



Simultaneous Optimization of Failure Risk Cost and Maintenance Costs Using a Hybrid Machine Learning and Genetic Algorithm Approach

Mahnaz Jalili¹, Sadeh Abedi^{2*}, Masoumeh Daneshshakib³

¹ PhD Student, Industrial Management Department, Qazvin Branch, Islamic Azad University, Qazvin, Iran. Email Address: Mahnaz.jalili@iau.ir

² Correspondence: Assistant Professor, Industrial Management Department, Qazvin Branch, Islamic Azad University, Qazvin, Iran. Email Address: abedi.sadeh@iau.ac.ir

³ Prof, Department of Business Administration, Faculty of Social Sciences, University of Mohaghegh Ardabili, Ardabil, Iran. Email Address: zareei@uma.ac.ir

⁴ Assistant Professor, Industrial Management Department, Qazvin Branch, Islamic Azad University, Qazvin, Iran. Email Address: m.danesh.shakib@iau.ac.ir

ARTICLE INFO

Article history:

Article Type: Research Paper

Received: 7 February 2026

Received in revised form: 28 June 2026

Accepted: 27 August 2026

Available online: 16 September 2026

Keywords:

Maintenance

Machine Learning

Failure Prediction

Multi-Objective Optimization

ABSTRACT

This study aims to evaluate a hybrid data-driven framework for the simultaneous optimization of equipment failure risk costs and scheduled maintenance and repair expenditures, relying on the output of a superior machine learning-based failure prediction model. Characterized as an applied and data-driven investigation, this research utilizes a dataset comprising 400 weekly records spanning an eight year period, related to equipment maintenance and repair operations across a three-echelon coke production supply chain—from coal extraction to processing. In the first stage, the failure probability of equipment was predicted using several machine learning algorithms. Subsequently, the predictive model's outputs were integrated as inputs into a multi-objective genetic algorithm to derive optimal schedules for preventive maintenance. The findings revealed that the gradient boosting model demonstrates superior capability in capturing complex failure patterns. Furthermore, coupling its output with the genetic algorithm enables the identification of a set of optimal trade-off solutions between mitigating failure risk and controlling maintenance costs. The resulting Pareto front indicates that intensifying maintenance efforts does not necessarily minimize total costs; rather, selecting the optimal plan is contingent upon managerial priorities and organizational risk tolerance. Overall, this research demonstrates that integrating machine learning-based failure prediction with multi-objective optimization can effectively elevate maintenance decision-making from a reactive paradigm to a proactive and intelligent level.

Cite this article: M. Jalili, S. Abedi, and M. Daneshshakib, "Simultaneous Optimization of Failure Risk Cost and Maintenance Costs Using a Hybrid Machine Learning and Genetic Algorithm Approach, vol. 28, no. 2, pp. 101-117, 2026.
DOI: <https://doi.org/10.47176/scmj.2026.1701>



© Author(s) retain the copyright and full publishing rights
Publisher: Imam Hossein University

Introduction

In capital-intensive heavy industries, such as mining and coke manufacturing, unexpected equipment breakdowns cause severe operational disruptions, throughput losses, and cascading supply chain bottlenecks. Traditional maintenance strategies rely heavily on reactive repairs or rigid, calendar-based intervals. While reactive maintenance leads to costly unplanned downtime, calendar-based programs often result in redundant overhauls, misallocated labor, and unnecessary parts consumption without addressing actual degradation states. Although predictive maintenance techniques have advanced, a major research gap remains in directly linking data-driven failure probability forecasts with constrained multi-objective mathematical optimization. This study proposes an integrated hybrid framework that connects machine learning failure prognostics directly with a multi-objective Genetic Algorithm to simultaneously minimize expected failure risk costs and scheduled preventive maintenance expenses across a three-tier industrial supply chain over a 52-week operational horizon.

Research Objectives and Questions

The primary research question addressed is:

How can predictive failure probabilities from machine learning models be systematically embedded into a multi-objective optimization framework to balance failure risk mitigation against maintenance costs under real-world resource constraints?

The specific research objectives are:

1. To predict weekly failure probabilities across a multi-tier mineral processing supply chain using diagnostic and operational indicators.
2. To benchmark multiple machine learning algorithms to select the most accurate prognostic model.
3. To formulate a bi-objective optimization model that minimizes expected failure risk costs and direct preventive maintenance expenditures under weekly budget and workforce capacity constraints.
4. To solve the maintenance scheduling problem using a multi-objective Genetic Algorithm and analyze Pareto-optimal trade-offs.
5. To evaluate operational trade-offs across varying managerial risk preferences, concurrency limits, and cost fluctuations.

Methodology

The research employs an applied quantitative modeling design using an industrial database of 400 weekly operational records spanning eight years from a coke manufacturing complex in the Central Alborz region. The production network encompasses three interconnected echelons—coal extraction, coal beneficiation, and outbound logistics—covering twelve critical equipment units.

The study was carried out in four main phases:

6. **Data Preprocessing and Feature Extraction:** Ten diagnostic features were extracted across the supply chain, including on-time maintenance rate, inspection defect counts, conveyor overload index, corrective work orders, composite anomaly scores, unplanned downtime hours, work order backlog,

voltage and speed deviations, operating hours since last overhaul, and hydraulic pressure. Missing entries were handled via median and moving-average imputations, while anomalies were filtered using statistical standard scores.

7. Machine Learning Predictive Modeling: Four algorithms—Artificial Neural Networks, Decision Trees, Random Forests, and Extreme Gradient Boosting (XGBoost)—were evaluated using root mean square error, mean absolute error, coefficient of determination, and mean absolute percentage error to estimate weekly failure probabilities. XGBoost achieved the best performance and was selected as the predictive engine.

8. Mathematical Formulation: A bi-objective model was constructed to balance expected failure risk costs (derived from failure probabilities and hourly unplanned downtime losses ranging from 135 to 185 Million Rials per hour) with scheduled maintenance costs (labor, spare parts, and planned stoppage expenses). Weekly constraints were imposed for financial budgets and maintenance labor capacity across the 52-week horizon.

9. Genetic Algorithm Optimization: A multi-objective Genetic Algorithm with binary chromosome representation was implemented to determine the optimal weekly schedule across all twelve machines. The algorithm utilized a population of 100 chromosomes, 150 generations, a 5% elitism rate, and early-stopping rules to prevent premature convergence across varied risk-preference scenarios.

Findings

The prognostic evaluation demonstrated that XGBoost effectively captured complex, non-linear degradation relationships from operational telemetry, providing reliable dynamic failure probabilities. The Genetic Algorithm successfully generated a non-dominated Pareto frontier reflecting the trade-off between failure risk and preventive maintenance expenses.

Under a baseline risk-averse managerial scenario, the optimal schedule comprised 61 total preventive maintenance actions over 52 weeks, averaging 1.173 interventions per week. This policy yielded an expected failure risk cost of 12,991 Million Rials and a total planned maintenance expenditure of 45,508 Million Rials, achieving a composite weighted fitness score of 25,998 with zero violations of weekly financial or labor constraints. Peak weekly expenditure reached 1,704 Million Rials in week 44, while the lowest was 894 Million Rials in week 49, maintaining an average interval of 1.1 weeks between successive maintenance events.

The optimization revealed an intelligent upstream scheduling priority: scheduling timely preventive interventions on extraction equipment significantly lowered failure rates at the source, preventing costly ripple-effect shutdowns in downstream processing and logistics. Furthermore, evaluating maintenance concurrency demonstrated that a limit of six simultaneously serviced machines offered the ideal balance between failure risk suppression and workshop workload feasibility.

Discussion

The results show that arbitrarily increasing maintenance frequency does not minimize total costs, as excessive interventions yield diminishing returns due to planned downtime and parts costs. The optimal balance depends heavily on organizational risk preferences.

The hybrid XGBoost–Genetic Algorithm structure bridges the gap between condition monitoring and actionable operational planning. The model responds adaptively to adjustments in risk weights, transitioning seamlessly between risk-minimizing and cost-saving configurations. Sensitivity analyses confirmed that spare parts price changes linearly affect maintenance budgets, while changes in failure probabilities directly impact risk expenditures, highlighting the critical importance of reliable machine learning prognostics in maintenance economics.

Conclusions and Implications

The integrated Machine Learning–Genetic Algorithm framework offers a reliable, data-driven approach for optimizing maintenance schedules and failure risks in complex industrial environments. The findings confirm that dynamically aligning maintenance actions with machine health and operational constraints yields major efficiency gains over rigid time-based practices.

Key recommendations for industrial decision-makers include:

- Migrating from calendar-based maintenance to dynamic, risk-weighted scheduling models informed by operational data.
- Prioritizing condition monitoring and preventive actions on upstream machinery to eliminate cascading downstream outages.
- Utilizing multi-objective Pareto trade-offs to match maintenance plans with corporate budget limits and risk appetites.
- Establishing realistic equipment concurrency thresholds to optimize workshop and crew utilization.

Limitations include relying on data from a single production facility and deterministic cost assumptions. Future work should investigate deep learning architectures for continuous time-series sensor streams, apply robust optimization under macroeconomic uncertainties, and scale the framework across multi-site industrial networks.

بهینه‌سازی همزمان هزینه ریسک خرابی و هزینه‌های نگهداری با رویکرد ترکیبی یادگیری ماشین - الگوریتم ژنتیک

مهناز جلیلی^۱، صادق عابدی^{۲*}، معصومه دانش شکیب^۳

^۱ دانشجوی دکتری، گروه مدیریت صنعتی، واحد قزوین، دانشگاه آزاد اسلامی، قزوین، ایران. رایانامه: mahnaz.jalili@iau.ac.ir

^۲ استادیار گروه مدیریت صنعتی، واحد قزوین، دانشگاه آزاد اسلامی، قزوین، ایران (نویسنده مسئول). رایانامه: abedi.sadegh@iau.ac.ir

^۳ استادیار گروه مدیریت صنعتی، واحد قزوین، دانشگاه آزاد اسلامی، قزوین، ایران. رایانامه: m.danesh.shakib@iau.ac.ir

چکیده

هدف این پژوهش، ارزیابی یک چارچوب ترکیبی داده‌محور برای بهینه‌سازی همزمان هزینه ریسک خرابی تجهیزات و هزینه‌های برنامه‌ریزی شده نگهداری و تعمیرات، با اتکا به خروجی مدل برتر پیش‌بینی خرابی مبتنی بر یادگیری ماشین است. پژوهش از نوع کاربردی و داده‌محور بوده و داده‌های مورد استفاده در این پژوهش شامل ۴۰۰ رکورد هفتگی استخراج‌شده از یک بازه زمانی ۸ ساله و مرتبط با فعالیت‌های نگهداری و تعمیرات تجهیزات در زنجیره تأمین سه‌سطحی تولید کک از استخراج زغال‌سنگ تا مرحله فرآوری می‌باشد. در مرحله نخست، پیش‌بینی احتمال خرابی تجهیزات با استفاده از چند الگوریتم یادگیری ماشین انجام شد. سپس، خروجی این مدل به‌عنوان ورودی یک الگوریتم ژنتیک چندهدفه به‌کار گرفته شد تا سناریوهای بهینه برای زمان‌بندی نگهداری پیشگیرانه استخراج شوند. یافته‌هایشان دادند که مدل گرادیان بوستینگ توانایی بالاتری در شناسایی الگوهای پیچیده خرابی تجهیزات دارد و اتصال خروجی آن به الگوریتم ژنتیک امکان استخراج مجموعه‌ای از راه‌حل‌های بهینه مبادله‌ای میان کاهش ریسک خرابی و کنترل هزینه‌های نگهداری را فراهم می‌کند. جبهه پارتو حاصل، بیانگر آن است که افزایش شدت نگهداری الزاماً به حداقل‌سازی هزینه کل منجر نمی‌شود و انتخاب طرح بهینه به اولویت‌های مدیریتی و میزان ریسک‌پذیری سازمان وابسته است. پژوهش حاضر نشان می‌دهد که یکپارچه‌سازی پیش‌بینی خرابی مبتنی بر یادگیری ماشین با بهینه‌سازی چندهدفه، می‌تواند تصمیم‌سازی نگهداری و تعمیرات را از سطح واکنشی به سطح پیش‌نگر و هوشمند ارتقا دهد.

