ تعداد کانالهای مغزی).

بعد فرکتال، اطلاعات نهفته در سیستم را آشکار می‌کند. با استفاده از بعد فرکتال دریچه تازه‌ای به سوی ناهنجاری‌ها باز می‌شود (سو و همکاران، ۱۹۹۹). از بعد فرکتال معمولاً در پردازش سیگنال‌های بیوالکتریک از جمله آنالیز سیگنال الکتروکاردیوگرام^۲ و EEG استفاده می‌شود. این ویژگی برای تشخیص حالت‌های خاص توابع فیزیولوژیکی استفاده می‌شود (پاراماناتان^۳ و اوتایاکومار^۴، ۲۰۰۸). روش‌های مختلفی برای محاسبه بعد فرکتال وجود دارد که ما در این مطالعه از روش ۳ از جمله کاتز، پطروس-یان و هیگوچی استفاده می‌کنیم که به شرح زیر است:

بعد فرکتال کاتز: یکی از روش‌های تعیین بعد فرکتال سیگنال، روش کاتز می‌باشد. در این روش شکل موج‌ها، منحنی‌های مسطحی هستند که از زوج مرتب‌های (x, y)

تشکیل شده‌اند و مقدار x به صورت تک واحدی افزایش پیدا می‌کند. یک روش برای طبقه بندی عددی موج‌ها تشخیص بعد فرکتال شکل موج‌ها است که به صورت زیر تعریف می‌شود:

$$FD = \frac{\log(n)}{\log(n) + \log\left(\frac{d}{L}\right)} \quad ۱$$

^۱ Fractal Dimension(FD)

^۲ Electrocardiogram

^۳ Paramanathan

^۴ Uthayakumar

^۵ Katz

^۶ Cervantes-De la Torre

$u = \{u(1), u(2), \dots, u(N)\}$ توالی اعداد به طول N باشد و $x(i)$ ، $x(j)$ و فاصله بین آنها $d[x(i), x(j)]$ به صورت:

$$x(i) = \{u(i), u(i+1), \dots, u(i+m-1)\}$$

$$x(j) = \{u(j), u(j+1), \dots, u(j+m-1)\}$$
و
$$d[x(i), x(j)] = \max_{k=1,2,\dots,m} (|u(i+k-1) - u(j+k-1)|)$$

تعریف شود (دلگادو-بونال^۷ و مارشاک^۸، ۲۰۱۹) و پارامترهای r و m که به ترتیب پارامترهای بعد و تلورانس نامیده می شوند (حسین زاده و همکاران، ۱۳۹۷)، با در نظر گرفتن مراحل زیر آنتروپی تقریبی برای هر سیگنال به دست می آید:

۱- $C_i^m(r)$ به شکل زیر محاسبه می شود:

$$C_i^m(r) = (\text{number of } j \leq N-m+1 \text{ such that } d[x(i), x(j)] \leq r) / (N-m+1) \quad 10$$

۲- تابع $\Phi^m(r)$ برای سیگنال بدست می آید:

$$\Phi^m(r) = \frac{1}{N-m+1} \sum_{i=1}^{N-m+1} \log C_i^m(r) \quad 11$$

۳- در نهایت برای مقادیر ثابت پارامترهای r, m, N مقادیر ApEn بدست می آید (دلگادو-بونال و مارشاک، ۲۰۱۹):

$$ApEn(m, r, N) = \Phi^m(r) - \Phi^{m+1}(r) \quad 12$$

پس از استخراج ویژگی، انتخاب ویژگی انجام می شود. انتخاب ویژگی، روشی است که با استفاده از آن می توان ویژگی های مناسب را انتخاب کرد و ویژگی های نامناسب، زائد یا پر نویز را حذف کرد. این کار موجب کاهش ابعاد و انتخاب زیر مجموعه کوچکی از ویژگی های استخراجی شده، دقت یادگیری بالاتر، هزینه محاسباتی کمتر و تفسیرپذیری بهتر مدل می شود (وانگ^۹ و همکاران، ۲۰۱۶). در این مقاله

$$z_i = \begin{cases} 1, & x_i > \text{mean}(y) \\ -1, & x_i \leq \text{mean}(y) \end{cases}, i = 1, \dots, N \quad 6$$

