Journal of Cognitive Psychology

Desember 2021, Volume 9, Issue 3

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

Faezeh Daneshmand-Bahman [1], 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. **J**ournal of **C**ognitive **P**sychology. 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.

[Downloaded from isharat.khu.ac.ir on 2026-10-29]

[DOI: 1052547/jcp.9.3.54]

طبقه بندی EEG در دو سطح نرمال و دارای اضطراب با استفاده از ویژگی‌های 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. (نویسندهٔ مسئول) استادیار، گروه مهندسی پزشکی، دانشگاه بین المللی امام رضا (ع)، مشهد، ایران.
ateke.goshvarpour@gmail.com

تاریخ دریافت
۱۴۰۰/۰۳/۱۳

تاریخ پذیرش نهایی
۱۴۰۰/۰۷/۱۰

واژگان کلیدی
الکتروآنسفالگرافی، اضطراب، ویژگی‌های غیرخطی، انتخاب ویژگی، شبکه پرسپترون چندلایه

چکیده

اضطراب واکنش طبیعی انسان‌ها در برابر فشار روانی است که در رویارویی با عوامل مختلف ایجاد می‌شود. امروزه، حالت‌های اضطرابی توسط متخصصان با استفاده از نشانه‌های اضطراب و با ارائه پرسش‌هایی تشخیص داده می‌شود. هدف از این مطالعه تحلیلی-مشاهده‌ای، طبقه‌بندی 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 تقسیم‌بندی شدند. آنتروپی تقریبی، بعد فرکتال و نمای لیاپانوف به عنوان ویژگی‌های غیر خطی از تمام کانال‌ها 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 می‌یابد. 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 دهنده‌ی توانمندی الگوریتم پیشنهادی برای تشخیص افراد مضطرب از افراد نرمال می‌باشد.

[Downloaded from isharat.khu.ac.ir on 2026-10-29]

[DOI: 1052547/jcp.9.3.54]

مقدمه

اضطراب یک مسئله بهداشت روان (بغدادی[1] و همکاران، ۲۰۱۹) و از شایعترین اختلالات روان‌پزشکی است و شامل تغییرات جسمی، روانی و رفتاری است که در رویارویی با تهدید و خطر به طور خودکار رخ می‌دهد (عزیزی و براتی، ۱۳۹۳) و می تواند پیامدهای جسمی بر بدن داشته باشد (بغدادی و همکاران، ۲۰۱۹) و بر بسیاری از جنبه‌های 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 اختلالات‌روان مانند اسکیزوفرنی، افسردگی، سوء مصرف مواد و بیماریهای جسمی همراه می‌باشد. علاوه بر بیماری‌های روانی نام برده شده که از اضطراب ناشی می‌شوند 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 (عزیزی 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 می‌شوند 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 (عزیزی 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 الکتروآنسفالوگرام (EEG) برای تشخیص اضطراب داشتند (لی[2] و همکاران، ۲۰۱۹؛ جاناناکاکیس[3] و همکاران، ۲۰۱۵؛ ترامبایولی[4] و بیازولی جونیور[5]، ۲۰۲۰؛ د پاسکالیس[6] و همکاران، ۲۰۲۰؛ لیو[7] و همکاران، ۲۰۱۹؛ شی[8] و همکاران، ۲۰۲۰). EEG یک روش غیر تهاجمی برای ثبت فعالیت الکتروفیزیولوژیک مغز است (لی و همکاران، ۲۰۱۹). EEG را می‌توان به پنج باند $\delta(0-3/5\ Hz)$، $\theta(3/5-8Hz)$، $\alpha(8-12Hz)$، $\beta(13-30Hz)$ و $\gamma(30-70Hz)$ 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 جونیور، 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 ویژگی‌های 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[10] ارتباط مثبت دارد (لی و همکاران، ۲۰۱۹). در مطالعه دیگری (جاناناکاکیس و همکاران، ۲۰۱۵)، از ویژگی‌های زمانی، طیفی و غیرخطی استفاده شد. ویژگی های طیفی شامل عدم تقارن پیشانی با استفاده از باند آلفا، همدوسی و شاخص بار مغز[11]، ویژگی

