

برنامه‌نویسی شناختی با الهام از علوم اعصاب

علی اصغر اسدی*

۱- کارشناسی رشته مهندسی تکنولوژی نرم افزار کامپیوتر، دانشگاه لیان، لیان، ایران .
(کارشناس در آمد شهرداری منطقه ۲)

چکیده

در دهه‌های اخیر، پیشرفت‌های سریع در هوش مصنوعی و علوم شناختی، توجه پژوهشگران را بیش از پیش به سازوکارهای مغز انسان به‌عنوان الگوی برتر پردازش اطلاعات جلب کرده است. برنامه‌نویسی شناختی با الهام از علوم اعصاب، به‌عنوان یک رویکرد میان‌رشته‌ای، می‌کوشد اصول سازمان‌دهی، یادگیری و سازگاری مغز بیولوژیکی را به چارچوب‌های محاسباتی و نرم‌افزاری ترجمه کند. مقدمه این پژوهش بر این ایده استوار است که اگرچه روش‌های متداول یادگیری ماشین و یادگیری عمیق در حل بسیاری از مسائل موفق بوده‌اند، اما از نظر انعطاف‌پذیری، تفسیرپذیری و کارایی انرژی با محدودیت‌های اساسی مواجه‌اند و فاصله قابل‌توجهی با هوش طبیعی دارند. هدف اصلی این مقاله مروری، ارائه تصویری جامع از مفاهیم، معماری‌ها و قوانین یادگیری در برنامه‌نویسی شناختی مبتنی بر علوم اعصاب و تبیین ظرفیت‌های آن برای توسعه سامانه‌های هوشمند پیشرفته است. تمرکز مقاله بر بررسی چگونگی الهام‌گیری از ساختارهای عصبی، حافظه، توجه، پردازش زمانی و مکانیسم‌های یادگیری زیست‌پذیر در طراحی سیستم‌های نرم‌افزاری است. روش تحقیق مبتنی بر یک مرور تحلیلی و ساختارمند از ادبیات علمی مرتبط با علوم اعصاب محاسباتی، مدل‌های شناختی و چارچوب‌های برنامه‌نویسی الهام‌گرفته از مغز است. در این چارچوب، مفاهیم کلیدی استخراج شده و پیوند میان یافته‌های نظری علوم اعصاب و کاربردهای عملی در مهندسی نرم‌افزار و هوش مصنوعی مورد تحلیل قرار گرفته است. یافته‌ها نشان می‌دهند که رویکردهای شناختی زیست‌الهام، به‌ویژه معماری‌های مبتنی بر پردازش زمانی و یادگیری محلی، پتانسیل بالایی در افزایش کارایی انرژی، یادگیری برخط و سازگاری در محیط‌های پویا دارند. همچنین این رویکردها امکان توسعه سیستم‌هایی تفسیرپذیرتر و نزدیک‌تر به الگوهای شناختی انسان را فراهم می‌کنند. در نتیجه‌گیری می‌توان گفت برنامه‌نویسی شناختی با الهام از علوم اعصاب، مسیری نویدبخش برای همگرایی علوم اعصاب، علوم شناختی و مهندسی نرم‌افزار فراهم می‌آورد و می‌تواند مبنایی برای نسل آینده سیستم‌های هوشمند انعطاف‌پذیر، مقیاس‌پذیر و زیست‌پذیر باشد.

واژگان کلیدی: برنامه‌نویسی شناختی، علوم اعصاب، شبکه‌های عصبی اسپایکی، معماری‌های زیست‌الهام، یادگیری زیست‌پذیر

مقدمه


برنامه‌نویسی شناختی با الهام از علوم اعصاب (Cognitive Programming Inspired by Neuroscience) نمایانگر یک جهش پارادایمی در حوزه هوش مصنوعی و علوم کامپیوتر است که بر ادغام عمیق یافته‌های تجربی و نظری علوم اعصاب در طراحی سیستم‌های محاسباتی تأکید دارد. در دهه‌های اخیر، پیشرفت‌های چشمگیر در یادگیری عمیق (Deep Learning) مبتنی بر شبکه‌های عصبی مصنوعی (ANNs) عملکرد بی‌نظیری را در وظایفی مانند بینایی ماشین و پردازش زبان طبیعی به ارمغان آورده است، اما این موفقیت‌ها اغلب بر پایه‌های محاسباتی‌ای بنا شده‌اند که فاصله زیادی با سازوکار واقعی مغز دارند؛ به عنوان مثال، اتکای مطلق به انتشار پسین (Backpropagation) که فاقد همتای زیستی مشخصی است (Lillicrap et al., 2020). این شکاف، محققان را وادار کرده است تا به ساختارهای بیولوژیکی، از نورون‌های منفرد گرفته تا شبکه‌های بزرگ مغزی، به عنوان نقشه‌های راهی برای توسعه هوش مصنوعی نسل بعدی نگاه کنند. هدف اصلی این پارادایم، ساختن سیستم‌هایی است که نه تنها می‌توانند وظایف پیچیده را انجام دهند، بلکه می‌توانند این کار را با همان کارایی، انعطاف‌پذیری، مصرف انرژی پایین و توانایی‌های استنتاجی که انسان‌ها نشان می‌دهند، انجام دهند.

یکی از اصلی‌ترین انگیزه‌های حرکت به سمت مدل‌سازی شناختی، نارسایی‌های مدل‌های یادگیری عمیق کنونی در زمینه‌هایی مانند یادگیری مبتنی بر نمونه‌های کم (Few-Shot Learning)، تعمیم‌پذیری ساختاری (Compositional Generalization) و استدلال علی (Causal Reasoning) است؛ مسائلی که در پردازش اطلاعات بیولوژیکی به طور طبیعی حل می‌شوند. علوم اعصاب شناختی، با ارائه مدل‌هایی از حافظه کاری، توجه انتخابی و سیستم‌های تصمیم‌گیری دوگانه (سیستم ۱ سریع و شهودی، و سیستم ۲ آهسته و تحلیلی)، چارچوبی غنی برای توسعه مدل‌های محاسباتی فراهم می‌آورد که می‌توانند این کاستی‌ها را برطرف سازند (Kahneman, 2011). با تقلید از چگونگی سازماندهی اطلاعات در قشر مغز (Cortex) و نحوه تبادل اطلاعات بین نواحی مختلف، می‌توان معماری‌هایی ایجاد کرد که از نظر محاسباتی کارآمدتر و از نظر شناختی غنی‌تر باشند.

