

Evaluation of Deep Neural Networks in Emotion Recognition Using Electroencephalography Signal Patterns

Azin Kermanshahian^{1,2}, M.Sc., Mahdi Khezri^{1,2}, Assistant Professor

¹Department of Electrical Engineering- Najafabad Branch, Islamic Azad University, Najafabad, Iran

²Digital Processing and Machine Vision Research Center- Najafabad Branch, Islamic Azad University, Najafabad, Iran

a.kermanshahian@gmail.com, mahdi.khezri@pel.iaun.ac.ir

Abstract

In this study, the design of a reliable detection system that is able to identify different emotions with the desired accuracy has been considered. To reach this goal, two different structures for the emotion recognition system include 1) using linear and non-linear features of the electroencephalography (EEG) signal along with common classifiers and 2) using EEG signal in a deep learning structure is considered to identify emotional states. To design the system, the EEG signals of the DEAP database which were recorded by displaying emotional videos from 32 subjects were used. After the preparation and noise removal, linear and non-linear features such as: Skewness, Kurtosis, Hjorth parameters, Lyapunov exponent, Shannon entropy, correlation and fractal dimension and time reversibility were extracted from the alpha, beta and gamma subbands of the EEG signals. Then according to structure 1, the features were applied as input to common classifiers such as decision tree (DT), k nearest neighbor (kNN) and support vector machine (SVM). Also in structure 2, the EEG signal was considered as the input of the convolutional neural network (CNN). The goal is to evaluate the results of deep learning networks and other methods for emotion recognition. According to the obtained results, the SVM achieved the best performance for identifying four emotional states with 94.1 % accuracy. Also, the proposed CNN identified the desired emotional states with the accuracy of 86%. Deep learning methods are superior to simple classifiers because they do not require the features of the signals and are resistant to different noises. Using a short period of time for the signals and performing near optimal preprocessing and conditioning, can further improve the results of deep neural networks.

Keywords: convolution neural network, dynamic features, electroencephalography signal, emotion recognition, support vector machines classifier

Received: 21 February 2023

Revised: 31 May 2023

Accepted: 21 June 2023

Corresponding Author: Dr. Mahdi Khezri

Citation: A. Kermanshahian, M. Khezri, "Evaluation of deep neural networks in emotion recognition using electroencephalography signal patterns", Journal of Intelligent Procedures in Electrical Technology, vol. 16, no. 64, pp. 31-46, March 2026 (in Persian).

<https://dorl.net/dor/20.1001>.....

مقاله پژوهشی

ارزیابی شبکه‌های عصبی عمیق در تشخیص احساسات با استفاده از الگوهای سیگنال الکتروانسفالوگرام

آذین کرمانشاهیان^{۱،۲}، دانش‌آموخته کارشناسی ارشد، مهدی خضری^{۱،۲}، استادیار

۱- دانشکده مهندسی برق- واحد نجف‌آباد، دانشگاه آزاد اسلامی، نجف‌آباد، ایران

۲- مرکز تحقیقات پردازش دیجیتال و بینایی ماشین- واحد نجف‌آباد، دانشگاه آزاد اسلامی، نجف‌آباد، ایران

a.kermanshahian@gmail.com, mahdi.khezri@pel.iaun.ac.ir

چکیده: در این مطالعه طراحی یک سیستم قابل اعتماد که قادر به شناسایی احساسات مختلف با دقت مطلوب باشد، مورد توجه قرار گرفته است. برای رسیدن به این هدف، دو ساختار متفاوت برای سیستم تشخیص احساسات شامل (۱) ویژگی‌های خطی و غیرخطی سیگنال الکتروانسفالوگرام (EEG) به همراه طبقه‌بندهای رایج و (۲) سیگنال EEG در یک ساختار یادگیری عمیق مدنظر قرار گرفته است. برای طراحی سیستم، سیگنال‌های EEG پایگاه داده DEAP که از ۳۲ نفر با نمایش ویدیوهای احساسی ثبت شده‌اند، مورد استفاده قرار گرفتند. پس از آماده‌سازی و حذف نویز، ویژگی‌های سیگنال شامل چولگی، کشیدگی، پارامترهای جورث، نمای لیاپانف، آنتروپی شانون، بعد همبستگی، بعد فرکتال و برگشت‌پذیری زمان از زیربندهای آلفا، بتا و گاما استخراج شدند. سپس با توجه به ساختار یک، ویژگی‌های تعیین شده به‌عنوان ورودی به طبقه‌بندهای رایج مانند درخت تصمیم (DT)، k نزدیک‌ترین همسایه (kNN) و ماشین بردار پشتیبان (SVM) اعمال شدند. همچنین مطابق با ساختار دو، سیگنال EEG به‌عنوان ورودی شبکه عصبی کانولوشنی (CNN) در نظر گرفته شد. هدف ارزیابی نتایج شبکه‌های آموزش عمیق و سایر روش‌ها برای تشخیص احساسات است. با توجه به نتایج کسب شده، SVM با دقت ۹۴/۱ درصد بهترین عملکرد را برای شناسایی چهار حالت احساسی به‌دست آورد. همچنین CNN پیشنهادی، با دقت ۸۶ درصد حالت‌های احساسی موردنظر را شناسایی کرد. روش‌های یادگیری عمیق به‌دلیل این‌که به تعیین ویژگی برای سیگنال‌ها نیاز ندارند و در برابر نویزهای مختلف مقاومند، نسبت به طبقه‌بندهای ساده برتری دارند. استفاده از سیگنال‌های با بازه زمانی کوتاه و انجام مراحل پیش‌پردازش و آماده‌سازی مطلوب، می‌تواند نتایج شبکه‌های عصبی عمیق را همچنان بهبود دهد.

کلمات کلیدی: تشخیص احساسات، سیگنال الکتروانسفالوگرام، شبکه عصبی کانولوشنی، طبقه‌بند ماشین بردار پشتیبانی، ویژگی‌های دینامیکی

تاریخ ارسال مقاله: ۱۴۰۱/۱۲/۲

تاریخ بازنگری مقاله: ۱۴۰۲/۳/۱۰

تاریخ پذیرش مقاله: ۱۴۰۲/۳/۳۱

نام نویسنده‌ی مسئول: دکتر مهدی خضری

نشانی نویسنده‌ی مسئول: نجف‌آباد- بلوار دانشگاه- دانشگاه آزاد اسلامی واحد نجف‌آباد- دانشکده مهندسی برق

۱- مقدمه

احساسات در زندگی روزمره انسان‌ها، در تصمیم‌گیری عقلانی، ادراک، تعامل و هوش نقش اساسی دارند. با این حال، احساسات به‌ویژه در زمینه تعامل انسان‌ها و کامپیوتر تا حد زیادی نادیده گرفته شده‌اند. محاسبات عاطفی برای رفع این اشکال پدید آمده است. هدف از محاسبات عاطفی، اعطای هوش احساسی به کامپیوترها است؛ به این معنی که کامپیوترها قابلیت شناسایی حالت‌های احساسی مختلف کاربر و ارائه پاسخ مناسب در صورت لزوم را داشته باشند [۱]. وضعیت عاطفی فرد ممکن است با حالت‌های چهره، طرز گفتار، حالت‌های فیزیکی و اشاره‌های بدنی و سیگنال‌های فیزیولوژیکی آشکار شود [۲]. به دلیل این‌که سیگنال‌های فیزیولوژیکی قابل جعل و تقلید نیستند، عملکرد بهتری در شناسایی حالت‌های احساسی دارند.

مطالعه‌های فراوانی در زمینه شناسایی احساسات خودکار انجام شده است. بعضی از مطالعه‌ها از حالت‌های چهره‌ای و گفتار که مبتنی بر پردازش صدا و تصویر هستند، احساس فرد را شناسایی می‌کنند. گفتار و بیان‌های چهره‌ای معیارهای دایمی و پیوسته برای شناسایی احساسات نیستند. به این دلیل که در صورتی که فرد ساکن و بی‌صدا باشد، نوع حالت احساسی قابل تشخیص نخواهد بود. همچنین این سیگنال‌ها بسیار مستعد خطا هستند و در موقعیت‌های مختلف به راحتی می‌توانند تغییر کنند [۱].

گروه دیگری از مطالعه‌ها بر روی سیگنال‌های فیزیولوژیکی برای شناسایی احساسات تمرکز دارند. نشان داده شده است که معیارهای فیزیولوژیکی مانند نرخ ضربان قلب، هدایت پوست، فعالیت مغز، انقباض عضلات و غیره در حالت‌های مختلف احساسی تغییر می‌کنند؛ و با توجه به این‌که تغییرات ایجاد شده در سیستم عصبی را منعکس می‌کنند، برای شناسایی احساسات مورد توجه قرار می‌گیرند. از جمله سیگنال‌هایی که معمولاً برای اندازه‌گیری احساسات مورد استفاده قرار می‌گیرند، می‌توان به پاسخ الکتریکی پوست^۱ (GSR) که به صورت خطی با سطح برانگیختگی احساس افزایش پیدا می‌کند، الکترو-میوگرافی^۲ (EMG) که با احساسات دارای ظرفیت منفی در ارتباط است، نرخ ضربان قلب^۳ (HR) که با احساسات منفی مانند ترس افزایش می‌یابد و نرخ تنفس^۴ (RR) که با افزایش برانگیختگی نامنظم می‌شود، اشاره کرد. همچنین اندازه‌گیری فعالیت مغز با استفاده از سیگنال الکتروانسفالوگرام^۵ (EEG) [۳]، الکتروکورتیگوگرام^۶ (ECOG) [۴]، تصویربرداری تشدید مغناطیسی^۷ (MRI) [۵] یا توموگرافی انتشار پوزیترون^۸ (PET) [۶] می‌تواند برای شناسایی احساسات به کار رود [۷]. در میان این روش‌ها استفاده از سیگنال EEG، غیرتهاجمی، سریع و ارزان است و آن را به روشی ارجح در مطالعه پاسخ‌های مغز به محرک‌های احساسی تبدیل می‌کند [۸].

