*Journal of Operational Research in its Applications*
*Vol.23, NO.1, Spring 2026*
*ISSN: 2251-7286*
*DOI: 10.71773/jamlu-2026-1-2322*

# A Machine Learning-Based Decision-Making Framework for the Green Flexible Job Shop Scheduling Problem Considering Preventive Maintenance

B. Espidkar[1], A. Mehrabian[2*], F. Harsej[3], H. Amoozad Khalili[4]
[1] *Ph.D. Student, Department of Industrial Engineering, AK.C., Islamic Azad University, Aliabad Katoul, Iran,*
[2] *Assistant Professor, Department of Industrial Engineering, AK.C., Islamic Azad University, Aliabad Katoul, Iran,*
[3] *Assistant Professor, Department of Industrial Engineering, No.C., Islamic Azad University, Noor, Iran,*
[4] *Associate Professor, Department of Industrial Engineering, Sar.C., Islamic Azad University, Sari, Iran.*

***Research Paper***

**Received:** 22 July 2025
**Accepted:** 10 January 2026

**Abstract:** This study focuses on one of the critical issues in manufacturing systems, namely the Flexible Job Shop Scheduling Problem (FJSP), which is addressed with considerations for environmental aspects and preventive maintenance. In this regard, the present paper develops a machine learning–based decision-making framework. To achieve this objective, a mathematical model is proposed that aims to minimize delivery tardiness, greenhouse gas emissions, and energy consumption, while incorporating preventive maintenance operations. To handle uncertainty, a data-driven approach based on fuzzy optimization and the Random Forest Regression (RFR) algorithm is developed. Subsequently, to tackle the multi-objective nature and complexity of the proposed model, an efficient solution approach combining a Genetic Algorithm (GA) with a normalized weighted sum method is presented. A sensitivity analysis is then conducted to examine the impact of key model parameters on the problem. The results indicate the efficiency and effectiveness of the proposed approach, as it is capable of delivering high-quality solutions within a reasonable computational time. Moreover, the developed machine learning algorithm provides reliable estimations of key parameters. According to the findings, an increase in processing time significantly raises total tardiness, greenhouse gas emissions, and energy consumption. Additionally, the results show that as the setup time parameter increases, all three objective functions—tardiness, emissions, and energy usage—also increase.

**Introduction:** This study aims to develop a data-driven and environmentally conscious decision-making framework for the Flexible Job Shop Scheduling Problem (FJSP) by integrating green manufacturing objectives with preventive maintenance considerations.

**Materials and Methods:** A multi-objective mixed-integer linear programming model was formulated to minimize total tardiness and environmental impacts such as energy consumption and carbon emissions. A robust fuzzy programming approach was adopted to manage uncertainty in processing times. Furthermore, a Random Forest Regression (RFR) algorithm was utilized to predict uncertain process durations based on shop-floor features. The final integrated model was solved using a Genetic Algorithm (GA) combined with a normalized weighted sum method to balance efficiency and accuracy.

* *Corresponding Author: mehrabian.project@iau.ac.ir*

**Results and Discussion:** The integrated hybrid approach significantly enhanced scheduling performance while reducing environmental impacts. The RFR-based estimations improved the model's realism and adaptability, and the GA exhibited strong capability in addressing the multi-objective and nonlinear nature of the optimization problem. Sensitivity analysis confirmed that variations in processing and setup times directly influence tardiness, energy consumption, and emissions, validating the robustness of the proposed framework under different operating conditions.

**Conclusions:** In conclusion, the development of an integrated, data-driven approach to the flexible job shop scheduling problem—considering both green objectives and preventive maintenance—offers a valuable pathway toward sustainable and efficient production planning. The proposed framework enables manufacturing organizations to effectively manage uncertainty, minimize environmental footprints, and enhance operational performance. By integrating predictive machine learning techniques with robust optimization, this study provides practical decision-support tools for complex and dynamic production systems. Industrial practitioners are encouraged to adopt and adapt such intelligent scheduling strategies to achieve higher levels of sustainability and productivity.

---

**Keywords:** Flexible Job Shop Scheduling, Preventive Maintenance, Machine Learning–Based Decision-Making, Genetic Algorithm.

مجله تحقیق در عملیات در کاربردهای آن، سال بیست و سوم، شماره اول (پیاپی ۸۸)،بهار ۰۵، ص ص ۱۱۸-۹۳
شاپا ۷۲۸۶-۲۲۵۱
*DOI: 10.71773/jamlu-2026-1-2322*

# چارچوب تصمیم‌گیری مبتنی بر یادگیری ماشین برای مساله زمان‌بندی جریان کارگاهی انعطاف‌پذیر سبز با در نظر گرفتن تعمیرات پیشگیرانه

**بهزاد اسپیدکار[۱]، احمد مهرابیان[۲*] ، فاطمه هرسج[۳]، حسین عموزاد خلیلی[۴]**
۱- دانشجوی دکتری، گروه مهندسی صنایع، واحد علی آباد کتول، دانشگاه آزاد اسلامی، علی آباد کتول، ایران.
۲- استادیار، گروه مهندسی صنایع، واحد علی آباد کتول، دانشگاه آزاد اسلامی، علی آباد کتول، ایران.
۳- استادیار، گروه مهندسی صنایع، واحد نور، دانشگاه آزاد اسلامی، نور، ایران.
۴- دانشیار، گروه مهندسی صنایع، واحد ساری، دانشگاه آزاد اسلامی، ساری، ایران.

رسید مقاله: ۳۱ تیر ۱۴۰۴
پذیرش مقاله: ۲۰ دی ۱۴۰۴

## چکیده

این مطالعه بر یکی از مسایل مهم در سیستم‌های تولیدی با عنوان مساله زمان‌بندی کارگاه جریان انعطاف‌پذیر تمرکز دارد که با در نظر گرفتن جنبه‌های زیست‌محیطی و نگهداری و تعمیرات پیشگیرانه بررسی شده است. در همین راستا، مقاله حاضر یک چارچوب تصمیم‌گیری مبتنی بر یادگیری ماشین توسعه داده است. به‌منظور دستیابی به این هدف، یک مدل ریاضی ارایه شده است که در آن کمینه‌سازی تاخیر در تحویل، انتشار گازهای گلخانه‌ای و مصرف انرژی مدنظر قرار گرفته، به‌طوری‌که عملیات نگهداری و تعمیرات پیشگیرانه نیز در آن لحاظ شده است. سپس، برای مقابله با عدم قطعیت، یک رویکرد داده‌محور بر پایه بهینه‌سازی فازی و الگوریتم جنگل تصادفی رگرسیونی توسعه شده است. در مرحله بعد، برای مواجهه با ماهیت چندهدفه مدل پیشنهادی و پیچیدگی‌های آن، یک رویکرد حل مساله کارا با ترکیب الگوریتم ژنتیک و روش مجموع وزنی بی‌مقیاس شده ارایه شده است. پس از آن، تحلیل حساسیت انجام شده تا تاثیر پارامترهای کلیدی مدل بر مساله تحقیق مشخص شود. نتایج به‌دست‌آمده نشان‌دهنده عملکرد قابل قبول رویکرد پیشنهادی هستند؛ چرا که توانسته در زمان معقول، راه‌حل‌های باکیفیتی ارایه دهد. در این زمینه، میانگین شکاف پاسخ به دست آمده از طریق روش فراابتکاری برای تابع هدف اول برابر با ۰/۰۱۶۰، برای تابع هدف دوم برابر با ۰/۰۲۳ و برای تابع هدف سوم برابر با ۰/۰۲۱ می‌باشد که نشان دهنده عملکرد مناسب آن است. الگوریتم یادگیری ماشین توسعه‌یافته نیز با دقت قابل قبولی پارامترهای کلیدی مدل را برآورد کرده است. همچنین، مطابق با نتایج به دست آمده از تحلیل حساسیت، با افزایش میزان زمان پردازش به عنوان یکی از پارامترهای ورودی کلیدی مدل ریاضی ارایه شده، میزان تاخیر، انرژی مصرفی و انتشار گازهای گلخانه‌ای به طور قابل توجهی افزایش می‌یابند. از سوی دیگر، بر اساس نتایج به دست آمده از تحلیل حساسیت، با افزایش پارامتر زمان آماده‌سازی، هر سه تابع هدف (یعنی تاخیر، انتشار گازهای گلخانه‌ای و مصرف انرژی) افزایش یافته‌اند.

**کلمات کلیدی:** زمان‌بندی کارگاه جریان انعطاف‌پذیر، نگهداری و تعمیرات پیشگیرانه، تصمیم‌گیری مبتنی بر یادگیری ماشین، الگوریتم ژنتیک.

* عهده‌دار مکاتبات
آدرس الکترونیکی: mehrabian.project@iau.ac.ir

## ۱ مقدمه

مساله زمان‌بندی یکی از چالش‌های اساسی در سیستم‌های تولیدی محسوب می‌شود که هدف آن تعیین توالی و زمان‌بندی بهینه عملیات به‌منظور افزایش بهره‌وری و کارایی فرایندهای تولید است [۱]. این مساله طیف گسترده‌ای از تصمیمات از قبیل تخصیص منابع، تعیین توالی کارها، تخصیص ماشین‌ها و برنامه‌ریزی تولید را در بر می‌گیرد و نقش مهمی در کاهش هزینه‌ها، کاهش زمان‌های انتظار، استفاده بهینه از منابع و تأمین به‌موقع نیاز مشتریان ایفا می‌کند [۲]. در سال‌های اخیر، مساله زمان‌بندی سبز با توجه به نگرانی‌های زیست‌محیطی و الزامات روزافزون پایداری، اهمیت روزافزونی یافته است [۳، ۴]. با توجه به چالش‌های ناشی از تغییرات اقلیمی، تصمیمات مربوط به زمان‌بندی در فرآیندهای تولیدی باید به‌گونه‌ای اتخاذ شوند که منجر به کاهش مصرف انرژی، کاهش انتشار آلاینده‌ها و مدیریت پسماند شوند [۵، ۶]. هم‌زمان با سخت‌گیرانه‌تر شدن مقررات زیست‌محیطی و افزایش تقاضای مصرف‌کنندگان برای محصولات دوستدار محیط‌زیست، اتخاذ استراتژی‌های زمان‌بندی پایدار به یک ضرورت راهبردی برای بنگاه‌های تولیدی تبدیل شده است [۷، ۸]. یکی از مسایل پرکاربرد در این حوزه، مساله زمان‌بندی جریان کارگاهی[1] است که در آن مجموعه‌ای از عملیات باید به‌ترتیب از مجموعه‌ای از ماشین‌ها عبور کنند [۹]. نوع پیشرفته‌تری از این مساله با عنوان جریان کارگاهی انعطاف‌پذیر[2] مطرح شده است که در آن هر مرحله می‌تواند شامل چندین ماشین موازی باشد و تخصیص کارها به ماشین‌ها می‌تواند به‌صورت انعطاف‌پذیر انجام شود [۱۰]. این مساله با پیچیدگی‌های ساختاری بیشتری مواجه است و در صنایع پیشرفته‌ای همچون خودروسازی، نیمه‌هادی و پتروشیمی کاربرد فراوان دارد [۱۱].

از سوی دیگر، نگهداری و تعمیرات پیشگیرانه[3] نقش مهمی در افزایش قابلیت اطمینان تجهیزات و کاهش توقفات پیش‌بینی‌نشده ایفا می‌کند. تلفیق راهبردهای نگهداری با زمان‌بندی تولید، منجر به استفاده بهینه‌تر از منابع، کاهش ریسک خرابی‌های ناگهانی و افزایش بهره‌وری کل تجهیزات می‌شود [۱۲، ۱۳]. به‌ویژه در محیط‌های جریان کارگاهی انعطاف‌پذیر، لحاظ کردن هم‌زمان الزامات نگهداری با الزامات تولید می‌تواند اثربخشی سیستم را افزایش دهد و عملکرد پایدارتری برای سازمان ایجاد کند.

با توجه به اهمیت موارد مذکور، مطالعه حاضر به بررسی مساله زمان‌بندی جریان کارگاهی انعطاف‌پذیر سبز با در نظر گرفتن نگهداری پیشگیرانه و در شرایط عدم قطعیت پرداخته است. بدین منظور، یک مدل ریاضی چندهدفه برای بهینه‌سازی سه هدف شامل تاخیر، مصرف انرژی و انتشار گازهای گلخانه‌ای توسعه یافته است. برخلاف مطالعات پیشین که عمدتاً از داده‌های قطعی یا روش‌های کلاسیک استفاده کرده‌اند، این پژوهش به توسعه یک چارچوب تصمیم‌گیری نوین مبتنی بر رویکردهای داده‌محور پرداخته و عدم قطعیت موجود در داده‌های زمانی را از طریق یک رویکرد ترکیبی مدل‌سازی کرده است. در این مطالعه، از روش‌های یادگیری ماشین و الگوریتم‌های ترکیبی برای حل مدل استفاده شده است وتمرکز بر بازطراحی بخش حل مساله و ارایه روش‌های حل جایگزین خواهد بود که ضمن حفظ ساختار مدل ریاضی، کارایی و کیفیت پاسخ‌ها را بهبود بخشد.

