



پرديس علوم  
دانشکده ریاضی، آمار و علوم کامپیوتر

# پیاده سازی الگوریتم دسته بندی تصویر بر اساس ساختار ستون‌های قشری مغز

نگارنده

نیکو رکنی

استاد راهنما: محمد گنج تابش

پایان نامه برای دریافت درجه کارشناسی

در رشته علوم کامپیوتر

۱۴۰۲

## چکیده

شبکه‌های عصبی اسپایکی<sup>۱</sup> (SNN) نوعی شبکه عصبی مصنوعی هستند که از نحوه ارتباط نورون‌های مغز الهام گرفته شده‌اند. این شبکه‌ها قادر به یادگیری انجام وظایف مختلف هستند، اما به دلیل چالش‌های مرتبط با تخصیص اعتبار، آموزش آن‌ها اغلب دشوار است. تخصیص اعتبار فرآیند تعیین چگونگی تغییرات در پارامترهای یک شبکه عصبی به منظور بهبود عملکرد شبکه است. در شبکه‌های عصبی اسپایکی، این یک مشکل چالش برانگیز است زیرا اسپایک‌ها رویدادهای مجزایی هستند که در زمان‌های غیرقابل پیش‌بینی رخ می‌دهند.<sup>۲</sup> در این پروژه، یک الگوریتم تخصیص اعتبار جدید برای شبکه‌های عصبی اسپایکی به نام فرآیند روبه‌جلو مبتنی بر رویداد (ED-FF) مورد بررسی قرار می‌دهیم. فرآیند ED-FF تعمیم فرآیندهای یادگیری رو به جلو و پیش‌بینی کننده روبه‌جلو برای این شبکه‌ها است. فرآیند روبه‌جلو مبتنی بر رویداد است، به این معنی که تنها در صورت دریافت اسپایک، سیناپس‌های<sup>۳</sup> نورون‌های اسپایک را به‌روزرسانی می‌کند. این امر ED-FF را کارآمد و مقیاس پذیر می‌کند، زیرا نیازی به ذخیره سازی اطلاعات زمانی ندارد. تحقیقات نشان می‌دهد که ED-FF می‌تواند برای آموزش یک سیستم اسپایک برگشتی پویا که قادر به طبقه‌بندی و بازسازی است استفاده شود. نتایج روی چندین مجموعه داده الگو نشان می‌دهد که ED-FF یک رویکرد امیدوارکننده برای یادگیری با سیستم‌های عصبی اسپایکی است. ED-FF کارآمد، مقیاس پذیر است و می‌تواند برای آموزش سیستم‌های عصبی اسپایکی برای کارهای مختلف استفاده شود.

---

<sup>1</sup>Spiking Neural Networks

<sup>2</sup>Event-Driven Forward-Forward Process

<sup>3</sup>Synapse

## پیشگفتار

در سال‌های اخیر، پیشرفت‌های قابل توجه در زمینه‌های هوش مصنوعی و علوم اعصاب محاسباتی، درک ما را از محاسبات عصبی و یادگیری تطبیقی دگرگون کرده است. همانطور که ما با چالش‌های مبرم افزایش هزینه‌های محاسباتی و انتشار کربن روبرو هستیم، یک الگوی پیشگامانه به نام "محاسبات فانی"<sup>۴</sup> ظهور کرده است تا جداسازی سنتی نرم افزار و سخت افزار را متحول کند. محاسبات فانی سیستم‌هایی را تجسم می‌کند که در آن دانش فانی و حقیقی با سخت‌افزارهای با توان متوسط مرتبط است و راه را برای راه‌حل‌های محاسباتی سازگار با انرژی و سازگار با محیط زیست هموار می‌کند.

این پروژه به بررسی الگوریتم رویداد محور روبه‌جلو می‌پردازد، یک پیشرفت مهم در یادگیری سیستم‌های عصبی اسپایک بدون سیناپس‌های بازخورد. الگوریتم روبه‌جلو مبتنی بر رویداد که برای تسهیل محاسبات عصبی موازی لایه‌ای و پویا طراحی شده است، نقشی محوری در تحقق محاسبات فانی بر روی سخت افزار نورومورفیک<sup>۵</sup> با ارائه یک تعمیم مبتنی بر رویداد از فرآیندهای یادگیری پیشرو و پیش‌بینی‌کننده ایفا می‌کند، رویکرد این الگوریتم چشم‌اندازی منحصر به فرد و قدرتمند در مورد تخصیص اعتبار استنتاج و یادگیری درهم‌تنیده در شبکه‌های عصبی اسپایکی ارائه می‌دهد. الگوریتم روبه‌جلو مبتنی بر رویداد از قدرت شبکه‌های عصبی اسپایک، که رفتار اسپایک نورون‌های بیولوژیکی را شبیه‌سازی می‌کنند، استفاده می‌کند و در نتیجه کارایی بی‌سابقه‌ای را در محاسبات عصبی ایجاد می‌نماید. این رویکرد مبتنی بر رویداد بر روی وقوع رویدادها در شبکه، بهینه‌سازی

---

<sup>4</sup>Mortal Computation

<sup>5</sup>Neuromorphic

منابع محاسباتی و به حداقل رساندن مصرف انرژی، کمک به تحقق سیستم‌های محاسباتی کارآمد انرژی سرمایه گذاری می کند.

در این پروژه، پتانسیل الگوریتم روبه‌جلو مبتنی بر رویداد را در ایجاد موازی‌سازی پویا و سازگاری در شبکه‌های عصبی اسپایک بررسی می‌کنیم. با حذف اتکا به سیناپس‌های بازخورد، رویکرد این الگوریتم معماری شبکه را ساده کرده و محاسبات عصبی ساده‌شده را تقویت می‌کند و گامی قابل توجه به سمت محاسبات فانی کارآمد ارائه می‌دهد.

یافته‌های ما ظرفیت الگوریتم رو به‌جلو مبتنی بر رویداد را برای پذیرش ماهیت فانی دانش نشان می‌دهد و اطلاعات مفدی در رابطه با یکپارچگی نرم‌افزار و سخت‌افزار برای بهبود عملکرد و پایداری محیطی ارائه می‌دهد. همانطور که ما به جزئیات تخصیص اعتبار استنتاج می‌پردازیم، توضیح می‌دهیم که چگونه این رویکرد استفاده از منابع محاسباتی را بهینه می‌کند و منجر به فرآیندهای یادگیری چابک‌تر و سازگارتر می‌شود.

از طرفی شبکه‌های عصبی اسپایکی شاخه برجسته‌ای از علوم اعصاب محاسباتی هستند که از عملکرد پیچیده مدارهای عصبی مغز انسان الهام گرفته شده‌اند. بر خلاف شبکه‌های عصبی مصنوعی سنتی، شبکه‌های عصبی اسپایکی با توانایی خود در تقلید دینامیک زمانی نورون‌های بیولوژیکی، با استفاده از اسپایک‌های گسسته یا پتانسیل‌های عمل برای رمزگذاری اطلاعات مشخص می‌شوند. این رویکرد منحصر به فرد مزایای متعددی مانند کاهش مصرف انرژی، بهبود پردازش مبتنی بر رویداد ارائه می‌دهد.

در زمینه محاسبات فانی، ادغام الگوریتم‌های رویداد محور رو به جلو در شبکه‌های عصبی اسپایکی افق‌های جدیدی را برای یکپارچه نرم‌افزار و سخت‌افزار به ارمغان می‌آورد. با کنار گذاشتن موانع سنتی بین نمایش و پردازش داده‌ها، شبکه‌های عصبی اسپایکی با الگوریتم‌های رویداد محور رو به جلو سازگاری و استحکام بیشتری را در محیط‌های پیچیده و پویا نشان می‌دهند.

# فهرست مطالب

۱	مقدمه	۱
۱	۱.۱ شبکه‌ها عصبی	۱
۲	۲.۱ بیان مسئله	۲
۴	۳.۱ تاریخچه سیستم های عصبی اسپایکی	۴
۷	۴.۱ چالش‌ها و ضرورت‌های بررسی مسئله	۷
۹	۲ مروری بر مطالعات انجام شده	۹
۹	۱.۲ گزاره‌ها	۹
۱۰	۱.۱.۲ نورون‌های بیولوژیکی	۱۰
۱۱	۲.۱.۲ پتانسیل غشا	۱۱
۱۲	۳.۱.۲ پتانسیل عمل (اسپایک)	۱۲
۱۳	۴.۱.۲ سایر اصطلاحات	۱۳
۱۵	۲.۲ انواع مدل‌های نرونی در شبکه‌های عصبی اسپایکی	۱۵
۱۶	۱.۲.۲ مدل هاچکین و هاکسلی: کشف بیوفیزیک اسپایکی عصبی	۱۶
		۱۷
		۱۹
		۲۰
۲۱	۳.۲ پژوهش‌های انجام شده	۲۱

۲۲	الگوریتم پس انتشار و محدودیت‌های آن	۱.۳.۲
۲۳	جایگزین‌های امیدوار کننده برای الگوریتم پس انتشار	۲.۳.۲
۲۴	مزایای یادگیری پیشرو	۳.۳.۲
۲۵	بررسی پیاده سازی انجام شده	۳
۲۵	شبکه‌های عصبی اسپایکی	۱.۳
۲۶	یادگیری شبکه‌های اسپایکی با تنظیم رویداد محور پیشرو	۲.۳
۲۶	دینامیک مدار عصبی اسپایکی مکرر	۱.۲.۳
۲۹	آموزش آنلایین پویا	۳.۳
۳۲	طبقه بندی اسپایک محور و تقریب‌های سریع آن	۴.۳
۳۴	آزمایش‌ها	۵.۳
۳۶	نتایج طبقه بندی روی داده‌های منتخب	۱.۵.۳
۳۹	بازنمایی های سطح پیچ	۲.۵.۳
۴۱	نتیجه گیری	۴

# فصل ۱

## مقدمه

### ۱.۱ شبکه‌ها عصبی

پیشرفت در علوم اعصاب محاسباتی و هوش مصنوعی منجر به کشف پارادایم‌های جدید در یادگیری و پردازش اطلاعات شده است. روش‌های سنتی محاسبات بر جداسازی نرم‌افزار از سخت‌افزار تکیه می‌کنند و به دانش درون برنامه‌ها اجازه می‌دهند تا در نمونه‌های سخت‌افزاری مختلف باقی بمانند. با این حال، یک مفهوم جدید به نام ”محاسبات فانی“، این اصل را به چالش می‌کشد. این ایده نوید صرفه‌جویی قابل توجهی در انرژی و کاهش هزینه‌های محاسباتی را ارائه می‌دهد که با چشم انداز ”هوش مصنوعی سبز“<sup>۱</sup> همسو می‌شود.

پیگیری محاسبات فانی مستلزم توسعه سیستم‌های تطبیقی است که درگیر استنتاج و یادگیری در هم تنیده می‌شوند، جایی که انتشار اطلاعات و فرآیندهای یادگیری کاملاً شبیه به فرآیندهای مکمل مشاهده شده در مغزهای بیولوژیکی هستند. این تغییر پارادایم این پتانسیل را دارد که شکاف بین علوم شناختی، علوم اعصاب محاسباتی و یادگیری ماشین را پر کند و راه را برای سیستم‌های عصبی کارآمد و الهام گرفته از مغز هموار کند.

یکی از بهترین گزینه‌ها برای پیاده‌سازی محاسبات فانی، شبکه‌های عصبی اسپایکی (SNNs)،

---

<sup>1</sup>Green AI

نسل سوم شبکه‌های عصبی است. این شبکه‌ها برای پیاده سازی بر روی سخت افزار نورومورفیک مناسب هستند و وسیله‌ای کارآمد برای انجام محاسبات عددی ارائه می‌دهند. با این حال، انجام موثر تخصیص اعتبار در این دسته از شبکه‌های عصبی پیچیده، همچنان یک چالش باقی مهم محسوب می‌شود، به ویژه زمانی که فرآیند تنظیم سیناپسی به ارتباطات مبتنی بر اسپایک گسسته متکی باشد.

در پاسخ به این چالش‌ها، این پروژه یک الگوریتم تخصیص اعتبار جدید را برای پردازش اطلاعات با نورون‌های اسپایک بدون نیاز به سیناپس‌های بازخورد بررسی می‌کند. رویکرد پیشنهادی یک تعمیم مبتنی بر رویداد از فرآیندهای یادگیری رو به جلو (FF) و پیش‌بینی‌کننده رو به جلو<sup>۲</sup> (PFF) برای یک سیستم عصبی اسپایکی مکرر ارائه می‌کند.

در طول این پروژه، ما به پیچیدگی‌های الگوریتم ED-FF و پیامدهای بالقوه آن برای پیشبرد محاسبات فانی در سخت‌افزار نورومورفیک خواهیم پرداخت. با درک نقاط قوت و محدودیت‌های این رویکرد، هدف ما روشن کردن فرصت‌های جدید برای تخصیص اعتبار با الهام از مغز، ارائه بینش‌هایی در زمینه‌های هوش مصنوعی، علوم اعصاب محاسباتی و یادگیری ماشین است.

## ۲.۱ بیان مسئله

در حوزه هوش مصنوعی و علوم اعصاب محاسباتی، پیگیری محاسبات با انرژی کارآمد و سازگار با محیط زیست به یک نگرانی مبرم تبدیل شده است. مفهوم «محاسبات فانی» جداسازی سنتی نرم‌افزار و سخت‌افزار را به چالش می‌کشد، سیستم‌هایی را پیش‌بینی می‌کند که در آن دانش گذرا و نزدیک به رسانه سخت‌افزاری است، و پتانسیل صرفه‌جویی در مصرف انرژی و کاهش هزینه‌های محاسباتی را ارائه می‌دهد.