امروزه با توجه به ارائه حسگرهای قابل پوشیدن، قیمت مناسب، قابلیت حمل و سهولت استفاده از آن‌ها، کاربرد سیگنال EEG در کاربردهای مرتبط با شناسایی احساسات بسیار گسترده است. از تشخیص احساسات مبتنی بر EEG در زمینه‌های مختلف سرگرمی، یادگیری الکترونیکی، دنیای مجازی مانند پیام‌رسانی فوری، بازی‌های آنلاین، کمک به درمانگران و روانشناسان برای بررسی وضعیت بیماران اشاره کرد [۱، ۹]. تاکنون مطالعه‌های متعددی در زمینه تشخیص حالت‌های احساسی با استفاده از سیگنال‌های فیزیولوژیکی صورت گرفته است؛ که به چند مورد آنها اشاره می‌شود.

در مرجع [۱۰] یک الگوریتم تشخیص احساسات مستقل از کاربر براساس شبکه عصبی کانولوشنی تجربی پویا^۹ (DECNN) پیشنهاد شده است. در این مطالعه با ترکیب مزیت‌های تجزیه حالت تجربی^{۱۰} (EMD) به منظور پیش‌پردازش سیگنال و آنترابی دیفرانسیل، روش آنترابی دیفرانسیل پویا برای استخراج ویژگی‌های سیگنال‌های EEG پیشنهاد شده است. ویژگی‌های استخراج شده سپس توسط شبکه طراحی شده طبقه‌بندی شده‌اند. روش پیشنهادی بر روی مجموعه داده^{۱۱} SEED اعمال شده است. محققان همچنین در مورد نواحی مغز که ارتباط نزدیکی با احساسات دارند، بررسی‌هایی انجام داده‌اند و بهترین مکان-های قرارگیری الکترودها را برای کاهش محاسبه و پیچیدگی سیستم تشخیص احساسات، ارزیابی کرده‌اند. نتایج کسب شده نشان می‌دهد که دقت روش پیشنهادی در مقایسه با سایر مطالعه‌ها، بهبود قابل توجهی را نشان می‌دهد؛ به گونه‌ای که روش پیشنهادی، دو حالت احساسی را با دقت ۹۷/۵ درصد شناسایی کرده است.

در مرجع [۱۱] یک مدل چند ستونی مبتنی بر شبکه عصبی کانولوشنی^{۱۲} (CNN) برای تشخیص احساسات از سیگنال‌های EEG پیشنهاد شده است. اخیراً شبکه عصبی عمیق برای استخراج ویژگی‌ها و تشخیص احساسات از سیگنال‌های زیستی

مختلف مورد توجه قرار گرفته است. تشخیص احساسات مبتنی بر CNN بهبودی در عملکرد را نسبت به سیستم‌های مبتنی بر استخراج ویژگی دستی معمولی نشان می‌دهد. در این مطالعه، برای بهبود بیشتر دقت سیستم‌های مبتنی بر CNN، یک مدل ساختاریافته چند ستونی ارائه شده که نتیجه آن توسط مجموع وزنی نتایج زیرسیستم‌های شناسایی، تولید می‌شود. مدل به سیگنال‌های EEG مجموعه داده DEAP برای مقایسه اعمال می‌شود و دقت بهبود یافته مدل تایید می‌شود. با استفاده از روش پیشنهادی احساسات مختلف با دقت ۹۰ درصد طبقه‌بندی شدند.

در مرجع [۱۲] یک روش تشخیص احساسات از طریق سیگنال‌های EEG چندکانالی بر اساس گراف دینامیکی جدید شبکه‌های عصبی کانولوشنی^{۱۳} (DGCNN) پیشنهاد شده است. ایده اصلی روش پیشنهادی تشخیص احساسات از سیگنال EEG با استفاده از یک نمودار برای مدل‌سازی ویژگی‌های EEG چندکانالی و سپس انجام طبقه‌بندی احساسات بر اساس این مدل است. در مقایسه با روش‌های سنتی شبکه‌های عصبی کانولوشنی گراف، روش DGCNN پیشنهادی می‌تواند به صورت پویا رابطه ذاتی بین کانال‌های مختلف EEG را که توسط یک ماتریس همسایگی نشان داده می‌شود، از طریق آموزش شبکه عصبی یاد بگیرد. به این ترتیب با تعیین کانال‌های مؤثرتر، روش قادر به شناسایی احساسات مورد نظر با دقت ۸۴/۵ درصد بود.

در مطالعه‌های پیشین در رابطه با شناسایی خودکار احساسات، دقت کم در تشخیص حالت‌های احساسی و وابسته بودن و حساس بودن روش‌های طبقه‌بندی ساده به نویزها باعث ناکارآمدی روش‌ها شده است. در این مطالعه ارائه عملکرد شبکه‌های آموزش عمیق و سایر روش‌های طبقه‌بندی در شناسایی حالت‌های احساسی با استفاده از الگوهای سیگنال EEG مورد نظر خواهد بود؛ تا بهترین ساختار برای شناسایی قابل اعتماد احساسات معرفی شود. طراحی سیستم شناسایی احساسات در مطالعه حاضر طی چند مرحله و با به‌کارگیری روش‌های پردازشی کارآمد در مرحله پیش‌پردازش و حذف نویز، استخراج و انتخاب ویژگی‌ها و طبقه‌بندی انجام می‌شود. یکی از اهداف مطالعه، بررسی عملکرد طبقه‌بندهای رایج با شبکه‌های عصبی با آموزش عمیق در تشخیص احساسات مختلف است. به این منظور ساختارهای طبقه‌بندی مختلف چون ماشین بردار پشتیبان^{۱۴} (SVM)، k نزدیک‌ترین همسایه^{۱۵} (kNN)، درخت تصمیم^{۱۶} (DT) و همچنین طبقه‌بند عمیق به‌منظور برجسب‌گذاری احساسات ارزیابی می‌شوند. همچنین در سایر مطالعه‌ها از چندین سیگنال استفاده شده که حجم محاسبات بالایی دارد، در حالی که تنها چهارکانال سیگنال EEG که مرتبط با احساسات است، بررسی شده است. همچنین با توجه به مدل ابعادی احساسات و وجود مشخصه‌های مشترک در حالت‌های احساسی مختلف، چهار حالت احساس در فضای برانگیختگی و ظرفیت مورد توجه قرار گرفته‌اند. در ادامه مراحل به‌کار گرفته شده در طراحی سیستم تشخیص احساسات معرفی می‌شوند. در بخش‌های سوم و چهارم نتایج کسب شده و نتیجه‌گیری در مورد عملکرد ساختارهای پیشنهادی ارائه شده است.

۲- طراحی سیستم تشخیص احساسات با استفاده از الگوهای سیگنال الکتروانسفالوگرام

تشخیص و تحلیل احساسات از روی بیوپتانسیل‌های حیاتی در سالیان اخیر بسیار مورد توجه قرار گرفته است. در این مطالعه از الگوهای سیگنال‌های EEG برای طراحی سیستم تشخیص احساسات استفاده می‌شود. مراحل پردازشی مورد توجه برای سیستم مشابه با مسایل تشخیص الگوی رایج است. آماده‌سازی و حذف نویز، استخراج ویژگی‌ها و انتخاب ویژگی‌ها و همچنین طبقه‌بندی از جمله مراحل رایج مورد استفاده هستند. در ادامه پایگاه داده مورد استفاده و مراحل اشاره به‌طور خلاصه مورد بررسی قرار می‌گیرند.

۲-۱- پایگاه داده مورد استفاده

در این مطالعه سیگنال‌های EEG مجموعه داده تجزیه و تحلیل احساسات با استفاده از سیگنال‌های فیزیولوژیکی^{۱۷} (DEAP) مورد استفاده قرار گرفته‌اند. افراد شرکت‌کننده در فرایند ثبت سیگنال‌ها سالم و بدون بیماری‌های روانی، قلبی یا بیماری‌های بازتولید عصبی و یا صرع بوده‌اند. این پایگاه داده شامل سیگنال‌های فیزیولوژیکی ثبت شده از ۳۲ نفر زن و مرد با میانگین سنی ۱۵ تا ۵۵ حین تماشای موسیقی ویدیو است. فرکانس نمونه‌برداری داده‌ها ۵۱۲ هرتز و بازه زمانی ثبت سیگنال‌ها ۱۲۰ دقیقه است؛ که شامل نمایش ۴۰ موسیقی ویدیو برای هر نفر است. برجسب‌گذاری احساسات افراد بر مبنای بررسی تصاویر

چهره توسط متخصص روان‌شناسی انجام شده است [۸]. سیگنال‌های فیزیولوژیکی موردنظر با جایگذاری ۴۶ الکتروود که شامل ۳۲ کانال EEG، یک کانال لکتروکاردیوگرام^{۱۸} (ECG)، ۴ کانال سیگنال الکترواوکلوگرام^{۱۹} (EOG)، ۴ کانال EMG از عضله‌ی ران، یک کانال پاسخ هدایت پوست^{۲۰} (SC)، یک کانال تنفس، یک کانال دمای بدن، یک کانال سیگنال فوتوپلیتسموگرافی^{۲۱} (PPG) و یک کانال وضعیت فرد است، ثبت می‌شوند [۸].

