Advances in Cognitive Sciences
Vol 22, No. 1, Spring 2020
Research Article
Pages 81-92

Design an intelligent system based on a computational cognitive model using attention network task

Azadeh Haratiannezhadi[1], Saeed Setayeshi[2], Javad Hatami[3]

1. PhD Student of Cognitive Modeling, Institute for Cognitive Science Studies, Tehran, Iran
2. Associate Professor of Physics, Amirkabir University of Technology, Tehran, Iran
3. Associate Professor Psychology, Institute for Cognitive Science Studies, Tehran, Iran

Recieved: 16 Jul. 2019
Revised: 14 Nov. 2019
Accepted: 28 Nov. 2019

Keywords
Attention network task
Brain-computer interface (BCI)
Machine learning
Brain signals

Corresponding author
Azadeh Haratiannezhadi, PhD Student of Cognitive Modeling, Institute for Cognitive Science Studies, Tehran, Iran

Email: Azadeh.haratian@gmail.com

doi.org/10.30699/icss.22.1.81

Abstract

Introduction: The attention is a gateway for learning and a limited resource. Attention cognitive model helps to perceive and use it efficiently. This research aimed to find an intelligent model for a different level of attention.

Methods: Developing a cognitive model based on the attention network task and brain signals. The model builds on machine learning techniques. The initial research population consists of 92 adult volunteers who completed the Depression Anxiety Stress Scales test (DASS-21). Based on the test results, 31 subjects selected and invited to take Attention Network test and during the test, brain signals were captured for this purpose, Brain-computer Interface (BCI) was used and a model constructed based on different levels which used subject's brain signal, reaction time and test result.

Results: Data were classified based on different machine learning methods such as Support Vector Machine (SVM), K-Nearest Neighbor (KNN), and Adaboost. The correct classification rate for these classifiers is 68, 90, and 87 percent.

Conclusion: The final model is selected based on the accuracy. So the KNN classifier has better generalization and it estimates test data better than other classifers. The desired Nero-cognitive model is based on the results and KNN classifiers are the best option for these types of cognitive models which is difficult to gather data and the dataset's size are small.

Citation: Haratiannezhadi A, Setayeshi S, Hatami J. Design an intelligent system based on a computational cognitive model using attention network task. Advances in Cognitive Sciences. 2020;22(1):81-92.

مجله تازه‌های علوم شناختی
دوره ۲۲، شماره ۱، بهار ۱۳۹۹
صفحات ۹۲-۸۱
مقاله پژوهشی

طراحی یک ماشین هوشمند مبتنی بر مدل‌سازی شناختی با استفاده از تکلیف شبکهٔ توجه

آزاده هراتیان نژادی[1*]، سعید ستایشی[2]، جواد حاتمی[3]

۱. دانشجوی دکتری مدل‌سازی شناختی، موسسه آموزش عالی علوم شناختی، تهران، ایران
۲. دانشیار فیزیک، دانشگاه صنعتی امیرکبیر، تهران، ایران
۳. دانشیار روان‌شناسی، موسسه آموزش عالی علوم شناختی، تهران، ایران

دریافت: ۱۳۹۸/۰۴/۲۵
اصلاح نهایی: ۱۳۹۸/۰۸/۲۳
پذیرش: ۱۳۹۸/۰۹/۰۷

واژه‌های کلیدی
تکلیف شبکهٔ توجه
سیستم واسط کاربری مغز
یادگیری ماشین
سیگنال مغزی

نویسنده مسئول
آزاده هراتیان نژادی، دانشجوی دکتری مدل‌سازی شناختی، موسسه آموزش عالی علوم شناختی، تهران، ایران

ایمیل: Azadeh.haratian@gmail.com

doi.org/10.30699/icss.22.1.81

چکیده

مقدمه: توجه دروازهٔ یادگیری و یکی از منابع قابل‌پردازش است که مدل‌سازیِ شناختی آن به درک و استفادهٔ بهتر از آن کمک می‌کند. هدف از این پژوهش ایجاد مدلی هوشمند با کارایی بسیار برای دسته‌بندی سطوح مختلف توجه بود.

روش کار: ایجاد مدل شناختیِ توجه با استفاده از نتایج تکلیف شبکهٔ توجه و امواج مغزی انجام گرفت. به این منظور، با استفاده از روش‌های مختلفِ یادگیریِ ماشین، به ایجاد مدلی از توجه پرداخته شد. در این پژوهش، جامعهٔ آماری شامل ۹۲ فرد بزرگسال داوطلب بود که به صورت تصادفی انتخاب شده و پرسشنامه DASS-21 را برای انتخاب اولیه انجام دادند. سپس بر اساس نتایج، از ۳۱ نفر بیماری که افسردگی و اضطراب نداشتند و واجد شرایط بودند، برای مرحلهٔ نهایی دعوت به عمل آمد. در حین تکلیفِ شبکهٔ توجه، با استفاده از سیستم واسط کاربری مغز، از شرکت‌کنندگان سیگنال مغزی گرفته شد و مدلی از سطوح مختلف با استفاده از سیگنال‌های مختلف، زمان واکنش و درستی جواب شرکت‌کننده ایجاد گردید.

یافته‌ها: داده‌ها با روش‌های دسته‌بندیِ یادگیریِ ماشین‌های مختلفی مانندِ ماشین بُردارهای پشتیبان (SVM) و K نزدیک‌ترین همسایگی (KNN) و آدابوست (Adaboost) بررسی شد و مدلی که کمترین خطای دسته‌بندی را داشت برگزیده شد. این دسته‌بندی‌ها، به ترتیب با نرخ دسته‌بندیِ ۶۰ و ۱۰۰ و ۹۴ درصد، در مورد دسته‌بندیِ الگوهای شناختیِ «توجه»، توانایی‌های مختلفی را برای این مجموعه از داده‌ها نشان داد.

نتیجه‌گیری: بر اساس نتایج دقت دسته‌بندی‌ها، مدل مناسب انتخاب شد و دسته‌بندی KNN از نظر تعمیم‌پذیری و تخمین داده‌های آزمون دقت بهتری از بقیه مدل‌های انتخاب شده در این پژوهش را نشان داده است. برای این نوع از مدل‌های شناختی که در آن امکان جمع‌آوریِ حجم کمتری داده وجود دارد نیز مدل مناسب تلقی می‌شود.

مقدمه

توجه نقش مهمی در یادگیری و عملکرد روزانهٔ انسان دارد و در عین حال جزو حساس‌ترین و یکی از مهم‌ترین فرایندهای شناختی است. توجه مستلزم انتخاب است. در واقع، توجه تعاملی موفق با محیط است و به عنوان دروازهٔ شناختی عمل می‌کند (۱). به عبارت دیگر، هر زمانی که محیطی کشف می‌شود، اطلاعات زیادی جمع‌آوری می‌گردد و از آنجا که سیستم پردازشی ظرفیت اندکی دارد، مغز باید ساز و کارهایی برای انتخاب این اطلاعات داشته باشد. عملکردهای اصلی توجه عبارت‌اند از: ۱) پایداری رفتارهای مبتنی بر هدف و محافظت در برابر رویدادهای منحرف شده در طی زمان؛ ۲) واکنش‌های سریع و کارا برای رویدادهای جدید. سامانهٔ «توجه» باید به اهداف شخصی مربوط باشد و این سامانه

بر اساس تجارب قبلی کار در محیط است (۲). این سامانه شناختی تنها بر روی یکی از جنبه‌های محیط، تمرکز دارد، در حالی که سایر جنبه‌ها نادیده گرفته می‌شود و همچنین وظیفه تخصیص منابع پردازشی را دارد (۱). نقص توجه می‌تواند باعث به خطر افتادنِ جان انسان‌ها در حین رانندگی یا راه رفتن شود. در سال ۲۰۱۰، Quinn با انجام پژوهشی دلایل تصادفات رانندگی را با پرسش از افرادی که شاهد ماجرا بوده‌اند بررسی نمود، که در آن از افراد در مورد عوامل مختلف وقوع تصادف سؤال شد و ۵۶/۳ درصد، نداشتن توجه کافی در حین رانندگی را دلیل اصلی تصادف اعلام کرده‌اند (۳).

