

تشخیص احساس از روی سیگنال‌های EEG به کمک الگوریتم یادگیری ماشین کوانتومی سلسله مراتبی

سیدعابد حسینی^۱، استادیار، محبوبه هوشمند^۲، استادیار

۱- گروه مهندسی برق، واحد مشهد، دانشگاه آزاد اسلامی، مشهد، ایران - hosseyni@mshdiau.ac.ir

۲- گروه مهندسی کامپیوتر، واحد مشهد، دانشگاه آزاد اسلامی، مشهد، ایران - ma.houshmand@iau.ac.ir

چکیده: در سال‌های اخیر استفاده از الگوریتم‌های یادگیری ماشین کوانتومی (QML) برای تشخیص حالت‌های مختلف مغزی از طریق سیگنال‌های EEG مورد توجه قرار گرفته است. تشخیص احساس با استفاده از سیگنال‌های EEG نقش کلیدی در تعامل انسان و رایانه و محاسبات احساسی ایفا می‌کند. این پژوهش از مجموعه داده DEAP متشکل از ۳۲ کانال سیگنال EEG اخذ شده از ۳۲ شرکت کننده در هنگام تماشای ۴۰ فیلم یک دقیقه‌ای استفاده می‌کند. مدل پیشنهادی مبتنی بر QML سلسله مراتبی شامل بخش‌های پیش پردازش سیگنال EEG به کمک لاپلاسین سطحی، آماده سازی سیگنال EEG به عنوان یک حالت کوانتومی، استخراج ویژگی به کمک تبدیل بسته موجک کوانتومی (QWPT) و آنتروپی انرژی بسته موجک (WPPE) و طبقه بند شبکه عصبی کوانتومی (QNN) سه لایه است. نتایج نشان می‌دهد مدل پیشنهادی می‌تواند دو دسته از احساس ظرفیت و برانگیختگی را به ترتیب با درصد صحت ۹۴/۷۱ و ۹۷/۶۲ تفکیک نماید. نتایج نشان از موفقیت قابل توجه مدل پیشنهادی در تشخیص احساسات مختلف دارد.

واژه‌های کلیدی: تشخیص احساس، استخراج ویژگی، سیگنال‌های مغزی، طبقه بندی و یادگیری ماشین کوانتومی.

Recognition of Emotion from EEG Signals Using Hierarchical Quantum Machine Learning Algorithm

Seyyed Abed Hosseini, Assistant Professor¹, Mahboobeh Houshmand, Assistant Professor²

1- Department of Electrical Engineering, Mashhad Branch, Islamic Azad University, Mashhad, Iran, Email: hosseyni@mshdiau.ac.ir

2- Department of Computer Engineering, Mashhad Branch, Islamic Azad University, Mashhad, Iran, Email: ma.houshmand@iau.ac.ir

Abstract: In recent years, quantum machine learning (QML) algorithms have been considered to detect different brain states through EEG signals. Emotion recognition using EEG signals plays a key role in human-computer interaction and emotional computing. This study uses the DEAP (A Database for Emotion Analysis Using Physiological Signals) dataset consisting of 32 channels of EEG signals obtained from 32 participants while watching 40 one-minute music videos. The proposed model based on hierarchical QML includes phases of EEG signal pre-processing using surface Laplacian, preparation of EEG signal as a quantum state, feature extraction using quantum wavelet packet transform (QWPT) and wavelet packet energy entropy (WPPE) and three layers quantum neural network (QNN) classifier. The results show that the proposed model can distinguish two categories of emotional states of valence and arousal states with 94.71 and 97.62 accuracy percentages, respectively. The results show the significant success of the proposed model in detecting different emotional states.

Keywords: Emotion Recognition, Feature Extraction, Brain Signals, Classification, and Quantum Machine Learning.

تاریخ ارسال مقاله: ۱۴۰۱/۱۲/۲۹

تاریخ اصلاح مقاله: ۱۴۰۲/۰۳/۱۲

تاریخ پذیرش مقاله: ۱۴۰۲/۰۴/۲۱

نام نویسنده مسئول: سیدعابد حسینی

نشانی نویسنده مسئول: ایران - مشهد - واحد مشهد، دانشگاه آزاد اسلامی - دانشکده مهندسی - گروه مهندسی برق.



۱- مقدمه

شناخت احساسات انسانی یکی از زمینه‌های مهم محاسبات عاطفی است. احساس پدیده‌ای بسیار پیچیده و از فردی به فرد دیگر متفاوت است. ماهیت پیچیده احساسات، فرآیند شناخت را چالش برانگیز می‌کند [1]. حالت‌های مختلف احساسی را می‌توان از طریق واکنش‌های بیرونی و درونی استنباط کرد. پژوهش‌های تشخیص احساسات عمدتاً با بهره‌گیری از سیگنال‌های غیر فیزیولوژیکی مانند بیان چهره، گفتار و حرکت بدن و همچنین سیگنال‌ها و تصاویر فیزیولوژیکی مانند مقاومت الکتریکی پوست (GSR)، نرخ ضربان قلب، الکتروکاردیوگرام، تصویربرداری تشدید مغناطیسی عملکردی، الکتروانسفالوگرام (EEG) و مگنتوانسفالوگرام انجام می‌شود [2]–[4]. تشخیص احساسات مختلف از روی تصاویر چهره، گاهی اوقات نتایج مطلوب در پی ندارد [5].

تاکنون پژوهش‌های متعددی در زمینه تشخیص احساسات از روی سیگنال‌های EEG انجام شده است [17]–[4]. استفاده از یادگیری ماشین کوانتومی (QML) با ظهور پردازنده‌های کوانتومی در حال افزایش است [18]. یکی از یافته‌های اخیر که جهت جدیدی به این پژوهش‌ها ارائه کرده این است که مغز به شیوه‌ای شبیه رایانه‌های کوانتومی عمل می‌کند [19]. شبکه‌های عصبی کوانتومی (QNN) به‌عنوان گونه‌ای از شبکه‌های عصبی پیش‌خور (FFNN) طراحی شدند [20]. در ادامه به‌مرور پژوهش‌های گذشته که از کوانتوم در پردازش سیگنال EEG استفاده کرده‌اند، پرداخته می‌شود.

کارایانیس و همکارانش در سال ۲۰۰۶ [21] به ارزیابی QNN‌ها در تشخیص تشنج‌های صرعی در EEG نوزادان پرداختند. آن‌ها نشان دادند که نتایج پاسخ QNN‌ها در مقایسه با پاسخ‌های FFNN، شاخص‌های قابل‌اعتمادتری از عدم قطعیت در داده‌های ورودی ارائه می‌دهند. تاها و همکارانش در سال ۲۰۱۴ [22] به طبقه‌بندی سیگنال‌های EEG بر اساس مدل تابع انتقال چند سطحی شبکه عصبی موجک کوانتومی (QWNN) پرداختند. پس از بهنجارسازی سیگنال‌ها از تحلیل مؤلفه‌های مستقل (ICA) به‌عنوان روش پردازشی استفاده کرده و برخی از ویژگی‌ها را به کمک روش خوشه‌بندی از داده‌ها استخراج کردند. آن‌ها نتایج طبقه‌بندی را با شبکه عصبی موجک (WNN)، QNN و FFNN مقایسه کردند. نتایج آن‌ها نشان داد که طبقه‌بند QWNN به میانگین صحت ۹۴/۱۸ درصد و طبقه‌بند WNN، QNN و FFNN به ترتیب به درصد صحت ۸۹/۸۰، ۸۳/۷۱ و ۷۵/۰۷ رسیده‌اند. نتایج آن‌ها نشان دهنده برتری روش QWNN نسبت به سایر روش‌های مورد استفاده دارد.

