

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. Email: hosseinshidelzade77@gmail.com

2. Corresponding author, Associate Professor, Department of Computer Engineering, Arv.C., Islamic Azad University, Abadan, Iran. Email: Ma.nooraei@iau.ac.ir

Received: ..., Revised: ..., Accepted: ...Paper type:

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

چارچوبی هوشمند مبتنی بر یادگیری ماشین و معماری مدل رانده برای بهینه سازی سیستم های IoT صنعتی

حسین شیدل زاده^۱، مریم نورانی آباده^{۲*}

۱. کارشناس ارشد مهندسی کامپیوتر واحد بین المللی اروند، دانشگاه آزاد اسلامی، آبادان، ایران، Hosseinshidelzade77@gmail.com

۲. دانشیار گروه مهندسی کامپیوتر، واحد بین المللی اروند، دانشگاه آزاد اسلامی، آبادان، ایران، رایانامه: Ma.nooraei@iau.ac.ir

تاریخ دریافت: ... تاریخ بازبینی: ... تاریخ پذیرش: ...
نوع مقاله: ...

چکیده

با گسترش روزافزون دستگاه های متصل به اینترنت اشیاء، حجم بالای داده های بدون برچسب و نیاز به پردازش سریع و مدیریت بهینه منابع، چالش های جدیدی در این حوزه ایجاد شده است. در این میان، اهمیت روش های نیمه نظارتی برای پیش بینی و همچنین استخراج ویژگی های کلیدی دامنه برای بهبود دقت، بیش از پیش آشکار شده است. در این پژوهش، رویکردی نوین برای بهبود کارایی سیستم های IoT صنعتی ارائه می شود که در آن یادگیری ماشین با بهره گیری از معماری مدل رانده (MDA) تقویت شده است. در این چارچوب، مدل های مفهومی دامنه محور به عنوان پایه ای برای استخراج ویژگی های کلیدی، ساختاردهی داده ها و کاهش نویز به کار می روند. این یکپارچه سازی باعث بهبود فرآیند یادگیری ماشین به ویژه در شرایط کمبود داده های برچسب دار می گردد. در مرحله اول، مدل های PIM و PSM برای جداسازی منطق سیستم از جزئیات پیاده سازی ایجاد شده و با تغییرات فناوری سازگار می شوند. سپس داده های پردازش شده و ویژگی های استخراج شده به الگوریتم های یادگیری نیمه نظارتی Self-training، Label Propagation و Semi-Supervised SVM وارد می شوند تا از داده های بدون برچسب نیز در فرآیند آموزش استفاده شود. ارزیابی این رویکرد در یک محیط شبیه سازی صنعتی مبتنی بر IoT (مانند سامانه پایش و کنترل انرژی) نشان می دهد که استفاده از MDA به عنوان لایه تقویت کننده ML، دقت پیش بینی را به طور میانگین تا ۹۵٪ افزایش داده، همچنین پایداری مدل در برابر داده های نویزی به طور قابل توجهی بهبود یافته است. نتایج نشان می دهد که ترکیب MDA و یادگیری ماشین نیمه نظارتی می تواند به عنوان یک چارچوب مقیاس پذیر و قابل اعتماد برای ارتقاء کارایی صنایع مبتنی بر IoT به کار گرفته شود.

کلیدواژگان: بهبود کارایی، محیط های اینترنت اشیاء صنعتی، معماری مدل رانده، یادگیری ماشین بهینه سازی

۱- مقدمه

دستگاه ها و تولید حجم عظیمی از داده های پیچیده و نیمه ساخت یافته را فراهم ساخته است. با این حال، این فرصت های نوین با چالش های قابل توجهی همراه هستند که از جمله آنها می توان به مدیریت حجم بالای داده های بدون برچسب، منابع

در دهه های اخیر، اینترنت اشیاء تحولی بنیادین در توسعه سیستم های هوشمند ایجاد کرده که امکان اتصال گسترده

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 سناریوهای عملیاتی متنوع (مانند خطوط تولید با شرایط محیطی متفاوت یا شبکه‌های IIoT 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

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 توانستند 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 هیپارامترها، احتمال ایجاد تعصبات در مدل‌های یادگیری، و وابستگی شدید به داده‌های برچسب‌دار روبرو بوده‌اند [۱]. 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 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 به عنوان برچسب‌های جدید (شبه‌برچسب) به مجموعه آموزش

Semi-Supervised Learning³Domain-Specific Modeling Language^۱
Model-Driven Architecture^۲

و پیشنهادات برای تحقیقات آتی اختصاص یافته است.

