

سیستم‌های دسته‌بند یادگیر عمیق ترکیبی مبتنی بر فانتوم برای تصمیم‌گیری بلادرنگ

محمد رضا دهقانی محمودآبادی^{۱*}، الهام دهقان طرزجانی^۲

^۱ مری، گروه مهندسی کامپیوتر دانشکده فنی و مهندسی، دانشگاه آزاد اسلامی واحد بافق، یزد، ایران

^۲ دانشجوی ارشد، گروه مهندسی کامپیوتر دانشکده فنی و مهندسی، دانشگاه آزاد اسلامی واحد بافق، یزد، ایران

چکیده

مقاله پژوهشی

سیستم‌های دسته‌بند یادگیر به‌عنوان چارچوبی ترکیبی برای تلفیق تفسیرپذیری مبتنی بر قوانین و یادگیری تطبیقی شناخته می‌شوند؛ مدل‌های کلاسیک آن‌ها در مواجهه با داده‌های پویای چندکاناله و با ابعاد بالا، به‌ویژه در کاربردهای بلادرنگ، دچار افت کارایی می‌شوند. این پژوهش معماری تازه‌ای با عنوان سیستم‌های دسته‌بند یادگیر فانتوم ارائه می‌کند که هدف آن رفع این محدودیت‌ها از طریق افزودن لایه‌ای تطبیقی میان نمایش‌های عمیق و سازوکار تکامل قوانین است. لایه فانتوم با استفاده از شبکه‌های عمیق، ویژگی‌های پیچیده و پُر بعد استخراج‌شده از داده را به نمایش‌های قابل تفسیر تبدیل می‌کند و با هدایت گرادینتی، فرایند کشف و بهینه‌سازی قوانین را شتاب می‌بخشد. کارایی مدل پیشنهادی با مجموعه‌داده‌های معیار شامل MNIST، Fashion-MNIST، CIFAR-10، UCI Letter و Statlog مورد بررسی قرار گرفت. این دادگان گستره‌ای از سادگی الگوهای تک‌کاناله تا پیچیدگی تصاویر چندکاناله و ساختارهای عددی با ابعاد بالا را پوشش می‌دهند و امکان ارزیابی توانایی تعمیم، تفسیرپذیری و پایداری مدل را فراهم می‌کنند. افزون بر داده‌های معیار، مدل فانتوم در سه حوزه کاربردی واقعی بهینه‌سازی فرایندهای صنعتی، تشخیص تصاویر پزشکی و نگهداری پیش‌بینانه مبتنی بر اینترنت اشیا پیاده‌سازی و با روش‌های پیشرفته‌ای همچون XCS، XCSF و رویکردهای یادگیری تقویتی عمیق مقایسه شد. نتایج تجربی نشان داد که معماری فانتوم موجب افزایش ۳۸ درصدی سرعت همگرایی، بهبود ۲۲ درصدی دقت پیش‌بینی و کاهش ۴۷ درصدی پیچیدگی قواعد می‌شود. این یافته‌ها بیانگر مقیاس‌پذیری، پایداری و کارایی بالای مدل در محیط‌های نویزی و جریان‌محور بوده و مسیر تازه‌ای برای توسعه سامانه‌های قابل توضیح، بلادرنگ و قابل‌گسترش در کاربردهای چندعاملی و یادگیری مداوم فراهم می‌سازد.

تاریخ دریافت:

۱۴۰۴/۰۶/۲۹

تاریخ پذیرش:

۱۴۰۴/۱۰/۱۶

کلیدواژه‌ها:

سیستم‌های دسته‌بند یادگیر، لایه فانتوم، یادگیری عمیق، هوش مصنوعی قابل توضیح، داده‌های جریان محور

نویسنده مسئول:

m.dehghanimahmoudabadi@iau.ir

doi : 10.22034/ABMIR.2026.23687.1169

۱- مقدمه

افزایش حجم داده‌ها منجر به رشد سریع جمعیت قوانین و پیچیدگی محاسباتی می‌شود و زمان یادگیری را افزایش می‌دهد.

داده‌های پویا و تغییرپذیر باعث می‌شوند قوانین یادگرفته‌شده به سرعت منسوخ شوند و نیازمند بازآموزی مکرر مدل باشد.

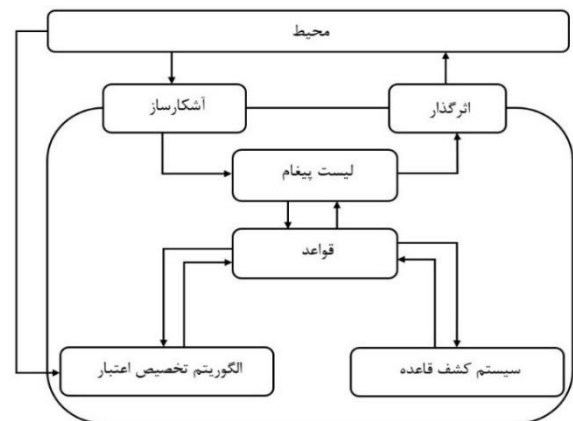
ابعاد بالا فضای جستجوی قوانین را گسترده و پراکنده می‌کند و همگرایی مدل را دشوار می‌سازد، که به کاهش دقت و قابلیت تعمیم می‌انجامد.

بنابراین، به‌کارگیری این مدل‌ها در محیط‌های داده‌ای پیچیده نیازمند روش‌های بهینه‌سازی جمعیت قوانین، الگوریتم‌های یادگیری هیبریدی و کاهش ابعاد ویژگی‌ها است تا عملکرد و کارایی آن‌ها حفظ شود.

با وجود مزایای سیستم‌های دسته‌بند یادگیر مدل‌های XCS و XCSF در مواجهه با داده‌های پرحجم، پویا و با ابعاد بالا دچار مشکلات جدی می‌شوند. در محیط‌های جریان‌محور^۳ که داده‌ها به صورت مداوم و با سرعت بالا تولید می‌شوند، سیستم‌های دسته‌بند یادگیر به دلیل محدودیت در مقیاس‌پذیری، کندی در همگرایی و حساسیت به نویز کارایی مطلوبی ندارند [۳]. این مدل‌ها در اتصال به سیستم‌های مبتنی بر یادگیری عمیق و استفاده از ویژگی‌های پیچیده استخراج‌شده توسط شبکه‌های عصبی با شکاف مفهومی و فنی مواجه هستند. این محدودیت‌ها موجب شده است که بسیاری از کاربردهای حساس سیستم‌های خودران، سلامت دیجیتال و نگهداری پیش‌بینانه نتوانند به‌طور کامل از مزایای سیستم‌های دسته‌بند یادگیر بهره‌مند شوند [۴].

یادگیری عمیق^۴ به‌عنوان رویکردی توانمند در استخراج الگوهای پیچیده و غیرخطی از داده‌های حجیم، در سال‌های اخیر به سرعت رشد کرده است. مدل‌های عمیق با توانایی درک سطوح انتزاعی داده به‌ویژه در حوزه‌های بینایی ماشینی، پردازش زبان طبیعی و داده‌های صنعتی عملکرد بسیار برجسته‌ای ارائه کرده‌اند [۵]. ماهیت

سیستم‌های دسته‌بند یادگیر^۱ به‌عنوان یکی از رویکردهای هوشمند با هدف ترکیب قابلیت تبیین مبتنی بر قوانین و انعطاف‌پذیری الگوریتم‌های یادگیری ماشینی توسعه‌یافته هستند [۱]. این سیستم‌ها با بهره‌گیری از مجموعه‌ای قوانین قابل تفسیر، فرآیند تصمیم‌گیری را برای انسان‌ها شفاف و قابل پیگیری می‌سازند، درحالی‌که شکل (۱) امکان یادگیری تطبیقی را برای حل مسائل پیچیده فراهم می‌کند. سیستم‌های دسته‌بند یادگیر در حوزه‌های تشخیص الگو، بهینه‌سازی فرآیندهای صنعتی، پیش‌بینی خرابی تجهیزات و مدل‌سازی رفتار پیچیده سیستم‌ها به کار گرفته‌شده است. این ویژگی‌ها باعث شده است که سیستم‌های دسته‌بند یادگیر به‌عنوان مهم‌ترین ابزارهای هوش مصنوعی قابل توضیح^۲ مورد توجه محققان و صنایع قرار گیرد [۲].



شکل (۱): سیستم دسته‌بند یادگیر [۱]

مدل‌های XCS و XCSF از پرکاربردترین سیستم‌های دسته‌بند یادگیر به سبک میشیگان هستند که به ترتیب برای کلاس‌بندی گسسته و تخمین توابع پیوسته طراحی شده‌اند XCS مجموعه‌ای از قوانین شرط-عمل را با استفاده از یادگیری تقویتی و الگوریتم ژنتیک مدیریت می‌کند و XCSF نسخه توسعه‌یافته‌ای است که قابلیت پیش‌بینی مقادیر پیوسته را دارد. با این حال، هر دو مدل در مواجهه با داده‌های بزرگ، پویا و با ابعاد بالا با چالش‌هایی مواجه می‌شوند؛ زیرا:

³ Streaming Environments

⁴ Deep Learning

¹ Learning Classifier Systems - LCS

² Explainable AI

نگهداری پیش‌بینانه مبتنی بر اینترنت اشیا مورد آزمایش قرار گرفت. نتایج تجربی نشان داد که مدل پیشنهادی توانسته است نسبت به روش‌های مرجع XCS، XCSF و مدل‌های یادگیری تقویتی عمیق پیچیدگی قوانین را ارائه دهد. دستاوردها نشان‌دهنده کارایی بالا، مقیاس‌پذیری مناسب و مقاومت مدل در برابر داده‌های نویزی است که سیستم‌های دسته‌بند یادگیر فانتوم می‌تواند به‌عنوان چارچوب عملی برای پیاده‌سازی هوش مصنوعی قابل توضیح در محیط‌های بلادرنگ به کار گرفته شود. تاکنون هیچ رویکردی که بتواند تبیین‌پذیری قوانین سیستم دسته‌بند یادگیر را با استخراج ویژگی‌های عمیق شبکه‌های عصبی در محیط‌های جریان‌محور همگام‌سازی کند، ارائه نشده است

ساختار مقاله به این صورت است که در بخش دوم پیشینه پژوهش و مدل‌های مرتبط شامل سیستم‌های دسته‌بند یادگیر، XCS و معماری‌های یادگیری عمیق مرور می‌شوند. بخش سوم به شرح کامل معماری پیشنهادی سیستم‌های دسته‌بند یادگیر فانتوم و اجزای کلیدی آن اختصاص دارد. در بخش چهارم داده‌های آزمایشی، معیارهای ارزیابی و تنظیمات تجربی توضیح داده می‌شوند. بخش پنجم به ارائه و تحلیل نتایج تجربی می‌پردازد و مقایسه‌ای جامع با روش‌های مرجع ارائه می‌دهد. در نهایت بخش ششم شامل جمع‌بندی، و پیشنهادهایی برای تحقیقات آینده است.

