

An Intelligent Framework Based on Machine Learning and Model-Driven Architecture for Optimization of Industrial IoT Systems

Hossein Shidelzadeh¹, Maryam Nooraei Abadeh^{2*}

¹ Msc, Department of Computer Engineering, Arv.C., Islamic Azad University, Abadan, Iran

² Associate Professor, Department of Computer Engineering, Arv.C., Islamic Azad University, Abadan, Iran

Received: 01 October 2025, Revised: 08 August 2026, Accepted: 16 August 2026

Paper type: Research

Abstract

By increasing proliferation of IoT devices, the large volume of unlabeled data, and the need for fast processing and optimal resource management, new challenges have emerged in this field. In the meantime, the importance of semi-supervised methods for prediction and also for extracting key domain features to improve accuracy has become more important. In this research, a new approach to improving the efficiency of industrial IoT systems is presented, in which machine learning is enhanced by using Model-Driven Architecture. In this framework, domain-oriented conceptual models are used as the basis for extracting key features, structuring data, and reducing noise. This integration improves the machine learning process, especially in conditions of lack of labeled data. In the first step, PIM and PSM models are created to separate the system logic from the implementation details and adapt to technological changes. Then, the processed data and extracted features are fed into the semi-supervised learning algorithms Self-training, Label Propagation, and Semi-Supervised SVM to also use unlabeled data in the training process. Evaluation of this approach in an IoT-based industrial simulation environment shows that using MDA as the ML reinforcement layer increases the prediction accuracy by an average of 95%, and the robustness of the model against noisy data is also significantly improved. The results indicate that the combination of MDA and semi-supervised machine learning can improve the efficiency of IoT-based industries.

Keywords: Performance Improvement, IoT environments, Model- Driven Architecture, Optimized Machine Learning.

* Corresponding Author's email: Ma.nooraei@iau.ac.ir

چارچوبی هوشمند مبتنی بر یادگیری ماشین و معماری مدل‌رانده برای بهینه‌سازی سیستم‌های IoT صنعتی

حسین شیدل‌زاده^۱، مریم نورائی آبادیه^{۲*}

^۱ کارشناس ارشد مهندسی کامپیوتر واحد بین‌المللی اروند، دانشگاه آزاد اسلامی، آبادان، ایران

^۲ دانشیار گروه مهندسی کامپیوتر، واحد بین‌المللی اروند، دانشگاه آزاد اسلامی، آبادان، ایران

تاریخ دریافت: ۱۴۰۴/۰۷/۰۹ تاریخ بازبینی: ۱۴۰۵/۰۵/۱۷ تاریخ پذیرش: ۱۴۰۵/۰۵/۲۵

نوع مقاله: پژوهشی

چکیده

با گسترش روزافزون دستگاه‌های متصل به اینترنت اشیاء، حجم بالای داده‌های بدون‌برچسب و نیاز به پردازش سریع و مدیریت بهینه منابع، چالش‌های جدیدی در این حوزه ایجاد شده است. در این میان، اهمیت روش‌های نیمه‌نظارتی برای پیش‌بینی و همچنین استخراج ویژگی‌های کلیدی دامنه برای بهبود دقت، بیش از پیش آشکار شده است. در این پژوهش، رویکردی نوین برای بهبود کارایی سیستم‌های IoT صنعتی ارائه می‌شود که در آن یادگیری ماشین با بهره‌گیری از معماری مدل‌رانده (MDA) تقویت شده است. در این چارچوب، مدل‌های مفهومی دامنه‌محور به‌عنوان پایه‌ای برای استخراج ویژگی‌های کلیدی، ساختاردهی داده‌ها و کاهش نویز به کار می‌روند. این یکپارچه‌سازی باعث بهبود فرآیند یادگیری ماشین به ویژه در شرایط کمبود داده‌های برچسب‌دار می‌گردد. در مرحله اول، مدل‌های PIM و PSM برای جداسازی منطق سیستم از جزئیات پیاده‌سازی ایجاد شده و با تغییرات فناوری سازگار می‌شوند. سپس داده‌های پردازش‌شده و ویژگی‌های استخراج‌شده به الگوریتم‌های یادگیری نیمه‌نظارتی Self-training، Label Propagation و Semi-Supervised SVM وارد می‌شوند تا از داده‌های بدون برچسب نیز در فرآیند آموزش استفاده شود. ارزیابی این رویکرد در یک محیط شبیه‌سازی صنعتی مبتنی بر IoT (مانند سامانه پایش و کنترل انرژی) نشان می‌دهد که استفاده از MDA به‌عنوان لایه تقویت‌کننده ML، دقت پیش‌بینی را به طور میانگین تا ۹۵٪ افزایش داده، همچنین پایداری مدل در برابر داده‌های نویزی به طور قابل توجهی بهبود یافته است. نتایج نشان می‌دهد که ترکیب MDA و یادگیری ماشین نیمه‌نظارتی می‌تواند به عنوان یک چارچوب مقیاس‌پذیر و قابل اعتماد برای ارتقاء کارایی صنایع مبتنی بر IoT به کار گرفته شود.

کلیدواژگان: بهبود کارایی، محیط‌های اینترنت اشیاء صنعتی، معماری مدل‌رانده، یادگیری ماشین بهینه‌سازی.

* رایانامه نویسنده مسؤول: Ma.nooraei@iau.ac.ir

۱- مقدمه

در دهه‌های اخیر، اینترنت اشیا تحولی بنیادین در توسعه سیستم‌های هوشمند ایجاد کرده که امکان اتصال گسترده دستگاه‌ها و تولید حجم عظیمی از داده‌های پیچیده و نیمه‌ساخت‌یافته را فراهم ساخته است. با این حال، این فرصت‌های نوین با چالش‌های قابل توجهی همراه هستند که از جمله آنها می‌توان به مدیریت حجم بالای داده‌های بدون برچسب، منابع محدود، پردازش و تحلیل داده‌های ناقص و نویزی، مقیاس‌پذیری سیستم‌ها و تضمین عملکرد پایدار در شرایط متغیر اشاره کرد [۳-۷]. این چالش‌ها، ضرورت بهره‌گیری از رویکردهای نوین مدل‌پردازی و یادگیری ماشین را بیش از پیش آشکار می‌سازند.

مطالعات پیشین عمدتاً بر ادغام یادگیری ماشین با مدل‌سازی نرم‌افزاری در قالب زبان‌های خاص دامنه (DSML^۱) و معماری‌های مدل‌رانده (MDA^۲) متمرکز بوده‌اند، که توانسته‌اند روند خودکارسازی تولید کد و بهبود توسعه نرم‌افزار در IoT را تسهیل کنند. این رویکردها در تسهیل توسعه، تولید کد خودکار و رابط‌های کاربری وب‌محور گام‌های مؤثری برداشته‌اند، اما با محدودیت‌هایی همچون دشواری تنظیم صحیح هیپرپارامترها، احتمال ایجاد تعصبات در مدل‌های یادگیری، و وابستگی شدید به داده‌های برچسب‌دار روبرو بوده‌اند [۸]. همچنین، بیشتر پژوهش‌ها در حوزه یادگیری نظارت‌شده تمرکز داشته و چالش حیاتی کمبود داده‌های برچسب‌دار و همچنین مدیریت داده‌های نویزی را کمتر مورد توجه قرار داده‌اند. علاوه بر این، تحقیقات موجود کمتر به بهینه‌سازی توزیع محاسبات در محیط‌های ترکیبی لبه-ابر پرداخته‌اند، که در توسعه سیستم‌های واقع‌گرای IoT اهمیت قابل توجهی دارد [۳-۱۱]. یادگیری نیمه‌نظارتی با بهره‌گیری همزمان از داده‌های برچسب‌دار و بدون برچسب، ظرفیت بالقوه‌ای برای کاهش نیاز شدید به داده‌های برچسب‌دار و مقابله با پراکندگی و نویز داده‌ها نشان داده است. با این حال، کاربرد یکپارچه و سیستماتیک این رویکرد نوین در چارچوب معماری مدل‌رانده برای استخراج ویژگی‌های دامنه در محیط‌های صنعتی واقعی IoT، هنوز به طور جامع پژوهش نشده است. این خلا پژوهشی فرصتی مهم برای افزایش دقت، پایداری و مقیاس‌پذیری سیستم‌های هوشمند فراهم می‌کند [۱۲، ۱۳]. الگوریتم‌های یادگیری نیمه‌نظارتی^۳ روش‌هایی هستند که در آن‌ها مدل با ترکیب مقدار کمی داده برچسب‌دار و مقدار زیادی داده بدون برچسب آموزش می‌بیند. دو نمونه پرکاربرد این دسته عبارت‌اند از:

S3VM که نسخه تعمیم‌یافته SVM است که علاوه بر جدا کردن داده‌های برچسب‌دار با حداکثر حاشیه، ساختار داده‌های بدون برچسب را نیز در فرآیند بهینه‌سازی لحاظ می‌کند تا مرز تصمیم‌گیری دقیق‌تری به دست آید. در روش Self-Training (خودآموزی) هم، ابتدا مدل با داده‌های برچسب‌دار آموزش داده می‌شود، سپس روی داده‌های بدون برچسب پیش‌بینی انجام می‌دهد، پیش‌بینی‌های با اطمینان بالا به‌عنوان برچسب‌های جدید (شبه‌برچسب) به مجموعه آموزش افزوده شده و مدل مجدداً بازآموزی می‌شود. این چرخه تا بهبود تدریجی مدل تکرار می‌گردد.

پژوهش حاضر در پاسخ به این شکاف، چارچوبی نوآورانه مبتنی بر معماری مدل‌رانده و تقویت شده با الگوریتم‌های یادگیری نیمه‌نظارتی از جمله S3VM و Self-Training ارائه می‌دهد که به طور خاص تمرکز بر استخراج ویژگی‌های دامنه در محیط‌هایی با داده‌های ناقص و پرنویز دارد. این چارچوب ضمن کاهش چشمگیر وابستگی به داده‌های برچسب‌دار، با بهینه‌سازی توزیع محاسبات بین لبه و ابر، عملکردی بهبود یافته در مواجهه با شرایط متغیر صنعتی فراهم می‌کند. نتایج حاصل از مدل‌های آموزش‌دیده نیمه‌نظارتی بیانگر دقت طبقه‌بندی حدود ۹۵٪ در محیط‌های واقعی [۳۴، ۳۵] (بهینه‌سازی مصرف انرژی و عملکرد سیستم‌های IoT صنعتی) است که معرف پایداری و کارایی بالای این رویکرد می‌باشد. نوآوری اصلی این مطالعه در تلاقی معماری مدل‌رانده و یادگیری نیمه‌نظارتی، تمرکز خاص بر استخراج ویژگی‌های کلیدی دامنه از داده‌های ناکامل و نویزی، و بهینه‌سازی معماری پردازشی است، مسائلی که در پژوهش‌های پیشین به آنها کمتر پرداخته شده است. وجه نوآوری پژوهش حاضر در ادغام MDA با یادگیری ماشین نیمه‌نظارتی (S3VM) برای بهینه‌سازی سیستم‌های IIoT است، که با جداسازی PIM از PSM و استخراج ویژگی‌های دامنه‌ای، دقت ۹۵٪ در داده‌های ناقص/پرنویز به دست می‌آورد. این رویکرد، وابستگی به داده‌های برچسب‌دار را کاهش داده و نسبت به روش‌های نظارت‌شده و بدون نظارت بهبود ۳-۵٪ ارائه می‌دهد. مقیاس‌پذیری پلتفرم مستقل و کاربرد در صنایع سنگین مانند (فولاد، پتروشیمی) از دیگر نوآوری‌های این پژوهش است. این رویکرد توانسته تعادلی عملی میان چهار معیار اصلی مصرف انرژی، تأخیر، انعطاف‌پذیری و امنیت ایجاد کند و مسیر توسعه سیستم‌های خودسازمانده و مقیاس‌پذیر در صنعت نسل چهارم را هموار سازد. با این وجود، پیچیدگی ذاتی الگوریتم‌های یادگیری افزایشی و دشواری تعمیم‌پذیری مدل‌ها به

^۳ Semi-Supervised Learning^۱ Domain-Specific Modeling Language^۲ Model-Driven Architecture

طراحی معماری پیشنهادی و جزئیات پیاده‌سازی را تشریح می‌کند. بخش پنجم نتایج تجربی و تحلیل عملکرد مدل پیشنهادی را ارائه می‌دهد و در نهایت به جمع‌بندی، نتیجه‌گیری و پیشنهادات برای تحقیقات آتی اختصاص یافته است.

۲- پیشینه تحقیق

جدول ۱ فهرستی از مقالات مرتبط با پژوهش حاضر را نشان می‌دهد.

جدول ۱. کارهای مرتبط

منبع	روش مورد استفاده (رویکرد)	ویژگی‌های کلیدی	چالش‌ها
[۱]	ادغام یادگیری ماشین با مدل‌سازی نرم‌افزار در IoT، تولید کد اتوماتیک، رابط وب کاربرپسند	ادغام ML با مدل‌سازی نرم‌افزار، تولید کد خودکار، استفاده از زبان مدل‌سازی خاص دامنه	تنظیم هیپرپارامترها، تعصبات بالقوه در یادگیری
[۱۴]	تحلیل کتابسنجی مهندسی سیستم مبتنی بر مدل (MBSE) در IoT	بررسی روندهای تحقیقاتی، ادغام MBSE با روش‌های تجاری، تحلیل کتابسنجی کمی و کیفی	نیاز به آموزش ذینفعان، توسعه زنجیره ابزار، انطباق با الزامات قانونی
[۱۵]	روش مدل‌رانه SI4IoT با زبان اختصاصی دامنه، ویرایشگر گرافیکی، تبدیل‌های M2T برای تولید کد	تولید کد خودکار، ادغام خدمات در سه لایه فیزیکی، منطقی و کاربردی، پشتیبانی از چند پلتفرم	چالش‌های ناهمگونی، هماهنگی خدمات، پیچیدگی توسعه
[۱۶]	معماری هوشمند و برنامه‌ریزی شهری در IoT، بررسی چالش‌های فنی، اجتماعی و اقتصادی	تمرکز بر معماری هوشمند، ادغام داده‌ها، نظارت در زمان واقعی، مسائل امنیت و حریم خصوصی	چالش‌های فنی، اجتماعی و اقتصادی، پذیرش کاربر، استاندارد
[۱۷]	مرور سیستماتیک پیشرفت‌های تکنولوژیکی در شهرهای هوشمند	ادغام فناوری‌های نوین، مدیریت منابع، امنیت، اتصال قابل اعتماد	نیاز به اتصال قابل اعتماد، مدیریت داده‌ها، نگرانی‌های امنیتی

به عنوان مزایای کلیدی می‌پردازد، در حالی که چالش‌هایی مانند تنظیم هیپرپارامترها و ریسک تعصبات ارزشیابی را مطرح می‌کند. نقاط ضعف، که توسط نویسندگان اذعان شده است، شامل آزمایش محدود به یک خانه در طول ۶ ماه با ۸ دستگاه، دقت ۱۰۰٪ روی داده‌های برچسب‌گذاری شده اما ۹۲٪ روی مجموعه داده‌های بدون نظارت، و چالش‌های مربوط به سوگیری ارزیابی و تنظیم فرآیند است که کاربردپذیری صنعتی را محدود می‌کند. در پژوهش [۱۷] (۲۰۲۲) نوشته فیصل شهزاد و همکاران، به بررسی توانمندسازی اینترنت اشیا مانند هوش مصنوعی و نسل ششم اینترنت اشیا برای شهرهای پایدار، با پرداختن به مدیریت منابع و امنیت سایبری می‌پردازد. نقاط قوت شامل یک دیدگاه جامع و بینش‌های بین رشته‌ای است. نقاط ضعف، شامل ماهیت نظری آن و عدم پیاده‌سازی MDE-ML و نادیده گرفتن چالش‌های عملی کلان داده است. پژوهش حاضر، "چارچوب هوشمند مبتنی بر یادگیری ماشین و معماری مدل‌رانده برای بهینه‌سازی سیستم‌های اینترنت اشیا صنعتی"، با تکیه بر نقاط قوت آنها - به عنوان مثال، اتوماسیون MDE از Moin و Alulema و در عین حال پرداختن به نقاط ضعف آنها، خود را در موقعیت مناسبی قرار می‌دهد. این مقاله از ML نیمه‌نظارتی (S3VM) برای دقت طبقه بندی ۹۵٪ در وظایف صنعتی مانند پیش‌بینی انرژی و تخمین تأخیر شبکه، حتی با

