



EEG-Based Emotional State Recognition using Deep Learning Network

Zahedi Haghighi, S. Saeide¹ / Sakhaei, S. Mahmoud^{2*} / Daliri, Mohammad Reza³

¹ - M.Sc. Student, Bioelectric Department, Electrical & Computer Engineering Faculty, Babol Noshirvani University of Technology, Babol, Iran

² - Assistant Professor, Bioelectric Department, Electrical & Computer Engineering Faculty, Babol Noshirvani University of Technology, Babol, Iran

³ - Professor, Electrical Engineering Department, Iran University of Science and Technology, Tehran, Iran

ARTICLE INFO

DOI: 10.22041/IJBME.2019.97535.1419

Received: 12 November 2018

Revised: 28/6/2019-16/8/2019

Accepted: 20 August 2019

KEYWORDS

EEG
Empirical Mode
Decomposition
Emotion Recognition
Deep Learning Network


ABSTRACT

Emotion is one of the most important human quality that plays an important role in life. Also, one way of communicating between human and computer is based on emotion recognition. One way of emotion recognition is based on electroencephalographic signal (EEG). In this paper, according to the non-stationary property of EEG, intrinsic mode functions (IMF) extracted by using empirical mode decomposition (EMD) and then first 3 IMFs selected. Each IMF converts into smaller pieces with a one-second window and power feature has been extracted from each piece. Then, by using a suitable mapping, the position of the electrodes in the 10-20 system becomes the position of the pixels in the picture. The extracted features are considered as pixel color components. To determine the class of valence, the set of all generated pictures is given as input to a deep learning network and output determine the high or low class of valence. The same process is used to determine the class of arousal. To examining the method, the DEAP dataset is used. By choosing 17×17 for the image size, the mean accuracy and standard deviation were obtained of 78.58% and 3.9 for the valence and 78.66% and 3.1 for the arousal which that shows a significant improvement compared to similar tasks.

*Corresponding Author

Address	Bioelectric Department, Electrical & Computer Engineering Faculty, Noshirvani University of Technology, Babol, Iran		
Postal Code	47148-71167	Tel	+98-11-35501426
E-Mail	smsakhaei@nit.ac.ir	Fax	+98-11-32339214





تشخیص حالت‌های احساسی مبتنی بر EEG با استفاده از شبکه‌ی یادگیری عمیق

زاهدی حقیقی، سیده سعیده^۱ / سخایی، سید محمود^{۲*} / دلیری، محمدرضا^۳

^۱ - دانشجوی کارشناسی ارشد مهندسی پزشکی، گروه بیوالکتریک، دانشکده‌ی مهندسی برق و کامپیوتر، دانشگاه صنعتی نوشیروانی بابل، بابل، ایران

^۲ - استادیار، گروه بیوالکتریک، دانشکده‌ی مهندسی برق و کامپیوتر، دانشگاه صنعتی نوشیروانی بابل، بابل، ایران

^۳ - استاد، دانشکده‌ی مهندسی برق، دانشگاه علم و صنعت ایران، تهران، ایران

مشخصات مقاله

شناسه‌ی دیجیتال: 10.22041/IJBME.2019.97535.1419

پذیرش: ۲۹ مرداد ۱۳۹۸

بازنگری: ۱۳۹۸/۵/۲۵-۱۳۹۸/۴/۷

ثبت در سامانه: ۲۱ آبان ۱۳۹۷

چکیده

واژه‌های کلیدی

یکی از راه‌های ارتباط انسان و کامپیوتر بر پایه‌ی شناخت احساسات است. در این مقاله، مساله‌ی تشخیص احساسات با استفاده از سیگنال الکتروانسفالوگرام (EEG) مورد بررسی قرار گرفته است. در ابتدا، با توجه به خاصیت غیرایستایی EEG، توابع مد ذاتی (IMF) با استفاده از تجزیه‌ی مد تجربی (EMD) استخراج شده و سپس ۳ IMF اول انتخاب شده است. هر IMF با پنجره‌ی یک ثانیه‌ای به تکه‌های کوچک‌تری تبدیل شده و ویژگی‌های آن از هر قسمت استخراج شده است. سپس با استفاده از یک نگاهت مناسب، موقعیت الکترودها در سیستم ۱۰-۲۰ به موقعیت پیکسل‌ها در یک تصویر تبدیل شده و ویژگی‌های استخراج شده به عنوان مولفه‌های رنگ پیکسل در نظر گرفته شده است. برای تعیین کلاس ظرفیت، تمام تصاویر تولید شده به عنوان ورودی به یک شبکه‌ی یادگیری عمیق داده شده و کلاس بالا یا پایین ظرفیت (خروجی شبکه) مشخص شده است. از همین روش برای تعیین کلاس برانگیختگی نیز استفاده شده است. برای بررسی روش پیشنهادی از پایگاه داده‌ی DEAP استفاده شده است. با انتخاب تصویر با اندازه‌ی ۱۷×۱۷، میانگین دقت و انحراف معیار طبقه‌بندی برای ظرفیت برابر با ۷۸/۵۸٪ و ۳/۹ و برای برانگیختگی برابر با ۷۸/۶۶٪ و ۳/۱ به دست آمده که در مقایسه با نتایج کارهای مشابه بهبود قابل توجهی داشته است.

*نویسنده‌ی مسئول

نشانی گروه بیوالکتریک، دانشکده‌ی مهندسی برق و کامپیوتر، دانشگاه صنعتی نوشیروانی، بابل، ایران

تلفن ۹۸-۱۱-۳۵۵۰۱۴۲۶

۴۷۱۴۸۷۱۱۶۷

دورنگار ۹۸-۱۱-۳۲۳۳۹۲۱۴

smsakhaei@nit.ac.ir

پست الکترونیک



۱- مقدمه

احساسات یک خصوصیت انسانی بوده و وجه تمایز مهمی بین انسان و رایانه ایجاد می‌کند. شناخت احساسات انسان توسط رایانه کاربردهای متنوعی در زمینه‌های تعامل انسان-رایانه^۱ و رابط‌های مغز-رایانه^۲ دارد [۱، ۲] که از آن جمله می‌توان به محیط آموزش از راه دور، سرگرمی و بازی، واقعیت مجازی، دروغ‌سنجی، روان‌شناسی، پزشکی اعصاب و روان، توان‌بخشی و کمک به کم‌توانان و ناتوانان جسمی اشاره کرد [۳].