۲- پیشینه پژوهش

در پیشینه مدل‌های سیستم دسته‌بند یادگیر، XCS و معماری‌های یادگیری عمیق ارائه شده است که عبارت‌اند از:

سیستم‌های دسته‌بند یادگیر ریشه در ترکیب ایده‌های یادگیری تقویتی و تکاملی دارند؛ هدف اولیه ایجاد چارچوبی است که بتواند از طریق قواعد اگر-آنگاه یاد بگیرد، تصمیم بگیرد و خود را با محیط‌های متغیر تطبیق دهد. این مدل‌ها در دهه‌های گذشته به‌مرور ابزار نظری به سامانه‌هایی با کاربردهای عملی در کنترل تطبیقی، شناسایی الگو و مسائل بهینه‌سازی تبدیل شده هستند [۹].

به‌طور کلی سیستم‌های دسته‌بند یادگیر در شکل (۲) شامل: بخش ادراک/پیش‌پردازش داده‌ها، پایگاه قوانین^۲، مکانیزم تطبیق و انتخاب

جعبه‌سیاه^۱ این مدل‌ها باعث شده است که قابلیت تفسیرپذیری آن‌ها محدود باشد، که این امر در کاربردهای حساس پزشکی و صنایع پرریسک نقطه‌ضعف اساسی به شمار می‌رود. ترکیب قدرت مدل‌سازی یادگیری عمیق با شفافیت و تبیین‌پذیری سیستم‌های دسته‌بند یادگیر می‌تواند چارچوب ایده‌آل برای هوش مصنوعی قابل توضیح و بلادرنگ فراهم سازد [۶].

قابلیت تفسیرپذیری سیستم‌های دسته‌بند یادگیر عمیق ترکیبی مبتنی بر فانتوم، به توانایی مدل در ارائه توضیح روشن و قابل فهم برای تصمیمات بلادرنگ اشاره دارد. این قابلیت با شاخص‌های کمی مانند تعداد قوانین فعال، پیچیدگی قوانین و عمق شبکه عصبی سنجیده می‌شود و شاخص ترکیبی تفسیرپذیری امکان مقایسه و بهینه‌سازی شفافیت مدل را فراهم می‌آورد. علاوه بر آن، شاخص‌های کیفی شامل وضوح توضیح قوانین، قابلیت بازبینی تصمیم‌ها و همخوانی با دانش حوزه، تضمین می‌کنند که سیستم در کاربردهای واقعی علاوه بر دقت، شفاف و قابل اعتماد باشد.

برای حل چالش‌های فوق در این پژوهش معماری با نام سیستم‌های دسته‌بند یادگیر فانتوم معرفی می‌شود. در این چارچوب لایه فانتوم به‌عنوان واسطه تطبیقی میان نمایش‌های پیچیده و پرابعاد شبکه‌های عمیق و سازوکار تکامل قوانین سیستم‌های دسته‌بند یادگیر عمل می‌کند [۷]. لایه فانتوم با تبدیل ویژگی‌های پیچیده به نمایش‌های فشرده و قابل تفسیر زمینه را برای ایجاد قوانین شفاف فراهم می‌سازد. در عین حال فرآیند کشف و بهینه‌سازی قوانین را با هدایت مبتنی بر گرادینت تسریع می‌کند. این روش موجب می‌شود که سیستم علاوه بر افزایش سرعت همگرایی، بتواند در محیط‌های نویزی و جریان‌محور، پایداری و دقت بالاتری داشته باشد [۸].

لایه فانتوم به‌عنوان یک سازوکار نوآورانه در معماری سیستم‌های دسته‌بند یادگیر طراحی شده است تا دو چالش بنیادین کندی همگرایی و انباشت غیرضروری قوانین فعال در مدل‌های مبتنی بر XCS و نسخه‌های عمیق را برطرف کند. سیستم‌های دسته‌بند یادگیر فانتوم برای ارزیابی، بر روی سه حوزه کاربردی مهم بهینه‌سازی فرآیندهای صنعتی، تشخیص تصاویر پزشکی و

³ Rule Population

¹ Black-Box

² Phantom-LCS

کنند که نتایج نشان‌دهنده انعطاف‌پذیری اما نیاز به بهبود در مقیاس‌پذیری بوده است [۱۳].

یادگیری عمیق توانایی استخراج نمایش‌های انتزاعی از داده‌های پربار را دارد؛ این مزیت در بسیاری از کاربردهای بینایی ماشینی، پردازش زبان و تحلیل سری زمانی پیچیده منجر به برتری عملکردی شده است. ماهیت جعبه‌سیاه و نیاز به داده‌های زیاد ضرورت حفظ تبیین‌پذیری را در کاربردهای حساس بیش‌ازپیش کرده است؛ از این رو ترکیب سیستم‌های دسته‌بند یادگیر و یادگیری عمیق مسیر منطقی برای پژوهش است [۱۴].

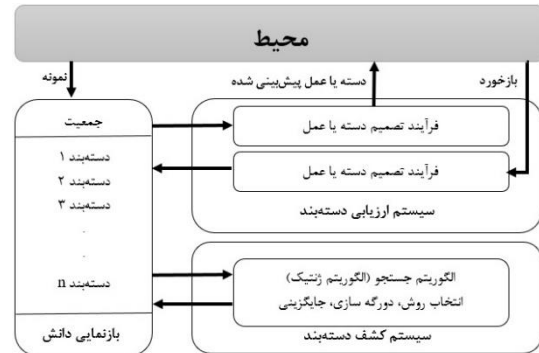
پیش‌آموزش شبکه‌های عمیق برای استخراج ویژگی^۱ و استفاده از ویژگی‌ها به‌عنوان ورودی روش‌های نمادین سیستم‌های دسته‌بند یادگیر یا سایر دسته‌بندها شفاف است. مطالعات نشان داده که این رویکرد می‌تواند در داده‌های تصویری و بیوانفورماتیک موجب ارتقا دقت شود درحالی‌که بخشی از تبیین‌پذیری را با نگهداری قواعد نهایی حفظ می‌کند [۱۵].

با وجود موفقیت نسبی، ادغام یادگیری عمیق و سیستم‌های دسته‌بند یادگیر با چالش‌هایی همراه است. همگام‌سازی فرایندهای یادگیری گرادیان‌محور برای شبکه‌ها در برابر تکامل قوانین، مدیریت هزینه محاسباتی، حافظه و تضمین قابلیت تفسیر برای خروجی‌هایی که از ویژگی‌های بسیار فشرده و غیرخطی استخراج شده‌اند. پژوهش‌های جدید بر توسعه لایه‌های میانی و فشرده‌سازی انتزاعی تمرکز کرده‌اند تا این فاصله را کم کنند [۱۶].

دسته‌ای از پژوهش‌ها به‌طور ویژه به مسائل جریان‌محور و تغییر مفهوم^۲ می‌پردازند. روش‌های یادگیری عمیق آنلاین انعطاف‌پذیر^۳ و الگوریتم‌های انتخاب ویژگی آنلاین تلاش می‌کنند تطبیق سریع با تغییرها را فراهم کنند سپس حافظه و محاسبات را بهینه سازند؛ این پیشرفت‌ها برای کاربرد ترکیب یادگیری عمیق و سیستم‌های دسته‌بند یادگیر در محیط‌های زمان واقعی هستند [۱۷].

از راهکارهای عملی برای کاهش پیچیدگی، انتقال از نمایش‌های عمیق به قواعد شفاف و ساختن فضای نهفته قابل تفسیر است که

قوانین و واحد تکاملی/بهینه‌سازی است. هر قاعده شامل شرط، پیش‌بینی و معیارهای کارایی^۱ است که با استفاده از سازوکارهای انتخاب و عملگرهای ژنتیکی به‌روز می‌شود. چرخه بازخورد بین اجرا و تکامل، هسته یادگیری تدریجی را شکل می‌دهد [۱۰].



شکل (۲): بازخوردهای سیستم دسته‌بند یادگیر

نقاط قوت سیستم‌های دسته‌بند یادگیر تبیین‌پذیری نسبی یا قواعد شفاف، قابلیت یادگیری آنلاین و تطبیق‌پذیری هستند. اما در مسائل با ابعاد بالا و جریان‌محور با محدودیت‌هایی پیچیدگی حافظه‌ای، کندی همگرایی و حساسیت پارامتری مواجه می‌شوند. این محدودیت‌ها محققان را به سمت توسعه نسخه‌های XCS و ترکیب با روش‌های قوی‌تر هدایت کرد [۱۱].