۲-۲- پیش‌پردازش

در این مطالعه به‌منظور کاهش حجم محاسبات و زمان پردازش مطابق با تحقیقات اخیر [۱۳، ۱۴]، در ابتدا سیگنال‌ها با روش کاهش نمونه‌ها به نرخ نمونه‌برداری ۱۲۸ تبدیل شدند. به‌منظور کاهش نویز و بهبود نسبت سیگنال به نویز از فیلترگذاری حوزه فرکانس توسط فیلتر میان‌گذر باترورث^{۲۲} مرتبه ده برای جداسازی مؤلفه‌های ۰/۱ تا ۴۵ هرتز با پاسخ ضربه محدود^{۲۳} استفاده شده است (مرتبه بهینه فیلتر بر مبنای الگوریتم تخمین مک-کلان تعیین شده است) [۱۴، ۱۵]. بازه فیلتر براساس محدوده عملیاتی سیگنال EEG در کاربرد مورد نظر یعنی شناسایی احساسات انتخاب شده است. به‌طور کلی دو دلیل برای این امر مورد نظر بوده است. اول این‌که معمولاً در کاربردهای شناسایی احساسات زیرباندهای تتا، آلفا، بتا و گاما برای استخراج اطلاعات مرتبط با احساسات مدنظر قرار می‌گیرند. دلیل دوم هم این است که نویزهای فرکانس بالای سیگنال (بیشتر از ۴۵ هرتز) که به‌دلیل اثرات تداخلات اکترومغناطیسی و تجهیزات، نویز برق شهر و بعضی از اثرات تداخلی سیگنال‌های فیزیولوژیکی دیگر ایجاد می‌شوند، را حذف کنیم. همچنین با توجه به این‌که نویز با منابع و الگوی نامشخص در محدوده فرکانسی موردنظر سیگنال را آلوده می‌کند، لازم است از یک فیلترگذاری تطبیقی که بتواند الگوی نویز را حذف کند، بهره گرفت. به این منظور از تبدیل موجک^{۲۴} با تابع مادر دابچیز نوع چهارم با هشت سطح تجزیه استفاده شده است. توابع موجک دابچیز^{۲۵} تطابق شکلی مناسبی با سیگنال‌های EEG دارند؛ و معمولاً در پردازش سیگنال‌های فیزیولوژیکی مورد استفاده قرار می‌گیرند [۱۶، ۱۷]. موجک‌های دابچیز با مراتب مختلف در این مطالعه مورد بررسی قرار گرفته‌اند. موجک دابچیز ۴ از بین موجک‌های ارزیابی شده، عملکرد بهتری را ارائه کرده است. با توجه به این‌که موجک‌ها ویژگی‌های سیگنال‌ها را در مقیاس‌های مختلف محلی سازی می‌کنند، می‌توانند اطلاعات مهم سیگنال را در حین حذف نویز، حفظ کنند. برای سیگنال‌های غیرایستا و با ماهیت تصادفی مثل سیگنال‌های فیزیولوژیکی که اطلاعات مهم آنها ممکن است در زیرباندهای مختلف فرکانسی قرار داشته باشند، استفاده از تبدیل موجک می‌تواند به‌طور تطبیقی ضمن حفظ اطلاعات سیگنال در آن زیرباند، اثرات نویزی را کاهش دهد.

۲-۳- استخراج ویژگی‌ها

مجموعه‌ای از ویژگی‌های خطی و غیرخطی شامل معیار چولگی^{۲۶}، کشیدگی^{۲۷}، فعالیت، پیچیدگی و پویایی جورث^{۲۸}، نمای لپانوف^{۲۹}، آنتروپی شانون^{۳۰}، بعد همبستگی^{۳۱}، بعد فرکتال^{۳۲} و برگشت‌پذیری زمان^{۳۳}، مطابق با جدول (۱) در مطالعه حاضر برای کسب اطلاعات احساسی از سیگنال‌ها مورد توجه قرار گرفته‌اند.

۲-۴- طبقه‌بندی

هدف مرحله طبقه‌بندی، اختصاص یک گروه به اطلاعات ورودی به طبقه‌بند است. در مطالعه حاضر از روش‌های رایج طبقه‌بندی مانند SVM، kNN و DT برای شناسایی حالت‌های احساسی استفاده شده است. همچنین CNN به‌عنوان یکی از ساختارهای مبتنی بر یادگیری عمیق^{۳۴} مورد ارزیابی قرار گرفته است.

۲-۴-۱- ماشین بردار پشتیبان

ماشین بردار پشتیبان یک خط یا یک ابر صفحه ایجاد می‌کند که داده‌ها را به گروه‌هایی تفکیک می‌کند. SVM یک روش یادگیری نظارت شده است که می‌تواند برای چالش‌های طبقه‌بندی یا رگرسیون استفاده شود، با این‌حال، بیشتر در مسایل طبقه‌بندی استفاده می‌شود.

Table (1): Features used in the present study
 جدول (۱): ویژگی‌های استفاده شده در مطالعه حاضر

متغیر فرمول‌ها	فرمول ویژگی	نام ویژگی	نوع ویژگی
N: تعداد نمونه‌های سیگنال x _i : سیگنال موردنظر برای پردازش	$x_S = \frac{1}{N} \sum_{i=1}^N \left(\frac{x_i - \mu}{\sigma} \right)^3$	معیار چولگی	خطی
σ: انحراف معیار μ: میانگین	$x_K = \frac{1}{N} \sum_{i=1}^N \left(\frac{x_i - \mu}{\sigma} \right)^4$	معیار کشیدگی	خطی
σ _x : انحراف استاندارد	$Hjorth = \frac{2}{\sigma_x}$	پارامتر فعالیت جورث	خطی
σ _{x'} : انحراف استاندارد مشتق سیگنال x σ _{x''} : انحراف استاندارد مشتق دوم سیگنال x	$Hjorth_mobility = \left(\frac{\sigma_{x''}}{\sigma_{x'}} \right)$	پارامتر پیچیدگی جورث	خطی
	$Hjorth_complexity = \left(\frac{\sigma_{x'}}{\sigma_x} \right) \div \left(\frac{\sigma_{x'}}{\sigma_x} \right)$	پارامتر پویایی جورث	خطی
M: نگاشت n: ضرب لیاپانوف	$h = \lim_{T \rightarrow \infty} \frac{1}{T} \sum_{n=0}^{T-1} \ln M'(x_n) $	نمای لیاپانوف	غیرخطی
M: یک عدد ثابت P: دنباله‌ی احتمال سیگنال	$RE = \frac{1}{1-M} \log \left(\sum_{i=1}^n P_i^m \right)$	آنتروپی شانون	غیرخطی
N: تعداد نمونه‌ها r: یک نقطه در فضای فاز θ: تابع پله P: احتمال درستی فرضیه m: نقطه مورد نظر	$C(r) = \frac{\sum_{i=1}^N \theta(r - p(x_i, x_j))}{\frac{1}{2} N(N-1)}$ $P(x_i, x_j) = \sqrt{\sum_{k=1}^m (x_i(k) - x_j(k))^2}$	بعد همبستگی	غیرخطی
N' = N - 1 d: میزان مسطح بودن منحنی L: طول منحنی	$D = \frac{\log_{10}(N')}{\log_{10}\left(\frac{d}{L}\right) + \log_{10}(N')}$	بعد فرکتال	غیرخطی
S: زیرمجموعه‌ای از فضای حالت n: تعداد کل نمونه‌ها	$\tau(\tau) = \frac{1}{N-\tau} \sum_{n=\tau+1}^N (S_n - S_{n-\tau})^3$	برگشت‌پذیری زمان	غیرخطی

در روش SVM ویژگی‌های هر گروه توسط خط یا ابرصفحه از هم جدا می‌شوند. بهترین خط یا صفحه جداکننده وقتی ایجاد می‌شود که بیشترین فاصله یا مرز را با ویژگی‌های گروه‌ها داشته باشد [۱۸]. برای این که SVM بتواند داده‌های با پیچیدگی بالا را دسته‌بندی کند، داده‌ها در ابتدا توسط تابع هسته به فضایی با ابعاد بالاتر منتقل می‌شوند. برخی از مهم‌ترین توابع هسته عبارتند از: تابع چندجمله‌ای^{۳۵}، تابع گاوسی^{۳۶} یا پایه شعاعی^{۳۷} (RBF) و تابع تانژانت هیپربولیک^{۳۸} که برای مسایل طبقه‌بندی مورد استفاده قرار می‌گیرند. برای مجموعه آموزشی مفروض با ترکیب زوج‌های ورودی و خروجی (x_i, y_i) مسئله بهینه‌سازی مطابق رابطه (۱) و شرط رابطه (۲) حل می‌شود [۱۹،۲۰].

$$\min_{\omega, b, \xi} \frac{1}{2} \omega^T \omega + c \sum_{i=1}^n \xi_i \quad (1)$$

$$y_i (\omega^T \phi(x_i) + b) \geq 1 - \xi_i \quad (2)$$

که $\xi_i \geq 0$ مقدار خطا یا طبقه‌بندی نادرست x_i را اندازه‌گیری می‌کند. C پارامتر جبران‌کننده برای بخش خطا و ω بردار نرمال صفحه‌ی جداکننده است.

روش طبقه‌بندی kNN بر مبنای فاصله داده‌ها عمل می‌کند. در این روش، داده ناشناخته به گروهی نسبت داده می‌شود که تعداد بیشتری از داده‌های آن گروه در میان k تا از نزدیکترین همسایگانش وجود داشته باشند [۲۰، ۲۱]. اندازه‌گیری فاصله بر اساس توابعی چون فاصله اقلیدسی^{۴۹}، فاصله ماهالونوبیس^{۴۰}، فاصله منهتن^{۴۱}، فاصله مینکووسکی^{۴۲} و غیره انجام می‌شود. به دلیل سادگی و سرعت محاسبات، طبقه‌بند kNN جزو محبوب‌ترین طبقه‌بندها است.

۳-۴-۲- درخت تصمیم

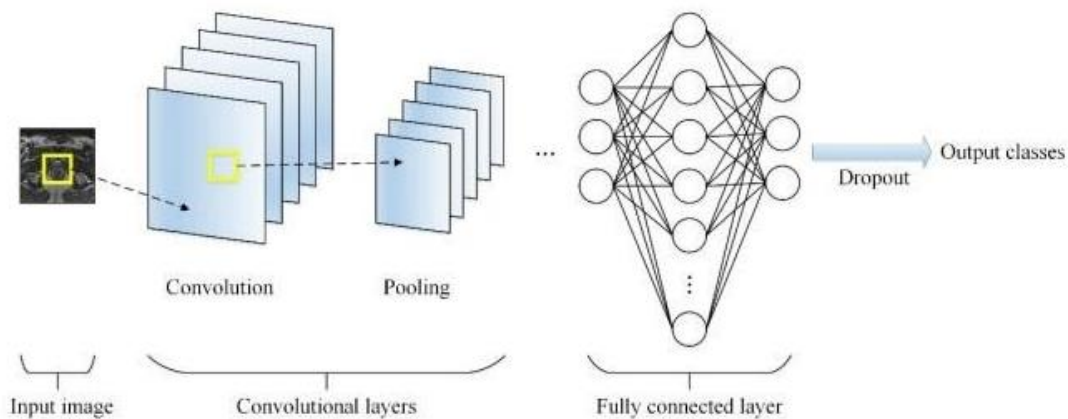
درخت تصمیم دانش را به شکل درخت به دست می‌آورد؛ که می‌تواند به عنوان مجموعه‌ای از قوانین گسسته بازنویسی شود تا درک آن آسان‌تر شود. مزیت اصلی طبقه‌بندی‌کننده DT، توانایی آن در استفاده از زیرمجموعه‌های ویژگی‌ها و قوانین تصمیم‌گیری در مراحل مختلف طبقه‌بندی است. یک درخت تصمیم کلی از یک گره ریشه، تعدادی گره داخلی و برگ و شاخه‌ها تشکیل شده است. گره برگ نشان دهنده گروهی است که باید به یک نمونه اختصاص داده شود. هر گره داخلی درخت مربوط به یک ویژگی است؛ و شاخه‌ها نشان دهنده ترکیبی از ویژگی‌هایی است که به آن طبقه‌بندی‌ها منجر می‌شود [۲۲].

