

پردازش پیشگویانه در ستون‌های قشری مغز با استفاده از شبکه‌های عصبی ضربه‌ای

علی رحیمی کلیشمی

دانشجوی کارشناسی ارشد، دانشکده ریاضی، آمار و علوم کامپیوتر، دانشکده علوم، دانشگاه تهران، تهران، ایران

پست الکترونیکی: saeed.ali.rahimi@ut.ac.ir

محمد گنج‌تابش *

استاد، دانشکده ریاضی، آمار و علوم کامپیوتر، دانشکده علوم، دانشگاه تهران، تهران، ایران

پست الکترونیکی: mgtabesh@ut.ac.ir

چکیده

می‌دهیم که پیش‌بینی می‌تواند منجر به تشکیل بازنمایی مناسب‌تر از ورودی در ساختار یک ستون قشری شود. **واژه‌های کلیدی:** پردازش پیشگویانه، شبکه‌های عصبی ضربه‌ای، دندریت چندبخشی، ستون قشری، هوش مصنوعی مولد.

پردازش پیشگویانه نگرشی جدید و نویددهنده است که عملکرد مغز را به صورت پیش‌بینی حواس ورودی در نظر می‌گیرد. ستون‌های قشری به عنوان واحدهای سازنده مغز وظیفه محاسبات پردازش پیشگویانه را بر عهده دارند. هرچند پژوهش‌های متعددی برای استفاده از این نگرش در حوزه هوش مصنوعی انجام شده است، اما در اکثر این پژوهش‌ها، ساختار مغز و دینامیک فعالیت واحدهای سازنده آن نادیده گرفته شده و یا بیش از حد ساده‌سازی شده‌اند. در این مقاله تلاش شده است تا با استفاده از شبکه‌های عصبی ضربه‌ای، یک مدل محاسباتی زیست توجیه‌پذیر برای ستون‌های قشری مغز معرفی شود. در این مدل از دندریت‌های نورونی چندبخشی به همراه دینامیک مربوط به آن‌ها استفاده شده و نقش ارتباطات رو به عقب در پردازش‌های پیشگویانه مورد بررسی قرار گرفته است. عملکرد مدل پیشنهادی را با استفاده از آزمایش‌های مربوط به پردازش پیشگویانه مورد بررسی قرار داده و نشان

۱ مقدمه

درک نحوه فعالیت مغز انسان، همواره ذهن محققان را درگیر خود کرده است و امروزه به طور ویژه به پیشرفت هوش مصنوعی و دستیابی به هوش مصنوعی قوی کمک می‌کند. نظریه پردازش پیشگویانه بیان می‌کند که مغز به طور پیوسته به دنبال پیش‌بینی سیگنال‌های حسی ورودی به آن است و در این راستا مدل ذهنی ساخته شده، مدلی بهینه برای پیش‌بینی رویدادهای آینده است [۱].

حدود ۹۰ درصد قشر مغز از نوقشر تشکیل شده است که در آن فعالیت‌های شناختی و ادراکی انجام می‌پذیرند [۲]. نوقشر ساختاری چند لایه دارد که این

* نویسنده مسئول

ساده از ستون قشری و آزمایش‌های مناسب این ساختار طراحی شدند. این آزمایش‌ها به درک بهتر توانایی‌های ستون قشری و اهمیت پردازش پیشگویانه کمک می‌کنند.

۲ مرور کارهای پیشین

به طور ساده، مدل‌هایی که می‌توانند ورودی خود را پیش‌بینی کنند به عنوان مدلی برای پردازش پیشگویانه در نظر گرفته می‌شوند. با چنین دیدگاهی، بسیاری از مدل‌های یادگیری ماشین در حوزه پردازش پیشگویانه قرار می‌گیرند. مدل‌های محاسباتی مختلفی برای پردازش پیشگویانه ارائه شده‌اند که با توجه به ارتباط نزدیک مفاهیم احتمالاتی در پردازش پیشگویانه، اکثر آن‌ها بر پایه مدل بیزی^۱ استوار هستند [۸]. در سال ۱۹۹۹ از پردازش پیشگویانه برای مدل‌سازی قشر بینایی استفاده شد که توانست عملکردی مشابه سلول‌های ساده در نواحی اولیه قشر بینایی را بازتولید کند [۹]. شبکه سلسله مراتبی ارائه شده در این مدل، زمینه توسعه شبکه‌های پردازش پیشگویانه را فراهم کرده است.