شاید نتوان تعریف دقیقی از احساسات انسان ارائه کرد، اما مفهوم آن مشخص و قابل فهم است [۴]. تغییرات روحی، روانی، فکری و بدنی را می‌توان نتیجه‌ی واکنش فرد به یک محرک بیرونی و احساسات را می‌توان به عنوان تابعی از شناخت بیرونی و احوال درونی که نسبت به یک موضوع خاص شکل می‌گیرد، در نظر گرفت. در واقع احساسات هر شخص به تجربه‌های احساسی او که در زندگی آموخته است، بستگی دارد.

احساسات به چند عامل بستگی دارد که از مهم‌ترین آن‌ها می‌توان به فرهنگ، جنسیت و سن اشاره کرد. همچنین پاسخ احساسی یک شخص نسبت به یک موضوع در زمان‌های مختلف ممکن است متفاوت باشد. احساسات ایجاد شده در افراد مختلف نسبت به یک موضوع واحد نیز می‌تواند متفاوت باشد. یک چالش دیگر در زمینه‌ی تشخیص احساسات، آن است که فرد ممکن است در نسبت دادن احساس خود به یکی از موارد استاندارد دچار خطا شود. گاه احساسات انسان ترکیبی از چند حس مختلف بوده و نمی‌توان آن را با یک کلمه توصیف کرد.

به منظور دسته‌بندی احساسات، برای اولین بار یک مدل ابعادی توسط اسپنسر و بر اساس تعریف احساسات انسان در بعدها^۳ خود آگاهی مطرح شد [۵]. پس از آن سه بعد ظرفیت^۴، برانگیختگی^۴ و تسلط^۵ برای احساسات بیان شده و برای اندازه‌گیری آن‌ها روش آدامک خودارزیابی^۶ (SAM) ارائه شد [۶]. هر کدام از این ابعاد، جنبه‌ای از احساس و هیجان را در بر می‌گیرد. بعد ظرفیت به میزان خوشایندی احساس گفته شده و کیفیت احساس را توصیف می‌کند که از احساس منفی (ناخوشایند) تا احساس مثبت (خوشایند) متغیر است. بعد برانگیختگی به میزان هیجان‌زدگی فرد اطلاق شده و میزان سطح فعالیت هیجانی فرد را تعیین می‌کند. این بعد از حالت غیرفعال تا حالت فعال متغیر بوده و شامل حالت‌های

کسل‌کننده تا هیجان‌زده می‌باشد. بعد تسلط به مقدار کنترل فرد روی احساساتش گفته شده که از مقدار ضعیف (غیرقابل کنترل) تا قوی (کنترل کامل احساسات) متغیر است [۷]. تشخیص نشانه‌های افسردگی و جلوگیری از اقدام به خودکشی یکی از کاربردهای بالینی تشخیص احساسات است. با استفاده از تشخیص احساسات در روش آهنگ‌درمانی^۷ می‌توان به درمان بیمارانی که از استرس، عصبانیت و افسردگی رنج می‌برند، کمک کرد [۳]. همچنین می‌توان با استفاده از شناخت احساسات به بیمارانی که مشکل گفتاری داشته و قادر به تکلم نیستند کمک نمود و به اطرافیان آن‌ها این امکان را داد تا با آگاهی از احساسات آن‌ها بتوانند ارتباط بهتری با این افراد برقرار کنند. به علاوه شناخت احساسات در معاینه و تشخیص دردهای این افراد و نیز در سیستم پزشکی از راه دور بسیار کارآمد است [۸]. ابزارها و روش‌های مختلفی برای تشخیص احساسات وجود داد که سیگنال الکتروانسفالوگرام (EEG) یکی از مهم‌ترین آن‌ها است. تشخیص احساسات توسط کامپیوتر از روی EEG، یک مساله‌ی یادگیری ماشین و تشخیص الگو بوده که شامل مراحل پیش‌پردازش، استخراج (و انتخاب) ویژگی و طبقه‌بندی می‌باشد. با توجه به ویژگی غیرایستایی سیگنال EEG، استفاده از روش‌هایی که این ویژگی در آن‌ها لحاظ شده باشد به پردازش مناسب سیگنال‌ها و تشخیص احساسات کمک خواهد کرد. سیگنال غیرایستا، سیگنالی است که رفتار فرکانسی آن در طول زمان قابل پیش‌بینی نبوده و تغییرات زیادی دارد. روش‌هایی مانند تجزیه‌ی مد تجربی^۸ (EMD) که بر پایه‌ی خاصیت زمان-فرکانس بنا شده‌اند در این زمینه مناسب هستند [۹]. این روش، یک روش تطبیقی بوده و برای تجزیه‌ی هر سیگنال از خود سیگنال استفاده می‌کند و برای تجزیه‌ی سیگنال به توابع پایه نیازی ندارد [۱۰]. پس از تجزیه‌ی سیگنال، مولفه‌های آن که توابع مد ذاتی^۹ (IMF) نام دارند، استخراج شده و سپس فرکانس فرکانس لحظه‌ای هر IMF با استفاده از تبدیل هیلبرت^{۱۰} محاسبه می‌شود [۱۱].

شبکه‌ی یادگیری عمیق، یکی از مباحث جدید در زمینه‌ی یادگیری ماشین بوده که به تازگی کاربرد زیادی پیدا کرده است. اصطلاح یادگیری عمیق برای نخستین بار در سال ۱۹۸۶ مطرح شده و در سال ۲۰۰۰ از آن در شبکه‌های عصبی مصنوعی استفاده شده است. در واقع شبکه‌های عصبی عمیق