[1] Baghdadi
[2] Li
[3] Giannakakis
[4] Trambaiolli
[5] Biazoli Jr
[6] De Pascalis
[7] Liu
[8] Xie
[9] Right temporal
[10] Frontal-central-parieta
[11] Brain load index

[Downloaded from isharat.khu.ac.ir on 2026-10-29]
[DOI: 1052547/jcp.9.3.54]

های غیر خطی شامل ابعاد همبستگی و پارامتر جورث[1] به عنوان ویژگی حوزه زمان مورد بررسی قرار گرفتند. برای انتخاب ویژگی از روش جستجوی مستقیم ترتیبی[2] و جستجوی معکوس ترتیبی[3] 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 می کند. همچنین تجزیه و تحلیل همدوسی نشان داد که قادر به تمایز بین حالت های اصلی بین مکان های بین نیم کره از داخل نیمکره است (جاناناکاکیس و همکاران، ۲۰۱۵). بررسی رابطه بین شدت افسردگی و اضطراب با استفاده از اتصال سراسری[4] 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 دانش آموزان در دو گروه اضطراب و آرامش انجام شد. ضریب همبستگی فرکانس متقابل بین مقادیر توان در فرکانس 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 فرکانس زمانی انجام شد. نتایج نشان داد افرادی که اضطراب ریاضی بالایی دارند نوسانات باند بتا و دامنه P300 قوی تری را نشان می دهند در حالی که افراد در حین حل مسئله، فعالیت باند گاما قوی‌تری دارند (لیو و همکاران، ۲۰۱۹). در مطالعه‌ای که اخیرا انجام شده است (شی و همکاران، ۲۰۲۰)، روشی برای تشخیص اضطراب و افسردگی بر اساس شبکه های مغزی و شبکه عصبی کانولوشن ارائه شد. در این روش، دادگان که توسط PLI[5] پیش پردازش شدند به عنوان ورودی به شبکه عصبی داده شدند و شبکه برای این دادگان آموزش دید و طبقه بندی انجام شد. 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 بهره گیری 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. اخیرا، الگوریتم‌های مبتنی بر تحلیل الکتروآنسفالوگرام به عنوان یک نشانگر زیستی بالقوه در میان محققان مورد توجه قرار گرفته‌اند. علت آن می تواند در غیرتهاجمی بودن، در دسترس بودن، و هزینه نسبتا پایین الکتروآنسفالوگرافی نسبت به روش های تصویربرداری مغزی باشد. با بکارگیری چنین الگوریتم های 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 طبقه بندی 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 ویژگی های غیر خطی سیگنال استفاده می شود، دلیل آن این است که سیگنال های پزشکی از جمله EEG دارای خاصیت ذاتی غیرخطی بودن هستند. در این مطالعه از انواع مختلفی از ویژگی های غیرخطی شامل بعد فرکتال، نمای لیاپانوف و آنتروپی تقریبی استفاده شده است. در نتیجه ما پروتکلی ارائه دادیم که با استفاده از ویژگی های غیر خطی و شبکه عصبی بتواند عملکرد مناسبی برای تشخیص اضطراب ارائه دهد. الگوریتم پیشنهادی این مطالعه در شکل ۱ نمایش داده شده است.