خودرمزگذارها^۲ به طور ویژه وظیفه تولید ورودی خود را دارند و با استفاده از یک تنگنا^۳، بازنمایی^۴ مناسبی برای مجموعه داده‌های ورودی پیدا می‌کنند [۱۰] و ترنسفورمرها نمونه‌ای موفق از این روش پردازش هستند [۱۱]. اگر هدف اصلی مدل را پیش‌بینی داده ورودی در زمان بعدی در نظر بگیریم، می‌توان از مدل‌های خودهمبسته^۵ استفاده نمود، که بر این اساس شبکه PredNet ارائه شده است [۱۲]. هدف پیش‌بینی به طور بنیادی دشوار تر از بازسازی است؛ زیرا ابهام ناشی از تغییرات در آینده را نیز باید در نظر بگیرد. هدف دیگری که در حوزه پردازش پیشگویانه قرار می‌گیرد،

ساختار در کل سطح نوقشر مشابه است و به برش ستونی از نوقشر با قطر مقطع نیم میلی‌متر ستون قشری گفته می‌شود [۳]. یک ستون قشری از شش لایه نورونی مجزا تشکیل شده است که در یک ساختار سلسله مراتبی، ورودی خود را از طریق نورون‌های لایه ۴ دریافت می‌کند. نورون‌های لایه‌های ۲ و ۳ به ستون‌های قشری بالاتر در ساختار سلسله مراتبی متصل هستند و نورون‌های لایه‌های ۵ و ۶ نیز به ستون‌های قشری پایین‌تر، تالاموس و ساقه مغز متصل هستند. همچنین نورون‌های موجود در لایه‌های ۲، ۳، ۵ و ۶ ورودی رو به عقب را از ستون‌های قشری در ساختار سلسله مراتبی بالاتر دریافت می‌کنند. لایه ۱ تعداد کمی نورون را در خود جای داده است و معمولاً از ساختار نورونی این لایه صرف نظر می‌شود. تفاوت عملکرد بخش‌های مختلف مغز تنها از تفاوت دستگاه‌های حسی یا دیگر ساختارهای نورونی متصل به آن نشئت می‌گیرد. در نتیجه از ستون‌های قشری به عنوان واحدهای پایه‌ای پردازش اطلاعات در مغز نام برده می‌شود و تلاش‌های متعددی برای یافتن الگوریتم‌های حاکم بر رفتار و عملکرد ستون‌های قشری انجام شده است [۴].

جف هاوکینر در نظریه هزاران مغز [۵] و کارل فریستون در نظریه استنباط فعال [۶] پیشنهاد می‌کنند که فرآیند پردازش پیشگویانه در مغز توسط ستون‌های قشری انجام می‌شود و هدف اصلی هر ستون قشری ساخت مدلی از ورودی‌هایش است که در برابر تغییرات ورودی مقاوم بوده و فعالیت پایداری از خود بروز دهد. این هدف به کمک پیش‌بینی ورودی‌های هر ستون قشری محقق می‌شود [۷]. تفاوت این دو نگرش در نحوه تعامل ستون‌های قشری با یکدیگر است.

در این مقاله با استفاده از شبکه‌های عصبی ضربه‌ای عملکرد یک ستون قشری را از دیدگاه پردازش پیشگویانه بررسی می‌کنیم. بدین منظور، برای تسهیل فرآیند پیش‌بینی، مدلی برای دینامیک دندریت‌ها طراحی و استفاده شد. سپس با توجه به ساختار زیستی، مدلی

1- Bayesian Model

2- Autoencoder

3- Bottleneck

4- Representation

5- Autoregressive

با توجه به ساختار زیستی مغز و ماهیت تحریکی اغلب اتصالات رو به عقب، در این مقاله از دیدگاه دوم برای مدل سازی استفاده می‌کنیم و به طور ویژه به بررسی نقش پردازش پیشگویانه در عملکرد ستون‌های قشری می‌پردازیم.

۳ روش‌ها

۱.۳ مدل نوروئی و یادگیری وزن‌های سیناپسی

نورون‌های استفاده شده در این مقاله از مدل نوروئی تجمیع و آتش نشستی^۴ پیروی می‌کنند [۲۰] که در آن پتانسیل غشای نورون از معادله دیفرانسیل (۱) پیروی می‌کند:

$$\tau \frac{du}{dt} = -(u - u_{rest}) + R \times I(t), \quad (1)$$

که در آن u اختلاف پتانسیل غشای نورون، u_{rest} اختلاف پتانسیل غشای نورون در حالت استراحت، R مقاومت غشای نورون، $I(t)$ جریان ورودی نورون در گذر زمان τ یک ثابت زمانی است که نرخ نشت را تعیین می‌کند. هنگامی که پتانسیل غشای نورون به مقدار آستانه مشخصی، که با θ نشان داده می‌شود، برسد، نورون فرآیند ضربه را اجرا کرده و پتانسیل غشای آن به مقدار کمتری از u_{rest} می‌رسد.

