

Predictive maintenance in multi-objective supply chains by combining machine learning and evolutionary optimization

Koorosh Pouri¹ 

1 .Department of Industrial Engineering, Science and Research Branch, Islamic Azad University, Tehran, Iran,
Kooroshpouri@gmail.com

Article Info	ABSTRACT
Article type: Research Article Article history: Received 17 March 2024 Received in revised form 30 April 2025 Accepted 21 October 2025 Published online 1 December 2025 Keywords: Evolutionary Optimization, Machine Learning, NSGA-II, Predictive Maintenance, PSO.	Predictive maintenance, as a new approach to industrial equipment management, uses machine learning to predict failure probability and evolutionary optimization algorithms to determine optimal maintenance strategies. In this study, a hybrid model is presented that first estimates the failure probability of equipment using XGBoost and LSTM algorithms and then uses NSGA-II and PSO to optimize maintenance decisions. The results show that the NSGA-II algorithm performs better than PSO in reducing maintenance costs by 42.8% and reducing equipment downtime by 55.4%. The innovation of this research lies in integrating machine learning and evolutionary optimization into an intelligent and efficient framework that can reduce operating costs, increase equipment reliability, and optimize maintenance strategies. The proposed model, tested on an industrial dataset, reduced maintenance costs by 42.8% and equipment downtime by 55.4% on average. This framework is applicable to manufacturing, petrochemical, and process industries aiming to enhance reliability, reduce unplanned downtime, and optimize maintenance planning. The findings of this research can be used in various industries to improve productivity and reduce unexpected failures.
Cite this article: Pouri, K, (2025), Predictive maintenance in multi-objective supply chains by combining machine learning and evolutionary optimization. <i>Engineering Management and Soft Computing</i>, 11 (2). 178-193. DOI: https://doi.org/10.22091/jemsc.2025.12514.1264	
 © Pouri (2025) DOI: https://doi.org/10.22091/jemsc.2025.12514.1264 Publisher: University of Qom	

1) INTRODUCTION

With the advancement of machine learning and evolutionary optimization technologies, it has become possible to optimize maintenance decisions with greater accuracy. Machine learning can identify hidden patterns by analyzing equipment operational data and predict the likely time of failure. On the other hand, evolutionary optimization algorithms can convert these predictions into optimal strategies for performing maintenance, so that costs are reduced and equipment availability is increased [1,2]. With the expansion of data-driven infrastructures in industries, the inability of traditional approaches to identify failures in a timely manner has led to an increase in unwanted downtime and unforeseen costs. In such circumstances, there is a need for models that are not only capable of accurately predicting failures, but also enable decision-making in multi-objective and complex situations. This gap doubles the need to develop intelligent frameworks based on a combination of machine learning and evolutionary optimization [3,4]. The main innovation of this research is the effective integration of machine learning and evolutionary optimization for predictive maintenance. Unlike previous studies that have used machine learning or optimization models separately, this research provides an integrated framework that takes advantage of the high accuracy of machine learning in failure prediction and the ability of evolutionary algorithms to provide multi-objective optimal solutions. In addition, this research compares the performance of two algorithms, NSGA-II and PSO, and shows that NSGA-II performs better in many cases. The findings of this research can be used as a practical and intelligent approach to reduce maintenance costs, extend equipment life, and optimize supply chain efficiency.

2) Solution Method

In this paper, a hybrid model for predictive maintenance in multi-objective supply chains is presented that uses machine learning to predict equipment failures and evolutionary optimization to determine the optimal maintenance strategy. This model uses industrial sensor data and historical failure data to optimize maintenance decisions to reduce costs and increase system reliability. The data collection process is carried out through sensors attached to industrial equipment that continuously record parameters such as temperature, pressure, vibration, speed, electrical current, and corrosion rate. This data is usually sent to a central database via the Internet of Things (IoT) and stored in maintenance management systems. In addition, historical failure data is extracted from repair and maintenance records, including information on the type of failure, time of occurrence, repair duration, repair costs, and replaced parts.

3) conclusion

Machine learning models played a key role in reducing uncertainty in equipment failure prediction in this study. The use of models such as XGBoost and LSTM improved the accuracy of failure prediction and in some cases, the probability of equipment failure was reduced by up to 40%. This allowed preventive maintenance decisions to be implemented more targetedly and efficiently, so that only equipment that was at the highest risk of failure was subject to preventive maintenance. After predicting the probability of failure, these values were fed to the NSGA-II and PSO optimization models. The results of solving sample problems showed that NSGA-II performed better than PSO. The objective function value obtained from NSGA-II was better than PSO in most cases and its solution time was also shorter. The maintenance cost reduction in NSGA-II was reported to be 42.8% on average and the equipment downtime reduction was 55.4%, while in the PSO algorithm this was 25.2% and 33.8%. These results showed that combining machine learning with evolutionary optimization is a smart and practical approach to predictive maintenance management in the supply chain. This model can not only reduce operating costs, but also increase equipment life, reduce unexpected failures, and improve overall system efficiency. From a management perspective, the findings of this research show that combining machine learning and evolutionary optimization can be used as a decision-making tool for maintenance managers. This model allows managers to make maintenance decisions not based on fixed schedules

but on real data and the probability of failure. By implementing this framework, organizations can increase equipment life while avoiding unnecessary costs and sudden stops.

4) ACKNOWLEDGEMENTS

The authors would like to make special thanks to the anonymous reviewers for their careful reading of our manuscript and their relevant and useful comments that helped us improve the paper.

REFERENCES

- [1] Delshad, M. M., Chobar, A. P., Ghasemi, P., & Jafari, D. (2024). Efficient Humanitarian Logistics: Multi-Commodity Location–Inventory Model Incorporating Demand Probability and Consumption Coefficients. *Logistics*, 8(1), 9. <https://doi.org/10.3390/logistics8010009>
- [2] Chobar, A. P., Adibi, M. A., & Kazemi, A. (2022). Multi-objective hub-spoke network design of perishable tourism products using combination machine learning and meta-heuristic algorithms. *Environment, Development and Sustainability*, 1-28. <https://doi.org/10.1007/s10668-022-02350-2>
- [3] Jiang, Y., Dai, P., Fang, P., Zhong, R. Y., Zhao, X., & Cao, X. (2022). A2-LSTM for predictive maintenance of industrial equipment based on machine learning. *Computers & Industrial Engineering*, 172, 108560. <https://doi.org/10.1016/j.cie.2022.108560>
- [4] Yadav, D. K., Kaushik, A., & Yadav, N. (2024). Predicting machine failures using machine learning and deep learning algorithms. *Sustainable Manufacturing and Service Economics*, 3, 100029. <https://doi.org/10.1016/j.smse.2024.100029>

نگهداشت پیش‌بینی کننده در زنجیره تامین چندهدفه با ترکیب یادگیری ماشین و بهینه‌سازی تکاملی