عبدل زهرا راهیم و همکارانش در سال ۲۰۱۶ [23] مدل اسپلاین مکعبی QNN را به‌منظور تحلیل و طبقه‌بندی سیگنال‌های EEG در هفت کانال ارائه دادند. در پژوهش آن‌ها سه مرحله بهنجارسازی سیگنال‌ها، استخراج ویژگی به کمک روش اسپلاین مکعبی و طبقه‌بند QNN انجام شده است. نتایج شبیه‌سازی آن‌ها نشان می‌دهد که پنج نوع سیگنال EEG برای هفت الکتروود به صحت متوسط ۹۴/۳ درصد با


استفاده از ۷۰ درصد از ویژگی‌ها برای آموزش و ۹۲/۸۴ درصد با استفاده از ۵۰ درصد از ویژگی‌ها برای آموزش حاصل شده است. تاها و همکارانش در سال ۲۰۱۸ [24] یک رویکرد ترکیبی را به کمک مدل خود همبسته (AR) و شبکه عصبی بازگشتی کوانتومی (QQRNN) برای طبقه‌بندی دو دسته از سیگنال‌های EEG ارائه دادند. آن‌ها نشان دادند که این ترکیب قادر است عدم قطعیت ذاتی در سیگنال‌های EEG را کمی کند، زیرا از مرزهای تصمیم‌فازی برای تقسیم فضای ویژگی استفاده می‌کند. آن‌ها از دو روش استخراج ویژگی مجزا شامل ضرایب AR با الگوریتم لوینسون-دوربین و میانگین مربعات خطا استفاده کردند. میانگین صحت مدل آن‌ها ۸۸/۲۸ درصد در شش ثانیه است. آن‌ها عملکرد QQRNN با الگوریتم انتشار برگشتی را با QNN و QWNN مقایسه کردند. نتایج آن‌ها نشان می‌دهد که روش آن‌ها بالاترین صحت و زمان پردازش کمتر را ارائه داده است.

سنونگ یوک و همکارانش در سال ۲۰۲۰ [25] پژوهشی برای آموزش شبکه‌های عصبی کانولوشنال کوانتومی (QCNN) ارائه دادند. شبکه عصبی کانولوشنال (CNN) یکی از مدل‌های محبوب در بینایی ماشین است و این مزیت را دارد که از اطلاعات همبستگی داده‌ها به‌خوبی استفاده می‌کند. با این حال CNN برای داشتن یک یادگیری کارآمد، در زمانی که ابعاد داده یا مدل بیش از حد بزرگ باشد با چالش روبه‌رو است. QCNN یک راه‌کار برای حل یکی از مشکلات CNN با استفاده از یک محیط محاسباتی کوانتومی به‌منظور بهبود عملکرد مدل یادگیری ارائه می‌دهد.

آشوراوی و همکارانش در سال ۲۰۲۰ [26] برخی از روش‌ها مانند طبقه‌بند کوانتومی متغیر (VQC)، طبقه‌بند بازپخت کوانتومی [27] و شبکه‌های عصبی ترکیبی کوانتومی سنتی را پیاده‌سازی و مقایسه کردند تا با استفاده از سیگنال‌های EEG از قدرت محاسبات کوانتومی برای پردازش حالات شناختی ذهن استفاده کنند. آن‌ها نشان دادند طبقه‌بند بازپخت کوانتومی به صحت ۶۱/۵۳ درصد به کمک کانال پنجم سیگنال EEG دست‌یافته و بهترین نتایج را حاصل کرده است.



چاکرابورتی و همکارانش در سال ۲۰۲۰ [18] به بررسی تحلیلی مدل‌های QNN پرداختند. آن‌ها بیان کردند تاکنون رویکردهای مختلفی برای پیاده‌سازی QNN مورد مطالعه قرار گرفته است. بیشتر کارهای انجام‌شده در این زمینه شامل ترجمه اجزای شبکه عصبی سنتی به زبان فیزیک کوانتومی بوده؛ اما ترجمه مستقیم نمی‌تواند راه‌حل مناسبی باشد، زیرا هر جزء سنتی معادل کوانتومی ندارد به عنوان نمونه توابع فعال‌سازی غیرخطی نمونه‌های خوبی از آن هستند. عملگرهای کوانتومی باید خطی باشند و بنابراین یافتن راه‌حل‌های جایگزین برای توابع فعال‌سازی یک حوزه فعال پژوهشی است. با این وجود مزایای آن نسبت به مدل‌های سنتی زیاد است. برهم‌نهی کوانتومی ظرفیت ذخیره‌سازی نمایی را به یک شبکه کوانتومی می‌دهد. موازی‌سازی کوانتومی می‌تواند مورد استفاده قرار گیرد و شبکه را با

و دوست داشتن و از ۱ تا ۵ امتیاز برای آشنایی (۱ به معنای هرگز نشنیده‌ام و ۵ به معنای به‌طور منظم شنیده‌ام) امتیاز بدهند؛ بنابراین مجموع امتیازات ویدیویی جمع‌آوری شده ۱۲۸۰ بوده که با ضرب تعداد ۴۰ کلیپ صوتی و ویدیویی در تعداد ۳۲ شرکت‌کنندگان به دست می‌آید. رتبه‌بندی آشنایی برای شرکت‌کنندگان ۲، ۱۵ و ۲۳ در پلی‌گاه داده وجود ندارد.




شکل ۳: خود اظهاری شرکت‌کنندگان از بالای شکل به ترتیب برای ظرفیت، برانگیختگی، غلبه و دوست داشتن [17].


سیگنال‌های خام و پیش‌پردازش شده همه شرکت‌کنندگان و همچنین فیلم‌های چهره ۲۲ نفر از آن‌ها در این پایگاه داده موجود است. نمونه‌ای از فیلم‌های احساسی منتخب در صفحه دو بُعدی ظرفیت-برانگیختگی در شکل ۴ آورده شده است.



سیگنال‌های محیطی شامل دو کانال سیگنال EMG نصب‌شده بر روی ماهیچه گونه‌ای بزرگ (zEMG) و ذوزنقه‌ای (tEMG)، دو کانال افقی و عمودی سیگنال الکترواکولوگرام (16 EOG)، یک کانال سیگنال GSR نصب‌شده بر روی دو انگشت دست، یک کانال سیگنال دمای پوست نصب‌شده بر روی انگشت دست، یک کانال سیگنال تغییرات میزان دامنه تنفس نصب‌شده بر روی قفسه سینه و یک کانال سیگنال پلتیسموگراف نصب‌شده بر روی انگشت دست برای سنجش تغییرات فشارخون مطابق شکل ۲ با دستگاه بایوسمی اکتیو ثبت کرده‌اند. سیگنال‌ها با نرخ ۵۱۲ هرتز نمونه‌برداری شده و سپس نرخ نمونه‌برداری به ۲۵۶ هرتز کاهش داده شده است. برای ۲۲ شرکت‌کننده، فیلم چهره از جلو نیز ضبط شده است. به دلیل وجود دو محل مختلف برای ثبت و تجهیزات متفاوت سخت‌افزاری، تفاوت‌های جزئی در قالب داده وجود دارد که این تفاوت‌ها شامل ترتیب کانال‌های EEG و اندازه‌گیری GSR بوده است. اندازه‌گیری GSR در تونته برحسب نانو ژیمنس و در ژنو برحسب اهم است.