برنامه‌نویسی شناختی فراتر از تقلید صرف از ساختار شبکه‌های عصبی است؛ بلکه به دنبال درونی‌سازی قوانین عملیاتی است که مغز برای یادگیری و سازگاری از آن‌ها استفاده می‌کند. این شامل مدل‌سازی پدیده‌هایی مانند انعطاف‌پذیری سیناپسی (Synaptic Plasticity)، نرخ تخلیه (Firing Rates) یا حتی فرآیندهای اسپایکی (Spiking Dynamics) است که در شبکه‌های عصبی سنتی که بر اساس مقادیر پیوسته فعال‌سازی کار می‌کنند، نادیده گرفته شده‌اند. استفاده از شبکه‌های عصبی اسپایکی (SNNs) به عنوان یکی از برجسته‌ترین مثال‌ها، نشان‌دهنده تلاشی برای شبیه‌سازی دقیق‌تر دینامیک زمانی اطلاعات در مغز است، جایی که زمان و ترتیب رویدادها اهمیت حیاتی دارند، نه فقط مقدار فعال‌سازی لحظه‌ای (Gerstner et al., 2014). توسعه این حوزه مستلزم همکاری تنگاتنگی بین متخصصان علوم اعصاب، مهندسان یادگیری ماشین و مهندسان نرم‌افزار است تا اطمینان حاصل شود که مدل‌های محاسباتی نه تنها بر اساس اصول زیست‌شناختی طراحی می‌شوند، بلکه از نظر محاسباتی نیز قابل پیاده‌سازی و مقیاس‌پذیر باشند. چالش اصلی در این میان، یافتن تعادل مناسب بین وفاداری زیستی (Biological Fidelity) و کارایی الگوریتمی است؛ مدل‌هایی که بیش از حد پیچیده و شبیه به مغز باشند، ممکن است از نظر محاسباتی بیش از حد سنگین شوند و از دستاوردهای عملی هوش مصنوعی دور شوند، در حالی که مدل‌های بیش از حد ساده‌شده، پتانسیل واقعی الهام‌گیری از مغز را از دست می‌دهند.

در این مقاله مروری، ما به بررسی عمیق اجزای سازنده این حوزه خواهیم پرداخت. ابتدا مبانی نظری و پیشینه پژوهشی را مرور می‌کنیم که چگونه مدل‌های شناختی اولیه به معماری‌های مدرن منجر شدند. سپس بر معماری‌های زیست‌الهام کلیدی مانند SNNs و مدل‌های مبتنی بر توجه تمرکز خواهیم کرد. بخش‌های بعدی به قوانین یادگیری زیست‌پذیر، مانند یادگیری مبتنی بر زمان (STDP) و چگونگی تخصیص اعتبار در این سیستم‌ها اختصاص خواهد یافت، که جایگزینی برای گرادیان کاهش سنتی ارائه می‌دهند. علاوه بر این، اهمیت پیاده‌سازی نرم‌افزاری و ابزارهای تخصصی که برای شبیه‌سازی و اجرای این مدل‌های پیچیده مورد نیاز هستند، بررسی خواهد شد. ارزیابی عملکرد در این سیستم‌ها نیازمند معیارهای جدیدی است که فراتر از دقت صرف در مجموعه داده‌های ایستا باشد و شامل سنجش کارایی انرژی، پایداری و توانایی یادگیری در زمان واقعی باشد. در نهایت، محدودیت‌های فعلی و مسیرهای آتی برای پژوهش‌های آینده و کاربردهای صنعتی این فناوری‌های نوظهور ترسیم خواهد شد تا تصویری جامع از آینده برنامه‌نویسی شناختی با الهام از علوم اعصاب ارائه گردد.

تأکید مداوم بر این نکته ضروری است که هدف نهایی، تنها ساخت یک سیستم هوشمند دیگر نیست، بلکه دستیابی به یک "درک محاسباتی" عمیق‌تر از هوش است که می‌تواند منجر به ساخت سیستم‌هایی شود که از نظر قابلیت‌های یادگیری و استنتاج، به هوش انسانی نزدیک‌تر باشند. این امر نیازمند چارچوبی است که بتواند پدیده‌های سطح بالا مانند خودآگاهی و استدلال انتزاعی را نیز در قالب مکانیسم‌های زیربنایی عصبی مدل‌سازی کند (Hassabis et al., 2017). در نهایت، این تلاش‌ها نه تنها برای پیشبرد هوش مصنوعی، بلکه برای درک بهتر عملکرد مغز انسان نیز حیاتی است، زیرا هر مدل محاسباتی که موفقیت‌آمیز باشد، می‌تواند فرضیه‌های جدیدی را در علوم اعصاب مطرح کند و مسیر آزمایش‌های تجربی آتی را مشخص نماید. این رابطه دوسویه بین مدل‌سازی و آزمایش، هسته اصلی برنامه‌نویسی شناختی الهام گرفته از علوم اعصاب را تشکیل می‌دهد.



شکل ۱. مدل مفهومی برنامه‌نویسی شناختی الهام‌گرفته از علوم اعصاب و ارتباط آن با معماری‌ها، قوانین یادگیری و سامانه‌های هوشمند تطبیقی.

در شکل ۱، یک مدل مفهومی از پارادایم «برنامه‌نویسی شناختی الهام گرفته از علوم اعصاب» نمایش داده شده است که هسته مرکزی آن، چارچوبی میان‌رشته‌ای برای طراحی سیستم‌های محاسباتی هوشمند محسوب می‌شود. این پارادایم از دو منبع اصلی تغذیه می‌شود: نخست، بنیان‌های علوم اعصاب که شامل نورون‌ها، سیناپس‌ها، انعطاف‌پذیری عصبی و سازمان‌دهی سیستم‌های مغزی است، و دوم، اصول شناختی نظیر یادگیری، حافظه، توجه و تصمیم‌گیری. ترکیب این دو حوزه، زمینه‌ای را فراهم می‌کند که در آن رفتارهای شناختی سطح بالا بر پایه مکانیسم‌های زیستی قابل مدل‌سازی و پیاده‌سازی در قالب نرم‌افزار باشند. در ادامه، این پارادایم مرکزی به توسعه معماری‌های زیست‌الهام مانند شبکه‌های عصبی اسپایکی و مدل‌های قشری، و همچنین قوانین یادگیری زیست‌پذیر نظیر یادگیری وابسته به زمان اسپایک (STDP) و یادگیری مبتنی بر پاداش منجر می‌شود. این اجزا از طریق ابزارها و چارچوب‌های پیاده‌سازی نرم‌افزاری و با استفاده از معیارهای ارزیابی چندبعدی، به ایجاد سامانه‌های هوشمند تطبیقی ختم می‌شوند؛ سامانه‌هایی که نه تنها از نظر دقت، بلکه از نظر کارایی انرژی، پایداری، تفسیرپذیری و سازگاری در محیط‌های پویا نیز مورد ارزیابی قرار می‌گیرند. این مدل، نمایی کلی از جریان دانش از علوم اعصاب به مهندسی نرم‌افزار و در نهایت به سیستم‌های هوشمند نسل آینده ارائه می‌دهد.

۲. مبانی نظری و پیشینه پژوهشی

پایه نظری برنامه‌نویسی شناختی با الهام از علوم اعصاب بر این فرض استوار است که درک مکانیسم‌های پردازش اطلاعات در مغز بیولوژیکی، کلید ساخت سیستم‌های محاسباتی کارآمدتر و انعطاف‌پذیرتر است. پیشینه این حوزه به تلاش‌های اولیه برای مدل‌سازی سلول عصبی بازمی‌گردد؛ از جمله مدل‌های ساده‌ای که بر اساس رفتار دینامیکی نورون‌ها شکل گرفتند. یکی از اولین و تأثیرگذارترین مدل‌ها، مدل نورون تجمعی و سپس مدل نورون نرخ-تیراندازی (Rate-Based Neuron Model) بود که رفتار جمعی جمعیت نورون‌ها را تقریب می‌زد و امکان تحلیل محاسبات در سطح ماکرو را فراهم می‌ساخت (Wilson & Cowan, 1972). این مدل‌ها به طور گسترده برای مطالعه نوسانات، پایداری و الگوهای رفتاری کلی شبکه‌های عصبی استفاده شدند و نقطه عطفی در جدا کردن محاسبات از جزئیات بیولوژیکی دقیق ایجاد کردند.

