

بررسی انواع حافظه های شناختی

مقدمه و تعریف مساله

ما از حافظه اپیزودیک (که به آن حافظه رویدادی و ضمنی نیز اطلاق می شود) برای یادآوری وقایعی که خودمان تجربه کرده ایم استفاده می کنیم (Tulving, 1972). با این حال، در حالی که ممکن است رویدادهای اساسی و رابطه متوالی آنها را در یک قسمت به خاطر بیاوریم، نمی توانیم اطلاعات حسی دقیقی را که در طول رویداد تجربه کرده ایم را نیز به خاطر بیاوریم. در واقع، مطالعات تجربی نشان داده اند که حافظه اپیزودیک در انسان عمدتاً جوهر اصلی رویداد تجربه شده و تعداد کمی از جزئیات را حفظ می کند (Koutstaal & Schacter, 1997). این ویژگی سیستم حافظه اپیزودیک از این واقعیت ناشی می شود که قسمت ها بر حسب نمایش مرتبه بالاتر ورودی حسی ذخیره می شوند و نه خود ورودی حسی (Cheng et al, 2016; Fang et al, 2018) که با نظریه نمایه سازی ارائه شده توسط (Teyler & DiScenna, 1986) سازگار است (Gorler et al, 2020).

سوالاتی که همواره در جوامع علمی مطرح است این است که انسان ها و حیوانات چگونه هنگام حرکت بین دو مکان به طور مستقیم یک میانبر پیدا می کنند؟ دانشمندان یک نقشه شناختی را در مغز یک حیوان کشف کرده اند که به آن کمک می کند یک (مدل داخلی) از (محیط بیرونی) خود بسازد تا مسیر بهینه را ترسیم کند (Gauthier et al, 2020). مغز به دلیل توانایی اش در درک توالی های فضا-زمان، بسیار باهوش

است یعنی دارای توانایی یادآوری توالی زمانی و مکانی رویدادهای گذشته از طریق تحریک شناختی را دارد. این حافظه شناختی موقعیتی می‌تواند زمان، مکان، رویداد، رفتار و سایر دانش تجربیات گذشته را به هم متصل کند که مجموعه‌ای از تجربیات فردی در یک زمان و مکان خاص در گذشته را شکل می‌دهد (Gauthier et al, 2019). تحقیقات علوم اعصاب نشان می‌دهد که نقشه‌برداری مکانی-زمانی مربوط به شناخت قسمت ریشه در هیپوکامپ، یک ناحیه خاص از مغز دارد. هیپوکامپ در زیر قشر مغز قرار دارد و نقش حافظه اپیزودیک کوتاه مدت و بلندمدت، موقعیت یابی فضایی و ناوبری را ایفا می‌کند. هیپوکامپ نام خود را از این واقعیت گرفته است که شکل آن شبیه اسب دریایی است. هیپوکامپ از سیستم شناختی اپیزودیک برای کاوش در فضا و زمان استفاده می‌کند تا "نقشه شناختی اپیزودیک" را تشکیل دهد، که می‌تواند برای استنتاج و حافظه استفاده شود. این «نقشه داخلی» به ارگانیسم‌ها اجازه می‌دهد تا با شبیه‌سازی احتمالات از طریق مغزشان پیش‌بینی کنند. مشخص شد که موش‌ها پس از آسیب به هیپوکامپ مغز در یافتن مکان‌های فضایی سکوه‌های مخفی در پیچ و خم‌های آبی مشکل داشتند (Yuan et al, 2023). دسته خاصی از "سلول‌های مکان" در مطالعات هیپوکامپ موش شناسایی شد، و این نورون‌ها زمانی فعال‌تر می‌شوند که موش در یک مکان خاص در محیط قرار دارد. محققان پاسخ موقعیت دیگری را از سلول‌ها در قشر انتورینال و هیپوکامپ در نزدیکی آن پیدا کردند. اگر فضای فعالیت به یک مثلث متساوی الاضلاع تقسیم شود، سلول‌ها می‌توانند در چندین مکان تخلیه شوند. سلول‌ها همیشه در موش‌ها در تخلیه رأس مثلث متساوی الاضلاع خواهند بود. از این رو، محققان آنها را "سلول‌های شبکه" نامیدند (Hafting et al, 2005). این مساله، نوعی رمز در نظر گرفته می‌شود که اساس عصبی "نقشه

شناختی" را تشکیل می‌دهد. سلول‌های دیگر نیز نقش اساسی در محلی‌سازی دارند: سلول‌های "پاداش"، برای مثال، پاداش‌های خاص مکان را بر اساس اطلاعات محیطی رمزگذاری می‌کنند. برخی دیگر سرعت و جهت حیوان را ردیابی می‌کنند، دقیقاً مانند سرعت‌سنج و قطب‌نمای مغز که می‌تواند پیشرفت کامل حیوان را هنگام کاوش در محیط خود محاسبه کند. هنگامی که حیوان به لبه نقشه نزدیک می‌شود، سلول دیگری فعال می‌شود که به "سلول‌های مرزی" معروف است (Yoo et al, 2021). در تحقیقات ناوبری بیونیک موجود، برخی از اتصال، فاصله، یا احتمال انتقال سلول‌های موقعیت برای هدایت رفتار فضایی هدف گرا استفاده می‌کنند. علاوه بر این، محاسبه برداری فضایی بین موقعیت‌ها با شبیه‌سازی کدگذاری فضایی سلول‌های شبکه انجام می‌شود، و ناوبری از طریق آموزش ترکیبی با شبکه‌های عصبی تحقق می‌یابد. از نظر استراتژی‌های ناوبری بیونیک، عمدتاً دو الگو وجود دارد: ناوبری توپولوژیکی با استفاده از سلول‌های مکان و ناوبری برداری با استفاده از سلول‌های شبکه (Yuan et al, 2023).

از سوی دیگر در زمینه‌ی جهانی شدن و فناوری، لجستیک با چالش‌های فزاینده‌ای مواجه است. بهره‌وری لجستیک، کاهش هزینه، و ایمنی و دقت حمل و نقل از خواسته‌های مهم هستند. مکان‌یابی و نقشه‌برداری همزمان (SLAM) یک فناوری یادگیری عمیق کلیدی برای ربات‌های متحرک است تا پس از ورود به محیط‌های پیچیده، به محلی‌سازی و ناوبری مستقل دست یابند که این روش از حافظه‌ی شناختی به عنوان کلید اصلی فعالیت خود استفاده میکند. در سال‌های اخیر، SLAM به تدریج به یک موضوع داغ در رباتیک تبدیل شده است (Shoukat et al, 2024). محققان در سراسر جهان راه‌حل‌های SLAM زیادی از جمله SLAM مبتنی بر گراف را پیشنهاد کرده‌اند که مسئله را به تخمین حداکثر احتمال تبدیل

می‌کند و یکی از مؤثرترین روش‌ها در نظر گرفته می‌شود (Fang et al, 2021). SLAM مبتنی بر نمودار، محیط را به صورت نموداری با گره‌هایی که موقعیت‌های ربات را نشان می‌دهند و نشانه‌ها و لبه‌هایی که محدودیت‌ها را نشان می‌دهند، بررسی میکند. ربات نمودار را با مشاهده ویژگی‌هایی در مسیر خود می‌سازد. تشخیص حلقه بسته کلید تحقق بهینه‌سازی نمودار در SLAM و یک نقطه دشوار در مسئله SLAM است. تشخیص حلقه بسته مناسب می‌تواند خطای انباشته کیلومتر شمار را برای به دست آوردن یک نقشه ثابت برطرف کند. از سوی دیگر، نتایج اشتباه تشخیص حلقه بسته، بهینه‌سازی نقشه بعدی را به هم می‌زند، که در ایجاد نقشه شکست خواهد خورد. رباتیک نیاز مبرمی به فناوری SLAM در زمان واقعی و با دقت بالا دارد که اخیراً رشد انفجاری را تجربه کرده است. برای تحقق حرکت مستقل، یک ربات باید توانایی درک صحنه اطراف و موقعیت آن در صحنه را داشته باشد که همگی نیازمند حافظه‌ی شناختی است. سیستم SLAM فعلی عمدتاً بر حسگرهایی مانند دوربین‌ها، واحد اندازه‌گیری اینرسی، LiDAR و غیره متکی است. Kundu و همکاران (۲۰۰۹) روشی را برای تشخیص حالت های ساکن یا متحرک اشیا با استفاده از محدودیت‌ها و حسگرهای هندسی چند نمای پیشنهاد کرد. همچنین (Wei et al, 2020) یک روش مبتنی بر مدل حرکت دوربین برای الگوریتم SLAM دید دوچشمی مبتنی بر حذف ناحیه پویا پیشنهاد کرد. در حال حاضر، رویکرد SLAM رادار لیزری دوبعدی می‌تواند به سرعت یک نقشه شبکه دو بعدی ایجاد کند. استفاده از LiDAR SLAM سه بعدی و SLAM بصری نیاز به طرح‌ریزی ابر نقطه فضایی تولید شده برای به دست آوردن یک نقشه شبکه دو بعدی دارد. مطالعه‌ی (Han, 2023) نیز اشاره کرد که SLAM به ربات‌ها کمک می‌کند تا به صورت پویا در محیط‌های پیچیده

۳ بعدی، مکان‌یابی و بومی‌سازی شوند. آنها یک سیستم ربات لجستیک هوشمند چندوجهی را پیشنهاد می‌کنند که CNN سه بعدی و SLAM بصری را برای برنامه‌ریزی و کنترل مسیر ترکیب می‌کند (Shoukat et al, 2024). همه‌ی این مطالعات بر اهمیت رباتیک شناختی و نقش حافظه‌ی شناختی در سیستم‌های هوشمند دارند.

بر اساس موارد بیان شده میتوان نتیجه گرفت که حافظه شناختی، به عنوان یک ابزار مهم در پردازش اطلاعات، نقش بسیار حیاتی در توانایی‌های شناختی انسان مانند یادگیری، استدلال، و ادراک ایفا می‌کند. دیدگاه‌های سنتی در مورد حافظه، آن را به عنوان یک ذخیره‌ساز ثابت و غیرپویا توصیف می‌کردند. اما در دیدگاه‌های جدیدتر که بر پایه تئوری‌های شناختی مدرن است، حافظه به عنوان یک سیستم پویا در نظر گرفته می‌شود که قادر است با انعطاف‌پذیری بالا به تغییرات محیطی واکنش نشان دهد. این پویایی در حافظه معنایی، به سیستم شناختی این امکان را می‌دهد تا اطلاعات دریافتی را با توجه به شرایط مختلف محیطی پردازش کند و به شیوه‌ای مناسب پاسخ دهد. چنین دیدگاهی نه تنها شناخت ما از حافظه را تغییر داده است، بلکه اهمیت این حافظه را در طراحی سیستم‌های هوشمند افزایش می‌دهد. در سیستم‌های هوشمند، حافظه شناختی از نوع حافظه کاری برای انجام وظایف پیچیده‌ی شناختی از جمله یادگیری، پردازش زبان و استدلال اهمیت بالایی دارد. این حافظه به عنوان یکی از مهم‌ترین عناصر سیستم‌های هوش مصنوعی عمل می‌کند، چرا که بسیاری از فرایندهای شناختی بر پایه آن صورت می‌گیرد. نقش عملیاتی حافظه شناختی به این معنا است که می‌تواند همچون پلی بین توابع شناختی و

توانایی زبانی عمل کند، که این خود باعث شبیه‌سازی رفتارهای پیچیده‌تر حافظه و پردازش اطلاعات در سیستم‌های هوشمند می‌شود.

از طرفی، شبیه‌سازی حافظه کاری انسان با استفاده از معماری‌های هوش مصنوعی مدرن، از جمله شبکه‌های عصبی، به ما این امکان را می‌دهد که ماژول‌های غشای مغزی انسان را تقلید کنیم و به یک حافظه پویا و انعطاف‌پذیر دست یابیم. این معماری‌ها به سیستم‌های هوشمند اجازه می‌دهند تا حافظه کاری را به طور موثرتری در فعالیتهای شناختی مانند پردازش زبان طبیعی و درک معنایی به کار بگیرند. بنابراین، درک عمیق‌تر از حافظه شناختی و بهره‌گیری از آن در معماری سیستم‌های هوشمند، امکان بهبود قابل توجهی در عملکرد این سیستم‌ها به وجود می‌آورد. به‌کارگیری حافظه شناختی در معماری‌های رباتیک نیز تاثیر مستقیمی در کیفیت تعاملات زبانی ربات‌ها دارد. سیستم‌های هوشمند با استفاده از این حافظه می‌توانند فرایندهای پیچیده‌تر زبانی را مدیریت کنند و با دقت بیشتری به تعامل با محیط بپردازند. برای مثال، ربات‌هایی که از حافظه شناختی پویا استفاده می‌کنند، قادر خواهند بود تعاملات زبانی پیچیده‌تری را اجرا کنند و به پرسش‌ها و دستورات با دقت و فهم بیشتری پاسخ دهند.

بنابراین با توجه به اینکه حافظه شناختی به عنوان یکی از کلیدی‌ترین بخش‌های شناخت انسان شناخته می‌شود، شبیه‌سازی آن در سیستم‌های هوشمند می‌تواند به ایجاد سیستم‌های هوش مصنوعی پیشرفته‌تر و با قابلیت‌های شناختی بیشتر منجر شود.

در نتیجه، این تحقیق بر این است که با بررسی معماری‌های موجود در سیستم‌های هوشمند و تلفیق آن‌ها با دیدگاه‌های مدرن حافظه شناختی، به شناخت سیستم‌های هوشمند با قابلیت‌های زبانی و شناختی

دست یابد. این تحقیق به روشن کردن نقش عملیاتی حافظه شناختی در بهبود عملکرد سیستم‌های هوشمند می‌پردازد و چالش‌ها و فرصت‌های این مسیر را نیز بررسی می‌کند.

تاریخچه تئوری‌های شناختی و مدل‌های محاسباتی آن‌ها

تئوری‌های شناختی به عنوان یکی از ستون‌های اصلی علوم شناختی، نقش برجسته‌ای در فهم فرایندهای ذهنی و رفتاری انسان ایفا کرده‌اند. این تئوری‌ها در طی قرن گذشته به طور مداوم تکامل یافته‌اند و از دیدگاه‌های سنتی ادراک و حافظه به سمت مفاهیم پیچیده‌تری مانند شناخت توزیع‌شده و بدن‌مند حرکت کرده‌اند. با شناخت تاریخچه این تئوری‌ها، پژوهشگران به درک بهتری از نحوه عملکرد ذهن انسان و ارتباط آن با محیط رسیده‌اند. در نتیجه، این تئوری‌ها به عنوان پایه‌ای برای پیشرفت‌های جدید در علوم شناختی و فناوری‌های مرتبط با آن، از جمله رباتیک شناختی، مورد استفاده قرار گرفته‌اند. رباتیک شناختی به‌طور مستقیم از تئوری‌های شناختی بهره‌برداری می‌کند تا ربات‌ها را قادر سازد رفتارها و فرایندهای شناختی مشابه انسان‌ها را انجام دهند. اخیراً، تقاضای اجتماعی برای تبدیل ربات به شرکای اجتماعی انسان به سرعت در حال افزایش است. برای این منظور، ربات‌ها باید محیط را درک کنند، شرایط اطراف را درک کنند، با مردم ارتباط برقرار کنند و به‌طور ایمن در محیط مشابه با انسان حرکت کنند. این امر به‌ویژه در زمینه‌هایی مانند تعامل با محیط، یادگیری از طریق تجربیات، و تصمیم‌گیری در شرایط پیچیده قابل مشاهده است. با استفاده از مدل‌های محاسباتی تئوری‌های شناختی، مانند شبکه‌های عصبی و سیستم‌های چندعاملی، می‌توان ربات‌هایی طراحی کرد که نه تنها محیط خود را درک می‌کنند، بلکه

توانایی تطبیق با تغییرات محیطی و یادگیری از تجربیات گذشته را دارند (Kumar et al, 2021; Shimoda et al, 2022).