یک چالش مهم در تحقق محاسبات فانی در توسعه سیستم‌های تطبیقی است که قادر به استخراج

---

<sup>۲</sup>Predictive Forward Forward



و یادگیری در هم تنیده هستند، جایی که انتشار اطلاعات و فرآیندهای یادگیری ذاتاً به هم مرتبط هستند. شبکه‌های عصبی اسپایکی، یک سیستم تطبیقی الهام‌گرفته از مغز، به دلیل محاسبات عددی با انرژی کارآمد، به عنوان گزینه‌ای امیدوارکننده برای پیاده‌سازی محاسبات فانی بر روی سخت‌افزار نورومورفیک ظاهر شده‌اند.

این حال، انجام کارآمد و پایدار تخصیص اعتبار در این شبکه‌ها یک مانع اساسی باقی است، به‌ویژه زمانی که فرآیند تنظیم سیناپسی به ارتباطات مبتنی بر اسپایک گسسته متکی باشد. رویکردهای موجود، مانند پس انتشار در طول زمان<sup>۳</sup>، (BPTT) مستلزم چالش‌های تمایزپذیری در ارتباطات مبتنی بر اسپایک، قفل کردن روبه‌جلو در انتشار اطلاعات، و مسیرهای سیناپسی بازخورد برای محاسبه تغییرات سیناپسی است.

این پروژه به مشکل تخصیص اعتبار در سیستم‌های عصبی بدون سیناپس بازخورد می‌پردازد. تمرکز ما بر چارچوب رویداد محور رو به‌جلو (ED-FF) است، یک الگوریتم تخصیص اعتبار جدید که برای دستیابی به محاسبات عصبی موازی پویا و لایه‌ای بدون تکیه بر مسیرهای سیناپسی بازخورد یا قفل کردن رو به عقب طراحی شده است. رویکرد ED-FF راه‌حلی نوآورانه برای یادگیری بازنمایی توزیع‌شده از الگوهای داده‌های حسی با سیگنال‌های اسپایک زمانی به صورت در لحظه و به‌موقع ارائه می‌دهد.

با بررسی دقیق مبانی نظری و روش‌شناسی تجربی چارچوب الگوریتم ED-FF هدف ما روشن کردن اثربخشی، نقاط قوت و محدودیت‌های آن است. ما به دنبال درک این هستیم که چگونه الگوریتم ED-FF استنتاج و یادگیری در هم تنیده را تسهیل می‌کند و به طور بالقوه شکاف بین علوم اعصاب محاسباتی، یادگیری ماشین و علوم شناختی را پر می‌کند.

سوالات اساسی که این پروژه به دنبال پرداختن به آن است :

---

<sup>3</sup>Backpropagation Through Time

۱. چگونه می‌توانیم یک فرآیند انتساب اعتباری رو به جلو مبتنی بر رویداد را طراحی کنیم تا سیناپس‌های سیستم‌های عصبی اسپایکی را به صورت محلی و پویا وفق دهد و محاسبات کارآمد را بدون نیاز به سیناپس‌های بازخورد ارتقا دهد؟

۲. چارچوب الگوریتم ED-FF تا چه اندازه در آموزش سیستم‌های اسپایکی مکرر پویا قادر به طبقه‌بندی و بازسازی است و چگونه با رویکردهای موجود مقایسه می‌شود؟

از طریق تجزیه و تحلیل جامع الگوریتم ED-FF و نتایج تجربی آن بر روی مجموعه داده‌های الگوی مختلف، ما در تلاش هستیم تا بینش‌هایی در مورد پتانسیل این رویکرد تخصیص اعتبار جدید ارائه دهیم. در نهایت، هدف ما کمک به پیشرفت محاسبات فانی در سخت‌افزار نورومورفیک است و راه را برای سیستم‌های عصبی با انرژی کارآمد و الهام‌گرفته از مغز که با چشم‌انداز «هوش مصنوعی سبز» همسو می‌شوند، هموار می‌کند.

### ۳.۱ تاریخچه سیستم‌های عصبی اسپایکی

کاوش در سیستم‌های عصبی اسپایکی به روزهای اولیه علوم اعصاب محاسباتی و تلاش برای تقلید دقیق‌تر از سازوکارهای پیچیده مغز برمی‌گردد. در حالی که ایده نورون‌های اسپایکی را می‌توان به کارهای پیشگام هاککین و هاکسلی<sup>۴</sup> در دهه ۱۹۵۰ ردیابی کرد، پیشرفت قابل توجهی در درک شبکه‌های عصبی اسپایک و پتانسیل آن‌ها برای پردازش اطلاعات در دهه‌های بعدی رخ داد.

• دهه ۱۹۵۰ - هاککین و هاکسلی: در سال ۱۹۵۲، آلن هاککین و اندرو هاکسلی کار پیشگامانه خود را در مورد توصیف ریاضی پتانسیل عمل<sup>۵</sup> در آکسون<sup>۶</sup> غول پیکر ماهی مرکب منتشر کردند. مدل هاککین-هاکسلی آنها درک جامعی از نحوه تولید و انتشار

<sup>4</sup>Hodgkin and Huxley

<sup>5</sup>Action Potential

<sup>6</sup>Axon

تکانه‌های الکتریکی توسط نورون‌ها ارائه کرد. این تحقیق محوری پایه و اساس علوم اعصاب محاسباتی را پایه‌گذاری کرد و علاقه به ساخت مدل‌های عصبی واقعی تر را برانگیخت.

- دهه ۱۹۸۰ - مدل‌های محاسباتی اولیه: در طول دهه ۱۹۸۰، دانشمندان علوم اعصاب محاسباتی و محققانی مانند کارور مید<sup>۷</sup> و جان هاپفیلد<sup>۸</sup> سهم قابل توجهی در توسعه مدل‌های اولیه نورون اسپایکی داشتند. تلاش‌های پیشگام مید در مهندسی نورومورفیک منجر به معرفی مدل‌های ادغام و آتش شد<sup>۹</sup>، که در آن نورون‌ها سیگنال‌های دریافتی را در طول زمان ادغام می‌کنند و پس از رسیدن به یک آستانه مشخص، اسپایک‌ها را تولید می‌کنند. این مدل‌ها در مقایسه با شبکه‌های عصبی مصنوعی سنتی، رویکرد قابل قبول‌تری از نظر بیولوژیکی برای پردازش اطلاعات ارائه می‌کنند.

- دهه ۱۹۹۰ - پیشرفت‌های نظری: دهه ۱۹۹۰ شاهد پیشرفت‌های نظری قابل توجهی در درک قابلیت‌های محاسباتی شبکه‌های عصبی اسپایکی بودیم. محققانی مانند ولفگانگ ماس<sup>۱۰</sup> و لری ابوت<sup>۱۱</sup> قدرت شبکه‌های مکرر نورون‌های اسپایک را بررسی کردند و توانایی آن‌ها را برای انجام محاسبات پیچیده، مانند تشخیص توالی و وظایف حافظه تداعی نشان دادند. این دوره ظهور شبکه‌های عصبی اسپایک را به عنوان یک چارچوب محاسباتی امیدوارکننده با ویژگی‌های منحصربه‌فرد مشخص کرد.

- دهه ۲۰۰۰ - پلاستیسیته وابسته به زمان اسپایک<sup>۱۲</sup>: در اوایل دهه ۲۰۰۰، کشف پلاستیسیته وابسته به زمان اسپایک توسط هنری مارکرام<sup>۱۳</sup> و همکارانش انقلابی در زمینه پلاستیسیته سیناپسی در شبکه‌های عصبی اسپایکی ایجاد کرد. پلاستیسیته وابسته به زمان

---

<sup>7</sup>Carver Mead

<sup>8</sup>John Hopfield

<sup>9</sup>Integrate and Fire Models

<sup>10</sup>Wolfgang Maass

<sup>11</sup>Larry Abbott

<sup>12</sup>Spike-Timing Dependent Plasticity

<sup>13</sup>Henry Markram

اسپایک یک قانون یادگیری سیناپسی است که سیناپس‌ها را بر اساس زمان بندی دقیق اسپایک‌های پیش سیناپسی و پس سیناپسی تقویت یا ضعیف می‌کند. این مکانیسم الهام گرفته از بیولوژیک نقش مهمی در شکل‌دهی ارتباطات سیناپسی و توانایی‌های یادگیری سیستم‌های عصبی اسپایکی ایفا کرد و امکان تشکیل بازنمایی‌های پیچیده و ذخیره‌سازی حافظه را فراهم کرد.

- دهه ۲۰۱۰ - سخت افزار نورومورفیک: با ظهور سخت‌افزار نورومورفیک، عصر جدیدی برای پیاده‌سازی شبکه‌های عصبی اسپایکی در مقیاس بزرگ در پلت‌فرم‌های سخت‌افزاری تخصصی آغاز شد. شرکت‌های قابل‌توجهی، مانند پلتفرم SpiNNaker که توسط استیو فربر<sup>۱۴</sup> و همکاران توسعه داده شد، امکان تقلید کارآمد این شبکه‌های عصبی را در معماری‌های سخت‌افزاری سفارشی فراهم کرد. سخت‌افزار نورومورفیک از کارایی نوروون‌های اسپایکی برای وظایف محاسباتی تخصصی استفاده کرد و راه را برای محاسبات انرژی کارآمد و الهام‌گرفته از مغز هموار کرد.

---

<sup>14</sup>Steve Furber

## ۴.۱ چالش‌ها و ضرورت‌های بررسی مسئله

بررسی تخصیص اعتبار در سیستم‌های عصبی بدون سیناپس بازخورد چالش‌های متعددی را ارائه می‌کند و ملاحظات اساسی را برای پیشبرد درک محاسبات عصبی و تسهیل اجرای محاسبات فانی به همراه دارد. در این بخش، چالش‌های کلیدی و ضرورت‌های کاوش در مسئله تخصیص اعتبار پیش‌روی رویداد محور (ED-FF) را برجسته می‌کنیم:

۱. ارتباطات مبتنی بر اسپایک غیرمتمايز: شبکه‌های عصبی اسپایکی با اسپایک‌های مجزا کار می‌کنند و ارتباطات مبتنی بر اسپیک را غیرقابل تمایز می‌کنند. پرداختن به این چالش برای توسعه موثر فرآیند تخصیص اعتبار ED-FF بسیار مهم است.

۲. استنتاج و یادگیری در هم تنیده: محاسبات فانی بر نیاز به سیستم‌های تطبیقی که در استنتاج و یادگیری در هم تنیده شرکت می‌کنند، تاکید می‌کند، جایی که انتشار اطلاعات و فرآیندهای یادگیری کاملاً یکپارچه هستند. بررسی این جنبه برای درک چگونگی دستیابی چارچوب ED-FF به محاسبات عصبی موازی پویا و لایه ای ضروری است.

۳. محاسبات عصبی موازی کارآمد: چکیده و مقدمه بر هدف محاسبات عصبی موازی کارآمد بدون سیناپس‌های بازخورد تأکید دارند. بررسی توانایی چارچوب ED-FF برای هماهنگ کردن سیگنال‌های بالا به پایین، پایین به بالا و جانبی به طور موثر برای نشان دادن قابلیت آن برای محاسبات کارآمد انرژی ضروری است.

۴. ارتباط علوم شناختی، علوم اعصاب محاسباتی و یادگیری ماشین: بررسی چارچوب ED-FF نیازمند یک رویکرد چند رشته‌ای است که علوم شناختی، علوم اعصاب محاسباتی و یادگیری ماشین را مرتبط می‌کند. ادغام بینش از این زمینه‌های متنوع برای درک ویژگی‌های

مدار عصبی و محدودیت‌های سخت‌افزاری بسیار مهم است، در نتیجه ED-FF به عنوان یک سیستم تطبیقی سازگار با محاسبات فانی توسعه می‌یابد.

۵. ارزیابی و تعمیم: ارزیابی دقیق الگوریتم ED-FF برای ارزیابی اثربخشی آن در سناریوهای مختلف دنیای واقعی ضروری است. تجزیه و تحلیل عملکرد آن در مجموعه داده‌های الگوی متنوع و وظایف محک برای اعتبارسنجی پتانسیل آن به عنوان یک رویکرد عملی و کارآمد برای یادگیری سیستم‌های عصبی اسپایک بسیار مهم است.

## فصل ۲

# مروری بر مطالعات انجام شده

### ۱.۲ گزاره‌ها

همانطور که ما به بررسی مقاله ”یادگیری سیستم‌های عصبی اسپایکی با فرآیند رو به جلو مبتنی بر رویداد” می‌پردازیم، آشکار می‌شود که درک مفاهیم اساسی شبکه‌های عصبی اسپایکی برای درک اهمیت مقاله بسیار مهم است.

شبکه‌های عصبی اسپایکی یک کلاس خاص از شبکه‌های عصبی است. در این نسل از شبکه‌های عصبی مدل نوروها به نوروهای بیولوژیکی نزدیک‌ترند، در حالی که شبکه‌های عصبی معمولی‌تر و کلاسیک از مدلی ساده‌تر استفاده می‌کنند که این مدل‌ها به طور کامل با نوروهای زیستی متفاوت است. نوروهای زیستی برای ارسال اطلاعات و ارتباط با یکدیگر از سیگنال‌های پالسی شکل (اسپایک) استفاده می‌کنند. شبکه‌های عصبی اسپایکی این ذات پالسی بودن نوروها را در نظر می‌گیرند و قادر به پردازش مقدار قابل توجهی داده با استفاده از تعداد نسبتاً کمی سیگنال اسپایک هستند. در این شبکه‌ها اطلاعات مکانی و زمانی در هر دو بعد زمان اسپایک و نرخ اسپایک رمزگذاری می‌شوند و این برخلاف شبکه‌های عصبی است که در آنها تنها نرخ اسپایک مهم است. در شبکه‌های عصبی اسپایکی نوروها اجزای مهمی هستند، زیرا این نوع شبکه‌ها نوروهای بیولوژیکی و عملکرد آن را به خوبی مدل می‌کنند.

در این بخش، ما اصول اساسی که زیربنای شبکه‌های عصبی اسپایکی، محاسبات رویداد محور و اصول علوم اعصاب محاسباتی هستند، بررسی کنیم. این مفاهیم زمینه را برای درک پیچیدگی‌های الگوریتم ED-FF ارائه شده در مقاله را فراهم می‌کند.

## ۱.۱.۲ نوروهای بیولوژیکی

نوروهای بیولوژیکی<sup>۱</sup> واحدهای اساسی سیستم عصبی در موجودات زنده از جمله انسان و حیوانات هستند. این سلول‌های تخصصی نقش مهمی در انتقال و پردازش اطلاعات از طریق سیگنال‌های الکتریکی و شیمیایی دارند. ساختار و عملکرد نوروهای بیولوژیکی الهام‌بخش است، زیرا آن‌ها پیچیدگی فرآیندهای شناختی، ادراک حسی، کنترل حرکتی و شکل‌گیری حافظه را که زیربنای عملکرد مغز هستند، ممکن می‌سازند.

- ساختار نوروهای بیولوژیکی: یک نرون بیولوژیکی معمولی از چندین جزء ضروری تشکیل شده است که توانایی آن را برای دریافت، پردازش و انتقال اطلاعات تسهیل می‌کند. این اجزا عبارتند از:

(آ) بدن سلولی (سوما<sup>۲</sup>): بدن سلولی بخش مرکزی نرون است که حاوی هسته و سایر اندامک‌های ضروری برای عملکردهای متابولیک نرون است.

(ب) دندریت‌ها<sup>۳</sup>: دندریت‌ها پسوندهای شاخه‌ای هستند که از بدن سلولی بیرون می‌آیند و سیگنال‌های دریافتی را از سایر نوروها یا گیرنده‌های حسی دریافت می‌کنند.

(ج) آکسون: آکسون یک برآمدگی بلند و باریک است که تکانه‌های الکتریکی را از بدن سلولی دور می‌کند. این ماده توسط یک ماده چرب به نام غلاف میلین پوشانده شده است که آکسون را عایق می‌کند و انتقال سریع سیگنال‌ها را تسهیل می‌کند.

<sup>1</sup>Biology Neurons

<sup>2</sup>Soma

<sup>3</sup>Dendrite



(د) پایانه آکسون: در انتهای آکسون، ساختارهای تخصصی به نام پایانه‌های آکسون وجود دارد که در آن انتقال دهنده‌های عصبی برای برقراری ارتباط با سایر نورون‌ها یا سلول‌های عامل آزاد می‌شوند.

- ارتباط در نورون‌های بیولوژیکی: نورون‌های بیولوژیکی از طریق فرآیندی به نام انتقال سیناپسی با یکدیگر ارتباط برقرار می‌کنند. هنگامی که یک سیگنال الکتریکی، به نام پتانسیل عمل یا اسپایک، به پایانه آکسون می‌رسد، باعث آزاد شدن مولکول‌های انتقال دهنده عصبی در سیناپس می‌شود، شکاف کوچک بین پایانه آکسون یک نورون و دندریت‌های دیگر. این انتقال دهنده‌های عصبی به گیرنده‌های خاصی روی دندریت‌های نورون گیرنده متصل می‌شوند و تغییرات الکتریکی ایجاد می‌کنند که می‌تواند نورون گیرنده را تحریک یا مهار کند.

## ۲.۱.۲ پتانسیل غشا

پتانسیل غشایی<sup>۴</sup> یک مفهوم اساسی در علوم اعصاب است که در قلب نحوه ارتباط نورون‌ها و پردازش اطلاعات قرار دارد. این امر به تفاوت ولتاژ در غشای سلولی یک نورون اشاره دارد که به دلیل توزیع نابرابر یون‌های باردار در داخل و خارج سلول ایجاد می‌شود. این پتانسیل الکتریکی برای تولید و انتشار پتانسیل‌های عمل، سیگنال‌های الکتریکی که ارتباط بین نورون‌ها را امکان‌پذیر می‌کند، ضروری است.

- پتانسیل استراحت غشا: در حالت استراحت، زمانی که یک نورون به طور فعال سیگنال ارسال یا دریافت نمی‌کند، پتانسیل غشایی پایداری به نام پتانسیل غشای استراحت را حفظ می‌کند. پتانسیل غشای در حال استراحت معمولاً در نورون‌های پستانداران حدود -۷۰ میلی ولت (mV) است، به این معنی که درون نورون نسبت به خارج دارای بار منفی است.

<sup>4</sup>Membrane potential

- تغییرات پتانسیل غشا: پتانسیل غشاء می‌تواند در پاسخ به محرک‌های مختلف، مانند انتشار انتقال دهنده‌های عصبی از نورون‌های مجاور یا ورودی حسی، تغییر کند. هنگامی که یک نورون سیگنال‌های تحریکی دریافت می‌کند، کانال‌های یونی ممکن است باز شوند و به یون‌های مثبت (به عنوان مثال، سدیم) اجازه دهند تا به داخل سلول جریان پیدا کنند. این هجوم بار مثبت نورون را دپولاریزه می‌کند و اختلاف ولتاژ در غشا را کاهش می‌دهد و احتمال ایجاد پتانسیل عمل را افزایش می‌دهد.

### ۳.۱.۲ پتانسیل عمل (اسپایک)

همه سلول‌های زنده خاصیت تحریک پذیری دارند، اما نورون‌ها این ویژگی را بهتر نشان می‌دهند. عامل تحریک نورون‌ها متفاوت است از جمله این محرک‌ها میتوان نور، الکتریسیته، تغییر دما، فشار، ضربه و مواد شیمیایی را نام برد. برای تحریک نورون باید شدت محرک از حد معینی که آن را شدت آستانه گویند، کمتر باشد. ولتاژ آستانه در حدود ۲۰ تا ۳۰ میلی ولت است. زمانی که سیگنال عصبی از آکسون به نورون‌ها و یا عنصر دیگر بدن مثل ماهیچه‌ها می‌رسد، باعث تحریک آن‌ها می‌شود. نورون‌ها از هر یک از اتصالات دندریتی ورودی خود یک ولتاژ کم دریافت می‌کنند و آن‌ها را با هم ترکیب می‌کنند. اگر حاصل این ترکیب به مقدار آستانه رسید اصطلاحاً نورون آتش می‌کند، که این حالت معمولاً شلیک نورونی نامیده می‌شود و باعث می‌شود که نورون روی آکسون خود یک ولتاژ خروجی ارسال کند. این پتانسیل در حالت تحریک به حدود ۱۰۰+ میلی ولت می‌رسد و به دندریت‌هایی که به این آکسون متصلند رسیده و باعث یک سری فعل و انفعالات شیمیایی در اتصالات سیناپسی می‌شود و می‌تواند باعث آتش کردن نورون‌های دیگر شود. وقتی نورون تحریک می‌شود، وضعیت بارهای الکتریکی در دو سوی غشای آن در نقطه تحریک تغییر می‌کند یعنی سطح خارجی نقطه تحریک شده منفی و سطح داخلی آن مثبت می‌شود. تغییر بار الکتریکی در نقطه تحریک شده باقی نمی‌ماند و نقطه به نقطه در طول تار عصبی حرکت میکند و جریان یا پیام عصبی را پدید می‌آورد. بار الکتریکی هر نقطه پس از تحریک فوری به حالت اول برمی‌گردد. نورون‌های زیستی از این افزایش کوتاه و ناگهانی ولتاژ برای ارسال اطلاعات استفاده می‌کنند. تمامی این عملیات با ایجاد و انتقال پالس‌هایی که با نام‌های مختلفی مانند پتانسیل عمل،

ایمپالس یا اسپایک شناخته می‌شوند انجام می‌پذیرد.

## ۴.۱.۲ سایر اصطلاحات

- سیناپس: یک اتصال تخصصی بین دو نورون که در آن اطلاعات از طریق سیگنال‌های شیمیایی یا الکتریکی منتقل می‌شود.
- یادگیری رو به جلو: یک رویکرد تخصیص اعتبار که شامل محاسبه مشتقات در طول زمان برای به روز رسانی وزن در شبکه‌های عصبی مکرر است.
- رویداد محور: یک الگوی محاسباتی که در آن به روز رسانی‌ها و پردازش‌ها تنها زمانی اتفاق می‌افتند که رویدادهای خاص (مثلاً جهش‌ها) اتفاق می‌افتند، نه در فواصل زمانی ثابت.
- موازی سازی لایه‌ها: توانایی انجام محاسبات به طور همزمان در لایه‌های مختلف یک شبکه عصبی.
- سخت افزار نورومورفیک: سخت افزاری که برای تقلید از ساختار و عملکرد مغز انسان طراحی شده و محاسبات عصبی با انرژی کارآمد را ممکن می‌سازد.
- سیناپس‌های پویا: سیناپس‌هایی با وزن‌های قابل تنظیم، مسئول انعطاف پذیری و یادگیری در شبکه‌های عصبی هستند.
- طبقه‌بندی<sup>۵</sup>: وظیفه تخصیص برچسب‌ها یا دسته‌های از پیش تعریف شده به داده‌های ورودی بر اساس الگوهای آموخته شده است.
- بازسازی: فرآیند بازسازی داده‌های ورودی از نمایش‌ها یا ویژگی‌های آموخته شده.
- نرخ یادگیری<sup>۶</sup>: یک فراپارامتر است که اندازه مرحله به روز رسانی وزن را در طول تمرین کنترل می‌کند.

---

<sup>5</sup>Classification

<sup>6</sup>Learning Rate

- یادگیری آنلاین: یک الگوی یادگیری که در آن مدل به طور مداوم پارامترهای خود را با رسیدن داده‌های جدید به روز می‌کند.
- سنسورهای مبتنی بر رویداد: حسگرهایی که اطلاعات را به شیوه‌ای مبتنی بر رویداد جمع‌آوری می‌کنند، افزونگی را به حداقل می‌رسانند و پردازش داده‌ها را کاهش می‌دهند.
- تابع فعال‌سازی اسپایکی: تابعی که پتانسیل غشاء را با احتمال ایجاد یک اسپایک ترسیم می‌کند.
- یادگیری نظارت شده<sup>۷</sup>: نوعی از یادگیری ماشینی که در آن مدل بر روی داده‌های برچسب دار آموزش داده می‌شود و یاد می‌گیرد که خروجی‌های ورودی داده شده را پیش بینی کند.
- یادگیری بدون نظارت<sup>۸</sup>: نوعی از یادگیری ماشینی که در آن مدل بر روی داده‌های بدون برچسب، الگوهای یادگیری و ساختارها بدون برچسب‌های صریح آموزش داده می‌شود.
- تشخیص الگو: فرآیند شناسایی الگوها یا قاعده مندی‌ها در داده‌ها برای طبقه‌بندی اشیا یا رویدادها.
- هموستاز<sup>۹</sup>: توانایی یک سیستم برای حفظ یک حالت داخلی پایدار، همانطور که در موجودات بیولوژیکی و سیستم‌های سازگار مشاهده می‌شود.
- پلاستیسته سیناپسی: توانایی سیناپس‌ها برای تغییر قدرت خود در طول زمان، مکانیزمی حیاتی برای یادگیری و حافظه.
- محاسبات عصبی: پردازش اطلاعات و انجام محاسبات با استفاده از شبکه‌های عصبی مصنوعی یا نورون‌های بیولوژیکی.

---

<sup>7</sup>Supervised Learning

<sup>8</sup>UnSupervised Learning

<sup>9</sup>Hemostasis

- سخت افزار رویداد محور: سخت افزاری که بر اساس وقوع رویدادهای خاص عمل می‌کند و در نتیجه مصرف انرژی کاهش می‌یابد.
- واگذاری اعتبار: فرآیند نسبت دادن موفقیت یا شکست یک کار به عوامل خاص یا ارتباطات عصبی.
- علوم اعصاب محاسباتی: حوزه‌ای میان رشته‌ای که به بررسی چگونگی پردازش اطلاعات توسط مغز و انجام محاسبات می‌پردازد.
- هوش مصنوعی سبز: مفهوم طراحی سیستم‌های هوش مصنوعی با انرژی کارآمد برای کاهش انتشار کربن و مصرف انرژی.

## ۲.۲ انواع مدل‌های نرونی در شبکه‌های عصبی اسپایکی

در پی درک و تقلید از پیچیدگی‌های مغز انسان، محققان و عصب‌شناسان محاسباتی مدل‌های متنوعی را برای شبیه‌سازی رفتار نرونها ایجاد کرده‌اند. در این بخش، ما به بررسی انواع مدل‌های عصبی در شبکه‌های عصبی اسپایکی می‌پردازیم. ما هر دو مدل ساده و پیچیده را بررسی می‌کنیم، از مدل‌های پایه‌ای ادغام و آتش گرفته تا مدل‌های پیچیده‌تر الهام گرفته از هاچکین هاگسلی و فراتر از آن. هر مدل دیدگاه منحصر به فردی در مورد نحوه تولید و انتشار اسپایک‌ها توسط نرونها، نحوه پاسخگویی آن‌ها به سیگنال‌های ورودی و نحوه تطبیق اتصالات سیناپسی خود در پاسخ به یادگیری ارائه می‌دهد. بررسی این مدل‌های عصبی، تنوع قابل توجه شبکه‌های عصبی اسپایکی و کاربردهای بالقوه آن‌ها را در طیف گسترده‌ای از حوزه‌ها، از یادگیری ماشین و هوش مصنوعی گرفته تا سخت‌افزار نورومورفیک و علوم اعصاب محاسباتی، آشکار می‌کند.

از دیدگاه مفهومی می‌توان گفت که تمام مدل‌های اسپایکی دارای خصوصیات مشترک زیر هستند:

۱. آن‌ها اطلاعات وارد شده از ورودی‌ها را پردازش کرده و سیگنال‌های اسپایکی را در خروجی خود تولید می‌کنند.

۲. احتمال شلیک نرونی (تولید اسپایک) به وسیله ورودی‌های تحریک کننده افزایش و به وسیله ورودی‌های تضعیف کننده کاهش می‌یابد.

۳. دینامیک آن‌ها با حداقل یک متغیر حالت مشخص می‌شود. هنگامی که متغیرهای داخلی مدل به یک حالت خاص می‌رسد یک یا چند اسپایک تولید می‌شود.

### ۱.۲.۲ مدل هاچکین و هاکسلی: کشف بیوفیزیک اسپایکی عصبی

مدل هاچکین و هاکسلی که توسط سر آلن هاچکین و سر اندرو هاکسلی در سال ۱۹۵۲ ایجاد شد، یک چارچوب ریاضی پیشگامانه است که رفتار الکتریکی آکسون غول پیکر در ماهی مرکب را توصیف می‌کند. این مدل پایه و اساس درک چگونگی تولید و انتشار پتانسیل‌های عمل توسط نوروها، سیگنال‌های الکتریکی است که ارتباط بین نوروها را امکان‌پذیر می‌سازد و محاسبات عصبی را در مغز پشتیبانی می‌کند.

- زمینه: در زمان آزمایش‌های هاچکین-هاکسلی، مکانیسم‌های زیربنای تولید و انتشار پتانسیل‌های عمل به خوبی شناخته نشده بودند. هاچکین و هاکسلی با انجام آزمایش‌های پیچیده الکتروفیزیولوژیکی روی آکسون غول پیکر ماهی مرکب به دنبال کشف بیوفیزیک اسپایک نوروها بودند. یافته‌های آن‌ها تأثیر متقابل پیچیده یون‌ها و کانال‌های یونی را در تولید پتانسیل‌های عمل نشان داد.

- مدل غشا: مدل هاچکین-هاکسلی مبتنی بر مفهوم غشای سلولی به عنوان یک خازن است که می‌تواند بار الکتریکی را ذخیره کند، و ادغام رسانایی یونی در سراسر غشای سلولی. این مدل دارای کانال‌های یونی است که جریان یون‌های خاص (سدیم و پتاسیم) را از طریق غشای سلولی امکان‌پذیر می‌کند و بر پتانسیل غشا تأثیر می‌گذارد.

- عناصر کلیدی مدل:

مدل هاچکین هاکسلی شامل چهار عنصر اساسی است:

۱. ظرفیت غشایی<sup>۱۰</sup> (Cm): نشان دهنده توانایی غشای سلولی برای ذخیره بار الکتریکی، شبیه به خازن در مدار الکترونیکی است.
۲. جریان غشایی<sup>۱۱</sup> (Im): جریان خالصی که از غشای سلول می‌گذرد که به حرکت یون‌ها بستگی دارد.
۳. کانال‌های سدیم (Na+) و پتاسیم (K+): این مدل شامل کانال‌های سدیم و پتاسیم دارای ولتاژ است که هر کدام توسط متغیرهای فعال‌سازی و غیرفعال‌سازی کنترل می‌شوند که به پتانسیل غشا بستگی دارد.
۴. جریان نشتی<sup>۱۲</sup>: نشان دهنده جریان ثابت پس زمینه ناشی از جریان یون غیرفعال در غشای سلولی است.

• اهمیت و تأثیر: مدل هاچکین-هاکسلی یک دستاورد بزرگ در زمینه علوم اعصاب محاسباتی بود. این مدل درک کمی از چگونگی کمک کانال‌های یونی به تولید و انتشار پتانسیل‌های عمل ارائه می‌کند و اهمیت دینامیک هدایت یونی را در تحریک‌پذیری عصبی نشان می‌دهد. مدل هاچکین-هاکسلی از آن زمان به سنگ بنای علوم اعصاب محاسباتی تبدیل شد و به عنوان مبنایی برای مدل‌های عصبی بعدی، از جمله مدل‌هایی که در شبکه‌های عصبی اسپایکی مدرن استفاده می‌شوند، عمل کرد. این به طور قابل توجهی بر درک ما از نحوه عملکرد نورون‌ها تأثیر گذاشته و راه را برای شبیه‌سازی رفتار عصبی پیچیده هموار کرده است که در نهایت به پیشرفت در تحقیقات هوش مصنوعی و علوم اعصاب کمک می‌کند.

## ۲.۲.۲ مدل نورونی تجمیع و آتش نشتی<sup>۱۳</sup>: یک انتزاع عصبی ساده شده

مدل نورونی تجمیع و آتش نشتی یک انتزاع عصبی اساسی و ساده شده است که به طور گسترده در علوم اعصاب محاسباتی و شبیه‌سازی‌های شبکه عصبی اسپایک استفاده می‌شود. اولین بار توسط

<sup>10</sup>Membrane Capacitance

<sup>11</sup>Membrane Current

<sup>12</sup>Leakage Current

<sup>13</sup>Leaky Integrate-and-Fire Model

جان رینزل<sup>۱۴</sup> در سال ۱۹۸۵ معرفی شد، این مدل جنبه‌های اساسی رفتار عصبی را در عین حفظ قابلیت حمل‌پذیری ریاضی به تصویر می‌کشد و آن را به ابزاری ارزشمند برای درک محاسبات عصبی تبدیل می‌کند.

- زمینه: مدل نورونی تجمعی و آتش‌نشتی به عنوان یک جایگزین محاسباتی کارآمدتر برای مدل هاچکین-هاکسلی، که شامل معادلات دیفرانسیل پیچیده برای توصیف دینامیک کانال یونی بود، توسعه یافت. در حالی که این مدل از نظر بیوفیزیکی جزئیات کمتری دارد، ویژگی‌های کلیدی اسپایک نورون را حفظ کرده و امکان شبیه‌سازی کارآمد شبکه‌های عصبی در مقیاس بزرگ را فراهم می‌کند.

- عناصر کلیدی مدل: این مدل یک نورون را به عنوان یک مدار الکتریکی نشان می‌دهد که جریان‌های سیناپسی ورودی را یکپارچه می‌کند و هنگامی که پتانسیل غشاء به آستانه معینی می‌رسد، اسپایک‌هایی منتشر می‌کند. این مدل از اجزای کلیدی زیر تشکیل شده است:

۱. پتانسیل غشایی (V): پتانسیل غشایی نورون نشان دهنده اختلاف ولتاژ در سراسر غشای سلولی است که مشابه بار روی یک خازن است. در طول زمان در پاسخ به جریان‌های سیناپسی ورودی و ویژگی‌های ذاتی نورون تغییر می‌کند.

۲. آستانه (V-th): آستانه، سطح پتانسیل غشایی بحرانی است که با رسیدن به آن، نورون را تحریک می‌کند تا یک پتانسیل عمل (سنبله) منتشر کند. هنگامی که پتانسیل غشاء از این آستانه فراتر می‌رود، گفته می‌شود که نورون "آتش" می‌شود.

۳. جریان نشتی (I-leak): این مدل دارای یک مکانیسم "نشت" است که جریان یون غیرفعال را از طریق غشای سلولی شبیه سازی می‌کند. جریان نشتی باعث می‌شود که پتانسیل غشاء به مرور زمان به تدریج به یک مقدار سکون بازگردد، زمانی که جریان سیناپسی ورودی وجود ندارد.

۴. جریان‌های سیناپسی<sup>۱۵</sup> (I-syn): همچنین مدل مذکور اثرات جریان‌های سیناپسی

<sup>14</sup>John Rinzel

<sup>15</sup>Synaptic Currents



ورودی از نورون‌های دیگر را محاسبه می‌کند. هنگامی که یک نورون پیش سیناپسی یک پتانسیل عمل را شلیک می‌کند، یک جریان سیناپسی را در نورون پس سیناپسی القا می‌کند و به طور بالقوه پتانسیل غشاء را به آستانه شلیک نزدیک می‌کند.

- اهمیت و تأثیر: مدل نورونی تجمیع و آتش نشستی به دلیل سادگی و کارایی آن به طور گسترده در علوم اعصاب محاسباتی استفاده می‌شود. این مدل امکان شبیه‌سازی سریع‌تر شبکه‌های عصبی بزرگ را فراهم می‌کند و آن را برای مطالعه رفتار جمعی و پدیده‌های نوظهور مناسب می‌سازد. علاوه بر این، سادگی آن بینش‌های تحلیلی را در مورد پویایی شبکه امکان پذیر می‌کند و تحقیقات نظری پردازش اطلاعات عصبی را تسهیل می‌نماید. در حالی که مدل نورونی تجمیع و آتش نشستی ممکن است پیچیدگی‌های بیوفیزیکی نورون‌های واقعی را نشان ندهد، اما به عنوان یک ابزار ارزشمند برای کاوش مفاهیم اساسی در شبکه‌های عصبی اسپایک، از جمله رمزگذاری اطلاعات و پدیده‌های همگام‌سازی عمل می‌کند. سادگی آن، آن را به یک بلوک ساختمانی ضروری در طراحی انواع مدل‌های شبکه عصبی اسپایکی تبدیل کرده است که به توسعه الگوریتم‌های الهام‌گرفته از مغز و سخت‌افزار نورومورفیک کمک می‌کند.

### ۳.۲.۲ مدل تشدید و آتش<sup>۱۶</sup>

مدل تشدید و آتش یک انتزاع نورونی اسپایکی است که ویژگی‌های تشدید و رفتار نوسانی را در خود جای داده است. این مدل که به عنوان توسعه مدل تشدید و آتش معرفی شده است، کاوشی در مورد چگونگی پاسخ نورون‌ها به فرکانس‌های ورودی خاص و نشان دادن الگوهای ریتمیک اسپایک را امکان پذیر می‌کند.

- تنظیم فرکانس: برخلاف رفتار اسپایکی ساده مبتنی بر آستانه در مدل تشدید و آتش این مدل دارای تنظیم فرکانس است. نورون‌ها در این مدل وقتی در معرض فرکانس‌های ورودی خاصی

<sup>16</sup>Resonate and Fire Model

قرار می‌گیرند که با فرکانس تشدیدشان مطابقت دارد، فعالیت اسپایکی افزایش یافته‌اند. این رزونانس پاسخ نوروں را تقویت می‌کند و منجر به الگوهای برجسته تر می‌شود.

- رفتار نوسانی: این مدل امکان مطالعه پدیده‌های نوسانی در شبکه‌های عصبی را فراهم می‌نماید. هنگامی که نوروں‌ها ورودی‌های ریتمیک را در فرکانس‌های تشدید خود یا نزدیک به آن دریافت می‌کنند، ممکن است فعالیت اسپایک خود را همگام کنند و منجر به نوسانات در شبکه شود. رفتار نوسانی در عملکردهای مختلف مغز مانند حافظه و پردازش حسی ضروری است.

- اهمیت و تأثیر: مدل تشدید و آتش برای بررسی رزونانس عصبی و دینامیک نوسانی ارزشمند است، و بینشی در مورد نحوه پردازش اطلاعات توسط شبکه‌های عصبی از طریق الگوهای ریتمیک ارائه می‌دهد. این مدل در مطالعه همزمانی عصبی، ریتم‌های مغز و نقش تشدید در عملکردهای شناختی کاربرد دارد.

## ۴.۲.۲ مدل پاسخ اسپایک<sup>۱۷</sup> (SRM): گرفتن زمان دقیق اسپایک در نوروں‌ها

مدل پاسخ اسپایک یک مدل عصبی اسپایکی ضروری و همه‌کاره است که در علوم اعصاب محاسباتی برای مطالعه زمان دقیق اسپایک‌های تولید شده توسط نوروں‌ها در پاسخ به محرک‌های ورودی استفاده می‌شود. SRM که در سال ۱۹۹۳ معرفی شد، چارچوبی برای بررسی انعطاف‌پذیری وابسته به زمان اسپایک و پردازش اطلاعات در شبکه‌های عصبی اسپیک ارائه می‌کند.

در واقع این مدل، مدل تجمیع و آتش را با ترکیب یک رویکرد دقیق تر به پویایی زمانی اسپایک‌های عصبی گسترش می‌دهد. در SRM، هر اسپایک از یک نوروں پیش سیناپسی به عنوان یک پاسخ جریان پس سیناپسی نشان داده می‌شود. این پاسخ فعلی به عنوان تابعی از زمان مدل‌سازی می‌شود و منعکس‌کننده چگونگی واکنش نوروں پس سیناپسی به رسیدن یک اسپایک پیش سیناپسی است.

- تابع پاسخ سیناپسی: مرکز SRM تابع پاسخ سیناپسی است که شکل و مشخصات زمانی جریان پس سیناپسی را که توسط یک اسپایک پیش سیناپسی ایجاد می‌شود، مشخص می‌کند. تابع

<sup>17</sup>Spike Response Model

پاسخ سیناپسی معمولاً شامل یک مؤلفه تحریکی و یک مؤلفه بازدارنده است که ورودی‌های سیناپسی تحریکی و مهارى را جذب می‌کند.

- پلاستیسیته وابسته به زمان اسپایک (STDP): یکی از ویژگی‌های کلیدی SRM توانایی آن در مدل سازی انعطاف پذیری وابسته به زمان اسپایک است، پدیده‌ای که در نورون‌های واقعی مشاهده می‌شود. STDP توضیح می‌دهد که چگونه زمان نسبی اسپایک‌های قبل و بعد از سیناپسی بر قدرت اتصال سیناپسی تأثیر می‌گذارد. در SRM، شکل تابع پاسخ سیناپسی امکان ادغام قوانین STDP را فراهم می‌کند و شبیه سازی فرآیندهای یادگیری و حافظه در شبکه‌های عصبی را ممکن می‌سازد.