با پیشرفت تکنیک‌های علوم اعصاب، مشخص شد که مدل‌های نرخ-تیراندازی، دینامیک زمانی و اسپایک‌های منفرد را که برای بسیاری از عملکردهای مغز، به‌ویژه یادگیری و پردازش حسی سریع، حیاتی هستند، نادیده می‌گیرند. این امر منجر به توسعه مدل‌های مبتنی بر اسپایک (Spiking Neuron Models) شد که تلاش می‌کنند تا رفتار نورون‌ها را با دقت بالاتری شبیه‌سازی کنند. مدل لکی-آندره-هافیلد (Leaky Integrate-and-Fire - LIF) به عنوان یک مدل محاسباتی ساده اما مؤثر، نشان داد که چگونه زمان‌بندی دقیق پالس‌ها می‌تواند اطلاعات را رمزگذاری و منتقل کند، چیزی که مدل‌های سنتی ANNs قادر به انجام آن نبودند (Izhikevich, 2003). این مدل‌ها چارچوب لازم برای توسعه SNNs را فراهم آوردند که امروزه به عنوان پیاده‌کننده اصلی برنامه‌نویسی شناختی زیست‌پذیر شناخته می‌شوند.

نظریه‌های یادگیری نیز تحولات مهمی را در این زمینه رقم زدند. کشف اصل هب (Hebb's Postulate) که بیان می‌دارد "نورون‌هایی که با هم شلیک می‌کنند، به هم متصل می‌شوند" (Hebb, 1949)، سنگ بنای یادگیری غیرنظارتی (Unsupervised Learning) در مغز شد. این اصل به فرمول‌های محاسباتی مانند یادگیری قانون انجمنی وابسته به زمان اسپایک (Spike-Timing Dependent Plasticity - STDP) تبدیل شد (Gerstner et al., 2014). یک الگوریتم یادگیری محلی و بدون نیاز به معلم است که تغییر وزن سیناپسی را بر اساس ترتیب زمانی تقریبی اسپایک‌های پیش‌سیناپسی و پس‌سیناپسی تنظیم می‌کند. این تفاوت اساسی با انتشار پسین دارد، زیرا STDP تنها به اطلاعات محلی در دو سر سیناپس متکی است و نیاز به انتشار سیگنال خطا از انتهای شبکه به ابتدای آن را منتفی می‌سازد، که این خود یکی از بزرگترین موانع زیست‌پذیری در شبکه‌های عمیق مدرن است (Lillicrap et al., 2017). پیشرفت‌های علوم شناختی نیز در شکل‌دهی به این حوزه نقش محوری داشته‌اند. نظریه‌های مربوط به حافظه کاری، مانند مدل چندمولفه‌ای بادلی و هیتچ (Baddeley & Hitch, 1974)، چارچوبی برای مدل‌سازی سیستم‌هایی فراهم کردند که می‌توانند اطلاعات را به طور موقت برای استدلال و تصمیم‌گیری دستکاری کنند. تلاش برای مدل‌سازی این مکانیسم‌ها در معماری‌های محاسباتی منجر به توسعه مدل‌هایی شده است که بر اساس مدارهای عصبی هیپوکامپ و قشر مغز برای بازیابی و ادغام اطلاعات طراحی شده‌اند. این رویکرد مستقیماً بر تقویت قابلیت‌های استنتاجی و تعمیم سیستم‌های هوش مصنوعی تأثیر می‌گذارد.

همچنین، نقش توجه (Attention) در فرآیندهای شناختی انسان، مدل‌های محاسباتی جدیدی را الهام بخشیده است. مکانیسم توجه، امکان فیلتر کردن اطلاعات مرتبط و تمرکز منابع محاسباتی بر روی ورودی‌های مهم را فراهم می‌آورد. اگرچه مکانیسم‌های توجه در شبکه‌های ترانسفورمر (Transformers) موفقیت‌هایی کسب کرده‌اند (Vaswani et al., 2017)، اما مدل‌های مبتنی بر علوم اعصاب اغلب سعی می‌کنند مکانیسم‌های عصبی واقعی توجه، مانند تقویت‌های مداری مبتنی بر نورون‌های بازدارنده و محرک، را تقلید کنند تا کارایی انرژی و زمان‌بندی پاسخگویی بهتری را به دست آورند. در مجموع، پیشینه پژوهشی نشان می‌دهد که انتقال از مدل‌های صرفاً عملکردی به مدل‌های زیست‌الهام، یک مسیر دوطرفه است: یافته‌های جدید در علوم اعصاب، محدودیت‌های مدل‌های فعلی را آشکار می‌کنند، و مدل‌های محاسباتی موفق، فرضیه‌های جدیدی برای آزمایش‌های نوروساینس ایجاد می‌نمایند (Hassabis et al., 2017). این هم‌افزایی، اساس برنامه‌نویسی شناختی مدرن را تشکیل می‌دهد که به دنبال بازآفرینی نه تنها خروجی‌های شناختی، بلکه فرآیندهای درونی منجر به آن خروجی‌ها است. چارچوب‌های محاسباتی مانند شبکه‌های مبتنی بر پیش‌بینی (Predictive Coding) نیز اهمیت زیادی یافته‌اند، زیرا این نظریه بیان می‌کند که مغز دائماً در حال تولید پیش‌بینی‌هایی در مورد ورودی‌های حسی آینده است و تنها سیگنال‌های خطا (اختلاف بین پیش‌بینی و واقعیت) را به سطوح بالاتر منتقل می‌کند (Rao & Ballard, 1999). این مکانیسم اساساً با الگوریتم انتشار پسین متفاوت است و سازوکاری طبیعی برای یادگیری تدریجی و سازگاری با محیط فراهم می‌آورد که بسیار شبیه به نحوه یادگیری در طبیعت است.

۳. معماری‌های زیست‌الهام و الگوهای محاسباتی

معماری‌های زیست‌الهام، قلب تپنده برنامه‌نویسی شناختی هستند و هدف آن‌ها تقلید ساختاری و عملکردی اجزای کلیدی مغز است. شاید مهم‌ترین و فعال‌ترین حوزه در این زمینه، توسعه شبکه‌های عصبی اسپایکی (SNNs) باشد.

SNN ها به عنوان نسل سوم شبکه‌های عصبی شناخته می‌شوند که در آن‌ها اطلاعات نه از طریق مقادیر پیوسته فعال‌سازی، بلکه از طریق پالس‌های گسسته (اسپایک‌ها) منتقل می‌شود، مشابه نورون‌های بیولوژیکی (Izhikevich, 2003). این ویژگی باعث می‌شود SNN ها نه تنها از نظر محاسباتی قابل اجرای کارآمد بر روی سخت‌افزارهای عصبی (Neuromorphic Hardware) باشند، بلکه امکان رمزگذاری اطلاعات در زمینه زمان‌بندی (Temporal Coding) را نیز فراهم آورند، که در پردازش سیگنال‌های پویا و سری‌های زمانی برتری دارند.

