



Computational Intelligence in Electrical Engineering
Vol. 14, No. 1, 2023
Research Paper

Analyzing the Brain Response to Marketing Stimuli Using Electroencephalogram (EEG) Signal in the Neuromarketing Application

Seyyed Abed Hosseini

Assistant Professor, Dept. of Electrical Engineering, Mashhad Branch, Islamic Azad University, Mashhad, Iran

Abstract:

Cognitive neuroscience is useful for understanding human behaviors related to marketing and adapting to consumer preferences. By analyzing consumers' brain responses to marketing stimuli, researchers seek to discover the reasons for decision-making. This study proposes a framework for participants' decision-making processes in terms of liking and disliking when viewing and selecting the products of an online store. To this end, the participants' brain signal (EEG) is used when displaying different products. Estimation of power spectrum density by Welch method, detrended fluctuation analysis (DFA), and recurrence quantification analysis (RQA) were used to extract the feature vector. The results show that the two categories of liking or disliking a product can be classified with 73.5% accuracy using a support vector machine (SVM), which compared to the previous study, there is a 3.5% improvement in results. By better understanding consumer behavior and mastery of consumer demands, market strategies can be determined in a way that in addition to customer satisfaction, increase sales and profits. The results are promising and the proposed method can be used for a better electronic commerce model.

Keywords: Feature extraction, Neuro-marketing, Consumer behavior, EEG signal, Classifier.



This is an open access article under the CC BY-NC-ND/4.0/ License (<https://creativecommons.org/licenses/by-nc-nd/4.0/>).



<https://doi.org/10.22108/ISEE.2022.130154.1503>

تحلیل پاسخ مغز به محرک‌های بازاریابی به کمک سیگنال مغزی (EEG) در کاربرد

بازاریابی عصبی

سیدعابد حسینی

استادیار، گروه مهندسی برق، واحد مشهد، دانشگاه آزاد اسلامی، مشهد، ایران

hosseyni@mshdiau.ac.ir

چکیده: علوم اعصاب‌شناختی برای درک رفتارهای انسانی مرتبط با بازاریابی و سازگاری با ترجیحات مصرف‌کننده مفید است. پژوهشگران با تحلیل پاسخ‌های مغزی مصرف‌کنندگان در مواجهه با محرک‌های بازاریابی، به دنبال کشف دلایل تصمیم‌گیری هستند. این پژوهش یک چارچوب را برای فرآیندهای تصمیم‌گیری شرکت‌کنندگان از نظر پسندیدن و نپسندیدن در زمان مشاهده و انتخاب محصولات یک فروشگاه اینترنتی پیشنهاد می‌دهد. بدین منظور، از سیگنال مغزی (EEG) شرکت‌کنندگان در هنگام نمایش محصولات مختلف استفاده می‌شود. برای استخراج ویژگی از تخمین چگالی طیف توان به روش ولش، تحلیل نوسان روند زدایی شده (DFA) و تحلیل کمی بازگشت (RQA) استفاده شده است. نتایج پژوهش نشان می‌دهند دو دسته پسندیدن یا نپسندیدن یک کالا را می‌توان به کمک ماشین بردار پشتیبان (SVM) با میزان صحت ۷۳/۵ درصد طبقه‌بندی کرد که در مقایسه با پژوهش گذشته ۳،۵ درصد بهبود در نتایج دیده می‌شود. با شناخت بهتر رفتار مصرف‌کننده و اشراف بر خواسته‌های مصرف‌کننده، استراتژی‌های بازار به‌گونه‌ای تعیین می‌شوند که علاوه بر رضایت مشتریان، سبب افزایش فروش و سود شوند. نتایج حاصله امیدوارکننده است و از روش پیشنهادی می‌توان برای مدل بهتر تجارت الکترونیکی استفاده کرد.

واژه‌های کلیدی: استخراج ویژگی، بازاریابی عصبی، رفتار مصرف‌کننده، سیگنال مغزی، طبقه‌بندی‌کننده.

۱- مقدمه

است [1]. روان‌شناسان دانشگاه هاروارد، مفهوم بازاریابی عصبی را نخستین بار در سال ۱۹۹۰ به وجود آوردند. پدر علم بازاریابی، دکتر پال آل اسمیتز، کلمه بازاریابی عصبی را با مضمون به‌کارگیری روش شناسایی مکانیسم‌های مغزی برای درک رفتار مشتریان به‌منظور بهبود استراتژی‌های بازاریابی ابداع کرد [2].

بازاریابی عصبی از حوزه‌های روان‌شناسی اجتماعی، بازاریابی و علوم اعصاب شناختی برای تجزیه و تحلیل مکانیسم‌های عصبی و روان‌شناختی ناشی از تصمیم‌ها و رفتارهای انسانی استفاده می‌کند [3]؛ از این رو، مطالعه این مکانیسم‌ها برای توضیح واکنش مصرف‌کنندگان به محرک‌های بازاریابی مفید است [4]. علوم اعصاب شناختی، اطلاعاتی درباره ترجیحات مصرف‌کننده در انتخاب محصولات را بیان می‌کند. این نگاه معمولاً با استفاده از روش‌های سنتی نظیر پرسشنامه، نظرسنجی، مصاحبه

در بخش فروش کالاهای مصرفی، هزینه زیادی صرف تبلیغ و موفقیت در فروش محصولات می‌شود. بازاریابی و تبلیغات محصولات مختلف مصرفی، یک اقدام مؤثر برای افزایش فروش و آگاهی در میان مصرف‌کنندگان است [1]. بازاریابی عصبی^۱ به معنای پی‌بردن به اولویت مصرف‌کنندگان برای تصمیم‌گیری و پیش‌بینی رفتار آنها در استفاده مؤثر از محصول، با استفاده از فرآیندهای ناخودآگاه

تاریخ ارسال مقاله: ۱۴۰۰/۰۵/۲۹

تاریخ پذیرش مقاله: ۱۴۰۰/۱۱/۱۸

نام نویسنده مسئول: سیدعابد حسینی

نشانی نویسنده مسئول: ایران - مشهد - دانشگاه آزاد اسلامی

واحد مشهد - گروه مهندسی برق

fMRI هستند، حد تفکیک مکانی آنها پایین است. به تازگی با معرفی روش‌های پیشرفته پردازش سیگنال، حد تفکیک مکانی روش‌های EEG و MEG نیز تا حدی بهبود یافته است [3].

برنز و مور در سال ۲۰۱۲ [10] با اندازه‌گیری فعالیت مغز ۲۷ نوجوان و به کمک داده‌های fMRI برای پیش‌بینی محبوبیت موسیقی استفاده کردند. آنها همبستگی مثبت در پاسخ‌های مغز شرکت‌کنندگان با فروش در گوش دادن به آهنگ‌های هنرمندان بسیار ناشناخته پس از سه سال را نشان دادند. همچنین، نشان دادند فعالیت درون جسم مخطوط^{۱۱} شکمی به‌طور چشمگیری با تعداد واحدهای فروخته‌شده ارتباط دارد. با وجود این، هزینه‌های آزمایش به کمک fMRI بسیار گران‌قیمت است.

خوشابا و همکارانش در سال ۲۰۱۳ [11] به کمک سیگنال EEG و ردیابی حرکات چشم به ارزیابی پاسخ مغز در محرک‌های بازاریابی پرداختند. آنها به بررسی فرآیندهای تصمیم‌گیری فیزیولوژیک مبتنی بر انتخاب، در زمان ارجحیت دادن شرکت‌کنندگان به محصولات پرداختند. سباستین در سال ۲۰۱۴ [3] به ارزیابی پاسخ‌های شناختی و احساسی مصرف‌کنندگان به محرک‌های بازاریابی پرداخت. بازاریابی عصبی به درک نحوه تأثیر پردازش ذهن به صورت ناخودآگاه بر فرآیند تصمیم‌گیری در خرید می‌پردازد؛ بنابراین، سبب درک بهتری از رفتارهای مصرف‌کننده، عواطف، احساس‌ها، نیازها و انگیزه‌ها در ارتباط با محصولات را ایجاد می‌کند.

مورگاپان و همکارانش در سال ۲۰۱۴ [12] به بررسی میزان محبوبیت برندهای مختلف خودرو در مالزی با استفاده از ثبت سیگنال EEG پرداختند. آنها برندهای تویوتا، آئودی، پرتون و سوزوکی را در آزمایش خود استفاده کردند. با استفاده از تبدیل سری فوریه سریع و شبکه عصبی احتمالی (PNN^{۱۳}) به تجزیه و تحلیل سیگنال مغزی پرداختند. نتایج نشان دادند افراد برند تویوتا را با میانگین نرخ طبقه‌بندی ۹۶،۶۲ درصد ترجیح می‌دهند.

بالوادی و همکارانش در سال ۲۰۱۵ [13] به پیش‌بینی آینده محصولات، قبل از ورود به بازار در خرده‌فروشی صنعت کفش پرداختند. نتایج آنها نشان دادند با استفاده از واکنش‌های مغز مصرف‌کننده می‌توان آینده یک محصول را

شخصی، مشاهدات، بررسی حالت‌ها و ارتباطات کلامی امکان‌پذیر نیست [4] و سبب بهبود طراحی محصولات، قبل از عرضه واقعی در بازار می‌شود. در واقع روشی که مدیران برای ارائه محصول و فروش در نظر می‌گیرند، توسط علوم شناختی و بررسی نقشه‌های مغزی، تهیه و در اختیار آنها قرار می‌گیرد. این امر موجب خواهد شد تا شرکت‌های تولیدکننده محصولات یا خدمات به اهداف خود به خوبی نزدیک شوند؛ بنابراین، نقش علوم اعصاب شناختی در برند سازی حائز اهمیت است [5].