آنگاه N_Δ تعداد کل تغییرات نمادهای مجاور را در دنباله پیدا می شود:

$$N_\Delta = \sum_{i=1}^{N-2} \left| \frac{z_{i+1} - z_i}{2} \right| \quad 7$$

بعد فراکتال پتروسیان به شرح زیر نشان داده شده است (تینگ شی^۱، ۲۰۱۸):

$$D = \frac{\log_{10} N}{\log_{10} N + \log_{10} \left(\frac{N}{N + 0.4N_\Delta} \right)} \quad 8$$

بزرگترین نمای لیاپونوف^۲ (LLE): لیاپانوف معیاری برای تشخیص رفتار آشوب در یک سیستم است (محمدی و همکاران، ۲۰۱۶)^۳ اگر نمای لیاپانوف مثبت باشد، به این معنا است که سیستم رفتاری آشوبناک دارد (آورجسویچ^۴ و همکاران، ۲۰۱۸؛ محمدی و همکاران، ۲۰۱۶). برای یک سیگنال، LLE به شرح زیر محاسبه می شود:

$$\lambda = \frac{1}{n} \ln \left(\frac{d_n}{d_0} \right) \quad 9$$

که در آن d_n فاصله بین نمونه های متوالی در زمان n^{th} و d_0 فاصله متوالی در زمان اولیه است (محمدی و همکاران، ۲۰۱۶).

آنتروپی تقریبی^۵: آنتروپی تقریبی، معیاری خوب است که قابلیت پیش بینی و نظم و ترتیب را بیان می کند (انصاری و همکاران، ۱۳۹۵). در واقع آنتروپی تقریبی میزان پیچیدگی یک سیگنال یا سیستم را به صورت کمی تعیین می کند (پینکس^۶، ۱۹۹۱). با فرض اینکه

¹ Ting Shi

² Largest Lyapunov Exponent

³ Mohammadi

⁴ Awrejcewicz

⁵ Approximate entropy

⁶ PINCUS


⁷ Delgado-Bonal

⁸ Marshak

⁹ Wang

یافته‌ها

پس از استخراج ویژگی با استفاده از روش‌های بیان شده، تعداد ۵،۱۰،۱۵ ویژگی با استفاده از روش MRMR انتخاب شد. این ویژگی‌ها به عنوان بردار ورودی به شبکه عصبی MLP با یک لایه پنهان دارای ۱۰، ۵ و ۱۵ نورون اعمال شدند. دلیل استفاده از تعداد ویژگی‌ها و تعداد نورون‌های مختلف این است که بررسی کنیم در کدام حالت نتیجه دقیق‌تری حاصل می‌شود.



شکل ۵. معماری کلی شبکه عصبی

خطای شبکه عصبی با استفاده از معیار خطای میانگین مربعات^۷ (MSE) محاسبه شد و برای تعیین ضرایب از الگوریتم لونیگ-مارکوارت استفاده شد. از مجموعه ویژگی‌های انتخاب شده، ۷۰٪ برای آموزش شبکه MLP، ۱۵٪ برای اعتبار سنجی و ۱۵٪ برای آزمایش استفاده شد. شبکه ۲۰ بار اجرا شد و در هر بار اجرا مقادیر صحت، دقت، حساسیت (سوکولووا^۸ و همکاران، ۲۰۰۶) و f1-score با استفاده از فرمول‌های زیر محاسبه شدند (چیکو^۹ و جورمن^{۱۰}، ۲۰۲۰).

$$Accuracy = \frac{(TP + TN)}{(TP + FP + FN + TN)} \quad ۱۳$$

$$Sensitivity = \frac{TP}{(TP + FN)} \quad ۱۴$$

از یک روش حداقل افزونگی حداکثر ارتباط^۱ (MRMR) برای انتخاب ویژگی استفاده شده است. MRMR یک روش انتخاب ویژگی مبتنی بر فیلتر است که با در نظر گرفتن ارتباط مربوط به پیش بینی متغیر نتیجه و افزونگی در ویژگی‌های انتخاب شده، این مشکل را حل می‌کند (ژائو و همکاران، ۲۰۱۹).