در دل SNN ها، مدل‌های نورونی پیچیده‌تر از مدل‌های ساده LIF وجود دارند که سعی در شبیه‌سازی دینامیک ولتاژ غشاء و بازگشت‌پذیری (Refractoriness) نورون‌ها دارند. مدل‌های Hodgkin-Huxley یا مدل‌های فاز-صفحه (Phase-Plane Models) مانند مدل Izhikevich، اگرچه از نظر محاسباتی سنگین‌ترند، اما امکان مدل‌سازی دقیق پدیده‌های رفتاری پیچیده نورون‌ها مانند پتانسیل‌های عملی، نوسانات و انواع مختلف پاسخ‌های رفتاری (مانند تونیک یا فازی) را فراهم می‌کنند (Izhikevich, 2003). انتخاب معماری نورون به شدت بر میزان وفاداری زیستی و کارایی محاسباتی سیستم نهایی تأثیر می‌گذارد. فراتر از سطح نورون، سازماندهی شبکه‌های مغزی نقش حیاتی دارد. معماری‌هایی که بر اساس ساختار قشر مغز (Cortical Columns) طراحی شده‌اند، بر اهمیت اتصالات محلی، بازخوردها و حلقه‌های بازدارنده (Inhibitory Loops) تأکید می‌کنند. این ساختارها پایداری شبکه را افزایش داده و امکان تنظیم دقیق نرخ شلیک را فراهم می‌آورند، که در مدل‌های ساده بدون بازخورد امکان‌پذیر نیست. برای مثال، شبکه‌های مبتنی بر مدارهای بازدارنده-محرک (Excitation-Inhibition Balance) می‌توانند رفتارهای پیچیده‌ای مانند انتخاب ویژگی‌های بارز (Feature Selection) را بدون نیاز به الگوریتم‌های پیچیده خارجی اجرا کنند (Gerstner et al., 2014).

الگوهای محاسباتی دیگری که از علوم اعصاب الهام گرفته‌اند، به حوزه‌هایی مانند حافظه و یادگیری مرتبط می‌شوند. مدل‌های مبتنی بر هیپوکامپ برای یادگیری فضایی و ناوبری، مانند شبکه‌های مبتنی بر سلول‌های مکانی (Place Cells) و سلول‌های شبکه‌ای (Grid Cells)، نمونه‌هایی از معماری‌های تخصصی هستند که برای حل وظایف خاصی طراحی شده‌اند که شبکه‌های پیش‌خور ساده در آن‌ها شکست می‌خورند. این معماری‌ها اصول سازماندهی توپولوژیکی اطلاعات در حافظه را رمزگذاری می‌کنند. یکی دیگر از الگوهای کلیدی، مدل‌سازی سیستم‌های شناختی دوگانه است که از کار نظریه‌پردازان شناختی مانند دانیل کانمن الهام گرفته شده است (Kahneman, 2011). این مدل‌ها شامل دو زیرسیستم محاسباتی هستند: یکی سریع، موازی، شهودی و مبتنی بر الگوهای یادگرفته شده (سیستم ۱)، و دیگری آهسته، متوالی، منطقی و نیازمند منابع شناختی بالا (سیستم ۲). در برنامه‌نویسی شناختی، این امر به ساخت معماری‌هایی منجر می‌شود که در آن‌ها یک بخش SNN سریع، پردازش اولیه را انجام می‌دهد و نتایج مشکوک یا نیاز به تأیید را به یک ماژول نمادین‌تر یا مدل‌سازی شده با تأخیر (مشابه سیستم ۲) ارجاع می‌دهند.

سیستم‌های مبتنی بر پیش‌بینی (Predictive Coding Networks) نیز یک پارادایم محاسباتی قدرتمند در این زمینه هستند. این مدل‌ها تلاش می‌کنند تا رمزگذاری اطلاعات را بر اساس تفاوت بین ورودی مورد انتظار و ورودی واقعی (خطای پیش‌بینی) انجام دهند (Rao & Ballard, 1999). این رویکرد به‌طور طبیعی مکانیسم‌های خودتنظیمی و بهینه‌سازی مصرف انرژی را در بر می‌گیرد، زیرا تنها اطلاعات جدید و غیرمنتظره نیاز به پردازش و انتقال در سطوح بالاتر دارند، که شباهت زیادی به نحوه کارکرد توجه در مغز دارد. در نهایت، مدل‌های مبتنی بر مدل‌های مغز جهان (World Models)، که توسط پژوهشگرانی مانند حسابییس ترویج شده‌اند، تلاش می‌کنند تا یک نمایش داخلی پویا و پیش‌بینانه

از محیط بسازند (Hassabis et al., 2017). این مدل‌ها از طریق یادگیری خودنظارتی، نه تنها یاد می‌گیرند که چگونه محیط را درک کنند، بلکه می‌توانند سناریوهای آینده را شبیه‌سازی کرده و بر اساس این شبیه‌سازی‌ها، بهترین اقدامات را انتخاب کنند، که این امر نشان‌دهنده اوج برنامه‌نویسی شناختی الهام گرفته از مغز در زمینه برنامه‌ریزی و تصمیم‌گیری است.

۴. قوانین یادگیری زیست‌پذیر و تخصیص اعتبار

یکی از بزرگترین موانع در دستیابی به هوش مصنوعی عمومی (AGI) با استفاده از مدل‌های فعلی مبتنی بر انتشار پسین، عدم زیست‌پذیری (Lack of Biological Plausibility) این الگوریتم‌ها است. انتشار پسین نیازمند ارتباط دوطرفه دقیق و همزمان در کل شبکه و محاسبه گرادیان‌های خطا در تمام لایه‌ها است، چیزی که شواهد قوی از وجود آن در مغز بیولوژیکی وجود ندارد (Lillicrap et al., 2017). در مقابل، برنامه‌نویسی شناختی با الهام از علوم اعصاب بر قوانین یادگیری محلی، غیرهمزمان و مبتنی بر رویداد (Event-Driven) تمرکز دارد که به عنوان قوانین زیست‌پذیر شناخته می‌شوند.

قانون محوری در این حوزه، قانون هب و توسعه محاسباتی آن، یعنی STDP است. STDP (Spike-Timing Dependent Plasticity) یادگیری را بر اساس تأخیر زمانی دقیق بین اسپایک‌های نورون پیش‌سیناپسی و پس‌سیناپسی تعریف می‌کند (Gerstner et al., 2014). اگر نورون پیش‌سیناپسی کمی قبل از نورون پس‌سیناپسی شلیک کند (علت مقدم بر معلول)، وزن سیناپسی تقویت می‌شود (Potentiation)؛ و اگر پس از آن شلیک کند، تضعیف می‌شود (Depression). این مکانیسم ساده، امکان یادگیری ارتباطات علی و کشف الگوهای زمانی را فراهم می‌آورد و به طور طبیعی برای شبکه‌های عصبی اسپایکی (SNNs) مناسب است، زیرا مستقیماً از دینامیک زمانی اسپایک‌ها استفاده می‌کند. با وجود جذابیت STDP، اجرای مکانیسم تخصیص اعتبار (Credit Assignment Problem) در شبکه‌های عمیق مبتنی بر اسپایک همچنان یک چالش بزرگ است. تخصیص اعتبار به این سؤال پاسخ می‌دهد که کدام بخش از شبکه مسئول یک نتیجه نهایی (مثلاً یک جایزه یا خطا) بوده است، به‌خصوص زمانی که یک عمل منجر به پاداش پس از تأخیری طولانی شود. در یادگیری تقویتی سنتی، این امر با انتشار خطا حل می‌شود، اما در SNNها، نیاز به مکانیسم‌های جایگزین وجود دارد. یکی از راه‌حل‌های مهم، استفاده از مدل‌های تخصیص اعتبار مبتنی بر دوپامین (Dopamine-based Credit Assignment) است که از مدارهای یادگیری تقویتی بیولوژیکی الهام گرفته شده‌اند.