پژوهشگران تا کنون روش‌ها و ابزارهای مختلفی را برای تحلیل رفتار مصرف‌کننده، پدیده تبلیغات و بازاریابی توسعه داده‌اند [7]، [6]. ابزارهای مختلفی نظیر الکتروانسفالوگرافی (EEG^{۱۴}) [1]، مگنتوانسفالوگرام (MEG^{۱۵})، تصویربرداری تشدید مغناطیسی عملکردی (fMRI^{۱۶})، برش‌نگاری با گسیل پوزیترون (PET^{۱۷})، تحریک مغناطیسی مغز (TMS^{۱۸})، پتانسیل‌های وابسته به رویداد (ERP^{۱۹})، هدایت الکتریکی پوست (GSR^{۲۰})، الکترومایوگرافی (EMG^{۲۱}) صورت، پلتیسموگراف (PPG^{۲۲})، نرخ ضربان قلب (HRV^{۲۳}) و ردیابی حرکات چشم در حوزه بازاریابی عصبی استفاده شده است. بسیاری از پژوهشگران علاقه‌مند به مطالعه درباره منشأ پدیده، یعنی مغز برای ترجیحات مصرف‌کنندگان هستند؛ برای نمونه، برخی پژوهشگران، مطالعه‌های fMRI را ترجیح می‌دهند؛ باین حال، تحلیل سیگنال‌های EEG و ردیابی حرکات چشم به دلیل کاهش هزینه‌ها و پیشرفت‌های سریع فناوری رو به افزایش است [7].

مورین و همکارش در سال ۲۰۱۱ [8] با رویکرد بازاریابی عصبی به بررسی رفتار مصرف‌کنندگان پرداختند. آنها بیان داشتند هر سال بیش از ۴۰۰ میلیارد دلار در کمپین‌های تبلیغاتی سرمایه‌گذاری می‌شود؛ باین حال، روش‌های متداول سنجش و پیش‌بینی اثربخشی این سرمایه‌گذاری‌ها به‌طور کلی شکست خورده‌اند؛ زیرا ارزیابی این روش‌های تبلیغ، به تمایل و صلاحیت مصرف‌کنندگان بستگی دارد. وکیاتو و همکارانش در سال ۲۰۱۱ [9] به کمک سیگنال‌های EEG و MEG به بررسی رفتار مصرف‌کنندگان در بازاریابی عصبی پرداختند. هرچند این روش‌ها دارای حد تفکیک زمانی بالاتری در مقایسه با

الکترونیک ازنظر «پسندیدن» و «نپسندیدن» را به کمک تحلیل سیگنال‌های EEG پیشنهاد دادند. سیگنال EEG از داوطلبان با سن و جنسیت متفاوت ثبت شده است؛ زمانی که آنها محصولات مختلف مصرفی را مرور می‌کنند.

اون و همکارانش در سال ۲۰۱۸ [19] اولویت‌های مصرف‌کننده را برای کالاهای مختلف بررسی کردند. در مجموعه کالاها ۴ دسته کالا و از هر دسته، ۵ مدل مختلف موجود است. سیگنال EEG ثبت‌شده را با استفاده از روش غیرخطی روش تحلیل نوسان روند زدایی شده (DFA^۴) برای استخراج ویژگی و طبقه‌بندی‌های نزدیک‌ترین همسایگی (KNN^۵) و شبکه عصبی برای پیش‌بینی ترجیحات مصرف‌کننده استفاده کردند و نتایج حاصل حاکی از آن است که مصرف‌کننده در صورت پسندیدن کالا، مقدار DFA برای امواج بتا بیشترین مقدار است.

حکیم و همکارش در سال ۲۰۱۸ [20] به بررسی دستاوردها، هشدارها و چشم‌اندازها در پیش‌بینی استفاده از سیگنال EEG در بازاریابی عصبی پرداختند. واکنش‌های احساسی به محرک‌های بازاریابی، برای بازاریابی مقصد توریست ضروری است؛ اما هنوز سنجش معتبر دشوار است [21]. بدین منظور، باستینسن و همکارانش در سال ۲۰۱۸ [21] یک آزمایش بازاریابی عصبی را با استخراج تصاویر مقصد برای ارزیابی اثربخشی محتوای بازاریابی مقصد توریست در فیلم‌ها به کمک ERPها استفاده کردند. دو گروه از شرکت‌کنندگان، تصاویری از شهرهای بروخه (بروژ) و کیوتو را مشاهده کردند. قبل از دیدن تصاویر هدف، گروه اول یک نمونه منتخب از فیلم جاذبه‌های گردشگری در بروژ را دیدند و گروه دوم، منتخبی از یک فیلم خاطرات عجیب‌وغریب^{۱۶} را دیدند که اثری از بروژ در آن نبود. نتایج پژوهش برای گروه اول یک پاسخ احساسی ابتدایی به تصاویر بروژ پس از ارائه آنها مشاهده شد؛ ولی برای گروه دوم، هیچ تفاوت معناداری در ERPهای مربوط به تصاویر کیوتو یافت نشد؛ در نتیجه، بازاریابی عصبی مبتنی بر سیگنال EEG یک ابزار ارزشمند برای ارزیابی اثربخشی بازاریابی مقصد است و فیلم‌های محبوب می‌توانند به‌طور مثبت بر تصویر مقصد عاطفی تأثیر بگذارند.

استاسی و همکارانش در سال ۲۰۱۸ [22] به بررسی سامانمند انتخاب مواد غذایی توسط مصرف‌کنندگان

پیش‌بینی کرد که آیا این محصول استقبال خواهد شد یا نیاز به اصلاح دارد. این نتایج به مدیران واحدهای تولیدی کمک می‌کند تولیدات خود را به سمت سلیقه بازار سوق دهند و تا حدودی از شکست برخی محصولات که بار مالی سنگینی برای واحدهای تولیدی به همراه دارند، جلوگیری کنند.

سو در سال ۲۰۱۷ [14] به بازاریابی عصبی و نقش آن بر ذهن مصرف‌کننده پرداخت. همواره علاقه‌مندی به روشی مبتنی بر فعالیت مغز وجود دارد که مدیران قادر باشند به‌طور مستقیم از افکار، احساس‌ها و قصد‌های مشتریان خود آگاه شوند. لی و همکارانش در سال ۲۰۱۷ [15] به بررسی ادبیات بازاریابی عصبی از نگاه یک تازه‌وارد پرداختند. آنها با بررسی پژوهش‌های گذشته نتیجه گرفتند علاقه به این زمینه رو به افزایش است و موضوع‌ها و روش‌های متنوعی هر ساله ارائه می‌شوند. هریس و همکارانش در سال ۲۰۱۷ [7] به مطالعه مروری بر ابزارهای حوزه بازاریابی عصبی پرداختند. کارمارکار و پلاسمان در سال ۲۰۱۷ [16] به بررسی گذشته، حال و آینده در زمینه نقش علوم اعصاب در رفتار مصرف‌کنندگان پرداختند و مزایا و معایب روش‌های مختلف را بیان کردند. لین و همکارانش در سال ۲۰۱۸ [17] برای نشان‌دادن کاربردهای سیگنال EEG در علوم اعصاب مصرف‌کننده، به مرور مطالعه‌های گذشته با تمرکز بر درک موضوع‌های مرتبط با مصرف‌کننده در بازاریابی و زمینه‌های بین‌رشته‌ای مرتبط پرداختند.

بُز و همکارانش در سال ۲۰۱۷ [18] بیان کردند قیمت یک محصول نقش تعیین‌کننده و کلیدی در درآمدها و سودهای یک تجارت گردشگری دارد. مشتریان قضاوت ارزش خود را برای یک محصول یا خدمات توریستی براساس قیمت پرداختی انجام می‌دهند. علاوه بر این، قیمت یک محصول یا خدمات توریستی ممکن است تأثیرات روانی بر مشتری داشته باشد؛ بنابراین، نحوه درک قیمت توسط گردشگران بالقوه اهمیت ویژه‌ای دارد.

یاداوا و همکارانش در سال ۲۰۱۷ [1] به تحلیل سیگنال‌های EEG و کاربرد آن در بازاریابی عصبی پرداختند. آنها یک چارچوب مدل‌سازی پیش‌بینی‌کننده برای درک گزینه‌های مصرف‌کننده به‌سوی محصولات تجارت

پیش‌بینی تصمیم‌گیری مصرف‌کننده استفاده شود؛ در حالی که برای به دست آوردن دقیق‌تر، دیگر ویژگی‌ها باید برای تمایز بین تنظیمات مختلف آزمایش شوند.

زمانی و همکارش در سال ۲۰۲۰ [26] به کمک تبدیل موجک گسسته، ویژگی‌های آماری و ماشین بردار پشتیبان (SVM) به تحلیل سیگنال EEG در کاربرد بازاریابی عصبی پرداختند. در آزمون آنها ۳۲ نفر شامل ۱۶ مرد و ۱۶ زن در محدوده سنی ۲۰ تا ۳۵ سال شرکت داشتند. آنها از بازاریابی عصبی برای پیش‌بینی اولویت مصرف‌کننده در هنگام مشاهده محصولات تجارت الکترونیک استفاده کردند. نتایج آنها نشان دادند که کمک SVM به صحت بیش از ۸۷ درصد دست یافتند.

