



Research Article

Recognition of Consumer Preferences from EEG Signals Using Discrete Wavelet Transformation, Lempel-Ziv Complexity, and Deep Neural Network

Seyyed Abed Hosseini* : Assistant professor, Dept. of Electrical Engineering, Mashhad Branch, Islamic Azad University, Mashhad, Iran
SA.Hosseini@iau.ac.ir

Abstract

Neuromarketing is the application of neuropsychology in marketing research to study the sensorimotor behavior of consumers such as cognitive and emotional responses to marketing stimuli with the help of new technologies. The performance of priority detection systems based on brain signals depends on the appropriate selection of feature extraction methods and machine learning algorithm. At first, EEG signals were pre-processed by low-pass and Savitzky Golay filters, and the features of discrete wavelet transform (DWT) and Lempel-Ziv complexity (LZC) were extracted from them. After that the features are normalized and divided into training and testing. Later on, the normalized features are given to a four-layer deep neural network (DNN) to predict the results of the training. Finally, the proposed model is ready to use. To evaluate the performance of the proposed model, parameters of precision, recall, and accuracy have been considered. The results show that a precision of 82%, recall of 87.5%, and accuracy of 87.5% for distinguishing the two categories of liking and disliking have been obtained in an average of five runs. In this study, the effect of advertising on the brain activity of consumers was investigated by analyzing EEG signals. Experimental results of the proposed model show that studies in this field can change and improve marketing strategies to improve producer performance and consumer satisfaction, leading to a mutual benefit.

Keywords: Neuromarketing, EEG signal, Discrete Wavelet Transform, Lempel-Ziv Complexity, Deep Neural Network.

Introduction

Neuromarketing is the study of brain reactions using medical technologies in response to marketing stimuli (Amin et al., 2020). By analyzing the collected information, companies try to find the reasons for consumer decisions to buy goods. They also want to understand which

brain regions become more active during decision-making.

Neuromarketing researchers assume that most consumer decisions are made unconsciously and in a fraction of a second. They also believe that the choices and decisions consumers make are often based on emotions instead of product comparison. Therefore, consumers' emotions influence decision-making. On the other hand, consumer feelings can be

Corresponding author



highly influenced by internal and external factors. Detecting the consumer's emotional state reveals his/her real preferences (Aldayel et al., 2020). The feeling and understanding caused by advertising make the consumer buy a particular product.

Neuromarketing studies are done through recording or analyzing biometric data, or through a combination of them such as electroencephalography (EEG), facial expression, movement pattern recognition, eye tracking, and galvanic skin response (GSR). A consumer preference recognition system based on EEG signals helps to understand consumer behavior and discover how a person makes a purchase decision. Understanding this, helps marketers and organizations to increase customer satisfaction, positive customer experiences, consumer loyalty, and revenue (Aldayel et al., 2020).

Materials and Methods

In this article, the EEG signals of 25 participants were used while viewing 14 different internet products of three different types. Such signals were recorded through 14 channels at different head surface areas with the international 10-20 system including AF3, F7, F3, FC5, T7, P7, O1, O2, P8, T8, FC6, F4, F8, and AF4. Common mode sense (CMS) and driven right leg (DRL) reference electrodes are placed at P3 and P4 positions above the ear. First, the EEG signals are pre-processed by band pass filter and Savitzky Golay filter. Then, the discrete wavelet transform (DWT) and Lampel-Ziv complexity (LZC) features are extracted from them. After that, normalized features are divided into two parts of training and testing. In the proposed model, the four-layer deep neural network (DNN) classifier is used to predict and distinguish two categories of liking and disliking. The input layer of DNN is not recognized as a layer in the network and is known as zero layer. Hidden layers include units with rectified linear unit (ReLU) (Kingma & Ba,

2014; He et al., 2015). The output is configured as a softmax layer with a binary cross-entropy cost function. Each hidden layer consists of 60% of its previous layer; therefore, the first hidden layer contains 1800 units, the second hidden layer contains 1080 units, and the third hidden layer contains 648 units. The dimension of the output layer is equal to two, because it corresponds to the number of units required to distinguish the categories of liking and disliking.

Results

The simulations have been performed by MATLAB 2014a software. The training set included 80% of extracted features while the testing set included 20% of extracted features. Various evaluation criteria such as precision, recall, and accuracy have been used to measure the performance of the classifiers. The values of statistical parameters after averaging five times to distinguish two categories of liking and disliking have been found to have 82% precision, 87.5% recall, and 87.5% accuracy.

Discussion

Various evaluation criteria such as precision, recall, and accuracy have been used to measure the performance of the classifier. The proposed model was able to distinguish the two categories of liking and disliking with 87.5% accuracy, which shows an increase of 0.5% compared to the reference (Aldayel et al., 2021). Also, by comparing the results with references (Aldayel et al., 2021; Yadava et al., 2017), it is clear that the LZC feature extraction method has an effective role in predicting the proposed model for separating the two categories of liking and disliking. The results show that the proposed method can provide a complementary solution to traditional measures of predicting products success in the market. Also, the proposed method can be used in the development of market strategies and research by predicting the success of the market

through expanding the existing models. This method helps advertisers understand which of their advertisements are effective and how they should plan their advertising strategy. Finally, by comparing the results with previous studies, the combined

feature extraction method of LZC and DWT with the use of DNN classification has an effective role in predicting the proposed model for separating the two categories of liking and disliking.





تشخیص ترجیحات مصرف‌کننده از سیگنال‌های EEG به کمک تبدیل موجک گسسته، پیچیدگی لمپل زیو و شبکه عصبی عمیق

سیدعابد حسینی*: استادیار، گروه مهندسی برق، واحد مشهد، دانشگاه آزاد اسلامی، مشهد، ایران.

SA.Hosseini@iau.ac.ir

چکیده

بازاریابی عصبی به کارگیری عصب‌روان‌شناسی در پژوهش‌های بازاریابی است تا به کمک فناوری‌های نوین به مطالعه حسی-حرکتی رفتار مصرف‌کننده مانند پاسخ‌های شناختی و احساسی به محرک‌های بازاریابی پردازد. عملکرد سیستم‌های تشخیص اولویت مبتنی بر سیگنال‌های مغزی (EEG) به انتخاب مناسب روش‌های استخراج ویژگی و الگوریتم‌های یادگیری ماشین بستگی دارند. در این مقاله از سیگنال‌های EEG ۲۵ شرکت‌کننده در زمان مشاهده ۱۴ محصول مختلف استفاده شده است. در اینجا ابتدا سیگنال‌های EEG توسط پالایه‌های میان‌گذر و ساویترکی گولای پیش‌پردازش می‌شوند و ویژگی‌های تبدیل موجک گسسته (DWT) و پیچیدگی لمپل زیو (LZC) از آنها استخراج می‌شود. سپس ویژگی‌های بهنجار شده به دو بخش آموزش و آزمون تقسیم می‌شوند. سپس ویژگی‌های بهنجار شده به شبکه عصبی عمیق (DNN) چهار لایه برای پیش‌بینی نتیجه آموزش داده می‌شوند و در نهایت پس از انجام آموزش، مدل پیشنهادی آماده پیش‌بینی است. برای ارزیابی عملکرد مدل پیشنهادی از مؤلفه‌های دقت، فراخوانی و صحت استفاده شده است. نتایج نشان می‌دهد مقدار مؤلفه‌های دقت ۸۲ درصد، فراخوانی ۸۷/۵ درصد و صحت ۸۷/۵ درصد برای تشخیص دو دسته پسندیدن و نپسندیدن پس از پنج بار متوسط‌گیری حاصل شده است. در این پژوهش اثر تبلیغات بر فعالیت مغز مصرف‌کنندگان با تحلیل سیگنال‌های EEG بررسی شد. نتایج تجربی بر روی مدل پیشنهادی نشان می‌دهد که مطالعات در این زمینه می‌تواند باعث تغییر و بهبود راهبردهای بازاریابی برای بهبود عملکرد تولیدکننده و رضایت مصرف‌کننده شود و در نهایت، به منفعت متقابل منجر شود.

واژگان کلیدی: بازاریابی عصبی، سیگنال مغزی، تبدیل موجک گسسته، پیچیدگی لمپل زیو، شبکه عصبی عمیق.

* نویسنده مسئول:



۱- مقدمه

تبلیغات، باعث می‌شود مصرف‌کننده در خرید یک محصول خاص مطابق با آن عمل کند.

پژوهش‌های بازاریابی عصبی با ثبت و تحلیل برخی از داده‌های بیومتریک یا ترکیبی از آنها مانند الکتروانسفالوگرافی (EEG)^۱، حالت چهره، تشخیص الگوی حرکتی، ردیابی حرکات چشم و پاسخ هدایت الکتریکی پوست (GSR)^۲ انجام می‌شود. در این میان، استفاده از سیگنال‌های EEG یک روش کاربردی، چندبُعدی، مقرون‌به‌صرفه، قابل‌حمل و غیرتهاجمی برای تحلیل فعالیت‌های شناختی است (Al-Nafjan et al., 2017). پژوهشگران همیشه خواهان یک راه‌حل حسگر زیستی قابل‌حمل بودند که نه مزاحم و نه ترسناک باشد، اما داده‌های دقیق و مؤثری را برای اهداف پژوهشی ارائه دهد. در اینجا بازاریابی عصبی می‌تواند راه‌حلی برای حل این مشکل باشد و پل ارتباطی بین داده‌ها و پژوهشگران باشد.