شناخت تاریخچه و اصول این تئوری‌ها به ما کمک می‌کند تا به نحوی پیشرفته‌تر به طراحی و پیاده‌سازی ربات‌های شناختی بپردازیم. به عنوان مثال، با درک مفاهیم حافظه شناختی پویا و تاثیر محیط بر تصمیم‌گیری‌های شناختی، می‌توانیم ربات‌هایی با قابلیت‌های پیشرفته‌تر از جمله درک زبانی و حل مسائل پیچیده طراحی کنیم. این فهم به‌ویژه در ربات‌های اجتماعی و کاربردهای هوش مصنوعی پیشرفته، که نیاز به تعامل مستمر با انسان و محیط دارند، بسیار مهم است.

تئوری پردازش اطلاعات (Information Processing Theory)

تئوری پردازش اطلاعات یکی از تئوری‌های شناختی برجسته است که ذهن انسان را به‌عنوان یک سیستم پردازش اطلاعات شبیه به یک کامپیوتر توصیف می‌کند. این تئوری در دهه‌های ۱۹۵۰ و ۱۹۶۰ شکل گرفت و بر این اساس است که اطلاعات از طریق حواس به سیستم وارد می‌شود، در حافظه ذخیره می‌شود و سپس پردازش می‌گردد. این تئوری چندین مرحله مختلف پردازش از جمله دریافت اطلاعات، رمزگذاری، ذخیره‌سازی، بازیابی و خروجی را شامل می‌شود. در این فرایند، حافظه کاری نقش کلیدی ایفا می‌کند و به عنوان مکانی که اطلاعات موقتی پردازش می‌شود، عمل می‌کند (Swanson, 1987).

این تئوری به‌طور گسترده در تحقیقات روان‌شناسی شناختی به‌کار گرفته شده است و به توضیح چگونگی عملکرد حافظه، ادراک، توجه و حل مسئله پرداخته است. یکی از نقاط قوت اصلی تئوری پردازش اطلاعات، ساختار ساده و انعطاف‌پذیری آن در مدلسازی فرایندهای شناختی است که به‌طور مداوم قابل بهبود و تکمیل است. در مدل‌های محاسباتی مرتبط با این تئوری، الگوریتم‌هایی طراحی می‌شوند که به پردازش اطلاعات به‌طور مشابه با ذهن انسان می‌پردازند. این مدل‌ها در زمینه‌های مختلف از جمله هوش مصنوعی، پردازش زبان طبیعی و طراحی رابط‌های کاربری استفاده می‌شوند. مدل‌های رایج شامل شبکه‌های عصبی مصنوعی و سیستم‌های مبتنی بر عامل هستند که هر کدام به نوعی فرایند پردازش اطلاعات را شبیه‌سازی می‌کنند (Simon, 1978). از جمله چالش‌های این تئوری، این است که گرچه می‌تواند بسیاری از فرایندهای شناختی را توضیح دهد، اما هنوز نمی‌تواند تمام پیچیدگی‌های رفتار انسانی را به‌طور کامل مدلسازی کند. به‌ویژه، تعامل‌های اجتماعی و احساسی که اغلب در رفتارهای انسانی نقش دارند، به‌سختی در چارچوب این تئوری گنجانده می‌شوند.

تئوری دوگانه (Dual-Process Theory)

تئوری دوگانه به فرایندهای تفکر انسان اشاره دارد و بیان می‌کند که دو سیستم اصلی در تصمیم‌گیری و پردازش اطلاعات نقش دارند. سیستم اول به‌صورت سریع و خودکار عمل می‌کند و سیستم دوم آهسته‌تر و متفکرانه‌تر است. سیستم اول غالباً در تصمیم‌گیری‌های روزمره و بدون نیاز به تمرکز بالا استفاده می‌شود، در حالی که سیستم دوم در موقعیت‌هایی که نیاز به تحلیل و بررسی دقیق‌تر دارند، فعال می‌شود.

سیستم اول اغلب به عنوان شهودی و غیرمنطقی توصیف می‌شود و به تجارب گذشته و الگوهای از پیش موجود وابسته است. این سیستم می‌تواند بسیار مؤثر باشد اما به همان اندازه نیز ممکن است دچار سوگیری‌ها و اشتباهات شود. از سوی دیگر، سیستم دوم مبتنی بر منطق و تحلیل است و اغلب برای حل مسائل پیچیده به کار می‌رود. مدل‌های محاسباتی مرتبط با این تئوری به بررسی چگونگی تصمیم‌گیری‌های انسان می‌پردازند و در طراحی سیستم‌های تصمیم‌یار هوش مصنوعی کاربرد دارند. این مدل‌ها معمولاً شامل شبکه‌های عصبی عمیق هستند که به‌طور خودکار از تجربیات قبلی یاد می‌گیرند و در صورت نیاز می‌توانند به‌صورت تحلیلی‌تر عمل کنند. چالش‌های این تئوری بیشتر در توضیح تعاملات بین دو سیستم است؛ چگونه و چه زمانی یک سیستم به جای دیگری به کار گرفته می‌شود و چه عواملی بر این تغییر تاثیر دارند. همچنین، تعیین مرزهای دقیق بین این دو سیستم همچنان موضوع بحث‌های علمی است (Wixted, 2007; Posner, 2020; Koban & Banks, 2023).

تئوری طرحواره‌ها (Schema Theory)

تئوری طرحواره‌ها به‌عنوان یکی از تئوری‌های اساسی در شناخت انسان، به نحوه‌ی ذخیره و سازماندهی اطلاعات در حافظه می‌پردازد. طرحواره‌ها واحدهای سازمان‌یافته‌ای از دانش هستند که به ما کمک می‌کنند تا اطلاعات جدید را به‌صورت منطقی پردازش کنیم. این تئوری بر این باور است که اطلاعات جدید در قالب طرحواره‌های از پیش موجود جذب یا تعدیل می‌شود. طرحواره‌ها به‌عنوان الگوهای ذهنی به ما کمک می‌کنند تا جهان را درک کنیم و بر اساس تجربه‌های گذشته پیش‌بینی کنیم. یکی از

کاربردهای مهم این تئوری در حوزه‌ی آموزش و یادگیری است، جایی که یادگیری موثر نیازمند پیوند دانش جدید به طرحواره‌های از پیش موجود است. همچنین در زمینه‌های روانشناسی شناختی و اجتماعی برای توضیح رفتارهای انسانی مانند تفکر قالبی و پیش‌داوری‌ها مورد استفاده قرار می‌گیرد. در مدل‌های محاسباتی، این تئوری در طراحی سیستم‌های مبتنی بر دانش و همچنین در پردازش زبان طبیعی استفاده می‌شود. سیستم‌های هوشمند که از این تئوری بهره می‌برند، می‌توانند اطلاعات جدید را با توجه به داده‌های گذشته تفسیر کنند و به این ترتیب یادگیری موثرتر و پردازش سریع‌تری داشته باشند (Arkin et al, 1997; Zushu & Guiping, 2003).

تئوری شبکه معنایی (Semantic Network Theory)

تئوری شبکه معنایی بر اساس این فرضیه است که دانش در ذهن به صورت شبکه‌ای از گره‌ها و پیوندها ذخیره شده است. گره‌ها نشان‌دهنده‌ی مفاهیم یا واحدهای اطلاعاتی هستند و پیوندها ارتباطات بین این گره‌ها را نشان می‌دهند. این شبکه به ما کمک می‌کند تا اطلاعات را به صورت سلسله‌مراتبی و معنایی سازمان‌دهی کنیم و هنگام نیاز آن را بازیابی کنیم. برای مثال، مفهوم "پرند" ممکن است به مفاهیمی مانند "پر"، "پرواز" و "آشیانه" مرتبط باشد. در مدل‌های محاسباتی، این تئوری برای طراحی سیستم‌های هوش مصنوعی که قادر به پردازش زبان طبیعی هستند، مورد استفاده قرار می‌گیرد. شبکه‌های معنایی در بازیابی اطلاعات، ترجمه‌ی ماشینی و تحلیل متن به کار می‌روند. این مدل‌ها به سیستم‌ها کمک می‌کنند تا ارتباطات بین مفاهیم مختلف را تشخیص دهند و به شکلی منطقی اطلاعات را سازماندهی کنند.

چالش‌های مرتبط با این تئوری شامل نحوه‌ی تعریف دقیق روابط بین گره‌ها و همچنین انعطاف‌پذیری شبکه در برابر اطلاعات جدید است. همچنین، ایجاد شبکه‌های معنایی که بتوانند تعاملات پیچیده بین مفاهیم را به‌خوبی بازتاب دهند، کار ساده‌ای نیست (Rapaport, 1996; Sarthou et al, 2019; Sarica & Luo, 2021).

تئوری بار شناختی (Cognitive Load Theory)

تئوری بار شناختی بر این بنا شده است که حافظه کاری انسان محدود است و در مواجهه با اطلاعات بیش از حد ممکن است عملکرد شناختی فرد کاهش یابد. این تئوری ابتدا در زمینه‌ی آموزش توسعه داده شد و بر چگونگی طراحی مواد آموزشی که حافظه کاری را بیش از حد مشغول نکند تمرکز دارد. بر اساس این تئوری، اطلاعات باید به شکلی ارائه شوند که فرد قادر به پردازش و ذخیره‌سازی آن در حافظه بلندمدت باشد. در مدل‌های محاسباتی، این تئوری در طراحی رابط‌های کاربری و سیستم‌های آموزشی هوشمند کاربرد دارد. سیستم‌هایی که بر پایه‌ی این تئوری طراحی شده‌اند، تلاش می‌کنند تا بار شناختی کاربران را به حداقل برسانند و تجربه کاربری را بهبود بخشند. چالش‌های این تئوری شامل اندازه‌گیری دقیق بار شناختی در موقعیت‌های واقعی و همچنین توسعه روش‌های آموزشی که بتوانند به‌طور کارآمد حافظه کاری را به‌کار گیرند، می‌باشد (Mason & Cooper, 2013; Spatola et al, 2022).

تئوری شناخت توزیع شده (Distributed Cognition Theory)

تئوری شناخت توزیع شده بیان می کند که فرایندهای شناختی انسان تنها در مغز فرد اتفاق نمی افتند، بلکه این فرایندها بین مغز انسان، ابزارها، محیط و افراد دیگر توزیع شده اند. این تئوری بر این باور است که شناخت در تعامل با محیط و دیگران اتفاق می افتد و به این ترتیب، ابزارهای فیزیکی و دیجیتالی می توانند بخشی از سیستم شناختی باشند. برای مثال، یک ابزار هوشمند یا نرم افزار می تواند به عنوان بخشی از حافظه کاری فرد عمل کند و اطلاعاتی را که فرد به آن ها نیاز دارد، در دسترس قرار دهد. در مدل های محاسباتی، تئوری شناخت توزیع شده در طراحی سیستم های چندعاملی (Multi-Agent Systems) و سیستم های تعاملی مورد استفاده قرار می گیرد. این سیستم ها تلاش می کنند تا فرایندهای شناختی را به صورت توزیع شده بین عامل ها و کاربران تسهیل کنند. از این رو، این تئوری در توسعه هوش مصنوعی و سیستم های اطلاعاتی کاربردهای فراوانی دارد (Deitrick et al, 2015; Hutchins, 2020).

تئوری شناخت موقعیتی (Situated Cognition Theory)

تئوری شناخت موقعیتی بیان می کند که شناخت در ارتباط با محیط و شرایط خاصی شکل می گیرد و نمی توان آن را به صورت کاملاً انتزاعی در نظر گرفت. این تئوری تأکید دارد که یادگیری و شناخت همیشه در یک بستر خاص و مرتبط با محیط اتفاق می افتد و افراد با استفاده از دانش خود در موقعیت های واقعی، مهارت های جدیدی کسب می کنند. در مدل های محاسباتی، این تئوری برای طراحی سیستم های یادگیری و رباتیک به کار می رود. سیستم هایی که براساس این تئوری طراحی شده اند، محیط های واقع گرایانه ای را شبیه سازی می کنند تا به کاربران و ربات ها اجازه دهند که در شرایط واقعی به یادگیری بپردازند. به ویژه

در رباتیک، مدل‌های شناخت موقعیتی به ربات‌ها کمک می‌کنند تا در محیط‌های پیچیده و پویا عملکرد مؤثری داشته باشند (Cobb & Bowers, 1999).

تئوری شناخت بدن‌مند (Embodied Cognition Theory)

تئوری شناخت بدن‌مند بیان می‌کند که شناخت انسان نه تنها به مغز، بلکه به بدن و تعامل آن با محیط وابسته است. این تئوری معتقد است که بدن انسان نقش کلیدی در فرایندهای شناختی دارد و مفاهیم شناختی از طریق تجربیات جسمی و حسی شکل می‌گیرند. در مدل‌های محاسباتی، این تئوری در توسعه سیستم‌های رباتیک پیشرفته و همچنین رابط‌های کاربری فیزیکی به کار می‌رود. ربات‌هایی که بر پایه‌ی این تئوری طراحی می‌شوند، از تعامل مستقیم با محیط و استفاده از تجربیات جسمی برای بهبود یادگیری و تصمیم‌گیری استفاده می‌کنند (Brouillet et al, 2010; Sullivan, 2018).

تئوری گشتالت (Gestalt Theory)

تئوری گشتالت یکی از قدیمی‌ترین تئوری‌های شناختی است که بر ادراک کلی و الگوهای ذهنی تمرکز دارد. این تئوری بر این اصل استوار است که انسان‌ها تمایل دارند اطلاعات را به صورت الگوهای کامل و

یکپارچه

درک کنند

نه به‌عنوان

عناصر


جداگانه.

گشتالت در

بسیاری از



(a)



(b)




(c)

و



(d)



(e)



(f)

فرایندهای شناختی مانند ادراک بصری و حل مسئله کاربرد دارد.

شکل ۱: نمونه‌ای از شکل‌های مبتنی بر تئوری گشتالت که برای آموزش شبکه‌های عصبی و رباتیک قابل استفاده است

(Amanatiadis et al, 2018)

در مدل‌های محاسباتی، تئوری گشتالت در طراحی الگوریتم‌های پردازش تصویر و تحلیل الگوها به کار گرفته می‌شود. این مدل‌ها به سیستم‌های هوشمند کمک می‌کنند تا الگوهای پیچیده را به‌طور خودکار تشخیص دهند و به تحلیل اطلاعات پرداخته و آن‌ها را به‌صورت کلی درک کنند (Mungan, 2023; Amanatiadis et al, 2018).