(الف)



(ب)

شکل ۴: (الف) محل نصب الکترودهای ثبت سیگنال‌های EEG و محیطی [17] و (ب) نام و موقعیت کانال‌های مختلف ثبت سیگنال‌های EEG

پس از اتمام هر ویدئو از هر شرکت‌کننده خواسته‌شده، مطابق پنج شاخص ظرفیت، برانگیختگی، غلبه، دوست داشتن (چقدر ویدئو را دوست دارید؟) و آشنایی (چقدر ویدئو را می‌شناسید؟) خود اظهاری را مطابق شکل ۳ انجام دهند. شرکت‌کنندگان می‌توانند روی شکل‌ها یا بین آن‌ها کلیک نمایند؛ بنابراین از ۱ تا ۹ امتیاز برای ظرفیت، برانگیختگی، غلبه

نویز غیر سیگنال EEG به‌طور قابل‌توجهی با سیگنال‌های EEG در هر دو ویژگی توپوگرافی و فرکانس متفاوت است. ریت‌های مو و بتا EEG اجزایی با فرکانس‌هایی هستند که بین ۸ تا ۳۰ هرتز توزیع شده و بر روی قشر حسی حرکتی قرار دارند. سیگنال‌های EOG حداکثر در فرکانس‌های پایین کمتر از ۵ هرتز هستند و به‌طور برجسته در مناطق قدامی سر قرار دارند. از این‌رو یک روش پالایه مناسب می‌تواند نسبت سیگنال به نویز را با افزایش سیگنال‌های EEG و کاهش نویز غیر سیگنال EEG به‌طور هم‌زمان افزایش دهد. پالایه لاپلاسین سطحی یک روش ساده اما مؤثر است. مشتق دوم توزیع ولتاژ فضایی را برای یک الکتروود انتخاب‌شده، محاسبه می‌کند. این یک پالایه فضایی بالا گذر است که فعالیت‌های محلی را افزایش می‌دهد و نویز پس‌زمینه را کاهش می‌دهد. این پالایه با تفریق پتانسیل متوسط مجموعه‌ای از الکترودهای اطراف الکتروود موردنظر مطابق رابطه (۱) به دست می‌آید.

$$V_i^{Lap} = V_i - \frac{1}{N} \sum_{j \in S_i} V_j, \quad (1)$$

که در آن V_i پتانسیل بین الکتروود i امین و مرجع Al را نشان می‌دهد و S_i و N به ترتیب مجموعه الکترودهای اطراف i امین الکتروود و تعداد الکترودهای اطراف را نشان می‌دهند. فاصله بین الکتروود انتخاب‌شده و الکترودهای اطراف آن مشخصه پالایه لاپلاسین سطحی را نشان می‌دهد که هر چه فاصله بیشتر باشد، عدم حساسیت به پتانسیل‌های بسیار موضعی بیشتر است. به‌عنوان نمونه برای یکی از الکترودهای سیگنال EEG با توجه به الکترودهای اطراف آن، پالایه لاپلاسین سطحی به شرح رابطه (۲) است.

$$V_{C_3}^{Lap} = V_{C_3} - \frac{1}{4} \{V_{FC_5} + V_{CP_5} + V_{CP_1} + V_{FC_1}\}. \quad (2)$$

۲-۳- مفاهیم پایه محاسبات کوانتومی

در این بخش به معرفی برخی مفاهیم پایه محاسبات کوانتومی پرداخته می‌شود و برای جزئیات بیشتر به [32], [33] مراجعه شود. محاسبات کوانتومی یک فناوری مبتنی بر پدیده‌های مکانیک کوانتومی مانند برهم‌نهی و درهم‌تنیدگی است. اطلاعات در محاسبات کوانتومی در بیت‌های کوانتومی (کیوبیت) ذخیره می‌شوند که مشابه بیت در رایانه دیجیتال سنتی است. مبنای اطلاعات کوانتومی و محاسبات آن برگرفته از ریاضیات برداری است و به‌نوعی با منطق دودویی همخوانی دارد. به‌عنوان نمونه، بردارهای دو عضوی در محاسبات کوانتومی به‌صورت (۳) تعریف می‌شوند.

$$ket: |\psi\rangle = \begin{bmatrix} a \\ b \end{bmatrix}, \quad bra: |\psi\rangle^\dagger = \langle\psi| = [a^* \quad b^*], \quad (3)$$

که * بیانگر مزدوج مختلط و $\dagger$ بیانگر مزدوج مختلط و ترانپوز است. نمادگذاری دیراک یکی از نمادهای استاندارد برای نمایش حالت‌های کوانتومی است. در حالت کلی یک واحد اطلاعات کوانتومی را می‌توان به‌صورت ریاضی در قالب یک کیوبیت کوانتومی مطابق (۴) نشان داد.

شکل ۴: الف) نمایشی از مدل دو بُعدی ظرفیت-انگیختگی (برگرفته‌شده از [31])، ب) توزیع کلیپ‌های صوتی ویدئویی مورد استفاده در پایگاه داده DEAP به رنگ سبز [17].

مدل ظرفیت-انگیختگی احساسات یک کمک دی‌داری است که احساسات را بر اساس سطح برانگیختگی آن‌ها (چقدر احساس آرامش یا تحریک می‌کنید) و ظرفیت (اعم از مثبت یا منفی) آن‌ها را سازمان‌دهی می‌کند. مدل ظرفیت-انگیختگی همچنین می‌تواند کمک نماید الگوهای تجربیات احساسی خود را بشناسید و محرک‌هایی را که منجر به پاسخ‌های احساسی خاصی می‌شوند، شناسایی شوند. در مدل دو بُعدی ظرفیت-انگیختگی به‌طور کلی می‌توان به چهار گروه ظرفیت بالا برانگیختگی بالا، ظرفیت بالا برانگیختگی پائین، ظرفیت پائین برانگیختگی بالا و ظرفیت پائین و برانگیختگی پائین تقسیم‌بندی کرد.

ظرفیت میزان منفی یا مثبت بودن یک احساس را توصیف می‌کند و معمولاً به دو دسته تقسیم می‌شود: احساس با ظرفیت کم (منفی) نظیر ترس، تنش، خشم، غم، کسالت و احساس با ظرفیت زیاد (مثبت) نظیر شادی، آرام، خوشحال، هیجان‌زده. در این پژوهش ظرفیت بین ۱ تا ۵ به‌عنوان کم و بین ۵ تا ۹ به‌عنوان زیاد در نظر گرفته می‌شود. برانگیختگی به قدرت یک حالت احساسی اشاره دارد و نشان‌دهنده میزان اشتیاق یا بی‌علاقگی است و معمولاً به دو دسته تقسیم می‌شود: احساس با برانگیختگی کم (منفی) نظیر آرام، خسته، بی‌حوصله، افسرده و احساس با برانگیختگی زیاد (مثبت) نظیر عصبانی، هیجان‌زده، پرتنش، ناامید، خوشحال. مشابهاً در این پژوهش برانگیختگی بین ۱ تا ۵ به‌عنوان کم و بین ۵ تا ۹ به‌عنوان زیاد در نظر گرفته می‌شود. تسلیم (بدون کنترل) در برابر تسلط سطوح مختلف غلبه هستند. مقیاس غلبه-تسلیم می‌زان کنترل و غلبه و همچنین کنترل و تسلیم بودن را ارزیابی می‌کند. به‌عنوان نمونه ترس و خشم هر دو احساس‌های منفی هستند، درحالی‌که خشم احساس غالب و ترس احساس مغلوب است. پژوهش‌های گذشته روی این داده دسته‌بندی‌های مختلفی را برای طبقه‌بندی در نظر گرفته‌اند. در پژوهش‌های گذشته بیشتر تشخیص دو دسته ظرفیت و برانگیختگی، تشخیص سه دسته احساسات مثبت، خنثی و منفی یا تشخیص چهار دسته شامل برانگیختگی زیاد-ظرفیت کم، برانگیختگی زیاد-ظرفیت زیاد، برانگیختگی کم-ظرفیت کم و برانگیختگی کم-ظرفیت زیاد در نظر گرفته شده است. در این مقاله هدف تشخیص دو دسته ظرفیت و برانگیختگی است.

۲-۲- پیش‌پردازش سیگنال EEG

یک پالایه میان‌گذر در باند فرکانسی ۴ تا ۴۵ هرتز روی سیگنال‌های EEG اعمال شده است و همچنین آرتیفکت‌های ناشی از سیگنال EOG نیز حذف شده است [17].

• لاپلاسین سطحی

گفته می‌شود. دروازه $SWAP$ حالت‌های دو کیوبیت را با یکدیگر تعویض می‌کند و نمایش ماتریسی آن در (۱۰) آمده است.

$$SWAP = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix}. \quad (10)$$

دروازه چرخش (R) و سه دروازه چرخشی پائولی $R_x(\theta)$ ، $R_y(\theta)$ و $R_z(\theta)$ مطابق ماتریس‌های (۱۱) تعریف می‌شوند.

$$R = \begin{bmatrix} \cos \theta & -\sin \theta \\ \sin \theta & \cos \theta \end{bmatrix},$$

$$R_x(\theta) = e^{-i\theta X/2} = \cos \frac{\theta}{2} I - i \sin \frac{\theta}{2} X = \begin{bmatrix} \cos \frac{\theta}{2} & -i \sin \frac{\theta}{2} \\ -i \sin \frac{\theta}{2} & \cos \frac{\theta}{2} \end{bmatrix},$$

$$R_y(\theta) = e^{-i\theta Y/2} = \cos \frac{\theta}{2} I - i \sin \frac{\theta}{2} Y = \begin{bmatrix} \cos \frac{\theta}{2} & -\sin \frac{\theta}{2} \\ \sin \frac{\theta}{2} & \cos \frac{\theta}{2} \end{bmatrix}, \quad (11)$$

$$R_z(\theta) = e^{-i\theta Z/2} = \cos \frac{\theta}{2} I - i \sin \frac{\theta}{2} Z = \begin{bmatrix} e^{-i\frac{\theta}{2}} & 0 \\ 0 & e^{i\frac{\theta}{2}} \end{bmatrix}.$$

۴-۲- استخراج ویژگی

هدف این بخش شناسایی بردارهای ویژگی ورودی مناسب شبکه است که بین حالت‌های مختلف احساسی تمایز قائل شود.

• آماده‌سازی حالت کوانتومی سیگنال EEG

قبل از ساخت یک چارچوب پردازشی، اولویت کدگذاری سیگنال معمولی ورودی با استفاده از عبارت کوانتومی است. برای جزئیات بیشتر روش آماده‌سازی حالت کوانتومی سیگنال EEG به [28] مراجعه شود.

• استخراج ویژگی با آنتروپی انرژی بسته موجک

در این بخش روش استخراج ویژگی WPEE از سیگنال EEG بر اساس QWPT ارائه شده است. تبدیل بسته موجک سنتی نقش اساسی در زمینه پردازش اطلاعات ایفا می‌کند. با این حال، پیچیدگی بالا توسعه آن را در داده‌های با ابعاد بالا و حجم داده‌های بزرگ محدود می‌کند. از طرف دیگر، برتری محاسبات کوانتومی به دلیل برهم‌نهی و درهم‌تنیدگی، می‌تواند راه‌حلی باشد. یک مطالعه جامع در مورد QWPT در [34] ارائه شده است که QWPT‌های چند سطحی و چند بُعدی را با توابع موجک Haar و DQWPT پیشنهاد می‌کند که به ترتیب به HQWPT و DQWPT نامیده می‌شوند. این مقاله با آنتروپی اطلاعاتی کوانتومی [35] برای استخراج ویژگی WPEE در سیگنال EEG توسعه و ترکیب یافته است.

۵-۲- بهنجار سازی ویژگی‌ها

بهنجار سازی، فرآیند حذف تفاوت در دامنه است. سیگنال‌های EEG در محدوده [0,1] با استفاده از روش مقیاس‌بندی حداقل-حداکثر مطابق رابطه (۱۲) بهنجار می‌شوند.

$$|\psi\rangle = a|0\rangle + b|1\rangle = a \begin{bmatrix} 1 \\ 0 \end{bmatrix} + b \begin{bmatrix} 0 \\ 1 \end{bmatrix} = \begin{bmatrix} a \\ b \end{bmatrix}. \quad (4)$$

که a و b اعداد مختلط هستند و دامنه‌های احتمال حالت‌های مربوطه را مشخص می‌کنند، یعنی $|a|^2$ و $|b|^2$ احتمالاتی هستند که کیوبیت به ترتیب در حالت $|0\rangle$ و $|1\rangle$ یافت می‌شود. به دلیل برقراری یک سری قوانین فیزیکی، شرط رابطه (۵) برای ضرایب این کیوبیت برقرار است.

$$|a|^2 + |b|^2 = 1. \quad (5)$$

آنگاه دو بردار (۶) به‌عنوان کت صفر و کت یک پایه‌های کیوبیت در فضای هیلبرت دو بُعدی هستند و تمامی اطلاعات کوانتومی تک کیوبیتی با یک ترکیب خطی از این دو بردار ساخته می‌شوند.

$$|0\rangle = \begin{bmatrix} 1 \\ 0 \end{bmatrix}, |1\rangle = \begin{bmatrix} 0 \\ 1 \end{bmatrix}. \quad (6)$$

کیوبیت‌های کوانتومی با قرار گرفتن در کنار یکدیگر، واحدهای بزرگ‌تری از اطلاعات را تشکیل می‌دهند (ثبات کوانتومی). به کیوبیت‌ها حالت یا ورودی مدارهای کوانتومی هم گفته می‌شود که در هر بُعدی باشند باید اندازه آن‌ها یک باشد.

در مدار دیجیتال معمولی دست‌کاری روی بیت‌ها با دروازه‌های منطقی انجام می‌شود. بلوک‌های سازنده معادل در مدار کوانتومی، دروازه‌های کوانتومی نامیده می‌شوند که روی یک حالت کوانتومی عمل می‌نمایند و آن را به حالت کوانتومی دیگری تبدیل می‌کنند. لازم به ذکر است هر ماتریس یکانی ($UU^\dagger = U^\dagger U = I$) می‌تواند نشان‌دهنده یک دروازه کوانتومی باشد و بنابراین دروازه‌های کوانتومی برگشت‌پذیر هستند و در نتیجه با دروازه‌های سنتی تفاوت دارند. دروازه تک کیوبیتی هادامارد (H) به‌صورت ماتریس (۷) بیان می‌شود.

$$H = \frac{1}{\sqrt{2}} \begin{bmatrix} 1 & 1 \\ 1 & -1 \end{bmatrix}. \quad (7)$$


دروازه‌های پائولی همانی (I)، X ، Y و Z با ماتریس‌های (۸) نمایش داده می‌شوند.

$$I = \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix}, X = \begin{bmatrix} 0 & 1 \\ 1 & 0 \end{bmatrix}, Y = \begin{bmatrix} 0 & -i \\ i & 0 \end{bmatrix}, Z = \begin{bmatrix} 1 & 0 \\ 0 & -1 \end{bmatrix}. \quad (8)$$

دروازه U کنترل‌شده که روی دو کیوبیت عمل می‌کند، مطابق ماتریس (۹) به دست می‌آید.

$$Controlled - U = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & u_{00} & u_{01} \\ 0 & 0 & u_{10} & u_{11} \end{bmatrix}. \quad (9)$$

هنگامی که U یکی از عملگرهای پائولی X ، Y و Z باشد، گاهی اوقات به ترتیب $Controlled - X$ ، $Controlled - Y$ و $Controlled - Z$ استفاده می‌شود. همچنین به $Controlled - X$ دروازه $CNOT$ نیز



شکل ۶: ساختار QNN سه لایه

لایه ورودی مقادیر ورودی از بازه $[0,1]$ را به حالت‌های کوانتومی با مقادیر فاز در بازه $[0, \pi/2]$ مطابق (۱۴) تبدیل می‌کند.

$$p_j = \frac{\pi}{2} x_j, j = 1, 2, \dots, m. \quad (14)$$

$$q_j = f(p_j).$$

که x_j ها ورودی هستند. در مورد ورودی صفر، ورودی شبکه با $|0\rangle$ مطابقت دارد که حالت مهاری است. اگر ورودی یک باشد، شبکه با $|1\rangle$ مطابقت دارد که حالت تحریکی است. حالت کوانتومی نورون‌ها به‌عنوان برهم‌نهی حالت‌های تحریکی و مهاری در نظر گرفته می‌شود. خروجی مدل نورون کوانتومی، با توجه به روابط (۱۳)، به‌صورت (۱۵) ارائه می‌شود.

$$I_k = \sum_{j=1}^m e^{i\theta_{j,k}} q_j, \quad (15)$$

$$u_k = \frac{\pi}{2} g(\delta_k) - \arg(I_k),$$

$$z_k = f(u_k).$$

برای خروجی نهایی، عموماً از دامنه احتمالی حالت کوانتومی $|1\rangle$ استفاده می‌شود و مطابق (۱۶) حاصل می‌شود.

$$y_k = |z_k| |z_k|. \quad (16)$$

برای بالا بردن توانایی یادگیری شبکه از نسخه الگوریتم پس انتشار خطا برای تنظیم پارامترهای خروجی موردنظر استفاده می‌شود [38]. روش نزول گرادیان برای محاسبه متغیر فاز θ و عامل کنترل شده فاز δ شبکه و تنظیم آن‌ها برای به حداقل رساندن خطای خروجی استفاده می‌شود. تابع متوسط مربع خطا (E_{total}) در نورون خروجی به‌صورت (۱۷) تعریف می‌شود.

$$E_{total} = \frac{1}{2} \sum_{i=1}^n (y_i^t - y_p)^2, \quad (17)$$

که y_p و y_i^t به ترتیب مقادیر هدف و خروجی هستند و کمینه‌سازی E_{total} هدف الگوریتم است. الگوریتم گرادیان نزولی، با توجه به خطای گرادیان مطابق (۱۸) محاسبه می‌شود.

$$y' = \frac{y - y_{min}}{y_{max} - y_{min}}, \quad (12)$$

که y_{min} و y_{max} به ترتیب بیانگر مقدار بیشینه و کمینه y است و y' بیانگر مقدار بهنجار شده ویژگی در بازه $[0,1]$ است.

۲-۶- طبقه‌بند شبکه عصبی کوانتومی


QNN ابتدا در سال ۱۹۹۵ توسط سبهاش کاک [36] مطرح گردید. در این مقاله یک QNN سه لایه ($L=3$) شامل لایه‌های ورودی، پنهان و خروجی استفاده می‌کند. در ادامه یک QNN و مدل یادگیری نورون کوانتومی معرفی می‌شود [37]. حالت نورون i ام (s_i) که ورودی‌ها را از N نورون دیگر دریافت می‌کند، به‌صورت (۱۳) ارائه می‌شود.

$$I_i = \sum_{j=1}^n f(\theta_{j,i}) q_j, \quad (13)$$

$$u_i = \frac{\pi}{2} g(\delta_i) - \arg(I_i),$$

$$y_i = f(u_i).$$

که $f(\theta) = e^{i\theta} = \cos\theta + i\sin\theta$ و g تابع سیگموئید به‌صورت $g(\delta) = 1/(1 + \exp(-\delta))$ است. θ متغیر فاز و δ عامل کنترل شده فاز است، آن‌ها دو پارامتر برای کنترل نورون هستند و هر دو به ترتیب با فاز دروازه چرخش و نرخ معکوس دروازه CNOT مطابقت دارند. مدل یک نورون کوانتومی در شکل ۵ آورده شده است.



شکل ۵: مدل یک نورون کوانتومی (برگرفته‌شده از [37])

ساختار یک QNN سه لایه در شکل ۶ نمایش داده شده است که در لایه ورودی n_i نورون، در لایه پنهان n_h نورون و در لایه خروجی n_o قرار دارد.

۳- نتایج

شبیه‌سازی‌ها در نرم‌افزار MATLAB نسخه R2018b انجام شده است. روش پیشنهادی در رایانه‌ای با رم ۸ گیگابایتی و پردازنده Intel(R) core(TM) Intel i5-6200u با سرعت ۲/۳ گیگاهرتز پیاده‌سازی شده

جدول ۱: مقایسه نتایج این مقاله با پژوهش‌های گذشته روی داده یکسان DEAP

مرجع	روش	تعداد کانال‌ها	صحت	
			ظرفیت	برانگیختگی
[17]	چگالی طیف توان و بیز ساده	۳۲	۵۷/۶۰	۵۸/۳۰
[10]	اسکیلوگرام و شبکه عصبی کانولوشنی	۳۲	۵۹/۵۰	۵۸/۰۰
[10]	اسکیلوگرام و شبکه عصبی کانولوشنی	۱۰	۶۱/۵۰	۵۸/۵۰
[11]	چگالی طیف توان و ماشین بردار پشتیبان	۱۰	۶۴/۹۰	۶۴/۹۰
[11]	چگالی طیف توان و ماشین بردار پشتیبان	۳۲	۶۴/۹۰	۶۵/۰۰
[14]	توابع مد ذاتی و ماشین بردار پشتیبان	۸	۶۹/۱۰	۷۱/۹۹
[14]	توابع مد ذاتی و ماشین بردار پشتیبان	۳۲	۷۰/۴۱	۷۲/۱۰
[13]	آنتروپی تفاضلی و حافظه کوتاه‌مدت و ماندگار دوطرفه	۳۲	۷۱/۰۰	۷۴/۰۰
[13]	آنتروپی تفاضلی اصلاح‌شده و حافظه کوتاه‌مدت و ماندگار دوطرفه	۳۲	۷۳/۵۰	۷۵/۰۰
[15]	شبکه عصبی کانولوشنی موازی عمقی	۳۲	۸۲/۹۵	۸۴/۰۸
[5]	ویژگی‌های زمانی و شبکه عصبی مصنوعی	۳۲	۸۵/۶۰	۸۷/۳۶
[16]	جنگل عمیق	۳۲	۹۷/۶۹	۹۷/۵۳
	روش پیشنهادی	۳۲	۹۴/۷۱	۹۷/۶۲

است. این بخش نتایج طبقه‌بندی دو دسته ظرفیت و برانگیختگی بر روی پایگاه داده DEAP حاوی سیگنال‌های EEG به کمک QML سلسله مراتبی را نشان می‌دهد. ابتدا سیگنال‌های EEG توسط پالایه میان‌گذر تمیز شده و آرتیفکت‌های حرکتی آن حذف می‌شود، سپس لاپلاسیان سطحی روی کانال‌های ثبت‌شده اعمال می‌شوند. سپس آماده‌سازی سیگنال EEG به‌عنوان یک حالت کوانتومی آماده‌شده و ویژگی به کمک QWPT و WPEE استخراج می‌شود و در نهایت به طبقه‌بند QNN سه لایه تحویل می‌شوند.

ورودی QNN پیشنهادی به ارقام ۰ یا ۱ محدود می‌شود، بنابراین ویژگی‌ها به ارقام باینری تبدیل می‌شوند. بدین منظور اگر ویژگی‌های استخراجی اعشاری باشند، آن‌ها را بزرگ‌تر کرده و سپس به باینری تبدیل می‌شوند. یک ورودی به‌صورت بردار ستونی بیان می‌شود. بردارهای شیء آن در QNN ممکن است به‌صورت $T1 = [0 \ 0 \ 1]^T$

$$\theta(k+1) = \theta(k) - \eta \frac{\partial E_{total}}{\partial \theta}, \quad (18)$$

$$\delta(k+1) = \delta(k) - \eta \frac{\partial E_{total}}{\partial \delta},$$

که η نرخ یادگیری شبکه و در بازه $[0,1]$ تعیین می‌شود. برای سرعت بخشیدن به همگرایی خطا در روش یادگیری، یک عبارت تکانه به گرادینان نزول اضافه‌شده که در روابط (۱۹) آورده شده است.

$$\theta(k+1) = \theta(k) - \eta \frac{\partial E_{total}}{\partial \theta} + \alpha \Delta \theta(k), \quad (19)$$

$$\delta(k+1) = \delta(k) - \eta \frac{\partial E_{total}}{\partial \delta} + \alpha \Delta \delta(k),$$

که پارامتر تکانه α در محدوده $[0,1]$ است. مراحل اصلی QNN به شرح زیر است:

مرحله ۱: تمام متغیر فاز θ و عامل کنترل‌شده فاز δ را به مقادیر تصادفی کوچک در محدوده مقداردهی می‌شوند.

مرحله ۲: بردارهای ورودی و بردارهای هدف داده می‌شوند.

مرحله ۳: مقادیر خروجی را در جهت پیش‌خور برای هر واحد از هر لایه محاسبه می‌شوند.

مرحله ۴: از مقادیر محاسبه‌شده توسط واحدهای لایه نهایی و مقدار هدف مربوطه برای محاسبه خطا استفاده می‌شود.

مرحله ۵: دلتاها برای هر یک از لایه‌های قبلی با انتشار مجدد خطاها محاسبه می‌شود.

مرحله ۶: تمام متغیر فاز θ و عامل کنترل‌شده فاز δ را به‌روزرسانی می‌شوند.

مرحله ۷: بازگشت به مرحله ۲ و برای هر الگو تکرار می‌شود تا به تعداد تکرار برسد.

مرحله ۸: روند آموزش با رسیدن به حداکثر تعداد تکرار متوقف می‌شود.

دوره‌های آموزشی برخط، در صورتی قابل توجه است که آن‌ها بر اساس وضعیت احساسی و رتبه‌بندی شرکت‌کنندگان ارزیابی شوند. علاوه بر این شرکت‌کنندگان همچنین می‌توانند در هنگام تماشای مطالب برنامه درسی، بازخوردی در مورد حالات احساسی خود دریافت نمایند. وبسایت‌های تجارت الکترونیک همچنین می‌توانند از حالات احساسی مصرف‌کنندگان برای درک بهتر الگوهای خرید مشتریان خود و حفظ آن‌ها استفاده نمایند. همچنین می‌توان از این اطلاعات برای درک علاقه یا عدم علاقه احساسی یک فرد به یک شیء استفاده کرد و بنابراین توصیه‌های قوی ارائه نمود. متخصصان پزشکی می‌توانند با ارائه حمایت و مشاوره کافی از اطلاعات احساسی برای درمان بیماران مبتلا به افسردگی نیز استفاده نمایند. علاوه بر این بازی‌های تعاملی با شرکت‌کننده را می‌توان درجایی که احساسات خاصی در آن ایجاد می‌شود توسعه داد. همچنین سطح بهینه یک احساس خاص، توجه و استرس و در نتیجه عملکرد یک فرد را به عنوان یک کل افزایش دهد.

تاکنون پژوهش‌های زیادی روی QNN‌ها با اینکه یک زمینه پژوهشی نسبتاً جدید هستند، انجام شده است. ویژگی‌های استخراجی به عنوان ورودی در یک سیستم طبقه‌بندی مبتنی بر QNN استفاده شدند. روش پیشنهادی به صحت ۹۴/۷۱ درصد در تشخیص ظرفیت و به صحت ۹۷/۶۲ درصد در تشخیص برانگیختگی دست یافته است. از نتایج به دست آمده می‌توان چنین استنباط نمود که احساسات را می‌توان به طور مؤثر در فضای ظرفیت-برانگیختگی طبقه‌بندی کرد. نتایج نشان می‌دهد که با شبکه سلسله مراتبی پیشنهادی، نتایج بهتر در مقایسه با سایر روش‌های گذشته ایجاد شده است. شایان ذکر است دلیل درصد صحت کمتر، ممکن است به دلیل مشکل ذاتی در قابلیت اطمینان برچسب‌گذاری داده‌ها بر اساس معیارهای ذهنی باشد، بدین منظور پیشنهاد می‌شود در آینده از سیگنال‌های محیطی برای برچسب‌گذاری صحیح سیگنال‌های EEG استفاده شود.

بدیهی است که در پژوهش‌های آتی می‌توان موارد افزوده زیادی را در مورد این کار در نظر گرفت. در این مقاله از WPEE به عنوان استخراج ویژگی استفاده شده است، در واقع بسیاری از روش‌های استخراج ویژگی دیگر را می‌توان با پردازش اطلاعات کوانتومی پیاده‌سازی کرد. همچنین از آنجایی که برای طبقه‌بندی از شبکه عصبی کوانتومی استفاده شده است، می‌توان از مدل‌های دیگر مبتنی بر کوانتوم برای طبقه‌بندی استفاده کرد. کارهای آینده در این زمینه عمدتاً انتقال این ایده‌ها به رایانه کوانتومی دنیای واقعی است.

مراجع

- [1] D. J. Hemanth and J. Anitha, "Brain signal based human emotion analysis by circular back propagation and Deep Kohonen Neural Networks," *Computers & Electrical Engineering*, vol. 68, pp. 170–180, 2018.
- [2] G. Chen, X. Zhang, Y. Sun, and J. Zhang, "Emotion feature analysis and recognition based on reconstructed EEG sources," *IEEE Access*, vol. 8, pp. 11907–11916, 2020.
- [3] S. A. Hosseini, "Quantification of EEG signals for evaluation of emotional stress level," MSc Thesis, Biomedical Department,

تعریف شوند، به دلیل اینکه مجموعه داده از سه دسته هدف تشکیل شده است، دو دسته دیگر به صورت $T2 = [0 \ 1 \ 0]^T$ و $T3 = [1 \ 0 \ 0]^T$ تعریف می‌شوند. در این مقاله یک QNN پیش‌خور سه لایه با ۲۵ نورون در لایه ورودی، ۱۰ نورون در لایه پنهان و ۲ نورون در لایه خروجی ایجاد می‌گردد. از ۷۰ درصد ویژگی‌ها برای آموزش شبکه و از ۳۰ درصد باقی‌مانده برای آزمون شبکه استفاده شده است. متغیر فاز θ به طور تصادفی در بازه $[0, 2\pi]$ و متغیر نرخ معکوس δ در بازه $[-1, 1]$ به طور تصادفی توزیع می‌شود. در این مقاله η به عنوان نرخ یادگیری شبکه روی ۰/۱ تنظیم شده و تعداد تکرارها ۱۵ در نظر گرفته می‌شود.

صحت معیاری است که به طور کلی نحوه عملکرد مدل را در همه دسته‌ها توصیف می‌کند. زمانی مفید است که همه دسته‌ها از اهمیت یکسانی برخوردار باشند. در این مقاله عملکرد طبقه‌بندی کننده با استفاده از معیار صحت اندازه‌گیری می‌شود:

T_N بیانگر تعداد رکوردهایی است که دسته‌ی واقعی آن‌ها منفی بوده و الگوریتم دسته‌بندی نیز دسته‌ی آن‌ها را به درستی منفی تشخیص داده است. T_p بیانگر تعداد رکوردهایی است که دسته‌ی واقعی آن‌ها مثبت بوده و الگوریتم دسته‌بندی نیز دسته‌ی آن‌ها را به درستی مثبت تشخیص داده است. F_p بیانگر تعداد رکوردهایی است که دسته‌ی واقعی آن‌ها منفی بوده و الگوریتم دسته‌بندی دسته‌ی آن‌ها را به اشتباه مثبت تشخیص داده است. F_N بیانگر تعداد رکوردهایی است که دسته‌ی واقعی آن‌ها مثبت بوده و الگوریتم دسته‌بندی دسته‌ی آن‌ها را به اشتباه منفی تشخیص داده است. صحت مطابق رابطه (۲۰) به عنوان نسبت بین تعداد پیش‌بینی‌های صحیح به تعداد کل پیش‌بینی‌ها محاسبه می‌شود.

$$Accuracy = \frac{T_p + T_N}{T_p + F_p + T_N + F_N} \times 100\%. \quad (20)$$

روش پیشنهادی توانسته است به درصد صحت ۹۴/۷۱ در تشخیص ظرفیت و به درصد صحت ۹۷/۶۲ در تشخیص برانگیختگی برسد. مقایسه نتایج این مقاله با پژوهش‌های گذشته روی داده یکسان DEAP در جدول ۱ آورده شده است.

همان‌طور که از جدول ۱ مشاهده می‌شود روش پیشنهادی از همه پژوهش‌های گذشته اشاره شده به جز [16] برای تشخیص ظرفیت بهتر عمل نموده است.

۴- بحث و نتیجه‌گیری

در این مقاله نتایج طبقه‌بندی باینری (بالا در مقابل کم) در مورد دو پارامتر احساسی معمولی انگیزتگی و ظرفیت با استفاده از روش یادگیری ماشین کوانتومی سلسله مراتبی در پایگاه داده DEAP ارزیابی گردیده است. اطلاعات احساسی یک شرکت‌کننده را می‌توان به روش‌های مختلفی مورد استفاده قرار داد. به عنوان نمونه می‌تواند با معلمان برخط در سیستم‌عامل‌های یادگیری برخط برای درک حالات احساسی دانش‌آموزان استفاده شود. سرمایه‌گذاری کلان در ایجاد