بازاریابی عصبی مبتنی بر سیگنال EEG به دنبال ارائه بینشی دربارهٔ تجربهٔ یک شخص با انواع محصولات و رسانه‌ها و همچنین، ارزیابی پاسخ به محرک‌های بازار به‌منظور تشخیص اولویت مصرف‌کننده است. یک سیستم تشخیص ترجیحات مصرف‌کننده مبتنی بر سیگنال EEG کمک می‌کند تا رفتار مصرف‌کننده درک و کشف شود که فرد چگونه تصمیم به خرید می‌گیرد. درک این موضوع به بازاریابان و سازمان‌ها کمک می‌کند تا رضایت مشتری، تجربیات مثبت مشتری، وفاداری مصرف‌کننده و درآمد را افزایش دهند (Aldayel et al., 2020). درک دیدگاه‌ها، رفتار، کنش، احساسات و بینش‌های ناخودآگاه مصرف‌کنندگان به بازاریابان کمک می‌کند تا استراتژی‌های بازاریابی را برنامه‌ریزی کنند و توسعه دهند. نه تنها برند از بازاریابی

بازاریابی عصبی، مطالعهٔ واکنش مغز با استفاده از فناوری‌های پزشکی در پاسخ به محرک‌های بازاریابی است (Amin et al., 2020). شرکت‌ها با تحلیل اطلاعات جمع‌آوری‌شده، سعی در یافتن دلایل تصمیمات مصرف‌کننده برای خرید کالا را دارند و همچنین، می‌خواهند بفهمند کدام یک از نواحی مغز در زمان تصمیم‌گیری فعال‌تر می‌شود. بازاریابی عصبی در پژوهش‌های بازاریابی و تجارت الکترونیک اهمیت ویژه‌ای دارد؛ زیرا ممکن است مصرف‌کنندگان اغلب افکار خود را پنهان کنند یا نتوانند بیان کنند. شرکت‌ها و سازمان‌ها نیاز فزاینده‌ای به درک و پیش‌بینی ترجیحات مصرف‌کننده دارند تا بتوانند در اقتصاد جهانی رقابت کنند. همچنین، روش‌های پژوهشی موجود در بازاریابی سنتی، توان رمزگشایی ضمیر ناخودآگاه مصرف‌کنندگان را ندارند. ضمیر ناخودآگاه محلی است که اکثر افکار انسان در آن رخ می‌دهد. از طریق بازاریابی عصبی می‌توان فهمید که مصرف‌کننده چه می‌خواهد و هم در ناخودآگاه خود به چه چیزی فکر می‌کند (Penenberg, 2011).

پژوهشگران بازاریابی عصبی فرض می‌کنند اکثر تصمیمات مصرف‌کنندگان به‌صورت ناخودآگاه و در کسری از ثانیه گرفته می‌شود. همچنین، اعتقاد دارند که انتخاب‌ها و تصمیماتی که مصرف‌کنندگان می‌گیرند، اغلب به‌جای مقایسه و تمایز بین محصولات، مبتنی بر احساسات است؛ بنابراین این یک واقعیت شناخته‌شده است که احساسات مصرف‌کننده بر تصمیم‌گیری تأثیر می‌گذارند. از سوی دیگر، احساسات مصرف‌کننده می‌تواند به‌شدت تحت تأثیر عوامل داخلی و خارجی بسیاری قرار گیرد؛ بنابراین، تشخیص وضعیت احساسی مصرف‌کننده، ترجیحات واقعی وی را آشکار می‌کند (Aldayel et al., 2020). احساس یا درک ناشی از

¹ ElectroEncephaloGram

² Galvanic Skin Response

مرحله بعد چندین الگوریتم یادگیری ماشین، از جمله مدل پنهان مارکوف (HMM)^۲، ماشین بردار پشتیبان (SVM)^۳، جنگل تصادفی (RF)^۴ و پرسپترون چندلایه (MLP)^۵ بر روی این ویژگی‌ها آموزش داده شده‌اند. با استفاده از طبقه‌بند HMM صحت پیش‌بینی انتخاب ۷۰/۳۳ درصد حاصل شده است.

ترمیم‌بیل به بررسی و تعیین کمیت تأثیر محیط خرده‌فروشی^۶ بر پاسخ‌های احساسی و شناختی مصرف‌کنندگان نسبت به محصولات پرداخت (Trimble, 2018). چندین عنصر از محیط خرده‌فروشی می‌تواند بر رفتار مصرف‌کننده و تصمیمات خریدار تأثیر گذار باشد. بیشترین تأثیری که محیط بر رفتار دارد و غالباً به آن توجه نمی‌شود، بر فرایندهای درونی تأثیر می‌گذارد که زیر سطح هوشیاری آگاهانه است. پرایمینگ^۷ تأثیر محرک‌های خارجی بر رفتار یا پاسخ فرد نسبت به محرک‌های هدف است. این پژوهش آزمایشی را طراحی کرده است تا شرکت‌کنندگان را با یک محرک رنگی خاص (صورتی، آبی یا قرمز) به منظور اندازه‌گیری تأثیر این تحریک بر تصمیم‌های خرید شرکت‌کنندگان مشخص کند. شرکت‌کنندگان وارد یک فروشگاه خرده‌فروشی شبیه‌سازی شده شبیه دنیای واقعی شده‌اند و در قالبی هدایت‌شده از میان لباس‌های موجود خرید کردند و در نهایت، سه لباس مورد علاقه خود را انتخاب کرده‌اند. پاسخ‌های فیزیولوژیکی شرکت‌کنندگان با استفاده از ردیاب حرکات چشم و دستگاه قابل حمل سیگنال EEG ثبت شده است. داده‌های ردیابی حرکات چشم برای افزایش سوگیری نگاه نسبت به محصولات

عصبی بهره‌مند خواهد شد، بلکه بازاریابی عصبی برای تولیدکنندگان نیز مفید است؛ زیرا عموم مردمی را که روزانه در معرض صدها آگهی تبلیغاتی قرار می‌گیرند، می‌توان از طریق ایجاد آگهی‌های احساسی‌تر و مفیدتر، بیشتر جلب محصولات و برندها کرد و تجربه بهتری را برای مشتری ایجاد نمود.

بازاریابی عصبی بسیار فراتر از نظرسنجی‌ها و روش‌های بازاریابی سنتی است (Amin et al., 2020) و در سال‌های اخیر پژوهش‌های زیادی در مبحث بازاریابی عصبی انجام شده است. کراجینویک و همکاران به پژوهشی با عنوان بازاریابی عصبی و اراده آزاد مشتریان پرداختند (Krajinovic et al., 2012). این پژوهش به تأثیر عناصر حسی شامل رنگ، طرح، موسیقی، بو و طعم بر ادراک مشتریان و تصمیم خرید آگاهانه یا ناآگاهانه آنها می‌پردازد. همچنین، آنها تأثیر ابزارهای بازاریابی بر احساسات مشتریان را بررسی کرده‌اند. پوژاریو به مطالعه تأثیر زمینه‌های مختلف اجتماعی بر فرایندهای شناختی مرتبط با تجربه مطالب تبلیغاتی پرداخته است (Pozharliev, 2017). برای رسیدن به این هدف از ترکیبی از اقدامات تبلیغاتی سنتی، ویژگی‌های شخصیتی، پروفایل‌های ژنتیکی و تحلیل سیگنال EEG استفاده کرده‌اند.

یاداو و همکاران یک چهارچوب پیش‌بینی برای درک انتخاب مصرف‌کننده نسبت به محصولات تجارت الکترونیکی را از نظر دو دسته پسندیدن و نپسندیدن به کمک تحلیل سیگنال‌های EEG ارائه داده‌اند (Yadava et al., 2017). در پژوهش آنها سیگنال‌های EEG شرکت‌کنندگان با سن و جنسیت متفاوت در هنگام مرور محصولات مختلف ثبت شده است. سپس ویژگی‌های مبتنی بر تبدیل موجک گسسته (DWT)^۱ از سیگنال پیش‌پردازش شده استخراج شد. در

^۲Hidden Markov Model

^۳Support Vector Machine

^۴Random Forest

^۵Multi-Layer Perceptron

^۶Retail

^۷Priming

^۱ Discrete Wavelet Transform

عصبی پرداختند (Amin et al., 2020). در مطالعه آنها از الگوریتم‌های داده‌کاوی و یادگیری ماشین برای تحلیل رفتار مصرف‌کننده به کمک سیگنال‌های EEG استفاده شده است. ویژگی‌های توزیع زمان فرکانس از سیگنال‌های EEG استخراج شده و سپس الگوریتم‌های طبقه‌بندی متفاوتی روی آنها اعمال شده است. از پاسخ‌های مصرف‌کننده به استراتژی‌های بازاریابی و رفتار آنها نسبت به خرید یا انتخاب کالا می‌توان برای درک رابطه تولیدکننده با مصرف‌کننده استفاده شود. دلیل اینکه آنها چگونه و چرا سیاست‌های بازاریابی خاص را دوست دارند، با تحلیل داده‌ها کشف شد. صحت مدل آنها ۹۵ درصد است که نسبت به صحت روش (Yadava et al., 2017) ۲۵ درصد افزایش را نشان می‌دهد. نتایج آنها نشان داد که مطالعات در این زمینه می‌تواند باعث تغییر و بهبود استراتژی‌های بازاریابی برای بهبود تولیدکننده و مصرف‌کننده شود.