مشخصات مقاله

تاریخچه مقاله:

نوع مقاله: علمی پژوهشی

دریافت: ۱۴۰۴/۱۱/۱۸

بازنگری: ۱۴۰۵/۰۴/۰۷

پذیرش: ۱۴۰۵/۰۶/۰۵

ارائه آنلاین: ۱۴۰۵/۰۶/۲۵

کلیدواژه‌ها:

نگهداری و تعمیرات

یادگیری ماشین

پیش‌بینی خرابی

بهینه‌سازی چندهدفه

استناد: جلیلی، مهناز، عابدی، صادق، دانش شکیب، معصومه، "بهینه‌سازی همزمان هزینه ریسک خرابی و هزینه‌های نگهداری با

رویکرد ترکیبی یادگیری ماشین - الگوریتم ژنتیک، دوره ۲۸، شماره ۲، صفحات ۱۱۷-۱۰۱، ۱۴۰۵.

DOI: <https://doi.org/10.47176/scmj.2026.1701>

۱- مقدمه

در سال‌های اخیر، پیچیدگی ساختار زنجیره‌های تأمین صنعتی، افزایش وابستگی متقابل میان سطوح مختلف عملیاتی و فشار فزاینده برای کاهش هزینه‌ها و افزایش قابلیت اطمینان، موجب شده است که مدیریت نگهداری و تعمیرات تجهیزات به یکی از مؤلفه‌های راهبردی تصمیم‌گیری در صنایع فرایندی و سرمایه‌بر تبدیل شود [۱،۲]. در چنین محیطی، خرابی تجهیزات نه تنها منجر به توقف‌های ناخواسته و افزایش هزینه‌های مستقیم تعمیرات می‌شود، بلکه اثرات زنجیره‌ای قابل توجهی بر عملکرد کل زنجیره تأمین، از لجستیک ورودی و عملیات تولید تا لجستیک خروجی و تحویل محصول، برجای می‌گذارد [۳]. این مسئله به‌ویژه در صنایع فرآوری مواد معدنی که با تجهیزات سنگین، جریان‌های پیوسته تولید و محدودیت‌های شدید زمانی و منابعی مواجه‌اند، از حساسیت دوجندانی برخوردار است [۴]. رویکردهای سنتی نگهداری و تعمیرات عمدتاً بر برنامه‌های زمان‌محور یا واکنشی مبتنی بوده‌اند و تصمیمات نگهداری در آن‌ها اغلب بدون اتکا به تحلیل نظام‌مند داده‌های عملیاتی و بدون در نظر گرفتن عدم قطعیت‌های موجود در رفتار خرابی تجهیزات اتخاذ شده است [۵]. با توسعه سیستم‌های اطلاعاتی، ثبت مستمر داده‌های عملکردی تجهیزات و گسترش ابزارهای تحلیل داده، امکان بهره‌گیری از رویکردهای داده‌محور برای پیش‌بینی خرابی و پشتیبانی از تصمیمات نگهداری فراهم شده است [۶،۷]. در این بستر، یادگیری ماشین به عنوان ابزاری توانمند برای مدل‌سازی روابط پیچیده و غیرخطی میان متغیرهای عملیاتی و احتمال وقوع خرابی مطرح شده و زمینه را برای گذار از نگهداری واکنشی به نگهداری هوشمند و پیش‌نگر فراهم کرده است. اگرچه پیش‌بینی خرابی تجهیزات به کمک مدل‌های یادگیری ماشین می‌تواند اطلاعات ارزشمندی درباره ریسک آتی خرابی در اختیار مدیران قرار دهد، اما صرفِ پیش‌بینی، به تنهایی برای پشتیبانی از تصمیمات عملیاتی کافی نیست. چالش اصلی زمانی شکل می‌گیرد که تصمیم‌گیران باید بر اساس این پیش‌بینی‌ها، برنامه‌های نگهداری را به گونه‌ای تنظیم کنند که هم‌زمان میان دو هدف متعارض تعادل برقرار شود: از یک‌سو کاهش ریسک و هزینه‌های ناشی از خرابی و توقف‌های غیرمنتظره، و از سوی دیگر کنترل هزینه‌های برنامه‌ریزی‌شده نگهداری شامل نیروی انسانی، قطعات یدکی و توقف‌های برنامه‌ریزی‌شده [۸]. نادیده گرفتن هر یک از این دو جنبه می‌تواند به تصمیماتی منجر شود که یا هزینه‌های پنهان بالایی در پی دارند یا موجب افزایش بار مالی مستقیم نگهداری می‌شوند [۹]. از این منظر، ضرورت

توسعه رویکردهایی که بتوانند پیش‌بینی داده‌محور خرابی را به فرآیند بهینه‌سازی تصمیمات نگهداری متصل کنند، بیش از پیش احساس می‌شود [۱۰]. مسئله مورد بررسی در این پژوهش به بهینه‌سازی برنامه‌ریزی نگهداری و تعمیرات تجهیزات در یک زنجیره تأمین سه‌سطحی شامل لجستیک ورودی، عملیات تولید و فرآوری و لجستیک خروجی مربوط می‌شود. در این چارچوب، خرابی تجهیزات پدیده‌ای تصادفی و وابسته به مجموعه‌ای از متغیرهای عملیاتی، شرایط بهره‌برداری و عملکرد گذشته سیستم است که پیامدهای آن به صورت هزینه‌های مستقیم تعمیرات، توقف‌های غیرمنتظره و اختلال در جریان مواد و محصول بروز می‌یابد. بنابراین، مسأله اصلی پژوهش را می‌توان به صورت یک مسئله بهینه‌سازی چندهدفه تعریف کرد که در آن، تصمیم‌گیرنده باید بین کمینه‌سازی هزینه موردانتظار ریسک خرابی و توقف‌های غیرمنتظره و کمینه‌سازی هزینه‌های برنامه‌ریزی‌شده نگهداری پیشگیرانه تعادل برقرار کند. پیچیدگی این مسئله ناشی از غیرخطی بودن روابط میان متغیرها، وابستگی تصمیمات به خروجی‌های پیش‌بینی‌شده و بزرگ بودن فضای جستجوی سناریوهای ممکن است؛ عواملی که استفاده از روش‌های تحلیلی کلاسیک را با محدودیت جدی مواجه می‌سازد. برخلاف مطالعات پیشین که پیش‌بینی خرابی و بهینه‌سازی نگهداری را به صورت مجزا یا مبتنی بر مدل‌های ریاضی ساده انجام داده‌اند، در این پژوهش خروجی مدل پیش‌بینی خرابی مبتنی بر یادگیری ماشین به عنوان یک جزء کلیدی در تعریف تابع برازش الگوریتم ژنتیک به کار گرفته می‌شود. این رویکرد امکان لحاظ کردن روابط پیچیده، غیرخطی و داده‌محور میان متغیرهای عملیاتی و ریسک خرابی را در فرآیند بهینه‌سازی فراهم می‌سازد. از منظر دانش‌افزایی، پژوهش حاضر چارچوبی ترکیبی ارائه می‌دهد که به صورت نظام‌مند پیوند میان پیش‌بینی داده‌محور و بهینه‌سازی چندهدفه را در بستر زنجیره تأمین برقرار می‌کند و می‌تواند به عنوان مبنایی برای توسعه رویکردهای تصمیم‌سازی هوشمند در حوزه نگهداری و تعمیرات مورد استفاده قرار گیرد. هدف اصلی این پژوهش، ارائه یک رویکرد ترکیبی داده‌محور برای بهینه‌سازی همزمان تصمیمات نگهداری و تعمیرات تجهیزات در زنجیره تأمین با اتکا به پیش‌بینی خرابی مبتنی بر یادگیری ماشین است. در راستای این هدف کلی، پژوهش حاضر به دنبال آن است که با بهره‌گیری از مدل برتر پیش‌بینی خرابی، تابع هدفی برای برآورد هزینه موردانتظار ریسک خرابی تعریف کرده و آن را در کنار هزینه‌های برنامه‌ریزی‌شده نگهداری در قالب یک مسئله بهینه‌سازی چندهدفه مورد استفاده قرار دهد.

۲- مبانی نظری و پیشینه پژوهش

بررسی نظام‌مند پژوهش‌های پیشین حاکی از آن است که بخش قابل توجهی از مطالعات، پیش‌بینی خرابی و بهینه‌سازی برنامه‌های نگهداری را به صورت مجزا مورد توجه قرار داده‌اند و پیوند ساختاری میان این دو حوزه کمتر به صورت یکپارچه توسعه یافته است. از یک سو، بسیاری از پژوهش‌ها به ارائه مدل‌های پیش‌بینی بسنده کرده‌اند و از سوی دیگر، مطالعات بهینه‌سازی غالباً بر توابع هدف ساده یا مفروضات تحلیلی تکیه داشته‌اند. از این رو، ادبیات موجود بستری مناسب برای طرح پژوهش‌هایی فراهم می‌کند که با رویکردی تلفیقی، پیش‌بینی داده‌محور خرابی را مستقیماً در فرآیند بهینه‌سازی تصمیمات نگهداری و تعمیرات در سطح زنجیره تأمین به کار گیرند.

۲-۱- چارچوب نظری

چارچوب نظری پژوهش حاضر بر تلفیق سه جریان اصلی ادبیات شامل مدیریت نگهداری و تعمیرات، یادگیری ماشین در پیش‌بینی خرابی تجهیزات و بهینه‌سازی تصمیمات عملیاتی در زنجیره تأمین استوار است [۷]. در سطح مفهومی، نگهداری و تعمیرات به عنوان یک کارکرد راهبردی در زنجیره تأمین تلقی می‌شود که نقش آن صرفاً محدود به حفظ قابلیت عملیاتی تجهیزات نیست، بلکه به طور مستقیم بر شاخص‌هایی نظیر قابلیت اطمینان سیستم، هزینه‌های عملیاتی، سطح خدمت و پایداری عملکرد زنجیره تأمین اثر می‌گذارد [۸]. از این منظر، تصمیمات نگهداری در تعامل مستمر با سایر تصمیمات زنجیره تأمین قرار داشته و ماهیتی چندبعدی و بین‌سطحی دارند. در بُعد پیش‌بینی، نظریه‌های مرتبط با نگهداری پیش‌نگر و مبتنی بر وضعیت بر این فرض استوارند که رفتار خرابی تجهیزات تابعی از مجموعه‌ای از متغیرهای عملیاتی، شرایط بهره‌برداری و تاریخچه عملکرد سیستم است [۹]. یادگیری ماشین در این چارچوب به عنوان ابزاری برای تقریب توابع پیچیده و غیرخطی میان این متغیرها و احتمال وقوع خرابی مطرح می‌شود [۱۰]. برخلاف مدل‌های آماری کلاسیک که معمولاً به فروض محدودکننده و ساختارهای از پیش تعریف شده متکی هستند، مدل‌های یادگیری ماشین امکان استخراج الگوهای پنهان از داده‌های واقعی و پرنویز را فراهم می‌کنند و مبنایی داده‌محور برای برآورد ریسک خرابی تجهیزات ارائه می‌دهند [۱۱]. در بُعد تصمیم‌سازی و بهینه‌سازی، چارچوب نظری پژوهش بر نظریه‌های بهینه‌سازی چندهدفه و تصمیم‌گیری تحت عدم قطعیت استوار است. در مسائل نگهداری و تعمیرات، تصمیم‌گیرنده با اهداف متعارضی همچون کاهش ریسک خرابی و کنترل هزینه‌های نگهداری مواجه است که دستیابی هم‌زمان به بهینه مطلق برای آن‌ها امکان‌پذیر نیست [۱۲]. الگوریتم‌های

فراابتکاری، به‌ویژه الگوریتم ژنتیک، در این چارچوب به عنوان ابزارهایی برای جستجوی کارای فضای پاسخ‌های پیچیده و چندقله‌ای مطرح می‌شوند و امکان استخراج مجموعه‌ای از راه‌حل‌های بهینه پارتو را فراهم می‌کنند [۱۳]. پیوند مفهومی این سه بُعد زمانی شکل می‌گیرد که خروجی مدل پیش‌بینی خرابی به عنوان یک ورودی کلیدی در تعریف تابع هدف بهینه‌سازی مورد استفاده قرار گیرد. در این چارچوب، احتمال خرابی پیش‌بینی شده نه تنها یک شاخص توصیفی، بلکه مبنایی برای برآورد هزینه موردانتظار ریسک خرابی و توقف‌های غیرمنتظره تلقی می‌شود. بدین ترتیب، چارچوب نظری پژوهش حاضر بر این ایده استوار است که ترکیب یادگیری ماشین و بهینه‌سازی فراابتکاری می‌تواند گذار از پیش‌بینی صرف به تصمیم‌سازی هوشمند در نگهداری و تعمیرات زنجیره تأمین را امکان‌پذیر سازد و بستری مفهومی برای توسعه رویکردهای داده‌محور یکپارچه در این حوزه فراهم آورد.

۲-۲- پیشینه پژوهش

مرور نظام‌مند پژوهش‌های پیشین نشان می‌دهد که نگهداری و تعمیرات پیش‌بینانه طی سال‌های اخیر به یکی از محورهای اصلی تحقیقات در حوزه مهندسی صنایع، زنجیره تأمین و سیستم‌های تولیدی تبدیل شده است. بخش قابل توجهی از این مطالعات بر توسعه و ارزیابی رویکردهای پیش‌بینی خرابی تجهیزات با استفاده از روش‌های داده‌محور و یادگیری ماشین متمرکز بوده‌اند و تلاش کرده‌اند با تحلیل داده‌های عملیاتی، الگوهای خرابی و رفتار تجهیزات را با دقت بالاتری مدل‌سازی کنند [۱۱، ۱۲]. نتایج این جریان پژوهشی نشان می‌دهد که مدل‌های یادگیری ماشین، به‌ویژه در مواجهه با داده‌های غیرخطی و پرنویز، نسبت به رویکردهای آماری کلاسیک توان پیش‌بینی بالاتری دارند. در کنار این رویکرد، دسته‌ای از پژوهش‌ها به مسئله برنامه‌ریزی و بهینه‌سازی نگهداری و تعمیرات در سطح زنجیره تأمین پرداخته‌اند. این مطالعات عمدتاً با تکیه بر مدل‌های ریاضی، شبیه‌سازی یا الگوریتم‌های بهینه‌سازی کلاسیک و فراابتکاری، به دنبال کاهش هزینه‌های نگهداری، بهبود قابلیت اطمینان سیستم و هماهنگی میان تصمیمات تولید، موجودی و تعمیرات بوده‌اند [۱۳]. با این حال، در بسیاری از این پژوهش‌ها، برآورد ریسک خرابی یا به صورت ایستا و مبتنی بر فروض ساده انجام شده یا به طور مستقل از داده‌های واقعی عملکرد تجهیزات در نظر گرفته شده است. بررسی دقیق‌تر ادبیات نشان می‌دهد که اگرچه برخی مطالعات به ترکیب نگهداری پیش‌بینانه با تصمیمات زنجیره تأمین یا موجودی پرداخته‌اند، اما تمرکز آن‌ها غالباً بر یک سطح خاص از سیستم یا یک بُعد تصمیم‌گیری محدود بوده است. به‌ویژه در این دسته از پژوهش‌ها،

پیش‌بینی خرابی و بهینه‌سازی نگهداری اغلب به‌عنوان دو مسئله مجزا بررسی شده‌اند؛ به‌گونه‌ای که خروجی مدل‌های پیش‌بینی، نقش مستقیمی در تعریف توابع هدف بهینه‌سازی ایفا نکرده است [۱۶، ۱۵ و ۱۴]. در نتیجه، پیوند داده‌محور و ساختاری میان مرحله پیش‌بینی و مرحله تصمیم‌سازی کمتر به‌صورت یکپارچه مورد توجه قرار گرفته است. از سوی دیگر، مطالعاتی که به حوزه معدن و صنایع فرآوری مواد معدنی پرداخته‌اند، عمدتاً بر معرفی چارچوب‌های مفهومی، دیجیتالی‌سازی داده‌ها یا بررسی قابلیت‌های نگهداری پیش‌بینانه در این صنعت تمرکز داشته‌اند [۱۷]. هرچند این پژوهش‌ها اهمیت بالای نگهداری هوشمند در محیط‌های معدنی را برجسته می‌سازند، اما در اغلب آن‌ها، مدل‌سازی پیش‌بینی خرابی به‌صورت محدود انجام شده و کمتر شاهد توسعه چارچوب‌های بهینه‌سازی چندهدفه مبتنی بر خروجی مدل‌های یادگیری ماشین در سطح زنجیره تأمین هستیم [۱۸]. در مجموع، پیشینه پژوهش نشان می‌دهد که ادبیات موجود از یک‌سو در حوزه پیش‌بینی خرابی تجهیزات با استفاده از یادگیری ماشین غنی شده و از سوی دیگر، رویکردهای متنوعی برای بهینه‌سازی برنامه‌های نگهداری ارائه شده است [۱۹]. با این حال، غالب این مطالعات یا بر مدل‌سازی تمرکز داشته‌اند یا بر بهینه‌سازی، و تلفیق نظام‌مند این دو در قالب یک چارچوب داده‌محور یکپارچه، به‌ویژه در بستر زنجیره تأمین صنایع فرآوری مواد معدنی، کمتر مورد بررسی قرار گرفته است [۲۰]. این وضعیت، زمینه را برای توسعه پژوهش‌هایی فراهم می‌کند که با اتصال مستقیم پیش‌بینی داده‌محور خرابی به فرآیند بهینه‌سازی تصمیمات نگهداری، شکاف میان تحلیل و عمل را در محیط‌های صنعتی واقعی کاهش دهند [۲۱، ۲۲].

بررسی پژوهش‌های داخلی نشان می‌دهد که اگرچه مطالعاتی که به‌صورت مستقیم به بهینه‌سازی هم‌زمان هزینه ریسک خرابی و هزینه‌های نگهداری در زنجیره تأمین با رویکرد ترکیبی یادگیری ماشین و الگوریتم ژنتیک پرداخته باشد، شناسایی نشده است، اما در چند حوزه مرتبط فعالیت‌های پژوهشی قابل توجهی انجام شده است [۲۳، ۲۴، ۲۵]. بخش عمده این مطالعات بر به‌کارگیری روش‌های داده‌کاوی و یادگیری ماشین برای پیش‌بینی خرابی تجهیزات یا ارزیابی قابلیت اطمینان سیستم‌ها متمرکز بوده‌اند [۲۶، ۲۷]. برخی دیگر به مدل‌سازی و بهینه‌سازی برنامه‌های نگهداری و تعمیرات با استفاده از روش‌های کلاسیک یا فراابتکاری پرداخته‌اند [۲۸، ۲۹]. همچنین، تعدادی از پژوهش‌ها در زمینه مدیریت نگهداری انجام شده‌اند که هرچند به اهمیت تصمیم‌گیری داده‌محور اشاره دارند، اما غالباً پیش‌بینی خرابی و بهینه‌سازی نگهداری را به‌صورت جداگانه بررسی کرده‌اند [۳۰، ۳۱، ۳۲]. این پراکندگی موضوعی نشان می‌دهد که

ادبیات داخلی، علی‌رغم برخورداری از مطالعات ارزشمند در حوزه‌های پیش‌بینی خرابی، نگهداری و تعمیرات و بهینه‌سازی، هنوز فاقد رویکردی یکپارچه است که بتواند خروجی مدل‌های یادگیری ماشین را به‌طور مستقیم در فرآیند بهینه‌سازی تصمیمات نگهداری در سطح زنجیره تأمین به‌کار گیرد.

جمع‌بندی مقایسه‌ای پژوهش‌های پیشین بر اساس جدول ارائه‌شده نشان می‌دهد که علی‌رغم پیشرفت‌های قابل توجه در حوزه نگهداری و تعمیرات پیش‌بینانه، خلأهای پژوهشی معناداری همچنان در ادبیات موضوع وجود دارد. نخست آن که بخش عمده مطالعات خارجی بر توسعه مدل‌های پیش‌بینی خرابی با استفاده از یادگیری ماشین متمرکز بوده‌اند و اگرچه در این پژوهش‌ها دقت پیش‌بینی بهبود یافته است، اما خروجی مدل‌ها غالباً به‌صورت توصیفی باقی مانده و به‌طور مستقیم در فرآیند تصمیم‌سازی و بهینه‌سازی نگهداری مورد استفاده قرار نگرفته است. در مقابل، پژوهش‌هایی که به بهینه‌سازی برنامه‌های نگهداری پرداخته‌اند، عمدتاً از توابع هدف ایستا یا مبتنی بر فروض تحلیلی استفاده کرده‌اند و ارتباط ساختاری آن‌ها با پیش‌بینی داده‌محور خرابی ضعیف یا غیرشفاف بوده است. دوم آن که بررسی جدول نشان می‌دهد بسیاری از مطالعات موجود یا بر یک سطح خاص از سیستم تمرکز داشته‌اند یا زنجیره تأمین را به‌صورت جزئی و غیریکپارچه در نظر گرفته‌اند. در این پژوهش‌ها، اثرات متقابل تصمیمات نگهداری در سطوح مختلف زنجیره تأمین به‌ندرت به‌صورت هم‌زمان مدل‌سازی شده و پیامدهای خرابی تجهیزات در کل زنجیره کمتر مورد توجه قرار گرفته است. این در حالی است که خرابی تجهیزات در یک بخش می‌تواند پیامدهای گسترده‌ای بر عملکرد سایر سطوح زنجیره داشته باشد و نادیده گرفتن این تعاملات، کارایی راهکارهای پیشنهادی را محدود می‌سازد. سوم، با وجود استفاده محدود برخی مطالعات از روش‌های بهینه‌سازی، اغلب آن‌ها به بهینه‌سازی تک‌هدفه یا ساده بسنده کرده‌اند و کمتر به مسئله تعادل میان اهداف متعارض، به‌ویژه هزینه ریسک خرابی و هزینه‌های برنامه‌ریزی‌شده نگهداری، پرداخته‌اند. به‌کارگیری چارچوب‌های بهینه‌سازی چندهدفه مبتنی بر داده‌های واقعی و خروجی مدل‌های یادگیری ماشین، در ادبیات موجود کمتر مشاهده می‌شود. علاوه بر این، حوزه صنایع فرآوری مواد معدنی، با وجود اهمیت بالای نگهداری تجهیزات و دسترس‌پذیری داده‌های عملیاتی، در مقایسه با سایر صنایع تولیدی سهم محدودی از این نوع مطالعات را به خود اختصاص داده است. بر این اساس، شکاف اصلی پژوهشی را می‌توان در فقدان یک چارچوب داده‌محور یکپارچه دانست که به‌طور هم‌زمان پیش‌بینی خرابی تجهیزات مبتنی بر یادگیری ماشین را به فرآیند بهینه‌سازی چندهدفه تصمیمات نگهداری در

پیش‌بینی خرابی تجهیزات صورت گرفته و از الگوریتم‌های یادگیری ماشین شامل شبکه عصبی مصنوعی، درخت تصمیم، جنگل تصادفی و گرادیان بوستینگ استفاده شده است. عملکرد این مدل‌ها با معیارهایی نظیر RMSE، MAE، MSE، ضریب تعیین و MAPE ارزیابی شده و مدل برتر انتخاب گردیده است. در سطح دوم، بهینه‌سازی چندهدفه برنامه‌های نگهداری و تعمیرات با استفاده از الگوریتم ژنتیک انجام شده است. در این مرحله، هزینه موردانتظار ریسک خرابی مبتنی بر خروجی مدل پیش‌بینی و هزینه‌های برنامه‌ریزی شده نگهداری به‌عنوان دو تابع هدف در نظر گرفته شده‌اند. تحلیل نتایج شامل بررسی جبهه پارتو و تحلیل حساسیت نسبت به تغییر پارامترهای کلیدی نظیر بودجه و ظرفیت منابع بوده است. در مجموع، روش‌شناسی پژوهش حاضر بر یک رویکرد ترکیبی داده‌محور استوار است که پیش‌بینی خرابی تجهیزات مبتنی بر یادگیری ماشین را به‌صورت مستقیم به فرآیند بهینه‌سازی چندهدفه تصمیمات نگهداری متصل می‌کند. استفاده از داده‌های واقعی بلندمدت، الگوریتم‌های یادگیری ماشین برای مدل‌سازی رفتار خرابی و الگوریتم ژنتیک برای استخراج سناریوهای بهینه، امکان ارائه راهکارهایی عملی، پایدار و قابل تعمیم را در بستر زنجیره تأمین فراهم کرده است.

۴- نتایج و بحث

۴-۱- پاک‌سازی داده‌ها

برای ساخت مدل پژوهش، ابتدا با مرور مقالات و پژوهش‌های پیشین در حوزه نگهداری و تعمیرات پیش‌بینانه، داده‌کاوی صنعتی و قابلیت اطمینان تجهیزات، شاخص‌های کلیدی مورد استفاده استخراج گردید. در این پژوهش، مجموعه داده‌ها شامل ۴۰۰ رکورد هفتگی استخراج‌شده از یک بازه زمانی ۸ ساله از زنجیره تولید کک (از استخراج زغال‌سنگ تا مرحله فرآوری) می‌باشد. داده‌ها ماهیت کمی پیوسته و شمارشی داشته و شامل ۱۰ متغیر ورودی در سه سطح زنجیره تأمین (لجستیک ورودی، عملیات تولید/فرآوری و لجستیک خروجی) و یک متغیر خروجی به‌صورت احتمال وقوع خرابی در دوره زمانی بعد است. در مرحله پاک‌سازی، ابتدا سازگاری زمانی رکوردها در بازه‌های هفتگی بررسی شد تا اطمینان حاصل شود که تمامی متغیرها به‌صورت هم‌تراز و منسجم ثبت شده‌اند. مقادیر گمشده در متغیرهای پیوسته نظیر درصد انجام PM، نسبت اضافه‌بار نقاله، امتیاز ناهنجاری وضعیت و فشار روغن هیدرولیک با استفاده از جایگزینی مبتنی بر میانه و در متغیرهای شمارشی مانند تعداد نقص‌های بازرسی و دستورکارهای اصلاحی با میانگین متحرک هفتگی جایگزین شدند. در ادامه، داده‌های پرت و مقادیر غیرواقع‌بینانه که عمدتاً در متغیرهایی مانند ساعات توقف‌های

سطح زنجیره تأمین متصل‌کننده. پژوهش حاضر با تمرکز بر این شکاف و با استفاده از خروجی مدل یادگیری ماشین به‌عنوان جزء اصلی تابع هدف الگوریتم ژنتیک، تلاش دارد پیوند میان مرحله پیش‌بینی و مرحله تصمیم‌سازی را تقویت کرده و پاسخی نظام‌مند به خلأهای شناسایی شده در ادبیات ارائه دهد.

۳- روش پژوهش

این پژوهش با هدف ارائه یک چارچوب داده‌محور برای بهینه‌سازی همزمان تصمیمات نگهداری و تعمیرات تجهیزات در زنجیره تأمین انجام شده است. منطق روش‌شناسی پژوهش بر پیوند نظام‌مند میان پیش‌بینی خرابی تجهیزات و بهینه‌سازی چندهدفه برنامه‌های نگهداری استوار است. بدین منظور، ابتدا با استفاده از داده‌های واقعی و عملیاتی، مدل پیش‌بینی خرابی مبتنی بر یادگیری ماشین توسعه داده شده و سپس خروجی مدل برتر به‌عنوان مبنای تعریف توابع هدف در مرحله بهینه‌سازی مورد استفاده قرار گرفته است. این رویکرد امکان گذار از تحلیل صرف داده‌ها به تصمیم‌سازی عملیاتی را در بستر واقعی زنجیره تأمین فراهم می‌سازد. پژوهش حاضر از نظر هدف، کاربردی است؛ زیرا نتایج آن مستقیماً در بهبود تصمیمات نگهداری و تعمیرات تجهیزات در محیط‌های صنعتی قابل استفاده است. از نظر رویکرد، تحقیق مبتنی بر داده‌محور و داده‌کاوی بوده و با استفاده از روش‌های یادگیری ماشین و بهینه‌سازی فراابتکاری انجام شده است. در این پژوهش، جامعه آماری مبتنی بر افراد انسانی تعریف نشده و تمرکز اصلی بر داده‌های عملیاتی تجهیزات در زنجیره تولید کک در صنعت مواد معدنی است. این داده‌ها از پایگاه داده سازمانی یکی از شرکت‌های فعال در حوزه مواد معدنی در منطقه البرز مرکزی گردآوری شده‌اند که کلیه فعالیت‌های نگهداری و تعمیرات تجهیزات در طول زنجیره تولید را به‌صورت منظم ثبت می‌کند. نمونه پژوهش شامل ۴۰۰ رکورد هفتگی از داده‌های واقعی عملیات نگهداری و تعمیرات طی یک دوره ۸ ساله است که رفتار تجهیزات کلیدی زنجیره تولید کک را در شرایط عملیاتی مختلف منعکس می‌کند. این زنجیره، به‌عنوان یک زنجیره تأمین سه‌سطحی، شامل لجستیک ورودی مرتبط با استخراج و انتقال زغال‌سنگ، عملیات تولید و فرآوری کک، و لجستیک خروجی محصولات فرآوری‌شده می‌باشد. فرآیند گردآوری و اجرای پژوهش به‌صورت مرحله‌ای انجام شده است. ابتدا داده‌های خام از پایگاه داده سازمانی استخراج و پس از بررسی اولیه، مراحل پیش‌پردازش شامل پاک‌سازی داده‌ها، شناسایی داده‌های پرت و آماده‌سازی داده‌ها برای تحلیل انجام شده است. تجزیه و تحلیل داده‌ها در این پژوهش در دو سطح اصلی انجام شده است. در سطح نخست، تحلیل داده‌ها با هدف

۴-۲- انتخاب مدل برتر برای پیش‌بینی خرابی تجهیزات

در این بخش، فرایند مدل‌سازی پیش‌بینی خرابی تجهیزات با هدف انتخاب الگوریتم برتر برای برآورد احتمال وقوع خرابی در دوره زمانی تشریح می‌شود:

۱. کمینه‌سازی هزینه ریسک خرابی تجهیزات بر اساس پیش‌بینی مدل XGBoost.

۲. کمینه‌سازی هزینه‌های نگهداری با توجه به محدودیت منابع، بودجه و ظرفیت اجرایی.

