

معماری یکپارچه بلادرنگ سیستم خبره ترکیبی با یادگیری عمیق تطبیقی برای تصمیم‌گیری لبه‌محور در اینترنت اشیا

محمد راستگو

مدرس دانشگاه، دانشجوی دکتری کامپیوتر - گروه مهندسی کامپیوتر - مرکز آموزش علمی کاربردی علمی صنعتی خراسان
mo.rastgoo@iau.ac.ir

آرمان حشمت‌مهاجر

دانشجوی کارشناسی مهندسی فناوری اطلاعات، دانشگاه علمی کاربردی علمی صنعتی خراسان
armanmohajer26@gmail.com

چکیده

این پژوهش یک معماری ترکیبی یکپارچه برای تصمیم‌گیری هوشمند و بلادرنگ در محیط لایه لبه اینترنت اشیا ارائه می‌دهد که چهار نیاز کلیدی کاهش تأخیر، افزایش دقت، تضمین شفافیت و رعایت مهلت‌های سخت زمانی را به‌طور همزمان برآورده می‌سازد. معماری پیشنهادی مبتنی بر پنج لایه است که شامل پیش‌پردازش داده، زمان‌بندی بلادرنگ، یادگیری عمیق تطبیقی، سیستم خبره فازی و تقطیر دانش دوطرفه است. این ساختار امکان یادگیری مادام‌العمر بدون نقض محدودیت‌های زمانی و انتقال کارآمد دانش را در گره‌های لبه با منابع محدود فراهم می‌کند. این پژوهش نشان می‌دهد که تلفیق هوشمندانه‌ای از مدل‌های نمادین و زیرنمادین می‌تواند شکاف بین دقت، سرعت و تفسیرپذیری را در سیستم‌های بلادرنگ پُر کند و پایه‌ای برای نسل آینده کاربردهای هوش مصنوعی در صنایع حساس ایجاد نماید.

کلیدواژه‌ها: اینترنت اشیا، سیستم خبره ترکیبی، یادگیری ماشین لبه‌ای، سیستم بلادرنگ سخت، یادگیری مادام‌العمر

۱ مقدمه

رشد سریع و گسترده دستگاه‌های اینترنت اشیا، منجر به تولید حجم عظیمی از داده در مقیاس کلان شده است. پردازش متمرکز این داده‌ها در زیرساخت‌های ابری، با چالش‌های اساسی از جمله تأخیر بالا، مصرف انرژی قابل توجه و نگرانی‌های مربوط به حفظ حریم خصوصی و امنیت داده‌ها همراه است. برای غلبه بر این محدودیت‌ها، پارادایم پردازش در لبه شبکه ارائه شده که با انتقال پردازش‌ها به نزدیکی منبع تولید داده، تأخیر را کاهش داده است و کارایی پهنای باند را بهبود بخشیده و سطح بهتری از امنیت و حریم خصوصی را فراهم می‌آورد. با این وجود، این رویکرد نیز خود با موانعی روبرو است. این موانع شامل محدودیت منابع محاسباتی، ذخیره‌سازی در گره‌های لبه و همچنین، لزوم پایداری به محدودیت‌های زمانی سختگیرانه در برنامه‌های کاربردی حساس و بلادرنگ است. (Xu, R. et al. 2023). این تعارض میان نیازمندی‌های پردازشی پیچیده و محدودیت‌های منابع، کانون اصلی بسیاری از پژوهش‌های معاصر در حوزه محاسبات لبه به شمار می‌رود. سیستم‌های خبره سنتی از دانش متخصصان برای تصمیم‌گیری استفاده می‌کنند اما توانایی یادگیری از داده‌های جریان یافته را ندارند. در حالی که مدل‌های یادگیری عمیق دقت بالایی ارائه می‌دهند ولی شفافیت و پیش‌بینی‌پذیری زمان‌بندی آن‌ها محدود است. (Lin, W 2017, Mohammadi2023).