اسکاناگاتا به بررسی نقش اساسی در فرایند تصمیم‌گیری مصرف‌کننده توسط آمیگدالا پرداخته است (Scanagatta, 2021). ناحیه آمیگدالا به شدت با احساسات عمیق و قوی مانند خشم، هیجان، ترس، اضطراب مرتبط است. به گفته کارشناسان، تحریک این ناحیه از طریق جلوه‌های بصری، می‌تواند بر روند تصمیم‌گیری مصرف‌کننده تأثیر بگذارد. هدف دوم مطالعه فرایندهای مغز است تا بفهمند کدام فیلم یا عکس می‌تواند برای مصرف‌کننده تأثیرگذار باشد. این پژوهش نه تنها نقش آمیگدالا را در فرایندهای تصمیم‌گیری تأیید می‌کند، بلکه استفاده از روش‌های بازاریابی عصبی را برای رقابتی‌تر کردن شرکت‌ها تشویق می‌کند.

گنوردیادیس و همکاران ابتدا مناسب بودن رویکرد ریمانی^۳ را برای مسائل مرتبط با بازاریابی عصبی تعیین

ترجیحی و اولیه به کمک نظریه آبشاری خیرگی^۱ مورد تحلیل قرار گرفته است. سیگنال‌های EEG اطلاعاتی در مورد فعالیت مغز شرکت‌کنندگان ارائه کرده است و مطابق با مدل احساسات دیویدسون^۲ تحلیل شده است که نشان‌دهنده رویکرد یا تمایل به کناره‌گیری نسبت به محصولات مختلف است. نتایج پژوهش نشان داده است که با ردیابی حرکات چشم و سیگنال EEG می‌توان تفاوت بین پاسخ‌های شناختی و احساسی شرکت‌کنندگان را نسبت به محصولات انتخاب و ترجیح داده شده در مقایسه با محصولات انتخاب نشده اندازه‌گیری کرد. سیگنال‌های EEG شواهدی مبنی بر تفاوت در پاسخ‌های عصبی بین محصولات رنگی تطبیق اصلی و محصولات تطبیق غیراصلی ارائه کرده است؛ با این حال، پاسخ‌های ردیابی حرکات چشم تفاوت قابل توجهی در حرکات چشم بین این دو گروه از محصولات را نشان نداده است. در پژوهش آنها امکان ثبت سیگنال‌های EEG در محیط فروشگاه نیمه کنترل شده مورد نیاز است تا امکان تحلیل داده‌های عاری از آرتیفکت‌های حرکتی فراهم شود. این نتایج توانایی سنجش پاسخ‌های فیزیولوژیکی، عصبی و ناخودآگاه مصرف‌کنندگان را در یک محیط خرده‌فروشی شبیه دنیای واقعی نشان داده است؛ در حالی که به شرکت‌کنندگان اجازه داده شده است آزادانه و بدون مانع حرکت کنند. نتایج نشان‌دهنده تفاوت قابل توجه در پاسخ‌های احساسی در اولویت نسبت به محصولات رنگی اصلی دارد؛ بنابراین، پرایمینگ در تصمیم‌گیری در محیط‌های خرده‌فروشی مد تأثیر دارد.

امین و همکاران به تحلیل رفتار مصرف‌کننده با استفاده از سیگنال‌های EEG برای کاربرد بازاریابی

¹ Gaze Cascade Theory

² Davidson's model of emotion

³ Riemannian

می‌کنند که آنها واقعاً چه می‌خواهند. عملکرد سیستم‌های تشخیص اولویت مبتنی بر سیگنال EEG به انتخاب مناسب روش‌های استخراج ویژگی و الگوریتم‌های یادگیری ماشین بستگی دارد. آنها برای استخراج ویژگی از سیگنال EEG از DWT و چگالی طیف توان (PSD)^۴ استفاده کردند. طبقه‌بندی به کمک یادگیری عمیق انجام شده است و در نهایت، نتایج را با دیگر طبقه‌بندها مانند k نزدیک‌ترین همسایه (kNN)^۵، SVM و RF مقایسه کرده‌اند. نتایج نشان داده است عملکرد شبکه عصبی عمیق (DNN)^۶ از SVM و kNN در صحت و یادآوری بهتر است؛ با این حال، RF نتایج مشابه DNN برای همان مجموعه داده به دست آورده است.

با مطالعه پیشینه پژوهشی مشاهده می‌شود پژوهش‌ها در حوزه بازاریابی عصبی همچنان جذاب و هنوز به سطحی از رضایت‌مندی نرسیده است. این پژوهش معتقد است که اقدامات عصب‌روانشناختی به زودی به‌طور گسترده تأیید می‌شود و به‌عنوان یک روش مکمل در پژوهش‌های بازاریابی سنتی استفاده می‌شوند. در این پژوهش یک چهارچوب بازاریابی عصبی برای پیش‌بینی ترجیحات مصرف‌کننده در زمان مشاهده محصولات مختلف در فروشگاه اینترنتی ارائه می‌شود. در این پژوهش سیگنال‌های EEG افراد به کمک DWT، پیچیدگی لمپل زیو (LZC)^۷ و DNN پردازش می‌شوند و در نهایت، یک تحلیل مقایسه‌ای با سایر پژوهش‌های گذشته روی یک پایگاه داده یکسان انجام می‌شود.

۲- روش پژوهش

روش پیشنهادی پژوهش در روند نمای شکل ۱ آورده شده است. اولین گام معرفی مجموعه داده EEG

کردند و سپس یک طرح رمزگشایی مرتبط را برای پیش‌بینی انتخاب‌های مصرف‌کنندگان نظیر تمایل به خرید یا عدم تمایل به خرید یک محصول خاص را پیشنهاد دادند (Georgiadis et al., 2022). پال و همکاران نشان دادند که SVM با تابع هسته سیگموئید بهتر از طبقه‌بندهای دیگر برای پیش‌بینی انتخاب مصرف‌کننده هنگام بررسی برندهای مختلف از همان نوع محصولات عمل کرده است (Pal et al., 2021). آنها بیان داشتند در نتایج حاصله برای تفکیک دو دسته پسندیدن و نپسندیدن به درصد صحت خوبی نرسیدند و باید از مدل‌های پیچیده‌تر نظیر یادگیری عمیق برای دست‌یابی به صحت بالاتر استفاده شود.

کابا به بررسی کاربرد روش‌های یادگیری عمیق در بازاریابی عصبی به کمک سیگنال EEG در مقایسه با رویکردهای یادگیری ماشین سنتی پرداخت (Kaba, 2020). کابا عملکرد طبقه‌بند ترکیبی^۱ را با شبکه عصبی کانولوشن (CNN)^۲ بر روی دو مجموعه داده EEG که به‌طور مستقل جمع‌آوری شده است (یک مجموعه مربوط به انتخاب محصول و دیگری مربوط به رتبه‌بندی فیلم‌ها) مقایسه کرده است. درحالی‌که هر دو چهارچوب، عملکرد ضعیفی را برای پیش‌بینی انتخاب‌های محصول نشان داده‌اند، CNN در کار پیش‌بینی رتبه‌بندی فیلم بهتر بوده است. این نتیجه شواهدی را برای برتری روش‌های یادگیری عمیق در پیش‌بینی بازاریابی عصبی ارائه داده است (Kaba, 2020; Alimardani & Kaba, 2021).

آلدایل و همکاران برای پُر کردن شکاف بین مطالعات بازاریابی مرسوم و پژوهش‌های رابط مغز و رایانه (BCI)^۳ مبتنی بر سیگنال EEG از بازاریابی عصبی استفاده کرده‌اند (Aldayel et al., 2021). از طریق پیش‌بینی اولویت مصرف‌کنندگان، مشخص

^۴ Power Spectral Density

^۵ k-Nearest Neighbors

^۶ Deep Neural Network

^۷ Lempel Ziv Complexity

^۱ Ensemble

^۲ Convolutional Neural Network

^۳ Brain Computer Interface

تقسیم می‌شود. در نهایت، مدل پیشنهادی از طبقه‌بند DNN چهار لایه برای پیش‌بینی و تشخیص دو دستهٔ پسندیدن و نپسندیدن استفاده می‌کند.