پردازش امواج EEG راجع به عملکردهای شناختی و انواع مختلف بیماری‌ها اطلاعات بسیار مفیدی می‌دهد (۴). در زمینهٔ مطالعهٔ مدل تکلیف شبکهٔ توجه (Attention Network Task (ANT)) و امواج EEG، تحقیقات مختلفی انجام شده است، اما تحقیقی در زمینهٔ تولید ماشین یادگیرندهٔ شبکهٔ توجه و امواج مغزی انجام نشده است. هدف این پژوهش تحقیق در همین زمینه و دسته‌بندی سطوح توجه با استفاده از همین ماشین است. این مدل برای بازخوردگیری از سطح توجه افراد مؤثر است و نیز سیستمی هوشمند برای شناسایی است. در پژوهش حاضر، برای مطالعهٔ توجه از ترکیب مدل تکلیف شبکهٔ توجه و امواج مغزی استفاده شده است. به دلیل انعطاف‌پذیریِ برنامه‌های رایانه‌ای و در نظر گرفتن شاخص‌های مختلف، توجه پروتکلی مناسب برای اندازه‌گیری سطح توجه است. همچنین با این تکلیف به درک بهتر توجه کمک می‌شود. Posner و همکاران برای توجه، مدلی محاسباتی به نام تکلیف شبکهٔ توجه (ANT) معرفی کردند. از این مدل مطرح برای اندازه‌گیری توجه استفاده شد. مدل یاد شده سه کارکرد اصلی زیر را محاسبه می‌کند (۵):

۱. قابلیت پردازش سیگنال‌ها یا هشدارهایی با اولویت زیاد

۲. موقعیت‌یابی

۳. جست‌وجو برای یافتن هدف

یکی دیگر از روش‌های اندازه‌گیری توجه استفاده از امواج مغزی است. الکتروآنسفاگرافی (EEG) سیستمی است که فعالیت امواج مغزی را با استفاده از روش‌های الکتریکی اندازه‌گیری می‌کند. EEG همان امواج ضبط شدهٔ مغزی است. اولین گزارش ضبط امواج مغزی در سال ۱۹۲۹ انجام شد و به طور معناداری، به محققان و پزشکان امکان می‌داد که اَعمال مغزی را مشاهده کنند. میلیون‌ها نورون در مغز هستند که فعالیت‌های آنها باعث ایجاد میدان ولتاژهای الکتریکی می‌شود. فرکانس‌های الکتریکی در EEG می‌توانند بسته به محرک‌های خارجی، وضعیت‌های مختلفی را نشان دهند (۶). در این تحقیق از سیستم واسط کاربری مغز (Computer Interface Brain (BCI)) برای ثبت EEG استفاده شده است، زیرا برنامهٔ تکلیف شبکهٔ توجه مبتنی بر وب نوشته شده است و این دستگاه‌ها آزادی عمل برای گرفتن تکلیف در هر زمان و مکانی را می‌دهند.

سیستم واسط کاربری ابزاری است که فعالیت الکتروفیزیولوژی یا نرخ متابولیک را به سیگنال‌هایی که توسط دستگاه درک می‌شوند نشان می‌دهد (۷). سیگنال‌های الکتریکی در طول الکترود برای تعیین سطح توجه اندازه‌گیری می‌شوند و به اطلاعات دودویی تبدیل می‌گردند (۸). بیشترِ این دستگاه‌ها اخیراً برای کاربردهای تحقیقاتی و پزشکی و برحسب اندازه و پیچیدگی طراحی شده‌اند. روش‌های مختلفی برای اندازه‌گیری سیگنال‌های مغزی از قبیل تداخلی یا غیرتداخلی وجود دارد (۹). Mindwave شرکت Neurosky دستگاهی است که دارای الکترود خشک بوده و برای ثبت امواج مغزی استفاده می‌شود (۶)، که با یک الکترود این کار را انجام می‌دهد (۱۰). دلایل استفاده از آن برای جمع‌آوری اطلاعات EEG و امکان متحرک بودن و قیمت کم است. انتقال اطلاعات EEG از طریق بلوتوث است. باندهای مختلفی را اندازه‌گیری می‌کند که عبارتند از: باند آلفا (۷ تا ۱۴ هرتز) که مربوط به هشیاری، آرام‌سازی و تفکر است؛ باند بتا (۱۴ تا ۳۰ هرتز) که مربوط به تفکر فعال، توجه فعال و حل مسائل عملی است؛ باند دلتا (۳ تا ۷ هرتز) که مربوط به جلوی سرِ افراد بالغ است، که دامنهٔ موج بالایی دارد و با استفاده از بعضی تکلیف‌های توجهِ ممتد شناسایی می‌شود؛ باند تتا (۴ تا ۷ هرتز) که معمولاً مربوط به استرس احساسی مانند ناامیدی است؛ باند گاما (۳۰ تا ۸۰ هرتز) که معمولاً مربوط به پردازش‌های شناختیِ محرک چند حسی است (۱۱). در این مقاله، مدل هوشمند ترکیبی جدیدی با استفاده از امواج الکتروآنسفاگرافی و نیز تکلیف شبکهٔ توجه ایجاد شده است. این مدل به درک بهتر فرایندهای شناختی منجر می‌شود. در ادامه به بررسی پژوهش‌های مختلفی که با همین دستگاه و برای تکلیف‌های روان‌شناختی و مدل‌های یادگیری ماشین انجام شده است پرداخته شد.

خواب‌آلودگی یکی از مشکلات شناخته شدهٔ کارگران است، مخصوصاً زمانی که باید برای مدت طولانی هشیار باشند. هدف از این پژوهش ضبط اطلاعات EEG با استفاده از تک کانال خشک است. در مطالعه Jones و Schwartz از سیگنال‌های EEG اطلاعات مهمی دربارهٔ وضعیت شرکت‌کنندگان گرفته شد (۱۲). وضعیت گوش به زنگی در این پروژه بسیار با اهمیت بود. همچنین در اینجا از طریق ترکیب روش‌های علوم شناختی و روش‌های پردازش اطلاعات به بهبود تحلیل و تفسیر فرایندهای شناختیِ مبتنی بر رنگ از طریق دستگاه

BCI نیز پرداخته شد. برای انجام این کار باید اول بر اساس مقایسهٔ نتایج سنتی روش تحلیل شناختی (کیفی و کمی) به وسیلهٔ تحلیل سیگنال EEG آزمایشی انجام شد. در حالی که تکلیف شناختی، شامل یادآوری کلمات در صفحه با ترکیب مختلف رنگی پیش زمینه و پس زمینه ظاهر می‌شود (۱۱). در این کار داده‌ها را از دانش‌آموزان جمع‌آوری کردند و محرک بصری بر اساس انواع رنگ‌ها به آنها نمایش داده شد. محرک پیش زمینهٔ متن یادگیری متنی و رنگ کاراکترها است (۱۱). آزمایش نتایج جالبی را نشان می‌داد که استفاده از RGB اصلی و رنگ‌های مکمل CMY است. برای گرفتن بازخورد خودآگاه و ناخودآگاه از کاربر، از EEG مبتنی بر BCI استفاده شد. در این مقاله، تحلیل داده‌های جمع‌آوری شده در دو مرحله انجام شد: ۱) تحلیل داده‌های رفتاری بر اساس یافته‌های پرسشنامه؛ ۲) تحلیل سیگنال EEG (۱۱).