در این پژوهش، هر کروموزوم بیانگر یک سناریوی زمان‌بندی تعمیرات پیشگیرانه (PM) برای تمامی تجهیزات در طول بازه برنامه‌ریزی است. این بازه بر اساس داده‌های پژوهش، ۵۲ هفته (یک سال کامل) در نظر گرفته شده است. هر کروموزوم از تعدادی ژن تشکیل شده که هر ژن، تصمیم مربوط به اجرای PM برای یک تجهیز در یک هفته مشخص را مشخص می‌کند. این ژن‌ها بر اساس حالت باینری کدگذاری می‌شوند:

۱ → انجام تعمیرات پیشگیرانه (PM) در هفته مورد نظر

۰ → عدم انجام تعمیرات پیشگیرانه در هفته مورد نظر

در الگوریتم ژنتیک، تابع برازندگی معیار اصلی برای ارزیابی کیفیت هر کروموزوم (سناریوی زمان‌بندی PM) است. در این پژوهش، تابع برازندگی به صورت چندهدفه تعریف می‌شود تا همزمان دو هدف زیر را دنبال کند:

هدف ۱: تابع هدف اول: کمینه‌سازی ریسک خرابی تجهیزات

$$\text{MIN } Z1 = \sum_{i=1}^I \sum_{t=1}^T P_{i,t} \times C_{i,t}^{\text{Unplanned}} \quad (1)$$

که در آن:

$P_{i,t}$: احتمال خرابی تجهیز i در هفته t (پیش‌بینی‌شده توسط مدل XGBoost)

$C_{i,t}^{\text{Unplanned}}$: هزینه توقف غیرمنتظره تجهیز i در هفته t

لازم به ذکر است در این تابع هزینه ناشی از خرابی‌ها محاسبه می‌شود که خودش وابسته به احتمال خرابی پیش‌بینی‌شده است. این احتمال از مدل XGBoost به دست می‌آید و مقدار آن تابعی غیرمستقیم از تصمیمات PM گذشته است. یعنی وقتی در یک هفته برای تجهیز PM انجام می‌دهی، احتمال خرابی در هفته‌های بعدی کمتر می‌شود. پس در فرمول ساده‌ی $Z1$ ، متغیر تصمیم $X_{i,t}$ به شکل مستقیم ظاهر نمی‌شود، بلکه اثرش از طریق تغییر احتمال خرابی پیش‌بینی‌شده وارد محاسبات شده است.

برنامه‌ریزی‌نشده، تعداد دستورکارهای اصلاحی و انحراف ولتاژ به سرعت مشاهده می‌شدند، با استفاده از آزمون Z-Score شناسایی گردیدند. مقادیری که ناشی از خطای ثبت بودند حذف و مواردی که بازتاب‌دهنده شرایط عملیاتی خاص محسوب می‌شدند، با حفظ منطق فرایندی تعدیل شدند. همچنین بازه‌های مجاز هر متغیر بر اساس تعریف عملیاتی آن‌ها کنترل شد؛ به‌عنوان مثال، مقادیر درصدی در دامنه ۰ تا ۱۰۰ و متغیر خروجی احتمال خرابی در بازه ۰ تا ۱۰۰ درصد تثبیت گردید. این فرآیند پاک‌سازی موجب شد داده‌ها ضمن حفظ رفتار واقعی خرابی تجهیزات، از نظر آماری پایدار شده و آمادگی لازم برای مراحل بعدی مدل‌سازی پیش‌بینی و بهینه‌سازی چندهدفه فراهم گردد.

جدول (۱): متغیرهای ورودی و خروجی پژوهش بر حسب سطح زنجیره تامین

سطح زنجیره تامین	تفسیر خروجی	تعریف
لجستیک ورودی	نزدیک ۱۰۰٪ ⇒ پایداری بالا و ریسک خرابی کمتر؛ زیر ۷۵٪ هشدار	درصد فعالیت‌های PM انجام‌شده به‌موقع در بازه زمانی
لجستیک ورودی	مقدار بالاتر ⇒ بار عیب‌یابی بیشتر؛ همراه با PM پایین ⇒ ریسک خرابی بالاتر	تعداد موارد نقص کشف‌شده در بازرسی‌های دوره‌ای
لجستیک ورودی	مقدار بالاتر ⇒ فشار مکانیکی/الکتریکی بیشتر و احتمال خرابی بالاتر	درصد اضافه‌بار جریان ماده روی نقاله نسبت به ظرفیت مرجع
عملیات تولید/فرآوری	مقدار بالاتر ⇒ نرخ خرابی رخ داده بیشتر؛ شاخص پیش‌نگر برای ریسک دوره بعد	تعداد دستورکارهای تعمیرات اصلاحی ثبت‌شده
عملیات تولید/فرآوری	نزدیک ۰ ⇒ پایداری؛ نزدیک ۱۰۰ ⇒ ناهنجاری شدید و ریسک خرابی بالا	امتیاز ناهنجاری وضعیت تجهیزات (۰ تا ۱۰۰)
عملیات تولید/فرآوری	مقدار بالاتر ⇒ قابلیت اطمینان کمتر؛ همراه با PM پایین ⇒ هشدار جدی	مجموع ساعات توقف‌های برنامه‌ریزی‌نشده
عملیات تولید/فرآوری	مقدار بالاتر ⇒ تجمع کار معوق؛ ریسک افزایش خرابی در آینده	میانگین روزهای عقب‌افتادگی دستورکارهای باز
لجستیک خروجی	انحراف بالاتر ⇒ احتمال لغزش/اشکال در درایو یا بارگذاری نامتعارف	درصد انحراف سرعت واقعی از مقدار مورد انتظار بر اساس ولتاژ/فرکانس
لجستیک خروجی	مقدار بالاتر ⇒ نزدیک شدن به آستانه سرویس بعدی و ریسک خرابی بیشتر	ساعات کارکرد از آخرین PM تا زمان جاری
لجستیک خروجی	افت ⇒ نشتی یا کاهش کارایی پمپ؛ افزایش غیرعادی ⇒ انسداد یا خرابی مکانیکی	میانگین فشار روغن هیدرولیک در سیستم
متغیر خروجی کل زنجیره	مقدار بالاتر ⇒ ریسک وقوع خرابی بیشتر در بازه بعدی؛ شاخص خروجی مدل پیش‌بینی	احتمال وقوع خرابی تجهیزات در دوره زمانی بعد (۰ تا ۱۰۰٪)

هدف ۲: کمینه‌سازی هزینه نگهداری برنامه‌ریزی شده (PM)

$$\text{MIN } Z2 = \sum_{i=1}^I \sum_{t=1}^T X_{i,t} (C_{i,t}^{lab} \times C_{i,t}^{Part} + (r_{i,t}^{Plan} \times H_{i,t}^{Plan})) \quad (2)$$

که در آن:

$X_{i,t}$ - متغیر تصمیم اجرای PM برای تجهیز i در هفته t (۱)
 = انجام PM ، ۰ = عدم انجام PM

$C_{i,t}^{lab}$ - هزینه نیروی انسانی برای انجام PM تجهیز i در هفته t

$C_{i,t}^{Part}$ - هزینه قطعات مصرفی برای انجام PM تجهیز i در هفته t

$r_{i,t}^{Plan}$ - نرخ هزینه توقف برنامه‌ریزی شده (MR/H)

$H_{i,t}^{Plan}$ - ساعات توقف برنامه‌ریزی شده تجهیز i در هفته t

محدودیت‌ها:

برای واقع‌بینانه بودن مدل، دو دسته محدودیت اصلی در نظر گرفته شده است:

۱. محدودیت بودجه هفتگی: هزینه کل فعالیت‌های PM در هر هفته نباید بیش از بودجه تخصیص‌یافته همان هفته باشد.

$$\sum_{i=1}^I X_{i,t} \times C_{i,t}^{PM} \ll B_t \quad (3)$$

$C_{i,t}^{PM}$ - هزینه کل فعالیت‌های PM می‌باشد که شامل $C_{i,t}^{lab}$ (هزینه نیروی انسانی برای انجام PM تجهیز i در هفته t) و $C_{i,t}^{Part}$ (هزینه قطعات مصرفی برای انجام PM تجهیز i در هفته t)

۳-۴- ترکیب اهداف

از آن‌جا که اهداف پژوهش چندمعیاره است (کاهش ریسک خرابی و کاهش هزینه PM)، برای تبدیل به یک شاخص برازندگی واحد از روش ترکیب وزنی استفاده شده است. در این روش، پس از نرمال‌سازی مقادیر هر هدف، تابع برازندگی به‌صورت زیر تعریف می‌شود:

$$j_2 \times w_2 + j_1 \times w_1 \quad (5)$$

که در آن j_1 بیانگر هزینه ناشی از ریسک خرابی و j_2 بیانگر هزینه PM و است. ضرایب وزنی w_1 و w_2 بر اساس اولویت‌های مدیریتی تنظیم می‌گردد. جمع وزن‌ها باید یک باشند. (برای مثال در شرایط ریسک‌گریز، وزن بیشتری به j_1 داده می‌شود).

جدول (۲): معیارهای توقف GA

مؤلفه	مقدار/قاعده	توضیح
معیار توقف نسلی	۱۵۰ نسل	پایان خودکار پس از رسیدن به نسل ۱۵۰
معیار توقف زودهنگام	بهبود $\geq 1\%$ در ۱۵ نسل پیاپی	اگر بهترین برازندگی طی ۱۵ نسل کمتر از ۱٪ بهبود کند، توقف
انتخاب بهترین سناریو	بهترین برازندگی قابل اجرا	سناریوی مرجع برای گزارش نتایج
انتخاب سناریوهای جایگزین	۵ سناریوی برتر متنوع	تنوع با آستانه شباهت پایین (مثلاً همبستگی الگوی هفتگی > 0.8)
کنترل قیود	صفر نقض قید در خروجی نهایی	بودجه، ظرفیت، حداقل فاصله بین PMها رعایت شود
شاخص‌های گزارش خروجی	$Z1, Z2, Z_{1-}, Z_{2-}$ ، هزینه کل، نرخ رعایت بودجه/ظرفیت	به‌همراه هفته‌های پیک و کمینه بار PM
نخبه‌گرایی (Elitism)	۵٪	حفظ بهترین‌ها بین نسل‌ها برای جلوگیری از افت کیفیت

نرخ و ساعات توقف برنامه‌ریزی شده می‌باشند. علاوه بر این، به‌منظور واقع‌بینانه بودن مدل، دو دسته محدودیت اصلی یعنی محدودیت بودجه هفتگی و محدودیت ظرفیت منابع نیز در نظر گرفته شده‌اند. بنابراین جداول زیر مقادیر و مفروضات مربوط به این پارامترها ارائه می‌کنند تا مبنای محاسبه توابع هدف $Z1$ و $Z2$ و همچنین قیود مدل قرار گیرند.

۴-۴- ارزیابی عملکرد GA

برای محاسبه توابع هدف و اعمال محدودیت‌های مدل، مجموعه‌ای از پارامترها و داده‌های پایه موردنیاز است. این پارامترها شامل هزینه‌های مستقیم نگهداری پیشگیرانه (PM)، هزینه‌های مرتبط با نیروی انسانی، قطعات مصرفی، و همچنین

جدول (۳): هزینه های پارامترهای هدف اول (Z1)

تجهیز (i)	هزینه توقف غیرمنتظره (میلیون ریال بر ساعت)
Eq1	۱۵۰
Eq2	۱۴۰
Eq3	۱۳۵
Eq4	۱۶۰
Eq5	۱۴۵
Eq6	۱۵۵
Eq7	۱۶۵
Eq8	۱۵۰
Eq9	۱۷۰
Eq10	۱۸۰
Eq11	۱۷۵
Eq12	۱۸۵

این مقادیر نشان دهنده هزینه توقف غیرمنتظره برای هر تجهیز در یک هفته مشخص (t) هستند. فرض شده که نرخ هزینه توقف غیرمنتظره برای هر تجهیز ثابت بوده و تفاوت آن هاناشی از حساسیت و اهمیت تجهیز است. همچنین احتمال خرابی تجهیزات در هفته t بر اساس خروجی مدل XGBoost می باشد.

