



Memristors from the Perspective of the Convergence of Nanotechnology, Biotechnology, Information Technology, and Cognitive Sciences

Zohreh Deljoo ✉

Corresponding Author, Department of Nanotechnology, Faculty of Strategic Sciences and Technologies, Qom university, Qom, Iran. E-mail: z.deljoo@gmail.com

Article Info	ABSTRACT
Article type Research Article	The convergence of nanotechnology, biotechnology, information technology, and cognitive sciences has led to the rapid advancement of artificial intelligence and machine learning technologies. In this regard, the demand for more advanced computing capabilities of devices has increased significantly. Neuromorphic computing has attracted increasing attention as an emerging computing paradigm. Inspired by the functioning of the human brain, this technology mimics the behavior of neurons and synapses to enable efficient and low-power computing. One of the keys to realizing neuromorphic computing is developing a reliable synaptic device that can modulate and maintain the connection between interconnected neurons. Implementing physical devices with synaptic characteristics is essential for building the hardware foundation for neuromorphic computing systems and is crucial for the advancement of this field. Memristors, as emerging memory devices, show remarkable efficiency in neuromorphic computing due to their low power consumption. Nanomaterials, due to their dimensional similarity to neurons and the ability to create complex circuits on a small chip, can improve the performance of memristors, including efficient resistive switching with fast response, increased storage density, and low power requirements. This article first introduces the concept and structure of memristors, and then the contribution of each of information technology, biotechnology, nanotechnology, and cognitive sciences in the creation and development of memristors is reviewed. Finally, existing challenges such as instability, variability, and scalability, and future research prospects, including bioinspired and quantum-enhanced neuromorphic systems, are discussed. In summary, this article reviews memristors from the perspective of the convergence of science and technology.
Article history Received: 15 March 2025 Revised: 17 April 2025 Accepted: 19 April 2025 Published: 30 April 2025	
Keywords Biomimetic Memristor NBIC Neuromorphic	

Cite this article: Deljoo, Z. (2025). Memristors from the perspective of the convergence of nanotechnology, biotechnology, information technology and cognitive sciences. *Mind and Technology*, 1(1), 23-42. <https://doi.org/10.22091/JMT.2025.14355.1010>



©The Author(s).

Publisher: University of Qom

DOI: <https://doi.org/10.22091/JMT.2025.14355.1010>



ممریستورها از منظر همگرایی نانوفناوری، زیست فناوری، فناوری اطلاعات و علوم شناختی

زهرة دلجو✉

نویسنده مسئول، گروه نانوفناوری، دانشکده علوم و فناوریهای راهبردی، دانشگاه قم، قم، ایران. رایانامه: z.deljoo@gmail.com

چکیده

رویکرد همگرایی فناوریهای نانو، زیست، اطلاعات و علوم شناختی منجر به پیشرفت سریع فناوریهای هوش مصنوعی و یادگیری ماشین شده است. در همین راستا تقاضا برای قابلیت‌های محاسباتی پیشرفته‌تر دستگاه‌ها به‌طور قابل توجهی افزایش یافته است. محاسبات نورومورفیک به‌عنوان الگوی محاسباتی نوظهور توجه فزاینده‌ای را به خود جلب کرده است. این فناوری که از عملکرد مغز انسان الهام گرفته، رفتار نورون‌ها و سیناپس‌ها را تقلید می‌کند تا محاسبات کارآمد و کم‌مصرف را امکان‌پذیر سازد. یکی از کلیدهای تحقق محاسبات نورومورفیک، ساخت دستگاه سیناپسی قابل اعتمادی است که بتواند ارتباط بین نورون‌های متصل به هم را مدوله و حفظ کند. پیاده‌سازی دستگاه‌های فیزیکی با ویژگی‌های سیناپسی، کلید ساخت زیرساخت ساخت‌افزایی برای سامانه‌های محاسباتی نورومورفیک بوده، برای پیشرفت این حوزه تعیین‌کننده است. ممریستورها به‌عنوان حافظه‌های نوظهور، به‌دلیل مصرف کم توان، کارایی بالایی در محاسبات نورومورفیک نشان می‌دهند. نانومواد به‌دلیل تشابه ابعادی با نورون‌ها و امکان ایجاد مدارهای پیچیده بر روی تراشه‌ای کوچک می‌توانند عملکرد ممریستور شامل سوئیچینگ مقاومتی کارآمد با پاسخ سریع، افزایش چگالی ذخیره‌سازی و نیاز به توان کم را بهبود بخشند. در این مقاله ابتدا مفهوم و ساختار ممریستورها معرفی می‌شود و در ادامه سهم هر کدام از فناوریهای اطلاعات، زیست، نانو و علوم شناختی در ایجاد و توسعه‌ی ممریستورها بررسی خواهد شد. در پایان چالش‌های موجود نظیر ناپایداری، تغییرپذیری و مقیاس‌پذیری، و چشم‌انداز آینده‌ی پژوهش شامل سامانه‌های نورومورفیک زیست‌الهام و تقویت‌شده با کوانتوم مورد بحث قرار خواهد گرفت. به‌طور خلاصه این مقاله ممریستورها را از منظر همگرایی علوم و فناوری‌ها بررسی می‌کند.

اطلاعات مقاله

نوع مقاله

پژوهشی

تاریخچه

دریافت: ۱۴۰۳/۱۲/۲۵

بازنگری: ۱۴۰۴/۰۱/۲۸

پذیرش: ۱۴۰۴/۰۱/۳۰

انتشار: ۱۴۰۴/۰۲/۱۰

کلیدواژه‌ها

زیست‌تقلید

علوم همگرا

ممریستور

نورومورفیک

استناد: دلجو، زهرة (۱۴۰۴). ممریستورها از منظر همگرایی نانوفناوری، زیست فناوری، فناوری اطلاعات و علوم شناختی. ذهن و فناوری، ۱(۱)، ۴۲-۲۳.

<https://doi.org/10.22091/JMT.2025.14355.1010>



© نویسندگان.

ناشر: دانشگاه قم

مقدمه

فناوری اطلاعات، زیست‌فناوری و نانوفناوری از آخرین ابتکارات بزرگ قرن بیستم هستند. فناوری اطلاعات زمینه را برای ایجاد و توسعه‌ی رایانه‌ها، تلفن‌های همراه و اینترنت فراهم کرد. پیشرفت‌های زیست‌فناوری لقاح آزمایشگاهی، غربالگری ژنتیکی، داروهای هدفمندتر و محصولات اصلاح‌شده ژنتیکی را ارائه داد. محققان نانوفناوری اتم‌های منفرد را دستکاری می‌کنند، مواد بهبودیافته را توسعه می‌دهند و هدفشان کوچک‌سازی تقریباً همه چیز است (Nordmann, 2004). اما پیشرفت یک‌بعدی این فناوری‌ها به نقطه‌ای رسید که برای پیشرفت سریع‌تر و بیشتر، دانشمندان را به فکر همگرایی و ترکیب علوم انداخت (William Sims Bainbridge, 2006). مفهوم فناوری‌های همگرا اولین بار در دسامبر ۲۰۰۱ در گزارشی با عنوان «فناوری‌های همگرا برای بهبود عملکرد انسان: نانوفناوری، زیست‌فناوری، فناوری اطلاعات و علوم شناختی» در کارگاهی مطرح شد که توسط بنیاد ملی علوم ایالات متحده و وزارت بازرگانی برگزار شده بود. در این گزارش، قرن ۲۱ آستانه‌ی رنسانسی جدید در علم و فناوری نامیده شد. مبنای این رنسانس، رسیدن به درکی جامع از ساختار و رفتار ماده از مقیاس نانو تا پیچیده‌ترین سامانه‌ی کشف‌شده تاکنون، یعنی مغز انسان، تعریف شد. طبق این گزارش، وحدت علم بر اساس وحدت در طبیعت و بررسی جامع آن، منجر به همگرایی فناوری و ساختار اجتماعی کارآمدتر برای دستیابی به هدف مشترک بهبود عملکرد انسان خواهد شد (Mihail C. Roco, 2002).

شاید بتوان گفت هوش مصنوعی مهم‌ترین محصول همگرایی فناوری‌ها است. علوم شناختی سازوکارهای نورونی مغز انسان را در بروز رفتارهای مختلف او توصیف می‌کند. فناوری اطلاعات الگوریتم‌هایی مشابه با این سازوکارها را طراحی و پیاده می‌کند. زیست‌فناوری با تبیین ساختارهای زیستی نرونها و سیناپس‌ها به تقلید مکانیکی از بافت‌های زنده انسانی کمک می‌کند و نانوفناوری با ایجاد ابزارهای مشاهده، دست‌کاری و ساخت مواد در مقیاس نانو آن سه فناوری و علم دیگر را یاری می‌کند. با رشد نمایی هوش مصنوعی و اهمیت پردازش کلان‌داده‌ها نیاز به توسعه‌ی ابزارهای سخت‌افزاری احساس می‌شود. در طول چند دهه گذشته، پیشرفت سخت‌افزار محاسباتی با افزایش مقیاس ترانزیستورهای سیلیکونی، که بلوک سازنده اساسی مدارهای مجتمع فعلی هستند، هدایت شده است. با این حال، این روند اخیراً با نزدیک شدن ترانزیستورها به محدودیت‌های فیزیکی خود، کند شده است. تقاضای رو به رشد برای قدرت محاسباتی، که توسط هوش مصنوعی و پیشرفت‌های تحلیلی کلان‌داده تقویت می‌شود، شکاف قابل‌توجهی بین عرضه و تقاضا ایجاد می‌کند. در نتیجه، بررسی الگوهای محاسباتی جدید که ریشه در دستگاه‌های غیرمتعارف دارند، بسیار مهم شده است (Jiang et al., 2025).


محاسبات نورومورفیک، با الهام از معماری مغز انسان، به‌عنوان راه‌حل امیدوارکننده برای توسعه دستگاه‌های محاسباتی و حافظه نسل بعدی با قدرت محاسباتی بی‌سابقه و مصرف انرژی به‌طور قابل‌توجهی کمتر، ظهور کرده است (Xie et al., 2024). یکی از مزایای اصلی محاسبات نورومورفیک، پذیرش معماری محاسبات درون‌حافظه‌ای است؛ معماری محاسباتی‌ای که در آن، عملیات داده مستقیماً در حافظه در دسترس هستند و نیاز به انتقال داده بین حافظه و واحدهای پردازش را از بین می‌برند (Xiao et al., 2024). تراشه‌های نورومورفیک مبتنی بر دستگاه‌های ممریستور به پیشرفت‌های قابل‌توجهی در کاربردهای مختلف هوش مصنوعی دست یافته‌اند. ممریستورها به‌عنوان لایه‌ی حافظه با چگالی فوق‌بالا، راه‌حلی ارائه می‌دهند که می‌تواند مستقیماً روی تراشه پردازنده ادغام شود و در نتیجه گلوگاه حافظه را به‌طور قابل‌توجهی کاهش داده و بازده انرژی و سرعت سامانه را بهبود بخشد (Zidan et al., 2018). بنابراین آن‌ها را می‌توان به‌عنوان واحد ایده‌آل برای محاسبات نورومورفیک در نظر گرفت (Gou et al., 2024).