شناخت و خلاصه‌سازی فعالیت‌ها، در افزایش آگاهی شخصی مؤثر است و امکان بهبود عادات را دارد. خواندن باعث بهبود مهارت‌های زبانی می‌شود و استراحت در بازه‌های زمانی مرتب باعث بهبود سلامتی می‌شود. شناخت این فعالیت‌ها و هدایت زمانی که صرف می‌شود به کاربر امکان استراحت و خواندن کافی را می‌دهد. در این پژوهش از دستگاه Neurosky استفاده شد. این دستگاه قابلیت تشخیص فعالیت‌های مغزی کاربر را دارد و مدل پشنهادی، اقدام به با بازخورد سطح توجه به کاربر در حین کار با نرم‌افزار می‌کند و برای یادگیری یا رایانه استفاده می‌شود (۱۳).

در پژوهش Tiwari و Saini، استخراج سیگنال‌های مغزی با استفاده از روش‌های غیرتداخلی با واسط مغز و رایانه انجام شده است. این سیگنال‌ها برای کنترل دستگاه‌های دیگر به کار گرفته می‌شود. سیگنال‌های مغزی حدود ۳۵۴ میلی ولتاژ دارد. پس از شبیه‌سازی سیگنال‌های مغزی، دو سیگنال کنترل به دست می‌آید. کاربرد این روش در حرکت روبات است. مقادیر توجه و آرام‌سازی انسان را برای کنترل روبات‌ها استفاده می‌کند. روبات با میزان مشخصی از توجه حرکت می‌کند و همین‌طور با مقادیر خاصی از آرام‌سازی به عقب می‌رود. در واقع، روباتی که با کنترلی امواج مغزی به وسیله BCI پیاده‌سازی کرده است. این دستگاه‌ها، کانال‌های ارتباطی ارتباط مستقیم بین مغز انسان و دستگاه فیزیکی را حذف می‌کند و با ترجمهٔ الگوهای مختلف از فعالیت‌های مغزی، آنها را فوراً ترجمه می‌کند. هدف از این پروژه کمک به انسان در زندگی روزمره بود (۱۴). در مطالعه Bose و همکاران با استفاده از EEG سطح توجه کاربر را در حین بازدید از یک صفحه وب اندازه‌گیری کردند. برای انجام این کار سه روش استفاده شد. اول به صورت مکانیزم کنترلی برای کنترل عناصر واسط کاربری مانند منو یا دکمه‌ها؛ دوم برای یافتن سطح تمرکز کاربر به بخشی از صفحهٔ نمایش‌گر (برای این منظور از توسعه‌دهندگان خواسته شد که ساختار صفحات را بهبود دهند)؛ سوم وسیله‌ای که می‌تواند سطح توجه کاربر را اندازه‌گیری کند. نتایج تحقیق ایجاد وب‌سایتی است که به توجه کاربر حساس است. تمام این مراحل از طریق حسگر دستگاه انجام شد و یک استاندارد وب مبتنی بر EEG ایجاد کردند. در پیاده‌سازی آنها این مورد را در نظر گرفتند که اگر بر یک آیتم بیش از یک ثانیه تمرکز داشتند همچنان بر آن باقی می‌مانند وگرنه به آیتم بعدی حرکت می‌کردند. این روش سومی است که توجه می‌تواند در جستجوی اینترنت (Browsing) استفاده شود. هدف ایجاد مرورگری است که به توجه حساس باشد و بتواند چگونگی توجه کاربر را کنترل کند، به طوری که بر اساس توجه محتوای متفاوتی تولید شود و به دستگاه کاربر ارسال شود (۱۵). در پژوهش Peters و همکاران، مدلی از سطح توجه کاربر ایجاد شد که سه مؤلفهٔ اصلی داشت. مولفه اول، حرکات چشم را تعقیب می‌کند و اطلاعات آن را جمع‌آوری می‌کند، دومی، داده‌های نوروفیزیولوژی است که اطلاعات را با استفاده از دستگاه Neurosky گردآوری می‌کند که شامل سطح توجه و آرام‌سازی است. مولفه سوم، مدل ترکیبی از دو مؤلفهٔ قبلی است که موقعیت مکانی، زمانی و درجه توجه را نشان می‌دهد. از این مدل برای تحلیل رفتار کاربر و همچنین اطلاع به عامل (Agent) و مدیریت تعاملات استفاده می‌شود (۱۶).

روش‌های مختلف یادگیری ماشین برای EEG در تحقیق‌های مختلف استفاده شده است. روش‌های k نزدیکترین همسایگی و ماشین بردارهای پشتیبان (Support Vector Machines (SVM)) برای ایجاد مدل و دسته‌بندی انواع احساسات استفاده شده است (۱۷). تمامی این دسته‌بندی‌کننده‌ها به همراه درخت تصمیم‌گیری و دسته‌بندی‌کننده‌های ترکیبی استفاده شد. در مقاله Ghanbari و همکاران نیز از دسته‌بندی‌کنندهٔ مبتنی بر شبکهٔ عصبی مصنوعی برای اطلاعات EEG گرفته شدهٔ کاربر استفاده شده است و نتایج بهتری را نسبت به SVM نشان داده است (۱۸). نوآوری این پژوهش در مدلی با هوشمند عصبی‌شناختی توجه است و ایجاد مدلی که هر دو جنبه را پوشش دهد. همچنین ایجاد دسته‌بندی‌کننده‌های که از مقالاتی که در این بخش آورده شده است. برای انجام این کار، از امواج مغزی BCI و آزمون شناختی ANT استفاده شد. در پژوهش حاضر سعی شد که مدلی هوشمند برای اندازه‌گیری سطوح توجه ایجاد شود. که در بخش بعد به تفصیل دربارهٔ آن توضیح داده شده است.

روش کار

با توجه به ماهیت پژوهش حاضر، ترکیبی از روش‌های علوم شناختی و مهندسی استفاده شد. کیفیت مدل‌های شناختی با زمان اجرا و نرخ خطا و حجم اطلاعات ارزیابی گردید. EEG امواج و الگوهای مغزی نیز ثبت و ضبط شد (۶). ابزارهای BCIs به دلیل این آسانی نصب، قابلیت انتقال اطلاعات امروزه برای مطالعات مغزی بسیار استفاده می‌شود. ابزارهای جدید از بلوتوث برای آسانی اتصال به رایانه برای اجرا در زمان‌های بیشتری استفاده می‌کنند. ۹۲ خانم و آقا که تجربهٔ استفاده از برنامه‌های رایانه‌ای را داشته‌اند و در بازهٔ سنیِ ۲۰ تا ۴۵ سال به صورت تصادفی ساده انتخاب شدند. از آنها پرسیده شد که داروی خاصی را مصرف نمی‌کنند و همچنین دچار اختلال‌های حافظه یا بیماری‌های روانی نباشند. برای این منظور، از آنها مصاحبه و پرسشنامهٔ DASS-21 گرفته شد. این تکلیف، مقیاس افسردگی، اضطراب، استرس مجموعه‌ای از سه مقیاس خود گزارش‌دهی برای ارزیابی حالات عاطفه منفی در افسردگی، اضطراب و استرس است. این روشی برای اندازه‌گیری شدت نشانه‌های اصلی افسردگی، اضطراب واسترس است (۱۹). برای تکمیل پرسشنامه فرد باید وضعیت یک نشانه را در طول هفته گذشته مشخص کند و افرادی که از سطح متوسط تا نرمال بودند برای آزمون نهایی این تحقیق، انتخاب شدند. سپس از بین آنها تعداد ۳۱ نفر واجد شرایط بودند وارد مطالعه شدند. مراحل انجام آزمایش برای آنها توضیح داده شد.

ابزار پژوهش

فرایند اجرای آزمون تحت وب انجام شد. آزمون در اتاقی ساکت که دیگران دسترسی ورود نداشتند انجام شد، هیچ نوع محرکی برای انحراف افراد از تکلیف وجود نداشت. فرایند کلی تحقیق در شکل ۱ آمده است. در این پژوهش از الگوریتم‌های یادگیری ماشین استفاده شد. در ادامه، به جزئیات بخش‌های مختلف پرداخته می‌شود.