سناریوهای عملیاتی متنوع (مانند خطوط تولید با شرایط محیطی متفاوت یا شبکه‌های IoT با توپولوژی‌های گوناگون) همچنان به عنوان موانع جدی پیش روی پژوهشگران این حوزه باقی مانده‌اند. در ادامه، مقاله در پنج بخش اصلی تنظیم شده است: بخش اول به مقدمه و بخش دوم پیشینه تحقیق و بخش سوم ادبیات پژوهش به معرفی مدل رانده و الگوریتم S3VM و نحوه ادغام آن‌ها در چارچوب مدل‌رانده می‌پردازد. بخش چهارم روش‌شناسی پژوهش، شامل

ادغام یادگیری ماشین و مدل‌سازی نرم‌افزار در حوزه اینترنت اشیا و سیستم‌های سایبری-فیزیکی، محور اصلی پژوهش‌های متعددی بوده است. پژوهش [۱۵] SI4IoT مبتنی بر مدل‌ها و خدمات برای ادغام سیستم‌های اینترنت اشیا «(۲۰۲۱) نوشته داروین آلوما و همکارانش، یک چارچوب MDE سه لایه (فیزیکی، منطقی، کاربردی) را با استفاده از DSL و تبدیل مدل به متن برای پلتفرم‌هایی مانند آردوینو و Node-Red ارائه می‌دهد. این چارچوب که در یک خانه هوشمند با کنترل‌های حسگر-محرك و API های REST نشان داده شده است، در قابلیت همکاری و استفاده مجدد عالی است. نقاط قوت آن شامل مدیریت ناهمگنی مؤثر و کاهش وابستگی به پلتفرم است. نقاط ضعف آن در تمرکز بر مصرف‌کننده، عدم وجود ML برای تجزیه و تحلیل پیش‌بینی‌کننده و مدیریت محدود داده‌های صنعتی نهفته است که به طور بالقوه مانع عملکرد با ریسک بالا می‌شود. پژوهش [۱] (۲۰۲۲)، آرمین معین و همکاران، ThingML را معرفی می‌کنند که ThingML را با ML برای تولید کامل کد در IoT/CPS، از جمله آموزش و استقرار، بهبود می‌بخشد. این چارچوب که در موارد داده‌محور اعتبارسنجی شده است، کارایی را افزایش می‌دهد. نقاط قوت آن یکپارچه‌سازی و اتوماسیون یادگیری ماشینی-یادگیری ماشین هستند. به تولید خودکار کد، رابط کاربری وب‌محور و دسترسی به روش‌های DAML

امکان آزمایش سریع و انعطاف‌پذیر مدل‌های ماشین لرنینگ را ایجاد نموده است. پژوهش [۲۶] به بررسی چالش‌های فناوری‌ها و راه‌حل‌های ارتباطی در IoT پرداخته و بر اهمیت همکاری میان حوزه‌های و نوآوری اقتصادی تأکید می‌نماید. پژوهش [۲۷] تعامل یادگیری ماشین و برنامه‌نویسی ریاضی را تحلیل کرده و بر توسعه مدل‌های بهینه‌سازی تأکید می‌کند، اما با چالش تفاوت اولویت‌ها در ML و MP مواجه است. پژوهش [۲۸] به توسعه پایدار IoT، کاهش مصرف منابع و اثرات زیست‌محیطی توجه کرده و نقش IoT در ارتقای کیفیت زندگی و ایمنی شبکه‌ها را برجسته ساخته است. در نهایت، پژوهش [۲۹] همگرایی IoT و هوش مصنوعی را بررسی کرده و فضای کاربرد، چالش‌های امنیتی و مسیرهای تحقیقاتی آینده را در اینترنت اشیا صنعتی (IIoT^۱) تحلیل می‌کند.

پژوهش حاضر با ارائه چارچوبی مبتنی بر معماری مدل‌رانده ویژه محیط‌های IoT و تقویت شده با یادگیری ماشین نیمه‌نظارتی، گامی نوین در بهبود دقت، پایداری و مقیاس‌پذیری سیستم‌های هوشمند برداشته است و در مقایسه با [۱] که به توسعه DSML و یکپارچگی یادگیری ماشین با مدل‌سازی نرم‌افزار پرداخته، این مطالعه به‌طور خاص به استخراج ویژگی‌های دامنه در محیط‌های IoT با داده‌های محدود و پرنویز می‌پردازد.

۳- ادبیات پژوهش

۳-۱- مروری بر کاربردهای IoT و نقش آن در تحول دیجیتال صنعت و صنعت فولاد

با گسترش روزافزون اینترنت اشیا، مدیریت حجم بالای داده‌های بدون برچسب، مقیاس‌پذیری و کارایی سیستم‌ها چالش‌های مهمی را ایجاد کرده است [۱، ۱۱، ۱۵، ۱۷، ۱۸، ۲۱، ۲۳، ۳۰]. اهمیت مدل‌سازی مفهومی دامنه در این حوزه موجب شده است، پیچیدگی ساختاری و عملکردی سیستم‌های IoT به صورت انتزاعی و قابل انتقال به لایه‌های اجرایی مدل‌سازی شود. رویکرد مدل‌محور مبتنی بر معماری مدل‌رانده و زبانهای مدل‌سازی خاص دامنه^۲، توسعه منعطف، خودکارسازی تولید کد و سازگاری با پلتفرم‌های متنوع را تسهیل می‌نماید [۱، ۱۸-۲۰، ۲۳، ۳۱]. ترکیب مدل‌سازی دامنه با الگوریتم‌های یادگیری نیمه‌نظارتی، دسترسی به مدل‌های دقیق و مقاوم در محیط‌های صنعتی متنوع را ممکن ساخته است. در صنعت فولاد، که از صنایع پایه و حساس است، بهره‌گیری از سیستم‌های هوشمند مبتنی بر IoT امکان نظارت لحظه‌ای تجهیزات، مدیریت عملیات تولید و پیش‌بینی

داده‌های برچسب‌گذاری شده محدود، در محیط‌های واقعی شبیه‌سازی شده (به عنوان مثال، شبکه‌های حسگر هوشمند) استفاده می‌کند. با جداسازی PIM از PSM از طریق تبدیل‌های Enterprise Architect، DSML و QVT، مقیاس‌پذیری مستقل از پلتفرم را تضمین می‌کند و هزینه‌های توسعه مجدد را کاهش می‌دهد. با این حال، در بحبوحه گسترش دستگاه‌های اینترنت اشیا و تولید کلان‌داده نیمه‌ساختاریافته، تحقیقات مداوم برای غلبه بر شکاف‌های مقیاس‌پذیری و بین دامنه‌ای باقی‌مانده ضروری است. پژوهش [۱۴] با کتاب‌سنجی حوزه مهندسی سیستم مبتنی بر مدل (MBSE) در IoT، روندها و موضوعات نوظهوری مانند ادغام با روش‌های تجاری را شناسایی و چالش‌هایی مانند آموزش ذینفعان، نیاز به ابزارهای مناسب و انطباق با الزامات قانونی را بررسی کرده است. پژوهش [۱۶] نقش IoT را در بهبود محیط‌های شهری و توسعه چارچوب‌های فراگیر و اخلاقی برای ارتقای کیفیت زندگی و اکوسیستم‌های هوشمند بررسی می‌کند. پژوهش [۱۸] به بررسی ابزارها و زبانهای مدل‌محور خاص دامنه برای IoT با تمرکز بر تحلیل داده DAML و طبقه‌بندی جامع روشهای مدل‌سازی می‌پردازد و چالش پوشش ناقص مطالعات را مطرح می‌کند. پژوهش [۱۹] با ادغام یادگیری ماشین و تحلیل داده در مهندسی نرم‌افزار، ابزار ThingML را توسعه داده که تولید خودکار کد و بهبود خدمات هوشمند در IoT را ممکن ساخته است. چالش‌هایی مانند مدیریت پیچیدگی ادغام فناوری‌ها، امنیت، مقیاس‌پذیری و تحمل خطا مطرح شده‌اند. پژوهش [۲۰] رویکردی نوین برای انتخاب خودکار مدل و تنظیم پارامترهای یادگیری ماشین در مهندسی نرم‌افزار مدل‌محور IoT ارائه کرده، هرچند چالش‌هایی در ساخت مدل‌های کارآمد و انتخاب توسعه‌ای هنوز پابرجاست. پژوهش [۲۱] با رویکرد مدل‌محور مبتنی بر شبکه، توسعه نرم‌افزار IoT را تسهیل و مقیاس‌پذیری شبکه‌های بزرگ را افزایش داده است. پژوهش [۲۲] چارچوب یادگیری عمیق بیزی را برای بهبود عملکرد در سیستم‌های توصیه‌گر ارائه داده است، اما با چالش‌های طراحی پیچیده و نیاز محاسباتی بالا روبرو است. از سوی دیگر، پژوهش [۲۳] تمرکز بر استقرار خودکار وظایف یادگیری ماشین روی دستگاه‌های لبه با منابع محدود و حفظ حریم خصوصی کرده است، هرچند با چالش اعتبارسنجی و داده ناقص مواجه است. پژوهش [۲۴] زبان مدل‌سازی IoT و ابزار ThingML را معرفی می‌کند که توسعه برنامه‌های سازگار و کارآمد برای پلتفرم‌های مختلف را تسهیل کرده است. پژوهش [۲۵] با توسعه ماژول تمایز خودکار در PyTorch،