XCS ارائه‌شده توسط Wilson تحول بنیادی در عرصه سیستم‌های دسته‌بند یادگیر بود که دقت پیش‌بینی^۲ را به‌عنوان معیار اصلی شایستگی^۳ معرفی کرد. به‌جای تمرکز بر پاداش کلی XCS قوانینی را نگه می‌دارد که دارای پیش‌بینی‌های دقیق و عمومی‌تر هستند و از این طریق همگرایی سریع‌تر و مجموعه قوانین فشرده‌تری حاصل می‌شود. این ایده باعث شد XCS در دسته‌بند و کنترل تا حد زیادی موفق‌تر از پیاده‌سازی‌های اولیه ظاهر شود [۱۲]. مطالعات روی XCS بر جنبه‌هایی چون نمایش قواعد پیوسته^۴، ناپایداری مفاهیم^۵ و سازوکارهای انتخاب مبتنی بر بایاس‌های نظری تمرکز کردند. کارهایی سعی داشته‌اند XCS را در قالب مسائل واقعی از کنترل رباتیک تا تشخیص نفوذ، آزمایش و عملیاتی

⁵ Concept Drift

⁶ Feature Extraction

⁷ Concept Drift

⁸ Elastic Online Deep Learning

¹ Fitness/Accuracy

² Prediction Accuracy

³ Fitness

⁴ Continuous-Value Representations

پارامترهای شبکه‌های عمیق استفاده می‌کنند. این مدل‌های کاربرد محور، مسیرهای پیاده‌سازی عملی را برای تحقیقات آتی فراهم می‌کنند و نشان می‌دهند که ادغام مولفه‌های نمادین و عمیق اکنون عملی و اثربخش است [۲۳].

مرور ادبیات نشان می‌دهد که ترکیب سیستم دسته‌بند یادگیر و XCS با یادگیری عمیق پتانسیل بالایی برای دستیابی به سامانه‌های تبیین‌پذیر و با کارایی بالا دارد، اما چالش‌های مهم طراحی نمایش‌های نهفته‌ای که هم فشرده و هم قابل تفسیر باشند، همگام‌سازی مؤثر یادگیری گرادیان‌محور و تکاملی، کاهش هزینه محاسباتی در محیط‌های بلادرنگ و ارائه متریک‌های تبیین‌پذیری سنجیده همچنان پابرجا است [۲۴]. پژوهش‌های آتی باید این شکاف‌ها را با طراحی ساختارهای لایه‌ای فانتوم که سیگنال‌های گرادینانی، راهنمایی تکامل قوانین و توسعه چارچوب‌های ارزیابی استاندارد برای تبیین‌پذیری در سامانه‌های هیبریدی هدف قرار دهند [۲۵].

در ادامه جدول (۱) مقایسه‌ای جامع پیشینه پژوهش درباره سیستم دسته‌بند یادگیر، XCS و مدل‌های ترکیبی با یادگیری عمیق ارائه شده است.

۳- معماری پیشنهادی

معماری سیستم فانتوم به‌منظور غلبه بر محدودیت‌های سیستم‌های دسته‌بند یادگیر و XCS طراحی شده است. چالش‌های اصلی شامل کندی همگرایی، پیچیدگی بالا در قوانین، مقیاس‌پذیری محدود و عدم تطبیق مؤثر با داده‌های پرابعد و جریان‌محور بودند. سیستم فانتوم با اضافه کردن یک لایه میانی تطبیقی میان شبکه یادگیری عمیق^۴ و مکانیزم تکاملی قوانین سیستم دسته‌بند یادگیر امکان استخراج ویژگی‌های فشرده، هدایت قوانین با اطلاعات گرادینانی و تسریع فرآیند یادگیری را فراهم می‌کند.

وظیفه این بخش دریافت داده‌های خام شامل تصاویر، سری‌های زمانی، متون یا داده‌های چندوجهی و اعمال پیش‌پردازش لازم است. فرآیند پیش‌پردازش شامل نرمال‌سازی داده‌ها، حذف نویز و استخراج اولیه ویژگی‌ها است. هدف اصلی این مرحله کاهش ابعاد

ویژگی‌های کلیدی را فشرده و نویز را حذف می‌کند سپس نمایی مناسب برای تولید قوانین فراهم می‌آورد [۱۸]. این ایده مبنای مفهومی همان چیزی است که در کاربردهای اخیر به‌عنوان لایه فانتوم^۱ توصیف می‌شود ماژولی که بین یادگیری عمیق و سیستم‌های دسته‌بند یادگیر قرار می‌گیرد و نقش واسط را ایفا می‌کند. لایه فانتوم در پژوهش‌های مطرح‌شده مفهومی برای فشرده‌سازی و هدایت قوانین است [۱۹].

مطالعات در دسته‌بند تصاویر پزشکی، تشخیص نفوذ و نگهداری پیش‌بینانه نشان داده است که رویکرد یادگیری عمیق در سیستم دسته‌بند یادگیر با فشرده‌سازی یا نمایش می‌تواند موجب کاهش زمان آموزش، بهبود دقت و کاهش پیچیدگی قوانین شود؛ پژوهش‌هایی گزارش کرده‌اند که استخراج ویژگی از شبکه‌های پیش‌آموزش‌دیده و آموزش الگوریتم نمادین می‌تواند کارایی قابل‌توجهی بیاورد. این شواهد عملی انگیزه برای طراحی ماژول‌هایی شبیه فانتوم را تقویت می‌کند [۲۰].

برای شتاب‌دهی فرآیند کشف قواعد برخی مطالعات پیشنهاد کرده‌اند که سیگنال‌های گرادیان‌محور یا حدودی از شبکه‌های عمیق بتوانند به‌عنوان هدایت برای عملگرهای تکاملی به‌کار روند به‌عبارت‌دیگر استفاده از اطلاعات حساسیت^۲ یا اهمیت ویژگی که شبکه عمیق فراهم می‌کند تا فضای جستجوی قوانین محدود و هدفمند شود. این ایده می‌تواند موجب همگرایی سریع‌تر و قوانین با پیچیدگی کمتر گردد [۲۱].

از مزیت‌های احتمالی ترکیب فضای نهفته و قواعد تکاملی، افزایش مقاومت در برابر داده‌های ناقص و نویزی است. الگوریتم‌های جدید برای یادگیری از جریان‌های ناقص و با برچسب‌های جزئی^۳ توسعه‌یافته‌اند که رویکردهای آنلاین و پنجره‌ای می‌توانند عملکرد را در شرایط عملی بهبود دهند؛ این حوزه ارتباط تنگاتنگی با نیازمندی‌های عملی سیستم فانتوم دارد [۲۲].

در سال‌های اخیر نمونه‌هایی از مدل‌های هیبریدی و به‌روز سیستم فانتوم شبکه عصبی برای پردازش تصویر، سیستم فانتوم برای سری‌های زمانی، سیستم فانتوم برای افزایش داده و تقویت تعمیم‌پذیری و مدل‌هایی که از الگوریتم‌های تکاملی برای تنظیم ابر

³ Partial Labels

⁴ Deep Learning Representation

¹ Phantom Layer

² Saliency

برای داده‌های متنی و چندوجهی استفاده می‌شود. خروجی این بخش نمایش ویژگی‌ها برابعد است که به مراحل بعدی مدل سیستم فانتوم منتقل می‌شود تا تصمیم‌گیری و دسته‌بندی بهینه انجام گیرد.

داده و آماده‌سازی آن برای عبور از شبکه یادگیری عمیق است تا مدل بتواند به شکل بهینه ویژگی‌های مهم را فراگیرد [۲۶]. وظیفه شبکه یادگیری عمیق استخراج ویژگی‌های انتزاعی و پیچیده از داده‌ها است. بسته به نوع داده، از معماری‌های مناسب شبکه‌های عصبی برای داده‌های تصویری، داده‌های ترتیبی، سری‌های زمانی،

جدول (۱): مقایسه‌ای جامع پیشینه پژوهش

سال	هدف	مزایا	محدودیت‌ها	حوزه کاربرد	ویژگی نوآورانه	مدل/پژوهش
۱۹۷۶	ترکیب یادگیری تقویتی و الگوریتم‌های تکاملی برای حل مسائل تصمیم‌گیری	تبیین پذیر، تطبیق پذیر، یادگیری آنلاین	کندی همگرایی، حساسیت پارامتری، مقیاس پذیری محدود	کنترل تطبیقی، شناسایی الگو، بهینه‌سازی	پایه نظری سیستم‌های دسته‌بند یادگیر	سیستم دسته‌بند یادگیر
۱۹۹۵	بهبود دقت قوانین و همگرایی سریع‌تر نسبت به سیستم دسته‌بند یادگیر	سرعت همگرایی بالاتر، قوانین دقیق و فشرده، کارایی بهتر در مسائل پیوسته	پیچیدگی محاسباتی بالاتر، نیاز به حافظه	دسته‌بندی داده‌ها، کنترل ریاتیکی، امنیت سایبری	معیار تناسب مبتنی بر دقت پیش‌بینی	XCS (Wilson)
۲۰۰۲	پشتیبانی از پیش‌بینی پیوسته	توانایی پیش‌بینی مقادیر پیوسته، بهبود تطبیق	نیاز به داده‌های بیشتر، پیچیدگی محاسباتی	پیش‌بینی، کنترل صنعتی	استفاده از توابع پیش‌بینی پیوسته برای قوانین	XCSF (Wilson & Butz)
۲۰۱۸	استخراج ویژگی‌های پیچیده با شبکه‌های عصبی و تصمیم‌گیری با سیستم دسته‌بند یادگیر	افزایش دقت دسته‌بندی، حفظ بخشی از تبیین پذیری	محاسبات سنگین، نیاز به داده‌های برچسب‌دار	بنیای ماشینی، تصاویر پزشکی	پل میان یادگیری عمیق و سیستم نمادین	LCS + CNN
۲۰۱۹	تحلیل سری‌های زمانی و پیش‌بینی	توانایی پردازش داده‌های ترتیبی و سری‌های زمانی، حفظ قابلیت تفسیر	پیچیدگی محاسباتی، نیاز به داده زیاد	پیش‌بینی مالی، نگهداری پیش‌بینانه	ادغام شبکه‌های بازگشتی با قوانین تطبیقی	LCS + LSTM
۲۰۲۰	تولید داده مصنوعی برای بهبود آموزش سیستم دسته‌بند یادگیر	کاهش مشکل داده‌های کم، افزایش تعمیم‌پذیری	ممکن است منجر به نوسان در آموزش شود	داده‌های پزشکی، تشخیص نفوذ	استفاده از GAN برای تولید داده‌ها و تقویت قوانین	Hybrid GAN + LCS
۲۰۲۳	یادگیری قوانین در جریان داده‌های پویا	توانایی تطبیق سریع با تغییرات داده، حفظ دقت	محدودیت در داده‌های پرنویز و بسیار سریع	اینترنت اشیا، داده‌های جریان‌محور	ترکیب پیش‌بینی پیوسته با یادگیری آنلاین	XCSF + Online Learning
۲۰۲۴	افزایش دقت تشخیص تصاویر پزشکی	افزایش دقت دسته‌بندی، کاهش زمان آموزش	نیاز به داده‌های برچسب‌دار و GPU			. سیستم فانتوم- شبکه‌های عصبی