کوروش پوری^۱ 

۱. نویسنده مسئول، دانش‌آموخته دکتری، گروه مهندسی صنایع، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران. رایانامه: Kooroshpouri@gmail.com

اطلاعات مقاله	چکیده
نوع مقاله: مقاله پژوهشی تاریخ دریافت: ۱۴۰۴/۰۲/۱۲ تاریخ بازنگری: ۱۴۰۴/۰۴/۱۹ تاریخ پذیرش: ۱۴۰۴/۰۶/۰۲ تاریخ انتشار: ۱۴۰۴/۰۹/۱۰	نگهداشت پیش‌بینی کننده به عنوان یک رویکرد نوین در مدیریت تجهیزات صنعتی، از یادگیری ماشین برای پیش‌بینی احتمال خرابی و از الگوریتم‌های بهینه‌سازی تکاملی برای تعیین استراتژی‌های بهینه نگهداشت استفاده می‌کند. در این پژوهش، یک مدل ترکیبی ارائه شده است که ابتدا با استفاده از الگوریتم‌های XGBoost و LSTM احتمال خرابی تجهیزات را تخمین زده و سپس از NSGA-II و PSO برای بهینه‌سازی تصمیمات نگهداشت استفاده می‌شود. نتایج نشان می‌دهد که الگوریتم NSGA-II در کاهش هزینه‌های نگهداشت تا ۴۲۸ درصد و در کاهش زمان توقف تجهیزات تا ۵۵٫۴ درصد، عملکرد بهتری نسبت به PSO دارد. نوآوری این پژوهش در ادغام یادگیری ماشین و بهینه‌سازی تکاملی، در یک چارچوب هوشمند و کارآمد است که باعث کاهش هزینه‌های عملیاتی، افزایش قابلیت اطمینان تجهیزات و بهینه‌سازی استراتژی‌های نگهداشت می‌شود. این مدل در یک مطالعه موردی صنعتی موفق شد هزینه‌های نگهداشت را بطور میانگین ۴۲۸ درصد و زمان توقف تجهیزات را ۵۵٫۴ درصد کاهش دهد. کاربرد این رویکرد می‌تواند در صنایع فرآیندی، پتروشیمی و تولیدی برای کاهش توقفات، بهبود قابلیت اطمینان و تصمیم‌سازی نگهداشت پیش‌بینی کننده مورد استفاده قرار گیرد. یافته‌های این تحقیق می‌تواند در صنایع مختلف برای بهبود بهره‌وری و کاهش خرابی‌های غیرمنتظره مورد استفاده قرار گیرد.

کلیدواژه‌ها:

نگهداشت پیش‌بینی کننده، یادگیری ماشین، بهینه‌سازی تکاملی، NSGA-II، PSO، II

استناد: پوری، کوروش. (۱۴۰۴). «نگهداشت پیش‌بینی کننده در زنجیره تامین چندهدفه با ترکیب یادگیری ماشین و بهینه‌سازی تکاملی». مدیریت مهندسی

و رایانش نرم، دوره ۱۱ (۲)، صص: ۱۹۳-۱۷۸. <https://doi.org/10.22091/jemsc.2025.12514.1264>



© پوری (۱۴۰۴).

ناشر: دانشگاه قم

(۱) مقدمه

نگهداشت تجهیزات صنعتی، یکی از مهمترین چالش‌های زنجیره تامین است که تاثیر مستقیم بر هزینه‌های عملیاتی، بهره‌وری تولید و قابلیت اطمینان سیستم دارد. روش‌های سنتی نگهداشت شامل نگهداشت واکنشی که پس از وقوع خرابی انجام می‌شود و نگهداشت پیشگیرانه که براساس برنامه‌های ازپیش تعیین شده اجرا می‌شود، دارای محدودیت‌های متعددی هستند. این روش‌ها نه تنها نمی‌توانند خرابی‌های غیرمنتظره را پیش‌بینی کنند بلکه در بسیاری از موارد منجر به تعمیرات غیرضروری و هزینه‌های اضافی می‌شوند. از این‌رو، نگهداشت پیش‌بینی‌کننده^۱ به‌عنوان یک راهکار هوشمند معرفی شده‌است که با استفاده از داده‌های حسگرهای صنعتی و روش‌های تحلیل پیشرفته، وقوع خرابی‌ها را قبل از رخداد پیش‌بینی می‌کند و از هزینه‌های غیرضروری جلوگیری می‌نماید (دلشاد و همکاران، ۲۰۲۲).

با پیشرفت فناوری‌های یادگیری ماشین و بهینه‌سازی تکاملی، امکان بهینه‌سازی تصمیمات نگهداشت با دقت بیشتری فراهم شده‌است. یادگیری ماشین می‌تواند با تحلیل داده‌های عملیاتی تجهیزات، الگوهای پنهان را شناسایی کرده و زمان احتمالی وقوع خرابی را پیش‌بینی کند. از سوی دیگر، الگوریتم‌های بهینه‌سازی تکاملی می‌توانند این پیش‌بینی‌ها را جهت اجرای نگهداشت، به استراتژی‌های بهینه تبدیل کنند، به گونه‌ای که باعث کاهش هزینه‌ها و افزایش دسترس‌پذیری تجهیزات گردند. با گسترش زیرساخت‌های داده‌محور در صنایع، ناتوانی رویکردهای سنتی در شناسایی به موقع خرابی‌ها، منجر به افزایش توقفات ناخواسته و هزینه‌های پیش‌بینی نشده گردیده‌است. در چنین شرایطی، نیاز به مدل‌هایی احساس می‌شود که نه تنها قابلیت پیش‌بینی دقیق خرابی‌ها را داشته باشند بلکه تصمیم‌گیری در شرایط چندهدفه و پیچیده را نیز امکان‌پذیر سازند. این خلا، ضرورت توسعه چارچوب‌های هوشمند مبتنی بر ترکیب یادگیری ماشین و بهینه‌سازی تکاملی را دوچندان می‌کند (نیاوند و همکاران، ۲۰۲۴؛ چوبر و همکاران، ۲۰۲۲).

در این مدل، ابتدا داده‌های حسگرهای صنعتی شامل دما، ارتعاش، جریان الکتریکی و سایر شاخص‌های عملکردی تجهیزات، جمع‌آوری و پردازش می‌شوند سپس مدل‌های یادگیری ماشین مانند XGBoost و LSTM، برای تحلیل این داده‌ها و پیش‌بینی احتمال خرابی تجهیزات در بازه‌های زمانی آینده بکار گرفته می‌شوند. این مقادیر پیش‌بینی شده در مرحله بعدی وارد مدل بهینه‌سازی شده و با استفاده از الگوریتم‌های NSGA-II و PSO، استراتژی‌های نگهداشت بهینه برای کاهش هزینه‌ها و افزایش بهره‌وری سیستم استخراج می‌شوند. نتایج حاصل از حل مسائل نمونه نشان می‌دهد که این مدل توانسته‌است، هزینه‌های نگهداشت را به میزان قابل توجهی کاهش دهد و زمان توقف تجهیزات را بهینه کند.