^۶ Self-Assessment Manikin

^۷ Music Therapy

^۸ Empirical Mode Decomposition

^۹ Intrinsic Mode Function

^{۱۰} Hilbert Transform

^۱ Human-Computer Interaction

^۲ Brain-Computer Interface

^۳ Valence

^۴ Arousal

^۵ Dominance



شبکه‌ی عصبی مصنوعی برای بعدهای ظرفیت و برانگیختگی به ترتیب برابر با $0.72/8$ و 0.75 و برای طبقه‌بند K-NN به ترتیب برابر با 0.67 و 0.51 به دست آمده است. یک پژوهش دیگر روی پایگاه داده‌ی DEAP، با استفاده از ویژگی‌های هم‌بستگی مانند هم‌بستگی پیرسون و هم‌بستگی فاز، با جدا کردن ۴ باند فرکانسی تتا، آلفا، بتا و گاما روی ۳۲ کانال EEG برای تشخیص احساسات در دو کلاس بالا و پایین و در بعدهای ظرفیت و برانگیختگی انجام شده است [۱۴]. میانگین دقت در بعدهای ظرفیت و برانگیختگی برای تمام فیلم‌های دیده شده توسط یک فرد، با استفاده از طبقه‌بند SVM، تابع پایه‌ی شعاعی و تکنیک Leave-One-Out به ترتیب برابر با $0.76/17$ و $0.73/59$ به دست آمده است. در مقاله‌ی [۱۵] چگالی طیفی توان ۳۲ کانال EEG روی داده‌های DEAP به عنوان ویژگی در نظر گرفته شده، سپس ویژگی‌های مهم با استفاده از PCA جدا شده و با استفاده از تکنیک Leave-One-Trial-Out برای هر شخص و با طبقه‌بندهای SVM، بیز ساده و شبکه‌ی یادگیری عمیق احساسات در دو بعد ظرفیت و برانگیختگی به سه کلاس بالا، پایین و خنثی طبقه‌بندی شده است. شبکه‌ی یادگیری عمیق با میانگین دقت $0.53/42$ و $0.52/03$ برای بعدهای ظرفیت و برانگیختگی، بهترین عمل‌کرد را داشته است. بهاری و جان‌قربانی [۱۶] با استفاده از توان طیفی باندهای فرکانسی متفاوت در نمونه‌های EEG پایگاه داده‌ی DEAP، روی تمام کانال‌های EEG، با تکنیک Leave-One-Out، طبقه‌بند K-NN و احساسات در دو کلاس بالا و پایین به میانگین دقت $0.58/05$ در بعد ظرفیت، $0.64/56$ در بعد برانگیختگی و $0.67/42$ برای دوست‌داشتن دست یافته‌اند. در پژوهشی دیگر روی داده‌های DEAP [۱۷]، با استفاده از ویژگی‌های مبتنی بر کانال و ویژگی‌های مبتنی بر هم‌بستگی و با طبقه‌بندهای ماشین بردار پشتیبان و بیز ساده به تشخیص احساسات پرداخته شده است. ویژگی‌های مبتنی بر کانال شامل انرژی نسبی و لگاریتم آن و همچنین توان طیفی برای باندهای فرکانسی آلفا، بتا، گاما و تتا محاسبه شده است. از ویژگی‌های مبتنی بر هم‌بستگی، مانند اطلاعات متقابل، برای توصیف فعالیت‌های مغزی و نشان دادن ارتباط دو ناحیه از مغز استفاده شده است. با استفاده از تکنیک Leave-One-Trial-Out از یکی از ویدئوها به عنوان آزمون و از بقیه برای آموزش استفاده شده است. بهترین دقت با طبقه‌بند ماشین بردار پشتیبان به دست آمده که مقدار آن در بعد ظرفیت و برانگیختگی به ترتیب برابر با $0.69/6$ و $0.67/7$ بوده است.

همان شبکه‌های عصبی متداول هستند که از تعداد لایه‌های بیش‌تری تشکیل شده‌اند. به طور کلی اتفاق نظری در رابطه با تعداد لایه‌هایی که لازم است تا یک شبکه‌ی عصبی به صورت عمیق در نظر گرفته شود وجود ندارد اما به عنوان یک قاعده‌ی کلی می‌توان هر شبکه‌ی عصبی با بیش از دو لایه را به صورت عمیق در نظر گرفت [۱۲]. در ادامه به بررسی چند پژوهش انجام شده برای تشخیص احساسات از روی EEG و بیان روش کار و نتایج آن‌ها پرداخته شده است. در اولین پژوهش که روی پایگاه داده‌ی DEAP انجام شده [۷]، توان طیفی در باندهای تتا، آلفای پایین، آلفا، بتا و گاما برای تمام الکترودها و همچنین توان طیفی نامتفازن روی ۱۴ جفت کانال در دو نیم‌کره‌ی سر در ۴ باند تتا، آلفا، بتا و گاما به عنوان ویژگی در نظر گرفته شده است. با استفاده از طبقه‌بند بیز ساده و تکنیک Leave-One-Out، مقادیر میانگین دقت $0.57/6$ ، 0.62 و $0.55/4$ به ترتیب در بعدهای ظرفیت، برانگیختگی و دوست داشتن و در دو کلاس بالا و پایین به دست آمده است. در یک پژوهش دیگر روی پایگاه داده‌ی DEAP [۱۳]، با استفاده از ویژگی‌های استخراج شده از تبدیل بسته‌ی موجک، احساسات در بعدهای مختلف و در دو کلاس بالا و پایین، با SVM طبقه‌بندی شده است. برای طبقه‌بندی کلاس‌های احساسی مختلف از روش Leave-One-Out استفاده شده است به طوری که برای هر شخص یک موزیک‌ویدئو به عنوان آزمون و ۳۹ موزیک‌ویدئوی دیگر به عنوان آموزش در نظر گرفته شده و این کار ۴۰ بار تکرار شده تا تمامی موزیک‌ویدئوها به عنوان آزمون مورد بررسی قرار گیرند. میانگین این ۴۰ آزمایش برای هر ۳۲ نفر اعلام شده و میانگین نتایج به دست آمده از این پژوهش برای تمام افراد در بعدهای ظرفیت، برانگیختگی، تسلط و دوست‌داشتن به ترتیب برابر با $0.64/3$ ، $0.66/2$ ، $0.68/9$ و $0.70/2$ به دست آمده است. در مقاله‌ی [۹] از EMD چندکاناله (MEMD) روی ۱۸ کانال سیگنال EEG (۸ کانال در راست، ۸ کانال در چپ و ۲ کانال مرکزی در ناحیه‌ی پیشانی) استفاده شده، سیگنال به مدهای ذاتی آن تجزیه شده، ویژگی‌های توان، چگالی طیفی توان، آنتروپی، پارامترهای جورت و هم‌بستگی از IMF-ها استخراج شده و سپس بهترین ویژگی‌ها با استفاده از ICA جدا شده‌اند. این روش روی پایگاه داده‌ی DEAP و برای ۲۰ شرکت‌کننده مورد بررسی قرار گرفته است. دو بعد ظرفیت و برانگیختگی با استفاده از دو طبقه‌بند K-NN و شبکه‌ی عصبی مصنوعی به دو کلاس بالا و پایین طبقه‌بندی شده‌اند. میانگین دقت نتایج

گرفته است. برای استخراج ویژگی‌ها، ابتدا سیگنال با استفاده از EMD به مدهای ذاتی تجزیه شده و سه IMF اول انتخاب شده است. سپس هر IMF با پنجره‌گذاری به قسمت‌های کوچک‌تری تبدیل شده و توان هر بخش به عنوان ویژگی در نظر گرفته شده است. ویژگی‌ها با استفاده از نگاهت منطبق بر سیستم ۱۰-۲۰ به تصویر تبدیل شده و این تصاویر که بیان‌گر احساسات هستند، با طراحی یک شبکه‌ی یادگیری عمیق، طبقه‌بندی شده‌اند.