^۲ DSML^۱ Industrial Internet of Things

پرهزینه می‌شود، بلکه مسیر یکپارچه طراحی، توسعه و نگهداری سیستم‌ها را هموار می‌سازد. برای مثال، در سامانه‌های کنترل کیفیت تولید^۱ یا مدیریت بهینه مصرف انرژی در خطوط نورد و کوره‌های قوس الکتریکی، مدل‌سازی مفهومی می‌تواند بستر یکپارچه‌ای برای پایش هوشمند و هشدار زودهنگام فراهم آورد. این اهمیت در معماری مدل‌محور و سامانه‌های IoT، با نقش حیاتی دانش دامنه و تبدیل خودکار مدل به کد اجرایی، دوچندان می‌شود، زیرا هر تغییر مفهومی صرفاً با ویرایش مدل صورت می‌گیرد و باقی چرخه توسعه به صورت خودکار تکرار می‌شود. این امر به شدت زمان و هزینه توسعه و نگهداری سیستم‌های صنعتی را کاهش می‌دهد. به‌عنوان مثال، ترکیب معماری مدل‌محور با زیرساخت OT/IT و تجهیزات قدیمی در صنعت فولاد، بستری یکپارچه برای تعامل هوشمندانه بین سیستم‌های جدید IoT و سامانه‌های قدیمی مانند PLC ها و حسگرهای صنعتی فراهم می‌کند و موجب تسهیل گذار تدریجی و کاهش خطرات چالش‌های ادغام فناوری‌های نسل جدید در محیط‌های صنعتی می‌شود. انتظار می‌رود استقرار این چارچوب مدل‌محور، نه تنها هزینه‌ها و ریسک هماهنگ‌سازی فناوری‌های هوشمند با بسترهای سنتی صنعت فولاد را کاهش دهد، بلکه انطباق سریع با تغییرات بازار، استانداردهای ایمنی و الزامات قانونی را نیز تضمین کند و مزیت عملیاتی پایداری برای صنعت ایجاد نماید.

مدل‌سازی دامنه مفهومی به عنوان زیربنای طراحی سیستم‌های نسل چهارم، امکان فهم بهتر نیازهای صنعتی و هماهنگی دقیق میان لایه‌های نرم‌افزاری و سخت‌افزاری را فراهم می‌آورد. کاربرد گسترده فناوری IoT در صنایع پیشرفته، از جمله پایش هوشمند، نگهداری پیشگیرانه و مدیریت انرژی، با استفاده از این رویکرد مدل‌محور، به بهبود کارایی، کاهش هزینه‌ها و افزایش ایمنی منجر خواهد شد. در نتیجه، ترکیب روشهای مدل‌رانده و یادگیری ماشین نیمه‌نظارتی می‌تواند نقش کلیدی در تسریع روند تحول دیجیتال صنایع نسل چهارم و ارتقای فناوری‌های هوشمند ایفا کند. در نتیجه، استفاده از مدل‌سازی مفهومی دامنه و ترکیب آن با تکنیک‌های هوشمندسازی نه تنها یک انتخاب مهندسی، بلکه یک الزام راهبردی برای شرکت‌ها و پژوهشگران حوزه سیستم‌های سایبری-فیزیکی و اینترنت اشیا محسوب می‌شود. انتظار می‌رود چارچوب پیشنهادی، به عنوان مرجعی توسعه‌یافته، پژوهش‌های آتی در زمینه ادغام مدل‌سازی مفهومی و یادگیری ماشین در محیط‌های صنعتی و IoT را تسهیل نماید [۱، ۲۰، ۲۱، ۲۳].

نگهداری را فراهم کرده و اتوماسیون هوشمند و کاهش ریسک‌های عملیاتی را محقق ساخته است. به علاوه، موفقیت کاربرد IoT در صنایع نفت، گاز، پتروشیمی و لجستیک نشان می‌دهد تلفیق فناوری‌های مدل‌محور و یادگیری ماشین، تحولی شتابان در دیجیتال‌سازی و توسعه سامانه‌های هوشمند مقاوم و تطبیق‌پذیر با داده‌های ناهمگون ایجاد نموده است [۳۲]. این موضوع بر اهمیت و ضرورت پژوهش حاضر تأکید دارد.

۳-۲ معماری مدل رانده

مهندسی نرم‌افزار مبتنی بر مدل، بر نقش محوری معماری مدل رانده تأکید می‌کند، به ویژه در زمینه استخراج و مدل‌سازی ویژگی‌های محیطی [۳۳]. با ادغام قابلیت‌های یادگیری ماشین، رویکرد مدل رانده، فراتر از صرفاً تولید کد خودکار، به ابزاری قدرتمند برای درک و بازنمایی جنبه‌های پویای محیط تبدیل می‌شود. این پژوهش یک معماری مدل نرم‌افزار هوشمند را که یک مدل نرم‌افزاری پیشرفته مبتنی بر AI/ML می‌باشد را پیشنهاد می‌کند. این مدل می‌تواند ساختار و رفتار خود را بر اساس اجزای ML تعبیه‌شده در آن تطبیق دهد و امکان تنظیمات بی‌درنگ و بهبود عملکرد را فراهم کند. در این رویکرد، مدل‌های ML برای یادگیری و کنترل جنبه‌های پویای مدل نرم‌افزاری به کار گرفته می‌شوند. این قابلیت برای محیط‌هایی با ویژگی‌های متغیر، مانند اینترنت اشیا، حیاتی است. در چنین محیط‌هایی، مدل رانده می‌تواند با استفاده از داده‌های جمع‌آوری‌شده از حسگرها که منعکس‌کننده ویژگی‌های محیطی هستند، الگوها را شناسایی کرده و پیش‌بینی‌هایی را انجام دهد. این پیش‌بینی‌ها به مدل نرم‌افزاری امکان می‌دهند تا خود را با شرایط محیطی وفق دهد و اقدامات لازم را آغاز کند یا داده‌ها را برای استفاده‌های آتی ذخیره نماید. بنابراین، معماری مدل رانده با توانایی خود در استخراج، تحلیل و مدل‌سازی دقیق ویژگی‌های پیچیده و متغیر محیطی، به‌ویژه در سناریوهایی که نیاز به درک و پاسخ‌گویی بی‌درنگ به تغییرات محیطی وجود دارد، اهمیت بسیار زیادی پیدا می‌کند [۱، ۲۰، ۲۱، ۲۳، ۳۰، ۳۳].

۳-۳ یکپارچه‌سازی معماری مدل رانده با یادگیری ماشین


توصیف دامنه مفهومی اصل محوری موفقیت پیاده‌سازی و توسعه سامانه‌های پیچیده صنعتی است. مدل مفهومی، بنیان شفافیت، کاهش ابهامات، شناسایی نیازهای کلیدی و هم‌زمانی میان ذینفعان، مهندسان و مدیران پروژه را فراهم می‌کند. در صنایع مادر همچون فولاد، مدل‌سازی دامنه نه تنها مانع دوباره‌کاری و خطاهای

¹ Quality Control

بر الگو^۳ و با استفاده از زبان QVT انجام شد، این کار تولید کد و پیکربندی را برای پلتفرم‌های مختلف سریع و کم‌هزینه کرد. در فرآیند توسعه، داده‌ها از سنسورها و دستگاه‌های هوشمند جمع‌آوری، پالایش و آماده‌سازی شدند. سپس با انتخاب الگوریتم مناسب، مدل یادگیری ماشین نیمه‌نظارتی S3VM آموزش و اعتبارسنجی شد. تمام مراحل مدل‌سازی و تبدیل مدل‌ها با DSML انجام گرفت تا یکپارچگی و خودکارسازی فرآیند تضمین شود.