- اهمیت و تأثیر: مدل پاسخ اسپایک به طور گسترده برای مطالعه تأثیر زمان‌بندی دقیق اسپایک بر پردازش اطلاعات و یادگیری در شبکه‌های عصبی اسپایک استفاده می‌شود. SRM با در نظر گرفتن جنبه‌های زمانی پاسخ‌های اسپایک و پیاده‌سازی STDP، بینش‌هایی را در مورد اینکه چگونه شبکه‌های عصبی با الگوهای ورودی خود تطبیق می‌دهند و نمایش‌های توزیع شده اطلاعات را تشکیل می‌دهند، ارائه می‌کند.

## ۳.۲ پژوهش‌های انجام شده

در تلاش برای ساخت شبکه‌های عصبی مصنوعی واقعی‌تر و کارآمدتر، محققان جایگزین‌هایی را برای الگوریتم پس انتشار سنتی بررسی کرده‌اند. الگوریتم پس انتشار، اگرچه برای آموزش شبکه‌های عصبی مصنوعی مؤثر است، اما به دلیل محدودیت‌هایی که در تقلید نحوه یادگیری مغز دارد، مورد انتقاد قرار گرفته است. تفاوت‌های بین پس انتشار و فرآیندهای عصبی مشاهده شده، علاقه به توسعه الگوریتم‌های جایگزین را برانگیخته است که بیشتر با اصول عصبی زیست‌شناسی همسو می‌شوند.

این بخش به بررسی کارهای مرتبط می‌پردازد و چالش‌های مرتبط با الگوریتم پس انتشار و جایگزین‌های امیدوارکننده‌ای را که پدیدار شده‌اند را برجسته می‌کند. با درک این رویکردهای

جایگزین، ما بینشی در مورد چگونگی تلاش محققان برای ایجاد مدل‌های عصبی به دست می‌آوریم که مکانیسم‌های یادگیری مغز را بهتر تقلید کنند.

## ۱.۳.۲ الگوریتم پس انتشار و محدودیت‌های آن

پس انتشار یک الگوریتم پرکاربرد برای آموزش شبکه‌های عصبی مصنوعی است. با این حال، در مورد معقول بودن بیولوژیکی آن، به ویژه در زمینه تقلید از نحوه یادگیری مغز، با انتقاداتی مواجه شده است. منتقدان استدلال می‌کنند که نحوه عمل پس انتشار با فرآیندهای عصبی مشاهده شده در تضاد است، و بعید به نظر می‌رسد که یک مدل قابل دوام برای تخصیص اعتبار در مغز باشد. یکی از نگرانی‌های اصلی این است که الگوریتم پس انتشار نیازمند ذخیره‌سازی صریح فعالیت‌های عصبی است تا بعداً برای تنظیم وزن‌های سیناپسی مورد استفاده قرار گیرد. این امر تناقض دارد که چگونه نورون‌های بیولوژیکی اتصالات خود را به شیوه‌ای پیوسته و سازگارتر به روز می‌کنند. موضوع دیگر الگوریتم پس انتشار، مشتقات خطا در طول مسیر بازخورد جهانی برای تولید سیگنال‌های آموزشی است. این سازوکار با محاسبات عصبی مشاهده شده سازگار نیست و سؤالاتی را در مورد امکان بیولوژیکی آن ایجاد می‌کند. علاوه بر این، مشکل انتقال وزن به دلیل انتشار سیگنال‌های خطا به سمت عقب در امتداد مسیرهای عصبی مشابهی که برای انتشار اطلاعات رو به جلو استفاده می‌شود، ایجاد می‌شود. در مغز، چنین سازوکاری به خوبی پشتیبانی نمی‌شود، که منجر به شک و تردید در مورد اعتبار انتشار پسین به عنوان یک مکانیسم یادگیری بیولوژیکی قابل قبول می‌شود. علاوه بر این، پس انتشار به یک فرآیند عمدتاً متوالی برای استنباط و یادگیری متکی است، در حالی که مغز محاسبات را به صورت انبوهی موازی انجام می‌دهد. اختلاف بین ماهیت متوالی انتشار پس‌زمینه و موازی‌سازی در پردازش مغز نشان می‌دهد که انتشار پس‌پشتی ممکن است به طور دقیق نحوه یادگیری و محاسبه مغز را منعکس نکند.

## ۲.۳.۲ جایگزین‌های امیدوار کننده برای الگوریتم پس انتشار

در پاسخ به محدودیت‌های پس انتشار، محققان الگوریتم‌های جایگزین و مدل‌های محاسباتی را بررسی کرده‌اند که مکانیسم‌های تخصیص اعتباری معقول‌تری را ارائه می‌دهند. یکی از امیدوارکننده‌ترین رویکردها، کدگذاری پیش‌بینی‌کننده<sup>۱۸</sup> (PC) است. رایانه شخصی مغز را درگیر پیش‌بینی‌هایی در مورد داده‌های حسی دریافتی می‌کند و سپس مدل داخلی خود را بر اساس خطاهای پیش‌بینی به روز می‌کند. این مکانیسم با برخی از فرآیندهای یادگیری عصب‌بیولوژیکی، مانند پردازش پیش‌بینی، که تصور می‌شود برای پردازش مؤثر اطلاعات حسی در مغز رخ می‌دهد، بهتر همسو می‌شود.

یکی دیگر از تمرکزهای اخیر روی رویکردهای یادگیری فقط رو به جلو بوده است، که شامل الگوریتم‌هایی مانند انتشار سیگنال، الگوریتم روبه‌جلو و روش پیش‌بینی به جلو است. برخلاف پس انتشار، فرآیندهای فقط به جلو شامل انتشار پس انتشار سیگنال‌های خطا نمی‌شوند. در عوض، آن‌ها صرفاً بر انتشار اطلاعات رو به جلو برای تسهیل یادگیری متکی هستند. در نتیجه، این رویکردها با یادگیری هبی، یک مکانیسم یادگیری قابل قبول بیولوژیکی که در مغز مشاهده می‌شود، سازگارتر است. یادگیری هبیان معتقد است که اتصالات سیناپسی زمانی تقویت می‌شوند که نورون‌هایی که نزدیک به هم هستند با هم فعال شوند.

یکی از مزیت‌های قابل توجه یادگیری رو به جلو، مناسب بودن آن برای یادگیری روی تراشه در سخت افزار نورومورفیک است. از آنجایی که فرآیندهای فقط رو به جلو به مسیرهای محاسباتی جداگانه برای انتقال سیگنال‌های آموزشی یا پیام‌های خطا نیاز ندارند، می‌توان آن‌ها را به راحتی در سخت افزار پیاده سازی کرد و آن‌ها را برای ساختن سیستم‌های محاسباتی الهام گرفته از مغز جذاب می‌کند.

---

<sup>18</sup>Predictive Coding

## ۳.۳.۲ مزایای یادگیری پیشرو

مزایای یادگیری پیشرو یادگیری پیشرو، چندین مزیت را نسبت به سایر طرح‌های تخصیص اعتبار بیولوژیکی ارائه می‌دهد. برای مثال، نیاز به سخت‌افزار تخصصی برای محاسبه مشتقات تابع فعال‌سازی یا نگهداری و تنظیم سیناپس‌های انتقال بازخورد جداگانه را که اغلب در پس‌انتشار و سایر روش‌ها مورد نیاز است، از بین می‌برد.

علاوه بر این، الگوریتم‌های پیشرو معمولاً سریع‌تر از فرآیندهای سازگاری مبتنی بر یادگیری متضاد هبین<sup>۱۹</sup> هستند. این روش‌های متضاد مستلزم محاسباتی هستند که در هر دو فاز مثبت و منفی مشروط می‌شوند، و آن‌ها را از نظر محاسباتی پیچیده‌تر و به طور بالقوه کمتر از رویکردهای پیشرو می‌سازد. یکی از ویژگی‌های مهم یادگیری پیشرو، مانند الگوریتم ED-FF، توانایی آن در ترکیب رقابت جانبی در فعالیت‌های لایه‌ای آن است. رقابت جانبی به فعل و انفعالات رقابتی بین نورون‌ها در همان لایه اشاره دارد که در آن فعال شدن یک نورون مانع از فعال شدن سایر نورون‌ها می‌شود. نشان داده شده است که این امر برای محاسبات عصبی مهم است، و ادغام یادگیری رقابتی با سازگاری با انعطاف‌پذیری وابسته به زمان اسپایک خالص ارزشمند است.

در نتیجه، جستجو برای مکانیسم‌های تخصیص اعتبار از نظر بیولوژیکی معقول منجر به کشف جایگزین‌هایی برای الگوریتم پس‌انتشار شده است.

کدگذاری پیش‌بینی‌کننده و الگوریتم‌های یادگیری فقط پیشرو، رویکردهای امیدوارکننده‌ای را نشان می‌دهند که با اصول یادگیری عصب‌بیولوژیکی بهتر همسو می‌شوند و در عین حال به عملکرد رقابتی دست می‌یابند. هدف محققان با الهام گرفتن از مکانیسم‌های محاسباتی مغز، توسعه الگوریتم‌های بیولوژیکی واقعی‌تر و کارآمدتر برای هوش مصنوعی است.

---

<sup>19</sup>Hebbian Learning

## فصل ۳

# بررسی پیاده سازی انجام شده

### ۱.۳ شبکه‌های عصبی اسپایکی

در این فصل، با ارائه یک بررسی پیاده سازی عمیق از روش‌های پیشنهادی ارائه شده برای یادگیری و طبقه بندی شبکه‌های عصبی اسپایکی، به جنبه‌های عملی این تحقیق می‌پردازیم. هدف ما ارائه یک درک جامع از مؤلفه‌های کلیدی است که رویکرد محققان را تشکیل می‌دهند، و بر پیچیدگی‌های پویایی یادگیری و مکانیسم‌هایی که طبقه بندی مبتنی بر اسپایک را هدایت می‌کنند، روشن می‌شود. در سرتاسر این فصل، توضیحات و بینش‌های مفصلی را در مورد اجزای مختلف پیاده سازی ارائه می‌دهیم و روش‌ها و تکنیک‌هایی را که عملکرد شبکه عصبی را هدایت می‌کنند، روشن می‌کنیم. با درک پیچیدگی‌ها، خوانندگان دانش عمیق‌تری از پیشرفت‌های مربوط به الگوریتم رو به جلو مبتنی بر رویداد، پویایی‌های مکرر، یادگیری آنلاین، طبقه بندی مبتنی بر اسپایک، و تأثیر جمعی آن‌ها در ساخت شبکه‌های عصبی اسپایک محور کارآمد و قدرتمند خواهند داشت. این فصل در پنج بخش مجزا تشکیل شده است که هر بخش به ارائه بینش‌های ارزشمند در مورد جنبه‌های مختلف تحقیق اختصاص دارد.

## ۲.۳ یادگیری شبکه‌های اسپایکی با تنظیم رویداد محور پیشرو

### ۱.۲.۳ دینامیک مدار عصبی اسپایکی مکرر

سیستم عصبی مورد مطالعه ما یک شبکه بازگشتی چند لایه است که هر لایه به موازات لایه‌های دیگر عمل می‌کند. در هر مرحله زمانی معین، "t" هر لایه "I" متشکل از نورون‌های  $J_{l-1}$  است که ورودی‌ها را از نورون‌های زیر خود در لایه قبلی در زمان "t-1" و از نورون‌های بالای آنها در لایه بعدی و در زمان "t-1" دریافت می‌کند. این الگوی اتصال مکرر به اطلاعات اجازه می‌دهد تا هم از پایین به بالا و هم از بالا به پایین جریان داشته باشند، و امکان تشکیل نمایش‌های اسپایک را فراهم می‌کند که اطلاعات ارزشمند و متمایز را رمزگذاری می‌کنند. علاوه بر این، نورون‌های درون هر لایه از طریق سیناپس‌هایی به یکدیگر متصل می‌شوند که مهار متقاطع را اعمال می‌کنند. در این زمینه، مهار متقاطع به این معنی است که نورون‌هایی که به شدت فعال می‌شوند، فعالیت‌های نورون‌های دیگر را در همان لایه سرکوب می‌کنند. این امر منجر به شکلی از رقابت می‌شود که در آن تعداد پویا و متغیری از نورون‌ها که با "K" مشخص می‌شوند، به عنوان برنده ظاهر می‌شوند و کنترل نمایش را در دست می‌گیرند. به طور رسمی، کل مدل به طور کامل با مجموعه‌ای از وزن‌های قابل یادگیری که به صورت  $\Theta = \{W^1, V^1, M^1, B^1, \dots, W^l, V^l, M^l, B^l, \dots, W^L, M^L, B^L\}$  مشخص می‌شود، پارامتر بندی می‌شود. در این مرحله، وضعیت فعال سازی هر لایه توسط چندین نوع اتصال سیناپسی تعریف می‌شود:

- اتصالات سیناپسی پایین به بالا با ماتریس‌های وزن  $W^l$ ، که در آن  $W^l \in [-1, 1]^{(J_l, J_{l-1})}$  نشان داده می‌شوند. این اتصالات اطلاعات را از نورون‌های لایه قبلی (l-1) به لایه فعلی (l) منتقل می‌کنند.
- سیناپس‌های میانجی از بالا به پایین با ماتریس‌های وزنی  $V^l$  نشان داده می‌شوند، که در آن  $V^l \in [-1, 1]^{(J_l, J_{l+1})}$  است. این سیناپس‌ها جریان بالا به پایین اطلاعات را از نورون‌های لایه بعدی (l+1) به لایه فعلی (l) تسهیل می‌کنند.



- سیناپس‌های مهار جانبی با ماتریس‌های وزنی  $M^l$  نشان داده می‌شوند، که در آن  $M^l \in [0,1]^{(J_l, J_l)}$ . این اتصالات بازدارنده را در بین نورون‌های درون همان لایه اعمال می‌کند و رقابت بین آنها را ترویج می‌کند.

- سیناپس‌های واسطه‌ی زمینه با ماتریس‌های وزنی  $B^l$ ، که در آن  $B^l \in [-1,1]^{(J_l, C)}$  نشان داده می‌شوند. این سیناپس‌ها اطلاعات مرتبط با زمینه را حمل می‌کنند که بر پویایی شبکه تأثیر می‌گذارد.