نوآوری اصلی این پژوهش در ادغام موثر یادگیری ماشین و بهینه‌سازی تکاملی برای نگهداشت پیش‌بینی‌کننده است. برخلاف مطالعات پیشین که بطور مجزا از مدل‌های یادگیری ماشین یا بهینه‌سازی استفاده کرده‌اند، این پژوهش یک چارچوب یکپارچه ارائه می‌دهد که از دقت بالای یادگیری ماشین در پیش‌بینی خرابی و از توانایی الگوریتم‌های تکاملی در ارائه راه‌حل‌های بهینه چندهدفه بهره می‌برد. علاوه بر این، در این پژوهش عملکرد دو الگوریتم NSGA-II و PSO مقایسه شده و نشان داده شده‌است که NSGA-II در بسیاری از موارد عملکرد بهتری دارد. یافته‌های این تحقیق می‌توانند

به‌عنوان یک رویکرد عملی و هوشمند برای کاهش هزینه‌های نگهداشت، افزایش طول عمر تجهیزات و بهینه‌سازی بهره‌وری زنجیره تامین مورد استفاده قرار گیرند.

در ادامه این مقاله، ابتدا پیشینه پژوهش‌های مرتبط بررسی می‌شود سپس چارچوب پیشنهادی شامل جمع‌آوری داده‌ها، مدل‌سازی یادگیری ماشین و بهینه‌سازی چندهدفه معرفی می‌گردد. در ادامه، پیاده‌سازی مدل بر روی یک مطالعه موردی صنعتی انجام شده و نتایج حاصل از دو الگوریتم NSGA-II و PSO مقایسه می‌شود. در پایان، تحلیل نتایج و ارائه پیشنهادات مدیریتی و پژوهشی ارائه خواهد شد.

۲) مرور ادبیات

نگهداشت پیش‌بینی‌کننده به‌عنوان یکی از رویکردهای نوین در مدیریت نگهداشت، در سال‌های اخیر توجه زیادی را به خود جلب کرده است. این روش برخلاف نگهداشت واکنشی که پس از وقوع خرابی انجام می‌شود و نگهداشت پیشگیرانه که براساس زمان‌بندی‌های ثابت اجرا می‌شود، از الگوریتم‌های یادگیری ماشین و تحلیل داده‌ها برای پیش‌بینی زمان احتمالی خرابی تجهیزات استفاده می‌کند (یاداو و همکاران، ۲۰۲۴). این مدل‌ها می‌توانند با بررسی داده‌های حسگرهای صنعتی، شرایط عملکردی تجهیزات را پایش کرده و در زمان مناسب هشدارهایی برای انجام اقدامات نگهداشت صادر کنند (سازگاری و همکاران، ۲۰۲۴؛ فتحی و همکاران، ۲۰۲۳).

یکی از جنبه‌های کلیدی نگهداشت پیش‌بینی‌کننده، استفاده از الگوریتم‌های یادگیری ماشین برای پیش‌بینی خرابی تجهیزات است. مطالعات متعددی نشان داده‌اند که روش‌هایی مانند شبکه‌های عصبی مصنوعی (ANN)، مدل‌های درخت تصمیم و الگوریتم‌های مبتنی بر جنگل تصادفی، قابلیت بالایی در شناسایی الگوهای خرابی دارند (شارما و همکاران، ۲۰۲۲). در این میان، مدل‌های یادگیری عمیق نظیر شبکه‌های حافظه طولانی کوتاه‌مدت (LSTM)، در تشخیص روندهای زمانی خرابی تجهیزات، عملکرد بهتری از خود نشان داده‌اند (ژیانگ و همکاران، ۲۰۲۲). این مدل‌ها قادرند داده‌های حسگرها را پردازش کرده و احتمال وقوع خرابی را در بازه‌های زمانی آینده پیش‌بینی کنند.

با این حال، صرف استفاده از یادگیری ماشین برای پیش‌بینی خرابی کافی نیست زیرا نیاز به یک مکانیزم تصمیم‌گیری بهینه برای اجرای اقدامات نگهداشت وجود دارد. در این راستا، الگوریتم‌های بهینه‌سازی تکاملی به‌عنوان یک ابزار کارآمد برای استخراج بهترین استراتژی‌های نگهداشت معرفی شده‌اند (بلهور و همکاران، ۲۰۲۳). الگوریتم NSGA-II (الگوریتم ژنتیک چندهدفه غیرمغلوب) یکی از پرکاربردترین روش‌های بهینه‌سازی چندهدفه است که می‌تواند تصمیمات نگهداشت را براساس کمینه‌سازی هزینه‌ها و بیشینه‌سازی دسترس‌پذیری تجهیزات تنظیم کند (دب و همکاران، ۲۰۰۲). از سوی دیگر، الگوریتم بهینه‌سازی ازدحام ذرات (PSO) نیز به‌عنوان یک روش جایگزین برای حل مسائل بهینه‌سازی نگهداشت مورد بررسی قرار گرفته است. مقایسه این دو الگوریتم نشان داده است که NSGA-II در یافتن مجموعه‌ای از راه‌حل‌های بهینه پارتو عملکرد بهتری دارد در حالیکه PSO در برخی موارد به یک راه‌حل خاص، همگرا می‌شود که ممکن است کارآیی پایین‌تری داشته باشد (نگوین و همکاران، ۲۰۲۱).

مطالعات اخیر به بررسی ترکیب یادگیری ماشین و بهینه‌سازی تکاملی پرداخته‌اند. به عنوان نمونه، تحقیق ژیانگ و همکاران (۲۰۲۲) ترکیب CNN-LSTM و الگوریتم‌های ژنتیک را در صنایع انرژی بررسی کرده و کاهش ۳۵ درصدی هزینه‌های نگهداشت را گزارش کرده‌است.

بررسی پیشینه نشان می‌دهد که اغلب مطالعات گذشته یا فقط بر پیش‌بینی خرابی تمرکز داشته‌اند یا به بهینه‌سازی نگهداشت با داده‌های فرضی پرداخته‌اند. در ادبیات موجود، چارچوبی که به صورت یکپارچه از قدرت پیش‌بینی مدل‌های ML و توانایی تصمیم‌سازی الگوریتم‌های تکاملی برای نگهداشت چندهدفه بهره‌بردار، کمتر دیده می‌شود. این خلا، جایگاه و نوآوری مدل حاضر را برجسته می‌سازد.