۴-۴-۲- شبکه عصبی مصنوعی

در یادگیری ماشین، شبکه‌های عصبی مصنوعی مدل‌هایی هستند که از ساختار سیستم عصبی انسان تقلید می‌کنند و الگوهای ذاتی در مشاهدات را یاد می‌گیرند. آموزش عمیق حوزه جدیدی از تحقیقات آموزش ماشین است که با هدف نزدیک کردن یادگیری ماشین به یکی از اهداف اصلی خود یعنی هوش مصنوعی معرفی شده است. یادگیری عمیق با یک مرحله یادگیری، به جای این‌که داده‌ها را به طور دستی پردازش کند، ویژگی استخراج شود و سپس بردارهای ویژگی طبقه‌بندی شوند، فقط به مجموعه‌ای از داده‌ها با پردازش جزئی نیاز دارد. یادگیری عمیق می‌تواند به عنوان شبکه‌های عصبی مصنوعی پیشرفته در نظر گرفته شود؛ زیرا ساخت شبکه‌هایی با چند لایه (بیش از دو) را امکان‌پذیر می‌کند. هنگامی که تعداد نمونه‌های موجود در مرحله آموزش زیاد است، روش‌های یادگیری عمیق بسیار مؤثر است. به عنوان مثال در رابطه با مطالعات خواب که با حجم زیادی از داده‌ها روبه‌رو هستیم، روش یادگیری عمیق می‌تواند بسیار مفید باشد [۲۳]. یادگیری عمیق توانایی طبقه‌بندی مقادیر زیادی از داده‌های دارای برچسب را دارد. اما یادگیری عمیق به قدرت محاسباتی قابل توجهی نیاز دارد.

۵-۴-۲- شبکه عصبی کانولوشنی

شبکه‌های عصبی در ابتدا با یک لایه پنهان و با تعداد محدودی از نورون‌ها در لایه بودند. این شبکه‌ها به دلیل محدودیت‌هایی که یک لایه در جداسازی داده‌ها ایجاد می‌کرد، معمولاً قادر به آموزش داده‌های غیرخطی نبودند و فقط برای داده‌های خطی کاربرد داشتند. در نسل جدید شبکه‌های عصبی با آموزش عمیق، تعداد زیادی لایه پنهان وجود دارد. بنابراین برای داده‌های با ابعاد بالا کارایی مناسبی دارند. CNN از جمله شبکه‌های مبتنی بر یادگیری عمیق هستند که در آن‌ها چندین لایه با روشی قدرتمند آموزش می‌بینند. معماری یک CNN در شکل (۱) نمایش داده شده است [۲۴، ۲۵]. به طور کلی یک CNN از سه لایه اصلی شامل لایه کانولوشن^{۴۳}، لایه پولینگ^{۴۴}، و لایه تماماً متصل^{۴۵} تشکیل می‌شود که هر کدام وظایف مختلفی را انجام می‌دهند. در هر CNN دو مرحله برای آموزش شامل تغذیه رو به جلو^{۴۶} و مرحله پس انتشار^{۴۷} وجود دارد. در مرحله اول سیگنال ورودی به شبکه تغذیه می‌شود و این عمل چیزی جز ضرب نقطه‌ای بین ورودی و پارامترهای هر نورون و در نهایت اعمال عملیات کانولوشن در هر لایه نیست. سپس خروجی شبکه محاسبه می‌شود. در اینجا به منظور تنظیم پارامترهای شبکه و یا به عبارت دیگر همان آموزش شبکه، از نتیجه خروجی جهت محاسبه میزان خطای شبکه استفاده می‌شود. در مرحله بعدی بر اساس میزان خطای محاسبه شده مرحله پس انتشار آغاز می‌شود. در این مرحله گرادینان هر پارامتر با توجه به قاعده زنجیره‌ای محاسبه می‌شود؛ و تمامی پارامترها با توجه به تاثیری که بر خطای ایجاد شده در شبکه دارند تغییر پیدا می‌کنند.



شکل (۱): معماری یک شبکه عصبی کانولوشنی [۲۴]

Figure (1): Structure of a convolutional neural network [24]

بعد از به‌روز شدن پارامترها مرحله بعدی تغذیه رو به جلو شروع می‌شود. بعد از تکرار تعداد مناسبی از این مراحل، آموزش شبکه پایان می‌یابد. جدول (۲) رابطه‌های مورد استفاده در مراحل مختلف CNN را ارائه می‌کند. در رابطه‌های جدول (۲) z^l لایه کانولوشن یا لایه‌های فیلتر است. h ماتریس ورودی و ویژگی، w ضرایب وزن است که به صورت تصادفی انتخاب می‌شود. h_{xy} ماتریس ویژگی ورودی بعد از لایه کانولوشن و (x,y) سطر و ستون ماتریس ویژگی هستند. z_i خروجی لایه تماماً متصل و z_i خروجی لایه i قبل از مرحله سافت مکس است.

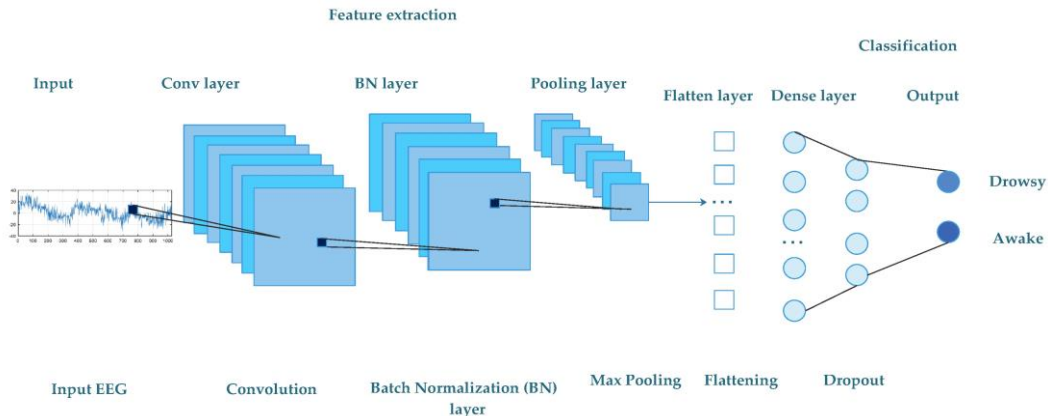
۱-۵-۴-۲- لایه‌های CNN

در حالت کلی، یک CNN همانطور که در شکل (۲) نمایش داده شده، یک شبکه عصبی سلسله مراتبی است که لایه‌های کانولوشن آن به صورت یک در میان با لایه‌های پولینگ قرار گرفته و بعد از آن‌ها، تعدادی لایه تماماً متصل وجود دارد. - لایه کانولوشن: در این لایه، CNN از هسته‌های مختلف برای کانال کردن سیگنال ورودی و همینطور نگاشت ویژگی‌های میانی استفاده می‌کند؛ به این ترتیب نگاشت‌های مختلفی از ویژگی‌ها ایجاد می‌کند. انجام عملیات کانولوشن فوایدی از جمله کاهش تعداد پارامترها و یادگیری ارتباط بین ویژگی‌های همسایه را داراست. - لایه پولینگ: یک لایه پولینگ معمولاً بعد از یک لایه کانولوشن قرار می‌گیرد و از آن برای کاهش اندازه نگاشت ویژگی‌ها و پارامترهای شبکه می‌توان استفاده کرد. همانند لایه‌های کانولوشن، لایه‌های پولینگ به دلیل در نظر گرفتن داده‌های همسایه در محاسبات خود، نسبت به تغییر مکان بی‌تغییر هستند [۲۹]. پیاده‌سازی لایه پولینگ با استفاده از تابع ماکزیمم‌گیری و تابع میانگین‌گیری از رایج‌ترین پیاده‌سازی‌ها است.

Table (2): Formulas of different stages of convolutional neural network [26,27]

جدول (۲): فرمول‌های مراحل مختلف شبکه عصبی کانولوشنی [۲۶،۲۷]

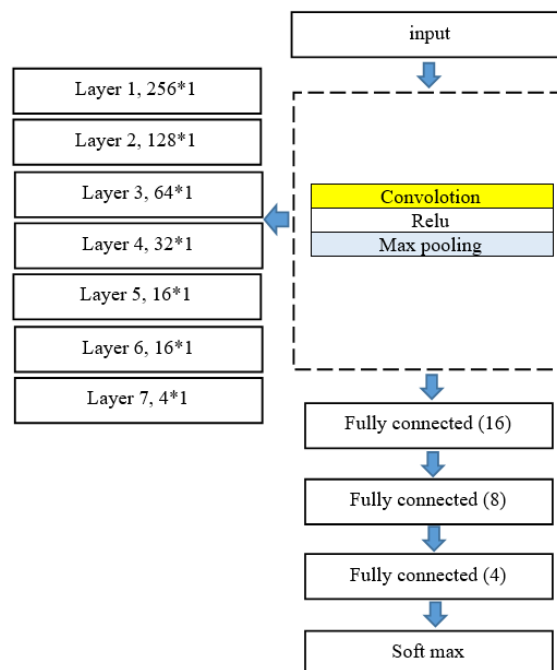
مراحل	فرمول
پیچیدگی	$z^l = h^{l-1} * w^l$
ماکس پولینگ	$h_{xy}^l = \max_{i=0..s, j=0..s} h^{l-1}(x+i)(y+J)$
لایه کاملاً متصل	$z_i = w_i * h_{i-1}$
یکسو کننده	$Re lu(z_i) = \max(0, z_i)$
سافت مکس	$Soft.Max(z_i) = e^{z_i} / \sum_j e^{z_j}$