۲- پیشینه تحقیق

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

در چارچوب مدل‌رانده می‌پردازد. بخش چهارم روش‌شناسی پژوهش، شامل 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

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 IoT در (MBSE)	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

خودکار کد، رابط کاربری وب‌محور و دسترسی به روشهای DAML 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 برجسب‌گذاری شده اما ۹۲٪ روی مجموعه داده‌های بدون نظارت، و چالش‌های مربوط به سوگیری ارزیابی و تنظیم فراپارامتری است که کاربردپذیری صنعتی را محدود می‌کند. در پژوهش [۱۷] (۲۰۲۲) نوشته فیصل شهزاد و همکاران، به بررسی توانمندسازهای 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

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، ML-Quadrat 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 ماشینی هستند. به تولید

مقاله از ML نیمه نظارتی (S3VM) برای دقت طبقه بندی ۹۵٪ در وظایف صنعتی مانند پیش بینی انرژی و تخمین تأخیر شبکه، حتی با داده های برچسب گذاری شده محدود، در محیط های واقعی شبیه سازی شده (به عنوان مثال، شبکه های حسگر هوشمند) استفاده می کند. با جداسازی PIM از PSM از طریق تبدیل های Enterprise Architect، DSML و QVT، مقیاس پذیری مستقل از پلتفرم را تضمین می کند و هزینه های توسعه مجدد را کاهش می دهد. با این حال، در بحبوحه گسترش دستگاه های اینترنت اشیا و تولید کلان داده نیمه ساختاریافته، تحقیقات مداوم برای غلبه بر شکاف های مقیاس پذیری و بین دامنه ای باقی مانده ضروری است. پژوهش [۱۴] با کتابسنگی حوزه مهندسی سیستم مبتنی بر مدل (MBSE) در IoT، روندها و موضوعات نوظهوری مانند ادغام با روش های تجاری را شناسایی و چالش هایی مانند آموزش ذینفعان، نیاز به ابزارهای مناسب و انطباق با الزامات قانونی را بررسی کرده است. پژوهش [۱۶] نقش IoT را در بهبود محیط های شهری و توسعه چارچوب های فراگیر و اخلاقی برای ارتقای کیفیت زندگی و اکوسیستم های هوشمند بررسی می کند. پژوهش [۱۸] به بررسی ابزارها و زبان های مدل محور خاص دامنه برای IoT با تمرکز بر تحلیل داده DAML و طبقه بندی جامع روش های مدل سازی می پردازد و چالش پوشش ناقص مطالعات را مطرح می کند. پژوهش [۱۹] با ادغام یادگیری ماشین و تحلیل داده در مهندسی نرم افزار، ابزار ThingML را توسعه داده که تولید خودکار کد و بهبود خدمات هوشمند در IoT را ممکن ساخته است. چالش هایی مانند مدیریت پیچیدگی ادغام فناوری ها، امنیت، مقیاس پذیری و تحمل خطا مطرح شده اند. پژوهش [۲۰] رویکردی نوین برای انتخاب خودکار مدل و تنظیم پارامترهای یادگیری ماشین در مهندسی نرم افزار مدل محور IoT ارائه کرده، هرچند چالش هایی در ساخت مدل های کارآمد و انتخاب توسعه ای هنوز پابرجاست. پژوهش [۲۱] با رویکرد مدل محور مبتنی بر شبکه، توسعه نرم افزار IoT را تسهیل و مقیاس پذیری شبکه های بزرگ را افزایش داده است. پژوهش [۲۲] چارچوب یادگیری عمیق بیزی را برای بهبود عملکرد در سیستم های توصیه گر ارائه داده است، اما با چالش های طراحی پیچیده و نیاز محاسباتی بالا روبرو است. از سوی دیگر، پژوهش [۲۳] تمرکز بر استقرار خودکار وظایف یادگیری ماشین روی دستگاه های لبه با منابع محدود و حفظ حریم خصوصی کرده است، هرچند با چالش اعتبارسنجی و داده ناقص مواجه است. پژوهش [۲۴] زبان مدل سازی IoT و ابزار ThingML را معرفی می کند که