همچنین یادگیری وزن‌های ارتباطی بین نورون‌ها در این مقاله توسط قاعده یادگیری وابسته به زمان ضربه انجام می‌شود [۲۱]. بر اساس این قاعده، تغییرات وزن سیناپس بین نورون پیش سیناپسی (pre) و نورون پس سیناپسی (post) به اختلاف زمانی ضربه‌های آن‌ها وابسته بوده و مطابق رابطه (۲) صورت می‌گیرد:

$$\Delta w = \begin{cases} A_+(w) \times \exp\left(\frac{-|\Delta t|}{\tau_+}\right) & \text{if } t_{pre} \leq t_{post}, \\ A_-(w) \times \exp\left(\frac{-|\Delta t|}{\tau_-}\right) & \text{if } t_{pre} > t_{post}, \end{cases} \quad (2)$$

که در آن w وزن سیناپسی بین دو نورون را نشان

تولید بخشی از داده با استفاده از بخش‌های دیگری از همان داده است. این هدف در پژوهش‌های اولیه پردازش پیشگویانه در شبکه‌ی چشم برای مدل سازی ویژگی‌های میدان دید در سلول‌های عقده‌ای^۱ استفاده شده [۱۳] و بر پایه آن، مدل محاسباتی کدگذاری پیشگویانه تقابلی^۲ نیز ارائه شده است [۱۴]. با توجه به ماهیت پردازش پیشگویانه، اکثر مدل‌ها به صورت بدون ناظر آموزش داده می‌شوند، با این حال با استفاده از فرآیند موازنه^۳ می‌توان مدلی از شبکه‌های سلسله مراتبی را با استفاده از روش‌های یادگیری باناظر نیز آموزش داد [۱۵].

در دیدگاه معمول از پردازش پیشگویانه در مغز، وقتی ضربه یک نورون پیش‌بینی می‌شود، آن نورون را می‌توان مهار کرد، که منجر به بهینگی در مصرف انرژی می‌شود. بر این اساس، از شبکه‌های عصبی ضربه‌ای نیز برای شبیه سازی فرآیند پردازش پیشگویانه استفاده شده است [۱۶]. در نتیجه می‌توان نشان داد که پتانسیل غشاء در هر لحظه زمانی تخمینی از خطای پیش‌بینی در شبکه‌های متوازن است [۱۷]. از این روش برای شبیه سازی قشر اولیه بینایی در مغز استفاده شده که عملکردی مشابه سامانه بینایی در مغز داشته و وجود ارتباطات مهارتی در آن انرژی مصرفی را به طور معناداری کاهش می‌دهد [۱۸]. در دیدگاه دوم از پردازش پیشگویانه، وقتی ضربه یک نورون پیش‌بینی می‌شود، پتانسیل غشاء آن نورون افزایش یافته و منجر به ضربه زودهنگام آن نورون می‌شود و در این حالت کنترل میزان انرژی مصرفی در مغز به کمک سایر سازوکارها، مانند فرایند هم‌ایستایی، محقق می‌شود. با این روش مدلی برای ستون قشری معرفی شده است که توانسته عملکرد مناسبی نیز از خود نشان دهد [۱۹]. در این مدل از چند نوع داده حسی استفاده شده و ارتباط بین ستون‌های قشری منجر به بهبود عملکرد مدل شده است.


1- Ganglion

2- Contrastive Predictive Coding

3- Equilibrium

4- Leaky integrate-and-fire

5- Spike-Timing Dependent Plasticity (STDP)



شکل ۱: مدل دندریتی طراحی شده برای دندریتهای دیستال و اپیکال

داده شده و I_h حافظه‌ی دندریت است که تغییرات آن در گذر زمان از رابطه‌ی (۴) پیروی می‌کند:

$$\frac{dI_h}{dt} = \frac{-I_h}{\tau} + \frac{I_{max} - I_h}{r} \times \sum_{syn} \frac{I_{syn}}{\|W_{syn}\|^2}, \quad (4)$$

که در آن پارامتر τ نشان دهنده نشت جریان دندریتی بوده و پارامتر r تاثیر لحظه‌ای ورودی‌های سیناپسی را مشخص می‌کند. جریان هر نوع دندریت که در هر لحظه بر جریان دریافتی نورون اثر می‌گذارد بر اساس رابطه (۵) نوشته می‌شود:

$$I(t) = \frac{I_{max} - I_h}{r} \times \sum_{syn} \frac{I_{syn}}{\|W_{syn}\|^2} \quad (5)$$

و پس از هر بار ضربه نورون، حافظه دندریت به مقدار پیش فرض صفر بر می‌گردد.