در مقاله‌ی حاضر، ابتدا به تشریح ممریستورها می‌پردازیم و در ادامه نقش علوم شناختی، زیست‌فناوری، فناوری اطلاعات و نانوفناوری در ایجاد و توسعه‌ی ممریستورها و محاسبات نورومورفیک تشریح خواهد شد. نظریه‌ی هیبی در مورد چگونگی یادگیری و سازوکار حافظه‌ی کوتاه‌مدت و بلندمدت در بخش علوم شناختی، به‌عنوان مبنای ساختارها و الگوریتم‌های یادگیری

ماشین معرفی خواهد شد. در بخش زیست‌فناوری، ساختار و نحوه‌ی عملکرد سلول‌های عصبی مغز (نورون‌ها) و چگونگی ارتباط‌گیری با سیناپس‌ها، با هدف استفاده از ممریستورها به‌عنوان سیناپس‌های مصنوعی تبیین خواهد شد. در بخش فناوری اطلاعات، معماری فون‌نویمان و محدودیت‌های آن، که منجر به ظهور محاسبات نورومورفیک شده است، معرفی و در ادامه، نقش ممریستورها در شبکه‌های عصبی مصنوعی و تقلید سخت‌افزاری مغز در مقابل تقلید نرم‌افزاری صرف، بررسی خواهد شد. از آنجا که ممریستورها نانومقیاس هستند، در بخش نانوفناوری، روش‌های ساخت این تراشه‌ها و نانومواد مورد استفاده در آن‌ها دسته‌بندی خواهد شد. در نهایت، چالش‌های پیش‌روی ممریستورها عنوان شده و چشم‌انداز آینده‌ی این فناوری همگرا ترسیم خواهد شد.

ممریستور

مقاومت حافظه‌دار یا ممریستور، که امروزه به‌عنوان چهارمین عنصر مدارهای الکتریکی شناخته می‌شود، عنصری دویانه است که عملکردی شبیه مقاومت دارد و در ابعاد نانو ساخته می‌شود. بر طبق منحنی هیستریزیس آن می‌توان ثابت کرد که مقدار این مقاومت در طول زمان ثابت باقی می‌ماند و مقدار این مقاومت به مقدار، پلاریته و زمان ولتاژ اعمال بستگی دارد. منحنی هیستریزیس جریان-ولتاژ در ممریستور باعث می‌شود تا این عنصر بتواند به‌عنوان حافظه مقاومتی غیرفرار عمل کرده و اطلاعات را تا زمانی که ولتاژی با مقدار و پلاریته متفاوتی به آن اعمال شود، حتی تا یک سال بعد، به یاد آورد. ممریستور می‌تواند جایگزین بسیاری از ترانزیستورها در برخی از مدارات شده و جای کمتری اشغال کند (Salmanpour and Berahman, 2023). در نظریه مدار، سه قطعه اساسی دو پایه (مقاومت، خازن و سلف) به‌خوبی شناخته شده‌اند. این سه عنصر اساسی، رابطه بین دو مورد از چهار متغیر اساسی مدار را توصیف می‌کنند: جریان، ولتاژ، بار و شار، همان‌طور که در شکل ۱ نشان داده شده است. ترکیب ممکن بین این چهار متغیر اساسی مدار وجود دارد که پنج مورد از آن‌ها به خوبی تعریف شده‌اند، اما ششمی وجود ندارد. در سال ۱۹۷۱، پروفیسور لئون چوا این عنصر گمشده را «ممریستور» نامید؛ ترکیبی از مخفف حافظه^۱ و مقاومت^۲، که رابطه بین بار و شار را فراهم می‌کند. او همچنین مدل نظری ممریستور با مدارهای الکتریکی حاوی حداقل پانزده ترانزیستور و سایر عناصر غیرفعال را پیشنهاد کرد (Tripathi et al., 2014).



شکل ۱. روابط دویانه‌ی چهار متغیر اساسی مدار (Tripathi et al., 2014)

^۱. Memory

^۲. Resistor

به‌طور کلی، ممریستور را می‌توان به‌عنوان سامانه‌ای غیرخطی تعریف کرد که از طریق تغییر مقاومت بین دو حالت مقاومت بالا و حالت مقاومت پایین (سوئیچینگ مقاومتی)، با عبور دادن یا ندادن جریان الکتریکی، داده‌ها را ذخیره می‌کند. دستگاه‌های ممریستو برای عملکرد به ولتاژ خارجی نیاز دارند و جریان عبوری از دستگاه، وضعیت مقاومت آن را تعیین می‌کند. در دینامیک ممریستور، مصرف برق و سرعت سوئیچینگ از ملاحظات محوری هستند. سوئیچینگ سریع و کارآمد در کل محدوده مقاومت برای عملکرد بهینه ممریستور بسیار مهم است. دوام و ماندگاری داده‌ها دو پارامتر مهم دیگر ممریستور هستند که باید در نظر گرفته شوند. دوام نشان‌دهنده تعداد چرخه‌های خواندن و نوشتن است، در حالی که زمان ماندگاری، توانایی حفظ حالت‌های روشن و خاموش را نشان می‌دهد (Thakkar et al., 2024).

آزمایشگاه HP (هیولت پاکارد) در سال ۲۰۰۸ مدل فیزیکی موفق از نظریه‌ی ممریستور چوا را در دستگاهی نانومقیاس پیاده کرد. اولین ممریستور با TiO_2 به‌عنوان لایه فعال که بین دو الکترود پلاتین قرار گرفته بود، در سال ۲۰۰۸ ساخته شد. مقاومت ممریستور بر اساس رانش یون در لایه فعال TiO_2 توضیح داده شد (Tripathi et al., 2014). ساختار ممریستور و مواد سازنده آن می‌تواند منشأ سازوکارهای مختلفی برای تغییر مقاومت ممریستور باشند. مطالعات در زمینه‌ی استفاده از مواد جدید و ایجاد ساختارهای بهتر ممریستورها در جریان است (Chakraverty & Ramakrishnan, 2020; Hoch et al., 2025; Xiao et al., 2023). در ادامه به ساختار ممریستورها و انواع سازوکارهای تغییر مقاومت پرداخته می‌شود.

ساختار ممریستور

ممریستور عمدتاً دارای ساختار ساندویچی فلز-عایق-فلز^۱ (MIM) یا ساختار مسطح است که شامل دو لایه الکترود و یک لایه مقاومتی میانی است که از نیمه‌هادی یا عایق تشکیل شده است. الکترودهای ممریستور نه تنها جریان الکتریکی را حمل می‌کنند، بلکه ممکن است در واکنش مقاومتی نیز شرکت کنند. آن‌ها معمولاً از فلزات معمولی، فلزات نجیب، آلیاژها، مواد مبتنی بر کربن مانند گرافن و نانولوله‌های کربنی، نیتrideهایی مانند TiN و TaN ، اکسیدهای انعطاف‌پذیر رسانای شفاف مانند اکسیدقلع-ایندیوم (ITO) و ITO آلاینده‌شده، اکسیدقلع آلاینده‌شده با F (FTO) و غیره ساخته می‌شوند. مواد الکترود رایج را می‌توان با توجه به نقش متفاوت آن‌ها در رفتار، به سه نوع طبقه‌بندی کرد:


گروه نخست: الکترودهایی که غالباً به‌عنوان واسطه جریان استفاده می‌شوند و تقریباً هیچ تأثیری بر رفتار سوئیچینگ مقاومتی ندارند. چنین مواد الکترودی عمدتاً شامل فلزات بی‌اثر مانند Au و Pt هستند.

گروه دوم: الکترودهایی که مسئول تشکیل رشته‌های رسانا هستند و به ممریستورهای مبتنی بر مهاجرت کاتیون مربوط می‌شوند. در این ممریستورها، رشته‌های رسانا با انحلال الکتروشیمیایی و رسوب الکترودهای فلزی فعال از نظر شیمیایی، از جمله عمدتاً Cu و Ag تشکیل می‌شوند.

گروه سوم: برخی الکترودهای جدید مانند ITO ، FTO و گرافن که عموماً برای ساخت ممریستورهای انعطاف‌پذیر و شفاف استفاده می‌شوند.

در نهایت الکترودهای TiN و الکترودهای آلیاژی (مانند Cu-Te ، Hf-Ta ، Ag-Cu و غیره) نیز وجود دارند که برای تثبیت رفتار سوئیچینگ مقاومتی طراحی شده‌اند.

^۱. Metal-Insulator-Metal (MIM)



شکل ۲. ساختار ممریستور (Ali et al., 2021)

لایه‌ی مقاومتی مهم‌ترین بخش ممریستورها است. استفاده از مواد مختلف، ویژگی‌های مقاومتی متفاوتی به ممریستور می‌بخشد. مواد مورد استفاده در لایه‌ی مقاومتی را به‌طور کلی می‌توان به مواد معدنی و آلی طبقه‌بندی کرد. مواد معدنی (اکسیدهای دوتایی، پروسکایت‌ها، مواد دوبعدی و غیره) معمولاً رفتار سوئیچینگ مقاومتی پایدارتر، سریع‌تر و قوی‌تری از خود نشان می‌دهند، در حالی که مواد آلی از مزایای انعطاف‌پذیری بالا، روش آماده‌سازی ساده و هزینه کم برخوردارند. اکسیدهای دوتایی دارای ترکیب ساده، پایداری بالا، هزینه کم و فرایند آماده‌سازی ساده هستند. آن‌ها شامل HfO_x , ZnO_x , CuO_x , NiO_x , AlO_x , SiO_x , TiO_x , TaO_x , WO_x , ZrO_x , SnO_x و غیره هستند. به‌طور خاص، HfO_x و TaO_x به‌دلیل سرعت عملکرد زیر نانوثانیه و استقامت نهایی بیش از ۱۰۱۰ چرخه، اکسیدهای دوتایی پرکاربردتری هستند. در میان بسیاری از مواد مقاومتی، اکسیدهای دوتایی فراوان‌ترین هستند و عملکرد مقاومتی مطلوبی دارند. با این حال، حافظه‌های مرسوم مبتنی بر اکسیدهای دوتایی معمولاً مصرف انرژی بالایی دارند یا یکنواختی کمی دارند. برای حل این مشکل از چند لایه اکسید دوتایی آلاییده‌شده بر روی هم استفاده می‌شود.

پروسکایت‌ها موادی با ساختار ABX_3 هستند. آلایش جایگاه A با یون‌های فلزی با ظرفیت پایین باعث ایجاد جای خالی‌های (حفره) اکسیژن در ماده می‌شود. با آلایش جزئی جایگاه A و B با کاتیون‌هایی با ظرفیت یا شعاع مختلف، می‌توان به طیف گسترده‌ای از خواص فیزیکی و شیمیایی دست یافت. در این ساختار، گونه‌های رایج برای جایگاه A شامل FA^+ , MA^+ یا Cs^+ هستند؛ B معمولاً Pb^{2+} یا Sn^{2+} است و X می‌تواند کلرید، برومید یا یدید باشد. به‌دلیل خواص اپتوالکترونیکی جدید مانند رسانایی مخلوط یون و الکترون و واپاشی آهسته جریان نوری، پروسکایت‌ها مواد امیدوارکننده‌ای برای طراحی ممریستورهای نورومورفیک نسل بعدی هستند.

با توجه به هزینه پایین، قابلیت پردازش محلول، انعطاف‌پذیری و توانایی آماده‌سازی در مقیاس بزرگ، مواد آلی مانند مولکول‌های کوچک آلی SU-8، فتالوسیانین‌مس مونوکلرو (ClCuPc)، کمپلکس Ru از ۲- (فنیل‌آزو) پیریدین $(\text{PF}_6)_2[\text{Ru}^{\text{II}}(\text{L})_3]$ و پلیمرهای آلی PEDOT: PSS و فلوروپلیمر گزینه‌های مناسبی برای ممریستورهای انعطاف‌پذیر هستند. برخی از مواد آلی جدید مانند DNA و پروتئین‌های تخم‌مرغ، به‌دلیل زیست‌تخریب‌پذیری، زیست‌جذب‌پذیری، سازگاری با محیط‌زیست، زیست‌سازگاری، قابل کاشت بودن و ارزان بودن، توجه گسترده‌ای را به خود جلب کرده‌اند (Xiao et al., 2023).