توسعه برنامه های سازگار و کارآمد برای پلتفرم های مختلف را تسهیل کرده است. پژوهش [۲۵] با توسعه ماژول تمایز خودکار در PyTorch، امکان آزمایش سریع و انعطاف پذیر مدل های ماشین لرنینگ را ایجاد نموده است. پژوهش [۲۶] به بررسی چالش های فناوری ها و راه حل های ارتباطی در IoT پرداخته و بر اهمیت همکاری میان حوزه های و نوآوری اقتصادی تأکید می نماید. پژوهش [۲۷] تعامل یادگیری ماشین و برنامه نویسی ریاضی را تحلیل کرده و بر توسعه مدل های بهینه سازی تأکید می کند، اما با چالش تفاوت اولویت ها در ML و MP مواجه است. پژوهش [۲۸] به توسعه پایدار IoT، کاهش مصرف منابع و اثرات زیست محیطی توجه کرده و نقش IoT در ارتقای کیفیت زندگی و ایمنی شبکه ها را برجسته ساخته است. در نهایت، پژوهش [۲۹] همگرایی IoT و هوش مصنوعی را بررسی کرده و فضای کاربرد، چالش های امنیتی و مسیرهای تحقیقاتی آینده را در اینترنت اشیا صنعتی (IIoT^۱) تحلیل می کند

پژوهش حاضر با ارائه چارچوبی مبتنی بر معماری مدل رانده ویژه محیط های IoT و تقویت شده با یادگیری ماشین نیمه نظارتی، گامی نوین در بهبود دقت، پایداری و مقیاس پذیری سیستم های هوشمند برداشته است و در مقایسه با [۱] که به توسعه DSML و یکپارچگی یادگیری ماشین با مدل سازی نرم افزار پرداخته، این مطالعه به طور خاص به استخراج ویژگی های دامنه در محیط های IoT با داده های محدود و پرنویز می پردازد.

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 داده های بدون برچسب، مقیاس پذیری و کارایی سیستم ها چالش های مهمی را ایجاد کرده است [۱، ۱۱، ۱۵، ۱۷، ۱۸، ۲۱، ۲۳، ۳۰]. اهمیت مدل سازی مفهومی دامنه در این حوزه موجب شده است، پیچیدگی ساختاری و عملکردی سیستم های IoT به صورت انتزاعی و قابل انتقال به لایه های اجرایی مدل سازی رویکرد مدل محور مبتنی بر معماری مدل رانده و زبان های مدل سازی خاص دامنه^۲، توسعه منعطف، خودکار سازی تولید کد و سازگاری با پلتفرم های متنوع را تسهیل می نماید [۱، ۱۸-۲۰، ۲۳، ۳۱]. ترکیب مدل سازی دامنه با الگوریتم های یادگیری نیمه نظارتی،

^۱ Industrial Internet of Things
^۲ DSML

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 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. به عنوان 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

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 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، برنقش 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].

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 مدل رانده تقویت شده با یادگیری ماشین

۴- روش پیشنهادی

هوشمندسازی نه تنها یک انتخاب مهندسی، بلکه یک الزام راهبردی برای شرکت‌ها و پژوهشگران حوزه سیستم‌های سایبری-فیزیکی و اینترنت اشیاء 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].

در نمودار ۱، لایه‌های معماری مدل رانده 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 برچسب‌گذاری‌شده و داده‌های بدون برچسب استفاده می‌شود. ۲- بخش مدل‌سازی و ارزیابی به




نمودار (۲): فلوچارت فعالیت

یادگیری ماشین (نیمه نظارتی) شامل مراحل است که در نمودار ۱- فلوچارت فعالیت نشان داده شده است. ما در این پژوهش، با

معماری روش پیشنهادی (نمودار ۲) برای بهبود کارایی در محیط‌های IoT با استفاده از معماری مدل رانده تقویت‌شده با

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 می‌تواند 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 خطاهای احتمالی.

