

ارائه رویکرد رمزگشایی عصبی بر پایه تشخیص الگوی فعالیت‌های عصبی برای یک سیستم رابط مغز و ماشین قابل کاشت در بدن درون قشری

دانیال کاتوزیان^۱، حسین حسینی نژاد^۲، محمدرضا ابوالقاسمی دهاقانی^۳

^۱ دانشجوی مقطع دکتری، آزمایشگاه FPGA، دانشکده مهندسی برق، دانشگاه صنعتی خواجه نصیرالدین طوسی، d.katoozian@gmail.com

^۲ استادیار، آزمایشگاه FPGA، دانشکده مهندسی برق، دانشگاه صنعتی خواجه نصیرالدین طوسی، hosseini_nezhad@kntu.ac.ir

^۳ استادیار، آزمایشگاه سیستم‌های شناختی، مرکز تعالی کنترل و پردازش هوشمند، دانشکده مهندسی برق و کامپیوتر، دانشکده فنی دانشگاه تهران، dehaqani@ut.ac.ir

پذیرش: ۱۴۰۲/۱۲/۲۳

ویرایش: ۱۴۰۲/۱۱/۰۷

دریافت: ۱۴۰۲/۰۹/۱۹

چکیده: در بحث رابط مغز و ماشین، به عمل تشخیص و تبدیل تصمیمات مغز به دستوراتی که قابل درک برای ماشین باشد، رمزگشایی گفته می‌شود. با وجود پیشرفت‌های بدست آمده در حوزه رابط مغز و ماشین، رمزگشایی همچنان یکی از مباحث چالش برانگیز بوده است. بعلاوه، بسیاری از روش‌های پیشنهادی به دلیل حجم محاسباتی بالای خود به پردازنده‌ای مانند رایانه جهت اجرای الگوریتم‌های خود نیاز دارند. این دسته از رویکردها به دلیل حجم و توان مصرفی رایانه‌ها رویکردی عملی برای یک سیستم رابط مغز و ماشین قابل کاشت در بدن به حساب نمی‌آیند. برای رفع این مشکلات در پژوهش پیشرو از یک رویکر نوین با الهام از روش محاسبات ابر بعدی استفاده شده است. به شکل خلاصه در این روش ابتدا فضای ورودی به یک بردار صفر و یک تبدیل می‌شود که در گام بعدی به وسیله یک الگوریتم مقایسه، شبیه‌ترین الگو به فضاهای خروجی به عنوان خروجی نهایی انتخاب می‌شود. روش پیشنهادی به کمک بانک داده‌ای ثبت شده از ناحیه جلوی چشم (Frontal Eye Field) از دو میمون مذکر (rhesus) که در یک تست نگاه کردن به اهداف در ۸ زاویه شرکت داشته‌اند ارزیابی شده است. نتایج حاکی از دقت بدست آمده ۵۱٫۵ درصد با حجم محاسباتی بسیار پایین است. از طرفی دیگر با پیاده‌سازی رویکرد پیشنهادی بر روی یک آرایه‌ی دروازه‌ی میدانی برنامه‌پذیر (FPGA) نشان داده شد این روش یک سیستم رابط مغز و ماشین بلادرنگ قابل کاشت در بدن با حجم محاسباتی بسیار پایین با دقتی متوسط است.

کلمات کلیدی: رمزگشایی عصبی درون قشری، الگوی فعالیت عصبی، محاسبات ابر بعدی، پیاده‌سازی سخت‌افزاری

A Neural Decoding Method Based on Neurons Activities Pattern Recognition for Implantable Intra-cortical BMIs

Danial Katoozian, Hossein Hosseini-Nejad, Mohammad-Reza A Dehaqani

Abstract: Converting motor intention to a machine command is called decoding in Brain Machine Interface (BMI) field. Despite recent advances, decoding remains among the most challenging steps in BMI. Furthermore, the majority of algorithms currently used in decoding require a computer, as a result of their high computational complexity. However, due to the size and power consumption of computers, they are not practical for implantable BMI systems. To address this issue, this paper proposes a novel approach based on hyperdimensional computing. This approach involves the conversion of the input space to binary, followed by the selection of the most similar vector to the answer. The proposed method is evaluated using a real dataset recorded from the Frontal Eye Field (FEF) of two male rhesus monkeys, with eight possible angles as the output space. The results demonstrate an accuracy rate of 51.5% with very low computational complexity. Furthermore, the

proposed algorithm is implemented on a field-programmable gate array, indicating that it is a practical choice for real-time implantable BMI applications requiring a low computational cost method with a medium level of accuracy.

Keywords: Intra-cortical neural decoding; Neurons activities patterns; Hyperdimensional computing; Hardware implementation;

۱- مقدمه

تقریباً از هر ۵۰ نفر یک نفر دارای معلولیت است [۱] و [۲]. رابط مغز و ماشین توانایی ایجاد یک پل ارتباطی بین قشای مغز و ماشین را برای رمزگشایی تصمیم‌های مغز جهت تبدیل آنها به دستورهای قابل درک برای ماشین دارد [۱]، [۳] و [۴]. این دستورها می‌توانند برای ابزارهای هجی-کننده [۵] و [۶] بازوهای رباتی [۷] و ویلچرها جهت کمک به بیماران استفاده شود [۸]، [۹] و [۱۰]. به این ترتیب این رویکرد می‌تواند به بهبود کیفیت زندگی فرد معلول کمک کرده و بعضی از توانایی از دست رفته را به فرد بیمار بازگرداند [۱۱] و [۱۲]. روش‌های رابط مغز و ماشین درون قشری که سیگنال‌های مغزی را از سطح قشای مغز دریافت کرده و برای دستیابی به هدف مورد نظر در مراحل مختلفی پردازش می‌کنند، از جمله امید بخش‌ترین روش‌ها در رویکردهای رابط مغز و ماشین هستند [۱]. این مراحل پردازشی عموماً به ترتیب شامل مرحله تشخیص اسپایک [۱۳] و [۱۴] مرتب‌سازی اسپایک [۱۵]، [۱۶]، [۱۷] و [۱۸] و مرحله رمزگشایی [۱۹] و [۲۰] هستند که از این میان، رمزگشایی مرحله تبدیل فعالیت‌های عصبی به دستورات قابل درک توسط ماشین است [۲۱].

بیشتر روش‌های رایج برای رمزگشایی از اطلاعات نهفته در تعداد رخداد اسپایک‌ها در یک بازه مشخص استفاده می‌کنند که نرخ آتش نام دارد [۲۲] و [۲۳] به این معنا که هر نورون برای هر تحریک خاص در یک زمان، تعداد معینی اسپایک داشته و نرخ آتش مشخصی دارد. از این رو برای مدل کردن تابعی که نگاشتی از فضای نرخ آتش به فضای خروجی مطلوب باشد، روش‌های متعددی پیشنهاد شده که در ادامه چند روش رایج بررسی خواهد شد. به عنوان مثال در فیلتر وینر به شکل ساده از یک فیلتر خطی برای رمزگشایی فضای خروجی مطلوب استفاده می‌شود [۲۴]، [۲۵]، [۲۶] و [۲۷] در تحقیقی دیگر مانند [۱۳] از مدل گسترش یافته فیلتر وینر با نام فیلتر وینر آبخاری^۱ استفاده شده است. در این روش پس از استفاده از فیلتر خطی مشابه فیلتر وینر از یک تابع نگاشت غیرخطی مانند چندجمله‌ای استفاده شده است تا رابطه غیرخطی فضای ورودی و خروجی نیز در نظر گرفته شود. فیلتر کالمن از دیگر روش‌های گسترش یافته فیلتر وینر است [۲۵] فیلتر کالمن از دو مرحله بروزرسانی و پیشبینی تشکیل شده است. در این رویکرد ابتدا خروجی فعلی بر اساس خروجی قبل پیشبینی می‌شود و در گام بعد به کمک یک رویکرد میانگین گیر اقدام به بروزرسانی می‌کند [۱]. از آنجایی که برای یک خروجی دقیق به وضعیت واقعی خروجی

گذشته نیاز است، این الگوریتم برای سیستم‌های حلقه بسته پیشنهاد شده است. روش رایج دیگر در رمزگشایی روش ماشین بردار پشتیبان^۲ (SVM) نام دارد [۲۸] و [۲۹]. در روش SVM، در ابتدا فضای ورودی به کمک توابع غیرخطی به نام کرنل به فضای دیگری نگاشت داده می‌شوند، در گام بعد این فضای جدید به کمک یک نگاشت خطی به فضای خروجی مطلوب نگاشت داده می‌شود [۳۰] و [۳]. روش رایج دیگر شبکه عصبی است [۳۱]. به عنوان مثال در شبکه عصبی پیشخور^۳ از چند لایه مخفی متوالی برای نگاشت متوالی فضای ورودی به فضای دیگر استفاده می‌شود، تا در نهایت در لایه نهایی فضای مطلوب خروجی به دست بیاید [۳۲]، [۳۳] و [۳۴]. در این روش‌ها نرخ آتش یک لحظه به عنوان ورودی، پردازش شده و یک مدل ریاضی برای خروجی متناظر با آن لحظه پیشنهاد می‌شود. از طرفی دیگر، الگوریتم‌های دیگری وجود دارند که رویکرد متفاوتی را استفاده می‌کنند.