پس از انتخاب ویژگی با روش بیان شده، ویژگی‌های انتخاب شده به شبکه عصبی مصنوعی^۳ (ANN) اعمال می‌شود. شبکه‌های عصبی مصنوعی برای برنامه خاص مانند طبقه بندی و شناسایی الگو از طریق فرآیند یادگیری طراحی می‌شوند (ابیودون^۴ و همکاران، ۲۰۱۸). ANN از سه واحد تشکیل می‌شود. واحد اول، لایه ورودی است که تعداد گره‌های ورودی آن توسط پارامترهای ورودی تعیین می‌شود. آخرین واحد، لایه خروجی است که تعداد گره‌های آن توسط تعداد خروجی‌ها مشخص می‌شود. واحد دوم، لایه‌هایی است که بین واحد اول و آخر قرار می‌گیرد و به آن‌ها لایه پنهان گفته می‌شود. در اکثر شبکه‌های عصبی، از توابع غیرخطی برای پردازش داده‌ها استفاده می‌شود. یکی از انواع شبکه‌های عصبی پرسپترون چندلایه^۵ (MLP) است. MLP یک طبقه‌بند کننده شبکه عصبی مصنوعی فید-فوروارد است. در هر لایه معمولاً یک تابع فعالسازی غیرخطی وجود دارد که بر روی دادگان اعمال می‌شود. نتیجه هر لایه به عنوان ورودی به لایه بعدی اعمال می‌شود و در نهایت خروجی در لایه آخر نمایش داده می‌شود. در این شبکه از پس انتشار برای یادگیری استفاده می‌شود (طراوت^۶ و همکاران، ۲۰۱۵). معماری کلی شبکه‌های عصبی در شکل ۵ نمایش داده می‌شود.

برای استفاده از شبکه عصبی تعدادی پارامتر برای ما مهم هستند که عبارت است از: تعداد لایه‌های پنهان، تعداد نورون در هر لایه، زمان یادگیری دادگان آموزش و آزمون (محمدی و همکاران، ۲۰۱۶).

¹ Minimum Redundancy Maximum Relevance

² Zhao

³ Artificial Neural Network

⁴ Abiodun

⁵ Multi-layer perceptron

⁶ Taravat

⁷ Mean Squared Error

⁸ Sokolova

⁹ Chicco

¹⁰ Jurman

$$Precision = \frac{TP}{(TP + FP)} \quad ۱۵$$

$$F1 \text{ score} = 2 \times \frac{(Sensitivity \times Precision)}{(Sensitivity + Precision)} \quad ۱۶$$

که TP (مثبت صحیح)^۱ نمونه های مثبتی هستند که درست طبقه بندی شده اند، TN (منفی صحیح)^۲ نمونه های منفی ای هستند که درست طبقه بندی شده اند، FP (مثبت کاذب)^۳ نمونه های مثبتی هستند که نادرست طبقه بندی شده اند و FN (منفی کاذب)^۴ نمونه های منفی هستند که نادرست طبقه بندی شده اند (جیاو^۵ و دو^۶، ۲۰۱۶؛ درزی و همکاران، ۱۳۹۵). ماتریس کانفیوژن (همدوسی) ابزاری است جهت بررسی کارایی سیستم طبقه بندی (درزی و همکاران، ۱۳۹۵) که در جدول ۱ نمایش داده شده است.