حکیم و همکارانش در سال ۲۰۲۱ [27] به بهبود پیش‌بینی اولویت‌ها از طریق گزارش‌های شخصی با استفاده از اندازه‌گیری EEG چندگانه و یادگیری ماشین پرداختند. آنها به کمک توان‌های باند فرونتال، عدم تقارن نیمکره، همبستگی میان کاربری و SVM به درصد صحت ۶۸٫۵ در پیش‌بینی محصولاتی رسیدند که بیشترین و کمترین ارجحیت را دارند. کالاکانیس و همکارانش در سال ۲۰۲۱ [28] به نظرسنجی درباره گذشته، حال و آینده طرح‌های EEG ترکیبی در بازاریابی عصبی پرداختند؛ باین حال، آنها بیان کردند باوجود استفاده گسترده از سیگنال EEG در بازاریابی عصبی، این روش تصویر کاملی را به‌تنهایی ارائه نمی‌دهد. به‌منظور غلبه بر محدودیت‌های استفاده از یک روش واحد، پژوهشگران بر رویکردهای گُل‌نگر تمرکز می‌کنند. بهره‌برداری از طرح‌های EEG ترکیبی به‌عنوان نمونه ترکیب EEG با ردیابی حرکات چشم، فعالیت الکترودرمال، ضربان قلب یا موارد دیگر روزه‌روز در حال رشد است و امیدوارند بازاریابی عصبی بتواند رفتار مصرف‌کنندگان را آشکار کند.

با مطالعه ادبیات گذشته مشاهده می‌شود پژوهش در حوزه بازاریابی عصبی همچنان جذاب و هنوز به سطحی از رضایت‌مندی نرسیده است. در این پژوهش، یک چارچوب بازاریابی عصبی برای پیش‌بینی ترجیحات مصرف‌کننده در زمان مشاهده محصولات مختلف ارائه می‌شود. در این پژوهش، سیگنال‌های EEG افراد پردازش و تحلیل می‌شوند و در نهایت، یک تحلیل مقایسه‌ای با سایر طبقه‌بندی‌ها نیز

پرداختند. این انتخاب اغلب به دلایلی انجام می‌شود که مصرف‌کنندگان از آن کاملاً آگاه نیستند. همچنین، تصمیم‌گیری درباره انتخاب غذا، از مجموعه‌ای پیچیده از احساس‌ها، نگرش‌ها و ارزش‌ها تأثیر می‌گیرد که ارزیابی ساده آنها از طریق نظرهای مصرف‌کنندگان غیرممکن است. در واقع، روش‌های سنتی عمدتاً امکان سنجش واکنش‌های آگاهانه و منطقی بر یک محصول یا تبلیغات را دارند؛ ولی بازاریابی عصبی از روش‌ها و ابزارهایی استفاده می‌کند که امکان سنجش واکنش‌های عاطفی و خودبه‌خودی مصرف‌کنندگان را به روشی عینی‌تر و مشاهده‌پذیرتر بیان می‌کند.

لیم در سال ۲۰۱۸ [23] پژوهشی با رویکرد تغییر شکل بازاریابی عصبی انجام دادند. این پژوهش سؤالات کلیدی درباره بازاریابی عصبی را روشن و راه‌های مختلفی را برای گسترش معنادار خطوط پژوهشی در زمینه بازاریابی عصبی مشخص می‌کند. یورال و همکارانش در سال ۲۰۱۹ [24] به کمک سیگنال‌های EEG، PPG و GSR به بازاریابی عصبی پرداختند که به تجزیه و تحلیل رابطه بین الکترودها و استرس هیجانی در سراسر تبلیغات تجاری مربوط می‌شود. آنها از همبستگی موجک و اختلاف فاز برای تحلیل سیگنال EEG، از توان در باند فرکانسی بالا و باند فرکانسی پایین برای تحلیل سیگنال PPG و از سطح هدایت پوست برای تحلیل سیگنال GSR استفاده کرده‌اند. نتایج آنها نشان دادند اختلاف معناداری بین همبستگی موجک و اختلاف فاز و همچنین، نسبت باند فرکانسی پایین به باند فرکانسی بالا بین مرحله آزمایش و مرحله کنترل وجود دارد؛ اما در سطح هدایت پوست وجود ندارد.

گلنارنیک و همکارانش در سال ۲۰۱۹ [25] به کمک توان سیگنال EEG برای پیش‌بینی و تفسیر تصمیم‌گیری مصرف‌کننده پرداختند. آنها نشان دادند اضافه کردن رنگ پس‌زمینه به تبلیغات طراحی شده، تأثیر مثبتی بر میزان علاقه به محصولات دارد. برای هرکدام از برندها چهار نوع تبلیغ استفاده شده است و در جریان آزمایش تبلیغات از حالت ساده به سمت پیچیده تغییر می‌کنند. نتایج این پژوهش نشان داد که تبلیغات در صورت ساده‌تر بودن بیشتر مصرف‌کننده را مجاب به خرید می‌کنند؛ در نتیجه، تجزیه و تحلیل سیگنال‌های EEG می‌تواند به‌عنوان یک ابزار مفید برای


ارائه می‌شود.

ساختار این پژوهش بدین صورت است که در بخش دوم به معرفی مواد و روش‌های پژوهش شامل معرفی داده، روش تحلیل سیگنال EEG شامل پردازش، استخراج ویژگی و طبقه‌بندی کننده پرداخته می‌شود. در بخش سوم به گزارش نتایج پژوهش پرداخته می‌شود و در نهایت، در بخش چهارم بحث و نتیجه‌گیری آورده می‌شود.

۲- مواد و روش‌ها

۲-۱- معرفی داده پژوهش

سیگنال‌های EEG با دستگاه بی‌سیم ۱۴ کاناله EMOTIV EPOC+ با استاندارد بین‌المللی ۱۰ - ۲۰ با آرایش الکترودهای AF3, AF4, F7, F8, F3, F4, FC5, FC6, T7, T8, CMS, DRL, P7, P8, O1, O2 مطابق شکل (۱) ثبت شده‌اند. [1]. الکترودهای مرجع ¹⁹DRL و ¹⁸CMS به ترتیب در موقعیت‌های P3 و P4 و در بالای گوش‌ها قرار دارند. فرکانس نمونه‌برداری داخل دستگاه ۲۰۴۸ هرتز است که نرخ نمونه‌برداری آنها به ۱۲۸ هرتز کاهش یافته است. اطلاعات با بلوتوث و دانگل USB به رایانه ارسال می‌شوند. قبل از استفاده، پدهای نمدی بالای حسگرها به کمک محلول نمکی مرطوب می‌شوند. باتری دستگاه به کمک یک شارژر USB شارژ می‌شود.



(ب)

شکل (۱): الف) نمایش دستگاه بی‌سیم ۱۴ کاناله EMOTIV EPOC+ و ب) نحوه آرایش الکترودها روی سطح سر (۲۹)

سیگنال EEG از ۲۵ شرکت‌کننده در زمان نمایش محصولات در صفحه نمایشگر رایانه به مدت ۴ ثانیه ثبت شده است. مجموعه‌ای از ۱۴ محصول مختلف مطابق شکل (۲) انتخاب شده که هر محصول دارای سه نوع مختلف (A, B و C) است که در مجموع ۴۲ (۳×۱۴) تصویر مختلف را ایجاد می‌کند.

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				چوراب			
دستکش				ساعت دیواری			
کروات				دستبند			

شکل (۲): مجموعه تصاویر کالاهای مختلف (برگرفته شده

از (۱))


در نهایت، ۱۰۵۰ (۲۵*۴۲) قطعه سیگنال EEG برای همه شرکت‌کنندگان ثبت شده است. شرکت‌کنندگان در گستره سنی ۱۸ تا ۳۸ سال قرار دارند. گروه A شامل ۱۰ مرد و ۶ خانم با گستره سنی ۱۸ تا ۲۳ سال، گروه B شامل ۸ مرد و ۵ خانم با گستره سنی ۲۵ تا ۳۰ سال و گروه C



(الف)

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

که m بیان‌کننده طول پنجره، C_i بیان‌کننده تعداد ضرایب کانولوشن و Q بیان‌کننده سیگنال هموار شده است. در این پژوهش، از پالایه برای هموارسازی سیگنال‌های EEG با استفاده از یک طول پنجره با اندازه ۵ ($m = 5$) با چندجمله‌ای درجه چهار استفاده شده است. اعمال پالایه SG روی قطعه‌ای از سیگنال EEG در شکل (۳) به نمایش گذاشته است.



شکل (۳): قطعه‌ای از سیگنال EEG خام و سیگنال EEG پیش‌پردازش شده با پالایه SG

• استخراج ویژگی از سیگنال EEG

برای استخراج ویژگی از سیگنال EEG از روش‌های مختلف خطی و غیرخطی استفاده می‌شود. در این پژوهش از ویژگی‌هایی نظیر تخمین چگالی طیف توان به روش ولش^{۱۱}، DFA و تحلیل کمی سازی بازگشتی (RQA^{۱۲}) استفاده شده است. نمایشی از چارچوب روش پیشنهادی در شکل (۴) آورده شده است.

شامل ۷ مرد و ۴ خانم با گستره سنی ۳۱ تا ۳۸ سال هستند [1]. پس از مشاهده، از شرکت‌کننده خواسته شد ترجیح خود را از نظر محصول به دو دسته پسندیدن یا نپسندیدن بیان کند [1]. 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- تحلیل سیگنال EEG

پیش‌پردازش با پالایه ساویتزکی-گولای (SG^{۲۰})

حرکات ناخواسته ناشی از پلک‌زدن، حرکت ماهیچه‌های صورت و ضربان قلب در هنگام ثبت سیگنال EEG از عوامل ایجاد آرتیفکت‌های ناخواسته‌اند؛ بنابراین، پیش‌پردازش سیگنال EEG از ایجاد برخی اختلال‌های به‌وجودآمده جلوگیری می‌کند.