این پژوهش با اتکا به مطالعات و مرور ادبیات نوین، یک معماری ترکیبی بلادرنگ ارائه می‌دهد که به‌صورت هم‌زمان و تطبیقی، قوانین سامانه استنتاج فازی و پارامترهای شبکه عصبی راجه‌روزرسانی می‌کند. این معماری با استفاده از یک روش زمان‌بندی پیش‌گیرانه که اولویت راجه وظایفی که مهلت انجام نزدیک‌تر می‌دهد و همچنین با تخصیص پویای منابع پردازشی، امکان تصمیم‌گیری هوشمند و انعطاف‌پذیر را در محیط‌هایی که محدودیت‌های زمانی شدیدی دارند، فراهم می‌کند. کارایی این راه‌حل به‌ویژه در کاربردهای حساس به تأخیر نظیر نگهداری و عیب‌یابی پیش‌بینانه تجهیزات و سامانه‌های پایش سلامت بلادرنگ مورد تأکید قرار گرفته است و قابلیت آن در تضمین پاسخ‌گویی مطمئن و پایدار در شرایط عملیاتی پویا بررسی شده است. هدف، پر کردن شکاف بین دقت مدل‌های پیچیده و محدودیت‌های دستگاه‌های لبه‌ای است. البته با تمرکز بر تقطیر دانش بلادرنگ برای انتقال دانش از سرورهای ابری به لبه بدون افزایش تأخیر است.

توسعه روزافزون شبکه اینترنت اشیا و افزایش تصاعدی گره‌های متصل به آن، منجر به تولید حجم بی‌سابقه‌ای از داده‌ها در بازه‌های زمانی کوتاه و با نرخ بلادرنگ گردیده است. اگرچه پردازش این داده‌ها در زیرساخت‌های متمرکز ابری در مقیاس بزرگ امکان‌پذیر است. این الگوی پردازشی با چالش‌های زیرساختی و کیفی متعددی مواجه می‌باشد. از جمله این چالش‌ها می‌توان به بروز تأخیرهای ارتباطی اشاره نمود که نگرانی‌های جدی در خصوص امنیت و محرمانگی داده‌ها، افزایش بار ترافیکی در شبکه‌های و همچنین وابستگی حیاتی به دسترسی پایدار و پیوسته به منابع ابری دارد. در این راستا، پارادایم پردازش در لبه شبکه به عنوان یک راهبرد کارآمد و نوین جهت مقابله با محدودیت‌های مذکور مطرح شده است. این الگو با انتقال عملیات پردازشی و تحلیلی به

نزدیکی منبع تولید داده، موجب کاهش محسوس تأخیر، بهینه‌سازی مصرف پهنای باند، افزایش ضریب امنیتی از طریق محدودسازی انتقال داده و تقویت قابلیت اطمینان سیستم‌ها می‌گردد. در نتیجه، این رویکردنه تنها بستری برای پاسخگویی بلادرنگ فراهم می‌سازد، بلکه گامی اساسی در راستای دستیابی به خوداتکایی محاسباتی گره‌های اینترنت اشیاء و تحقق یک اکوسیستم مقیاس‌پذیر، کارآمد و تاب‌آور محسوب می‌شود. با این حال پردازش در لبه نیز با محدودیت‌هایی مانند ظرفیت پردازشی اندک، انرژی محدود، نوسانات داده و نیاز به تصمیم‌گیری سریع مواجه است. سیستم‌های خبره سنتی اگرچه می‌توانند دانش متخصصان را مدل کنند، اما فاقد توانایی یادگیری از داده‌های بلادرنگ و تطبیق سریع با شرایط جدید هستند. از سوی دیگر شبکه‌های یادگیری عمیق قدرت فراوانی در یادگیری الگوهای پیچیده دارند، ولی به دلیل نیاز به منابع سنگین محاسباتی، عدم شفافیت و ناتوانی در یادگیری مادام‌العمر، مناسب استفاده در لبه نیستند. از این رو پژوهشگران به دنبال معماری‌هایی هستند که بتوانند این کمبودها را جبران کند و ترکیبی از تبیین‌پذیری و دقت بالا را فراهم آورد. معماری ارائه‌شده در این مقاله، با بهره‌گیری از قواعد فازی، یادگیری عمیق سبک‌سازی‌شده و تقطیر دانش، تلاش دارد پاسخی جامع به این نیاز ارائه دهد (Zhou, Y 2023, Mohammadi 2023, Xu, R. et al. 2023).