تئوری کارکرد اجرایی (Executive Function Theory)

تئوری کارکرد اجرایی به مجموعه‌ای از فرایندهای شناختی اشاره دارد که مسئول کنترل رفتار، تصمیم‌گیری و حل مسئله هستند. این کارکردها شامل توجه، برنامه‌ریزی، حافظه کاری و کنترل شناختی می‌شوند. این تئوری توضیح می‌دهد که چگونه انسان‌ها می‌توانند به‌طور مؤثر اهداف خود را پیگیری کنند و رفتارهای خود را در مواجهه با چالش‌ها تنظیم کنند. مدل‌های محاسباتی مبتنی بر تئوری کارکرد اجرایی در توسعه هوش مصنوعی استفاده می‌شوند که توانایی مدیریت وظایف پیچیده و تصمیم‌گیری در شرایط ناپایدار را دارند. این مدل‌ها به‌ویژه در رباتیک و سیستم‌های تصمیم‌یار به کار گرفته می‌شوند تا

عملکردهای اجرایی را در محیط‌های پیچیده شبیه‌سازی کنند (Di Lieto et al, 2017; Berggvist et al, 2023).

تئوری پردازش دوگانه (Dual Coding Theory)

تئوری پردازش دوگانه بیان می‌کند که اطلاعات به دو شکل مجزا، یعنی به صورت کلامی و بصری پردازش می‌شوند. این تئوری نشان می‌دهد که انسان‌ها بهتر می‌توانند اطلاعات را یاد بگیرند و به خاطر بیاورند اگر این اطلاعات به صورت تصویری و زبانی ارائه شود. این تئوری به‌ویژه در زمینه‌ی آموزش و یادگیری بسیار مفید است. در مدل‌های محاسباتی، این تئوری در طراحی سیستم‌های چندرسانه‌ای و رابط‌های کاربری کاربرد دارد. مدل‌های هوش مصنوعی که بر اساس پردازش دوگانه کار می‌کنند، می‌توانند اطلاعات را هم به صورت تصویری و هم زبانی پردازش کنند و تجربه‌ی کاربری بهتری ارائه دهند (Wang & Wu, 2022; Turuk, 2019).

تئوری پردازش موازی (Parallel Distributed Processing Theory)


تئوری پردازش موازی توزیع شده (PDP) بیان می کند که پردازش اطلاعات در مغز به صورت همزمان و موازی در شبکه های عصبی انجام می شود. این تئوری تأکید دارد که یادگیری و حافظه نتیجه ی تغییرات

وزن های اتصال

نورون ها است.

در

بین



شکل ۲: نمونه ای از پردازش موازی. شکل A از جسمی که با یک زاویه خاص می چرخد تشکیل شده است، و نتایج نمایش آن نیز با یک زاویه خاص چرخانده می شود که می توان مشاهده کرد که دارای تغییرناپذیری چرخش است. با این حال، نتایج نمایش در میان اشیاء مختلف بسیار متفاوت است و توزیع های متفاوتی را در فضای ویژگی جهت گیری ارائه می دهد که در شکل B نشان داده شده است (Wei et al, 2023).

در مدل‌های محاسباتی، این تئوری اساس توسعه شبکه‌های عصبی مصنوعی است که از معماری‌های مشابه مغز انسان استفاده می‌کنند. این مدل‌ها می‌توانند اطلاعات را به‌صورت موازی پردازش کنند و در زمینه‌های مختلف مانند یادگیری عمیق و شبیه‌سازی شناخت انسان کاربرد دارند (Wei et al, 2023).

انواع حافظه‌های شناختی و بررسی دستاوردها و چالش‌های شبیه‌سازی‌های انجام شده برای

هر یک

حافظه‌های شناختی نقش بسیار مهمی در فهم و تفسیر اطلاعات و تصمیم‌گیری‌های پیچیده در انسان‌ها ایفا می‌کنند. این حافظه‌ها به‌طور معمول به چندین دسته تقسیم می‌شوند که هر یک نقش متفاوتی در فرایندهای شناختی و ادراکی دارند. حافظه‌ی شناختی، که شامل حافظه‌ی کاری، حافظه‌ی اپیزودیک (رویدادی) و حافظه‌ی معنایی است، به ما این امکان را می‌دهد تا اطلاعات را ذخیره، پردازش، و بازیابی کنیم. هر نوع از این حافظه‌ها دارای ویژگی‌ها و کاربردهای خاصی هستند و درک آن‌ها برای طراحی سیستم‌های هوشمند و ربات‌های شناختی که توانایی پردازش و تفسیر اطلاعات را دارند، حیاتی است. در طی چند دهه‌ی گذشته، تلاش‌های بسیاری برای شبیه‌سازی حافظه‌های شناختی به منظور پیاده‌سازی در سیستم‌های هوشمند و رباتیک انجام شده است. شبیه‌سازی این حافظه‌ها به پژوهشگران کمک کرده

تا عملکرد مغز انسان را بهتر درک کنند و بتوانند سیستم‌هایی را طراحی کنند که از قابلیت‌های شناختی مشابه بهره ببرند. یکی از چالش‌های اصلی در این حوزه، دقت در شبیه‌سازی حافظه و توانایی انتقال این دانش به سیستم‌های مصنوعی است. این تلاش‌ها از جمله در شبیه‌سازی حافظه‌ی کاری و حافظه‌ی بلندمدت بسیار مفید بوده‌اند و بسیاری از دستاوردهای پیشرفته را به ارمغان آورده‌اند.

با این حال، شبیه‌سازی حافظه‌های شناختی با چالش‌های متعددی همراه است. از جمله این چالش‌ها می‌توان به پیچیدگی‌های ساختاری و فرایندی مغز انسان، محدودیت‌های محاسباتی، و همچنین مسائل مربوط به تطابق این حافظه‌ها با محیط‌های واقعی اشاره کرد. طراحی معماری‌هایی که بتوانند این نوع حافظه‌ها را به‌طور دقیق و مؤثر شبیه‌سازی کنند، همچنان به عنوان یک موضوع پژوهشی فعال در حوزه‌های رباتیک شناختی و هوش مصنوعی مطرح است. بسیاری از مدل‌های محاسباتی کنونی همچنان تلاش می‌کنند تا به سطحی از شبیه‌سازی نزدیک شوند که بتواند رفتارهای پیچیده انسانی را تقلید کند. با بررسی دستاوردها و چالش‌های شبیه‌سازی حافظه‌های شناختی، می‌توان به چشم‌اندازهای جدیدی برای توسعه سیستم‌های هوشمند دست یافت. در این بخش از پایان‌نامه، تلاش خواهیم کرد تا انواع مختلف حافظه‌های شناختی را به‌طور دقیق بررسی کنیم و به چالش‌های شبیه‌سازی آن‌ها در حوزه‌های مختلف بپردازیم. همچنین دستاوردهای کنونی در این حوزه و تلاش‌های پژوهشی برای بهبود شبیه‌سازی این نوع حافظه‌ها را تحلیل خواهیم کرد.

۱,۳. حافظه‌ی معنایی (Semantic Memory)

اینکه افراد چگونه دانش مفاهیم را بازنمایی می‌کنند، یکی از مهم‌ترین پرسش‌ها در تحقیقات حافظه معنایی و علوم شناختی است. بنابراین، تحقیقات قابل توجهی بر روی حافظه معنایی انسان بر روی مسائل مربوط به بازنمایی حافظه متمرکز شده و سه دسته از مدل‌های متمایز را به وجود آورده است: مدل‌های شبکه انجمنی، مدل‌های مبتنی بر ویژگی، و مدل‌های معنایی توزیعی. این بخش یک نمای کلی از این مدل‌ها را ارائه می‌کند، و همچنین برخی بحث‌های مهم در مورد بازنمایی حافظه را که این مدل‌ها در این زمینه ایجاد کرده‌اند، مورد بحث قرار می‌دهد. یکی دیگر از سؤالات اساسی مرتبط در تحقیقات حافظه معنایی در مورد یادگیری مفاهیم است و بقیه این بخش بر مدل‌های معنایی متمرکز است که با دو مکانیسم روانشناختی گسترده (یادگیری بدون خطا و مبتنی بر خطا) که به عنوان زیربنای آن مطرح شده‌اند. یادگیری بازنمایی معنا رویکردهای مبتنی بر شبکه برای حافظه ذهنی دارای سنت طولانی و غنی است که ریشه در روانشناسی و علوم رایانه دارد. به عنوان مثال (Collins & Quillian, 1969) بررسی کردند که چگونه افراد از طریق حافظه معنایی برای تأیید صحت جملات (مثلاً زمان صرف شده برای تأیید اینکه یک کوسه <باله دارد>) استفاده می‌کنند، و دریافتند که زمان بازیابی با سازماندهی سلسله مراتبی سازگارتر است. شبکه حافظه که در آن گره‌ها، کلمات را نشان می‌دهند، و پیوندها یا لبه‌ها، گزاره‌های معنایی در مورد کلمات را نشان می‌دهند (به عنوان مثال، ماهی توسط یک پیوند "است" به حیوان متصل می‌شود، و ماهی نیز ویژگی‌های خاص خود را دارد مانند <باله دارد> و <می‌تواند شنا کند>). توضیح مکانیکی این یافته‌ها از طریق یک چارچوب فعال‌سازی گسترده انجام شد (Quillian, 1969, 1967)، که بر اساس آن گره‌های منفرد در شبکه فعال می‌شوند، که به نوبه خود منجر به فعال

شدن گره‌های همسایه می‌شود و شبکه تا زمانی که به گره یا گزاره مورد نظر برسد، ادامه می‌یابد. جالب توجه است، تعداد مراحل انجام شده برای پیمودن مسیر در شبکه حافظه پیشنهادی، زمان صرف شده برای تأیید یک جمله در مدل اصلی کالینز و کویلیان (۱۹۶۹) را پیش‌بینی می‌کرد. با این حال، مدل اصلی نمی‌تواند تأثیرات معمولی را توضیح دهد (به عنوان مثال، چرا افراد سریع‌تر به «پرنده کبوتر یک پرنده است» در مقایسه با «شترمرغ یک پرنده است»، و همچنین در توضیح تفاوت‌ها در تأخیرها با مشکلاتی مواجه شدند. جملات "کاذب" (به عنوان مثال، چرا افراد در رد "پروانه <پرنده> است" در مقایسه با "دلفین <پرنده> است" کندتر هستند). محققان بعداً یک مدل شبکه تجدید نظر شده را پیشنهاد کردند که در آن پیوندهای بین کلمات، قدرت رابطه را منعکس می‌کند و در نتیجه ساختار سلسله مراتبی را از مدل اصلی حذف می‌کند تا الگوهای رفتاری را بهتر توضیح دهد. این چارچوب فعال سازی شبکه/گسترش به طور گسترده برای تئوری‌های کلی تر زبان، حافظه و حل مسئله به کار گرفته شد (Anderson, 2000). مدل‌های مبتنی بر شبکه‌های محاسباتی حافظه معنایی در دهه گذشته، به دلیل محبوبیت اخیر رویکردهای نظری گراف و علوم شبکه برای مدل‌سازی فرآیندهای شناختی، کشش قابل توجهی پیدا کرده‌اند. رویکردهای مبتنی بر شبکه مدرن از پایگاه‌های داده در مقیاس بزرگ برای ساخت شبکه‌ها و گرفتن روابط در مقیاس بزرگ بین گره‌های داخل شبکه استفاده می‌کنند. این رویکرد برای مطالعه تجربی شبکه جهانی وب، سیستم‌های بیولوژیکی و زبان استفاده شده است. در مطالعه حافظه معنایی (Steyvers & Tenenbaum, 2005) این رویکرد را با ساختن سه شبکه معنایی مختلف با استفاده

از هنجارهای همبستگی آزاد در مقیاس بزرگ آغاز کردند. آنها چندین تحلیل ارائه کردند تا نشان دهند که شبکه‌های معنایی دارای یک "ساختار دنیای کوچک" هستند.

مطالعات دیگر در این زمینه تأثیر معیارهای شبکه معنایی را بر اختلالات روانشناختی، خلاقیت و شخصیت بررسی کرده است. علیرغم موفقیت شبکه‌های معنایی مدرن در پیش‌بینی عملکرد شناختی، تردیدهایی در این زمینه در مورد استفاده از هنجارهای انجمن آزاد برای ایجاد بازنمایی شبکه وجود دارد. به طور خاص، مشخص نیست که آیا آثار شبکه‌ای که از هنجارهای تداعی ساخته شده‌اند، واقعاً یک گزارش بازنمایی از حافظه معنایی هستند یا صرفاً محصول یک فرآیند مبتنی بر بازیابی را بر روی بازنمایی زیربنایی حافظه معنایی منعکس می‌کنند (Kumar, 2021).

تحقیقات حافظه معنایی منجر به توسعه سه مدل اصلی برای بازنمایی دانش مفاهیم در ذهن انسان شده است: مدل‌های شبکه انجمنی، مدل‌های مبتنی بر ویژگی، و مدل‌های معنایی توزیعی. هر یک از این مدل‌ها رویکرد متفاوتی به چگونگی سازماندهی و پردازش اطلاعات در ذهن دارند. مدل‌های شبکه انجمنی بر اساس شبکه‌های مفاهیم و روابط معنایی میان آن‌ها ساخته می‌شوند. در این مدل‌ها، گره‌های شبکه نمایانگر مفاهیم هستند و پیوندهای میان گره‌ها نشان‌دهنده ارتباطات معنایی میان مفاهیم می‌باشند. مدل‌های مبتنی بر ویژگی، مفاهیم را به‌عنوان مجموعه‌ای از ویژگی‌ها و صفات در نظر می‌گیرند که با یکدیگر ترکیب شده و یک مفهوم خاص را شکل می‌دهند. در مدل‌های توزیعی، اطلاعات معنایی به صورت گسترده و پراکنده در شبکه‌های نورونی مصنوعی یا زیستی ذخیره می‌شود و با الگوهای فعال‌سازی عصبی ارتباط دارند (Saumier & Chertkow, 2002; Yee et al, 2018).

در رباتیک شناختی، حافظه معنایی نقش مهمی در پردازش زبان طبیعی و تعامل با محیط ایفا می‌کند. ربات‌ها برای انجام وظایف شناختی پیچیده مانند درک زبانی، تشخیص اشیا و تصمیم‌گیری‌های هوشمندانه، نیازمند دسترسی به حافظه معنایی هستند. حافظه معنایی به ربات‌ها این امکان را می‌دهد تا مفاهیم را درک کرده و بین آن‌ها ارتباط برقرار کنند، اطلاعات عمومی را بازیابی کرده و از آن‌ها برای انجام وظایف استفاده کنند. در واقع، حافظه معنایی می‌تواند به‌عنوان یک پل بین ورودی‌های ادراکی ربات‌ها (مانند بینایی و شنیداری) و عملکردهای زبانی و شناختی آن‌ها عمل کند. به همین دلیل، مدل‌سازی دقیق و شبیه‌سازی حافظه معنایی در ربات‌های شناختی به‌منظور ایجاد تعاملات هوشمندانه و طبیعی ضروری است (Sarhou et al, 2019, Ho et al, 2010). شبیه‌سازی حافظه معنایی در ربات‌ها به کمک ابزارهای مختلفی انجام می‌شود، که از جمله آن‌ها می‌توان به شبکه‌های عصبی مصنوعی و سیستم‌های مبتنی بر دانش اشاره کرد. شبکه‌های عصبی مصنوعی به دلیل شباهت ساختاری با نورون‌های مغزی، یکی از رایج‌ترین روش‌ها برای شبیه‌سازی حافظه معنایی هستند. این شبکه‌ها می‌توانند اطلاعات معنایی را به صورت توزیعی و پراکنده ذخیره کنند و با استفاده از الگوریتم‌های یادگیری عمیق، مفاهیم جدید را یاد بگیرند. از سوی دیگر، سیستم‌های مبتنی بر دانش با استفاده از پایگاه‌های داده بزرگ و قواعد منطقی، قادر به شبیه‌سازی روابط معنایی میان مفاهیم و بازنمایی دانش عمومی هستند (Huang et al, 2023).