شکل (۲): نمودار شبکه عصبی کانولوشنی پیشنهادی [۲۸]
Figure (2): Diagram of the proposed convolutional neural network [28]

- لایه تماماً متصل: بعد از آخرین لایه پولینگ، لایه‌های تماماً متصل وجود دارند که نداشت ویژگی‌ها را به بردار ویژگی یک بعدی انجام می‌دهند. لایه‌های تماماً متصل همانند هم‌تایان خود در شبکه‌های عصبی مصنوعی سنتی عمل می‌کنند و تقریباً ۹۰ درصد پارامترهای یک CNN را شامل می‌شوند. لایه تماماً متصل به ما این امکان را می‌دهد تا نتیجه شبکه را در قالب یک بردار با اندازه مشخص ارایه کرده و برای دسته‌بندی سیگنال‌ها یا ادامه پردازش‌ها به کار ببریم. تغییر ساختار لایه‌های تماماً متصل، رایج نیست. اما یک مورد در روش آموزش منتقل شده^{۴۸} انجام شد. به این ترتیب که در آن پارامترهای فراگرفته شده توسط شبکه حفظ شده اما لایه تماماً متصل آخر با دو لایه تماماً متصل جایگزین شد تا شبکه به این ترتیب بتواند با فعالیت‌های تشخیصی جدید انطباق پیدا کند.

مشکل بزرگ این نوع لایه‌ها این است که دارای تعداد بسیار زیادی پارامترند که نتیجه این امر هزینه پردازشی بسیار بالاست که در زمان آموزش بایستی صرف شود. بنابراین یک روش که معمولاً به کار برده می‌شود و نتایج رضایت بخشی نیز دارد این است که یا کلاً این لایه‌ها حذف شوند و یا تعداد اتصالات در این لایه‌ها توسط روش‌هایی کاهش یابد [۳۰]. شکل (۳) ساختار CNN طراحی شده در این مطالعه را نشان می‌دهد.



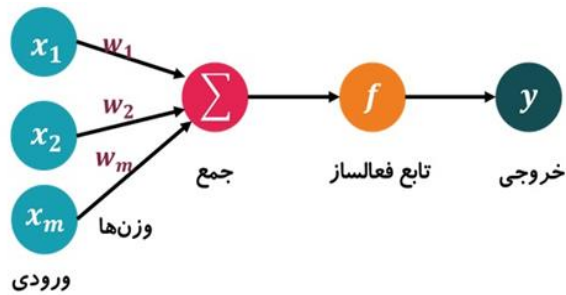
شکل (۳): شبکه عصبی کانولوشنی طراحی شده در این مطالعه
Figure (3): Designed convolutional neural network in this study

۲-۵-۴-۲- ساختار سلول عصبی مصنوعی

خروجی هر نورون با جمع وزن دار ورودی‌ها به آن نورون برابر است. نورون‌ها باید توانایی جداسازی دو کلاس را از هم داشته باشند و این دقیقاً چیزی است که ما از یک شبکه عصبی انتظار داریم. تابع فعال‌ساز^{۴۹} در شبکه عصبی بعد از بلوک جمع در نورون مصنوعی قرار می‌گیرد. یعنی پس از جمع ورودی‌ها، نتیجه از یک تابع فعال‌ساز عبور می‌کند. شکل (۴) ساختار یک سلول عصبی مصنوعی نمونه را نشان می‌دهد. تابع فعال‌ساز خطی ورودی را به خودش نگاشت می‌کند. در واقع یک تابع فعال‌ساز خطی، هیچ تغییری روی ورودی ایجاد نمی‌کند. این تابع از دو طرف بی‌کران است و خاصیت غیرخطی در نورون مصنوعی ایجاد نمی‌کند. پس تابع فعال‌ساز خطی مطلوب ما نیست. به‌همین دلیل توابع فعال‌ساز غیرخطی به‌وجود آمدند. تابع فعال‌ساز سیگموئید و تابع فعال‌ساز تانژانت، از توابع غیرخطی هستند. سیگموئید یک تابع فعال‌ساز کران‌دار، اکیدا صعودی و همواره مثبت است. این تابع ورودی‌های خود را به بازه‌ی صفر و یک نگاشت می‌کند. تابع تانژانت نیز کران‌دار و اکیدا صعودی است. تابع تانژانت، ورودی‌های خود را به بازه -1 و $+1$ نگاشت می‌کند. در دو تابع سیگموئید و تانژانت، خروجی‌ها محدود به یک بازه شدند. یکی دیگر از خصوصیات که یک تابع فعال‌ساز باید داشته باشد، محدود کردن خروجی است. یکی از پرستفاده‌ترین توابع، تابع فعال‌ساز خطی یکسوسده^{۵۰} (ReLU) است. این تابع از یک طرف بی‌کران و صعودی است. تابع ReLU ورودی‌های کوچک‌تر از صفر را به صفر و ورودی‌های بزرگتر از صفر را به خودش نگاشت می‌کند. علاوه بر تابع فعال‌ساز پارامتر دیگری نیز به نورون مصنوعی اضافه می‌شود و آن بایاس نام دارد. بایاس یک عدد ثابت است که مستقیم به تابع فعال‌ساز وارد می‌شود. بایاس از صفر شدن خروجی وقتی ورودی‌های یک نورون صفر باشند، جلوگیری می‌کند. این صفر در شبکه عصبی منتشر می‌شود و در این صورت یادگیری شبکه با مشکل مواجه می‌شود. به‌علاوه بایاس به تابع فعال‌ساز انعطاف می‌دهد. یعنی تابع فعال‌ساز می‌تواند جایجا شود و این در انجام بهتر یادگیری کمک خواهد کرد.


۳- نتایج و بحث

در این مطالعه، هدف ارزیابی شبکه‌های عصبی کانولوشنی با بهره‌گیری از مزیت یادگیری عمیق برای شناسایی حالت‌های احساسی از روی الگوهای سیگنال EEG است. همچنین عملکرد شبکه با سایر روش‌های طبقه‌بندی رایج مورد مقایسه و تحلیل قرار خواهد گرفت. در گام اول این پژوهش، سیگنال‌های EEG پایگاه داده DEAP به‌منظور کاهش نویز و اثرات تداخلی همانطور که اشاره شد در معرض فیلترینگ فرکانسی و زمان-فرکانس با تبدیل موجک قرار داده می‌شوند. برای سیگنال‌های آماده‌سازی شده با توجه به ماهیت تصادفی و غیرایستای سیگنال، پنجره‌گذاری زمانی و در بازه‌های زمانی ۱۰ ثانیه‌ای انجام می‌شود [۳۱]. شکل (۵) نتایج مربوط به اعمال فیلترینگ بر سیگنال خام را ارائه می‌کند. لازم به‌ذکر است محور عمودی ولتاژ و محور افقی زمان است. سیگنال برای مدت زمان یک بخش یعنی ۱۰ ثانیه نمایش داده شده است. نمودار اول از بالا سیگنال خام، نمودار دوم سیگنال بعد از اعمال فیلتر میان‌گذر، نمودار سوم سیگنال بعد از اعمال فیلتر موجک و نمودار چهارم تفاضل سیگنال خام از سیگنال فیلتر شده بعد از دو مرحله فیلترینگ است. این نمودار نمایانگر حذف الگوهای فرکانس بالا توسط فیلتر میان‌گذر و حذف الگوهای نامشخص و فرکانس پایین به‌وسیله‌ی فیلتر موجک است. همچنین شکل (۶) آنالیز طیفی نمونه‌ای از سیگنال EEG به‌کار رفته با استفاده از تبدیل فوریه سیگنال را نشان می‌دهد. محور عمودی اندازه پاسخ فرکانس ناشی از تبدیل فوریه و محور افقی فرکانس از ۰ تا ۷۰ هرتز است. نمودار اول از بالا سیگنال خام با محدوده‌ی فرکانسی صفر تا ۶۵ هرتز است. نمودار دوم سیگنال بعد از اعمال فیلتر میان‌گذر است که با توجه به محدوده‌ی فرکانسی در نظر گرفته شده، به بازه ۰ تا ۴۵ هرتز کاهش یافته است. همچنین نمودار سوم، اندازه تابع فرکانسی سیگنال بعد از اعمال فیلتر موجک را نمایش می‌دهد. ویژگی‌های مختلف خطی و غیرخطی شامل: چولگی، کشیدگی، پارامترهای جورث، نمای لیاپانف، آنتروپی شانون، بعد همبستگی، بعد فرکتال و برگشت‌پذیری زمان، برای سیگنال‌های EEG پنجره‌گذاری شده محاسبه شدند. در یک ارزیابی، داده‌های پردازش شده با ابعاد ماتریس ویژگی $۱۲۸۰ * ۴۸$ و طبقه‌بندی‌کننده‌های رایج مانند SVM، KNN و DT و طبقه‌بند CNN به‌منظور شناسایی احساسات به‌کار گرفته شدند. همچنین در یک بررسی، سیگنال فقط پیش‌پردازش شده با ابعاد ماتریس $۳۲۲۵۶ * ۱۲۸۰$ به یک CNN اعمال شدند.