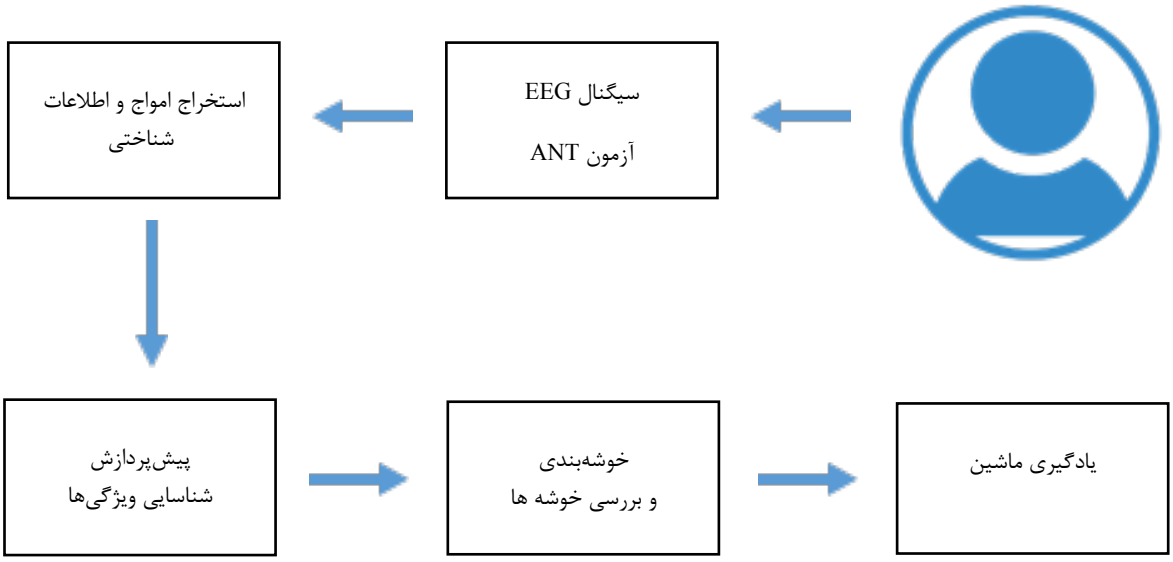

شکل ۱. فرایند کلی پژوهش

۱. تکلیف شبکهٔ توجه

این آزمون بر پایه به کارگیری ترکیب نشانه و تکلیف Eriksen Flanker است. این مدل محاسباتی، سه پارامتر مهم (هشدار و موقعیت‌یابی و عملکردهای اجرایی) را با زمان واکنش اندازه‌گیری می‌کند. هشدار مفهوم کلی‌تر، تغییر در وضعیت ورودی برای آماده‌سازی تکلیف مرتبط با ورودی است. موقعیت‌یابی انتخاب اطلاعات از ورودی حسی است و کنترل اجرایی وظیفهٔ حل اختلاف بین پاسخ‌ها را دارد (۲۰). در این تکلیف از شرکت‌کننده خواسته می‌شود که فلش چپ یا راست را بزنند. چنان چه که فلش چپ را شرکت‌کننده در آزمون مشاهده کرد، کلید متناظر چپ را بزند و به همین ترتیب زمانی که کلید راست دیده شد، فلش راست بزند. قبل از هدف، نشانه‌هایی برای ارائهٔ اطلاعات دربارهٔ مکان و زمان آن نمایش داده می‌شود، مطابق شکل ۳ (۲۱).

در شکل ۲ شماتیک چگونگی اجرای تکلیف شبکهٔ توجه که مراحل آن و تنوع مراحل ارائه شده است. مراحل برنامه در این تحقیق، به وسیلهٔ برنامهٔ مبتنی بر وب انجام شد و کاربران در حین انجام آن دستگاه Neurosky بر سرشان قرار دارد.

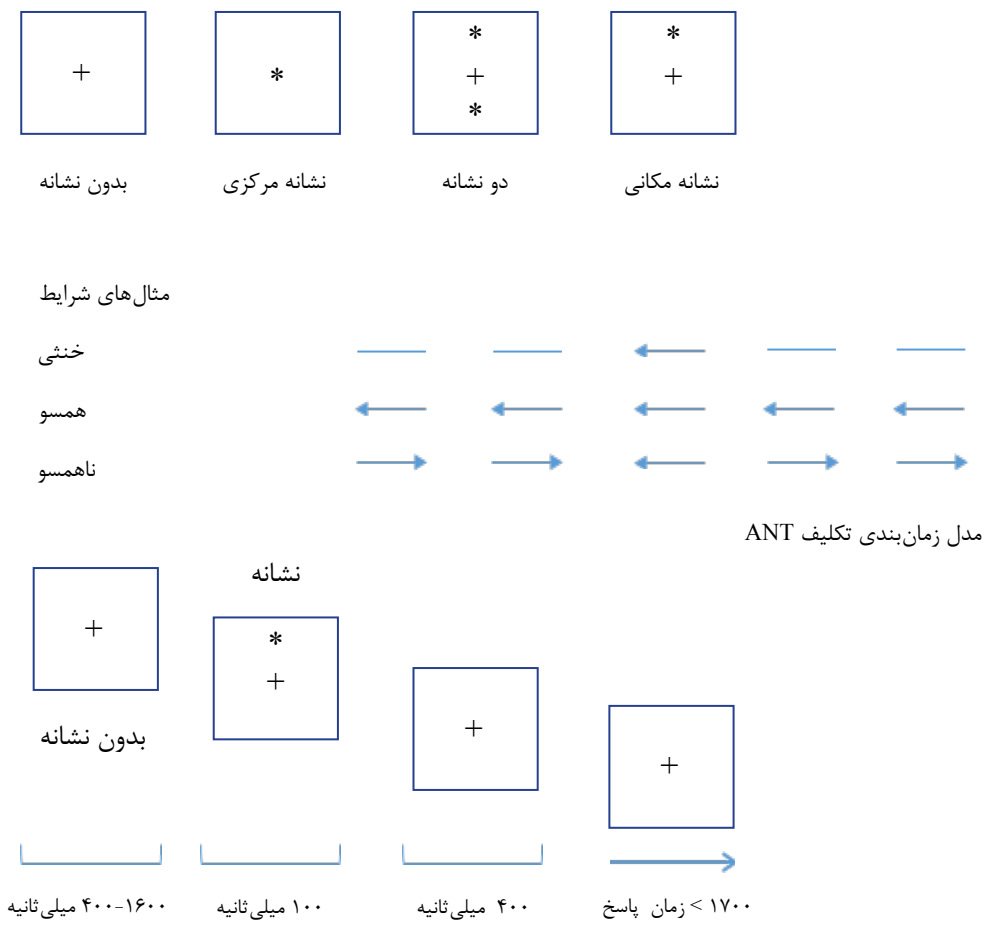

شکل ۲. شماتیک اجرای ANT (۲۱)

تکلیف شبکهٔ توجه، به معنی تمرین تکلیف‌های مرتبط با تناقض، حافظهٔ کاری و دیگر تکلیف‌های مرتبط با مکانیزم‌های کنترل اجرایی است. این تکلیف‌ها اغلب برای اجراهای تکراری که شامل کنترل‌های اجرایی است، و با هدف تمرین مکانیزم‌های کنترلی است. این نوع از تمرین‌ها نیازمند توجه به جهت است و کنترل‌ها برای آموزش شبکه‌های مغزی خاص است (۲۱). در جدول ۱، مشخصات این تکلیف از منظر افراد داده شده است.