تحقیقات متعددی تلاش کردند که اطلاعات زمانی قطار اسپایک را در فرآیند رمزگشایی استفاده کنند و نشان دادند که این اطلاعات نه تنها در اطلاعات سیگنال‌های بینایی و شنیداری موثر است [۳۵]، [۳۶] و [۳۷]، بلکه در بهبود رمزگشایی موتور حرکتی بدن نیز تاثیر مثبت دارد [۳۸]. به عنوان مثال در [۳۹] از یک شبکه عصبی بازگشتی^۴ (RNN) استفاده شده است تا از چند نرخ آتش متوالی به عنوان ورودی برای تشخیص خروجی بهره گرفته شود. در [۴۰] بررسی مشابه انجام شده است که در آن دقت روش‌های بازگشتی در مقایسه با روش‌های غیربازگشتی جمع‌آوری و تحلیل شده است. اطلاعات زمانی به کمک روش‌های دیگری نیز در فرآیند رمزگشایی در نظر گرفته می‌شود. به عنوان مثال در [۳۹] معیار فاصله قطار ضربه به عنوان ورودی فرآیند رمزگشایی در نظر گرفته شده است. نهایتاً در [۲۰] یک فضای ورودی جدید پیشنهاد گردید تا بتوان به شکلی بهینه از اطلاعات زمانی به کمک یک بردار صفر و یک برای یک رویکرد مناسب برای پیاده‌سازی سخت‌افزاری استفاده کرد.

اگرچه روش‌های ذکر شده دقیق و کارآمد هستند، اما همه آنها بر اساس یک مدل ریاضی در تلاش هستند که ارتباطی بین فضای ورودی و خروجی بدست بیاورند. این روش پردازش عموماً دارای پیچیدگی محاسباتی زیاد و توان مصرفی بالا هستند. بنابراین این گونه الگوریتم‌ها برای استفاده طولانی مدت در سیستم‌های واقعی رابط مغز و ماشین مناسب نیستند [۲۱]. پیاده‌سازی سخت‌افزاری الگوریتم‌ها بر روی یک پردازنده،


^۲. Feedforward neural network

^۴. Recurrent neural network

^۱. Wiener cascade filter


^۲. Support vector machine

یک هدف در یکی از زاویه های ۸ گانه (صفر درجه، ۴۵ درجه، ۹۰ درجه، ۱۳۵ درجه، ۱۸۰ درجه، ۲۲۵ درجه، ۲۷۰ درجه و ۳۱۵ درجه) به مدت یک ثانیه ظاهر خواهد شد ولی میمون باید همچنان به نقطه وسط خیره بماند. بعد از آنکه نقطه وسط محو شد اگر میمون به زاویه درستی که هدف آنجا ظاهر شده بود نگاه کند به عنوان جایزه مقداری آبمیوه بدست می‌آورد. این فرآیند به کمک یک آرایه ۱۶ کاناله از الکترودهایی که پیش‌تر به کمک یک عمل جراحی در داخل مغز کاشته شده است، ثبت می‌شود. در [۲۸] به کمک یک الگوریتم مرتب‌سازی اسپایک [۴۷] بانک داده‌ای بر اساس ۳۲ نورون و ۷۹۲ آزمون تشکیل می‌شود.



شکل ۱: فرآیند هر آزمون

از آنجایی که بیشتر روش‌های رمزگشایی بر اساس فرضیه رمزگشایی نرخ آتش کار می‌کنند، تغییرات نرخ آتش برای تحریک‌های مختلف مربوط به دو نورون مختلف در شکل ۲ جهت بررسی دقیق‌تر نمایش داده شده است.



شکل ۲: تغییرات نرخ آتش متوسط برای

نورون‌های الف) ۱۸ و ب) ۲۶

اعداد گزارش شده برای نرخ آتش‌ها مربوط به پنجره‌ای با طول ۳۵ میلی-ثانیه و بدون همپوشانی است. ظاهر دو کوهان نمودار به دلیل ذات آزمون‌های انجام شده از میمون‌ها است. به این ترتیب که اولین کوهان مربوط به زمانی است که هدف به میمون برای اولین بار نشان داده شده است و کوهان دوم مربوط به زمانی است که میمون به آن نقطه نگاه کرده است. همان‌گونه که در شکل ۲ مشخص است هر نورون نسبت به نورون

می‌تواند به شکل قابل توجهی توان مصرفی و اندازه کل سیستم را کاهش داده و منجر به یک پردازنده قابل کاشت در بدن، برای رمزگشایی بلادرنگ با تأخیری ناچیز شود [۴۱]. علاوه با ادغام سیستم ثبت فعالیت عصبی و الگوریتم رمزگشایی می‌توان نرخ ارسال داده به بیرون از مغز را کاهش داد که خود دیگر ویژگی مطلوب برای یک سیستم رابط مغز و ماشین قابل کاشت در بدن است [۴۲] و [۴۳] بنابراین مشابه دیدگاهی که در [۱]، [۲۰] و [۴۱] وجود داشت، در ارائه یک رویکرد قابل کاشت در بدن، علاوه بر دقت خروجی، حجم پیچیدگی محاسبات و طراحی معماری سخت‌افزاری نیز باید مورد توجه قرار بگیرد.

در این پژوهش تلاش می‌شود با کمینه کردن مدل ریاضی یک رویکرد جدید برای رمزگشایی پیشنهاد شود. به این معنی که تلاش می‌شود بجای انجام محاسبات ریاضی پیچیده، با رویکردی ساده فرآیند تشخیص الگوی فضای ورودی انجام شود و این فرآیند جایگزین مدل‌های ریاضی رایج گردد. روش پیشنهادی قادر خواهد بود که الگوهای تغییر نرخ آتش در طول زمان را به عنوان اطلاعات زمانی با الگو برداری از روش محاسبات ابر بعدی [۴۴] تشخیص دهد. در این روش محاسبه، داده‌های ورودی به کمک یک حافظه انجمنی و یک فرآیند خاص به یک بردار با ابعاد بزرگ تبدیل می‌شوند. مقدار بزرگی هر یک از عناصر بردار مورد نظر اصلاً اهمیتی ندارد و تنها تشابه الگوی آنها است که در فرآیند تصمیم‌گیری برای مساله خوشه‌بندی نقش بازی می‌کند [۴۵]. از آنجایی که این رویکرد نیاز به محاسبات عددی را کاهش می‌دهد حجم محاسبات به شدت کاهش یافته ولی دقت آن برای بسیاری از مسائل در محدوده‌های قابل قبول باقی می‌ماند [۴۶]. از این رو، در این مقاله ابتدا یک رویکرد برای استخراج الگوی تغییرات نرخ آتش و استفاده از آن در فرآیند رمزگشایی پیشنهاد شده است و در گام بعد کارآمدی آن در کنار سایر روش‌ها مورد ارزیابی قرار گرفت. ارزیابی‌ها نشان می‌دهد که نه تنها به دلیل حذف محاسبات عددی، حجم حافظه مورد نیاز برای یک پیاده‌سازی سخت‌افزاری در مقابل سایر روش‌های رایج کاهش می‌یابد، بلکه حجم پیچیدگی محاسباتی و الگوریتم آن بسیار ناچیز خواهد بود.


در ادامه عناوین بخش‌های مختلف مقاله ارائه می‌شود: در بخش دوم اطلاعات کلی در مورد دیتابیس که برای ارزیابی عملکرد روش استفاده می‌شود ارائه خواهد شد. در بخش سوم روش پیشنهادی توضیح داده خواهد شد. در بخش چهارم معماری سخت‌افزاری پیشنهادی که مدلی از الگوریتم پیشنهادی است ارائه می‌گردد. در نهایت نتایج ارزیابی و تحلیل آن در بخش‌های پنجم و ششم به ترتیب گزارش خواهد شد.