در این پژوهش از پالایه بالاگذر SG استفاده شده است. پالایه ساویتزکی-گولای در هموارسازی سیگنال‌های حیاتی در پژوهش‌های گذشته استفاده شده [31], [30], [1] که براساس تقریب چندجمله‌ای حداقل مجذور محلی است. هدف اصلی این روش، افزایش نسبت سیگنال به نویز است و این کار تا حد زیادی بدون خدشه‌دار شدن سیگنال اصلی انجام می‌شود. 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. شایان ذکر است گرچه استفاده از این روش‌های هموارسازی باعث بهبود وضعیت ظاهری طیف می‌شود، ممکن است سبب حذف اطلاعات مفید و درخور استفاده شود [32]. از یک سیگنال $S_j = f(t_j)$ به طول n که $j = 1, 2, \dots, n$ است، پالایه SG با رابطه (۱) محاسبه می‌شود.

می آید.

$$x_s[m] = x[m + sD],$$

$$s = 0, 1, \dots, S - 1 \text{ and } m = 0, 1, \dots, M - 1 \quad (2)$$

که sD نقطه شروع بخش های پی در پی دنباله است (بدون همپوشانی $D = M$ و دارای همپوشانی ۵۰ درصد $D = M/2$).

۲- برای هر بخش، یک پنجره اعمال می شود و سپس پریدوگرام روی بخش های پنجره شده، با رابطه (۳) محاسبه می شود (پریدوگرام پنجره شده).

$$P_k(f) = \frac{1}{MU} \left| \sum_{m=0}^{M-1} w[m] \cdot x_s[m] e^{-j2\pi f m} \right|^2 \quad (3)$$

که فاکتور $U = \frac{1}{M} \sum_{m=0}^{M-1} |w[m]|^2$ ثابت بهنجارشده بوده و به منظور جبران انرژی سیگنال ناشی از تابع پنجره ($w[m]$) است (U توان پنجره زمانی $w[m]$ است).

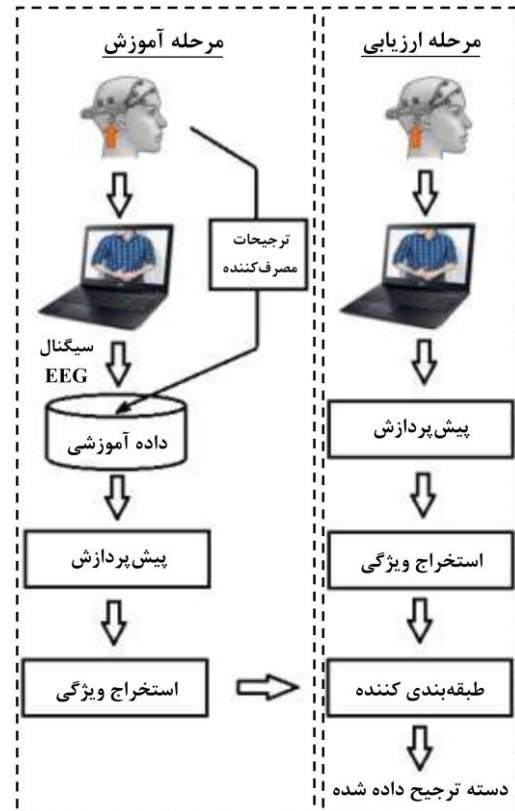
۳- تخمین چگالی طیف توان به روش ولش با میانگین پریدوگرام های پنجره شده از S بخش مطابق رابطه (۴) محاسبه می شود.

$$P^w(f) = \frac{1}{S} \sum_{s=0}^{S-1} P_s(f) \quad (4)$$

در این پژوهش، از هشت بخش به طول مساوی با ۵۰ درصد همپوشانی برای مرحله اول و پنجره همینگ در مرحله دوم استفاده می شود.

• روش تحلیل نوسان روند زدایی شده (DFA)

در تحلیل های مبتنی بر تبدیل فوریه برای استخراج طیف توان سیگنال EEG که ماهیتی غیر ایستاد دارد، فرض ایستایی در یک بازه زمانی کوچک لازم است؛ بنابراین، در این پژوهش علاوه بر روش های مبتنی بر تبدیل فوریه، به کمک روش DFA به بررسی تغییرات ضریب خودهمانی سیگنال EEG پرداخته شده است. هارولد ادوین هرست در سال ۱۹۵۱ میلادی، روش تحلیل نمای هرست را برای بررسی حافظه طولانی مدت داده ها معرفی کرد [35]. این



شکل (۴): نمایش چارچوب روش پیشنهادی شامل

پیش پردازش با ساویتزکی-گولای، استخراج ویژگی با روش های تخمین چگالی طیف توان به روش ولش، تحلیل نوسان روند زدایی شده و تحلیل کمی سازی بازگشتی و طبقه بندی کننده با ماشین بردار پشتیبان

• روش ولش

روش ولش یکی از روش های غیر پارامتری تخمین طیف توان است [33]. این روش مبتنی بر ایده بارتلت درباره تقسیم داده به بخش ها و یافتن میانگین پریدوگرام آنها است. دو تفاوت عمده با روش بارتلت عبارتند از: نخست، بخش های داده در روش ولش مجاز به همپوشانی هستند و دوم، هر بخش داده قبل از محاسبه پریدوگرام پنجره می شوند [34]. فرض کنید $n = x[n]$ $0, 1, \dots, N - 1$ نمونه هایی از یک قسمت سیگنال EEG باشد $(x[0], x[1], \dots, x[N - 1])$. در اینجا برای تخمین طیف توان به روش ولش از سه مرحله اساسی برای پیاده سازی در نرم افزار MATLAB استفاده شده است.

۱- ابتدا، دنباله طول اصلی N به S بخش با طول مساوی تقسیم می شود. k امین دنباله از رابطه (۲) به دست

روش برای سری‌های زمانی با تعداد داده کم اتکاپذیر نبود. در سال ۱۹۹۴ روش DFA یک تحلیل قابل اطمینان و مناسب برای به دست آوردن نمای هرست سری‌های زمانی معرفی شد [36]. این روش، قابلیت آشکارسازی همبستگی‌های طولانی‌مدت در سری‌های زمانی غیر ایستا را دارد و خواص همبستگی سیگنال را با یک پارامتر کمی ساده به نام نمای مقیاس‌گذاری (α) به خوبی نشان می‌دهد [37]. با این روش می‌توان خودهمانی را که در محدوده وسیعی از مقیاس‌های زمانی رخ می‌دهد، در مقیاس زمانی خاصی محاسبه کرد. برای محاسبه DFA از روش پنگ و همکارانش استفاده شده است [36]. این روش شامل چند مرحله به شرح زیر است.

سری زمانی $\alpha[n]$ برای $n = 0, 1, \dots, N-1$ را در نظر بگیرید. سری زمانی $y[n]$ مطابق رابطه (۵) با استفاده از جمع انباره‌ای تفاضل سری زمانی $x[n]$ از میانگین سری زمانی $x[n]$ آن به دست می‌آید.

$$y[n] = \sum_{i=0}^k (x[n] - \bar{x}) \quad (5)$$

در مرحله بعد، سری زمانی به دست آمده $y[n]$ به تعداد $l_B = \text{int}(N/B)$ پنجره مساوی به طول B تقسیم شده و در هر یک از این پنجره‌ها یک خط y_B روی مجموعه نقاط آن پنجره با استفاده از روش کمترین مربع خطا برازش می‌شود. سپس تابع میانگین مربع خطا $F(n)$ برای کل سری زمانی $y[n]$ و طول پنجره B براساس رابطه (۶) به دست می‌آید (واریانس نوسانات $y[n]$ از خط $y_B[n]$ در پنجره B ام).

$$F(n) = \sqrt{\frac{1}{N} \sum_{n=0}^{N-1} (y[n] - y_B[n])^2} \quad (6)$$

که $y_B[n]$ سری زمانی ناشی از خط به دست آمده در هریک از پنجره‌ها است.

به همین ترتیب، تابع $F(n)$ را به ازای طول پنجره‌های مختلف، محاسبه و سپس لگاریتم $F(n)$ برحسب لگاریتم n رسم می‌شود. با توجه به اینکه سیگنال مغزی دارای خاصیت

خودهمانی است، در منحنی به دست آمده یک ناحیه خطی قابل شناسایی است که شیب خط برازش شده در ناحیه خطی به منزله نمای مقیاس‌گذاری (نمای خودهمانی) محاسبه می‌شود. نمای مقیاس‌گذاری α مقداری بزرگ‌تر از صفر دارد؛ در صورتی که در سیگنال ضد همبستگی‌های طولانی‌مدت وجود داشته باشد، مقدار $\alpha < 0.5$ ، در صورتی که در سیگنال هیچ همبستگی وجود نداشته باشد (سیگنال‌های غیر همبسته) مقدار $\alpha \approx 0.5$ (مثل نویز سفید)، در صورتی که در سیگنال همبستگی‌های طولانی‌مدت وجود داشته باشد، مقدار $0.5 < \alpha < 1$ ، در صورتی که رفتار قانون توان یکنواختی از نویز $1/f$ وجود داشته باشد، مقدار $\alpha \approx 1$ (مثل نویز صورتی)، در صورتی که سیگنال به شدت همبسته باشد (همبستگی‌های طولانی‌مدت) مقدار $\alpha \approx 1.5$ (مثل نویز براون یا نویز قرمز) و در صورتی که فرآیند غیر ایستا باشد، مقدار $\alpha > 1$ به دست می‌آید [38].