۳.۳ مدل پیشنهادی

ساختاری که در این پژوهش برای مدل‌سازی ستون قشری در نظر گرفته شده سه لایه ۲/۳، ۴ و ۵/۶ تشکیل شده است (شکل ۲). نورون‌ها در لایه ۴ ضربه‌های جمعیت نورونی ورودی را دریافت می‌کنند، نورون‌های لایه ۲/۳ یک بازنمایی مناسب و پایدار از ورودی می‌سازند و نورون‌های لایه ۵/۶ با توجه به اطلاعات متعددی که ستون قشری از ورودی مستقیم خود در لایه ۴ و دیگر ورودی‌های رو به عقب دریافت می‌کند، وظیفه تصمیم‌گیری و پیش‌بینی را بر عهده دارند. این پیش‌بینی

می‌دهد، $|\Delta t| = |t_{post} - t_{pre}|$ ، نشان دهنده اختلاف زمانی ضربه‌های دو نورون متصل است، $\tau_{\pm}$ ثابت‌های زمانی و $A_{\pm}$ بیانگر شدت تقویت و یا تضعیف وزن سیناپسی می‌باشند. همچنین، در این مقاله از معیار همگرایی ارائه شده در رابطه (۳) برای بررسی روند تغییر وزن‌های سیناپسی استفاده شده است:

$$C = \frac{1}{|W_{syn}|} \sum_{w \in W_{syn}} (w - w_{min}) \times (w_{max} - w),$$

که در آن w_{max} و w_{min} به ترتیب وزن‌های کمینه و بیشینه ممکن برای ارتباطات را نشان داده و W_{syn} مجموعه وزن‌های متعلق به سیناپس‌های بین دو جمعیت نورونی است. در این رابطه، با نزدیک شدن وزن‌های سیناپسی به مقادیر مرزی، مقدار C کمتر خواهد بود.

۲.۳ دندریت چند بخشی


ساختار دندریت‌ها و عملکرد آن‌ها تاثیرات بنیادین بر عملکرد نورون‌ها دارد [۲۲]. در این پژوهش سه نوع دندریت پروکسیمال^۱، دیستال^۲ و اپیکال^۳ برای نورون‌ها در نظر گرفته شده است. دندریت‌های پروکسیمال مستقیماً بر پتانسیل غشاء نورون و در نتیجه بر فعالیت آن تاثیر می‌گذارند. دندریت‌های دیستال و اپیکال تنها می‌توانند پتانسیل غشاء را تا حد معینی افزایش دهند که منجر به فعال شدن نورون نمی‌شوند، ولی آن نورون را آماده فعال شدن می‌کنند؛ در نتیجه یک نورون بدون دریافت ورودی پروکسیمال نمی‌تواند ضربه بزند. لازم به ذکر است که در این مقاله از مدل یکسانی برای دندریت‌های دیستال و اپیکال استفاده شده است.

مدل محاسباتی برای دندریت‌های دیستال و اپیکال به کمک نشت نمایی در نظر گرفته شده است (شکل ۱). در این مدل یک پارامتر سقف وجود دارد که با I_{max} نشان

1- Proximal

2- Distal

3- Apical



شکل ۲: ساختار ستون قشری مورد استفاده در این پژوهش شامل سه لایه ۲/۳، ۴ و ۵/۶ است.

لایه ۵/۶) نیز دریافت می‌کنند، جمعیت نورونی مربوط به مکان باعث می‌شود تا ستون قشری، اطلاعات مضاعفی از ورودی را دریافت کند. لازم به ذکر است که جمعیت‌های نورونی ورودی و مکانی تنها ضربه‌ها را انتقال می‌دهند و برای سادگی در مدل سازی گنجانده شده‌اند.

۴ آزمایش‌ها و نتایج

۱.۴ داده‌های ورودی

در این مقاله از دادگان MNIST برای ساخت مجموعه دادگان ورودی مناسب برای مدل پیشنهادی استفاده شده است [۲۴]. بدین منظور ابتدا روی داده‌های MNIST، هسته اختلاف گوسی اعمال می‌شود و سپس تصاویر حاصل در طول و عرض به چندین بخش تقسیم می‌شوند (این بخش‌ها می‌توانند با یکدیگر همپوشانی داشته باشند). سپس هر یک از این بخش‌ها به ضربه‌هایی برای جمعیت نورونی ورودی تبدیل می‌شوند. این ضربه‌ها در یک بازه زمانی مشخص و با استفاده از روش کدگذاری پواسون تولید می‌شوند. همزمان نورون مربوط به آن بخش از ورودی نیز در جمعیت نورونی مکانی ضربه می‌زند (شکل ۳). در

مجدداً بر فعالیت نورون‌های لایه ۴ اثر می‌گذارد.

ارتباطات بین جمعیت ورودی و لایه ۴، ثابت و مشابه هسته گبور در چهار راستای مختلف (با زوایای ۰، ۴۵، ۹۰ و ۱۳۵ درجه) هستند [۲۳]. این ارتباطات به دندریت‌های پروکسیمال متصل هستند، درحالی که ارتباطات از لایه ۵/۶ به لایه ۴ به دندریت‌های اپیکال متصل هستند و وظیفه پیش‌بینی درونی ستون قشری را بر عهده دارند. لایه ۴ از فرآیند برنده-صاحب-همه-می‌شود^۱ و ارتباطات مهاری جانبی بهره می‌برد که موجب می‌شود از بین نورون‌هایی که دارای میدان دید یکسان هستند، تنها نورون مربوط به یک راستای گبور خاص که بیشترین جریان ورودی را داشته برنده شده و ضربه بزند. نورون‌های موجود در لایه ۲/۳ تنها عملیات ادغام^۲ را روی ضربه‌های ورودی از لایه ۴ انجام می‌دهند.