۲. امواج مغزی

در این پژوهش، همان‌طور که قبلا اشاره شد از Neurosky استفاده شد، که یک هدست کامل است. همچنین از بلوتوث برای انتقال اطلاعات استفاده شد که امکان استخراج سطح توجه و آرام‌سازی را داشت. این هدست دارای حسگر خشک است که به پیشانی، خارج از قشر مغزی (Cerebral Cortex) در لوب پیشانی مغز متصل می‌شود که مسئول توجه و تکلیف‌های مربوط به حافظهٔ کوتاه مدت بود (۲۲). پیش از مرحلهٔ تکلیف شبکهٔ توجه، از شرکت‌کننده خواسته شد که هدست امواج مغزی را روی پیشانی خود نصب کند. سپس آزمون اولیه انجام شد که آیا ارسال اطلاعات امواج مغزی یا EEG موفقیت‌آمیز است یا خیر. این دستگاه، حسگری حیاتی دارد که رفتارهای حیاتی الکتریکی را در مغز می‌خواند.

جدول ۱. مشخصات تکلیف ANT

مشخصات تکلیف ANT	تعداد
کل مراحل	۶۲
مراحل آزمایشی	۳۱

فعالیت‌های مغزی را با استفاده از سه الکترود خشک می‌گیرد (مناطق جوی پیشانی و گوش) و آنها را با استفاده از تعدادی الگوریتم رمزگشایی می‌کند. اطلاعات دلتا، تتا، آلفا، بتا و گامای مغزی سطح قدرت باندی کاربر را اندازه‌گیری می‌کند. چون محل‌های Fp1 و Fp2 در این هدبند قرار دارد و مو در پیشانی رشد نمی‌کند، قرارگیری آن ساده‌تر است.

ویژگی‌های این دستگاه که آن را برای این تحقیق سودمند کرده است، به شرح زیر است (۱۴):

- وزن سبک
- هدست امواج مغزیِ قابلِ جابه‌جایی EEG
- اتصال مستقیم با الکترود خشک
- فیلترهای پیشرفته با محافظت از نویز زیاد

این دستگاه سیگنال‌های خام با باند مغزی در ۵۱۲ هرتز را جمع‌آوری می‌کند. از تبدیل فوریه برای تولید پنج کانال اضافی از موج خام، دلتا، تتا، آلفا و گاما استفاده می‌کند (۲۳). در این دستگاه، حدود چهار ثانیه تأخیرِ زمان رسیدن این مقادیر به رایانه وجود دارد و در هر بازهٔ زمانی یک ثانیه مقدار جدید توجه محاسبه می‌شود. مقدار صفر نشان‌دهندهٔ این است که سیگنالی خوانده نشده و مقدار بیش از صفر نشان‌دهندهٔ افزایش سطح توجه با مقدار نزدیک ۱۰۰ است (۱۳). پس از بررسی اطلاعات، ۳۱ داده برای انجام دسته‌بندی، واجد شرایطِ پردازشِ اطلاعات است. برای ایجاد ماشینی هوشمند از اطلاعاتِ توجه در سطح عصبی و شناختی از یادگیری ماشین استفاده کردیم که برای ایجاد الگوی رفتاری‌عصبی استفاده شده است (۲۴).

روند تحلیل داده‌ها

برای ایجاد مدل، از روش‌های یادگیری ماشین استفاده شد. این روش فرایندی کلی دارد و در مرحلهٔ (۱) ویژگی‌های تأثیرگذار در تعیین کلاس‌ها مشخص می‌شود، در مرحلهٔ (۲) داده‌ها جمع‌آوری می‌شوند (در این مرحله هر یک از ویژگی‌های مرحلهٔ قبل برای داده‌ها محاسبه می‌شود). در نهایت در مرحله (۳)، اگر فرایند سیستم تحت نظارت باشد لازم است که فرد خبره‌ای در آن حوزه برای داده‌ها برچسب کلاس تهیه کند. با این کار دادهٔ آموزش تهیه می‌شود. این داده به دسته‌بندی‌کنندهٔ مورد نظر داده می‌شود و دسته‌بندی‌کننده مدلی را بر اساس پارامترهای تنظیم‌شده ایجاد می‌کند. این مدل نگهداری می‌شود و سپس داده‌های آزمون، بر اساس دو مرحلهٔ اول ایجاد می‌شوند. داده‌های آزمون ورودی با مدل آموزشی و تنظیمی است، سپس مدل مذکور کلاس یا نوع داده‌های آزمون را تعیین می‌کند. روش تحت نظارت معمولاً کارایی بهتری نسبت به روش بدون نظارت دارد. البته تعیین برچسب کلاس‌ها فرایندی هزینه‌بر است. در این پژوهش از روش تحتِ نظارت استفاده شد، به این ترتیب که ابتدا خوشه‌بندی دسته‌ها با روش خودکار مشخص شد و سپس برای تأیید خوشه‌ها از مقادیر خروجی دستگاه استفاده گردید. برای پیاده‌سازی الگوریتم‌های یادگیری ماشین از زبان برنامه‌نویسی پایتون استفاده شد.

۱. خوشه‌بندی

خوشه‌بندی یکی از شاخه‌های یادگیری بدون نظارت است و فرایند خودکاری است که در طی آن، نمونه‌ها به دسته‌هایی که اعضای آن مشابه یکدیگرند تقسیم می‌شوند که به این دسته‌ها خوشه گفته می‌شود. بنابراین خوشه مجموعه‌ای از نمونه‌ها است که در آن نمونه‌ها با یکدیگر مشابه بوده و با نمونه‌های موجود در خوشه‌های دیگر غیر مشابه‌اند. برای مشابه بودن می‌توان معیارهای مختلفی را برای خوشه‌بندی مورد استفاده قرار داد که یکی از آنها معیار فاصله است که در آن می‌توان نمونه‌هایی را که به یکدیگر نزدیک‌ترند به عنوان یک خوشه در نظر گرفت. به این نوع خوشه‌بندی، خوشه‌بندیِ مبتنی بر فاصله نیز گفته می‌شود (۲۵). هدف خوشه‌بندی، یافتن خوشه‌های مشابه در بین نمونه‌های ورودی است، اما انتخاب خوشه‌بندی مناسب پیچیده است. با این حال معیارهای مختلفی برای مناسب بودن خوشه‌بندی ارائه شده که می‌تواند کاربر را برای رسیدن به یک خوشه‌بندی مناسب راهنمایی کند. یکی از مسائل مهم در خوشه‌بندی انتخاب تعداد خوشه‌ها است. در روش خوشه‌بندی، K-means هر داده دقیقاً در یک خوشه قرار می‌گیرد. این روش با پارتیشن‌بندی الگوریتم با K نقطهٔ اولیهٔ تصادفی شروع می‌شود و پس از آن با استفاده از فرایندی تکراری برای این که کیفیت خوشه، به مراکز جدید بروزرسانی می‌شوند. الگوریتم K-means به تعداد خوشه‌های مورد نظر، اعداد تصادفی در نظر گرفته می‌شود. سپس متناسب با میزان شباهت، هر یک از نمونه‌ها به یک خوشه تعلق می‌گیرد. سپس برای بروزرسانی مراکز، میانگین داده‌های موجود در هر خوشه، در مرکز جدید خوشه قرار داده می‌شود. خوشه‌بندی برای ارزیابی سطح توجه فرد در خوشه مشخص می‌شود که در مدل جایگاه توجه فرد را بازگو می‌کند. پس از این مرحله، برچسب‌های به دست آمده در دسته‌بندی از روش‌های یادگیری ماشین مختلفی استفاده می‌شود.