جدول ۱. ماتریس کانفیوژن

		برچسب پیش بینی شده	
		مثبت	منفی
برچسب شناخته شده	مثبت	TP	FN
	منفی	FP	TN

پس از ۲۰ بار اجرای طبقه بندی، میانگین و انحراف معیار و ماکسیمم برای مقادیر نام برده شده بدست آمد که در جداول ۲ تا ۴ ارائه شده اند. در جدول ۲ نتایج برای ۵ ویژگی، در جدول ۳ نتایج برای ۱۰ ویژگی و در جدول ۴ نتایج برای ۱۵ ویژگی و با تعداد نوروں های ۵،۱۰ و ۱۵ نشان داده شده است.

¹ true positives

² true negatives

³ false positives

⁴ false negatives

⁵ Jiao

⁶ Du

جدول ۲. نتایج برای ۵ ویژگی

تعداد نورون	صحت			F1 – score			دقت			حساسیت		
	mean	std	max	mean	std	max	mean	std	max	mean	std	max
5	۷۷	۲۱,۷۸	۱۰۰	۸۱,۵۹	۲۱,۴۵	۱۰۰	۷۹,۹۱	24.90	۱۰۰	۸۶,۹۱	۲۴,۱۴	۱۰۰
10	۷۵	۱۷,۰۱	۱۰۰	۸۰,۲۳	۱۴,۲۸	۱۰۰	۸۳	14.84	۱۰۰	۸۲,۸۳	۲۲,۲۱	۱۰۰
15	۸۰	۲۰,۵۱	۱۰۰	۸۴,۱۵	۱۷,۱۹	۱۰۰	۹۲,۷۵	13.19	۱۰۰	۸۰,۵۸	۲۱,۶۷	۱۰۰

جدول ۳. نتایج برای ۱۰ ویژگی

تعداد نورون	صحت			F1 – score			دقت			حساسیت		
	mean	std	max	mean	std	max	mean	std	max	mean	std	max
5	۶۷	۳۰,۶۲	۱۰۰	۷۱,۶۰	۳۱,۴۷	۱۰۰	۷۹,۲۵	32.13	۱۰۰	۷۰	۳۴,۸۷	۱۰۰
10	۷۰	۲۰	۱۰۰	۷۴,۱۹	۲۱,۱۲	۱۰۰	۷۸,۱۶	19.38	۱۰۰	۷۵,۴۱	۲۷,۸۹	۱۰۰
15	۷۴	۱۷,۲۹	۱۰۰	۷۹,۹۳	۱۴,۵۵	۱۰۰	۸۶,۲۵	22.17	۱۰۰	۸۰,۳۳	۱۶,۱۵	۱۰۰

جدول ۴. نتایج برای ۱۵ ویژگی

تعداد نورون	صحت			F1 – score			دقت			حساسیت		
	mean	std	max	mean	std	max	mean	std	max	mean	std	max
۵	۶۹	۱۷,۷۴	۱۰۰	۷۲,۶۷	۲۶,۳۸	۱۰۰	۷۱,۶۶	۳۰,۰۱	۱۰۰	۷۸,۸۳	۳۰,۷۳	۱۰۰
۱۰	۷۶	۲۱,۱۲	۱۰۰	۸۲,۴۹	۱۵,۰۹	۱۰۰	۸۵,۰۸	۲۰,۳۰	۱۰۰	۸۴,۹۱	۱۸,۵۶	۱۰۰
۱۵	۷۸	۱۸,۲۳	۱۰۰	۸۳,۸۹	۱۵,۴۳	۱۰۰	۸۷	۱۸,۸۷	۱۰۰	۸۷,۳۳	۱۹,۲۶	۱۰۰

بهترین عملکرد با ۵ ویژگی و ۱۵ نورون بوده و ماکزیمم صحت، F1-score، دقت و حساسیت برای تمامی حالات ۱۰۰٪ بوده است.