با توجه به رشد تصاعدی حجم داده‌ها در محیط‌های لبه‌ای، نیاز به طراحی و استقرار معماری‌هایی که از یکسو کارایی محاسباتی بهینه داشته باشد و از سوی دیگر انعطاف‌پذیری و پایداری در برابر نوسانات پویای محیط عملیاتی را تضمین کنند، پژوهش‌های اخیر در حوزه رایانش لبه و سیستم‌های بلادرنگ نیز تأکید کرده‌اند که مدل‌های یادگیری عمیق، علی‌رغم دقت بالا، در محیط‌های دارای محدودیت شدید زمانی، نیازمند سازوکارهای تکمیلی برای کنترل میزان تأخیر هستند (Zhou, Y 2023, Xu, R. et al. 2023). علاوه بر این، مسائلی مانند نرخ بالای تولید داده و نیاز به جلوگیری از انتقال زیاد داده به هسته ابری، سبب شده است که راهکارهای مبتنی بر یادگیری تطبیقی و تصمیم‌گیری نمادین دوباره مورد توجه قرار گیرند. همان‌گونه که مطالعات جدید نشان می‌دهند، ترکیب لایه‌های یادگیری عصبی با قواعد فازی می‌تواند شکاف میان دقت پیش‌بینی و تبیین‌پذیری را در کاربردهای حساس مانند سلامت و صنعت کاهش دهد. از این رو، ضرورت یک معماری یکپارچه که بتواند این دو بُعد را همزمان مدیریت کند، بیش از پیش احساس می‌شود. (Zhang 2023, Kirk 2024, Lin, W 2017)

مسئله اصلی پژوهش این است که چگونه در سامانه‌های اینترنت اشیاء با منابع محدود و مهلت‌های سخت، تصمیم‌گیری دقیق، شفاف و تطبیقی بدون نقض محدودیت‌های محاسباتی و ارتباطی انجام شود. این مسئله در سناریوهای واقعی مانند نگهداری صنعتی و پایش پزشکی بسیار حیاتی است، زیرا تأخیر حتی چند میلی‌ثانیه می‌تواند پیامدهای جدی داشته باشد. (Zhang, Q 2023)

بر اساس مرور نظام‌مند پژوهش‌های اخیر، شکاف‌های عمده و چالش‌های کلیدی در حوزه یادگیری در لبه به شرح زیر شناسایی شده است: اول، عدم وجود یک چارچوب یکپارچه برای ترکیب پویا و برخط سیستم‌های خبره مبتنی بر منطق فازی با مدل‌های عصبی در سطح گره‌های لبه است، که در نتیجه منجر به ایجاد مدل‌های ایستا و فاقد توانایی انطباق و یادگیری از جریان‌های داده‌های پویا می‌گردد (Kirk 2024, Zhou, Y 2023). دوم، ناتوانی روش‌های

متداول یادگیری مادام‌العمر در تضمین مهلت‌های سخت زمانی است. زیرا فرآیندهای بازآموزی و به‌روزرسانی مدل معمولاً نیازمند زمان پردازش و منابع محاسباتی قابل توجهی هستند (Liu, Y 2023, Yang, Q 2023). سوم، فقدان مکانیسم‌های کارآمد برای انتقال و تقطیر دانش به‌صورت برخط از سرورهای مرکزی به گره‌های لبه است. این مورد موجب تأخیر در به‌روزرسانی مدل‌های محلی و افت دانش در طول انتقال می‌شود (Cao, K 2022, Gao, Z 2024). چهارم، کمبود ارزیابی‌های تجربی جامع بر بستر سخت‌افزارهای واقعی لبه و با استفاده از مجموعه‌داده‌های عملیاتی همراه با محدودیت‌های زمانی سخت، که قابلیت تعمیم‌پذیری روش‌های پیشنهادی را زیر سؤال می‌برد (Murshed, M 2023, Saxena, S 2023).

با توجه به محدودیت‌های جدی توان پردازشی و انرژی در گره‌های لبه، پرسش کلیدی بسیاری از پژوهش‌ها این بوده است که چگونه می‌توان یک مدل یادگیری عمیق پویا و همیشه‌به‌روز طراحی کرد که همزمان بتواند مهلت‌های سخت زمانی را رعایت کند و کارایی محاسباتی خود را نیز حفظ نماید؟ نتایج حاصل از پژوهش‌ها نشان می‌دهد که اغلب راهکارهای موجود، تنها بر یکی از جنبه‌های مذکور مانند سازگاری با داده‌های پویا، قابلیت توجیه و تفسیر تصمیم‌ها، یا پایبندی به محدودیت‌های زمانی تمرکز داشته است و یک معماری جامع که بتواند این نیازهای چندگانه را به‌طور همزمان برآورده سازد، کمتر ارائه شده است (Yang, Q 2023, Gao, Z 2024, Zhang, Q 2023).