در لایه ۵/۶ برای هر دسته آموزشی یک صفحه نورونی وجود دارد که سیگنال آموزش، اثر خود را بر دندریت‌های دیستال نورون‌های دسته مربوطه می‌گذارد. این امر موجب می‌شود که این نورون‌ها تنها در حین فرآیند آموزش فعال شده و ضربه بزنند. ابعاد و چیدمان نورون‌ها در هر صفحه با تعداد نورون‌های جمعیت ورودی مربوط به مکان برابر بوده و با فعال شدن هر نورون در جمعیت مکانی، نورون‌های متناظر با استفاده از دندریت‌های اپیکال، ورودی دریافت می‌کند. این لایه از دو نوع اتصال مهاری بین دسته‌ها و اتصال مهاری بین کل نورون‌ها بهره می‌برد که تعداد ضربه‌ها را محدود کرده و باعث ایجاد تعادل در فعالیت نورون‌ها می‌شوند. از بین تمام ارتباطات موجود در یک ستون قشری تنها ارتباطات بین لایه‌های ۲/۳ و ۵/۶ و همچنین ارتباطات بین لایه‌های ۵/۶ و ۴ قابلیت آموزش دارند.

با توجه به این که ستون‌های قشری ارتباطات معناداری با یکدیگر دارند و علاوه بر ورودی در لایه ۴، ورودی رو به عقب از دیگر ستون‌های قشری (عموما در

1- k-Winner-Take-All

2- Pooling

ارتباط رو به عقب	تعداد بخش‌ها	اشتراک بخش‌ها	کلاس‌های ارقام استفاده شده	میانگین دقت	انحراف از معیار
•	2×2	۳	۰, ۶, ۸, ۹	۰/۸۲۰۶	۰/۰۱۰۸
•	3×2	۳	۰, ۶, ۸, ۹	۰/۷۹۶۱	۰/۰۰۸۹
•	3×3	۳	۰, ۶, ۸, ۹	۰/۷۴۸۱	۰/۰۱۵۱
•	2×2	۳	۲, ۳, ۵, ۸	۰/۶۲۹۶	۰/۰۰۴۶
•	2×2	۷	۲, ۳, ۵, ۸	۰/۷۰۲۰	۰/۰۰۶۸
○	2×2	۳	۲, ۳, ۵, ۸	۰/۵۷۹۱	۰/۰۱۱۶
•	2×2	۳	۰, ۱, ..., ۹	۰/۶۴۵۲	۰/۰۰۳۴

جدول ۱: جدول دقت مدل‌های بررسی شده (هر یک از این مدل‌ها پنج مرتبه ارزیابی شده‌اند).


به پتانسیل استراحت برگردند.

به منظور ارزیابی مدل پیشنهادی، سیگنال آموزش به همراه قواعد یادگیری غیر فعال شده تا وزن‌های سیناپسی در حین فرآیند ارزیابی تغییر نکنند. معیار ارزیابی مدل به ازای بخش‌های مختلف هر تصویر ورودی، تعداد ضربه‌های تولید شده برای هر صفحه نرونی در لایه ۵/۶ بوده و صفحه‌ای که دارای تعداد بیشتری ضربه باشد به عنوان نتیجه ارزیابی در نظر گرفته می‌شود.

۳.۴ آزمایش‌ها

آزمایش‌های طراحی شده در این پژوهش را می‌توان به عملکرد چشم و نواحی اولیه بینایی در مغز تشبیه کرد. ابتدا مدلی از شیء یا منظره مشاهده شده در مغز تشکیل می‌شود و سپس با توجه به آن مدل و حرکت چشم، منظره قابل مشاهده بعدی پیش‌بینی می‌شود. در این مقاله، نقطه خیره‌شدگی به عنوان سند جزئی در نظر گرفته شده است.

تقابل میان دو دسته: در این آزمایش تقابل میان هر دو دسته از داده‌های ارقام موجود در MNIST انجام شده که نتایج آن در شکل ۴ مشاهده می‌شوند. در همه حالات، تصاویر به چهار بخش با اشتراک سه پیکسل در طول و عرض تقسیم شده‌اند و میانگین عملکرد مدل پیشنهادی ۹۱ درصد بوده است. دو کلاس مربوط به ارقام ۰ و ۱ در بخش‌های مختلف کم‌ترین شباهت ظاهری را با دیگر ارقام دارند که در نتیجه عملکرد بهتری نیز از خود




شکل ۳: پیش‌پردازش تصاویر ورودی و تولید داده‌های مناسب برای وظیفه سند جزئی.


نتیجه، در هر پنجره زمانی، مدل تنها بخشی از تصاویر کامل را با استفاده از جمعیت نرونی ورودی دریافت می‌کند و جمعیت نرونی مکانی با مشخص کردن مکان هر بخش در تصویر کامل، اطلاعات کمکی به مدل می‌دهد. این اطلاعات کمکی موجب می‌شود تا وظیفه آزمایش‌ها در دسته سند جزئی قرار گیرد [۲۵].

۲.۴ فرآیند آموزش و ارزیابی

در فرآیند آموزش، بخش‌های مختلف یک تصویر در گذر زمان و به طور متوالی، به همراه موقعیت مکانی هر بخش به مدل پیشنهادی داده می‌شود. علاوه بر این اطلاعات، دسته تصاویر ورودی (به واسطه سیگنال یادگیری که بر لایه ۵/۶ اثر می‌گذارد) نیز به مدل داده می‌شود. سیگنال یادگیری باعث می‌شود تا ساختار جمعیت نرونی در لایه ۵/۶ به کمک دسته‌های تصاویر تفکیک شود. طی این فرآیند، وزن‌های سیناپسی رو به جلو از لایه ۲/۳ به لایه ۵/۶ و وزن‌های سیناپسی رو به عقب از لایه ۵/۶ به لایه ۴ آموزش داده می‌شوند. پس از اتمام ورودی برای بخش‌های مختلف یک تصویر، برای مدتی ورودی مدل پیشنهادی قطع می‌شود تا پتانسیل غشاء نوروهای آن




شکل ۵: ماتریس‌های درهم‌ریختگی برای گروه‌های $\{0, 6, 8, 9\}$ و $\{2, 3, 5, 8\}$ با اشتراک سه پیکسل بین بخش‌های 2×2 .



شکل ۶: نمودار تغییرات دقت در روند نمایش هر بخش برای گروه $\{0, 6, 8, 9\}$ با بخش‌بندی 2×2 و اشتراک سه پیکسل بین بخش‌ها. نمودار دقت لحظه‌ای، ارزیابی مدل را تنها با استفاده از ضربه‌های آن مرحله از نمایش بخش نشان می‌دهد و نمودار دقت تجمعی، ضربه‌های آن بخش و تمام بخش‌های پس از آن را برای ارزیابی استفاده می‌کند.

از تصویر ورودی دریافت می‌کند و دقت تصمیم‌گیری نیز افزایش می‌یابد. با استفاده از مطالعه فرسابق^۱ و حذف ارتباطات رو به عقب که وظیفه پیش‌بینی را بر عهده دارند، با کاهش دقت مدل رو به رو می‌شویم که نشان از تاثیر مثبت پردازش پیشگویانه بر روند تصمیم‌گیری دارد. علاوه بر این، وجود ارتباطات رو به عقب می‌تواند موجب تغییر روند یادگیری وزن‌های رو به جلو نیز بشود (شکل ۷). این روند کمک می‌کند که وزن‌ها در تحلیل اکتشاف-استخراج، اکتشافات بیشتری انجام دهند.

تقابل میان تمام دسته‌ها: عملکرد مدل پیشنهادی بر روی تمام دسته‌های ارقام از دادگان MNIST در جدول ۱ و شکل ۸ نمایش داده شده است. با توجه به افزایش قابل توجه تعداد دسته‌ها (ده دسته) نسبت به آزمایش‌های قبلی (دو و چهار دسته)، مدل همچنان توانسته عملکرد




شکل ۴: دقت‌های مدل در آزمایش‌های تقابل دو دسته.

نشان داده‌اند. کلاس‌های مربوط به ارقام ۴ و ۹ بیشترین شباهت ظاهری را در بخش‌های مختلف با یکدیگر دارند و در نتیجه یکی از کم‌ترین عملکردها مربوط به این دو دسته می‌باشد. در تقابل کلاس‌های مربوط به ارقام ۳ و ۵ و همچنین تقابل کلاس‌های مربوط به ارقام ۵ و ۸ نیز پدیده مشابهی رخ داده است.


تقابل میان چهار دسته: در این آزمایش از دو گروه، هر یک شامل چهار دسته از ارقام که دارای بیشترین شباهت ظاهری هستند، استفاده شده است. با توجه به نتایج آزمایش‌ها در جدول ۱، مدل پیشنهادی برای گروه $\{0, 6, 8, 9\}$ در شرایط مشابه عملکرد بهتری نسبت به گروه $\{2, 3, 5, 8\}$ داشته است (شکل ۵). در گروه $\{0, 6, 8, 9\}$ بخش‌ها دارای الگوهای تمایز دهنده بیشتری از یکدیگر هستند. در شکل ۶، نمودار تغییرات دقت با نمایش هر بخش برای گروه $\{0, 6, 8, 9\}$ نشان می‌دهد که مدل پیشنهادی با دریافت بخش جدیدی از تصویر ورودی، تصمیم‌گیری خود را بهبود می‌دهد. با افزایش تعداد بخش‌ها، اندازه ورودی برای هر بخش کاهش یافته و در نتیجه مدل اطلاعات کمتری در هر لحظه دریافت می‌کند که موجب تصمیم‌گیری سخت‌تر و کاهش دقت شده است. اگر تعداد بخش‌ها یکسان باشد و اشتراک بخش‌ها را افزایش دهیم، مدل اطلاعات بیشتری