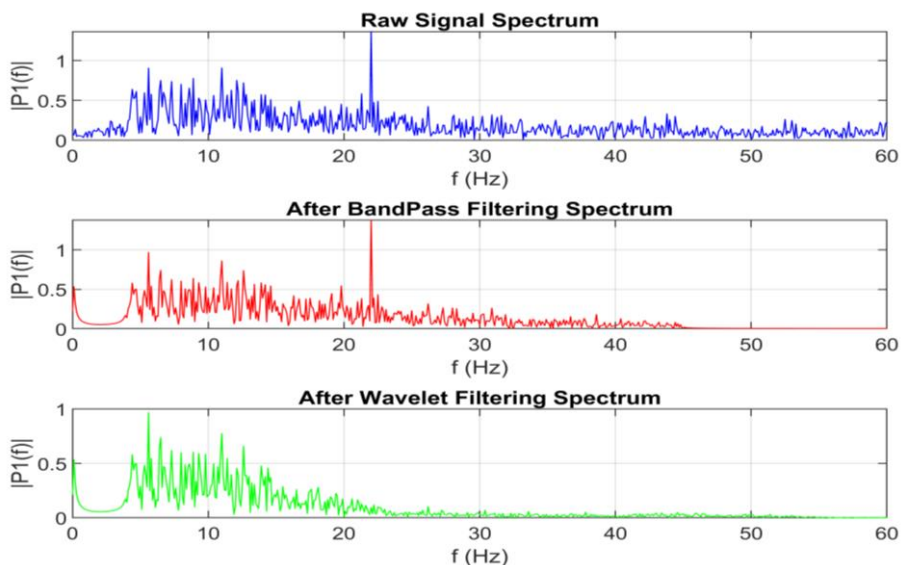
شکل (۴): یک سلول عصبی مصنوعی

Figure (4): An artificial neuron



شکل (۵): نمایش سیگنال بعد از اعمال مراحل فیلترینگ

Figure (5): Display of the signal after applying the filtering steps



شکل (۶): نمایش تابع دامنه سیگنال در حوزه فرکانس بعد از اعمال مراحل مختلف فیلترینگ

Figure (6): Display of the signal amplitude function in the frequency domain after applying different stages of filtering

شبکه مورد استفاده شامل ۷ لایه پنهان و ۳ لایه تماماً متصل با تابع فعالساز ReLU و نرخ یادگیری 0.001 است. جدول (۳) مشخصات روش‌های طبقه‌بندی استفاده شده را ارائه می‌کند. تمامی شبیه‌سازی‌ها تحت نرم‌افزار متلب ۲۰۲۰ انجام شده است.

به‌منظور اعتبارسنجی نتایج، از روش k لایه^{۵۲} با مقدار k برابر ۵ استفاده می‌شود. عملکرد روش‌های طبقه‌بندی به‌وسیله ماتریس درهم ریختگی و محاسبه معیارهای صحت، حساسیت و معین‌پذیری ارزیابی می‌شود. معیارهای صحت، حساسیت و معین‌پذیری با رابطه‌های زیر محاسبه می‌شوند [۳۲،۳۳].

$$\text{accuracy} = \frac{TP + TN}{TP + FP + FN + TN} \quad (۳)$$

$$\text{specificity} = \frac{TN}{TN + FP} \quad (۴)$$

$$\text{sensitivity} = \frac{TP}{TP + FN} \quad (۵)$$

که TP بیانگر کلاس‌های هدف درست طبقه‌بندی شده، TN کلاس‌های غیرهدف درست طبقه‌بندی شده، FP کلاس‌های هدف به اشتباه طبقه‌بندی شده و FN کلاس‌های غیرهدف به اشتباه طبقه‌بندی شده است. در بهترین حالت ممکن که تمامی نتایج به‌درستی تشخیص داده شده باشند، مقدار سه پارامتر صحت، حساسیت و معین‌پذیری یک می‌شود. بنابراین نزدیک شدن هرچه بیشتر مقدار این سه پارامتر به مقدار یک، بیانگر نزدیک شدن پاسخ به حالت ایده‌آل است. جدول (۴) نتایج مربوط به طبقه‌بندی احساسات با استفاده از سیگنال EEG با تمامی باندهای فرکانسی برای طبقه‌بندهای SVM، kNN و DT را ارائه می‌کند. لازم به‌ذکر است تمامی ویژگی‌های استخراج شده به طبقه‌بندها اعمال شده‌اند. همچنین جدول (۵) نتایج مربوط به طبقه‌بندی احساسات با استفاده از سیگنال EEG با تمامی باندهای فرکانسی با استفاده از CNN را نشان می‌دهد. در این حالت یکبار ویژگی‌های خطی و غیرخطی از سیگنال‌های پردازش شده و در ارزیابی دیگر سیگنال‌های خام به شبکه اعمال می‌شوند. شکل (۷) نمودار مربوط به گرادین کاهشی و افزایش صحت طبقه‌بندی را در حین طبقه‌بندی با استفاده از داده‌های پردازش شده نشان می‌دهد. همان‌طور که در شکل مشاهده می‌شود، خطای طبقه‌بند در طول ۲۵۰ تکرار به مرور به پایین‌ترین سطح خود رسیده و این بیانگر توانایی طبقه‌بند است. همچنین این شکل نشان می‌دهد که شبکه عصبی در مینیمم‌های محلی متوقف نشده است.

Table (3): Specifications of the classification methods used

جدول (۳): مشخصات روش‌های طبقه‌بندهای مورد استفاده

نوع طبقه‌بند	مشخصات
ماشین بردار پشتیبان	با کرنل گوسی
k نزدیکترین همسایه	براساس فاصله اقلیدسی و k برابر ۳
درخت تصمیم	درخت تصمیم از نوع درشت با حداکثر انشعاب ۴
شبکه عصبی کانولوشنی	۷ لایه کانولوشن و ۳ لایه تماماً متصل با تابع فعال‌ساز ReLu

Table (4): The results obtained in the identification of emotional states by applying traditional classification methods


جدول (۴): نتایج به‌دست آمده در شناسایی حالت‌های احساسی با اعمال روش‌های طبقه‌بندی سنتی

نوع طبقه‌بند	حساسیت (درصد)	معین‌پذیری (درصد)	صحت
ماشین بردار پشتیبان	۹۱/۳	۹۰/۹	۹۴/۱
k نزدیکترین همسایه	۷۴/۱۷	۷۵/۸	۷۹/۶
درخت تصمیم	۷۳/۲	۷۱/۰	۷۶/۳

Table (5): The results obtained in the identification of emotional states using CNN for two different types of input

جدول (۵): نتایج به‌دست آمده در شناسایی حالت‌های احساسی با استفاده از CNN به ازای دو نوع ورودی مختلف

نوع شبکه	نوع داده	حساسیت (درصد)	معین‌پذیری (درصد)	صحت (درصد)
شبکه عصبی کانولوشنی	داده پیش پردازش شده	۷۱/۱	۶۸/۰۱	۷۰
	ویژگی‌های استخراج شده	۸۵/۱	۸۷/۸	۸۶



شکل (۷): پردازش داده‌ها در آموزش شبکه عصبی کانولوشنی

Figure (7): Data processing in convolutional neural network training, (a) loss function and (b) classification accuracy

مقایسه نتایج به‌دست آمده برای شناسایی احساسات توسط روش پیشنهادی با نتایج مطالعات گذشته که از مجموعه داده مشابه استفاده کرده‌اند، همان‌طور که در جدول (۶) ارائه شده، عملکرد مطلوب ساختارهای پیشنهادی را تایید می‌کند. ساختار شبکه عمیق برای شناسایی ۴ حالت احساسی میزان صحت ۸۶ درصد را کسب کرده است که نسبت به مطالعه مرجع [۳۴] که از شبکه‌های عصبی عمیق برای شناسایی همین تعداد حالت احساسی استفاده شده است، حدود ۱۰ درصد بهبود عملکرد را نشان می‌دهد. بدیهی است در صورتی که سیگنال‌های ورودی به شبکه عمیق در معرض مراحل آماده‌سازی دقیق‌تری قرار بگیرند، نتایج همچنان بهبود خواهند یافت. مراحل آماده‌سازی بر روی سیگنال با توجه به افزایش کیفیت سیگنال می‌تواند منجر به نتایج بهتری شود. کاهش بازه زمانی سیگنال EEG ورودی، استفاده از باندهای فرکانسی مشخص از سیگنال که مرتبط با میزان هیجان و ظرفیت احساس باشند، در کنار استفاده از روش‌های فیلترینگ کارآمد برای کاهش میزان نویزهای سیگنال، از جمله روش‌های آماده‌سازی ممکن سیگنال هستند. همچنین نتایج کسب شده با طبقه‌بند SVM موقعی که از ویژگی‌های دینامیکی استفاده می‌شود، نیز قابل ملاحظه است. بنابراین می‌توان نتیجه‌گیری کرد که برای سیگنال‌های تصادفی و غیرایستا مانند سیگنال EEG استفاده از روش‌های یادگیری عمیق یا استفاده از ویژگی‌های دینامیکی و غیرخطی با توجه به ماهیت آشوبی سیگنال به‌همراه طبقه‌بندهای سنتی می‌تواند نتایج مطلوبی کسب کند.

۱-۳- بحث

هدف از انجام این پژوهش بهبود تشخیص احساسات در سیگنال‌های EEG به‌وسیله یادگیری عمیق بوده است. نتایج کسب شده نشان داد که فیلترهای حوزه فرکانس در استخراج محدوده معنادار سیگنال و حفظ فاز خطی کارآیی لازم را دارند. همچنین استفاده از فیلتر بانک تبدیل موجک، منجر به کاهش نویز در محدوده فرکانسی موردنظر و استخراج زیرباندهای مختلف مغز در کنار اطلاعات زمانی می‌شود. بعد از انجام مراحل فیلترینگ و آماده‌سازی، دو مدل از سیستم تشخیص احساسات مورد ارزیابی قرار گرفته‌اند؛ که شامل استفاده از CNN به‌منظور بهره‌گیری از مزایای یادگیری عمیق در شناسایی حالت‌های احساسی و همچنین استفاده از ویژگی‌های غیرخطی و فرکانسی سیگنال‌ها به‌همراه روش‌های طبقه‌بندی سنتی مانند SVM، KNN و DT بود.

Table (6): Comparing the results of the system designed to identify emotional states in the present study with the results of previous studies that used the DEAP database

جدول (۶): مقایسه نتایج سیستم طراحی شده در شناسایی حالت‌های احساسی در مطالعه حاضر با نتایج مطالعات گذشته که از پایگاه داده DEAP استفاده کرده‌اند.

