

شبکه عصبی Spiking روشی برای مدل سازی، طبقه بندی و فهم داده های

فضا_زمان EEG

اعظم زارعی¹، همایون ابراهیمیان²

1. دانشگاه آزاد اسلامی، واحد تبریز، گروه مهندسی پزشکی، تبریز، ایران

2. دانشگاه آزاد اسلامی، واحد اردبیل، گروه مهندسی پزشکی، اردبیل، ایران

چکیده

این مقاله یک روش جدید برای مدل سازی، شناخت و فهم های داده های فضا-زمانی الکتروانسفالوگرافی و اندازه گیری شناختی پیچیده مغز را در طول فرآیندهای فعالیت ذهنی ارائه می دهد. عنصر کلیدی این است که فعالیت ذهنی از طریق انجام فرآیندهای فضا-زمانی پیچیده مغز بوده و تنها در صورتی می توان آنها را قابل درک دانست که ما مدل درستی داده های طیفی فضایی-زمانی این فرآیند را اندازه گیری کنیم. روش پیشنهادی بر روی شبکه عصبی spiking اخیرا ارائه شده است معماری NeoCube نامیده شده است به عنوان چهار چوب کلی برای مدل سازی داده های فضا-زمان مبتنی بر داده های الکتروانسفالوگرافی است. نتایج مدل سازی داد ها با نرم افزار متلب مورد شبیه سازی انجام گرفته و ارائه شده است.

واژه های کلیدی: شبکه های عصبی spiking، اطلاعات شناختی، EEG، بیماری آلزایمر

مقدمه

مدل سازی داده های محرک، با هدف شناخت و درک فرآیندهای پیچیده ی یک مشکل عمده در علوم اطلاعاتی مرتبط با برنامه های مهم مانند این موارد است:

-رابط مغز و کامپوتر و (BCI)

- تشخیص زود هنگام و پیشگیری از بیماری های مغزی دژنراتیو مانند بیماری آلزایمر

- پیش بینی بیماری شخصی و توانبخشی عصبی

فرآیندهای شناختی مغزی با داده های STBD که جهت پردازش و درک در مدل کامپیوتری مشکل ساز است تا زمانی که یک مدل محاسباتی که به داده ها مربوط است را در دست داشته باشیم. بسیاری از داده ها مغزی مرتبط با برنامه ها در موارد لیست شده ی بالا هنوز از تکنیک های نامناسب استفاده می کنند و نیازمند موارد موثرتر بحث شده ی بعدی می باشد. هدف BCT ها رمزگذاری سیگنال های مغزی است که نشان دهنده ی فرآیند شناختی جهت امکان پذیری ارتباطات انسان - کامپیوتر هستند. BCI ها هنوز از روش های هوش مصنوعی و آماری برای تشخیص STBP پیچیده استفاده می کنند این مورد اغلب عملکرد BCI ها را محدود کرده و باعث عملکرد ضعیفی می شود. افزایش در طول عمر مردم در جامعه ی مدرن، ضرورت مواجه با مشکلات روز مره با افزایش چشم گیر بیماری های عصبی و بیشتر از همه AD حتی شروع زود رس را ایجاد می کند. این تبدیل به یک مشکل سلامتی عمده ی اساسی و پرسش های جدی در سلامتی را به وجود می آورد و ممکن است نیازمند سازمان دهی مجدد خدمات مراقبت اجتماعی باشد، آزمایشات شناختی و غربالگری حافظه به طور معمول مرحله به مرحله برای تشخیص اختلال شناختی مانند AD می باشد در واقع اولین علائم که به دنبال شروع آسیب شناسی، زوال شناختی و اتلاف حافظه شروع می شوند. تشخیص اولیه همان طور که درمان اولیه را مجاز می سازد مهم است. در این زمینه تحقیق neuro informatic می تواند یک نقش حیاتی را ایفا کند. یک مشارکت عمده می تواند توسط دانشمندان اطلاعات به دست بیاید یک تکنیک آموزشی ماشینی بسیار موثر است که می تواند توانایی یک فرد را با درک عمیقی از فرآیندهای مغزی آزمایش کند پزشکی شخصی یک روند فعلی در مراقبت های بهداشتی با پتانسیل عظیمی در بسیاری از نواحی مرتبط با سلامتی از جمله BCI و روباتیک عصبی - توانبخشی است.

هنوز روش علوم اطلاعات جدید در اجرای کار آمد این مفهوم همان طور که قبلا در بخش 37 مطرح شده است، مورد نیاز هستند. داده های EFG رایج ترین داده های جمع آوری شده اند در فرآیندهای مغزی مرتبط با هر دو BCI و بیماری مغزی هستند. هر چند، این داده ها محصول مسیرهای سیگنال مغزی فضایی - زمانی پیچیده هستند که رویدادهای وابسته به زمان مرتبط با ساختار مغز و عملکرد آن می باشند. در اصل، داده های EEG همان داده های مغزی STBD هستند و به منظور درک درست باید پردازش شوند. این مورد تاکنون تنها با موفقیت نسبی انجام شده است که برای توسعه ی روش های علم اطلاعاتی جدید همان طور در بخش های مختلف به آن ها اشاره شد، لازم است. در این مقاله یک روش جدید را در طبقه بندی EEG - STBD ثبت شده در طول فعالیت های شناختی مختلف مطرح می کنیم. این روش براساس شبکه های SNN و به طور خاص براساس یک Neu cube ساختاری SNN مطرح شده است.