در ادامه، در بخش ۲ مجموعه‌ی دادگان مورد بررسی معرفی شده و روش پیشنهادی به تفصیل شرح داده شده است. در بخش ۳ نتایج اعمال روش روی دادگان، ارائه شده و با کارهای مشابه مورد مقایسه قرار گرفته است. در بخش آخر نیز نتیجه‌گیری و پیشنهادهایی برای کارهای آتی مطرح شده است.

۲- مواد و روش‌ها

در این بخش ابتدا پایگاه داده‌ی مورد استفاده در پژوهش معرفی شده و سپس مراحل مختلف روش پیشنهادی شامل استخراج ویژگی با استفاده از EMD، نگاهت ویژگی‌ها به تصویر و شبکه‌ی یادگیری عمیق شرح داده شده است.

۲-۱- پایگاه داده

برای بررسی روش پیشنهادی، ابتدا به معرفی مجموعه‌ی داده‌ی مورد بررسی پرداخته شده، سپس روش پیشنهادی روی داده‌ها اجرا شده و نتایج به دست آمده ارائه شده است.

در این پژوهش از پایگاه داده‌ی DEAP استفاده شده است [۷]. این پایگاه داده شامل سیگنال‌های ثبت شده از ۳۲ نفر در هنگام تماشای ۴۰ موزیک‌ویدئوی یک دقیقه‌ای است. سیگنال‌های ثبت شده شامل EEG ۳۲-کاناله (بر اساس سیستم الکتروگذاری ۱۰-۲۰) و ۸ سیگنال فیزیولوژیکی (گالوانیک پوستی، دامنه‌ی تنفسی، دمای پوست، ضربان قلب، فشار خون، فعالیت ماهیچه‌های گردن و ماهیچه‌های مربوط به لبخند و EOG) می‌باشند.

در انتهای هر موزیک‌ویدئو از فرد خواسته شده تا با استفاده از روش آدامک خودارزیابی، احساسات خود را در بعدهای ظرفیت، برانگیختگی، تسلط و دوست داشتن به صورت مقادیر کمی از ۱ تا ۹ بیان کرده و برای توصیف خوش آمدن از ویدئو از ۳ حالت خوش آمدن، خنثی و خوش نیامدن استفاده کند.

نمونه‌برداری سیگنال‌های EEG با نرخ ۵۱۲ نمونه‌بر ثانیه انجام شده است. این سیگنال‌ها از یک فیلتر میان‌گذر با باند عبور ۴

در پژوهش [۱۸] با استفاده از تبدیل ویولت گسسته، ضرایب ویولت به عنوان ویژگی در نظر گرفته شده و ویژگی‌ها از کانال‌های P3, FC2, AF3, O1 و Fp1 استخراج شده است. ۲۰ نفر از ۳۲ شرکت کننده انتخاب شده، برای هر شخص ۱۰ ویدئو برای آزمون و ۳۰ ویدئو برای آموزش در نظر گرفته شده و این کار برای هر ۲۰ نفر تکرار شده است. میانگین دقت تشخیص ظرفیت برای طبقه‌بند شبکه‌ی عصبی مصنوعی برابر با ۷۷/۱۴٪ و برای K-NN برابر با ۷۲/۹۲٪ گزارش شده است.

در مقاله‌ی [۱۹] ویژگی‌هایی در حوزه‌ی فرکانس، زمان و ویولت مانند توان، میانگین، انحراف معیار و آنتروپی در ۳۲ کانال EEG استخراج شده و داده‌ها با استفاده از خوشه‌بندی مبتنی بر ابرگراف برچسب‌زنی شده‌اند. سپس با استفاده از روش Leave-One-Trial-Out یک ویدئو برای مجموعه‌ی آزمون و سایر ویدئوها برای مجموعه‌ی آموزش تقسیم‌بندی شده‌اند. میانگین دقت (برای ۳۲ نفر) برای بعد ظرفیت برابر با ۵۲/۵۸٪ و برای بعد برانگیختگی برابر با ۶۱/۰۲٪ به دست آمده است.

در اکثر پژوهش‌ها، طبقه‌بند برای هر شخص به صورت جداگانه مورد آموزش و آزمون قرار گرفته و در مطالعات اندکی به تشخیص احساسات با استفاده از سیستم آموزش یافته با داده‌های مربوط به افرادی غیر از فرد مورد آزمون^۱ پرداخته شده است. از آن‌جا که ویژگی‌های سیگنال EEG افراد مختلف با هم متفاوت است، این نوع تشخیص از دقت مناسبی برخوردار نمی‌باشد. از این رو، در مطالعه‌ی [۲۰] از تکنیک یادگیری انتقالی^۲ استفاده شده است که در آن از ویژگی‌های مشترک میان تمام افراد جهت طبقه‌بندی استفاده می‌شود. در مطالعه‌ی [۲۱] طبقه‌بندی احساسات روی دو پایگاه داده‌ی DEAP و SEED انجام شده است. مقدار آنتروپی تفاضلی برای هر یک از باندهای دلتا، تتا، آلفا، بتا و گاما در هر کانال EEG محاسبه شده و مجموعه‌ی آن‌ها به عنوان ویژگی در نظر گرفته شده است. پس از تبدیل ویژگی‌ها با کمک یادگیری انتقالی، از طبقه‌بند رگسیون لجستیکی برای طبقه‌بندی استفاده شده است. با بررسی تکنیک‌های متفاوت یادگیری انتقالی، بهترین دقت میانگین برای پایگاه داده‌ی DEAP برابر با ۴۸/۹۳٪ و برای SEED برابر با ۷۵/۶۴٪ به دست آمده است. هم‌چنین با تغییر مجموعه‌ی آموزش و آزمون به طوری که یکی از پایگاه‌های داده به عنوان آموزش و دیگری به عنوان آزمون در نظر گرفته شود، بهترین دقت برابر با ۴۷/۶۸٪ گزارش شده است.