۲. نزدیک‌ترین K همسایگی (K Nearest Neighbor (KNN))

یکی دیگر از دسته‌بندی‌کننده‌هایی که در این پژوهش از آن استفاده شده است، الگوریتمی غیر پارامتری است که نزدیک‌ترین K همسایه است. در مرحلهٔ آموزش همهٔ نمونه‌ها در فضای هندسی به صورت بردارهای چند

بعدی (هر بردار یکی از ویژگی‌های اندازه‌گیری‌شده) هستند. این فضا به برچسب‌های کلاس و موقعیت این نقاط تفکیک می‌شود. معمولاً فاصلهٔ اقلیدسی معیار مناسبی است (در این تحقیق نیز از همین معیار استفاده شده است) برای انجام محاسبات، کل نمونه‌ها را در حافظه نگهداری می‌شوند (۲۶). یکی از مزایای این روش یافتن محدودهٔ کلاس در زمان اجرا است. بنابراین نیاز است که کلیهٔ نقاط با اطلاعات آنها در حافظه ذخیره شود. حال اگر محدودیت حافظه وجود داشته باشد، این روش با حجم زیاد مشکل‌ساز می‌شود (۲۵). اما چون حجم نمونه‌ها کم است، روشی مناسب تلقی می‌شود.

۳. ماشین بردارهای پشتیبان (SVM)

روش ماشین بردارهای پشتیبان، داده‌ها را به فضای بالاتر انتقال می‌دهد و این گونه داده‌ها در کلاس‌های مختلف از یکدیگر مجزا و به دسته‌های مختلفی تقسیم می‌شوند. چون در این موضوع چندین ویژگی وجود دارد، صفحه‌ای جداساز در فضای چند بعدی، دادهٔ کلاس‌ها را از هم مجزا می‌کند. روش ماشین بردارهای پشتیبان، سعی می‌کند تا فاصلهٔ بین کلاس‌های مختلف را بیشینه کند و افزایش این فاصله به بهبود دقت دسته‌بندی‌کنندهٔ جداساز منجر می‌شود. البته اگر این فاصله به صورت خطی قابلِ‌جدا کردن نباشد، با استفاده از هستهٔ غیرخطی سعی در تفکیک دو کلاس می‌کند. در مرحلهٔ آموزش تنها نقاطی به عنوان مدل نگهداری می‌شوند که به ابر صفحه (در فضای چند بعدی اندازه‌ها) نزدیک‌اند، که به آنها بردارهای پشتیبان می‌گویند. قدرت تعمیم SVM تحت‌تأثیر پارامترهای هسته‌اند. البته ایجاد تابع جداساز با استفاده از SVM به نسبت بزرگی و حجم نمونه‌های مجموعهٔ داده، معمولاً برای آموزش مدل زمان‌بر است (۲۵). برای ایجاد صفحهٔ جداساز باید معادلهٔ بهینه‌سازی شماره ۱ که در آن x_i بردار ورودی و بردار کلاس‌هاست و در اینجا کلاس‌های مختلف را نشان می‌دهد حل شود. ضرایب α_i و α_j ضرایب لاگرانژ هستند.

$$\sum_{i=1}^{n}\alpha_i-\frac{1}{2}\sum_{i,j}\alpha_i\alpha_j\,c_ic_{ij}x_i^Tx_j$$
$$and\ \sum_{i}^{n}\alpha_ic_i=0 \qquad (۱)$$
$$w=\sum_{i}^{n}\alpha_ic_ix_i$$

این روش برای انتخاب ویژگی‌ها نیز استفاده می‌شود. دلیل ویژگی عمومی‌سازی SVM همان بیشینه‌سازی فاصلهٔ بین دو دسته است. به این ترتیب عکس مجذور فاصله از رابطهٔ زیر محاسبه می‌شود:

$$\|w\|^2=\sum_{i,j=1}^{n}\alpha_i\alpha_jc_ic_jx_i^Tx_j \qquad (۲)$$

اهمیت هر ویژگی در مجموعهٔ داده (هر k یک ویژگی است) یا w_k به دست می‌آید، بدین ترتیب که:

$$\|w\|^2=\sum_{i,j=1}^{n}\alpha_i\alpha_jc_ic_jx_i^Tx_j \qquad (۳)$$

اگر مقدار w_k نزدیک به صفر باشد، کارایی دسته‌بندی‌کننده بدون وجود این ویژگی تغییری نمی‌کند و این ویژگی تعیین‌کننده نیست (۲۵).

۴. آدابوست (Adaboost)

یادگیری جمعی (Boosting) روشی برای ترکیب چندین دسته‌بندی‌کننده پایه است که در واقع مجموعه‌ای از دسته‌بندی‌کننده‌ها را ایجاد می‌کند. به همین دلیل کارایی آن بهتر از هر کدام از دسته‌بندی‌کننده‌های سازنده‌اش است. معروف‌ترین الگوریتم یادگیری جمعی آدابوست (Adaptive boosting learning) است که از دیگر روش‌ها بیشتر مورد استفاده است (۲۷، ۲۸). یادگیری جمعی می‌تواند کارایی نسبتاً خوبی را ایجاد کند، حتی اگر دسته‌بندی‌کننده‌های سازندهٔ آن کمی بهتر از حالت تصادفی عمل کنند. این دسته‌بندی‌کننده‌های پایه، یادگیرندهٔ ضعیف (Weak learner) نیز نامیده می‌شوند (۲۹). در این پژوهش از درخت تصمیم‌گیری به عنوان دسته‌بندی‌کنندهٔ پایه استفاده شد. اصول معماری در طراحی یادگیری جمعیِ دسته‌بندی‌کننده‌ها ترتیبی‌اند. هر دسته‌بندی‌کننده از مجموعهٔ داده‌های وزن‌دار با ضریب وزنی ساخته می‌شود که وابسته به نتایج دسته‌بندی‌کنندهٔ قبلی است. وقتی که همهٔ دسته‌بندی‌کننده‌ها آموزش داده شوند، پیش‌بینی نمونه‌ها مبتنی بر مدل و رأی اکثریت وزنی است (۳۰).

یافته‌ها

همان‌طور که در جدول ۲ نمایش داده شده است، بعضی از ویژگی‌ها از طریق دستگاه و یا از طریق تکلیف شناختی استخراج شده‌اند.

تعداد نمونه‌ها تا زمانی که مدل مقاوم شود ادامه می‌یابد، به این معنی که مدل تحت نویز تغییر نکند و دقت و کارایی آن کاهش نیابد. برای استخراج بهینه‌ترین تعداد دسته‌ها از روش آرنج (Elbow) استفاده شد، این روش برای تعداد خوشه‌های مختلف از ۱ تا ۱۵ مجموع مربعات را محاسبه می‌کند. جایی که زانو قرار دارد مقدار بهینه است زیرا فاصله بین

خوشه‌ها مناسب است. همان طور که در شکل ۳ مشخص است، مقدار خوشه ۳ محل قرارگیری آرنج است. به همین منظور درتنظیمات الگوریتم K-means که پیشتر توضیح داده شد، تعداد خوشه‌ها را ۳ قرار داده‌ایم و برچسب دسته‌بندی‌ها را مشخص کردیم.