بحث و نتیجه گیری

اضطراب یکی از شایع ترین اختلالات روان پزشکی است که تشخیص به موقع آن می تواند از عوارض و شدت یافتن آن جلوگیری کند. در این مقاله، ما با استفاده از ویژگی های غیر خطی سیگنال EEG و شبکه عصبی، یک سیستم برای تشخیص اضطراب ارائه کردیم. تاکنون بیشتر مطالعات از ویژگی های طیفی، زمانی، فرکانسی برای تمایز افراد دارای اضطراب استفاده کرده اند. اما نتایج نشان می دهند که برای دستیابی به نتایج بهتر، به روش های پیشرفته نیاز است. بغدادی و همکاران (۲۰۱۹)، ویژگی های دامنه زمان، دامنه فرکانس، دامنه فرکانس-زمان و ویژگی های کمی دیگر را در ۲۳ فرد سالم با محرک های رو در رو ارزیابی کردند. ویژگی های دامنه زمان شامل جورث و بعد فرکتال هیگوشی، ویژگی دامنه فرکانس شامل باند توان، ویژگی های دامنه فرکانس-زمان شامل طیف هیلبرت هوانگ^۱ و باند توان و RMS با استفاده از تبدیل موجک گسسته DWT^۲ و همچنین ویژگی های کمی شامل دامنه، فرکانس، اتصال و عدم تقارن تفاضلی بود. برای طبقه بندی در ۲ و ۴ سطح اضطراب SSAE^۳ استفاده شد. نتایج نشان دادند که با استفاده از طبقه بندی SSAE ویژگی ۸۳/۵۰٪ برای ۲ کلاس و ۷۴/۶۰٪ برای ۴ کلاس بدست می آید (بغدادی و همکاران، ۲۰۱۹) که در این مطالعه در مقایسه با مطالعه ای که ما انجام دادیم، از تعداد ویژگی بیشتری برای طبقه بندی استفاده شده است و انتخاب ویژگی انجام نشده است که باعث می شود طبقه بندی با تعداد ویژگی بیشتری آموزش ببیند که باعث پیچیده شدن محاسبات می شود در صورتی که ما از انتخاب ویژگی استفاده کردیم و آموزش را با ۵،۱۰ و ۱۵ ویژگی انجام دادیم. کلادوس^۴ و همکاران (۲۰۱۷)، از ۱۶ دانش آموز ویژگی های استخراج شده از سطح سنسوری را استخراج

کردند. آنها برای انتخاب ویژگی از CfsSubsetEval و برای طبقه بندی از درخت نیویز (NBTree)^۵ استفاده کردند. مطالعه کلادوس و همکاران (۲۰۱۷) صحت ۹۳/۷۵٪ را نشان داد، در صورتی که ما از ۲۳ داده استفاده کردیم که باعث می شود آموزش طبقه بندی بهتر انجام شود. در جدول ۵ خلاصه ای از مقایسه روش کار این مطالعات با مطالعه انجام گرفته بیان شده است. ما برای بهبود دقت از انتخاب ویژگی MRMR استفاده کردیم تا ویژگی های زاید را حذف کنیم و از ویژگی های مرتبط با خروجی استفاده کنیم و سپس ویژگی های بدست آمده را به عنوان ورودی به شبکه عصبی MLP اعمال کردیم. ما تعداد ویژگی را ۵،۱۰ و ۱۵ عدد انتخاب کردیم ویژگی ها کمتر باشد، پیچیدگی محاسبات کمتر خواهد بود. طبق نتایج بدست آمده که در جداول ۲ تا ۴ قرار گرفته اند، بهترین نتایج برای ۵ ویژگی با ۱۵ نورون بدست آمد. با توجه به صحت و دقت بدست آمده، ویژگی های غیرخطی ای که استفاده کردیم ویژگی های مناسب برای تجزیه و تحلیل سیگنال EEG هستند.

محدودیت این مطالعه شامل محدودیت دسترسی به دادگان بیشتر، استفاده از یک روش برای انتخاب ویژگی، تقسیم بندی اضطراب در ۲ سطح و استفاده از ویژگی های غیر خطی محدود است.