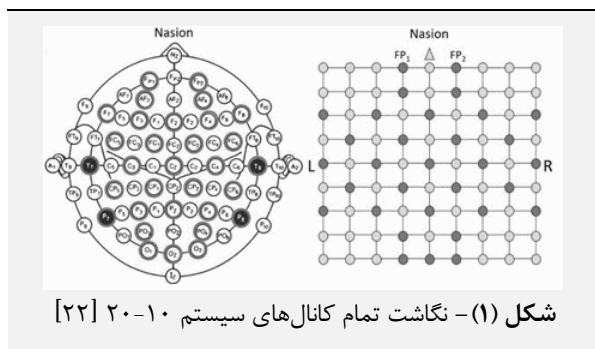
در پژوهش حاضر، مساله‌ی دسته‌بندی احساسات در دو کلاس بالا و پایین برای بعد ظرفیت و برانگیختگی مورد بررسی قرار

^۱ Transfer Learning

^۲ Leave-One-Subject-Out



ماتریس سه‌بعدی $125 \times 3 \times 32$ به ازای هر ویدئو-شخص به دست آمده که به صورت 125 تصویر رنگی دوبعدی تعبیر می‌شود. لازم به ذکر است که تنها مقادیر 32 پیکسل از هر تصویر مشخص بوده و برای تعیین موقعیت این پیکسل‌ها از نگاشت مربعی که در آن موقعیت الکترودها نسبت به هم بر اساس سیستم $10-20$ تعریف می‌شود، استفاده شده است [۲۲]. همان‌طور که در شکل (۱) نشان داده شده است، این نگاشت موقعیت الکترودهای روی سر را به نقطه‌ای از یک شبکه‌ی مربعی 9×9 نگاشت داده و تصویر مورد نظر را تشکیل می‌دهد. به این ترتیب، تنها مقادیر 32 پیکسل از 81 پیکسل تصویر مشخص است. برای تعیین مقادیر پیکسل‌هایی که بین دو پیکسل با مقدار معلوم قرار دارند، از درون‌یابی مکعبی و برای سایر پیکسل‌ها، که متناظر با نقاط بیرونی سیستم $10-20$ هستند، از برون‌یابی با مقداردهی به صفر استفاده شده است.



ابعاد شبکه‌ی نگاشت شده برابر با 9×9 بوده که می‌توان با درون‌یابی مجدد، ابعاد آن را تغییر داد. اگر بین هر دو پیکسل تصویر در شکل (۱)، یک پیکسل اضافه شود، ابعاد این شبکه به 17×17 افزایش پیدا خواهد کرد. واضح است که اگر تعداد پیکسل‌های اضافه شده مضرب صحیحی از 8 باشد، موقعیت کانال‌ها دقیقاً بر یکی از پیکسل‌های تصویر منطبق خواهد شد. در حالت کلی، ابعاد تصویر یا شبکه‌ی مربعی برابر با $(n \times 8) + 1$ بوده که در آن $n-1$ بیان‌گر تعداد نقاط اضافه شده بین هر دو پیکسل اولیه در شبکه‌ی 9×9 است. به این ترتیب، با جای‌گذاری مقادیر $1, 2$ و 3 برای n ، شبکه‌های مربعی با ابعاد $9 \times 9, 17 \times 17$ و 25×25 تولید شده و پس از آن، مقادیر هر پیکسل بین 0 و 1 نرمالیزه خواهد شد.

$$x' = \frac{x - \min(x)}{\max(x) - \min(x)} \quad (1)$$

پس از انجام این مراحل، برای هر ویدئو-شخص تعداد 125 تصویر به دست آمده که با توجه به تعداد 40 موزیک-ویدئو، تعداد کل تصاویر برای هر شخص برابر با 5000 می‌باشد. در

تا 45 هرتز عبور داده شده تا نویزها و آرتیفکت‌های احتمالی حذف شده و محدوده‌ی فرکانسی مناسب باقی بماند. پس از آن، نرخ نمونه‌برداری از 512 به 128 کاهش یافته و به این ترتیب با احتساب 3 ثانیه زمان اضافه (برای استراحت و تمرکز شخص) طول داده‌ی مورد بررسی در هر کانال EEG برای هر نفر-موزیک ویدئو برابر با 8064 نمونه است.

۲-۲- استخراج ویژگی

در ابتدا داده‌های هر کانال-ویدئو-شخص با اعمال EMD به مدهای ذاتی تجزیه شده است. تعداد نمونه‌های هر IMF با تعداد نمونه‌های سیگنال ورودی برابر است یعنی هر IMF دارای 8064 نمونه می‌باشد. از آن‌جا که تعداد IMF-های به دست آمده زیاد بوده و باعث سنگین و پیچیده شدن فرایند پردازش می‌شود، در محاسبه‌ی ویژگی از مدهای نامرتبط با احساسات صرف نظر شده است. از آن‌جا که مولفه‌های فرکانس پایین سیگنال EEG، چندان تحت تاثیر احساسات نیستند، می‌توان مدهای فرکانس پایین را در استخراج ویژگی در نظر نگرفت. بدین منظور، فرکانس لحظه‌ای هر IMF با استفاده از تبدیل هیلبرت محاسبه شده و مشاهده شد که محدوده‌ی فرکانسی IMF-های چهارم به بعد، تقریباً کم‌تر از 8 هرتز می‌باشد. از آن‌جا که معمولاً احساسات در باندهای فرکانسی کم‌تر از 8 هرتز سیگنال EEG بروز پیدا نمی‌کنند، در این‌جا تنها از 3 IMF اول برای محاسبه‌ی ویژگی استفاده شده است.

در مرحله‌ی بعد سیگنال‌های IMF با اعمال پنجره‌های 1 ثانیه‌ای و هم‌پوشانی 0.5 ثانیه‌ای به قسمت‌های کوچک‌تری شکسته شده‌اند. با این کار، هر داده برای کانال-شخص-ویدئو به 125 قسمت تبدیل شده و نیاز شبکه‌ی یادگیری عمیق به تعداد زیاد داده‌ی ورودی مرتفع شده است. هم‌چنین با کوچک شدن پنجره‌ی زمانی، تغییرات سیگنال به صورت بهتری دنبال شده و رفتار غیرایستایی سیگنال به خوبی قابل توصیف است. برای هر یک از پنجره‌ها، توان سیگنال به عنوان ویژگی محاسبه شده است. به این ترتیب با توجه به سه IMF استخراج شده، برای یک کانال-ویدئو-شخص ماتریسی با ابعاد 125×3 به عنوان ماتریس ویژگی نسبت داده شده است.