مراحل پیاده‌سازی روش DFA در نرم‌افزار MATLAB به ترتیب در ذیل آمده است:

- ۱- پیش پردازش سیگنال مغزی و حذف آرتیفکت‌های آن؛
- ۲- محاسبه میانگین سیگنال پیش پردازش شده و تفاضل آن از کل سیگنال؛
- ۳- محاسبه جمع انباره‌ای سیگنال حاصل با استفاده از رابطه (۵) و به ازای k برابر ۱ تا طول کل سیگنال و ذخیره آن در سری زمانی $y[n]$ ؛
- ۴- تقسیم سری زمانی $y[n]$ به N_B پنجره مساوی به طول B ؛
- ۵- برازش یک خط با استفاده از دستور polyfit روی مجموعه نقاط هر پنجره؛
- ۶- محاسبه میانگین مربع خطا $F(n)$ به ازای پنجره به طول B با استفاده از رابطه (۶)؛
- ۷- تکرار مراحل ۴ تا ۶ به ازای $B = 3$ تا طول کل سیگنال؛
- ۸- رسم $\log F(n)$ برحسب $\log(n)$ و شناسایی ناحیه خطی در منحنی به دست آمده؛
- ۹- برازش یک خط در ناحیه خطی با استفاده از دستور

polyfit و استخراج شیب خط.

منحنی‌های بازگشتی دو ساختار مقیاس کوچک عمده مشاهده می‌شود؛ نخست، ساختار خط قطری به طول L که به این معنی است که دو قطعه تراژکتوری به مدت L واحد زمانی در همسایگی ε از یکدیگر بوده و دوم، ساختار خط قائم به طول V که نشان‌دهنده این است که تراژکتوری به مدت V واحد زمانی تغییر چندانی نکرده است. هشت شاخص از RQA شامل موارد ذیل استخراج می‌شوند [43].

سنجش‌ها براساس خط‌های قطری

نرخ بازگشت یا درصد بازگشت (RR°)

نرخ بازگشت ساده‌ترین شاخص RQA است و بیان‌کننده احتمال بازگشت فضای فاز به نقاط در ε همسایگی‌اش مطابق رابطه (۸) است.

$$RR(\varepsilon) = \frac{1}{N^2} \sum_{i,j=1}^N R_{i,j}(\varepsilon) \quad (8)$$

که اندازه‌ای از چگالی نقاط بازگشتی در RP است. در این رابطه نسبت نقاط تیره به کل نقاط در RP محاسبه می‌شود. RR یک شاخص کارآمد از منظم بودن یا پیش‌بینی یک سری زمانی است. برای سیستم‌های پیچیده، مقدار RR خیلی کم بیان‌کننده نظم کم و پیش‌بینی‌پذیری کم و مقدار RR خیلی بالا بیان‌کننده سیستم‌های پرپویا و پیش‌بینی‌پذیر است [39].

قطعیت یا پیش‌بینی‌پذیری (DET°)

قطعیت، بیان‌کننده تعدادی از نقاط بازگشت است که خطوط قطری را ایجاد می‌کند. نرخ نقاط بازگشتی که از ساختارهای قطری هستند (با طول حداقل l_{min}) نسبت به همه نقاط بازگشتی از رابطه (۹) محاسبه می‌شود.

$$DET = \frac{\sum_{l=l_{min}}^N lP(l)}{\sum_{l=1}^N lP(l)}, \quad (9)$$

که l_{min} بیان‌کننده حداقل طول موردنیاز به‌عنوان تعریف برای خط قطری است. $P(l)$ کل تعداد خطوط قطری با طول l است. اساس رابطه (۹) مبتنی بر هیستوگرام $P(\varepsilon, l)$ مربوط به خطوط قطری به طول l و مطابق رابطه (۱۰) نوشته می‌شود.

در منحنی نهایی به‌دست‌آمده برای سیگنال مغزی، دو ناحیه خطی مشاهده می‌شود که ناحیه خطی پایین مربوط به ضریب مقیاس‌گذاری در پنجره‌های زمانی کوچک و ناحیه خطی بالا مربوط به ضریب مقیاس‌گذاری در پنجره‌های زمانی بزرگ‌تر است. در این پژوهش، تنها به استخراج ناحیه خطی بالایی پرداخته شده که مربوط به ضریب مقیاس‌گذاری در پنجره‌های زمانی بزرگ‌تر است.

• تحلیل کمی‌سازی بازگشتی (RQA)

تحلیل کمی بازگشت یک روش مؤثر برای استخراج توصیف جنبه‌های مختلف یک سیستم غیرخطی است [39]. این ویژگی اطلاعاتی درباره بازگشت حالت‌های مختلف یا تکرار نقاط حالت در فضای حالت یک سیستم را در زمان‌های مختلف از یک سری زمانی داده‌شده کمی می‌کند. برخلاف سنجش‌های غیرخطی مرسوم، RQA در توصیف تغییرات در ویژگی‌های دینامیکی از سیگنال‌های دینامیکی واقعی که کوتاه، نویزی و غیر ایستا هستند، مؤثر است [40]. اِکمان و همکارانش [41] طرح‌های بازگشتی (RP°) را ارائه کردند که ویژگی بازگشتی یک سیستم دینامیکی را توصیف می‌کنند. گام کلیدی RP محاسبه ماتریس $N \times N$ مطابق رابطه (۷) است.

$$R_{i,j}(\varepsilon) = \theta(\varepsilon - \|\vec{x}_i - \vec{x}_j\|), \quad (7)$$

$$i, j = 1, 2, \dots, N.$$

که N تعداد نقاط اندازه‌گیری شده مسیر حالت X, ε حد آستانه فاصله، $\theta(x)$ تابع هویساید^۴ و $\|\cdot\|$ بیان‌کننده نرم بیشینه است. به‌منظور پیدا کردن فاصله قطع ε ، فاصله N^2 بین هر جفت بُردار محاسبه می‌شود [42]. کمترین فاصله که ۱۰ درصد از فاصله‌ها کوچک‌تر است، فاصله قطع شناخته می‌شود.

نقشه بازگشتی رفتار وابسته به زمان یک سیستم دینامیکی را نمایش می‌دهد که به‌صورت بصری به‌سختی تشخیص داده می‌شود؛ به همین دلیل، این نقشه‌ها نیاز به یک کمی‌کننده دارند. در ادامه، به بررسی ویژگی‌های استخراج‌شده با روش RQA پرداخته می‌شود. در

تحلیل پاسخ مغز به محرک‌های بازاریابی به کمک سیگنال مغزی (EEG) در کاربرد بازاریابی عصبی

خط قطری به طول دقیقاً l را در RP پیدا می‌کند. آنتروپی از رابطه (۱۳) محاسبه می‌شود.

$$ENTR = - \sum_{l=l_{min}}^N p(l) * \ln(p(l)). \quad (13)$$

$ENTR$ پیچیدگی RP را با توجه به خطوط قطری بیان می‌کند؛ برای مثال، برای نویز ناهمبسته، مقدار $ENTR$ نسبتاً کم است که بیان‌کننده پیچیدگی پایین آن است.

سنجش‌ها بر اساس خط‌های عمودی لایه‌ای بودن (LAM)^{۲۸}

لایه‌ای بودن مشابه رابطه (۹) محاسبه می‌شود و به صورت نسبت بین نقاط بازگشتی تشکیل‌دهنده ساختارهای عمودی به همه نقاط بازگشتی مطابق رابطه (۱۴) است.

$$LAM = \frac{\sum_{v=v_{min}}^N vP(v)}{\sum_{v=1}^N vP(v)}, \quad (14)$$

که $P(v)$ لامیناریتی یا تعداد خطوط عمودی به طول v نامیده می‌شود و از رابطه (۱۵) محاسبه می‌شود.

$$P(v) = \sum_{i,j=1}^N (1 - R_{i,j})(1 - R_{i,j+v}) \prod_{k=0}^{v-1} R_{i,j+k}. \quad (15)$$

محاسبه LAM برای v هایی تحقق می‌یابد که از v_{min} بیشتر شود تا اثر حرکت مماسی کاهش یابد. برای نگاشت‌ها، $v_{min} = 2$ مقدار مناسبی است. LAM وقوع وضعیتهای لایه‌ای در سیستم را نشان می‌دهد؛ بدون اینکه طول این فازهای لایه‌ای را توصیف کند. در صورتی که RP شامل نقاط بازگشتی منفرد بیشتری نسبت به ساختارهای عمودی باشد، LAM کاهش خواهد یافت.

زمان به دام افتادن (TT)^{۲۹}

زمان به دام افتادن، بیان‌کننده میانگین طول خطوط عمودی با میزان طول بیشتر از v_{min} است و از رابطه (۱۶) محاسبه می‌شود.

$$P(\varepsilon, l) = \sum_{i,j=1}^N (1 - R_{i-1,j-1}(\varepsilon)) (1 - R_{i+l,j+l}(\varepsilon)) \prod_{k=0}^{l-1} R_{i+k,j+k}(\varepsilon). \quad (10)$$

برای سادگی، ε را در اندازه‌های RQA نمی‌نویسند (یعنی $P(\varepsilon, l) = P(l)$). شاخص قطعیت در سیستم‌های پررودیک که کاملاً پیش‌بینی‌پذیر و به صورت قطری هستند، برابر یک و در سیستم‌های تصادفی به سمت صفر میل می‌کند. انتخاب l_{min} مشابه انتخاب اندازه برای پنجره تیلر^{۲۷} انجام می‌شود [44].

متوسط طول خطوط قطری (L_{mean})

متوسط طول خطوط قطری، زمان پیش‌بینی میانگین سیستم را کمی می‌کند و از رابطه (۱۱) محاسبه می‌شود.

$$L_{mean} = \frac{\sum_{l=l_{min}}^N lP(l)}{\sum_{l=l_{min}}^N P(l)}. \quad (11)$$

متوسط زمانی است که دو قطعه تراژکتوری به یکدیگر نزدیک‌اند و می‌تواند به عنوان متوسط زمان پیش‌بینی تفسیر شود.