جدول ۱. مشخصات تکلیف ANT

شماره	نوع ویژگی	نام ویژگی	روش استخراج	توضیحات
۱	EEG	Stream Power Delta	دستگاه	جریان ۰/۵ – ۲/۷۵ هرتز
۲	EEG	Stream Power Theta	دستگاه	جریان ۳/۵ – ۶/۷۵ هرتز
۳	EEG	Stream Power Low Alpha	دستگاه	جریان ۷/۵ – ۹/۲۵ هرتز
۴	EEG	Stream Power High Alpha	دستگاه	جریان ۱۰ – ۱۱/۷۵ هرتز
۵	EEG	Stream Power Low Beta	دستگاه	جریان ۱۸ – ۲۹/۷۵ هرتز
۶	EEG	Stream Power High Beta	دستگاه	جریان ۱۸ – ۱۹ هرتز
۷	EEG	Stream Power low Gamma	دستگاه	جریان ۳۱ – ۳۹/۷۵ هرتز
۸	EEG	Stream Power Middle Gamma	دستگاه	جریان ۴۱ – ۴۹/۷۵ هرتز
۹	ANT	mean.all	تکلیف روان‌شناختی	Mean RT for all test block trials میانگین زمان پاسخ برای همهٔ بلاک‌های کوشش تکلیف
۱۰	ANT	pc.all	تکلیف روان‌شناختی	(۲) Percent correct over all test trials درصد صحیح بر همهٔ تکلیف کوشش‌ها

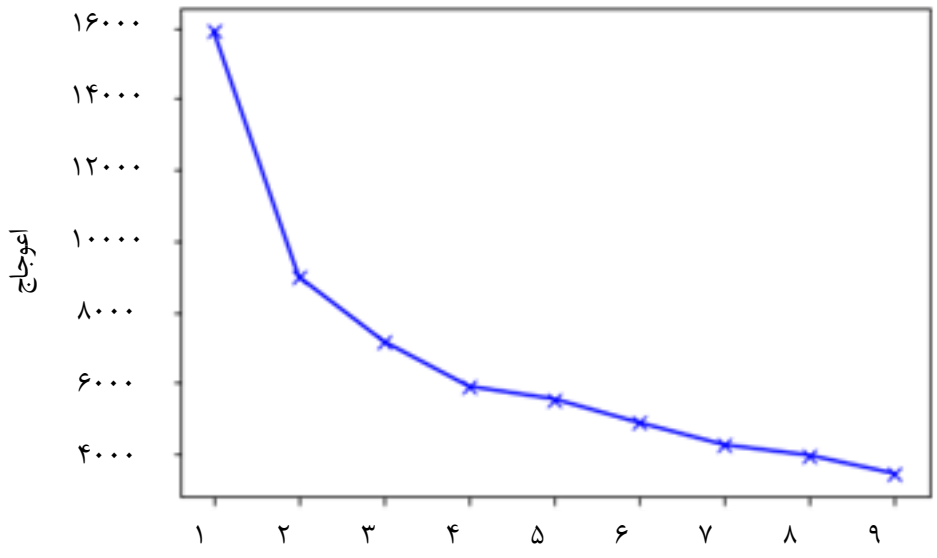

شکل ۳. نمودار آرنج

بحث

چون هدف از این پژوهش ایجاد مدلی جدید، با روش یادگیری ماشین برای توجه بود، از روش‌های یادگیری ماشین: KNN و SVM و Adaboost که در کارهای گذشته بیشتر استفاده شده‌اند، برای تحلیل اطلاعات جمع‌آوری‌شده استفاده شد. یکی از چالش‌های این تحقیق، تعداد نمونه‌ها برای مدل‌سازی بود و تعداد این نمونه‌ها کم بود. به همین منظور از روش اعتبارسنجی متقابل (Cross Validation) استفاده شد. یکی از محبوب‌ترین روش‌های نمونه‌گیری مجدد، رویهٔ اعتبارسنجی متقابل K دستهٔ K–Fold Cross Validation است که بسیار ساده و مؤثر و مطمئن است، روشی که مجموعهٔ داده‌ها را به K زیر مجموعهٔ مستقل تقسیم‌بندی می‌کند. یکی از این زیر مجموعه‌ها برای یادگیری دسته‌بندی‌کننده انتخاب می‌شود، در حالی که بقیه برای خطای تعمیم‌سازی استفاده می‌شوند (۲۶)؛ بنابراین پس از آموزش، K تعداد مدل مختلف ایجاد می‌شود. پارامترهای مؤثر در ارزیابی دسته‌بندی روش‌های ذکرشده در زیر آمده است:

(۴) نرخ صحیح= تعداد نمونه‌های دسته‌بندی‌شده/نمونه‌های دسته بندی‌شده

در این پژوهش سه مدل یادگیری ماشین مختلف انجام شده است. پارامترهای مختلفی که برای هر یک از دسته‌بندی‌کننده‌ها مؤثر بوده است. در ماشین بردارهای پشتیبان، تابع هستهٔ خطی نتایج بهتر از انواع غیرخطی را نشان داده است. در KNN پارامتر K از ۱ تا ۱۰ بررسی شد و بهترین نتیجه برای همسایگی ۳ به دست آمد. در روش یادگیری ماشین Adaboost، تعداد متفاوت درختان تا ۲۰۰ را محاسبه کرده و بهینه‌ترین تعداد درختان ۱۰۰ برای آن می‌شود.

نتایج روش‌های مختلف، در جدول ۳ نمایش داده شده است. معیار انتخاب دسته‌بندی‌کننده، دقت در ایجاد مدل و همین‌طور تخمین داده‌های آزمون است. از آنجا که تعداد K=3 برای نزدیک‌ترین همسایگی، بهترین دقت را هم در بازه مدل و داده‌های آزمون نشان داده است. این روش برای داده‌های با حجم کم مناسب است، زیرا محاسبات در زمان اجرا انجام می‌شود.

جدول ۳. ارزیابی مدل‌های روش‌های یادگیری ماشین

روش یادگیری ماشین	بازه نرخ صحیح مدل (درصد)	نرخ صحیح برای داده آزمون (درصد)	پارامترهای مختلف
SVM	۹۴ (-/+۰/۱۲)	۹۴	تابع خطی
KNN	۹۷ (-/+۰/۱۳)	۱۰۰	K=۳
Adaboost	۸۸ (-/+۰/۲۲)	۶۰	تعداد درختان ۱۰۰

استفاده از این دستگاه BCI برای تحقیق در زندگی روزمره انجام شود. این دستگاه‌ها چون ارزان‌ترند و قابلیت جابه‌جایی دارند، برای استفاده از مناطق باز مناسب‌اند و می‌توان تکلیف‌هایی را در حین رانندگی یا کارهای دیگری که به توجه زیاد نیاز دارند مورد استفاده قرار داد (۳۱). اما محدودیت این ابزار در دقت کمتر آن نسبت به دستگاه‌های پزشکی EEG است که تعداد کانال‌های بیشتری دارند.

یکی از اصلی‌ترین چالش‌های این پژوهش همان‌طور که پیش از آن گفته شد جمع‌آوری اطلاعات از افراد بیشتری است و بنابراین انتخاب الگوریتم Adaboost برای رفع این چالش است. تولید اپلیکیشن‌های موبایل برای افراد ناتوان حرکتی یکی دیگر از کاربردهای چنین مدل‌هایی است (۳۲). روش KNN نسبت به بقیهٔ روش‌ها از دقت بیشتری برخوردار است. این مدل یادگیری ماشین برای پیش‌بینی سطح هشدار توجه مخصوصاً برای یادگیری و تعامل با رایانه می‌تواند استفاده شود، همچنین یکی دیگر از کاربردهای این تحقیق برای رانندگانی است که در طی زمانی طولانی به طور منظم ترمز نمی‌کنند، خطر بالای خواب آلودگی دارند. در تحقیقات قبلی تاکید بر ایجاد مدل هوشمند، تحلیل تصاویر حالت چشم یادگیری ماشین حرکات خواب است (۳۱). یک روش دیگر، استفاده از مدل هوشمند امواج مغزی برای تشخیص عدم توجه است که در این مقاله ایجاد شده است. یکی دیگر از کاربردهای این پژوهش، هوشمندسازی ماشین‌ها و یا ربات‌ها می‌باشد.

نتیجه گیری

با توجه به داده‌های جمع‌آوری شده، مدل یادگیری ماشین KNN انتخاب شد. این روش برای نمونه‌های کم مناسب‌تر است. در صورتی که داده‌های آزمایش بیشتر شود، مدل‌های مقاوم‌تری ایجاد می‌شود که کارایی بیشتری نیز دارند. روش‌های یادگیری ماشین امکان دسته‌بندی نمونه‌ها را دارند و در مطالعات شناختی بسیار کارآمد هستند. در آینده از این مدل‌ها برای تعامل انسان و ماشین‌ها بسیار استفاده خواهد شد.