با وجود پیشرفت‌های قابل توجه در شبیه‌سازی حافظه معنایی، چالش‌های بسیاری در این زمینه وجود دارد. یکی از این چالش‌ها، مسئله پیچیدگی و گستردگی اطلاعات معنایی است. حافظه معنایی انسان

بسیار پیچیده و چندوجهی است و بازنمایی دقیق آن در سیستم‌های هوشمند نیازمند پردازش حجم عظیمی از داده‌ها و دانش عمومی است. علاوه بر این، نیاز به توانایی درک مفاهیم جدید و سازگاری با تغییرات محیطی نیز یکی دیگر از چالش‌های شبیه‌سازی حافظه معنایی در ربات‌ها است. این مسائل موجب می‌شوند تا توسعه سیستم‌های هوشمند با حافظه معنایی پویا و سازگار بسیار پیچیده و زمان‌بر باشد. یکی از راهکارهای پیشرفته برای غلبه بر چالش‌های شبیه‌سازی حافظه معنایی، استفاده از سیستم‌های هوشمند تطبیقی است که قادرند به صورت پویا و براساس تجربیات جدید، حافظه معنایی خود را به‌روزرسانی کنند. این سیستم‌ها می‌توانند با استفاده از تکنیک‌های یادگیری تقویتی و عمیق، از تعاملات خود با محیط و کاربران، مفاهیم جدید را یاد بگیرند و به‌صورت خودکار شبکه معنایی خود را گسترش دهند. به این ترتیب، ربات‌های هوشمند می‌توانند نه تنها به دانش‌های موجود دسترسی داشته باشند، بلکه به مرور زمان دانش و توانایی‌های خود را ارتقا دهند و بهتر با محیط‌های جدید سازگار شوند (French et al, 2023).

حافظه معنایی نقش مهمی در بهبود تعاملات انسان و ربات ایفا می‌کند. با داشتن حافظه معنایی قوی، ربات‌ها قادر به درک بهتر مفاهیم زبانی و ارائه پاسخ‌های دقیق‌تر به کاربران خواهند بود. این امر به‌ویژه در کاربردهای رباتیک اجتماعی که تعاملات طبیعی و پیچیده میان انسان و ربات‌ها اهمیت دارد، بسیار مفید است. ربات‌های مجهز به حافظه معنایی می‌توانند به سوالات کاربران با دقت بیشتری پاسخ دهند، روابط معنایی میان مفاهیم را درک کنند و به طور کلی تعاملات خود را با کاربران بهبود بخشند. این

مسئله می‌تواند نقش مهمی در توسعه ربات‌های شخصی و همراه ایفا کند (Wei, 2013; Meger et al, 2008).

یکی از مهم‌ترین تفاوت‌ها میان حافظه معنایی انسان و ماشین، نحوه یادگیری و بازنمایی اطلاعات است. حافظه معنایی انسان به طور طبیعی از طریق تجربه‌های حسی و شناختی شکل می‌گیرد و ارتباطات پیچیده میان مفاهیم به تدریج و با استفاده از تجربیات فرد ایجاد می‌شود. در مقابل، حافظه معنایی ماشین‌ها بیشتر بر اساس داده‌های از پیش موجود و الگوریتم‌های پردازشی ایجاد می‌شود. این تفاوت موجب می‌شود تا حافظه معنایی انسان به مراتب انعطاف‌پذیرتر و قابل سازگاری‌تر با محیط‌های پویا باشد، در حالی که حافظه معنایی ماشین‌ها به‌طور مستقیم وابسته به داده‌های ورودی و الگوریتم‌های یادگیری آن‌ها است.

با پیشرفت فناوری‌های هوش مصنوعی و یادگیری ماشین، انتظار می‌رود که شبیه‌سازی حافظه معنایی در ربات‌های هوشمند بهبود یابد. سیستم‌های آینده قادر خواهند بود به صورت پویا و با استفاده از تجربیات جدید، شبکه‌های معنایی پیچیده‌تری ایجاد کنند و با دقت بیشتری اطلاعات معنایی را پردازش کنند. این پیشرفت‌ها می‌توانند منجر به توسعه ربات‌هایی با توانایی‌های شناختی پیشرفته‌تر، از جمله درک زبانی بهتر و تعاملات اجتماعی کارآمدتر، شوند. از این رو، حافظه معنایی همچنان یکی از حوزه‌های کلیدی در توسعه رباتیک شناختی به‌شمار می‌آید (Garg et al, 2020).

۲,۳. حافظه‌ی کاری (Working Memory)

آیا می‌توان توانایی‌های شناختی مانند استدلال را از طریق آموزش حافظه فعال بهبود بخشید؟ این سوال هنوز به شدت بحث‌برانگیز است، زیرا مطالعات قبلی یافته‌های متناقضی را ارائه می‌دهند. فقدان رویکردهای تئوری محور و سیستمی و کاستی‌های روش‌شناختی این بحث را بیش از پیش پیچیده می‌کند (Von Bastian & Oberauer, 2014).

در سال‌های اخیر، بحث شدیدی در مورد اثربخشی آموزش حافظه کاری رایانه‌ای (WM) مطرح شده است. WM یک سیستم شناختی است که دسترسی موقت به بازنمایی‌های مورد نیاز برای شناخت پیچیده در لحظه حال را فراهم می‌کند. حد ظرفیت فردی این توانایی به‌عنوان یک ویژگی تا حد زیادی پایدار فرض می‌شود، و تحقیقات قبلی رابطه قوی بین ظرفیت WM و چندین توانایی شناختی دیگر را نشان داده‌اند (Barrett et al, 2004). به طور خاص، ظرفیت WM به عنوان یکی از بهترین پیش‌بینی کننده‌ها برای هوش شناخته شده است. از طرف دیگر، اختلالات WM اغلب در شرایط عصبی مانند اختلال بیش فعالی کمبود توجه یا ناتوانی‌های یادگیری مشاهده می‌شود. چندین مطالعه در واقع افزایش نمرات استدلال را به دنبال اشکال مختلف آموزش WM گزارش کردند، که نشان می‌دهد هوش سیال - که تاکنون تصور می‌شد یک ویژگی ثابت است - در نهایت می‌تواند انعطاف‌پذیر باشد (Jaeggi et al., 2010). تغییر در عملکرد شناختی را می‌توان با دو مکانیسم کلی واسطه کرد: افزایش ظرفیت WM یا افزایش کارایی WM (Von Bastian & Oberauer, 2014).

علیرغم باورهای رایج، WM مترادف حافظه کوتاه مدت (STM) نیست. مناطق عصبی اختصاص داده شده به هر دو احتمالاً در مجاورت یکدیگر هستند، اما STM فقط یک مکانیسم حفظ است، در حالی که WM داده‌های ذخیره شده را دستکاری هم می‌کند. WM یک حافظه فعال است که مسئول نگهداری اطلاعات مربوطه در یک ذخیره موقت است و آنها را در دسترس فرآیندهای شناختی قرار می‌دهد تا وظیفه‌ای را که در حال حاضر انجام می‌شود تکمیل کند (Baddeley, 2012). اطلاعات به لطف قابلیت‌های خودتحریکی نواحی عصبی مرتبط با WM به صورت فعال حفظ می‌شود. فرض بر این است که چند قطعه (حداکثر هفت قطعه) از اطلاعات را می‌توان همزمان در حافظه فعال نگه داشت. محتوای WM برای سایر فرآیندهای شناختی قابل دسترسی است، اما نمی‌توان آزادانه آن را بازنویسی کرد. به روزرسانی و نوشتن آن محتوا توسط یک سیگنال تنظیم می‌شود (Persiani et al, 2018).

به طور خلاصه این حافظه به افراد اجازه می‌دهد اطلاعات را برای مدت کوتاهی حفظ و دستکاری کنند تا فعالیت‌های پیچیده‌تر شناختی انجام شود. در بسیاری از موارد، حافظه کاری به عنوان فضای موقتی در نظر گرفته می‌شود که در آن اطلاعات ذخیره و پردازش می‌شود تا نتایج نهایی به دست آید. این ویژگی باعث می‌شود که حافظه کاری به عنوان یکی از عوامل اصلی در سیستم‌های شناختی هوشمند، از جمله رباتیک، مورد توجه قرار گیرد (Persiani et al, 2018).

یکی از مدل‌های مهم حافظه کاری، مدل چندبخشی بدلی (Baddeley's multi-component model) است که شامل سه بخش اصلی است: حلقه آوایی، اسکچ‌پد فضایی دیداری و سیستم اجرایی مرکزی. حلقه آوایی برای پردازش و ذخیره اطلاعات صوتی و زبانی استفاده می‌شود، در حالی که اسکچ‌پد فضایی دیداری

برای پردازش و ذخیره اطلاعات بصری و فضایی به کار می‌رود. سیستم اجرایی مرکزی به عنوان یک مدیر عمل می‌کند که منابع شناختی را تخصیص داده و فرآیندهای اجرایی را هماهنگ می‌کند. این مدل به دلیل قابلیت توصیف تعاملات مختلف در حافظه کاری، به عنوان یکی از پایه‌های اصلی برای شبیه‌سازی‌های شناختی در سیستم‌های هوشمند استفاده می‌شود (Gruszka-Gosiewska & Orzechowski, 2016).

ارتباط حافظه کاری با رباتیک در توانایی سیستم‌های رباتیک برای انجام وظایف پیچیده و چندمرحله‌ای است. برای مثال، در یک سناریوی رباتیک که نیاز به تصمیم‌گیری سریع و دقیق دارد، حافظه کاری می‌تواند به ربات کمک کند تا اطلاعات محیطی را به صورت موقت ذخیره و از آن برای انجام عملیات‌های بعدی استفاده کند. این مسئله به ویژه در مواردی که ربات باید به داده‌های چندمنظوره پاسخ دهد و به طور همزمان چندین وظیفه را مدیریت کند، حائز اهمیت است. بنابراین، شبیه‌سازی حافظه کاری در رباتیک به عنوان یک گام اساسی در توسعه سیستم‌های رباتیک پیشرفته با قابلیت‌های شناختی در نظر گرفته می‌شود (Gordon et al, 2006; Sousa Silva & Williams, 2024).

راهکارهای شبیه‌سازی حافظه کاری اغلب بر پایه شبکه‌های عصبی مصنوعی استوار هستند. برای مثال، شبکه‌های عصبی بازگشتی (RNN) به دلیل قابلیت حفظ و پردازش اطلاعات متوالی، به عنوان یکی از ابزارهای اصلی برای شبیه‌سازی حافظه کاری مورد استفاده قرار می‌گیرند. این شبکه‌ها می‌توانند دنباله‌ای از اطلاعات را به صورت دینامیک پردازش کنند و از اطلاعات قبلی برای به‌روزرسانی وضعیت فعلی استفاده

کنند. در اینجا، چالش اصلی حفظ اطلاعات گذشته و تصمیم‌گیری بر اساس آن‌ها است که با ساختارهای بازگشتی در RNN به خوبی شبیه‌سازی می‌شود (Zou et al, 2021).

یکی دیگر از روش‌های شبیه‌سازی حافظه کاری در رباتیک استفاده از مدل‌های شناختی هیبریدی است که در آن‌ها از ترکیب شبکه‌های عصبی مصنوعی و مدل‌های کلاسیک حافظه کاری برای ایجاد سیستمی با قابلیت پردازش چندوظیفه‌ای استفاده می‌شود. این مدل‌ها تلاش می‌کنند تا تعاملات پیچیده‌ای را که در حافظه کاری انسان رخ می‌دهد، با استفاده از محاسبات مصنوعی به دقت شبیه‌سازی کنند. این رویکرد هیبریدی امکان پردازش همزمان اطلاعات صوتی، بصری و اجرایی را فراهم می‌کند و در نتیجه سیستم‌های رباتیک با قابلیت‌های شناختی بالاتر ایجاد می‌شوند (De Jager, 2020). چالش‌های شبیه‌سازی حافظه کاری در رباتیک عمدتاً به دلیل پیچیدگی‌های موجود در تعاملات چندگانه بین اجزای مختلف حافظه کاری است. برای مثال، یکی از چالش‌های مهم، شبیه‌سازی درست سیستم اجرایی مرکزی است که باید بتواند اطلاعات را به درستی مدیریت و تخصیص منابع را بهینه کند. این مسئله به ویژه در سناریوهای پیچیده رباتیک، مانند ربات‌های اجتماعی یا صنعتی که نیاز به پردازش همزمان اطلاعات مختلف دارند، اهمیت پیدا می‌کند. علاوه بر این، محدودیت‌های ظرفیت حافظه کاری نیز یکی از چالش‌های دیگر در شبیه‌سازی‌های رباتیک است. در انسان، حافظه کاری دارای ظرفیت محدودی برای ذخیره و پردازش اطلاعات است و یکی از مسائل مهم در شبیه‌سازی این است که چگونه می‌توان این محدودیت‌ها را به گونه‌ای پیاده‌سازی کرد که سیستم رباتیک نیز با محدودیت‌های مشابه مواجه شود. این موضوع به پژوهش‌های بیشتری در زمینه چگونگی بهینه‌سازی حافظه کاری در سیستم‌های هوشمند نیاز دارد. در

نهایت، رویکردهای آینده در شبیه‌سازی حافظه کاری به سمت استفاده از سیستم‌های هوش مصنوعی چندعاملی متمایل است که در آن‌ها چندین عامل مستقل می‌توانند به طور همزمان با استفاده از حافظه کاری مشترک به تعامل بپردازند. این سیستم‌ها قابلیت هماهنگی بین عوامل مختلف و انجام وظایف پیچیده‌تر را فراهم می‌کنند و از این رو می‌توانند در سناریوهای رباتیک پیچیده مانند ربات‌های هماهنگ‌سازی شده در محیط‌های صنعتی یا اجتماعی به کار گرفته شوند (Persiani et al, 2018).