نمودار (۲-فلوچارت فعالیت) مراحل اصلی مدل‌سازی دامنه، جمع‌آوری داده، پیش‌پردازش، انتخاب و آموزش مدل، اعتبارسنجی و بازگشت به مراحل قبلی در صورت نیاز به اصلاح را، شامل می‌شود و در حقیقت مراحل کلیدی چرخه توسعه مدل‌محور را نشان می‌دهد. این نمودار ماهیت تکرارشونده و بازخوردی مهندسی مدل‌محور را برجسته می‌کند، یعنی هر مرحله می‌تواند بر اساس نتایج اعتبارسنجی، اصلاح شود. نمودار ۳ دیاگرام کلاس، نمایانگر یک سیستم صنعتی مبتنی بر اینترنت اشیاء و یادگیری ماشین نیمه‌نظارتی است. هر کلاس و ارتباط آن نمایانگر موجودیت‌ها و داده‌های کلیدی است که می‌تواند به عنوان ویژگی‌های مهم جهت تحلیل و آموزش مدل ML استخراج شود. فیچرهای استخراج‌پذیر از کلاس‌ها شامل: دستگاه و زیرکلاس‌ها (دستگاه تولید، پایش و کنترل)، نوع دستگاه (نوع تولید، نظارت، کنترل)، وضعیت سلامت دستگاه، شناسه یکتا دستگاه (برای ردیابی)، تأخیرهای زمانی دستورات یا ارسال داده‌ها، عملکرد عملگرهای مرتبط هستند. این فیچرها می‌توانند در تحلیل کارایی دستگاه‌ها، تشخیص خطا، و بهینه‌سازی فرآیند به کار روند. پارامترهای فرآیند عبارتند از: مقادیر عددی مهم مانند دما، فشار، سرعت، زمان، مقدار انرژی مصرفی، مقادیر کیفی مرتبط با وضعیت فرآیند. این اطلاعات به عنوان ویژگی‌های کلیدی برای پیش‌بینی کیفیت و عیب‌یابی سیستم استفاده می‌شوند. داده و ویژگی داده‌ها شامل: داده‌های خام و پردازش‌شده سنسور، کیفیت داده نوع داده (برچسب‌دار، بدون برچسب)، کیفیت داده و ویژگی آن است که، تعیین‌کننده قابل اعتماد بودن داده‌ها برای آموزش مدل است و نقش مهمی در فیلترینگ و انتخاب فیچرهای موثر دارد. نتیجه پیش‌بینی مقدار پیش‌بینی شده و میزان اطمینان این داده‌ها می‌توانند در ارزیابی مدل و بهبود مداوم به کار روند. نگهداری و پایش وضعیت عبارتند از: سیگنال‌های هشدار و وضعیت نگهداری، زمان‌بندی تعمیرات. اینها فیچرهایی هستند برای پیش‌بینی رفتار آتی دستگاه‌ها و کاهش

در نمودار ۱، لایه‌های معماری مدل‌رانده تقویت شده با یادگیری ماشین، در لایه حسگر، جمع‌آوری داده‌ها از دستگاه‌های IoT صورت می‌گیرد که می‌تواند شامل حسگرهای مختلف باشد (مانند حسگرهای محیطی و غیره). در لایه پردازش محلی، داده‌ها فیلتر و پردازش اولیه می‌شوند. سپس جداسازی مدل مفهومی و انتزاعی از مدل وابسته به پلتفرم^۲ صورت می‌گیرد. در مرحله بعد از الگوریتم‌های یادگیری ماشین برای استخراج ویژگی‌ها و شناسایی الگوها استفاده می‌شود. لایه یادگیری ماشین، عملکرد کلیدی دارد و به دو بخش تقسیم می‌شود. ۱- بخش یادگیری نیمه‌نظارتی که در آن برای بهبود مدل‌ها از داده‌های برچسب‌گذاری شده و داده‌های بدون برچسب استفاده می‌شود. ۲- بخش مدل‌سازی و ارزیابی به منظور آزمایش و بهینه‌سازی مدل‌ها برای عملکرد بهتر. در لایه ابر، داده‌های پردازش‌شده و تحلیل‌شده به سرورهای ابری منتقل می‌شوند، جایی که مدل‌ها به‌روز می‌شوند و نتایج به کاربر نهایی ارائه می‌شوند.



نمودار (۱): لایه‌های معماری مدل‌رانده تقویت شده با یادگیری ماشین

۴- روش پیشنهادی

معماری روش پیشنهادی (نمودار ۲) برای بهبود کارایی در محیط‌های IoT با استفاده از معماری مدل‌رانده تقویت‌شده با یادگیری ماشین (نیمه‌نظارتی) شامل مراحل است که در نمودار ۱- فلوچارت فعالیت نشان داده شده است. ما در این پژوهش، با رویکرد معماری مدل‌رانده، مدل مفهومی و انتزاعی را از مدل وابسته به پلتفرم جدا کردیم تا تغییر پلتفرم نیازمند بازنویسی کل سیستم نباشد. برای این جداسازی، از ابزار Enterprise Architect و زبان مدل‌سازی خاص دامنه استفاده شد تا مفاهیم را، دقیق مدل کنیم. تبدیل مدل‌ها از PIM به PSM به صورت خودکار و با تبدیلات مبتنی

³ Template-based

¹ PIM

² PSM

۴-۱- رویکرد به کار رفته در این پژوهش

را آموزش دادیم. سپس مدل را اعتبارسنجی نموده و مطمئن شدیم که دقت خوبی دارد. در نهایت، همه این کارها را با استفاده از یک زبان مدل‌سازی خاص دامنه انجام دادیم. این زبان به ما کمک کرد که بتوانیم مدل‌ها را به صورت یکپارچه تعریف و فرآیند تبدیل مدل‌ها را خودکار کنیم. زبان DSML در دو مرحله اصلی مورد استفاده قرار گرفت. اول مدل‌سازی PIM، که در این مرحله، از DSML برای تعریف مفاهیم و روابط موجود در دامنه خانه هوشمند استفاده شد. به عنوان مثال، DSML این امکان را فراهم کرد تا مفاهیمی مانند "اتاق"، "سنسور دما"، "عملگر روشنایی" و "قانون اتوماسیون" را به صورت دقیق و با استفاده از واژگان خاص دامنه تعریف کنیم. این امر، مدل‌سازی PIM را تسهیل کرده و از ایجاد ابهام جلوگیری می‌کند. سپس تبدیل مدل از DSML برای تعریف تبدیلات بین مدل PIM و PSM استفاده شد. این تبدیلات، نحوه نگاشت عناصر PIM به عناصر PSM را مشخص می‌کنند. به عنوان مثال، یک "سنسور دما" در مدل PIM می‌تواند به یک شیء سنسور با تنظیمات خاص در کد PSM تبدیل شود. پیاده‌سازی و ارزیابی چارچوب پیشنهادی با استفاده از زبان برنامه‌نویسی Python انجام شده است. تمامی آزمایش‌ها و شبیه‌سازی‌ها در محیط Google Colab صورت گرفته و مدل‌های یادگیری ماشین نیمه‌نظارتی (از جمله S3VM و Self-Training) با بهره‌گیری از کتابخانه‌های استاندارد scikit-learn، NumPy و Pandas توسعه و اعتبارسنجی شده‌اند. این بستر امکان اجرای سریع، تکرارپذیری نتایج و دسترسی به منابع محاسباتی ابری را فراهم ساخته است.

۴-۲- مجموعه داده‌ها و تنظیمات

در این پژوهش، از مجموعه داده‌های مختلف از جمله synthetic_dataset [۳۴] با ۱۴ ویژگی و ۱۰,۰۰۰ رکورد از پلتفرم گیت‌هاب استفاده شد که به دلیل تناسب با اهداف پژوهشی و کیفیت مطلوب انتخاب گردید [۳۰]. از مجموعه داده واقعی Steel Industry Energy Consumption [۳۵] نیز استفاده گردید. این مجموعه داده واقعی شامل ۳۵۰۴۰ رکورد و ۹ ویژگی است که از یک کارخانه فولاد در کره جنوبی جمع‌آوری شده و به دلیل تناسب کامل با اهداف پژوهشی (بهینه‌سازی مصرف انرژی و عملکرد سیستم‌های IoT صنعتی) و کیفیت مطلوب انتخاب شده است. در همین راستا، شهپر و بدرقه [۳۶] نشان دادند که ترکیب روش‌های یادگیری ماشین با تحلیل مؤلفه‌های اصلی، ضمن کاهش ابعاد داده‌ها و زمان پردازش، می‌تواند دقت تشخیص حملات در شبکه‌های اینترنت اشیا را نیز