۲-۳- تولید تصویر

در این مرحله، با کنار هم قرار دادن ویژگی‌های استخراج شده برای هر کانال، یک تصویر دوبعدی رنگی برای هر 0.5 ثانیه از سیگنال EEG ساخته شده است. به بیان دقیق‌تر، پس از محاسبه‌ی ماتریس ویژگی 125×3 برای هر کانال EEG، یک


گام یک روی ماتریس حرکت کرده و در هر لایه از ۳۲ کرنل متفاوت استفاده شده است. سپس تابع فعال‌سازی relu روی خروجی اعمال شده که مقادیر منفی را حذف کرده و باعث افزایش سرعت یادگیری شده است. در ادامه نیز لایه‌ی maxpooling قرار داشته که به منظور کاهش ابعاد تصویر با حفظ ویژگی‌های اصلی به کار رفته است. برای این کار، یک پنجره‌ی 2×2 در نظر گرفته شده است که با حرکت روی ماتریس، بزرگ‌ترین عدد پنجره را بر می‌گرداند. برای جلوگیری از بیش‌برازش شدن مدل، از یک لایه‌ی Dropout استفاده شده [۲۵] که در آن ۲۵٪ از نورون‌ها به صورت کاملاً تصادفی در مرحله‌ی آموزش صفر می‌شوند. در انتها نیز دو لایه‌ی کاملاً متصل، با ۱۰ و ۲ نورون مانند شبکه‌ی عصبی مصنوعی پرسپترون چندلایه قرار دارد. برای تخصیص داده به یک کلاس، از تابع softmax استفاده شده که مقداری با مفهوم احتمالی بین ۰ و ۱ تولید می‌کند. برای آموزش مدل از بهینه‌ساز Adam و تابع هزینه‌ی cross entropy استفاده شده است. اندازه‌ی batch برابر با ۱۲۸ تنظیم شده که معادل تعداد ورودی‌های هر دور آموزش است. پس از تعریف مدل، مقداردهی اولیه برای تمامی وزن‌ها به کمک روش گلووروت انجام شده است [۲۶].

۳- نتایج

در این بخش به بررسی نتایج استفاده از روش پیشنهادی پرداخته شده است. در ابتدا آزمایش‌هایی برای انتخاب اندازه‌ی مناسب تصویر انجام شده که در آن‌ها ۸۰٪ تمام داده‌ها به عنوان مجموعه‌ی آموزش و ۲۰٪ باقی‌مانده به عنوان مجموعه‌ی آزمون در نظر گرفته شده و ارزیابی نیز روی همین دو مجموعه انجام شده است. پس از آن، عمل‌کرد شبکه‌ی طراحی شده در تشخیص احساسات مورد بررسی قرار گرفته است. در این مرحله از تکنیک $\text{Leave-One-Trial-Out}$ برای تهیه‌ی داده‌های آموزش و آزمون استفاده شده و هر شخص به طور جداگانه مورد بررسی قرار گرفته است. برای هر شخص یک موزیک‌ویدئو به عنوان آزمون کنار گذاشته شده و ۳۹ موزیک‌ویدئوی دیگر در مجموعه‌ی آموزش قرار داده شده است. به بیان دیگر، از مجموعه‌ی ۵۰۰۰ تایی تصاویر تولید شده برای یک شخص، ۱۲۵ تصویر برای آزمون (۱۲۵ تصویر مربوط به یک ویدئو) و بقیه برای آموزش در نظر گرفته شده است. این کار برای هر شخص ۴۰ بار تکرار شده تا تمام موزیک‌ویدئوها برای یک بار به عنوان آزمون قرار گرفته و سپس میانگین و انحراف معیار دقت ۴۰ بار آزمون برای هر شخص گزارش شده است.

مرحله‌ی بعد، از این تصاویر برای یادگیری و آزمون شبکه‌ی یادگیری عمیق استفاده شده است.


واضح است که می‌توان تصویر رنگی به دست آمده را با میانگین‌گیری از ۳ مولفه‌ی رنگ هر پیکسل، به یک تصویر خاکستری تبدیل کرد. یک نمونه از تصویر خاکستری تولید شده در این مرحله در شکل (۲) نشان داده شده است.



شکل (۲) - یک تصویر خاکستری نگاشت شده از ویژگی

۲-۴- شبکه‌ی یادگیری عمیق

مدل ارائه شده برای طبقه‌بند از نوع مدل شبکه‌ی یادگیری عمیق کانولوشن است که با الهام از بسیاری از روش‌های مشابه مانند VGG^۱ طراحی شده است [۲۳]. با بررسی‌های مختلفی که روی انواع حالت‌های اتصال و تعداد لایه‌های مختلف انجام شده و با توجه به مواردی چون محدودیت محاسباتی و اندازه‌ی کوچک تصاویر، سعی شده است تا ساده‌ترین و در عین حال موثرترین مدل ممکن ارائه گردد [۲۴]. طراحی نهایی این مدل به همراه مشخصات کلی آن در شکل (۳) نشان داده شده است.



شکل (۳) - ساختار کلی مدل ارائه شده

ساختار مدل به صورت ترتیبی بوده و خروجی‌های هر لایه به ورودی لایه‌ی بعد متصل شده است. در ابتدا دو لایه‌ی کانولوشن قرار داشته که در آن تصویر با یک کرنل پیش‌داده شده است. اندازه‌ی کرنل برابر با یک پنجره‌ی 3×3 است که با

^۱ Visual Geometry Group



جدول (۲) - دقت برای تصویر رنگی و خاکستری

نوع تصویر	بعد ظرفیت	بعد برانگیختگی
رنگی	٪۷۸/۵۸	٪۷۸/۶۶
خاکستری	٪۷۳/۶۸	٪۷۳/۲۷

برای ارزیابی روش پیشنهادی، نتایج آن با نتایج کارهای مشابه دیگری که روی پایگاه داده‌ی DEAP انجام شده، مورد مقایسه قرار گرفته و در جدول (۳) ارائه شده است. لازم به ذکر است که پژوهش‌های مورد مقایسه، از نظر نتایج، جزء بهترین‌ها بوده و در تمام آن‌ها مانند روش پیشنهادی از روش Leave-One-Trial-Out برای آموزش و آزمون استفاده شده است. مشاهده می‌شود که عمل‌کرد روش پیشنهادی در هر دو بعد ظرفیت و برانگیختگی مناسب‌تر از روش‌های مورد مقایسه است. اگر چه پژوهش [۱۴] در بعد ظرفیت عمل‌کردی نزدیک به روش پیشنهادی داشته اما عمل‌کرد آن در بعد برانگیختگی بسیار ضعیف‌تر می‌باشد.