جدول (۴): هزینه های پارامترهای هدف دوم (Z2)

تجهیز (i)	هزینه نیروی انسانی برای انجام هر PM (میلیون ریال)	هزینه قطعات مصرفی برای هر PM (میلیون ریال)	مجموع کل هزینه های PM (میلیون ریال)	توقف برنامه ریزی شده برای هر PM (ساعت)
Eq1	۵۵	۱۲۰	۱۷۵	۸
Eq2	۵۰	۱۱۰	۱۶۰	۷
Eq3	۶۰	۱۴۰	۲۰۰	۹
Eq4	۴۸	۱۰۰	۱۴۸	۶
Eq5	۵۲	۱۱۵	۱۶۷	۷
Eq6	۵۸	۱۳۰	۱۸۸	۸
Eq7	۴۵	۹۰	۱۳۵	۶
Eq8	۶۲	۱۵۰	۲۱۲	۹
Eq9	۵۴	۱۲۵	۱۷۹	۷
Eq10	۴۷	۹۵	۱۴۲	۶
Eq11	۵۹	۱۳۵	۱۹۴	۸
Eq12	۵۳	۱۱۸	۱۷۱	۷

برای هر تجهیز، هزینه نیروی انسانی به ازای هر PM طی تمام هفته ها ثابت فرض شده است. برای هر تجهیز، هزینه قطعات مصرفی به ازای هر PM طی تمام هفته ها ثابت فرض شده است. تمام هفته ها ثابت فرض شده است. نرخ هزینه توقف برنامه ریزی شده $(P_{i,t}^{Plan})$ ۱۵ میلیون ریال/ساعت در نظر گرفته شده است.


جدول (۵): محدودیت بودجه و ظرفیت منابع انسانی

مجموع نفر-ساعت موجود	محدودیت ظرفیت منابع (ساعت)	محدودیت بودجه هفتگی (میلیون ریال)	هفته (t)
۱۵۰	۱۵۰	۱،۲۰۰	۱
۱۵۰	۱۵۰	۱،۳۰۰	۵
۱۵۵	۱۵۵	۱،۳۲۰	۷
۱۶۵	۱۶۵	۱،۴۵۰	۲۱
۱۶۰	۱۶۰	۱،۳۸۰	۲۹
۱۶۵	۱۶۵	۱،۴۲۰	۳۱
۱۷۰	۱۷۰	۱،۴۸۰	۳۹
۱۶۰	۱۶۰	۱،۳۶۰	۴۵
۱۶۲	۱۶۲	۱،۴۰۰	۵۰
۱۵۸	۱۵۸	۱،۳۵۰	۵۲
۸،۰۶۰	۸،۰۶۰	۶۸،۶۴۰	مجموع ۵۲ هفته

پس از اجرای الگوریتم ژنتیک و ارزیابی هر سناریوی زمان‌بندی PM بر اساس دو تابع هدف (کمینه‌سازی هزینه نگهداری و کمینه‌سازی ریسک خرابی)، مجموعه‌ای از راه‌حل‌های غیرقابل غلبه به دست آمد.


جدول (۶): خلاصه خروجی حل مساله بهینه‌سازی؛ سناریوی برتر

مقدار	شاخص
۶۱	تعداد PM (کل)
۱/۱۷۳	میانگین PM/هفته
۱۲۹۹۱	Z1: هزینه سالانه توقف غیرمنتظره (MR)
۴۵۵۰۸	Z2: هزینه سالانه PM برنامه‌ریزی شده (MR)
۲۵۹۹۸	تابع برازندگی وزنی ($w_1=0.6$, $w_2=0.4$)
۱۷۰۴ (هفته ۴۴)	بیشترین هزینه هفتگی
۸۹۴ (هفته ۴۹)	کمترین هزینه هفتگی
در همه هفته ها	هفته‌های انجام PM
۱/۱	میانگین فاصله بین PMها (هفته)
۰	نقض قید فاصله ≤ 2 هفته




شکل (۲): همگرایی الگوریتم ژنتیک در طول نسل‌ها (بهترین و میانگین برازندگی)

هر دو نمودار با افزایش نسل‌ها روند نزولی دارند و به ناحیه‌ای پایدار نزدیک می‌شوند؛ ابتدا فاصله بین بهترین و میانگین زیاد است (تنوع بالا و کیفیت پایین‌تر جمعیت)، اما این فاصله به تدریج کم می‌شود که نشان‌دهنده بهبود جمعیت و همگرایی الگوریتم به یک ناحیه پاسخ با کیفیت است.



شکل (۳): مسیر تغییر بهترین جواب‌ها برای توابع هدف Z1 و Z2 در طول نسل‌ها

همان‌طور که مشاهده می‌شود، مقادیر اولیه Z1 و Z2 در نسل‌های ابتدایی بالا هستند که نشان‌دهنده کیفیت پایین راه‌حل‌ها است. با تکرار نسل‌ها، الگوریتم ژنتیک توانسته است




شکل (۱): پارتو بین تابع هدف اول (هزینه ریسک خرابی) و تابع هدف دوم (هزینه نگهداری پیشگیرانه)

نمودار بالا نقاط هفتگی را و جبهه پارتو را (خط با برچسب شماره هفته) نشان می‌دهد؛ در پارتو هیچ نقطه‌ای وجود ندارد که همزمان Z1 و Z2 را از نقطه دیگری کمتر یا مساوی و حداقل در یکی کمتر داشته باشد. نقاط روی خط قرمز، سناریوهای غیربرتر را حذف کرده و مجموعه‌ای از گزینه‌های بهینه‌ی مبادله‌ای را ارائه می‌دهند؛ با کاهش Z1 معمولاً Z2 افزایش می‌یابد و بالعکس. اعداد کوچک کنار نمودار می‌بینید که مثلاً هفته‌های ۲۶، ۲۷، ۲۸، ۲۹، ۳۰ روی جبهه پارتو هستند؛ به ترتیب از Z1 بالاتر/Z2 پایین‌تر تا Z1 پایین‌تر/Z2 بالاتر حرکت می‌کنیم. تصمیم‌گیرنده می‌تواند با توجه به اولویت هزینه ریسک خرابی یا هزینه PM، یکی از نقاط پارتو را انتخاب کند (مثلاً اگر ریسک‌گریزی بالاست، هفته ۲۹ با Z1 پایین‌تر جذاب‌تر است؛ اگر کنترل هزینه PM مهم‌تر است، هفته ۲۴-۲۶ مناسب‌تر خواهند بود).



محور افقی وزن $W1$ (سهم $Z1$) است؛ محور عمودی چپ مقدار $Z1$ (خط ممتد) و محور عمودی راست مقدار $Z2$ (خط چین) برای سناریوی منتخب در هر وزن را نشان می‌دهد. برای هر $W1$ ، سناریویی که کمینه‌ی برانندگی نرمال شده $W1.Z1 + (1-W1).Z2$ را دارد انتخاب شده است؛ بنابراین منحنی‌های پله‌ای‌اند (با تغییر وزن، نقطه منتخب جهش می‌کند). مشاهده می‌شود با افزایش $W1$ (تأکید بیشتر بر $Z1$)، پاسخ منتخب به سمت سناریوهایی می‌رود که $Z1$ پایین‌تر و در نتیجه $Z2$ بالاتر دارند؛ برعکس، وقتی $W1$ کوچک است، سناریوهای با $Z2$ پایین‌تر انتخاب می‌شوند ولو اینکه $Z1$ بزرگ‌تر بماند. نمودار نشان می‌دهد برای هر وزن، کدام هفته به عنوان پاسخ منتخب انتخاب شده و مقادیر $Z1$ و $Z2$ متناظر آن چیست. افزایش وزن به یک تابع در بهینه‌سازی چندهدفه به معنی این نیست که مقدار آن تابع بالاتر می‌رود، بلکه به معنی این است که آن تابع اهمیت بیشتری در انتخاب جواب‌ها پیدا می‌کند.

مقادیر بهینه هر دو تابع را کاهش دهد. روند نزولی $Z1$ سریع‌تر است زیرا با افزایش PM هاریسک خرابی به سرعت کاهش پیدا می‌کند، اما $Z2$ کاهش ملایم‌تری دارد چون هزینه‌های PM به صورت مستقیم وابسته به تصمیمات نگهداری است. در نسل‌های پایانی هر دو منحنی به یک سطح پایدار می‌رسند که نشان‌دهنده همگرایی الگوریتم و دستیابی به جبهه پارتو باثبات است.

۴-۵- تحلیل حساسیت




شکل (۴): تحلیل حساسیت توابع $Z1$ و $Z2$ بر حسب ضریب $w1$



شکل (۵): تحلیل حساسیت $Z2$ نسبت به قیمت قطعات (چپ) و $Z1$ نسبت به احتمال خرابی (راست)

نسبت بالا/پایین می‌برد. نتیجه این است که $Z2$ به طور مستقیم به قیمت قطعات حساس است، و $Z1$ مستقیماً به تغییرات احتمال خرابی واکنش نشان می‌دهد؛ شدت اثر هر کدام متناسب با مقیاس پایه همان تابع در هفته‌های می‌شود.

در نمودار سمت چپ، افزایش ۲۰٪ قیمت قطعات مصرفی باعث جابه‌جایی صعودی یکنواخت منحنی $Z2$ در تمام هفته‌ها و کاهش ۲۰٪ موجب افت متناسب شده است. در نمودار سمت راست، افزایش/کاهش ۲۰٪ احتمال خرابی نیز $Z1$ را به همان



شکل (۶): مقایسه روند هزینه کل هفتگی ($Z1+Z2$) در طول ۵۲ هفته تحت سقف هم‌زمانی ۴، ۶ و ۸ تجهیز

مستقیم قطعات" تعادل ایجاد کند. نتایج نشان داد، خرابی‌های پیش‌بینی شده در سطح استخراج، اثر دومینویی بر هزینه‌های توقف در سطح فرآوری دارد؛ لذا بهینه‌ساز با اولویت‌دهی به PM در بالادست زنجیره، ریسک Z1 را به طور معناداری کاهش داده است. همچنین، پله‌ای بودن نمودار تحلیل حساسیت تایید می‌کند که سیستم نسبت به تغییر وزن‌های مدیریتی (w1) رفتاری هوشمند دارد و تنها زمانی استراتژی خود را تغییر می‌دهد که هزینه ریسک خرابی از آستانه بحرانی فراتر رود. این امر نشان‌دهنده پایداری مدل پیشنهادی در مواجهه با نوسانات بودجه‌ای سازمان است.