در کارهای آتی می توان علاوه بر طبقه بندی اضطراب در دو سطح، آن را در چهار سطح طبقه بندی کرد. سطح اضطراب با میزان برانگیختگی و ارزش احساسی مقیاس گذاری و با داده های مغزی مورد بررسی قرار گیرد. اثر کانال های مغزی و ارتباطات مغزی را می توان مورد مطالعه قرار داد. به علاوه می توان از طبقه بندی دیگر و از طیف وسیع تری از ویژگی های غیر خطی استفاده کرد و با دسترسی به دادگان بیشتر، طبقه بندی را به شکل مناسب تری آموزش داد.

تشکر و قدردانی

در این مقاله از دادگان موجود در پایگاه داده IEEE (بغدادی و همکاران، ۲۰۱۹) استفاده شده است. بدین وسیله، مراتب سپاس خود را از خانم بغدادی و همکاران ایشان برای در دسترس قرار دادن دادگان بطور رایگان اعلام می داریم.

^۱ Hilbert-huang spectrum

^۲ Discrete wavelet transform

^۳ Stacked Sparse Autoencoder

^۴ Klados

^۵ Naïve Bayesian Tree

پژوهش توسط تیم تحقیقاتی دیگری در خارج از کشور ثبت شده است و در این مطالعه فقط کارهای پردازشی انجام شده است، کد اخلاق پزشکی مورد نیاز نمی‌باشد.

کد اخلاق: این مقاله فاقد هرگونه مطالعه با شرکت کنندگان انسانی است که دادگان آن توسط نویسندگان مقاله حاضر اخذ شده باشد. نظر به اینکه داده‌های این

جدول ۵. مقایسه روش کار مقاله‌های مرتبط با مقاله کنونی

نتایج	طبقه بند	انتخاب ویژگی	استخراج ویژگی	تعداد آزمودنی	مراجع
صحت=۸۰٪ دقت=۹۲/۷۵٪ F1 score=۸۴/۱۵٪ حساسیت=۸۰/۵۸٪	MLP	MRMR	ویژگی غیرخطی	۲۳	مطالعه کنونی
- ویژگی برای دو کلاس=۸۳/۵۰٪ - ویژگی برای چهار کلاس=۷۴/۶۰٪	SSAE	-	ویژگی دامنه زمان، دامنه فرکانس، دامنه فرکانس-زمان و ویژگی های کمی	۲۳	(بغدادی و همکاران، ۲۰۱۹)
صحت=۹۳/۷۵٪	NBTree	CfsSubsetEval	ویژگی استخراج شده از سطح سنسور	۱۶	(کلادوس و همکاران، ۲۰۱۷)
- ارتباط منفی سطح اضطراب با انحراف معیار، میانه قدر مطلق انحراف، دامنه بین چارکی در حالت چشم بسته - ارتباط مثبت سطح اضطراب با چولگی در حالت چشم بسته	-	-	ویژگی های زمانی	۷۳	(لی و همکاران، ۲۰۱۹)
کاهش عدم تقارن هنگام اضطراب در مقایسه با حالت آرامش	-	SFS SBS	ویژگی های زمانی، طیفی، غیرخطی	۱۸	(جاناناکاکیس و همکاران، ۲۰۱۵)
ارتباط مثبت معنادار باند آلفا با افسردگی و اضطراب	SVR	-	-	- ۷۵ فرد سالم - ۴۴ فرد مبتلا به اختلال افسردگی اساسی	(ترامبایولی و بیازولی جونیور، ۲۰۲۰)
- در گروه اضطراب همبستگی مثبت معنادار بین دلتا-بتا - در گروه آرامش جداسازی دلتا-بتا	-	-	-	- ۵۹ دانش آموز در وضعیت اضطراب آور - ۶۶ نفر در وضعیت آرامش	(دپاسکالیس و همکاران، ۲۰۲۰)
دقت طبقه بندی=۶۷/۶۷٪	CNN	-	-	- ۱۰ فرد سالم - ۱۰ فرد بیمار	(شی و همکاران، ۲۰۲۰)

منابع

Abiodun, O. I., Jantan, A., Omolara, A. E., Dada, K. V., Mohamed, N. A., & Arshad, H. (2018). State-of-the-art in artificial neural network applications: A survey. *Heliyon*, 4(11), e00938. doi:10.1016/j.heliyon.2018.e00938