رویکرد ما در این پژوهش، بر مبنای معماری مدل رانه است. یکی از مهم‌ترین کارهایی که انجام دادیم، جداسازی لایه‌ها بود. ما مدل‌های انتزاعی را از مدل‌های وابسته به پلتفرم جدا کردیم. این کار باعث می‌شود، اگر بخواهیم پلتفرم را تغییر دهیم، نیازی نباشد کل سیستم را از ابتدا بنویسیم. کافی است مدل PSM را تغییر دهیم، برای اینکه بتوانیم این جداسازی را انجام دهیم، از ابزارهای مختلف و همچنین از تکنیک‌های MDA برای تبدیل خودکار مدل‌ها از PIM به PSM استفاده نمودیم. این کار باعث شد که زمان و هزینه توسعه خیلی کم شود. بعنوان مثال در راستای پیاده‌سازی یک خانه هوشمند با رویکرد MDA، برای جداسازی مدل‌های PIM و PSM، از ابزار Enterprise Architect استفاده نمودیم. این ابزار، امکان مدل‌سازی UML را فراهم کرده و با پشتیبانی از پروفایل‌های سفارشی، امکان تعریف کلیشه‌ها^۱ و مقدار برچسب خاص دامنه خانه هوشمند را فراهم می‌کند. این امر، امکان تعریف دقیق‌تر مفاهیم PIM و انطباق آن‌ها با نیازمندی‌های PSM را تسهیل می‌کند. برای تبدیل خودکار مدل از PIM به PSM، از تکنیک تبدیلات مبتنی بر الگو استفاده نمودیم. در این تکنیک، الگوهایی بر اساس زبان QVT تعریف شدند که نحوه نگاشت عناصر مدل PIM (مانند سنسورها، عملگرها، قوانین) به عناصر مدل PSM (مانند کدهای اجرایی، پیکربندی دستگاه‌ها، پروتکل‌های ارتباطی) را مشخص می‌کنند. این الگوها، فرآیند تبدیل را خودکار کرده و امکان تولید کد و پیکربندی متناسب با پلتفرم مورد نظر را فراهم می‌کنند. فرض کنیم ما یک سری دستورالعمل کلی برای ساخت یک خانه هوشمند در مدل PIM داریم. می‌خواهیم این دستورالعمل‌ها را برای یک پلتفرم خاص (مثلاً یک سیستم عامل خاص) در مدل PSM پیاده‌سازی کنیم. کاری که انجام دادیم، این بود که یک سری الگو تعریف کردیم. هر الگو می‌گوید: که چطور یک قسمت از دستورالعمل کلی (PIM) را به یک قسمت خاص از پلتفرم (PSM) تبدیل کنیم. مثلاً یک الگو می‌گوید: اگر در دستورالعمل کلی گفتیم: "یک سنسور دما بگذار"، این را به (کد X را اجرا کن که با سنسور دمای Y ارتباط برقرار کند) تبدیل کنید. با استفاده از این الگوها، می‌توانیم خیلی سریع و بدون اینکه لازم باشد، کد دستی بنویسیم، دستورالعمل‌های کلی را به کدهای اجرایی برای پلتفرم مورد نظر تبدیل کنیم. اسم این روش "تبدیل مبتنی بر الگو" است. ما داده‌ها را پیش‌پردازش نموده و آن‌ها را به فرمت مناسب برای تحلیل، تبدیل کردیم. یک الگوریتم مناسب انتخاب نموده و مدل یادگیری ماشین نیمه نظارتی S3vm


² Tag value

¹ Stereotype

بهبود بخشد.

(تأخیر/زدست‌دادن بسته) و بار سیستم و همچنین سنجه‌های کلیدی مانند زمان پاسخ‌گویی، مصرف انرژی، پهنای باند و رضایت کاربر. تحلیل نتایج: با روش‌های آماری، مصورسازی داده‌ها، مقایسه با روش‌های پایه و اعتبارسنجی K-Fold Cross-Validation. در نمودار ۴، چارچوب ترکیب داده‌های بهینه‌شده، الگوریتم‌های نیمه‌نظارتی منتخب و راهکارهای ارزیابی چندبُعدی، سیستمی کارآمد برای محیط‌های IoT ایجاد می‌کند که همزمان اهداف کلیدی مانند سرعت پاسخگویی، بهینه‌سازی منابع و تجربه کاربری مطلوب را محقق می‌سازد. برای تبدیل متغیر هدف به سه کلاس (کم، متوسط و زیاد)، از روش تقسیم‌بندی بازه‌ای با عرض مساوی استفاده شد. بدین صورت که دامنه مقادیر به سه بازه مساوی تقسیم گردید و برچسب‌های «کم»، «متوسط» و «زیاد» بر اساس دو آستانه حاصل از تقسیم دامنه به سه قسمت مساوی تخصیص یافت. این برچسب‌گذاری امکان آموزش مدل‌های نیمه‌نظارتی S3VM و Self-Training را با ترکیب داده‌های برچسب‌دار و بدون برچسب فراهم ساخت.

برای مدل‌سازی مبتنی بر یادگیری نیمه‌نظارتی، چهار الگوریتم کلیدی به کار گرفته شد: S3VM برای ایجاد مرزهای تصمیم‌گیری دقیق در مسائل پیچیده طبقه‌بندی، Self-Training با رویکرد آموزش تدریجی روی داده‌های بدون برچسب. Label_Propagation و Co-Training با استفاده از مدل‌های موازی برای افزایش دقت پیش‌بینی. با استفاده از تنظیم هسته‌های S3VM (خطی/چندجمله ایی/RBF و...) و پارامترهای (C, γ) ، کاهش پیچیدگی محاسباتی با PCA و انتخاب ویژگی، پردازش توزیع‌شده و بهینه‌سازی انتقال داده (فشرده‌سازی، نمونه‌برداری، پروتکل‌های MQTT/CoAP). کاهش مصرف منابع با مدیریت انرژی (الگوریتم‌های کم‌مصرف، Sleep Mode، دستگاه‌های بهینه)، بهینه‌سازی پهنای باند (انتقال انتخابی داده‌های ضروری)، تجربه کاربری: از طریق ارزیابی بازخورد کاربران و طراحی رابط کاربری ساده. ارزیابی سیستم: با استفاده از سناریوهای آزمون شامل شرایط محیطی (دما/رطوبت)، شبکه‌ای



نمودار (۴): معرفی معیارها

مسئله تعریف‌شده در این پژوهش، به بررسی و پیش‌بینی مصرف انرژی در سیستم‌های اینترنت اشیا می‌پردازد. هدف اصلی، استفاده از ویژگی‌های مستقل مانند شرایط شبکه، مسافت‌ها، نیازهای محاسباتی، منابع محاسباتی، اندازه وظایف، تأخیر، و موقعیت‌های مکانی برای مدل‌سازی و پیش‌بینی مقدار مصرف انرژی است. این پیش‌بینی می‌تواند به بهینه‌سازی عملکرد سیستم‌های IoT و کاهش مصرف انرژی کمک کند. داده‌ها شامل پارامترهای مهمی همچون شرایط شبکه، فاصله دستگاه‌ها، نیازهای محاسباتی، منابع محاسباتی، اندازه وظایف، تأخیر و موقعیت‌های مکانی هستند و هدف مدل، دسته‌بندی مصرف انرژی به سه گروه کم، متوسط و زیاد است (مطابق جدول ۲) که این کار با توجه به ویژگی‌های عملیاتی و محیطی هر دستگاه انجام می‌شود. اعمال محدودیت‌های دامنه‌ای:


۴-۳- روش‌های مورد مقایسه

در زیر روش‌های مورد استفاده در این پژوهش را بررسی می‌کنیم.


۴-۳-۱- روش پیشنهادی (یادگیری ماشین نیمه نظارتی)

باتوجه به ویژگی داده‌های اینترنت اشیا، از یادگیری ماشین نیمه‌نظارتی که از ترکیب داده‌های برچسب‌دار و بدون برچسب استفاده می‌کند، استفاده نمودیم. نوآوری دیگر این پژوهش، استفاده از الگوریتم S3VM و Self-Training در موضوع عنوان پژوهش است.