[1] Hjorth
[2] sequential forward selection (SFS)
[3] sequential backward selection (SBS)
[4] global connectivity
[5] Phase Lag Index

[Downloaded from isharat.khu.ac.ir on 2026-10-29]
[DOI: 1052547/jcp.9.3.54]

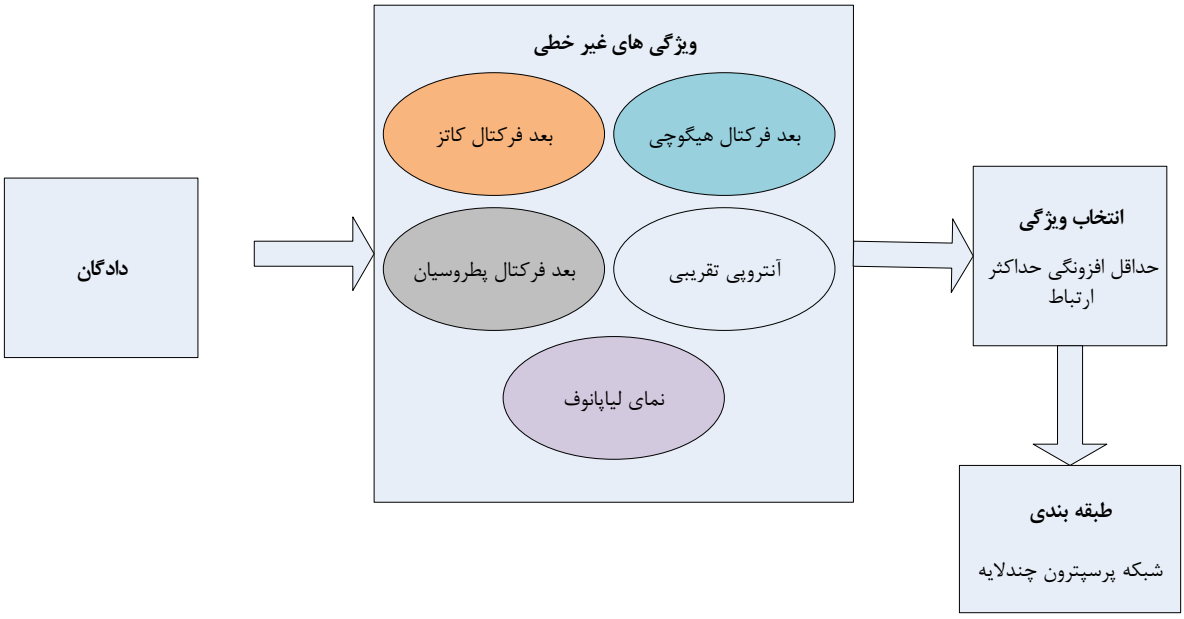

شکل۱. الگوریتم کلی مطالعه

[Downloaded from isharat.khu.ac.ir on 2026-10-29]

[DOI: 1052547/jcp.9.3.54]

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). سیگنال ها 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[1] در مواجهه درمانی مستقیم[2]، مواجهه واقعی با یک محرک ترسناک انجام شد (بغدادی و همکاران، ۲۰۱۹). بدین منظور، تحریک روانی رو در رو به صورت حرفه ای توسط روان درمانگر انجام شد.

برای ثبت سیگنال از هدست Emotiv EPOC که دارای ۱۴ کانال و بی‌سیم است، استفاده شد. نحوه قرارگیری کانال ها 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.

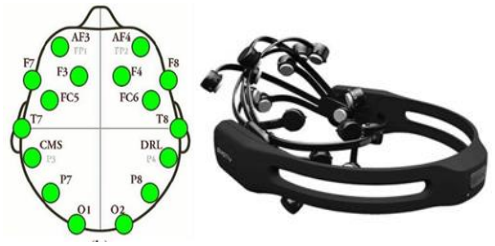

(ب) (الف)

شکل۲. (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.