Ansari, G., Abbasi, A., & Goshvarpour, A. (2016). Entropy analysis of heart rate signal during creative thinking. *Innovation and Creativity in the Humanities*, 6 (2), 53-76. [Persian]
Awrejcewicz, J., Krysko, A. V., Erofeev, N. P., Dobriyan, V., Barulina, M. A., & Krysko, V. A. (2018). Quantifying chaos by various computational methods. Part 1: simple

- systems. *Entropy*, 20(3), 175. doi:10.3390/e20030175
- Azizi, M., & Barati, M. (2014). A review of anxiety disorders and its nursing practices. *Paramedical Sciences and Military Health*, 9 (1), 54-58. [Persian] <https://jps.ajaums.ac.ir/article-1-38-fa.html>
- Baghdadi, A., Aribi, Y., Fourati, R., Halouani, N., Siarry, P., & Alimi, A. M. (2019). DASPS: A Database for Anxious States based on a Psychological Stimulation. arXiv preprint arXiv:1901.02942.
- Cervantes-De la Torre, F., González-Trejo, J. I., Real-Ramirez, C. A., & Hoyos-Reyes, L. F. (2013). Fractal dimension algorithms and their application to time series associated with natural phenomena. In *Journal of Physics: Conference Series* (Vol. 475, No. 1, p. 012002). IOP Publishing. doi:10.1088/1742-6596/475/1/012002
- Chicco, D., & Jurman, G. (2020). The advantages of the Matthews correlation coefficient (MCC) over F1 score and accuracy in binary classification evaluation. *BMC genomics*, 21(1), 1-13. doi:10.1186/s12864-019-6413-7
- Darzi, M., Ulfatbakhsh, A., Gorgin, S., Oveisi, F., Hashemi, E. A., ... & Alavi, N. A. (2016). Classification of unbalanced data in the initial diagnosis of breast diseases by methods of adabost, probabilistic neural network and K to the nearest neighbor. *Iranian Journal of Breast Diseases*, 9 (2), 7-18.
- Delgado-Bonal, A., & Marshak, A. (2019). Approximate entropy and sample entropy: A comprehensive tutorial. *Entropy*, 21(6), 541. doi:10.3390/e21060541
- De Pascalis, V., Vecchio, A., & Cirillo, G. (2020). Resting anxiety increases EEG delta-beta correlation: Relationships with the Reinforcement Sensitivity Theory Personality traits. *Personality and Individual Differences*, 156, 109796. doi:10.1016/j.paid.2019.109796
- Giannakakis, G., Grigoriadis, D., & Tsiknakis, M. (2015). Detection of stress/anxiety state from EEG features during video watching. In 2015 37th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC) (pp. 6034-6037). IEEE. doi:10.1109/EMBC.2015.7319767
- Hosseinzadeh, M. S., Ismailzadeh Khadem, S., & Sadoughi, M. S. (2018). Enhancement of Hilbert-Huang transform with entropy-based nonlinear properties for fast troubleshooting in a rotating equipment vibration simulator. *Modares Mechanical Engineering*, 18 (2). [Persian]
- Jiao, Y., & Du, P. (2016). Performance measures in evaluating machine learning based bioinformatics predictors for classifications. *Quantitative Biology*, 4(4), 320-330. doi:10.1007/s40484-016-0081-2
- Katz, M. J. (1988). Fractals and the analysis of waveforms. *Computers in biology and medicine*, 18(3), 145-156. doi:10.1016/0010-4825(88)90041-8
- Klados, M. A., Pandria, N., Athanasiou, A., & Bamidis, P. D. (2017). An automatic EEG based system for the recognition of math anxiety. In 2017 IEEE 30th International Symposium on Computer-Based Medical Systems (CBMS) (pp. 409-412). IEEE. doi:10.1109/CBMS.2017.107
- Li, J., Ran, H., & Zhao, J. (2019). Relationship Between Multiple Temporal Features of Resting EEG and the Anxiety State of Normal Subjects. In 2019 12th International Congress on Image and Signal Processing, BioMedical Engineering and Informatics (CISP-BMEI) (pp. 1-6). IEEE. doi:10.1109/CISP-BMEI48845.2019.8965982
- Liu, J., Li, J., Peng, W., Feng, M., & Luo, Y. (2019). EEG correlates of math anxiety during arithmetic problem solving: Implication for attention deficits. *Neuroscience letters*, 703, 191-197. doi:10.1016/j.neulet.2019.03.047
- Mohammadi, M. R., Khaleghi, A., Nasrabadi, A. M., Rafieivand, S., Begol, M., & Zarafshan, H. (2016). EEG classification of ADHD and normal children using non-