۳,۳. حافظه‌ی اپیزودیک یا رویدادی (Episodic Memory)

مطالعه حافظه اپیزودیک در اوایل دهه ۱۹۷۰ آغاز شد، زمانی که روانشناس اندل تولوینگ^۱ برای اولین بار بین حافظه اپیزودیک و معنایی تمایز قائل شد (Tulving, 1972). در آن زمان حافظه اپیزودیک (EM) بر حسب مواد و وظایف تعریف می‌شد. تولوینگ حافظه اپیزودیک را به‌عنوان تجربیات ما از اپیزودهای معین مکانی-زمانی (مثلاً آخرین سفر کاری ما) و دانش عمومی ما (ترجمه‌های زبانی، حقایق مانند «قلم چیست» و غیره) را به‌عنوان حافظه معنایی (SM) مشخص کرد. با این حال، پیشنهاد او مبنی بر اینکه حافظه اپیزودیک و معنایی دو سیستم حافظه از نظر عملکردی متفاوت هستند، به سرعت بحث برانگیز شد. امروزه، حافظه اپیزودیک به عنوان یکی از سیستم‌های حافظه عصبی شناختی اصلی دیده می‌شود

^۱ Endel Tulving

که بر اساس عملکردهای ویژه آن (آنچه سیستم انجام می‌دهد یا تولید می‌کند) و پیوندهای مناسب آن (نحوه انجام آن) تعریف می‌شود.

این حافظه ویژگی‌های مشترک زیادی با حافظه معنایی دارد، که از آن رشد یافته است، اما همچنین دارای ویژگی‌هایی است که حافظه معنایی ندارد (Tulving & Markowitsch, 1998). جهت‌گیری حافظه اپیزودیک به گذشته به گونه‌ای است که هیچ نوع سیستم حافظه دیگری در آن وجود ندارد. این تنها سیستم حافظه‌ای است که به افراد اجازه می‌دهد آگاهانه گذشته خود را دوباره تجربه کنند در نتیجه رابطه خاص و منحصر به فردی با زمان دارد. روانشناسان بعدی، حافظه اپیزودیک را در پیش گرفته و سعی کردند برای این مفهوم در سیستم‌های بیولوژیکی شواهدی بیابند. آزمایش‌ها بر روی بیماران مبتلا به فراموشی نشان داد که حافظه اپیزودیک عمدتاً مربوط به لوب تمپورال داخلی و ساختارهای هیپوکامپ است (Squire et al, 1993). مغز از مقادیر زیادی حافظه برای ایجاد مدلی از جهان استفاده می‌کند. هر آنچه که شخص می‌داند و آموخته است در این مدل ذخیره می‌شود. مغز از این مدل مبتنی بر حافظه برای پیش‌بینی مداوم رویدادهای آینده استفاده می‌کند. اگر این پیش‌بینی‌ها رد شوند، مغز یاد می‌گیرد و حافظه‌های خود را با توجه به داده‌های جدید تنظیم می‌کند. به نظر می‌رسد حافظه در یک سلسله مراتب سازماندهی شده است، هر سطح مسئول یادگیری بخش کوچکی از مدل کلی است. به عنوان مثال (Kanerva, 1988) یک مدل حافظه پراکنده توزیع شده (SDM) را پیشنهاد کرد که بسیاری از ویژگی‌های حافظه انسانی را ارائه می‌دهد. او همچنین یک مدل ریاضی برای این نظریه ایجاد کرد. در طول دهه

گذشته علاقه فزاینده ای به مکانیسم‌های حافظه اپیزودیک در مهندسی و علوم کامپیوتر مشاهده شده است (Jockel et al, 2008).

چندین مدل نظری برای توضیح ساختار و عملکرد حافظه رویدادی پیشنهاد شده است. مدل اولیه تولویگ حافظه رویدادی را از حافظه معنایی متمایز می‌کند و بر طبیعت شخصی و زمینه‌ای خاطرات رویدادی تمرکز دارد. دیگر مدل‌ها، مانند نظریه ردیابی چندگانه (MTT)، بیان می‌کنند که هر بازیابی خاطره یک ردیابی جدید ایجاد می‌کند و در نتیجه یک شبکه پیچیده و پویا از خاطرات شکل می‌گیرد. نظریه سیستم‌های یادگیری مکمل (CLS) نیز پیشنهاد می‌دهد که حافظه رویدادی شامل هم هیپوکامپ برای یادگیری سریع و هم نئوکورتکس برای یکپارچه‌سازی تدریجی اطلاعات است. این مدل‌ها به عنوان بنیانی برای تلاش‌های مربوط به شبیه‌سازی عملکردهای حافظه رویدادی در سیستم‌های هوش مصنوعی، به ویژه در حوزه رباتیک، مطرح شده‌اند. ادغام حافظه رویدادی در رباتیک به هدف بهبود توانایی ربات‌ها در تعامل با محیط و تصمیم‌گیری به شیوه‌ای مشابه انسان انجام می‌شود. با تجهیز ربات‌ها به سیستم‌هایی که حافظه رویدادی را شبیه‌سازی می‌کنند، آن‌ها قادر خواهند بود تجربیات گذشته را به یاد آورده و از آن‌ها برای بهبود تصمیم‌گیری و تطبیق رفتار خود با محیط استفاده کنند. به عنوان مثال، یک ربات می‌تواند به یاد بیاورد که چگونه یک کار خاص را در یک محیط مشابه انجام داده و از آن دانش در یک موقعیت جدید استفاده کند. این قابلیت به ربات‌ها امکان می‌دهد که از اشتباهات خود یاد بگیرند و عملکرد خود را در محیط‌های پویا بهبود بخشند (Cheng, 2024; Zeng et al, 2023).

شبیه‌سازی حافظه رویدادی در ربات‌ها معمولاً شامل الگوریتم‌های پیشرفته و معماری‌های حافظه‌ای است که عملکرد مغز انسان را تقلید می‌کنند. شبکه‌های عصبی، به‌ویژه شبکه‌های عصبی بازگشتی (RNN)، اغلب برای مدیریت دینامیک‌های زمانی مرتبط با حافظه رویدادی به کار می‌روند. RNN‌ها قادر به ذخیره دنباله‌های رویدادها هستند و از این رو برای تقلید از یادآوری تجربیات رویدادی مناسب هستند. روش‌های دیگر شامل مدل‌های ترکیبی هستند که بازنمایی‌های نمادین و غیرنمادین را برای شبیه‌سازی هر دو جنبه ساختاری و تجربی حافظه ترکیب می‌کنند. ترکیب این مدل‌های مبتنی بر هوش مصنوعی با سیستم‌های کنترلی رباتیک، توانسته است توانایی‌های ربات‌ها را در وظایفی که نیاز به یادگیری و تصمیم‌گیری مبتنی بر حافظه دارند، بهبود بخشد (Yang et al, 2021; Chin et al, 2022).

یکی از چالش‌های بزرگ در شبیه‌سازی حافظه رویدادی در ربات‌ها، پیچیدگی حافظه انسانی است. حافظه رویدادی نه تنها شامل یادآوری اطلاعات واقعی است، بلکه زمینه، احساسات و روابط مرتبط با رویدادها را نیز در بر می‌گیرد. شبیه‌سازی این ابعاد چندگانه در یک ماشین نیازمند الگوریتم‌های پیچیده‌ای است که بتوانند ابعاد زمانی، فضایی و احساسی حافظه را تقلید کنند. علاوه بر این، محدودیت‌های محاسباتی چالش دیگری را مطرح می‌کند. ذخیره و پردازش حجم عظیمی از اطلاعات مورد نیاز برای حافظه رویدادی در زمان واقعی، منابع زیادی را می‌طلبد و سیستم‌های رباتیک کنونی ممکن است با این سطح از پیچیدگی مشکل داشته باشند.

سیستم‌های حافظه رویدادی در ربات‌ها باید دو وظیفه حیاتی را مدیریت کنند: ذخیره‌سازی و بازیابی. چالش در این است که خاطرات را به گونه‌ای سازماندهی کنند که به‌طور مؤثری ذخیره شوند و در زمان

مناسب و به شکلی صحیح بازیابی شوند. یکی از راهکارها برای حل این مسئله، استفاده از تکنیک‌های فشرده‌سازی حافظه است که حجم اطلاعات ذخیره‌شده را با تمرکز بر جزئیات اساسی کاهش می‌دهد. الگوریتم‌های بازیابی حافظه نیز به گونه‌ای طراحی شده‌اند که بتوانند پایگاه داده تجربیات گذشته ربات را جستجو کرده و خاطراتی را که بیشترین ارتباط با نیازهای فعلی دارند، شناسایی کنند. با این حال، بهبود این تکنیک‌ها همچنان یک موضوع پژوهشی فعال است. حافظه رویدادی نقش مهمی در توانایی ربات‌ها برای یادگیری از تجربیات و تطبیق با محیط‌های جدید ایفا می‌کند. الگوریتم‌های یادگیری در این فرآیند حیاتی هستند، زیرا به ربات‌ها اجازه می‌دهند که سیستم‌های حافظه خود را بر اساس تجربیات جدید به‌روزرسانی و اصلاح کنند. یادگیری تقویتی (RL)، که ربات‌ها از طریق آزمون و خطا یاد می‌گیرند، می‌تواند با استفاده از حافظه رویدادی بهبود یابد، زیرا ربات قادر خواهد بود موفقیت‌ها و شکست‌های گذشته را به یاد آورده و تصمیمات دقیق‌تری بگیرد. ادغام حافظه رویدادی با چارچوب‌های RL یکی از نویدبخش‌ترین رویکردها برای بهبود یادگیری تطبیقی در سیستم‌های رباتیک است (Yang et al, 2021; Jockel et al, 2007).


نقش حافظه در پردازش پیش‌بینانه (Predictive Processing) در رباتیک شناختی

پردازش پیش‌بینانه به یکی از چارچوب‌های تأثیرگذار در علوم شناختی تبدیل شده است. یکی از ویژگی‌های تعریف‌کننده پردازش پیش‌بینانه این است که «... ادراک، شناخت و عمل را به عنوان محصولی به‌هم‌پیوسته از یک نوع فرآیند استنتاجی واحد توصیف می‌کند» (Clark, 2018, p. 522). این ایده تأثیر عمیقی بر مدل‌ها و نظریه‌های مختلف در جوامع پژوهشی، از علوم اعصاب تا روان‌شناسی، مدل‌سازی محاسباتی و رباتیک شناختی گذاشته است. در متون، اصطلاحاتی مانند «پردازش پیش‌بینانه»، «پردازش پیش‌بینانه سلسله‌مراتبی»، «استنتاج فعال»، «کدگذاری پیش‌بینانه» و «اصل انرژی آزاد» اغلب به‌طور جایگزین استفاده می‌شوند. پژوهشگران به این اصطلاحات گاهی به‌عنوان نظریه و گاهی به‌عنوان چارچوب اشاره می‌کنند و گاه ایده‌های اصلی آن‌ها را با هم ترکیب می‌کنند.

در رباتیک شناختی، چندین معماری و مدل ادعا کرده‌اند که از اصول این چارچوب‌ها پیروی می‌کنند. پژوهش‌ها در حوزه رباتیک شناختی به درک و مدل‌سازی ادراک، شناخت و عمل در عامل‌های مصنوعی می‌پردازند. عامل‌ها از طریق تعاملات بدنی با محیط خود، انتظار می‌رود که یاد بگیرند و سپس قادر باشند وظایف شناختی را به صورت خودمختار انجام دهند (Lara et al., 2018). پردازش پیش‌بینانه پیشنهاد می‌کند که تصویر سنتی ادراک را وارونه کند (Clark, 2015). تصویر استاندارد از پردازش ادراکی عمدتاً به جریان از پایین به بالا اطلاعات متکی است که از گیرنده‌های حسی منتقل می‌شود. در این تصویر از ادراک، با بالا رفتن اطلاعات، تصویری غنی‌تر از جهان ساخته می‌شود؛ به‌طوری که از یک لایه ویژگی‌های سطح پایین که ورودی ادراکی را پردازش می‌کند به لایه معنایی سطح بالا که اطلاعات را تفسیر می‌کند می‌رسد.

پردازش پیش‌بینانه ادعا می‌کند که ادراک، شناخت و عمل را تحت یک دامنه توضیحی واحد یکپارچه می‌کند. دیدگاه پردازش پیش‌بینانه از ادراک بیان می‌کند که عامل‌ها به طور مداوم و فعالانه تحرکات حسی را پیش‌بینی می‌کنند و تنها انحرافات از ورودی حسی پیش‌بینی‌شده (خطاهای پیش‌بینی) به صورت از پایین به بالا پردازش می‌شوند. خطای پیش‌بینی اطلاعات حسی ارزشمند و جدیدی است که بازخورد اصلاحی درباره پیش‌بینی‌های از بالا به پایین ارائه می‌دهد و موجب یادگیری می‌شود. بنابراین، در این دیدگاه از ادراک، جریان اصلی اطلاعات از بالا به پایین است و جریان از پایین به بالا اطلاعات حسی جایگزین جریان از پایین به بالا خطای پیش‌بینی می‌شود. عملکرد اصلی مغز به حداقل رساندن خطای پیش‌بینی است. این فرآیند به عنوان حداقل‌سازی خطای پیش‌بینی (Prediction Error Minimization) یا (PEM) شناخته شده است. به طور کلی، PEM به عنوان یک طرح در بسیاری از الگوریتم‌های یادگیری ماشین استفاده شده است، که در آن، خطای بین خروجی مطلوب و خروجی تولید شده توسط شبکه برای یادگیری استفاده می‌شود (برای نمونه، الگوریتم‌های پس‌انتشار خطا در آموزش شبکه‌های عصبی را ببینید). استراتژی‌های مختلف PEM در مدل‌های ادراک و کنترل عمل در عامل‌های مصنوعی به کار گرفته شده‌اند.

فراتر از این، پردازش پیش‌بینانه پیشنهاد می‌کند که مغز عضوی فعال است که به طور مداوم توضیحاتی درباره ورودی‌های حسی ایجاد کرده و سپس این فرضیه‌ها را با اطلاعات حسی ورودی مقایسه می‌کند، به شیوه‌ای که با دیدگاه هلمهولتز درباره ادراک به عنوان نوعی استنتاج ناخودآگاه سازگار است (Ciria et



(al, 2021).

شکل ۳: نمایش شماتیک پیام عصبی سلسله‌مراتبی تحت اصول پردازش پیش‌بینانه (Ciria et al, 2021)

بر اساس اصول پردازش پیش‌بینانه، تعاملات عصبی تکرارشونده با پیش‌بینی‌های نزولی و خطاهای پیش‌بینی صعودی در بخشی ساده‌شده از سلسله‌مراتب قشری در شکل بالا قسمت A نشان داده شده است. فعالیت عصبی سلول‌های هرمی عمقی (نمایش داده‌شده با رنگ سیاه) در لایه‌های بالاتر قشر،

باورهای قبلی را درباره وضعیت‌های پیش‌بینی‌شده سلول‌های هرمی سطحی (نمایش داده‌شده با رنگ قرمز) در لایه‌های پایین‌تر رمزگذاری می‌کنند. در هر سطح قشری، باورهای قبلی فعالیت عصبی محتمل‌تر را در سطوح پایین‌تر رمزگذاری می‌کنند. سلول‌های هرمی سطحی پیش‌بینی‌های نزولی را با شواهد حسی صعودی مقایسه می‌کنند که در نهایت به چیزی که به عنوان خطای پیش‌بینی شناخته می‌شود، منجر می‌شود. خطای پیش‌بینی در سلول‌های هرمی سطحی به سلول‌های هرمی عمقی ارسال می‌شود تا باورها به‌روز شوند (باور پسین). در شکل قسمت B، مدولاسیون نزولی تأثیر نسبی خطاهای پیش‌بینی را در سطوح پایین‌تر سلسله‌مراتب بر سلول‌های هرمی عمقی رمزگذار پیش‌بینی‌ها تعیین می‌کند. باورهای دقت با گیت‌گذاری یا کنترل دستاورد نزولی عصبی (سبز) سلول‌های هرمی سطحی رمزگذاری می‌شوند. در استنتاج بیزی، باورهای مربوط به دقت تأثیر زیادی بر چگونگی به‌روزرسانی باورهای پسین دارند. باورهای دقت به عنوان یک مکانیزم توجهی در نظر گرفته می‌شوند که پیش‌بینی‌ها و شواهد حسی را بسته به میزان اطمینان یا سودمندی آنها برای یک کار و زمینه خاص وزن‌دهی می‌کند. شکل قسمت C یک مثال خاص از استنتاج فعال برای به حداقل رساندن خطای پیش‌بینی را نشان می‌دهد. استنتاج‌های ادراکی درباره گرفتن یک فنجان، خطاهای پیش‌بینی بصری، پوستی و حس وضعیتی را تولید می‌کنند که سپس با حرکت به حداقل می‌رسند. پیش‌بینی‌های نزولی حس وضعیتی باید با وزن بالا به گونه‌ای ارضا شوند که حرکت را برانگیزانند. سپس، خطاهای پیش‌بینی حس وضعیتی در سطح نخاع ایجاد شده و در سطح بازتاب‌های محیطی به حداقل می‌رسند. هم‌زمان، وقتی که مسیر حرکت برای گرفتن فنجان انجام می‌شود، خطاهای پیش‌بینی بصری و پوستی در تمامی سطوح سلسله‌مراتب قشری به حداقل می‌رسند. انسان‌ها و

دیگر عاملان زیستی باید با دنیایی پر از عدم اطمینان حسی کنار بیایند. در انسان‌ها، شواهد روان‌فیزیکی نشان می‌دهد که چگونه مدل‌های بیزی می‌توانند سوگیری‌های ادراکی و حرکتی را با رمزگذاری عدم اطمینان در بازنمایی‌های درونی مغز توضیح دهند (Knill and Pouget, 2004). چندین رویکرد بیزی وجود دارد که بر اساس این ایده شکل گرفته‌اند که فرایندهای ادراکی و شناختی توسط مدل‌های زایشی احتمالی درونی پشتیبانی می‌شوند. یک مدل زایشی مدلی احتمالی (چگالی مشترک) است که علل پنهان در محیط را با پیامدهای حسی پیوند می‌دهد که از آنها نمونه‌ها تولید می‌شود. این مدل معمولاً به صورت توزیع احتمالی احتمال مشاهده اطلاعات حسی معین با توجه به علل آن و توزیع احتمالی قبلی باورها درباره علل پنهان اطلاعات حسی (پیش از نمونه‌گیری مشاهدات جدید) تعریف می‌شود (Badcock et al., 2017). یک چگالی پسین، باوری پسین است که با ترکیب باور قبلی و احتمال وزندهی شده بر اساس دقتشان، که به عنوان واریانس معکوس تعریف می‌شود، به دست می‌آید. در استنتاج بیزی، باورهای درباره باورها (اولویت‌های تجربی) وجود دارد به طوری که انتظاراتی درباره دقت یا عدم اطمینان باورها وجود دارد. در اینجا، توجه به عنوان نمونه‌گیری انتخابی از اطلاعات حسی دیده می‌شود، به گونه‌ای که پیش‌بینی‌هایی درباره اعتماد به سیگنال‌ها انجام می‌شود تا خطاهای پیش‌بینی از روش‌های حسی مختلف را تقویت یا تضعیف کند. برای رسیدن به این نمونه‌گیری، این چارچوب مکانیزمی به نام وزندهی دقت را پیشنهاد می‌کند. اطلاعات ورودی از روش‌های مختلف با توجه به اعتماد مورد انتظار داده‌شده در یک کار و زمینه خاص وزندهی می‌شوند (Parr and Friston, 2017). به طور مهمی، وزن‌های دقت نه تنها با توجه به قابلیت اطمینان آنها اختصاص داده می‌شوند، بلکه بر اساس سودمندی متفاوت آنها در زمینه‌های

مختلف نیز تخصیص داده می‌شوند، و از این رو به عنوان مکانیزمی برای کنترل رفتار در نظر گرفته می‌شوند (Clark, 2020). در مغز، وزن‌دهی دقت ممکن است توسط کنترل دستیابی عصبی مدوله‌شونده‌ای میانجی‌گری شود که می‌تواند به عنوان رمزگذاری بهینه بیزی دقت در سطح سیناپسی جمعیت‌های عصبی رمزگذار خطاهای پیش‌بینی تلقی شود. خطاهای پیش‌بینی با دقت بالا تأثیر زیادی بر به‌روزرسانی باورها دارند و اولویت‌های با دقت بالا در برابر خطاهای پیش‌بینی پرنویز یا بی‌ربط مقاوم هستند. باورهای بیزی به عنوان استنتاج‌هایی درباره توزیع احتمالی پسین (چگالی شناخت) از طریق فرایند به‌روزرسانی باورها مورد بررسی قرار می‌گیرند (Ramstead et al., 2020). چگالی شناخت، یک توزیع احتمالی تقریبی از علل اطلاعات حسی است که باورهای پسین را به عنوان محصولی از وارونه‌سازی مدل زایشی رمزگذاری می‌کند. بر اساس فرضیه مغز بیزی، باورهای قبلی به عنوان بازنمایی‌های عصبی رمزگذاری می‌شوند و در پرتو شواهد جدید، باورها (چگالی پسین) به‌روزرسانی می‌شوند تا باور پسین با پیروی از قاعده بیز تولید شود. این به این معناست که مغز چگالی‌های شناختی بیزی را درون پویایی‌های عصبی خود رمزگذاری می‌کند که می‌توان آن را به عنوان استنتاج علل پنهان برای یافتن بهترین «حدس» از محیط تصور کرد (Demekas et al., 2020).

به گفته‌ی Friston و همکاران (۲۰۰۶)، پردازش پیش‌بینانه باید در چارچوب اصل انرژی آزاد قرار گیرد زیرا "به حداقل رساندن خطای پیش‌بینی" تحت برخی فرضیات با به حداقل رساندن انرژی آزاد متناظر است. پردازش پیش‌بینانه می‌تواند به‌عنوان نامی برای خانواده‌ای از نظریات مرتبط دیده شود، که در آن اصل انرژی آزاد (FEP) یک چارچوب ریاضی برای پیاده‌سازی این ایده‌ها فراهم می‌کند. اصل انرژی آزاد،

چارچوبی زیستی و عصب‌شناختی است که در آن به حداقل رساندن خطای پیش‌بینی به‌عنوان یک فرایند بنیادی در سیستم‌های خودسازمان‌دهی برای حفظ حالت‌های حسی در محدوده‌های فیزیولوژیکشان در مواجهه با تغییرات محیطی مداوم در نظر گرفته می‌شود.

اساساً، اصل انرژی آزاد، فرمول‌بندی ریاضی از چگونگی مقاومت عوامل یا سیستم‌های زیستی (مانند مغزها) در برابر گرایش طبیعی به بی‌نظمی از طریق محدود کردن دامنه‌ی حالت‌های فیزیولوژیکی و حسی است که فنوتیپ‌های آنها را تعریف می‌کند. به عبارت دیگر، برای حفظ یکپارچگی ساختاری، حالت‌های حسی هر سیستم زیستی باید آنتروپی پایینی داشته باشند. آنتروپی، منفی لگاریتم احتمال یک نتیجه یا متوسط "غافلگیری" سیگنال‌های حسی تحت مدل زایشی از علل آن سیگنال‌ها است.

بنابراین، سیستم‌های زیستی باید غافلگیری حسی خود (و به طور ضمنی آنتروپی) را به حداقل برسانند تا احتمال باقی ماندن در محدوده‌های فیزیولوژیکی خود را در بازه‌های زمانی طولانی افزایش دهند. هدف اصلی از به حداقل رساندن انرژی آزاد این است که اطمینان حاصل شود سیستم‌های زیستی بیشتر زمان خود را در حالت‌های ارزشمند خود می‌گذرانند، حالتی که انتظار دارند به‌طور مکرر در آن قرار گیرند. انتظارات قبلی یک دامنه‌ی اصلی از حالت‌های ارزشمند را که دارای ارزش ذاتی است، تجویز می‌کنند، که از طریق مکانیسم‌های ژنتیکی و اپی‌ژنتیکی به ارث رسیده‌اند (Ciria et al, 2021).

عوامل زیستی می‌توانند با استفاده از دو استراتژی انرژی آزاد را به حداقل برسانند: تغییر چگالی شناختی یا تغییر فعالانه‌ی حالت‌های داخلی خود. تغییر چگالی شناختی، انرژی آزاد را به حداقل می‌رساند و در نتیجه، اختلاف ادراکی را کاهش می‌دهد. این یک مؤلفه‌ی مرتبط با فرمول انرژی آزاد است که به‌عنوان

پیچیدگی منهای دقت بیان می‌شود. به حداقل رساندن اختلاف ادراکی، پیچیدگی مدل را افزایش می‌دهد، که به‌عنوان تفاوت بین چگالی قبلی و باورهای پسین رمزگذاری‌شده توسط چگالی شناختی تعریف می‌شود. (Friston, 2010a) این استراتژی اول به عنوان استنتاج ادراکی شناخته می‌شود، یعنی زمانی که عوامل پیش‌بینی‌های خود را تغییر می‌دهند تا با اطلاعات حسی ورودی مطابقت داشته باشند. از آنجا که اطلاعات حسی می‌تواند بسیار پر نویز و مبهم باشد، استنتاج‌های ادراکی ضروری هستند تا ورودی معنادار و منسجم شود.

استراتژی دوم، رویکرد استاندارد به عمل در پردازش پیش‌بینانه است که به عنوان استنتاج فعال شناخته می‌شود (Brown et al., 2013) که شامل تغییر ورودی‌های حسی از طریق اقداماتی است که با پیش‌بینی‌ها سازگار هستند. این همان به حداقل رساندن انرژی آزاد مورد انتظار است. هنگام اقدام در جهان، انرژی آزاد با نمونه‌برداری از اطلاعات حسی که با باورهای قبلی سازگار است، به حداقل می‌رسد. یک اقدام به‌عنوان مجموعه‌ای از حالت‌های واقعی تعریف می‌شود که حالت‌های پنهان جهان را تغییر می‌دهند و با حالت‌های کنترلی که توسط مدل زایشی برای توضیح پیامدهای عمل استنتاج می‌شوند، ارتباط نزدیکی دارند. بنابراین، اقدامات مستقیماً بر دقت مدل زایشی تأثیر می‌گذارند، که به‌عنوان غافلگیری در مورد اطلاعات حسی مورد انتظار تحت چگالی شناختی تعریف می‌شود. برای بقا، اقدامات ارزشمند آنهایی هستند که انتظار می‌رود به عوامل امکان اجتناب از حالت‌های غافلگیرانه را بدهند. هر اقدام برای به حداقل رساندن شواهد مدل زایشی عمل می‌کند به‌گونه‌ای که سیاست‌ها برای به حداقل رساندن پیچیدگی انتخاب می‌شوند.

پیامدهای مورد انتظار از اقدامات شامل عدم‌دقت یا ابهام مورد انتظار و پیچیدگی یا ریسک مورد انتظار است که با هم در انرژی آزاد مورد انتظار ترکیب می‌شوند. بنابراین، انرژی آزاد مورد انتظار ارزش یک سیاست را توصیف می‌کند که ارزش عملی (ابزاری) و شناختی آن را نشان می‌دهد. به عبارت دیگر، اقدامات زمانی ارزشمند هستند که از طریق بهره‌برداری (برآورده کردن ترجیحات) به حداکثر سودمندی برسند و از طریق کاوش در پارامترهای مدل (جمع‌آوری اطلاعات، مانند استراتژی‌های انگیزش درونی) عدم‌اطمینان را به حداقل برسانند (Seth and Tsakiris, 2018).

به حداکثر رساندن ارزش شناختی با انتخاب اقداماتی که پیچیدگی مدل را از طریق تغییر باورها افزایش می‌دهند، مرتبط است، در حالی که به حداکثر رساندن ارزش عملی با اقداماتی که حالت‌های داخلی را تغییر می‌دهند تا با باورها همسو شوند، مرتبط است. در نتیجه، به حداقل رساندن انرژی آزاد مورد انتظار زمانی رخ می‌دهد که ارزش عملی و شناختی به حداکثر برسند (Ciria et al, 2021).

۴-۱- کاربردها در رباتیک

تحلیل ادبیات با یکی از نخستین پیاده‌سازی‌های رباتیک پردازش پیش‌بینانه آغاز می‌شود. محققین (Tani & Nolfi, 1999) معماری سلسله‌مراتبی دو لایه‌ای را معرفی کردند که به صورت خودسازمان‌دهی ماژول‌های تخصصی را ایجاد می‌کند. هر ماژول تخصصی یک شبکه عصبی بازگشتی (RNN) است. لایه پایین RNN ها آموزش دیده و به انواع مختلف ورودی‌های حسی و حرکتی پاسخ می‌دهد. مجموعه بالایی از ماژول‌ها به‌عنوان یک مکانیسم گذرگاهی برای RNN های سطح پایین عمل می‌کند. این مدل محاسباتی

در یک ربات متحرک شبیه‌سازی‌شده برای انجام یک وظیفه ناوبری به کار گرفته شده است. معماری به صورت برخط آموزش می‌بیند. پس از مدتی کوتاه، متخصصین گذرگاهی در پیمایش از طریق راهروها، چرخش‌های راست و چپ و تقاطع‌های T تخصص پیدا می‌کنند. پارامترهای آزاد معماری به صورت برخط با استفاده از الگوریتم باز-انتشار در زمان آموزش داده می‌شوند. با این حال، همان‌طور که نویسندگان اشاره می‌کنند، محدودیت این معماری این است که فقط از جریان اطلاعات پایین به بالا استفاده می‌کند و پیش‌بینی‌های بالا به پایین را برای تنظیم فعال‌سازی سطوح پایین‌تر ادغام نمی‌کند.

(Tani (2019) مروری جامع بر آزمایش‌های نورورباتیک مرتبط، بسیاری از آن‌ها که در آزمایشگاه نویسندگان انجام شده است، ارائه می‌دهد. یکی از پیاده‌سازی‌های بسیار جالب در مطالعه‌ی Hwang و همکاران (۲۰۱۸) توصیف شده است که نویسندگان از آن به عنوان یک مدل کدگذاری پیش‌بینانه یاد می‌کنند. شبکه پذیرفته‌شده یک معماری سلسله‌مراتبی چندلایه‌ای است که اطلاعات بصری و پیکری را رمزگذاری می‌کند. اگرچه این کار از فرمول‌بندی‌های ارائه‌شده در اصل انرژی آزاد فاصله دارد، شبکه VMDNN (شبکه عصبی پویا پیش‌بینی‌کننده دیداری-حرکتی عمیق) عملیات بسیار مشابهی انجام می‌دهد. این عملیات شامل تولید اقدامات پیروی از یک طرح به حداقل رساندن خطای پیش‌بینی و استفاده از همان ساختار مدل برای تولید و شناسایی عمل است. نویسندگان ادعا می‌کنند که "مدل پیشنهادی یک مکانیسم برخط به حداقل رساندن خطای پیش‌بینی فراهم می‌کند که با به‌روزرسانی حالت‌های داخلی نورون‌ها در جهت به حداقل رساندن خطای پیش‌بینی، نیت پشت الگوهای دیداری-پیکری مشاهده‌شده استنباط می‌شود (Hwang et al, 2018).

شایان ذکر است که چنین به‌روزرسانی به وزن‌های مدل اشاره نمی‌کند، بلکه تنها به حالت نوروها مربوط می‌شود. آموزش مدل به صورت نظارت‌شده انجام می‌شود. خطایی که به حداقل رسانده می‌شود تفاوت بین سیگنال تولیدشده از طریق آموزش جنبشی (یعنی جایی که یک آزمایشگر انسانی حرکات عضو ربات را به صورت دستی هدایت می‌کند) و پیش‌بینی‌های مدل است. جنبه بسیار جالب این شبکه اتصالات جانبی بین مدالیت‌ها در هر لایه از سلسله مراتب است.

کار مهم دیگری از همین گروه توسط (Ahmadi & Tani, 2019) به دلیل فرمول‌بندی استنتاج فعال و استراتژی آموزشی مبتنی بر شبکه‌های عصبی بازگشتی بیزی واریانسی برجسته است. همین محققین در مقاله‌ای دیگر یک شبکه عصبی بازگشتی چندمقیاسه (MTRNN) پیشنهاد کردند که شامل چندین سطح از زیرشبکه‌ها با محدودیت‌های زمانی خاص در هر لایه است. مدل داده‌ها را از سه مدالیت مختلف پردازش می‌کند و قادر به تولید پیش‌بینی‌های بلندمدت در هر دو حالت حلقه باز و حلقه بسته است. در طول تولید خروجی حلقه بسته، حالت‌های داخلی شبکه می‌توانند از طریق رگرسیون خطا استنتاج شوند. شبکه به صورت حلقه باز آموزش داده می‌شود و پارامترهای آزاد آن با استفاده از خطا بین حالت‌های مطلوب و مقادیر فعال‌سازی واقعی اصلاح می‌شود (Ahmadi & Tani, 2017).

ویژگی مشترک پیاده‌سازی‌های مورد بررسی تا کنون این است که آموزش و آزمون از هم جدا هستند. در مرحله آزمون، خطاهای پیش‌بینی از پایین به بالا جریان دارند و "حالت داخلی شبکه در جهت به حداقل رساندن خطای پیش‌بینی از طریق رگرسیون خطا اصلاح می‌شود" (Ahmadi & Tani, 2017). این بدین معناست که وزن‌های شبکه پس از آموزش تغییر نمی‌کنند. در بیشتر کارهای خود، Tani و همکاران از

فرمول‌بندی‌های ریاضی بر اساس شبکه‌های پیوندگرا و متفاوت از آنچه (Friston, 2009) پیشنهاد داده است استفاده می‌کنند؛ با این حال، کار از نظر مفهومی به کدگذاری پیش‌بینانه و استنتاج فعال بسیار مرتبط است.

یک رویکرد مشابه برای خودتولید اهداف توسط Annabi و همکاران (۲۰۲۰) در یک آزمایش شبیه‌سازی شده که در آن یک بازوی رباتیک دو درجه آزادی باید یاد بگیرد که چگونه اعداد را بنویسد به کار گرفته شده است. معماری پیشنهادی توالی‌های ابتدایی حرکتی را بر اساس رویکرد به حداقل رساندن انرژی آزاد می‌آموزد. سیستم، شبکه‌های عصبی بازگشتی برای رمزگذاری مسیرها را با یک سیستم خودسازمان‌ده برای تخمین هدف ترکیب می‌کند که بر اساس داده‌های تولیدشده از طریق رفتارهای تصادفی آموزش داده می‌شود. در آزمایشات، سیستم به‌طور افزایشی توالی‌های حرکتی و سیاست‌ها را با استفاده از یک مدل پیشرو مولد از پیش تعریف‌شده می‌آموزد. به حداقل رساندن انرژی آزاد برای انتخاب اقدام استفاده می‌شود.

Zhong و همکاران (۲۰۱۸) مدل سلسله‌مراتبی‌ای را ارائه داده‌اند که از مجموعه‌ای از ماژول‌های انباشته شده‌ی تکرارشونده برای پیاده‌سازی استنتاج فعال در عوامل شبیه‌سازی‌شده تشکیل شده است. هر لایه از شبکه شامل ماژول‌های مختلفی است، از جمله واحدهای مولد که به‌عنوان شبکه‌های بازگشتی کانولوشنی (شبکه‌های حافظه بلندمدت کوتاه‌مدت (LSTM)، پیاده‌سازی شده‌اند. در این معماری سلسله‌مراتبی، پیش‌بینی‌ها و خطاهای پیش‌بینی به ترتیب به‌صورت بالا به پایین و پایین به بالا جریان دارند. واحدهای مولد در یک جلسه یادگیری خارج از خط طی دو آزمایش شبیه‌سازی‌شده آموزش داده

می‌شوند. نکته مهم دیگری که باید به آن اشاره کرد وزن‌دهی دقت است، زیرا در پردازش پیش‌بینانه، به این موضوع نقش مهمی در تنظیم رفتار و هدف و همچنین در فرآیندهای بهینه‌سازی ادراکی داده شده است. مطالعات بیشتر در حوزه رباتیک شناختی باید این مسیر را بررسی کنند.

بیشتر پیاده‌سازی‌های غیررباتیک از یک فرمول‌بندی بیزی یا احتمالاتی برای طرح‌های به حداقل رساندن خطا استفاده می‌کنند. این موضوع به فرمول‌بندی شیک از دقت در طرح‌های وزن‌دهی اجازه می‌دهد که شامل معکوس واریانس توزیع‌های پیشین و پسین است. با این حال، راهکارهای جایگزینی برای پیاده‌سازی فرآیندهای شبیه وزن‌دهی دقت در مدل‌های غیراحتمالاتی وجود دارد، از جمله تعدیل فعال‌سازی نورونی یا وزن‌های سیناپسی در شبکه‌های عصبی مصنوعی، تعدیل نرخ آتش‌زنی در شبکه‌های عصبی اسپایکینگ، تعدیل دوپامین‌ژیک و غیره. ادبیات گسترده‌ای در تکنیک‌های ادغام حسگر در جامعه یادگیری ماشین وجود دارد که بر روی چالش‌های مرتبط بسیاری تمرکز دارد، مانند یادگیری و تعدیل اهمیت حسگرهای منفرد در تنظیمات چندمدالی و پیش‌بینانه (Fayyad et al., 2020).

نتیجه‌گیری

این مطالعه‌ی مروری به بررسی انواع حافظه شامل حافظه معنایی، حافظه کاری و حافظه رویدادی بر اساس نظریه‌های شناختی و کاربردهای عملی آن‌ها در سیستم‌های هوشمند و رباتیک اختصاص داشت. در این بخش، با تکیه بر اصول نظری شناختی، به تفصیل به ساختار و کارکرد هر یک از این نوع حافظه‌ها

پردازنده و نقشی که این حافظه‌ها در بهبود عملکرد ربات‌ها و سیستم‌های هوشمند ایفا می‌کنند، تحلیل شد. همچنین چگونگی شبیه‌سازی این حافظه‌ها در ربات‌ها و چالش‌های فنی مرتبط با پیاده‌سازی آن‌ها مورد بررسی قرار گرفت.

در بررسی حافظه معنایی، به ساختار دانش عمومی و نحوه ذخیره‌سازی اطلاعات کلی و بدون وابستگی به زمان و مکان اشاره شد. این حافظه به ربات‌ها کمک می‌کند تا دانش مفهومی مانند شناخت اشیاء، مفاهیم و زبان را به دست آورند. در سیستم‌های هوشمند، حافظه معنایی به ربات‌ها اجازه می‌دهد تا درک بهتری از محیط داشته باشند و بتوانند به صورت مستقل از تجربه‌های گذشته، دانش خود را اعمال کنند. یکی از چالش‌های عمده در شبیه‌سازی حافظه معنایی در ربات‌ها، پیچیدگی در نمایه‌سازی و دسته‌بندی اطلاعات است.

حافظه کاری، که برای ذخیره و پردازش همزمان اطلاعات به کار می‌رود، در رباتیک نقشی کلیدی دارد، زیرا ربات‌ها برای انجام وظایف پیچیده نیاز به استفاده از اطلاعات موجود در لحظه دارند. این نوع حافظه به ربات‌ها امکان می‌دهد که به طور مؤثری از داده‌های فعلی برای حل مسائل فوری استفاده کنند. با این حال، محدودیت ظرفیت حافظه کاری در سیستم‌های رباتیک یک چالش عمده است. در سیستم‌های هوشمند فعلی، تلاش‌هایی برای بهینه‌سازی ظرفیت حافظه کاری از طریق الگوریتم‌های محاسباتی و شبکه‌های عصبی صورت گرفته است، اما همچنان بهبودهایی نیاز است. حافظه رویدادی، که به ذخیره‌سازی و بازیابی تجربیات شخصی و رویدادهای خاص مرتبط است، در رباتیک امکان شبیه‌سازی تجربیات گذشته را فراهم می‌کند. این قابلیت به ربات‌ها این توانایی را می‌دهد که از تجربیات گذشته خود

برای تصمیم‌گیری بهتر در آینده استفاده کنند. در ربات‌های اجتماعی، حافظه رویدادی به تعاملات پویا و مؤثرتر با انسان‌ها کمک می‌کند، زیرا ربات‌ها می‌توانند تجربیات قبلی با کاربران را به یاد آورده و پاسخ‌های مناسب‌تری ارائه دهند. چالش اصلی در این حوزه، پیچیدگی ذخیره و بازیابی دقیق رویدادها و خاطرات است که نیاز به توسعه الگوریتم‌های پیشرفته دارد.

در مقایسه این سه نوع حافظه، می‌توان گفت که هر یک از آن‌ها نقش مکملی در بهبود عملکرد ربات‌ها دارند. حافظه معنایی به درک کلی و مستقل از زمان و مکان کمک می‌کند، حافظه کاری در حل مسائل آنی و فرآیندهای شناختی لحظه‌ای مؤثر است و حافظه رویدادی به ذخیره‌سازی تجربیات شخصی و یادگیری از گذشته کمک می‌کند. هرچند که هر یک از این حافظه‌ها دارای کارکردهای ویژه‌ای هستند، اما ترکیب آن‌ها می‌تواند به ایجاد سیستم‌های هوشمند و ربات‌های پیچیده‌تر با قابلیت‌های تصمیم‌گیری و یادگیری قوی‌تر منجر شود. در نهایت، این فصل نشان داد که اگرچه شبیه‌سازی حافظه‌های شناختی انسانی در ربات‌ها هنوز در مراحل اولیه خود قرار دارد، اما پیشرفت‌های اخیر در الگوریتم‌های یادگیری و شبکه‌های عصبی به ربات‌ها اجازه می‌دهد تا به مرور زمان به شبیه‌سازی این حافظه‌ها نزدیک‌تر شوند. چالش‌های موجود، به ویژه در زمینه ظرفیت محاسباتی و پیچیدگی ذخیره‌سازی، فرصت‌هایی برای پژوهش‌های بیشتر در آینده فراهم می‌کنند تا سیستم‌های هوشمند بتوانند از مزایای کامل این حافظه‌ها بهره‌مند شوند.

منابع و مآخذ:

1. Ahmadi, A., & Tani, J. (2017). How can a recurrent neurodynamic predictive coding model cope with fluctuation in temporal patterns? Robotic experiments on imitative interaction. *Neural Networks*, 92, 3-16.
2. Ahmadi, A., & Tani, J. (2019). A novel predictive-coding-inspired variational RNN model for online prediction and recognition. *Neural computation*, 31(11), 2025-2074.
3. Amanatiadis, A., Kaburlasos, V. G., & Kosmatopoulos, E. B. (2018, October). Understanding deep convolutional networks through Gestalt theory. In *2018 IEEE International Conference on Imaging Systems and Techniques (IST)* (pp. 1-6). IEEE.
4. Anderson, J. R. (2000). *Learning and memory: An integrated approach*. John Wiley & Sons Inc.
5. Annabi, L., Pitti, A., & Quoy, M. (2020, July). Autonomous learning and chaining of motor primitives using the free energy principle. In *2020 International Joint Conference on Neural Networks (IJCNN)* (pp. 1-8). IEEE.
6. Arkin, R. C., Cervantes-Pérez, F., & Weitzenfeld, A. (1997). Ecological robotics: A schema-theoretic approach. *Series in Machine Perception and Artificial Intelligence*, 27, 377-393.
7. Badcock, P. B., Davey, C. G., Whittle, S., Allen, N. B., & Friston, K. J. (2017). The depressed brain: An evolutionary systems theory. *Trends in Cognitive Sciences*, 21(3), 182-194.
8. Baddeley, A. (2012). Working memory: Theories, models, and controversies. *Annual review of psychology*, 63(1), 1-29.
9. Barrett, L. F., Tugade, M. M., & Engle, R. W. (2004). Individual differences in working memory capacity and dual-process theories of the mind. *Psychological bulletin*, 130(4), 553.
10. Bergqvist, M., Möller, M. C., Björklund, M., Borg, J., & Palmcrantz, S. (2023). The impact of visuospatial and executive function on activity performance and outcome after robotic or conventional gait training, long-term after stroke—as part of a randomized controlled trial. *Plos one*, 18(3), e0281212.
11. Brouillet, T., Heurley, L., Martin, S., & Brouillet, D. (2010). The embodied cognition theory and the motor component of “yes” and “no” verbal responses. *Acta Psychologica*, 134(3), 310-317
12. Brown, H., Adams, R. A., Parees, I., Edwards, M., & Friston, K. (2013). Active inference, sensory attenuation and illusions. *Cognitive processing*, 14, 411-427.
13. Cheng, S. (2024). Distinct mechanisms and functions of episodic memory. *Philosophical Transactions B*, 379(1913), 20230411.
14. Cheng, S., Werning, M., & Suddendorf, T. (2016). Dissociating memory traces and scenario construction in mental time travel. *Neuroscience & Biobehavioral Reviews*, 60, 82-89.
15. Chin, W. H., Kubota, N., & Loo, C. K. (2022). An Episodic-Procedural Semantic Memory Model for Continuous Topological Sensorimotor Map Building. In *Cognitive Robotics and Adaptive Behaviors*. IntechOpen.
16. Ciria, A., Schillaci, G., Pezzulo, G., Hafner, V. V., & Lara, B. (2021). Predictive processing in cognitive robotics: a review. *Neural Computation*, 33(5), 1402-1432.

17. Clark, A. (2015). Embodied prediction. In *Open mind*. Open MIND. Frankfurt am Main: MIND Group.
18. Clark, A. (2020). Beyond desire? Agency, choice, and the predictive mind. *Australasian Journal of Philosophy*, 98(1), 1-15.
19. Cobb, P., & Bowers, J. (1999). Cognitive and situated learning perspectives in theory and practice. *Educational researcher*, 28(2), 4-15.
20. Collins, A. M., & Quillian, M. R. (1969). Retrieval time from semantic memory. *Journal of verbal learning and verbal behavior*, 8(2), 240-247.
21. De Jager, D. (2020). *Real-time optimization of working memory in autonomous reasoning for high-level control of cognitive robots deployed in dynamic environments* (Doctoral dissertation, Kingston University).
22. Deitrick, E., Shapiro, R. B., Ahrens, M. P., Fiebrink, R., Lehrman, P. D., & Farooq, S. (2015, August). Using distributed cognition theory to analyze collaborative computer science learning. In *Proceedings of the eleventh annual international conference on international computing education research* (pp. 51-60).
23. Demekas, D., Parr, T., & Friston, K. J. (2020). An investigation of the free energy principle for emotion recognition. *Frontiers in Computational Neuroscience*, 14, 30.
24. Di Lieto, M. C., Inguaggiato, E., Castro, E., Cecchi, F., Cioni, G., Dell'Omo, M., ... & Dario, P. (2017). Educational Robotics intervention on Executive Functions in preschool children: A pilot study. *Computers in human behavior*, 71, 16-23.
25. Fang, B., Mei, G., Yuan, X., Wang, L., Wang, Z., & Wang, J. (2021). Visual SLAM for robot navigation in healthcare facility. *Pattern recognition*, 113, 107822.
26. Fang, J., R  ther, N., Bellebaum, C., Wiskott, L., & Cheng, S. (2018). The interaction between semantic representation and episodic memory. *Neural Computation*, 30(2), 293-332.
27. Fayyad, J., Jaradat, M. A., Gruyer, D., and Najjaran, H. (2020). Deep learning sensor fusion for autonomous vehicle perception and localization: A review. *Sensors*, 20(15):4220.
28. Friston, K. (2009). The free-energy principle: a rough guide to the brain?. *Trends in cognitive sciences*, 13(7), 293-301.
29. Friston, K., Kilner, J., & Harrison, L. (2006). A free energy principle for the brain. *Journal of physiology-Paris*, 100(1-3), 70-87.
30. Garg, S., S  nderhauf, N., Dayoub, F., Morrison, D., Cosgun, A., Carneiro, G., ... & Milford, M. (2020). Semantics for robotic mapping, perception and interaction: A survey. *Foundations and Trends   in Robotics*, 8(1  2), 1-224.
31. Gauthier, B., Pestke, K., & van Wassenhove, V. (2019). Building the arrow of time... over time: a sequence of brain activity mapping imagined events in time and space. *Cerebral Cortex*, 29(10), 4398-4414.
32. Gauthier, B., Prabhu, P., Kotegar, K. A., & van Wassenhove, V. (2020). Hippocampal contribution to ordinal psychological time in the human brain. *Journal of Cognitive Neuroscience*, 32(11), 2071-2086.
33. Gordon, S. M., & Hall, J. (2006, June). System integration with working memory management for robotic behavior learning. In *Proc. Int. Conf. Develop. Learn.*

34. Görler, R., Wiskott, L., & Cheng, S. (2020). Improving sensory representations using episodic memory. *Hippocampus*, 30(6), 638-656.
35. Gruszka-Gosiewska, A., & Orzechowski, J. (2016). Meta-analysis of the research impact of Baddeley's multicomponent working memory model and Cowan's embedded-processes model of working memory: A bibliometric mapping approach.
36. Hafting, T., Fyhn, M., Molden, S., Moser, M. B., & Moser, E. I. (2005). Microstructure of a spatial map in the entorhinal cortex. *Nature*, 436(7052), 801-806.
37. Han, Z. (2023). Multimodal intelligent logistics robot combining 3D CNN, LSTM, and visual SLAM for path planning and control. *Frontiers in Neurorobotics*, 17, 1285673.
38. Ho, W. C., Dautenhahn, K., Lim, M. Y., & Du Casse, K. (2010). Modelling human memory in robotic companions for personalisation and long-term adaptation in HRI. In *Biologically Inspired Cognitive Architectures 2010* (pp. 64-71). IOS Press.
39. Huang, B., Liao, H., Ge, Y., Zhang, W., Kang, H., Wang, Z., & Wu, J. (2023, February). Development of BIM Semantic Robot Autonomous Inspection and Simulation System. In *2023 9th International Conference on Mechatronics and Robotics Engineering (ICMRE)* (pp. 35-40). IEEE.
40. Hutchins, E. (2020). The distributed cognition perspective on human interaction. In *Roots of human sociality* (pp. 375-398). Routledge.
41. Hwang, J., Kim, J., Ahmadi, A., Choi, M., & Tani, J. (2018). Dealing with large-scale spatio-temporal patterns in imitative interaction between a robot and a human by using the predictive coding framework. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 50(5), 1918-1931.
42. Jaeggi, S. M., Studer-Luethi, B., Buschkuhl, M., Su, Y. F., Jonides, J., & Perrig, W. J. (2010). The relationship between n-back performance and matrix reasoning—implications for training and transfer. *Intelligence*, 38(6), 625-635.
43. Jockel, S., Weser, M., Westhoff, D., & Zhang, J. (2008, July). Towards an episodic memory for cognitive robots. In *Proc. of 6th Cognitive Robotics workshop at 18th European Conf. on Artificial Intelligence (ECAI)* (pp. 68-74).
44. Jockel, S., Westhoff, D., & Zhang, J. (2007, December). Epirome—a novel framework to investigate high-level episodic robot memory. In *2007 IEEE International Conference on Robotics and Biomimetics (ROBIO)* (pp. 1075-1080). IEEE.
45. Kanerva, P. (1988). *Sparse distributed memory*. MIT press.
46. Knill, D. C., & Pouget, A. (2004). The Bayesian brain: the role of uncertainty in neural coding and computation. *TRENDS in Neurosciences*, 27(12), 712-719.
47. Koban, K., & Banks, J. (2023). Dual-Process Theory in Human–Machine Communication. *The SAGE Handbook of Human–Machine Communication*, 302.
48. Koutstaal, W., & Schacter, D. L. (1997). Gist-based false recognition of pictures in older and younger adults. *Journal of memory and language*, 37(4), 555-583.
49. Kumar, A. A. (2021). Semantic memory: A review of methods, models, and current challenges. *Psychonomic Bulletin & Review*, 28(1), 40-80.
50. Kundu, A., Krishna, K. M., & Sivaswamy, J. (2009, October). Moving object detection by multi-view geometric techniques from a single camera mounted robot. In *2009*

- IEEE/RSJ International Conference on Intelligent Robots and Systems* (pp. 4306-4312). IEEE.
51. Lara, B., Astorga, D., Mendoza-Bock, E., Pardo, M., Escobar, E., & Ciria, A. (2018). Embodied cognitive robotics and the learning of sensorimotor schemes. *Adaptive Behavior*, 26(5), 225-238.
 52. Mason, R., & Cooper, G. (2013). Mindstorms robots and the application of cognitive load theory in introductory programming. *Computer Science Education*, 23(4), 296-314.
 53. Mungan, E. (2023). Gestalt theory: A revolution put on pause? Prospects for a paradigm shift in the psychological sciences. *New Ideas in Psychology*, 71, 101036.
 54. Parr, T., & Friston, K. J. (2017). Working memory, attention, and salience in active inference. *Scientific reports*, 7(1), 14678.
 55. Persiani, M., Franchi, A. M., & Gini, G. (2018). A working memory model improves cognitive control in agents and robots. *Cognitive Systems Research*, 51, 1-13.
 56. Posner, H. (2020). Robots thinking fast and slow: on dual process theory and metacognition in embodied AI.
 57. Quillian, M. R. (1967). Word concepts: A theory and simulation of some basic semantic capabilities. *Behavioral science*, 12(5), 410-430.
 58. Quillian, M. R. (1969). The teachable language comprehender: A simulation program and theory of language. *Communications of the ACM*, 12(8), 459-476.
 59. Ramstead, M. J., Kirchhoff, M. D., & Friston, K. J. (2020). A tale of two densities: Active inference is enactive inference. *Adaptive behavior*, 28(4), 225-239.
 60. Rapaport, W. J. (1996). *Understanding understanding: semantics, computation, and cognition*. Department of Computer Science, State University of New York at Buffalo.
 61. Sarica, S., & Luo, J. (2021). Design knowledge representation with technology semantic network. *Proceedings of the Design Society*, 1, 1043-1052.
 62. Sarthou, G., Clodic, A., & Alami, R. (2019, October). Ontologenius: A long-term semantic memory for robotic agents. In *2019 28th IEEE International Conference on Robot and Human Interactive Communication (RO-MAN)* (pp. 1-8). IEEE.
 63. Sarthou, G., Clodic, A., & Alami, R. (2019, October). Ontologenius: A long-term semantic memory for robotic agents. In *2019 28th IEEE International Conference on Robot and Human Interactive Communication (RO-MAN)* (pp. 1-8). IEEE.
 64. Saumier, D., & Chertkow, H. (2002). Semantic memory. *Current neurology and neuroscience reports*, 2(6), 516-522.
 65. Seth, A. K. and Tsakiris, M. (2018). Being a beast machine: the somatic basis of selfhood. *Trends in cognitive sciences*, 22(11):969–981.
 66. Shimoda, S., Jamone, L., Ognibene, D., Nagai, T., Sciutti, A., Costa-Garcia, A., ... & Taniguchi, T. (2022). What is the role of the next generation of cognitive robotics?. *Advanced Robotics*, 36(1-2), 3-16.
 67. Shoukat, M. U., Yan, L., Deng, D., Imtiaz, M., Safdar, M., & Nawaz, S. A. (2024). Cognitive robotics: Deep learning approaches for trajectory and motion control in complex environment. *Advanced Engineering Informatics*, 60, 102370.
 68. Simon, H. A. (1978). Information-processing theory of human problem solving. *Handbook of learning and cognitive processes*, 5.

69. Sousa Silva, R., & Williams, T. (2024). Uncovering the Rules of Entity-Level Robotic Working Memory. In *Proceedings of the Annual Meeting of the Cognitive Science Society* (Vol. 46).
70. Spatola, N., Marchesi, S., & Wykowska, A. (2022). Cognitive load affects early processes involved in mentalizing robot behaviour. *Scientific Reports*, 12(1), 14924.
71. Squire, L. R., Knowlton, B., & Musen, G. (1993). The structure and organization of memory. *Annual review of psychology*, 44(1), 453-495.
72. Steyvers, M., & Tenenbaum, J. B. (2005). The large-scale structure of semantic networks: Statistical analyses and a model of semantic growth. *Cognitive science*, 29(1), 41-78.
73. Sullivan, J. V. (2018). Learning and embodied cognition: A review and proposal. *Psychology Learning & Teaching*, 17(2), 128-143.
74. Sullivan, J. V. (2018). Learning and embodied cognition: A review and proposal. *Psychology Learning & Teaching*, 17(2), 128-143.
75. Swanson, H. L. (1987). Information processing theory and learning disabilities: An overview. *Journal of learning Disabilities*, 20(1), 3-7.
76. Tani, J. (2019). Accounting for the minimal self and the narrative self: Robotics experiments using predictive coding. In *CEUR workshop proceedings* (Vol. 2287). Okinawa Institute of Science and Technology Graduate University.
77. Tani, J. and Nolfi, S. (1999). Learning to perceive the world as articulated: an approach for hierarchical learning in sensory-motor systems. *Neural Networks*, 12(7-8):1131–1141.
78. Teyler, T. J., & DiScenna, P. (1986). The hippocampal memory indexing theory. *Behavioral neuroscience*, 100(2), 147.
79. Tulving, E. (1972). “Episodic and semantic memory,” in *Organization of Memory*. (No Title), 381.
80. Tulving, E., & Markowitsch, H. J. (1998). Episodic and declarative memory: role of the hippocampus. *Hippocampus*, 8(3), 198-204.
81. Von Bastian, C. C., & Oberauer, K. (2014). Effects and mechanisms of working memory training: a review. *Psychological research*, 78, 803-820.
82. Wang, C. H., & Wu, K. C. (2022). Interdisciplinary Learning of Low-Code Development Platform Programming with Dual Coding Theory-A Case Study of Agilepoint NX. *Journal of ICT, Design, Engineering and Technological Science*, 21-25.
83. Wei, H., Ye, J., Li, J., & Wang, Y. (2023). Design and Simulation of a Hierarchical Parallel Distributed Processing Model for Orientation Selection Based on Primary Visual Cortex. *Biomimetics*, 8(3), 314.
84. Wei, T., & Li, X. (2020). Binocular vision SLAM algorithm based on dynamic region elimination in dynamic environment. *Robot*, 42(3), 336-345.
85. Wei, W. A. N. G. (2013). Towards Semantic Robot Manipulation for Human Living Support.
86. Wixted, J. T. (2007). Dual-process theory and signal-detection theory of recognition memory. *Psychological review*, 114(1), 152.

87. Yang, C. Y., Gamborino, E., Fu, L. C., & Chang, Y. L. (2021). A brain-inspired self-organizing episodic memory model for a memory assistance robot. *IEEE Transactions on Cognitive and Developmental Systems*, 14(2), 617-628.
88. Yee, E., Jones, M. N., & McRae, K. (2018). Semantic memory. *The Stevens' handbook of experimental psychology and cognitive neuroscience*, 3.
89. Yoo, H. B., Umbach, G., & Lega, B. C. (2021). Boundary cells in the representation of episodes in the human hippocampus. *BioRxiv*, 2021-05.
90. Yuan, J., Guo, W., Hou, Z., Zha, F., Li, M., Sun, L., & Wang, P. (2023). Robot navigation strategy in complex environment based on episode cognition. *Journal of Bionic Engineering*, 20(1), 1-15.
91. Yürük, N. (2019). DUAL CODING THEORY AND SUBTITLES: ENCODING STRATEGY IN VOCABULARY LEARNING. *Ines Journal-Journal of International Education Science*, 6, 38-50.
92. Zeng, X., Diekmann, N., Wiskott, L., & Cheng, S. (2023). Modeling the function of episodic memory in spatial learning. *Frontiers in Psychology*, 14, 1160648.
93. Zhong, J., Cangelosi, A., Zhang, X., & Ogata, T. (2018, July). AFA-PredNet: The action modulation within predictive coding. In *2018 International Joint Conference on Neural Networks (IJCNN)* (pp. 1-8). IEEE.
94. Zou, X., Scott, E., Johnson, A., Chen, K., Nitz, D., De Jong, K., & Krichmar, J. (2021, July). Neuroevolution of a recurrent neural network for spatial and working memory in a simulated robotic environment. In *Proceedings of the Genetic and Evolutionary Computation Conference Companion* (pp. 289-290).
95. Zushu, L., & Guiping, W. (2003, October). Schema theory and human simulated intelligent control. In *IEEE International Conference on Robotics, Intelligent Systems and Signal Processing, 2003. Proceedings. 2003* (Vol. 1, pp. 524-530). IEEE.