مرجع	سیگنال	پیش پردازش	تعداد ویژگی‌ها	نوع ویژگی‌ها	روش طبقه بند	تعداد حالات احساسی	صحت (درصد)
[۳۴]	EEG	فیلترگذاری فرکانسی ۴ تا ۴۵ هرتز	یک تصویر دوبعدی ۴۲ در ۲۰۰ پیکسل	نگاشت دوبعدی اسکالوگرام	CNN	۴ حالت احساسی	۷۶
[۳۵]	EEG	ندارد	یک آرایه سه بعدی ۹ در ۹ در ۴	زیرباندهای فرکانسی داده‌های خام	CNN-LSTM	۲ حالت برانگیختگی ظرفیت	۸۹/۴۵
[۳۶]	EEG	ندارد	یک آرایه سه بعدی ۶ در ۳۲ در ۱۲۸	زیرباندهای فرکانسی داده‌های خام و اختلاف توان زیرباندها	D-CNN3	۲ حالت برانگیختگی ظرفیت	۸۷/۴۴
[۳۷]	EEG	روش آنالیز مولفه-های مستقل	یک آرایه ۱۲ در ۳۲	استخراج منابع سیگنال از الکترودهای شش گانه ناحیه پیشانی برمبنای آنالیز مولفه-های مستقل	LSTM خودرمنگار	۲ حالت برانگیختگی ظرفیت	۷۴/۳۸
[۳۸]	EEG	ندارد	یک تصویر دوبعدی ۲۰۰ در ۲۰۰ در ۳	استخراج نگاشت دوبعدی (هولوگرام مپ) از ویژگی‌های زمانی، فرکانسی و غیر خطی	CNN	۲ حالت برانگیختگی ظرفیت	۷۷
روش پیشنهادی	EEG	فیلتر میان‌گذر و تبدیل موجک	۸	خطی و غیر خطی	SVM	۴ حالت احساسی	۹۴/۱
روش پیشنهادی	EEG	فیلتر میان‌گذر و تبدیل موجک	یک آرایه ۸*۱	خطی و غیر خطی	CNN	۴ حالت احساسی	۸۶

در مدل اول استفاده از سیگنال‌های باکیفیت و عاری از نویز در شبکه عصبی عمیق منجر به نتایج مطلوب در شناسایی حالت‌های احساسی مورد نظر می‌شود. در این حالت نیازی به مراحل استخراج و انتخاب ویژگی‌ها نیست و شبکه طراحی شده تنها با استفاده از اطلاعات خود سیگنال ورودی حالت مورد نظر را شناسایی می‌کند. در مسایل چندکلاسه زمان محاسبات به‌طور قابل توجه افزایش خواهد داشت. اما با این حال عملکرد سیستم و دقت شناسایی علیرغم زیاد بودن تعداد حالت‌ها مطلوب خواهد بود. به‌کار بردن سیگنال‌های با کیفیت و انجام مراحل آماده‌سازی، فیلترینگ و بخش‌بندی مطلوب، می‌تواند به‌طور قابل توجهی منجر به بهبود نتایج شبکه عمیق شود. در مدل دوم یعنی استفاده از طبقه‌بندهای سنتی، ویژگی‌های فرکانسی به دلیل این‌که در مقایسه با دیگر ویژگی‌ها نسبت به نویز مقاوم‌ترند و ویژگی‌های دینامیکی به‌دلیل این‌که ماهیت دینامیکی فعالیت مغز را منعکس می‌کنند و حاوی اطلاعات مطلوب‌تری هستند، عملکرد قابل قبولی آرایه می‌کنند. در این مدل SVM با کرنل غیرخطی و طبقه‌بند KNN با مقیاس ریز در طبقه‌بندی ویژگی‌ها، نتایج مطلوبی آرایه می‌کنند. مزیت استفاده از روش‌های طبقه‌بندی سنتی در این است که به پردازش کمتری نیاز دارند و سرعت پاسخ‌دهی آن‌ها در مقایسه با روش‌های یادگیری عمیق بیشتر

است. اما عملکرد آن‌ها بسیار به نوع و تعداد ویژگی‌های ورودی وابسته است. در صورتی‌که ویژگی‌های تعیین شده دقیق و حاوی اطلاعات مهم از سیگنال‌ها باشند، عملکرد طبقه‌بند در شناسایی حالت‌ها مطلوب خواهد بود.

۴- نتیجه‌گیری

در این مطالعه ساختاری برای سیستم تشخیص احساسات بر مبنای پردازش سیگنال EEG ارائه شد. در مطالعات پیشین در رابطه با شناسایی خودکار احساسات، دقت کم در تشخیص حالت‌های احساسی، حساس بودن روش‌های طبقه‌بندی به نویزها باعث کاهش عملکرد آنها شده است. در این پژوهش سعی شد تا با ارائه یک سیستم شناسایی احساسات کارآمد و کاربردی مبتنی بر شبکه‌های عصبی عمیق، معایب روش‌های پیشین تا حد امکان مرتفع گردد. سیگنال‌های EEG پایگاه داده DEAP پس از انجام مراحل پیش‌پردازش و کاهش نویز با فیلترگذاری حوزه‌ی فرکانس و حوزه زمان-فرکانس برای طراحی سیستم شناسایی احساسات به کار گرفته شدند. برای فیلتر حوزه زمان-فرکانس از تبدیل موجک دابلیو-نویز نوع چهارم با هشت سطح تجزیه و برای فیلترگذاری حوزه فرکانس از یک فیلتر میان‌گذر در محدوده ۴ تا ۴۵ هرتز با پاسخ ضربه محدود استفاده شد. برای سیگنال‌های آماده‌سازی شده، ویژگی‌های خطی و غیرخطی شامل میانگین و واریانس، پارامترهای جورث، نمای لیاپانف، آنتروپی شانون، بعد همبستگی، بعد فرکتال و برگشت‌پذیری زمان محاسبه شدند. با هدف ارزیابی نتایج شبکه‌های آموزش عمیق و سایر روش‌های رایج طبقه‌بندی، سه روش طبقه‌بندی SVM، kNN و DT به‌همراه CNN به‌منظور تشخیص احساسات و طبقه‌بندی داده‌ها به کار گرفته شدند. مجموعه ویژگی‌های استخراج شده به‌عنوان ورودی به ساختارهای طبقه‌بندی موردنظر و شبکه عصبی عمیق اعمال شدند. در ارزیابی دیگر سیگنال‌های EEG آماده‌سازی شده به‌عنوان ورودی شبکه عصبی عمیق در نظر گرفته شدند. با توجه به نتایج کسب شده، روش SVM با دقت ۹۴/۱ درصد بیشترین دقت طبقه‌بندی را برای شناسایی چهار حالت احساسی به‌دست آورد. همچنین CNN پیشنهادی با ورودی سیگنال‌های آماده‌سازی شده، با دقت ۸۶ درصد حالت‌های احساسی موردنظر را به‌طور مطلوبی شناسایی کرد. عملکرد شبکه آموزش عمیق در صورت استفاده از تعداد ویژگی‌های زیاد یا سیگنال‌های با کیفیت بهبود خواهد یافت؛ همچنین روش یادگیری عمیق با توجه به مقاوم بودن به نویز و پردازش خودکار مزیت‌های قابل توجهی نسبت به روش‌های طبقه‌بندی سنتی دارد.

References

مراجع

- [1] R. W. Picard, E. Vyzas, J. Healey, "Toward machine emotional intelligence: analysis of affective physiological state," *IEEE Trans. on Pattern Analysis and Machine Intelligence*, vol. 23, no. 10, pp. 1175-1191, Oct. 2001 (doi: 10.1109/34.954607).
- [2] H. Gunes, B. Schuller, M. Pantic, R. Cowie, "Emotion representation, analysis and synthesis in continuous space: A survey", *Proceedings of the IEEE/ICAFGR*, pp. 827-834, Santa Barbara, CA, USA, May 2011 (doi: 10.1109/FG.2011.5771357).
- [3] N. Dashti, M. Khezri, "Recognition of motor imagery based on dynamic features of EEG signals", *Journal of Intelligent Procedures in Electrical Technology*, vol. 11, no. 43, 13-27, December 2020 (in Persian) (doi: 20.1001.1.23223871.1399.11.43.2.5).
- [4] A. Tragoudaras, C. Antoniadis, Y. Massoud, "Enhancing DNN models for EEG/ECOG BCI with a novel data-driven offline optimization method", *IEEE Access*, vol. 11, pp. 35888-35900, April 2023 (doi: 10.1109/ACCESS.2023.3265040).
- [5] T. Hinterberger, N. Weiskopf, R. Veit, B. Wilhelm, E. Betta, N. Birbaumer, "An EEG-driven brain-computer interface combined with functional magnetic resonance imaging (fMRI)", *IEEE Trans. on Biomedical Engineering*, vol. 51, no. 6, pp. 971-974, June 2004 (doi: 10.1109/TBME.2004.827069).
- [6] I. Neuner, R. Rajkumar, C.R. Brambilla, S. Ramkiran, A. Ruch, L. Orth, E. Farrher, J. Mauler, C. Wyss, E.R. Kops, J. Scheins, L. Tellmann, M. Lang, J. Ermert, J. Dammers, B. Neumaier, C. Lerche, K. Heekeren, W. Kawohl, K.J. Langen, H. Herzog, N.J. Shah, "Simultaneous PET-MR-EEG: Technology, challenges and application in clinical neuroscience", *IEEE Trans. on Radiation and Plasma Medical Sciences*, vol. 3, no. 3, pp. 377-385, May 2019 (doi: 10.1109/TRPMS.2018.2886525).
- [7] M. Khezri, M. Jahed, "An inventive quadratic time-frequency scheme based on wigner-ville distribution for classification of sEMG signals", *Proceeding of the IEEE/TTAB*, pp. 261-264, Tokyo, Japan, Nov. 2007 (doi: 10.1109/ITAB.2007.4407397).