جدول (۳) - مقایسه‌ی روش پیشنهادی با سایر پژوهش‌ها

پژوهش	دقت در بعد ظرفیت	دقت در بعد برانگیختگی
[۷]	٪۵۷/۶	٪۶۲
[۱۳]	٪۶۴/۳	٪۶۶/۲
[۹]	٪۷۲/۸	٪۷۵
[۱۴]	٪۷۶/۱۷	٪۷۳/۵۹
[۲۱]	٪۵۲/۵۸	٪۶۱/۰۲
[۱۷]	٪۶۹/۶۶	٪۶۷/۷
روش پیشنهادی	٪۷۸/۵۸	٪۷۸/۶۶

۴- نتیجه‌گیری

در این مقاله، برای استخراج ویژگی از سیگنال EEG جهت تشخیص احساسات از EMD استفاده شده است. هم‌چنین با توجه به تاثیر ناچیز احساسات در باندهای فرکانس پایین EEG، IMF-های مناسب با استفاده از تبدیل هیلبرت و محاسبه‌ی فرکانس لحظه‌ای انتخاب شده‌اند. نوآوری مهم این مقاله در نگاشت IMF-های انتخابی به تعداد زیادی تصویر رنگی است که در آن موقعیت هر پیکسل از تصویر با توجه به موقعیت الکتروود متناظر روی سر تعیین شده است. سپس از یک شبکه‌ی یادگیری عمیق برای تشخیص احساسات با کمک تصاویر رنگی به دست آمده، استفاده شده است.

نتایج بررسی‌ها نشان می‌دهد که روش پیشنهادی قادر به تشخیص احساسات در دو بعد ظرفیت و برانگیختگی با دقتی

۳-۱- تعیین اندازه‌ی تصویر

در این مرحله، تصاویری با اندازه‌های مختلف تولید شده و میزان دقت پاسخ‌ها مورد بررسی قرار گرفته است. در این حالت ٪۸۰ از داده‌ها به عنوان آموزش جدا شده و روی ٪۲۰ از داده‌ها آزمون انجام شده است. مجموعه‌ی آموزش و آزمون ذخیره شده و تمام روش‌ها روی همان مجموعه انجام شده است تا امکان مقایسه‌ی روش‌ها با هم فراهم شود. نتایج به دست آمده برای تصاویر با ابعاد ۹×۹، ۱۷×۱۷ و ۲۵×۲۵ در دو بعد ظرفیت و برانگیختگی و دو کلاس بالا و پایین در جدول (۱) ارائه شده است.

جدول (۱) - دقت برای تصاویر با اندازه‌های متفاوت

اندازه‌ی تصویر	بعد ظرفیت	بعد برانگیختگی
داده‌ی اصلی	٪۵۲/۳	٪۵۶/۷
۹×۹	٪۶۷/۸۵	٪۷۰/۱۷
۱۷×۱۷	٪۶۸/۹	٪۷۱/۲۶
۲۵×۲۵	٪۶۸/۷	٪۷۰/۰۵

همان‌طور که مشاهده می‌شود، میزان دقت برای تصویر با اندازه‌ی ۹×۹ پایین‌تر از سایر تصاویر است. دقت تصویرهای ۱۷×۱۷ و ۲۵×۲۵ بسیار به هم نزدیک است اما تصویرهای ۲۵×۲۵ به پردازش بیش‌تری نیاز داشته و زمان بیش‌تری برای پردازش آن‌ها لازم است. از این رو ابعاد ۱۷×۱۷ برای تصویر انتخاب شده است.

۳-۲- نتایج روش پیشنهادی

در این بخش، نتایج حاصل از به کارگیری روش پیشنهادی ارائه شده است. این نتایج با استفاده از تصاویری با اندازه‌ی ۱۷×۱۷ و انتخاب داده‌های آموزش و آزمون با روش Leave-One-Trial-Out به دست آمده است. پاسخ مساله نیز به صورت میانگین دقت برای تمام افراد در ابعاد ظرفیت و برانگیختگی و در دو کلاس احساسات بالا و پایین در هر بعد گزارش شده است.

برای آن که پردازش‌های مرحله‌ی شبکه‌ی یادگیری عمیق کم‌تر شود می‌توان ماتریس سه‌بعدی تصویر رنگی را به ماتریس دوبعدی تصویر خاکستری تبدیل کرد. برای بررسی تاثیر این کار بر دقت حل مساله، نتایج حاصل از اعمال تصویر خاکستری و نتایج استفاده از تصویر رنگی در جدول (۲) ارائه شده است. با مقایسه‌ی این نتایج مشاهده می‌شود که دقت طبقه‌بندی برای تصویر رنگی در حدود ٪۵ از دقت آن برای تصویر خاکستری بیش‌تر است. بنابراین با وجود افزایش سرعت پردازش روی تصویر خاکستری، تصویر رنگی انتخاب مناسب‌تری برای حل مساله‌ی تشخیص احساسات می‌باشد.

- viewed from a prototype perspective.," J. Exp. Psychol. Gen., vol. 113, no. 3, p. 464, 1984.
- [5] H. Spencer, The principles of psychology, vol. 1. Appleton, 1895.
- [6] M. M. Bradley and P. J. Lang, "Measuring emotion: the self-assessment manikin and the semantic differential," J. Behav. Ther. Exp. Psychiatry, vol. 25, no. 1, pp. 49-59, 1994.
- [7] S. Koelstra et al., "Deap: A database for emotion analysis; using physiological signals," IEEE Trans. Affect. Comput., vol. 3, no. 1, pp. 18-31, 2012.
- [8] P. C. Petrantonakis and L. J. Hadjileontiadis, "Adaptive emotional information retrieval from EEG signals in the time-frequency domain," IEEE Trans. Signal Process., vol. 60, no. 5, pp. 2604-2616, 2012.
- [9] A. Mert and A. Akan, "Emotion recognition from EEG signals by using multivariate empirical mode decomposition," Pattern Anal. Appl., vol. 21, no. 1, pp. 81-89, 2018.
- [10] R. Fontugne, J. Ortiz, D. Culler, and H. Esaki, "Empirical mode decomposition for intrinsic-relationship extraction in large sensor deployments," in Workshop on Internet of Things Applications, IoT-App, 2012, vol. 12.
- [11] N. E. Huang et al., "The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis," in Proceedings of the Royal Society of London A: mathematical, physical and engineering sciences, 1998, vol. 454, no. 1971, pp. 903-995.
- [12] D. J. Hand, H. Mannila, and P. Smyth, Principles of data mining (adaptive computation and machine learning). MIT press Cambridge, MA, 2001.
- [13] D. S. Naser and G. Saha, "Recognition of emotions induced by music videos using DT-CWPT," in Medical Informatics and Telemedicine (ICMIT), 2013 Indian Conference on, 2013, pp. 53-57.
- [14] M. Chen, J. Han, L. Guo, J. Wang, and I. Patras, "Identifying valence and arousal levels via connectivity between EEG channels," in Affective Computing and Intelligent Interaction (ACII), 2015 International Conference on, 2015, pp. 63-69.
- [15] S. Jirayucharoensak, S. Pan-Ngum, and P. Israsena, "EEG-based emotion recognition using deep learning network with principal component based covariate shift adaptation," Sci. World J., vol. 2014, 2014.
- [16] F. Bahari and A. Janghorbani, "Eeg-based emotion recognition using recurrence plot analysis and k nearest neighbor classifier," in Biomedical Engineering (ICBME), 2013 20th Iranian Conference on, 2013, pp. 228-233.
- [17] P. Arnau-González, M. Arevalillo-Herráez, and N. Ramzan, "Fusing highly dimensional energy and connectivity features to identify affective states from EEG signals," Neurocomputing, vol. 244, pp. 81-89, 2017.