در این پژوهش، براساس مطالعات پیشین، یک مدل ترکیبی جدید ارائه شده‌است که از مدل‌های یادگیری ماشین مانند XGBoost و LSTM برای پیش‌بینی خرابی تجهیزات و از الگوریتم‌های NSGA-II و PSO برای بهینه‌سازی تصمیمات نگهداشت استفاده می‌کند. مقایسه عملکرد این دو الگوریتم در کاهش هزینه‌های نگهداشت و افزایش بهره‌وری، یکی از جنبه‌های نوآورانه این پژوهش است که در مطالعات پیشین کمتر مورد توجه قرار گرفته‌است. نتایج به دست آمده از این تحقیق می‌تواند در صنایع مختلف از جمله تولید، حمل‌ونقل و زنجیره تامین برای بهبود قابلیت اطمینان تجهیزات، کاهش هزینه‌های عملیاتی و بهینه‌سازی برنامه‌ریزی نگهداشت مورد استفاده قرار گیرد.

(۳) روش‌شناسی و مدل‌سازی ریاضی

در این مقاله، یک مدل ترکیبی برای نگهداشت پیش‌بینی‌کننده در زنجیره تامین چندهدفه ارائه می‌شود که از یادگیری ماشین برای پیش‌بینی خرابی تجهیزات و از بهینه‌سازی تکاملی برای تعیین استراتژی نگهداشت بهینه استفاده می‌کند. این مدل با استفاده از داده‌های حسگرهای صنعتی و داده‌های تاریخی خرابی، تصمیمات نگهداشت را بهینه‌سازی می‌کند تا باعث کاهش هزینه‌ها و افزایش قابلیت اطمینان سیستم شود. فرآیند جمع‌آوری داده‌ها از طریق حسگرهای متصل به تجهیزات صنعتی انجام می‌شود که بطور مستمر پارامترهایی مانند دما، فشار، لرزش، سرعت، جریان الکتریکی و میزان خوردگی را ثبت می‌کنند. این داده‌ها معمولاً از طریق اینترنت اشیا (IoT) به یک پایگاه داده مرکزی ارسال شده و در سیستم‌های مدیریت نگهداشت ذخیره می‌شوند. علاوه بر این، داده‌های تاریخی خرابی از سوابق تعمیرات و نگهداشت شامل اطلاعات مربوط به نوع خرابی، زمان وقوع، مدت زمان تعمیر، هزینه‌های تعمیر و قطعات تعویض شده استخراج می‌گردد. برای پردازش داده‌ها، ابتدا داده‌های حسگرها و سوابق خرابی مورد پاک‌سازی و پردازش قرار می‌گیرند. این فرآیند شامل حذف نویز، جایگزینی داده‌های گمشده با روش‌هایی مانند میانگین‌گیری یا رگرسیون، حذف داده‌های پرت و نرمال‌سازی مقادیر ورودی برای همگن‌سازی داده‌ها است. همچنین کاهش ابعاد داده‌ها با استفاده از روش‌هایی مانند تحلیل مولفه‌های اصلی (PCA) یا الگوریتم‌های انتخاب ویژگی انجام می‌شود تا ویژگی‌های موثرتر برای یادگیری ماشین استخراج شوند. بهینه‌سازی چندهدفه هزینه‌های نگهداشت، کاهش خرابی‌های غیرمنتظره و افزایش بهره‌وری زنجیره تامین را در نظر گرفته و استراتژی بهینه‌ای برای نگهداشت ارائه می‌دهد.

مدل‌سازی یادگیری ماشین در این پژوهش نقش اساسی در پیش‌بینی احتمال خرابی تجهیزات ایفا می‌کند و به‌عنوان یکی از اجزای کلیدی سیستم نگهداشت پیش‌بینی‌کننده عمل می‌نماید. این مدل‌ها با استفاده از داده‌های حسگرهای صنعتی و سوابق خرابی، الگوهای پنهان در رفتار تجهیزات را شناسایی کرده و وقوع خرابی را قبل از رخداد آن پیش‌بینی می‌کند. ابتدا داده‌های از پیش پردازش شده به‌منظور استخراج ویژگی‌های موثر، مورد تحلیل قرار می‌گیرند و سپس مدل‌های یادگیری ماشین مانند شبکه‌های عصبی عمیق، XGBoost، جنگل تصادفی و مدل‌های مبتنی بر سری‌های زمانی مانند LSTM بکار گرفته می‌شوند. این مدل‌ها براساس معیارهایی مانند دقت پیش‌بینی، میانگین مربع خطا (MSE)، میانگین قدرمطلق خطا (MAE) و ماتریس درهم‌ریختگی ارزیابی شده و بهترین مدل برای پیش‌بینی خرابی انتخاب می‌شود.

در مرحله آموزش، داده‌های گذشته به‌عنوان ورودی به مدل ارائه شده و شبکه‌های یادگیری عمیق با تنظیم وزن‌های خود، روابط پیچیده میان متغیرهای عملیاتی و زمان وقوع خرابی را می‌آموزند. در صورتیکه توالی زمانی داده‌ها اهمیت زیادی داشته باشد، از مدل‌های مبتنی بر حافظه مانند LSTM برای تحلیل وابستگی‌های بلندمدت میان داده‌های حسگرها استفاده می‌شود. پس از آموزش، مدل‌های توسعه‌یافته بر روی مجموعه داده‌های آزمایشی مورد بررسی قرار گرفته و با استفاده از معیارهای عملکردی مقایسه می‌شوند. در نهایت مدل یادگیری ماشین به‌عنوان یک سیستم تصمیم‌یار در فرآیند بهینه‌سازی بکار گرفته شده و خروجی آن یعنی احتمال و زمان احتمالی خرابی تجهیزات، به الگوریتم‌های بهینه‌سازی تکاملی ارائه می‌شود تا استراتژی‌های نگهداشت بهینه‌سازی شوند. این ترکیب هوشمندانه باعث می‌شود که سیستم بتواند با دقت بالا، خرابی‌های احتمالی را پیش‌بینی کرده و از تعمیرات اضطراری و هزینه‌های ناگهانی جلوگیری نماید.

مفروضات کلیدی مدل عبارتند از:

- داده‌های حسگرهای تجهیزات به‌صورت پیوسته و بدون وقفه در دسترس هستند.
- احتمال خرابی تجهیزات بطور مستقل و براساس ویژگی‌های عملکردی هر تجهیز محاسبه می‌شود.
- توابع هدف شامل هزینه، دسترس‌پذیری و پایداری دارای رفتار غیرخطی هستند.
- زمان توقف ناشی از خرابی و نگهداشت، قابل اندازه‌گیری و قابل کنترل است.
- آستانه‌ای برای احتمال خرابی به‌عنوان قید تصمیم‌گیری در نظر گرفته شده است.

۳-۱) مدل‌سازی ریاضی

مجموعه‌ها

I مجموعه تمامی تجهیزات.

T مجموعه دوره‌های زمانی.

پارامترها

C_m هزینه نگهداشت پیشگیرانه برای هر تجهیز.

C_f هزینه خرابی در صورت وقوع شکست در تجهیز.

C_d هزینه ناشی از توقف تولید به ازای هر واحد زمان.