شبیه سازی SNN مغزی برای مدل سازی اطلاعات فضایی - زمانی


مقدار زیادی از اطلاعات در مورد ویژگی های ساختاری و عملکرد انباشته شده ی مغز انسان تاکنون وجود داشته اند. از جمله فرآیند های سیناپسی رمز گذاری اطلاعات اتصال، اطلس های ساختاری و عملکرد، پیش بینی قشر مغز، ژنتیک و پروتئومیکس اطلس های عصبی ژنتیک اختلالات وضعیت های مغزی .

تمام این ها می تواند هنگام پردازش داده های شناختی اگر مدل کامپیوتری بتواند آن را ارائه دهد اطلاعات ارزشمندی باشد . از نکته نظر علم اطلاعات، مغز اطلاعات را در سطح پایین در شکل بسیاری از زنجیره های پتانسیل الکتریکی موقت ارائه و پردازش می کند که می توانند به عنوان وقایع باینری در نظر گرفته شوند و از این طریق اتصالات سیناپسی بین نرون ها منتقل می شوند. از طرق یادگیری اطلاعات، اطلاعات سیناپسی جهت بازتاب زمان بندی دقیق تر داده ها از ورودی های حسی

اصلاح می شوند و این یکی از اصول SNN است از نسل سوم شبکه های عصبی الهام گرفته از مغز آنها در نظر گرفته اند روش های SNN برای یادگیری داده ها در زنجیره های دسته ای مانند شبکه سیلیکون و دستگاه های حسی سیلیکون حلزونی و محاسبه عصبی ژنتیکی با عملکرد بالا سیستم های مهندسی نروموروفیک توسعه یافته اند مشخصات امیدوار کننده SNN این موارد هستند نمایش فشرده فضا و زمان پردازش سریع اطلاعات و پردازش سریع اطلاعات نمایشی پایه زمانی و پایه فرکانسی اطلاعات همچنین روش هایی از SNN در شناخت الگوی فضا و زمانی توسعه یافته است از جمله طبقه SNN در حال تحول، برنامه آزمایشی برای تشخیص شی در حال حرکت برنامه شناختی برای طبقه بندی داده های EEG، محاسبه مخزن SNN، ساختار حالت مایع مدل سازی محدود اتوماتیک. روش ها و تکنیک های SNN یک پس زمینه ی خوبی را برای توسعه ی روش های اطلاعاتی جدید و سیستم های مربوط به STBD فراهم می کنند. یکی از آنها به نام NECUBE در زیر شرح داده شده و در بخش بعدی با هدف شناخت در این مقاله برای مدل سازی داده های EEG و طبقه بندی و درک آنها توصیف شده است.

ساختارهای SNN NECUBE برای مدل سازی STBD

NECUBE یک معماری SNN در STBD است که اول در بخش اول مطرح شد و سپس در بخش های مختلف توسعه یافت. نمودار بلوکی مدل NECUBE در شکل (1) نشان داده شده است. معماری NECUBE شامل مدول های زیر است؛ مدول رمزگذاری اطلاعات، ورودی به مدل SNN مکعبی سه بعدی؛ مدول خروجی؛ مدول شبکه ی نظارتی ژن، مدول بهینه سازی. مدول ورودی اطلاعات داده شده را به دسته هایی انتقال می دهند که سپس به مدول اصلی-SNNC 3 بعدی وارد می شوند. SNNC برای نقشه کشی فضای نواحی مغزی که در آن STBD موجود است ساخته شده است.



شکل (1) بلوک دیاگرام ساختار مکعب نئو

ساختار شناخته شده و یا اتصالات عملکردی بین نواحی مختلفی از مغز نشان داده شده در داده ها می باشد. راه اندازی مفهوم ساختاری ابتدایی در یک مدل، در مورد SNNC، به منظور یادگیری بهتر از داده های فضایی-زمانی و ضبط کاربردی مهم است. داده های اتصالی ساختاری بسیار خاص می توانند با استفاده از روش DTI حاصل شوند. ساختار ابتدایی SNNC می تواند به صورت اولیه براساس داده های مغزی موجود و مسائل ایجاد شده مانند اتصال Small-world تعریف شود.