مواد دوبعدی به‌دلیل ضخامت در مقیاس اتمی و همچنین خواص الکتریکی عالی و ویژگی‌های جدیدشان، مانند انعطاف‌پذیری و شفافیت، توجه گسترده‌ای را جلب کرده‌اند. دی‌سولفید تنگستن، دی‌سلنید مولیبدن، گرافن اکسید، گرافن اکسید کاهش‌یافته، نیتريدبور شش‌وجهی و مکسین برخی از مواد دوبعدی هستند که در تحقیقات مختلف استفاده شده‌اند (Bouzouita et al., 2024; Choi et al., 2025; Hoch et al., 2025; Teixeira et al., 2025). به‌دلیل نیروهای ضعیف واندروالسی بین لایه‌های مجاور، می‌توان یک یا چند لایه را از بلور دوبعدی حجیم جدا کرد. این ویژگی‌ها، مواد دوبعدی را به گزینه‌ای مناسب برای ساخت ممریستورها با ضخامت اتمی و خواص الکتریکی عالی، مانند انعطاف‌پذیری و شفافیت، تبدیل می‌کند. بر همین اساس، ممریستورهای دوبعدی در قالب ساختارهای عمودی و مسطح مورد بررسی قرار گرفته‌اند.

به منظور بهبود خواص الکتریکی، مغناطیسی و نوری مواد دوبعدی، برخی از محققان به دنبال آرایش برای تقویت ویژگی‌های عملکردی این مواد بوده‌اند. به‌طور کلی، ممریستورهای مبتنی بر مواد دوبعدی روی ویفرهای سیلیکونی یا زیرلایه‌های پلیمری ساخته می‌شوند، اما این زیرلایه‌ها نه ارزان هستند و نه زیست‌تخریب‌پذیر. در مقابل، کاغذ سلولزی به‌دلیل زیست‌تخریب‌پذیری خوب، هزینه کم، قابلیت بازیافت، سبکی و انعطاف‌پذیری مکانیکی، جایگزین مناسبی است (Xiao et al., 2023).

ممریستورهایی با ساختار آرایه‌ای متقاطع نیز وجود دارند. در این ساختار، سلول‌های حافظه در تقاطع خطوط الکترودهای عمود بر هم قرار می‌گیرند و این امکان را فراهم می‌کنند که چگالی ادغام بالاتری نسبت به پیکربندی تخت داشته باشند. آرایه‌های متقاطع قابلیت داشتن اندازه سلول‌های کوچک و در نتیجه چگالی ذخیره‌سازی بالا را دارند. با این حال، آرایه‌های متقاطع تحت تأثیر جریان‌های مسیریابی پنهان قرار دارند که داده‌های ذخیره‌شده را خراب کرده و می‌توانند منجر به خوانش‌های اشتباه شوند. برای رفع این مشکل، دستگاه‌های انتخابگر شامل دیودها یا ترانزیستورها به سلول‌های حافظه افزوده می‌شوند تا جریان‌های پنهان را کنترل کرده و قابلیت اطمینان آرایه را افزایش دهند.

در ساخت ممریستورهای سه‌بعدی، از فضای عمودی در هر سه بعد برای ایجاد آرایه‌های حافظه چندلایه استفاده می‌شود و با کاهش ابعاد، ظرفیت ذخیره‌سازی افزایش می‌یابد. پیاده‌سازی‌های آن به طور کلی به دو دسته تقسیم می‌شوند: حافظه‌های انباشته‌ای افقی و حافظه‌های سه‌بعدی عمودی که از نظر مقیاس‌پذیری و پیچیدگی ساخت با هم تفاوت دارند. حافظه‌های انباشته‌ای افقی معماری حافظه‌ای هستند که از چندین لایه دوبعدی ممریستور مسطح تشکیل شده‌اند که روی هم قرار گرفته‌اند. با وجود طراحی نوآورانه حافظه‌های سه‌بعدی افقی، برخی چالش‌های مهم فناوری گزارش شده است. یکی از مسائل مهم، پیچیدگی ساخت است. ساختار معمول آرایه متقاطع افقی، به‌صورت عمودی برای حافظه‌های عمودی سه‌بعدی توسعه یافته است. این ساختار ظرفیت ذخیره‌سازی بیشتری با اشغال فضای کم ارائه می‌دهد و نشان‌دهنده مقیاس‌پذیری هزینه‌ییت بالاتر نسبت به سایر ساختارهای متقاطع است و برای پیاده‌سازی شبکه‌های عصبی بسیار امیدوارکننده محسوب می‌شود (Bouzouita et al., 2025).

سازوکارهای عمل ممریستور

سازوکارهای سوئیچینگ در ممریستورها بسیار متنوع‌اند و وابسته به ماده فعال، ساختار دستگاه، نوع الکترودها و شرایط ساخت هستند. اما می‌توان آن‌ها را با توجه به نوع ماده‌ای استفاده‌شده در لایه‌ی مقاومتی میانی، به چند دسته کلی تقسیم کرد.

ممریستورهای مقاومتی که در آن‌ها اعمال ولتاژ باعث جابه‌جایی یون‌ها یا بارها شده و مسیر بسیار باریک (نانومتری) رسانایی را ایجاد می‌کند. این مسیر با تغییر ولتاژ از بین می‌رود (Xia et al., 2025). ممریستور مقاومتی شامل دو نوع اصلی است: حافظه فلزی‌سازی الکتروشیمیایی (ECM) و حافظه تغییر ظرفیت (VCM). دستگاه حافظه ECM معمولاً از الکترود فلز فعال (مثلاً Ag یا Cu)، لایه‌ی میانی و الکترود فلز بی‌اثر (مثلاً Pt یا Au) تشکیل شده است. سازوکار سوئیچینگ مقاومتی آن به تشکیل و پارگی رشته‌های رسانا در داخل لایه‌ی میانی متکی است. اتم‌های فلز فعال به یون‌ها اکسید می‌شوند و تحت ولتاژ تنظیم^۱ به لایه‌ی میانی مهاجرت می‌کنند. متعاقباً این یون‌ها در الکترود بی‌اثر به اتم‌ها کاهش می‌یابند و رشته‌های رسانای فلزی تشکیل می‌دهند که الکترودها را به هم متصل می‌کنند (شکل ۳A، سمت چپ). اعمال ولتاژ استراحت^۲ منجر به پارگی این رشته‌های رسانا به‌دلیل اکسایش مجدد اتم‌ها می‌شود (شکل ۳A، سمت راست).

VCM شامل دو دسته مجزا، رشته‌ای و بین‌سطحی است. دستگاه VCM رشته‌ای از دو الکترود داخلی و یک لایه‌ی میانی با جای خالی فراوان (مانند جای خالی اکسیژن یا گوگرد) تشکیل شده است. با اعمال ولتاژ تنظیم، جاهای خالی به سمت کاتد حرکت می‌کنند و رشته‌های رسانای خالی ایجاد می‌کنند. یون‌های مربوطه به سمت آند مهاجرت می‌کنند و مخزن یونی تشکیل

¹. Set


². Reset

می‌دهند (شکل ۳B، سمت چپ). اعمال ولتاژ استراحت باعث پارگی رشته‌های رسانای خالی به دلیل ترکیب مجدد جاهای خالی و یون‌ها می‌شود (شکل ۳B، سمت راست). در دستگاه VCM بین سطحی، لایه‌ی میانی از یک ناحیه با مقاومت کم که با یون‌ها (اغلب یون‌های اکسیژن) آلوده شده و ناحیه‌ی خالص با مقاومت بالا تشکیل شده است. سازوکار سوئیچینگ مقاومتی با حرکت سطح مشترک بین نواحی آلوده شده و خالص مرتبط است (شکل ۳C) (Xiao et al., 2024).

ممریستورهای تغییر فاز که در آن‌ها ماده‌ی استفاده شده در لایه‌ی میانی می‌تواند در اثر اعمال حرارت بین حالت‌های بلوری (رسانا) و آمورف (نارسانا) تغییر فاز دهد و سوئیچینگ مقاومتی را ایجاد کند.

در ممریستورهای مغناطیسی از مواد مغناطیسی غیرفرار و الکترونیک اسپینی برای ذخیره‌سازی استفاده می‌شود. این ممریستورها داده‌ها را از طریق اتصال تونلی مغناطیسی ذخیره می‌کند که از دو لایه ماده مغناطیسی و یک لایه عایق تشکیل شده است. یک لایه مغناطیسی ثابت است و جهت مغناطش لایه آزاد دیگر را می‌توان با جریان تغییر داد. حالت مقاومت اتصال تونلی نشان‌دهنده داده‌ها است؛ مقاومت کم مربوط به مغناطش موازی و مقاومت بالا مربوط به مغناطش غیرموازی است.

ممریستورهای فروالکتریک از ویژگی قطبش مواد فروالکتریک برای تنظیم حالت مقاومت دستگاه استفاده می‌کنند. مواد فروالکتریک دارای جهت قطبش برگشت‌پذیر هستند. هنگامی که میدان الکتریکی خارجی اعمال می‌شود، جهت قطبش مواد فروالکتریک می‌تواند تغییر کند و در نتیجه ارتفاع سد یا توزیع بار سطح مشترک تغییر می‌کند. این تغییر بر رفتار تونل‌زنی جریان و ویژگی‌های رسانایی تأثیر می‌گذارد و در نهایت به صورت حالت‌های مختلف مقاومتی ظاهر می‌شود (Xia et al., 2025).



شکل ۳. سازوکارهای سوئیچینگ مقاومتی ممریستورها، شامل (الف) حافظه فلزی سازی الکتروشیمیایی، (ب) حافظه تغییر ظرفیت رشته‌ای، (ج) حافظه تغییر ظرفیت بین سطحی، (د) حافظه دسترسی تصادفی تغییر فاز، (ه) اتصال تونلی فروالکتریک، و (و) اتصال تونلی مغناطیسی. TE، الکترود بالایی؛ BE، الکترود پایینی؛ FL، لایه فروالکتریک؛ IL، لایه عایق (Xiao et al., 2024).

علوم شناختی در ممریستورها

یادگیری هبی^۱ به عنوان یکی از بنیادی ترین اصول در علوم اعصاب، بیان می کند که «اتصالات بین نورون ها زمانی تقویت می شود که آن ها به صورت هم زمان فعال شوند». این اصل زیربنای پدیده ی «تقویت بلندمدت سیناپسی»^۲ است که به عنوان سازوکار سلولی حافظه و یادگیری شناخته می شود. انعطاف^۳ هبی در انسان را می توان از طریق تحریک دیداری مکرر و ثبت سیگنال های نوار مغزی به صورت غیرتهاجمی مشاهده کرد. در این مطالعات، تحریکات دیداری با فرکانس حدود ۹ هرتز سبب افزایش پایدار در دامنه ی پتانسیل های برانگیخته ی دیداری (VEPs) می شود که نشانه ای از تقویت سیناپسی در قشر بینایی است. یافته های حاصل از مدل سازی علی پویا^۴ نشان می دهد که القای LTP دیداری سبب افزایش اتصالات پیش رونده در مسیرهای بینایی (از نواحی پس سری به آهیانه و گیجگاهی) می شود، در حالی که اتصالات بازگشتی تغییر محسوسی ندارند. این پدیده با نظریه های مدرن «کدگذاری پیش بینانه»^۵ و «اصل انرژی آزاد»^۶ هم خوانی دارد که مغز را به عنوان سامانه ای پیش بینی کننده توصیف می کنند. در این چارچوب، یادگیری هبی نقش مکانیکی در تعدیل وزن های سیناپسی دارد و موجب می شود مدل های پیش بینی مغز به تدریج دقیق تر شوند. بنابراین، یادگیری هبی زیربنای فیزیولوژیک به روزرسانی مدل های ذهنی است و پیوندی میان سطح نورویولوژیک و سطح محاسباتی مغز برقرار می کند.