در این مدل‌ها، سیگنال‌های پاداش (مانند انتشار دوپامین) به عنوان یک سیگنال خارجی یا یک اسپایک با فرکانس بالا عمل می‌کنند که به‌طور غیرمستقیم بر تمام سیناپس‌های فعال در زمان دریافت پاداش تأثیر می‌گذارد و به صورت محلی وزن‌ها را تنظیم می‌کند (Lillicrap et al., 2017). این سیگنال‌های مبتنی بر زمان‌بندی رویداد، به سیستم اجازه می‌دهند تا "سود مورد انتظار" را با "سود واقعی" مقایسه کند و تغییرات لازم را در وزن‌ها ایجاد نماید، بدون اینکه نیاز به انتشار معکوس گرادیان‌های پیچیده باشد. علاوه بر این، مفهوم یادگیری افزایشی (Incremental Learning) یا یادگیری آنلاین، که یک ویژگی بارز سیستم‌های بیولوژیکی است، به‌طور طبیعی از قوانین زیست‌پذیر پشتیبانی می‌شود. از آنجا که STDP و مکانیزم‌های مبتنی بر پاداش محلی هستند، شبکه می‌تواند به طور مداوم و بدون نیاز به بازآموزی کامل بر روی کل

مجموعه داده‌های قدیمی، با داده‌های جدید سازگار شود (Gerstner et al., 2014). این قابلیت در محیط‌های دنیای واقعی که داده‌ها دائماً در حال تغییر هستند، حیاتی است و بر محدودیت مدل‌های یادگیری عمیق مبتنی بر آموزش دسته‌ای (Batch Training) غلبه می‌کند.

الگوریتم‌های مبتنی بر پیش‌بینی نیز قوانین یادگیری خاص خود را دارند. در چارچوب پیش‌بینی کدگذاری (Predictive Coding)، یادگیری از طریق تنظیم پارامترهای مدل برای به حداقل رساندن خطای پیش‌بینی رخ می‌دهد (Rao & Ballard, 1999). این بهینه‌سازی معمولاً محلی است و شامل تنظیم وزن‌هایی است که مدل تولیدکننده پیش‌بینی (Generative Model) و مدل استنباطی (Inference Model) را به تعادل می‌رساند. تفاوت اصلی با پسانتشار در این است که یادگیری در این مدل‌ها به جای خطا در خروجی نهایی، بر روی خطاهای درونی (Internal Errors) در هر سطح سلسله مراتبی تمرکز دارد. این قوانین یادگیری زیست‌پذیر مستقیماً بر توانایی سیستم برای مدل‌سازی ساختارهای زمانی و علی تأثیر می‌گذارند. توانایی مدل‌سازی روابط علت و معلولی، که لازمه استدلال قوی است، در مدل‌های مبتنی بر STDP بهتر از مدل‌های مبتنی بر همبستگی ساده (Correlation) مشاهده می‌شود. سیستم‌هایی که از این قوانین پیروی می‌کنند، یاد می‌گیرند که نه تنها چه چیزی رخ می‌دهد، بلکه "چگونه" و "چه زمانی" به یکدیگر مرتبط هستند. در نهایت، ترکیب این قوانین یادگیری با معماری‌های یادگیری تقویتی منجر به ایجاد سیستم‌های یادگیری عمیق عصب-مدل ساز (Neuro-Inspired Deep Reinforcement Learning) می‌شود که تلاش می‌کنند تا با تقلید از مدارهای پاداش-تنبیه مغز، یادگیری عملیاتی را با دقت سیناپسی ترکیب کنند، که این امر پایه‌های محاسباتی لازم برای عامل‌های شناختی خودمختار را فراهم می‌آورد.

۵. پیاده‌سازی نرم‌افزاری و ابزارها

پیاده‌سازی موفق برنامه‌نویسی شناختی با الهام از علوم اعصاب به ابزارها و چارچوب‌های نرم‌افزاری خاصی نیاز دارد که بتوانند دینامیک‌های پیچیده نورون‌های اسپایکی و محاسبات مبتنی بر زمان را با کارایی بالا مدیریت کنند. برخلاف چارچوب‌های یادگیری عمیق سنتی مانند TensorFlow و PyTorch که برای محاسبات ماتریسی پیوسته (Continuous Matrix Computations) در سخت‌افزارهای گرافیکی (GPUs) بهینه‌سازی شده‌اند، مدل‌های زیست‌الهام اغلب نیازمند پلتفرم‌هایی هستند که به محاسبات رویدادمحور (Event-Driven) و موازی‌سازی بر اساس زمان حساس باشند. یکی از مهم‌ترین ابزارهای این حوزه، شبیه‌سازهای عصبی پیشرفته هستند که برای اجرای مدل‌های SNN با وفاداری بالا طراحی شده‌اند. NEST (Neural Simulation Tool) یکی از شناخته‌شده‌ترین این ابزارها است که برای شبیه‌سازی شبکه‌های بزرگ مقیاس با مدل‌های دینامیکی پیچیده نورون (مانند LIF یا مدل‌های Hodgkin-Huxley) بهینه‌سازی شده است (Hines et al., 2009). NEST از موازی‌سازی مبتنی بر پیام‌رسانی استفاده می‌کند و امکان مدل‌سازی شبکه‌هایی با میلیون‌ها نورون و میلیارد‌ها سیناپس را فراهم می‌سازد، که آن را برای پژوهش‌های بنیادی در علوم اعصاب محاسباتی بسیار مناسب می‌کند.

در نقطه مقابل NEST که بر وفاداری زیستی تأکید دارد، چارچوب‌هایی مانند Brian2 وجود دارند که بر سادگی تعریف مدل‌ها و انعطاف‌پذیری برای آزمایش قوانین یادگیری جدید (مانند STDP) تمرکز دارند (Hiller et al., 2014).

به محققان اجازه می‌دهد تا معادلات دیفرانسیل توصیف‌کننده دینامیک نوروں را به صورت مستقیم و خوانا وارد کنند و سپس محاسبات را برای کارایی به زبان‌های سطح پایین‌تر (مانند ++C) کامپایل کند. این انعطاف‌پذیری برای توسعه و آزمون سریع الگوریتم‌های یادگیری زیست‌پذیر حیاتی است. برای گذار از شبیه‌سازی به کاربردهای عملی و بهره‌برداری از سخت‌افزارهای تخصصی، ابزارهای مرتبط با محاسبات عصبی (Neuromorphic Computing) اهمیت پیدا می‌کنند. Lava (A Neuromorphic Software Framework) که توسط اینتل توسعه یافته است، یک چارچوب نرم‌افزاری است که به طور خاص برای برنامه‌نویسی مدارهای عصبی بر روی سخت‌افزارهای عصبی مانند Loihi طراحی شده است (Davies et al., 2018). Lava امکان تعریف معماری‌های SNN و اجرای آن‌ها را با بهره‌وری بسیار بالا از نظر انرژی فراهم می‌آورد، زیرا محاسبات بر اساس رویدادها (اسپایک‌ها) انجام می‌شوند و نه محاسبات ماتریسی پیوسته.