افزون بر این، در اغلب پژوهش‌ها، تمرکز اصلی بر آموزش پیش‌پردازش‌شده مدل بوده و فرآیند به‌روزرسانی برخط مدل با داده‌های جریان یافته تا حد زیادی نادیده گرفته شده است. این در حالی است که در محیط‌های حساس، کوچک‌ترین تأخیر یا انباشت داده، پیامدهای جدی ایجاد می‌کند. از سوی دیگر، فقدان مکانیزم‌های مؤثر برای انتقال دانش در لحظه میان سرور و لبه، موجب شده است که سیستم‌های موجود توانایی انطباق سریع را نداشته باشند. این موارد شکاف اصلی پژوهش را برجسته می‌کند که معماری حاضر تلاش می‌کند آن را پر کند. (Cao, K 2022, Gao, Z 2024).

۲ پیشینه پژوهش

پژوهش‌های اولیه در این حوزه از سال ۲۰۱۹ آغاز شد. جایی که مجموعه‌داده‌های پوشیدنی و حسگرها برای نخستین‌بار به‌طور گسترده در تصمیم‌گیری هوشمند مورد استفاده قرار گرفتند. داده‌های PPG-DaLiA نشان دادند که سامانه‌های لبه‌ای با وجود محدودیت منابع، می‌توانند داده‌های زیستی را با دقت مناسب پردازش کنند (Reiss, A 2019). این مطالعات زمینه‌ساز استفاده گسترده از مدل‌های یادگیری در محیط‌های زمان‌واقعی شد. در سال ۲۰۲۰، تمرکز پژوهش‌ها بر توسعه روش‌های یادگیری ماشین و عمیق برای اینترنت اشیاء بود. این دوره با بررسی جامع روش‌های امنیت، یادگیری و تحلیل داده همراه شد و اهمیت معماری‌های سبک و امن را برجسته کرد (AlGaradi 2020). با پیشرفت پردازنده‌های لبه، از ۲۰۲۲ به بعد توجه پژوهشگران به سمت یادگیری بلادرنگ و زمان‌بندی وظایف هوشمند جلب شد. مطالعاتی درباره زمان‌بندی بلادرنگ مدل‌های یادگیری عمیق (Li, H ۲۰۲۲) و تقطیر دانش برای کاربردهای لبه (Cao, K 2022) نشان دادند که می‌توان کارایی مدل‌های سنگین را بدون کاهش دقت حفظ کرد. همچنین روش‌های بلادرنگ برای انتقال دانش و کاهش تأخیر معرفی شدند (Gao, Z 2024). مرحله

مهم‌تر پیشرفت‌ها در سال ۲۰۲۳ رقم خورد. زمانی که رویکردهای یادگیری مادام‌العمر، پیش‌بینی زمانی و معماری‌های قابل پیش‌بینی بلادرنگ وارد ادبیات شدند. نتایج پژوهش‌هایی چون DeepRT، راهکارهای مقابله با پدیده فراموشی فاجعه‌بار همچون EWC (Liu, Y۲۰۲۳) و نیز معماری‌های تطبیقی مبتنی بر لبه (Zhang, Q۲۰۲۳) نشان می‌دهد که امکان پیاده‌سازی یادگیری مادام‌العمر در محیط‌های دارای محدودیت زمانی سخت، بدون نقض مهلت‌های عملیاتی، وجود دارد (Xu, R۲۰۲۳). در نهایت، جدیدترین مطالعات ۲۰۲۴ به ترکیب سیستم‌های نمادین و عصبی در قالب معماری‌های ترکیبی پرداخته شد. این پژوهش‌ها ثابت کرده‌اند که ترکیب قواعد فازی با یادگیری عمیق می‌تواند هم دقت و هم تبیین‌پذیری را بهبود دهد (۲۰۲۴ Zhang, 2023, Wang, X2024, Chen, Z). همچنین بررسی‌های جدید بر تقطیر دانش بلادرنگ و سامانه‌های هوشمند صنعتی، مسیر توسعه معماری‌های ترکیبی واقعی را هموار کرده‌اند. (Gao, Z2024)

تحقیقات نوین در حوزه اینترنت اشیا و یادگیری عمیق عموماً در سه دسته اصلی قابل تفکیک هستند. دسته نخست شامل مدل‌های سبک‌وزن بهینه‌شده برای اجرا در لبه است، که نمونه‌ای از آن‌ها شبکه‌های عصبی کانولوشنی مختص پردازش داده‌های حسگری می‌باشد. با وجود کارایی قابل توجه، این دسته غالباً فاقد تضمین‌های لازم برای زمان‌بندی سخت بلادرنگ هستند (Kim, J 2024، Lin, J 2023). به‌عنوان مثال در حوزه نگهداری پیش‌بینانه، از مدل‌های مبتنی بر شبکه عصبی برای پیش‌بینی عمر باقی‌مانده تجهیزات استفاده می‌شود، اما چالش ناهمگونی ذاتی داده‌های حسگرها در آن‌ها کمتر مورد توجه قرار گرفته است (Saxena, S 2023). دسته دوم، سیستم‌های خبره تطبیقی و رویکردهای تلفیقی عصبی نمادین را دربرمی‌گیرد که با ترکیب منطق فازی و یادگیری عمیق، قابلیت تبیین‌پذیری تصمیم‌ها را ارتقا می‌بخشند. با این حال، این رویکردها اغلب در محیط‌های عملیاتی بلادرنگ با افت عملکرد مواجه می‌شوند (Kirk, R 2024, Lin, W 2017). مطالعاتی نیز نشان می‌دهند اگرچه سیستم‌های خبره در شناسایی برخی الگوهای پیچیده مانند حملات سایبری توانمند هستند، اما قابلیت یادگیری تطبیقی و به‌روزرسانی پویا از جریان داده‌های جدید در آن‌ها کمرنگ است (Al-Garadi 2020). دسته سوم به الگوریتم‌های زمان‌بندی بلادرنگ برای وظایف هوش مصنوعی اختصاص دارد که با روش‌هایی مانند اولویت‌دهی مبتنی بر میزان فوریت مهلت‌های زمانی وظایف به تخصیص بهینه منابع در لبه می‌پردازند. نقطه ضعف عمده این دسته، عدم ادغام اثرگذار با چارچوب‌های یادگیری مادام‌العمر است (Chen, T 2022، Li, H 2022).

پژوهش‌های اخیر در حوزه یادگیری لبه عمدتاً به سمت ساخت مدل‌های سبک رفته‌اند تا بتوانند نیازهای محاسباتی سیستم‌های زمان‌واقعی را پوشش دهند؛ اما بسیاری از این مدل‌ها، به دلیل تکیه بر معماری‌های صرفاً عصبی، مقاومت کمی در برابر تغییرات داده نشان داده‌اند (Kim, J 2024، Lin, J 2023). در مقابل، مطالعاتی که بر سیستم‌های خبره تطبیقی تمرکز دارند، توانسته‌اند شفافیت تصمیم‌گیری را افزایش دهند، اما در محیط‌های پویا، سرعت و پایداری کافی را ارائه نکرده‌اند (Kirk, R 2024، Lin, W 2017، Al-Garadi 2020).

۲.۱ چارچوب مفهومی و معماری پیشنهادی

معماری پیشنهادی در این پژوهش، متشکل از پنج لایه اصلی و یکپارچه است که در ادامه به توصیف هر یک پرداخته می‌شود:

۱. لایه حسگر و پیش‌پردازش لبه‌ای: این لایه مسئول جمع‌آوری داده‌های خام از حسگرهای مختلف و انجام پردازش‌های اولیه در محل است. برای کاهش ناهمگونی و افزایش کیفیت داده‌ها، از یک فیلتر کالمن تطبیقی همراه با الگوریتم حذف نویز مبتنی بر انحراف مطلق میانه استفاده می‌شود. این رویکرد موجب کاهش مؤثر نویز و افزایش پایداری داده‌های ورودی به لایه‌های بعدی می‌گردد. (Reiss, A2019, Al-Garadi 2020).

۲. موتور زمان‌بندی بلادرنگ: برای تضمین رعایت مهلت‌های سخت در محیط‌های عملیاتی، یک موتور زمان‌بندی پیش‌گیرانه طراحی شده است. این موتور از الگوریتم اولویت‌دهی بر اساس نزدیک‌ترین مهلت بهره می‌برد. مکانیزم وراثت اولویت بین وظایف نیز در آن پیاده‌سازی شده است. قابلیت خروج زودهنگام از فرآیند استنتاج در صورت عدم نیاز به پردازش کامل، در نظر گرفته شده است. تنظیم پویای ولتاژ و فرکانس نیز در این موتور گنجانده شده است. این ترکیب، مدیریت بهینه منابع و پایداری به محدودیت‌های زمانی را ممکن می‌سازد. (Kim, Li, H 2022). (J 2024)

۳. موتور یادگیری عمیق تطبیقی: در این بخش، یک معماری سبک‌وزن مبتنی بر ترکیب شبکه‌های عصبی کانولوشنی زمانی و حافظه‌های کوتاه‌مدت بلند طراحی شده است. برای جلوگیری از پدیده فراموشی فاجعه‌بار در یادگیری مادام‌العمر، از روش تثبیت انعطاف‌پذیر پارامترها همراه با یک بافر بازپخش کوچک استفاده می‌شود که امکان به‌روزرسانی مدل بدون تخریب دانش قبلی را فراهم می‌کند (He, K 2023, Liu, Y 2023).

۴. سیستم خبره فازی تطبیقی: این مؤلفه شامل یک پایگاه دانش پویا مبتنی بر ۳۲۰ قاعده فازی است که به‌طور برخط و با استفاده از بهینه‌سازی مبتنی بر گرادینت به‌روز می‌شود. همچنین، یک موتور استنتاج با پیچیدگی زمانی قابل پیش‌بینی در نظر گرفته شده که ضمن حفظ شفافیت و تبیین‌پذیری تصمیم‌ها، قابلیت اجرا در محیط‌های بلادرنگ را دارا باشد (Zhang, L2023, Lin, W 2017).

۵. لایه تقطیر دانش دوطرفه: برای انتقال کارآمد دانش بین سرور و گره‌های لبه، از یک مکانیزم تقطیر دانش دوطرفه با دوره تناوب ده دقیقه استفاده می‌شود. در این فرآیند، از روش‌های مبتنی بر پاسخ‌های مدل، ویژگی‌های لایه‌های میانی و فشرده‌سازی تفاضلی بهره گرفته می‌شود تا حجم تبادلات کاهش یافته و دانش با حداقل افت کیفیت انتقال یابد (Gao, Z 2024, Cao, K 2022).

چارچوب پیشنهادی، یک معماری یکپارچه و پنج‌لایه برای یادگیری تطبیقی، تبیین‌پذیر و بلادرنگ در محیط لبه‌ارائه می‌دهد. این معماری متشکل از لایه‌های پیش‌پردازش داده (برای پاک‌سازی و کاهش نویز)، زمان‌بندی بلادرنگ (برای تضمین مهلت‌های سخت)، یادگیری عمیق تطبیقی (برای استخراج الگو و به‌روزرسانی مداوم)، سیستم خبره فازی (برای افزایش شفافیت و انعطاف تصمیم‌گیری) و تقطیر دانش دوطرفه (برای انتقال کارآمد دانش بین مؤلفه‌ها) است. هم‌افزایی این لایه‌ها، دقت محاسباتی، تبیین‌پذیری و پایبندی به محدودیت‌های زمانی را به‌طور همزمان در دستگاه‌های لبه با منابع محدود فراهم می‌سازد و پاسخی یکپارچه به چالش‌های اصلی این حوزه محسوب می‌شود.

۳ روش‌شناسی پژوهش

این پژوهش با به‌کارگیری یک روش‌شناسی سه‌مرحله‌ای ساختاریافته و جامع، به ارزیابی دقیق و چندبُعدی معماری پیشنهادی می‌پردازد.

۱. ۳ مرحله اول: پیاده‌سازی و استقرار بر بستر سخت‌افزاری واقعی لبه

در گام نخست، معماری طراحی‌شده بر روی پلتفرم‌های سخت‌افزاری پرکاربرد و در دسترس حوزه لبه است که شامل پردازنده‌های پیشرفته‌ای چون NVIDIA Jetson Nano، پیاده‌سازی و مستقر می‌گردد. برای تضمین الزامات حیاتی سیستم‌های بلادرنگ، یک سیستم عامل بلادرنگ بر روی این گره‌ها پیکربندی می‌شود تا قابلیت اطمینان، پیش‌بینی‌پذیری و کنترل دقیق بر زمان‌بندی وظایف فراهم گردد. این مرحله امکان اندازه‌گیری مستقیم و عینی شاخص‌های کلیدی از جمله کارایی محاسباتی، مصرف توان و میزان پایبندی به مهلت‌های سخت زمانی را در یک محیط عملیاتی و با تمام محدودیت‌های ذاتی سخت‌افزار لبه فراهم می‌کند.

۲. ۳ مرحله دوم: شبیه‌سازی جامع در مقیاس شبکه‌های گسترده

با هدف تحلیل رفتار سیستم تحت بار کاری سنگین و بررسی قابلیت مقیاس‌پذیری آن، مرحله دوم به شبیه‌سازی محیط‌های پیچیده لبه و محاسباتی اختصاص می‌یابد. در این مرحله، سناریوهای بزرگ‌مقیاس با استفاده از ابزارهای تخصصی شبیه‌سازی پیاده‌سازی می‌شود تا توپولوژی‌های توزیع‌شده، ناهمگونی گره‌ها و ترافیک شبکه واقعی مدل شوند. پارامترهای مهمی از قبیل تأخیر انتها به انتها، توان عملیاتی، نرخ پردازش کارها، مصرف انرژی در سطح شبکه و قابلیت تحمل خطا به دقت مورد سنجش و تحلیل قرار خواهد گرفت. این شبیه‌سازی‌ها بینشی ارزشمند در مورد عملکرد سیستم در ابعاد بزرگ و قبل از استقرار هزینه‌بر فراهم می‌نماید.

۳. ۳ مرحله سوم: ارزیابی تجربی مبتنی بر مجموعه داده‌های واقعی و معتبر

برای سنجش اثربخشی و دقت معماری پیشنهادی در حل مسائل واقعی، مرحله‌نهایی به ارزیابی تجربی با استفاده از دو مجموعه داده معتبر در حوزه‌های کاربردی مهم اینترنت اشیا اختصاص می‌یابد. از مجموعه داده واقعی برای ارزیابی می‌توان استفاده کرد.

۳.۴. مقایسه با روش‌های پایه و پیشرفته موجود

به منظور قضاوت عینی درباره عملکرد، معماری پیشنهادی می‌بایست در معرض مقایسه مستقیم با طیف وسیعی از روش‌های مرجع قرار گیرد. این مجموعه مقایسه‌ای شامل موارد زیر است: مدل‌های تک‌سازه‌ای مانند شبکه عصبی عمیق ایستا و سیستم خبره فازی مستقل؛ مدل‌های بهینه‌شده سبک‌وزنی که خاص محیط لبه طراحی شده‌اند؛ و نیز معماری‌های تلفیقی پیشرفته‌تر که اخیراً برای یادگیری عمیق بلادرنگ در لبه ارائه شده است. این مقایسه جامع، امکان درک دقیق مزایا، نوآوری‌ها و احتمالات نقاط قوت و ضعف راهکار پیشنهادی نسبت به گزینه‌های موجود را فراهم می‌سازد.

این چارچوب روش‌شناختی منسجم، امکان اعتبارسنجی همه‌جانبه معماری پیشنهادی را (از آزمایش‌های فیزیکی گرفته تا شبیه‌سازی‌های گسترده و ارزیابی با داده‌های واقعی) مهیا کرده است و پایه‌ای محکم برای استنتاج نتایج معتبر و قابلیت تعمیم‌پذیری یافته‌های پژوهش ایجاد می‌نماید.

۴ نتیجه‌گیری

این پژوهش یک معماری نوین ارائه می‌دهد که برای نخستین بار، یادگیری مادام‌العمر را در محیط‌های بلادرنگ با مهلت‌های سخت، بدون نقض این محدودیت‌ها، ممکن می‌سازد. ترکیب همزمان قواعد فازی و شبکه عصبی عمیق در این معماری، موجب افزایش همزمان دقت، سرعت و شفافیت تصمیم‌گیری شده است. همچنین، مکانیزم تقطیر دانش برخط، چالش به‌روزرسانی مدل در دستگاه‌های لبه با منابع محدود را به طور مؤثر حل کرده است. یافته‌ها در ادبیات پیشین تأکید می‌کند، که یکپارچه‌سازی دانش نمادین (فازی) و یادگیری عمیق، محدودیت‌های هر دو پارادایم را کاهش می‌دهد و تقطیر دانش، راهکاری کلیدی برای افزایش استقلال و کارایی سیستم‌های لبه است. با این وجود، وابستگی عملکرد مدل به کیفیت داده‌های ورودی به عنوان یک محدودیت اصلی باقی است که همسو با چالش عمومی در محیط‌های ناهمگن داده است. بنابراین، اگرچه این معماری گامی مهم در پوشش شکاف‌های پژوهشی فعلی است، ولی بررسی پایداری بلندمدت یادگیری و بهبود مقاومت در برابر داده‌های نویزی، زمینه‌هایی برای پژوهش‌های آتی به شمار می‌روند.

این پژوهش، یک معماری نوین برای تصمیم‌گیری ترکیبی بلادرنگ در اینترنت اشیا ارائه می‌دهد که به‌طور همزمان چهار شاخص کلیدی تأخیر، دقت، شفافیت و پایداری به مهلت زمانی را بهبود می‌بخشد. ارزیابی بر مهم‌ترین دستاوردها عبارتند از: امکان یادگیری مادام‌العمر بدون افزایش تأخیر، انتقال بلادرنگ دانش بین لایه‌ها و کارایی عملی بر روی سخت‌افزارهای کم‌مصرف لبه است. این قابلیت‌ها، بستری قدرتمند برای به‌کارگیری هوش مصنوعی در صنایع حساس و بلادرنگ مانند هوایی، پزشکی و تولید هوشمند فراهم می‌کند. در مجموع، این معماری گامی

مهم در جهت پوشش شکاف بین نیازهای عملیاتی سامانه‌های لبه و محدودیت‌های مدل‌های یادگیری عمیق به‌شمار می‌رود و پایه‌ای برای توسعه نسل آینده سیستم‌های هوشمند بلادرنگ محسوب می‌شود.

منابع

1. Al-Garadi, M. A., et al. (2020). A survey of machine and deep learning methods for internet of things (IoT) security. *IEEE Communications Surveys & Tutorials*, 22(3), 1646–1685.
2. Lin, J., et al. (2023). Edge intelligence: On-device continual learning for IoT. *IEEE Internet of Things Journal*, 10(5), 4123–4138.
3. Xu, R., et al. (2023). DeepRT: Predictable deep learning inference for real-time systems. *Real-Time Systems*, 59(2), 123–156.
4. Lin, W. Yu, N. Zhang, X. Yang, H. Zhang and W. Zhao, "A Survey on Internet of Things: Architecture, Enabling Technologies, Security and Privacy, and Applications," *IEEE Internet of Things Journal*
5. Chen, Z., et al. (2024). Real-time hybrid neuro-symbolic architecture for edge intelligence. *IEEE Transactions on Industrial Informatics*, 20(3), 2890–2901.
6. Mohammadi, M., et al. (2023). Deep learning meets stream processing: A comprehensive survey. *ACM Computing Surveys*, 55(12), 1–38.
7. Zhang, Q., et al. (2023). Continuously adaptive learning for edge devices with knowledge distillation. *IEEE Internet of Things Journal*, 10(8), 6789–6801.
8. Li, H., et al. (2022). Real-time scheduling of deep learning tasks on edge devices. *IEEE Transactions on Computers*, 71(10), 2456–2468.
9. Kirk, R., et al. (2024). Survey of neuro-symbolic approaches for continual learning. *Artificial Intelligence Review*, 57(1), 1–45.
10. Zhou, Y., et al. (2023). EdgeAI meets real-time systems: A survey. *Journal of Systems Architecture*, 142, 102954.
11. Cao, K., et al. (2022). Real-time knowledge distillation for edge intelligence. *IEEE Transactions on Neural Networks and Learning Systems*, 33(11), 6789–6801.
12. Gao, Z., et al. (2024). Knowledge distillation for real-time edge applications: A survey. *IEEE Transactions on Knowledge and Data Engineering*, 36(5), 2100–2118.
13. Kim, J., et al. (2024). Early-exit inference for real-time edge AI. *IEEE Internet of Things Journal*, 11(4), 5678–5690.
14. Liu, Y., et al. (2023). Elastic weight consolidation for lifelong learning on edge devices. *Neurocomputing*, 521, 156–168.
15. Yang, Q., et al. (2023). Continual learning meets real-time constraints: A benchmark. *IEEE Transactions on Industrial Informatics*, 19(6), 7890–7901.

16. Murshed, M., et al. (2023). Edge real-time systems: A comprehensive survey. *Future Generation Computer Systems*, 140, 289–310.
17. He, K., et al. (2023). Temporal convolutional networks for edge time-series prediction. *IEEE Internet of Things Journal*, 10(12), 10456–10468.
18. Saxena, S., et al. (2023). NASA CMAPSS dataset updates and benchmarks for predictive maintenance. *Journal of Intelligent Manufacturing*, 34(1), 123–145.
19. Reiss, A., et al. (2019). PPG-DaLiA: Daily life activities dataset with PPG and motion sensors. *Proceedings of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies*, 3(2), 1–25.
20. Wang, X., et al. (2024). Hybrid expert system with adaptive fuzzy rules for industrial IoT. *Expert Systems with Applications*, 238, 121987.
21. Zhang, L., et al. (2023). Real-time fuzzy inference engine for embedded systems. *IEEE Embedded Systems Letters*, 15(2), 89–92.
22. Chen, T., et al. (2022). A survey on real-time scheduling for deep learning. *ACM Computing Surveys*, 55(7), 1–38.