۵- بحث و نتیجه‌گیری

مسئله اصلی این پژوهش، نبود یک چارچوب داده‌محور یکپارچه برای پیوند میان پیش‌بینی خرابی تجهیزات و تصمیم‌سازی بهینه در برنامه‌ریزی نگهداری و تعمیرات در زنجیره تأمین است. در پاسخ به این مسئله، پژوهش حاضر یک فرایند مرحله‌ای شامل پاک‌سازی داده‌های واقعی صنعتی، مدل‌سازی پیش‌بینی خرابی با الگوریتم‌های یادگیری ماشین و بهینه‌سازی چندهدفه مبتنی بر الگوریتم ژنتیک را دنبال کرده است. هدف نهایی، حداقل‌سازی همزمان هزینه ریسک خرابی و هزینه‌های برنامه‌ریزی‌شده نگهداری با اتکا به خروجی مدل پیش‌بینی بوده است. نتایج به‌دست‌آمده امکان ارزیابی کارایی این رویکرد ترکیبی و تبیین نقش آن در بهبود تصمیم‌گیری نگهداری در سطح زنجیره تأمین را فراهم می‌سازد. یافته‌های پژوهش نشان داد که XGBoost با ایجاد تعادل مناسب میان دقت پیش‌بینی، پایداری و توان توضیح‌دهندگی، به‌عنوان مدل مرجع برای برآورد احتمال خرابی انتخاب شد و خروجی آن مبنای تعریف تابع هدف اول (Z1) قرار گرفت. در مرحله بهینه‌سازی، الگوریتم ژنتیک با کدگذاری باینری سناریوهای PM و اعمال قیود بودجه، ظرفیت و فاصله زمانی، توانست مجموعه‌ای از راه‌حل‌های غیرقابل غلبه را استخراج کند که مبادله‌ای روشن میان کاهش ریسک خرابی و افزایش هزینه‌های برنامه‌ریزی‌شده PM را نشان می‌دهند. تحلیل جبهه پارتو بیانگر آن است که افزایش شدت PM لزوماً به کاهش هزینه کل منجر نمی‌شود و انتخاب سناریوی بهینه به اولویت‌های مدیریتی و میزان ریسک‌گریزی سازمان وابسته است. همگرایی مناسب الگوریتم و پایداری نتایج در تحلیل حساسیت، کارایی رویکرد پیشنهادی را تأیید می‌کند. در مقایسه مفهومی با ادبیات موجود، این پژوهش فراتر از مطالعاتی قرار می‌گیرد که یا صرفاً به پیش‌بینی خرابی پرداخته‌اند یا به بهینه‌سازی نگهداری با فروض ایستا و مدل‌های ریاضی صریح متکی بوده‌اند. اتصال مستقیم خروجی مدل یادگیری ماشین به تابع هدف بهینه‌سازی، شکاف

-محدودیت انجام PM برای ۴ تجهیز در طول هفته (خط وسط - مبنا): تعادل نسبی بین هزینه‌های PM و ریسک خرابی برقرار است.

-محدودیت انجام PM برای ۶ تجهیز در طول هفته (خط بالا - خط‌چین): با کاهش سقف PM، هزینه‌های برنامه‌ریزی‌شده کمتر شده ولی به دلیل افزایش ریسک خرابی، هزینه کل در بیشتر هفته‌ها بالاتر از حالت تعادل است.

-محدودیت انجام PM برای ۸ تجهیز در طول هفته (خط پایین - خط‌چین): با افزایش سقف PM، ریسک خرابی کاهش یافته ولی هزینه‌های PM رشد کرده است؛ در برخی هفته‌ها هزینه کل پایین‌تر از حالت تعادل است، اما در بقیه مواقع به علت PM اضافی هزینه کل بالا می‌رود.

جدول (۷): مقایسه‌ای میانگین و مجموع هزینه کل هفتگی

(Z1+Z2) در سه سناریو

سناریو	میانگین هزینه کل (میلیون ریال)	مجموع هزینه کل سالانه (میلیون ریال)
سقف ۴ تجهیز	۲۰۴۴,۷	۱۰۶,۳۲۲
سقف ۶ تجهیز	۲۵۲۷,۳	۱۳۱,۴۲۲
سقف ۸ تجهیز	۰۱۰,۳	۱۵۶,۵۲۲

نتایج نشان می‌دهد سقف هم‌زمانی ۶ تجهیز بهترین نقطه تعادل است، زیرا در مقایسه با ۴ و ۸ هزینه کل در اکثر هفته‌ها کمتر یا متعادل‌تر باقی می‌ماند. الگوریتم ژنتیک توانست به‌خوبی تعادل میان دو هدف اصلی یعنی کاهش هزینه ریسک خرابی (Z1) و کاهش هزینه‌های برنامه‌ریزی‌شده (Z2) را برقرار کند. نتایج نشان داد که افزایش تعداد PM به کاهش محسوس Z1 منجر می‌شود اما همزمان Z2 را بالا می‌برد و این مبادله روی جبهه پارتو به‌وضوح نمایان شد. نمودارهای روندی و همگرایی نیز اثبات کردند که الگوریتم به سمت پاسخ‌های پایدار و کارا حرکت کرده است. در بخش تحلیل حساسیت مشخص شد که تغییر در بودجه و ظرفیت منابع بیشترین تأثیر را بر هزینه کل دارد، همچنین نوسان در قیمت قطعات مصرفی مستقیماً Z2 و تغییر در احتمال خرابی تجهیزات مستقیماً Z1 را جابه‌جا می‌کند. این نتایج نشان می‌دهد که تصمیم‌گیرندگان باید بر مدیریت مؤثر متغیرهای کلیدی و تنظیم درست ضرایب اولویت (وزن‌ها) تمرکز کنند تا در شرایط مختلف به نقطه تعادل بهینه دست یابند. تحلیل خروجی‌های حاصل از پیوند مدل XGBoost و الگوریتم ژنتیک نشان‌دهنده یک تغییر پارادایم از نگهداری زمان‌محور به نگهداری ریسک‌محور است. برتری مدل ثابت کرد که الگوهای خرابی در زنجیره تأمین مواد معدنی، خطی نبوده و به شدت تحت تأثیر تداخلات عملیاتی سطوح سه‌گانه زنجیره است. تفسیر جبهه پارتو آشکار می‌سازد که نقطه بهینه عملیاتی در هفته‌هایی رخ می‌دهد که الگوریتم توانسته است بین "هزینه فرصت توقف" و "هزینه

فرآوری مواد معدنی استخراج شده‌اند و تعمیم مستقیم نتایج به سایر صنایع نیازمند احتیاط است. همچنین برخی پارامترهای هزینه‌ای به‌صورت ثابت فرض شده‌اند که می‌تواند در شرایط واقعی دچار نوسان شود. افزون بر این، اگرچه الگوریتم ژنتیک کارایی مناسبی نشان داد، اما هزینه محاسباتی آن در مسائل با ابعاد بزرگ‌تر می‌تواند افزایش یابد. با توجه به یافته‌های این پژوهش، پیشنهاد می‌شود در پژوهش‌های آتی از شبکه‌های عصبی پیچشی (CNN) یا حافظه طولانی کوتاه‌مدت (LSTM) برای تحلیل داده‌های سری زمانی حسگرهای نصب‌شده روی تجهیزات استفاده شود تا دقت پیش‌بینی خرابی در لحظه ارتقا یابد. همچنین با توجه به نوسانات نرخ ارز و تأثیر آن بر قیمت قطعات، پیشنهاد می‌شود از رویکرد بهینه‌سازی استوار برای مدیریت عدم قطعیت در هزینه‌های Z2 استفاده گردد. پژوهش‌های آتی می‌توانند با توسعه مدل‌های پیش‌بینی مبتنی بر یادگیری عمیق، دقت برآورد احتمال خرابی را افزایش دهند و اثر آن را بر بهینه‌سازی بررسی کنند. همچنین استفاده از الگوریتم‌های تکاملی چندهدفه پیشرفته‌تر و مقایسه آن‌ها با GA می‌تواند به بهبود کیفیت جبهه پارتو منجر شود. گسترش چارچوب پیشنهادی به زنجیره‌های تأمین چندسایته و لحاظ عدم قطعیت‌های اقتصادی و عملیاتی به‌صورت پویا، از دیگر مسیرهای پژوهشی پیشنهادی است. در مجموع، این پژوهش با ارائه یک چارچوب داده‌محور ترکیبی، نشان داد که اتصال مستقیم مدل پیش‌بینی خرابی مبتنی بر یادگیری ماشین به فرآیند بهینه‌سازی چندهدفه می‌تواند تصمیم‌سازی نگهداری و تعمیرات را از سطح واکنشی به سطح پیش‌نگر و هوشمند ارتقا دهد. نتایج حاصل، علاوه بر افزایش دقت پیش‌بینی، امکان برقراری تعادل مؤثر میان کاهش ریسک خرابی و کنترل هزینه‌های نگهداری را فراهم ساخته و ارزش نظری و کاربردی قابل توجهی برای مدیریت زنجیره تأمین تجهیزات ایجاد می‌کند.

۶- مراجع

- [1] R. van Dinter, B. Tekinerdogan, and C. Catal, "Predictive maintenance using digital twins: A systematic literature review," *Information and Software Technology*, vol. 151, Art. no. 107008, 2022, doi: 10.1016/j.infsof.2022.107008.
- [2] D. K. Yadav, A. Kaushik, and N. Yadav, "Predicting machine failures using machine learning and deep learning algorithms," *Sustainable Manufacturing and Service Economics*, vol. 3, no. 1, pp. 1–10, 2024, doi: 10.1016/j.smse.2024.100029.
- [3] R. Zimmermann and P. Brandtner, "From data to decisions: Optimizing supply chain management with machine learning-infused dashboards," *Procedia Computer Science*, vol. 237, pp. 955–964, 2024, doi: 10.1016/j.procs.2024.05.184.
- [4] A. Benhanifia, Z. Ben Cheikh, P. M. Oliveira, A. Valente, and J. Lima, "Systematic review of predictive maintenance practices in the manufacturing sector," *Intelligent Systems with Applications*, vol. 26, Art. no. 200501, 2025, doi: 10.1016/j.iswa.2025.200501.
- [5] M. M. Ershadi, M. Momeni Sharifabad, M. J. Ershadi, A. Azizi, and S. Behzadipour, "Multi-objective modeling of green vehicle routing problem using a hybrid extreme learning machine

میان پیش‌بینی و تصمیم‌سازی را پوشش داده و چارچوبی یکپارچه برای مدیریت نگهداری در سطح زنجیره تأمین ارائه می‌دهد. همچنین تمرکز بر داده‌های واقعی بلندمدت و چندسطحی، تمایز روش‌شناختی این پژوهش را نسبت به مطالعات تک‌سطحی یا مبتنی بر شبیه‌سازی‌های محدود برجسته می‌سازد. از منظر نظری، پژوهش حاضر به توسعه ادبیات نگهداری و تعمیرات داده‌محور کمک می‌کند و نشان می‌دهد که مدل‌های پیش‌بینی زمانی ارزش‌افزوده واقعی ایجاد می‌کنند که در قالب توابع هدف تصمیم‌سازی به‌کار گرفته شوند. چارچوب پیشنهادی، پیوند میان یادگیری ماشین، بهینه‌سازی چندهدفه و مدیریت زنجیره تأمین را تقویت کرده و مبنایی برای توسعه مدل‌های ترکیبی پیشرفته‌تر در حوزه تصمیم‌گیری عملیاتی فراهم می‌آورد. در سطح مدیریتی، نتایج پژوهش ابزار عملی برای مدیران نگهداری و زنجیره تأمین فراهم می‌کند تا به‌جای اتکا به برنامه‌های زمان‌بندی ثابت، از سناریوهای بهینه مبتنی بر ریسک و هزینه استفاده کنند. نخست، چارچوب پیشنهادی این پژوهش به مدیران نگهداری و زنجیره تأمین امکان می‌دهد برنامه‌ریزی نگهداری را از حالت تقویمی و تجربه‌محور به یک تصمیم‌سازی مبتنی بر ریسک پیش‌بینی‌شده تبدیل کنند. استفاده از خروجی مدل XGBoost به‌عنوان ورودی مستقیم تابع هدف Z1، باعث می‌شود تصمیمات PM مستقیماً بر اساس احتمال واقعی خرابی تجهیزات اتخاذ شده و منابع نگهداری به تجهیزاتی تخصیص یابد که بیشترین سهم را در کاهش هزینه توقف‌های غیرمنتظره دارند. دوم، نتایج بهینه‌سازی و جبهه پارتو استخراج‌شده، ابزار عملی برای تنظیم سیاست‌های نگهداری متناسب با محدودیت‌های بودجه و ظرفیت منابع فراهم می‌کند. مدیران می‌توانند با انتخاب نقاط مختلف روی جبهه پارتو، سطح ریسک‌پذیری خود را به‌صورت شفاف اعمال کرده و سناریوی نگهداری را بر اساس اولویت کاهش ریسک خرابی یا کنترل هزینه‌های PM تنظیم نمایند؛ امری که در محیط‌های صنعتی با نوسان منابع و فشار هزینه‌ای اهمیت بالایی دارد. سوم، تحلیل حساسیت انجام‌شده نشان می‌دهد که پارامترهایی نظیر وزن‌دهی اهداف، قیمت قطعات مصرفی و سقف هم‌زمانی انجام PM بیشترین اثر را بر هزینه کل دارند. این یافته به مدیران کمک می‌کند تا به‌جای مداخلات کلی، بر اهرم‌های کلیدی تصمیم‌سازی تمرکز کرده و با تنظیم هدفمند این متغیرها، عملکرد نگهداری را در شرایط مختلف عملیاتی بهینه‌سازی کنند. در نتیجه، خروجی پژوهش می‌تواند به‌عنوان مبنای طراحی سیستم‌های پشتیبان تصمیم برای مدیریت هوشمند نگهداری در زنجیره تأمین مورد استفاده قرار گیرد. با وجود نتایج قابل اتکا، این پژوهش با محدودیت‌هایی مواجه است. داده‌ها از یک زنجیره تولید مشخص در صنعت

- Applications of Artificial Intelligence, vol. 119, Art. no. 105749, 2023, doi: 10.1016/j.engappai.2022.105749.
- [20] A. Theissler, J. Pérez-Velázquez, M. Kettelgerdes, and G. Elger, "Predictive maintenance enabled by machine learning: Use cases and challenges in the automotive industry," *Reliability Engineering & System Safety*, vol. 215, Art. no. 107864, 2021, doi: 10.1016/j.res.2021.107864.
- [21] E. Traini, G. Bruno, G. D'Antonio, and F. Lombardi, "Machine learning framework for predictive maintenance in milling," *IFAC-PapersOnLine*, vol. 52, no. 13, pp. 177–182, 2019, doi: 10.1016/j.ifacol.2019.11.172.
- [22] Y.-C. Tsao, A. Pantisoontorn, T.-L. Vu, and T.-H. Chen, "Optimal production and predictive maintenance decisions for deteriorated products under advance-cash-credit payments," *International Journal of Production Economics*, vol. 269, Art. no. 109132, 2024, doi: 10.1016/j.ijpe.2023.109132.
- [23] S. Ahmadi and R. Yousefpour, "A hybrid data mining and data-driven supply chain modeling algorithm for warehouse allocation and warehouse-to-customer service," *Journal of Industrial Management Perspective*, vol. 11, no. 3, pp. 269–295, 2021 (in Persian).
- [24] S. Asadi Shomia, S. Nosratpanah, and M. M. Mohtadi, "Assessing organizational readiness for implementing an online computerized maintenance management system," *Andisheh Amad Journal*, vol. 20, no. 76, pp. 1–34, 2021 (in Persian).
- [25] M. Esmaeili, L. Alfati, M. Amiri, and I. Raeisi Vanani, "Classification and allocation of suppliers to customers in a resilient supply chain using machine learning approaches," *Journal of Industrial Management Perspective*, vol. 13, no. 3, pp. 39–70, 2023 (in Persian).
- [26] M. Esmaili and Z. Goodarzi, "Application of game theory approach in selected maintenance problems," *Journal of Industrial Engineering*, vol. 52, no. 3, pp. 309–324, 2018 (in Persian).
- [27] F. Afsharnia and A. Marzban, "Investigating the long-term effect of preventive maintenance strategy on operational efficiency and failure rate trend using time series analysis," *Journal of Agricultural Machinery*, vol. 10, no. 2, pp. 347–359, 2020 (in Persian).
- [28] M. Pourhabib Yekta Sharmi and R. Shafaei, "Optimal solution of supply chain management problem in thermal power plants," *International Journal of Industrial Engineering and Production Management*, vol. 28, no. 3, pp. 447–458, 2017 (in Persian).
- [29] R. Taghipour and S. Avakh Dastani, "Selecting an appropriate maintenance strategy using a fuzzy hierarchical approach," *Industrial Management Studies*, vol. 16, no. 50, pp. 193–228, 2018 (in Persian).
- [30] M. Touhidi and H. Fayyazi, "Presenting aircraft maintenance strategies based on total productive maintenance approach," *Interdisciplinary Studies of Strategic Knowledge*, vol. 14, no. 57, pp. 147–171, 2024 (in Persian).
- [31] M. M. Mohtadi, "The conceptualization of sustainable resistive maintenance as an indigenous maintenance strategy (research action: a military organization)," *Supply Chain Management*, vol. 23, no. 72, pp. 71–82, 2022, doi: 10.1001.1.20089198.1400.23.72.6.2 (in Persian).
- [32] M. Mohammadi, S. Khalili, S. Ramezani, and M. Mosadegh-Khah, "Presentation of a decision-making model for long-term storage (conservation) of defense items (case study: armor equipments)," *Supply Chain Management*, vol. 26, no. 85, pp. 89–105, 2025, doi: 10.1001.1.20089198.1403.26.85.6.9 (in Persian).
- and genetic programming," *Supply Chain Management*, vol. 25, no. 81, pp. 17–41, 2024 (in Persian).
- [6] S. Abedi, M. R. Karimi, and A. Alinezhad, "Predicting and analyzing pathways toward sustainable development of the mining sector under the NZE scenario," *Journal of Mining and Environment*, in press, 2025, doi: 10.22044/jme.2025.16846.3304.
- [7] A. Boujarif, D. W. Coit, O. Jouini, Z. Zeng, and R. Heidsieck, "Repairing smarter: Opportunistic maintenance for a closed-loop supply chain with spare parts dependency," *Reliability Engineering & System Safety*, vol. 255, Art. no. 110642, 2025, doi: 10.1016/j.res.2024.110642.
- [8] Bahramzad, M., Abedi, S. and Ehtesham Rasi, R. (2027). Designing a Predictive Model for Product Acceptance Rate in Lean Manufacturing Using an Artificial Neural Network. *System Engineering and Productivity*, 6(4), 55–80. doi: 10.22034/sep.2026.2079391.1442
- [9] U. Dereci and G. Tuzkaya, "An explainable artificial intelligence model for predictive maintenance and spare parts optimization," *Supply Chain Analytics*, vol. 8, Art. no. 100078, 2024, doi: 10.1016/j.sca.2024.100078.
- [10] Bahramzad, M., Abedi, S. and Ehtesham Rasi, R. (2026). A data-driven approach to extracting rules governing product acceptance rates in a lean production environment: A case study of Zar Food Industries. (e733999). *Modern Research in Decision Making*, 0, e733999
- [11] N. Elkhenin and H. Mrad, "Maintenance 4.0 in mining trucks: Data digitalization and advanced protocols," *Procedia Computer Science*, vol. 253, pp. 2147–2155, 2025, doi: 10.1016/j.procs.2025.01.275.
- [12] M. Gallab, H. Bouloiz, E. Garbolino, M. Tkiouat, M. A. Elkilani, and N. Bureau, "Risk analysis of maintenance activities in a LPG supply chain with a multi-agent approach," *Journal of Loss Prevention in the Process Industries*, vol. 47, pp. 41–56, 2017, doi: 10.1016/j.jlp.2017.02.026.
- [13] J. Li, J. Milisavljevic-Syed, and K. Salonitis, "Predictive maintenance servitisation pathways," *IFAC-PapersOnLine*, vol. 58, no. 8, pp. 329–334, 2024, doi: 10.1016/j.ifacol.2024.08.142.
- [14] H. Lin, J. Lin, and F. Wang, "An innovative machine learning model for supply chain management," *Journal of Innovation & Knowledge*, vol. 7, no. 4, Art. no. 100276, 2022, doi: 10.1016/j.jik.2022.100276.
- [15] Y.-Y. Liu, K.-H. Chang, and Y.-Y. Chen, "Simultaneous predictive maintenance and inventory policy in a continuously monitoring system using simulation optimization," *Computers & Operations Research*, vol. 153, Art. no. 106146, 2023, doi: 10.1016/j.cor.2023.106146.
- [16] P. Mallioris, E. Aivazidou, and D. Bechtsis, "Predictive maintenance in Industry 4.0: A systematic multi-sector mapping," *CIRP Journal of Manufacturing Science and Technology*, vol. 50, pp. 80–103, 2024, doi: 10.1016/j.cirpj.2024.02.003.
- [17] A. Murtaza, A. Saher, M. H. Zafar, S. K. R. Moosavi, M. F. Aftab, and F. Sanfilippo, "Paradigm shift for predictive maintenance and condition monitoring from Industry 4.0 to Industry 5.0," *Results in Engineering*, vol. 24, Art. no. 102935, 2024, doi: 10.1016/j.rineng.2024.102935.
- [18] P. Nunes, J. Santos, and E. Rocha, "Challenges in predictive maintenance – A review," *CIRP Journal of Manufacturing Science and Technology*, vol. 40, pp. 53–67, 2023, doi: 10.1016/j.cirpj.2022.11.004.
- [19] B. Shaheen, A. Kocsis, and I. Németh, "Data-driven failure prediction and RUL estimation of mechanical components using accumulative artificial neural networks," *Engineering*