دقت خوبی داده‌های ورودی را بازسازی کند، بازنمایی مناسبی تشکیل شده است. این بازسازی به عنوان پیش‌بینی داده ورودی در ستون قشری مطرح می‌شود. در مدل ارائه شده در این پژوهش، پیش‌بینی داده‌های ورودی و تصمیم‌گیری در مورد آن‌ها توسط مجموعه نورون‌های موجود در لایه ۵/۶ ستون قشری انجام می‌شود. نتیجه این پیش‌بینی از طریق ارتباطات رو به عقب از نورون‌های لایه ۵/۶ به نورون‌های لایه ۴ منتقل می‌شود. در آزمایش‌های این مطالعه نشان داده شد که این پیش‌بینی‌ها عملکرد مدل را بهبود می‌دهند و موجب می‌شوند ستون قشری بازنمایی مناسب‌تری در لایه ۲/۳ تشکیل دهد. همچنین، ارتباطات رو به عقب ساختار ارتباطات رو به جلو را نیز به نحو مؤثری تحت تاثیر قرار می‌دهند.

همان طور که در آزمایش‌ها مشاهده شد، سند جزئی به تصمیم‌گیری بهتر مدل کمک کرده است، حال آنکه در واقعیت این اطلاعات از دیگر ستون‌های قشری نشئت می‌گیرند. بنابراین ترکیب ستون‌های قشری و بررسی ارتباطات میان آن‌ها می‌تواند گام مهم بعدی برای این پژوهش باشد. همچنین، با توجه به اینکه نواحی مختلف مغز که هر یک از چندین ستون قشری تشکیل شده‌اند، ساختاری سلسله‌مراتبی در مغز دارند، چیدمان سلسله‌مراتبی ستون‌های قشری و تبیین ارتباطات کناری، رو به جلو و رو به عقب در آن‌ها گام مهم دیگری است که در صورت انجام می‌توان از این‌گونه مدل‌ها برای حل مسئله‌های پیچیده‌تر در حوزه‌های مرتبط با هوش مصنوعی و یادگیری ماشین استفاده نمود. علاوه بر این موارد، قاعده یادگیری وابسته به زمان ضربه، تمایل به همگرا کردن وزن‌ها به مقادیر مرزی خود را دارد، درحالی که از لحاظ زیستی چنین اتفاقی به ندرت رخ می‌دهد. با توجه به اینکه فرآیند پیش‌بینی در مدل طراحی شده سرعت همگرایی را کاهش داده، بررسی بیشتر این موضوع و بهره‌گیری از سایر قاعده‌های یادگیری زیست توجیه‌پذیر، مانند



شکل ۷: تغییرات همگرایی وزن‌های رو به جلو در مطالعه فرسپاب. ارتباطات رو به جلو از لایه ۲/۳ به لایه ۵/۶ همگرایی آهسته‌تری را با حضور ارتباطات رو به عقب از خود نشان می‌دهند.



شکل ۸: ماتریس درهم‌ریختگی برای آزمایش شامل تمام دسته‌های ارقام.

مناسبی از خود نشان دهد. بنابراین انتظار، ارقام ۴ و ۹ که بیشترین شباهت ظاهری را دارند، بیشترین میزان خطا را نیز داشته‌اند. همچنین دشواری گروه {۲, ۳, ۵, ۸} موجب شده است تا کمترین دقت‌ها مربوط به این گروه از ارقام باشد و با یکدیگر و همچنین دیگر دسته‌ها خطای دسته‌بندی بیشتری را نشان دهند.

۵ نتیجه‌گیری

مدل‌های مبتنی بر پردازش پیشگویانه، به شیوه‌های مختلفی تلاش می‌کنند تا یک بازنمایی از داده‌های ورودی بسازند و فرض بر این است که اگر بازنمایی بتواند با