- [8] S. Koelstra, C. Muehl, M. Soleymani, J.S. Lee, A. Yazdani, T. Ebrahimi, T. Pun, A. Nijholt, I. Patras, "DEAP: A database for emotion analysis ;using physiological signals", IEEE Trans. on Affective Computing, vol. 3, no. 1, pp. 18-31, Jan./March 2012 (doi: 10.1109/T-AFFC.2011.15).
- [9] M. Ali, A.H. Mosa, F.A. Machot, K. Kyamakya, "EEG-based emotion recognition approach for e-healthcare applications", Proceeding of the ICUFN, pp. 946-950, Vienna, Austria, July 2016 (doi: 10.1109/ICUFN.20-16.7536936).
- [10] S. Liu, X. Wang, L. Zhao, J. Zhao, Q. Xin, S.H. Wang, "Subject-independent emotion recognition of EEG signals based on dynamic empirical convolutional neural network", IEEE Trans. on Computational Biology and Bioinformatics, vol. 18, no. 5, pp. 1710-1721, Sept./Oct. 2021 (doi: 10.1109/TCBB.2020.3018137).
- [11] H. Yang, J. Han, K.J.S. Min, "A multi-column CNN model for emotion recognition from EEG signals", Sensors, vol. 19, no. 21, p. 4736, Nov. 2019 (doi:10.3390/s19214736).
- [12] T. Song, W. Zheng, P. Song, Z. Cui, "EEG emotion recognition using dynamical graph convolutional neural networks", IEEE Trans. on Affective Computing, vol. 11, no. 3, pp. 532-541, July/Sept. 2020 (doi: 10.1109/TAFFC.2018.2817622).
- [13] J. Zhang, M. Chen, S. Hu, Y. Cao, R. Kozma, "PNN for EEG-based Emotion Recognition", Proceeding of the IEEE/ICSMC, pp. 002319-002323, Budapest, Oct. 2016 (doi: 10.1109/SMC.2016.7844584).
- [14] M. Bengalur, A. Saxena, "A systematic review on approaches to recognize emotions using electroencephalography (EEG) signals", Data Engineering Intelligent, pp. 107-120, May 2021 (doi: 10.1007/978-981-16-0171-2_11).
- [15] M.S. Aldayel, M. Ykhlef, A.N. Al-Naffjan, "Electroencephalogram-based preference prediction using deep transfer learning", IEEE Access, vol. 8, pp. 176818-176829, Sept. 2020 (doi: 10.1109/ACCESS.2020.302-7429).
- [16] P. Chrapka, H. Bruin, G. Hasey, J. Reilly, "Wavelet-based muscle artefact noise reduction for short latency rTMS evoked potentials", IEEE Trans. on Neural Systems and Rehabilitation Engineering, vol. 27, no. 7, pp. 1449-1457, July 2019 (doi: 10.1109/TNSRE.2019.2908951).
- [17] Z. Gu, G. Yan, J. Zhang, Y. Li, Z.L. Yu, "Automatic epilepsy detection based on wavelets constructed from data", IEEE Access, vol. 6, pp. 53133-53140, Sept. 2018 (doi: 10.1109/ACCESS.2018.2867642).
- [18] C. Cortes, V. Vapnik, "Support-vector networks", Machine Learning, vol. 20, no. 3, pp. 273-297, Sept. 1995.
- [19] C.A. Frantzidis, C. Bratsas, C.L. Papadelis, E. Konstantinidis, C. Pappas, P.D. Bamidis, "Toward emotion aware computing: an integrated approach using multichannel neurophysiological recordings and affective visual stimuli", IEEE Trans. on Information Technology in Biomedicine, vol. 14, no. 3, pp. 589-597, May 2010 (doi: 10.1109/TITB.2010.2041553).
- [20] S. Karimi-Shahraki, M. Khezri, "Identification of ADHD patients using wavelet-based features of EEG signals", Journal of Intelligent Procedures in Electrical Technology, vol. 12, no. 47, pp. 1-11, Dec. 2021 (in Persian) (dor: 20.1001.1.23223871.1400.12.3.1.1).
- [21] N.S. Altman, "An introduction to kernel and nearest-neighbor nonparametric regression", The American Statistician, vol. 46, no. 3, pp. 175-185, Aug. 1992 (doi: 10.2307/2685209).
- [22] F.Z. Salmam, A. Madani, M. Kissi, "Facial expression recognition using decision trees", Proceeding of the IEEE/CGiV, pp. 125-130, Beni Mellal, Morocco, March 2016 (doi: 10.1109/CGiV.2016.33).
- [23] D. Shen, G. Wu, H.I. Suk, "Deep learning in medical image analysis", Annual Review of Biomedical Engineering, vol. 19, pp. 221-248, June 2017 (doi: 10.1146/annurev-bioeng-071516-044442).
- [24] P. Dutta, P. Upadhyay, M. De, R.G. Khalkar, "Medical image analysis using deep convolutional neural networks: CNN architectures and transfer learning", Proceeding of the IEEE/ICICT, pp. 175-180, Coimbatore, India, Deb. 2020 (doi: 10.1109/ICICT48043.2020.9112469).
- [25] M. Torabian, H. Pourghassem, H. Mahdavi-Nasab, P. Sanaee, "Fire detection based on extraction of spatio-temporal features by convolutional neural networks and fractal analysis", Journal of Intelligent Procedures in Electrical Technology, vol. 15, no. 60, pp. 71-86, March 2025 (in Persian).
- [26] D.P. Sudharshan, R.N. Vismaya, "Handwritten signature verification system using deep learning", Proceeding of the IEEE/ICDSIS, pp. 1-5, Hassan, India, Oct. 2022 (doi: 10.1109/ICDSIS55133.2022.9915833).
- [27] I. Shahin, A.B. Nassif, S. Hamsa, "Emotion recognition using hybrid gaussian mixture model and deep neural network", IEEE Access, vol. 7, pp. 26777-26787, Feb. 2019 (doi: 10.1109/ACCESS.2019.2901352).
- [28] S. Chaabene, B. Bouaziz, A. Boudaya, A. Hökelmann, A. Ammar, L. Chaari, "Convolutional neural network for drowsiness detection using EEG signals", Sensors, vol. 21, no.5, pp.1734. March. 2021 (doi: 10.3390/s21051734).
- [29] D. Yu, H. Wang, P. Chen, Z. Wei, "Mixed pooling for convolutional neural networks", Proceeding of the Springer/ICRSKT, pp. 364-375, Shanghai, China, Oct. 2014 (doi: 10.1007/978-3-319-11740-9_34).

- [30] H. Nakahara, T. Fujii, S. Sato, "A fully connected layer elimination for a binarized convolutional neural network on an FPGA", *Proceeding of the IEEE/FPL*, pp. 1-4, Ghent, Belgium, Sept. 2017 (doi: 10.23919/FPL.2017.8056771).
- [31] N. Behzadfar, "A brief overview on analysis and feature extraction of electroencephalogram signals", *Signal Processing and Renewable Energy*, vol. 6, no. 1, pp. 39-64, March 2022 (doi: 20.1001.1.25887327.2022.6-1.3.9).
- [32] M. Dorvashi, N. Behzadfar, G. Shahgholian, "An efficient method for classification of alcoholic and normal electroencephalogram signals based on selection of an appropriate feature", *Journal of Medical Signals and Sensors*, vol.13, no. 1, pp. 11-20, March 2023 (doi: 10.4103/jmss.jmss_183_21).
- [33] M. Dorvashi, N. Behzadfar, G. Shahgholian, "Classification of alcoholic and non-alcoholic individuals based on frequency and non-frequency features of electroencephalogram signal", *Iranian Journal of Biomedical Engineering*, vol. 14, no. 2, pp. 121-130, July 2020 (doi: 10.22041/ijbme.2020.119841.1551).
- [34] Y.H. Kwon, S.B. Shin, S.D. Kim, "Electroencephalography based fusion two-dimensional (2D)-convolution neural networks (CNN) model for emotion recognition system", *Sensors*, vol. 18, no. 5, pp. 1383, May 2018 (doi: 10.3390/s18051383).
- [35] Y. Yang, Q. Wu, Y. Fu, X. Chen, "Continuous convolutional neural network with 3D input for EEG-based emotion recognition", *Proceeding of the Springer/ICNIP*, pp. 433-443, Siem Reap, Cambodia. Dec. 2018 (doi: 10.1007/978-3-030-04239-4_39).
- [36] E. S. Salama, R. A. El-Khoribi, M. E. Shoman, M. A. W. Shalaby, "EEG-based emotion recognition using 3D convolutional neural networks", *International Journal of Advanced Computer Science Applications*, vol. 9, no. 8, pp. 329-337, Sept. 2018 (doi: 10.14569/IJACSA.2018.090843).
- [37] X. Xing, Z. Li, T. Xu, L. Shu, B. Hu, X. Xu, "SAE+LSTM: A New framework for emotion recognition from multi-channel EEG", *Frontiers in Neurorobotics*, vol. 13, Article Number: 37, June. 2019 (doi: 10.3389/fnbot.2019.00037).
- [38] A. Topic, M. Russo, "Emotion recognition based on EEG feature maps through deep learning network", *Engineering Science Technology, an International Journal*, vol. 24, no. 6, pp. 1442-1454, Dec.2021 (doi: 10.1016/j.jestch.2021.03.012).

زیر نویس‌ها

- | | |
|--|----------------------------------|
| 1. Galvanic skin response | 26. Skewness |
| 2. Electromyography | 27. Kurtosis |
| 3. Heart rate | 28. Hjorth parameters |
| 4. Respiration rate | 29. Lyapunov exponent |
| 5. Electroencephalogram | 30. Shannon entropy |
| 6. Electrocardiogram | 31. Correlation dimension |
| 7. Magnetic resonance imaging | 32. Fractal dimension |
| 8. Positron emission tomography | 33. Time reversibility |
| 9. Dynamical empirical convolutional neural networks | 34. Deep learning |
| 10. Empirical mode decomposition | 35. Polynomial kernel |
| 11. SJTU emotion EEG dataset | 36. Gaussian kernel |
| 12. Convolutional neural networks | 37. Radial basis function Kernel |
| 13. Convolutional neural network using dynamical graph | 38. Hyperbolic tangents |
| 14. Support vector machines | 39. Euclidean distance |
| 15. K-nearest neighbors | 40. Mahalanobis distance |
| 16. Decision tree | 41. Manhattan distance |
| 17. A dataset for emotion analysis using physiological signals | 42. Minkowski distance |
| 18. Electrocardiogram | 43. Convolution Layer |
| 19. Electrooculogram | 44. Pooling layer |
| 20. Skin conductance | 45. Fully connected layer |
| 21. Photoplethysmography | 46. Feed forward |
| 22. Butterworth bandpass filter | 47. Backpropagation |
| 23. Finite impulse response | 48. Transferred learning |
| 24. Wavelet Transform | 49. Activation function |
| 25. Daubechies wavelet | 50. Rectified linear unit |
| | 51. Learning rate |
| | 52. K-fold cross validation |