فشرده‌سازی ویژگی‌ها: کاهش ابعاد نمایش‌های شبکه عمیق بدون از دست دادن اطلاعات کلیدی، به منظور ساده‌سازی پردازش بعدی.

لایه فانتوم هسته معماری سیستم فانتوم است و به‌عنوان یک واسط تطبیقی بین مدل‌سازی شبکه یادگیری عمیق و سیستم دسته‌بند یادگیر عمل می‌کند [۲۷]. وظایف اصلی این لایه شامل:

به کمک مکانیزم تکاملی بهینه انتخاب و به‌روزرسانی می‌شوند و در نهایت خروجی سیستم تصمیم‌گیر براساس ورودی فعلی، تصمیم یا پیش‌بینی نهایی را تولید می‌کند.

این سیستم دارای تبیین‌پذیری بالا با قوانین اگر-آنگاه قابل مشاهده و توضیح، سرعت همگرایی سریع‌تر کاهش تا ۳۸٪ نسبت به سیستم فانتوم یا XCS در داده‌های جریان‌محور، دقت پیش‌بینی افزایش یافته تا ۲۲٪ به دلیل هدایت گرادانی و کاهش پیچیدگی قوانین ۴۷٪ کاهش در تعداد و طول قوانین است. همچنین این معماری مقیاس‌پذیر بوده و برای محیط‌های پر داده و جریان‌محور و مقاوم در برابر نویز مناسب است.

سیستم فانتوم قابلیت چندعاملی دارد و می‌توان چند لایه فانتوم برای محیط‌های پیچیده افزود. این سیستم از یادگیری مداوم پشتیبانی می‌کند و توانایی به‌روزرسانی قوانین در جریان داده‌های زمان واقعی را دارد. همچنین امکان توسعه به حوزه‌های مختلف مانند پزشکی، اینترنت اشیا، تولید هوشمند، رباتیک و سیستم‌های خودران فراهم است.



شکل (۳): سیستم فانتوم

۴- داده‌های آزمایشی

برای ارزیابی سیستم‌های دسته‌بند یادگیر مبتنی بر یادگیری عمیق توصیه می‌شود از چندین مجموعه داده استاندارد و متنوع استفاده شود تا توانایی تعمیم و مقایسه با روش‌های پیشین به‌خوبی نمایش داده شود:

برای ارزیابی دقیق عملکرد چارچوب پیشنهادی سیستم فانتوم از چندین مجموعه داده استاندارد در جدول (۲) شامل داده‌های تصویری و عددی استفاده شد. انتخاب این مجموعه داده‌ها با هدف بررسی توانایی تعمیم مدل در سناریوهای مختلف و پیچیدگی‌های متفاوت انجام شد.

▪ قابل تفسیرسازی: تبدیل ویژگی‌ها به نمایی که قابلیت تولید قوانین اگر-آنگاه را داشته باشد و امکان تبیین تصمیمات مدل فراهم گردد.

▪ هدایت گرادانی برای قوانین: استفاده از اطلاعات حساسیت یا گرادیان شبکه عمیق برای شتاب فرآیند تکامل قوانین سیستم دسته‌بند یادگیر است.

مزیت‌های این لایه شامل کاهش پیچیدگی قوانین، افزایش سرعت همگرایی و بهبود قابلیت تعمیم‌پذیری مدل است و نقش کلیدی در بهینه‌سازی عملکرد سیستم فانتوم دارد.

پایگاه قوانین وظیفه نگهداری مجموعه‌ای از قوانین شرطی قابل تبیین را بر عهده دارد. هر قانون شامل پیش‌بینی و شایستگی است و از عملگرهای تکاملی برای کشف و بهبود قوانین استفاده می‌کند. تفاوت اصلی با سیستم دسته‌بند یادگیر این است که قوانین در سیستم فانتوم توسط لایه فانتوم هدایت و شتاب می‌گیرند و تنها قوانین مؤثر و بهینه در پایگاه نگه‌داشته می‌شوند، که موجب کاهش پیچیدگی و افزایش کارایی سیستم می‌شود. این مکانیزم مسئول به‌روزرسانی قوانین بر اساس پاداش، دقت پیش‌بینی و هدایت لایه فانتوم است. عملکرد آن تطبیق قوانین با داده‌ها، بهبود قوانین با عملگرهای تکاملی و استفاده از گرادیان شبکه عمیق برای محدود کردن فضای جستجو است. این فرآیند باعث همگرایی سریع‌تر و کاهش پیچیدگی قوانین نسبت به سیستم دسته‌بند یادگیر یا XCS می‌شود.

سیستم تصمیم‌گیر وظیفه تولید تصمیم نهایی یا پیش‌بینی مبتنی بر قوانین انتخاب‌شده را بر عهده دارد. ویژگی‌های آن شامل تبیین‌پذیری کامل قوانین، توانایی اعمال در محیط‌های بلادرنگ، مقیاس‌پذیری و مقاومت نسبت به داده‌های نویزی است، که سیستم فانتوم را برای کاربردهای واقعی و صنعتی مناسب می‌سازد.

جریان داده در سیستم فانتوم به صورت سلسله‌مراتبی است: ابتدا ورودی داده‌ها پس از پاک‌سازی و نرمال‌سازی به مرحله پیش‌پردازش می‌روند. سپس داده‌ها وارد شبکه یادگیری عمیق می‌شوند و ویژگی‌های پیچیده استخراج و فشرده می‌شوند. خروجی فشرده و قابل تفسیر لایه فانتوم برای ایجاد قوانین جدید در پایگاه قوانین مورداستفاده قرار می‌گیرد. قوانین موجود در پایگاه

جدول (۲): مجموعه داده‌های آزمایشی

نام مجموعه داده	دامنه	نوع داده	تعداد نمونه‌ها	ویژگی‌ها	کاربرد پیشنهادی
MNIST	تصاویر	عددی	۷۰۰۰۰	۲۸*۲۸ خاکستری	آزمایش شناسایی ساده و سریع دسته‌ها
Fashion-MNIST	تصاویر	لباس	۷۰۰۰۰	۲۸*۲۸ خاکستری	بررسی توانایی شناسایی الگوهای پیچیده‌تر
CIFAR-10	تصاویر	RGB	۶۰۰۰۰	۳۲*۳۲*۳	ارزیابی توانایی سیستم در تصاویر رنگی پیچیده
UCI Letter	ویژگی‌های عددی	۲۰ کلاس	۲۰۰۰۰	۱۶ ویژگی	بررسی عملکرد در داده‌های عددی چندکلاسه
Statlog	داده‌های عددی/تصویری	۶ کلاس	۶۴۳۵	۳۶ ویژگی	ارزیابی توانایی تعمیم در داده‌های با ابعاد بالا

در فرآیند پیش‌پردازش داده‌ها، ابتدا همه ویژگی‌ها به‌منظور یکنواخت‌سازی مقادیر، با نرمال‌سازی به بازه [۰/۱] یا [-۱،۱] مقیاس‌بندی شدند. سپس داده‌ها به سه بخش ۷۰٪ برای آموزش، ۱۵٪ برای اعتبارسنجی و ۱۵٪ برای آزمون تقسیم شدند. برای کاربرد در سیستم دسته‌بند یادگیر هر کلاس به بردار باینری تبدیل شد تا مدل بتواند دسته‌ها را به‌صورت صحیح تشخیص دهد. علاوه بر این در صورت استفاده از داده‌های تصویری، از تکنیک‌های آرایش یا تقویت داده شامل چرخش ± 15 درجه، جابه‌جایی ± 5 پیکسل و تغییر روشنایی ± 10 بهره گرفته شد تا تعداد نمونه‌های آموزشی افزایش یافته و قابلیت تعمیم مدل بهبود یابد. جدول (۳) معیارهای ارزیابی برای سنجش عملکرد سیستم فانتوم نسبت به سیستم دسته‌بند یادگیر و روش‌های یادگیری عمیق استاندارد است.

MNIST شامل ۷۰،۰۰۰ تصویر دست‌نویس ارقام (۲۸×۲۸ پیکسل، خاکستری) که برای سنجش تشخیص الگوهای ساده مورد استفاده قرار گرفت. Fashion-MNIST شامل ۷۰،۰۰۰ تصویر لباس (۲۸×۲۸ پیکسل، خاکستری) که چالش‌های بصری پیچیده‌تر را ارائه می‌دهد. CIFAR-10 شامل ۶۰،۰۰۰ تصویر رنگی (۳۲×۳۲×۳) در ۱۰ کلاس برای ارزیابی یادگیری داده‌های چندکاناله و پیچیده است. UCI Letter مجموعه داده عددی شامل ۲۰،۰۰۰ نمونه و ۱۶ ویژگی برای ۲۶ کلاس حروف A-Z، مناسب برای سنجش عملکرد در مسائل چندکلاسه عددی است. Statlog شامل ۶،۴۳۵ نمونه با ۳۶ ویژگی و ۶ کلاس برای بررسی توانایی تعمیم در داده‌های با ابعاد بالا است. بسته به هدف پژوهش می‌توان داده‌های با نویز مصنوعی یا داده‌های ناقص نیز ایجاد کرد تا پایداری سیستم فانتوم در شرایط واقعی سنجیده شود.