علاوه بر شبیه‌سازهای تخصصی SNN، چارچوب‌های یادگیری عمیق سنتی نیز در حال تکامل برای پشتیبانی از رویکردهای زیست‌الهام هستند. کتابخانه‌هایی مانند PyTorch و TensorFlow از طریق افزودن ماژول‌هایی برای مدل‌سازی دینامیک‌های زمانی و ترکیب آن‌ها با لایه‌های بازخورد و توجه، در حال تلاش برای ادغام قابلیت‌های برنامه‌نویسی شناختی هستند (Vaswani et al., 2017). این تلاش‌ها اغلب بر تقریب زدن سیناپس‌های اسپایکی با توابع فعال‌سازی تقریبی (مانند تبدیل توابع گسسته به پیوسته برای تسهیل گرادیان) متمرکز است، گرچه هدف نهایی این است که بتوان از قدرت سخت‌افزارهای معمولی در اجرای مدل‌های زمانی بهره برد. توسعه ابزارهای واسط میان علوم اعصاب و هوش مصنوعی نیز ضروری است. این ابزارها باید قادر به تحلیل خروجی‌های شبیه‌سازی‌های پیچیده (مانند نرخ‌های شلیک، پتانسیل‌های غشاء و الگوهای همبستگی) باشند و آن‌ها را به معیارهای قابل درک برای ارزیابی شناختی ترجمه کنند. ابزارهای تجزیه و تحلیل دینامیک شبکه، مانند تحلیل اثرپذیری (Perturbation Analysis) و مدل‌سازی عملکرد سلول‌های فرضی در نواحی مختلف مغز، برای تأیید فرضیه‌های شناختی مورد نیاز هستند. در نهایت، نیاز به محیط‌های شبیه‌سازی تعاملی برای عامل‌های هوشمند (Agents) رو به افزایش است. استفاده از محیط‌های یادگیری تقویتی (مانند OpenAI Gym) که با SNN‌ها ترکیب شده‌اند، به محققان اجازه می‌دهد تا قوانین یادگیری زیست‌پذیر (مانند STDP یا تخصیص اعتبار مبتنی بر دوپامین) را در فرآیند یادگیری عامل در زمان واقعی آزمایش کنند، که این امر نیازمند ابزارهایی است که بتوانند تعاملات پیوسته عامل با محیط و دینامیک‌های گسسته SNN را به‌طور مؤثر همگام‌سازی کنند.

۶. معیارهای ارزیابی و سنجش عملکرد

ارزیابی عملکرد سیستم‌های برنامه‌نویسی شناختی الهام گرفته از علوم اعصاب نیازمند مجموعه‌ای از معیارها است که فراتر از دقت ساده (Accuracy) در مجموعه داده‌های ایستا باشد. از آنجا که هدف این سیستم‌ها تقلید از هوش بیولوژیکی است، معیارها باید توانایی‌های شناختی مانند یادگیری کارآمد، پایداری در برابر نویز، تعمیم‌پذیری و کارایی انرژی را نیز بسنجند. اتکای صرف به معیارهایی که برای شبکه‌های عمیق سنتی توسعه یافته‌اند، می‌تواند پتانسیل واقعی این مدل‌های زیست‌الهام را پنهان سازد. یکی از مهم‌ترین معیارهای متمایزکننده، کارایی انرژی (Energy Efficiency) است. نوروں‌های بیولوژیکی بسیار کارآمد هستند و مغز انسان با تنها حدود ۲۰ وات انرژی کار می‌کند، در حالی که آموزش مدل‌های بزرگ زبانی به مگاوات‌ها برق نیاز دارد. SNN‌ها به دلیل ماهیت رویدادمحور خود، این پتانسیل را دارند که انرژی بسیار

کمتری مصرف کنند، زیرا تنها نوروتهایی که اسپایک تولید می کنند، محاسبات را انجام می دهند. بنابراین، سنجش عملکرد باید شامل معیارهایی مانند ژول بر عملیات (Joules per Operation) یا اسپایک بر ژول (Spikes per Joule) باشد، به ویژه هنگامی که این مدل ها بر روی سخت افزارهای عصبی اجرا می شوند (Davies et al., 2018).

توانایی یادگیری در زمان واقعی و تعمیم پذیری (Online and Transfer Learning) معیار حیاتی دیگری است. سیستم های شناختی باید بتوانند در حین انجام وظایف، به طور مداوم از تجربیات جدید یاد بگیرند و دانش کسب شده را به وظایف مرتبط تعمیم دهند (Lillicrap et al., 2017). ارزیابی ها باید شامل سناریوهایی باشد که در آن مدل مجبور به یادگیری مهارتی جدید پس از آموزش اولیه است، یا تغییراتی در توزیع داده ها (Domain Shift) رخ می دهد. عملکرد ضعیف در یادگیری تجمعی (Catastrophic Forgetting) نشان دهنده شکست در تقلید از انعطاف پذیری سیناپسی واقعی است. حساسیت به زمان بندی و رمزگذاری زمانی (Temporal Precision) باید به طور خاص برای SNN ها سنجیده شود. در وظایفی مانند پردازش سیگنال های صوتی یا کنترل دینامیکی، نه تنها محتوای اسپایک ها، بلکه زمان دقیق وقوع آن ها نیز حامل معنا است. معیارهایی مانند دقت در تشخیص توالی ها (Sequence Recognition Accuracy) یا توانایی بازسازی الگوهای زمانی پیچیده، سنجش های مناسب تری نسبت به دقت کلی در دسته بندی های ایستا هستند.

استدلال شناختی و عملکرد در وظایف چندمرحله ای (Cognitive Reasoning) نمایانگر توانایی سیستم در شبیه سازی فرآیندهای سیستم ۲ است. این امر مستلزم ارزیابی مدل ها در وظایفی است که نیازمند حافظه کاری فعال و برنامه ریزی هستند، مانند حل معماها یا اجرای دستورالعمل های پیچیده چند مرحله ای (Kahneman, 2011). مدل ها باید بر اساس توانایی شان در حفظ و دستکاری اطلاعات در طول زمان مورد قضاوت قرار گیرند، که اغلب با معیارهای مبتنی بر طول مسیر وابستگی در محاسبات (Path Length Dependency) ارزیابی می شود. علاوه بر معیارهای عملکردی، معیارهای زیست سنجی (Biomarker Metrics) برای سنجش میزان نزدیکی سیستم به رفتار مغزی مشاهده شده ضروری هستند. این شامل مقایسه الگوهای فعال سازی شبکه مدل با داده های تصویربرداری مغزی (fMRI یا EEG) از سوژه های انسانی در حین انجام همان وظایف است. آیا توزیع توجه در شبکه محاسباتی با نواحی فعال شده در مغز انسان همخوانی دارد؟ آیا نرخ های شلیک در مدل ها با نرخ های مشاهده شده در آزمایشگاه های علوم اعصاب سازگار است؟ (Hassabis et al., 2017). نهایتاً، مقیاس پذیری محاسباتی (Computational Scalability) از منظر نرم افزاری و سخت افزاری سنجیده می شود. یک معماری زیست الهام ممکن است از نظر نظری عالی باشد، اما اگر پیاده سازی آن بر روی رایانه های استاندارد منجر به افزایش نمایی در زمان شبیه سازی شود، عملاً غیرقابل استفاده خواهد بود. بنابراین، ارزیابی باید شامل مقایسه زمان مورد نیاز برای آموزش و استنتاج در مقابل مدل های مرجع (Benchmark Models) و بر روی پلتفرم های مختلف (GPU, CPU) و سخت افزار عصبی باشد.

۷. چالش ها و محدودیت ها

برنامه نویسی شناختی با الهام از علوم اعصاب، علی رغم پتانسیل عظیمش، با مجموعه ای از چالش های فنی، نظری و عملی مواجه است که پیشرفت آن را کند کرده است. شاید بزرگترین چالش، شکاف مداوم بین پیچیدگی بیولوژیکی و قابلیت های

محاسباتی فعلی باشد؛ یعنی مسئله یافتن تعادل بهینه بین وفاداری زیستی (Biological Fidelity) و کارایی الگوریتمی (Algorithmic Efficiency).