- linear features and neural network. *Biomedical Engineering Letters*, 6(2), 66-73. doi:10.1007/s13534-016-0218-2
- Mousavi, R., Mousavi, S. S., Mahmoudi Qaraei, J., & Akbari Zardkhaneh, S. (2008). Tools for assessing and diagnosing anxiety disorders in children and adolescents. *Scientific Research Journal of Army University of Medical Sciences of the Islamic Republic of Iran*. [Persian]
- Paramanathan, P., & Uthayakumar, R. (2008). An algorithm for computing the fractal dimension of waveforms. *Applied Mathematics and Computation*, 195(2), 598-603. doi:10.1016/j.amc.2007.05.011
- Pincus, S. M. (1991). Approximate entropy as a measure of system complexity. *Proceedings of the National Academy of Sciences*, 88(6), 2297-2301. doi:10.1073/pnas.88.6.2297
- Shi, C. T. (2018). Signal pattern recognition based on fractal features and machine learning. *Applied Sciences*, 8(8), 1327. doi:10.3390/app8081327
- Sokolova, M., Japkowicz, N., & Szpakowicz, S. (2006). Beyond accuracy, F-score and ROC: a family of discriminant measures for performance evaluation. In *Australasian joint conference on artificial intelligence* (pp. 1015-1021). Springer, Berlin, Heidelberg. doi:10.1007/11941439_114
- So, P., Barreto, E., & Hunt, B. R. (1999). Box-counting dimension without boxes: Computing D_0 from average expansion rates. *Physical Review E*, 60(1), 378. doi:10.1103/PhysRevE.60.378
- Taheri, H., Taheri, A., & Amiri, M. (2017). Evaluation of the effectiveness of group behavioral activation therapy on social anxiety, avoidance and negative evaluations of people with social anxiety symptoms. *Journal of Mental Health Principles*, 19 (5), 361-365. doi:10.22038/JFMH.2017.9057 [Persian]
- Taravat, A., Proud, S., Peronaci, S., Del Frate, F., & Oppelt, N. (2015). Multilayer perceptron neural networks model for meteosat second generation SEVIRI daytime cloud masking. *Remote Sensing*, 7(2), 1529-1539. doi:10.3390/rs70201529
- Trambaiolli, L. R., & Biazoli, C. E. (2020). Resting-state global EEG connectivity predicts depression and anxiety severity. In *2020 42nd Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC)* (pp. 3707-3710). IEEE. doi:10.1109/EMBC44109.2020.9176161
- Wang, S., Tang, J., & Liu, H. (2017). Feature Selection. doi:10.1007/978-1-4899-7502-7_101-1
- Xie, Y., Yang, B., Lu, X., Zheng, M., Fan, C., Bi, X., & Li, Y. (2020). Anxiety and depression diagnosis method based on brain networks and convolutional neural networks. In *2020 42nd Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC)* (pp. 1503-1506). IEEE. doi:10.1109/EMBC44109.2020.9176471
- Zhao, Z., Anand, R., & Wang, M. (2019). Maximum relevance and minimum redundancy feature selection methods for a marketing machine learning platform. In *2019 IEEE International Conference on Data Science and Advanced Analytics (DSAA)* (pp. 442-452). IEEE. doi:10.1109/DSAA.2019.00059