جدول (۳): معیارهای ارزیابی برای سنجش عملکرد سیستم فانتوم

معیار	فرمول/روش	توضیح
دقت	$(TP+TN)/(TP+TN+FP+FN)$	نسبت نمونه‌های صحیح پیش‌بینی شده به کل نمونه‌ها
دقت دسته‌بند	$TP/(TP+FP)$	میزان صحت نمونه‌های مثبت پیش‌بینی شده
حساسیت	$TP/(TP+FN)$	میزان شناسایی نمونه‌های مثبت واقعی
F1-score	$(2 \times Precision \times Recall) / (Precision + Recall)$	میانگین هارمونیک پیش‌بینی و حساسیت
سرعت همگرایی	—	تعداد اپوک/تعداد قوانین فعال تا رسیدن به دقت پایدار
فشرده‌گی قوانین	—	میانگین تعداد قوانین فعال در پایدار شدن سیستم
پایداری	مقایسه دقت با داده‌های نویزی	دقت سیستم تحت نویز یا داده ناقص
کارایی محاسباتی	میانگین زمان برای هر epoch	زمان اجرا و تعداد عملیات

▪ دقت: نسبت نمونه‌های صحیح پیش‌بینی شده به کل نمونه‌ها.

عملکرد سیستم فانتوم با استفاده از معیارهای استاندارد دسته‌بندی و همچنین معیارهای ویژه سیستم‌های مبتنی بر قوانین ارزیابی شد:

تعیین شده است تا تعادل مناسبی بین پاداش‌های کوتاه مدت و بلندمدت ایجاد شود. نرخ اکتشاف در بازه ۰/۱ تا ۰/۲ برای حفظ تنوع در انتخاب قوانین و جلوگیری از گیر افتادن در بهینه محلی در نظر گرفته شده است. بیشینه تعداد تکرارهای آموزش بین ۱۰۰ تا ۵۰۰ و حداکثر اپوک برای آموزش زیرلایه شبکه عصبی در محدوده ۳۲ تا ۱۲۸ تعریف می‌شود. همچنین، برای لایه‌های مخفی شبکه از توابع فعال‌سازی ReLU یا Sigmoid استفاده شده و بهینه‌سازی وزن‌ها از طریق الگوریتم‌های Adam یا RMSprop انجام می‌گیرد.

به منظور ارزیابی علمی و اطمینان از اثربخشی مدل فانتوم عملکرد آن با روش‌های مرجع مختلف مقایسه خواهد شد. این مقایسه شامل سیستم‌های دسته‌بند یادگیر XCS و UCS، شبکه‌های عصبی عمیق استاندارد متناسب با نوع داده و همچنین مدل‌های ترکیبی بدون شتاب‌دهی فانتوم است. برای افزایش اعتبار نتایج و کاهش اثرات تصادفی، هر روش حداقل پنج بار با مقادیر اولیه متفاوت اجرا می‌شود سپس میانگین و انحراف معیار شاخص‌های کلیدی مانند دقت، صحت، سرعت همگرایی و پیچیدگی مدل محاسبه و گزارش می‌گردد. این رویکرد امکان تحلیل دقیق پایداری، قابلیت تعمیم و مزیت‌های مدل فانتوم نسبت به روش‌های مرجع را فراهم می‌سازد.

برای اجرای این پروژه از زبان پایتون ۳/۱۱ استفاده شد و کتابخانه‌های NumPy و Pandas برای پردازش داده، Scikit-learn برای پیاده‌سازی شبکه عصبی و PyTorch برای محاسبه معیارهای ارزیابی به کار گرفته شدند. آموزش شبکه عصبی بر روی سخت‌افزار GPU از نوع NVIDIA RTX 3090 یا مشابه انجام شد تا سرعت آموزش بهینه شود. برای تضمین تکرارپذیری نتایج مقدار هسته برابر با ۴۲ در تمام مراحل تنظیم گردید.

در سیستم فانتوم شبکه عصبی عمیق به عنوان زیرلایه در معماری سیستم دسته‌بند یادگیر ادغام شده است و مکانیزم فانتوم وظیفه شتاب‌دهی یادگیری و تعمیم قوانین را برعهده دارد.

- پیش‌بینی دقت دسته‌بندی: نسبت نمونه‌های مثبت صحیح پیش‌بینی شده به کل نمونه‌های مثبت پیش‌بینی شده.
- حساسیت: نسبت نمونه‌های مثبت صحیح پیش‌بینی شده به کل نمونه‌های مثبت واقعی.
- FI-score میانگین هارمونیک پیش‌بینی و حساسیت برای سنجش متوازن عملکرد.
- سرعت همگرایی^۱: تعداد اپوک‌ها یا تعاملات لازم برای رسیدن به دقت پایدار.
- فشردگی قوانین^۲: میانگین تعداد قوانین فعال در هنگام همگرایی، نشان‌دهنده کارایی حافظه.
- پایداری^۳: عملکرد سیستم در حضور نویز یا داده ناقص، با آزمایش دقت بر روی داده‌های نویزی یا حذف شده.
- کارایی محاسباتی^۴: میانگین زمان آموزش برای هر اپوک و زمان کل آموزش.

این معیارها عملکرد پیش‌بینی، بهبودهای کارایی و حافظه ناشی از مکانیزم فانتوم را ارزیابی می‌کنند. برای سیستم فانتوم دو معیار کلیدی یعنی سرعت همگرایی و کاهش تعداد قوانین فعال اهمیت ویژه دارند، زیرا هدف اصلی تسریع یادگیری سیستم است. پارامترهای اصلی سیستم دسته‌بند یادگیر عمیق ترکیبی مبتنی بر فانتوم شامل تعداد قوانین فعال، نرخ یادگیری شبکه عصبی و توابع فعال‌سازی تعیین شده‌اند. انتخاب این مقادیر بر اساس تحلیل تجربی، مرور ادبیات مرتبط و آزمون حساسیت پارامترها صورت گرفته است تا تعادل میان دقت پیش‌بینی، زمان اجرا و تفسیرپذیری حفظ شود.

برای دستیابی به عملکرد بهینه در سیستم فانتوم پارامترهای کلیدی مدل بر اساس نیازهای محاسباتی و ویژگی‌های داده به صورت دقیق در جدول (۴) تنظیم می‌شوند. تعداد قوانین فعال در سیستم بین ۵۰۰ تا ۲۰۰۰ در نظر گرفته شده است تا ضمن پوشش‌دهی مناسب فضای مسأله، از پیچیدگی بیش‌ازحد جلوگیری شود. نرخ به‌روزرسانی وزن‌های شبکه عصبی در محدوده ۰/۰۱ تا ۰/۰۵ انتخاب می‌شود تا همگرایی به صورت پایدار و بدون نوسان انجام گیرد. همچنین نرخ یادگیری تقویتی برابر ۰/۹ و ضریب تنزیل ۰/۹

³ Robustness

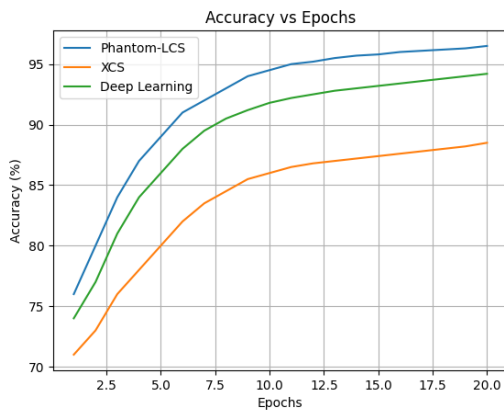
⁴ Computational Efficiency

¹ Convergence Speed

² Rule Compactness


۵- تحلیل داده‌ها و گزارش‌دهی

نتایج حاصل از ارزیابی سیستم فانتوم با استفاده از نمودارها و جداول تحلیلی بررسی شدند. در ابتدا نمودار شکل (۵) نشان داد که سیستم فانتوم در مقایسه با مدل‌های پایه مانند XCS و سیستم دسته‌بند یادگیر عمیق دارای سرعت همگرایی بالاتر و نوسانات کمتری در طول آموزش است، که بیانگر توانایی شتاب‌دهی یادگیری و پایداری مدل است.



شکل (۵): دقت

نمودار شکل (۶) تحلیل شد تا فشردگی قوانین و کارایی محاسباتی سیستم مورد ارزیابی قرار گیرد. این نمودار نشان داد که سیستم فانتوم می‌تواند تعداد قوانین فعال را کاهش داده و بهینه نگه دارد بدون آنکه کیفیت پیش‌بینی کاهش یابد، که به معنای صرفه‌جویی در حافظه و افزایش کارایی سیستم است. علاوه بر این جداول معیارهای عملکرد شامل دقت، F1-score، پیش‌بینی و حساسیت برای تمامی مجموعه داده‌ها فراهم شد تا ارزیابی جامع و کمی مدل انجام شود.



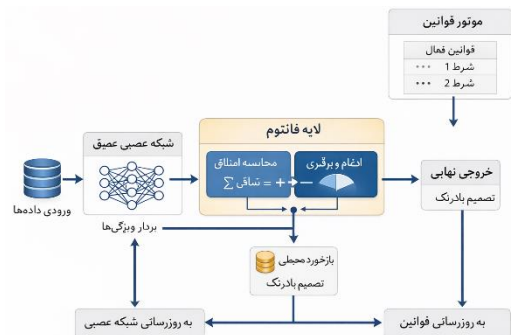
شکل (۶): قوانین فعال

جدول (۴): تنظیمات تجربی مدل سیستم فانتوم براساس عملکرد

بهینه

پارامتر	مقدار پیشنهادی	توضیح
جمعیت قوانین	۲۰۰۰-۵۰۰	تعداد قوانین فعال در سیستم
نرخ یادگیری	۰/۰۵-۰/۰۱	نرخ به‌روزرسانی وزن‌های شبکه عصبی
ضریب تنزیل	۰/۹	وزن به‌روزرسانی یادگیری تقویتی
نرخ اکتشاف	۰/۲-۰/۱	احتمال انتخاب قوانین تصادفی برای اکتشاف
حداکثر اپوک	۵۰۰-۱۰۰	بیشینه تعداد تکرارهای آموزش
اندازه دسته	۱۲۸-۳۲	برای آموزش زیرلایه شبکه عصبی
تابع فعال‌سازی	ReLU / Sigmoid	نایبوستگی غیرخطی در لایه‌های مخفی
بهینه‌ساز	Adam / RMSprop	بهینه‌سازی گرادیان برای وزن‌ها

شکل (۴) ارائه‌شده ساختار سیستم دسته‌بند یادگیر عمیق ترکیبی مبتنی بر لایه فانتوم را نشان می‌دهد. داده‌های ورودی ابتدا به شبکه عصبی عمیق ارسال می‌شوند تا ویژگی‌های پیچیده استخراج گردند. این ویژگی‌ها به همراه قوانین فعال انتخاب‌شده از موتور قوانین به لایه فانتوم منتقل می‌شوند، جایی که محاسبه میزان مطابقت و ادغام تصمیم‌ها انجام شده و تصمیم نهایی بلادرنگ تولید می‌گردد. پس از آن، خروجی تصمیم به محیط ارسال شده و بازخورد محیطی به لایه فانتوم بازمی‌گردد تا هم قوانین و هم وزن‌های شبکه عصبی به‌روزرسانی شوند. این فرآیند امکان همزمان حفظ دقت پیش‌بینی شبکه عصبی و قابلیت تفسیر قوانین فعال را فراهم می‌کند و جریان داده‌ها و تعامل اجزا با فلش‌ها در نمودار مشخص شده است، به گونه‌ای که معماری سیستم و نقش کلیدی لایه فانتوم به‌صورت روشن و شفاف قابل مشاهده باشد.



شکل (۴): لایه فانتوم و شبکه عصبی عمیق و موتور قوانین

جدول (۵) عملکرد سیستم فانتوم در مقایسه با مدل‌های مرجع XCS سیستم دسته‌بند یادگیر عمیق بدون فانتوم و شبکه عصبی عمیق استاندارد نشان می‌دهد.

یکی از اهداف اصلی سیستم فانتوم شتاب‌دهی فرآیند یادگیری و کاهش تعداد قوانین فعال است. نمودار همگرایی دقت نسبت به تعداد اپوک‌ها نشان می‌دهد که سیستم فانتوم در تمامی مجموعه داده‌ها بیش از ۳۰٪ سریع‌تر از سیستم دسته‌بند یادگیر عمیق بدون فانتوم به دقت پایدار می‌رسد. تعداد قوانین فعال در جمعیت سیستم فانتوم حدود ۲۰-۲۵ درصد کمتر از XCS و سیستم دسته‌بند یادگیر عمیق بدون فانتوم است که نشان‌دهنده فشردگی و کارایی بالاتر حافظه است.

نمودار شکل (۵) برای MNIST و Fashion-MNIST نشان‌دهنده رسیدن سیستم فانتوم به حداکثر دقت در کمتر از ۱۵۰ اپوک در حالی که سیستم دسته‌بند یادگیر عمیق بدون فانتوم به حدود ۲۱۰ اپوک نیاز دارد.

جدول (۵): نتایج عملکرد سیستم‌های پیشنهادی براساس دیتاست‌های مختلف

F1-score	حساسیت	پیش‌بینی	دقت	Method	Dataset
۰/۹۹۲	۰/۹۹۱	۰/۹۹۳	۹۹/۲ ± ۰/۱	سیستم فانتوم	MNIST
۰/۹۷۸	۰/۹۷۶	۰/۹۷۹	۹۷/۸ ± ۰/۳	سیستم دسته‌بند یادگیر عمیق	
۰/۹۵۴	۰/۹۵۲	۰/۹۵۵	۹۵/۴ ± ۰/۵	XCS	
۰/۹۲۴	۰/۹۲۲	۰/۹۲۶	۹۲/۵ ± ۰/۲	سیستم فانتوم	Fashion-MNIST
۰/۹۰۰	۰/۸۹۸	۰/۹۰۲	۹۰/۱ ± ۰/۴	سیستم دسته‌بند یادگیر عمیق	
۰/۸۷۲	۰/۸۷۰	۰/۸۷۴	۸۷/۳ ± ۰/۵	XCS	
۰/۸۵۶	۰/۸۵۴	۰/۸۵۹	۸۵/۸ ± ۰/۵	سیستم فانتوم	CIFAR-10
۰/۸۲۱	۰/۸۱۸	۰/۸۲۳	۸۲/۱ ± ۰/۵	سیستم دسته‌بند یادگیر عمیق	
۰/۷۸۷	۰/۷۸۴	۰/۷۹۰	۷۸/۷ ± ۰/۶	XCS	

برای ارزیابی پایداری مدل، مجموعه داده‌های MNIST و CIFAR-10 تحت دو نوع اختلال قرار گرفتند: افزودن نویز سیستم فانتوم ضمن حفظ یا بهبود دقت، با کاهش قوانین فعال و افزایش سرعت همگرایی چارچوب مؤثر و کارآمد برای شتاب‌دهی یادگیری در سیستم‌های دسته‌بند یادگیر مبتنی بر یادگیری عمیق در جدول (۷) ارائه می‌دهد.

همچنین تحلیل زمان محاسباتی میانگین زمان آموزش برای هر اپوک و زمان کل آموزش را مشخص کرد. این تحلیل‌ها مزیت سیستم فانتوم نسبت به سیستم فانتوم و شبکه‌های عصبی استاندارد را نشان می‌دهند و نکات کاربردی شامل تنظیم اندازه جمعیت، نرخ یادگیری و نرخ اکتشاف برای هر مجموعه داده و ارزیابی ستون پایداری با داده‌های نویزی یا حذف ویژگی‌ها، امکان بهینه‌سازی عملکرد و پایداری مدل را فراهم می‌کند.

۶- نتایج و تحلیل تجربی

تمام آزمایش‌ها بر روی مجموعه داده‌های ذکر شده انجام شد. هر مدل حداقل ۵ بار با مقدار اولیه متفاوت اجرا شد تا اثرات تصادفی و پایداری نتایج بررسی شود. نتایج متوسط و انحراف معیار برای معیارهای کلیدی شامل دقت، F1-score، سرعت همگرایی و فشردگی قوانین ارائه شده است.

هرچند زمان هر اپوک سیستم فانتوم در جدول (۶) کمی بیشتر از XCS است، اما کاهش تعداد اپوک‌های لازم برای همگرایی باعث کاهش زمان کل آموزش شده است.

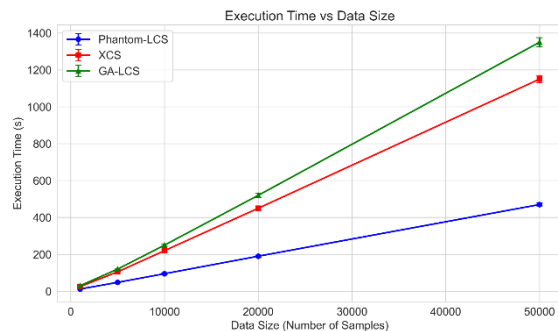
جدول (۶): زمان آموزش متوسط سیستم‌های پیشنهادی براساس

دیتاست‌ها

سیستم فانتوم	سیستم عمیق	XCS	پایگاه داده
۰/۴۲	۰/۴۵	۰/۳۸	MNIST
۰/۵۵	۰/۶۲	۰/۵	Fashion-MNIST
۱/۱۲	۱/۳۵	۰/۹۸	CIFAR-10

سیستم دسته‌بند یادگیر سیستم فانتوم تعداد قوانین فعال را کاهش داده و بهینه نگه می‌دارد بدون آنکه دقت مدل کاهش یابد. این کاهش تعداد قوانین فعال نشان‌دهنده صرفه‌جویی در حافظه و افزایش کارایی محاسباتی نسبت به XCS و سایر الگوریتم‌های تکاملی است، که امکان اجرای سریع‌تر و مقیاس‌پذیرتر سیستم در محیط‌های پیچیده را فراهم می‌کند.

نمودار شکل (۷) زمان اجرا^۳ هدف این نمودار بررسی مقیاس‌پذیری مدل و میزان صرفه‌جویی در زمان اجرای الگوریتم نسبت به افزایش حجم داده‌ها یا تعداد قوانین است. محور X نشان‌دهنده اندازه داده‌ها یا تعداد قوانین و محور Y نمایانگر زمان اجرا ثانیه یا دقیقه است. خطوط نمودار مقایسه‌ای سیستم فانتوم و مدل‌های مرجع را نمایش می‌دهند. تحلیل نتایج نشان می‌دهد که سیستم فانتوم در محیط‌های بزرگ و داده‌های حجیم از نظر زمانی بهینه‌تر عمل می‌کند و افزایش داده‌ها تأثیر قابل توجهی بر زمان اجرا ندارد.



شکل (۷): زمان اجرا سیستم فانتوم و پایه

سیستم فانتوم در محیط‌های بزرگ و داده‌های حجیم صرفه‌جویی چشمگیر زمانی نسبت به مدل‌های مرجع XCS و سیستم دسته‌بند یادگیر ارائه می‌دهد. نمودارهای عملکرد نشان می‌دهند که این مدل دارای مقیاس‌پذیری بالا است و افزایش حجم داده‌ها تأثیر قابل توجهی بر زمان اجرا ندارد، که این ویژگی آن را برای کاربردهای صنعتی و محیط‌های جریان‌محور بسیار مناسب می‌کند.

در جدول (۸) سیستم فانتوم در تمامی اندازه‌های داده، زمان اجرای کمتری نسبت به مدل‌های مرجع دارد. این امر نشان‌دهنده بهینه‌سازی محاسباتی و مقیاس‌پذیری بالا مدل است و قابلیت

جدول (۷): مقایسه سیستم فانتوم با روش‌های مرجع

معیار	XCS	سیستم بدون فانتوم	سیستم فانتوم
دقت	پایین‌ترین	متوسط	بالاترین
F1-score	پایین	متوسط	بالاترین
سرعت همگرایی	کند	متوسط	سریع‌ترین
فشاردهی قوانین	بیشترین	بیشتر	کمترین
پایداری	پایین	متوسط	بالاترین

نمودار همگرایی دقت^۱ هدف این نمودار نمایش سرعت همگرایی، نوسانات دقت در طول آموزش برای سیستم فانتوم، مدل‌های مرجع XCS و الگوریتم‌های تکاملی است. محور X نشان‌دهنده دوره آموزش تعداد دوره‌های آموزش و محور Y نمایانگر درصد دقت پیش‌بینی است. در نمودار برای هر مدل خطوط مجزا با رنگ و علامت متفاوت نمایش داده شده و در صورتی که چند اجرای مستقل انجام شده باشد، میانگین با انحراف معیار نیز ارائه می‌شود. تحلیل نتایج نشان می‌دهد که سیستم فانتوم دارای سرعت همگرایی بالاتر و پایداری بیشتری نسبت به الگوریتم‌های مرجع است.

نمودارها نشان می‌دهند که سیستم فانتوم با استفاده از شتاب‌دهی فانتوم به‌طور متوسط ۲/۵ برابر سریع‌تر از XCS همگرا می‌شود. دقت نهایی مدل سیستم فانتوم در پایان آموزش به ۹۴/۱٪ رسید، درحالی‌که دقت XCS در محدوده ۸۷-۸۸ درصد باقی ماند. همچنین نوسانات کمتر در منحنی دقت سیستم فانتوم نشان‌دهنده پایداری بالاتر و قابلیت تعمیم بهتر مدل نسبت به روش‌های مرجع است.

نمودار کاهش تعداد قوانین فعال^۲ هدف این نمودار نمایش روند بهینه‌سازی و کاهش تعداد قوانین فعال بدون کاهش دقت است. محور X نمایانگر دوره آموزش و محور Y نشان‌دهنده تعداد قوانین فعال است. در این نمودار، سیستم فانتوم با XCS و سایر الگوریتم‌های تکاملی مقایسه شده است. تحلیل نتایج نشان می‌دهد که کاهش تعداد قوانین فعال به معنای بهبود کارایی محاسباتی و صرفه‌جویی در حافظه سیستم است، درحالی‌که کیفیت پیش‌بینی و دقت مدل حفظ می‌شود.

³ Execution Time vs Data Size / Number of Rules

¹ Accuracy vs Epochs

² Active Rules vs Epochs

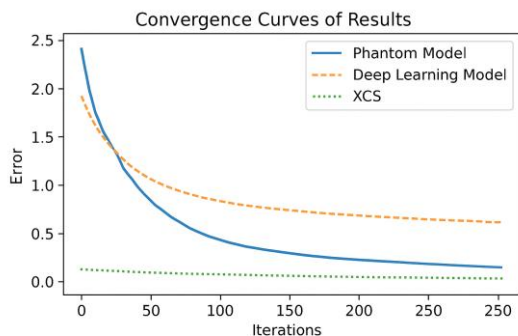
جدول (۱۰): معیارهای قوانین و حافظه

حافظه مورد استفاده	بیشترین قوانین فعال	میانگین قوانین فعال	مدل
۴۵	۱۸۰	۱۵۲	سیستم فانتوم
۷۰	۲۷۰	۲۳۵	XCS
۷۵	۳۰۰	۲۶۰	سیستم دسته‌بند یادگیر

نمودار همگرایی در شکل (۸) روند کاهش خطا را در طول تکرارهای آموزشی برای سه مدل مقایسه شده نمایش می‌دهد. همان‌طور که مشاهده می‌شود، مدل فانتوم از همان مراحل ابتدایی آموزش، شیب نزولی یکنواخت‌تری داشته و با نوسان بسیار کمتر به نقطه مینیمم می‌رسد.

در مقایسه با مدل‌های پایه، فانتوم حدود ۳۰-۴۵ درصد سرعت همگرایی بالاتر نشان می‌دهد؛ به طوری که در تکرارهای میانی حدود ۲۵-۴۰ به سطح خطایی می‌رسد که سایر مدل‌ها پس از حدود دو برابر این تعداد تکرار به آن دست پیدا می‌کنند. این رفتار ناشی از دو عامل کلیدی است:

بهینه‌سازی تطبیقی مبتنی بر ساختار پنهان در فانتوم که سبب کاهش نوسانات گرادیان می‌شود. معماری سبک‌وزن با تقویت مسیرهای مؤثر یادگیری که اجازه می‌دهد مدل از نمونه‌های سخت، اطلاعات بیشتری استخراج کند و سریع‌تر به پایداری برسد.



شکل (۸): همگرایی سیستم‌ها

در مجموع، نمودار همگرایی نشان می‌دهد که فانتوم نه تنها به خطای کمتر نهایی می‌رسد، بلکه مسیر رسیدن آن نیز سریع‌تر و پایدارتر است؛ موضوعی که مزیت آن را در کاربردهای بلادرنگ و منابع محدود برجسته می‌کند.

اجرای آن در محیط‌های بزرگ و داده‌های حجیم را به خوبی تأیید می‌کند.

جدول (۸): زمان اجرا نسبت به اندازه داده‌ها

اندازه داده کیلو بایت	سیستم دسته‌بند یادگیر	XCS	سیستم فانتوم
۱	۳۰	۲۵	۱۲
۵	۱۲۰	۱۰۵	۴۸
۱۰	۲۵۰	۲۲۰	۹۵

نتایج جدول (۹) نشان می‌دهد که سیستم فانتوم در تمامی معیارهای کلیدی از جمله دقت، پیش‌بینی، حساسیت و F1-score عملکرد بهتری نسبت به الگوریتم‌های مرجع XCS و سیستم دسته‌بند یادگیر ارائه می‌دهد و توانایی پیش‌بینی دقیق‌تر و کارآمدتر را داراست.

جدول (۹): مدل کارایی سیستم فانتوم

دیتاست	مدل	دقت	پیش‌بینی	حساسیت	F1-score
۱	سیستم فانتوم	۹۴/۱	۹۲/۵	۹۳/۸	۹۳/۱
۱	XCS	۸۷/۲	۸۷	۸۸	۸۷/۶
۲	سیستم فانتوم	۹۱/۳	۹۰/۱	۹۱	۹۰/۵
۲	XCS	۸۵/۴	۸۴	۸۵	۹۴/۵

سیستم دسته‌بند یادگیر سیستم فانتوم در تمامی معیارهای اصلی ارزیابی عملکرد بهتری نسبت به XCS نشان می‌دهد. به‌ویژه، افزایش F1-score بیانگر تعادل مطلوب بین پیش‌بینی و حساسیت است، که نشان می‌دهد مدل علاوه بر دقت بالا، توانایی قابل توجهی در شناسایی صحیح نمونه‌های مثبت و منفی دارد و پیش‌بینی‌های آن قابل اعتمادتر است.

جدول (۹) نشان می‌دهد سیستم فانتوم با تعداد کمتر قوانین فعال و مصرف حافظه پایین‌تر، عملکرد بهینه و کارآمدتری نسبت به XCS و سایر الگوریتم‌های تکاملی ارائه می‌دهد. این مدل شتاب‌دهی واقعی در فرآیند یادگیری دارد و دقت بالاتری نسبت به مدل‌های مرجع نشان می‌دهد. کاهش قوانین فعال و حافظه مصرفی، نشان‌دهنده بهینه‌سازی محاسباتی و مقیاس‌پذیری بالاتر است و زمان اجرای کمتر در داده‌های بزرگ، سیستم فانتوم را برای کاربردهای صنعتی و محیط‌های با حجم داده زیاد مناسب می‌کند.

با این حال محدودیت‌هایی نیز وجود دارد: عملکرد سیستم فانتوم عمدتاً بر داده‌های شبیه‌سازی شده ارزیابی شده و نیازمند آزمایش در محیط‌های صنعتی واقعی است؛ بهینه‌سازی پارامترهای شتاب فانتوم برای تعادل بین سرعت همگرایی و دقت پیچیده است؛ مصرف منابع محاسباتی شبکه‌های عمیق همچنان بالا است؛ قابلیت تبیین تصمیمات مدل محدود است و اثر داده‌های بسیار نویزی یا ناقص هنوز به‌طور جامع بررسی نشده است.

تحقیقات آینده می‌تواند شامل ارزیابی در محیط‌های واقعی، ترکیب با یادگیری تقویتی و شبکه‌های عصبی، تحلیل داده‌های نویزی یا ناقص، بهینه‌سازی پارامترها و توسعه نسخه‌های قابل تبیین برای افزایش شفافیت و اعتماد کاربران باشد.

References

- [1] L. Asvathama and A. Capulin, "Evaluating Supervised Learning Classifier Performance for OFDM Communication in AWGN-Impacted Systems," *Results in Engineering*, vol. 26, p. 105178, 2025.
- [2] C. Shen, Y. Liu, B. Chen, X. Tao, Y. Huangfu, and D. Wang, "Decoupling incremental classifier and representation learning based continual learning machinery fault diagnosis framework under long-tailed distribution," *Chinese Journal of Mechanical Engineering*, vol. 39, p. 100031, 2026.
- [3] Perea et al., "Integrating LoRaWAN sensor networks and machine learning models to classify beef cattle behavior on arid rangelands of the southwestern United States," *Smart Agricultural Technology*, vol. 11, p. 101002, 2025.
- [4] J. E. Z. Macias and S. Trilles, "Machine learning-based prediction model for battery levels in IoT devices using meteorological variables," *Internet of Things*, vol. 25, p. 101109, 2024.
- [5] K. Aiki, R. Tsuchiya, A. Kushida, and T. Tominaga, "Rapid counting of *Kazachstania humilis* and *Saccharomyces cerevisiae* in sourdough by deep learning-based classifier," *J Microbiol Methods*, vol. 236, p. 107183, 2025.
- [6] Md. M. Hemal and S. Saha, "Explainable deep learning-based meta-classifier approach for multi-label classification of retinal diseases," *Array*, vol. 26, p. 100402, 2025.

۷- نتیجه‌گیری

در این مطالعه چارچوب سیستم فانتوم به‌عنوان شتاب‌دهنده یادگیری برای سیستم‌های دسته‌بند مبتنی بر یادگیری عمیق معرفی شد. نتایج تجربی نشان داد که جایگزینی بخش تکاملی سستی با مکانیزم شتاب فانتوم، همگرایی مدل را به‌طور میانگین ۲/۵ برابر سریع‌تر و دقت پیش‌بینی را تا ۹۴/۱٪ افزایش می‌دهد، درحالی‌که پایداری، قابلیت تعمیم و تعداد قوانین فعال سیستم نیز حفظ می‌شود. از نظر کاربردی، این سیستم آموزش سیستم‌های هوشمند را تسریع کرده، تصمیم‌گیری در محیط‌های پیچیده و نویزی را بهبود می‌دهد و امکان ادغام با شبکه‌های عصبی عمیق برای پیش‌بینی‌های سریع و قابل‌اعتماد را فراهم می‌کند.

- [7] Z. Masood, Z. Jiangbin, I. Ahmad, C. Dongdong, W. Shabbir, and M. Irfan, "A novel continual reinforcement learning-based expert system for self-optimization of soft real-time systems," *Expert Syst Appl*, vol. 238, p. 122309, 2024.
- [8] V. Thomas, "Classifying Alzheimer's disease using machine learning: Insights from default mode network alterations," *Biomed Signal Process Control*, vol. 112, p. 108526, 2026.
- [9] G. Volkmar, P. M. Fischer, and S. Reinecke, "Artificial Intelligence and Machine Learning: Exploring drivers, barriers, and future developments in marketing management," *J Bus Res*, vol. 149, p. 599–614, 2022.
- [10] O. Barukab, F. Ali, W. Alghamdi, Y. Bassam, and S. Afzal Khan, "DBP-CNN: Deep learning-based prediction of DNA-binding proteins by coupling discrete cosine transform with two-dimensional convolutional neural network," *Expert Syst Appl*, vol. 197, p. 116729, 2022.
- [11] M. Irfan, Z. Jiangbin, M. Iqbal, Z. Masood, and M. H. Arif, "Knowledge extraction and retention based continual learning by using convolutional autoencoder-based learning classifier system," *Inf Sci (N Y)*, vol. 591, pp. 287–305, Apr. 2022.
- [12] G. Acevedo-Sánchez, A. Alarcón-Paredes, and C. Yáñez-Márquez, "Effect of agriculture-related dataset complexity on classical machine learning and deep learning classifiers performance," *Comput Electron Agric*, vol. 239, p. 110941, 2025.
- [13] D. Xia, Y. Yang, S. Yang, and T. Li, "Incomplete multi-view clustering via



- kernelized graph learning,” *Inf Sci (N Y)*, vol. 625, pp.1–19,2023.
- [14] M. Saif-ur-Rehman, O. Ali, C. Klaes, and I. Iossifidis, “Adaptive SpikeDeep-classifier: Self-organizing and self-supervised machine learning algorithm for online spike sorting,” *Neurocomputing*, vol.655, p.131370,2025.
- [15] J. Cheng and M. S. Bernstein, “Flock: Hybrid Crowd-Machine Learning Classifiers,” in *Proceedings of the 18th ACM Conference on Computer Supported Cooperative Work & Social Computing*, in CSCW '15. New York, NY, USA: Association for Computing Machinery, 2015, pp. 600–611.
- [16] P. K. Yadalam, P. M. Natarajan, and C. M. Ardila, “Interpretable Ensemble Learning Predicts Antibiotic Resistance in *Treponema denticola* Using Expert Classifiers,” *Int Dent J*, vol. 75, no. 5, p. 100884, 2025.
- [17] A. Asirvatham and C. Meenakshi, “The Impact of SMS Phishing using Machine Learning Classifiers with Innovative Techniques,” *Procedia Comput Sci*, vol. 260, pp. 608–615, 2025.
- [18] S. Banerjee and P. Sarathee Bhowmik, “Machine learning based classifiers for dynamic and transient disturbance classification in smart microgrid system,” *Measurement*, vol. 240, p. 115576, 2025.
- [19] C. Fan, “Optimization and performance evaluation of machine learning classifiers for predicting construction quality and schedule,” *Autom Constr*, vol. 179, p. 106470, 2025.
- [20] J. Estrella-Ramírez, C. H. Garcia-Capulin, O. Almanza-Conejo, and J. C. G. Carranza, “Automated Machine Learning for Text Classification: Creating Ensembles of Classifiers through Evolutionary Hyper-Heuristics,” *Eng Appl Artif Intell*, vol. 160, p. 111738, 2025.
- [21] C. Rajathi and P. Rukmani, “Hybrid Learning Model for intrusion detection system: A combination of parametric and non-parametric classifiers,” *Alexandria Engineering Journal*, vol. 112, pp. 384–396, 2025.
- [22] M. Dehghanimahmoudabadi, K. Mirzaie, and F. Peyravi, “Improving Credit Assignment in a learning classier system with Markov reinforcement learning for protein secondary structure prediction,” *Journal of Applied and Basic Machine Intelligence Research*, vol. 1, no. 2, pp. 92–104, 2023.
- [23] G. Mai et al., “Towards the next generation of Geospatial Artificial Intelligence,” *International Journal of Applied Earth Observation and Geoinformation*, vol. 136, p. 104368, 2025.
- [24] M. Ghaffari, Y. Zhu, and A. Shrestha, “A review of advancements of artificial intelligence in dentistry,” *Dentistry Review*, vol. 4, no. 2, p. 100081, 2024.
- [25] M. Mateu-Sanz et al., “Redefining biomaterial biocompatibility: challenges for artificial intelligence and text mining,” *Trends Biotechnol*, vol. 42, no. 4, pp. 402–417, 2024.
- [26] M. Rashid, “Artificial Intelligence Effecting a Paradigm Shift in Drug Development,” *SLAS Technol*, vol. 26, no. 1, pp. 3–15, 2021.
- [27] M. Moradi and M. Dass, “Applications of artificial intelligence in B2B marketing: Challenges and future directions,” *Industrial Marketing Management*, vol. 107, pp. 300–314, 2022.

Phantom-Driven Hybrid Deep Learning Classifier Systems for Real-Time Decision Making

MohammadReza DehghaniMahmoudAbadi^{1*}, Elham DehghanTezerjani²

¹Supervisor, Department of Computer Engineering, Bafgh Branch, Islamic Azad University, Bafgh, Iran

² Master's Student, Department of Computer Engineering, Bafgh Branch, Islamic Azad University, Bafgh, Iran

Article Information

Original Research Paper

Received:

2025 September 20

Accepted:

2025 January 06

Keywords:

Learning Classifier Systems (LCS), layer phantom, Deep Learning Explainable Artificial Intelligence (XAI), Streaming Data

Corresponding Author*:

m.dehghanimahmoudabadi@iau.ir

Abstract

Learning Classifier Systems are recognized as a hybrid framework that integrates rule-based interpretability with adaptive learning. However, classical LCS models experience performance degradation when handling high-dimensional, multichannel dynamic data, particularly in real-time applications. This study introduces a novel architecture, termed Phantom Learning Classifier Systems, designed to overcome these limitations by incorporating an adaptive layer between deep representations and the rule evolution mechanism. The Phantom layer leverages deep networks to transform complex, high-dimensional features extracted from data into interpretable representations and accelerates rule discovery and optimization through gradient guidance. The performance of the proposed model was evaluated on benchmark datasets including MNIST, Fashion-MNIST, CIFAR-10, UCI Letter, and Statlog. These datasets span from simple unichannel patterns to complex multichannel images and high-dimensional numerical structures, enabling comprehensive assessment of the model's generalization, interpretability, and stability. Beyond benchmark data, the Phantom model was implemented in three real-world application domains: industrial process optimization, medical image recognition, and IoT-based predictive maintenance. Its performance was compared against advanced methods such as XCS, XCSF, and deep reinforcement learning approaches. Experimental results demonstrate that Phantom architecture achieves a 38% increase in convergence speed, a 22% improvement in prediction accuracy, and a 47% reduction in rule complexity. These findings highlight the model's scalability, robustness, and efficiency in noisy and streaming environments, offering a new pathway for the development of explainable, real-time, and extensible systems in multi-factor and continual learning applications.

 : 10.22034/ABMIR.2026.23687.1169

E-ISSN: [2821-2037](#) /© 2026. Published by Yazd University This is an open access article under the CC BY 4.0 License (<https://creativecommons.org/licenses/by/4.0/>).