در حوزه ی فناوری، این سازوکار زیستی الهام بخش طراحی نسل جدیدی از سخت افزارها موسوم به محاسبات نورومورفیک شده است. در این سامانه ها، عناصر الکترونیکی مانند ممریستورها به عنوان همتای مصنوعی سیناپس عمل می کنند و توانایی تغییر مقاومت الکتریکی بر پایه ی سابقه ی تحریک را دارند. این رفتار دقیقاً مشابه قاعده ی هبی است: «نورون هایی که با هم فعال می شوند، با هم ارتباط قوی تری می سازند.» از این رو، ممریستورها می توانند تقویت یا تضعیف پیوندهای الکتریکی را همانند LTP و رکود بلندمدت سیناپسی^۷ در نورون های زیستی بازتولید کنند. در نتیجه، شبکه های ممریستوری قادرند یادگیری هم زمان، حافظه ی بلندمدت و تطبیق پذیری ادراکی را در سطح سخت افزار و بدون نیاز به الگوریتم های یادگیری مجزا پیاده سازی کنند. در واقع، یافته های نوار مغزی و مدل سازی DCM می توانند الگوهای بهینه ی تقویت و تضعیف سیناپسی را برای طراحی شبکه های سخت افزاری یادگیرنده در سطح نانومقیاس ارائه دهند. از این دیدگاه، نظریه ی هبی پلی میان علوم اعصاب، نانوفناوری و علوم رایانه ای است؛ پلی که می تواند منجر به توسعه ی سامانه هایی شود که مانند مغز انسان یاد می گیرند، تطبیق می یابند و انرژی بسیار کمی مصرف می کنند (Sumner et al., 2020).

زیست فناوری در ممریستورها

مغز انسان تقریباً از ۱۰۰ میلیارد نورون و کوادرلیون سیناپس تشکیل شده است و به عنوان یک سامانه محاسباتی کارآمد با حجم کم (حدود ۱/۵ لیتر) و مصرف برق بسیار کم (حدود ۲۰ وات) عمل می کند (Tripathi et al., 2014). نورون های مصنوعی با تقلید از نورون های زیستی ایجاد شده اند. نورون های زیستی قطعات سازنده ی شبکه ی عصبی زیستی هستند. نورون ها از طریق اتصالاتی به نام سیناپس به هم متصل می شوند (Weilenmann et al., 2024). هر سیناپس محل تماس میان دو نورون است و معمولاً از سه بخش تشکیل می شود:

۱. پایانه پیش سیناپسی: شامل وزیکول های حاوی ناقل عصبی است.
۲. شکاف سیناپسی: فاصله ی حدود ۲۰-۳۰ نانومتر میان دو نورون.

¹. Hebbian Learning

². Long-Term Potentiation (LTP)

³. Plasticity

⁴. Dynamic Causal Modelling (DCM)


⁵. Predictive Coding

⁶. Free Energy Principle

⁷. Long-Term Depression (LTD)

۳. غشای پس‌سیناپسی: دارای گیرنده‌های اختصاصی برای ناقل‌های عصبی است.

شکل ۴ طرحواره‌ای از نورون زیستی ساده‌شده را نشان می‌دهد (Zhang et al., 2019). در انتهای دندریت‌ها، ارتباطات سیناپسی از طریق چندین کانال بین نورون‌های مجاور اتفاق می‌افتد. هنگامی که پیام عصبی به پایانه‌ی پیش‌سیناپسی می‌رسد، باعث باز شدن کانال‌های کلسیمی وابسته به ولتاژ می‌شود. افزایش غلظت یون کلسیم در پایانه موجب هم‌جوشی وزیکول‌ها با غشای پیش‌سیناپسی می‌شود. مولکول‌هایی مانند گلوتامات، GABA، استیل‌کولین یا دوپامین به درون شکاف سیناپسی آزاد می‌شوند. ناقل‌ها به گیرنده‌های اختصاصی (مثلاً AMPA و NMDA برای گلوتامات) در غشای پس‌سیناپسی متصل می‌شوند. بسته به نوع گیرنده، جریان‌های یونی (Cl^- ، Ca^{2+} ، K^+ ، Na^+) ایجاد شده و نورون تحریک یا مهار می‌شود. در نهایت، ناقل‌های عصبی از طریق بازجذب، تجزیه‌ی آنزیمی یا انتشار از شکاف حذف می‌شوند (Kandel et al., 2014; Nicoll, 2017).



شکل ۴. ساختار نورون زیستی (Prakash et al., 2023)

شاخه‌های دندریتیک و خارهای روی آن می‌توانند سطح جسم سلولی نورون را برای دریافت تحریک گسترش دهند و همچنین کارایی انتقال اطلاعات را بهبود بخشند (Meng et al., 2024). نورون معمولاً دارای هزاران خار دندریتیک، جسم سلولی با ظرفیت غشایی تقریباً ۲۰۰ پیکوفاراد و آکسون میلین‌دار است که قادر به انتشار پتانسیل‌های عمل با سرعت ۱ تا ۱۲۰ متر بر ثانیه است. دندریت‌ها ورودی‌هایی از نورون‌های پیش‌سیناپسی دریافت می‌کنند. جسم سلولی مانند یک پردازشگر عمل کرده، این ورودی‌ها را ادغام می‌کند. با تغییر چگالی یونها در بدنه، پتانسیل غشای جسم سلولی تغییر می‌کند. زمانی که این پتانسیل از حد آستانه بیشتر شود از طریق یک پالس الکتریکی توسط آکسون تخلیه می‌شود (Wang et al., 2025). ورود پتانسیل عمل، منجر به فعال شدن کانال Ca^{2+} وابسته به ولتاژ می‌شود و ورود Ca^{2+} امکان آزادسازی انتقال‌دهنده عصبی را در انتهای نورون پیش‌سیناپسی فراهم می‌کند. دریافت انتقال‌دهنده عصبی در غشای پس‌سیناپسی می‌تواند تغییرات پتانسیلی را در غشا القا کند. پتانسیل عمل نورون در مغز انسان تنها حدود ۱۰۰ میلی‌ولت است که می‌تواند پاسخ سیگنال را تحریک کند. با این حال، بیشتر ولتاژهای عملیاتی گزارش‌شده بالاتر از پتانسیل عمل زیستی هستند که برای بهبود کارایی دستگاه مفید نیست. بنابراین، استفاده از الکترونیک برای تحقق پردازش اطلاعات بسیار کارآمد در سطح زیستی بسیار مهم است (Meng et al., 2024).


هر سیناپس سه عملکرد را انجام می‌دهد: (۱) ذخیره‌ی خازرات بلندمدت در وزن‌هایشان (W)، (۲) انتقال سیناپسی که به صورت ضرب وزن ورودی مدل‌سازی می‌شود، و (۳) انعطاف‌پذیری بلندمدت (به‌روزرسانی وزن) در طول آموزش. پیچیدگی سازوکارهای بیوفیزیکی در سیناپس‌ها و قوانین مربوط به انعطاف‌پذیری برای عملکرد سامانه عصبی ضروری هستند؛ اما در شبکه‌های عصبی مصنوعی مرسوم وجود ندارند. به همین دلیل سامانه‌های هوش مصنوعی اغلب در جنبه‌های مختلف، مانند مهارت‌های حرکتی و سازگاری با محیط‌های پویا، نسبت به انسان‌ها و حیوانات عملکرد ضعیف‌تری دارند. علاوه بر این، شبکه‌های عصبی مصنوعی

امروزی به دلیل اندازه بزرگ شبکه مورد نیاز برای وظایف پیچیده، مقادیر زیادی انرژی مصرف می کنند. به عنوان مثال، آموزش مدل زبان بزرگ GPT3، ۱/۲۸۷ گیگاوات ساعت انرژی الکتریکی مصرف می کند که برای تأمین انرژی بیش از ۱۰۰ خانوار به مدت یک سال کافی است (Weilenmann et al., 2024).


فناوری اطلاعات در ممریستورها

قانون مور پیش بینی کرده بود که تعداد ترانزیستورهای روی تراشه هر دو سال دو برابر می شود و عملکرد و پیچیدگی افزایش می یابد. با کوچک تر شدن فناوری تراشه، چالش های زیادی مانند اثرات کوانتومی، اثرات حرارتی، هزینه و مسائل مربوط به پیچیدگی به وجود آمد. در عین حال، با توسعه سریع هوش مصنوعی و اینترنت اشیا، الزامات بالاتری برای قابلیت های پردازش داده دستگاه ها مطرح شد. بنابراین معماری های محاسباتی مرسوم فون نویمان حتی با کوچک تر شدن تراشه ها نتوانستند از حداکثر سرعت و حافظه ی خود پیشی بگیرند و به اصطلاح با «دیوار سرعت»، «دیوار حافظه» و پایان قانون مور مواجه شدند. تلاش برای رفع این چالش ها زمینه ساز ظهور معماری محاسباتی نورومورفیک شد (شکل ۵) (Gou et al., 2024).

معماری فون نویمان، معماری پایه کامپیوترهای مدرن است که توسط ریاضیدان جان فون نویمان در سال ۱۹۴۵ پیشنهاد شد. ایده اصلی آن، ذخیره دستورالعمل های برنامه و داده ها در یک بخش حافظه و پردازش داده ها با خواندن و اجرای این دستورالعمل ها از طریق واحد پردازش مرکزی (CPU) است. به عبارت دیگر، معماری فون نویمان حافظه و محاسبات را از هم جدا می کند. مزیت اصلی این معماری در سازگاری و انعطاف پذیری آن نهفته است که به کامپیوتر اجازه می دهد وظایف مختلفی را با تغییر برنامه های ذخیره شده در حافظه خود انجام دهد. با این حال، ساختار فون نویمان دارای نقص های ذاتی خود است. اولین تنگنای این معماری، توان عملیاتی محدود گذرگاه داده بین حافظه و پردازنده است. در طول اجرای یک برنامه، گذرگاه داده عمدتاً با انتقال داده های پردازشی از/به حافظه دسترسی تصادفی (RAM) بارگذاری می شود. علاوه بر این، حداکثر توان عملیاتی گذرگاه داده بسیار کمتر از سرعتی است که پردازنده می تواند داده ها را پردازش کند. یکی دیگر از محدودیت های مهم، تفاوت زیاد در سرعت RAM و رجیسترهای پردازنده است. این موضوع می تواند باعث تأخیر و از کار افتادن پردازنده هنگام دریافت داده ها از حافظه شود. این پدیده به عنوان «گلوگاه فون نویمان» شناخته می شود. این رویکرد همچنین انرژی بر است. انرژی مورد نیاز برای عملیات جابه جایی داده ها در امتداد گذرگاه می تواند حدود ۱۰۰۰ برابر بیشتر از انرژی مورد نیاز برای عملیات محاسباتی باشد. به عنوان مثال، جمع دو عدد صحیح ۸ بیتی حدود ۰/۳ پیکوژول مصرف می کند، در حالی که خواندن از حافظه دسترسی تصادفی پویا (DRAM) حدود ۲/۶ نانوژول مصرف می کند (Ivanov et al., 2022; Xia et al., 2025). شکل ۶ طرحواره ی هر دو معماری را نشان می دهد.



شکل ۵. موانع پیش روی محاسبات فون نویمان (Zidan et al., 2018)



شکل ۶. معماری فون نویمان در مقابل معماری نورومورفیک (Prakash et al., 2023)

اصطلاح «نورومورفیک» توسط کارور مید^۱ در اواخر دهه ۱۹۸۰ ابداع شد. محاسبات نورومورفیک توانایی ایجاد انقلابی در نحوه طراحی و استفاده از سامانه‌های هوش مصنوعی را دارد. شبکه‌های عصبی مغز انسان توسط این سامانه‌ها که به‌عنوان رایانه‌های نورومورفیک نیز شناخته می‌شوند، تقلید می‌شوند. رایانه‌های نورومورفیک با بهره‌گیری از ظرفیت مغز برای پردازش موازی اطلاعات، مدیریت الگوهای پیچیده و سازگاری با محیط، به دنبال رفع برخی از معایب سامانه‌های محاسباتی مرسوم هستند (Prakash et al., 2023). پیاده‌سازی دستگاه‌های فیزیکی با ویژگی‌های سیناپسی، کلید ساخت پایه سخت‌افزاری برای سامانه‌های محاسباتی نورومورفیک است و برای پیشرفت این حوزه تعیین‌کننده است. در ابتدا، عملکرد سیناپس‌ها با استفاده از فناوری مکمل فلز-اکسید-نیمه‌رسانا (CMOS^۲) در مهندسی نورومورفیک شبیه‌سازی شد. با این حال، این مدارهای CMOS انرژی بسیار بیشتری نسبت به سیناپس‌های زیستی مصرف می‌کنند و مقیاس‌بندی اندازه مدار را به سطحی قابل مقایسه با مغز دشوار می‌سازد. در تحقیقات بعدی، با الهام از زیست‌شناسی، محققان حافظه سوئیچینگ مقاومتی، ممریستورها و سوئیچ‌های اتمی را در مدارهای نورومورفیک بررسی کرده‌اند و قوانین مهم یادگیری سیناپسی، مانند انعطاف‌پذیری وابسته به زمان‌بندی اسپایک (STDP) و انتقال از حافظه کوتاه‌مدت به حافظه بلندمدت را مطالعه کرده‌اند (Huang et al., 2025).

به این ترتیب، استفاده از ممریستورها در محاسبات نورومورفیک شبیه‌سازی مغز انسان را نه تنها در مرحله‌ی نرم‌افزاری و کدنویسی، بلکه در مرحله‌ی سخت‌افزاری محقق می‌کند (Huang et al., 2025). سامانه‌های نورومورفیک می‌توانند با شبیه‌سازی پردازش موازی و اتصال شبکه‌های مغزی، محاسبات با کارایی بالا را با استفاده از انرژی کمتری نسبت به رایانه‌های سنتی فون نویمان انجام دهند (Prakash et al., 2023).

نانوفناوری در ممریستورها

مقاومت ممریستور در دستگاه‌های نانومقیاس، که میدان‌های الکتریکی بالا می‌توانند حرکت یونی را القا کنند، بسیار قابل توجه‌تر است. از آنجایی که مقاومت ممریستور نیاز به تغییر مکان اتم‌ها تحت ولتاژ اعمال شده دارد، این امر در مقیاس نانو به راحتی قابل مشاهده است. در سال‌های اخیر، ساخت و توصیف ممریستورها به دلیل پیشرفت‌های بیش از حد در نانوفناوری، توجه دنیای تحقیقات را به خود جلب کرده است. هدف اصلی طراحان تراشه‌های الکترونیکی، افزایش عملکرد تراشه با قرار دادن تعداد بیشتری ترانزیستور روی یک مدار است. اما تراکم بالاتر ترانزیستورها، مشکل تولید گرما را افزایش می‌دهد و در نتیجه بر عملکرد دستگاه‌ها تأثیر می‌گذارد. این مشکل تولید گرما را می‌توان با استفاده از نانوفناوری و ساخت مدارهای هیبریدی با چگالی بالا و کارآمد از نظر انرژی که شامل ترانزیستورها و ممریستورها هستند، برطرف کرد (Tripathi et al., 2014). انتخاب بهترین فناوری ساخت برای مواد، کلید تعیین عملکرد ممریستور است. در حال حاضر، روش‌های ساخت که عمدتاً در مساحت بزرگ

^۱. Carver Mead

^۲. Complementary Metal-Oxide-Semiconductor

اعمال می‌شوند، تقریباً به دو دسته‌ی رسوب فیزیکی و رسوب شیمیایی تقسیم می‌شوند که هر کدام شامل روش‌های مختلفی هستند. به عنوان مثال، ساخت اکسیدهای فلزی بیشتر با پاشش و لایه‌نشانی اتمی انجام می‌شود. مواد دوبعدی بیشتر از رسوب بخار شیمیایی استفاده می‌کنند. در فرایند ساخت، الگوسازی و چاپ دوبعدی/سه‌بعدی، انعطاف‌پذیری طراحی بهتری فراهم می‌شود. نانوفناوری علاوه بر روش ساخت، در معرفی نانومواد مختلف صفربعدی، یک‌بعدی و دوبعدی نیز می‌تواند در خدمت فناوری ممریستورها باشد. در ادامه، ضمن معرفی هر کدام از روش‌های سنتز، تأثیر آن روش بر روی مواد، مانند بلورینگی، نقص‌ها، ریزساختار و غیره، مورد بحث قرار خواهد گرفت و سپس به انواع نانومواد مورد استفاده در ساختمان ممریستورها اشاره خواهد شد.

رسوب بخار شیمیایی

رسوب بخار شیمیایی (CVD) فناوری‌ای است که از مواد گازی یا بخار برای واکنش شیمیایی روی یک سطح جامد استفاده می‌کند تا رسوبات جامد را در شرایط دما و فشار خاص تولید کند. این روش نقش مهمی در علم و تولید مواد نوین ایفا می‌کند و امکان کنترل دقیق ترکیب، ساختار و ضخامت فیلم را فراهم می‌کند که منجر به خواص الکتریکی، شیمیایی و مکانیکی خاص می‌شود. محققان از CVD برای ساخت یک لایه منفرد سولفید مولیبدن (MoS_2) استفاده کردند. سولفید مولیبدن تک‌لایه، به عنوان ماده‌ای با گاف انرژی مستقیم، مشخصه پاسخ نوری حساس تر و حالت روشن/خاموش و قابلیت تنظیم بهتر در دستگاه‌ها را نشان می‌دهد. علاوه بر این، CVD به طور گسترده در ساخت فیلم‌های با مساحت بزرگ به کار گرفته شده است. یو و همکارانش از CVD برای رشد آرایه‌های ممریستور لایه‌ای دوبعدی با مساحت بزرگ استفاده کردند که یکنواختی فوق‌العاده با نسبت سوئیچینگ متوسط 10^4 و دوام حافظه بیش از ۸۰۰۰ چرخه دارد. علاوه بر این، محققان با ترکیب فناوری کندوپاش و CVD، آرایه 4×4 متقاطع ساختند که دوام آن تا ۵۰۰ چرخه و زمان نگهداری تا 10^4 ثانیه است. حالت مقاومت بسیار همگن است که نشان‌دهنده توانایی قابل توجه برای ساخت ممریستور بر اساس فناوری رسوب بخار شیمیایی است. انواع CVD شامل: رسوب بخار شیمیایی با فشار کم (LPCVD)، رسوب بخار شیمیایی با فشار اتمسفر (APCVD) و رسوب بخار شیمیایی با پلاسما (PECVD) هستند. فناوری PECVD با فعال‌سازی پلاسما، سرعت واکنش سطحی و دمای رسوب لایه‌ها را کاهش می‌دهد و باعث رسوب یکنواخت‌تر و با کیفیت بالا می‌شود. محققان از فناوری رسوب بخار شیمیایی بهبودیافته با پلاسما برای سنتز لایه‌های ۷ تا ۱۰ نانومتری MoS_2 استفاده کردند. فعال‌سازی پلاسما می‌تواند فعالیت مواد واکنش فاز گازی را افزایش دهد، سرعت واکنش سطحی را افزایش دهد و دمای رسوب لایه‌های نازک را توسط یون‌های پرانرژی به طور قابل توجهی کاهش دهد. این امر امکان رسوب فیلم یکنواخت‌تر و با کیفیت بالا را فراهم می‌کند. علاوه بر این، بلورینگی و خواص الکتریکی دی‌سولفیدمولیبدن با استفاده از PECVD و APCVD همراه با دو فرایند آنیل، افزایش داده شده است. در مقابل PECVD، استفاده از رسوب بخار شیمیایی به کمک نمک برای تهیه نانوصفحات WSe_2 لایه‌ای دوبعدی، پیشنهاد شده است. این امر مقیاس‌پذیری خوب فناوری رسوب بخار شیمیایی را نشان می‌دهد. علاوه بر این، روش رسوب بخار اتمیزه شده، معرفی شده است. الکتروالومینیوم در فرایند رسوب بخار شیمیایی غبار روغن اکسید می‌شود و لایه AlO_x روی سطح فیلم پایانه‌ی پایینی تشکیل می‌شود. لایه AlO_x مانع از رانش و انتشار یون‌های اکسیژن و پایداری مقاومت می‌شود. قطعات لایه نازک آمورف Sn-Ga-O (a-TGO) که از طریق CVD دیواره داغ رسوب داده می‌شوند، می‌توانند در سطح وسیع و در دمای پایین تولید شوند و چشم‌اندازهای جدیدی را برای آماده‌سازی دستگاه‌های با عملکرد بالا در آینده فراهم کنند.

لایه‌نشانی اتمی

لایه‌نشانی اتمی (ALD) روش رسوب لایه‌های فوق نازک است که مواد را لایه‌به‌لایه از طریق واکنش شیمیایی با پیش‌سازهای متناوب فاز بخار روی سطح زیرلایه رسوب می‌دهد. چون در روش لایه‌نشانی اتمی رسوب لایه‌به‌لایه مواد انجام می‌شود، می‌توان با این روش به ساخت دستگاه کوچک‌تر و یکپارچه‌سازی با چگالی بالا دست یافت. محققان از رسوب لایه اتمی برای ساخت ممریستور MoS_2 با مقاومت خطی بالا استفاده کردند. لایه آمورف MoS_2 می‌تواند از طریق کنترل در مقیاس اتمی و

عملیات آنیل به لایه پلی کریستالی تبدیل شود. این دستگاه می‌تواند از وابستگی مرزهای دانه تصادفی جلوگیری کند. محققان نانوذرات پلاتین را بین لایه‌های سوئیچینگ اکسید آلومینیوم هافنیوم (HfAlO_x) رسوب دادند. این امر منجر به بهبود قابل توجهی در ویژگی‌های تعدیل رسانایی، مانند وابستگی به فرکانس و دامنه، می‌شود. علاوه بر این، برای مواد حساس به گرما مانند پلاستیک‌ها و پلیمرها، عملکرد دستگاه می‌تواند تحت تأثیر انتشار حرارتی در طول فرایند آماده‌سازی قرار گیرد. رسوب لایه اتمی در دمای پایین می‌تواند بدون ایجاد ترک، نقص یا سوراخ‌های ریز از این مشکل جلوگیری کند. علاوه بر این، لایه‌نشانی اتمی مزایای زیادی در رسوب ساختار سه‌بعدی دارد، مانند نرخ پوشش پله‌ای بهتر، گزینش‌پذیری منطقه‌ای و بودجه حرارتی پایین. محققان سامانه‌ی هوش مصنوعی با قابلیت‌های ادغام اطلاعات و محاسبات کارآمد با استفاده از لایه‌نشانی اتمی در دمای پایین، و فرایند رسوب آن توسعه دادند. آرایه سه‌بعدی متقاطع دارای عملکرد انتقال اطلاعات چندمرحله‌ای است. در همان سال، آرایه‌ی ممریستور انعطاف‌پذیر سه‌بعدی با رسوب لایه اتمی در دمای پایین توسعه داده شد. این دستگاه به ذخیره‌سازی چندبیتی دست می‌یابد و زمان ماندگاری طولانی دارد. در مقایسه با ساختار سنتی، وضعیت مقاومت شبکه ممریستور با چیدمان عمودی، افزایش نمایی را نشان می‌دهد. این امر اهمیت لایه‌نشانی اتمی را برای چیدمان دستگاه‌های سه‌بعدی اثبات می‌کند.

کندوپاش

کندوپاش در دسته‌ی روش‌های رسوب فیزیکی بخار (PVD) قرار دارد و از ذرات پرنرژی (معمولاً یون‌های آرگون) برای بمباران ماده هدف در محیط خلأ و رسوب لایه نازک استفاده می‌کند. این روش دارای ویژگی‌های سرعت بالا، دمای پایین و آسیب کم به لایه است. در ممریستورهای مبتنی بر اکسیدها، کنترل غلظت حفرات اکسیژن برای عملکرد دستگاه بسیار مهم است. محققان ممریستور مبتنی بر ZnO را با استفاده از کندوپاش فرکانس رادیویی تهیه کرده‌اند. از طریق میکروسکوپ الکترونی عبوری (TEM) با وضوح بالا، تشکیل نواقص مربوط به حفرات اکسیژن در ZnO پلی کریستالی در طول واکنش Zn و O_2 مشاهده شد که تأیید کرد حفرات اکسیژن مستقیماً در فرایند تشکیل رشته‌های رسانا نقش دارد. همچنین تأثیر توان فرکانس رادیویی و درجه خلأ در طول کندوپاش بر عملکرد ممریستور ZnO بررسی شده است. غلظت حفرات اکسیژن در توان بالا کم است و دستگاه ویژگی‌های مقاومتی و یکنواختی عالی را نشان می‌دهد. با کاهش توان فرکانس رادیویی، رفتار سوئیچینگ ضعیف می‌شود و ممکن است دستگاه را از کار بیندازد. با این حال، در خلأ بالا، غلظت حفرات اکسیژن تمایل به کاهش دارد و دستگاه‌ها دارای ویژگی‌های ذخیره‌سازی WORM (یک بار بنویس، چند بار بخوان) هستند. در خلأ بالاتر، غلظت جای خالی اکسیژن افزایش می‌یابد. دستگاه‌ها ویژگی‌های سوئیچینگ تکرارپذیر و قابلیت ذخیره‌سازی قابل توجهی را در فرایند رسوب‌گذاری فشار پایین نشان می‌دهند. علاوه بر این، غلظت حفرات اکسیژن را می‌توان با عملیات پلاسما در طول کندوپاش نیز بهبود بخشید. انرژی پلاسما به ناحیه اطراف منتقل می‌شود و تعامل بین پلاسما و ماده هدف را تسهیل می‌کند. بنابراین، کیفیت کندوپاش لایه نازک افزایش می‌یابد. محققان غلظت حفرات اکسیژن را از طریق پلاسمای اکسیژن کنترل کردند. با ورود اکسیژن در طول کندوپاش، حفره‌ی اکسیژن در لایه‌های نازک اکسید روی ایندیوم گالیوم (IGZO) به‌طور قابل توجهی کاهش می‌یابد و ممریستور در طول تشکیل رشته‌های رسانا پایداری بهتری نشان داد. در عین حال، برخی از محققان روش‌های جدید کندوپاش، مانند فرایند کندوپاش هم‌زمان مغناطیسی و کندوپاش پرتو یونی دوگانه را پیشنهاد کرده‌اند که بینش‌های جدیدی را برای ساخت دستگاه‌های با کارایی بالا در آینده ارائه می‌دهد.

چاپ دوبعدی/سه‌بعدی

فناوری چاپ دوبعدی/سه‌بعدی امکان آماده‌سازی ساده، یکنواخت و سریع مواد را فراهم می‌کند و از آسیب دمایی به مواد و زیرلایه‌های انعطاف‌پذیر جلوگیری کند. در مقایسه با روش‌های پیچیده رسوب خلأ یا لیتوگرافی، فناوری چاپ دوبعدی/سه‌بعدی آسان‌تر عمل می‌کند. در حال حاضر، با توجه به ابعاد مواد، چاپ دوبعدی/سه‌بعدی مانند پوشش‌دهی چرخشی، ریخته‌گری قطره‌ای و چاپ سه‌بعدی به‌طور گسترده در ساخت دستگاه‌ها استفاده می‌شود. عملکرد آن ساده است و فیلم را می‌توان تحت فشار معمولی و شرایط دمای اتاق تهیه کرد. آرایه‌ی ممریستور Pt/Cu/Pt با استفاده از پوشش‌دهی چرخشی و حکاکی لیزری

ساخته شد. دستگاه‌های سیناپسی جدید عملکرد قابل اعتمادی را در سرعت سوئیچینگ و محاسبات ماتریس ارائه می‌دهند. به‌منظور افزایش بیشتر یکنواختی و بلورینگی فیلم، محققان این دستگاه را با پوشش‌دهی چرخشی ساختند. با کنترل سرعت چرخش، می‌توان لایه‌ای با کیفیت بالاتر و یکنواخت ساخت. همچنین روش ریخته‌گری داغ پویا^۱ برای افزایش بلورینگی ماده پیشنهاد شد. در طول فرایند چرخش، پیش‌ساز پروسکایت داغ به‌صورت قطره‌ای روی زیرلایه گرم‌شده ریخته می‌شود که باعث تسریع تبخیر حلال می‌شود و دانه‌های یکنواخت و بدون سوراخ با بلورینگی برجسته تشکیل می‌دهد. علاوه‌براین، ماده‌ی فراوری‌شده با محلول دارای انعطاف‌پذیری خاصی است. محققان روش خودآرایی به کمک ماده‌ی سطح‌فعال را برای ساخت ورق تک‌کریستالی مبتنی بر متیل‌آمونوم سرب‌برومید (MAPbBr_3) گزارش کردند. ضخامت و اندازه ورق را می‌توان با این روش تنظیم کرد و دستگاه دارای جریان کاری بسیار پایینی است. این روش طرحی جدید برای دستگاه‌های سیناپسی آینده در محاسبات نورومورفیک ارائه می‌دهد. با این حال، پوشش‌دهی چرخشی در ساخت فیلم‌های الگودار محدودیت دارد. فناوری چاپ سه‌بعدی مزایای متمایزی در الگوسازی فیلم نازک، مانند چاپ جوهرافشان، چاپ ایروسل، چاپ الکتروهایدرودینامیک (EHD)، چاپ توری و چاپ دوگانه دارد. در فرایند چاپ، غلظت محلول عامل حیاتی برای عملکرد دستگاه است. محققان با کنترل غلظت محلول چاپ توری، به پروسکایت‌های دوبعدی با لایه‌های مختلف دست یافته‌اند. علاوه بر این، فناوری چاپ سه‌بعدی امکان ساخت کامل دستگاه مبتنی بر چاپ را از الکتروتود تا کانال فراهم می‌کند و در نتیجه پیچیدگی پردازش را به‌طور قابل‌توجهی کاهش می‌دهد. چاپ الکتروهایدرودینامیک می‌تواند ضخامت و الگوی رسوب نانوسیم را به‌طور دقیق کنترل کند. با تنظیم دلخواه جهت و موقعیت تراز، چاپ دقیق الگو حاصل می‌شود و عملکرد دستگاه در حین تحقق چاپ الگودار تضمین می‌شود. به‌طور مشابه، کیفیت رسوب فیلم با کنترل محیطی که در آن آماده می‌شود تضمین می‌شود؛ مانند چاپ ایروسل جت در دمای پایین و چاپ جوهرافشان در دمای پایین با آنیل حرارتی و عملیات پرتودهی فرابنفش. این روش راه جدیدی را برای آماده‌سازی دستگاه‌ها باز می‌کند. همچنین متغیرهای فرایند، سامانه‌ها، مواد و سایر الزامات برای تولید افزایشی در ساخت ممریستور بررسی شده است (Gou et al., 2024).

انواع نانومواد در ممریستورها

نانومواد صفربعدی

نانومواد کربنی صفربعدی مانند نانونقاط کربنی، نقاط کوانتومی گرافن و فولرن‌ها از طریق تولید رشته‌های رسانای جهت‌دار به رشد لایه‌ی عملکردی ممریستور کمک می‌کنند. علاوه بر این، ثابت شده است که نانوذرات فلزی مانند مس (Cu) و نقره (Ag) تأثیر مهمی بر سوئیچینگ ممریستور با ولتاژ متناوب زیر ۴ میلی‌ولت دارند که تغییرپذیری بسیار کمی را نشان می‌دهد.

نانومواد تک‌بعدی

به‌دلیل اندازه نانومقیاس، انتقال منحصربه‌فرد و رسانایی الکتریکی بالا در ولتاژ پایین، به‌طور گسترده در ممریستورها استفاده می‌شوند. به‌عنوان مثال، نانومواد کربنی تک‌بعدی به‌دلیل پایداری دستگاه و قابلیت تنظیم وزن، کاندیداهای خوبی برای توسعه ممریستورهای با عملکرد بالا هستند. علاوه بر این، نانوسیم‌ها و نانومیله‌های اکسیدفلزی، مانند اکسیدروی (ZnO)، دی‌اکسیدتیتانیوم (TiO_2)، اکسیدنیکل (NiO) و تری‌اکسیدتنگستن (WO_3) در ممریستورها برای بهبود نسبت حجم به سطح و مقیاس‌پذیری به کار می‌روند؛ زیرا قابلیت خودآرایی از پایین به بالای آن‌ها کنترل دقیق ابعاد را تضمین می‌کند. حافظه‌ی ممریستوری تک‌بعدی مبتنی بر Ni/NiO/HfO_2 با دوام ۲۰۰ چرخه، زمان ماندگاری تا 10^7 ثانیه، نسبت روشن/خاموش نزدیک به 10^4 و حداکثر ولتاژ تنظیم/استراحت به‌ترتیب برابر با ۳ ولت و ۲ ولت گزارش شده است.

نانومواد دوبعدی

^۱. Dynamic Hot Casting

نانومواد دوبعدی به خاطر ساختارهای فوق‌العاده نازک، انعطاف‌پذیر و لایه‌ای خود شناخته شده‌اند. نیمه‌رساناهای TMD دوبعدی مانند دی‌سولفید تنگستن (WS_2) و دی‌سلنید مولیبدن ($MoSe_2$) مقیاس‌پذیری و یکپارچگی بالایی از خود نشان می‌دهند. بنابراین، از آن‌ها برای ممریستورهای با چگالی بالا و مصرف توان کم استفاده می‌شود. اکسیدگرافن دوبعدی (GO)، اکسیدگرافن کاهش‌یافته (rGO) و نیتريدبور شش‌ضلعی (h-BN)، که گرافن سفید نیز نامیده می‌شود، کاربرد بالقوه‌ای برای ممریستورهای کارآمد نشان می‌دهند. منشأ رفتار ممریستوری در این مواد، ساختار جایگزین رشته‌رسانای آغاز شده توسط جای خالی است. در سال ۲۰۲۳، محققان ممریستور را بر اساس لایه‌ی نازک اکسیدپروسیکایت استرانسیم‌تیتانات ($SrTiO_3$) مدل‌سازی کردند که به ترتیب ولتاژ تنظیم‌شده و استقامت ۲ ولت و ۱۰۰ چرخه را نشان داد. نانومواد دوبعدی که به‌صورت عمودی چیده شده‌اند می‌توانند عملکرد ممریستورها را افزایش دهند زیرا یکنواختی و سوئیچینگ مقاومتری متمایز را تضمین می‌کنند (Bouzouita et al., 2025).

چالش‌ها و چشم‌انداز ممریستورها

با وجود پیشرفت‌های قابل‌توجه در جنبه‌های مختلف، سامانه‌های نورومورفیک مبتنی بر ممریستور هنوز با چالش‌های متعددی برای استقرار در مقیاس بزرگ مواجه هستند؛ مانند تغییرپذیری قابل‌توجه دستگاه، استقامت محدود و رفتارهای سوئیچینگ تصادفی، که همه آن‌ها ممکن است دقت محاسباتی و مقیاس‌پذیری را به خطر بیندازند. علاوه بر این، الگوریتم‌های یادگیری کارآمد که ویژگی‌های غیر ایده‌آل ممریستورها را در نظر بگیرند، هنوز در حال توسعه هستند. تلاش‌های مداوم شامل محاسبات تقریبی، طراحی ترکیبی CMOS-ممریستور و بهینه‌سازی الگوریتم‌ها و سخت‌افزار، با هدف غلبه بر این موانع و سرعت‌بخشیدن به کاربردهای عملی، ادامه دارد. با وجود این پیشرفت‌ها، چالش‌های قابل‌توجهی همچنان باقی هستند؛ به‌ویژه پرداختن به تغییرپذیری دستگاه‌ها، افزایش استقامت سوئیچینگ و کاهش پراکندگی زمان‌بندی در آرایه‌های مقیاس بزرگ. این محدودیت‌ها به‌صورت آستانه‌های متناقض، مسائل مربوط به نگهداری و خطاهای زمان‌بندی ظاهر می‌شوند که می‌توانند دقت زمانی در شبکه‌های جرقه‌ای را کاهش دهند. در پیکربندی‌های متقاطع، جریان‌های مسیر پنهان و اختلالات خواندن/نوشتن، پایداری بلندمدت و بهره‌وری انرژی را مختل می‌کنند. پرداختن به این محدودیت‌ها نیازمند راهبرد بهینه‌سازی چندسطحی است؛ از جمله نوآوری در مواد (مانند، اکسیدهای آلاییده و ساختارهای ناهمگن دوبعدی)، ادغام انتخاب‌گر، جبران سطح مدار و الگوریتم‌های آموزشی مقاوم در برابر نقص‌های سخت‌افزاری. پروتکل‌های معیارسنجی استاندارد و مدل‌سازی آماری سینتیک سوئیچینگ نیز برای استقرار مقیاس بزرگ حیاتی هستند. برای پیشرفت به سمت پیاده‌سازی عملی، کارهای آینده باید به بررسی مواد جدید و روش‌های ساخت پیشرفته برای کاهش تغییرپذیری دستگاه و افزایش پایداری چرخه برای ادغام در مقیاس بزرگ بپردازند. رویکردهای طراحی مشترک که فیزیک دستگاه، طراحی مدار و الگوریتم‌های شبکه را همسو می‌کنند، برای دستیابی به عملکرد تطبیقی و آبی در سکوه‌های نورومورفیک ضروری خواهند بود. با تلاقی محاسبات نورومورفیک با حوزه‌های نوظهور مانند رباتیک هوشمند، رابط‌های مغز-ماشین و مراقبت‌های بهداشتی شخصی، تقاضا برای تأخیر کم، استحکام محیطی و قابلیت‌های یادگیری درون-دستگاه تشدید خواهد شد. سامانه‌های نورومورفیک مبتنی بر ممریستور، با شکل فشرده و دینامیک زیستی قابل‌قبول خود، می‌توانند به‌عنوان زیرساخت سخت‌افزاری بنیادی برای الکترونیک شناختی نسل بعدی عمل کنند (Wang et al., 2025).

توسعه سخت‌افزار و عملکرد آنالوگ

شبیه‌سازی دقیق شبکه‌ی عصبی زیستی، مهم‌ترین چالش محاسبات نورومورفیک است که خود را در تطابق هرچه بیشتر اجزای سخت‌افزاری شبکه‌ی عصبی مصنوعی نشان می‌دهد. سوئیچینگ مقاومتری ممریستورها می‌تواند از حالت روشن/خاموش به حالت آنالوگ (حالت ذخیره‌سازی چندسطحی قابل‌تنظیم) که دربردارنده‌ی طیفی از مقاومت به‌جای فقط دو حالت صفر و یکی است، تبدیل شود. دستگاه‌های آنالوگ سطوح بالای دقت وزنی را فراهم می‌کنند، اما نسبت روشن/خاموش آن‌ها نسبتاً کم است و تشخیص حالت‌های مقاومت مختلف را چالش‌برانگیز می‌کند. تلاش‌هایی در این زمینه انجام شده ولی هنوز مشکلاتی بر سر راه عملکرد دقیق ممریستورهای آنالوگ وجود دارد. معیارهای عملکرد ممریستورها، به‌اندازه‌ی کافی مورد توجه قرار نگرفته است.

به عنوان مثال، مصرف انرژی عملیات خواندن در دستگاه‌های ممریستيو، بازده انرژی تراشه‌های نورومورفیک را در طول مرحله استنتاج تعیین می‌کند. علاوه بر این، عواملی مانند تغییرپذیری و ویژگی‌های تغییر مقاومت در دستگاه‌های ممریستيو برای بازده آموزش تراشه‌های نورومورفیک حیاتی هستند. اگرچه کاهش اندازه‌ی دستگاه‌های ممریستيو باعث افزایش چگالی تراشه می‌شود اما پایداری آن‌ها را کاهش می‌دهد. در نتیجه، در طراحی دستگاه‌های ممریستيو، رویکرد جامعی برای متعادل کردن مؤثر معیارهای عملکرد آن‌ها مورد نیاز است.

آرایه‌های نوظهور و شبکه‌های نانوسیم

علاوه بر ساختار میله‌ای متقاطع مرسوم، پیکربندی‌های آرایه‌ای نوظهوری مانند شبکه‌های نانوسیم نیز به وجود آمده‌اند که نیاز به توجه مداوم دارند. پدیده‌هایی مانند تداخل بین دستگاه‌های منفرد، که معمولاً به عنوان منشأ ناخواسته‌ی جریان‌های پنهان در پیکربندی متداول آرایه‌ی متقاطع هستند، اجزای ضروری برای دینامیک ممریستوری در شبکه‌های نانوسیم به شمار می‌روند. این ویژگی منحصربه‌فرد شبکه‌های نانوسیم، چالش‌ها و فرصت‌هایی را برای نوآوری در زمینه محاسبات نورومورفیک ارائه می‌دهد. قوانین یادگیری الهام گرفته از زیست‌شناسی هنوز در مراحل اولیه توسعه هستند. علاوه بر این، کمبود مجموعه داده‌های تخصصی نورومورفیک متناسب با شبکه‌های عصبی مصنوعی وجود دارد. علاوه بر این، بهینه‌سازی مدارهای جانبی برای افزایش عملکرد کلی تراشه‌های نورومورفیک بسیار مهم است. برای بهینه‌سازی مؤثر مدارهای جانبی، توسعه طرح‌های مسیریابی با توان عملیاتی بالا برای انتقال کارآمد داده‌ها در تراشه‌ها ضروری است (Xiao et al., 2024).

مواد و فناوری‌های آینده

توسعه مواد جدید همچنان کلید بهبود عملکرد ممریستورها است. محققان در حال بررسی مواد دوبعدی مانند گرافن و دی‌کالکوژنیدهای فلزات واسطه هستند که خواص الکتریکی منحصربه‌فرد و ضخامت اتمی دارند. این مواد می‌توانند تعدیل مقاومت دقیق‌تر و مصرف توان پایین‌تری را به دست آورند. تحقیقات در مورد اکسیدهای فلزی با تمرکز بر طراحی حالت‌های نقص و خواص رابط برای دستیابی به ویژگی‌های سوئیچینگ و قابلیت اطمینان بهتر ادامه دارد. بهینه‌سازی ساختار آرایه برای به حداقل رساندن جریان پنهان و بهبود حاشیه‌های خواندن/نوشتن است. می‌توان انتخابگرهای پیشرفته، از جمله انتخابگرهای سوئیچ فرار و موانع تونلی مهندسی شده را توسعه داد. در عین حال، راهبردهای یکپارچه‌سازی سه‌بعدی برای افزایش تراکم ذخیره‌سازی در عین حفظ سطح مصرف توان پایین بررسی می‌شوند. برای کاربردهای ذخیره‌سازی، محققان در حال توسعه طرح‌های برنامه‌نویسی پیچیده‌تر و روش‌های تصحیح خطا هستند. تحقیقات روی سازوکارهای سوئیچینگ جدید مانند تغییر فاز و اثرات مقاومت مغناطیسی می‌تواند دستگاه‌های دوگانه با ترکیب مزایای سازوکارهای ذخیره‌سازی مختلف ارائه دهد.

کاربردها و محاسبات نورومورفیک

برای محاسبات منطقی دیجیتال، تحقیقات آینده بر روی بهینه‌سازی ویژگی‌های دستگاه برای عملیات منطقی، توسعه طرح‌های برنامه‌نویسی کارآمدتر و ایجاد توپولوژی‌های مدار جدید با استفاده از خواص منحصربه‌فرد ممریستورها، تمرکز دارد. در محاسبات نورومورفیک، تحقیقات آینده بر روی توسعه دستگاه‌ها و سامانه‌های فوق‌العاده کم‌مصرف، دستیابی به جریان‌های برنامه‌نویسی بسیار کم برای دستیابی به تولید و انتقال پالس با مصرف انرژی بسیار کم متمرکز خواهد شد. از نظر طرح‌های آموزشی، طرح‌های توسعه آینده باید غیر ایده‌آل بودن دستگاه را در نظر بگیرند و تعادل توان-عملکرد را از طریق فنون تقریبی محاسبات و معماری‌های چند دستگاهی بهینه کنند. توسعه ممریستور چندمنظوره نیز در حال پیشرفت است که می‌تواند عملکردهای سیناپسی و عصبی را هم‌زمان انجام دهد و در نتیجه به سامانه‌های نورومورفیک فشرده‌تر و کارآمدتری دست یابد. در پاسخ به چالش‌های کاربردهای نورومورفیک، محققان در حال بهبود بهره‌وری انرژی از طریق طرح‌های برنامه‌نویسی نوآورانه و فنون دقت تطبیقی هستند (Xia et al., 2025).

نتیجه گیری

شاید بتوان گفت هوش مصنوعی مهم‌ترین محصول همگرایی فناوری‌ها است. علوم شناختی سازوکارهای نورونی مغز انسان را در بروز رفتارهای مختلف او توصیف می‌کند. فناوری اطلاعات الگوریتم‌هایی مشابه با این سازوکارها را طراحی و پیاده می‌کند. زیست‌فناوری با تبیین ساختارهای زیستی نورون‌ها و سیناپس‌ها به تقلید مکانیکی از بافت‌های زنده انسانی کمک می‌کند و نانوفناوری با ایجاد ابزارهای مشاهده، دست‌کاری و ساخت مواد در مقیاس نانو آن سه فناوری و علم دیگر را یاری می‌کند. با پیشرفت سریع فناوری‌های هوش مصنوعی و یادگیری ماشین تقاضا برای قابلیت‌های محاسباتی پیشرفته‌تر دستگاه‌ها به‌طور قابل‌توجهی افزایش یافته است. محاسبات نورومورفیک به‌عنوان الگوی محاسباتی نوظهور با تقلید از شبکه‌ی عصبی مغز انسان ایجاد شده و توجه فزاینده‌ای را به خود جلب کرده است. ممریستورها با تسری تقلید زیستی از سطح نرم‌افزاری به سطح سخت‌افزاری چالش‌های پیش‌روی محاسبات نورومورفیک را حل کرده‌اند. ممریستورها را می‌توان محصول همگرایی علوم دانست. در علوم شناختی با کمک نظریه‌ی هی‌بی می‌توان فرایند یادگیری و حافظه‌ی طولانی‌مدت را با کمک سخت‌افزار در ماشین اجرا کرد. زیست‌فناوری به تشریح عملکرد شبکه‌ی عصبی انسان می‌پردازد. نانوفناوری نانومواد و روش‌های ساخت و نانومواد ممریستورها را مهیا می‌کند و فناوری اطلاعات از ممریستورها در کنار الگوریتم‌های شبکه‌های عصبی مصنوعی برای افزایش میزان شبیه‌سازی شبکه‌های عصبی زیستی استفاده می‌کند. ممریستورها مزایای قابل‌توجهی را با خواص فیزیکی ذاتی و ویژگی‌های عملیاتی خود به ارمغان می‌آورند. اول، حالت مقاومت غیرفرار به آن‌ها اجازه می‌دهد تا اطلاعات را بدون مصرف برق اضافی برای انتقال داده ذخیره کنند. دوم، بسیاری از ممریستورها در اندازه‌های زیر ۱۰ نانومتر به ویژگی‌های سوئیچینگ پایدار دست می‌یابند و قابلیت زیادی برای گسترش دارند. محاسبات درون‌حافظه‌ای، تنگنای سنتی فون‌نویمان را از بین می‌برد و مصرف انرژی مرتبط با جابه‌جایی داده‌ها بین واحدهای پردازش و ذخیره‌سازی مستقل را تا حد زیادی کاهش می‌دهد. حالت ذخیره‌سازی چندسطحی قابل تنظیم، ضرب ماتریس و به‌روزرسانی وزن را برای محاسبات نورومورفیک امکان‌پذیر می‌کند. ممریستورها اگرچه با چالش‌هایی از جمله پایداری، تغییرپذیری و مقیاس‌پذیری مواجه هستند، اما چشم‌انداز آینده پژوهشی آن‌ها شامل سامانه‌های نورومورفیک زیست‌الهام و تقویت‌شده با کوانتوم بسیار امیدبخش است.

منابع

سلمان‌پور، آوا؛ و برهمن، مسعود (۱۴۰۱). کاربرد ممریستور به عنوان سیناپس در سلول‌های عصبی Integrate and fire و هاجکین هاگسلی. *انجمن مهندسی برق و الکترونیک ایران*، ۲۰ (۱)، ۹-۱۴.

References

- Ali, S., Khan, S., Khan, A., & Bermak, A. (2021). Memristor Fabrication Through Printing Technologies: A Review. *IEEE Access*, 9, 95970–95985. <https://doi.org/10.1109/access.2021.3094027>
- Bouzouita, M., Pathak, S., Zayer, F., Belgacem, H., & Tzouvadaki, I. (2025). Advanced memristive architectures based on nanomaterials for biomedical applications: a mini review. *Frontiers in Nanotechnology*, 7. <https://doi.org/10.3389/fnano.2025.1558743>
- Chakraverty, M., & Ramakrishnan, V. N. (2020). A Qualitative Study of Materials and Fabrication Methodologies for Two Terminal Memristive Systems. *Materials Today: Proceedings*, 22, 1628–1637. <https://doi.org/10.1016/j.matpr.2020.02.160>
- Choi, Y., Jeong, S., Jeong, H., Han, S., Ko, J., Yu, S. E., Xu, Z., Chae, M. S., Son, M., Meng, Y., Xu, S., Kang, J.-H., Mun, S., & Bae, S. H. (2025). Advanced AI computing enabled by 2D material-based neuromorphic devices. *npj Unconventional Computing*, 2(1). <https://doi.org/10.1038/s44335-025-00023-7>

- Gou, K., Li, Y., Song, H., Lu, R., & Jiang, J. (2024). Optimization strategy of the emerging memristors: From material preparation to device applications. *iScience*, 27(12), 111327. <https://doi.org/10.1016/j.isci.2024.111327>
- Hoch, F. L., Wang, Q., Lim, K. G., & Loke, D. K. (2025). Multifunctional Organic Materials, Devices, and Mechanisms for Neuroscience, Neuromorphic Computing, and Bioelectronics. *Nano-Micro Letters*, 17(1), 251. <https://doi.org/10.1007/s40820-025-01756-7>
- Huang, T., Wang, Y., Jin, Z., Liu, H., Wang, K., Chee, T. L., Shi, Y., & Yan, S. (2025). A Review of Nanowire Devices Applied in Simulating Neuromorphic Computing. *Nanomaterials (Basel)*, 15(10). <https://doi.org/10.3390/nano15100724>
- Ivanov, D., Chezhegov, A., Kiselev, M., Grunin, A., & Larionov, D. (2022). Neuromorphic artificial intelligence systems. *Front Neurosci*, 16, 959626. <https://doi.org/10.3389/fnins.2022.959626>
- Jiang, M., Xu, Y., Li, Z., & Li, C. (2025). Current opinions on memristor-accelerated machine learning hardware. *Current Opinion in Solid State and Materials Science*, 37. <https://doi.org/10.1016/j.cossms.2025.101226>
- Kandel, E. R., Dudai, Y., & Mayford, M. R. (2014). The molecular and systems biology of memory. *Cell*, 157(1), 163–186. <https://doi.org/10.1016/j.cell.2014.03.001>
- Meng, J., Song, J., Fang, Y., Wang, T., Zhu, H., Ji, L., Sun, Q. Q., Zhang, D. W., & Chen, L. (2024). Ionic Diffusive Nanomemristors with Dendritic Competition and Cooperation Functions for Ultralow Voltage Neuromorphic Computing. *ACS Nano*, 18(12), 9150–9159. <https://doi.org/10.1021/acsnano.4c00424>
- Mihail C. Roco, W. S. B. (2002). *Converging Technologies for Improving Human Performance*.
- Nicoll, R. A. (2017). A Brief History of Long-Term Potentiation. *Neuron*, 93(2), 281–290. <https://doi.org/10.1016/j.neuron.2016.12.015>
- Nordmann, A. (2004). *Converging Technologies – Shaping the Future of European Societies*.
- Prakash, C., Gupta, L. R., Mehta, A., Vasudev, H., Tominov, R., Korman, E., Fedotov, A., Smirnov, V., & Kesari, K. K. (2023). Computing of neuromorphic materials: an emerging approach for bioengineering solutions. *Materials Advances*, 4(23), 5882–5919. <https://doi.org/10.1039/d3ma00449j>
- Salmanpour, A., & Berahman, M. (2023). Memristor Bridge Synapse Application for Integrate and Fire and Hodgkin-Huxley Neuron Cell. *Journal of Iranian Association of Electrical and Electronics Engineers*, 20(1), 9–14. <https://doi.org/10.52547/jiaeee.20.1.9> (in persian)
- Sumner, R. L., Spriggs, M. J., Muthukumaraswamy, S. D., & Kirk, I. J. (2020). The role of Hebbian learning in human perception: a methodological and theoretical review of the human Visual Long-Term Potentiation paradigm. *Neuroscience & Biobehavioral Reviews*, 115, 220–237. <https://doi.org/10.1016/j.neubiorev.2020.03.013>
- Teixeira, H., Dias, C., Silva, A. V., & Ventura, J. (2024). Advances on MXene-Based Memristors for Neuromorphic Computing: A Review on Synthesis, Mechanisms, and Future Directions. *ACS Nano*, 18(33), 21685–21713. <https://doi.org/10.1021/acsnano.4c03264>
- Thakkar, P., Gosai, J., Gogoi, H. J., & Solanki, A. (2024). From fundamentals to frontiers: a review of memristor mechanisms, modeling and emerging applications. *Journal of Materials Chemistry C*, 12(5), 1583–1608. <https://doi.org/10.1039/d3tc03692h>
- Tripathi, S. K., Kaur, R., & Rani, M. (2014). Oxide Nanomaterials and their Applications as a Memristor. *Solid State Phenomena*, 222, 67–97. <https://doi.org/10.4028/www.scientific.net/SSP.222.67>
- Wang, X., Zhu, Y., Zhou, Z., Chen, X., & Jia, X. (2025). Memristor-Based Spiking Neuromorphic Systems Toward Brain-Inspired Perception and Computing. *Nanomaterials (Basel)*, 15(14). <https://doi.org/10.3390/nano15141130>
- Weilenmann, C., Ziogas, A. N., Zellweger, T., Portner, K., Mladenovic, M., Kaniselman, M., Moraitis, T., Luisier, M., & Emboras, A. (2024). Single neuromorphic memristor closely emulates multiple synaptic mechanisms for energy efficient neural networks. *Nature Communications*, 15(1), 6898. <https://doi.org/10.1038/s41467-024-51093-3>
- William Sims Bainbridge, M. C. R. (2006). *Managing Nano-Bio-Info-Cogno Innovations*. Springer.
- Xia, Z., Sun, X., Wang, Z., Meng, J., Jin, B., & Wang, T. (2025). Low-Power Memristor for Neuromorphic Computing: From Materials to Applications. *Nano-Micro Letters*, 17(1), 217. <https://doi.org/10.1007/s40820-025-01705-4>

- Xiao, Y., Gao, C., Jin, J., Sun, W., Wang, B., Bao, Y., Liu, C., Huang, W., Zeng, H., & Yu, Y. (2024). Recent Progress in Neuromorphic Computing from Memristive Devices to Neuromorphic Chips. *Advanced Devices & Instrumentation*, 5. <https://doi.org/10.34133/adi.0044>
- Xiao, Y., Jiang, B., Zhang, Z., Ke, S., Jin, Y., Wen, X., & Ye, C. (2023). A review of memristor: material and structure design, device performance, applications and prospects. *Science and Technology of Advanced Materials*, 24(1), 2162323. <https://doi.org/10.1080/14686996.2022.2162323>
- Xie, P., Li, D., Yip, S., & Ho, J. C. (2024). Emerging optoelectronic artificial synapses and memristors based on low-dimensional nanomaterials. *Applied Physics Reviews*, 11(1). <https://doi.org/10.1063/5.0173547>
- Zhang, Q., Yu, H., Barbiero, M., Wang, B., & Gu, M. (2019). Artificial neural networks enabled by nanophotonics. *Light: Science & Applications*, 8(1), 42. <https://doi.org/10.1038/s41377-019-0151-0>
- Zidan, M. A., Strachan, J. P., & Lu, W. D. (2018). The future of electronics based on memristive systems. *Nature Electronics*, 1(1), 22–29. <https://doi.org/10.1038/s41928-017-0006-8>