در مورد پیش‌بینی مصرف انرژی در سیستم‌های اینترنت اشیا،



نمودار (۵): ماتریس سردرگمی انرژی



نمودار (۶): نمودار TPR به FPR انرژی



نمودار (۷): نمودار precision به recall انرژی


هدف دیگر پژوهش ارائه شده، بهبود کارایی محیط‌های اینترنت اشیا مدل‌رانده از طریق بهبود زمان پاسخگویی در شبکه‌های IoT با استفاده از روش‌های یادگیری نیمه‌نظارتی می‌باشد. در این بخش هدف اصلی، پیش‌بینی دقیق تأخیر در این محیط‌ها بر اساس ویژگی‌های مستقل نظیر شرایط شبکه، مسافت‌ها، نیازهای محاسباتی، منابع محاسباتی، اندازه وظایف، مصرف انرژی و موقعیت‌های مکانی، به منظور بهینه‌سازی و بهبود عملکرد کلی سیستم می‌باشد این پژوهش می‌تواند به بهبود کارایی و عملکرد شبکه‌های IOT کمک کند. مدل S3VM نیمه‌نظارتی با استفاده از

داده‌ها با توجه به محدودیت‌های عملیاتی (مانند بازه دما، رطوبت، مصرف انرژی مجاز، وضعیت قفل درب، تعداد دستگاه‌های متصل و سرعت شبکه) پاک‌سازی و اعتبارسنجی شدند تا کیفیت داده و صحت نتایج تضمین شود.

داده‌ها با استفاده از روش‌های استانداردسازی نرمال شدند تا اثر مقیاس ویژگی‌ها حذف شود، مصرف انرژی به سه دسته کم، متوسط و زیاد تقسیم‌بندی شد تا مدل قابلیت طبقه‌بندی پیدا کند. ۸۰٪ داده‌ها به صورت عمدی بدون برچسب قرار گرفت تا سناریوی واقعی کمبود داده برچسب‌دار شبیه‌سازی شود و قدرت مدل نیمه‌نظارتی به چالش کشیده شود. با استفاده از تکنیک SMOTE و SMOTETomek داده‌های برچسب‌دار متوازن شدند تا مدل از یادگیری سوگیرانه جلوگیری کند و ابعاد ویژگی‌ها با تحلیل مؤلفه‌های اصلی (PCA) کاهش یافت تا پیچیدگی مدل و نویز داده‌ها کم شود و سرعت پردازش افزایش یابد. مدل S3VM نیمه‌نظارتی با استفاده از داده‌های ترکیبی برچسب‌دار و بدون برچسب آموزش داده شد تا از اطلاعات ساختاری داده‌های بدون برچسب نیز بهره‌برداری شود. مطابق جدول ۲، مدل با دقت نهایی ۹۵٪ عملکرد بسیار مطلوبی داشت. گزارش طبقه‌بندی نشان داد که مدل در هر سه گروه کم، متوسط و زیاد، به طور متوازن دقت و بازخوانی بالایی حدود ۹۵ درصد precision و recall دارد. نمودارهای ۵ و ۶ و ۷ ماتریس سردرگمی و نمودارهای ROC و Precision-Recall برای هر کلاس رسم شد و نشان داد مدل توانایی تفکیک مناسبی میان دسته‌ها دارد. با GridSearchCV بهترین پارامترهای مدل انتخاب شد و مدل نهایی به صورت فایل joblib ذخیره گردید تا در کاربردهای عملی قابل استفاده باشد.

جدول ۲. گزارش طبقه بندی مصرف انرژی

Classification Report				
	precision	recall	f1-score	support
high	0.94	0.96	0.95	734
Low	0.94	0.95	0.95	595
Medium	0.95	0.93	0.94	551
Accuracy			0.95	1880
macro avg	0.95	0.94	0.94	1880
weighted avg	0.95	0.95	0.95	1880



نمودار (۱۰): نمودار Precision به recall


۴-۴- تحلیل نتایج-ارزیابی

تحلیل نتایج حاصل از چارچوب ترکیبی معماری مدل‌محور و یادگیری ماشین نیمه‌نظارتی، نشان‌دهنده ارتقاء قابل توجه در دقت پیش‌بینی مدل‌ها و پایداری عملکرد آنها، به ویژه در شرایط مواجهه با داده‌های نویزی و کمبود داده‌های برچسب‌دار است. این قابلیت، نسبت به روش‌های پیشرفته نظیر یادگیری عمیق مبتنی بر شبکه‌های عصبی و الگوریتم‌های نظارت شده کامل، که معمولاً به حجم زیادی داده برچسب خورده و منابع محاسباتی وسیع نیاز دارند، برتری محسوسی را به همراه داشته است. شاخص اصلی و متمایز رویکرد پیشنهادی، امکان تطبیق و مقیاس‌پذیری مدل با داده‌های صنعتی ناهمگون، غیرساختاریافته و پراکنده است، این ادعا بر پایه دو ویژگی اصلی چارچوب استوار است: (۱) استفاده از یادگیری نیمه‌نظارتی که با بهره‌گیری همزمان از داده‌های برچسب‌دار محدود و داده‌های بدون برچسب فراوان، توانایی کار با داده‌های ناقص، نویزی و پراکنده را فراهم می‌کند. (۲) معماری مدل‌رانده با جداسازی PIM از PSM، که مقیاس‌پذیری و تطبیق‌پذیری مستقل از پلتفرم را در محیط‌های صنعتی ناهمگون تضمین می‌نماید. نتایج تجربی نیز با دقت طبقه‌بندی ۹۵٪ بر روی داده‌های ناقص و نویزی این قابلیت را تأیید کرده است. شرایطی که در کاربردهای واقعی صنایع تولیدی، از جمله سامانه‌های مبتنی بر اینترنت اشیاء و صنایع سنگین مانند فولاد و پتروشیمی، به عنوان چالش جدی مطرح می‌باشد. مدل نیمه‌نظارتی توسعه‌یافته، با بهره‌گیری از معماری مبتنی بر کلاس‌های صنعتی و تعامل با انواع دستگاه‌ها، سنسورها و داده‌های تولیدی، از انعطاف‌پذیری بالایی در به‌روزرسانی پارامترهای فرآیندی و استفاده اثربخش از داده‌های نیمه‌برچسب‌خورده، برخوردار بوده و امکان کاربرد موفق در محیط‌های صنعتی دینامیک و پیچیده را


داده‌های ترکیبی برچسب‌دار و بدون برچسب آموزش داده شد تا از اطلاعات ساختاری داده‌های بدون برچسب نیز بهره‌برداری شود. مطابق جدول ۳ مدل با دقت نهایی ۹۵٪ عملکرد بسیار مطلوبی داشت. گزارش طبقه‌بندی نشان داد که مدل در هر سه گروه کم، متوسط و زیاد، به طور متوازن دقت و بازخوانی بالایی حدود ۹۵ درصد precision و recall دارد. نمودارهای ۸ و ۹ و ۱۰ ماتریس سردرگمی و نمودارهای ROC و Precision-Recall برای هر کلاس رسم شد و نشان داد مدل توانایی تفکیک مناسبی میان دسته‌ها دارد.

جدول ۳. گزارش طبقه‌بندی تاخیر

Classification Report:				
	precision	recall	f1-score	support
High	0.94	0.95	0.94	659
Low	0.94	0.94	0.94	581
medium	0.95	0.94	0.95	636
accuracy			0.95	1876
macro avg	0.95	0.95	0.95	1876
weighted avg	0.95	0.95	0.95	1876