به ترتیب برابر با $0.78/58\%$ و $0.78/66\%$ است که در مقایسه با پژوهش‌های پیشین برتری قابل قبولی را نشان می‌دهد. یکی از مشکلات مرتبط با شبکه‌های یادگیری عمیق، حجم بالای محاسبات آن است. در روش پیشنهادی نیز با وجود خلاصه کردن یک سیگنال به طول 8064 نمونه به یک داده به طول 125 نمونه (با کمک ویژگی توان در پنجره‌های زمانی 0.5 ثانیه‌ای)، ملاحظه می‌شود که ورودی شبکه به صورت $125 \times 17 \times 17$ است. هر کدام از این تصاویر دو بار تحت عمل کانولوشن و هر بار با استفاده از 32×32 کرنل 3×3 متفاوت قرار گرفته است. در ادامه نیز دو لایه‌ی کاملاً متصل با تعداد 10 و 2 نورون قرار دارد. این ساختار پیچیده باعث افزایش تعداد پارامترهای قابل تنظیم در مرحله‌ی آموزش و در نتیجه طولانی شدن زمان آموزش شده و هم‌چنین بار محاسباتی سنگینی در مرحله‌ی اجرا خواهد داشت.

در این مقاله، از پارامتر توان به عنوان ویژگی برای IMF-های انتخابی، در پنجره‌هایی به طول 0.5 ثانیه استفاده شده است، در حالی که در شبکه‌های یادگیری عمیق معمولاً سیگنال زمانی (بدون استخراج ویژگی) به عنوان ورودی شبکه در نظر گرفته می‌شود. البته هدف اصلی این مقاله جلوگیری از پیچیدگی شبکه و کاهش حجم محاسبات بوده است. پیشنهاد می‌شود که در کارهای آینده از پنجره‌های زمانی با طول کم‌تر استفاده شود و یا حتی سیگنال به صورت مستقیم به شبکه اعمال گردد. به نظر می‌رسد که انتخاب بازه‌ی زمانی مناسب می‌تواند در بهبود نتایج موثر باشد. با انتخاب بخشی از داده که تحریک احساسات در آن بیش‌تر اتفاق افتاده است، هم‌بستگی بیش‌تری بین ویژگی‌های محاسبه شده و احساسات ایجاد شده و در نتیجه انتظار می‌رود که عمل کرد طبقه‌بندی بهبود یابد. به علاوه در صورت شناسایی کانال‌هایی که تاثیرپذیری بیش‌تری از احساسات دارند، می‌توان با حذف آن‌ها و کاهش تعداد کانال‌ها، ضمن کاهش حجم پردازش، دقت طبقه‌بندی را نیز افزایش داد.

۵- مراجع

- [1] S. Brave and C. Nass, "Emotion in human-computer interaction," human-computer Interact. Handb. Fundam. Evol. Technol. Emerg. Appl., pp. 81-96, 2003.
- [2] G. Garcia-Molina, T. Tsoneva, and A. Nijholt, "Emotional brain-computer interfaces," Int. J. Auton. Adapt. Commun. Syst., vol. 6, no. 1, pp. 9-25, 2013.
- [3] Y. Liu, O. Sourina, and M. K. Nguyen, "Real-time EEG-based emotion recognition and its applications," in Transactions on computational science XII, Springer, 2011, pp. 256-277.
- [4] B. Fehr and J. A. Russell, "Concept of emotion

- [23] K. Simonyan and A. Zisserman, "Very deep convolutional networks for large-scale image recognition," arXiv Prepr. arXiv1409.1556, 2014.
- [24] A. Krizhevsky, I. Sutskever, and G. E. Hinton, "Imagenet classification with deep convolutional neural networks," in Advances in neural information processing systems, 2012, pp. 1097–1105.
- [25] N. Srivastava, G. Hinton, A. Krizhevsky, I. Sutskever, and R. Salakhutdinov, "Dropout: a simple way to prevent neural networks from overfitting," J. Mach. Learn. Res., vol. 15, no. 1, pp. 1929–1958, 2014.
- [26] X. Glorot and Y. Bengio, "Understanding the difficulty of training deep feedforward neural networks," in Proceedings of the thirteenth international conference on artificial intelligence and statistics, 2010, pp. 249–256.
- [18] M. S. Özerdem and H. Polat, "Emotion recognition based on EEG features in movie clips with channel selection," Brain informatics, vol. 4, no. 4, p. 241, 2017.
- [19] Z. Liang, S. Oba, and S. Ishii, "An unsupervised EEG decoding system for human emotion recognition," Neural Networks, 2019.
- [20] Z. Lan, O. Sourina, L. Wang, R. Scherer, and G. R. Müller-Putz, "Domain adaptation techniques for EEG-based emotion recognition: a comparative study on two public datasets," IEEE Trans. Cogn. Dev. Syst., vol. 11, no. 1, pp. 85–94, 2019.
- [21] W.-L. Zheng and B.-L. Lu, "Investigating critical frequency bands and channels for EEG-based emotion recognition with deep neural networks," IEEE Trans. Auton. Ment. Dev., vol. 7, no. 3, pp. 162–175, 2015.
- [22] Y. Li, J. Huang, H. Zhou, and N. Zhong, "Human Emotion Recognition with Electroencephalographic Multidimensional Features by Hybrid Deep Neural Networks," Appl. Sci., vol. 7, no. 10, p. 1060, 2017.