در پروتکل تجربی از روش غرقه سازی (توضیح اضافه:غرقه سازی بر این فرض متکی است که فرار از یک تجربه اضطراب انگیز از طریق شرطی سازی موجب تقویت حافظه می گردد.) استفاده شد. این روش به شرح زیر است: هدف مطالعه برای شرکت کنندگان بیان شد و از همه آنها خواسته شد پیش از آزمایش رضایت نامه را امضا کنند. سطح اضطراب هر شرکت کننده قبل از اعمال هرگونه تحریک با استفاده از مقیاس رتبه بندی همیلتون (HAM-A) محاسبه شد. سطح اضطراب در مقیاس صفر تا چهار درجه بندی شد.

[1] Flooding
[2] in-vivo exposure therapy

[Downloaded from isharat.khu.ac.ir on 2026-10-29]
[DOI: 1052547/jcp.9.3.54]

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

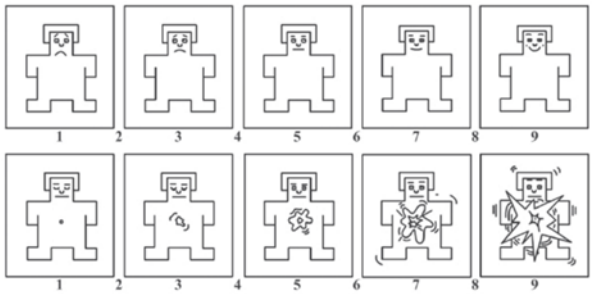

شکل۳. یک نمونه آزمون خودارزیابی آدمک

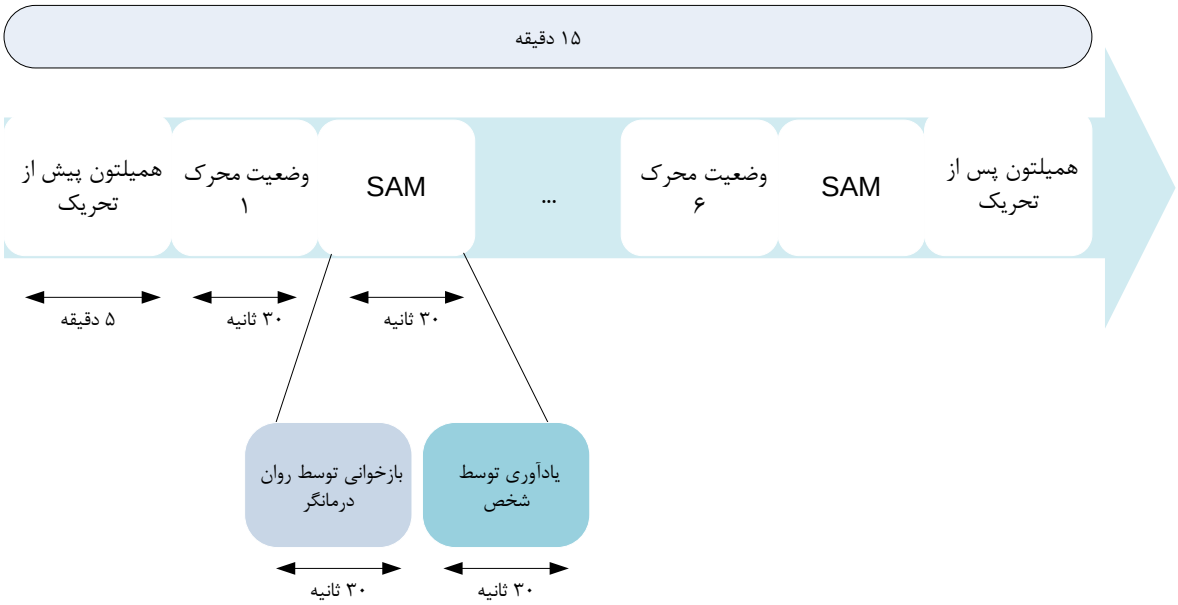

شکل۴. پروتکل تجربی تحریک اضطراب

می شود که احساس خود را در هنگام تحریک با استفاده از آزمون خودارزیابی آدمک ارزیابی کند (شکل۳). 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 رتبه‌بندی 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 می‌شود. در پایان آزمایش، سطح اضطراب با استفاده از همیلتون