است (Yadava et al., 2017)؛ سپس سیگنال‌های EEG پیش‌پردازش می‌شوند؛ سپس ویژگی‌های DWT و LZC از آنها استخراج می‌شوند؛ سپس ویژگی‌های استخراجی به‌نحی دیگر شده و به دو بخش آموزش و آزمون



شکل ۱: روند نمای روش پیشنهادی برای تحلیل ترجیحات مصرف‌کننده و تشخیص دو دستهٔ پسندیدن و نپسندیدن

۲-۱-۱ داده پژوهش

شرکت‌کنندگان ۴۲ تصویر محصول مختلف از ۱۴ دستهٔ ۳ تایی به مدت ۴ ثانیه مطابق شکل ۲ نشان داده شده است؛ بنابراین، در مجموع ۱۰۵۰ (یعنی ۴۲ در ۲۵) قطعه سیگنال EEG ثبت شده است که از این تعداد ۱۰۴۵ به صورت دسترسی آزاد است. پس از مشاهده، از شرکت‌کننده خواسته شده ترجیح خود را از نظر محصول به دو دستهٔ پسندیدن یا نپسندیدن بیان کند.

سیگنال EEG این پژوهش توسط هدست Emotiv EPOC+ ثبت شده است (Yadava et al., 2017). سیگنال‌های EEG تعداد ۲۵ شرکت‌کننده متعلق به موسسه فناوری هند ثبت شده است؛ در حالی که محصولات مختلف را روی صفحه نمایش رایانه تماشا می‌کردند. محدوده سنی شرکت‌کنندگان بین ۱۸ تا ۳۸ (متوسط سنی ۲۸/۱۵) سال بوده است. به هریک از

نوع	نمونه ۱	نمونه ۲	نمونه ۳	نوع	نمونه ۱	نمونه ۲	نمونه ۳
پیراهن				خودکار			
کفش				ساعت مچی			
کیف مدرسه				عینک آفتابی			
شال گردن				ژاکت			
کمر بند				جوراب			
دستکش				ساعت دیواری			
کروات				دستبند			

شکل ۲: مجموعه تصاویر کالاهای مختلف در سه نوع مختلف

پیش‌پردازش سیگنال EEG از ایجاد برخی اختلال‌های به وجود آمده جلوگیری می‌کند. در پژوهش‌ها معمولاً محدوده فرکانس سیگنال EEG زیر ۴۵ هرتز در نظر گرفته می‌شود؛ بنابراین، از یک پالایه میان‌گذر باترورت درجه دوم^۳ بین ۰/۴ تا ۴۵ هرتز برای حذف آرتیفکت‌ها استفاده شده است. سپس از پالایه دیجیتال ساویتزکی گولای^۴ برای هموارسازی^۵ سیگنال EEG استفاده شده است. پالایه ساویتزکی گولای مبتنی بر چندجمله‌ای است که روش چندجمله‌ای حداقل مربعی سیگنال‌های پالایه شده را با ارزیابی ترکیبی سیگنال‌های همسایه پیدا می‌کند. هدف اصلی این روش افزایش نسبت سیگنال به نویز است و این کار تا حد زیادی بدون خدشه‌دار شدن سیگنال اصلی انجام می‌دهد. در این روش که بر پایه انتگرال کانولوشن است، ابتدا سیگنال به پنجره‌هایی به طول n قسمت بندی می‌شود. سپس یک منحنی چندجمله‌ای با درجه m ($m < n$) به نقاط این بخش از سیگنال با روش حداقل مربعات خطا برازش می‌شود. گفتنی است که گرچه استفاده از این روش‌های هموارسازی باعث بهبود وضعیت ظاهری طیف می‌شود، ممکن است سبب حذف اطلاعات مفید و قابل استفاده شود (Nicolai et al., 2007). عملکرد پالایه ساویتزکی گولای بر روی سیگنال $S_j = f(t_j)$ به طول n که $j = 1, 2, \dots, n$ مطابق رابطه (۱) است.

$$Q_j = \sum_{i=-\frac{m-1}{2}}^{\frac{m-1}{2}} c_i S_{j+i}, \frac{m+1}{2} \leq j \leq n - \frac{m-1}{2} \quad (1)$$

که m دهانه فریم (طول پنجره در این پژوهش $m = 5$)، c_i بیانگر تعداد ضرایب کانولوشن و Q سیگنال هموار شده حاصل است. مقدار m برای محاسبه مقادیر c_i با یک چندجمله‌ای استفاده می‌شود.

سیگنال‌های EEG از طریق ۱۴ کانال در مناطق مختلف سطح سر با سیستم بین‌المللی ۱۰ - ۲۰ شامل AF3, F7, F8, FC5, T7, P7, O1, O2, P8, T8, FC6, F4, F8 و AF4 ثبت شده است. الکترودهای مرجع CMS^۱ و DRL^۲ به ترتیب در موقعیت‌های P3 و P4 در بالای گوش در قرار داده شده‌اند. در سیستم ثبت آنها داده‌ها با استفاده از اتصال بلوتوث به یک رایانه منتقل شده‌اند. فرکانس نمونه برداری سیگنال‌های EEG به صورت پیش فرض ۲۰۴۸ بوده است که به ۱۲۸ هرتز کاهش یافته است. سیستم ثبت قادر به اعمال پالایه‌های مختلف نرم‌افزاری روی سیگنال EEG بوده است؛ ولی سیگنال ذخیره شده در فایل‌ها به صورت خام و فاقد هرگونه پیش‌پردازش اولیه هستند. از شرکت کنندگان خواسته شده محصولات را برحسب پسندیدن یا نپسندیدن برچسب گذاری کنند.

شرکت کنندگان بر روی صندلی روبه‌روی یک صفحه نمایش نشسته‌اند و با مشاهده هر تصویر باید احساس دوست داشتن یا دوست نداشتن خود را با فشردن دکمه موس در مدت زمان ۴ ثانیه مشخص کنند تا سیگنال دریافتی مشخصاً مربوط به تصمیم هر شرکت کننده باشد. پس از آزمودنی شخص باید تا انتهای ۴ ثانیه تصویر را نگاه کند و بین نمایش محرک‌های تصویری مختلف، فیکسیشن برای توجه و آماده‌سازی کاربر نمایش داده نمی‌شود. داده شامل فایل برچسب مربوط به هر شخص است که در صورت پسندیدن محصول مقدار یک و در صورت نپسندیدن محصول مقدار منفی یک را گرفته است.

۲-۲- پیش‌پردازش سیگنال EEG

حرکات ناشی از پلک‌زدن، حرکت ماهیچه‌های صورت و ضربان قلب در هنگام ثبت سیگنال EEG از عوامل ایجاد آرتیفکت‌های ناخواسته هستند؛ بنابراین،

³ Second-order Butterworth

⁴ Savitzky-Golay

⁵ Smoothing

¹ Common Mode Sense

² Driven Right Leg

مقادیر محاسبه شده برای c_i عبارت اند از ۳-، ۱۲، ۱۷، ۱۲ و ۳-.

۳-۲- استخراج ویژگی

۳-۲-۱- تبدیل موجک گسسته

استخراج ویژگی فرایندی برای استخراج اطلاعات مرتبط از داده‌های خام است. روش‌های مختلفی برای استخراج ویژگی از سیگنال‌های EEG وجود دارد. یکی از مناسب‌ترین روش‌ها برای پردازش سیگنال EEG روش تبدیل موجک (WT) است. هنگام استخراج ویژگی‌ها دامنه زمان و هم دامنه فرکانس در نظر گرفته می‌شود. برای حد تفکیک فرکانس بالا یا پایین، به ترتیب از پنجره‌های کوتاه مدت و بلندمدت استفاده می‌شود. در این روش سیگنال‌های EEG با استفاده از موجک‌ها نمایش داده می‌شوند. یک موجک مادر وجود دارد که باعث پیدایش این موجک‌ها می‌شود. دو نوع روش تبدیل موجک نظیر تبدیل موجک پیوسته (CWT) و DWT وجود دارد. در اینجا از DWT برای استخراج ویژگی استفاده شده است.

DWT یک روش تحلیل دامنه زمان فرکانس است که سیگنال‌ها را به ضرایب مختلف تجزیه می‌کند. می‌توان DWT را به عنوان تجزیه و تحلیل چندمقیاسی تعریف کرد که در آن هر ضریب نمایش منحصر به فردی از سیگنال‌های ذهنی است. عملیات کانولوشن یک فرایند ضرب دو تابع است (Chen et al., 2015; Vega-Escobar, et al., 2015). هر ضرب داخلی یک ضریب موجک را به همراه دارد؛ بنابراین، DWT را می‌توان با استفاده از رابطه (۲) بیان کرد.

$$W(j, k) = \sum_{N=0}^{M-1} f(n) \cdot \psi_{j,k}^*(n), \quad (2)$$

که در آن $f(n)$ سیگنال (دنباله) به طول n و $\psi_{j,k}^*(n)$ تابع موجک مقیاس پذیر است. تجزیه DWT را می‌توان به عنوان گروهی از پالایه‌های بالاگذر (HP) و پایین‌گذر (LP) در یک بانک پالایه پیاده‌سازی کرد. خروجی پالایه‌های پایین‌گذر را ضرایب تقریبی (A) و خروجی پالایه‌های بالاگذر را ضرایب جزئیات (D) موجک می‌نامند. پس از پالایه کردن، سیگنال با ضریب دو براساس قضیه نایکوئیست نمونه برداری می‌شود و در نتیجه یک باند فرکانسی بین f_n و $f_n/2$ ایجاد می‌شود. با فرض فرکانس نمونه برداری f_s و سطح تجزیه L ، هر فرکانس ضریب جزئیات مربوط به نرخ فرکانس نمونه برداری f_s سیگنال‌های خام است که با $f_n = f_s/2L + 1$ ارائه می‌شود. در استفاده از تبدیل موجک تعداد سطوح تجزیه موجک و انتخاب موجک مادر مناسب برای دستیابی به تحلیل مطلوب DWT حیاتی است. هرچه شکل موجک مادر هم خوانی بهتری با سیگنال اصلی داشته باشد، تجزیه با کیفیت بهتری صورت می‌گیرد. در حالت کلی یک روش معمول برای انتخاب موجک مادر مشاهده نتیجه هر موجک پایه و به عبارت دیگر، شباهت شکل ظاهری موجک با سیگنال اصلی است.

انتخاب تعداد سطوح مبتنی بر اجزای فرکانس غالب است و به نحوی انتخاب می‌شود که قسمت‌هایی از سیگنال که با فرکانس‌های لازم برای طبقه‌بند همبستگی دارند، به وسیله ضرایب موجک نگه داشته شوند. از آنجایی که فرکانس نمونه برداری در مطالعه حاضر ۱۲۸ هرتز است، از چهار سطح موجک دابشیز ۴ (db4) برای تجزیه سیگنال‌های EEG به پنج ضریب، یعنی D_1 ، D_2 ، D_3 ، D_4 و A_4 استفاده می‌شود. هر ضریب تقریباً با محدوده‌های فرکانسی پایه، یعنی دلتا

³ High Pass

⁴ Low Pass

⁵ Approximation

⁶ Detail

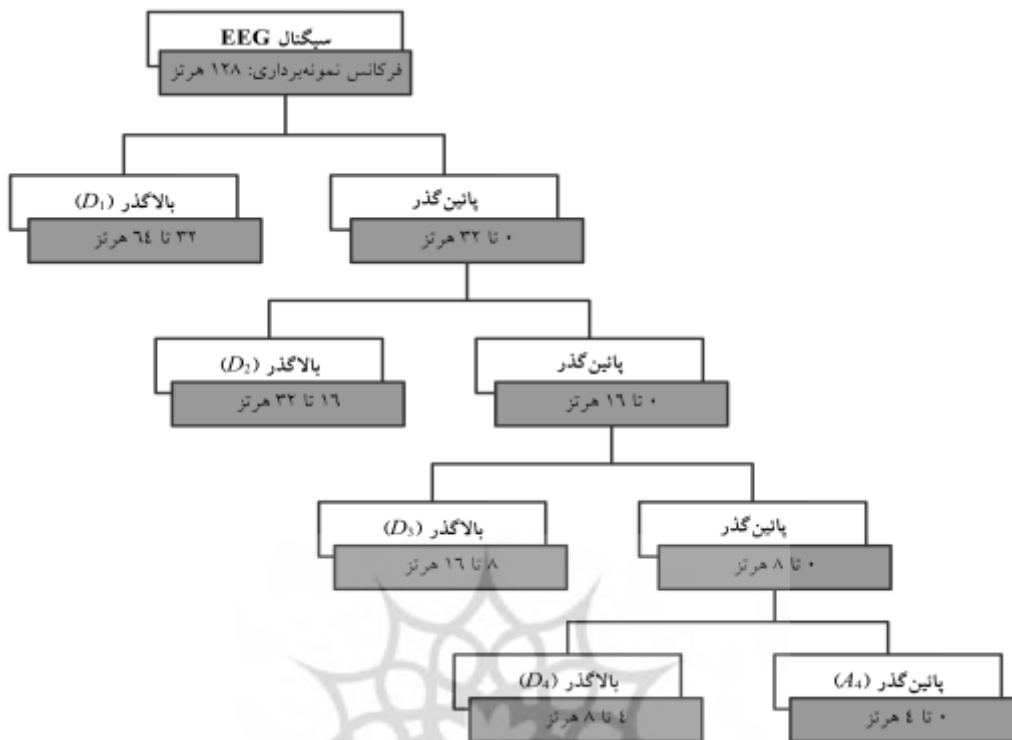
⁷ Daubechies

¹ Wavelet Transform

² Continuous Wavelet Transform

جزئیات تجزیه شده D_1-D_4 و تقریب A_4 برای هریک از ۱۴ کانال در شکل ۳ نشان داده شده است.

(۴-۱) هرتز، بتا (۸-۴) هرتز، آلفا (۸-۱۳) هرتز، بتا (۳۰-۱۳) هرتز و گاما (۳۰-۴۵) هرتز مرتبط است.



شکل ۳: سطوح مختلف تجزیه DWT توسط پالایه پایین گذر و پالایه بالاگذر D_1, D_2, D_3, D_4 و A_4 مربوط به دلتا، بتا، آلفا، بتا و گاما با فرکانس نمونه برداری ۱۲۸ هرتز

می شوند. در نهایت، تعداد ویژگی های DWT برابر $11 \times 5 \times 14 = 770$ است.

مطابق شکل ۳ مؤلفه A_4 تقریباً در داخل محدوده فرکانسی دلتا (1-4 Hz)، D_4 تقریباً در محدوده بتا (4-8 Hz)، D_3 تقریباً در محدوده آلفا (8-13 Hz)، D_2 تقریباً در محدوده بتا (13-30 Hz) و D_1 تقریباً در محدوده گاما (30-45 Hz) قرار دارند؛ بنابراین، این پنج بازه به عنوان ضرایب معتبر استخراج می شوند. علاوه بر این مقادیر، آنتروپی شانون به عنوان معیار سنجش پیچیدگی سیگنال و ویژگی های آماری واریانس، انحراف معیار، متوسط، میانه، مقادیر صدک ۲۵ام و ۷۵ام، ریشه میانگین مربع (RMS)^۱ مقادیر متوسط دامنه، نرخ عبور از صفر و متوسط مشتقات سیگنال استخراج می شوند؛ بنابراین، ده ویژگی آماری، مقدار آنتروپی و مقادیر پنج ضریب در ۱۴ کانال سیگنال EEG محاسبه

۲-۳-۲- پیچیدگی لمپل زیو
یکی دیگر از روش های تحلیل غیرخطی برای داده های با طول کم LZC است (Lempel & Ziv, 1976). این معیار در مقایسه با سایر معیارهای پیچیدگی، ساده و سریع است. مطالعات قبلی نشان داده اند که LZC به دلیل حساسیت بیشتر به توزیع دامنه زمانی، با موفقیت برای تشخیص اختلالات روانی استفاده شده است؛ از این رو، می تواند ویژگی خوبی برای توصیف حالات مختلف مغز باشد (Fernandez et al., 2011). LZC تعداد الگوهای ایجاد شده جدید را برای دنباله های با طول محدود می شمارد. برای محاسبه LZC، سری های زمانی ابتدا باید به یک دنباله

¹ Root Mean Square

در اینجا برای تبدیل باینری مقدار $\alpha = 2$ در نظر گرفته شده است. برای جزئیات بیشتر درخصوص محاسبه LZC می‌توان به (Fernandez et al., 2011) مراجعه کرد.

۲-۴- بهنجارسازی ویژگی‌های استخراج شده

ویژگی‌های استخراج شده (F) از بازه دلخواه $[F_{min}, F_{max}]$ با استفاده از رابطه (۶) در بازه بین صفر و یک بهنجار می‌شوند و سپس به طبقه‌بند DNN وارد می‌شوند.

$$F_{Norm} = \frac{F - F_{min}}{F_{max} - F_{min}} \quad (6)$$

که F_{min} مقدار کمینه ویژگی، F_{max} مقدار بیشینه ویژگی و F_{Norm} مقدار دامنه نسبی (مقدار ویژگی بهنجار شده) است.

۲-۵- طبقه‌بند شبکه عصبی عمیق

یادگیری عمیق قادر به ارائه راه‌حل‌های بهینه برای بسیاری از مسائل در پردازش زبان طبیعی، طبقه‌بندی تصویر، پردازش سیگنال و تشخیص گفتار است (Aldayel et al., 2021; Hinton et al., 2012; Kumar et al., 2016). یادگیری عمیق در کاربرد BCI یک ابزار مؤثر برای تحلیل سیگنال‌های EEG است (Roy et al., 2019). به زبان ساده، یادگیری عمیق به مجموعه‌ای از روش‌های محاسباتی اشاره دارد که اخیراً برای آموزش DNN توسعه یافته‌اند (Hinton et al., 2006). در پژوهش حاضر هدف تشخیص دو دسته ترجیحی پسندیدن یا نپسندیدن از سیگنال‌های EEG در کاربرد بازاریابی عصبی به کمک DNN است.

DNN یک شبکه عصبی با بیش از یک لایه پنهان است. شبکه عصبی معمولی دارای یک لایه ورودی، یک لایه پنهان و یک لایه خروجی است. در این پژوهش از DNN با چهار لایه کاملاً متصل روبه‌جلو^۳

با سمبل‌های محدود تبدیل شوند. برای سادگی تنها یک دنباله باینری (صفر و یک) نظیر $P_b = S(1), S(2), \dots, S(N)$ را در نظر بگیرید که در آن $S(i) \in \{0,1\}, i = 1,2, \dots, N$ طول داده (طول پنجره) است. برای محاسبه LZC، ابتدا سیگنال با یک آستانه T_d مقایسه می‌شود و به دنباله باینری از «0» و «1»ها مطابق رابطه (۳) تبدیل می‌شود.

$$S(i) = \begin{cases} 0, & \text{if } x(i) < M \\ 1, & \text{if } x(i) \geq M \end{cases} \quad (3)$$

که M تخمینی از مقدار میانه^۱ دامنه سیگنال در هر کانال است. میانه به دلیل مقاوم بودن نسبت به موارد پرت و مجزا^۲ انتخاب شده است (Nagarajan, 2002; Zhang et al., 2001). دنباله P_b از چپ به راست پویش می‌شود و یک شمارنده پیچیدگی $c(n)$ هر زمان که یک زیر دنباله جدید کاراکترهای بعدی در فرآیند پویش واقع شود، یک واحد افزایش می‌یابد. هر بار که با یک الگوی جدید مواجه می‌شود، پیچیدگی $c(n)$ افزایش می‌یابد. $c(n)$ بیانگر مقدار LZC سری زمانی است و با مقدار ۱ شروع می‌شود و به محض ظهور یک دنباله جدید یک واحد به آن اضافه می‌شود. برای به دست آوردن یک سنجش پیچیدگی که مستقل از طول دنباله است، $c(n)$ باید بهنجار شود. کران بالای $c(n)$ به صورت رابطه (۴) به دست می‌آید.

$$c(n) < \frac{n}{(1 - \varepsilon_n) \log_{\alpha} n} \quad (4)$$

که α بیانگر تعداد نمادهای مختلف و ε_n بیانگر یک مقدار کوچک است و به عبارت دیگر، در $n \rightarrow \infty$ مقدار $\varepsilon_n \rightarrow 0$ میل می‌کند. به طور کلی، حد بالای $c(n)$ است. بعد از بهنجارسازی $c(n)$ مطابق رابطه (۵)، $C(n)$ بیانگر نرخ اتفاق افتادن الگوهای جدید در زمان که با افزایش طول دنباله ایجاد شده است.

$$C(n) = \frac{c(n)}{\lim_{n \rightarrow \infty} c(n)} = \frac{c(n)}{\frac{n}{\log_{\alpha} n}} \quad (5)$$

¹ Median

² Outliers

³ Fully connected feed-forward

شامل یک لایه ورودی، سه لایه پنهان و یک لایه خروجی مطابق شکل ۴ استفاده می‌شود.



شکل ۴: ساختار شبکه DNN با سه لایه پنهان

که نرخ یادگیری برای آخرین دوره ۰/۰۱ باشد. نرخ حذف^۶ برای لایه ورودی و لایه‌های پنهان (به جز لایه خروجی) روی ۰/۵ تنظیم شد. در این پژوهش نرخ حذف به منظور جلوگیری از یادگیری بیش از حد^۷ داده‌های آموزشی پیاده‌سازی شده است. نرخ حذف به خروج تصادفی واحدها یا نورون‌ها در یک شبکه عصبی در طول هر مرحله آموزشی اشاره دارد. افزودن نرخ حذف به یک شبکه عصبی معمولاً به عملکرد تعمیم بهتر منجر می‌شود؛ زیرا اساساً در طول هر مرحله آموزشی، نوع متفاوتی از شبکه عصبی آموزش داده می‌شود که از وابستگی مشترک بین نورون‌ها جلوگیری می‌کند.

معیار توقف آموزش شبکه براساس عملکرد مدل در مجموعه اعتبارسنجی است. اگر شبکه شروع به یادگیری بیش از حد کند، آموزش شبکه متوقف می‌شود. این معیار توقف در کاهش یادگیری بیش از حد برآزش در داده‌های اعتبارسنجی مفید است. سپس، طبقه‌بند DNN بر روی یک مجموعه آزمون آزمایش شد. مجموعه آزمون شامل ۲۰ درصد از نمونه‌های داده بود. همچنین، افزودن نویز گوسی^۸ به مدل DNN در یک مجموعه داده نسبتاً کوچک، می‌تواند استحکام آن را با اثر منظم کننده بهبود بخشد و از یادگیری بیش از حد

لایه ورودی به عنوان یک لایه در شبکه محاسبه نمی‌شود و به عنوان لایه صفر شناخته می‌شود. لایه‌های پنهان شامل واحدهایی با توابع فعال‌سازی خطی اصلاح شده (ReLU)^۱ هستند (Kingma & Ba, 2014; He et al., 2015). خروجی به عنوان یک لایه softmax با تابع هزینه آنتروپی متقاطع^۲ باینری پیکربندی شده است. هر لایه پنهان ۶۰ درصد از لایه قبلی خود تشکیل شده است؛ بنابراین، اولین لایه پنهان شامل ۱۸۰۰ واحد، دومین لایه پنهان شامل ۱۰۸۰ واحد و سومین لایه پنهان شامل ۶۴۸ واحد است. ابعاد لایه خروجی دو است؛ زیرا با تعداد واحد لازم برای تشخیص دو دسته پسندیدن و نپسندیدن هدف مطابقت دارد.

برای آموزش طبقه‌بند DNN، از گرادیان نزول آدام^۳ با تابع تلفات لگاریتمی استفاده شده است که آنتروپی متقاطع طبقه‌ای^۴ به عنوان تابع تلفات هدف نامیده می‌شود. برای تمام مقادیر اولیه وزن تصادفی، مقداردهی اولیه^۵ می^۵ مطابق (He et al., 2015) انتخاب شد. برای انتقال یادگیری، الگوریتم با پیش فرض ۰/۰۲ به عنوان نرخ یادگیری شروع انتخاب می‌شود و سپس با هر دوره به صورت خطی کاهش داده می‌شود؛ به طوری

¹ Rectified Linear Unit

² Cross-entropy

³ Adam gradient descent

⁴ Categorical cross-entropy

⁵ He-initialization

⁶ Dropout

⁷ Excessive learning

⁸ Gaussian noise

محاسبه معیارهای عملکرد دقت، فراخوانی و صحت به شرح زیر است.

دقت نسبت مشاهدات مثبت پیش‌بینی شده صحیح به کل مشاهدات مثبت پیش‌بینی شده است. دقت به طور شهودی توانایی طبقه‌بند است که نمونه‌ای را که منفی است، به عنوان مثبت نشان ندهد و مطابق رابطه (۷) درصد دقت محاسبه می‌شود.

$$Precision = \frac{T_P}{T_P + F_P} \times 100\% \quad (7)$$

فراخوانی نسبت مشاهدات مثبت پیش‌بینی شده درست به همه مشاهدات در دسته واقعی است. فراخوان به طور شهودی توانایی طبقه‌بند برای یافتن تمام نمونه‌های مثبت است و مطابق رابطه (۸) درصد فراخوانی محاسبه می‌شود.

$$Recall (Sensitivity) = \frac{T_P}{T_P + F_N} \times 100\% \quad (8)$$

صحت یکی از مفیدترین معیارها برای ارزیابی طبقه‌بند است. این کسری از پیش‌بینی‌های صحیح از همه پیش‌بینی‌ها است. در مدل پیشنهادی، صحت بالاتر به معنای قدرت مدل برای پیش‌بینی صحیح این است که آیا مصرف‌کننده محصول را پسندیده است یا خیر. درصد صحت را می‌توان مطابق رابطه (۹) محاسبه کرد.

$$Accuracy = \frac{T_N + T_P}{T_N + T_P + F_N + F_P} \times 100\% \quad (9)$$

جدول ۱ مقادیر چهار عنصر ماتریس درهم‌ریختگی برای یک بار آزمایش آورده شده است.

بکاهد. بدین منظور، در این پژوهش از نویز گوسی سیگما در لایه‌های پنهان استفاده شده است.

۳- یافته‌ها

در این پژوهش ابتدا سیگنال‌های EEG توسط پالایه‌های میان‌گذر و ساویترکی گولای پیش‌پردازش می‌شوند و سپس ویژگی‌های DWT و LZC از آنها استخراج می‌شوند؛ سپس ویژگی‌های بهنجار شده به دو بخش آموزش و آزمون تقسیم می‌شوند. در مدل پیشنهادی، طبقه‌بند DNN چهار لایه برای پیش‌بینی و تشخیص دو دسته پسندیدن و نپسندیدن استفاده شده است. شبیه‌سازی‌ها در محیط نرم‌افزار MATLAB 2014a انجام شده است.

۳-۱- معیارهای عملکردی

عملکرد طبقه‌بند با استفاده از معیارهای عملکردی نظیر دقت^۱، فراخوانی^۲ (حساسیت^۳) و صحت^۴ اندازه‌گیری می‌شود. هریک از مقادیر عناصر ماتریس درهم‌ریختگی^۵ بدین شرح است: مثبت واقعی (T_P) مواردی است که مصرف‌کننده محصول را پسندیده و پیش‌بینی درست بوده است. منفی واقعی (T_N) مصرف‌کننده محصول را نپسندیده، اما درست پیش‌بینی شده است. مثبت کاذب (F_P) در اینجا مصرف‌کننده محصول را پسندیده و پیش‌بینی اشتباه بوده است. منفی کاذب (F_N) در اینجا مصرف‌کننده محصول را نپسندیده و پیش‌بینی اشتباه بوده است. معرفی نحوه

¹ Precision
² Recall
³ Sensitivity
⁴ Accuracy
⁵ Confusion matrix
⁶ True Positive
⁷ True Negative
⁸ False Positive
⁹ False Negative

جدول ۱: مقادیر چهار عنصر ماتریس درهم ریختگی برای یک بار آزمایش

مقدار	پارامتر
۹/۷	F_P
۴۷/۲	T_P
۴/۹	F_N
۳۸/۲	T_N

مقدار پارامترهای آماری دقت، فراخوانی و صحت در جدول ۲ برای یک بار آزمایش آورده شده است. طبق نتایج حاصل شده، مقدار پارامتر دقت ۸۲/۹۵ درصد، فراخوانی ۹۰/۵۹ درصد و صحت ۸۵/۴ درصد برای تشخیص دو دسته پسندیدن و نپسندیدن به دست آمده است. نرخ طبقه بندی اشتباه هم ۱۴/۶ درصد است.

مقدار پارامترهای آماری دقت، فراخوانی و صحت در جدول ۲ برای یک بار آزمایش آورده شده است. طبق نتایج حاصل شده، مقدار پارامتر دقت ۸۲/۹۵ درصد، فراخوانی ۹۰/۵۹ درصد و صحت ۸۵/۴ درصد برای تشخیص دو دسته پسندیدن و نپسندیدن به دست آمده است. نرخ طبقه بندی اشتباه هم ۱۴/۶ درصد است.

جدول ۲: نمایش مقادیر پارامترهای دقت، فراخوانی و صحت پس از پنج بار متوسط گیری

مقدار (درصد)	پارامتر
۸۲/۹۵	دقت
۹۰/۵۹	فراخوانی
۸۵/۴	صحت

۲-۳- مقایسه نتایج با پژوهش های گذشته در گذشته کارهای پژوهشی مختلفی در زمینه انتخاب و ترجیحات مصرف کننده انجام شده است. در جدول ۲ مقایسه ای بین مدل پیشنهادی و پژوهش های گذشته مبتنی بر تشخیص ترجیحات مصرف کنندگان بر روی یک پایگاه داده یکسان آورده شده است.

مقدار پارامترهای آماری دقت، فراخوانی و صحت پس از پنج بار متوسط گیری عبارت است از دقت ۸۲ درصد، فراخوانی ۹۰/۵۹ درصد و صحت ۸۵/۴ درصد برای تشخیص دو دسته پسندیدن و نپسندیدن به دست آمده است. نرخ طبقه بندی اشتباه هم ۱۴/۶ درصد است.

جدول ۲: مقایسه نتایج مدل پیشنهادی با پژوهش های گذشته در مورد پیش بینی اولویت مصرف کننده بر روی یک پایگاه داده یکسان

مقدار (درصد)	روش/روش های تحلیل	مرجع
۶۰/۱۰	DWT-DNN	(Yadava et al., 2017)
۶۲/۸۵	DWT-SVM	
۶۸/۴۱	DWT-RF	
۷۰/۳۳	DWT-HMM	
۵۰/۷۱	Ensemble	(Kaba, 2020)
۵۱/۴۸	CNN	(Alimardani et al., 2021)
۷۳	PSD-DWT-kNN	(Aldayel et al., 2021)
۸۱	PSD-DWT-SVM	
۸۳	PSD-DWT-DNN	
۸۷	PSD-DWT-RF	
۸۷/۵	DWT-LZC-DNN	مدل پیشنهادی

بازاریابی عصبی برای پُر کردن شکاف بین مطالعات بازاریابی مرسوم و پژوهش‌های BCI مبتنی بر سیگنال EEG ایجاد شده است. اگر بازاریابی عصبی به بالاترین ظرفیت خود برسد، مصرف‌کننده و هم تبلیغ‌کننده سود خواهند بُرد. مشتریان مجبور نخواهند بود محصولاتی را جست‌وجو کنند که نیازهای آنها را برآورده کند و نهایت آرزوهای آنها فوراً برآورده خواهد شد. این زمانی است که متوجه می‌شوید بازاریابی عصبی چقدر موفق بوده است.

عملکرد سیستم‌های تشخیص اولویت مبتنی بر سیگنال EEG به انتخاب مناسب روش‌های استخراج ویژگی و الگوریتم‌های یادگیری ماشین بستگی دارد. در این مقاله از سیگنال‌های EEG ۲۵ شرکت‌کننده در زمان مشاهده ۱۴ محصول مختلف اینترنتی در سه نوع متفاوت استفاده شده است. در این کار پژوهشی سیگنال‌های EEG را برای درکِ بهتر رفتار، انتخاب و ترجیح مصرف‌کننده تحلیل شد؛ بنابراین، ابتدا سیگنال‌های EEG توسط پالایه‌های میان‌گذر باترورث درجه دوم و ساویتزکی گولای پیش‌پردازش می‌شوند و ویژگی‌های DWT و LZC از آنها استخراج می‌شوند؛ سپس ویژگی‌های استخراجی بهنجار شده به دو بخش آموزش و آزمون تقسیم می‌شوند. سپس ویژگی‌های بهنجار شده به DNN برای پیش‌بینی نتیجه آموزش داده می‌شوند و در نهایت، پس از انجام آموزش مدل پیشنهادی آماده پیش‌بینی است. شواهد نشان داده است سیگنال EEG ماهیتی آشوب‌گون دارد؛ بنابراین، از روش آشوب‌گون غیرخطی در کنار DWT برای استخراج ویژگی استفاده شده است. LZC میزان وقوع الگوهای جدید را در چند زمان نشان می‌دهد. هرچه LZC بزرگ‌تر باشد، احتمال الگوهای توالی جدید بیشتر است و در نتیجه، رفتار دینامیکی پیچیده‌تری ایجاد می‌شود.

درصد صحت مدل پیشنهادی با توجه به جدول ۲ از روش‌های موجود قبلی (Yadava et al., 2017; Kaba, 2021; Alimardani, 2021; Aldayel, 2021) بر روی یک پایگاه داده یکسان بهتر عمل کرده و افزایش ۵/۰ درصدی را نسبت به مرجع (Aldayel et al., 2021) نشان می‌دهد. این افزایش صحت به نظر می‌رسد به دلیل استفاده از روش آشوب‌گون LZC به کمک DWT با طبقه‌بند DNN باشد. در مرجع (Aldayel et al., 2021) مشاهده می‌شود که استفاده از DWT و DNN به نتایج بهتری منجر شده است؛ بنابراین، با مقایسه نتایج با پژوهش‌های گذشته، روش استخراج ویژگی ترکیبی LZC با DWT و استفاده از طبقه‌بند DNN نقش مؤثری در پیش‌بینی مدل پیشنهادی برای تفکیک دو دسته پسنیدن و نپسنیدن دارد.

۴- بحث و نتیجه‌گیری

بازاریابی عصبی به کارگیری عصب‌روان‌شناسی در پژوهش‌های بازاریابی است تا با استفاده از فناوری‌های نوین به مطالعه حسی-حرکتی رفتار مصرف‌کننده مانند پاسخ‌های شناختی و احساسی به محرک‌های بازاریابی بپردازد. امروزه استفاده از روش‌های سنتی بازاریابی مانند پرسشنامه، نظرسنجی، مصاحبه شخصی، مشاهدات، بررسی حالت‌ها و ارتباطات کلامی کم‌رونق شده است. سازمان‌های تجاری علاقه‌مند به روش‌های نفوذ در ذهن مصرف‌کننده و تسلط بر خواسته‌های مصرف‌کننده شده‌اند تا بازخورد بهتر و قوی‌تری از محصولات یا خدمات خود دریافت کنند.