تشکر و قدردانی

پژوهش حاضر بر گرفته از بخشی از رساله دکتری نویسنده نخست پژوهش است؛ به این جهت، از همکاری همه افرادی که در این پژوهش شرکت کردند، همچنین از موسسه آموزش عالی علوم شناختی و گروه مدل‌سازی برای راهبری این پژوهش، کمال تقدیر و تشکر را داریم.

References

1. Ong G, Sewell DK, Weekes B, McKague M, Abutalebi J. A diffusion model approach to analysing the bilingual advantage for the Flanker task: The role of attentional control processes. *Journal of Neurolinguistics*. 2017;43(Part A):28-38.

2. Bourgeois A, Neveu R, Bayle DJ, Vuilleumier P. How does reward compete with goal-directed and stimulus-driven shifts of attention?. *Cognition and Emotion*. 2017;31(1):109-118.

3. Quinn K. An in depth study of how the psychological behaviors affect construction safety [MSc Thesis]. West Lafayette, Indiana:Purdue University;2010.

4. Khasraghi BJ, Setayeshi S. Applying fuzzy mathematical model of emotional learning for eeg signal classification between schizophrenics and control participant. *International Journal of Neural Systems*. 2017;4(1):49-54.

5. Posner MI, Petersen SE. The attention system of the human brain. *Annual Review of Neuroscience*. 1990;13(1):25-42.

6. Tychkov AY, Alimuradov AK, Ageykin AV, Tychkova AN. Multi-neural interface of borderline mental disorders express-evaluation. *International Journal of Applied Engineering Research*. 2017;12(16):6224-6229.

7. Yildirim N, Varol A. Developing educational game software which measures attention and meditation with brainwaves: Matching mind math. In ICEE/ICIT Conference. 2013 Dec 8-12; Cape Town, South Africa;2013.

8. Rebolledo-Mendez G, Dunwell I, Martínez-Miron EA, Vargas-Cerdán MD, De Freitas S, Liarokapis F, et al. Assessing neurosky's usability to detect attention levels in an assessment exercise. In International Conference on Human-Computer Interaction; 2009 Jul 19; Springer, Berlin, Heidelberg. pp. 149-158.

9. Jafri SR, Hamid T, Mahmood R, Alam MA, Rafi T, Haque MZ, et al. Wireless brain computer interface for smart home and medical system. *Wireless Personal Communications*. 2019;106(4):2163-2177.

10. Li M, Liang Z, He B, Zhao CG, Yao W, Xu G, et al. Attention-controlled assistive wrist rehabilitation using a low-cost EEG Sensor. *IEEE Sensors Journal*. 2019;19(15):6497-6507.

11. Folgieri R, Lucchiari C, Marini D. Analysis of brain activity and response to colour stimuli during learning tasks: an EEG study. In Color Imaging XVIII: Displaying, Processing, Hardcopy, and Applications. 2013 Feb 4-6; Burlingame, Ca, United States; Washington:International Society for Optics and Photonics;2013. Vol. 8652, p. 86520I.

12. Jones A, Schwartz G. Using brain-computer interfaces to analyze EEG data for safety improvement. Berkeley, CA:Team for Research in Ubiquitous Secure Technology;2010.

13. Rebolledo-Mendez G, De Freitas S. Attention modeling using inputs from a Brain Computer Interface and user-generated data in second life. In ACM Tenth International Conference on Multimodal Interfaces (ICMI). 2008 Oct 20-22; Chania, Crete, Greece;2008.

14. Tiwari K, Saini S. Brain controlled robot using neurosky mindwave. *Journal of Technology Advances Scientific Research*. 2015;1(4):328-331.

15. Bose J, Singhai A, Patankar AA, Kumar A. Attention sensitive web browsing. In Proceedings of the 9th annual ACM India conference. 2016 October 21-23; Gandhinagar, India. pp. 147-152.

16. Peters C, Asteriadis S, Rebolledo-Mendez G. Modelling user attention for human-agent interaction. In 10th Workshop on Image Analysis for Multimedia Interactive Services. 2009 May 6-8; London, United Kingdom; New Jersey:IEEE;2009.

pp. 266-269.

15. Bose J, Singhai A, Patankar AA, Kumar A. Attention sensitive web browsing. In Proceedings of the 9th annual ACM India conference. 2016 Oct 21-23; Gandhinagar, India. pp. 147-152.

16. Peters C, Asteriadis S, Rebolledo-Mendez G. Modelling user attention for human-agent interaction. In 10th Workshop on Image Analysis for Multimedia Interactive Services. 2009 May 6-8; London, United Kingdom; New Jersey:IEEE;2009. pp. 266-269.

17. Hondrou C, Caridakis G. Affective, natural interaction using EEG: Sensors, application and future directions. In Hellenic Conference on Artificial Intelligence; 2012 May 28; Berlin, Heidelberg, Germany; Springer;2012.

18. Ghanbari AA, Heidari E, Setayeshi S. Brain emotional learning based Brain Computer Interface. *International Journal of Computer Science Issues* (IJCSI). 2012;9(5):146-154.

19. Lovibond PF, Lovibond SH. The structure of negative emotional states: Comparison of the Depression Anxiety Stress Scales (DASS) with the Beck Depression and Anxiety Inventories. *Behaviour Research and Therapy*. 1995;33(3):335-343.

20. Dye MW, Green CS, Bavelier D. The development of attention skills in action video game players. *Neuropsychologia*. 2009;47(8-9):1780-1789.

21. Tang YY, Posner MI. Attention training and attention state training. *Trends in Cognitive Sciences*. 2009;13(5):222-227.

22. Liarokapis F, Vourvopoulos A, Ene A, Petridis P. Assessing brain-computer interfaces for controlling serious games. In 2013 5th International Conference on Games and Virtual Worlds for Serious Applications (VS-GAMES). 2013 Sep 11-13; Poole, United Kingdom;2013. pp. 1-4.

23. Xu Y, Chang KM, Yuan Y, Mostow J. EEG Helps Knowledge Tracing!. In Intelligent Tutoring Systems (ITS 2014 WSEEG). 2014 Jun 5-9; Hawaii, United States;2014. p. 43.

24. Webb GI, Pazzani MJ, Billsus D. Machine learning for user modeling. *User Modeling and User-Adapted Interaction*. 2001;11(1-2):19-29.

25. Alpaydin E. Introduction to machine learning. Cambridge:MIT Press;2014;22

26. Burkov A. The Hundred-Page Machine Learning Book. Quebec City, Can:Andriy Burkov;2019.

27. Haque MN, Moscato P. From ensemble learning to meta-analytics: A review on trends in business applications. In: Moscato P, De Vries N, editors. Business and consumer analytics: New ideas. Cham, Switzerland:Springer;2019. pp. 703-731.

28. Taşcı E. A meta-ensemble classifier approach: Random rotation forest. *Balkan Journal of Electrical and Computer Engineering*. 2019;7(2):182-187.

29. Panesar A. Machine learning and ai for healthcare. New York:Apress;2019.

30. Geron, A. Hands-On machine learning with scikit-learn, keras, and tensorflow: concepts, tools, and techniques to build intelligent systems. 2nd ed. Sebastopol, CA:O'Reilly Media;2019.

31. Saini V, Saini R. Driver drowsiness detection system and techniques: A review. *International Journal of Computer Science and Information Technologies*. 2014;5(3):4245-4249.

32. Serna B, Baltazar R, Casillas M, Saavedra Y, Alanis A, Meza A. Medical diagnostic through a mobile application controlled by brain waves: Consult app. In: Jezic G, Chen-Burger YH, Kusek M, Šperka R, Howlett R, Jain L, editors. Agents and multi-agent systems: Technologies and applications 2019. Singapore:Springer;2020. pp. 185-193.