[Downloaded from isharat.khu.ac.ir on 2026-10-29]
[DOI: 1052547/jcp.9.3.54]

پس از جمع آوردی دادگـان، پـردازش روی آنهـا انجـام مـی شود. دادگان موجود در پایگـاه داده تمیـز و پـیش پـردازش شده هستند به همین دلیل پیش پردازشی برای حذف نـویز و آرتیفکـت روی آنهـا انجـام نمـی‌شـود و از همـان دادگـان موجود در پایگاه داده برای استخراج ویژگی استفاده می‌شود. برای استخراج ویژگی از ویژگی‌های غیرخطی اسـتفاده مـی-شود که دلیـل آن الگـوی آشـفته در سـیگنال هـای EEG است. ویژگی‌های غیر خطی استخراج شده عبارت‌انـد از بعـد فراکتال[1] شامل ابعاد فراکتال هیگـوچی، کـاتز و پطروسـیان، نمای لیاپونوف و آنتروپی تقریبی. همه این ویژگـی هـا بـرای هر ۱۴ کانـال محاسـبه مـی شـود (۷۰ ویژگـی = ۵ × ۱۴ = تعداد ویژگی های غیرخطی × تعداد کانالهای مغزی).

بعد فرکتال، اطلاعات نهفته در سیستم را آشکار میکنـد. بـا استفاده از بعد فرکتال دریچه تازه ای به سوی ناهنجاری ها باز میشود (سو و همکاران، ۱۹۹۹). از بعد فراکتال معمـولا در پردازش سیگنال‌های بیوالکتریک از جمله آنالیز سـیگنال الکتروکاردیوگرام[2] و EEG استفاده می‌شـود. ایـن ویژگـی برای تشخیص حالت‌های خاص توابع فیزیولوژیکی اسـتفاده مـی‌شـود (پاراماناتـان[3] و اوتایاکومـار[4]، ۲۰۰۸). روش هـای مختلفی برای محاسبه بعد فرکتال وجود دارد که مـا در ایـن مطالعـه از ۳ روش از جملـه کـاتز، پطروسـیان و هیگـوچی استفاده می‌کنیم که به شرح زیر است:

بعد فرکتال کاتز: یکـی از روش‌هـای تعیـین بعـد فراکتـال سیگنال، روش کاتز می‌باشد. در این روش شـکل مـوج‌هـا، منحنی‌های مسطحی هستند که از زوج مرتب هـای (x,y) تشکیل شده اند و مقدار x به صورت تک واحـدی افـزایش پیدا می‌کند. یک روش برای طبقـه بنـدی عـددی مـوج‌هـا تشخیص بعد فرکتال شکل موج ها است که به صـورت زیـر تعریف می شود :

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

[1] Fractal Dimension(FD)
[2] Electrocardiogram
[3] Paramanathan
[4] Uthayakumar

در معادله فوق n: تعداد مراحل در شکل موج یا یکی کمتـر از تعداد زوج نقاط (x,y)، d: فضای مسطح شکل موج اسـت و L طول کلی شکل موج است (کاتز[5]، ۱۹۸۷).

بعد فرکتال هیگوچی: برای بـه دسـت آوردن بعـد فراکتـال هیگوچی باید مجموعه‌ای از مشاهدات را در یک بـازه مـنظم در نظر گرفت:

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

از این مجموعه، یک X_k^m جدید بایـد سـاخته شـود، کـه بـه 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 نشـان مـی دهد و هر دو k و m صحیح هستند. m و k به ترتیب زمـان اولیه و فاصله را نشان می دهند. طول منحنی مربوط به هـر سری زمانی $L_m(k)$ با استفاده از X_k^m به شرح زیر است:

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

که در آن اصطلاح

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

یک عامل نرمال کردن را نشان می دهد (سروانتس-دلا توره و همکاران، ۲۰۱۳)[6].