بیشینه طول خط قطری (L_{max})

بیشینه طول خط قطری، طولانی‌ترین خط قطری است که در RP یافت می‌شود و از رابطه (۱۲) محاسبه می‌شود. عکس آن به عنوان واگرایی مدنظر قرار می‌گیرد ($DIV = 1/L_{max}$).

$$L_{max} = \max(\{l_i\}_{i=1}^{N_l}), \quad (12)$$

که $N_l = \sum_{l \geq l_{min}} P(l)$ تعداد کل خط‌های قطری است. این سنجش مربوط به واگرایی‌نمایی مسیر فضای فاز است. L_{max} می‌تواند به عنوان تخمینی‌نمای لیاپانوف بیشینه مثبت از سیستم دینامیکی باشد [43].

آنتروپی ($ENTR$)

آنتروپی، پیچیدگی ساختار بازگشتی را اندازه‌گیری می‌کند. آنتروپی شانون از احتمال $p(l) = P(l)/N_l$ یک

تابع هدف تعیین می‌شود. در پیاده‌سازی از تابع هسته گوسین استفاده شده است. در این مدل، داده‌ها به صورت بردار استفاده می‌شوند. بخش کوچکی از داده‌های آموزش به‌عنوان بردار پشتیبان به کار برده می‌شوند. هدف SVM یافتن یک تابع خطی است که بهترین درون‌یابی را برای نقاط آموزش انجام می‌دهد. انتخاب پارامترها با سعی و خطا و ارزیابی نتایج حاصل از پارامترهای مختلف روی یک دادگان کوچک اولیه انجام شد و پس از تعیین پارامترهای بهینه، روش بر کل دادگان، اعمال و نتایج آن استخراج شد. از LIBSVM در نرم‌افزار متلب برای پیاده‌سازی SVM استفاده شده است [45].

۳- نتایج

به‌منظور دست‌یابی به نظر مصرف‌کننده، نسبت به هر کالا واکنش‌های مغزی مصرف‌کننده ثبت شده است. برای رسیدن به اهداف پژوهش، در ابتدا به‌منظور حذف نویز و پیش‌پردازش از پالایه SG استفاده شده است. برای استخراج ویژگی از سیگنال EEG از روش‌های مختلف خطی و غیرخطی نظیر تخمین چگالی طیف توان به روش ولش، DFA و RQA استفاده شده است. هشت ویژگی استخراج‌شده از RQA شامل نرخ بازگشت، قطعیت، متوسط طول خطوط قطری، بیشینه طول خط قطری، آنتروپی، لایه‌ای بودن، زمان به دام افتادن و بیشینه طول خط عمودی است. از جعبه‌ابزار CRP در نرم‌افزار MATLAB [43] برای استخراج ویژگی‌های آماری مربوط به سنجش RQA استفاده شده است. در شکل (۵) ویژگی مختلف با RQA برای یک قطعه از سیگنال EEG محاسبه و ترسیم شده است.

$$TT = \frac{\sum_{v=v_{min}}^N vP(v)}{\sum_{v=v_{min}}^N P(v)} \quad (16)$$

TT میانگین زمانی را که سیستم در یک وضعیت خاص پایدار می‌ماند، سیستم با سرعت خیلی کم تغییر می‌کند یا مدت‌زمان گرفتارشدن این سیستم را تخمین می‌زند.

بیشینه طول خط عمودی (V_{max})

بیشینه طول خط عمودی مشابه با سنجش L_{max} است و بیان‌کننده طولانی‌ترین خط عمودی است که با رابطه (۱۷) محاسبه می‌شود.

$$V_{max} = \max(\{v_l\}_{l=1}^{N_v}) \quad (17)$$

که N_v تعداد مطلق خطوط عمودی است.

۲-۳- ماشین بردار پشتیبان (SVM)

ولادیمیر و پینک ماشین بردار پشتیبان اولیه را در ۱۹۶۳ ابداع کرد و وپنیک و کورتز آن را در سال ۱۹۹۵ برای حالت غیرخطی تعمیم داد. SVM یک روش یادگیری با نظارت است و دو فاز آموزش و آزمون دارد [45]. در واقع SVM یک طبقه‌بندی دودویی است که دو دسته را با استفاده از یک خط مرزی از هم جدا می‌کند. مراحل یادگیری به صورت رابطه (۱۸) است.

$$y = f(x) = \sum_{i=1}^M w_i \varphi_i(x) \quad (18)$$


خروجی مدل به‌طور کلی M جزء است. بخش تبدیل غیرخطی مدل به‌وسیله $\varphi(\cdot)$ نشان داده شده است. این مدل برای به‌کارگیری SVM به صورت رابطه (۱۹) است.

$$y = f(x) = \left\{ \sum_{i=1}^N w_i k(x_i, x) \right\} - b \quad (19)$$

که در آن، k تابع هسته \cdot ، w_i و b پارامترهای مدل، N تعداد داده برای آموزش، x_i بردار داده‌ها برای آموزش شبکه و x بردار مستقل است. پارامترهای مدل با حداکثرسازی

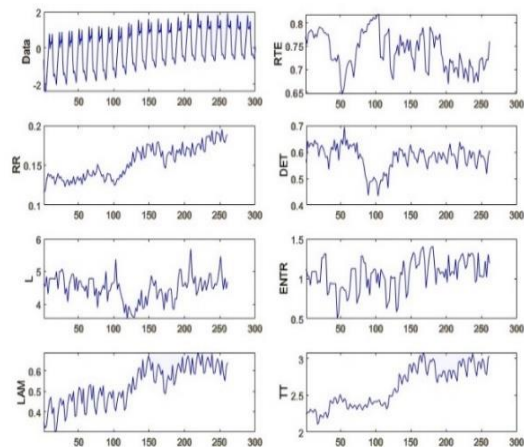
توضیح T_P , T_N , F_P , F_N در رابطه (۲۰) برای تمایز بین دو دستهٔ پسندیدن و نپسندیدن به این شرح است؛ T_P داده‌هایی که شخص، کالا را نپسندیده است و به‌درستی پسندیده‌نشده کالا تشخیص داده شده است؛ T_N داده‌هایی که شخص، کالا را نپسندیده است و به‌درستی پسندیده‌شدن کالا تشخیص داده شده‌اند؛ F_P داده‌هایی که شخص، کالا را پسندیده است؛ ولی به‌اشتباه پسندیده‌نشده کالا تشخیص داده شده است؛ F_N داده‌هایی که شخص کالا را نپسندیده است؛ ولی به‌اشتباه پسندیده‌شدن کالا تشخیص داده شده است.

برای نمونه، در بررسی میزان صحت پیش‌بینی آیتم A کیف از نظر دوست داشتن و دوست‌نداشتن، نمودار کارایی SVM در شکل (۶) آورده شده است.



شکل (۶): نمودار کارایی ماشین بردار پشتیبان

با توجه به شکل (۶)، SVM توانسته است با جلوگیری از آموزش بیش‌ازاندازه، در تکرار ۱۷ آموزش را متوقف کند و به خطای MSE معادل ۱۸,۱۲ دست پیدا کند. به‌منظور ارزیابی بهتر، از الگوریتم k-fold در آموزش استفاده شده و سپس مدل، آموزش داده و آزمون شده است. ۶۰ درصد داده برای آموزش، ۳۰ درصد داده برای آزمون و ۱۰ درصد برای اعتبارسنجی استفاده شده است و نتایج به ازای ۵ بار تکرار گزارش شده‌اند. جدول (۲) مقدار پارامترهای آماری حساسیت، میزان عدم اشتراک و صحت را نشان می‌دهد. طبق نتایج حاصل، مقدار پارامتر حساسیت ۶۷,۶ درصد، میزان عدم اشتراک ۷۴,۹ درصد و میزان پارامتر صحت ۷۳,۵ درصد است.



شکل (۵): نمایش مقادیر ویژگی‌های مختلف با RQA

ویژگی‌های استخراجی از RQA برای هر قطعه سیگنال با بُعد ۱، تأخیر زمانی ۱ و حد آستانه ۰,۲ و نرم بیشینه محاسبه شده است. جدول (۱) میانگین ویژگی‌های RQA استخراج شده را برای دو دستهٔ پسندیدن و نپسندیدن نشان می‌دهد.

جدول (۱): میانگین ویژگی‌های RQA استخراج شده برای دو

دستهٔ پسندیدن و نپسندیدن

نپسندیدن	پسندیدن	ویژگی‌های RQA
۰/۰۱۰۶	۰/۱۰۷	RR
۰/۳۶۳۰	۰/۳۶۱۱	DET
۲/۲۵۹۳	۲/۲۶۲۶	L_{mean}
۰/۲۷۶۸	۰/۲۷۱۵	L_{max}
۰/۴۴۰۳	۰/۴۳۹۸	ENTR
۰/۲۰۰۵	۰/۲۰۲۰	LAM
۲/۱۱۲۰	۲/۱۱۵۰	TT
۱/۱۱۰	۱/۱۵۶۰	V_{max}

سپس ویژگی‌های محاسبه شده بر مبنای پسندیدن یا نپسندیدن یک کالا به کمک SVM دسته‌بندی شده‌اند. عملکرد آزمون با محاسبهٔ پارامتر آماری مانند حساسیت^{۳۱}، مشخصه^{۳۲} و صحت مطابق رابطه (۲۰) ارزیابی می‌شود.

$$Sensitivity = \frac{T_P}{T_P + F_N}$$

$$Specificity = \frac{T_N}{T_N + F_P} \quad (20)$$

$$Accuracy = \frac{T_P + T_N}{T_P + T_N + F_P + F_N}$$

جدول (۳): مقایسه روش پیشنهادی با پژوهش گذشته.