- توجه داشته باشید، همه ماتریس‌های وزن در مدل دارای مقادیر محدود شده بین  $-1$  و  $1$  هستند، به جز  $M^l$  که فقط حاوی مقادیر مثبت در محدوده  $[0, 1]$  است. این پارامترسازی امکان تنظیم انعطاف‌پذیر و پویا نقاط قوت سیناپسی را در طول فرآیند یادگیری فراهم می‌کند که منجر به ظهور نمایش‌های کارآمد و قوی در شبکه عصبی اسپیک می‌شود.

دینامیک هر لایه معین (I) در سیستم اسپایکی به صورت زیر محاسبه می‌شود:

$$j^l(t) = W^l \cdot s^{l-1}(t) + V^l \cdot s^{l+1}(t) - (M^l \odot (1 - I^l)) \cdot s^l(t) + B^l \cdot s_y(t)$$

$$v^l(t + \Delta t) = v^l(t) + \frac{\Delta t}{\Gamma m} (-v^l(t) + R_m j^l(t))$$

$$s^l(t) = v^l(t + \Delta t) > v_{thr}^l, \text{ and, } v^l(t) = v^l(t + \Delta t) \odot (1 - s^l(t))$$

$$v_{thr}^l = v_{thr}^l + \lambda_v \left( \left( \sum_{j=1}^{j_l} s^l(t)_j \right) - 1 \right)$$

سیستم عصبی اسپایکی مکرر که در این قسمت توضیح داده شده است از چندین لایه نورون تشکیل

شده است که به موازات یکدیگر عمل می‌کنند. در هر مرحله زمانی،  $(t)$  سیستم ورودی‌های جریان الکتریکی  $j^l(t)$  را برای هر نورون در لایه  $(l)$  پردازش می‌کند و پتانسیل‌های غشای فعلی  $v^l(t)$  و خروجی‌های اسپایک باینری  $s^l(t)$  را برای هر نورون در همان لایه به‌روزرسانی می‌کند. رفتار نورون‌ها توسط پارامترهای مختلفی کنترل می‌شود:

- $R_m$  ثابت مقاومت (بر حسب دسی اهم) مخصوص لایه "I" است که بر رفتار الکتریکی نورون‌ها تأثیر می‌گذارد.
- $\Delta t$  ثابت زمانی ادغام است که سرعت تغییر پتانسیل غشا را در طول زمان تعیین می‌کند.
- $\Gamma_m$  نشان دهنده ثابت زمانی غشاء است و کنترل می‌کند که با چه سرعتی پتانسیل غشا به مقدار حالت پایدار خود نزدیک می‌شود.

معادلات درگیر در دینامیک عصبی در قسمت نشان داده شده است. معادله اول پتانسیل غشا را برای هر نورون در لایه "I" بر اساس ورودی‌های فعلی و پتانسیل غشای قبلی محاسبه می‌کند. معادله دوم خروجی اسپایک را با مقایسه پتانسیل غشاء فعلی با مقدار آستانه  $v_{thr}^l$  مدل می‌کند. اگر پتانسیل از آستانه فراتر رود، نورون یک خروجی اسپایک باینری  $s^l(t) = 1$  تولید می‌کند. در غیر این صورت  $s^l(t) = 0$  تولید می‌کند.

این سیستم همچنین دارای یک مکانیسم آستانه تطبیقی است که مقدار آستانه  $v_{thr}^l$  را در هر مرحله زمانی بر اساس تعداد اسپایک‌های ثبت شده در لایه "I" تنظیم می‌کند. این آستانه تطبیقی به شبکه اجازه می‌دهد تا به صورت پویا به تغییرات ورودی پاسخ دهد و رفتار شلیک خود را بر این اساس تطبیق دهد.

در لایه ورودی  $l = 0$ ، نمایش اسپایک دودویی  $s^0(t)$  از ورودی حسی "x" با عادی‌سازی مقادیر پیکسل و در نظر گرفتن هر بعد به عنوان یک احتمال برنولی ایجاد می‌شود. این فرآیند یک نمایش دودویی از ورودی حسی ایجاد می‌کند، که در آن هر بعد می‌تواند افزایش یابد یا ساکت بماند. لایه خروجی "I=y" با آموزش اسپایک متنی  $s_y(t)$  مرتبط است که در طول آموزش به برجسب "y" متصل می‌شود. این بدان معنی است که در طول آموزش، فعالیت اسپایک لایه خروجی مستقیماً با برجسب ارائه شده مطابقت دارد و به شبکه کمک می‌کند تا تولید خروجی‌های صحیح را یاد بگیرد.

یکی از مزیت‌های مهم این سیستم عصبی اسپایک مکرر موازی‌پذیری لایه‌ای آن است که آن را نه قفل به جلو و نه قفل به عقب می‌کند. بر خلاف بسیاری از طرح‌های شبکه عصبی اسپایکی موجود که بر پردازش متوالی (قفله شده به جلو) تکیه می‌کنند، این مدل می‌تواند فعالیت‌های اسپایک و به‌روزرسانی‌های سیناپسی را به‌طور موازی برای لایه‌های مختلف محاسبه کند و محاسبات موازی و کارآمد را ممکن می‌سازد.

موازی بودن سیستم تنها با در نظر گرفتن گام قبلی بلافاصله "t-1" هنگام به‌روزرسانی فعالیت‌های اسپایک (انتگرال‌کننده نشتی) به دست می‌آید. این انتخاب طراحی تضمین می‌کند که فعالیت‌های اسپایک هر لایه فقط به فعالیت‌های محاسبه‌شده بلافاصله قبلی بستگی دارد، که امکان محاسبه موازی و اجرای کارآمدتر دینامیک عصبی را فراهم می‌کند.

### ۳.۳ آموزش آنلاین پویا

در فرآیند یادگیری متضاد مبتنی بر رویداد سیستم عصبی اسپایکی مکرر محققان، یک جزء مهم، متغیر ردیابی، (یا بطور ویژه ردیابی متغیر فعالیت یا ردیابی فعال‌سازی) است. این اثر به عنوان یک محفظه اضافی در هر لایه عصبی گنجانده شده است.

ردیابی متغیر فعالیت به منظور ثبت و حفظ تاریخچه فعالیت عصبی در یک لایه است. به عنوان مکانیزم حافظه‌ای عمل می‌کند که اطلاعات مربوط به فعالیت‌های گذشته نورون‌ها در لایه را حفظ می‌کند. این ردیابی به‌طور مداوم به روز می‌شود زیرا نورون‌ها اسپایک‌ها را تولید می‌کنند و اطلاعات را در طول زمان پردازش می‌کنند. متغیر ردیابی برای فرآیند یادگیری متضاد ضروری است زیرا به سیستم اجازه می‌دهد تا فعالیت عصبی فعلی را با الگوهای فعالیت گذشته مقایسه کند. با تضاد وضعیت فعلی با حالت‌های قبلی، سیستم می‌تواند تغییرات یا الگوهای دینامیک عصبی را شناسایی کند.

یکی از مزایای اصلی استفاده از ردیابی متغیر فعالیت این است که سیستم عصبی را قادر می‌سازد تا یادگیری متضاد را به روش رویداد محور انجام دهد. یادگیری متضاد مبتنی بر رویداد به این معنی است که سیستم ردیابی را به‌روزرسانی می‌کند و یادگیری را تنها زمانی انجام می‌دهد که رویدادهای

مربوطه رخ می دهند، مانند جهش هایی در فعالیت عصبی. ادغام متغیر ردیابی در هر لایه به سیستم عصبی اجازه می دهد تا پویایی زمانی و وابستگی های فعالیت عصبی را به تصویر بکشد. این امر به ویژه در شبکه های عصبی اسپایکی مهم است، جایی که زمان اسپایک ها نقش مهمی در پردازش اطلاعات ایفا می کند.

در مجموع این بدان معنی است که برای هر لایه، یک ردیابی متغیر به صورت پویا به صورت زیر به روز می شود:

$$z^l(t) = s^l(t) - \frac{\Delta t}{\Gamma tr} z^l(t) \odot (1 - z^l(t))$$

در این پروژه، ردیابی فعال سازی یک جزء ضروری از سیستم عصبی اسپایکی مکرر است و ثابت زمانی آن،  $\Gamma tr$ ، روی ۳۰۰ میلی ثانیه تنظیم شده است. ردیابی فعال سازی یک هدف مهم در فرآیند یادگیری متضاد رویداد محور است.

عملکرد اصلی ردیابی فعال سازی صاف کردن آموزش های پراکنده اسپایک تولید شده توسط مدل اسپایکی است. در شبکه های عصبی اسپایک، نورون ها از طریق اسپایک های گسسته ارتباط برقرار می کنند که می تواند منجر به الگوهای فعالیت پراکنده و ناپیوسته شود. ردیابی فعال سازی به عنوان مکانیزم هموار سازی عمل می کند و نمایشی پیوسته و پویا با نرخ کدگذاری فعالیت عصبی ارائه می کند. این نمایش صاف از نظر بیولوژیکی قابل قبول تر است و به فرآیند یادگیری قوی تر و پایدارتر اجازه می دهد.

با استفاده از ردیابی فعال سازی، قانون انطباق محلی در مدل لایه عصبی می تواند با استفاده از اطلاعات اسپایک انجام شود. این یک مزیت قابل توجه است زیرا فرآیند یادگیری را به انعطاف پذیری وابسته به زمان اسپایک نزدیک می کند، که یک پدیده بیولوژیکی مشاهده شده است که در آن زمان اسپایک ها بر تغییرات سیناپسی تأثیر می گذارد. در مقابل، برخی دیگر از رویکردهای مرتبط مستقیماً از مقادیر ولتاژ یا جریان الکتریکی برای انطباق استفاده می کنند، که ممکن است دینامیک زمانی و یادگیری وابسته به سنبه ذاتی در STDP را به طور کامل نشان ندهد.

در فرآیند یادگیری پیشرو رویداد محور، هدف بهینه سازی نقاط قوت سیناپسی در هر لایه از سیستم عصبی اسپایک مکرر در هر مرحله از زمان شبیه سازی شده است. این فرآیند بهینه سازی مبتنی بر

تعمیم اصل نیکویی است که در یادگیری رو به جلو و یادگیری پیش‌بینی‌کننده رو به جلو ذاتی است. اصل نیکویی، به این مفهوم اشاره دارد که هر لایه در شبکه عصبی اسپایکی قصد دارد اتصالات سیناپسی خود را به گونه‌ای تنظیم کند که خوبی نمایش عصبی کلی داده‌های ورودی را به حداکثر برساند. ”خوبی” در اینجا را می‌توان به عنوان دقت یا کیفیت نمایشی که شبکه عصبی برای یک ورودی معین ایجاد می‌کند درک کرد.

یادگیری قوانین در مورد نورون‌های اسپایک. در نتیجه تابع هزینه به شکل زیر در می‌آید:

$$L_G(z^l(t), y_{type}) = -\frac{1}{N} \sum_{i=1}^N y_{type} \log p(y_{type} = 1)_l + (1 - y_{type}) \log p(y_{type} = 0)_l,$$

$$p(y_{type} = 1)_l = \frac{1}{1 + \exp(-\sum_{j=1}^{J_l} (z_j^l(t))^2 - \theta_z)}$$

در زمینه مدل شبکه عصبی اسپایکی مورد بحث، متغیر  $y_{type}$  یک عدد صحیح است که ”نوع” ورودی حسی فعلی را نشان می‌دهد. این مدل برای انجام طبقه بندی باینری طراحی شده است، که در آن هر ورودی حسی ( $x$ ) با یک برجسب مربوطه ( $y$ ) مرتبط است، و برجسب می‌تواند مثبت (۱) یا منفی (۰) باشد. بنابراین،  $y_{type}$  یکی از دو مقدار را می‌گیرد: ۱ یا ۰، که نشان می‌دهد ورودی فعلی ( $x, y$ ) یک ورودی حسی مثبت (۱) است یا یک ورودی حسی منفی (۰).

ردیابی فعال‌سازی که قبلاً ذکر شد، نمایشی با نرخ رمزگذاری شده پویا از فعالیت عصبی است که از آموزش‌های پراکنده اسپایک که توسط شبکه عصبی اسپایکی تولید می‌شوند، هموار شده است. در زمینه این فرمول بندی هدف، مجذور مقادیر فعالیت ردیابی فعال‌سازی با یک آستانه مقایسه می‌شود که با  $\theta_z$  نشان داده می‌شود. هدف از این مقایسه تعیین این است که آیا فعالیت ردیابی به اندازه کافی بالا است که نشان دهد لایه عصبی فعال است و به طور قابل توجهی به تصمیم طبقه بندی فعلی کمک می‌کند.

مقدار  $\theta_z$  که در این مقاله روی ۶.۵ تنظیم شده است، به عنوان آستانه‌ای برای این تعیین عمل می‌کند. اگر مجذور مقدار فعالیت ردیابی برای یک لایه عصبی خاص بیشتر از  $\theta_z$  باشد، نشان

می‌دهد که لایه به شدت در تصمیم‌گیری طبقه‌بندی نقش دارد و اتصالات سیناپسی آن بر این اساس برای بهبود عملکرد شبکه در ورودی فعلی تنظیم می‌شود.

برای به حداقل رساندن این تابع هزینه محلی و کاهش خطا، اتصالات سیناپسی (وزن) در یک لایه از شبکه عصبی اسپایکی با استفاده از یک قانون هبین مانند تنظیم می‌شود. قانون هبین مانند برای تنظیم سیناپسی شامل به روز رسانی ماتریس سیناپسی (ماتریس وزن) یک لایه معین در جهتی است که تابع هزینه محلی را به حداقل می‌رساند. تنظیم نقاط قوت سیناپسی تحت تأثیر ردیابی فعال سازی فعلی است که نمایش کدگذاری شده با نرخ پویا فعالیت عصبی در آن لایه است.

به طور خاص، اگر تابع هزینه محلی نشان دهد که پاسخ لایه فعلی به طور قابل توجهی به خطای طبقه بندی کمک می‌کند، نقاط قوت سیناپسی اتصالات در آن لایه برای کاهش خطا به روز می‌شوند. برعکس، اگر تابع هزینه محلی نشان دهد که پاسخ لایه دقیق است و با طبقه‌بندی صحیح مطابقت دارد، اتصالات سیناپسی برای حفظ یا بهبود پاسخ صحیح تقویت می‌شوند.

### ۴.۳ طبقه بندی اسپایک محور و تقریب‌های سریع آن

برای انجام طبقه‌بندی با استفاده از مدل سیستم اسپایکی مکرر، فرآیندی مشابه رویکردهای قبلی دنبال می‌شود. در واقع ایده این است که روی تمام مقادیر کلاس ممکن تکرار شود (که با  $c$  نشان داده می‌شود)، جایی که هر کلاس مربوط به برجسب یا دسته خاصی است که مدل سعی می‌کند طبقه بندی کند. برای هر شاخص کلاس  $c$ ، ورودی حسی  $x$  و زمینه احتمالی آن  $y_c$  در طول مدت زمان ثابتی در شبکه عصبی اسپایکی کدگذاری می‌شوند که به عنوان پنجره محرک با مراحل  $T$  شناخته می‌شود. در طول این فرآیند، شبکه عصبی اسپایکی دینامیک سیستم اسپایک مکرر را با در نظر گرفتن زمینه کلاس خاص  $y_c$  شبیه‌سازی می‌کند و اصل خوبی (تعمیم اصل خوبی که در الگوریتم‌های رو به جلو و پیش‌بینی‌کننده استفاده می‌شود) در سراسر لایه های شبکه به کار می‌رود. صل خوبی یک امتیاز خوب را برای هر زمینه کلاس  $y$  محاسبه می‌کند، که نشان‌دهنده عملکرد خوب مدل با آن زمینه خاص در طول زمان است. امتیاز خوبی با جمع و میانگین مقادیر خوبی در تمام

لایه‌های شبکه عصبی اسپایک در طول شبیه‌سازی روی پنجره محرک محاسبه می‌شود. این فرآیند برای همه شاخص‌های کلاس ممکن  $y = 12...C$  تکرار می‌شود، که در آن  $C$  تعداد کل کلاس‌ها است. در نتیجه، آرایه‌ای از نمرات خوب  $C$  که با  $G = [G_y = 1, G_y = 2, \dots, G_y = C]$  نشان داده می‌شود، به دست می‌آید.

برای پیش‌بینی برچسب کلاس برای یک ورودی داده شده، عملیات  $\text{argmax}$  روی آرایه خوب  $G$  اعمال می‌شود. عملیات  $\text{argmax}$  شاخص کلاسی را با بالاترین میانگین مقدار خوب انتخاب می‌کند که با  $c_{pred} = \text{argmax}_{c \in C} G$  نشان داده می‌شود. شاخص کلاس پیش‌بینی شده‌ای است که مربوط به کلاسی است که بالاترین میانگین نمره خوبی را در بین تمام کلاس‌های در نظر گرفته دارد.

با این حال، از آنجایی که تعداد کلاس‌ها ( $C$ ) بسیار زیاد می‌شود، فرآیند طبقه‌بندی هر کلاس بالا می‌تواند از نظر محاسباتی گران شود، زیرا نیاز به شبیه‌سازی بار شبکه اسپایکی  $C$  یک بار برای هر زمینه کلاس دارد. برای پرداختن به این، یک رویکرد جایگزین پیشنهاد شده است، که شامل ترکیب یک لایه خروجی طبقه‌بندی اسپایکی در سیستم اسپایکی مکرر است. این لایه خروجی طبقه‌بندی اسپایکی طراحی شده است تا خروجی اسپایک را از هر لایه از سیستم برگشتی به عنوان ورودی بگیرد و به طور مشترک همراه با بقیه پارامترهای مدل یاد گرفته شود. با گسترش مجموعه پارامتر  $\theta$  برای شامل سیناپس‌های طبقه‌بندی خاص، شبکه عصبی اسپایکی می‌تواند مستقیماً نتایج طبقه‌بندی را بدون نیاز به شبیه‌سازی جداگانه برای هر کلاس تولید کند. این رویکرد می‌تواند کارآمدتر و مقیاس‌پذیرتر باشد، به‌ویژه برای تعداد زیادی از کلاس‌ها، زیرا شبکه می‌تواند از سیناپس‌های طبقه‌بندی آموخته‌شده خود برای پیش‌بینی کلاس مستقیماً از خروجی‌های اسپایک استفاده کند، و از نیاز به شبیه‌سازی‌های اضافی اجتناب کند.

بطور مشخص، ماژول طبقه‌بندی کننده طبق فرمول‌های زیر عمل می‌کند:

$$v_y(t + \Delta t) = v_y(t) + \frac{\Delta t}{\Gamma m} (-v_y(t) + R_m (\sum_{l=1}^L A^l \cdot S^l(t)))$$

$$\mu_y(t) = v_y(t + \Delta t) > v_{thr}^y, v_y(t) = v_y(t + \Delta t) \odot (1 - \mu_y(t))$$

$$v_{thr}^y = v_{thr}^y + \gamma_v \left( \sum_{j=1}^C \mu_{y,j}(t) - 1 \right)$$

جایی که متوجه می‌شویم که ولتاژ پیش‌بینی متنی  $v_y(t)$  نتیجه تجمیع پیام‌های بردار اسپایک است که از لایه‌ها  $l = 1$  به  $l = L$  منتقل شده است.

### ۵.۳ آزمایش‌ها

در تنظیم آزمایشی، دو مجموعه داده مختلف برای ارزیابی استفاده می‌شوند: مجموعه داده ارقام MNIST و مجموعه داده Kuzushiji-MNIST (K-MNIST). مجموعه داده MNIST از تصاویر ارقام دست‌نویس از ۰ تا ۹ تشکیل شده است، در حالی که مجموعه داده K-MNIST حاوی نویسه‌های کانجی ژاپنی است که با دست‌ترسیم شده‌اند، که مربوط به نویسه‌های هیراگانای مدرن با مجموع ۱۰ کلاس است. قبل از استفاده از داده‌های تصویر، مقادیر پیکسل با تقسیم هر پیکسل بر ۲۵۵ در محدوده [۰، ۱] نرمال می‌شوند. سپس مقادیر پیکسل نرمال شده به عنوان احتمالاتی برای ایجاد آموزش‌های اسپایک ورودی حسی در نظر گرفته می‌شوند. این امر با در نظر گرفتن هر مقدار پیکسل به عنوان پارامتری برای توزیع چند متغیره برنولی به دست می‌آید، و در هر مرحله زمانی در یک پنجره محرک به طول  $T$ ، توزیع برای تولید آموزش‌های اسپایک نمونه‌برداری می‌شود.

شبه‌سازی، مدل فرآیند ED-FF پیشنهادی را با چندین خط پایه شبکه اسپایکی دیگر مقایسه می‌کند. این خطوط پایه عبارتند از:

- انتشار هدف تصادفی مستقیم (DTRP) یک طبقه‌بندی کننده شبکه اسپایکی که با استفاده از یک الگوریتم انتشار هدف تصادفی مستقیم آموزش داده شده است.



- هم ترازى بازخورد پخش (BFA) يك شبكه اسپايكى آموزش ديده با تراز بازخورد پخش، يك الگوريتم تخصيص اعتبار جايجزين است.
  - L2-SigProp: يك شبكه اسپايكى كه با استفاده از يك نوع ساده انتشار سيگنال، با استفاده از يك قانون مبتنى بر ولتاژ و هزينه محلى بر اساس تابع فاصله اقليدى ( $L_2$ ) آموزش داده شده است.
  - طبقه‌بندى‌كننده/خطاهاى محلى: يك شبكه اسپايكى كه با استفاده از تعميم ساده طبقه‌بندى‌كننده‌ها/خطاهاى محلى آموزش داده مى‌شود، كه در آن هر طبقه‌بندى لايه به طور مشترك با سيستم عصبى كلّى ياد مى‌شود.
- علاوه بر اين، يك مدل پايه كدگذارى شده با نرخ ارائه شده توسط يك شبكه عصبى پيشرو تنظيم شده آموزش ديده با استفاده از الگوريتم پس انتشار (BP-FNN) براى مقايسه گنجانده شده است. همه مدل‌هاى شبكه شبيه‌سازى شده داراى دو لايه پنهان هستند كه هر کدام شامل 6400 نورون نشتى ادغام و آتش (LIF) است. اتصالات سيناپسى بين نورون‌ها به طور تصادفى از يك توزيع استاندارد گاوسى کوتاه شده به محدوده  $[-1, 1]$  مقداردهى اوليه مى‌شود، به جز سيناپس‌هاى جانبى در مدل ED-FF، كه به  $[0, 1]$  کوتاه شده اند. يك طبقه‌بندى‌كننده اسپايكى در همه مدل‌ها براى تجمع خروجى‌هاى بردار اسپايك در تمام لايه‌ها استفاده مى‌شود.
- فرايند آموزش با ميني دسته‌اى از 200 الگو، به طور تصادفى بدون جايجزىنى از مجموعه داده‌هاى آموزشى، براى سرعت بخشيدن به شبيه‌سازى‌ها، انجام مى‌شود. نرخ يادگيرى تطبيقى Adam براى تنظيم اثربخشى سيناپسى بر اساس به روز رسانى‌هاى ارائه شده توسط هر الگوريتم يادگيرى استفاده مى‌شود. هر نقطه / دسته داده  $(x, y)$  براى يك پنجره محرک  $T = 50$  مرحله اى (معادل 150 ميلي ثانیه) به همه شبكه‌هاى اسپايكى ارائه مى‌شود. همه شبكه‌هاى اسپايكى از همان طرح به روز رسانى آستانه تطبيقى استفاده شده توسط سيستم ED-FF استفاده مى‌کنند كه براى بهبود پايدارى تمرين مشاهده شده است.
- هدف محققان با مقايسه عملکرد مدل ED-FF با ساير خطوط پايه شبكه اسپايكى و يك خط پايه با نرخ كدگذارى شده، نشان دادن اثربخشى و مزايای رويكرد يادگيرى رو به جلو مبتنى بر رويداد

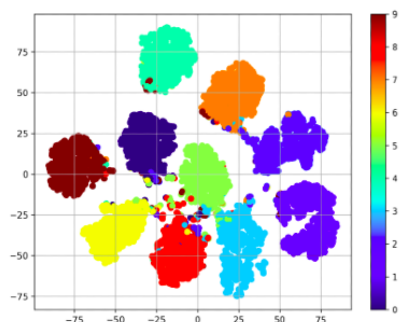
پیشنهادی برای شبکه‌های عصبی اسپایکی است.

### ۱.۵.۳ نتایج طبقه بندی روی داده‌های منتخب


	MNIST	K-MNIST
BP-FNN	$1.300 \pm 0.023$	$6.340 \pm 0.202$
Spiking-RBM	11.000	-
SNN-LM	5.930	-
STDP Power-Law	5.000	-
DRTP (Imp.)	$6.451 \pm 0.172$	$21.320 \pm 1.130$
L2-SigProp (Imp.)	$11.425 \pm 0.0152$	$35.045 \pm 0.005$
BFA (Imp.)	$3.353 \pm 0.0102$	$11.250 \pm 0.050$
SigProp (Imp.)	$6.240 \pm 0.030$	$24.820 \pm 0.200$
ED-FF	$2.540 \pm 0.030$	$8.860 \pm 0.021$

جدول ۱.۳:

جدول ۱.۳، نتایج شبیه‌سازی را برای مدل اسپایکی مکرر پیشنهادی ارائه شده با یادگیری رو به جلو مبتنی بر رویداد، ارائه می‌کند. عملکرد مدل ED-FF با سایر خطوط پایه شبکه اسپایکی و یک خط مبنا با کدگذاری نرخ (BP-FNN) آموزش دیده با پس انتشار مقایسه شده است. در حالی که مدل ED-FF با عملکرد BP-FNN که یک سیستم صرفاً رمزگذاری شده است مطابقت ندارد، از نظر خطای تعمیم به طرز شگفت آوری نزدیک است. این امر موضوعی امیدوار کننده است زیرا لایه زمینه پیش بینی شده در مدل ED-FF خود لایه ای از نورون های اسپایک است. مدل ED-FF در مقایسه با سایر الگوریتم‌های تخصیص اعتبار شبکه اسپایکی بهتر عمل می‌کند، و همانطور که مشاهده می‌کنید شبکه اسپایکی BFA در جایگاه دوم قرار می‌گیرد. مدل کدگذاری پیش‌بینی‌کننده اسپایکی به دلیل ماهیت بدون نظارت آن و تعبیه پس از یک طبقه‌بندی‌کننده لاگ خطی برای رتبه‌بندی تقریب‌های کد استفاده نشده است، چرا که تمرکز مطالعه بر روی مدل‌های اسپایکی بوده است که به طور مشترک یک طبقه‌بندی‌کننده اسپایکی را با بازنمایی درونی ورودی حسی یاد می‌گیرد.



(a) MNIST latents.



(b) K-MNIST latents.

### شکل ۱

شکل ۱ خوشه‌هایی را نشان می‌دهد که در فضای پنهان ایجاد شده توسط شبکه اسپایکی مکرر آموزش دیده با ED-FF ایجاد می‌شوند. برای محاسبه بردارها یا کدهای نهفته، محققان یک کد نرخ تقریبی را از آموزش‌های اسپایک لایه بالایی هر نقطه داده تشکیل می‌دهند. پس از تغذیه هر نقطه داده بدون بافت آن به مدل ED-FF، آنها بردار نرخ-کد لایه بالایی تقریبی آن را جمع‌آوری می‌کنند و خوشه‌های نوظهور را با استفاده از جاسازی همسایه تصادفی t-Distributed (t-SNE) تجسم می‌کنند. شکل نشان می‌دهد که خوشه‌های مربوط به هر دسته به طور طبیعی برای مجموعه داده‌های MNIST و K-MNIST شکل می‌گیرند و توانایی مدل اسپایکی ED-FF را در طبقه‌بندی موثر الگوهای آزمایشی دیده نشده نشان می‌دهد. این امر به ویژه برای مجموعه داده‌های چالش‌برانگیز K-MNIST چشمگیر است، و نشان می‌دهد که سازگاری ED-FF می‌تواند اطلاعات کلاس محور را از الگوهای پیچیده استخراج کند.




(a) MNIST data samples.



(b) MNIST reconstruction.



(c) K-MNIST data samples.




(d) K-MNIST reconstruction.

شکل ۲

همانطور که در شکل ۲ مشاهده می‌کنید، توانایی بازسازی الگوی مدل اسپایکی ED-FF بررسی شده‌است. الگوهای تصویری نمونه‌برداری تصادفی از پایگاه‌های داده MNIST و K-MNIST برای ایجاد الگوهای بازسازی تصویر منفرد استفاده می‌شوند. این الگوها با محاسبه میانگین در طول ردپای فعال‌سازی اسپایک‌ها خروجی پایین‌ترین پیش‌بینی‌گر جمع‌آوری شده در طول پنجره محرک به طول T ایجاد می‌شوند. مدل بازسازی ED-FF الگوی تصویر معقولی را نشان می‌دهد، که این امر بیانگر توانایی مدل در رمزگذاری اطلاعات در سیناپس‌های مولد خود است. برای رمزگشایی نمایش‌های آموزش اسپایک پراکنده تولید شده توسط لایه‌های داخلی نوروهای LIF قابل توجه، متن  $y$  در طول ارزیابی بازسازی به مدل متصل نشد، که نشان می‌دهد هر گونه اطلاعات متنی

ذخیره‌شده در سیناپس‌های سیستم برای تعیین نحوه بازسازی نمونه‌های آزمایشی استفاده شده‌است. به طور کلی، نتایج تجربی اثربخشی رویکرد یادگیری رو به جلو مبتنی بر رویداد را برای آموزش شبکه‌های عصبی اسپایکی نشان می‌دهد. مدل ED-FF عملکرد امیدوارکننده‌ای را در وظایف طبقه‌بندی نشان می‌دهد، خوشه‌های معنی‌داری را در فضای پنهان تشکیل می‌دهد، و توانایی بازسازی الگوهای تصویر را به طور موثر نشان می‌دهد.

### ۲.۵.۳ بازنمایی های سطح پیچ



شکل ۳

در این بخش از پروژه، به بررسی قابلیت نمایش شبکه عصبی اسپایکی در زمینه پیچ‌های تصویر می‌پردازیم. برای این کار پیچ‌هایی با دو اندازه مختلف،  $8 \times 8$  پیکسل و  $12 \times 12$  پیکسل، از زیر مجموعه‌ای از پایگاه داده MNIST استخراج می‌نماییم. این زیر مجموعه شامل ۱۰۰۰ الگوی تصویری با ۱۰ الگو از هر کلاس است. سپس یک مدل را با استفاده از روش رویداد محور رو به جلو آموزش می‌دهیم که از ۲۰۰۰ واحد LIF نشتی در هر دو لایه تشکیل شده‌است.

فیلدهای دریافتی آموخته شده در پایین‌ترین لایه مدل آموزش دیده ( $l = 1$ ) در شکل ۳ نشان داده شده‌است. برای به دست آوردن این فیلدهای دریافتی برای تجسم، به طور تصادفی، بدون جایگزینی، ۱۰۰ برش از ماتریس سیناپسی  $W_1$  را نمونه برداری می‌کنیم. هر برش از  $W_1$  نشان دهنده میدان پذیرنده یک نورون منفرد در لایه پایینی است. نتایج در این شکل نشان می‌دهد که

میدان‌های گیرنده در شبکه عصبی اسپایکی الگوهای اساسی را در وضوح‌های مختلف بر اساس اندازه پچ استخراج می‌کنند. در مدل کوچکتر  $8 \times 8$ ، الگوهای ساده تری مانند لبه‌ها یا قطعات ضربه‌ای ("strokelet") با جهت‌گیری‌های مختلف ظاهر می‌شوند. این فیلدهای گیرنده قادر به تشخیص الگوهای محلی در پچ‌های تصویر  $8 \times 8$  پیکسل هستند.

از سوی دیگر، در مدل بزرگتر  $12 \times 12$ ، فیلدهای گیرنده بخش‌هایی از الگوها را که به عنوان "الگوهای کوچک" ظاهر می‌شوند، ثبت می‌کنند. این الگوهای کوچک را می‌توان برای نوشتن ارقام بزرگتر مورد استفاده قرار داد، که نشان می‌دهد شبکه عصبی اسپایکی می‌تواند الگوهای پیچیده تری را در صورت داده شدن پچ‌های تصویر بزرگتر بیاموزد.

## فصل ۴

### نتیجه گیری

در این پروژه پیاده سازی الگوریتم دسته‌بندی تصویر بر اساس ساختار ستون‌های قشری مغز را مورد بررسی قرار دادیم. همانطور که در فصول قبل توضیح دادیم فرآیند رو به جلو مبتنی بر رویداد، یک الگوریتم تخصیص اعتبار جدید برای تنظیم اثربخشی سیناپسی سیستم‌های عصبی اسپایکی مکرر است. با بسط دادن اصول یادگیری رو به جلو و پیش‌بینی‌کننده به جلو به حوزه آموزش اسپایک‌ها، انطباق الگوریتم رو به جلو مبتنی بر رویداد قابلیت‌های امیدوارکننده‌ای را در یادگیری مؤثر بازنمایی‌های زمانی گسسته، امکان طبقه‌بندی کارآمد داده‌های تصویر، و بازسازی ورودی‌های تصویر در طول زمان به نمایش گذاشت.

نتایج تجربی کارآمدی رویکرد ED-FF را در یادگیری بازنمایی از شبکه‌های عصبی اسپایک نشان داد. عملکرد تعمیم مدل به طور قابل ملاحظه‌ای به شبکه‌های پیشرو مبتنی بر پس انتشار نزدیک شد، علی‌رغم چالش‌های ذاتی ناشی از پویایی اسپایک. علاوه بر این، ED-FF از سایر الگوریتم‌های تخصیص اعتبار شبکه، از جمله BFA و DTRP بهتر عمل کرد و آن را به یک انتخاب قانع‌کننده برای آموزش سیستم‌های اسپایکی مکرر تبدیل کرد.

در حالی که این مطالعه بر وظایف طبقه‌بندی تصاویر با استفاده از مجموعه داده‌هایی مانند MNIST و K-MNIST متمرکز بود، محققان مسیرهای هیجان انگیز آینده را برجسته کردند. به عنوان مثال، بررسی انطباق ED-FF در مجموعه داده‌های پیچیده‌تر، مانند تصاویر طبیعی یا توالی‌هایی مانند

فریم‌های ویدئویی، می‌تواند بیش‌های ارزشمندی در مورد کاربرد الگوریتم برای داده‌های دنیای واقعی ارائه دهد. درک اینکه چگونه مدارهای سطح اسپایک، که از طریق یادگیری ED-FF تنظیم شده‌اند، می‌توانند برای معماری‌های شناختی عصبی-مرکز مفید باشند، یک راه امیدوارکننده برای کاوش خواهد بود که از مدل‌های موفق‌ی مانند معماری اشاره‌گر معنایی (SPAUN) الهام گرفته شده است.

به طور خلاصه، فرآیند ED-FF پتانسیل خود را به عنوان روشی مناسب برای یادگیری و تطبیق وزن‌های سیناپسی در شبکه‌های عصبی اسپایک نشان می‌دهد. ED-FF با توانایی پردازش کارآمد اطلاعات زمانی، مدیریت بازنمایی‌های مبتنی بر اسپایک و دستیابی به عملکرد رقابتی با شبکه‌های سنتی نرخ‌گذاری شده، نویدبخش پیشرفت زمینه یادگیری مبتنی بر رویداد و افزایش قابلیت‌های سیستم‌های عصبی اسپایکی در انواع مختلف است. وظایف شناختی و محاسباتی با افزایش تقاضا برای مکانیسم‌های یادگیری قابل قبول و کارآمد، مشارکت ED-FF ممکن است راه را برای مدل‌های شبکه عصبی پیچیده‌تر و مقیاس‌پذیرتر که عملکرد مغز را تقلید می‌کنند، هموار کند.



## واژه‌نامه فارسی به انگلیسی

Axon	آکسون
Steve Furber	استیو فربر
John Hopfield	جان هاپفید
John Rinzel	جان رینزل
Membrane Current	جریان غشایی
Leakage Current	جریان نشتی
Synaptic Currents	جریان سیناپسی
Dendrite	دندریت
Chain Reaction	راکنش زنجیره‌ای
Event Driven Forward-Forward	روبه‌جلو مبتنی بر رویداد
Soma	سوما
Synapse	سیناپس
Synaptogenesis	سیناپس‌زایی
Spiking Neural Networks	شبکه عصبی اسپایکی
Membrane Capacitance	ظرفیت غشایی
Integrate and Fire Models	مدل ادغام و آتش
Leaky Integrate-and-Fire Model	مدل تجمیع و آتش نشتی
Resonate and Fire Model	مدل تشدید و آتش
Spike Response Model	مدل پاسخ اسپایک
Excitability	منفجرکنندگی
Action Potential	موج اکشن
Neural Engineering	مهندسی عصبی
Neuromorphic	نورومورفیک
Biological Neurons	نورون بیولوژیکی
Hodgkin	هاچکین
Huxley	هاکسلی
Hemostasis	هموستاز
Henry Markram	هنری مارکرام

Convergence	واگرایی
Wolfgang Maass	ولفگانگ ماس
Membrane Potential	پتامسیل غشایی
Backpropagation Through Time	پس انتشار در طول زمان
Predictive Forward Forward	پیش بینی کننده روبه جلو
Carver Mead	کارور مید
Larry Abbott	لری ابوت
From the Side Studies	مطالعات از جانب ورد
Diffusion Differential Equation	معادله دیفرانسیل انتشار
Learning Rate	نرخ یادگیری
Neurite	نورونیت
Neuroplasticity	نوروپلاستیسیته
Green AI	هوش مصنوعی سبز
Unsupervised Learning	یادگیری بدون نظارت
Supervised Learning	یادگیری نظارت شده

## واژه‌نامه انگلیسی به فارسی

Action Potential	موج اکشن
Axon	آکسون
Backpropagation Through Time	پس انتشار در طول زمان
Biological Neurons	نورون بیولوژیکی
Carver Mead	کارور مید
Chain Reaction	راکنش زنجیره‌ای
Convergence	واگرایی
Dendrite	دندریت
Diffusion Differential Equation	معادله دیفرانسیل انتشار
Event Driven Forward-Forward	روبه جلو مبتنی بر رویداد
Excitability	منفجرکنندگی
From the Side Studies	مطالعات از جانب ورد
Green AI	هوش مصنوعی سبز
Hemostasis	هموستاز
Henry Markram	هنری مارکرام
Hodgkin	هاچکین
Huxley	هاکسلی
Integrate and Fire Models	مدل ادغام و آتش
John Hopfield	جان هاپفید
John Rinzel	جان رینزل
Larry Abbott	لری ابوت
Leakage Current	جریان نشتی
Leaky Integrate-and-Fire Model	مدل تجمیع و آتش نشتی
Learning Rate	نرخ یادگیری
Membrane Capacitance	ظرفیت غشایی
Membrane Current	جریان غشایی
Membrane Potential	پتامسیل غشایی
Neuromorphic	نورومورفیک
Neurite	نورونیت

Neural Engineering	مهندسی عصبی
Neuroplasticity	نوروپلاستیسیته
Predictive Forward Forward	پیش‌بینی‌کننده روبه‌جلو
Resonate and Fire Model	مدل تشدید و آتش
Soma	سوما
Spiking Neural Networks	شبکه عصبی اسپایکی
Steve Furber	استیو فربر
Supervised Learning	یادگیری نظارت شده
Synapse	سیناپس
Synaptic Currents	جریان سیناپسی
Synaptogenesis	سیناپس‌زایی
Unsupervised Learning	یادگیری بدون نظارت
Wolfgang Maass	ولفگانگ ماس

## Abstract

Spiking neural networks (SNNs) are a type of artificial neural network that are inspired by the way that neurons in the brain communicate. SNNs are capable of learning to perform a variety of tasks, but they are often difficult to train because of the challenges associated with credit assignment.

Credit assignment is the process of determining how changes to the parameters of a neural network should be made in order to improve the performance of the network. In SNNs, this is a challenging problem because spikes are discrete events that occur at unpredictable times.

In this paper, we propose a novel credit assignment algorithm for SNNs called the event-driven forward-forward (ED-FF) process. The ED-FF process is a generalization of the forward-forward and predictive forward-forward learning processes for SNNs. ED-FF is event-driven, meaning that it only updates the synapses of spiking neurons when spikes are received. This makes ED-FF efficient and scalable, as it does not require the storage of any temporal information.

We demonstrate that ED-FF can be used to train a dynamic recurrent spiking system capable of both classification and reconstruction. The results on several pattern datasets show that ED-FF is a promising approach for learning with spiking neural systems.



College of Science  
School of Mathematics, Statistics, and Computer Science

# Implementation of the image classification algorithm based on the brain cortical columns

**Niko Rokni**

Supervisor: Mohammad GanjTabesh

A thesis submitted to Graduate Studies Office  
in partial fulfillment of the requirements for the degree of  
B.Sc. of Philosophy in Computer Science

2023