این پژوهش روشی برای کشف فعالیت مغزی مصرف‌کنندگان به کمک سیگنال‌های EEG با استفاده از روش‌های بازاریابی عصبی طراحی شده است. هدف اصلی این مطالعه بررسی اثرات تبلیغات بر فعالیت مغزی مصرف‌کنندگان با تحلیل سیگنال‌های EEG است.

حوزه زمانی سیگنال‌های EEG ادغام کرد، می‌توان ویژگی‌های ترجیح دیداری مصرف کننده را استخراج کرد. برای مثال، چه شیء یا چه رنگی بر آنها تأثیر می‌گذارد.

References

- Aldayel, M., Ykhlef, M., & Al-Nafjan, A. Deep learning for EEG-based preference classification in neuromarketing. *Applied Sciences*, 10(4), 1525, 2020.
- Aldayel, M., Ykhlef, M., & Al-Nafjan A. (2021). Recognition of consumer preference by analysis and classification EEG signals. *Frontiers in Human Neuroscience*, 560.
- Alimardani, M. & Kaba, M. (2021). Deep Learning for Neuromarketing; Classification of User Preference using EEG Signals. *12th Augmented Human International Conference*, Geneva, Switzerland, 1-7.
- Al-Nafjan, A., Hosny, M., Al-Ohali, Y., & Al-Wabil A. (2017). Review and classification of emotion recognition based on EEG brain-computer interface system research: a systematic review. *Applied Sciences*, 7(12), 1239.
- Amin, C. R., Hasin, M. F., Leon, T. S., Aurko, A. B., Tamanna, T., Rahman, & M. A., Parvez, M. Z. (2020). Consumer Behavior Analysis using EEG Signals for Neuromarketing Application. *IEEE Symposium Series on Computational Intelligence (SSCI)*, 2061–2066.
- Chen, L., Zhao, Y., Zhang, J., & Zou, J. (2015). Automatic detection of alertness/drowsiness from physiological signals using wavelet-based nonlinear features and machine learning. *Expert Systems with Applications*, 42(21), 7344-7355.
- Fernández, A., López-Ibor, M. I., Turrero, A., Santos, J. M., Morón, M. D., Hornero, R., Gómez, C., Méndez, M. A., Ortiz, T., & López-Ibor, J. J. (2011). Lempel–Ziv complexity in schizophrenia: a MEG study. *Clinical neurophysiology*, 122(11), 2227-2235.
- Georgiadis, K., Kalaganis, F. P., Oikonomou, V. P., Nikolopoulos, S., Laskaris, N. A., & Kompatsiaris, I. (2022). RNeuMark: A

از معیارهای ارزیابی مختلف نظیر دقت، یادآوری و صحت برای سنجش عملکرد طبقه‌بند استفاده شده است. درنهایت، مدل پیشنهادی توانسته با صحت ۸۷/۵ درصد دو دسته پسندیدن و نپسندیدن را از یکدیگر تفکیک کند که افزایش ۰/۵ درصدی را نسبت به مرجع (Aldayel et al., 2021) نشان می‌دهد. همچنین، با مقایسه نتایج با مراجع (Aldayel et al., 2021; Yadava et al., 2017) نشان می‌دهد روش استخراج ویژگی LZC نقش مؤثری در پیش‌بینی مدل پیشنهادی برای تفکیک دو دسته پسندیدن و نپسندیدن دارد. نتایج نشان می‌دهد روش پیشنهادی می‌تواند راه‌حل مکمل برای اقدامات سنتی پیش‌بینی موفقیت محصول در بازار ارائه دهد. همچنین، روش پیشنهادی می‌تواند در توسعه استراتژی‌های بازار، پژوهش و پیش‌بینی موفقیت بازار با گسترش مدل‌های موجود استفاده شود. این روش به تبلیغ کنندگان کمک می‌کند تا متوجه شوند کدام یک از تبلیغات آنها مؤثر است و چگونه باید استراتژی تبلیغات خود را برنامه‌ریزی کنند. تلاش برای راه‌های جدید و سودآور هنوز یک سؤال پژوهشی باز است؛ بدین‌منظور، پیشنهادهایی جهت بهبود پژوهش در آینده می‌توان ارائه داد. الف) برای دستیابی به یک نتیجه واضح‌تر و قابل‌توجه‌تر داده با تعداد شرکت کنندگان بیشتر لازم است؛ ب) در زمان فرایند ثبت می‌توان از الکترودهای خشک، برای آزمون‌های قابل‌جابه‌جایی افراد در پژوهش‌های دنیای واقعی استفاده کرد؛ ج) از روش‌های تحلیل بلادرنگ استفاده شود؛ د) استفاده از داده ردیابی حرکات چشم نیز در تحلیل‌ها مفید است و ه) برنامه‌ریزی برای استخراج ویژگی‌های صورت مصرف‌کننده برای پیش‌بینی اولویت مصرف‌کننده نیز در دستور کار قرار گیرد. پردازش تصویر می‌تواند در این زمینه پژوهش‌ها را کمک کند. اگر بتوان پردازش تصویر را در همان

- Nicolai, B. M., Beullens, K., Bobelyn, E., Peirs, A., Saeys, W., Theron, K. I., & Lammertyn J. (2007). Nondestructive measurement of fruit and vegetable quality by means of NIR spectroscopy: A review. *Postharvest biology and technology*, 46(2), 99-118.
- Pal, S., Das, P., Sahu, R., & Dash S. R. (2021). Study of Neuromarketing with EEG Signals and Machine Learning Techniques. *Machine Learning for Healthcare Applications*, 33-56.
- Penenberg, A. (2011). NeuroFocus uses neuromarketing to hack your brain. *Fast company*, 84-125.
- Pozharliev R., (2017). Social Neuromarketing: The role of social context in measuring advertising effectiveness. PhD Thesis, 2017.
- Roy, Y., Banville, H., Albuquerque, I., Gramfort, A., Falk, T. H., & Faubert, J. (2019). Deep learning-based electroencephalography analysis: a systematic review. *Journal of neural engineering*, 16(5), 051001.
- Scanagatta, C. (2021). Exploring the consumer's brain: a neuromarketing approach. Msc Thesis, Ca' Foscari University of Venice.
- Trimble, E. (2018). *The Influence of Colour Priming on Consumers' Physiological Responses in a Retail Environment Using EEG and Eye-Tracking*. The University of Manchester (United Kingdom).
- Vega-Escobar, L., Castro-Ospina, A. E., & Duque-Munoz, L. (2015). DWT-based feature extraction for motor imagery classification, *6th Latin-American Conference on Networked and Electronic Media (LACNEM)*.
- Yadava, M., Kumar, P., Saini, R., Roy, P. P., & Dogra, D. P. (2017). Analysis of EEG signals and its application to neuromarketing. *Multimedia Tools and Applications*, 76(18), 19087-19111.
- Zhang, X. S., Roy, R. J., & Jensen, E. W. (2001). EEG complexity as a measure of depth of anesthesia for patients. *IEEE Transactions on Biomedical Engineering*, 48(12), 1424-1433.
- Riemannian EEG Analysis Framework for Neuromarketing.
- He, K., Zhang, X., Ren, S., & Sun, J. (2015). Delving deep into rectifiers: Surpassing human-level performance on imagenet classification," *IEEE international conference on computer vision*, 1026-1034.
- Hinton, G., Deng, L., Yu, D., Dahl, G. E., Mohamed, A. R., Jaitly, N., Senior, A., Vanhoucke, V., Nguyen, P., Sainath, T. N., & Kingsbury, B. (2012). Deep neural networks for acoustic modeling in speech recognition: The shared views of four research groups," *IEEE Signal processing magazine*, 29(6), 82-97.
- Hinton, G. E., Osindero, S., & Teh, Y. W. (2006). A fast learning algorithm for deep belief nets. *Neural computation*, 18(7), 1527-1554.
- Kaba, M. (2020). The Application of Deep Learning and Traditional Machine Learning in EEG Neuromarketing Prediction Tasks. PhD Thesis, Tilburg University.
- Kingma, D. P. & Ba, J. (2014). Adam: A method for stochastic optimization. *arXiv preprint arXiv:1412.6980*.
- Krajnović, A., Sikirić, D., & Jašić D. (2012). Neuromarketing and customers' free will. *Gomezelj Omerznel, D., Nastav, B., Sedmak, S., MIC*, 1143-1163.
- Kumar, S., Sharma, A., Mamun, K., & Tsunoda, T. (2016). A deep learning approach for motor imagery EEG signal classification. *3rd Asia-Pacific World Congress on Computer Science and Engineering (APWC on CSE)*, 34-39.
- Lempel, A. & Ziv, J. (1976). On the complexity of finite sequences. *IEEE Transactions on Information Theory*, 22(1), 75-81.
- Mathewson, K. E., Harrison, T. J., & Kizuk, S. A. (2017). High and dry? Comparing active dry EEG electrodes to active and passive wet electrodes. *Psychophysiology*, 54(1), 74-82.
- Nagarajan, R. (2002). Quantifying physiological data with Lempel-Ziv complexity-certain issues. *IEEE Transactions on Biomedical Engineering*, 49(11), 1371-1373.