مرجع	موضوع	روش تحلیل	دسته بند	صحت
[1]	تصمیم‌گیری مصرف‌کننده	تبدیل موجک گسسته	SVM	٪۷۰
[13]	صنعت مد	ویژگی‌های آماری	KNN	٪۸۰
[12]	برند سازی	چگالی طیف توان	PNN	٪۹۶٫۶۲
[19]	تصمیم‌گیری مصرف‌کننده	DFA	NN	٪۸۰
[25]	تصمیم‌گیری مصرف‌کننده	چگالی طیف توان	SVM	٪۶۳
[26]	تصمیم‌گیری مصرف‌کننده	تبدیل موجک گسسته و ویژگی‌های آماری	SVM	٪۸۷
[27]	تصمیم‌گیری مصرف‌کننده	عدم تقار نیم‌کره توان‌های باند فرونتال همبستگی بین کاربری	SVM	٪۶۸٫۵
روش پیشنهادی	تصمیم‌گیری مصرف‌کننده	ولش، DFA و RQA	SVM	٪۷۳٫۵

جدول (۲): نمایش مقادیر پارامترهای حساسیت، میزان عدم

اشتراک و صحت.

پارامتر	مقدار	انحراف معیار
حساسیت	٪۶۷/۶	۱٫۹۸۱۷
میزان عدم اشتراک	٪۷۴/۹	۱٫۲۴۵۶
صحت	٪۷۳/۵	۱٫۳۰۷۷

با توجه به جدول (۲)، درصد صحت روش پیشنهادی از روش موجود قبلی روی داده یکسان بهتر است [1] و افزایش ۳٫۵ درصدی را نشان می‌دهد که این افزایش صحت، بیشتر به دلیل استفاده از روش‌های آشوب‌گون است. شکل (۷) درصد پسندیده‌شدن کالاهای فروشگاه را برای ۲۵ مصرف‌کننده نشان می‌دهد.

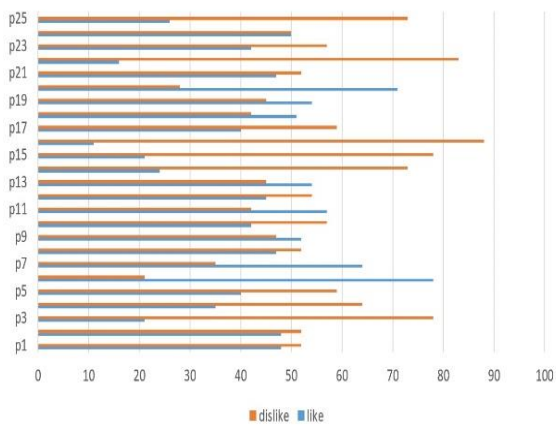
این مدل یادگیری به‌منظور پیش‌بینی ترجیحات مصرف‌کننده و اصلاح محصولات در جهت مطابق‌بودن با سلیقه مشتری کاربرد دارد. همچنین، از نتایج حاصل از این پژوهش می‌توان به سبب افزایش یا کاهش موجودی یک کالا که رابطه مستقیم با حفظ مشتری دارد تا هنگام مراجعه به فروشگاه با اتمام موجودی مواجه نشود، می‌توان براساس میزان پسندیده‌شدن یا نپسندیدن آن کالا تصمیم گرفت.

با توجه به جدول (۳)، ویژگی‌های چگالی طیف توان، تبدیل موجک گسسته، آماری، DFA و RQA به‌ترتیب بهترین نتایج را حاصل کرده‌اند و همچنین، طبقه‌بندی‌کننده‌های SVM، PNN و KNN به‌ترتیب بهترین نتایج را حاصل کرده‌اند. از نتایج جدول (۳) مشاهده می‌شود پژوهش [12] دارای بیشترین درصد صحت و پژوهش [25] دارای کمترین درصد صحت است؛ البته باید توجه داشت داده بیشتر پژوهش‌ها متفاوت بوده است.

۴- بحث و نتیجه‌گیری

فرآیند توسعه کسب‌وکار برنامه‌ای هدفمند و پویا است که به‌منظور بهبود عملکرد یک نام تجاری خاص تدوین می‌شود. اینگونه برنامه‌ها به‌منظور رشد یک واحد تجاری شامل ایجاد برند، تبلیغات و تثبیت برند است. برای اینکه هریک از اجزای این برنامه به‌صورت کارآمد اجرا شوند، نیاز به اطلاعات دقیق از نیازهای مصرف‌کننده و واکنش مصرف‌کننده نسبت به کالا است.

امروزه استفاده از روش‌های سنتی بازاریابی مانند



شکل (۷): نظر مصرف‌کننده در دو دسته پسندیدن به رنگ آبی و نپسندیدن به رنگ نارنجی

برای مقایسه روش پیشنهادی با پژوهش گذشته و بررسی نقاط قوت و ضعف، جدول (۳) آورده شده است.

هزینه‌های تولید و افزایش فروش و سود واحدهای تجاری و مطابقت بیشتر کالا با نیازهای مصرف‌کننده، منجر و مصرف‌کننده تبدیل به یک مصرف‌کننده وفادار می‌شود و جذب و حفظ مصرف‌کننده، کلیدهای اصلی برای رشد یک واحد تجاری است. ایجاد یک مدل تجاری براساس یافته‌های بازاریابی عصبی باعث افزایش سود، افزایش رضایت مشتری و درنهایت، جلوگیری از شکست یک برند خواهد شد و تا حدودی می‌تواند موفقیت یک کسب‌وکار را تضمین کند.

در مطالعه حاضر، پاسخ جعلی نسبت به اولویت محصول تحلیل نشده است؛ بنابراین، رویکردهای مقابله با پاسخ‌های جعلی می‌تواند در پژوهش‌های آینده مطالعه شود. علاوه بر این، یک انتخاب بی‌طرف برای محصولات نیز می‌تواند استفاده شود تا ترجیحات بیشتری را برای شرکت‌کنندگان فراهم کند. همچنین، استفاده از داده‌های ردیابی حرکات چشم نیز در تحلیل‌ها مفید است.

مراجع

- [1] M. Yadava, P. Kumar, R. Saini, P. P. Roy, and D. P. Dogra, "Analysis of EEG signals and its application to neuromarketing," *Multimedia Tools and Applications*, vol. 76, no. 18, pp. 19087–19111, 2017.
- [2] B. Veronica, "Brief history of neuromarketing," *J Bert Rus*, pp. 119–21, 2009.
- [3] V. Sebastian, "Neuromarketing and evaluation of cognitive and emotional responses of consumers to marketing stimuli.," *Procedia-Social and Behavioral Sciences*, vol. 127, pp. 753–757, 2014.
- [4] L. Alvino, E. Constantinides, and M. Franco, "Towards a better understanding of consumer behavior: Marginal Utility as a parameter in Neuromarketing research," *International Journal of Marketing Studies*, vol. 10, no. 1, pp. 90–106, 2018.
- [5] D. S. Vashishta and B. Balaji, "Social cognitive neuroscience, marketing persuasion and customer relations," *Procedia-Social and Behavioral Sciences*, vol. 65, pp. 1033–1039, 2012.
- [6] P. R. Solomon, "Neuromarketing-Applications, Challenges and Promises," *Biomedical Journal of Scientific & Technical Research*, vol. 12, no. 2, pp. 9136–9146, 2018.
- [7] J. M. Harris, J. Ciorciari, and J. Gountas, "Consumer neuroscience for marketing researchers," *Journal of Consumer Behaviour*, vol. 17, no. 3, pp. 239–252, 2018.
- [8] C. Morin, "Neuromarketing: the new science of consumer behavior," *Society*, vol. 48, no. 2, pp.

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. با توجه به حجم بالای محصولات، فراوانی تبلیغات و سلیقه‌های مختلف، علوم اعصاب شناختی به ابزارهای مهم و حیاتی برای واحدهای تجاری تبدیل شده و زمینه جدید بازاریابی عصبی پا به عرصه علم گذاشته است.

در این مقاله با استفاده از سیگنال EEG به تحلیل رفتار مصرف‌کننده و پیش‌بینی ترجیحات شرکت‌کنندگان برای انتخاب محصول پرداخته شده است. فعالیت مغزی ۲۵ شرکت‌کننده در هنگام تماشای ۱۴ محصول مختلف اینترنتی در سه نوع متفاوت که جمعاً ۴۲ تصویر نمایش داده، جمع‌آوری شده است. شواهد نشان دادند سیگنال EEG ماهیتی آشوب‌گون دارد؛ بنابراین، از روش‌های آشوب‌گون غیرخطی نیز استفاده شده است. استخراج ویژگی با روش‌های ولش، تحلیل نوسان روند زدایی شده و تحلیل کمی بازگشت انجام شده است و طبقه‌بند استفاده‌شده، ماشین بردار پشتیبان با تابع هسته گوسین است. نتایج نشان می‌دهند دو دسته پسندیدن و نپسندیدن یک کالا با میزان صحت ۷۳٫۵ درصد طبقه‌بندی می‌شوند که در مقایسه با پژوهش گذشته ۳٫۵ درصد بهبود در نتایج دیده می‌شود [1]؛ این افزایش درصد صحت بیشتر به دلیل استفاده از روش‌های آشوب در تجزیه و تحلیل و نزدیک‌بودن به ماهیت آشوب‌گون سیگنال EEG است. نتایج نشان می‌دهند روش پیشنهادی، راه‌حل مکمل برای اقدامات سنتی پیش‌بینی موفقیت محصول در بازار ارائه می‌دهد. همچنین، روش پیشنهادی در توسعه استراتژی‌های بازار، پژوهش و پیش‌بینی موفقیت بازار با گسترش مدل‌های موجود استفاده می‌شود.