رویکرد معماری مدل‌رانه، 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 بر الگو¹ 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



نمودار (۳): کلاس دیاگرام دامنه خاص صنعت ادغام با S3VM

۴-۱- رویکرد به کار رفته در این پژوهش


رویکرد ما در این پژوهش، بر مبنای معماری مدل ارائه است. یکی از مهم ترین کارهایی که انجام دادیم، جداسازی لایه ها بود. ما مدل های انتزاعی را از مدل های وابسته به پلتفرم جدا کردیم. این کار باعث می شود، 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 تکنیک های MDA برای تبدیل خودکار مدل ها از PIM به PSM استفاده نمودیم. این کار باعث شد که زمان و هزینه توسعه خیلی کم شود. بعنوان مثال در راستای پیاده سازی یک خانه هوشمند با رویکرد MDA، برای جداسازی مدل های PIM و PSM، از ابزار Enterprise Architect استفاده نمودیم. این ابزار، امکان مدل سازی UML را فراهم کرده و با پشتیبانی از پروفایل های سفارشی، امکان **تعریف کلیشه ها^۱ و مقدار برچسب^۲ خاص** دامنه خانه هوشمند را فراهم می کند. این امر، امکان تعریف دقیق تر مفاهیم PIM و انطباق آن ها با نیازمندی های PSM را تسهیل می کند. 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 دستگاه ها، پروتکل های ارتباطی) را مشخص می کنند. این الگوها، فرآیند تبدیل را خودکار کرده و امکان تولید کد و پیکربندی متناسب با پلتفرم مورد نظر را فراهم می کنند. فرض کنیم ما یک سری دستورالعمل کلی برای ساخت یک خانه هوشمند در مدل PIM داریم. می خواهیم این دستورالعمل ها را برای یک پلتفرم خاص (مثلاً یک سیستم عامل خاص) در مدل PSM پیاده سازی کنیم. کاری که انجام دادیم، این بود که یک سری الگو تعریف کردیم. هر الگو می گوید: که چطور یک قسمت از دستورالعمل کلی (PIM) را به یک قسمت خاص از پلتفرم (PSM) تبدیل کنیم. مثلاً یک الگو می گوید: 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، می توانیم خیلی سریع و بدون اینکه لازم باشد، کد دستی بنویسیم، دستورالعمل های کلی را به کدهای اجرایی برای پلتفرم مورد نظر تبدیل کنیم. اسم این روش "تبدیل

مبتنی بر الگو" است. ما داده ها را پیش پردازش نموده و آنها را به فرمت مناسب برای تحلیل، تبدیل کردیم. یک الگوریتم مناسب انتخاب نموده و مدل یادگیری ماشین نیمه نظارتی S3vm 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 مدل سازی خاص دامنه انجام دادیم. این زبان به ما کمک کرد که بتوانیم مدل ها را به صورت یکپارچه تعریف و فرآیند تبدیل مدل ها را خودکار کنیم. زبان DSML در دو مرحله اصلی مورد استفاده قرار گرفت. اول مدل سازی 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، مدل سازی PIM را تسهیل کرده و از ایجاد ابهام جلوگیری می کند. 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 می کنند. به عنوان مثال، یک "سنسور دما" در مدل PIM می تواند به یک شیء سنسور با تنظیمات خاص در کد PSM تبدیل شود. پیاده سازی و ارزیابی چارچوب پیشنهادی با استفاده از زبان برنامه نویسی Python انجام شده است. تمامی آزمایش ها و شبیه سازی ها در محیط Google Colab صورت گرفته و مدل های یادگیری ماشین نیمه نظارتی (از جمله S3VM و Self-Training) با بهره گیری از کتابخانه های استاندارد scikit-learn، NumPy و Pandas توسعه و اعتبارسنجی شده اند. این بستر امکان اجرای سریع، تکرارپذیری نتایج و دسترسی به منابع محاسباتی ابری را فراهم ساخته است.

۴-۲- مجموعه داده ها و تنظیمات

در این پژوهش، از مجموعه داده های مختلف از جمله synthetic_dataset [۳۴] با ۱۴ ویژگی و ۱۰,۰۰۰ رکورد از پلتفرم گیت هاب 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 جمع آوری شده و به دلیل تناسب کامل با اهداف پژوهشی (بهینه سازی مصرف انرژی و

عملکرد سیستم‌های IoT صنعتی) و کیفیت مطلوب انتخاب شده است.



نمودار (۴): معرفی معیارها

۳-۴- روش‌های مورد مقایسه

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

۱-۳-۴- 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،

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: 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

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/چندجمله‌ای 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 (تأخیر/ازدست‌دادن بسته)

و بار سیستم و همچنین سنجه‌های کلیدی مانند زمان پاسخ‌گویی،

مصرف انرژی، پهنای باند و رضایت کاربر. تحلیل نتایج: با روش‌های

آماري، 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.