۲- ارائه مشخصات بانک داده

در این پژوهش از بانک داده فراهم شده در مقاله [۲۸] برای بررسی، آموزش و ارزیابی روش‌ها استفاده شده است. داده‌ها از ناحیه جلوی چشم (Frontal Eye Field) و از دو میمون مذکر (Rhesus) ثبت شده‌اند. همان‌گونه که در شکل ۱ نشان داده شده است میمون مورد نظر باید فرآیند تست را با نگاه کردن به نقطه وسط به مدت یک ثانیه شروع کند. در گام بعد،

دیگر در هر لحظه نرخ آتش خود را دارد که آن نیز برای هر یک از تحریک‌های مجزا (زاویه‌های مختلف) متفاوت است. روش‌های رمزگشایی دیگر از این تفاوت‌ها برای رمزگشایی فضای خروجی استفاده می‌کنند. بنابراین اگر به طریقی بتوان تفاوت الگوی حالت‌های مختلف را متوجه شد و مدل کرد، می‌توان به کمک این تشخیص، فرآیند رمزگشایی را ممکن کرد.

از طرفی دیگر همانطور که در شکل ۳ مشخص است، زمانی که پراکندگی آماری نرخ آتش یک نورون در یک لحظه خاص مربوط به یک تحریک مشخص رسم گردد، درک می‌شود که نرخ آتش یک نورون همواره یک عدد ثابت نیست ولی تقریباً از یک توزیع احتمال نرمال پیروی می‌کند. بنابراین نمی‌توان با یک مقایسه ساده اقدام به تشخیص الگوی نرخ آتش برای هر نورون کرد و به الگوریتمی ویژه نیاز است که در ادامه معرفی می‌شود.



شکل ۳: نمودار هیستوگرام و تابع چگالی احتمال متناظر آن که برای نورون ۲۶ در زمان نمایش هدف زاویه ۵ برای اولین بار به میمون

۳- ارائه روش پیشنهادی برای تشخیص الگو

برای مدل کردن تفاوت بین نورون‌ها، در تحریک‌های متفاوت و در زمان‌های مختلف، دو رویکرد می‌تواند پیشنهاد شود: رویکردهای بر اساس مدل و رویکردهای بر اساس الگو. در روش‌های بر اساس مدل ریاضی مانند ماشین بردار پشتیبان که از یک الگوریتم ریاضی به همراه جمع و ضرب برای تشخیص تفاوت خروجی استفاده می‌کنند، به دلیل بالا بودن حجم محاسباتی پیاده‌سازی سخت‌افزاری مشکل می‌شود.


از طرف دیگر روش محاسبات ابر بعدی با رویکردی متفاوت اقدام به پردازش داده‌های ورودی می‌کند. در این روش، ابتدا فضای ورودی به کمک یک حافظه از قبل تعریف شده که با ویژگی‌های فضای ورودی و به شکل اتفاقی انتخاب شده است، نگاشت داده می‌شود. به این ترتیب فضای ورودی به مجموعه‌ای از بردارهای حاوی عناصر صفر و یک تبدیل خواهد شد که اگرچه مقدار عددی صفر یا یک‌های موجود در بردار از نظر مقداری مهم نیستند ولی الگوی حاضر در آنها حاوی اطلاعات مهم در فضای ورودی اولیه است. به وسیله چند عملیات مشخص که هر کدام دارای هدف و خاصیتی ویژه هستند، فضای ورودی یک خروجی (خوشه) خاص با هم ترکیب شده و یک بردار و الگوی نماینده برای آن خوشه ایجاد می‌کنند تا فاز آموزش الگوریتم تکمیل شود. در نهایت در فاز

ارزیابی رویکرد به روشی مشابه فضای ورودی اولیه به کمک حافظه تعریف شده اولیه به بردار صفر و یکی تبدیل می‌شود تا خروجی حاصله از نظر شباهت الگوی صفر و یکی با نماینده هر خروجی بررسی گردد. در نهایت خروجی نهایی، آن خوشه‌ای خواهد بود که بردار نماینده آن بیشترین شباهت را با بردار الگوی ورودی دارد [۴۸]. از آنجایی که پیچیدگی محاسبات ریاضی در این رویکرد زیاد نیست، می‌تواند انتخاب مناسبی برای پیاده‌سازی سخت‌افزاری باشد. نکته منفی این روش نیاز به حافظه‌ای برای نگاشت فضای ورودی به بردار صفر است که موجب استفاده از حافظه RAM بیشتر در طراحی می‌شود. حجم حافظه یادشده در این رویکرد رابطه مستقیمی با دقت روش دارد که این مورد برای مساله پیچیده‌ای مانند رمزگشایی حساس‌تر خواهد شد [۴۶]. در تحقیقات مشخص شده است که برای دستیابی به دقتی قابل قبول، حجم قابل توجهی از حافظه بایتری نیاز است که موجب ناکارآمدی رویکرد برای پیاده‌سازی سخت‌افزاری می‌شود. از این رو به رویکردی دیگر نیاز است که در ادامه بررسی خواهد شد. همانطور که در شکل ۲ مشخص است، هر نورون در هر لحظه برای هر تحریک مشخص یک مقدار نرخ آتش میانگین دارد. بعلاوه بر اساس شکل ۳ اگرچه مقدار نرخ آتش یک مقدار ثابت نیست ولی عموماً در محدوده مشخصی قرار دارد. بنابراین اگر همه نورون‌ها همزمان در محدوده مشخصی از یک تحریک خاص با هم آتش کنند فضای خروجی مورد نظر (تحریک) قابل شناسایی خواهد بود. از این روی، الگوی فضای ورودی باید با الگوی کلیه فضاهای خروجی شناخته شده مقایسه شود و شبیه‌ترین الگو به عنوان خروجی مورد نظر پذیرفته شود. برای اینکه این رویکرد ممکن شود باید دو به ابهام پاسخ داده شود: محدوده نرخ آتش الگو و روش مقایسه.

۳-۱ محاسبه مرز بالا و پایین نرخ آتش

بر اساس شکل ۳ تابع توزیع نرخ آتش نورون یک توزیع نرمال است و می‌تواند به کمک مقدار میانگین و انحراف معیار^۱ (STD) توصیف گردد. در شکل ۴ ملاحظه می‌شود که در توزیع نرمال در حدود ۶۸/۲۷ درصد اطلاعات توزیع در محدوده فاصله انحراف معیار از مقدار میانگین پراکنده شده است. از آنجایی که بیشتر اطلاعات در محدوده انحراف معیار از میانگین واقع شده است منطقی خواهد بود که این بخش برای محدوده قابل قبول نرخ آتش پذیرفته شود. به این معنی که اگر نرخ آتش در محدوده انحراف معیار از مقدار میانگین قرار بگیرد با احتمال بالایی تحریک مورد نظر برای این نورون مهم بوده است، در حالی که اگر نرخ آتش فعلی در خارج از این محدوده باشد این رفتار به تحریک دیگری شباهت داشته است و یا نویز و خطای ناشی از مراحل قبلی از جمله مرتب‌سازی اسپایک است. به این ترتیب با تمرکز بر این که آیا نرخ آتش در محدوده تحت بررسی بوده است یا خیر، علاوه بر تعیین میزان اهمیت نورون به تحریک تحت مطالعه، روش در برابر نویز و خطای مراحل پیش پردازش قبلی نیز مقاوم خواهد شد که ویژگی ارزشمندی برای روش پیشنهادی است.


^۱ Standard deviation



شکل ۴: سهم پراکندگی توزیع در یک توزیع نرمال

۳-۲ روش مقایسه

برای مقایسه نرخ آتش فعلی با تحریک‌های مشخص از روشی مشابه رویکرد محاسبات ابر بعدی استفاده می‌شود. در این روش ابتدا برداری صفر و یک با بعدی مشخص تولید می‌شود که در گام بعد با بردار خروجی‌های تعریف شده که خود نیز صفر و یک هستند مقایسه می‌شوند. برابری هر عنصر از بردارها باید با عنصر متناظر خود در بردار دیگر مقایسه شود. اگر مقدار آنها یکسان بود خروجی تحت بررسی یک امتیاز مثبت بدست می‌آورد و اگر برابر نباشد خروجی مورد نظر امتیازی نمی‌گیرد. در نهایت پس از بررسی همه بردارهای خروجی تعریف شده، خروجی به عنوان پاسخ نهایی معرفی می‌شود که بیشترین امتیاز را به دست آورده است. از طرفی دیگر طبق بررسی انجام شده در پژوهش [۲۰] در نظر گرفتن اطلاعات نرخ آتش مربوط به گذشته علاوه بر نرخ آتش فعلی موجب افزایش دقت فرآیند رمزگشایی می‌شود. این بهبود به دلیل دخالت اطلاعات زمانی در الگوریتم است که مشابه رویکرد RNN است. بنابراین یک بردار مشابه آنچه در شکل ۵ نشان داده شده است بکار گرفته می‌شود که در آن همه نرخ‌های آتش متوالی قبلی در کنار نرخ آتش فعلی بکار گرفته شده‌اند. بنابراین برداری با ابعاد $N \times B$ ایجاد می‌شود که در آن N تعداد نورون‌ها و B تعداد پنجره‌های محاسبه نرخ آتش که به آن Bin گفته می‌شود خواهد بود.



شکل ۵: فرآیند تبدیل نرخ آتشی متوالی به بردار صفر و یک و تشخیص


خروجی نهایی

در این فرآیند با بررسی بردار ورودی مشخص می‌شود که الگوری نرخ آتش آن با کدام فضای خروجی از قبل مشخص شده بیشترین شباهت را دارد. بنابراین در این رویکرد ابتدا هر نرخ آتش در هر لحظه برای هر نورون بررسی می‌شود که آیا در در محدوده از قبل مشخص شده قرار دارد یا خیر. اگر در این حالت آن پنجره در نرخ مورد نظر قرار داشت این شباهت به مقدار یک در بردار صفر و یک نگاشت داده می‌شود و اگر در محدوده نبود به مقدار صفر تبدیل می‌شود. بنابراین از آنجایی که برای بانک داده

معرفی شده ۸ تحریک (۸ زاویه) وجود داشت، ۸ بردار با ابعاد $N \times B$ بدست می‌آید. از آنجایی که مقدار آستانه هر زاویه تحریک برای آن خروجی بهینه شده بود و بر اساس آن مقدار صفر و یک‌ها مشخص می‌شد، بردار ایده‌آلی که بیشترین تطابق را با آن تحریک داشته باشد همه اعضای آن یک خواهد بود. این ویژگی مهم موجب حذف بردار مقایسه دیگری می‌شود که مشابه رویکرد محاسبات ابر بعدی مقدار شباهت را محاسبه کند. بنابراین در این روش خروجی نهایی آن تحریکی برگزیده خواهد بود که بیشترین مقدار یک را بدست آورده است.

برای درک راحت‌تر روش پیشنهادی، روندنمای مراحل آموزش و ارزیابی در شکل ۶ نمایش شده است.

همان‌گونه که در این شکل مشاهده می‌شود، رویکرد پیشنهادی، نیازی به یک فرآیند آموزش پیچیده ندارد. فرآیند آموزش تنها محدود به مشخص کردن مقادیر بهینه برای طول پنجره محاسبه نرخ آتش و تعداد Bin ها به همراه مقادیر میانگین و انحراف معیار برای هر لحظه، نورون و خروجی‌های مشخص طبق روند توضیح داده شده از قبل است. روند تعیین مقدار میانگین و انحراف معیار قبلاً توضیح داده شد و در ادامه روند مشخص کردن مقادیر بهینه طول پنجره نرخ آتش و تعداد آنها در ادامه تشریح می‌شود.



شکل ۶: روند نمای فرآیند آموزش و رمزگشایی رویکرد پیشنهادی


برای انتخاب متغیرهای بهینه می‌توان به دو روش مختلف اقدام نمود. در روش اول مشابه روش ارائه شده در [۲۰] ابتدا یکی از متغیرها بر اساس ملاحظات مساله و پیچیدگی محاسباتی مقدار منطقی انتخاب شود و سپس مقدار دیگر در محدوده‌ای مناسب که از نظر کاربر منطقی است تغییر کند تا مشخص شود در چه حالتی بیشترین دقت بدست می‌آید. در گام بعد با مقدار بهینه شده جدید به شکلی مشابه روند مشخص شدن بیشترین دقت بدست آمده برای متغیر اولی که با آن مقدار بهینه دوم بدست آورده بود تکرار گردد. اگرچه این رویکرد می‌تواند به بهینه شدن متغیرها کمک کند و اثر بخش باشد ولی مقدار نهایی متغیرها به مقدار اولیه انتخاب شده وابسته خواهد بود و در واقع فرآیند بهینه‌سازی حول آن مقدار انجام می‌شود. این در حالی است که در رویکرد دوم اگر تاثیر تغییر همزمان دو متغیر بر روی

پس از آنکه برای بانک داده شرح داده شده مقادیر بهینه طول پنجره نرخ آتش، تعداد نرخ‌های آتش پشت سر هم و مقدار میانگین و انحراف معیار برای هر نورون در هر لحظه و هر تحریک مشخص شد، الگوریتم تکمیل شده و آماده پیاده‌سازی است. در ادامه پیاده‌سازی سخت‌افزاری الگوریتم پیشنهادی ارائه می‌شود.

۴- پیاده‌سازی سخت‌افزاری

جهت دستیابی به یک سیستم رابط مغز و ماشین بهینه، ضروری است که علاوه بر دقت معیارهای دیگری شامل توان مصرفی و سخت‌افزار مورد نیاز هم مد نظر قرار گیرد. از طرفی دیگر پیاده‌سازی سخت‌افزاری یک الگوریتم امکان پردازش بلادرنگ را ممکن می‌سازد که خود ویژگی مهمی برای یک سیستم رابط مغز و ماشین به حساب می‌آید. بنابراین در این بخش معماری سخت‌افزاری برای رمزگشایی رویکرد پیشنهادی ارائه می‌شود. برای این هدف ابتدا سیستم به شکل کلی توضیح داده شده و سپس هر بخش آن با جزئیات بررسی می‌گردد.

در تصویر ۸ سخت‌افزار پیشنهادی برای رمزگشایی مورد نظر ترسیم شده است. در این سیستم اسپایک تشخیص داده شده ۳۲ نورون به وسیله ورودی neuron fire به طراحی اعلام می‌شود. این ورودی برای شمارش نرخ آتش‌ها در بلوک محاسبه گر نرخ آتش استفاده خواهد شد. به کمک ورودی merging value این بلوک شمارش خود را مجدداً صفر خواهد کرد تا به این شکل قادر باشد برای در نظر گرفتن اطلاعات زمانی، نرخ‌های آتش متوالی دیگر را نیز محاسبه کند. پس از آنکه تعداد Time bin آتش پشت هم بدست آمد تعداد نرخ آتش بدست آمده برای هر نورون در طول زمان برای پردازش و تشخیص یکی از زاویه‌های ۸ گانه به واحد محاسبه هر کلاس تحویل داده می‌شود. بر اساس نرخ تشابه ورودی جدید با هر یک از کلاس‌های تعریف شده امتیازی به هر کلاس داده می‌شود. در انتها در واحد تصمیم‌گیری کلاس با بیشترین امتیاز به عنوان پاسخ نهایی به واحد ثبات خروجی تحویل داده می‌شود. در فرآیند آغاز به کار سیستم برای انبارش هر یک از مقادیر محدوده پذیرش نورون، تحریک در زمان‌های مختلف مقادیر آستانه از طریق ورودی initial values به حافظه‌های داخلی واحد محاسبه هر کلاس ورود کرده و سیستم به کمک ورودی initial mode از این فرآیند مطلع خواهد شد. واحد کنترل و زمانبندی مسئولیت زمانبندی کارکردن واحدهای مختلف بر اساس ورودی‌های مختلف از جمله CLK را بر عهده دارد.




شکل ۸: پیاده‌سازی سخت‌افزاری برای رمزگشایی پیشنهادی

در تصویر ۸، هشت واحد محاسبه هر کلاس رویت می‌شود که مأمور محاسبه امتیاز هر یک از کلاس‌های هشت گانه هستند. جزئیات هر یک از این واحدها در شکل ۹ ترسیم شده است. در این طراحی از یک RAM برای ذخیره مقادیر محدوده مربوط به هر نورون در هر لحظه در نظر گرفته


بیشترین دقت بدست آمده بررسی گردد، این مساله رخ نداده و مقدار بهینه برای رویکرد بدست خواهد آمد. بنابراین مشابه آنچه در شکل ۷ نشان داده شده است، دو متغیر مورد نظر در محدوده‌ای منطقی که از لحاظ فیزیکی مساله و پیچیدگی پیاده‌سازی سخت‌افزاری مناسب به نظر می‌رسد تغییر کرده‌اند. در این نمودار بیشینه دقت بدست آمده در لحظه نشان دادن هدف به میمون ملاک بررسی قرار گرفته شده است و نمودار آن به شکل زیر است.

تأثیر متغیرهای مختلف بر روی دقت رویکرد پیشنهادی



شکل ۷: بیشترین دقت بدست آمده در صورت تغییر متغیرهای طول محاسبه پنجره آتش و تعداد نرخ‌های آتش متوالی در فرآیند رمزگشایی روش پیشنهادی

در شکل ۷، رنگ‌های سرد (مانند آبی) به معنی دقت کمتر رویکرد در آن ناحیه از تغییر متغیرها و رنگ‌های گرم (مانند زرد) نماینده دقت بیشتر رویکرد در آن ناحیه از بررسی‌ها خواهد بود. بررسی شکل ۷ نشان دهنده دو واقعیت مهم است. اول آنکه افزایش تعداد Bin ها تا ۸ عدد پشت سر هم موجب افزایش دقت سیستم می‌شود که پس از آن تقریباً به مقدار اشباع خود می‌رسد. این مورد به این معنی است که تعداد ۸ نرخ آتش متوالی به اندازه کافی حاوی اطلاعات زمانی است که بتوان به کمک آنها به یک فرآیند رمزگشایی دقیق رسید. از آنجایی که پذیرش تعداد بیشتری Bin های متوالی موجب ذخیره شدن محدوده بیشتر تعداد نرخ آتش در حافظه و در نتیجه مقدار RAM بزرگتر در آن می‌شود که خود موجب افزایش اندازه سخت‌افزار و توان مصرفی آن می‌گردد، منطقی خواهد بود که کمینه مقدار Bin های متوالی که در آن بیشترین دقت بدست آمده است به عنوان مقدار بهینه انتخاب شود. بنابراین برای این بانک داده، مقدار بهینه Bin های متوالی ۸ خواهد بود. از طرفی دیگر بررسی طول پنجره محاسبه نرخ آتش نشان می‌دهد وقتی که طول پنجره انتخاب شده کوچک باشد، اطلاعات موجود به اندازه‌ای نخواهد بود که بتوان تفاوت بین حالت‌های مختلف خروجی را از هم تشخیص داد. این مساله از آنجایی سرچشمه می‌گیرد که وقتی طول پنجره بسیار کوچک باشد، الگوریتم پیشنهادی قادر نخواهد بود در بین تحریک‌های مختلف تفاوت را درک کرده و آنها را از هم جدا کند بنابراین دقت در طول پنجره‌های باریک کم خواهد بود. از طرفی افزایش طول پنجره تا مقداری در حدود ۳۸ میلی‌ثانیه باعث افزایش دقت می‌شود اما بعد از آن تقریباً ثابت می‌ماند. از آنجایی که طول پنجره بیشتر منجر به نرخ آتش بزرگ‌تر و در نتیجه حافظه بزرگتر خواهد شد، پس منطقی خواهد بود که مقدار ۳۸ میلی‌ثانیه برای بانک داده به عنوان مقدار بهینه برای متغیر طول پنجره محاسبه نرخ آتش انتخاب گردد.




شکل ۱۰: نتایج دقت رمزگشایی برای الف) روش‌های غیر بازگشتی، ب)

روش‌های بازگشتی و ج) روش‌های مبتنی بر پردازش ورودی صفر و یک

همانطور که در شکل ۱۰ بخش الف مشخص است، تقریباً دقت روش‌های غیربازگشتی در یک محدوده قرار دارد هرچند که در این بین فیلتر وینر بیشترین دقت را به خود اختصاص داده است. ظاهر دو کوهان نتایج به دلیل ذات آزمایش است که کوهان اول آن مربوط به زمانی است که هدف برای اولین بار به میمون نشان داده شده است و کوهان دوم نتیجه زمانی است که میمون به هدف مورد نظر نگاه کرده است. از طرفی دیگر با بررسی بیشتر نمودار در بخش ب درک می‌گردد که عموماً روش‌های بازگشتی دقت بیشتری نسبت به روش‌های غیربازگشتی ارائه کرده‌اند. این مساله از آنجایی نشأت می‌گیرد که در این روش‌ها به دلیل در نظر گرفتن نرخ آتش‌های متوالی اطلاعات زمانی نیز در نظر گرفته شده و شبکه عصبی قادر است مدل دقیق‌تری از پدیده را ایجاد و رمزگشایی کند. این توانایی با میزان پیچیدگی معماری و محاسبات این شبکه‌ها رابطه‌ای مستقیم دارد به شکلی که این روند در شبکه عصبی LSTM به بیشترین مقدار خود می‌رسد. در نهایت نتایج روش پیشنهادی در این مقاله با روش ارائه شده در پژوهش [۲۰] که در آن هم از ورودی‌های صفر و یک برای رمزگشایی استفاده می‌شود در بخش ج مقایسه شده است. همانطور که مشاهده می‌شود روش دیگر از دقت بیشتری برخوردار است. دلیل این مساله این است که در روش دیگر اهمیت نوروها به کمک الگوریتم SVM در روند محاسبات متفاوت در نظر گرفته می‌شود حال اینکه در روش پیشنهادی این پژوهش شباهت و تفاوت همه نوروها با الگوهای مشخص اهمیت یکسان دارند. بنابراین بر اساس این ارزیابی روش‌های غیربازگشتی به عنوان

شده است. فعالیت این حافظه به وسیله ورودی‌هایی مانند Initial mode، enable، initial values و CLK کنترل می‌شود. برای کاهش تعداد ورودی‌ها کلیه حافظه‌ها از طریق یک ترمینال initial values مشترک ورودی خود را می‌پذیرند و برای انتخاب شدن هر یک از آنها از ورودی enable استفاده شده است. زمانی که همه RAMها با مقدار آستانه مورد نظر خود پر شدند، مقایسه‌کننده و شمارنده موجود در این واحد تصمیم خواهند گرفت که چه تعداد از نرخ آتش‌ها با الگوی از قبل بار شده یکسان هستند. این اعداد به عنوان ورودی برای انبار خواهند بود که قادر خواهد بود امتیاز کل کلاس را در طول زمان ورودی time bin محاسبه کند. پس از محاسبه امتیاز کلاس در طول تعداد time bin نرخ آتش این بخش به مقدار صفر بازنشانی می‌شود تا خود را برای رمزگشایی بعدی آماده کند. سادگی معماری پیشنهادی کاملاً واضح است. حداقل سخت‌افزار لازم به همراه کمترین مقدار RAM موجب یک طراحی بهینه از نظر توان مصرفی، پیچیدگی محاسباتی و حجم سخت‌افزار مورد نظر خواهد شد. برتری و سود ویژگی‌های یاد شده به وسیله ارزیابی‌های مختلف نسبت به سایر رویکردها نشان داده خواهد شد.



شکل ۹: سخت‌افزار پیاده‌سازی شده برای هر کلاس

۵- نتایج ارزیابی و بررسی‌ها

تا کنون اقدامات انجام شده برای کاهش حجم محاسبات، حذف مدل ریاضی و چگونگی توانایی مدل در تشخیص الگوی تغییرات زمانی تشریح شد. در این بخش جهت بررسی ادعاهای گفته شده عملکرد روش در مقابل سایر روش‌های رایج مورد ارزیابی قرار می‌گیرد. با توجه به اینکه نوع بانک داده شرح داده شده خاص بوده و می‌تواند در یک ارزیابی عادلانه نقش داشته باشد، نتایج خروجی علاوه بر روش پیشنهادی باید برای سایر روش‌ها و این بانک داده نیز استخراج و تحلیل شود. به همین دلیل شبیه‌سازی متعددی برای روش‌های غیربازگشتی شامل فیلتر وینر، فیلتر وینر آبخاری، SVM با کرنل خطی و شبکه عصبی پیشخور در کنار شبکه‌های بازگشتی LSTM [۴۹]، Elman [۴۹] و GRU [۵۰] انجام خواهد شد. برای یک ارزیابی عادلانه کلیه متغیرهای روش‌های اشاره شده مشابه روش پیشنهادی با مقدار بهینه خود انتخاب شده‌اند. برای این هدف برای روش‌های غیربازگشتی طول پنجره محاسبه نرخ آتش ۳۵ میلی ثانیه و برای روش‌های بازگشتی علاوه بر نرخ آتش زمان فعلی نرخ آتش مربوط به ۸ مرحله گذشته نیز در روند محاسبات در نظر گرفته شده است. به این ترتیب بیشترین دقت با حجم محاسبات منطقی مشابه روش پیشنهادی در ارزیابی‌ها در نظر گرفته شده است. لازم به توجه است که کمیت‌های انتخاب شده برای بهترین حجم محاسبات و بیشترین دقت در نظر گرفته شده‌اند. در شکل ۱۰ نتایج مربوط به روش‌های مختلف نمایش داده شده است.

روش‌ها	تعداد جمع‌ها	تعداد ضرب‌ها	تعداد توابع غیرخطی	بیشینه دقت تخمین
فیلتر وینر	۲۵۰	۲۵۰	۰	۵۰/۴٪
SVM خطی	۲۵۰	۲۵۰	۰	۴۲/۳٪
شبکه عصبی پیشخور	۱۶۰۰۰	۱۶۰۰۰	۴۰۰	۴۷/۲٪
ELMAN	۱۷۶۰۰۰	۱۷۶۰۰۰	۴۰۰	۵۳/۹٪
LSTM	۶۹۵۰۰۰	۶۹۵۰۰۰	۲۰۰۰	۶۱٪
[۲۰]	۴۵۰۰	۰	۰	۶۲٪
روش پیشنهادی	۲۰۵۰	۰	۰	۵۱/۴٪

پیچیدگی محاسباتی می‌تواند مشابه اطلاعات جمع‌آوری شده در جدول ۲ به شکل دیگری نیز مقایسه شود. در پژوهش‌های زیادی الگوریتم پیشنهاد شده به صورت FPGA پیاده‌سازی می‌شود تا بتوان از توان و ابعاد کمتر آن سود برد. بنابراین برای آنکه بتوان از این جهت نیز پیچیدگی محاسباتی روش‌ها را مقایسه کرد روش‌های مختلف از نظر منابع مورد نیاز برای پیاده سازی FPGA در جدول ۲ مقایسه شده اند.

جدول ۲: منابع مورد نیاز برای پیاده‌سازی FPGA

روش‌ها	پژوهش		رویکرد پیشنهادی
	[۵۲]	[۲۰]	
	شبکه عصبی پیشخور	SVM	
Blocks of RAMs	140 Kbytes	5.6 Kbytes	2.3 Kbytes
DSP48E	234	2	0
LUT	26,855	1,877	9,781
LUT-FF pairs	10,735	684	3,925
Slice registers	19,423	728	3,013

در جدول ۲ نتایج سنتز معماری‌ها به کمک Xilinx ISE 14.7 بر روی Virtex5 vsx50 گزارش شده است. بر اساس نتایج قابل ملاحظه روش پیشنهادی در این پژوهش نیاز به حافظه کمتری در مقایسه با سایر روش‌ها دارد. این برتری از آنجایی منشا می‌گیرد که در روش پیشنهادی به مدل ریاضی و در نتیجه متغیرهای مدل ریاضی نیازی ندارد. بجای آن روش پیشنهادی تنها از یک مقایسه کننده استفاده می‌کند که نیاز دارد بررسی کند که آیا نرخ آتش فعلی بین دو عدد صحیح قرار دارد یا خیر که نیازمند پیچیدگی محاسباتی و ذخیره داده بسیار کمتری است. از طرفی دیگر سایر روش‌ها برای انجام محاسبات ریاضی و مدل خود نیاز به ضرایب و متغیرهای بسیار بیشتری دارند تا بتوانند خروجی رمزگشایی خود را محاسبه کنند. این مورد در روش شبکه عصبی پیشخور بسیار شدیدتر دیده می‌شود

روش‌هایی با دقت پایین، روش‌های بازگشتی به عنوان روش‌های با دقت بالا و روش پیشنهادی این پژوهش به عنوان یک روش میان‌رده از نظر دقت طبقه‌بندی می‌شود.

در یک سیستم رابط مغز و ماشین علاوه بر دقت پیچیدگی محاسباتی نیز اهمیت دارد. امکان پیاده‌سازی سخت‌افزاری یک الگوریتم به صورت یک FPGA یا یک مدار مجتمع خاص منظوره (ASIC) می‌تواند ویژگی‌هایی چون پردازش بلادرنگ را علاوه بر راه‌حلی بهینه از جهت توان و اندازه را مهیا کند. در این بخش از ارزیابی، کلیه کمیت‌هایی که برای یک پیاده‌سازی سخت‌افزاری مهم است بررسی خواهد شد. کمیت‌های کلیدی مانند تعداد جمع‌کننده، ضرب‌کننده و توابع غیر خطی در یک پیاده‌سازی سخت‌افزاری نقش مهمی بازی می‌کنند. از این رو در جدول ۱ این کمیت‌ها برای روش‌های مختلف با هم مقایسه شده اند. از بین روش‌های غیربازگشتی روش فیلتر وینر، شبکه عصبی پیشخور و SVM به ترتیب به عنوان دقیق‌ترین، میانه‌رده و دارای کمترین دقت انتخاب شده‌اند. به شکلی مشابه شبکه عصبی Elman و LSTM هم به عنوان پایین‌ترین دقت و بیشترین دقت روش‌های بازگشتی مورد بررسی قرار خواهند گرفت. در نهایت از آنجایی که روش ارائه شده در [۲۰] از ورودی مشابه صفر و یک پیشنهادی در این مقاله استفاده می‌کند به عنوان نماینده این دسته از روش‌ها در جدول ۱ قرار گرفته است.

بررسی جدول ۱ نشان دهنده تفاوت بسیار چشمگیر منابع مصرفی روش‌های بازگشتی با دیگر روش‌ها است و این در حالی است که بیشترین دقت عموماً با این روش‌ها بدست آمده است. به عنوان مثال روش LSTM تقریباً ۴۰۰ برابر روش پیشنهادی این مقاله جمع‌کننده نیاز دارد درحالی که دقت آن تنها ۱۰ درصد بیشتر است. بنابراین روش‌های بازگشتی تنها زمانی توصیه می‌شوند که بیشترین دقت رمزگشایی نیاز است و حجم پیچیدگی محاسبات مساله مهمی نیست. بنابراین از بین روش‌های بازگشتی روش ارائه شده در [۲۰] با بیشترین دقت به عنوان یک روش با دقت بیشینه برای چنین شرایطی پیشنهاد می‌شود که دقت رمزگشایی یکسانی در مقایسه با سایر روش‌های بازگشتی دارد. با توجه به دقت مشابه روش‌های غیربازگشتی و روش پیشنهادی در این مقاله یک بررسی دقیق‌تر بین این دو دسته ضروری به نظر می‌رسد. اگرچه روش پیشنهاد شده در این مقاله از جمع‌کننده‌های بیشتری در مقایسه با سایر روش‌های غیربازگشتی استفاده می‌کند ولی این روش به هیچ ضرب‌کننده‌ای نیاز ندارد. در پیاده‌سازی سخت‌افزاری یک ضرب‌کننده به منابع بیشتری در مقایسه با یک جمع‌کننده نیاز دارد. به عنوان مثال در [۵۱] نشان داده شده است که هر ضرب‌کننده به اندازه ۱۰ جمع‌کننده پیچیدگی محاسباتی به سخت‌افزار اضافه می‌کند. بنابراین نه تنها روش پیشنهادی از فیلتر وینر به عنوان دقیق‌ترین روش غیربازگشتی دقیق‌تر است بلکه پیچیدگی محاسباتی کمتری داشته و برای پیاده‌سازی سخت‌افزاری به منابع کمتری نیاز دارد.

جدول ۱: پیچیدگی محاسباتی روش‌های مختلف

الگوریتم همچنان امکان یک رمزگشایی دقیق با یک مقدار میانگین و انحراف معیار حدودی نیز میسر است. بنابراین روش پیشنهادی حتی در شرایطی که بانک داده حجیمی در اختیار نیست دقیق و کارآمد خواهد بود.

۶- نتیجه‌گیری

در این پژوهش یک رویکرد جدید که برای پیاده‌سازی سخت‌افزاری بهینه شده بود تا بتواند برای یک سیستم رابط مغز و ماشین قابل کاشت در بدن استفاده شود معرفی شد. این رویکرد از روش‌های رایج الهام گرفته و از نرخ آتش به عنوان ورودی استفاده می‌کند ولی با تغییراتی آنها را به سبک روش محاسبات ابر بعدی پردازش می‌کند. بر اساس بررسی روش‌های مختلف، مشخص گردید که بیشتر آنها از یک مدل ریاضی برای تشخیص تفاوت حالت‌های مختلف از هم استفاده می‌کنند و به کمک این تفاوت‌ها تلاش می‌کنند خروجی را محاسبه کنند. در مسیری متفاوت روش پیشنهادی در این پژوهش از یک مقایسه تجمعی نرخ آتش برای هدف رمزگشایی استفاده کرده است. این رویکرد از ویژگی‌های زیادی مانند الگوریتم ساده‌تر، کاهش حافظه لازم برای ذخیره کمیت‌ها و نیاز به حجم بانک داده آموزش کمتر سود برده و یک رمزگشا با دقتی متوسط در اختیار کاربر خود قرار می‌دهد. از آنجایی که کلیه محاسبات بر اساس مقادیر صفر و یک است این الگوریتم برای پیاده‌سازی سخت‌افزاری یک گزینه بسیار مناسب است.


بر اساس ارزیابی‌های انجام شده منطقی به نظر می‌رسد برای زمان‌هایی که یک روش با دقت بالا نیاز است از الگوریتمی مشابه [۲۰] استفاده شود که اگرچه دقت بالایی را فراهم می‌کند ولی دقت آن در مقابل حجم محاسباتی روش‌های دیگر مانند LSTM کمتر است. در شرایطی که حجم پیچیدگی محاسباتی یک نکته مهم برای کاربر است و حجم بانک داده بالایی در اختیار نیست و به روشی با دقت متوسط نیاز است روش پیشنهادی به عنوان یک انتخاب بهینه توصیه می‌شود. در روش پیشنهادی ارزش کلیه نرخ‌های آتش برای همه زمان‌ها و تحریک‌ها یکسان است. این در حالی است که همه نورون‌ها به همه تحریک‌ها به یک شدت عکس العمل نشان نمی‌دهند. مطلوب است که این تفاوت رفتاری بین نورون‌های مختلف تشخیص داده شده و در فرآیند محاسبات و امتیازدهی در نظر گرفته شود. برای این هدف می‌توان از روشی مشابه SVM استفاده نمود به این ترتیب می‌توان از دقتی مشابه [۲۰] بهره برد ولی برتری‌هایی مانند نیاز به بانک داده کم را نیز در اختیار داشت.

۷- سپاس‌گزاری

نویسندگان این مقاله از آقای بهروز نودوست به دلیل فراهم کردن بانک داده واقعی که برای ارزیابی و بررسی روش‌ها نقش کلیدی داشت تشکر می‌کنند.

که باید برای پیاده‌سازی شبکه عصبی ضرایب بسیار زیادی استفاده و با هم جمع و ضرب شوند.

فرآیند آموزش نقش مهمی در الگوریتم‌های یادگیری ماشین بازی می‌کند. یکی از نکات مهم در فرآیند آموزش حجم بانک داده مورد نیاز برای این مرحله است که به کمک آن مقادیر متغیرها و ضرایب مشخص می‌شود. به عنوان مثال به دلیل پیچیدگی ذاتی بیشتر روش LSTM این روش در مقایسه با روش فیلتر وینر به حجم بانک داده آموزش حساس‌تر خواهد بود. بنابراین در این مقاله علاوه بر روش پیشنهادی تأثیر کاهش حجم بانک داده آموزش بر روی فیلتر وینر و LSTM به عنوان دقیق‌ترین روش‌های غیر بازگشتی و بازگشتی بررسی شده است. نتایج این بررسی در شرایط مختلف در شکل ۱۱ نشان داده شده است.



شکل ۱۱: نتایج کاهش حجم داده آموزش برای الف) فیلتر وینر، ب) LSTM و ج) روش پیشنهادی

بررسی‌ها نشان می‌دهد همانطور که پیش‌بینی می‌شد روش LSTM به دلیل پیچیدگی معماری و ضرایب بیشتر، بیشترین حساسیت به کاهش حجم بانک داده را نشان می‌دهد. از طرفی دیگر فیلتر وینر به دلیل ساختار ساده‌تر در مقابل این تغییرات مقاوم‌تر است. این در حالی است که روش پیشنهادی در این مقاله بیشترین پایداری را در مقایسه با سایر روش‌ها از خود نشان می‌دهد، چون این روش هیچ مدل ریاضی و ضریبی نیاز ندارد و تنها پردازش خود را بر اساس یک سیستم امتیاز بندی و مقایسه انجام می‌دهد. اگرچه در روش پیشنهادی حجم بانک داده بیشتر منجر به محاسبه مقدار میانگین و انحراف معیار دقیق‌تر می‌گردد ولی به دلیل نوع پردازش این

مراجع

- [11]. Sui Y, Yu H, Zhang C, Chen Y, Jiang C, Li L., "Deep brain-machine interfaces: sensing and modulating the human deep brain," *National Science Review*, vol. 9, no. 10, October 2022.
- [12]. Syrov N, Yakovlev L, Nikolaeva V, Kaplan A, Lebedev M. "Mental Strategies in a P300-BCI: Visuomotor Transformation Is an Option. " *Diagnostics.*, vol. 12, no. 11, 2022 Oct 27.
- [13]. Zhang Z, Constandinou TG., "Firing-rate-modulated spike detection and neural decoding co-design." *Journal of Neural Engineering*, vol. 20, no. 3, 2023.
- [14]. Kim KH, Kim SJ., "Neural spike sorting under nearly 0-db signal-to-noise ratio using nonlinear energy operator and artificial neural-network classifier." *IEEE Transactions on Biomedical Engineering*, vol. 47, no. 10, pp. 1406–1411, 2000.
- [15]. Okreghe CO, Zamani M, Demosthenous A., "A Deep Neural Network-Based Spike Sorting with Improved Channel Selection and Artefact Removal," *IEEE Access*, vol. 11, pp. 15131–15143, doi: 10.1109/ACCESS.2023.3242643, 2023
- [16]. Kalantari F, Hosseini-Nejad H, Sodagar AM., "Hardware-Efficient, On-the-Fly, On-Implant Spike Sorter Dedicated to Brain-Implantable Microsystems," *IEEE Transactions on Very Large Scale Integration (VLSI) Systems*, vol. 30, no. 8, pp. 1098–1106, doi: 10.1109/TVLSI.2022.3170596, Aug. 2022
- [17]. Soleymankhani A, Shalchyan V. , "A new spike sorting algorithm based on continuous wavelet transform and investigating its effect on improving neural decoding accuracy." *Neuroscience*, vol. 468, pp. 139–48, 2021 Aug 1.
- [18]. Sukiban J, Voges N, Dembek TA, Pauli R, Visser-Vandewalle V, Denker M, Weber I, Timmermann L, Grün S., "Evaluation of spike sorting algorithms: application to human subthalamic nucleus recordings and simulations." *Neuroscience.*, vol. 414, pp. 168–85, 2019 Aug 21.
- [19]. Dong Y, Hu D, Wang S, He J., "Decoder calibration framework for intracortical brain-computer interface system via domain adaptation." *Biomedical Signal Processing and Control.*, vol. 81, 2023.
- [20]. Katoozian D, Hosseini-Nejad H, Abolghasemi Dehaqani MR, Shoeibi A, Manuel Gorriz J., "A hardware efficient intra-cortical neural decoding approach based on spike train temporal information." *Integrated Computer-Aided Engineering*, (Preprint):1–5, 2022.
- [21]. Chen Y, Yao E, Basu A., "A 128-Channel Extreme Learning Machine-Based Neural Decoder for Brain Machine Interfaces." *IEEE Transactions on*
- [1]. Shaikh S, So R, Sibindi T, Libedinsky C, Basu A., "Towards Intelligent Intracortical BMI (i2BMI): Low-Power Neuromorphic Decoders That Outperform Kalman Filters," *IEEE Transactions on Biomedical Circuits and Systems*, vol. 13, no. 6, pp. 1615–1624, Dec. 2019. doi: 10.1109/TBCAS.2019.2944486.
- [2]. Armour BS, Courtney-Long EA, Fox MH, Fredine H, Cahill A., "Prevalence and causes of paralysis-United States, 2013," *American journal of public health*, vol. 106, no. 10, pp. 1855–1857, 2016.
- [3]. Shen X, Zhang X, Huang Y, Chen S, Yu Z, Wang Y., "Intermediate Sensory Feedback Assisted Multi-Step Neural Decoding for Reinforcement Learning Based Brain-Machine Interfaces," *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 30, pp. 2834–2844, doi: 10.1109/TNSRE.2022.3210700, 2022.
- [4]. García-Murillo DG, Álvarez-Meza AM, Castellanos-Dominguez CG. "KCS-FCnet: Kernel Cross-Spectral Functional Connectivity Network for EEG-Based Motor Imagery Classification" *Diagnostics*, vol. 13, no. 6, 2023 Mar 16.
- [5]. Birbaumer N, Ghanayim N, Hinterberger T, Iversen I, Kotchoubey B, Kübler A, Perelmouter J, Taub E, Flor H., "A spelling device for the paralyzed," *Nature*, vol. 398, no. 6725, pp. 297–298, 1999.
- [6]. Perdakis S, Leeb R, Williamson J, Ramsay A, Tavella M, Desideri L, Hoogerwerf EJ, Al-Khodairy A, Murray-Smith R, d R Millán J., "Clinical evaluation of BrainTree, a motor imagery hybrid BCI speller," *Journal of neural engineering*, vol. 11, no. 3, 2014.
- [7]. Collinger JL, Wodlinger B, Downey JE, Wang W, Tyler-Kabara EC, Weber DJ, McMorland AJ, Velliste M, Boninger ML, Schwartz AB., "High-performance neuroprosthetic control by an individual with tetraplegia," *The Lancet*, vol. 381, no. 9866, pp. 557–564, 2013.
- [8]. Galán F, Nuttin M, Lew E, Ferrez PW, Vanacker G, Philips J, Millán JD., "A brain-actuated wheelchair: Asynchronous and non-invasive Brain-computer interfaces for continuous control of robots," *Clinical neurophysiology*, vol. 119, no. 9, pp. 2159–2169, 2008.
- [9]. Leeb R, Tonin L, Rohm M, Desideri L, Carlson T, Millan JD. "Towards independence: A BCI telepresence robot for people with severe motor disabilities," *Proceedings of the IEEE*, vol. 103, no. 6, pp. 969–982, 2015.
- [10] Sharma R, Kim M, Gupta A., "Motor imagery classification in brain-machine interface with machine learning algorithms: Classical approach to multi-layer perceptron model." *Biomedical Signal Processing and Control*, vol. 71, 2022.