بعـد فرکتـال پطروسـیان: سـری زمـانی $x(1), x(2), x(3), \dots, x(N)$ است. فـرض مـی‌شـود کـه شکل موج سیگنال از مجموعه‌ای از نقاط $\{y_1, y_2, \dots, y_N\}$ تشکیل شده است، در ابتـدا بایـد دنبالـه را بـاینری کنیـد و ماتریس باینری z_i را تنظیم کنید، سپس:

[5] Katz
[6] Cervantes-De la Torre

[Downloaded from isharat.khu.ac.ir on 2026-10-29]
[DOI: 1052547/jcp.9.3.54]

۶
$$z_i = \begin{cases} 1, x_i > mean(y) \\ -1, x_i \le mean(y) \end{cases}, i = 1, \dots, N$$

آنگاه ، N_Δ تعداد کل تغییرات نمادهـای مجـاور را در دنبالـه پیدا می شود:

۷
$$N_\Delta = \sum_{i=1}^{N-2} \left| \frac{z_{i+1} - z_i}{2} \right|$$

بعد فراکتال پطروسیان به شرح زیـر نشـان داده شـده اسـت (تینگ شی[1]، ۲۰۱۸) :

۸
$$D = \frac{log_{10} N}{log_{10} N + log_{10}\left(\frac{N}{N + 0.4N_\Delta}\right)}$$

بزرگترین نمای لیـاپونوف[2](LLE): لیاپـانوف معیـاری بـرای تشخیص رفتـار آشـوب در یـک سیسـتم اسـت (محمـدی و همکاران، ۲۰۱۶)[3] اگر نمای لیاپانوف مثبـت باشـد، بـه ایـن معنا است که سیستم رفتاری آشوبناک دارد (آورجسـویچ[4] و همکـاران، ۲۰۱۸؛ محمـدی و همکـاران، ۲۰۱۶). بـرای یـک سیگنال، LLE به شرح زیر محاسبه می‌شود:

۹
$$\lambda = \frac{1}{n} ln\left(\frac{d_n}{d_0}\right)$$

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

آنتروپی تقریبی[5]: آنتروپی تقریبی، معیاری خوب اسـت کـه قابلیت پیش بینی و نظم و ترتیب را بیان می‌کند (انصاری و همکاران، ۱۳۹۵). در واقع آنتروپی تقریبی میزان پیچیدگی یک سیگنال یا سیستم را به صورت کمّـی تعیـین مـی‌کنـد (پیـنکس[6]، ۱۹۹۱). بـا فـرض اینکـه $u = \{u(1), u(2), \dots, u(N)\}$ 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

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

تعریـف شـود (دلگـادو-بونـال[7] و مارشـاک[8]، ۲۰۱۹) و پارامترهای m و r که به ترتیب پارامتر های بعـد و تلـورانس نامیده می شوند (حسین زاده و همکاران، ۱۳۹۷)، با در نظر گرفتن مراحل زیر آنتروپـی تقریبـی بـرای هـر سـیگنال بـه دست می‌آید:

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

۱۰
$$C_i^m(r) = (number\ of\ j \le N - m + 1\ such\ that\ d[x(i), x(j)] \le r)/(N - m + 1)$$

2-تابع $\Phi^m(r)$ برای سیگنال بدست می‌آید:

۱۱
$$\Phi^m(r) = \frac{1}{N - m + 1} \sum_{i=1}^{N-m+1} logc_i^m(r)$$

3-در نهایت برای مقادیر ثابت پارامترهای N ,m ,r مقـادیر ApEn بدست می‌آید (دلگادو-بونال و مارشاک، ۲۰۱۹):