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 شبکه های 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 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 تأخیر

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

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 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




۴-۴- تحلیل نتایج-ارزیابی

تحلیل نتایج حاصل از چارچوب ترکیبی معماری مدل محور و یادگیری ماشین نیمه نظارتی، نشان دهنده ارتقاء قابل توجه در دقت پیش بینی مدل ها و پایداری عملکرد آنها، به ویژه در شرایط مواجهه با داده های نویزی و کمبود داده های برچسب دار است. این قابلیت، نسبت به روش های پیشرفته نظیر یادگیری عمیق مبتنی بر شبکه های عصبی و الگوریتم های نظارت شده کامل، که معمولاً به حجم زیادی داده برچسب خورده و منابع محاسباتی وسیع نیاز دارند، برتری محسوسی را به همراه داشته است. شاخصه اصلی و متمایز رویکرد پیشنهادی، امکان تطبیق و مقیاس پذیری مدل با داده های صنعتی ناهمگون، غیرساختاریافته و پراکنده است. این ادعا بر پایه دو ویژگی اصلی چارچوب استوار است: (۱) استفاده از یادگیری نیمه نظارتی که با بهره گیری همزمان از داده های برچسب دار محدود و داده های بدون برچسب فراوان، توانایی کار با داده های ناقص، نویزی و پراکنده را فراهم می کند. (۲) معماری مدل رانده با جداسازی PIM از PSM، که مقیاس پذیری و تطبیق پذیری مستقل از پلتفرم را در محیط های صنعتی ناهمگون تضمین می نماید. نتایج تجربی نیز با دقت طبقه بندی ۹۵٪ بر روی داده های ناقص و نویزی این قابلیت را تأیید کرده است. شرایطی که در کاربردهای واقعی صنایع تولیدی، از جمله سامانه های مبتنی بر اینترنت اشیاء و صنایع سنگین مانند فولاد و پتروشیمی، به عنوان چالش جدی مطرح می باشد. مدل نیمه نظارتی توسعه یافته، با بهره گیری از معماری مبتنی بر کلاس های صنعتی و تعامل با انواع دستگاه ها، سنسورها و داده های تولیدی، از انعطاف پذیری بالایی در به روزرسانی پارامترهای فرآیندی و استفاده اثربخش از داده های نیمه برچسب خورده، برخوردار بوده و امکان کاربرد موفق در محیط های صنعتی دینامیک و پیچیده را فراهم آورده است. این توانمندی مدل، علاوه بر حفظ دقت بالا در تشخیص و پیش بینی، بهینه سازی مصرف منابع محاسباتی، کاهش زمان پاسخگویی سامانه، ارتقاء سطح اعتماد پذیری و پایداری سیستم را نیز موجب گردیده است. بنابراین ابزارهای پیشنهادی این پژوهش، زمینه تسهیل پذیرش و استقرار فناوری های هوشمندسازی و دیجیتال سازی را در صنایع نسل چهارم فراهم نموده و ارزش افزوده عملیاتی قابل توجهی را به ارمغان می آورد.


۵- نتیجه گیری و پیشنهاد برای تحقیقات آتی

تحلیل آماری نتایج نشان داد که مدل نیمه نظارتی پیشنهادی در هر دو مسئله طبقه بندی مصرف انرژی و تخمین تأخیر شبکه، دقت


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 پاسخگویی



نمودار (۹): نمودار TPR به FPR



نمودار (۱۰): نمودار Precision به recall

۷. Akhbarifar, S., et al., *RETRACTED ARTICLE: A secure remote health monitoring model for early disease diagnosis in cloud-based IoT environment*. Personal and Ubiquitous Computing, 2023. **27**(3): p. 697-713.
۸. 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. **۳۵**(۵): p. 101544.
۹. Wang, Y., et al., *Machine learning-enhanced flexible mechanical sensing*. Nano-Micro Letters, 2023. **15**(1): p. 55.
۱۰. Liu, J., et al., *Internet of things challenges and future scope for enhanced living environments*, in *Advances in Computers*. 2024, Elsevier. p. 201-246.
۱۱. Park, Y.-S., B.U. Park, and H.-J. Jeon, *Advances in machine learning-enhanced nanozymes*. Frontiers in Chemistry, 2024. **12**: p. 1483986.
۱۲. 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, 2022. **10**(11): p. 1017-1022.
۱۳. 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.
۱۴. Ahmad, E., *Model-based system engineering of the Internet of Things: A bibliometric literature analysis*. IEEE Access, 2023. **11**: p. 50642-50658.
۱۵. 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.
۱۶. Marques, G., *Internet of Things: Architectures for Enhanced Living Environments*. 2024: Elsevier.
۱۷. Javed, A.R., et al., *Future smart cities: Requirements, emerging technologies, applications, challenges, and future aspects*. Cities, 2022. **129**: p. 103794.
۱۸. 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.
۱۹. 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.
۲۰. Moin, A., et al., *Enabling automated machine learning for model-driven AI engineering*. arXiv preprint arXiv:2203.02927, 2022.
۲۱. 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.