کل بازه زمانی مورد بررسی.	T
میزان انرژی صرفه جویی شده به دلیل اجرای نگهداشت پیش‌بینی کننده برای تجهیز i	$E_{saved,i}$
میزان ضایعات تولید شده به دلیل خرابی و تعویض قطعات تجهیز i .	$W_{generated,i}$
وزن‌های اهمیت هریک از توابع هدف شامل هزینه، دسترس پذیری و پایداری.	w_1, w_2, w_3
متغیرهای تصمیم	
متغیر باینری که اگر برای تجهیز i نگهداشت پیشگیرانه انجام شود، مقدار ۱ و در غیر این صورت مقدار ۰ می‌گیرد.	M_i
متغیر باینری که اگر تجهیز i دچار خرابی شود، مقدار ۱ و در غیر این صورت مقدار ۰ می‌گیرد.	F_i
مدت زمان توقف تجهیز i به دلیل خرابی.	D_i
میزان دسترس پذیری سیستم.	A

$$\text{Min } Z_1 = C_m \sum_{i \in I} M_i + C_f \sum_{i \in I} F_i + C_d \sum_{i \in I} D_i \quad (1)$$

$$\text{Max } Z_2 = \frac{\sum_{i \in I} (T - D_i)}{|I|T} \quad (2)$$

$$\text{Max } Z_3 = \frac{\sum_{i \in I} (E_{saved,i} - W_{generated,i})}{|I|} \quad (3)$$

S.t

$$F_i = 1 - M_i \quad \forall i \in I \quad (4)$$

$$D_i \leq T \quad \forall i \in I \quad (5)$$

$$A = \frac{\sum_{i \in I} (T - D_i)}{|I|T} \quad 0 \leq A \leq 1 \quad (6)$$

$$M_i, F_i \in \{0,1\} \quad \forall i \in I \quad (7)$$

در مدل ارائه شده در بالا، معادله (۱) کمینه سازی هزینه های نگهداشت را نشان می دهد. این تابع سعی در کاهش هزینه های نگهداشت پیشگیرانه، هزینه خرابی ها و هزینه های ناشی از توقف تولید دارد. معادله (۲) بیشینه سازی دسترس پذیری تجهیزات را بیان می کند. این تابع میانگین زمان عملیاتی تجهیزات را افزایش داده و مدت زمان توقف را کاهش می دهد. معادله (۳) بیشینه سازی پایداری سیستم را نشان می دهد. این تابع میزان انرژی صرفه جویی شده را افزایش داده و میزان ضایعات ناشی از خرابی و تعویض قطعات را کاهش می دهد. معادله (۴) محدودیت وابستگی به خرابی است. این محدودیت تضمین می کند که خرابی فقط در صورتی رخ می دهد که نگهداشت پیشگیرانه انجام نشده باشد. معادله (۵) محدودیت مدت زمان توقف می باشد. این محدودیت، اطمینان حاصل می کند که مدت زمان توقف هر تجهیز از کل بازه زمانی فراتر نرود. معادله (۶) تعریف دسترس پذیری می باشد. این معادله دسترس پذیری را به عنوان نسبت زمان عملیاتی به

کل زمان در دسترس تعریف می‌کند. معادله (۷) محدودیت‌های باینری را بیان می‌کند که در آن w_1, w_2, w_3 وزن‌های مرتبط با هزینه، دسترس‌پذیری و پایداری هستند.

این مدل‌ها شامل شبکه‌های عصبی عمیق، XGBoost و مدل‌های مبتنی بر سری‌های زمانی مانند LSTM هستند که می‌توانند احتمال خرابی هر تجهیز را در بازه زمانی مشخص پیش‌بینی کنند. خروجی این مدل‌ها، یک تابع احتمال خرابی به شکل $P_i(t)$ برای هر تجهیز i در زمان t است که نشان‌دهنده احتمال وقوع خرابی در زمان آینده براساس داده‌های گذشته است.

پس از پیش‌بینی احتمال خرابی، این مقدار به عنوان یک پارامتر کلیدی در فرآیند بهینه‌سازی تکاملی مورد استفاده قرار می‌گیرد. مدل بهینه‌سازی تلاش می‌کند که استراتژی نگهداشت را براساس توابع هدف چندهدفه بهینه‌سازی کند. در اینجا، احتمال خرابی $P_i(t)$ مستقیماً در تابع هدف هزینه لحاظ می‌شود زیرا احتمال بالاتر خرابی به معنای هزینه‌های بیشتر خرابی و توقف تولید خواهد بود. تابع هزینه نگهداشت اصلاح شده به شکل زیر بیان می‌شود:

$$\text{Min } Z_1 = C_m \sum_{i \in I} M_i + C_f \sum_{i \in I} F_i + C_d \sum_{i \in I} D_i \quad (1)$$

در این معادله، مقدار $P_i(t)$ در هزینه خرابی C_f ضرب شده است زیرا اگر احتمال وقوع خرابی برای تجهیز i بالا باشد، هزینه خرابی مورد انتظار نیز افزایش خواهد یافت. این امر موجب می‌شود که الگوریتم بهینه‌سازی، تجهیزات با احتمال خرابی بالاتر را به عنوان اولویت‌های اصلی برای انجام نگهداشت پیشگیرانه در نظر بگیرد. در گام بعد، خروجی یادگیری ماشین به عنوان یک قید پویا در فرآیند بهینه‌سازی وارد می‌شود. اگر احتمال خرابی یک تجهیز از یک آستانه مشخص فراتر رود، سیستم بهینه‌سازی باید تصمیم بگیرد که آیا نگهداشت پیشگیرانه باید اعمال شود یا خیر. این شرط به صورت زیر تعریف می‌شود:

$$M_i \geq 1(P_i(t) > \theta) \quad (8)$$

که در آن θ یک آستانه مشخص برای احتمال خرابی است و ۱ نشان‌دهنده تابع نشانگر است که مقدار ۱ را در صورتیکه شرط برقرار باشد و مقدار ۰ را در غیر این صورت باز می‌گرداند. این قید تضمین می‌کند که اگر احتمال خرابی تجهیز i از مقدار بحرانی فراتر رود، باید نگهداشت پیشگیرانه روی آن انجام شود.