۱۲
$$ApEn(m,r,N) = \Phi^m(r) - \Phi^{m+1}(r)$$

پـس از اسـتخراج ویژگـی، انتخـاب ویژگـی انجـام می‌شـود. انتخاب ویژگی، روشی است کـه بـا اسـتفاده از آن مـی‌تـوان ویژگی‌های مناسب را انتخاب کرد و ویژگـی‌هـای نامناسـب، زائد یا پر نویز را حذف کرد. این کار موجب کاهش ابعـاد و انتخاب زیر مجموعه کوچکی از ویژگی‌های استخراجی شـده، دقت یادگیری بالاتر، هزینه محاسباتی کمتر و تفسـیرپذیری بهتر مدل می‌شود (وانگ[9] و همکاران، ۲۰۱۶). در این مقالـه

[1] Ting Shi
[2] Largest Lyapunov Exponent
[3] Mohammadi
[4] Awrejcewicz
[5] Approximate entropy
[6] PINCUS
[7] Delgado-Bonal
[8] Marshak
[9] Wang

[Downloaded from isharat.khu.ac.ir on 2026-10-29]
[DOI: 1052547/jcp.9.3.54]

از یک روش حداقل افزونگی حداکثر ارتباط[1](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[2] و همکاران، ۲۰۱۹).

پس از انتخاب ویژگی با روش بیان شده، ویژگی های انتخاب شده به شبکه عصبی مصنوعی[3](ANN) اعمال می شود. شبکه های عصبی مصنوعی برای برنامه خاص مانند طبقه بندی و شناسایی الگو از طریق فرآیند یادگیری طراحی می شوند (ابیودون[4] و همکاران، ۲۰۱۸). ANN از سه واحد تشکیل می‌شود. واحد اول،لایه ورودی است که تعداد گره های ورودی آن توسط پارامترهای ورودی تعیین می‌شود. آخرین واحد، لایه خروجی است که تعداد گره‌های آن توسط تعداد خروجی‌ها مشخص می شود. واحد دوم، لایه‌هایی است که بین واحد اول و آخر قرار می گیرد و به آن‌ها لایه پنهان گفته می‌شود. در اکثر شبکه‌های عصبی، از توابع غیرخطی برای پردازش داده‌ها استفاده می‌شود. یکی از انواع شبکه های عصبی پرسپترون چندلایه[5](MLP) است. MLP یک طبقه‌بند کننده شبکه عصبی مصنوعی فید-فوروارد است. در هر لایه معمولا 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[6] و همکاران، ۲۰۱۵). معماری کلی شبکه‌های عصبی عصبی در شکل 5 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

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 ۵، ۱۰و ۱۵ نورون اعمال شدند. دلیل استفاده از تعداد ویژگی‌ها و تعداد نورون های مختلف این است که بررسی کنیم در کدام حالت نتیجه دقیق‌تری حاصل می‌شود.

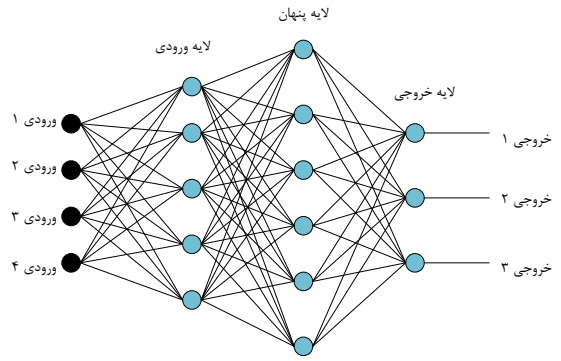

شکل۵. معماری کلی شبکه عصبی

خطای شبکه عصبی با استفاده از معیار خطای میانگین مربعات[7] (MSE) محاسبه شد و برای تعیین ضرایب از الگوریتم لونبرگ-مارکواردت 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[8] و همکاران، ۲۰۰۶) و f1-score با استفاده از فرمول‌های زیر محاسبه شدند (چیکو[9] و جورمن[10]، ۲۰۲۰).

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

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

[7] Mean Squared Error
[8] Sokolova
[9] Chicco
[10] Jurman

[Downloaded from isharat.khu.ac.ir on 2026-10-29]
[DOI: 1052547/jcp.9.3.54]

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

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

که TP(مثبت صحیح[1]) نمونه های مثبتی هستند که درست طبقه‌بندی شده اند، TN(منفی صحیح[2]) نمونه های منفی ای هستند که درست طبقه‌بندی شده اند،FP(مثبت کاذب[3]) نمونه های مثبتی هستند که نادرست طبقه بندی شده اند و FN(منفی کاذب[4]) نمونه های منفی هستند که نادرست طبقه‌بندی شده اند(جیائو[5] و دو[6]، ۲۰۱۶؛ درزی و همکاران،۱۳۹۵). ماتریس کانفیوژن (همدوسی) ابزاری است جهت بررسی کارآیی سیستم طبقه بندی (درزی و همکاران،۱۳۹۵) که در جدول ۱ نمایش داده شده است.

جدول۱. 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 نورون 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

[Downloaded from isharat.khu.ac.ir on 2026-10-29]

[DOI: 1052547/jcp.9.3.54]

جدول۲. 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

جدول۳. 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

جدول۴. 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

[Downloaded from isharat.khu.ac.ir on 2026-10-29]

[DOI: 1052547/jcp.9.3.54]

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

بحث و نتیجه‌گیری

اضطراب یکی از شایع‌ترین اختلالات روان پزشکی است که تشخیص به موقع آن می‌تواند 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 می‌دهند که برای دستیابی به نتایج بهتر، به روش های پیشرفته نیاز است. بغدادی و همکاران (۲۰۱۹)، ویژگی‌های 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 هیگوچی، ویژگی دامنه فرکانس شامل باند توان، ویژگی های دامنه فرکانس-زمان شامل طیف هیلبرت هوانگ[1] و باند توان و RMS با استفاده از تبدیل موجک گسسته DWT[2] و همچنین ویژگی های کمی شامل دامنه، فرکانس، اتصال و عدم تقارن تفاضلی بود. برای طبقه بندی در ۲ و ۴ سطح اضطراب SSAE[3] 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 بند 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 ۱۵ویژگی انجام دادیم. کلادوس[4] و همکاران (۲۰۱۷)، از ۱۶ دانش‌آموز ویژگی‌های استخراج شده از سطح سنسوری را استخراج کردند. آنها برای انتخاب ویژگی از CfsSubsetEval و برای طبقه‌بندی از درخت نیوبیز (NBTree[5]) استفاده کردند. مطالعه کلادوس و همکاران (۲۰۱۷) صحت ۹۳/۷۵ ٪ را نشان داد، در صورتی که ما از ۲۳ داده استفاده کردیم که باعث می‌شود آموزش طبقه بند 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 امده 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 بند های دیگر و از طیف وسیع تری از ویژگی های غیر خطی استفاده کرد و با دسترسی به دادگان بیشتر، طبقه بند را به شکل مناسب‌تری آموزش داد.

تشکر و قدردانی

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

[1] Hilbert-huang spectrum
[2] Discrete wavelet transform
[3] Stacked Sparse Autoencoder
[4] Klados
[5] Naïve Bayesian Tree

[Downloaded from isharat.khu.ac.ir on 2026-10-29]
[DOI: 1052547/jcp.9.3.54]

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 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.

جدول۵. مقایسه روش کار مقاله های 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 دوکلاس=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

[Downloaded from isharat.khu.ac.ir on 2026-10-29]

[DOI: 1052547/jcp.9.3.54]

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-

[Downloaded from isharat.khu.ac.ir on 2026-10-29]
[DOI: 1052547/jcp.9.3.54]

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. :doi10.22038/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

[Downloaded from isharat.khu.ac.ir on 2026-10-29]
[DOI: 1052547/jcp.9.3.54]