نهایی حدود ۹۵٪ را به دست آورد. مقادیر Precision و Recall هر سه کلاس به طور متوازن در محدوده ۰/۹۳ تا ۰/۹۶ قرار گرفت و ماتریس سردرگمی به همراه منحنی های ROC و Precision-Recall. پایداری عملکرد مدل را در شرایط کمبود داده برچسب دار تأیید کرد. با وجود این نتایج مطلوب، پژوهش حاضر با محدودیت ها و چالش هایی مواجه است که مهم ترین آن ها عبارتند از: وابستگی به داده واقعی تنها از یک محیط صنعتی (کارخانه فولاد)، حساسیت نسبی مدل به تنظیم فرایارامترها، پیچیدگی محاسباتی در مقیاس های بسیار بزرگ، و فقدان ارزیابی کامل در شرایط بلادرنگ و مکانیزم های خودترمیمی. این محدودیت ها تعمیم پذیری نتایج به صنایع متنوع و سناریوهای عملیاتی پویا را محدود می سازد.

با توجه به نتایج مثبت چارچوب پیشنهادی، مسیرهای متعددی برای توسعه پژوهش های آتی وجود دارد. از جمله می توان به توسعه مدل های یادگیری انتقالی برای افزایش دقت در داده های چندداده ای، استفاده از یادگیری فدریتد به منظور حفظ حریم خصوصی و افزایش مقیاس پذیری، پیاده سازی الگوریتم های Explainable AI برای ارتقای شفافیت مدل ها، ارزیابی چارچوب در سناریوهای بلادرنگ و طراحی مکانیزم های خودپایدار مبتنی بر مدل اشاره کرد.

منابع

۱. 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. 98.۱۰۱۴-۷
۲. 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.
۳. M Casares, P.A., et al., *GradDFT. A software library for machine learning enhanced density functional theory*. The Journal of Chemical Physics, 2024. **160**(۶)
۴. Bishop, C.M., *Model-based machine learning*. Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences, ۲۰۱۲. **۳۷۱**(۱۹۸۴): p. 20120222.
۵. 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.
۶. 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.

۲۲. <https://archive.ics.uci.edu/dataset/851/steel+industry+energy+consumption>
۲۳. Wang, H. and D.-Y. Yeung, *A survey on Bayesian deep learning*. ACM computing surveys (csur), 2020. **53**(5): p. 1-37.
۲۴. 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.
۲۵. Morin, B., N. Harrand, and F. Fleurey, *Model-based software engineering to tame the IoT jungle*. IEEE software, 2017. **34**(1): p. 30-36.
۲۶. Paszke, A., et al., *Automatic differentiation in pytorch*. 2017.
۲۷. Atzori, L., A. Iera, and G. Morabito, *The internet of things: A survey*. Computer networks, 2010. **54**(15): p. 2787-2805.
۲۸. 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.
۲۹. 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.
۳۰. Aouedi, O., et al., *A survey on intelligent Internet of Things: Applications, security, privacy, and future directions*. IEEE Communications Surveys & Tutorials, 2024.
۳۱. 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.
۳۲. Moin, A., S. Rössler, and S. Günnemann, *ThingML+ augmenting model-driven software engineering for the Internet of Things with machine learning*. arXiv preprint arXiv:2009.10633, 2020.
۳۳. 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.
۳۴. Verbruggen, C. and M. Snoeck, *Practitioners' experiences with model-driven engineering: a meta-review*. Software and Systems Modeling, 2023. **22**(1): p. 111-129.
۳۵. GitHub - komeilmoghaddasi/IoT_Task_Offloading_Datase: This synthetic dataset represents a scenario of 10,000 interactions between different types of IoT devices and edge servers. if you want to use this dataset please cite article: <https://doi.org/10.1007/s10586-023-04195-4>

[۳۵] Steel Industry Energy Consumption Dataset. UCI Machine Learning Repository. Available: