

## نوقشر مغز و نقش آن در هوش مصنوعی

آشنا گرگان محمدی

دانشجوی دکتری، دانشکده ریاضی، آمار و علوم کامپیوتر، دانشکدگان علوم، دانشگاه تهران، تهران، ایران

پست الکترونیکی: ashena.mohammadi@ut.ac.ir

محمد گنج‌تابش\*

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

پست الکترونیکی: mgtabesh@ut.ac.ir

### چکیده

### ۱ مقدمه

در سال‌های اخیر، شبکه‌های عصبی مصنوعی تحول شگرفی در هوش مصنوعی به وجود آورده‌اند. با این وجود، همچنان چالش‌هایی اساسی در روند فعلی پیشرفت این شبکه‌ها وجود دارد. کلید حل این مسائل در شناخت بیشتر مغز موجودات زنده و به‌ویژه پستانداران نهفته است. از آنجایی که نوقشر به عنوان مرکز اصلی عملکرد هوشمندانه در پستانداران شناخته می‌شود، مطالعه و مدل‌سازی محاسباتی ساختار و سازوکار آن می‌تواند نقش مؤثری در مسیر توسعه سیستم‌های هوشمند و شبکه‌های عصبی مصنوعی ایفا کند. در این مطالعه، سعی داریم با مرور یافته‌ها و فرضیات موجود از ساختار و سازوکار نوقشر، به بررسی یکی از نظریه‌های محاسباتی ارائه شده به منظور طراحی شبکه‌های عصبی مصنوعی بپردازیم. همچنین، مطالعات کاربردی حول این نظریه را مرور کرده و حل چالش‌های حال حاضر هوش مصنوعی بر پایه این نظریه را بررسی می‌کنیم.

آنچه مغز پستانداران را از دیگر موجودات متمایز می‌کند، لایه‌ای چین‌خورده و نازک متشکل از میلیاردها نورون است که به آن نوقشر<sup>۱</sup> می‌گویند. بیش از هزاران میلیارد اتصالات سیناپسی نورون‌های نوقشر را به یکدیگر و دیگر قسمت‌های مغز مرتبط می‌کند و عملکردهایی که از آن‌ها به عنوان هوشمندی یاد می‌شود، حاصل همین ارتباطات است. نوقشر ساختاری شش لایه دارد که از بیرون به داخل با اعداد ۱ تا ۶ شماره‌گذاری شده‌اند. از طرف دیگر، نحوه اتصالات نورون‌ها در این لایه‌ها ساختاری ستونی را شکل می‌دهد که از آن به عنوان ستون‌های قشری<sup>۲</sup> یاد می‌شود [۱]. هر کدام از این ستون‌ها متشکل از ستون‌های باریک‌تری از حدود ۱۰۰ نورون در لایه‌های ۲ تا ۶ می‌باشد که به آن‌ها ستون‌های کوچک<sup>۳</sup> گفته می‌شود [۱، ۲]. به عبارت دیگر، یک ستون قشری مجموعه‌ای از قشرهای کوچک است که به صورت افقی به یکدیگر متصلند. ستون‌های کوچک در یک ستون قشری یک میدان دریافتی<sup>۴</sup> مشترک

واژه‌های کلیدی: شبکه‌های عصبی مصنوعی،

نوقشر، ستون‌های قشری، کدگذاری پیشگویانه.

\* نویسنده مسئول


1- Neocortex

2- Cortical columns

3- Minicolumn

4- Receptive field

دارند و با مهار فعالیت یکدیگر، هر یک قادر به یادگیری ویژگی خاصی است. بنابراین، هر ستون قشری می‌تواند هزاران ویژگی را بیاموزد [۲، ۳]. محققان بر این باورند که هر ستون قشری یک واحد پردازش حسی-حرکتی<sup>۱</sup> است و از آنجایی که ساختار تقریباً واحدی در تمام سطح نوقشر دارند، آنچه موجب تمایز عملکرد آن‌ها با یکدیگر می‌شود، اتصالات آن‌ها به قسمت‌های مختلف مغز است [۴]. شکل ۱ شمایی از ساختار نوقشر را نشان می‌دهد.



شکل ۱: شمایی از ساختار یک ستون قشری در نوقشر (برگرفته از <https://neuwritesd.org/2014/07/10/cortical-columns/>).

تحقیقات متعددی در راستای شناخت عملکرد نوقشر و به‌ویژه، سازوکار و اتصالات سیناپسی ستون‌های قشری صورت گرفته است. بر اساس این مطالعات، لایه ۴ اولین دریافت‌کننده اطلاعات حسی از ناحیه تالاموس مغز است و پس از پردازش این اطلاعات، آن را به لایه‌های ۲ و ۳ ارسال می‌کند. در نهایت، پیامی که به بخش‌های دیگر مغز مخابره می‌شود حاصل پردازش‌های صورت گرفته بر روی اطلاعات حسی در لایه‌های ۲ و ۳ است [۱، ۲، ۴]. با وجود اینکه سازوکار لایه‌های عمیق‌تر کمتر شناخته شده است، مطالعاتی بر روی نواحی حرکتی مغز صورت گرفته است که منجر به فرضیه‌هایی در ارتباط با نحوه پردازش و اتصالات

سیناپسی لایه‌های ۵ و ۶ شده است. آزمایشات نشان داده‌اند که اتصالات سیناپسی در لایه ۵، بر خلاف دیگر اتصالات، متراکم است و باور بر این است که این لایه تصویری از دستورات حرکتی ارسال شده به نواحی زیرقشری<sup>۲</sup> است [۳، ۵]. لایه ۶ نیز بخشی از ورودی خود را از این لایه گرفته و بخش دیگر ورودی آن از ناحیه تالاموس می‌باشد [۶]. آخرین مطالعات نیز مستقیماً به نقش نورون‌های لایه ۶ قشر آنتورینال<sup>۳</sup> مغز در کدگذاری و حافظه مکانی اشاره می‌کنند [۷].