---

[1] Flowshop
[2] Flexible Flowshop
[3] Preventive Maintenance

در مجموع، با توجه به پیچیدگی‌های موجود در محیط‌های تولیدی مدرن، ترکیب ملاحظات زیست‌محیطی، الزامات نگهداری پیشگیرانه و ساختار انعطاف‌پذیر خطوط تولید در قالب یک مدل زمان‌بندی جامع، ضرورتی انکارناپذیر است. همچنین، مواجهه با شرایط عدم قطعیت در داده‌های عملیاتی، نیازمند بهره‌گیری از رویکردهای محاسباتی کارآمد و قابل اتکا برای پشتیبانی از تصمیم‌گیری در محیط‌های واقعی است. بر این اساس، پژوهش حاضر با هدف توسعه یک مدل ریاضی و ارایه روش‌های حل مناسب، تلاش می‌کند چارچوبی کاربردی برای بهینه‌سازی زمان‌بندی در سیستم‌های جریان کارگاهی انعطاف‌پذیر فراهم آورد.

## ۲ پیشینه تحقیق

در این بخش، برخی از مطالعات اخیر در حوزه زمان‌بندی جریان کارگاهی مرور و تحلیل شده‌اند. برای نمونه، تیرکلائی و همکاران [۱۴] یک مدل ریاضی فازی همراه با الگوریتم ازدحام ماهی مصنوعی خودتطبیق‌پذیر برای حل مساله جریان کارگاهی با در نظر گرفتن سناریوی برون‌سپاری پیشنهاد کردند. آن‌ها از یک مدل برنامه‌ریزی عدد صحیح مختلط با داده‌های ورودی فازی بهره گرفتند. نتایج نشان داد الگوریتم پیشنهادی عملکرد بهتری نسبت به حل‌کننده CPLEX دارد. با وجود بهبود عملکرد به کمک مدل فازی، این پژوهش فاقد توجه به الزامات تولید سبز و تعمیرات پیشگیرانه است. وانگ و ژی [۱۵] مدلی برای زمان‌بندی جریان کارگاهی با لحاظ عدم قطعیت زمانی معرفی کردند. آن‌ها برای مدیریت این نوع عدم قطعیت، از روش عدد خاکستری فاصله‌ای استفاده کرده و مدل را با الگوریتم کلونی زنبور مصنوعی و استراتژی‌های متنوع حل کردند. یافته‌ها نشان دادند که الگوریتم مذکور از لحاظ کارایی بر سایر روش‌ها برتری دارد. هرچند این رویکرد در مواجهه با عدم قطعیت زمانی موفق عمل کرده، اما فاقد لحاظ‌کردن معیارهای بهره‌وری انرژی و پایداری زیست‌محیطی است. کین و همکاران [۱۶] الگوریتم حریصانه[1] تکراری بهبودیافته‌ای برای مساله جریان کارگاهی ترکیبی با تمرکز بر بهینه‌سازی انرژی توسعه دادند. آن‌ها با تاکید بر نقش فزاینده مصرف انرژی، ۱۵۰ نمونه در اندازه‌های مختلف را مورد آزمایش قرار دادند و نتایج نشان داد عملکرد الگوریتم آن‌ها نسبت به سایر روش‌ها برتر است. با وجود ارزش بالای تمرکز بر انرژی، نبود تعمیرات پیشگیرانه و انعطاف‌پذیری در مدل، از کاربردی بودن آن در محیط‌های پیچیده می‌کاهد.

در مطالعات دیگر ژائو و همکاران [۱۷] الگوریتمی با نام «بهینه‌سازی موج آبی[2]» برای مساله زمان‌بندی جریان کارگاهی معرفی کردند و از برنامه‌ریزی عدد صحیح خطی برای فرمول‌بندی استفاده نمودند. در آزمون‌های عددی، ۹۰۰ نمونه کوچک و ۸۱۰ نمونه بزرگ تحلیل شد و نتایج حاکی از عملکردی تا چهار برابر بهتر نسبت به روش‌های مقایسه‌ای بود. با این حال، این الگوریتم نیز فاقد معیارهای زیست‌محیطی و راهبردهای تعمیرات پیشگیرانه است و از منظر پایداری، تمامی ابعاد زیست‌محیطی و اقتصادی و اجتماعی ارزیابی نمی‌شوند. هم‌چنین سیدحمزه و همکاران [۱۸] به بررسی مساله زمان‌بندی خط مونتاژ دو مرحله‌ای با زمان‌های مونتاژ متغیر پرداختند. آن‌ها مدلی از نوع برنامه‌ریزی عدد صحیح ارایه کردند و برای حل آن، از الگوریتم ژنتیک استفاده نمودند. همچنین برای مقابله با عدم

[1] Greedy Algorithm
[2] Blue Wave Optimization (BWO) Algorithm

قطعیت زمانی، از رویکرد مقاوم بهره گرفتند. نتایج نشان داد مدل مقاوم در کنترل عدم قطعیت عملکرد مناسبی دارد و الگوریتم ژنتیک از شبیه‌سازی تبریدی بهتر عمل کرده است. با این حال، توجهی به موضوعات زیست‌محیطی یا نگهداری پیشگیرانه در این پژوهش مشاهده نمی‌شود. کاستاندا و همکاران [۱۹] نیز مدلی فازی برای حل مساله جریان کارگاهی در شرایط عدم قطعیت پیشنهاد دادند. آن‌ها هم زمان تغییرپذیری در زمان اجرای فعالیت‌ها و نرخ یادگیری کارکنان را با روش‌های فازی و تصادفی مدل‌سازی کردند. از روش شبیه‌سازی برای حل مدل استفاده شد و عملکرد عملیاتی بالایی را نسبت به سایر روش‌ها نشان داد. با این حال، این مدل نیز فاقد ابعاد نگهداری و پایداری محیطی است و برای محیط‌های تولید سبز چندان کاربردی نیست.

استفاده از الگوریتم‌های توسعه‌یافته در ابعاد بزرگ نیز در مطالعات این حوزه مورد بررسی قرار گرفته است. به طور مثال وانگ و همکاران [۲۰] مدلی فازی برای زمان‌بندی جریان کارگاهی ترکیبی توسعه دادند که بهره‌وری انرژی و بهینه‌سازی سرعت ماشین‌ها را در بر می‌گیرد. در این مطالعه، از الگوریتم توسعه‌یافته NSGA-II موسوم به ENSGA-II استفاده شد که نسبت به نسخه پایه عملکرد برتری نشان داد. هرچند تمرکز بر بهینه‌سازی انرژی ارزشمند است، اما عدم توجه به نگهداری پیشگیرانه یکی از کاستی‌های مدل است. ژانگ و همکاران [۲۱] نیز الگوریتمی تکاملی چندهدفه با قابلیت طراحی خودکار و داده‌محور برای زمان‌بندی جریان کارگاهی ارایه دادند. آن‌ها با استفاده از داده‌های بلادرنگ و درخت تصمیم، به پیکربندی الگوریتم پرداختند. نتایج بهبود دقت مدل را نشان داد، اما مانند بسیاری از پژوهش‌های مشابه، فاقد یکپارچه‌سازی با مفاهیم تولید سبز و تعمیرات پیشگیرانه است. هم‌چنین یو و همکاران [۲] مدلی ریاضی برای مساله زمان‌بندی در سیستم‌های تولید ترکیبی همراه با خطوط مونتاژ پیشنهاد دادند و از الگوریتم حریصانه تکراری مبتنی بر دانش (KBIG[1]) برای حل آن بهره گرفتند. آن‌ها نشان دادند که KBIG در مسایل کوچک‌مقیاس عملکرد مطلوبی دارد. با این حال، مدل مورد بررسی آن‌ها فاقد ملاحظات پایداری یا نگهداری است. در نهایت، فکری و همکاران [۱۰] به بهینه‌سازی دوهدفه در مساله زمان‌بندی کارگاهی انعطاف‌پذیر با استفاده از نیروی انسانی چندمهارته پرداختند. اهداف مدل شامل کاهش زمان تکمیل کل و توازن بار کاری بود. آن‌ها برای حل مدل از الگوریتم‌های NSGA-III و ژنتیک استفاده کردند. هرچند به‌کارگیری نیروی انسانی چندمهارته نوآورانه است، اما مدل فاقد درنظر گرفتن تعمیرات پیشگیرانه و معیارهای تولید سبز است که در چارچوب‌های مدرن تولید اهمیت زیادی دارند.

در مجلات فارسی نیز مطالعاتی در این زمینه انجام شده و طی سال‌های اخیر نیز مورد توجه قرار گرفتند.

حسنی و حسینی [۲۲] یک مدل برنامه‌ریزی عدد صحیح مختلط برای مساله زمان‌بندی سبز در محیط جریان کارگاهی انعطاف‌پذیر ارایه کردند که در آن وابستگی مراحل پردازش به ماشین، محدودیت دسترسی به ماشین‌ها و زمان‌های ترخیص کارها لحاظ گردید. آن‌ها با درنظر گرفتن هزینه تولید و مصرف انرژی به‌عنوان دو تابع هدف اصلی، مدل را ابتدا با روش اپسیلون-محدودیت و سپس با الگوریتم ژنتیک NSGA-II حل کردند. نتایج حاکی از برتری روش پیشنهادی نسبت به الگوریتم SPEA-II بود. هرچند این مطالعه در تلفیق اهداف زیست‌محیطی موفق

[1] Knowledge-Based Iterative Greedy (KBIG) Algorithm

عمل کرده، اما راهبردهای نگهداری و عدم‌قطعیت داده‌ها را در مدل لحاظ نکرده است. نیکوئی و امیری [۲۳] نیز با بهره‌گیری از ترکیب روش‌های تصمیم‌گیری چندمعیاره فازی و طراحی آزمایش‌ها، به تعیین تعداد بهینه تجهیزات در سیستم جریان کارگاهی مونتاژ دو مرحله‌ای پرداختند. آن‌ها با استفاده از شبیه‌سازی و رویکرد فازی بهترین–بدترین و تاپسیس، تابع پایایی سیستم را تخمین زده و گزینه بهینه را انتخاب کردند. هرچند تمرکز اصلی این پژوهش بر ارزیابی پایداری سیستم تولیدی بوده است، اما رویکرد آن می‌تواند به‌عنوان مکملی برای مدل‌های تصمیم‌گیری چندهدفه در محیط‌های جریان کارگاهی مورد استفاده قرار گیرد. از سوی دیگر، اخگر و همکاران [۲۴] با هدف ارتقای پاسخ‌گویی و بهره‌وری در سیستم‌های تولید قابل پیکربندی مجدد، یک مدل ریاضی برای زمان‌بندی جریان کارگاهی با در نظر گرفتن ربات‌های حمل‌ونقل قابل پیکربندی مجدد ارایه کردند. مدل پیشنهادی در محیط چندمحصولی و با هدف حداقل‌سازی زمان تکمیل کل توسعه یافت و با استفاده از نرم‌افزار GAMS و حل‌کننده CPLEX مورد ارزیابی قرار گرفت. نتایج نشان داد که با افزایش تعداد کارها، زمان حل مدل به‌صورت نمایی افزایش می‌یابد و استفاده از روش‌های فراابتکاری برای حل مسایل بزرگ‌مقیاس ضرورت دارد. در همین راستا، خاکساری و قندی بیدگلی [۲۵] نیز به بررسی مساله زمان‌بندی جریان کارگاهی بدون انتظار با در نظر گرفتن زمان آزادسازی کارها و فعالیت‌های نگهداری و تعمیرات پیشگیرانه پرداختند. آن‌ها با ارایه یک مدل غیرخطی عدد صحیح مختلط و به‌کارگیری الگوریتم فراابتکاری جستجوی هارمونی ترکیبی، نشان دادند که رویکرد پیشنهادی از نظر زمان حل و کیفیت پاسخ نسبت به الگوریتم‌های کلاسیک عملکرد برتری دارد. در مجموع، مرور مطالعات مذکور بیانگر آن است که علی‌رغم پیشرفت‌های قابل توجه در زمینه مدل‌سازی و توسعه الگوریتم‌های کارا برای مسایل جریان کارگاهی، همچنان نیاز به پژوهش‌هایی وجود دارد که ابعاد مختلف پایداری، انعطاف‌پذیری، نگهداری پیشگیرانه و یادگیری داده‌محور را به‌صورت هم‌زمان و یکپارچه در چارچوب‌های تصمیم‌گیری جامع لحاظ نمایند. در جدول ۱ خلاصه و دسته‌بندی ادبیات تحقیق نمایش داده شده است.

مرور ادبیات نشان می‌دهد که محققان در سال‌های اخیر تلاش‌های متعددی برای بهینه‌سازی مسایل زمان‌بندی در محیط‌های جریان کارگاهی داشته‌اند. با این حال، شکاف‌هایی همچنان در ادبیات موجود است. به‌ویژه، تعداد اندکی از مطالعات به بررسی هم‌زمان سه بُعد حیاتی شامل ملاحظات زیست‌محیطی، انعطاف‌پذیری تولید، و نگهداری پیشگیرانه پرداخته‌اند. این در حالی است که همان‌طور که در بخش مقدمه اشاره شد، ادغام این عوامل در چارچوب زمان‌بندی از منظر پایداری عملیاتی، کاهش خرابی‌ها و کاهش اثرات محیطی از اهمیت بالایی برخوردار است. از سوی دیگر، در بررسی منابع مشاهده شد که اغلب پژوهش‌های پیشین از مدل‌های داده‌محور و مبتنی بر یادگیری ماشین برای تخمین پارامترهای زمان‌بندی استفاده نکرده‌اند. این در حالی است که در عصر داده‌محور امروزی، به‌کارگیری الگوریتم‌های یادگیری ماشین برای تخمین دقیق‌تر پارامترها می‌تواند موجب بهبود دقت و کارایی خروجی‌های تصمیم‌گیری شود. توسعه چنین رویکردهایی، به‌ویژه در مدل‌سازی عدم قطعیت و کاهش اتکا به داده‌های ذهنی، گامی مؤثر در مسیر واقع‌گراتر شدن مدل‌های زمان‌بندی محسوب می‌شود.

**جدول ۱.** خلاصه‌بندی و دسته‌بندی ادبیات تحقیق

| نویسنده (شماره منبع) | زمان‌بندی | جریان کارگاهی انعطاف‌پذیر | معیارهای سبز | تعمیرات پیشگیرانه | داده‌محور | عدم‌قطعیت | روش حل |
|---|---|---|---|---|---|---|---|
| وانگ و ژی [۱۵] | * | – | – | – | – | * | روش عدد خاکستری فاصله‌ای + کلونی زنبور مصنوعی |
| کین و همکاران [۱۶] | * | – | * | – | – | – | الگوریتم حریصانه تکراری بهبودیافته |
| ژائو و همکاران [۱۷] | * | – | – | – | – | – | برنامه‌ریزی عدد صحیح خطی + الگوریتم بهینه‌سازی موج آبی |
| سیدحمزه و همکاران [۱۸] | * | – | – | – | – | * | الگوریتم ژنتیک |
| کاستاندا و همکاران [۱۹] | * | – | – | – | – | * | مدل فازی + شبیه‌سازی |
| وانگ و همکاران [۲۰] | * | – | * | – | – | – | الگوریتم ENSGA-II (نسخه توسعه‌یافته NSGA-II) |
| ژانگ و همکاران [۲۱] | * | – | – | – | * | – | الگوریتم تکاملی چندهدفه داده‌محور |
| یو و همکاران [۲] | * | – | – | – | – | – | الگوریتم حریصانه تکراری مبتنی بر دانش (KBIG) |
| فکری و همکاران [۱۰] | * | * | – | – | – | – | NSGA-III + الگوریتم ژنتیک |
| حسنی و حسینی [۲۲] | * | * | * | – | – | – | MILP + روش-ε محدودیت + NSGA-II |
| نیکوئی و امیری [۲۳] | – | – | – | – | – | * | تصمیم‌گیری چندمعیاره فازی (F-BWM + TOPSIS) + شبیه‌سازی |
| اخگر و همکاران [۲۴] | * | – | – | – | – | – | MILP + CPLEX |
| خاکساری و قندی بیدگلی [۲۵] | * | – | – | * | – | – | MILP غیرخطی + الگوریتم جستجوی هارمونی ترکیبی |
| مطالعه حاضر | * | * | * | * | * | * | برنامه‌ریزی فازی داده‌محور + الگوریتم جنگل تصادفی + الگوریتم ژنتیک و جمع وزنی نرمال‌شده |

برای پوشش این شکاف‌ها، پژوهش حاضر یک چارچوب تصمیم‌گیری داده‌محور برای مساله زمان‌بندی جریان کارگاهی انعطاف‌پذیر با در نظر گرفتن ملاحظات زیست‌محیطی و نگهداری پیشگیرانه پیشنهاد می‌کند. در این راستا، یک مدل ریاضی چندهدفه توسعه داده شده و عدم قطعیت با استفاده از ترکیب بهینه‌سازی استوار فازی

و الگوریتم‌های داده‌محور مدیریت شده است. در ادامه نیز روش‌های حل مناسب برای کاهش پیچیدگی و زمان محاسباتی ارایه شده‌اند. بدین‌ترتیب، پژوهش حاضر گامی در جهت ادغام پایداری، قابلیت اطمینان و یادگیری داده‌محور در مسایل پیشرفته زمان‌بندی به شمار می‌رود.

## ۳ شرح مساله و مدل ریاضی

همانطور که پیش‌تر بیان گردید، تحقیق حاضر به دنبال بهینه‌سازی فرآیند خط تولید کمپرسور با مطالعه موردی در شرکت نفتی با در نظر گرفتن شاخص‌های نگهداری و تعمیرات می‌باشد. در این زمینه، در این تحقیق، یک مدل برنامه‌ریزی ریاضی چندهدفه ارایه گردیده است. در سیستم تولیدی در نظر گرفته شده، چندین ایستگاه کاری وجود دارد که هر کدام دارای ماشین‌های موازی هستند. در سیستم در نظر گرفته شده، هر کار بر روی یک یا چند ماشین در یک ایستگاه کاری پردازش می‌شود. در سیستم مورد مطالعه، ماشین‌ها تحت اجرای کارها دچار استهلاک می‌شوند و برای حفظ قابلیت عملیاتی، نیازمند اجرای فعالیت‌های نگهداری و تعمیرات دوره‌ای هستند. هر کار، بسته به نوع پردازش، مدت زمان اجرا و الگوی مصرف ماشین، می‌تواند میزان متفاوتی از استهلاک ایجاد کند. به همین دلیل، پیش از مدل‌سازی، کارها بر اساس ویژگی‌های مؤثر بر رفتار نگهداری ماشین (نظیر شدت استهلاک، نیاز به هم‌زمان‌سازی PM، یا نوع فرایند) در گروه‌هایی طبقه‌بندی می‌شوند. این گروه‌بندی به مدل اجازه می‌دهد اثر کارها بر نیاز به PM را به‌درستی لحاظ کند. لازم به ذکر است که در این پژوهش، گروه‌ها مربوط به کارها هستند و نه به ماشین‌ها، تجهیزات یا تیم‌های تعمیراتی.

فرض کنید $I$ نشان دهنده مجموعه مراحل است که با i شاخص‌گذاری (اندیس) شده است. همچنین، T نشان دهنده مجموعه دوره‌ها بوده که اندیس آن t می‌باشد. از سوی دیگر، J مجموعه مجموعه کارها بوده که با j و k شاخص‌گذاری شده است. از طرفی، M نشان دهنده مجموعه ماشین‌ها می‌باشد که اندیس آن نیز m است. همچنین، G مجموعه گروه‌های نگهداری و تعمیرات است که با g شاخص‌گذاری شده است. همچنین، $Gr$ نشان دهنده تعداد گروه‌های نگهداری و تعمیرات را نشان می‌دهد. مجموعه گروه‌ها (G) بیانگر طبقه‌بندی کارها بر اساس سطح و نوع تأثیر آن‌ها بر استهلاک ماشین و نیاز به برنامه‌ریزی مناسب فعالیت‌های نگهداری است. این گروه‌ها به ماشین‌ها، تجهیزات یا تیم‌های تعمیراتی اشاره ندارند. علاوه بر این، $N_g$ بیانگر تعداد کارها در گروه گروه نگهداری تعمیرات g است و N نشان دهنده تعداد کل کارها می‌باشد ($N = \sum_{g=1}^{G} N_g$). باید دقت داشت که در مدل حاضر، منظور از «گروه‌های نگهداری و تعمیرات»، طبقه‌بندی کارها براساس ویژگی‌های مرتبط با نگهداری است.کارها با توجه به نیازهای متفاوت تعمیرات پیشگیرانه، میزان استهلاک و دیگر ویژگی‌های مؤثر بر فرآیند نگهداری، در گروه‌های مختلف قرار می‌گیرند. این گروه‌بندی به مدل کمک می‌کند تا: (الف) تفاوت در ویژگی‌های نگهداری میان انواع کارها را لحاظ کند، (ب) زمان‌بندی مناسب فعالیت‌های PM را مدیریت نماید و (ج) زمان‌های آماده‌سازی وابسته به گروه (setup times) را بهتر مدل‌سازی کند. لازم به ذکر است که این گروه‌ها به تیم‌های نگهداری، گروه‌های تجهیزاتی یا قطعات یدکی اشاره ندارند، بلکه صرفاً دسته‌بندی کارها با

هدف کنترل بهتر اثرات نگهداری در برنامه‌ریزی است. همچنین، Me نشان دهنده تعداد مراحل بوده و $M_i$ نمایانگر تعداد ماشین‌ها در مرحله i است. همچنین، $t^{pm}{}_{it}$ نشان دهنده زمان نگهداری و تعمیرات در مرحله i در دوره t بوده، $\widetilde{Td}_{gjt}$ بیانگر موعد تحویل کار j از گروه g در دوره t بوده، $\widetilde{S}_{igg't}$ نشان دهنده زمان پردازش برای مورد نیاز گروه g به g' در مرحله i در دوره t می‌باشد. $\widetilde{PT}_{gjit}$ نمایانگر زمان پردازش کار j در گروه g در مرحله i در دوره t است، $\widetilde{GH}_{jgm}$ نشان دهنده میزان انتشار گازهای گلخانه‌ای اگر کار j در گروه g روی ماشین m پردازش شود و $\widetilde{ENG}_{jgm}$ بیانگر میزان انتشار مصرف انرژی اگر کار j در گروه g روی ماشین m پردازش شود. علاوه بر این، متغیرهای تصمیم این تحقیق شامل موارد زیر می‌باشند. $NP_{imkt}$ نشان دهنده تعداد فعالیت‌های نگهداری و تعمیرات قبل از عملیات k-ام روی ماشین m بوده، $X_{gjimkt}$ نیز متغیر صفر و یک است که زمانی مقدار یک می‌گیرد که کار j از گروه g برابر با k-امین کار روی ماشین m باشد، $ET_{imkt}$ برابر با زمان مورد انتظار برای پایان کار k روی ماشین m در مرحله i و در دوره t بوده، $T_{imkt}$ نشان دهنده زمان پردازش کار کار k روی ماشین m بوده، $Y_{imkt}$ یک متغیر باینری است و زمانی مقدار یک می‌گیرد که نگهداری و تعمیرات روی ماشین m در مرحله i در دوره t قبل از پردازش کار k انجام گردد، $ST_{im(k-1)kt}$ بیانگر زمان شروع کار بین کارهای $k-1$ و k روی ماشین m در مرحله i و دوره t می‌باشد. این زمان‌های آماده‌سازی بین گروه‌ها به این دلیل در نظر گرفته می‌شود که کارهای هر گروه، الگوی متفاوتی از فشار عملیاتی بر ماشین ایجاد می‌کنند و در نتیجه، آماده‌سازی بین دو گروه می‌تواند نیازمند تنظیمات متفاوتی باشد. در انتها نیز، $CT_{imkt}$ نمایانگر زمان زمان اتمام کار k روی ماشین m در مرحله i است. در این تحقیق، عوامل زیست‌محیطی با در نظر گرفتن انتشار گازهای گلخانه‌ای و مصرف انرژی به عنوان توابع هدف در مدل پیشنهادی در نظر گرفته شده است. همچنین نگهداری در محدودیت های مربوطه در نظر گرفته شده است. با توجه به موارد بیان شده، مدل ریاضی چند هدفه به‌صورت زیر می‌باشد. لازم به ذکر است که تفاوت اساسی این مدل با مدلهای موجود در ادبیات تحقیق مربوط به در نظر گرفتن همزمان توابع مصرف انرژی و انتشار گازهای گلحانه‌ای در کنار فازی بودن آن می‌باشد.

$$MinZ_1 = \sum_{n=1}^{\infty} \frac{f^{(n)}(a)}{n!}(z-a)^n$$

$$Min\ Z_1 = \sum_{g=1}^{G}\sum_{j=1}^{N_g} Max\left\{\cdot\cdot \sum_{m=1}^{M}\sum_{k=1}^{N}\sum_{t=1}^{T}\sum_{i=1}^{I} ET_{imkt}\cdot X_{gjimkt} - \widetilde{Td}_{gjt}\right\} \quad (1)$$

$$Min\ Z_2 = \sum_{m=1}^{M}\sum_{k=1}^{N}\sum_{t=1}^{T}\sum_{i=1}^{I}\sum_{j=1}^{N} \widetilde{GH}_{jgm}\cdot T_{imjt}\cdot X_{gjimkt} \quad (2)$$

$$Min\ Z_3 = \sum_{m=1}^{M}\sum_{k=1}^{N}\sum_{t=1}^{T}\sum_{i=1}^{I}\sum_{j=1}^{N} \widetilde{ENG}_{jgm}\cdot T_{imjt}\cdot X_{gjimkt} \quad (3)$$

$$NP_{imkt} = Max\{CT_{imkt}\cdot ET_{im(k-1)t} + max\{ST_{im(k-1)kt}\cdot t^{pm}{}_{it} Y_{imkt}\}\} \qquad \forall m,i,k,t \quad (4)$$

$$ET_{imkt} = NP_{imkt} + T_{imkt} \qquad \forall m,i,k,t \quad (5)$$

$$CT_{imkt} = \sum_{g=}^{G}\sum_{j=1}^{N_g}\sum_{m.m'=1(m\neq m')}^{M_i}\sum_{k.k'=1(k\neq k')}^{N}\sum_{i=}^{I}\sum_{t=1}^{T} X_{gjimkt}\ X_{gj(i-1)m'k't} ET_{(i-1)m'k't} \quad (6)$$

$$ST_{im(k-1)kt} = \sum_{g=1}^{G}\sum_{g=1}^{G}\left(\left(\sum_{j=1}^{N_g} X_{gjim(k-1)t}\right)\left(\sum_{j'=1}^{N'_g} X_{g'j'imkt}\right)\tilde{S}_{igg't}\right) \qquad \forall m,i,k,t \qquad (۷)$$

$$\sum_{m=1}^{M_i}\sum_{k=1}^{N}\sum_{t=1}^{T} X_{gjimkt} = 1 \qquad \forall g,i,j \qquad (۸)$$

$$T_{imkt} = \sum_{g=1}^{G}\sum_{j=1}^{N_g} \widetilde{PT}_{gjit} X_{gjimkt} \qquad \forall m,i,k,t \qquad (۹)$$

$$\sum_{g=}^{G}\sum_{j=}^{N_g}\sum_{t=1}^{T} X_{gjimkt} \geq \sum_{g=1}^{G}\sum_{j=1}^{N_g}\sum_{t=}^{T} X_{gjim(k+1)t} \qquad \forall i,m \quad \forall k < N \qquad (۱۰)$$

$$\sum_{g=}^{G}\sum_{j=}^{N_g}\sum_{t=1}^{T} X_{gjimkt} \leq 1 \qquad \forall k,i,m \qquad (۱۱)$$

$$\sum_{m=1}^{M_i}\sum_{k=1}^{N-N_g}\sum_{t=1}^{T}\left(\prod_{p=0}^{N_g-1}\left(\sum_{j=1}^{N_g} X_{gjim(k+p)t}\right)\right) = 1 \qquad \forall g,i \qquad (۱۲)$$

$$X_{gjimkt}, Y_{imkt} \in \{0,1\}; ET_{imkt}, NP_{imkt}, ST_{im(k-1)kt}, CT_{imkt} \geq 0 \qquad \forall m,i,k,t,g,j \qquad (۱۳)$$

رابطه (۱) تاخیر کل را به حداقل می‌رساند. معادله (۲) انتشار گازهای گلخانه‌ای را به حداقل می‌رساند. رابطه (۳) مصرف کل انرژی را به حداقل می‌رساند. رابطه (۴) مقدار متغیر $NP_{imkt}$ را که تعداد فعالیت‌های نگهداری و تعمیرات قبل از عملیات k-ام روی ماشین m می‌باشد، محاسبه می‌کند. محدودیت (۵) زمان تکمیل را محاسبه می کند. محدودیت (۶) زمان لازم برای تکمیل کار k را در دوره t در مرحله (i-۱) محاسبه می‌کند. محدودیت (۷) زمان بین کارهای (k-۱) و k را محاسبه می‌کند. محدودیت (۸) نشان می‌دهد که هر عملیات از یک کار در هر مرحله در یک دوره به یک ماشین می‌تواند تخصیص داده شود. محدودیت (۹) زمان پردازش کارها را محاسبه می کند. محدودیت (۱۰) حداکثر تعداد وظایفی را که می‌توان به یک ماشین اختصاص داد را نشان می‌دهد. محدودیت (۱۱) نشان می‌دهد که پردازش دو کار نمی‌تواند توسط یک ماشین در یک مرحله تکمیل شود. برای جلوگیری از تداخل در سیستم تولیدی و نیز مدل‌سازی صحیح زمان‌های آماده‌سازی بین گروه‌ها، لازم است که ماشین در یک لحظه تنها درگیر یک گروه باشد که در محدودیت (۱۲) لحاظ شده است. در نهایت، محدوده متغیرها در محدودیت (۱۳) تعریف شده است.

## ٤ مدل‌سازی عدم قطعیت

### ٤-١ برنامه‌ریزی فازی

روش برنامه ریزی فازی استوار یک رویکرد قدرتمند است که برای رسیدگی به عدم قطعیت در مسایل بهینه‌سازی با ترکیب منطق فازی استفاده می‌شود. این روش به تصمیم گیرندگان اجازه می‌دهد تا عدم اطمینان و پراکندگی در داده‌های ورودی و همچنین عدم قطعیت در محدودیت ها و اهداف مساله بهینه‌سازی را در نظر بگیرند. این رویکرد روشی انعطاف‌پذیر و مؤثر برای تصمیم‌گیری در شرایط عدم اطمینان ارایه می‌کند [۲۶، ۲۷]. یکی از مزایای کلیدی این روش توانایی آن در ایجاد تعادل بین بهینه بودن و استواری مدل است. برای درک بهتر، مدل فرضی زیر را در نظر بگیرید. در این مدل، f و $\tilde{c}$ ضرایب تابع هدف هستند که در آن c یک عدد فازی می‌باشد. همینطور، A، B و

S ضرایب معین محدودیت‌ها و $\tilde{d}$، $\tilde{L}$ و $\tilde{N}$ ضرایب فازی محدودیت‌ها می‌باشند. X و y نیز نشان دهنده متغیرهای تصمیم هستند. لازم به ذکر است که اعداد فازی به صورت فازی ذوزنقه‌ای در نظر گرفته شده‌اند. ( $\theta_{(۱)}.\theta_{(۲)}.\theta_{(۳)}.\theta_{(٤)}.$ $\theta=\theta_{(۱)}.\theta_{(۲)}.\theta_{(۳)}.\theta_{(٤)}$).

$$\begin{aligned} Min\ Z &= f.y + \tilde{c}.x \\ A.x &\geq \tilde{d} \\ B.x &= \tilde{L} \\ S.x &\leq \tilde{N}.y \end{aligned} \tag{۱۴}$$

با در نظر گرفتن به $\sigma_j$ عنوان سطح ارضا شدن محدودیت j، می‌توان مدل هم‌ارز فازی را برای مدل فوق بصورت زیر نوشت.

$$\begin{aligned} Min\ Z &= f.y + \frac{c_۱ + c_۲ + c_۳ + c_۴}{۴}.x \\ A.x &\geq (۱ - \sigma_j).d_۲ + \sigma_j.d_۱ \\ B.x &\geq \left(۱ - \frac{\sigma_j}{۲}\right).\left(\frac{L_۱ + L_۲}{۲}\right) + \left(\frac{\sigma_j}{۲}\right).\left(\frac{L_۳ + L_۴}{۲}\right) \\ B.x &\leq \left(۱ - \frac{\sigma_j}{۲}\right).\left(\frac{L_۳ + L_۴}{۲}\right) + \left(\frac{\sigma_j}{۲}\right).\left(\frac{L_۱ + L_۲}{۲}\right) \\ S.x &\leq \left((۱ - \sigma_j).N_۲ + \sigma_j.N_۱\right).y \end{aligned} \tag{۱۵}$$

## ٤-۲ الگوریتم جنگل تصادفی رگرسیونی

در این پژوهش، برای تخمین موثر پارامترهای زمانی مرتبط با زمان پردازش فعالیت‌ها، از الگوریتم جنگل تصادفی رگرسیونی (RFR) به‌عنوان یک روش یادگیری ماشین استفاده شده است. الگوریتم جنگل تصادفی یک مدل یادگیری تجمعی[1] مبتنی بر درختان تصمیم[2] است که از طریق ترکیب چندین مدل پایه و انجام میانگین‌گیری پیش‌بینی‌ها، عملکرد و دقت نهایی را بهبود می‌بخشد. در مدل پیشنهادی، RFR با استفاده از مجموعه‌ای از ویژگی‌های توصیفی مانند تجربه اپراتور، شیفت کاری، ابزار مورد استفاده، سن و جنسیت اپراتور، سطح دشواری کار، میزان روتین بودن فعالیت و شرایط محیط کار، اقدام به پیش‌بینی زمان‌های اجرای فعالیت‌ها می‌کند. داده‌های آموزشی مدل شامل مقادیر این ویژگی‌ها به‌همراه برچسب‌های زمانی واقعی بوده است.

در فرآیند آموزش مدل، RFR تعداد مشخصی از درختان تصمیم را بر روی زیرمجموعه‌های تصادفی از داده‌ها و ویژگی‌ها آموزش می‌دهد. هر درخت به‌طور مستقل آموزش دیده و پیش‌بینی مجزایی ارایه می‌کند. سپس

[1] Ensemble Learning
[2] Decision Trees

خروجی نهایی مدل با میانگین‌گیری از خروجی درخت‌ها به‌دست می‌آید، که باعث افزایش پایداری، دقت و کاهش حساسیت به نویز می‌شود.

برای تنظیم مدل، سه پارامتر کلیدی به‌صورت تجربی تعیین شده‌اند:

- تعداد درخت‌ها (n_estimators) برابر با ۱۰۰ در نظر گرفته شد تا تعادلی میان دقت و پیچیدگی محاسباتی فراهم شود.
- عمق حداکثری درخت‌ها (max_depth) بر روی مقدار ۴ تنظیم شد تا از بیش‌برازش جلوگیری شود.
- سایر پارامترها مانند min_samples_split و min_samples_leaf بر اساس مقادیر پیش‌فرض پیاده‌سازی کتابخانه Scikit-learn تنظیم شدند.

الگوریتم RFR به‌دلیل توانایی بالای خود در مدل‌سازی روابط غیرخطی، تحمل نسبتاً مناسب در برابر داده‌های ناقص یا نویزی، و قابلیت اندازه‌گیری اهمیت ویژگی‌ها، انتخاب مناسبی برای این مساله بود. همچنین، قابلیت ارایه تخمین‌های دقیق از پارامترهای زمانی به‌صورت مؤثر، این مدل را به یک ابزار مناسب برای استفاده در فرآیندهای تصمیم‌گیری برنامه‌ریزی تولید تحت عدم‌قطعیت تبدیل می‌کند [۳۰-۲۸].

## ۵ روش حل

برای حل مدل ارایه شده در این مقاله، دو چالش عمده وجود دارد. اولین مورد به ماهیت چند هدفه مدل پیشنهادی مربوط می شود. همچنین، چالش دوم به پیچیدگی مدل پیشنهادی مربوط می شود. بنابراین، این کار یک روش ترکیبی را با ترکیب رویکرد جمع وزنی نرمالیزه شده و الگوریتم ژنتیک برای غلبه بر چالش‌های ذکر شده پیشنهاد می‌کند. در واقع، در این تحقیق، ابتدا مدل چند هدفه با استفاده از روش LP-Metric به یک مدل تک هدفه تبدیل شده و سپس با استفاده از الگوریتم ژنتیک حل گردیده.

### ۵-۱ روش جمع وزنی نرمال شده

در این مطالعه، برای دستیابی به راه‌حل بهینه، از روش مجموع وزنی نرمال‌شده استفاده شده است. دلایل انتخاب روش مجموع وزنی نرمال‌شده عبارتند از: (۱) این روش برای مدیران قابل فهم‌تر است و (۲) این روش در چندین تحقیق در ادبیات موضوع به کار رفته و عملکرد مناسبی نشان داده است. معادله (۱۶) مدل اصلی این روش است [۳۱]. با توجه به اینکه در پیش فرض هر دو تابع هدف به صورت بیشینه‌سازی هستند، تابع هدف روش مجموع وزنی نرمال‌شده به صورت زیر فرموله شده است:

$$Z_{total} = \frac{W_1(Z_1^{max} - Z_1)}{Z_1^{max} - Z_1^{min}} + \frac{W_2(Z_2^{max} - Z_1)}{Z_2^{max} - Z_2^{min}} \quad (۱۶)$$

در معادله (۱۶)، $W_i$ نشان‌دهنده اهمیت تابع هدف $i$ است که توسط نظر کارشناسان تعیین می‌شود.

$Z_i^{max}$ و $Z_i^{min}$ به ترتیب نشان‌دهنده حدود پایین و بالا برای تابع هدف $i$ می‌باشند. به منظور محاسبه حدود بیان شده، $Z_i^{min}$ با حل کردن مساله با تابع هدف $i$ در حالت کمینه‌سازی و $Z_i^{max}$ با حل کردن مساله با تابع هدف $i$ در حالت بیشینه‌سازی به دست می‌آیند.

## ۵-۲ الگوریتم ژنتیک

الگوریتم ژنتیک یکی از روش‌های بهینه‌سازی مبتنی بر فرایندهای تکامل طبیعی است که از مفاهیم زیست‌شناسی نظیر انتخاب طبیعی، جهش، و ترکیب ژنتیکی الهام گرفته است. این الگوریتم برای حل مسایل پیچیده و غیرخطی که روش‌های کلاسیک در آن‌ها ناکارآمد هستند، کاربرد فراوانی دارد. در الگوریتم ژنتیک، ابتدا مجموعه‌ای از پاسخ‌های احتمالی به‌صورت تصادفی تولید می‌شود که به آن‌ها "جمعیت اولیه" گفته می‌شود. هر یک از این پاسخ‌ها (یا کروموزوم‌ها) با استفاده از یک تابع برازندگی ارزیابی می‌شوند و بر اساس میزان برازندگی، افراد منتخب برای تولید نسل بعد انتخاب می‌گردند. در مراحل بعد، با استفاده از عملگرهای انتخاب، تقاطع و جهش، نسل‌های جدیدی از پاسخ‌ها تولید می‌شود که انتظار می‌رود کیفیت بهتری نسبت به نسل‌های قبلی داشته باشند. این فرایند تا زمانی که شرایط توقف برقرار شود (مانند رسیدن به تعداد مشخصی از تکرارها یا بهبود ناچیز در پاسخ‌ها)، ادامه می‌یابد. الگوریتم ژنتیک به دلیل توانایی بالای آن در جستجوی فضاهای بزرگ و پیچیده و اجتناب از به دام افتادن در بهینه‌های محلی، در مسایل گوناگون مهندسی، علوم داده، یادگیری ماشین و طراحی سیستم‌ها به‌کار گرفته می‌شود. برای تنظیم پارامترهای الگوریتم ژنتیک (از جمله تعداد تکرار، اندازه جمعیت، نرخ جهش و نرخ تقاطع)، می‌توان از روش تاگوچی بهره گرفت. در این روش، با طراحی یک ماتریس متعامد برای ترکیب سطوح مختلف هر پارامتر، مجموعه‌ای از آزمایش‌های محدود اما کارا انجام می‌شود. سپس با تحلیل نسبت سیگنال به نویز و نتایج عملکرد تابع هدف، بهترین سطح هر پارامتر تعیین می‌گردد. این رویکرد باعث کاهش تعداد آزمایش‌ها و یافتن تنظیمات بهینه در زمان کمتر می‌شود. از سوی دیگر، در خصوص مکانیسم انتخاب والدین با استفاده از چرخه رولت، هر کروموزوم متناسب با میزان برازش خود، بخشی از دایره رولت را به خود اختصاص می‌دهد. سپس با چرخاندن تصادفی رولت، کروموزوم‌هایی که سهم بیشتری از کل شایستگی دارند، احتمال بیشتری برای انتخاب به‌عنوان والدین دارند. این مکانیسم باعث حفظ تعادل بین بهره‌برداری از پاسخ‌های خوب و کاوش در سایر نواحی فضای جستجو می‌شود.

در این پژوهش، یک نمایش کروموزومی مبتنی بر توالی عملیات برای ماشین‌های موجود در هر مرحله استفاده شده است. به این صورت که هر کروموزوم شامل یک رشته ترتیبی از کارهاست که جایگاه هر کار در رشته، ترتیب انجام آن را مشخص می‌کند و گروه مربوط به هر کار نیز در همان ساختار لحاظ می‌شود. این نمایش باعث می‌شود که محدودیت‌های مربوط به پردازش کارها، انتقال بین گروه‌ها و زمان‌های آماده‌سازی قابل اعمال باشد. عملگر تقاطع مورد استفاده بر پایه رویکرد حفظ ترتیب نسبی عملیات طراحی شده است؛ بدین صورت که ابتدا یک زیررشته از والد اول انتخاب و در موقعیت مشابه به فرزند منتقل می‌شود و سپس جایگاه‌های خالی با حفظ ترتیب نسبی کارها از والد دوم تکمیل می‌گردد. این روش تضمین می‌کند که هیچ کار تکرار یا حذف نشود و

توالی حاصل نیز معتبر باشد. عملگر جهش نیز به‌صورت جابه‌جایی تصادفی موقعیت دو کار یا دو گروه در کروموزوم اعمال می‌شود. این نوع جهش باعث افزایش تنوع جمعیت و جلوگیری از همگرایی زودهنگام می‌شود، در حالی که ساختار کلی توالی عملیات حفظ می‌گردد. اگرچه چارچوب کلی این ساختارها مشابه تحقیق [۳۲] است، در این پژوهش پارامترهای الگوریتم و کنترل‌های مربوط به ترتیب گروه‌ها، زمان‌های آماده‌سازی و فعالیت‌های PM متناسب با ساختار مدل پیشنهادی تنظیم شده‌اند.

## ۵-۳ روش ترکیبی

در این پژوهش، به‌منظور دستیابی به یک چارچوب تصمیم‌گیری کارا و داده‌محور، رویکردی ترکیبی در چند گام متوالی طراحی و اجرا شده است. در گام نخست، ساختار اصلی مساله بر پایه مدل‌سازی ریاضی چندهدفه شکل گرفت تا ارتباط میان اهداف کلیدی شامل حداقل‌سازی تأخیر در تحویل، کاهش انتشار گازهای گلخانه‌ای و کاهش مصرف انرژی به‌صورت کمی و قابل تحلیل بیان شود. پس از تدوین مدل، در گام دوم، مجموعه‌ای از عوامل بیرونی مؤثر بر پارامترهای زمانی مانند تجربه اپراتور، شیفت کاری، دشواری فعالیت، شرایط محیطی و میزان روتین بودن عملیات شناسایی گردید تا نقش متغیرهای انسانی و محیطی در رفتار زمانی سیستم مشخص شود. در گام سوم، با بهره‌گیری از داده‌های جمع‌آوری‌شده، یک مدل یادگیری ماشین مبتنی بر الگوریتم جنگل تصادفی رگرسیونی (RFR) توسعه یافت که هدف آن تخمین دقیق پارامترهای زمانی مدل ریاضی از جمله زمان‌های پردازش، آماده‌سازی و تکمیل بود. این مدل با تحلیل روابط غیرخطی بین ویژگی‌ها و خروجی‌های زمانی، برآوردهایی با دقت بالا ارایه داد و زمینه استفاده از داده‌های واقعی و پویا را در فرآیند زمان‌بندی فراهم ساخت.

در ادامه، برای مدیریت عدم قطعیت موجود در داده‌های زمانی و عملیاتی، از رویکرد برنامه‌ریزی فازی استوار استفاده شد تا پایداری تصمیمات در مواجهه با نوسانات و تخمین‌های نادقیق تضمین گردد. پس از آن، مدل ترکیبی توسعه‌یافته با بهره‌گیری از روش جمع وزنی نرمال‌شده (Normalized Weighted Sum) و الگوریتم ژنتیک حل گردید تا ضمن حفظ قابلیت چندهدفه مدل، کیفیت پاسخ‌ها و سرعت همگرایی بهبود یابد. در نهایت، عملکرد روش‌های حل از نظر دقت، زمان محاسباتی و کیفیت راه‌حل‌ها مورد ارزیابی قرار گرفت و از طریق تحلیل حساسیت، اثر تغییر پارامترهای کلیدی نظیر زمان پردازش و آماده‌سازی بر مقادیر توابع هدف بررسی شد. این توالی گام‌ها موجب شکل‌گیری یک چارچوب منسجم و داده‌محور شد که ضمن پوشش ابعاد پایداری، قابلیت انطباق با شرایط واقعی تولید و بهبود تصمیم‌گیری در محیط‌های پیچیده و نامطمئن را فراهم می‌سازد.

در شکل ۱ به طور خلاصه فرآیند گام‌های پژوهش نمایش داده شده است. به طور کلی مشاهده می‌شود که خروجی‌های روش داده‌محور RFR به عنوان ورودی در روش برنامه‌ریزی فازی استوار برای مقابله با عدم قطعیت و حل مدل استفاده شده است.

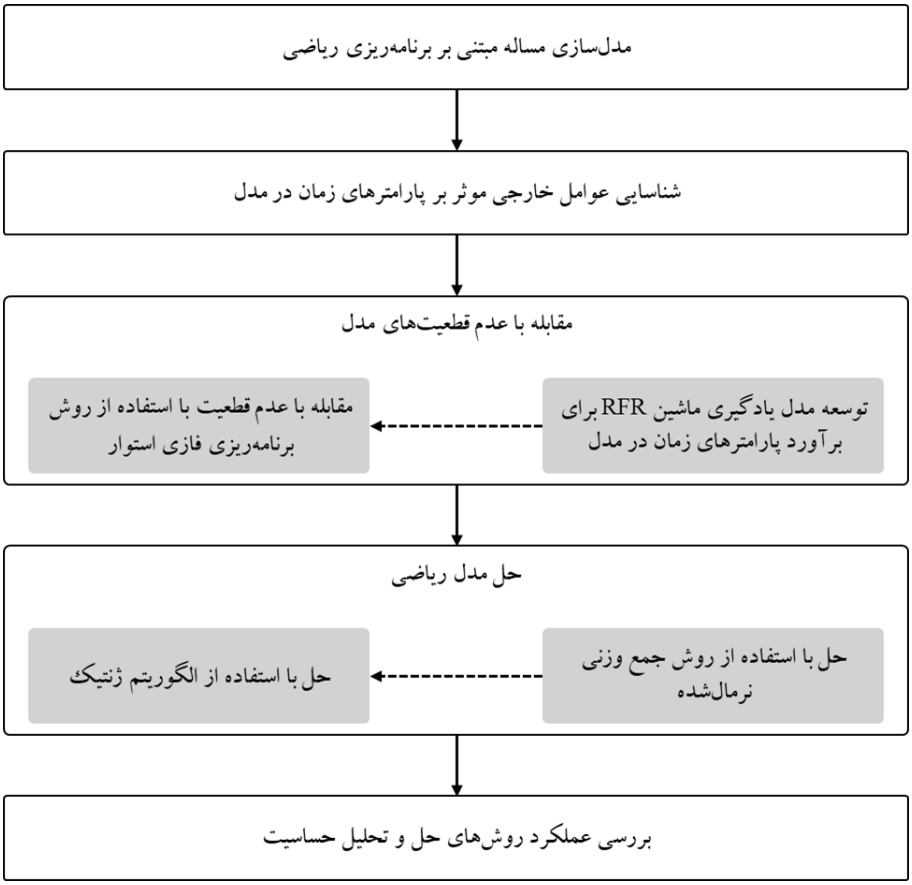


**شکل ۱.** فلوچارت گام‌های پژوهش

## ٦ نتایج عددی

### ٦-١ برآورد پارامترها با RFR

در این بخش، پارامترهای زمانی مهم مدل شامل زمان تکمیل ($\widetilde{Td}_{gjt}$)، زمان آماده‌سازی ($\tilde{S}_{igg't}$) و زمان پردازش ($\widetilde{PT}_{gjit}$) برآورد شده‌اند. این پارامترها تحت تأثیر عوامل مختلفی قرار دارند که در مدل‌سازی رگرسیونی به‌عنوان متغیرهای ورودی در نظر گرفته شده‌اند. عوامل اصلی تأثیرگذار بر زمان شامل موارد زیر هستند:

- تجربه اپراتور: مدت‌زمان فعالیت تخصصی مرتبط با وظیفه موردنظر.
- شیفت کاری: کارخانه در سه شیفت (صبح، عصر، شب) با تقسیم‌بندی به شش بازه زمانی فعالیت می‌کند.
- ابزار مورد استفاده: نوع ماشین‌آلات و ابزار مورد استفاده توسط اپراتور.
- جنسیت اپراتور: به‌عنوان یک عامل تأثیرگذار بر سرعت عملیاتی در نظر گرفته شده است.
- سن اپراتور: سن بر عملکرد حرکتی و زمان اجرای فعالیت‌ها اثر می‌گذارد.
- سطح دشواری کار: میزان سختی یا پیچیدگی کار تولیدی.
- میزان روتین بودن کار: نشان‌دهنده تکراری یا غیرتکراری بودن عملیات.
- شرایط محیط کاری: شامل دما، نور، صدا و کیفیت هوای محیط تولید.

بر اساس داده‌های جمع‌آوری‌شده، یک مدل یادگیری ماشین مبتنی بر الگوریتم جنگل تصادفی رگرسیونی توسعه یافت که هدف آن تخمین دقیق زمان پردازش فعالیت‌ها با استفاده از ویژگی‌های فوق است. این مجموعه داده با الگوگیری از نمونه داده واقعی مستند شده از سازمان مورد مطالعه جمع‌آوری شده است. از این مجموعه داده برای آموزش و تست مدل یادگیری ماشین استفاده شده است که مبتنی بر آن، مقادیر پارامترهای زمانی برآورد شده است. در گام اول، همبستگی میان متغیرهای ورودی تحلیل شد که در شکل ۲ نمایش داده شده است. بر اساس این نمودار، تجربه اپراتور با سن اپراتور و شیفت کاری همبستگی مثبت قوی دارد (به ترتیب ۰/۷۲ و ۰/۶۸)، که بیانگر این است که اپراتورهای باتجربه‌تر معمولاً در شیفت‌های خاص‌تری فعالیت دارند یا سن بالاتری دارند. همچنین، سطح دشواری کار با میزان روتین بودن فعالیت‌ها همبستگی منفی معنادار دارد (ضریب -۰.۶۸)، که منطقی است زیرا کارهای دشوار معمولاً از یکنواختی کمتری برخوردارند. از سوی دیگر، شرایط محیط کاری با برخی متغیرها مانند دشواری کار و روتین بودن، همبستگی ضعیف اما قابل توجهی دارد. به طور کلی روابط خطی شدیدی بین ویژگی‌ها وجود ندارد و از آنجا که از الگوریتم RFR استفاده می‌شود و این الگوریتم روابط خطی را به خوبی مدیریت می‌کند، چالشی در حذف یا ادغام ویژگی‌ها وجود ندارد.

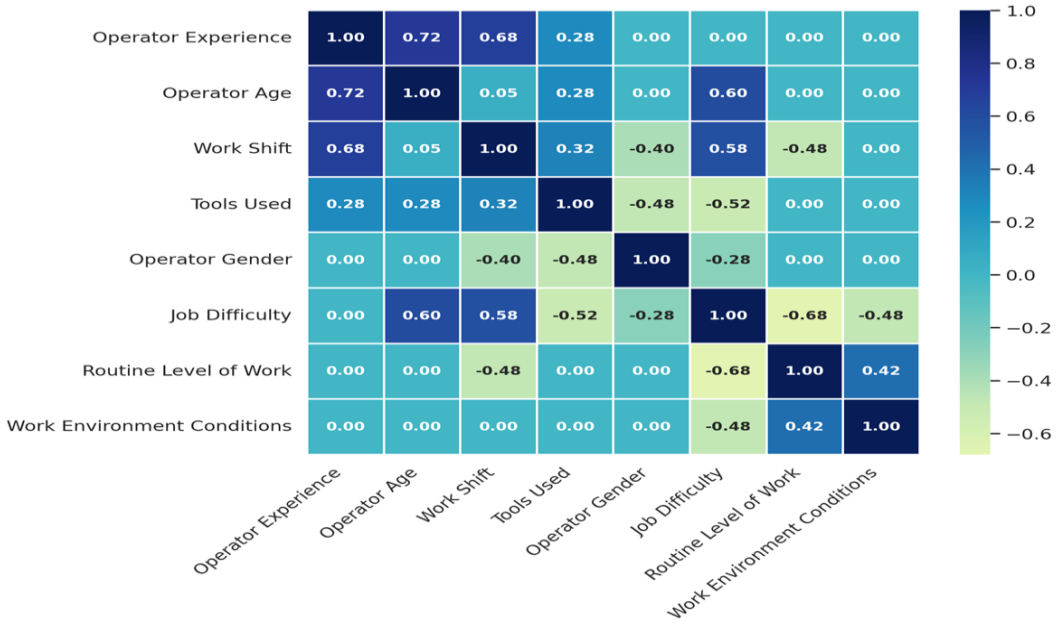


**شکل ۲.** ضریب همبستگی بین ویژگی‌ها

در گام بعد، اهمیت نسبی هر ویژگی در پیش‌بینی زمان نیز محاسبه شد که در شکل ۳ نمایش داده شده است.

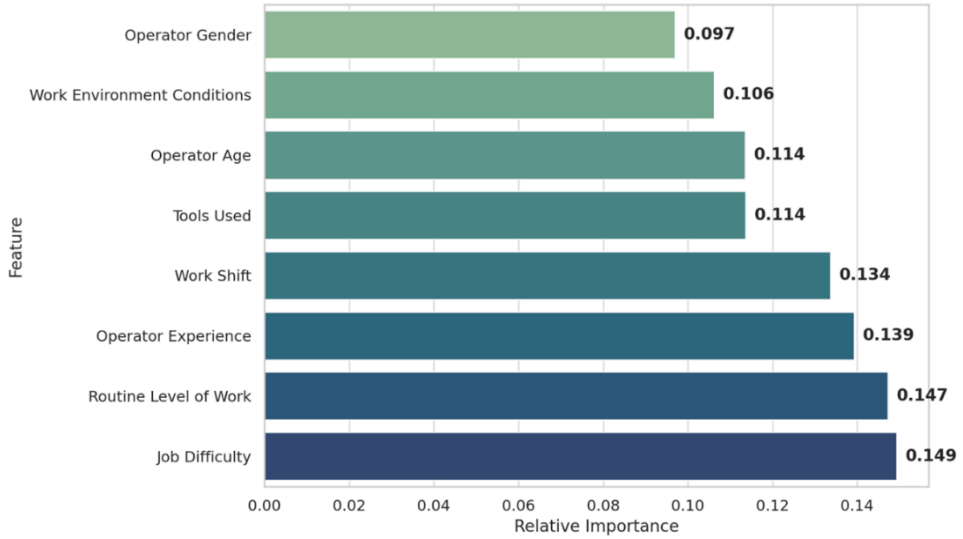


**شکل ۳.** میزان اهمیت ویژگی‌ها

بر اساس نتایج، دشواری فعالیت و میزان روتین بودن کار بیشترین تأثیر را بر زمان پردازش داشته‌اند، که منطقی است زیرا فعالیت‌های پیچیده یا غیرتکراری معمولاً نیازمند زمان بیشتری هستند. همچنین، ویژگی‌هایی مانند تجربه اپراتور، شیفت کاری و ابزار مورد استفاده نیز نقش قابل‌توجهی در مدل ایفا کرده‌اند. در مقابل، جنسیت اپراتور کمترین تأثیر را داشته که می‌تواند بیانگر توزیع یکنواخت عملکرد در بین اپراتورها فارغ از جنسیت باشد. این تحلیل به تصمیم‌گیرندگان کمک می‌کند تا در بهینه‌سازی فرآیند تولید، بر عوامل کلیدی تمرکز کنند.

در ساختار داده‌ها، هر نمونه شامل ویژگی‌های ورودی ذکرشده و برچسب خروجی زمان فعالیت بوده است. برای آموزش مدل RFR، پارامترهای تعداد درخت‌ها[1]، حداکثر عمق[2]، و حداقل تعداد نمونه در برگ‌ها تنظیم شدند. تعداد درخت‌ها بر مقدار ۱۰۰ تنظیم شد تا تعادل مناسبی میان دقت و سرعت فراهم شود. عمق درخت‌ها نیز تا چهار سطح در نظر گرفته شد تا از بیش‌برازش جلوگیری گردد. حداقل تعداد نمونه در برگ‌ها نیز ۵ مورد در نظر گرفته شد. پس از آموزش، مدل توانست زمان فعالیت‌ها را با دقت بالا در قالب اعداد فازی ذوزنقه‌ای برای سناریوهای مختلف (بدبینانه، محتمل، خوشبینانه) برآورد کند.

در جدول ۲ مقدار پارامترهای مرتبط با زمان که خروجی‌های الگوریتم RFR می‌باشد نمایش داده شده است. همانطور که بیان شده بود، سه سناریو مختلف برای برآورد پارامترها در نظر گرفته شد که در هر سناریو مقدار پارامترها به صورت فازی ذوزنقه‌ای برآورد شده‌اند. به طور خلاصه، مقدار فازی هر پارامتر در هر سناریو در جدول ۲ نمایش داده شده است.

[1] n_estimators
[2] max_depth

**جدول ۲.** مقادیر پارامترها برای سه سناریو

| پارامتر | سناریو | مولفه فازی | ارزش |
|---|---|---|---|
| $\widetilde{Td}_{gjt}$ | بدبینانه | $\theta_۱$ | ۹۰/۴۱ |
| | | $\theta_۲$ | ۹۱/۵۲ |
| | | $\theta_۳$ | ۹۳/۸۲ |
| | | $\theta_٤$ | ۹۶/۱۲ |
| | محتمل | $\theta_۱$ | ۸۱/۱۱ |
| | | $\theta_۲$ | ۸۲/۴۱ |
| | | $\theta_۳$ | ۸۳/۴۲ |
| | | $\theta_٤$ | ۸۴/۵۱ |
| | خوش‌بینانه | $\theta_۱$ | ۷۱/۲۶ |
| | | $\theta_۲$ | ۷۲/۳۴ |
| | | $\theta_۳$ | ۷۴/۶۵ |
| | | $\theta_٤$ | ۷۵/۹۵ |
| $\tilde{S}_{igg't}$ | بدبینانه | $\theta_۱$ | ۱۲۲/۴۷ |
| | | $\theta_۲$ | ۱۲۴/۷۴ |
| | | $\theta_۳$ | ۱۲۶/۳۴ |
| | | $\theta_٤$ | ۱۲۸/۱۵ |
| | محتمل | $\theta_۱$ | ۱۱۷/۵۶ |
| | | $\theta_۲$ | ۱۱۸/۵۸ |
| | | $\theta_۳$ | ۱۱۹/۴۷ |
| | | $\theta_٤$ | ۱۲۰/۸۲ |
| | خوش‌بینانه | $\theta_۱$ | ۱۱۱/۳۵ |
| | | $\theta_۲$ | ۱۱۴/۵۲ |
| | | $\theta_۳$ | ۱۱۶/۵۸ |
| | | $\theta_٤$ | ۱۱۷/۹۸ |
| $\widetilde{PT}_{gjit}$ | بدبینانه | $\theta_۱$ | ۱۵۷/۲۵ |
| | | $\theta_۲$ | ۱۵۹/۶۵ |
| | | $\theta_۳$ | ۱۶۱/۳۱ |
| | | $\theta_٤$ | ۱۶۳/۴۸ |
| | محتمل | $\theta_۱$ | ۱۳۲/۳۲ |
| | | $\theta_۲$ | ۱۳۳/۴۸ |
| | | $\theta_۳$ | ۱۳۴/۰۸ |
| | | $\theta_٤$ | ۱۳۵/۶۴ |
| | خوش‌بینانه | $\theta_۱$ | ۱۲۷/۱۵ |
| | | $\theta_۲$ | ۱۲۸/۴۱ |
| | | $\theta_۳$ | ۱۲۹/۳۵ |
| | | $\theta_٤$ | ۱۳۰/۱۸ |

## ۶-۲ بررسی عملکرد روش حل مدل

برای ارزیابی عملکرد روش ترکیبی تشریح شده، در این بخش، عملکرد آن را با روش سنتی (مجموع وزنی نرمالیزه شده) مقایسه می‌کنیم. در این راستا، برای ارزیابی عملکرد روش پیشنهادی، دو معیار شناخته شده در این به شرح زیر در نظر گرفته شده است: (۱) زمان حل و (۲) کیفیت راه حل. زمان حل زمان مورد نیاز برای حل مدل را نشان می‌دهد. همچنین کیفیت حل که با عبارت GAP نشان داده می‌شود بر اساس معادله (۱۷) محاسبه می‌شود که در آن $GA - LP_{sol}$ و $LP_{sol}$ به ترتیب نشان دهنده راه حل به دست آمده به دست آمده توسط روش ابتکاری ترکیبی و مجموع وزنی نرمالیزه شده است هستند.

$$GAP = \frac{GA - LP_{sol}}{LP_{sol}} \times ۱۰۰ \qquad (۱۷)$$

جدول ۲ نتایج به دست آمده را نشان می دهد. در این جدول، Z۱، Z۲ و Z۳ به ترتیب توابع هدف اول، دوم و سوم را نشان می دهند. زمان حل نیز برای حل مدل پیشنهادی با استفاده از روش بکار گرفته شده مورد نیاز است. همچنین جدول ۳ مقادیر GAP ها را نشان می دهد. در این جدول GAP۱ انحراف نسبی تابع هدف اول، GAP۲ انحراف نسبی تابع هدف دوم و GAP۳ انحراف نسبی تابع هدف سوم را نشان می دهد. بر اساس جداول ۳ و ۴، رویکرد حل ارایه شده می‌تواند در یک زمان معقول به راه‌حل‌های نزدیک به بهینه و بهینه برسد. برای درک بهتر، شکل ۴ عملکرد روش توسعه یافته و رویکرد سنتی را بر اساس معیار زمان حل مقایسه می‌کند. همچنین، شکل ۴ عملکرد روش توسعه یافته بر اساس معیار GAP را نشان می‌دهد. در مجموع، نتایج به‌دست‌آمده نشان می‌دهد که رویکرد توسعه‌یافته از عملکرد مناسبی برخوردار است.

**جدول ۳.** مقایسه پاسخ‌های به دست آمده از حل مدل با ترکیبی (ترکیب الگوریتم ژنتیک و روش مجموع وزنی نرمال‌شده) و روش وزنی نرمال شده به تنهایی

| مساله | روش ابتکاری ترکیبی | | | | مجموع وزنی نرمالیزه شده | | | |
|---|---|---|---|---|---|---|---|---|
| | Z۱ | Z۲ | Z۳ | زمان حل | Z۱ | Z۲ | Z۲ | زمان حل |
| ۱ | ۳۴۸/۵۳ | ۲۱/۸۴ | ۱۷۵/۲۱ | ۳۸/۲۹ | ۳۴۸/۵۳ | ۲۱/۸۰ | ۱۷۵/۱۹ | ۳۲/۵۵ |
| ۲ | ۳۰۵/۰۳ | ۲۴/۰۶ | ۱۹۸/۴۶ | ۵۶/۵۴ | ۳۰۵/۰۳ | ۲۴/۰۶ | ۱۹۸/۴۶ | ۶۵/۳۵ |
| ۳ | ۲۹۳/۵۰ | ۲۶/۴۹ | ۲۲۴/۹۵ | ۸۰/۷۳ | ۲۹۳/۵۴ | ۲۶/۴۹ | ۲۲۴/۹۵ | ۱۷۰/۸۵ |
| ۴ | ۲۶۷/۷۵ | ۲۹/۲۲ | ۲۵۴/۸۴ | ۱۰۹/۱۸ | ۲۶۷/۸۰ | ۲۹/۲۲ | ۲۵۴/۸۴ | ۳۹۱/۵۵ |
| ۵ | ۴۰۸/۳۸ | ۳۲/۲۵ | ۲۸۸/۸۴ | ۱۴۹/۱۷ | ۴۰۸/۴۶ | ۳۲/۲۵ | ۲۸۸/۷۴ | ۹۶۲/۱۵ |
| ۶ | ۳۴۴/۹۹ | ۳۵/۵۶ | ۳۲۷/۲۶ | ۲۱۷/۶۰ | ۳۴۵/۰۵ | ۳۵/۵۹ | ۳۲۷/۱۶ | ۲۹۴۹/۳۵ |
| ۷ | ۵۱۴/۷۴ | ۳۹/۲۳ | ۳۷۰/۷۳ | ۳۱۹/۴۱ | ۵۱۴/۸۵ | ۳۹/۲۳ | ۳۷۰/۶۳ | ۶۸۷۲/۰۵ |
| ۸ | ۳۸۷/۳۶ | ۴۳/۲۷ | ۴۲۰/۰۷ | ۵۳۳/۵۵ | ۳۸۷/۴۵ | ۴۳/۲۷ | ۴۱۹/۹۷ | ۱۰۹۶۰/۰۵ |
| ۹ | ۵۸۱/۹۵ | ۴۷/۸۲ | ۴۷۶/۰۸ | ۷۳۱/۰۱ | ۵۸۲/۰۹ | ۴۷/۷۲ | ۴۷۵/۸۸ | ۱۷۰۸۳/۲۵ |
| ۱۰ | ۴۵۳/۹۰ | ۵۲/۶۷ | ۵۳۹/۳۷ | ۹۲۲/۹۷ | ۴۵۴/۰۲ | ۵۲/۶۷ | ۵۳۹/۱۷ | ۲۱۲۹۳/۹۵ |
| ۱۱ | ۵۶۸/۷۴ | ۵۸/۵۴ | ۵۹۸/۷۱ | ۱۱۵۹/۷۵ | - | - | - | >۲۵۰۰۰ |
| ۱۲ | ۷۱۲/۶۳ | ۶۴/۹۱ | ۶۶۴/۵۳ | ۱۳۳۹/۴۵ | - | - | - | >۲۵۰۰۰ |

**جدول ٤.** بررسی عملکرد الگوریتم ترکیبی بر مبنای معیار کیفیت پاسخ‌ها

| مساله | GAP۱ | GAP۲ | GAP۳ |
|---|---|---|---|
| ۱ | ۰ | ۰ | ۰ |
| ۲ | ۰ | ۰ | ۰ |
| ۳ | ۰/۰۱۴۲۶ | ۰/۰۲۳۷۷ | ۰/۰۱۹۰۲ |
| ۴ | ۰/۰۱۷۴۳ | ۰/۰۲۵۳۶ | ۰/۰۲۲۱۹ |
| ۵ | ۰/۰۱۹۰۲ | ۰/۰۲۶۹۴ | ۰/۰۲۵۳۶ |
| ۶ | ۰/۰۱۷۴۳ | ۰/۰۲۵۳۶ | ۰/۰۲۲۱۹ |
| ۷ | ۰/۰۲۲۱۹ | ۰/۰۲۸۵۳ | ۰/۰۲۵۳۶ |
| ۸ | ۰/۰۲۰۶ | ۰/۰۳۰۱۱ | ۰/۰۲۸۵۳ |
| ۹ | ۰/۰۲۳۷۷ | ۰/۰۳۳۲۸ | ۰/۰۳۴۸۶ |
| ۱۰ | ۰/۰۲۵۳۶ | ۰/۰۳۹۶۲ | ۰/۰۳۸۰۳ |

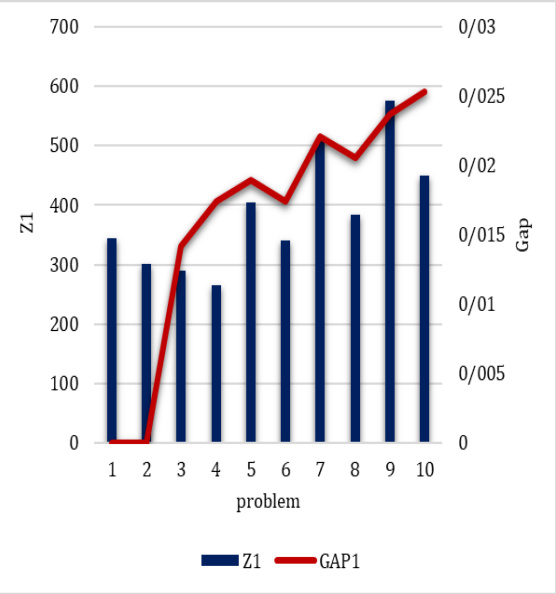


**(الف) تابع هدف اول**

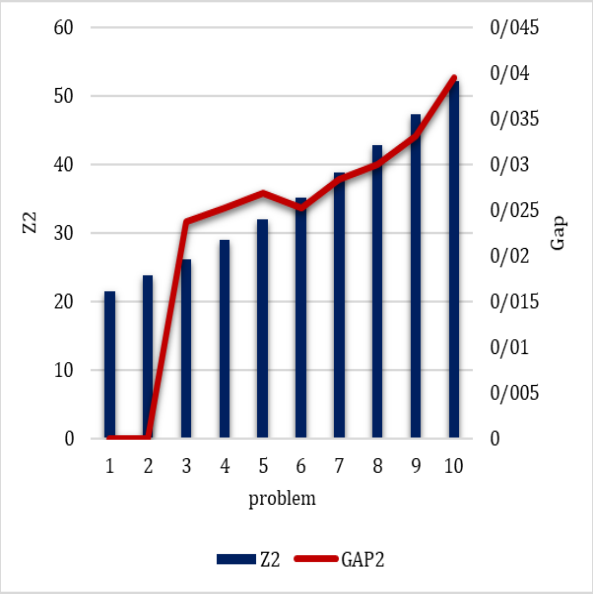


**(ب) تابع هدف دوم**

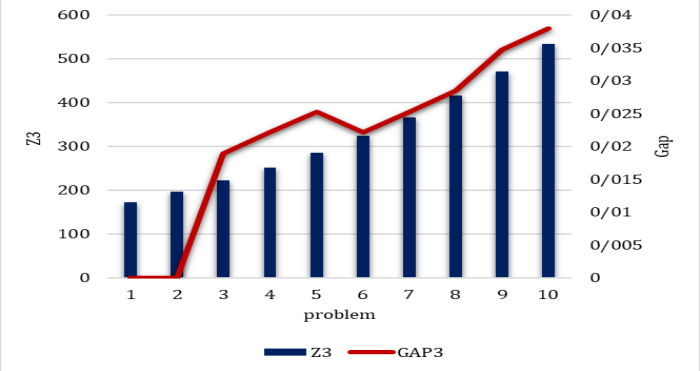


**ج) تابع هدف سوم**

**شکل ٤.** تحلیل عملکرد روش پیشنهادی بر مبنای معیار کیفیت پاسخ‌ها

### ٦-٣ بررسی عملکرد الگوریتم RFR در برآورد پارامترها

برای ارزیابی دقت و کارایی الگوریتم جنگل تصادفی رگرسیونی در پیش‌بینی پارامترهای زمانی مرتبط با فعالیت‌های تولیدی، از سه معیار ارزیابی متداول شامل ریشه میانگین مربعات خطا[1]، میانگین قدر مطلق خطا[2] و ضریب تعیین[3] استفاده شد. پس از آموزش و تست مدل بر روی مجموعه داده‌ی مورد استفاده، نتایج نشان داد که مقدار RMSE برابر با ۷/۴۶، مقدار MAE برابر با ۵/۱۳ و مقدار $R^2$ معادل ۰/۹۱ به‌دست آمده است. این نتایج حاکی از عملکرد دقیق و پایدار مدل در برآورد مقادیر زمانی هستند و بیانگر آن است که بیش از ۹۱ درصد از واریانس متغیر وابسته توسط مدل قابل توضیح است.

براساس تحلیل خروجی مدل، می‌توان نتیجه گرفت که الگوریتم RFR توانسته است به‌صورت مؤثر روابط پیچیده و غیربخطی میان ویژگی‌های تأثیرگذار (نظیر تجربه اپراتور، شیفت کاری، دشواری فعالیت و ...) و زمان اجرای عملیات را شناسایی نماید. مقدار نسبتاً پایین RMSE و MAE نشان‌دهنده‌ی خطای پیش‌بینی محدود و قابل‌قبول در سطوح مختلف داده‌ها بوده و مقدار بالای $R^2$ نشان می‌دهد که مدل از قدرت پیش‌بینی بالایی برخوردار است. این عملکرد مطلوب، الگوریتم جنگل تصادفی را به گزینه‌ای مناسب برای تخمین پارامترهای کلیدی در مسایل زمان‌بندی تولید تحت شرایط عدم‌قطعیت تبدیل کرده و زمینه را برای اتخاذ تصمیم‌های داده‌محور و دقیق فراهم می‌سازد.

### ٦-٤ تحلیل حساسیت

#### ٦-٤-١ زمان پردازش

برای ارزیابی رفتار خروجی‌ها با تغییر پارامتر زمان پردازش، در این بخش به تحلیل حساسیت پرداخته شده است. برای این منظور، مدل پیشنهادی با در نظر گرفتن مقادیر مختلف برای پارامتر زمان پردازش حل شده است. نتایج تجزیه و تحلیل حساسیت توابع هدف مساله در شکل ۵ ارایه شده است. همانطور که در این شکل مشاهده می شود، افزایش قابل توجهی در Z۱ با افزایش زمان پردازش مشاهده شده است. بر اساس نتاسج، تابع هدف دوم با افزایش پارامتر زمان پردازش به طور قابل توجهی افزایش یافته است. نتایج به دست آمده مطابق شکل ۵ نشان می دهد که تابع هدف سوم با افزایش زمان پردازش افزایش یافته است.

[1] RMSE
[2] MAE
[3] $R^2$

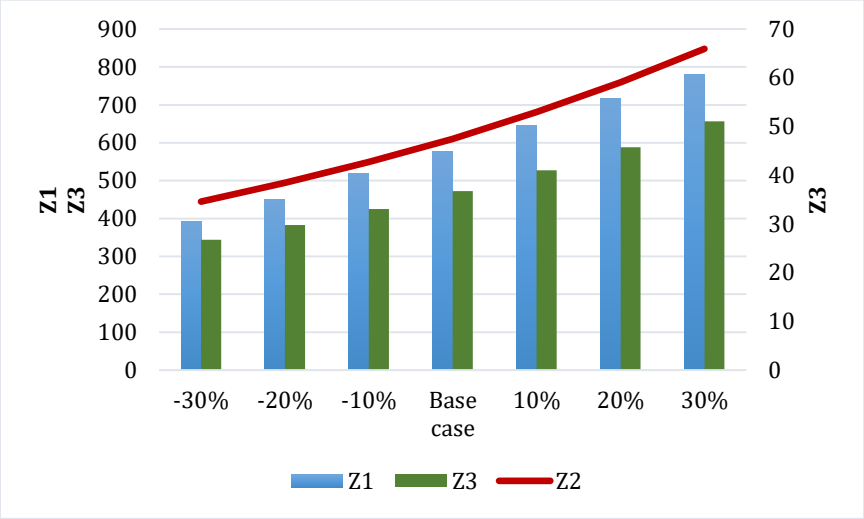


**شکل ۵.** تحلیل حساسیت مساله نسبت به پارامتر زمان پردازش

## ٦-٤-٢ زمان راه‌اندازی

در این قسمت به بررسی نقش پارامتر زمان راه اندازی در نتایج می پردازیم. به این ترتیب مدل پیشنهادی با در نظر گرفتن مقادیر مختلف برای زمان راه اندازی حل شده است. نتایج به دست آمده در شکل ۶ نشان داده شده است. این شکل نشان می دهد که تمامی توابع هدف با افزایش پارامتر مذکور افزایش یافته‌اند.

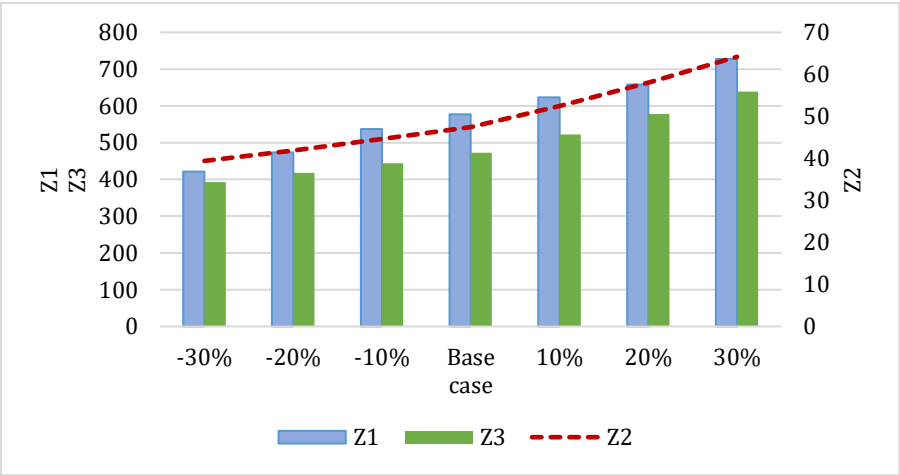


**شکل ٦.** تحلیل حساسیت مساله نسبت به پارامتر زمان راه‌اندازی

## ۷ بینش‌های مدیریتی و نتیجه‌گیری

در این بخش، نتایج کلیدی حاصل از پژوهش حاضر مرور شده و بر اساس تحلیل‌های انجام‌شده، بینش‌هایی کاربردی برای مدیران تولید ارایه می‌گردد. همچنین، محدودیت‌های پژوهش و مسیرهای پیشنهادی برای توسعه مطالعات آینده بیان می‌شود.

## ۷-۱ بینش‌های مدیریتی

تحلیل‌های صورت‌گرفته در این تحقیق حاکی از آن است که برخی ویژگی‌های فردی و محیطی از جمله تجربه اپراتور، شیفت کاری، و سطح دشواری فعالیت‌ها نقش کلیدی در تعیین زمان اجرای عملیات دارند. بنابراین، پیشنهاد می‌شود مدیران با طراحی سیاست‌هایی در جهت حفظ و ارتقاء اپراتورهای باتجربه، ایجاد تعادل در توزیع شیفت‌ها، و تطابق وظایف با توانایی‌های پرسنل، بهره‌وری سازمان را ارتقاء دهند.

همچنین، نتایج مدل یادگیری ماشین نشان داد که استفاده از ابزارهای دیجیتال برای پیش‌بینی و برنامه‌ریزی می‌تواند عدم‌قطعیت‌های عملیاتی را کاهش داده و قابلیت واکنش سریع‌تری برای برنامه‌ریزی تولید فراهم آورد. در این راستا، استفاده از تعمیرات پیش‌بینانه، بهره‌گیری از سیستم‌های داده‌محور و سرمایه‌گذاری در تحول دیجیتال، راهکارهایی هستند که به پایداری عملیاتی، کاهش توقفات تولید و افزایش سودآوری منجر خواهند شد. در کنار آن، تلفیق فناوری‌های سبز با فرآیندهای تولید نه تنها مزیت رقابتی ایجاد می‌کند، بلکه فرصت بهره‌مندی از حمایت‌های دولتی و جذب مشتریان حساس به مسایل زیست‌محیطی را نیز فراهم می‌سازد.

## ۷-۲ نتیجه‌گیری

در این مطالعه، یک چارچوب تصمیم‌گیری داده‌محور برای مساله زمان‌بندی جریان کارگاهی انعطاف‌پذیر با لحاظ نگهداری پیشگیرانه و ابعاد زیست‌محیطی توسعه داده شد. مدل ریاضی پیشنهادی به‌صورت چندهدفه تدوین گردید و اهداف شامل کمینه‌سازی تأخیر، انتشار گازهای گلخانه‌ای و مصرف انرژی بود. برای مدیریت عدم‌قطعیت، از ترکیب رویکرد بهینه‌سازی فازی و الگوریتم جنگل تصادفی رگرسیونی استفاده شد. همچنین به‌منظور حل کارای مدل در زمان معقول، یک الگوریتم ترکیبی شامل برنامه‌ریزی هدفمند فازی و روش ابتکاری طراحی گردید.

نتایج عددی نشان دادند که روش پیشنهادی قادر است راه‌حل‌هایی با کیفیت بالا در زمان مناسب ارایه دهد و نسبت به رویکردهای سنتی عملکرد بهتری داشته باشد. تحلیل حساسیت نیز نشان داد که با افزایش پارامترهای زمانی مانند زمان پردازش و زمان آماده‌سازی، مقادیر توابع هدف افزایش می‌یابد، که تأکیدی است بر اهمیت بهینه‌سازی این پارامترها در تصمیم‌گیری‌های برنامه‌ریزی تولید.

## ۷-۳ محدودیت‌ها و پیشنهادهای پژوهشی آتی

علیرغم دستاوردهای قابل توجه این پژوهش، محدودیت‌هایی نیز وجود دارد که زمینه‌ساز توسعه مطالعات آتی خواهد بود:

- نخست، مدل ارایه شده تنها در فضای عدم‌قطعیت فازی توسعه یافته و سایر انواع عدم‌قطعیت همچون ترکیبی (سناریو-فازی) یا احتمالی لحاظ نشده‌اند. پیشنهاد می‌شود در پژوهش‌های آتی از رویکردهایی مانند برنامه‌ریزی تصادفی-امکانی بهره‌گیری شود.

- دوم، تمرکز این مطالعه تنها بر ابعاد زیست‌محیطی بوده و ابعاد دیگری همچون مسئولیت اجتماعی، تولید بدون انتظار[1] و قابلیت اطمینان انسانی در مدل وارد نشده‌اند. افزودن این ابعاد می‌تواند مدل را به‌صورت جامع‌تری به واقعیت‌های تولید نزدیک کند.
- در نهایت، الگوریتم حل توسعه‌یافته راه‌حل‌های نزدیک به بهینه ارایه می‌دهد. به‌منظور رسیدن به جواب‌های بهینه جهانی، استفاده از روش‌های دقیق مانند تجزیه بندرز[2] یا روش شاخه و قیمت‌گذاری[3] در مطالعات آینده توصیه می‌شود.
- اضافه کردن سایر محدودیت‌ها مانند در نظر گرفتن انقطاع در کارها و انعطاف‌پذیر بودن سیستم تولیدی به مساله فعلی نیز می‌تواند مسیری برای تحقیقات آتی باشد.

## منابع


[1] Goli, A., Ala, A., Hajiaghaei-Keshteli, M. (2023). Efficient multi-objective meta-heuristic algorithms for energy-aware non-permutation flow-shop scheduling problem. Expert Systems with Applications, 2023(213), 1-13.

[2] Yu, F., Lu, C., Zhou, J., Yin, L. (2024). Mathematical model and knowledge-based iterated greedy algorithm for distributed assembly hybrid flow shop scheduling problem with dual-resource constraints. Expert Systems with Applications, 2024(239), 122434.

[3] Li, M., Wang, G.-G. (2022). A review of green shop scheduling problem. Information Sciences, 2022(589), 478–496.

[4] Ghanavati Nejad, M., Tavakoli, M., Sheikhalishahi, M., Aydın, N., Aria, S. S. (2025). An integrated smart framework for fast-moving consumer goods online market logistics: A digital twin framework. Journal of Industrial and Production Engineering, 2025(42), 1–17.

[5] Gong, Q., Li, J., Jiang, Z., Wang, Y. (2024). A hierarchical integration scheduling method for flexible job shop with green lot splitting. Engineering Applications of Artificial Intelligence, 2024(129), 1-16.

[6] Tajally, A., Vamarzani, M. Z., Ghanavati-Nejad, M., Zeynali, F. R., Abbasian, M., Bahengam, A. (2025). A hybrid machine learning-based decision-making model for viable supplier selection problem considering circular economy dimensions. Environment, Development and Sustainability, 2025(27), 1–33.

[7] Xiao, Y., Konak, A. (2017). A genetic algorithm with exact dynamic programming for the green vehicle routing and scheduling problem. Journal of Cleaner Production, 2017(167), 1450–1463.

[8] Rostami, O., Tavakoli, M., Tajally, A., Ghanavati Nejad, M. (2023). A goal programming-based fuzzy best–worst method for the viable supplier selection problem: A case study. Soft Computing, 2023(27), 2827–2852.

[9] Perez-Gonzalez, P., Framinan, J. M. (2024). A review and classification on distributed permutation flowshop scheduling problems. European Journal of Operational Research, 2024(312), 1–21.

[10] Fekri, M., Heydari, M., Mazdeh, M. M. (2024). Bi-objective optimization of flexible flow shop scheduling problem with multi-skilled human resources. Engineering Applications of Artificial Intelligence, 2024(133), 1-17.

[11] Shao, W., Shao, Z., Pi, D. (2021). Effective constructive heuristics for distributed no-wait flexible flow shop scheduling problem. Computers & Operations Research, 2021(136), 105482.

[12] Wang, J., Miao, Y. (2021). Optimal preventive maintenance policy of the balanced system under the semi-Markov model. Reliability Engineering & System Safety, 2021(213), 1-21.

[13] Shi, Y., Lu, Z., Huang, H., Liu, Y., Li, Y., Zio, E., Zhou, Y. (2022). A new preventive maintenance strategy optimization model considering lifecycle safety. Reliability Engineering & System Safety, 2022(221), 108325.


[1] No-Wait
[2] Benders Decomposition
[3] Branch and Price

[14] Tirkolaee, E. B., Mardani, A., Dashtian, Z., Soltani, M., Weber, G.-W. (2020). A novel hybrid method using fuzzy decision making and multi-objective programming for sustainable-reliable supplier selection in two-echelon supply chain design. Journal of Cleaner Production, 2020(250), 1-19.
[15] Wang, Y., Xie, N. (2021). Flexible flow shop scheduling with interval grey processing time. Grey Systems: Theory and Application, 2021(11), 779–795.
[16] Qin, H.-X., Han, Y.-Y., Zhang, B., Meng, L.-L., Liu, Y.-P., Pan, Q.-K., Gong, D.-W. (2022). An improved iterated greedy algorithm for the energy-efficient blocking hybrid flow shop scheduling problem. Swarm and Evolutionary Computation, 2022(69), 1-17.
[17] Zhao, F., Shao, D., Wang, L., Xu, T., Zhu, N. (2022). An effective water wave optimization algorithm with problem-specific knowledge for the distributed assembly blocking flow-shop scheduling problem. Knowledge-Based Systems, 2022(243), 108471.
[18] Seyedhamzeh, M., Amoozad Khalili, H., Hosseini, S. M. H., Honarmand Azimi, M., Rahmani, K. (2022). Investigating the two-stage assembly flow shop scheduling problem with uncertain assembling times. *Journal of Industrial Systems Engineering, 2022(14), 245–267.
[19] Castaneda, J., Martin, X. A., Ammouriova, M., Panadero, J., Juan, A. A. (2022). A fuzzy simheuristic for the permutation flow shop problem under stochastic and fuzzy uncertainty. Mathematics, 2022(10), 1760.
[20] Wang, Y.-J., Wang, G.-G., Tian, F.-M., Gong, D.-W., Pedrycz, W. (2023). Solving energy-efficient fuzzy hybrid flow-shop scheduling problem at a variable machine speed using an extended NSGA-II. Engineering Applications of Artificial Intelligence, 2023(121), 1-14.
[21] Li, X., Xu, Y., Zhang, X., Shi, W., Yue, Y., Li, Q. (2023). Improving short-term bike sharing demand forecast through an irregular convolutional neural network. Transportation Research Part C: Emerging Technologies, 2023(147), 1-15.
[22] Hassani, H., Hosseini, S. M. (2023). Green scheduling in a flexible flow shop environment with machine-dependent processing stages, machine accessibility limitations, and job release times. Journal of Operations Research and Its Applications, 2023(20), 25–47. (In Persian)
[23] Nikooei, M., Amiri, M. (2022). Application of design of experiments and fuzzy multi-criteria decision-making methods in determining the optimal reliability model of a two-stage assembly flow shop system. Journal of Operations Research and Its Applications, 2022(19), 45–62. (In Persian)
[24] Akhgar, M., Fattahi, P., Noori, V., Rohani, B. (2025). Mathematical modeling and solving the flow shop scheduling problem in a production system with reconfigurable material handling. Journal of Industrial Engineering Research in Production Systems, 2025(12), 155–167. (In Persian)
[25] Khaksari, P., Gheandi Bidgoli, G. (2024). Mathematical modeling and solving the no-wait flow shop scheduling problem considering release times and preventive maintenance activities. Journal of Industrial Engineering Research in Production Systems, 2024(11), 39–55. (In Persian)
[26] Mamashli, Z., Javadian, N. (2020). Sustainable design modifications municipal solid waste management network and better optimization for risk reduction analyses. Journal of Cleaner Production, 2020(276), 1-23.
[27] Nayeri, S., Paydar, M. M., Asadi-Gangraj, E., Emami, S. (2020). Multi-objective fuzzy robust optimization approach to sustainable closed-loop supply chain network design. Computers & Industrial Engineering, 2020(148), 106716.
[28] Han, S., Kim, H. (2021). Optimal feature set size in random forest regression. Applied Sciences, 2021(11), 1-17.
[29] Ładyżyński, P., Żbikowski, K., Gawrysiak, P. (2019). Direct marketing campaigns in retail banking with the use of deep learning and random forests. Expert Systems with Applications, 2019(134), 28–35.
[30] Javan-Molaei, B., Tavakkoli-Moghaddam, R., Ghanavati-Nejad, M., Asghari-Asl, A. (2024). A data-driven robust decision-making model for configuring a resilient and responsive relief supply chain under mixed uncertainty. Annals of Operations Research, 2024(335), 1–38.
[31] Sazvar, Z., Zokaee, M., Tavakkoli-Moghaddam, R., Salari, S. A., Nayeri, S. (2022). Designing a sustainable closed-loop pharmaceutical supply chain in a competitive market considering demand uncertainty, manufacturer's brand and waste management. Annals of Operations Research, 2022(315), 2057–2088.
[32] Gholizadeh, H., Fazlollahtabar, H., Fathollahi-Fard, A. M., Dulebenets, M. A. (2024). Preventive maintenance for the flexible flowshop scheduling under uncertainty: A waste-to-energy system (Retracted). Environmental Science and Pollution Research, 2024(31), 1-19.