- [21] N. B. Karayiannis, A. Mukherjee, J. R. Glover, J. D. Frost, J. R. Hrachovy, and E. M. Mizrahi, "An evaluation of quantum neural networks in the detection of epileptic seizures in the neonatal electroencephalogram," *Soft Computing*, vol. 10, no. 4, pp. 382–396, 2006.
- [22] S. M. Taha and Z. K. Taha, "Analysis and classification of EEG signals based on a new quantum inspired wavelet neural network model," *International Journal of Computer Applications*, vol. 975, p. 8887, 2014.
- [23] M. A.-Z. Raheem and E. A. Hussein, "Classification of EEG Signals Using Quantum Neural Network and Cubic Spline," *International Journal of Electronics and Telecommunications*, 2016.
- [24] S. M. Taha and Z. K. Taha, "EEG signals classification based on autoregressive and inherently quantum recurrent neural network," *International Journal of Computer Applications in Technology*, vol. 58, no. 4, pp. 340–351, 2018.
- [25] S. Oh, J. Choi, and J. Kim, "A tutorial on quantum convolutional neural networks (QCNN)," in *2020 International Conference on Information and Communication Technology Convergence (ICTC)*, IEEE, 2020, pp. 236–239.
- [26] S. Aishwarya, V. Abeer, B. B. Sathish, and K. N. Subramanya, "Quantum Computational Techniques for Prediction of Cognitive State of Human Mind from EEG Signals," *Journal of Quantum Computing*, vol. 2, no. 4, p. 157, 2020.
- [27] M. Ohzeki and H. Nishimori, "Quantum annealing: An introduction and new developments," *Journal of Computational and Theoretical Nanoscience*, vol. 8, no. 6, pp. 963–971, 2011.
- [28] Y. Li, R.-G. Zhou, R. Xu, J. Luo, and S.-X. Jiang, "A quantum mechanics-based framework for EEG signal feature extraction and classification," *IEEE transactions on emerging topics in computing*, vol. 10, no. 1, pp. 211–222, 2020.
- [29] D. S. Abdul-Zahra, A. T. Jawad, H. M. Gheni, and A. N. Abdullah, "Classification of EEG Signal by Using Optimized Quantum Neural Network," *Indonesian Journal of Electrical Engineering and Informatics (IJEET)*, vol. 9, no. 4, pp. 1008–1014, 2021.
- [30] T. Koike-Akino and Y. Wang, "quEEGNet: Quantum AI for Biosignal Processing," in *2022 IEEE-EMBS International Conference on Biomedical and Health Informatics (BHI)*, IEEE, 2022, pp. 01–04.
- [31] L.-C. Yu *et al.*, "Building Chinese affective resources in valence-arousal dimensions," in *Proceedings of the 2016 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies*, 2016, pp. 540–545.
- [32] M. A. Nielsen and I. Chuang, "Quantum computation and quantum information." American Association of Physics Teachers, 2002.
- [33] G. E. Crooks, "Gates, states, and circuits," 2020.
- [34] H.-S. Li, P. Fan, H. Xia, S. Song, and X. He, "The multi-level and multi-dimensional quantum wavelet packet transforms," *Scientific reports*, vol. 8, no. 1, pp. 1–23, 2018.
- [35] S. Kak, "Quantum information and entropy," *International Journal of Theoretical Physics*, vol. 46, no. 4, pp. 860–876, 2007.
- [36] S. C. Kak, "Quantum neural computing," *Advances in imaging and electron physics*, vol. 94, pp. 259–313, 1995.
- [37] S. Yu and N. Ma, "Quantum neural network and its application in vehicle classification," in *2008 Fourth International Conference on Natural Computation*, IEEE, 2008, pp. 499–503.
- [38] T. Nitta, "An extension of the back-propagation algorithm to complex numbers," *Neural Networks*, vol. 10, no. 8, pp. 1391–1415, 1997.
- [4] S. A. Hosseini and M. A. Khalilzadeh, "Emotional stress recognition system using EEG and psychophysiological signals: Using new labelling process of EEG signals in emotional stress state," in *Biomedical Engineering and Computer Science (ICBECS), 2010 International Conference on*, IEEE, 2010, pp. 1–6.
- [5] R. C. Dhinra and S. Ram Avtar Jaswal, "Emotion Recognition Based on EEG using DEAP Dataset," *European Journal of Molecular & Clinical Medicine*, vol. 8, no. 3, pp. 3509–3517, 2021.
- [6] M. Khateeb, S. M. Anwar, and M. Alnowami, "Multi-domain feature fusion for emotion classification using DEAP dataset," *Ieee Access*, vol. 9, pp. 12134–12142, 2021.
- [7] T. D. Kusumaningrum, A. Faqih, and B. Kusumoputro, "Emotion recognition based on DEAP database using EEG time-frequency features and machine learning methods," in *Journal of Physics: Conference Series*, IOP Publishing, 2020, p. 012020.
- [8] N. Kumar, K. Khaund, and S. M. Hazarika, "Bispectral analysis of EEG for emotion recognition," *Procedia Computer Science*, vol. 84, pp. 31–35, 2016.
- [9] S. A. Hosseini, M. A. Khalilzadeh, and S. Changiz, "Emotional stress recognition system for affective computing based on bio-signals," *Journal of Biological Systems*, vol. 18, no. spec01, pp. 101–114, 2010.
- [10] P. Pandey and K. R. Seeja, "Subject independent emotion recognition system for people with facial deformity: an EEG based approach," *Journal of Ambient Intelligence and Humanized Computing*, vol. 12, no. 2, pp. 2311–2320, 2021.
- [11] I. Wichakam and P. Vateekul, "An evaluation of feature extraction in EEG-based emotion prediction with support vector machines," in *2014 11th international joint conference on computer science and software engineering (JCSSE)*, IEEE, 2014, pp. 106–110.
- [12] N. Zhuang, Y. Zeng, L. Tong, C. Zhang, H. Zhang, and B. Yan, "Emotion recognition from EEG signals using multidimensional information in EMD domain," *BioMed research international*, vol. 2017, 2017.
- [13] V. M. Joshi and R. B. Ghongade, "IDEA: Intellect database for emotion analysis using EEG signal," *Journal of King Saud University-Computer and Information Sciences*, 2020.
- [14] N. Zhuang, Y. Zeng, L. Tong, C. Zhang, H. Zhang, and B. Yan, "Emotion recognition from EEG signals using multidimensional information in EMD domain," *BioMed research international*, vol. 2017, 2017.
- [15] Y. Zhan, M. I. Vai, S. Barma, S. H. Pun, J. W. Li, and P. U. Mak, "A computation resource friendly convolutional neural network engine for EEG-based emotion recognition," in *2019 IEEE International Conference on Computational Intelligence and Virtual Environments for Measurement Systems and Applications (CIVEMSA)*, IEEE, 2019, pp. 1–6.
- [16] J. Cheng *et al.*, "Emotion recognition from multi-channel eeg via deep forest," *IEEE Journal of Biomedical and Health Informatics*, vol. 25, no. 2, pp. 453–464, 2020.
- [17] S. Koelstra *et al.*, "Deap: A database for emotion analysis; using physiological signals," *IEEE transactions on affective computing*, vol. 3, no. 1, pp. 18–31, 2011.
- [18] S. Chakraborty, T. Das, S. Sutradhar, M. Das, and S. Deb, "An analytical review of quantum neural network models and relevant research," in *2020 5th International Conference on Communication and Electronics Systems (ICCES)*, IEEE, 2020, pp. 1395–1400.
- [19] S. Gao, "Are human brains quantum computers? Why quantum cognition says Yes," 2019.
- [20] G. Purushothaman and N. B. Karayiannis, "Quantum neural networks (QNNs): inherently fuzzy feedforward neural networks," *IEEE Transactions on neural networks*, vol. 8, no. 3, pp. 679–693, 1997.

زیر نویس ها

⁵ Feedforward Neural Network

⁶ Quantum Wavelet Neural Network

⁷ Independent Component Analysis

⁸ Wavelet Neural Network

¹ Galvanic Skin Response

² Electroencephalogram

³ Quantum Machine Learning

⁴ Quantum Neural Network

⁹ AutoRegressive

¹⁰ Quantum Recurrent Neural Network

¹¹ Quantum Convolutional Neural Networks

¹² Convolutional Neural Networks

¹³ Variational Quantum Circuit

¹⁴ Quantum Wavelet Packet Transformation

¹⁵ Wavelet Packet Energy Entropy

¹⁶ Wavelet Transform

¹⁷ Electromyogram

¹⁸ Deep Neural Network

¹⁹ Electrooculogram

²⁰ Daubechies four-order