مجموعه این شواهد می‌تواند محاسبه جابه‌جایی نسبت به یک چارچوب مرجع<sup>۴</sup> را به عنوان سازوکار این دو لایه معرفی کند که به توسعه فرضیه وجود نورون‌هایی شبیه سلول‌های شبکه<sup>۵</sup> در لایه ۶ نیز منجر شده است [۸، ۳]. این ساختار همواره مورد توجه دانشمندان حوزه علوم اعصاب محاسباتی بوده است که در میان آن‌ها می‌توان گراسبرگ<sup>۶</sup> و هاوکینز<sup>۷</sup> را به عنوان سردمداران مطالعات محاسباتی ستون‌های قشری و نوقشر دانست. گراسبرگ پس از معرفی نظریه رزونانس تطبیقی<sup>۸</sup> در سال ۱۹۷۶، که نظریه‌ای در توضیح یادگیری در جهان متغیر و در حال حرکت پیرامون ما می‌باشد، در سال ۲۰۰۷ مدل نظریه رزونانس تطبیقی لایه‌ای<sup>۹</sup> را ارائه کرد که در آن ساختار لایه‌ای نوقشر برجسته شده بود [۹، ۱۰]. بر خلاف گراسبرگ که عمدتاً بر روی مدل‌سازی ریاضیاتی این ساختار با تکیه بر علوم اعصاب شناختی<sup>۱۰</sup> و خودآگاهی<sup>۱۱</sup> متمرکز بوده است، هاوکینز و همکارانش به مطالعه و پیاده‌سازی این شواهد در جهت بهبود مدل‌های هوش مصنوعی پرداخته‌اند. مطالعات او و گروهش در این سال‌ها به توسعه نظریه

2- Subcortical

3- Entorhinal cortex

4- Frame of reference

5- Grid cells

6- Grossberg

7- Hawkins

8- Adaptive Resonance Theory

9- Laminar Adaptive Resonance Theory

10- Cognitive neuroscience

11- consciousness

1- Sensorimotor

هزاران مغزاً منجر شده است و الهام‌بخش برخی محققان حوزه هوش مصنوعی بوده است که در اینجا قصد داریم به عمده آن‌ها بپردازیم.

در ادامه، ابتدا به تشریح نظریه هزاران مغز با معرفی اصول پایه‌ای آن و شواهد عصب‌شناختی زیربنای آن‌ها می‌پردازیم. سپس، در بخش ۳ مدل‌های محاسباتی دیگر که مبتنی بر ساختار نوقشر و این نظریه هستند را بررسی می‌کنیم. از آنجایی که به نظر می‌رسد این نظریه می‌تواند کلید حل معماهای پیش روی دانشمندان حوزه هوش مصنوعی باشد، در بخش ۴ مشکلات موجود در شبکه‌های عصبی مصنوعی حال حاضر و نحوه حل آن‌ها به کمک سازوکارهای موجود در نظریه هزاران مغز را بازگو می‌کنیم. در انتها نیز، به بحث و جمع‌بندی درباره مسیره‌های آینده در توسعه شبکه‌های عصبی مصنوعی زیست‌توجیه‌پذیر بر مبنای این نظریه می‌پردازیم.

## ۲ نظریه هزاران مغز

همان‌طور که پیش‌تر گفته شد، نوقشر متشکل از ستون‌های قشری با ساختاری تقریباً مشابه در تمام سطح خود است که هر یک به‌عنوان یک پردازشگر حسی-حرکتی عمل می‌کند. هر ستون قشری را می‌توان به عنوان یک واحد هوشمند، یا مغز، در نظر گرفت و به همین دلیل این نظریه، هزاران مغز نام دارد [۱۱]. این نظریه که بر تشکیل یک نمایش از کل شیء در ستون‌های قشری حاضر در نواحی مختلف سلسله‌مراتب مغز تأکید دارد (شکل ۲)، بر اصول مختلفی استوار است که هر کدام بر پایه شواهد و یا استنتاجی بر اساس مجموعه‌ای از شواهد عصب‌شناختی از نوقشر می‌باشند.

نظریه هزاران مغز تلاش دارد نحوه درک و تعامل ما با جهان در حال تغییر پیرامون را توضیح دهد. بر اساس این نظریه، ما جهان را به صورت دنباله‌ای از رویدادها در طول زمان درک می‌کنیم و برای مثال، حتی وقتی به

یک تصویر ثابت می‌نگریم، حرکات ریز چشمان ما که منجر به توجه ما به قسمت‌های مختلف تصویر می‌شود، باعث تجمع اطلاعات دریافتی از قسمت‌های مختلف تصویر در کسری از ثانیه شده و ما آن را به عنوان یک تصویر ثابت با اجزای مختلف درک می‌کنیم [۱۲]. از طرف دیگر، در بسیاری از شرایط، اطلاعات حسی گوناگون با یکدیگر ترکیب شده و به درک ما از محیط منجر می‌شود. به‌علاوه، نوقشر به عنوان یک موتور پیشگو عمل می‌کند و همواره مدلی از جهان پیرامون را در خود ذخیره می‌کند. این امر سبب می‌شود که ما بر اساس این مدل ذاتی با محیط در تعامل باشیم و به محض بروز تغییری مغایر با مدل ذهنی ما، یادگیری صورت می‌گیرد تا مدل بر شواهد تازه از محیط اطراف منطبق شود [۴، ۳، ۸]. از طرف دیگر، فعالیت‌های شبکه عصبی مغز ما تنک<sup>۲</sup> است و به همین دلیل، سازوکاری محاسباتی جهت توضیح تمام سازوکارها در غالب نمایش تنک اطلاعات نیاز است [۱۳]. در ادامه، هر یک از این اصول را بر اساس شواهد زیستی و آنچه در نظریه هزاران مغز پیاده‌سازی شده است، بررسی می‌کنیم.

### ۱.۲ یادگیری با حرکت: سلول‌های شبکه و سلول‌های مکانی

کلیدی‌ترین اصل در نظریه هزاران مغز، یادگیری با حرکت است که از سازوکار سلول‌های شبکه و سلول‌های مکانی<sup>۲</sup> الهام گرفته است [۳]. این سلول‌ها که نقش اصلی را در جهت‌یابی و درک مکانی ایفا می‌کنند، در کنار دیگر سلول‌های جهت‌یابی<sup>۴</sup> شناخته شده نظیر سلول‌های جهت سره و سلول‌های لبه<sup>۶</sup>، یک نقشه شناختی از فضا را در مغز به تصویر می‌کشند [۱۴].

سلول‌های مکانی که در سال ۱۹۷۱ طی آزمایشاتی

2- Sparse

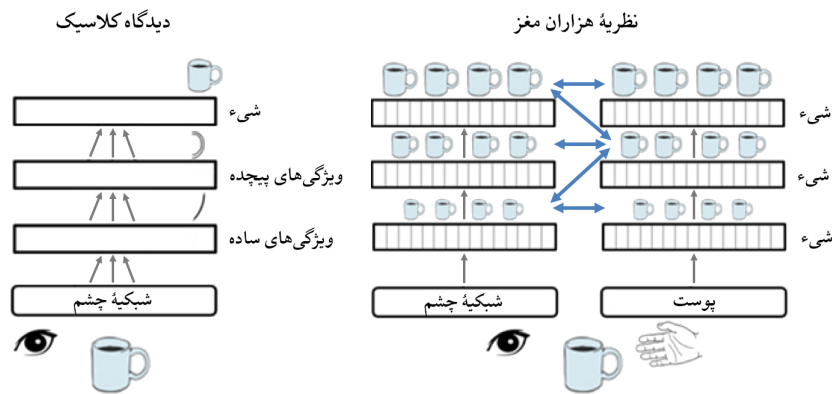
3- Place cells

4- Navigation cells

5- Head-direction cells

6- Border cells

1- Theory of A Thousand Brains



شکل ۲: تفاوت نظریه هزاران مغز و دیدگاه کلاسیک در استخراج ویژگی‌ها و نمایش اشیا (برگرفته از [۸]).

می‌شود [۴]. این نظریه همچنین ادعا می‌کند که بر پایه شواهد موجود از سازوکار لایه‌های ۵ و ۶، می‌توان نتیجه گرفت که این لایه‌ها مانند سلول‌های شبکه عمل کرده و با فراهم کردن بستری برای درک مکان میدان دریافتی ستون قشری نسبت به محیط و حرکت آن به منظور دریافت اطلاعات محیطی بیشتر، منجر به تشکیل نقشه شناختی می‌شوند [۳، ۸].

## ۲.۲ کدگذاری پیشگویانه و محاسبات دندریتی

مغز ما همواره در حال ساخت و به‌روزرسانی یک مدل ذهنی از جهان پیرامون است که به این فرایند کدگذاری پیشگویانه می‌گویند. منشأ این سازوکار نوقشر بوده و به‌طور دقیق‌تر، اتصالات میان ستون‌های قشری در یک سطح از سلسله مراتب نواحی مغز و اتصالات از ستون‌های قشری در نواحی بالادستی مغز به نواحی پایین دستی می‌باشد [۵].

می‌دانیم که در سطح سلولی، اتصالات سیناپسی میان آکسون نورون پیش‌سیناپسی و دندریتهای نورون پس‌سیناپسی شکل می‌گیرد. یکی از انواع نورون متداول در نوقشر، نورون‌های هرمی<sup>۱</sup> هستند که دندریتهای متنوعی دارند. این دندریتهای از لحاظ فاصله با بدنه سلول، به دو دسته مجاور<sup>۲</sup> و دور<sup>۳</sup> تقسیم

بر روی موش‌ها در ناحیه هیپوکامپ کشف شدند، سلول‌هایی با میدان دریافتی مکانی هستند که با قرارگیری در یک محیط محلی مشخص فعال می‌شوند و عناصر پایه در شکل‌گیری نمایش‌های غیرمتمرکز نقشه-گونه به‌شمار می‌روند. چند سال بعد، گروهی دیگر از محققان سلول‌هایی را در قشر آنتورینال مغز موش مشاهده کردند که به‌صورت مشبک تمام فضا را تقسیم‌بندی می‌کردند و هر کدام به چندین مکان از محیط واکنش نشان می‌داد. این سلول‌ها نقشی کلیدی در جهت‌یابی و تشخیص حرکت در فضا دارند و کشف آن‌ها به‌همراه سلول‌های مکانی تحولی شگرف در شناخت ما از مغز و رفتار آن در جهان در حال تغییر ایجاد کرد. بر اساس این شواهد، نوقشر در این نواحی به عنوان محل شکل‌گیری نقشه شناختی و مدل ما از جهان شناخته می‌شود [۱۴، ۱۵].

نظریه هزاران مغز پا را فراتر گذاشته و اذعان می‌کند که نوقشر در تمام نواحی مغز یک نقشه شناختی می‌سازد و آنچه درک ما از جهان و عملکردهای سطح بالایی نظیر تفکر را شکل می‌دهد، حاصل کنار هم قرارگیری همین نقشه‌های شناختی یا نمایش‌های حاصل از ستون‌های قشری در نواحی مختلف است. بر اساس این نظریه، آنچه موجب شکل‌گیری یک نمایش از محیط می‌شود، حرکت است. با تغییر ورودی حسگرهای ما در نتیجه حرکت، نمایش شکل‌گرفته در لایه‌های ۲ و ۳ بهبود یافته و به شناخت منجر

1- Pyramidal neurons  
2- Proximal  
3- Distal

می‌شوند. دندریتهای دور، خود بر دو قسم قاعدهای<sup>۱</sup> و رأسی<sup>۲</sup> هستند که ورودی خود را، به ترتیب از دیگر لایه‌های همان ستون قشری و از لایه‌های هم‌سطح از ستون‌های قشری دیگر می‌گیرند. بنابراین، دندریتهای مجاور و قاعدهای ورودی‌های پیش‌خور<sup>۳</sup> و دندریتهای رأسی ورودی‌های پس‌خور<sup>۴</sup> دریافت می‌کنند [۴، ۱۶].


درحالی‌که دندریتهای مجاور مستقیماً موجب تحریک بدنه سلول می‌شوند، دندریتهای قاعدهای و رأسی تنها پس از دریافت میزان کافی ورودی فعال شده و سیگنال وضعیفی به بدنه سلول ارسال می‌کنند. بدین واسطه، ورودی‌هایی که از طریق دندریتهای دور به بدنه نورون وارد می‌شوند، آن را به حالت آماده‌فعالیت در می‌آورند تا به محض رسیدن ورودی پیش‌خور زودتر و بیشتر از سایر نورون‌ها فعال شوند. این سازوکار، به همراه ورودی‌هایی که از لایه‌های ۵ و ۶ به کمک دندریتهای قاعدهای به لایه‌های بالاتر ستون قشری می‌رسند و یک کدگذاری مکانی پیشگویانه را فراهم می‌کنند، بستری برای کدگذاری پیشگویانه می‌باشند [۴، ۱۶، ۵].

## ۴.۲ ساختار مدل هزاران مغز

با کنار هم قرار دادن این اصول و ساختار نوقشر، این نظریه مدلی کلی از سازوکار مغز ارائه می‌دهد. بر این اساس، هر شبکه عصبی مصنوعی که بر پایه این نظریه ساخته شود، ضمن در نظر گرفتن محاسبات دندریتی و لزوم وجود نمایش توزیع‌شده تنک، می‌تواند یادگیری با حرکت را حتی بدون در نظر گرفتن لایه‌های ۵ و ۶ پیاده‌سازی کند و تنها لازم است که درک مکانی به طریقی در ورودی شبکه نهادینه شود. این نظریه همچنین شمایی از اتصالات در صورت لحاظ کردن لایه‌های عمیق‌تر ستون قشری را بر اساس مشاهدات عصب‌شناختی ارائه می‌کند (شکل ۳). بر این اساس، لایه ۴ و ۶ منبع دریافت ورودی از ناحیه تالاموس بوده و لایه ۲/۳ و ۵ تصویری از پردازش‌های حاصل را به ترتیب، به قشر مغز و ناحیه تالاموس ارسال می‌کنند. در بخش بعد، مدل‌های هوش مصنوعی ارائه شده بر اساس این نظریه را بررسی می‌کنیم.

## ۳.۲ نمایش توزیع‌شده تنک

پیش‌تر دیدیم که ستون‌های کوچک در یک ستون قشری میدان دریافتی مشترکی دارند و در عین حال، با مهار یکدیگر موجب می‌شوند که هر کدام به ویژگی‌های خاصی از آن میدان دریافتی حساس شود. بدین منظور، سازوکار شناخته شده در علوم اعصاب محاسباتی  $k$ -winner-take-all است. طبق این سازوکار،  $k$  نورونی که زودتر فعال می‌شوند فعالیت دیگر نورون‌ها را در مجموعه مهار کرده و مانع از فعال شدن آن‌ها در آن لحظه می‌شوند. در حالت خاص آن، در هر لحظه تنها به یک نورون اجازه فعال شدن داده می‌شود. پیاده‌سازی این سازوکار میان ستون‌های کوچک، نه تنها بستری محاسباتی برای یادگیری ویژگی‌های منحصربه‌فرد




شکل ۳: ساختار اتصالات پیشنهادی بر اساس شواهد زیستی در نظریه هزاران مغز (برگرفته از [۴]).

## ۳ مدل‌های توسعه یافته مبتنی بر نظریه هزاران مغز

هاوکینز و همکاران همزمان با مطرح کردن ایده‌های نظری خود بر اساس مطالعات علوم اعصاب و تجربیات

- 1- Basal
- 2- Apical
- 3- Feedforward
- 4- Backward




شکل ۵: ساختار به کار رفته در اولین مدل کاربردی بر پایه نظریه هزاران مغز (برگرفته از [۳]). اعداد نشان‌دهنده ترتیب انتقال اطلاعات هستند.

پایان فرآیند آموزش و به کمک سازوکار k-winner-take-all قادر به تشخیص قطعاتی  $5 \times 5$  از قسمت‌های مختلف تصویر بود. سپس، این بردار ویژگی به همان مدل پیشین داده شد. آن‌ها در این آزمایش نشان دادند که پس از تبدیل تصویر ثابت به دنباله‌ای از قطعاتی کوچک‌تر همان تصویر، مدل‌های مبتنی بر شبکه‌های عصبی بازگشتی<sup>۲</sup> و مدل‌های یادگیری ماشین نمونه-محور<sup>۳</sup> به مراتب ضعیف‌تر از مدل آن‌ها عمل می‌کند [۱۸]. با این حال، دقت حاصل از این مدل همچنان با مدل‌های کلاسیک یادگیری ماشین و شبکه‌های عصبی مصنوعی قابل رقابت نیست.

اخیراً نیز گروهی دیگر از محققان مدلی تحت عنوان شبکه‌های یادگیری ستونی<sup>۴</sup> را توسعه داده‌اند که از نورون‌های ضربه‌ای<sup>۵</sup> و یادگیری وابسته به زمان ضربه<sup>۶</sup> در شبکه‌های عصبی ضربه‌ای بهره گرفته‌اند. در این تحقیق، به جای انتخاب قطعات از قسمت‌های مختلف تصویر به صورت تصادفی، حرکتی منظم و سطح به سطح بر روی تصویر جهت استخراج دنباله قطعاتی تصویر به کار گرفته شده است. بدین واسطه، مدل نیازی به درک جابه‌جایی مکانی نداشته و می‌توان ساختار مدل را در لایه‌های ۲ تا ۴ متمرکز کرد. مدل ارائه شده دو ستون قشری را به تصویر می‌کشد که هر کدام

محاسباتی خود مبتنی بر مدل نورونی ارائه شده توسط خودشان تحت عنوان HTM (شکل ۴)، اولین مدل‌های کاربردی را نیز آزمایش کردند. اولین مدل آن‌ها که در یک محیط مشبک با ورودی حسی-حرکتی آزموده شد، لایه‌های یک ستون قشری را در دو لایه حسی (که نماینده لایه‌های ۲، ۳ و ۴ است) و مکانی (که لایه‌های ۵ و ۶ را نمایندگی می‌کند) خلاصه کرده است (شکل ۵). در این مدل که تمام اصول را در خود جای داده است، ابتدا یک ورودی حرکتی به لایه مکانی که ساختار و سازوکاری مشابه سلول‌های شبکه دارد، داده می‌شود. این ورودی به کمک دندریته‌های قاعده‌ای به نورون‌های لایه حسی رسیده و با ورودی داده‌های حسی از طریق دندریته‌های مجاور و فعال شدن سازوکار k-winner-take-all، تعدادی از نورون‌ها فعال می‌شوند (پیش از یادگیری، تمام نورون‌های ستون‌های کوچک برنده فعال می‌شوند و به مرور و طی فرآیند یادگیری، نورون‌های خاصی از ستون‌های کوچک برنده فعال می‌شوند). این فعالیت به کمک اتصالات پس‌خور و از طریق دندریته‌های رأسی موجب به‌روزرسانی نمایش لایه مکانی می‌شود [۳].



شکل ۴: ساختار مدل نورونی HTM که برگرفته از ساختار نورون‌های هرمی است (برگرفته از [۴]).

دو سال بعد و در سال ۲۰۲۱، هاوکینز و همکاران کارایی مدل پیشین خود را بر روی یک مجموعه داده شناخته شده در حوزه یادگیری ماشین، یعنی دادگان تشخیص ارقام دست‌نویس MNIST، به تصویر کشیدند. بدین منظور، یک شبکه عصبی پیشی<sup>۱</sup> تنک را به منظور استخراج بردار ویژگی تنک آموزش دادند که پس از

2- Recurrent neural networks  
3- Instance-based  
4- Columnar Learning Networks  
5- Spiking neurons  
6- Spike-Timing Dependent Plasticity (STDP)

1- Convolutional neural network

می‌تواند ورودی خود را از یک حسگر مجزا بگیرد. این ورودی‌ها توسط دندریتهای قاعده‌ای که به‌کمک یک شبکه پیچشی کم‌عمق پیاده‌سازی شده‌اند، به لایه ۴ ستون قشری متناظر وارد می‌شوند. سپس سازوکار  $k$ -winner-take-all اعمال شده و اطلاعات به‌کمک شبکه‌ای تماماً متصل (که نقش آکسون را بازی می‌کند) به لایه ۲ و ۳ منتقل می‌شود. در این مطالعه با کنار هم قرار دادن داده‌های تصویری و صوتی ارقام دست‌نویسه، ستون‌های قشری را به‌صورت مجزا آموزش داده و نشان داده شده است که نه تنها هر ستون قشری با دقت قابل قبولی قادر به تشخیص ارقام می‌باشد، بلکه با کنار هم قرار دادن نمایش‌های حاصل از این دو ستون قشری، دقت تشخیص ارقام افزایش یافته و با نتایج حاصل از مدل‌های یادگیری ماشین قابل رقابت است [۱۹].

پیش‌تر نیز مدلی نظری با تکیه بر شبکه‌های عصبی ضربه‌ای و تأکید بر اصل کدگذاری پیشگویانه به‌کمک محاسبات دندریتی تحت عنوان کدگذاری پیشگویانه دندریتی ارائه شده بود [۵]. این مدل با قرار دادن مفاهیمی نظیر شبکه‌های متعادل<sup>۱</sup> و مهار جانبی<sup>۲</sup> در کنار نظریه کدگذاری پیشگویانه سلسله‌مراتبی و محاسبات پیشگویانه در دندریتهای رأسی، نظریه‌ای جدید از محاسبات قشری در نوقشر ارائه می‌کند. این نظریه، دندریتهای دور را مراکز محاسبه خطا معرفی می‌کند و با برقراری ارتباط میان محاسبات پیوسته در دندریتهای دور و ضربه‌های بدنه نورون، روشی برای کاهش خطاهای بازشناسی و پیش‌بینی در شبکه ارائه می‌دهد. با کنار هم قرار دادن این نظریه و نظریه کاربرد هزاران مغز در هوش مصنوعی، به‌ویژه شبکه یادگیری ستونی، می‌توان آینده‌ای درخشان برای نسل سوم شبکه‌های عصبی مصنوعی متصور شد که قابلیت پیاده‌سازی بر روی پردازنده‌های نورومورفیک<sup>۳</sup> را نیز دارند. سؤال اینجاست که این مسیر به چه چالش‌هایی در حوزه هوش مصنوعی و به‌ویژه شبکه‌های عصبی

مصنوعی حال حاضر پاسخ می‌دهد؟ در ادامه به بررسی پاسخ این سؤال خواهیم پرداخت.

## ۴ شبکه‌های عصبی مصنوعی: چالش‌ها و راه‌حل‌ها

شبکه‌های عصبی مصنوعی نسل دوم تاکنون پیشتازان عرصه هوش مصنوعی بوده‌اند و در کارهایی نظیر بازشناسی اشیا، تشخیص دست‌نویسه، تبدیل گفتار به متن، تولید آثار هنری و انجام بازی‌های رایانه‌ای عملکردی قابل رقابت با انسان دارند. جدیدترین مدل‌های مبتنی بر این نوع از شبکه‌های عصبی که تحت عنوان مبدل‌ها<sup>۴</sup> شناخته می‌شوند، در کنار روش یادگیری خودنظارتی<sup>۵</sup> عملکرد بسیار خوبی را در بسیاری از کاربردها از خود به‌نمایش گذاشته‌اند [۲۰]. مبدل‌ها تبلوری از ساختار نوقشر در شبکه‌های عصبی مصنوعی کلاسیک است؛ چراکه بن‌مایه این شبکه‌ها نیز یک ساختار تکرار شونده دارد و سازوکار توجه نقشی کلیدی در این شبکه‌ها ایفا می‌کند. با وجود عملکرد فوق‌العاده آن‌ها، این شبکه‌ها بسیار بزرگ بوده، مصرف انرژی بالایی داشته و نشان داده شده است که در بسیاری از موارد از مشکل بیش‌برازش<sup>۶</sup> رنج می‌برند و نسبت به داده‌های مشاهده شده جانب‌دارانه<sup>۷</sup> عمل می‌کنند [۲۰].

علاوه‌بر چالش‌های اخلاقی و فلسفی که امروزه به‌شدت مورد توجه قرار گرفته‌اند و هشدارهایی را در رابطه با مسیر فعلی هوش مصنوعی مطرح می‌کنند، همچنان چالش‌های زیادی در طراحی و به‌کارگیری این شبکه‌ها در کاربردهای پیچیده‌تر وجود دارد. یکی از این چالش‌ها، تک‌منظوره بودن مدل‌های توسعه‌یافته بر اساس این شبکه‌هاست. برای مثال، یک شبکه عصبی که به منظور انجام بازی‌ها آتاری آموزش داده شده

4- Transformers

5- Self-supervised learning

6- Overfitting

7- Bias

1- Balanced network

2- Lateral inhibition

3- Neuromorphic chips

است، نمی‌تواند شطرنج بازی کند، یا حتی ساده‌تر، شبکه‌ای که جهت بازشناسی اشیا در محیط خانه آموزش دیده است، قادر به بازشناسی وسایل حمل و نقل در محیط بیرون از خانه نیست. این مشکلات در سال‌های اخیر مورد توجه بسیاری از دانشمندان حوزه هوش مصنوعی بوده است و راه‌حلهایی نیز برای رفع آن‌ها ارائه شده‌اند؛ ولی همچنان، کاربردهای این راه‌حل‌ها محدود بوده و عملکرد بسیار پایین‌تری نسبت به مدل‌های تک منظوره یا عملکرد انسان دارند. دو مثال مطرح شده به مشکلاتی اشاره می‌کنند که به ترتیب تحت عنوان چندمنظورگی<sup>۱</sup> و فراموشی فاجعه‌بار<sup>۲</sup> شناخته می‌شوند [۲۱]. چندمنظورگی به عدم توانایی این شبکه‌ها به انجام کارهای مختلف اشاره کرده و فراموشی فاجعه‌بار شرایطی است که در آن با آموزش دوباره شبکه در یک محیط جدید، آن شبکه تمام یا بخشی از اطلاعات آموخته شده در محیط قبلی را فراموش می‌کند. طبق این تعریف، می‌توان گفت که با حل مسئله فراموشی فاجعه‌بار، مشکل چندمنظورگی نیز رفع می‌شود. مسئله فراموشی فاجعه‌بار در هوش مصنوعی عمدتاً در یادگیری مستمر<sup>۳</sup> بررسی می‌شود [۲۲].

با توجه به آنچه از نظریه هزاران مغز و ساختار نوقشر گفته شد، این نظریه می‌تواند راه حلی قابل اتکا برای چالش‌های مطرح شده باشد. ساختار یکنواخت ستون‌های قشری، افزایش ظرفیت یادگیری در نمایش تنک، کدگذاری پیشگویانه و حافظه دنباله‌ای، و نیز اصل یادگیری با حرکت که یادگیری داده‌های دنباله‌ای را تسهیل می‌کند، هر یک به نوبه خود نقشی در رفع این مشکلات ایفا می‌کنند. یکنواختی ساختار موجب می‌شود که به سادگی بتوان ورودی یک ستون قشری را تغییر داد و به دلیل اتصالات تنک و نمایش توزیع شده تنک، این ستون قشری ظرفیت یادگیری ورودی جدید را خواهد داشت. همچنین، به واسطه سازوکار کدگذاری پیشگویانه و یادگیری با حرکت، شبکه در صورت دیدن

ورودی غیرمنتظره به شدت فعال شده و یادگیری نیز با شدت بالایی صورت می‌گیرد؛ این در حالی است که اگر ورودی مطابق انتظار باشد، فعالیت نورون‌های ستون قشری بسیار پایین بوده و نرخ یادگیری کم و نزدیک به صفر خواهد بود. از طرف دیگر، اتصالات میان ستون‌های قشری این امکان را می‌دهد که ورودی‌های حسی گوناگون به شبکه وارد شوند و شبکه برای انجام کارهای مختلف آموزش ببیند. بدین ترتیب، شبکه می‌تواند به‌طور مستمر و بدون فراموش کردن اطلاعات آموخته شده، یک یا چندین کار را به‌طور مؤثر یاد گرفته و انجام دهد. از طرف دیگر، زیست‌توجیه‌پذیری این نظریه و موفقیت در پیاده‌سازی آن به کمک شبکه‌های عصبی ضربه‌ای، بستری را برای طراحی مدل‌هایی با مصرف انرژی پایین فراهم می‌کند.

## ۵ بحث و نتیجه‌گیری

نظریه هزاران مغز راهکارهای مؤثری به‌منظور شبیه‌سازی و پیاده‌سازی شبکه‌های عصبی مصنوعی مبتنی بر ساختار یکنواخت نوقشر و سازوکارهای عملکردی آن ارائه می‌کند. این نظریه ضمن تأکید بر لزوم نمایش تنک، شبیه‌سازی محاسبات دندریتی و کدگذاری پیشگویانه، به نقش یادگیری با حرکت و به‌کارگیری سازوکار سلول‌های شبکه در راستای شکل‌گیری یک مدل از محیط عمل سیستم‌های هوشمند می‌پردازد. با وجود اینکه پایه‌های عملیاتی این نظریه مدل نورونی HTM است، زیست‌توجیه‌پذیری آن مورد توجه محققان شبکه‌های عصبی ضربه‌ای نیز قرار گرفته است. لذا، این نظریه علاوه بر امکان کاهش انرژی مصرفی سیستم‌های هوشمند، می‌تواند پاسخگوی چالش‌های اساسی هوش مصنوعی و شبکه‌های عصبی مصنوعی از جمله چندمنظورگی و فراموشی فاجعه‌بار باشد.

به نظر می‌رسد یکی از مسیرهای قابل اتکا در ساخت آینده هوش مصنوعی، پیاده‌سازی اصول این نظریه