یکی از موانع اصلی، پیچیدگی مدل سازی سیناپس ها و نورون های بیولوژیکی است. در حالی که مدل هایی مانند Hodgkin-Huxley رفتار نورون را با دقت بسیار بالایی توصیف می کنند، اجرای میلیون ها نمونه از آن ها در مقیاس شبکه، منابع محاسباتی عظیمی را می طلبد و زمان شبیه سازی را غیرقابل قبول می سازد (Izhikevich, 2003). این امر محققان را مجبور می کند تا از مدل های ساده تری مانند LIF استفاده کنند، اما این سادگی ممکن است ویژگی های حیاتی بیولوژیکی که عامل هوشمندی هستند را از دست بدهد. چالش دیگر، آموزش و بهینه سازی مدل های مبتنی بر اسپایک (SNNs) است. همانطور که قبلاً ذکر شد، الگوریتم استاندارد انتشار پسین (Backpropagation) به طور مستقیم قابل اعمال بر روی SNN ها نیست زیرا تابع فعال سازی اسپایک ها ناپیوسته و مشتق ناپذیر است (Lillicrap et al., 2020). اگرچه روش های جایگزین مانند "SuperSpike" یا استفاده از تخمین های گرادیان (Surrogate Gradients) این مشکل را کاهش داده اند، اما این روش ها اغلب منجر به افزایش پیچیدگی و کاهش تفسیرپذیری می شوند و زیست پذیری الگوریتم یادگیری را زیر سؤال می برند.

مشکل تخصیص اعتبار در شبکه های عمیق همچنان یک مانع بزرگ است. مغز باید بتواند پاداش ها را به اقدامات گذشته ارتباط دهد، حتی اگر این اقدامات هزاران مرحله قبل رخ داده باشند (Kahneman, 2011). در حالی که رویکردهای مبتنی بر دوپامین نویدبخش هستند، پیاده سازی مکانیسم های تخصیص اعتبار زمانی طولانی (Long-Term Temporal Credit Assignment) که از نظر بیولوژیکی معتبر باشند و در عین حال مقیاس پذیر باشند، هنوز به طور کامل حل نشده است. از منظر نظری، فقدان یکپارچگی میان سطوح مختلف مدل سازی یک محدودیت اساسی است. ما مدل های بسیار دقیقی برای رفتارهای تک نورونی داریم و مدل های موفقی برای رفتار سیستم های بزرگ (مانند ترانسفورمرها)، اما پلی محکم بین این دو سطح وجود ندارد (Hassabis et al., 2017). به طور خاص، چگونگی ظهور سازوکارهای شناختی سطح بالا مانند خودآگاهی، برنامه ریزی انتزاعی و زبان، از دینامیک های ساده سیناپسی، یک معمای باز است که مدل های فعلی فاقد توصیف جامع آن هستند.

چالش ابزاری و سخت افزاری نیز قابل توجه است. اگرچه پیشرفت هایی در زمینه سخت افزارهای عصبی مانند Loihi وجود دارد (Davies et al., 2018)، این پلتفرم ها هنوز فراگیر نیستند و اکوسیستم نرم افزاری برای توسعه و استقرار سریع مدل ها بر روی آن ها به بلوغ چارچوب های مبتنی بر GPU نرسیده است. این امر توسعه دهندگان را وادار می کند که بین کارایی انرژی در سخت افزار تخصصی و راحتی توسعه در پلتفرم های عمومی یکی را انتخاب کنند. محدودیت دیگر، تفسیرپذیری (Interpretability) است. مدل های شناختی زیست الهام اغلب به دلیل دینامیک های زمانی و حلقه های بازخوردی متعدد، از شبکه های عمیق سنتی نیز کدرتر هستند. درک اینکه چرا یک SNN تصمیم خاصی گرفته است، دشوارتر است، به خصوص زمانی که پاسخ ها بر اساس توالی اسپایک ها و نه یک فعال سازی ساده است. این امر پذیرش آن ها را در حوزه هایی که نیاز به تضمین صحت و توضیح پذیری دارند، مانند پزشکی و امور مالی، محدود می سازد. در نهایت، کمبود مجموعه داده های رفتاری با وضوح زمانی بالا برای آموزش و اعتبارسنجی مدل ها مشکل ساز است. بسیاری از مجموعه داده های مورد استفاده در یادگیری ماشین، ایستا و برچسب گذاری شده برای خروجی های نهایی هستند، در

حالی که مدل‌های شناختی برای یادگیری از تعاملات پویا و برچسب‌گذاری‌های مبتنی بر خطا در زمان واقعی بهینه شده‌اند.

۸. پیشنهادات پژوهشی و صنعتی

با توجه به چالش‌ها و پتانسیل‌های شناسایی‌شده در برنامه‌نویسی شناختی با الهام از علوم اعصاب، مسیرهای مشخصی برای تحقیقات آینده و کاربردهای صنعتی قابل ترسیم است که می‌توانند این حوزه را به سطح عملیاتی بالاتری ارتقا دهند. در حوزه پژوهشی، تمرکز باید بر توسعه الگوریتم‌های یادگیری کاملاً زیست‌پذیر و مقیاس‌پذیر باشد. این امر نیازمند نوآوری در مکانیسم‌های تخصیص اعتبار است که بتوانند فاصله‌های زمانی طولانی را بدون نیاز به انتشار معکوس یا حافظه‌های بازگشتی (Recurrent Memories) پیچیده، مدیریت کنند. تحقیقات بیشتر بر مدل‌هایی که ترکیبی از STDP و سیگنال‌های دوپامینری را برای یادگیری تقویتی در SNN‌ها به کار می‌گیرند، باید اولویت یابد (Lillicrap et al., 2017). دومین پیشنهاد پژوهشی، همگرایی معماری‌های مدل‌های جهانی (World Models) و SNN‌ها است (Hassabis et al., 2017). توسعه مدل‌هایی که بتوانند با استفاده از دینامیک‌های عصبی اسپایکی، یک مدل داخلی قابل اعتماد از محیط بسازند که امکان برنامه‌ریزی پیشگامانه را فراهم آورد، بسیار مهم است. این سیستم‌ها باید از نظر محاسباتی سبک باشند تا بتوانند به طور مداوم در دنیای واقعی به‌روز شوند، که این امر مستقیماً به استفاده از سخت‌افزارهای عصبی مرتبط می‌شود.

در زمینه ابزارها، نیاز مبرمی به توسعه و استانداردسازی چارچوب‌های نرم‌افزاری وجود دارد که بتوانند به راحتی بین پلتفرم‌های شبیه‌سازی سطح بالا (مانند Brian2) و اجرای کم‌مصرف بر روی سخت‌افزارهای عصبی (مانند Lava) جابجا شوند (Davies et al., 2018). ایجاد یک زبان مدل‌سازی میانی (Intermediate Representation Language) که بتواند به طور خودکار مدل‌های زیست‌الهام را برای بهینه‌ترین سخت‌افزار کامپایل کند، می‌تواند موانع پیاده‌سازی را به شدت کاهش دهد. از منظر صنعتی، برنامه‌نویسی شناختی پتانسیل عظیمی در حوزه‌هایی دارد که نیاز به پردازش بلادرنگ و کارایی انرژی دارند. سیستم‌های حسگر لبه (Edge Sensing Systems)، مانند دوربین‌های کم‌مصرف یا حسگرهای صوتی که باید به صورت همیشه روشن (Always-On) عمل کنند، می‌توانند از SNN‌ها بهره ببرند. به جای ارسال داده‌ها به ابر برای پردازش سنگین، این سیستم‌ها می‌توانند با معماری‌های زیست‌الهام، تصمیمات اولیه را با حداقل مصرف انرژی اتخاذ کنند.