- biomedical circuits and Systems*, vol. 10, no. 3, pp. 679–692, 2015.
- [22]. Dayan P, Abbott LF. "Theoretical Neuroscience: Computational and Mathematical Modeling of Neural Systems." *MIT press*; 2005 Aug 12.
- [23]. Rieke F, Warland D, Van Steveninck RD, Bialek W. "Spikes: Exploring the Neural Code." *MIT press*; 1999 Jul 26.
- [24]. Pan H, Mi W, Lei X, Zhong W. "A closed-loop BMI system design based on the improved SJIT model and the network of Izhikevich neurons." *Neurocomputing*, vol. 401, pp. 271-280. 2020.
- [25]. Ahmadi N, Constandinou TG, Bouganis CS., "Robust and accurate decoding of hand kinematics from entire spiking activity using deep learning." *Journal of Neural Engineering*, vol. 18, no. 2, 2021.
- [26]. Wu H, Feng J, Zeng Y. "Neural Decoding for Macaque's Finger Position: Convolutional Space Model." *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 27, no. 3, pp. 543-551, 2019.
- [27]. Pan H, Mi W, Lei X, Deng J. "A closed-loop brain-machine interface framework design for motor rehabilitation." *Biomedical Signal Processing and Control*, vol. 58, 2020.
- [28]. Dehaqani MR, Vahabie AH, Parsa M, Noudoost B, Soltani A., "Selective Changes in Noise Correlations Contribute to an Enhanced Representation of Saccadic Targets in Prefrontal Neuronal Ensembles." *Cereb Cortex*, vol. 28, no. 8, pp. 3046–3063, 2018.
- [29]. Li C, Zhang Y, Wang T, Xu X, Wang Q, Xu B, Cui H., "Generative Decoding of Intracortical Neuronal Signals for Online Control of Robotic Arm to Intercept Moving Objects," *Journal of Physics: Conference Series*, vol. 576, no. 1. IOP Publishing, 2020.
- [30]. Li C, Wang T, Zhang Y, Xu X, Wang Q, Zheng R, Cui H., "Serial Decoding of Macaque Intracortical Activity for Feedforward Control of Coherent Sequential Reach." *2021 10th International IEEE/EMBS Conference on Neural Engineering*, pp. 49-52, 2021.
- [31]. Baggenstoss PM. "On the Duality Between Belief Networks and Feed-Forward Neural Networks." *IEEE Transactions on Neural Networks and learning systems*, vol. 30, no. 31, pp. 190-200, 2019.
- [32]. Taeckens E, Dong R, Shah S., "A Biologically Plausible Spiking Neural Network for Decoding Kinematics in the Hippocampus and Premotor Cortex." *2023 11th International IEEE/EMBS Conference on Neural Engineering*, pp. 1-4, 2023.
- [33]. Zhang P, Chao L, Chen Y, Ma X, Wang W, He J, Huang J, Li Q., "Reinforcement Learning Based Fast Self-Recalibrating Decoder for Intracortical Brain-Machine Interface." *Sensors*, vol. 20, no. 19, 2020.
- [34]. Sarić R, Jokić D, Beganović N, Pokvić LG, Badnjević A. "FPGA-based real-time epileptic seizure classification using Artificial Neural Network." *Biomedical Signal Processing and Control*, vol. 62, 2020.
- [35]. Bair W, Koch C. "Temporal precision of spike trains in extrastriate cortex of the behaving macaque monkey." *Neural computation*, vol. 8, no. 6, pp. 1185-1202, 1996.
- [36]. Buracas GT, Zador AM, DeWeese MR, Albright TD. "Efficient discrimination of temporal patterns by motion-sensitive neurons in primate visual cortex." *Neuron*, vol. 20, no. 5, pp. 959-969, 1998.
- [37]. Salinas E, Sejnowski TJ. "Correlated neuronal activity and the flow of neural information." *Nature reviews neuroscience*, vol. 2, no. 8, pp. 539-550, 2001.
- [38]. Chew G, Ang KK, So RQ, Xu Z, Guan C., "Combining Firing Rate and Spike-Train Synchrony Features in the Decoding of Motor Cortical Activity." *2015 37th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, pp. 1091-1094, 2015.
- [39]. Ran X, Zhang S, Sun G, Zhu J, Chen W, Pan G. "Decoding Velocity from Spikes Using a New Architecture of Recurrent Neural Network." *2019 9th International IEEE/EMBS Conference on Neural Engineering*, pp. 231-234, 2019.
- [40]. Glaser JI, Benjamin AS, Chowdhury RH, Perich MG, Miller LE, Kording KP., "Machine learning for neural decoding." *Eneuro*, vol. 7, no. 4, 2020.
- [41]. Heelan C, Nurmikko AV, Truccolo W., "FPGA implementation of deep-learning recurrent neural networks with sub-millisecond real-time latency for BCI-decoding of large-scale neural sensors (104 nodes)." *2018 40th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, pp. 1070-1073, 2018.
- [42]. Stevenson IH, Kording KP. "How advances in neural recording affect data analysis." *Nature neuroscience*, vol. 14, no. 2, pp. 139–142, 2011.
- [43]. Ahmadi-Dastgerdi N, Hosseini-Nejad H, Amiri H, Shoeibi A, Gorriz JM. "A vector quantization-based spike compression approach dedicated to multichannel neural recording microsystems." *International Journal of Neural Systems*, vol. 32, no. 03, 2022.
- [44]. Thomas A, Dasgupta S, Rosing T. "A theoretical perspective on hyperdimensional computing." *Journal of Artificial Intelligence Research*, vol. 72, pp. 215-249, 2021.
- [45]. Karunaratne G, Le Gallo M, Cherubini G, Benini L, Rahimi A, Sebastian A. "In-memory

- hyperdimensional computing." *Nature Electronics*, vol. 3, no. 6, pp. 327-337, 2020.
- [46]. Ge L, Parhi KK. "Classification using hyperdimensional computing: A review." *IEEE Circuits and Systems Magazine*, vol. 20, no. 2, pp. 30-47, 2020.
- [47]. Buccino AP, Garcia S, Yger P. "Spike sorting: new trends and challenges of the era of high-density probes." *Progress in Biomedical Engineering*, vol. 4, no. 2, 2022.
- [48]. Burrello A, Cavigelli L, Schindler K, Benini L, Rahimi A., "Laelaps: An Energy-Efficient Seizure Detection Algorithm from Long-term Human iEEG Recordings without False Alarms," *2019 Design, Automation & Test in Europe Conference & Exhibition*, pp. 752-757, 2019.
- [49]. Du Y, Sun HQ, Tian Q, Zhang SY, Wang C., "Design of blender IMC control system based on simple recurrent networks," *2009 International Conference on Machine Learning and Cybernetics*, vol. 2, pp. 1048-1052, 2009.
- [50]. Heck J, Salem FM., "Simplified minimal gated unit variations for recurrent neural networks," *IEEE 60th International Midwest Symposium on Circuits and Systems*, 2017.
- [51]. Zviagintsev A, Perelman Y, Ginosar R., "Low-power architectures for spike sorting," *2nd International IEEE EMBS Conference on Neural Engineering*, pp. 162-165, 2005.
- [52]. Zhou F, Liu J, Yu Y, Tian X, Liu H, Hao Y, Zhang S, Chen W, Dai J, Zheng X., "Field-programmable gate array implementation of a probabilistic neural network for motor cortical decoding in rats," *Journal of Neuroscience Methods*, vol. 185, no. 2, pp. 299-306, 2010.