نتیجه حاصل از این پژوهش می‌تواند به‌عنوان مکمل روش‌های سنتی در تعیین استراتژی‌های بازار نظیر طراحی محصول از ابتدا و اصلاح مجدد محصول، ارتقای تبلیغات تجاری و افزایش تأثیرگذاری، ایجاد برند و عملیاتی کردن آن، به‌خاطر سپاری برند، شناخت بهتر مصرف‌کننده و آگاهی کامل از نیازهای مصرف‌کننده استفاده شود که این به کاهش

- destination marketing,” *Journal of destination marketing & management*, vol. 7, pp. 76–88, 2018.
- [22] A. Stasi *et al.*, “Neuromarketing empirical approaches and food choice: A systematic review,” *Food Research International*, vol. 108, pp. 650–664, 2018.
- [23] W. M. Lim, “Demystifying neuromarketing,” *Journal of Business Research*, vol. 91, pp. 205–220, 2018.
- [24] G. Ural, F. KAÇAR, and S. CANAN, “Wavelet Phase Coherence Estimation of EEG Signals for Neuromarketing Studies,” *NeuroQuantology*, vol. 17, no. 2, 2019.
- [25] P. Golnar-Nik, S. Farashi, and M.-S. Safari, “The application of EEG power for the prediction and interpretation of consumer decision-making: A neuromarketing study,” *Physiology & behavior*, vol. 207, pp. 90–98, 2019.
- [26] J. Zamani and A. B. Naieni, “Best Feature Extraction and Classification Algorithms for EEG Signals in Neuromarketing,” *Frontiers in Biomedical Technologies*, vol. 7, no. 3, pp. 185–190, 2020.
- [27] A. Hakim, S. Klorfeld, T. Sela, D. Friedman, M. Shabat-Simon, and D. J. Levy, “Machines learn neuromarketing: Improving preference prediction from self-reports using multiple EEG measures and machine learning,” *International Journal of Research in Marketing*, vol. 38, no. 3, pp. 770–791, 2021.
- [28] F. P. Kalaganis, K. Georgiadis, V. P. Oikonomou, N. A. Laskaris, S. Nikolopoulos, and I. Kompatsiaris, “Unlocking the Subconscious Consumer Bias: A Survey on the Past, Present, and Future of Hybrid EEG Schemes in Neuromarketing,” *Frontiers in Neuroergonomics*, vol. 2, p. 11, 2021.
- [29] <https://www.emotiv.com>.
- [30] M. A. Awal, S. S. Mostafa, and M. Ahmad, “Performance analysis of Savitzky-Golay smoothing filter using ECG signal,” *International Journal of Computer and Information Technology*, vol. 1, no. 02, 2011.
- [31] F. A. Rahman and M. F. Othman, “Real time eye blink artifacts removal in electroencephalogram using savitzky-golay referenced adaptive filtering,” in *International conference for innovation in biomedical engineering and life sciences*, 2015, pp. 68–71.
- [32] B. M. Nicolai *et al.*, “Nondestructive measurement of fruit and vegetable quality by means of NIR spectroscopy: A review,” *Postharvest biology and technology*, vol. 46, no. 2, pp. 99–118, 2007.
- [33] G. P. John, G. M. Dimitris, and G. Manolakis, “Digital Signal Processing: Principles, Algorithms and Applications,” *Pentice Hall*, 1996.
- [34] P. Stoica and R. L. Moses, “Spectral analysis of signals,” 2005.
- [35] H. E. Hurst, “Long-term storage capacity of reservoirs,” *Trans. Amer. Soc. Civil Eng.*, vol. 116, pp. 770–808, 1951.
- [36] C.-K. Peng, S. Havlin, H. E. Stanley, and A. L. Goldberger, “Quantification of scaling 131–135, 2011.
- [9] G. Vecchiato *et al.*, “On the use of EEG or MEG brain imaging tools in neuromarketing research,” *Computational intelligence and neuroscience*, vol. 2011, p. 3, 2011.
- [10] G. S. Berns and S. E. Moore, “A neural predictor of cultural popularity,” *Journal of Consumer Psychology*, vol. 22, no. 1, pp. 154–160, 2012.
- [11] R. N. Khushaba, C. Wise, S. Kodagoda, J. Louviere, B. E. Kahn, and C. Townsend, “Consumer neuroscience: Assessing the brain response to marketing stimuli using electroencephalogram (EEG) and eye tracking,” *Expert Systems with Applications*, vol. 40, no. 9, pp. 3803–3812, 2013.
- [12] M. Murugappan, S. Murugappan, and C. Gerard, “Wireless EEG signals based neuromarketing system using Fast Fourier Transform (FFT),” in *2014 IEEE 10th international colloquium on signal processing and its applications*, 2014, pp. 25–30.
- [13] D. Baldo, H. Parikh, Y. Piu, and K.-M. Müller, “Brain waves predict success of new fashion products: a practical application for the footwear retailing industry,” *Journal of Creating Value*, vol. 1, no. 1, pp. 61–71, 2015.
- [14] M. Hsu, “Neuromarketing: inside the mind of the consumer,” *California Management Review*, vol. 59, no. 4, pp. 5–22, 2017.
- [15] N. Lee, L. Chamberlain, and L. Brandes, “Welcome to the jungle! The neuromarketing literature through the eyes of a newcomer,” *European Journal of Marketing*, vol. 52, no. 1/2, pp. 4–38, 2018.
- [16] U. R. Karmarkar and H. Plassmann, “Consumer neuroscience: Past, present, and future,” *Organizational Research Methods*, vol. 22, no. 1, pp. 174–195, 2019.
- [17] M.-H. Lin, S. N. Cross, W. J. Jones, and T. L. Childers, “Applying EEG in consumer neuroscience,” *European Journal of Marketing*, vol. 52, no. 1/2, pp. 66–91, 2018.
- [18] H. Boz, A. Arslan, and E. Koc, “Neuromarketing aspect of tourism pricing psychology,” *Tourism Management Perspectives*, vol. 23, pp. 119–128, 2017.
- [19] H. N. Oon, A. Saidatul, and Z. Ibrahim, “Analysis on Non-linear features of electroencephalogram (EEG) signal for neuromarketing application,” in *2018 International Conference on Computational Approach in Smart Systems Design and Applications (ICASSDA)*, 2018, pp. 1–8.
- [20] A. Hakim and D. J. Levy, “A gateway to consumers’ minds: Achievements, caveats, and prospects of electroencephalography-based prediction in neuromarketing,” *Wiley Interdisciplinary Reviews: Cognitive Science*, vol. 10, no. 2, p. e1485, 2019.
- [21] M. Bastiaansen, S. Straatman, E. Driessen, O. Mitas, J. Stekelenburg, and L. Wang, “My destination in your brain: A novel neuromarketing approach for evaluating the effectiveness of

- [41] J. P. Eckmann, S. O. Kamphorst, and D. Ruelle, "Recurrence plots of dynamical systems," *World Scientific Series on Nonlinear Science Series A*, vol. 16, pp. 441–446, 1995.
- [42] M. Niknazar, S. R. Mousavi, B. V. Vahdat, and M. Sayyah, "A new framework based on recurrence quantification analysis for epileptic seizure detection," *IEEE journal of biomedical and health informatics*, vol. 17, no. 3, pp. 572–578, 2013.
- [43] N. Marwan, M. C. Romano, M. Thiel, and J. Kurths, "Recurrence plots for the analysis of complex systems," *Physics reports*, vol. 438, no. 5–6, pp. 237–329, 2007.
- [44] J. Theiler, "Spurious dimension from correlation algorithms applied to limited time-series data," *Physical review A*, vol. 34, no. 3, p. 2427, 1986.
- [45] C.-C. Chang and C.-J. Lin, "LIBSVM: A library for support vector machines," *ACM Transactions on Intelligent Systems and Technology (TIST)*, vol. 2, no. 3, p. 27, 2011.
- exponents and crossover phenomena in nonstationary heartbeat time series," *Chaos: An Interdisciplinary Journal of Nonlinear Science*, vol. 5, no. 1, pp. 82–87, 1995.
- [37] A. V. Coronado and P. Carpena, "Size effects on correlation measures," *Journal of biological physics*, vol. 31, no. 1, pp. 121–133, 2005.
- [38] A. Isvoran, "Describing some properties of adenylyl kinase using fractal concepts," *Chaos, Solitons & Fractals*, vol. 19, no. 1, pp. 141–145, 2004.
- [39] L. T. Timothy, B. M. Krishna, and U. Nair, "Classification of mild cognitive impairment EEG using combined recurrence and cross recurrence quantification analysis," *International Journal of Psychophysiology*, vol. 120, pp. 86–95, 2017.
- [40] M. C. Romano, M. Thiel, J. Kurths, I. Z. Kiss, and J. L. Hudson, "Detection of synchronization for non-phase-coherent and non-stationary data," *EPL (Europhysics Letters)*, vol. 71, no. 3, p. 466, 2005.

-
- ¹ Neuromarketing
 - ² Electroencephalography
 - ³ Magnetoencephalography
 - ⁴ functional Magnetic Resonance Imaging
 - ⁵ Positron Emission Tomography
 - ⁶ Transcranial Magnetic Stimulation
 - ⁷ Event Related Potential
 - ⁸ Galvanic Skin Response
 - ⁹ Electromyography
 - ¹⁰ Plethysnography
 - ¹¹ Heart Rate Variability
 - ¹² Striatum
 - ¹³ Probabilistic Neural Network
 - ¹⁴ Detrended Fluctuation Analysis
 - ¹⁵ K Nearest Neighbors
 - ¹⁶ The Rum Diary
 - ¹⁷ Support Vector Machine
 - ¹⁸ Common Mode Sense
 - ¹⁹ Driven Right Leg
 - ²⁰ Savitzky–Golay filter
 - ²¹ Welch
 - ²² Recurrence Quantification Analysis
 - ²³ Recurrence Plots
 - ²⁴ Heaviside
 - ²⁵ Recurrence Rate
 - ²⁶ Determinism
 - ²⁷ Theiler
 - ²⁸ Laminarity
 - ²⁹ Trapping Time
 - ³⁰ Kernel function
 - ³¹ Sensitivity
 - ³² Specificity