- ترکیب یادگیری تقویتی و قاعده یادگیری وابسته به زمان ضربه، می‌تواند گام بنیادی دیگری در این زمینه باشد.
- ### مراجع
- [14] A. v. d. Oord, Y. Li, and O. Vinyals, "Representation learning with contrastive predictive coding," *ArXiv*, vol. abs/1807.03748, 2018.
 - [15] J. Orchard and W. Sun, "Making predictive coding networks generative," *arXiv*, vol. abs/1910.12151, 2019.
 - [16] A. Ororbia, "Spiking neural predictive coding for continual learning from data streams," *arXiv*, vol. abs/1908.08655, 2019.
 - [17] M. Boerlin, C. K. Machens, and S. Denève, "Predictive coding of dynamical variables in balanced spiking networks," *PLoS Computational Biology*, vol. 9, p. e1003258, November 2013.
 - [18] A. W. N'Dri, T. Barbier, C. Teulière, and J. Triesch, "Predictive coding light: learning compact visual codes by combining excitatory and inhibitory spike timing-dependent plasticity," in *2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)*, IEEE, June 2023.
 - [19] S. Yoo, Y. Park, Z. Wang, Y. Wu, S. Medepalli, W. Thio, and W. D. Lu, "Columnar learning networks for multi-sensory spatiotemporal learning," *Advanced Intelligent Systems*, vol. 4, October 2022.
 - [20] L. Abbott, "Lapicque's introduction of the integrate-and-fire model neuron (1907)," *Brain Research Bulletin*, vol. 50, p. 303–304, November 1999.
 - [21] G.-q. Bi and M.-m. Poo, "Synaptic modifications in cultured hippocampal neurons: Dependence on spike timing, synaptic strength, and postsynaptic cell type," *The Journal of Neuroscience*, vol. 18, p. 10464–10472, December 1998.
 - [22] M. E. Larkum, "Are dendrites conceptually useful?," *Neuroscience*, vol. 489, p. 4–14, May 2022.
 - [23] B. Willmore, R. J. Prenger, M. C.-K. Wu, and J. L. Gallant, "The berkeley wavelet transform: A biologically inspired orthogonal wavelet transform," *Neural Computation*, vol. 20, p. 1537–1564, June 2008.
 - [24] Y. LeCun, C. Cortes, and C. Burges, "Mnist handwritten digit database," *AT&T Labs [Online]*. Available: <http://yann.lecun.com/exdb/mnist>, vol. 2, 2010.
 - [25] M. Koperski, T. Konopczynski, R. Nowak, P. Sembracki, and T. Trzcinski, "Plugin networks for inference under partial evidence," in *2020 IEEE Winter Conference on Applications of Computer Vision (WACV)*, IEEE, March 2020.
 - [1] A. Clark, "Whatever next? predictive brains, situated agents, and the future of cognitive science," *Behavioral and Brain Sciences*, vol. 36, p. 181–204, May 2013.
 - [2] S. Lodato and P. Arlotta, "Generating neuronal diversity in the mammalian cerebral cortex," *Annual Review of Cell and Developmental Biology*, vol. 31, p. 699–720, November 2015.
 - [3] V. B. Mountcastle, "Modality and topographic properties of single neurons of cat's somatic sensory cortex," *Journal of Neurophysiology*, vol. 20, p. 408–434, July 1957.
 - [4] M. Awad and R. Khanna, *Cortical Algorithms*. Apress, 2015.
 - [5] J. Hawkins, *A Thousand Brains: A new theory of intelligence*. London, England: Basic Books, mar 2021.
 - [6] T. Parr, G. Pezzulo, and K. J. Friston, *Active Inference: The Free Energy Principle in Mind, Brain, and Behavior*. The MIT Press, March 2022.
 - [7] A. M. Bastos, W. M. Usrey, R. A. Adams, G. R. Mangun, P. Fries, and K. J. Friston, "Canonical microcircuits for predictive coding," *Neuron*, vol. 76, no. 4, pp. 695–711, 2012.
 - [8] K. Friston, "Learning and inference in the brain," *Neural Networks*, vol. 16, p. 1325–1352, November 2003.
 - [9] R. P. N. Rao and D. H. Ballard, "Predictive coding in the visual cortex: a functional interpretation of some extra-classical receptive-field effects," *Nature Neuroscience*, vol. 2, no. 1, pp. 79–87, 1999.
 - [10] M. A. Kramer, "Nonlinear principal component analysis using autoassociative neural networks," *AICHE Journal*, vol. 37, p. 233–243, February 1991.
 - [11] A. Vaswani, N. Shazeer, N. Parmar, J. Uszkoreit, L. Jones, A. N. Gomez, L. u. Kaiser, and I. Polosukhin, "Attention is all you need," in *Advances in Neural Information Processing Systems* (I. Guyon, U. V. Luxburg, S. Bengio, H. Wallach, R. Fergus, S. Vishwanathan, and R. Garnett, eds.), vol. 30, Curran Associates, Inc., 2017.
 - [12] W. Lotter, G. Kreiman, and D. Cox, "Deep predictive coding networks for video prediction and unsupervised learning," *ArXiv*, vol. abs/1605.08104, 2016.
 - [13] S. B. L. Mandyam Veerambudi Srinivasan and A. Dubs, "Predictive coding: a fresh view of inhibition in the retina," *Proceedings of the Royal Society of London. Series B. Biological Sciences*, vol. 216, p. 427–459, November 1982.