نمودار (۸): نمودار ماتریس سردرگمی تاخیر و زمان پاسخگوئی



نمودار (۹): نمودار TPR به FPR

- [4] Nooraei Abadeh, M., A semantic axiomatic design for integrity in IoT. Transactions on Emerging Telecommunications Technologies, 2024. 35(9): p. e5032. <https://doi.org/10.1002/ett.5032>.
- [5] Eyke, N.S., B.A. Koscher, and K.F. Jensen, Toward machine learning-enhanced high-throughput experimentation. Trends in Chemistry, 2021. 3(2): p. 120-132.
- [6] Snoeck, M. and Y. Wautelet, Agile MERODE: a model-driven software engineering method for user-centric and value-based development. Software and Systems Modeling, 2022. 21(4): p. 1469-1494.
- [7] Nooraei Abadeh, M. and M. Mirzaie, DiffPageRank: An efficient differential PageRank approach in MapReduce. The Journal of Supercomputing, 2021. 77(1): p. 188-211. <https://doi.org/10.1007/s11227-020-03265-3>.
- [8] Boumahdi, F., et al., MDA4SOA+ d: A new model driven architecture to supporting decision making in SOA. Journal of King Saud University-Computer and Information Sciences, 2023. 35(5): p. 101544.
- [9] Wang, Y., et al., Machine learning-enhanced flexible mechanical sensing. Nano-Micro Letters, 2023. 15(1): p. 55.
- [10] Liu, J., H. Hu, W. Xu, and D. Luo, Internet of things challenges and future scope for enhanced living environments, in Advances in Computers. 2024, Elsevier. p. 201-246.
- [11] Park, Y.-S., B.U. Park, and H.-J. Jeon, Advances in machine learning-enhanced nanozymes. Frontiers in Chemistry, 2024. 12: p. 1483986.
- [12] Kwon, H., Z.A. Ali, and B.M. Wong, Harnessing semi-supervised machine learning to automatically predict bioactivities of per-and polyfluoroalkyl substances (PFASs). Environmental Science & Technology Letters, 2023. 10(11): p. 1017-1022.
- [13] Albayati, M.G., et al., Semi-supervised machine learning for fault detection and diagnosis of a rooftop unit. Big Data Mining and Analytics, 2023. 6(2): p. 170-184.
- [14] Ahmad, E., Model-based system engineering of the Internet of Things: A bibliometric literature analysis. IEEE Access, 2023. 11: p. 50642-50658.
- [15] Alulema, D., et al., SI4IoT :A methodology based on models and services for the integration of IoT systems. Future Generation Computer Systems, 2023. 143: p. 132-151.
- [16] Marques, G., Editor, Internet of Things: Architectures for Enhanced Living Environments. Advances in Computers. Vol. 133. 2024, Cambridge, MA: Academic Press/Elsevier.
- [17] Javed, A.R., et al., Future smart cities: Requirements, emerging technologies, applications, challenges, and future aspects. Cities, 2022. 129: p. 103794.
- [18] Mardani Korani, Z., et al., Model-driven engineering techniques and tools for machine learning-enabled IoT applications: A scoping review. Sensors, 2023. 23(3): p. 1458.
- [19] Moin, A. Data analytics and machine learning methods, techniques and tool for model-driven engineering of smart IoT services. in 2021 IEEE/ACM 43rd International Conference on Software Engineering: Companion Proceedings (ICSE-Companion). 2021. IEEE, p. 287-292.
- [20] Moin, A., et al., Enabling automated machine learning for model-driven AI engineering. arXiv preprint arXiv:2203.02927, 2022.
- [21] Berrouyne, I., et al., A model-driven methodology to accelerate software engineering in the internet of things. IEEE Internet of Things Journal, 2022. 9(20): p. 19757-19772.
- [22] Wang, H. and D.-Y. Yeung, A survey on Bayesian deep learning. ACM computing surveys (csur), 2020. 53(5): p. 1-37.
- [23] Moin, A., et al. Supporting AI engineering on the IoT edge through model-driven TinyML. in 2022 IEEE 46th Annual Computers, Software, and Applications Conference (COMPSAC). 2022. IEEE.

فراهم آورده است. این توانمندی مدل، علاوه بر حفظ دقت بالا در تشخیص و پیش‌بینی، بهینه‌سازی مصرف منابع محاسباتی، کاهش زمان پاسخگویی سامانه، ارتقاء سطح اعتمادپذیری و پایداری سیستم را نیز موجب گردیده است. بنابراین ابزارهای پیشنهادی این پژوهش، زمینه تسهیل پذیرش و استقرار فناوری‌های هوشمندسازی و دیجیتال‌سازی را در صنایع نسل چهارم فراهم نموده و ارزش افزوده عملیاتی قابل توجهی را به ارمغان می‌آورد.

۵- نتیجه‌گیری و پیشنهاد برای تحقیقات آتی

تحلیل آماری نتایج نشان داد که مدل نیمه‌نظارتی پیشنهادی در هر دو مسئله طبقه‌بندی مصرف انرژی و تخمین تأخیر شبکه، دقت نهایی حدود ۹۵٪ را به دست آورد. مقادیر Precision و Recall در هر سه کلاس به‌طور متوازن در محدوده ۰/۹۳ تا ۰/۹۶ قرار گرفت و ماتریس سردرگمی به همراه منحنی‌های ROC و Precision-Recall، پایداری عملکرد مدل را در شرایط کمبود داده برجسته‌سازی تأیید کرد. با وجود این نتایج مطلوب، پژوهش حاضر با محدودیت‌ها و چالش‌هایی مواجه است که مهم‌ترین آن‌ها عبارتند از: وابستگی به داده واقعی تنها از یک محیط صنعتی (کارخانه فولاد)، حساسیت نسبی مدل به تنظیم فرآپارامترها، پیچیدگی محاسباتی در مقیاس‌های بسیار بزرگ، و فقدان ارزیابی کامل در شرایط بلادرنگ و مکانیزم‌های خودترمیمی. این محدودیت‌ها تعمیم‌پذیری نتایج به صنایع متنوع و سناریوهای عملیاتی پویا را محدود می‌سازد.

با توجه به نتایج مثبت چارچوب پیشنهادی، مسیرهای متعددی برای توسعه پژوهش‌های آتی وجود دارد. از جمله می‌توان به توسعه مدل‌های یادگیری انتقالی برای افزایش دقت در داده‌های چنددانه‌ای، استفاده از یادگیری فدریتد به‌منظور حفظ حریم خصوصی و افزایش مقیاس‌پذیری، پیاده‌سازی الگوریتم‌های Explainable AI برای ارتقای شفافیت مدل‌ها، ارزیابی چارچوب در سناریوهای بلادرنگ و طراحی مکانیزم‌های خودپایدار مبتنی بر مدل اشاره کرد.

منابع

- [1] Moin, A., et al., A model-driven approach to machine learning and software modeling for the IoT: Generating full source code for smart Internet of Things (IoT) services and cyber-physical systems (CPS). Software and Systems Modeling, 2022. 21(3): p. 987-1014.
- [2] Dral, P.O., et al., MLatom 3: a platform for machine learning-enhanced computational chemistry simulations and workflows. Journal of Chemical Theory and Computation, 2024. 20(3): p. 1193-1213.
- [3] M Casares, P.A., et al., GradDFT. A software library for machine learning enhanced density functional theory. The Journal of Chemical Physics, 2024. 160(6).

- [31] Moin, A., S. Rössler, and S. Günemann, ThingML+ augmenting model-driven software engineering for the Internet of Things with machine learning. arXiv preprint arXiv:2009.10633, 2020.
- [32] Rademacher, F., et al., Model-Driven Engineering of Microservice Architectures—The LEMMA Approach, in Ernst Denert Award for Software Engineering 2022: Practice Meets Foundations. 2024, Springer Nature Switzerland Cham. p. 105-147.
- [33] Verbruggen, C. and M. Snoeck, Practitioners' experiences with model-driven engineering: a meta-review. *Software and Systems Modeling*, 2023. **22**(1): p. 111-129.
- [34] Moghaddasi, K. and M. Masdari, Blockchain-driven optimization of IoT in mobile edge computing environment with deep reinforcement learning and multi-criteria decision-making techniques. *Cluster Computing*, 2024. **27**(4): p. 4385–4413.
- [35] Steel Industry Energy Consumption Dataset. UCI Machine Learning Repository. Available: <https://archive.ics.uci.edu/dataset/851/steel+industry+energy+consumption>.
- [36] Shahpar, Z. and M. Badragheh, Presenting a hybrid model based on machine learning and principal component analysis for attack detection in the Internet of Things. *Journal of Information and Communication Technology*, 2026. **17**(66–67): p. 178–188. Available from: <https://jour.aicti.ir/en/Article/49811>.
- [24] Morin, B., N. Harrand, and F. Fleurey, Model-based software engineering to tame the IoT jungle. *IEEE software*, 2017. **34**(1): p. 30-36.
- [25] Paszke, A., et al., Automatic differentiation in PyTorch, in NIPS 2017 Workshop on Autodiff: The Future of Gradient-Based Machine Learning Software and Techniques. 2017, Long Beach, CA, USA.
- [26] Atzori, L., A. Iera, and G. Morabito, The internet of things: A survey. *Computer networks*, 2010. **54**(15): p. 2787-2805.
- [27] Bennett, K.P. and E. Parrado-Hernández, The interplay of optimization and machine learning research. *The Journal of Machine Learning Research*, 2006. **7**: p. 1265-1281.
- [28] Nižetić, S., et al., Internet of Things (IoT): Opportunities, issues and challenges towards a smart and sustainable future. *Journal of cleaner production*, 2020. **274**: p. 122877.
- [29] Aouedi, O., et al., A survey on intelligent Internet of Things: Applications, security, privacy, and future directions. *IEEE Communications Surveys & Tutorials*, 2025. **27**(2): p. 1238–1292.
- [30] Moghaddasi, K. and M. Masdari, Blockchain-driven optimization of IoT in mobile edge computing environment with deep reinforcement learning and multi-criteria decision-making techniques. *Cluster Computing*, 2024. **27**(4): p. 4385–4413.