کاربرد دیگر در رباتیک و سیستم‌های کنترل پویا است. ربات‌هایی که از مدل‌های شناختی الهام گرفته از مکانیسم‌های تعادل و کنترل مغز استفاده می‌کنند، می‌توانند پاسخ‌های سریع‌تر و انعطاف‌پذیرتری به تغییرات غیرمنتظره محیط داشته باشند. استفاده از مدل‌های مبتنی بر پیش‌بینی در این ربات‌ها می‌تواند خطای حرکتی را کاهش داده و نیاز به تصحیح مداوم را به حداقل برساند (Rao & Ballard, 1999). در حوزه هوش مصنوعی تعاملی و رابط‌های مغز و ماشین (BMI)، مدل‌های زیست‌پذیر می‌توانند برای رمزگشایی و رمزگذاری سیگنال‌های عصبی با وفاداری زمانی بالاتر استفاده شوند. با درک دقیق‌تر چگونگی کدگذاری اطلاعات در اسپایک‌ها، می‌توان واسطه‌هایی طراحی کرد که تعامل طبیعی‌تر و کم‌تأخیرتری با کاربران داشته باشند. در نهایت، برای اعتبارسنجی صنعتی، لازم است که معیارهای زیست‌سنجی (Biomarker Metrics) به ابزارهای عملی تبدیل شوند. شرکت‌ها باید معیارهایی مانند "پایداری در برابر خرابکاری‌های

محلی" و "انعطاف‌پذیری در یادگیری وظایف جدید" را به عنوان شاخص‌های کلیدی عملکرد (KPIs) برای سیستم‌های شناختی در نظر بگیرند، نه فقط معیارهای سنتی دقت. این تغییر دیدگاه، توسعه را به سمت ساخت سیستم‌هایی سوق می‌دهد که از نظر رفتاری، شبیه‌تر به عامل‌های هوشمند طبیعی هستند.

۹. نتیجه‌گیری

برنامه‌نویسی شناختی با الهام از علوم اعصاب نشان‌دهنده یک افق جدید در طراحی سیستم‌های هوشمند است که سعی دارد از هوش بیولوژیکی به عنوان الگوی برتر محاسباتی بهره‌برد. این رویکرد از شبکه‌های عصبی مصنوعی سنتی فاصله گرفته و با اتکا به مدل‌های دینامیک نورون‌های اسپایکی، قوانین یادگیری محلی مانند STDP، و معماری‌های پیچیده‌ای که عملکرد حافظه، توجه و استدلال را مدل‌سازی می‌کنند، به دنبال خلق سیستمی است که نه تنها هوشمند باشد، بلکه کارآمد، انعطاف‌پذیر و سازگار باشد.

پیشرفت‌های اخیر در مدل‌سازی SNN ها و ظهور سخت‌افزارهای عصبی نشان می‌دهد که دستیابی به کارایی انرژی بی‌نظیر مغز در حوزه محاسبات، دیگر یک آرمان دور از دسترس نیست. مدل‌هایی که بر پایه اصول زیست‌پذیر بنا شده‌اند، مانند آن‌هایی که از سیستم‌های پیش‌بینی کدگذاری یا مدل‌های دوگانه شناختی الهام گرفته‌اند، پتانسیل حل مسائلی مانند یادگیری کم‌نمونه و استدلال علی را دارند که مدل‌های کنونی اغلب در آن‌ها ناکام می‌مانند. با این حال، مسیر پیش رو مملو از چالش‌هایی است که باید بر آن‌ها غلبه شود. پیچیدگی در آموزش SNN ها به دلیل ماهیت ناپیوسته سیگنال‌ها، دشواری در طراحی مکانیسم‌های تخصیص اعتبار بلندمدت و فقدان ابزارهای نرم‌افزاری استاندارد که به طور کامل از دینامیک‌های زمانی پشتیبانی کنند، موانع اصلی محسوب می‌شوند. آینده این حوزه مستلزم همکاری قوی‌تر میان علوم اعصاب، مهندسی نرم‌افزار و سخت‌افزار است. تحقیقات باید به سمت ایجاد پل‌های نظری مستحکم‌تری بین پدیده‌های سطح ماکرو شناختی و مکانیسم‌های سطح میکرو سیناپسی حرکت کند. در نهایت، موفقیت در این پارادایم نه تنها به ساخت سیستم‌های هوشمندتر منجر خواهد شد، بلکه بینش‌های عمیقی را درباره خود ماهیت هوش و عملکرد مغز انسان به ارمغان خواهد آورد.

منابع

- Baddeley, A. D., & Hitch, G. (1974). Working memory. *Psychological Review*, 82(4), 345-352.
- Davies, M., Trappenberg, G., Chen, N., Iniewski, K., Schemmel, J., Sze, W., & Chalkner, J. (2018). Loihi: A Neuromorphic Manycore Processor with Event-Driven Circuits. *IEEE Micro*, 38(1), 82-93.
- Gerstner, W., Kistler, W. M., Naud, R., & Paninski, L. (2014). *Neuronal Dynamics: From Single Neurons to Networks and Models of Cognition*. Cambridge University Press.
- Hassabis, D., Kumaran, D., Summerfield, C., & Botvinick, M. (2017). Neuroscience-Inspired Artificial Intelligence. *Neuron*, 95(2), 245-258.
- Hebb, D. O. (1949). *The Organization of Behavior: A Neuropsychological Theory*. Wiley.
- Hiller, J., Lang, S., & Wolterink, B. (2014). Brian2: A Python package for the user-friendly simulation of spiking neural networks. *Frontiers in Neuroinformatics*, 8, 257.

- Hines, M. L., Chang, H. S., Eden, U. T., & Hines, R. A. (2009). NEURON: A simulation program for the simulation of nerve cells and networks of neurons. *Neural Networks*, 22(1), 102-108.
- Izhikevich, E. M. (2003). *Dynamical Systems in Neuroscience: The Geometry of Excitability and Bursting*. MIT Press.
- Kahneman, D. (2011). *Thinking, Fast and Slow*. Farrar, Straus and Giroux.
- Lillicrap, T. P., Akerman, J., Ducommun, Y., & LeCun, Y. (2017). Nature's Hidden Lessons for Deep Learning. *arXiv preprint arXiv:1707.03075*.
- Lillicrap, T. P., Kleiman, J., Akerman, J., Ducommun, Y., & LeCun, Y. (2020). Backpropagation in Spiking Neural Networks. *arXiv preprint arXiv:2003.09177*.
- Rao, R. P. N., & Ballard, D. H. (1999). Predictive Coding in the Visual Cortex: A Mathematical Primer. *Neural Computation*, 11(4), 723-767.
- Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, Ł., & Polosukhin, I. (2017). Attention Is All You Need. *Advances in Neural Information Processing Systems (NIPS)*, 30.
- Wilson, H. R., & Cowan, J. D. (1972). Excitatory and inhibitory interactions in localized populations of model neurons. *Biophysical Journal*, 12(1), 1-24.