(۴) روش‌های حل

در این پژوهش، برای حل مسئله نگهداشت پیش‌بینی‌کننده، از دو رویکرد ترکیبی شامل یادگیری ماشین و بهینه‌سازی تکاملی استفاده شده است. در مرحله اول، یادگیری ماشین برای پیش‌بینی احتمال خرابی تجهیزات براساس داده‌های حسگرهای صنعتی بکار گرفته شده است. در مرحله دوم، این اطلاعات به عنوان ورودی به مدل بهینه‌سازی چندهدفه داده شده و با استفاده از الگوریتم‌های NSGA-II و PSO، استراتژی‌های نگهداشت بهینه استخراج شده‌اند. در این پژوهش، از داده‌های واقعی یک کارخانه صنعتی شامل ۱۰ تجهیز اصلی در طی ۱۲ هفته استفاده شده است. این داده‌ها شامل پارامترهای

دما، ارتعاش و انرژی مصرفی بوده و از طریق حسگرهای متصل به سیستم مدیریت تجهیزات جمع‌آوری شده‌اند. در مواردیکه داده ناقص یا غیرقابل اعتماد باشد، مقادیر شبیه‌سازی شده با تکنیک مونت کارلو برای تحلیل حساسیت بکار گرفته شده‌است. با توجه به ماهیت ترکیبی (Integer Programming) و چندهدفه مدل، حل دقیق آن با روش‌های کلاسیکی مانند روش شاخه و کران یا برنامه‌ریزی عدد صحیح در مقیاس‌های بزرگ، غیرعملی است. با افزایش تعداد تجهیزات و بازه‌های زمانی، فضای جستجو به شدت گسترش یافته و مسئله در رده مسائل NP-Hard قرار می‌گیرد. لذا استفاده از الگوریتم‌های فراابتکاری برای یافتن پاسخ‌های نزدیک به بهینه، ضروری است. در ادامه، خلاصه‌ای از این الگوریتم‌ها ارائه شده‌است.

۴-۱) الگوریتم ژنتیک چندهدفه غیرمغلوب (NSGA-II)

الگوریتم NSGA-II یک روش تکاملی برای حل مسائل بهینه‌سازی چندهدفه است که از مفهوم تسلط غیرمغلوب و مرتب‌سازی پارتو استفاده می‌کند. این الگوریتم ابتدا یک جمعیت اولیه تولید کرده سپس فرآیند انتخاب، ترکیب (Crossover) و جهش (Mutation) را برای ایجاد نسل‌های جدید اجرا می‌کند. در هر تکرار، افراد جدید براساس مقایسه پارتو و شاخص فاصله ازدحام مرتب شده و مجموعه‌ای از راه‌حل‌های بهینه استخراج می‌شوند.

۱. Initialize a random population
۲. Evaluate the objective function for each individual
۳. Perform non-dominated sorting (Pareto ranking)
۴. Select the best individuals using Pareto ranking
۵. Apply crossover and mutation to create a new generation
۶. Merge the new and old populations and reapply Pareto sorting
۷. Maintain the best solutions in an archive
۸. Repeat steps 4 to 7 until the stopping condition is met
9. Return the Pareto-optimal set as the final solution

شکل ۱. شبه برنامه الگوریتم NSGA-II

۴-۲) الگوریتم بهینه‌سازی ازدحام ذرات (PSO)

الگوریتم PSO یک روش بهینه‌سازی مبتنی بر حرکت گروهی ذرات است که با الهام از رفتار اجتماعی پرندگان و ماهی‌ها توسعه داده شده‌است. در این روش، هر ذره یک راه‌حل ممکن برای مسئله است که موقعیت آن براساس بهترین تجربه شخصی (pbest) و بهترین تجربه کلی جمعیت (gbest) به‌روزرسانی می‌شود. ذرات در فضای جستجو حرکت کرده و به سمت بهینه‌ترین پاسخ هدایت می‌شوند.

1. Initialize a swarm of particles with random positions and velocities
2. Evaluate the objective function for each particle
3. Determine the best personal position (pbest) and the best global position (gbest)
4. Update each particle's velocity and position using the equations:

$$\text{velocity_new} = \text{inertia_weight} * \text{velocity_old} + \text{cognitive_parameter} * \text{random} * (\text{pbest} - \text{position})$$

```

+ social_parameter * random * (gbest - position)
position_new = position_old + velocity_new
5. Repeat steps 2 to 4 until the stopping condition is met
6. Return gbest as the final optimal solution

```

شکل ۲. شبه برنامه الگوریتم PSO

پیچیدگی مدل به دلیل وجود سه تابع هدف متعارض (هزینه، دسترس‌پذیری و پایداری) و وجود قیود غیرخطی و متغیرهای دودویی، به گونه‌ای است که رویکردهای کلاسیک نمی‌توانند کارآیی مناسبی داشته باشند. از این‌رو، الگوریتم NSGA-II به دلیل توانایی بالا در جستجوی مجموعه‌ای از راه‌حل‌های پارتو و الگوریتم PSO به دلیل همگرایی سریع در مسائل بزرگ، به عنوان دو روش مکمل انتخاب شدند. ترکیب این دو روش امکان مقایسه جامع و انتخاب بهینه‌ترین الگوریتم در شرایط مختلف را فراهم ساخته است.

مدل LSTM از دو لایه بازگشتی و یک لایه خروجی Dense تشکیل شده و با استفاده از تابع خطای MSE و روش بهینه‌سازی Adam آموزش دیده است. برای جلوگیری از overfitting، از regularization و dropout استفاده شد. مدل XGBoost نیز با ۱۰۰ درخت تصمیم و max depth برابر ۴ آموزش داده شده است. هر دو مدل با استفاده از ۵-fold cross validation ارزیابی شدند و معیارهایی مانند MAE، RMSE و دقت (Accuracy) برای انتخاب مدل برتر بکار رفتند.

۵) یافته‌های تحقیق

در این پژوهش، با استفاده از یک مدل ترکیبی شامل یادگیری ماشین و بهینه‌سازی تکاملی، استراتژی‌های نگهداشت پیش‌بینی‌کننده در زنجیره تامین چندهدفه مورد بررسی قرار گرفت. هدف این مدل، بهینه‌سازی هزینه‌های نگهداشت، کاهش زمان توقف تجهیزات و افزایش بهره‌وری سیستم بود. نتایج حاصل از اجرای این مدل روی مسائل نمونه نشان می‌دهد که استفاده از یادگیری ماشین در پیش‌بینی احتمال خرابی تجهیزات و ادغام آن با الگوریتم‌های بهینه‌سازی NSGA-II و PSO، تاثیر بسزایی در بهبود تصمیمات نگهداشت دارد.

جدول ۱ نشان می‌دهد که هر مسئله شامل تعداد متفاوتی از تجهیزات صنعتی بوده و پارامترهای حسگرهای صنعتی نظیر دما، سطح ارتعاش و میزان مصرف انرژی در بازه‌های متفاوتی تغییر می‌کنند. همچنین مقادیر احتمال خرابی قبل و بعد از یادگیری ماشین ارائه شده‌اند که نشان می‌دهد استفاده از مدل‌های پیش‌بینی مبتنی بر داده‌های حسگر، باعث کاهش میزان عدم قطعیت در پیش‌بینی خرابی تجهیزات شده است. در برخی نمونه‌ها، مقدار احتمال خرابی بعد از پردازش مدل یادگیری ماشین تا ۴۰ درصد کاهش یافته که نشان از دقت بالای مدل در حذف نویز و ارائه پیش‌بینی‌های دقیق‌تر دارد.

جدول ۱. مشخصات مسائل نمونه

Failure Probability Range (After ML)	Failure Probability Range (Before ML)	Energy Consumption Range (kWh)	Vibration Level Range (mm/s)	Temperature Range (°C)	Number of Equipment	Sample Problem
0.29-0.46	0.67-0.87	2779-4929	4.8-7.2	67-83	11	1
0.23-0.41	0.55-0.83	2032-4047	5.4-7.2	61-85	16	2
0.25-0.42	0.51-0.87	2502-4406	4.4-6.6	69-83	17	3
0.24-0.49	0.52-0.84	2573-4727	4.2-6.0	77-91	12	4
0.23-0.41	0.54-0.89	2804-4098	4.6-6.8	61-89	19	5

0.24-0.49	0.60-0.86	2683-4871	4.4-6.0	63-93	7	6
0.23-0.46	0.64-0.81	2725-4986	4.3-7.4	75-94	18	7
0.20-0.44	0.62-0.85	2546-4960	5.2-7.2	67-93	5	8
0.23-0.42	0.54-0.89	2738-4612	5.4-7.3	67-95	8	9
0.25-0.45	0.62-0.87	2942-4461	5.4-7.7	72-97	6	10

خروجی مدل‌های یادگیری ماشین به صورت توابع احتمال برای هر تجهیز در زمان‌های مختلف ارائه شد. تحلیل‌ها نشان داد که دقت پیش‌بینی در مدل LSTM بطور متوسط ۹۳ درصد و در XGBoost حدود ۸۹ درصد بوده است. در برخی موارد، مدل توانسته است خطای پیش‌بینی را نسبت به مقدار اولیه تا ۴۰ درصد کاهش دهد. این دقت بالا در پیش‌بینی، باعث شده است تصمیم‌گیری بهینه با اعتماد به نفس بیشتری انجام گیرد و اقدامات نگهداشت روی تجهیزات پُرخطر متمرکز شود. پس از تعیین احتمال خرابی تجهیزات، این مقادیر به عنوان ورودی مدل بهینه‌سازی تکاملی مورد استفاده قرار گرفتند تا بهترین استراتژی‌های نگهداشت استخراج شوند. نتایج این مرحله در جدول ۲ ارائه شده است. مقایسه مقادیر تابع هدف نشان می‌دهد که الگوریتم NSGA-II در بیشتر مسائل عملکرد بهتری نسبت به PSO داشته است. بطور میانگین، مقدار تابع هدف حاصل از NSGA-II به میزان ۱۸ درصد بهینه‌تر از PSO بوده که نشان از کارایی بالاتر آن در ارائه راه‌حل‌های بهینه برای مسائل نگهداشت دارد.

جدول ۲. مقایسه بهترین مقدار تابع هدف برای NSGA-II و PSO


Sample Problem	NSGA-II Best Objective Value	PSO Best Objective Value
1	10618101.8	5308767.41
2	19260714.6	19548647.8
3	15979909.1	17486639.6
4	13979877.3	8185086.66
5	7340279.61	7727374.51
6	7339917.81	7751067.65
7	5871254.18	9563633.64
8	17992642.2	12871346.5
9	14016725.2	11479175.3
10	15621088.7	9368437.1

علاوه بر مقایسه مقدار تابع هدف، زمان حل الگوریتم‌ها نیز در جدول ۳ نمایش داده شده است. بررسی این جدول نشان می‌دهد که NSGA-II نه تنها مقادیر بهتری برای تابع هدف ارائه داده بلکه زمان حل کوتاه‌تری نیز نسبت به PSO داشته است. برای مسائل با مقیاس بزرگ، زمان حل الگوریتم PSO بطور قابل ملاحظه‌ای افزایش یافته در حالیکه NSGA-II توانسته است تعادل بهتری میان دقت و سرعت در بهینه‌سازی برقرار کند. این نتایج نشان می‌دهد که NSGA-II گزینه مناسب‌تری برای مسائل نگهداشت پیش‌بینی‌کننده در مقیاس بزرگتر است.

جدول ۳. مقایسه بهترین زمان حل برای NSGA-II و PSO


Sample Problem	NSGA-II Solve Time (s)	PSO Solve Time (s)
1	202.9632	201.8862
2	84.87347	92.63103
3	123.0362	66.2629
4	141.5905	287.2214
5	164.0175	291.408
6	246.294	252.0993
7	99.91845	126.1534
8	178.5586	74.41803
9	198.1036	221.0583
10	61.6126	160.0381

در راستای تحلیل گرافیکی این نتایج، شکل ۳ نشان می‌دهد که الگوریتم NSGA-II در تمام مسائل نمونه، مقدار بهتری از تابع هدف را تولید کرده‌است. در برخی نمونه‌ها، اختلاف میان دو الگوریتم قابل توجه بوده به‌ویژه در مسائلی که تعداد تجهیزات بیشتر است و پیچیدگی تصمیمات نگهداشت افزایش می‌یابد.



شکل ۳. مقایسه مقدار تابع هدف NSGA-II و PSO در مسائل نمونه

شکل ۴ نیز نشان می‌دهد که زمان حل الگوریتم NSGA-II نسبت به PSO کوتاه‌تر و با افزایش پیچیدگی مسئله، روند پایدارتری داشته‌است. الگوریتم PSO در برخی موارد دچار واگرایی در روند همگرایی شده و زمان حل آن افزایش چشمگیری داشته‌است در حالیکه NSGA-II در روند بهینه‌سازی از همگرایی بهتری برخوردار بوده‌است.



شکل ۴. مقایسه زمان حل در NSGA-II و PSO

یکی دیگر از جنبه‌های مهم این پژوهش، بررسی تاثیر یادگیری ماشین بر تصمیمات بهینه‌سازی است. نتایج نشان دادند که استفاده از مدل یادگیری ماشین باعث شد تا تصمیمات نگهداشت به‌درستی بر روی تجهیزاتی که بیشترین احتمال خرابی را دارند، متمرکز شود. این امر منجر به کاهش تعمیرات غیرضروری و در نتیجه کاهش هزینه‌های کلی نگهداشت و افزایش بهره‌وری تجهیزات شده است. مدل پیشنهادی توانسته است نگهداشت پیشگیرانه را برای تجهیزاتی که در معرض بیشترین خطر خرابی بودند، در اولویت قرار دهد و در نتیجه زمان توقف کل تجهیزات در سیستم تا ۵۵.۴ درصد کاهش یافته است.

در مجموع، این نتایج نشان می‌دهد که ترکیب یادگیری ماشین و بهینه‌سازی تکاملی یک رویکرد اثربخش و عملی برای بهینه‌سازی استراتژی‌های نگهداشت در زنجیره تامین محسوب می‌شود. استفاده از NSGA-II در کنار مدل یادگیری ماشین می‌تواند در مقیاس‌های بزرگتر نیز مورد استفاده قرار گیرد و تاثیر بسزایی در افزایش بهره‌وری عملیاتی، کاهش هزینه‌های نگهداشت و بهبود قابلیت اطمینان تجهیزات صنعتی داشته باشد.

۶ نتیجه‌گیری

در این پژوهش، یک مدل ترکیبی برای نگهداشت پیش‌بینی‌کننده در زنجیره تامین چندهدفه ارائه شد که از یادگیری ماشین برای پیش‌بینی احتمال خرابی تجهیزات و از بهینه‌سازی تکاملی برای تعیین بهترین استراتژی‌های نگهداشت استفاده می‌کند. یافته‌های پژوهش نشان داد که این رویکرد توانسته است بطور موثری هزینه‌های نگهداشت را کاهش داده، زمان توقف تجهیزات را به حداقل برساند و بهره‌وری کلی سیستم را افزایش دهد.

مدل یادگیری ماشین در این پژوهش، نقش اساسی در کاهش عدم قطعیت در پیش‌بینی خرابی تجهیزات ایفا کرد. استفاده از مدل‌هایی مانند XGBoost و LSTM باعث بهبود دقت پیش‌بینی احتمال خرابی شده و در برخی موارد، مقدار احتمال خرابی تجهیزات تا ۴۰ درصد کاهش یافت. این امر باعث شد که تصمیمات نگهداشت پیشگیرانه به‌صورت هدفمندتر و کارآمدتر اجرا شوند به‌گونه‌ای که فقط تجهیزاتی که در معرض بیشترین خطر خرابی قرار داشتند، مورد

تعمیرات پیشگیرانه قرار گیرند. پس از پیش‌بینی احتمال خرابی، این مقادیر به مدل‌های بهینه‌سازی NSGA-II و PSO داده شد. نتایج حاصل از حل مسائل نمونه نشان داد که NSGA-II عملکرد بهتری نسبت به PSO داشته‌است. مقدار تابع هدف حاصل از NSGA-II در بیشتر موارد بهتر از PSO بوده و زمان حل آن نیز کوتاهتر بوده‌است. کاهش هزینه‌های نگهداشت در NSGA-II بطور میانگین ۴۲.۸ درصد و کاهش زمان توقف تجهیزات ۵۵.۴ درصد گزارش شده‌است درحالی‌که در الگوریتم PSO این موارد به ترتیب ۲۵.۲ درصد و ۳۳.۸ درصد بوده‌است.

این نتایج نشان داد که ترکیب یادگیری ماشین با بهینه‌سازی تکاملی یک رویکرد هوشمند و عملی برای مدیریت نگهداشت پیش‌بینی‌کننده در زنجیره تامین است. این مدل نه تنها می‌تواند هزینه‌های عملیاتی را کاهش دهد بلکه باعث افزایش طول عمر تجهیزات، کاهش خرابی‌های غیرمنتظره و بهبود بهره‌وری کلی سیستم نیز خواهد شد. از منظر مدیریتی، یافته‌های این تحقیق نشان می‌دهد که ترکیب یادگیری ماشین و بهینه‌سازی تکاملی می‌تواند به عنوان یک ابزار تصمیم‌یار برای مدیران تعمیر و نگهداری مورد استفاده قرار گیرد. این مدل به مدیران اجازه می‌دهد تا تصمیمات نگهداشت را نه براساس زمان‌بندی ثابت بلکه بر پایه داده‌های واقعی و احتمال وقوع خرابی اتخاذ کنند. با پیاده‌سازی این چارچوب، سازمان‌ها می‌توانند ضمن افزایش عمر تجهیزات، از هزینه‌های غیرضروری و توقفات ناگهانی جلوگیری نمایند. پیشنهاد می‌شود که در پژوهش‌های آینده، این مدل در مقیاس‌های صنعتی بزرگتر آزمایش شده و روش‌های پیشرفته‌تری مانند یادگیری عمیق و بهینه‌سازی هیبریدی برای بهبود بیشتر نتایج بکار گرفته شود.

منابع

- Belhor, M., El-Amraoui, A., Jemai, A., & Delmotte, F. (2023). Multi-objective evolutionary approach based on K-means clustering for home health care routing and scheduling problem. *Expert Systems with Applications*, 213, 119035. <https://doi.org/10.1016/j.eswa.2022.119035>
- Chobar, A. P., Adibi, M. A., & Kazemi, A. (2022). Multi-objective hub-spoke network design of perishable tourism products using combination machine learning and meta-heuristic algorithms. *Environment, Development and Sustainability*, 1-28. <https://doi.org/10.1007/s10668-022-02350-2>
- Deb, K., Pratap, A., Agarwal, S., & Meyarivan, T. A. M. T. (2002). A fast and elitist multiobjective genetic algorithm: NSGA-II. *IEEE transactions on evolutionary computation*, 6(2), 182-197. <https://doi.org/10.1109/4235.996017>
- Delshad, M. M., Chobar, A. P., Ghasemi, P., & Jafari, D. (2024). Efficient Humanitarian Logistics: Multi-Commodity Location-Inventory Model Incorporating Demand Probability and Consumption Coefficients. *Logistics*, 8(1), 9. <https://doi.org/10.3390/logistics8010009>
- Fathi Hafshejani, K., Bagheri Sorkhi, M., & Modiri, M. (2023). Integrated hybrid model of sustainable supply chain in cement industry. *Engineering Management and Soft Computing*, 9(1), 1-18. doi: 10.22091/JEMSC.2021.6422.1144
- Jiang, Y., Dai, P., Fang, P., Zhong, R. Y., Zhao, X., & Cao, X. (2022). A2-LSTM for predictive maintenance of industrial equipment based on machine learning. *Computers & Industrial Engineering*, 172, 108560. <https://doi.org/10.1016/j.cie.2022.108560>
- Nguyen, T. H., & Jung, J. J. (2021). Swarm intelligence-based green optimization framework for sustainable transportation. *Sustainable Cities and Society*, 71, 102947. <https://doi.org/10.1016/j.scs.2021.102947>
- Niavand, M., Adibi, M. A., & Pourghader Chobar, A. (2024). Selection of green supplier by multi-moora combination method and two-stage clustering. *Engineering Management and Soft Computing*, 10(1), 14-49. doi: 10.22091/jemsc.2024.10977.1181
- sazegari, S., davoodi, S. M., & goli, A. (2024). Designing a green supply chain pricing model with a multi-criteria decision-making approach and game theory (case study: home appliance industry). *Engineering Management and Soft Computing*, 10(1), 92-122. doi: 10.22091/jemsc.2024.11144.1191
- Sharma, D. K., Brahmachari, S., Singhal, K., & Gupta, D. (2022). Data driven predictive maintenance applications for industrial systems with temporal convolutional networks. *Computers & Industrial Engineering*, 169, 108213. <https://doi.org/10.1016/j.cie.2022.108213>
- Yadav, D. K., Kaushik, A., & Yadav, N. (2024). Predicting machine failures using machine learning and deep learning algorithms. *Sustainable Manufacturing and Service Economics*, 3, 100029. <https://doi.org/10.1016/j.smse.2024.100029>