1- Multi-tasking

2- Catastrophic forgetting

3- Continual learning



- [6] A. Thomson, "Neocortical layer 6, a review," *Frontiers in Neuroanatomy*, vol. 4, 2010.
- [7] Y. Ben-Simon, K. Kaefer, P. Velicky, J. Csicsvari, J. G. Danzl, and P. Jonas, "A direct excitatory projection from entorhinal layer 6b neurons to the hippocampus contributes to spatial coding and memory," *Nature communications*, vol. 13, no. 1, pp. 1–14, 2022.
- [8] J. Hawkins, M. Lewis, M. Klukas, S. Purdy, and S. Ahmad, "A framework for intelligence and cortical function based on grid cells in the neocortex," *Frontiers in Neural Circuits*, vol. 12, 2019.
- [9] S. Grossberg, "Adaptive resonance theory: How a brain learns to consciously attend, learn, and recognize a changing world," *Neural networks*, vol. 37, pp. 1–47, 2013.
- [10] S. Grossberg, "Towards a unified theory of neocortex: laminar cortical circuits for vision and cognition," in *Computational Neuroscience: Theoretical Insights into Brain Function* (P. Cisek, T. Drew, and J. F. Kalaska, eds.), vol. 165 of *Progress in Brain Research*, pp. 79–104, Elsevier, 2007.
- [11] K. J. Hole and S. Ahmad, "A thousand brains: toward biologically constrained ai," *SN Applied Sciences*, vol. 3, no. 8, pp. 1–14, 2021.
- [12] J. Hawkins and S. Ahmad, "Why neurons have thousands of synapses, a theory of sequence memory in neocortex," *Frontiers in Neural Circuits*, vol. 10, 2016.
- [13] Y. Cui, S. Ahmad, and J. Hawkins, "The htm spatial pooler—a neocortical algorithm for online sparse distributed coding," *Frontiers in Computational Neuroscience*, vol. 11, 2017.
- [14] C. Barry and N. Burgess, "Neural mechanisms of self-location," *Current Biology*, vol. 24, no. 8, pp. R330–R339, 2014.
- [15] E. I. Moser, E. Kropff, M.-B. Moser, et al., "Place cells, grid cells, and the brain's spatial representation system," *Annual review of neuroscience*, vol. 31, no. 1, pp. 69–89, 2008.
- [16] N. Wagatsuma, T. Potjans, M. Diesmann, and T. Fukai, "Layer-dependent attentional processing by top-down signals in a visual cortical microcircuit model," *Frontiers in Computational Neuroscience*, vol. 5, 2011.
- [17] G. Rinkus, "A cortical sparse distributed coding model linking mini- and macrocolumn-scale functionality," *Frontiers in Neuroanatomy*, vol. 4, 2010.
- [18] N. Leadholm, M. Lewis, and S. Ahmad, "Grid cell path integration for movement-based visual object recognition," *arXiv preprint arXiv:2102.09076*, 2021.
- [19] S. Yoo, Y. Park, Z. Wang, Y. Wu, S. Medepalli, W. Thio, and W. D. Lu, "Columnar learning networks for multisensory spatiotemporal learning," *Advanced Intelligent Systems*, vol. 4, no. 11, p. 2200179, 2022.
- [20] T. Lin, Y. Wang, X. Liu, and X. Qiu, "A survey of transformers," *AI Open*, vol. 3, pp. 111–132, 2022.
- [21] A. Ierusalem, "Catastrophic importance of catastrophic forgetting," *arXiv preprint arXiv:1808.07049*, 2018.
- [22] M. De Lange, R. Aljundi, M. Masana, S. Parisot, X. Jia, A. Leonardis, G. Slabaugh, and T. Tuytelaars, "A continual learning survey: Defying forgetting in classification tasks," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 44, no. 7, pp. 3366–3385, 2022.

به کمک شبکه‌های عصبی ضربه‌ای باشد. در سال‌های اخیر مطالعات در حوزه محاسبات نورومورفیک، الگوریتم‌های محاسبات قشری، و الگوریتم‌های یادگیری در شبکه عصبی زیستی و مصنوعی در علوم اعصاب محاسباتی و انفورماتیک رشد بسزایی داشته است و روزبه‌روز محققان بیشتری جذب این مسیرهای مطالعاتی می‌شوند. شبکه‌های عصبی ضربه‌ای می‌توانند نقطه عطفی میان این مطالعات و هوش مصنوعی به‌شمار روند و اصول الگوریتمی و محاسباتی موجود در این شبکه‌ها، همانطور که در شبکه‌های یادگیرنده ستونی نیز به‌تصویر کشیده شد، بستری را برای پیاده‌سازی تمامی اصول نظریه هزاران مغز فراهم آورد. به علاوه، این شبکه‌ها ابزاری جهت مطالعه بهتر نوقشر و الگوریتم محاسبات قشری را در دسترس قرار می‌دهند. با این حال، هر فردی که یک بار با این شبکه‌ها کار کرده باشد، می‌داند که تنظیم پارامترهای این شبکه‌ها بسیار دشوار است و به همین دلیل، حتی شبکه یادگیرنده ستونی نیز در بخشی از مدل شرط ضربه‌ای بودن را ضعیف کرده و از روش رگرسیون بیشینه هموار و یادگیری باناظر به‌کمک روش گرادیان کاهشی بهره می‌گیرد [۱۹]. با این حال، انتظار می‌رود که محققان بیشتری در حوزه‌های علوم اعصاب محاسباتی و هوش مصنوعی دست در دست هم دهند و به کمک این گونه از شبکه‌های عصبی مصنوعی، نسل جدید سیستم‌های هوشمند در تعامل با انسان را توسعه دهند.

## مراجع

- [1] V. B. Mountcastle, "The columnar organization of the neocortex," *Brain*, vol. 120, pp. 701–722, 04 1997.
- [2] D. P. Buxhoeveden and M. F. Casanova, "The minicolumn hypothesis in neuroscience," *Brain*, vol. 125, pp. 935–951, 05 2002.
- [3] M. Lewis, S. Purdy, S. Ahmad, and J. Hawkins, "Locations in the neocortex: A theory of sensorimotor object recognition using cortical grid cells," *Frontiers in Neural Circuits*, vol. 13, 2019.
- [4] J. Hawkins, S. Ahmad, and Y. Cui, "A theory of how columns in the neocortex enable learning the structure of the world," *Frontiers in Neural Circuits*, vol. 11, 2017.
- [5] F. A. Mikulasch, L. Rudelt, M. Wibrall, and V. Priesemann, "Dendritic predictive coding: A theory of cortical computation with spiking neurons," *arXiv preprint arXiv:2205.05303*, 2022.