همچنین ساختار از طریق ایجاد نرون ها و اتصالات جدید براساس اصول استفاده شده در طبقه بندی ECOS تکامل می یابد. اگر داده های جدید به حد کافی نرون های موجود را در طبقه بندی کننده ی خروجی فعال نکنند نرون های جدید جهت تطابق اطلاعات با اتصالات جدید ایجاد می شوند. یادگیری در NECUBE دارای دو مرحله می باشد:

آموزش بدون نظارت، که در آن STBD در شکل زنجیره های Spike به نواحی مرتبط با SNNC وارد شده است. آموزش بدون نظارت جهت تغییر مجموعه وزن اتصال اولیه اجرا شده است. SNNC جهت فعال سازی همان گروه از نرون های Spiking وقتی محرک های ورودی مشابه فراهم شوند، اکنون بار دیگر از طریق SNNC زنجیره ای گسترش یافته است و نرون های خروجی جهت طبقه بندی الگوی spiking فضایی- زمانی SNNC در طبقات از پیش تعریف شده تولید و آموزش داده شده اند. به عوان یک مورد خاص تمام نرون ها از SNNC به هر نرون خروجی متصل شده اند. اتصالات بازخوردی از نرون های خروجی به نرون ها در SNNC می توانند در تقویت آموزش ایجاد شوند. روش های SNN متفاوت می توانند جهت کسب و طبقه بندی الگوهای دسته ای از SNNC از جمله SNN ESSN محرک پویا نرون تجمعی الگوی دسته ای طبقه بندی کننده های دیگر SNN استفاده شوند. همه ی این گزینه ها در برخی راه اندازی های مکعبی نئوی اولیه ی اجرا شده اند. حافظه در مدل نئوی اولیه ی اجرا شده اند. حافظه در مدل پایه مکعب نئو به این صورت نشان داده شده است: حافظه ی کوتاه مدت به عنوان تغییراتی از پتانسیل PSD و تغییرات موقتی اثر سیناپسی نشان داده شده است. حافظه ی بلند مدت به عنوان یک تأسیس پایدار از تأثیر سیناپسی-تقویت طولانی مدت و افسردگی طولانی مدت نشان داده شده است. حافظه ی ژنتیکی به عنوان یک کد ژنتیکی ارائه شده است. NECUBE (مکعب نئو) یک نوع جدیدی از معماری محاسباتی است که ایجاد روش های متفاوت در STBD بر پایه ی اصول پردازش اطلاعات را مجاز می سازد:

- 1- این مدل دارای یک ساختار فضایی است که تقریباً از نواحی منطقه ای مغزی را که در آن STBD جمع آوری شده نقشه برداری می کند.
 - 2- پارادایم اطلاعاتی یکسان-پردازش اطلاعات دسته ای که در نهایت منجر به تولید STBD در سطح پایین پردازش اطلاعاتی مغز می شود، در مدل جهت ارائه و پردازش این STBD استفاده می شود.
 - 3- قواعد یادگیری مغز-مانند که در مدل جهت کسب STBD استفاده شده اند در مناطق فضایی طراحی شده از مدل طرح ریزی شده اند.
 - 4- مدل A که از لحاظ الگوهای STBD جدید کسب شده در حال تکامل است، شناخته شده و تدریج افزایش یافته است که همچنین اصلی از توسعه ی شناختی مغز می باشد.
 - 5- مدل A همیشه حافظه ی فضایی-زمانی را که می تواند بهره برداری شده و در درک بهتری از فرآیند شناختی تفسیر شود، حفظ می کند.
 - 6- تجسم تکامل مدل در طول آموزش می تواند به عنوان یک بازخورد زیستی به کار گرفته شود.
- تمامی اصول بالا مکعب نئو را یک ساختار SNN مناسب جهت کسب و آشکارسازی الگوهای فضایی-زمانی پیچیده در STBD ساخته چون در توسعه روش جدید جهت مدل سازی EEG STBD شناختی همان طور که در بخش فرعی بعدی خلاصه شده انتخاب شده اند.

روش پایه مکعب نئو در مدل سازی داده های فضایی-زمانی EEG از فعالیت های شناختی مغز

روش مطرح شده در این جا برای مدل سازی طبقه بندی و درک داده های شناختی EEG شامل روندهای زیر است:

1- EEG جمع آوری شده STBD مربوط به فرآیند شناختی مغز را نشان می دهد.

2- رمزگذاری داده های EEG در توالی دسته ای.

3- نقشه برداری توالی دسته ای در SNNC طراحی شده ی خاص که تعدادی از متغیرها و داده های موجود را بازتاب می کند.

4- آموزش SNNC در STBD دسته ای با استفاده از روش آموزش بدون نظارت مانند STDP.

5- آموزش از طبقه بندی کننده ی خروجی در یک حالت تحت نظارتی.

6- اعتبار سنجی نتایج طبقه بندی

7- تکرار مراحل 2 و 6 در مقدار پارامترهای متفاوت به منظور بهینه سازی عملکرد طبقه بندی ثبت بهترین اجرای مدل.

8- تجسم SNNr و تحلیل قابلیت شناختی و فعالیت دسته ای آن در درک بهتری از داده ها و پردازش های مغزی که آن را ایجاد کرده است.

برای نقشه برداری از موقعیت های فضایی از کانال های EEG در SNNC از قالب Talairacl استفاده می کنیم. نرون ها در SNNr به دنبال مختصات یکسان (x,y,z) از Talairacl واقع شده اند و کانال های EEG بر طبق نقشه برداری استاندارد پیشنهاد شده نقشه برداری نگاشته اند. توالی دسته ای که داده ها از کانال های EEG فراهم می سازند در نرون های مربوطه ی واقع در SNNC در طول روند آموزش بدون نظارت وارد شده اند. روش بالا step-wis را در مورد مسئله ی مطالعه ی مدل سازی داده های شناختی EEG ر بخش بعدی اعمال می کند. شکل 4-2 روش های بالا را نشان می دهند.

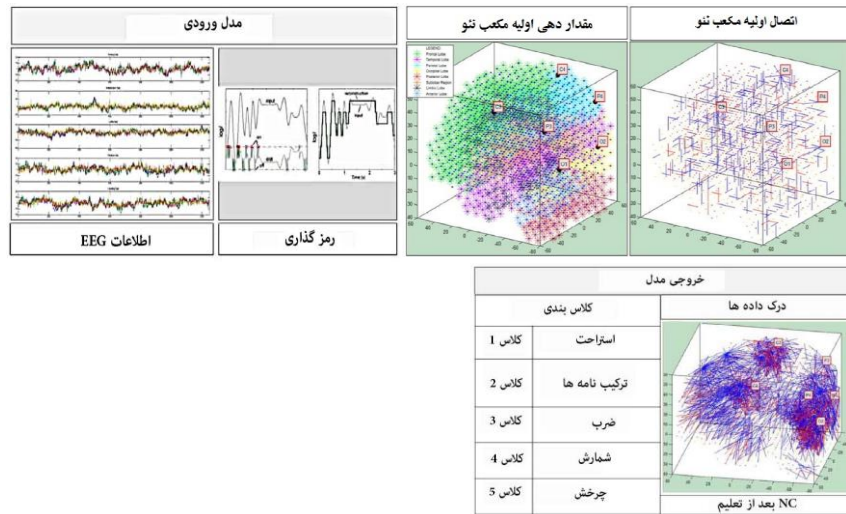
مورد مطالعه براساس مدل سازی داده های شناختی EEG

توصیف داده ها

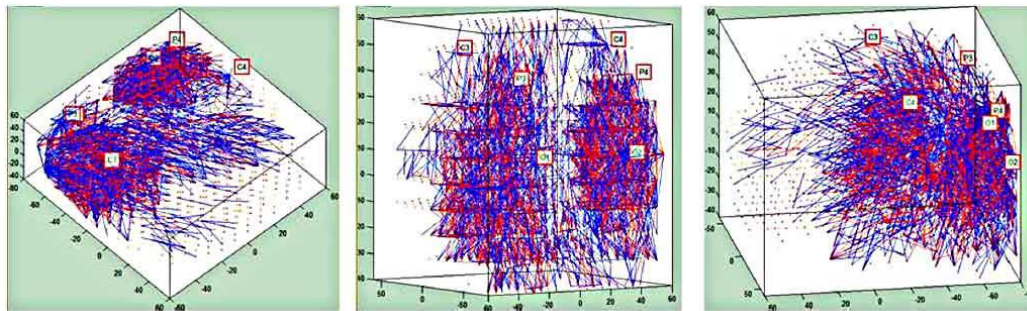
داده های استفاده شده در این تحقیق در یک آزمایش اولیه و مطالعات بیشتر ثبت شده اند. این داده ها از قشر مغز هفت فرد پس از 5 سناریوی متفاوت یکی در حال استراحت و چهار مورد آزمایش شناختی جمع آوری شدند. یک دستگاه رابط کامپیوتر مغزی جهت جمع آوری داده های EEG استفاده شده است. سناریو کار ذهنی طراحی شده شامل این موارد است: استراحت فرد در حال استراحت تا حد امکان از افکار اجتناب می کند. عمل «نامه نویسی» کار فرد تصور نامه نگاری به یک فرد بدون بیان شفاهی آن است، کار ضرب کردن- فرد در حال ضرب ذهنی دو رقمی ساده می باشد؛ کار شمارش فرد تخته سیاهی را که در آن اعداد به ترتیب نوشته شده اند را تجسم می کند کار چرخش- فرد به طور ذهنی شکل هندسی 3بعدی را چرخش می دهد. هر جلسه ی ثبت با استفاده از 16 الکتروود C3 و C4 و P4 و O1 و O2 اجرا شد. داده ها در 10 ثانیه در 250THZ در نتیجه ی 2500 نقطه ی اطلاعاتی در هر جلسه ثبت شدند. هر کار در طول جلسه ی روزانه 5 مرتبه تکرار شدند. برخی از اطلاعات در جلسه ی یک روزه ثبت شدند در حالی که افراد دیگر 5 کار آزمایشی را در جلسات دو یا سه روزه تکرار کردند. داده های مورد 4 از آزمایش حذف شدند، همان طور که براساس مطالعه ی قبلی سیگنال به طور مکرر آزمایشات متعدد را اشباع یا باطل ساخته است.

طراحی و راه اندازی مدل


ما روش بخش 2 را در آزمایش بالا همان طور که به صورت گرافیکی در شکل (2) نشان داده شد اعمال کردیم. برای مدل سازی و راه اندازی از یک شبیه ساز نرم افزاری مشابه NECUBE نوشته شده در MATLAB استفاده کردیم.



شکل (2) مدل ورودی و خروجی در مقدار دهی اولیه



شکل (3) نظریه های مختلف از SNNC و 1471 نرون ها با 6 ورودی برای داده های مورد مطالعه



شکل (4) تجزیه و تحلیل و تفسیر برای درک بهتر از داده های شناختی EEG

EEG STBD هر مورد و هر جلسه را با استفاده از مدل پایه NECUBE که دارای یک SNNC از 1471 نرون دسته ای است با استفاده از قالب نقشه برداری الکتروود EEG Talairac1 طبقه بندی نموده است. یکی از مزایای قالب کاری NECUBE این است که در بسیاری موارد هیچ نیازی به پیش پردازش نیست- داده های خام به مدل به عنوان سری های زمانی تغذیه شده و به زنجیره های Spike با استفاده از روش رویداد ADDRESS انتقال داده شده و سپس زنجیره های Spike انتقال یافته در SNNR در آموزش بدون نظارت ترسیم می شوند. روش AER در EEG شناختی STBD مناسب است همان طور که این الگوریتم فقط تفاوت ها در مقدار EEG متوالی را شناسایی می کند. توالی های دسته ی ورودی به SNNC ارائه شده اند که با استفاده از نرون های نشتی که از لحاظ محاسباتی گران هستند، راه اندازی شده اند. SNNC با استفاده از قانون آموزش پلاستیسیته ی وابسته به زمان بندی spike آموزش داده شده و قانون آموزش STPD دسته بندی نرون های SNNC را جهت آموزش مجموعه توالی زمانی از داده های EEG با کانال های EEG مقابل و تشکیل اتصالات

جدید در ساختاری که می تواند آنالیز و تفسیر شود، مجاز می سازد. این مورد ساختار Neucube را در الگوهای آموزشی فضایی زمانی از داده های EEG با تشکیل نوع حافظه جمعی که می تواند بیشتر مورد بررسی قرار بگیرد، قابل استفاده می سازد. اگر چه SNNc می تواند از لحاظ اندازه در حال تکامل باشد، در این تحقیق قابلیت طبقه بندی ساختار Neu cube را از 1471 نرون دسته ای مورد بررسی قرار دادیم که هر کدام مختصات مرکزی یک ناحیه ی مکعبی یک سانتی متری از اطلس سه بعدی را نشان می دهند. ساختار سه بعدی SNNc به عنوان شبکه های اتصالی SW در مقدار دهی اولیه، پردازش آموزش مدل و در پردازش الگوهای مرتبط از داده ها بنیادی است. داده های توالی دسته ای کد گذاری شده از EEG 6 کانال های دستگاه ثبت کننده به عنوان سری های زمانی به نرون های ناحیه فضایی به دنبال مختصات مطرح شده وارد زمینه شدند. شکل (3) نواحی مختلفی از SNNc را که به طور فضایی نواحی مغز را بر طبق قالب Talairach نمایش می دهند را نشان می دهد یعنی لوب فرونتال، لوب تمپورال، لوب آهیانه ای، اکسی پیتال لوب، لوب خلفی، منطقه ی زیر لوبی، لوب لیمبیک، لوب قدامی که به رنگ های مختلفی رنگ آمیزی شده اند را نشان می دهد. به عنوان یک طبقه بندی کننده ی خروجی از الگوریتم SNN جهت طبقه بندی EEGSTBD در 5 وضعیت ادراکی مغز استفاده کردیم. این روش طبقه بندی تنها با استفاده از یک پاس انتشار داده ها، قانون آموزش نظم محدوده و آموزش موقت STDP را در هر نرون خروجی جهت آموزش الگوهای فضایی زمانی، ترکیب می کند. نتایج طبقه بندی با استفاده از هر دو روش نمونه برداری RRSSV , LOOCV ارزیابی شدند. آخرین تصویر از نمودار شکل 2 مزایای کلیدی دیگری را که Neucube فراهم می سازد، یعنی امکان تفسیر داده ها و پردازش شناختی مغز ارائه می دهد. وضعیت SNNc پس از آموزش می تواند به طریق مختلفی تجسم و آنالیز شود. می توان مشاهده کرد که اتصالات جدید بین نرون هایی تشکیل یافته اند که بیشتر می توانند در زمینه ی عملیات شناختی متفاوت تفسیر شوند. برجسته سازی این مورد مهم است که مدل Neucube یک مدل تصادفی است و بنابراین نسبت به تنظیمات آرام تری حساس می باشد. برخی پارامتر هالی اصلی که به شدت بر مدل تاثیر می گذارند شامل این موارد هستند: -آستانه ی AER کد گذاری زنجیره ی دسته ای- آستانه ی دو جهتی که به شیب سیگنال بر اساس زمان اعمال شده است. وقتی داده های EEG در ورودی بار گذاری شوند، به گونه های دسته ای تبدیل می شوند. میزان Spike به آستانه ی AER بستگی دارند که می تواند یا به عنوان یک مقدار خاص در هر متغیر ورودی یا به عنوان سطح آستانه ی جهانی جهت اعمال به تمام موارد تعیین شود.

-اتصال بین نرون های شبکه بسته به پارامتر اتصالی SW هر نرون از SSNR در ابتدا به نرون های مجاور خود در پارامتر خود به صورت فاصله متصل می شود ما مقدار 0/15 را استفاده کرده ایم.

- پارامتر سرعت STDP بر طبق قانون آموزش STDP فعالیت خروج دو نرون اتصالی باعث اتصال وزن آنها جهت افزایش یا کاهش وابسته به ترتیب خروج می شود، به طوری که وزن اتصالی در ارتباط موقت بین فعالیت های این نرون ها منعکس شود. در این آزمایش از مقدار 0/01 استفاده می شود.

- تعداد دفعاتی که مکعب نئو در یک حالت بدون نظارت آموزش داده شده است. این به طور پیش فرض به 2 تنظیم می شود، چون مقادیر بالاتر ممکن است باعث کسب بیش از حد SNNc شوند.

حالت متغیرها و نحوه طبقه بندی DE SNN هر نمونه ی آموزشی به یک نرون خروجی مرتبط است که هر کدام به نرون خروجی از مکعب متصل هستند. وزن های اتصالی اولیه این نرون های خروجی همگی به صفر تنظیم می شوند. وزن های اتصالی جدید بر طبق قانون آموزش Ro شکل گرفته اند. این مورد وابسته به عامل مدولاسیون ترتیب spike های ورودی محاسبه می شود. سپس اتصال جدید وزن ها بر طبق تعداد spike هایی که اولی را دنبال می کند افزایش یا کاهش خواهد یافت. ما در این پارامترها مقادیر 0/4 و 0/25 را به کار بردیم. گام مهم در دستیابی نتایج خوب از مدل مکعب نئو بهینه سازی این مقادیر پارامترها است. بهینه سازی پارامتری می تواند از طریق روش تحقیق شبکه ای الگوریتم ژنتیک یا الگوریتم تکاملی الهام گرفته از کوانتوم به دست بیاید. در این مطالعه یک شبکه را با استفاده از 50 درصد از مجموعه زمانی کامل برای آموزش و 50 درصد دیگر برای آزمایش که هر دو به طور تصادفی انتخاب شده اند به کار بردیم. ما دقت طبقه بندی را با 20 مدل

پیکربندی در هر فرد و در هر جلسه را با استفاده از مقادیر AER متفاوت ارزیابی کرده و از AER که منجر به دقت بالا شده است استفاده کردیم. دیگر مقادیر پارامترها مانند مورد شرح داده شده در بالا تنظیم شده بودند. این پارامترهای بهینه سازی شده جهت ارزیابی خروجی طبقه بندی در تمام آزمایشات از جمله روش LooCV استفاده شدند.

3-3- نتایج آزمایش

در این تحقیق از دقت طبقه بندی مدل های مکعب نئو و زمان متوسط در اجرای برنامه استفاده کرده ایم. جدول 1 نتایج طبقه بندی هر فرد و هر جلسه را خلاصه وار نشان می دهد. نتایج به عنوان درصدی از نمونه های به دقت طبقه بندی شده و نوع طبقه بندی و تمام طبقات بیان شده اند. نتایج با استفاده از 50 مورد انتخاب شده ی تصادفی 50٪ اطلاعات آزمون آموزشی و روش LooCV به دست آمدند.

نمونه		LooCV (%)							
موضوع و نشست		میانگین گیری کل کلاس ها (%)							
		کلاس (%)	کلاس (%)	کلاس (%)	کلاس (%)	کلاس (%)	کلاس (%)	کلاس (%)	کلاس (%)
1	جلسه 1	2.00	80	100	100	60	100	88	80
	جلسه 2	1.99	100	100	100	100	100	100	100
2	جلسه 1	1.30	100	100	100	100	20	84	74
	جلسه 1	4.07	80	40	80	40	40	56	52
3	جلسه 2	2.94	80	40	100	80	100	80	80
	جلسه 1	5.23	100	80	80	80	80	84	70
5	جلسه 2	2.95	20	60	100	100	80	72	54
	جلسه 3	5.89	80	100	60	100	60	80	94
6	جلسه 1	6.48	60	80	40	100	80	72	56
	جلسه 2	5.57	80	100	100	80	60	84	86
7	جلسه 1	1.70	60	100	100	100	80	88	82

شکل (5) نتایج تجربی با مدل مبتنی بر NeuCube در هر موضوع و در هر جلسه

زمان CPU	
رمز گذاری اطلاعات	مقدار دهی اولیه مکعب نئو
کلاس بندی ST و T	آموزش بدون نظارت
کل اطلاعات	هر نمونه هر تکرار 48.46
20هرنمونه	5854.51

شکل (5) الگوریتم اصلی مکعب نئو و آموزش بدون نظارت و تحت نظارت

تنظیم اطلاعات در حد کمتری بود که نتیجه گیری علمی از عملکرد ذهنی توسط افراد مختلف مناسب نبوده و این مورد هدف مقاله نمی باشد. لذا نتیجه گرفتیم که در با در نظر گرفتن روش مکعب نئو در آنالیز بیشتر و مدینگ اطلاعات آزمایشی بیشتر باشد و جهت تبدیل به یک روش، به طور وسیع استفاده شود در آنالیز داده های EEG مربوط به عملکردهای ذهنی و فرآیند ادراکی در سراسر برنامه ها کار آسانی است. نتایج این آزمایشات هنوز برخی پدیده های مورد انتظار را تأیید می کند:

- افراد در عملکردهای متفاوت عملکرد های مختلفی دارند.
- داده های مربوط به بخش اول در تمام افراد به خوبی طبقه بندی شده اند.
- دقت طبقه بندی با برخی پارامترهای دستی تنظیم شده افزایش یافته نشان می دهد که پتانسیل کاملی از مدل پایه مکعب نئو نیست و هنوز نیازمند بهینه سازی بیشتری می باشد.
- حتی با توجه به وظایف ذهنی بسیار پیچیده دقت طبقه بندی هنگام مقایسه با مدل های طبقه بندی شده که از قبل استفاده شده است بهتر بود. مقایسه ی بالا به عنوان نتایجی از روش پایه مکعب نئو با نتایج به دست آمده در آزمایشات قبلی انجام شده و در مجموعه اطلاعاتی یکسان تأیید شود. با روش پایه مکعب نئو مطرح شده دقت طبقه بندی بالاتری

را در اطلاعات هر جلسه نمایان می کند در هر فرد به طور کلی هنگام مقایسه با روش های دیگری مانند ماشین بردار و دستگاه های آموزشی فوق العاده به دست آوردیم. وقتی روش های SVM و ELM به کار گرفته شدند، داده های EEG ابتدا پیش پردازش شدند و سپس در تعداد کمتری از بردارهای ورودی، بیش تر از این که به عنوان داده های فضایی زمانی مانند مورد مدل مکعب نئو در نظر گرفته شوند، فشرده سازی شدند. زمان CPU گزارش داده شده در جدول 2 تحت تنظیمات زیر سنجیده شدند: شبیه سازی نرم افزاری مکعب نئو نوشته شده در MATLAB 2015:

طبق موارد بالا مدل پایه مکعب نئو مزایای مهم متعددی دارد:

- فقط نیازمند تکرار یک بار داده ها برای آموزش دارد در حالی که روش های طبقه بندی SVM و ELM نیازمند صدها بار تکرار هستند. مدل پایه ی مکعب نئو با داده های جدید و طبقات جدید سازگار است در حالی که مدل های دیگر ثابت بوده و برای تطبیق با داده های جدید سخت هستند.
- مدل پایه مکعب نئو تفسیر بهتری از داده ها را همان طور که بعداً بحث می شود مجاز می سازد.

تفسیر مدل برای درک بهتری از داده ها

مکعب نئو به منزله ی یک محیط سه بعدی الهام گرفته از محیط SNN در آموزش آنلاین و شناخت داده های فضایی-زمانی مغز است. با ارائه ی درک بهتری از اطلاعات و پدیده های مطالعاتی و ویژگی داده ها را به محاسبه می کند این مورد در شکل 4 به تصویر کشیده شده است و پس از این که SNNC با یک مجموعه ای از داده ها آموزش داده شد به دست آمد. از شکل 4 متوجه می شویم که اتصالات جدیدی که در اطراف نرون های ورودی SNNr اختصاص یافته اند به لحاظ موقعیت فضایی مکانی، الکترودهای EEG را نقشه برداری می کنند با مطالعه ی تصویر همچنین توانستیم برخی اطلاعاتی اضافی مانند افرادی که به صورت فعالانه قشر بنیادی خود را مورد استفاده قرار می دادند را استنباط کنیم.

موضوع	جلسه	روش مکعب نئو	Nan-Ying	روش مورد استفاده
1	2	100	86.70	ELM
2	1	84	78.76	SVM
3	2	80	64.60	SVM
5	1	84	63.43	SVM
6	2	84	69.47	ELM
7	1	88	79.77	SVM

شکل(6) نتایج طبقه بندی مکعب نئو به روش نان یینگ

به طور موثر افراد هر سناریو را با چشمان باز انجام دادند. همچنین می توانیم از تصویر فعالیت ها را در لوب آهیانه ی ودر طول عملکرد شناختی مرتبط با این داده ها مشاهده کنیم. مدل Neucube بیشتر می تواند به صورت تدریجی براساس داده های جدید، از جمع طبقات جدید، با توجه به ظرفیت SNNR به جای داده ها در یک الگوی آموزشی و با قابلیت تکامل طبقه بندی کننده ی خروجی آموزش داده شود. قابلیت مدل های Neucube پیگیری فرآیندهای توسعه و کاهش شناختی در طول زمان و استخراج اطلاعات جدید در مورد آنها را مجاز می سازد.

نتایج

هدف این تحقیق توسعه ی یک روش و یک قالب کاری برای مدل سازی و تفسیر داده های EEG است که فعالیت مغز را در طول عملیات ادراکی اندازه گیری می کند. این مورد در ایجاد انواع جدیدی از BCI و همچنین در جستجوی اولیه ی زوال شناختی جهت استفاده توسط پزشکان در تشخیص روزمره اهمیت دارد. برای این منظور، داده های EEGSTBD را در عملیات تشخیصی پیچیده به عنوان داده های معیاری انتخاب کردیم. در این مطالعه روشی براساس ساختار SNN جدیدی به

نام Neucube برای طبقه بندی داده های EEG مکانی - زمانی جمع آوری شده هنگامی که افراد چهار نوع عملیات شناختی و یک نوع استراحت را انجام می دادند، مطرح کردیم. Neucube چندین مزایا را وقتی با روش های اطلاعاتی سنتی مقایسه می شود، فراهم می سازد:

- یادگیری سریع ST BD.
- دقت بالاتر طبقه بندی
- قابلیت تطبیق با داده های جدید از طریق آموزش تدریجی که شامل آموزش الگوی ورودی جدید از داده ها و طبقات جدید می باشد.
- تجسم بهبود یافته از SNNr و طبقه بندی کننده در طول روندهای آموزشی و فراخوان مربوط به درک بهبود یافته ای از فرآیندهای اطلاعاتی و مغزی.
- اجرای روش مطرح شده در سخت افزار neuromorphic جهت اکتشاف پتانسیل آن در یک محاسبه ی شدت موازی.

مراجع:

- [1] C. Anderson, D. Peterson, Recent advances in EEG signal analysis and classification, in: R. Dybowski, V. Gant (Eds.), *Clinical Applications of Artificial Neural Networks*, Cambridge University Press, UK, 2001, pp. 175–191 (Chapter 8).
- [2] C. Anderson, Effects of variations in neural network topology and output averaging on the discrimination of mental tasks from spontaneous electroencephalogram, *J. Intell. Syst.* 11 (4) (1997) 423–431.
- [3] C. Anderson, Z. Sijercic, Classification of EEG signals from four subjects during five mental tasks, in: A.B. Bulsari, S. Kallio, D. Tsaptsinos (Eds.), *Solving Engineering Problems with Neural Networks: Proc. Conf. on Engineering Applications in Neural Networks (EANN'96)*, Systems Engineering Association, PL 34, FIN-20111 Turku 11, Finland, pp. 407–414.
- [4] C. Anderson, E. Stolz, S. Shamsunder, Multivariate autoregressive models for classification of spontaneous electroencephalogram during mental tasks, *IEEE Trans. Biomed. Eng.* 45 (3) (1998) 277–286.
- [5] L. Benuskova, N. Kasabov, *Computational Neuro-genetic Modelling*, Springer, New York, 2007. p. 290.
- [6] Y. Chen, J. Hu, N. Kasabov, Z. Hou, L. Cheng, NeuroCubeRehab: a pilot study for EEG classification in rehabilitation practice based on spiking neural networks, in: *Proc. ICONIP 2013*, vol. 8228, Springer LNCS, pp. 70–77.
- [7] M. Defoin-Platel, S. Schliebs, N. Kasabov, Quantum-inspired evolutionary algorithm: a multi-model EDA, *IEEE Trans. Evolution. Comput.* 13 (6) (2009) 1218–1232.
- [8] T. Delbruck, jAER Open Source Project, 2007. <<http://jaer.wiki.sourceforge.net>> (14.04.14).
- [9] C.W. Anderson, M. Kirby, Colorado State University – Brain Computer Interface Laboratory, 2003. <www.cs.colostate.edu/eeg/main/data/1989_Keirn_and_Aunon> (14.04.14).
- [10] A. Delorme, S. Makeig, EEGLAB: An Open Source Environment for Electrophysiological Signal Processing, 2004. <<http://sccn.ucsd.edu/eeglab/>>(14.04.14).
- [11] EvoSpike Project of the EU FP7, Jun 27, 2012. <<http://ncs.ethz.ch/projects/evospike>> (14.04.14).